

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



“Melhoramento de previsão de potência eólica a curto prazo
com recurso a técnicas de assimilação de dados”


Rodrigo Aparício Cardoso de Matos

Dissertação

Mestrado Integrado em Engenharia da Energia e Ambiente

(2016)

UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA



LISBOA

UNIVERSIDADE
DE LISBOA

“Melhoramento de previsão de potência eólica a curto prazo
com recurso a técnicas de assimilação de dados”

Rodrigo Aparício Cardoso de Matos

Dissertação

Mestrado Integrado em Engenharia da Energia e Ambiente

Trabalho realizado sob a supervisão de:

Orientador interno Doutor Carlos Alberto Leitão Pires (FCUL, IDL)

Orientador externo Mestre Rui José Oliveira Nóbrega Pestana (REN, Divisão do Sistema)

(2016)

A presente tese encontra-se escrita segundo o antigo acordo ortográfico.

ABSTRACT

This thesis presents an online statistical model that uses refreshment of data using a SCADA (Supervisory Control and Data Acquisition) system. The developed model is a combination of MOS (Model Output Statistics) and EMOS (Ensemble Model Output Statistics). The data used was collected from 1/1/2011 to 31/12/2011 and from 1/2/2012 to 30/4/2012. The algorithm uses data of persistence and power predicted for mainland Portugal. To obtain data of wind power prediction REN (Redes Energéticas Nacionais) uses data from NWP (Numerical Weather Prediction) models, SCADA data, downscaling model and upscaling model. The algorithm developed is a three step combination procedure that was developed to reduce the error of wind power prediction for mainland Portugal. The first step, is composed by MOS model. The MOS model uses a combination of moving average, Pearson coefficient of correlation, adaptive bias prediction to reduce the error of the initial data. The second step is the first step of EMOS model, in this step a wide range of wind power predictions is determined. This is accomplished using a combination of methods: stepwise linear regression, simple and multiple linear regression and Kalman Filter as well as varying the models calibration period. The third step is the last step of EMOS model. The third step uses MIX model a variation of B.I. Tracking (Best Intersection point Tracking) method to aggregate the various models used by the second step to produce a final prediction optimal for every time-step. The algorithm generated a final prediction that was compared with REN's final prediction for an independent time series. The developed algorithm obtained an improvement value over REN model for the time horizon: 00-06 hours, of 20.03% for NMAE (Normalized Mean Absolute Error), of 24.93% for NRMSE (Normalized Root Mean Square Error), of 24.54% for NSDE (Normalized Standard Deviation Error); 06-12 hours, of 29.03% for NMAE, of 31.03% for NMRSE, of 27.05% for NSDE; 12-18 hours, of 32.95% for NMAE, of 34.26% for NMRSE, of 31.57% for NSDE; 18-24 hours, of 17.71% for NMAE, of 18.96% for NMRSE, of 17.05% for NSDE.

RESUMO

Esta dissertação apresenta um modelo de tratamento estatístico *online* com recurso a actualização de dados SCADA (Supervisory Control and Data Acquisition) composto por um módulo MOS (*Model Output Statistics*) e um módulo EMOS (*Ensemble Model Output Statistics*). Os dados utilizados pertencem ao período de 1/1/2011 a 31/12/2011 e de 1/2/2012 a 30/4/2012. O algoritmo recorre a dados de persistência e a dados de potência eólica prevista para Portugal continental. Estes foram cedidos pela REN (Redes Energéticas Nacionais), sendo calculados com recurso a modelos numéricos de previsão do tempo, dados de SCADA, modelos de conversão de potência um módulo de downscaling e um módulo de upscaling. O algoritmo desenvolvido é composto por três fases distintas tendo como objectivo melhorar as previsões de potência eólica. A primeira fase corresponde ao módulo MOS. É neste módulo que se reduz o erro associado às várias previsões de base de forma individual com recurso aos métodos coeficiente de correlação de Pearson, média móvel e previsão adaptativa do viés. A segunda fase corresponde á primeira fase do módulo EMOS. É nesta fase que é efectuado um espectro de previsões. Isto é efectuado utilizando diferentes métodos, entre os quais regressões linear simples e múltipla, filtro de Kalman, regressão linear passo a passo, e distintos períodos de calibração. A terceira fase é a última fase do módulo EMOS, nesta fase é escolhido o melhor modelo para um determinado *time-step*, sendo isto efectuado com recurso ao modelo MIX uma variação do método *B.I. Tracking* (*Best Intersection point Tracking*). O modelo desenvolvido foi comparado ao modelo REN num período independente tendo obtido melhorias para os horizontes temporais: 00-06 horas, 20.03% para NMAE (Normalized Mean Absolute Error), de 24.93% para NRMSE (Normalized Root Mean Square Error), de 24.54% para NSDE (Normalized Standard Deviation Error); 06-12 horas, 29.03% para NMAE, de 31.03% para NMRSE, de 27.05% para NSDE; 12-18 horas, 32.95% para NMAE, de 34.26% para NMRSE, de 31.57% para NSDE; 18-24 horas, 17.71% para NMAE, de 18.96% para NMRSE, de 17.05% para NSDE.

PALAVRAS-CHAVE:

WIND POWER FORECAST, KALMAN FILTER, STATISTICAL FORECAST REGRESSION, STEPWISE REGRESSION, B.I.TRACKING, MODEL OUTPUT STATISTICS, ENSEMBLE MODEL OUTPUT STATISTICS
PREVISÃO DE POTÊNCIA EÓLICA, FILTRO KALMAN, PREVISÃO POR REGRESSÃO ESTATÍSTICA, B.I.TRACKING, MODELOS DE TRATAMENTO DE DADOS, COMBINAÇÃO ESTATÍSTICA DE PREVISÕES

AGRADECIMENTOS

Gostaria de agradecer aos meus pais, avós e família pela compreensão e apoio até esta fase da vida. Quero também agradecer a todos os amigos e conhecidos pelo apoio e com quem troquei ideias relacionadas com esta dissertação.

Por outro lado gostaria de agradecer ao Prof. Doutor Pedro Miranda pelo contacto estabelecido inicialmente com o Eng. Rui Pestana o que permitiu o desenvolvimento da presente dissertação. Também não poderia deixar de agradecer aos orientadores da presente dissertação (Prof. Carlos Pires e Eng. Rui Pestana) pelas contribuições feitas ao longo da elaboração desta tese já que sem eles esta não seria possível. Gostaria de agradecer ao Eng. Rui Pestana que em nome da REN cedeu os dados utilizados já que sem estes não seria também possível realizar a presente tese.

Por último gostaria de dedicar esta dissertação ao meu avô que faleceu no meio do processo de elaboração da presente dissertação.

ÍNDICE

ABSTRACT	i
RESUMO	i
PALAVRAS-CHAVE:.....	ii
AGRADECIMENTOS	iii
ÍNDICE	iv
LISTA DE TABELAS	viii
LISTA DE FIGURAS	xiv
LISTA DE ACRÓNIMOS, SIGLAS E ABREVIATURAS	xviii
LISTA DE SIMBOLOS	xxi
1. INTRODUÇÃO.....	1
2. ENQUADRAMENTO	3
2.1 METAS 2020-UNIÃO EUROPEIA.....	3
2.2 REN- REDES ENERGÉTICAS DE PORTUGAL, SGPS, S.A.....	3
2.2.1 REN-REDE ELÉCTRICA NACIONAL, S.A.	3
3. ENQUADRAMENTO TEÓRICO	4
3.1 REVISÃO LITERÁRIA.....	6
3.2 PREVISAO DE POTÊNCIA EÓLICA (PPE)	17
3.3 DADOS DE <i>INPUT</i> E <i>OUTPUT</i> DE MODELOS DE PREVISÃO	20
3.3.1 <i>INPUT</i> DE DADOS	20
3.3.2 <i>OUTPUT</i> DE DADOS	21
3.4 METODOLOGIAS PARA O CÁLCULO DA PPE	22
3.4.1 FONTES DE DADOS E MODELOS	22
3.4.2 ABORDAGENS À PPE.....	26
3.4.3 <i>DOWNSCALING</i>	27
3.4.4 <i>POWER CURVE MODELS</i> (PCM'S)	28
3.4.5 <i>MODEL OUTPUT STATISTICS</i> (MOS)	29

3.4.6	UPSCALING	30
3.4.7	ENSEMBLE MODEL OUTPUT STATISTICS (EMOS).....	31
3.4.8	OPERACIONALIDADE DO SISTEMA.....	32
3.4.9	ARQUITECTURA DE UM SISTEMA DE PPE	32
3.4.10	PREVISÕES DE BASE E DADOS UTILIZADOS	35
3.4.11	MODELO REN.....	38
4.	METODOLOGIA	39
4.1	MEDIDAS DE CARACTERIZAÇÃO E AVALIAÇÃO DAS PREVISÕES.....	39
4.1.1	DESCRIÇÃO ESTATÍSTICA	40
4.1.2	MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA.....	45
4.2	PREVISÕES DE BASE E OBSERVAÇÕES DE POTÊNCIA	48
4.2.1	SÉRIE DE DADOS E SUBDIVISÃO DE DADOS	48
4.2.2	DADOS DAS PREVISÕES E OBSERVAÇÕES.....	49
4.2.3	ORGANIZAÇÃO E PRÉ TRATAMENTO DOS DADOS	49
4.2.4	CARACTERIZAÇÃO DOS DADOS DE SCADA	50
4.2.5	CARACTERIZAÇÃO DAS PREVISÕES DE BASE E DADOS DE PERS	52
4.3	ALGORITMO DESENVOLVIDO (MOSF+EMOS)	69
4.3.1	TRATAMENTO DE DADOS-MOS (1ªFASE).....	70
4.3.2	PREVISÃO POTÊNCIA (2ªFASE)	74
4.3.3	MIX (3ªFASE).....	80
5.	RESULTADOS PRÁCTICOS	81
5.1	TRATAMENTO DE DADOS-MOS (1ªFASE).....	82
5.1.1	COEFICIENTE DE CORRELAÇÃO DE PEARSON (MOS1)	82
5.1.2	MÉDIA MÓVEL (MOS2)	88
5.1.3	PREVISÃO ADAPTATIVA DO VIÉS (MOS3).....	96
5.1.4	REGRESSÃO QUANTÍLICA ADAPTATIVA (MOS4)	103
5.1.5	COMBINAÇÃO DE TRATAMENTOS (MOSF)	110
5.2	PREVISÃO DE POTÊNCIA - MOSF+ALFA2 E ALFA1 (2ªFASE)	124

5.2.1	ALFA1.....	124
5.2.2	ALFA2.....	136
5.3	MODELO DESENVOLVIDO - MOSF+EMOS (3ªFASE).....	148
5.3.1	DESCRIÇÃO ESTATÍSTICA	149
5.3.2	MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA.....	150
5.4	COMPARAÇÃO ENTRE O MODELO DESENVOLVIDO (MOSF+EMOS) E MODELO REN	151
5.4.1	DESCRIÇÃO ESTATÍSTICA	151
5.4.1	MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA.....	154
6.	CONCLUSÕES.....	158
6.1	PREVISÕES DE BASE, DADOS DE PERS E DADOS DE SCADA.....	159
6.1.1	DADOS DE SCADA	159
6.1.2	PREVISÕES DE BASE	159
6.2	MÓDULO DE TRATAMENTO DE DADOS-MOS (1ªFASE)	160
6.2.1	COEFICIENTE DE CORRELAÇÃO DE PEARSON (MOS1)	160
6.2.2	MÉDIA MÓVEL (MOS2)	161
6.2.3	PREVISÃO ADAPTATIVA DO VIÉS (MOS3).....	161
6.2.4	REGRESSÃO QUANTÍLICA ADAPTATIVA (MOS4).....	162
6.2.5	COMBINAÇÃO DE TRATAMENTOS (MOSF)	162
6.3	PREVISÕES DE POTÊNCIA (2ªFASE)	164
6.3.1	MÓDULO ALFA1	165
6.3.2	MÓDULO ALFA2	165
6.3.3	ESTUDO DA CONTRIBUIÇÃO DE VÁRIOS MODELOS (MOSF+MIX)	167
6.4	MIX (3ªFASE).....	168
6.5	COMPARAÇÃO ENTRE MODELO MOSF+EMOS E MODELO REN	168
6.6	CONCLUSÕES GERAIS	168
7.	TRABALHO FUTURO	169
	REFERÊNCIAS	xxii

ANEXO A – VARIAÇÕES ESTUDADAS E VARIAÇÕES UTILIZADAS PELOS MODELOS MOS	xxix
ANEXO B – CALIBRAÇÃO DO MODELO STEPWISE-LR	xxx
ANEXO C – ESTUDO DA CONTRIBUIÇÃO DE DIFERENTES HORIZONTES TEMPORAIS COM RECURSO AO MODELO MIX	xxxvii
ANEXO D – COEFICIENTES REGRESSIVOS DO MODELO SLR/MLR-1 DO MÓDULO ALFA1	xxxix
ANEXO E – MÉTODO DOS MÍNIMOS QUADRADOS	xl
ANEXO F – SISTEMAS DE PPE COMERCIAIS	xli

LISTA DE TABELAS

Tabela 1- Relevância dos horizontes temporais por operador. Adaptado [66].....	18
Tabela 2- Aplicações da PPE e características dos tipos de modelos. Adaptado [66]	20
Tabela 3- Alguns modelos numéricos de previsão do tempo globais. Adaptado [66]	23
Tabela 4- Alguns modelos numéricos de previsão do tempo regionais. Adaptado [66]	23
Tabela 5- Modelos estatísticos de previsão do tempo e de potência a muito curto prazo de tempo. Adaptado [66].....	24
Tabela 6- Modelos estatísticos e computacionais de previsão a curto prazo de tempo. Adaptado [66]	24
Tabela 7- Alguns métodos de modelação para calcular a curva de potência característica de uma turbina. Adaptado [65] e [85].	29
Tabela 8- Síntese das medidas de caracterização do erro utilizadas.	40
Tabela 9- Descrição estatística dos erros da série de dados SCADA.....	50
Tabela 10- Descrição estatística das séries dos erros das previsões para o horizonte temporal 00-06hr.	52
Tabela 11- Descrição estatística das séries dos erros das previsões para o horizonte temporal 06-12hr.	56
Tabela 12- Descrição estatística das séries dos erros das previsões para o horizonte temporal 12-18hr.	59
Tabela 13- Descrição estatística das séries dos erros das previsões para o horizonte temporal 18-24hr.	62
Tabela 14- Síntese das variações dos métodos SLR/MLR.....	76
Tabela 15- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 00-06hr.	83
Tabela 16- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 00-06hr.....	83
Tabela 17- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 06-12hr.	84
Tabela 18- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 06-12hr.....	84
Tabela 19- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 12-18hr.	85
Tabela 20- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 12-18hr.....	85
Tabela 21- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 18-24hr.	86

Tabela 22- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 18-24hr.....	86
Tabela 23- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 00-06hr.	89
Tabela 24- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 00-06hr.....	89
Tabela 25- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 06-12hr.	90
Tabela 26- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 06-12hr.....	90
Tabela 27- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 12-18hr.	91
Tabela 28- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 12-18hr.....	91
Tabela 29- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 18-24hr.	92
Tabela 30- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 18-24hr.....	92
Tabela 31- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 00-06hr.	96
Tabela 32- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 00-06hr.....	97
Tabela 33- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 06-12hr.	97
Tabela 34- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 06-12hr.....	98
Tabela 35- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 12-18hr.	98
Tabela 36- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 12-18hr.....	99
Tabela 37- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 18-24hr.	99
Tabela 38- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 18-24hr.....	100
Tabela 39- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 00-06hr.	103

Tabela 40- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 00-06hr.....	104
Tabela 41- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 06-12hr.	104
Tabela 42- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 06-12hr.....	105
Tabela 43- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 12-18hr.	105
Tabela 44- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 12-18hr.....	106
Tabela 45- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 18-24hr.	106
Tabela 46- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 18-24hr.....	107
Tabela 47- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de validação.	110
Tabela 48- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de validação.	111
Tabela 49- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de validação.	111
Tabela 50- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de validação.	112
Tabela 51- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de validação.	112
Tabela 52- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de validação.	113
Tabela 53- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de validação.	113
Tabela 54- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de validação.	114
Tabela 55- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de teste.	114
Tabela 56- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de teste.	115
Tabela 57- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de teste.	115

Tabela 58- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de teste.	116
Tabela 59- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de teste.	116
Tabela 60- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de teste.	117
Tabela 61 - Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de teste.	117
Tabela 62- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de teste.	118
Tabela 63- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 00-06hr no período de validação.	126
Tabela 64- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 06-12hr no período de validação.	127
Tabela 65- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 12-18hr no período de validação.	128
Tabela 66- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 18-24hr para o período de validação.	129
Tabela 67- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 00-06hr no período de teste.	130
Tabela 68- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 06-12hr no período de teste.	131
Tabela 69- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 12-18hr no período de teste.	132
Tabela 70- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 18-24hr no período de teste.	133
Tabela 71- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 00-06hr no período de validação.	138
Tabela 72- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 06-12hr no período de validação.	139
Tabela 73- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 12-18hr no período de validação.	140
Tabela 74- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 18-24hr no período de validação.	141
Tabela 75- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 00-06hr no período de teste.	142

Tabela 76- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 06-12hr no período de teste.....	143
Tabela 77- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 12-18hr no período de teste.....	144
Tabela 78- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 18-24hr no período de teste.....	145
Tabela 79- Descrição estatística das séries dos erros das previsões MOSF+EMOS para os vários horizontes temporais nos períodos de validação e de teste.	149
Tabela 80- Síntese da avaliação estatística das séries dos erros das previsões MOSF+EMOS para os vários horizontes temporais entre os períodos de validação e de teste.....	149
Tabela 81- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 00-06hr nos períodos de validação e de teste.	151
Tabela 82- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 00-06hr nos períodos de validação e de teste.	152
Tabela 83- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 06-12hr nos períodos de validação e de teste.	152
Tabela 84- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 06-12hr nos períodos de validação e de teste.	152
Tabela 85- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 12-18hr nos períodos de validação e de teste.	153
Tabela 86- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 12-18hr nos períodos de validação e de teste.	153
Tabela 87- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 18-24hr nos períodos de validação e de teste.	154
Tabela 88- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 18-24hr nos períodos de validação e de teste.	154
Tabela 89- Síntese das medidas de avaliação de potência em média e em função do horizonte temporal para o modelo desenvolvido (MOSF+EMOS) e para o modelo REN no período de teste.	157
Tabela 90- Síntese da comparação, das medidas de avaliação mais relevantes, do modelo desenvolvido (MOSF+EMOS) face ao modelo REN no período de teste.....	157
Tabela 91- Síntese das medidas de avaliação de potência em média e em função do horizonte temporal para o modelo desenvolvido e para o modelo REN no período de validação.	158
Tabela 92- Síntese da comparação, das medidas de avaliação mais relevantes, do modelo desenvolvido (MOSF+EMOS) face ao modelo REN no período de validação.....	158
Tabela 93- Síntese dos estudos efectuados para os modelos MOS.	xxix
Tabela 94- Descrição estatística das previsões efectuadas com recurso ao modelo MIX no período de validação.....	xxxvii

Tabela 95- Descrição estatística das previsões efectuadas com recurso ao modelo MIX no período de teste.....	xxxviii
Tabela 96- Valores dos coeficientes regressivos calculados com recurso ao modelo SLR/MLR-1 (ALFA1) por combinação de séries de previsão e por horizonte temporal.....	xxxix
Tabela 97- Sistemas de PPE operacionais disponíveis em mercado. [66]	xli
Tabela 98- Sistemas de PPE operacionais disponíveis em mercado (cont.). [66].....	xlii

LISTA DE FIGURAS

Fig. 1 – Cenários de evolução de procura de energia eléctrica em Portugal. [3]	4
Fig. 2 – Cenário de previsão de evolução da Produção em Regime Especial (PRE). [3]	4
Fig. 3 – Representação de um corte transversal de uma pá com diferentes ângulos de ataque ou incidência (<i>pitch</i>), magnitude das forças envolvidas e escoamento do ar à superfície da pá. [4]	5
Fig. 4 – Curva característica de potência de uma turbina em função da intensidade do vento. Adaptado [3] e [5].....	5
Fig. 5 – Curva de potência característica de um parque eólico. [6]	6
Fig. 6 – Curvas de potência estimadas para um parque eólico consoante a orientação do vento. [6] ...	6
Fig. 7 –Relação entre <i>time-step</i> e o horizonte temporal.	18
Fig. 9 – Relação entre KDD e <i>data-mining</i> . [69]	25
Fig. 8 – Síntese dos vários tipos de abordagens de organização para calcular a PPE. Adaptado [66].	27
Fig. 10 – Tipos de <i>upscaling</i> . Adaptado [66].	30
Fig. 11 – Principais passos para efectuar uma previsão de potência pelo método estatístico. Adaptado [66]	34
Fig. 12 – Principais passos para efectuar uma previsão de potência pelo método físico. Adaptado [66]	34
Fig. 13 – Síntese dos vários tipos de metodologias para calcular a PPE. [66]	35
Fig. 14 – Simplificação do modelo PCM utilizado. Adaptado [94]	36
Fig. 15 – Fluxo do modelo MM5.	37
Fig. 16 – Interpretação dos vários tipos de dispersão para valores de covariância.	42
Fig. 17 – Ilustração da variação da curtose. Adaptado [102]	43
Fig. 18 – Ilustração dos tipos de simetria. Adaptado [102].....	44
Fig. 19 – Esquematização da subdivisão da série de dados.....	49
Fig. 20 – Gráfico das observações SCADA Vs. observações METER.....	51
Fig. 21 – Histograma dos erros dos dados de SCADA.	51
Fig. 22 – Medidas de avaliação do SCADA por <i>time-step</i> da interpolação.	52
Fig. 23 – Gráficos das séries de previsões do horizonte temporal 00-06hr vs observação (METER). 54	
Fig. 24 – Histograma dos erros das séries das previsões de base para o horizonte temporal 00-06hr. 55	
Fig. 25 – Gráficos das séries de previsões do horizonte temporal 06-12hr vs observação (METER).. 57	
Fig. 26 – Histograma dos erros das séries das previsões de base para o horizonte temporal 06-12hr. 58	
Fig. 27 – Gráficos das séries de previsões do horizonte temporal 12-18hr vs observação (METER). 61	
Fig. 28 – Histograma dos erros das séries das previsões de base para o horizonte temporal 12-18hr. 62	
Fig. 29 – Gráficos das séries de previsões do horizonte temporal 18-24hr vs observação (METER). 64	
Fig. 30 – Histograma dos erros das séries das previsões de base para o horizonte temporal 18-24hr. 65	

Fig. 31 – Gráfico síntese do valor de MAE das séries dos erros das previsões para o horizonte temporal 00-24hr.	66
Fig. 32 – Gráfico síntese do valor de RMSE das séries dos erros das previsões para o horizonte temporal 00-24hr.	67
Fig. 33 – Gráfico síntese do valor de BIAS das séries dos erros das previsões para o horizonte temporal 00-24hr.	68
Fig. 34 – Gráfico síntese do valor de SDE das séries dos erros das previsões para o horizonte temporal 00-24hr.	68
Fig. 35 – Arquitectura do sistema de melhoramento de previsão.	70
Fig. 36 – Representação das funções cumulativas das observações e das previsões.	73
Fig. 37 – Representação cumulativa do processo de tratamento MOSF.	74
Fig. 38 – Exemplo de uma RLS com o pormenor de cálculo para um ponto individual.	76
Fig. 39 – Exemplo de uma RP de 2º grau e RP de 3º grau com o pormenor de cálculo para um ponto.	77
Fig. 40 – Esquema do fluxo de cálculo de um Filtro de Kalman.	79
Fig. 41 – Esquema do fluxo de cálculo do modelo STEPWISE-LR.	80
Fig. 42 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS1 para o horizonte temporal 00-24hr.	87
Fig. 43 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS1 para o horizonte temporal 00-24hr.	88
Fig. 44 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS2 para o horizonte temporal 00-24hr.	94
Fig. 45 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS2 para o horizonte temporal 00-24hr.	95
Fig. 46 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS3 para o horizonte temporal 00-24hr.	101
Fig. 47 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS3 para o horizonte temporal 00-24hr.	102
Fig. 48 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS4 para o horizonte temporal 00-24hr.	108
Fig. 49 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS4 para o horizonte temporal 00-24hr.	109
Fig. 50 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de validação.	119
Fig. 51 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de validação.	120

Fig. 52 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de teste.	122
Fig. 53 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de teste.	123
Fig. 54 – Gráfico síntese do valor de BIAS B) e SDE S) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA1 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	134
Fig. 55 – Gráfico síntese do valor de MAE (M) e RMSE (R) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA1 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	135
Fig. 56 – Gráfico síntese do valor de BIAS B) e SDE S) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA2 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	146
Fig. 57 – Gráfico síntese do valor de MAE M) e RMSE R) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA2 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	147
Fig. 58 – Gráfico síntese do valor de BIAS B), SDE S), MAE M) e RMSE R) para as séries dos erros das previsões MOSF+EMOS para o horizonte temporal 00-24hr nos períodos de validação e de teste.	150
Fig. 59 – Gráfico síntese do valor de BIAS B) e SDE S) comparativamente entre as séries dos erros das previsões efectuadas com recurso ao modelo MOSF+EMOS e modelo REN para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	155
Fig. 60 – Gráfico síntese do valor de MAE M) e RMSE R) comparativamente entre as séries dos erros das previsões efectuadas com recurso ao modelo MOSF+EMOS e modelo REN para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).	156
Fig. 61 – Histograma do valor do viés previsto para cada série de previsão em função do horizonte temporal.	163
Fig. 62 – Taxa de aprendizagem utilizada para o horizonte temporal 18-24hr.	167
Fig. 63 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 00-06hr.	xxxii
Fig. 64 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 06-12hr.	xxxiii
Fig. 65 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 12-18hr.	xxxiii

Fig. 66 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 18-24hr. xxxiv

Fig. 67 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 00-06hr. xxxv

Fig. 68 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 06-12hr. xxxv

Fig. 69 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 12-18hr. xxxvi

Fig. 70 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 18-24hr. xxxvi

Fig. 71 – Esquematização do *input* de dados utilizados para efectuar previsões com recurso ao modelo MIX para os vários horizontes temporais..... xxxvii

Fig. 72 – Gráfico comparativo do valor da agregação das previsões, tratadas com recurso a, MOSF com recurso ao modelo MIX, sendo as medidas de avaliação referentes aos períodos de a) validação e b) teste..... xxxviii

LISTA DE ACRÓNIMOS, SIGLAS E ABREVIATURAS

ADALINE	<i>ADaptive LInear NEuron or Later Adaptive Linear Element</i>
AEC	<i>Adaptive Exponencial Combination</i>
AFNN	<i>Adaptive Fuzzy Neural Networks</i>
AFTER	<i>Aggregated Forecast Through Exponential Re-Weighting</i>
AFWA	<i>Air Force Weather Agency</i>
ALADIN	<i>Aire Limitée Adaptation dynamique Développement InterNational</i>
ANFIS	<i>Adaptive Neuro Fuzzy Inference System</i>
ANN	<i>Adaptive Neural Networks</i>
AR	<i>AutoRegression</i>
ARCH	<i>AutoRegressive Conditional Heteroskedasticity</i>
ARIMA	<i>AutoRegression Integrated Moving Average</i>
ARIMA-ARCH	<i>AutoRegression Integrated Moving Average -AutoRegressive Conditional Heteroskedasticity</i>
ARMA	<i>AutoRegression Moving Average</i>
ARPEGE	<i>Action de Recherche Petite Echelle Grande Echelle</i>
ARX	<i>AutoRegression With Exogenous Input</i>
ARXM	<i>AutoRegression with eXogenous input and Multi-timescale parameter</i>
<i>B.I.Tracking</i>	<i>Best Intersection point Tracking</i>
BCSD	<i>Bias-Correction – Spatial Disaggregation</i>
C&R Tree	<i>Classification and Regression Tree</i>
CAISO	<i>California Independent System Operator</i>
CENER	<i>Centro Nacional de Energías Renovables</i>
CFD	<i>Computed Fluid Dynamics</i>
CI	<i>Critério de Inclusão</i>
CIEMAT	<i>Centro De Investigaciones Energéticas, Medioambientales Y Tecnológicas</i>
DPE	<i>Desvio Padrão dos Erros</i>
DTU	<i>Danmarks Tekniske Universitet</i>
ECWF	<i>European Centre for Medium-Range Weather Forecasts</i>
ELR	<i>Exponential Linear Regression</i>
EMA	<i>Erro Médio Absoluto</i>
EMOS	<i>Ensemble Model Output Statistics</i>
EMQ	<i>Erro Médio Quadrático</i>
EnKF	<i>Ensemble Kalman Filter</i>
ENTSO-E	<i>European Network Of Transmission System Operators For Electricity</i>
EPS	<i>Ensemble Prediction System</i>
EU	<i>União Europeia</i>
FAA	<i>Federal Aviation Administration</i>
FFNN	<i>Feed Forward Neural Networks</i>
FIS	<i>Fuzzy Inference System</i>
GEE	<i>Gases de Efeito de Estufa</i>
GENCOs	<i>Generation Companies</i>
GFS	<i>Global Forecast System</i>
GN	<i>Gás Natural</i>
HIRLAM	<i>High Resolution Limited Area Model</i>
IFS	<i>Integrated Forecasting System</i>
ISO	<i>Independent System Operator</i>
KDD	<i>Knowledge Discovery in Databases</i>
KDE	<i>Kernel Density Estimation</i>
KF	<i>Kalman Filter</i>
K-NN	<i>K-Nearest Neighbor</i>
LLR	<i>Logarithmic Linear Regression</i>
LQR	<i>Linear Quantile Regression</i>
LR	<i>Linear Regression</i>

MAE	<i>Mean Absolut Error</i>
MLP	<i>Multilayer Perceptron Network</i>
MLR	<i>Multiple Linear Regression</i>
MM5	<i>Fifth-Generation Penn State/NCAR Mesoscale Model</i>
MOS	<i>Model Output Statistics</i>
MSE	<i>Mean Square Error</i>
NBIAS	<i>Normalized BIAS</i>
NCAR	<i>National Center For Atmospheric Research</i>
NCEP	<i>National Centers For Environmental Prediction</i>
NERC	<i>North American Electric Reliability Corporation</i>
NEULONET	<i>Neural Logic Network</i>
NMAE	<i>Normalized Mean Absolut Error</i>
NN	<i>Neural Network</i>
NNAM	<i>NNAM Neural Network Assembling Model</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
NRMSE	<i>Normalized Root Mean Square Error</i>
NSDE	<i>Normalized Standard Deviation Error</i>
NWP	<i>Numerical Weather Prediction</i>
NWS	<i>United States National Weather Service</i>
PAM	<i>Power Agregation Model</i>
PCM	<i>Power Curve Model</i>
PDF	<i>Probability Density Function</i>
PDIRT	Plano de Desenvolvimento e Investimento da Rede de Transporte de Electricidade
PPE	Previsão de Potência Eólica
PPE-CP	Previsão de Potência Eólica-Curto Prazo
PPE-MCP	Previsão de Potência Eólica-Muito Curto Prazo
PPE-MP	Previsão de Potência Eólica-Médio Prazo
PRE	Produção em Regime Especial
PSU	<i>Penn State University</i>
RBF	<i>Radial Basis Function</i>
RCLE-UE	Regime de Comércio de Licenças de Emissão da União Europeia
REMQ	Raiz do Erro Médio Quadrático
REN	Redes Energéticas Nacionais
RIX	<i>Roughness IndeX</i>
RMSE	<i>Root Mean Square Error</i>
RNN	<i>Recurrent Neural Network</i>
RNT	Rede Nacional de Transporte
RP	Regressão Polinomial
SAR	<i>Statistical Asynchronous Regression</i>
SARIMA	<i>Seasonal Auto Regression Integrated Moving Average</i>
SCADA	<i>Supervisory Control And Data Acquisition</i>
SDE	<i>Standard Deviation Error</i>
SDSM	<i>Statistical DownScaling Model</i>
SEN	Sistema Eléctrico Nacional
SLR	<i>Simple Linear Regression</i>
SO	<i>System Operator</i>
SQD	Soma dos Quadrados dos Desvios
SVM	<i>Suport Vector Machine</i>
SVMreg	<i>Suport Vector Machine Regression</i>
TKE	<i>Turbulent Kinetic Energy</i>
TSK	<i>Takagi-Sugeno-Kang</i>
TSO	<i>Transmission System Operator (Operador da Rede de Transporte)</i>
TU	Tempo universal
TYNDP	<i>Ten Year Network Development Plan</i>

UE	União Europeia
WAsP	<i>Wind Atlas Analysis and Applications Program</i>
WFLM	<i>Wind Farm Losses Model</i>
WPPT	<i>Wind Power Prediction Tool</i>
WRF	<i>Weather Research and Forecasting Model</i>
WRF-STS	<i>Statistical Weather Research and Forecasting Model</i>

LISTA DE SIMBOLOS

A	Área de varrimento
AS_1	Primeiro coeficiente de assimetria utilizado
AS_2	Segundo coeficiente de assimetria utilizado
CA	Critério de avaliação
CA_{REF}	Critério de avaliação de referência
$cov(x,y)$	Covariância
C_p	Coeficiente de desempenho da turbina
E	Erro
\bar{E}	Média do erro
\tilde{E}	Mediana do erro
h	Horizonte temporal
hr	Hora
i	<i>Time-step</i>
IMP	Quantificação do grau de melhoria
IMP%	Quantificação do grau de melhoria em percentagem
K	Coeficiente percentílico de curtose
Km	Kilometro
m	Metro
m/s	Metro por segundo
Max	Máximo
min	Minutos
Min	Mínimo
MW	Mega Watt
MWh	Mega Watt hora
n	Número de dados
P	Potência
p	Intervalo passado
P_{10}	Percentil 10
P_{90}	Percentil 90
POT_{inst}	Potência instalada
Q	Quantil
Q_1	Primeiro quantil
Q_3	Terceiro quantil
s	Segundo
s	Segundo
t	Período passado
V	Velocidade do vento
Var	Variância
x	Série de previsão
\bar{x}	Média da previsão x
y	Série de observação
\bar{y}	Média da observação y
ρ_{ar}	Densidade do ar
$\rho_{x,y}$	Coeficiente de correlação de Pearson
σ	Desvio padrão

1. INTRODUÇÃO

Actualmente, a previsão de produção de potência tem uma elevada importância, reconhecida pelos vários agentes do mercado energético (TSO, companhias eléctricas, micro-produtores, etc), já que permite uma aproximação do diagrama de carga ao diagrama de consumos minimizando os custos de produção e facilitando a gestão da energia eléctrica, sendo isto especialmente importante para mercados energéticos liberalizados e para elevadas penetrações de energias de fonte variável. Assim torna-se necessário prever o melhor possível a potência que irá ser produzida pelas centrais que têm como fonte as energias renováveis.

A energia eólica é a energia renovável, dentro das PRE's, com a maior potência instalada no território nacional. Assim, torna-se necessário quantificar o melhor possível qual a energia que esta irá produzir a muito curto, a curto prazo, a médio prazo e a longo prazo, possibilitando assim uma melhor gestão da RNT e do SEN.

Esta tese tem como objectivo avaliar, melhorar e indicar uma possível direcção para melhorar o processo de cálculo usado pelo *Transmission System Operator* (TSO) para prever a potência eólica para o território de Portugal Continental. Deste modo, pretende-se adequar o diagrama de carga ao diagrama de consumos e, desta forma, minimizar os custos relacionados com a geração de energia, a manutenção de uma reserva girante sobredimensionada, a manutenção da RNT e/ou SEN e a importação de energia, permitindo uma melhor gestão energética, entre outras vantagens. Neste sentido, idealizou-se um algoritmo que tivesse em conta:

- Um conjunto de métodos de tratamento de dados dinâmico;
- Um conjunto de métodos que por um lado combinem várias previsões de potência e por outro tenham vários períodos de calibração e/ou validação;
- Um modelo que efectue uma agregação de previsões dinâmicas no tempo com base na avaliação de desempenhos passados.

No entanto, existiriam algumas limitações que seriam:

- Os dados de SCADA nem sempre poderiam ser exactos, apresentando um erro relativo ao valor posteriormente registado pelo METER;
- As previsões de vento efectuadas pelas entidades externas poderiam nem sempre chegar a tempo;
- Poderia ocorrer um erro no ficheiro de previsão impedindo os vários algoritmos intermediários de trabalhar os ficheiros.

Assim, foi utilizada uma metodologia que por um lado permitisse identificar qual a melhor abordagem à problemática em estudo e por outro lado permitisse efectuar previsões de potência mais precisas para horizontes temporais a 24 horas.

Este estudo recorreu a dados de potência eólica para o território de Portugal Continental, fornecidos pela REN. As previsões de velocidade e de direcção do vento foram obtidas com recurso a modelos numéricos de previsão do tempo (MM5, WRF, ALADIN) e a um modelo de previsão numérica acoplado a um módulo MOS (WRF-STTS) estes dados foram posteriormente utilizados como *input* num modelo de *downscaling*, posteriormente através de *Power Curve Models* (PCM's) os valores de previsão foram convertidos em valores de potência, na última etapa recorreu-se a um modelo de *upscaling* para efectuar previsões para o território continental. As observações em potência foram registadas por contadores (METER) e por um sistema SCADA (*Supervisory Control and Data Acquisition*).

Com a presente dissertação desenvolveu-se um modelo estatístico adaptativo de melhoramento das previsões de potência eólica para o território de Portugal Continental. O modelo estatístico é composto por dois módulos principais: um módulo MOSF e um módulo EMOS.

O módulo MOSF tinha como objectivo reduzir erros sistemáticos e melhorar as previsões de potência das várias séries de previsão utilizadas, o qual é composto pelos tratamentos MOS1, MOS2 e

MOS3 utilizados de forma sucessiva. MOS1 consiste na utilização do coeficiente de correlação de Pearson para tratar as séries de dados e tinha como objectivo reduzir o valor da dispersão associada às séries. MOS2 consiste num modelo de média móvel e tinha como objectivo suavizar a série de dados. MOS3 consiste num modelo que tinha como objectivo prever o viés associado às previsões de forma adaptativa.

O módulo EMOS tinha como objectivo efectuar um espectro alargado de previsões por forma a ser escolhida a melhor previsão com base num passado recente. Isto foi efectuado recorrendo a diferentes métodos lineares e não lineares. Os quais estão distribuídos por 2 módulos e um modelo com funcionalidades e/ou períodos de calibração distintos (ALFA1, ALFA2 e modelo MIX), por forma a efectuar um espectro alargado de previsões e a efectuar a escolha do melhor modelo.

O módulo ALFA1 recorre às variações do método linear regressivo, nomeadamente, regressão linear simples e/ou múltipla (SLR/MLR). Este módulo recorreu a uma série anual de dados passados para calibrar os coeficientes regressivos. Além disso, alguns destes modelos recorreram a uma janela de dados passados, de dimensão variável (até 10 dias), para avaliar os modelos. Os vários modelos que compõem este módulo recorrem às combinações possíveis dos vários predictores disponíveis, por outro lado, este módulo é composto por 4 módulos distintos: SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 que efectuaram previsões em paralelo.

O módulo ALFA2 recorre aos métodos: linear regressivo, nomeadamente regressão linear simples e/ou múltipla (SLR/MLR) e variação do método regressão linear passo a passo (STEPWISE-LR); variação do Filtro de Kalman a que se deu o nome de KF, a qual efectuou previsões com recurso a variação da taxa de aprendizagem. Este módulo recorreu a uma janela móvel de dados referentes a um passado recente, até 10 dias, para calibrar os parâmetros necessários, consistindo por isso o módulo mais adaptativo. Este módulo é composto por 4 módulos distintos: SLR/MLR-3, SLR/MLR-4, STEPWISE-LR e KF.

O modelo MIX é uma variação do método *B.I. Tracking*. Este modelo foi responsável, numa primeira fase, por escolher a melhor previsão, por *time-step*, efectuada com recurso aos módulos: SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 pertencentes a ALFA1; SLR/MLR-3, SLR/MLR-4 e STEPWISE-LR pertencentes a ALFA2. A previsão obtida foi posteriormente utilizada como *input* no módulo KF, este módulo efectuou previsões em paralelo em que se variou a taxa de aprendizagem do modelo. A segunda fase que o modelo MIX foi utilizado foi para avaliar qual a melhor taxa de aprendizagem para um determinado *time-step* e assim efectuar as previsões finais.

O modelo desenvolvido consiste em 3 fases distintas: melhoramento de previsões com recurso a MOSF (módulo de tratamento de dados), cálculo do espectro de previsões com recurso aos modelos ALFA (módulo ALFA1 e ALFA2); escolha do melhor modelo/taxa de aprendizagem em função do *time-step* com recurso ao modelo MIX.

Tendo em conta a caracterização do erro efectuado, verificou-se que o modelo desenvolvido foi adequado para efectuar um melhoramento das previsões eólicas para Portugal Continental. Por outro lado, verificou-se que o modelo desenvolvido obteve um melhor desempenho do que o modelo actualmente utilizado para efectuar a previsão eólica para o território de Portugal Continental.

Além disso, a presente dissertação apresenta estudos efectuados com recurso ao método de regressão quantílica adaptativa, estudo da calibração do modelo STEPWISE-LR, estudo da contribuição do modelo MOSF acoplado ao modelo MIX. Estudo da utilização de diferentes módulos ALFA com diferentes períodos de calibração.

A presente dissertação efectua recomendações com base nos resultados obtidos com vista a melhorar as previsões de potência eólica para o território de Portugal Continental. Além disso, sugere o estudo e desenvolvimento de novos módulos com vista a melhorar as previsões de potência efectuadas assim como para acrescentar novas funcionalidades ao modelo desenvolvido.

Deste modo, a presente dissertação está estruturada da seguinte forma. No capítulo dois é efectuado um enquadramento institucional. No capítulo três é efectuado um enquadramento teórico ao tema da previsão de potência eólica. No capítulo quatro é apresentada a metodologia adoptada. No capítulo cinco são apresentados os resultados da metodologia adoptada. No capítulo seis são apresentadas as

conclusões. No capítulo sete são apresentadas sugestões futuras para melhorar o desempenho do modelo desenvolvido e complementar as suas funcionalidades com vista a uma melhoria da gestão do sistema.

2. ENQUADRAMENTO

2.1 METAS 2020-UNIÃO EUROPEIA

A União Europeia (UE) tem fomentado o combate às alterações climáticas e lutado por um desenvolvimento sustentável da civilização humana. Uma das últimas iniciativas de maior relevo foi levada a cabo pelo Conselho Europeu que, decidindo elevar a fasquia em relação ao que se tinha comprometido anteriormente, diminuiu, no mínimo, as emissões de GEE em 20% relativamente ao ano 1990 e, caso se chegasse a acordo a nível internacional, a UE comprometia-se com uma redução de 30%. Além disso, a UE comprometeu-se com a incorporação de 20% de energia renovável no *mix* energético, ao invés do que se passa actualmente em que a energia renovável representa 8% do *mix* energético. Por outro lado, a UE comprometeu-se, ainda, com o objectivo de economizar 20% de energia até 2020 através da eficiência energética. Num comunicado, a UE [1] refere que com esta medida “(...) economizaria assim cerca de 100 mil milhões de euros e reduziria as emissões em quase 800 milhões de toneladas por ano. A eficiência energética constitui um dos principais meios de redução das emissões de CO₂”. Ainda segundo o mesmo comunicado a UE refere que “Para atingir estes objectivos da UE a um custo mínimo, as propostas da Comissão baseiam-se na experiência adquirida com o RCLE-UE, deixando, tanto quanto possível, a iniciativa ao mercado”, defendendo que o mercado irá estabilizar a um custo mínimo para RCLE-EU apoiado por políticas governamentais e a própria auto-regulação de mercado.

2.2 REN- REDES ENERGÉTICAS DE PORTUGAL, SGPS, S.A.

A REN [2] “tem como missão garantir o fornecimento ininterrupto de electricidade e gás natural, ao menor custo, satisfazendo critérios de qualidade e de segurança mantendo o equilíbrio entre a oferta e a procura em tempo real, assegurando os interesses legítimos dos intervenientes no mercado e conjugando as missões de operador de sistema e de operador de rede que lhe estão cometidas”. Assim e considerando as características mercado Ibérico, torna-se necessário aumentar a eficiência de processos sem esta afectar a qualidade de serviços, ser um exemplo ao nível da sustentabilidade tendo em conta os vários pilares que a compõem e garantir imparcialidade a todos os seus intervenientes.

A REN tem duas grandes áreas de negócio: o sector eléctrico e o sector do Gás Natural (GN). O sector eléctrico engloba áreas de negócio como o transporte de energia eléctrica a muito alta tensão e a gestão técnica global do Sistema Eléctrico Nacional (SEN), sendo o titular da Rede Nacional de Transporte (RNT), ou seja, a única empresa com concessão para transporte de electricidade a muita alta tensão em Portugal continental.

2.2.1 REN-REDE ELÉCTRICA NACIONAL, S.A.

O sector eléctrico em Portugal pode ser dividido em 5 grandes áreas, sendo elas, a produção, transporte, distribuição, comercialização de electricidade e operação dos mercados organizados de electricidade.

A electricidade pode ser produzida com recurso a vários tipos de tecnologias, podendo utilizar vários tipos de fontes de energia primária, sejam estas fontes de origem renovável e/ou não renovável. Em Portugal, os principais actores na área da produção de energia são a EDP Produção, a Turbogás e a Tejo Energia.

A REN (Rede Eléctrica Nacional, S.A.) é a entidade que opera a RNT, ligando os produtores aos centros de consumo conseguindo assim assegurar o equilíbrio entre a oferta e a procura. No âmbito do respectivo contracto de concessão, esta é a única entidade de transporte de electricidade em Portugal continental. Para além das actividades de planeamento, de construção e de operação da RNT, a REN actua também como o gestor técnico global do SEN.

Citando [3], “A REN é membro da ENTSO-E (organização que reúne todos os operadores da rede de transporte (TSO) da Europa) e das participações daí decorrentes na elaboração do *Ten Year Network Development Plan* — TYNDP — e nos estudos e planos regionais dos países da Europa Ocidental (Portugal, Espanha e França). Deste modo a proposta de PDIRT manterá a máxima coerência com os princípios estratégicos da ENTSO-E”

Conclui-se, portanto, que a REN assumiu uma estratégia baseada em três pilares principais: segurança e qualidade de abastecimento, integração de renováveis e desenvolvimento dos mercados de energia. Por outro lado, a REN estima que o consumo nacional terá tendência a crescer conforme os cenários expressos na Fig. 1.

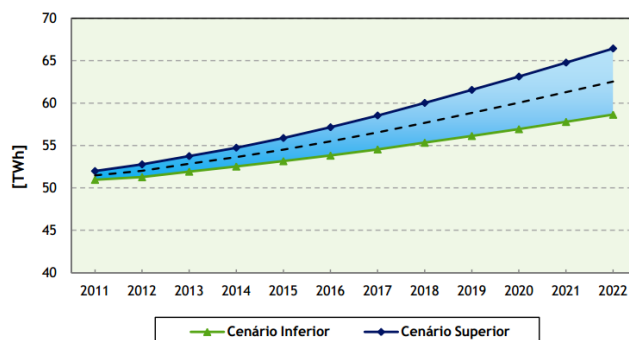


Fig. 1 – Cenários de evolução de procura de energia eléctrica em Portugal. [3]

No que à integração de energias renováveis diz respeito, segundo a mesma fonte [3], “A REN está comprometida com as políticas nacionais de promoção e de facilitação de integração das energias renováveis nas redes, que definem como objectivo para 2020 uma parcela de contribuição da energia renovável de, pelo menos, 60% do consumo final de electricidade no País”.

Assim, é necessária uma forte aposta nas energias renováveis. Esta tendência está bem patente na (Fig. 2) em que a REN traça cenários de evolução para a implementação de várias tecnologias de energias renováveis no território nacional.

Horizonte	Potência Instalada (MW)								
	Cogeração	RSU & RI*	Biomassa	Ondas	Biogás	Solar	PCH	Eólica	
								on-shore	off-shore
2010	1 555	85	117	0	30	122	414	3 854	0
2020	2 250	165	250	250	142	1 500	750	6 800	75

* Incluindo 15MW de resíduos industriais (incineração de óleos usados)
 RSU & RI - Resíduos Sólidos Urbanos & Resíduos Industriais
 PCH - Pequenas centrais hidroeléctricas

Fig. 2 – Cenário de previsão de evolução da Produção em Regime Especial (PRE). [3]

Perante o cenário apresentado é imperativo que sejam criadas as ferramentas técnicas e materiais que tenham em conta as características menos atractivas das fontes de energia renovável, com vista a que estas tecnologias se tornem mais competitivas e, conseqüentemente, mais atractivas, facilitando a sua incorporação no *mix* energético e indo ao encontro das metas propostas pela REN.

3. ENQUADRAMENTO TEÓRICO

A energia eólica é a energia produzida a partir do vento e, por conseguinte, trata-se de uma fonte de energia renovável. Este é o tipo de energia renovável que se prevê ser dominante em termos de potência instalada, dentro das PRE's, no território nacional na próxima década.

A potência eólica é extraída do vento por meio da criação de uma diferença de pressão entre as faces das pás da turbina, por acção do vento, e transformando a energia do vento em energia mecânica, é possível obter energia eólica. Tal princípio é aplicável através de um *design* aerodinâmico das pás e variando o ângulo de incidência do vento nas pás, conforme a (Fig. 3).




Fig. 3 – Representação de um corte transversal de uma pá com diferentes ângulos de ataque ou incidência (*pitch*), magnitude das forças envolvidas e escoamento do ar à superfície da pá. [4]

A potência produzida por uma turbina é possível ser calculada por meio do cálculo da energia cinética que a massa de ar transporta ao atravessar as pás da turbina eólica (Equação 1).

$$P = \frac{1}{2} \times C_p \times \rho_{ar} \times A \times V^3 \quad (1)$$

Em que C_p , ρ_{ar} , A e V são respectivamente o coeficiente de desempenho da turbina, a densidade do ar, a área de varrimento das pás e V a velocidade do ar (vento).

No entanto, é necessário ter em conta as próprias especificidades da turbina eólica (*nacelle*), o ângulo de incidência do vento na pá (*pitch*), Fig. 3, e a direcção do vento, já que também estas, entre outras, influenciam a produção de energia eólica.

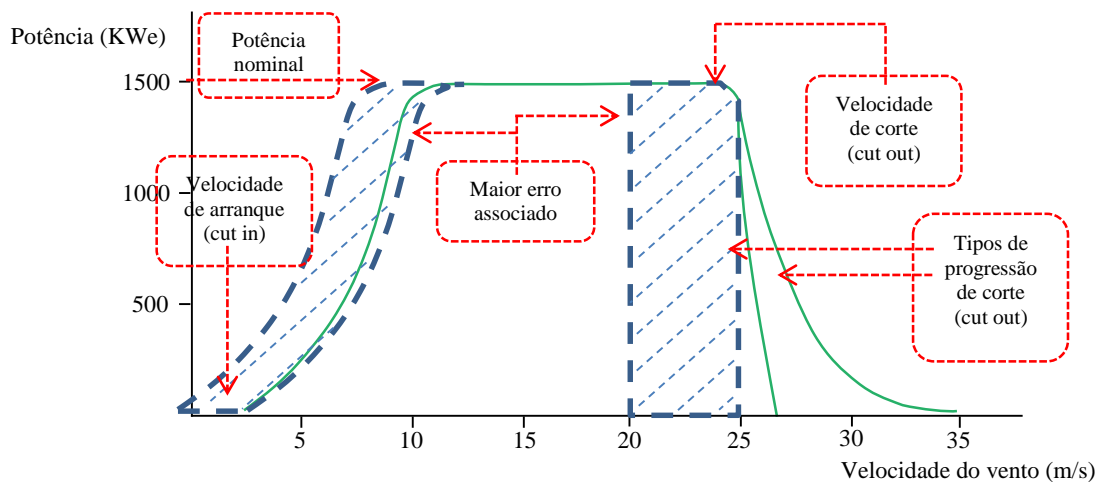


Fig. 4 – Curva característica de potência de uma turbina em função da intensidade do vento. Adaptado [3] e [5].

Como se pode observar na Fig. 4, a curva de potência característica teórica de uma turbina varia da seguinte forma:

- Dos 2,5 m/s aos 5 m/s de uma forma linear;
- Dos 5 m/s ate aos 12,5 m/s de uma forma exponencial;
- Dos 12,5 m/s aos 25 m/s não apresenta uma variação significativa;

- A partir dos 25 m/s a turbina tende a bloquear de modo a salvaguardar o equipamento de eventos extremos.

A representação anterior da curva característica de potência da turbina (a verde na Fig. 4) é cedida pelo fabricante, mas nem sempre esta reflete a potência real produzida por uma turbina, já que esta pode ter um desempenho bastante variável para diferentes velocidades do vento (Fig. 4 e 5) e diferentes direcções do vento (Fig. 6). Diversas velocidades do vento estão associadas a diferentes situações e por vezes esporádicas exemplo disso é efectuar previsões de potência a velocidades no intervalo 22-25 m/s. Estas velocidades (para o território de Portugal continental) estão normalmente relacionadas com a ocorrência de rajadas, sendo que estas não são passíveis de ser facilmente previstas com recurso aos métodos tradicionais, sendo que poderá ser vantajoso ter modelos específicos para cada situação distinta. Por outro lado, actualmente já existem turbinas com diferentes tipos de *cut-out*, (Ex: turbinas ENERCON com e sem storm control [5]), o que tem um impacto considerável, na previsão eólica, sendo necessário ser tido em conta este aspecto quando se efectua a previsão de potência eólica.

Nas Fig. 5 e 6 estão representadas a curva de potência característica cedida pelo fabricante e a estimada a partir das observações para os vários quadrantes de direcção do vento. A direcção assim como a velocidade do vento é influenciada pela variação dos regimes sinópticos, orografia, *layout* do parque eólico, entre outros pelo que isto poderá ser um factor de aumento do erro associado às previsões pelo que deverá ser tido em conta para melhorar a qualidade destas.




Fig. 5 – Curva de potência característica de um parque eólico. Vermelho – curva do fabricante, verde – curva estimada com base em medições de vento e *output* de potência (pontos pretos). [6]




Fig. 6 – Curvas de potência estimadas para um parque eólico consoante a orientação do vento. [6]

Assim sendo, poderá ser vantajoso, em alguns casos, efectuar uma modelação da curva característica de potência para diferentes direcções do vento e/ou diferentes turbinas e/ou diferentes parques. Por outro lado, as previsões de velocidade e direcção do vento, posição de frentes quentes/frias, entre outros dados ainda não são passíveis de ser previstos com o detalhe necessário pelo que medições *in situ* poderão melhorar os modelos de previsão. Assim, a contribuição de observações *online* pode contribuir de forma relevante para reduzir o erro de previsão de velocidade do vento e consequentemente o erro de previsão de potência eólica.

3.1 REVISÃO LITERÁRIA

Como já anteriormente foi referido a presente dissertação tem como objectivo melhorar as previsões de potência eólica através da utilização de diferentes métodos com diferentes períodos de calibração. Assim, e tendo em conta as especificidades inerentes, já referidas no capítulo 1, consultou-se bibliografia para tentar perceber qual a melhor forma de resolver o problema proposto.

Um dos primeiros estudos remete para a década de 70 e tinha como intenção [7], perceber quais seriam as vantagens de possuir uma PPE-MCP (Previsão de Potência Eólica-Muito Curto Prazo) e PPE-CP (Previsão de Potência Eólica-Curto Prazo) sendo o responsável pelo estudo a companhia *Pacific Northwest Laboratory*. As conclusões apontavam para que caso se atingissem valores próximos da

realidade então a PPE (Previsão de Potência Eólica) seria uma ferramenta importante para as áreas de planeamento de manutenção do sistema electroprodutor e planeamento diário do *mix* energético da rede. No entanto, não existiam ferramentas que permitissem fazer uma PPE com a precisão necessária. Estes primeiros algoritmos só começam a aparecer de uma forma significativa na década de 80.

Segundo Costa *et al.* [7] é na década de 80 que Notis *et al.* [8] publica um paper que refere um algoritmo para prever o vento com um horizonte temporal de 24 horas para um dado local, este utilizava previsões climatéricas que eram posteriormente tratadas, a que se dá o nome de *Model Output Statistics* (MOS), de modo a refinar as previsões iniciais e fazer uma previsão meteorológica mais precisa.

Segundo Costa *et al.* [7] Wegley *et al.* [9] desenvolveram três algoritmos que previam a velocidade do vento, nestes foram usados a persistência, modelos auto regressivos e modelo de Markov para *time-steps* de 10, 30 e 60 minutos. Este estudo revelou que para o *time-step* de 10 minutos a persistência foi a que melhor desempenho teve a calcular a PPE e o modelo de Markov foi o que melhor desempenho teve a fazer a PPE para o *time-step* de 60 minutos.

Segundo Costa *et al.* [7] Geerts [10] desenvolveu um modelo, com o objectivo final de calcular a potência a ser injectada na rede, baseado no KF (*Kalman Filter*) e ARMA (*AutoRegression Moving Average*) para calcular a velocidade do vento para um horizonte temporal de 24 horas e *time-steps* de 1 hora. Este modelo foi corrido sobre uma série de dados anual conseguindo melhores resultados relativamente à persistência para horizontes temporais até 16 horas, no entanto a ARMA foi a que melhor desempenho teve. Posteriormente Geerts adicionou para além da velocidade do vento outras variáveis como a direcção do vento, humidade, temperatura e outras verificando que se conseguia melhorar as PPE.

Segundo Costa *et al.* [7] Bossanyi [11] recorreu a um KF para prever a velocidade de vento com um *time-step* de 1 minuto avançado conseguindo assim melhorias relativamente a persistência. Posteriormente utilizou um KF para efectuar previsões de velocidade de vento para os 10 próximos *time-steps* conseguindo também assim melhorias de uma forma geral. Numa outra fase utilizou o KF para verificar a evolução do erro médio das previsões de vento variando os *time-steps*. Para isto foram geradas novas séries de previsão para 2, 5, 10 e 15 minutos partindo da série de dados original com o objectivo de verificar qual o *time-step* com maior erro. Numa fase final e para uma segunda localização Bossanyi variou o *time-step* entre os 2 segundos e os 5 minutos para observar a evolução da previsão. Deste estudo Bossanyi concluiu que o menor erro de previsão estava associado a previsões inferiores a 5 minutos, o melhor desempenho do algoritmo ocorreu para um *time-step* de 1 minuto, a persistência foi mais vantajosa para previsões horárias, além disso refere que a curva entre menor erro versus variação de *time-step* está intimamente ligada com a distribuição sinóptica do vento.

Segundo Costa *et al.* [7] Bailey e Stewart [12] refere que estes desenvolveram um importante trabalho em que efectuaram uma compilação de vários estudos feitos até aquela altura para efectuar os cálculos de PPE-MCP sendo que indicam sugestões para melhorar esses mesmos algoritmos. Além disto, defendem que o caminho para os novos desenvolvimentos da PPE-MCP passam por ter bases de dados acessíveis e claras, medidas de erro standart, modelos da orografia, modelos que reproduzam os ventos sinóticos entre outras ferramentas.

Segundo Costa *et al.* [7] é na década de 90 assiste-se a um elevado aumento da capacidade de produção eólica aumentando assim o interesse e as verbas para investigação de ferramentas utilizáveis para a PPE, já que a integração de uma energia produzida através de uma fonte de energia bastante variável como é o vento apresentava os seus desafios, assim como era atractiva pois não tinha custos de energia primária.

Segundo Costa *et al.* [7] é na década de 90 que Troen e Landberg [13] anunciam um consórcio entre os serviços meteorológicos Inglês e Dinamarquês inserido no programa EC-JOULE. Neste estudo os autores propuseram um modelo que melhorasse as previsões de vento para uma dada localidade usando dados do modelo HIRLAM que representavam a orografia, rugosidade e obstáculos. Os resultados de melhoria não foram muito significativos contudo, conseguiram-se melhorias relativamente a persistência para a velocidade de vento e direcção para velocidades iguais ou superiores a 5m/s com um horizonte temporal de 9 horas.

Segundo Costa *et al.* [7] Fellows e Hill [14]. Os quais tentaram prever a carga na rede para *time-steps* de 1 hora e para horizontes temporais de 6 horas, para isto usaram a base de dados e separaram os valores por períodos de tempo, já que os consumos diários tendem a ser cíclicos consoante a altura do dia e do ano. Posteriormente usaram esses dados para fazer previsões através da persistência e da média dos dados referentes a algumas semanas passadas. Por outro lado tentaram prever o *input* de carga na rede de origem eólica para *time-steps* de 10 minutos e horizontes temporais de 2 horas. Para isso usaram um método para capturar a tendência de evolução e posteriormente usaram um modelo auto-regressivo para calcular a PPE. Com isto conseguiram alcançar uma PPE marcada pela sazonalidade e usando dados como a produção de energia eólica no dia anterior para a mesma hora conseguiram efectuar PPE com menores erros de previsão, no entanto o modelo não apresentava vantagens face à persistência para ventos atípicos. Por outro lado também estudaram a conjugação das turbinas eólicas com geradores diesel, para diversos horizontes temporais de PPE, do qual concluíram:

- Conseguiu-se uma redução significativa do excesso de carga na rede;
- A previsão da potência tem um maior peso na diminuição do consumo de diesel do que a previsão de vento;
- A persistência conseguiu prever o vento de uma forma mais eficaz do que a carga.

Segundo Costa *et al.* [7] Watson *et al.* [15] estudaram a possibilidade de reduzir os custos resultantes da geração de energia eléctrica que tinha como fonte primária combustíveis fósseis através de uma melhor planificação das operações de manutenção das turbinas eólicas e da redução da reserva girante. Assim, utilizaram um sistema que recorria a dados de um modelo de previsão climatérica que posteriormente eram tratados por um sistema MOS para assim preverem a direcção do vento e intensidade para um horizonte temporal de 18 horas e para *time-steps* de 1 hora. Com este modelo concluíram que se conseguia obter melhores resultados de PPE ao invés de usar a persistência e assim conseguiam uma maior economia no uso de combustíveis fósseis.

Segundo Costa *et al.* [7] Jensen *et al.* [16] anunciaram a ferramenta *Wind Power Prediction Tool* (WPPT), desenvolvida pela *Danmarks Tekniske Universitet* (DTU). Esta ferramenta recorria a AR (*AutoRegression*) para calcular o *output* de potência e utilizava como variável independente a velocidade do vento. Esta ferramenta foi testada para sete parques eólicos da Dinamarca. Para efectuar o estudo usou-se a WPPT para fazer previsões de PPE com *time-steps* de 30 minutos e horizontes temporais a 36 horas. Esta ferramenta apresentava inovações na medida em que recorria a uma função harmónica para representar os padrões diurnos e assumia que a distribuição dos erros de previsão se aproximava de uma distribuição Gaussiana. Os autores referiram que o desenvolvimento futuro desta ferramenta iria passar por incluir previsões climatéricas como variáveis independentes e efectuar previsões para toda a região de estudo (360 MW de potência instalada) com base nos sete parques eólicos que totalizavam 40 MW de potência instalada recorrendo a uma ferramenta de *Upscalling*.

Segundo Costa *et al.* [7] Madsen [17] continuou o trabalho de Jensen *et al.* publicando os resultados obtidos pela DTU para a zona de ELSAM e SEP usando a ferramenta WPPT. Nesta publicação descreveu vários métodos para fazer a PPE. Além disso, descreveu um método para fazer uma previsão *upscaling* e avaliou estes métodos utilizando dados *online*. Segundo a avaliação, o modelo que melhor desempenho obteve foi um modelo AR que recorria a uma série harmónica para representar os padrões diurnos.

Segundo Costa *et al.* [7] Lin *et al.* [18] utilizaram diferentes tipos de redes neuronais com diferentes períodos de aprendizagem e diferentes métodos de aprendizagem para efectuar previsões de velocidade e direcção do vento para *time-steps* de 1 segundo conseguindo melhores resultados relativamente a um modelo auto regressivo óptimo.

Bowen *et al.* [19] introduziram o conceito de RIX (*Roughness Index*) value. Este valor é um indicador da orografia do terreno. Os autores utilizaram o RIX value para efectuarem previsões com recurso á ferramenta WASP (*Wind Atlas Analysis and Applications Program*) conseguindo assim resultados mais precisos, já que tinham em conta os valores de rugosidade do terreno.

Segundo Costa *et al.* [7] Akylas *et al.* [20] testaram diversas abordagens utilizando previsões meteorológicas e dados recolhidos por sensores meteorológicos, para efectuar previsões de velocidade

de vento que posteriormente seriam convertidas em potência produzida utilizando curvas de potência. Estas previsões tinham um horizonte temporal de 24 horas e *time-steps* de 1 hora. As diversas abordagens que se destacaram face à persistência foram: a utilização de regressões multivariáveis sobre dados registados por sensores meteorológicos nomeadamente dados de velocidade de vento, temperatura, pressão e evolução da variação de pressão; regressões sobre previsões meteorológicas utilizando dados históricos registados por sensores meteorológicos; correcção de previsões meteorológicas para efeitos de microescala. Sendo que destas três a que menor melhoria teve face à persistência foi a primeira, a segunda e a terceira estiveram bastante próximas em termos de melhoria face à persistência no entanto a que melhor desempenho teve foi a terceira.

Segundo Costa *et al.* [7] Bailey *et al.* [21] apresentaram a ferramenta EWind, desenvolvida pela empresa TRUEWIND, que faz previsões a 48 horas com *time-steps* de 1 hora ou 30 minutos. Esta ferramenta baseava-se num modelo de mesoescala (ForeWind) que recorre a dados de um modelo regional. Assim, esta ferramenta utiliza um modelo MOS para tentar prever as variações futuras de vento para previsões *online*. Além disso, este modelo utiliza duas abordagens consoante a complexidade orográfica onde se situa o parque eólico para efectuar previsões de potência: abordagem estatística e abordagem física.

Segundo Costa *et al.* [7] Beyer *et al.* [22] desenvolveram um modelo baseado no modelo de Troen e Landberg (que efectuava um melhoramento das previsões de vento utilizando dados da orografia, turbulência e outros), para efectuar previsões de vento a 48 horas com *time-steps* de 6 horas para seis localidades diferentes. Seguidamente estas velocidades de vento eram convertidas em potência utilizando a curva de potência característica da turbina fornecida pelo fabricante, obtendo bons resultados para horizontes temporais inferiores a 24 horas. Por último, analisaram qual a correlação espacial dos desvios de previsão concluindo que: a correlação diminuiu com o aumento da distância e que os desvios de previsão para horizontes temporais maiores estavam mais correlacionados do que para pequenos, isto segundo o autor devia-se ao facto de que os erros sistemáticos eram maiores para horizontes temporais mais longos.

Segundo Costa *et al.* [7] Nielsen *et al.* [23] no trabalho intitulado “*A New Reference for Wind Power Forecasting*” defendem que a persistência não deverá ser usada para horizontes temporais superior a algumas horas, tipicamente 3 horas, mas deverá antes ser usada como referência uma média ponderada entre a persistência e a média da potência, consoante a correlação dos dados.

Segundo Costa *et al.* [7] desde o ano 2000 a I&D tem vindo a ser focada principalmente em ferramentas de previsão bastante complexas e no cálculo das incertezas de previsão.

Segundo Costa *et al.* [7] Sfetsos [24] comparou modelos lineares baseados em AR com modelos não lineares baseados em diferentes tipos de NN, nomeadamente: FFNN (*FeedForward Neural Networks*); RBF (*Radial Basis Function network*); RNN (*Recurrent Neural Network*); ANFIS (*Adaptive Neuro Fuzzy Inference System*); NEULONET (*NEUral LOGic NETwork*). Para efectuar previsões de vento a horizontes de 30 minutos. Segundo este estudo para a previsão a um *time-step*, o modelo baseado na NEULONET teve melhor desempenho. De uma forma geral os modelos lineares apresentaram piores resultados face aos resultados dos modelos não lineares e os modelos não lineares apresentaram valores de RMSE (*Root Mean Square Error*) semelhantes.

Segundo Costa *et al.* [7] Lange e Waldl [25] publicaram as suas conclusões sobre as incertezas de previsão do modelo PREVIENTO no trabalho “*Assessing the uncertainty of wind power predictions with regard to specific weather situations*”. Segundo estes a incerteza de previsão do vento não estava ligada à magnitude da velocidade do vento, a incerteza de previsão era amplificada quer pela curva de potência quer pelo erro médio de previsão e que a incerteza de previsão variava para uma dada localização conforme as condições meteorológicas.

Segundo Costa *et al.* [7] Watson *et al.* [26] divulgaram resultados obtidos pela ferramenta Prediktor. Nestes referiam que a ferramenta tinha alcançado bons resultados para efectuar previsões para 15 parques eólicos situados na Irlanda, sendo que ainda faltava calibrar a ferramenta para localizações específicas.

Segundo Costa *et al.* [7] Giebel *et al.* [27] referiram um projecto financiado pelo Ministério da Energia Dinamarquês para o desenvolvimento de uma ferramenta num prazo a três anos denominada *Wind Power Prediction Tool* (WPPT), que tinha como objectivo efectuar previsões de potência para toda a potência eólica instalada Dinamarquesa. Mais tarde estas duas ferramentas (Prediktor e WPPT) deram lugar a uma ferramenta de previsão a que se deu o nome de Zephyr, esta junção tinha como objectivo dotar esta nova ferramenta com as previsões do Prediktor que tinham um horizonte temporal de 6 horas e com as previsões do WPPT que tinham um horizonte temporal entre 6 horas e o limite de previsão dos serviços meteorológicos. Além disso, o Zephyr foi dotado de uma ferramenta de *Upscaling* que permitia efectuar previsões para os parques eólicos para os quais não existiam previsões.

Segundo Costa *et al.* [7] Martí *et al.* [28] estudaram a influência da utilização de diferentes resoluções para obter dados de previsão, através do modelo HIRLAM, para um parque eólico situado em Espanha em terreno moderadamente montanhoso. Para efectuarem o estudo utilizaram um modelo para prever a velocidade do vento, um modelo que calculasse a curva de potência e um modelo que transformasse as previsões de velocidade do vento em potência gerada pelas turbinas. Relativamente ao primeiro modelo e para dois tipos de resolução foram calculadas previsões de vento seguindo as seguintes abordagens: interpolação de dados para uma dada localidade usando os quatro valores da grid point mais próxima, correcção da densidade da velocidade do vento usando para isso previsões da pressão e temperatura ao nível do mar, *Downscaling* e posterior cálculo de velocidade do vento. Os segundo e terceiro modelos foram baseados numa regressão polinomial adaptativa tendo como variável a orientação do vento, dos quais retiraram as conclusões: os modelos com base em dados HIRLAM com maior resolução obtiveram sempre melhores resultados para horizontes temporais até 24 horas, do que modelos de menor resolução e que independentemente da dimensão da malha o *Downscaling* teve melhor desempenho do que a interpolação e do que modelos baseados na correcção da densidade.

Focken *et al.* [29] efectuaram previsões de potência para horizontes temporais a 48 horas para 30 parques eólicos em diversas localizações. Com este trabalho concluíram que o erro de previsão era mais sensível à dimensão da região a prever do que propriamente ao número de parques, observando que efectuando um *spacial smoothing* conseguiam melhorar de forma substancial as previsões. Os autores referiram que para um sistema com um diâmetro de implementação de sensivelmente 370 Km e com um número de medidas relativas a menos de 50 locais se conseguia reduzir o erro em cerca de 63%.

Segundo Costa *et al.* [7] Costa *et al.* [30] anunciou o desenvolvimento do projecto UPMPREDICTION. Este teria como objectivo principal combinar as duas abordagens, matemática e física, para efectuar previsões mais precisas. Após esta fase estar concluída, o próximo passo seria desenvolver uma ferramenta de previsão *online* que tivesse em mente a gestão de carga na rede assim como o mercado energético. Para isso numa primeira fase a *Universidad Politécnica de Madrid* e CIEMAT testaram os seguintes tipos de modelos matemáticos: modelos AR, modelos *fuzzy logic-based*, modelos baseados nas NN, sendo que este último foi o que melhor desempenho teve face à persistência.

Segundo Costa *et al.* [7] Palomares e de Castro [31] testaram a qualidade dos dados da ECMWF para a zona de Gibraltar usando para isso dados de vento registados em estações meteorológicas, tendo sido efectuadas 10 variações de modo a adequar os modelos às variações da direcção do vento consoante a época do ano e tendo efectuado previsões a 48 horas concluíram que: as previsões de vento mantinham a qualidade apesar do horizonte temporal. Os melhores resultados foram obtidos para ventos de leste e os piores resultados foram obtidos para velocidades de vento inferiores a 1 m/s.

Segundo Costa *et al.* [7] Lozano [32] apresentou os resultados preliminares para um modelo desenvolvido pela IBERDROLA que se baseava numa abordagem física à problemática da previsão eólica e que recorria a dados do modelo global NCEP/NCAR e de modelos de microescala/mesoscala para efectuar previsões a 48 horas com *time-steps* de 30 minutos.

Segundo Yuan-kang e Jing-Shan [33] Makarov *et al.* [34] que desenvolveram um algoritmo para a CAISO (*California Independent System Operator*) baseado no modelo ARIMA (*AutoRegression Integrated Moving Average*) para efectuar previsões de vento a horizontes de 02hr30. Os coeficientes do modelo foram ajustados de forma adaptativa de modo a obter previsões mais precisas e foi adicionado um termo ao algoritmo de forma a calcular o viés de uma forma adaptativa. Os autores referiram a necessidade de incorporação de variáveis meteorológicas assim como a incorporação de informação

relativamente a estas. Outro aspecto que concluíram, foi que a previsão de produção de energia (MWh) tem um menor erro associado do que a previsão de potência (MW) sendo assim mais preciso prever energia eólica.

Segundo Costa *et al.* [7] Gallardo *et al.* [35] anunciaram a colaboração entre a *Universidad de Castilla-La Mancha, Barlovento Recursos Naturales* e *Gamesa Energía* para a elaboração do projecto CASANDRA. Esta ferramenta de previsão tinha como objectivo efectuar previsões a horizontes de 72 horas com *time-steps* de 1 hora. Esta baseava-se na obtenção de dados do modelo global NCEP, modelo de mesoescala, num módulo MOS que serviria para tratamento dos dados obtidos pelo modelo de mesoescala tendo em conta diversas variáveis (temperatura, pressão, direcção do vento, entre outros), baseou-se num modelo *multivariate regression* e num modelo da curva de potência. Por último, o modelo fornece também intervalos de confiança para essas previsões dando assim ao operador uma informação importante para a gestão do sistema. Os autores depois utilizaram esta ferramenta para efectuar previsões de potência para dois parques eólicos situados em tipos diferentes de terreno, tendo obtido bons resultados de previsão. Os autores apontaram ainda que o uso de técnicas combinatórias seriam uma opção para diminuir o erro de previsão.

Segundo Yuan-kang e Jing-Shan [33] Pinson e Kariniotakis [36] apresentaram um modelo que utilizava dados de SCADA, dados de modelos NWP (*Numerical Weather Prediction*) e um modelo baseado em AFNN (*Adaptive Fuzzy Neural Networks*) para efectuar previsões de vento a horizontes de 10 horas e 48 horas. Conjuntamente com este modelo foi elaborado um método *online* que permitia aferir intervalos de confiança das previsões efectuadas pelo modelo assim como a qualidade das previsões efectuadas pelo modelo. Este modelo e método foram posteriormente avaliados para alguns parques eólicos situados na Irlanda durante um ano, sendo que o modelo proposto obteve melhorias relativamente á persistência.

Giebel *et al.* [37] apresentam de uma forma detalhada os actuais métodos de previsão, ferramentas *software* e projectos de I&D para efectuar previsões de potência. Além disso, efectuaram um estudo comparativo entre ferramentas de previsão classificando-as consoante a abordagem adoptada para efectuar previsões, a escala de resolução e desempenho das previsões *online* assim como a relevância da informação para a gestão da rede. Nesta publicação os autores referem que o desempenho das ferramentas advém em grande medida da tipologia do terreno, ou seja, se este é plano, complexo ou muito complexo referindo que estas características fazem com que seja difícil a comparação entre as várias ferramentas.

Segundo Costa *et al.* [7] Madsen *et al.* [38] apresentaram uma proposta de protocolo com vista a uniformizar a avaliação das técnicas de previsão. Neste sentido referiu que o uso da persistência como medida de referência pode levar a erros de interpretação já que ao comparar as previsões com a persistência pode sobrevalorizar os modelos em estudo. Os autores calcularam os erros de previsão utilizando para isso a base de dados do projecto ANEMOS referindo a relevância de calcular as incertezas associadas às previsões.

Segundo Costa *et al.* [7] Bustamante *et al.* [39] estudou o comportamento de duas abordagens distintas: o uso de modelos baseados em modelos AR e modelos baseados em NN; o uso de modelos baseados em *Downscaling* estatístico e *Downscaling* dinâmico para efectuar previsões a muito curto prazo. No modelo baseado em *Downscaling* estatístico (com recurso a AR) foram utilizados os dados do ERA40 project reanalysis, de modo a ser excluída informação redundante e a utilizar os padrões já observados foi feita uma regressão linear sobre as observações. Por último, foi feito um estudo baseado em *Downscaling* dinâmico (com recurso a NN) utilizando o modelo de mesoescala MM5. Assim, os autores concluíram que um modelo que utilize dados provenientes de bases de dados tratados, como o ERA15 ou o ERA40, e utilize dados de modelos de mesoescala, como o modelo MM5, consegue efectuar melhores previsões.

Segundo Costa *et al.* [7] Pinson e Kariniotakis [40] desenvolveram uma metodologia *online* para efectuar a avaliação do risco associado às previsões de potência. Este baseava-se numa reanálise das previsões para efectuar bandas de confiança. Estes introduziram o conceito do *meteo-risk index* que deveria ser usado para ajustar as bandas de confiança das previsões de potência e sugeriram que este fosse também utilizado como indicador da probabilidade de ocorrência de elevados erros de previsão.

Segundo Costa *et al.* [7] Kariniotakis *et al.* [41] no âmbito do projecto ANEMOS apresentaram os resultados obtidos para 6 parques eólicos situados em regiões a oeste e a norte do continente Europeu, que compreendiam as seguintes tipologias de parques eólicos: 1 *offshore*, 2 *onshore* terreno plano, 2 *onshore* terreno complexo e 1 terreno muito complexo. Este estudo teve por base o uso de previsões efectuadas a 12 horas, sendo que nem sempre foram utilizados os mesmos modelos para todos os parques eólicos e que os períodos de validação também não foram sempre coincidentes. A partir deste estudo concluíram que: 1) a resolução da malha usada pelo NWP é de elevada importância especialmente em terreno complexo; 2) o desempenho do modelo era pior para terrenos complexos, mostrando assim alguma dependência da orografia; 3) a dispersão dos erros de previsão era mais acentuada para terrenos complexos; 4) os modelos tendo em conta os vários *time-steps* efectuaram previsões com erros muito semelhantes e 5) apontaram a necessidade de efectuar previsões combinatórias de modo a reduzir o erro de previsão.

Segundo Costa *et al.* [7] Torres *et al.* [42] publicaram os resultados obtidos para previsões de velocidade de vento utilizando modelos baseados em ARMA (*AutoRegression Moving Average*), para horizontes temporais a 10 horas e *time-steps* de 1 hora. Para este estudo utilizaram dados relativos a 9 anos e que eram compostos por medições em 5 estações meteorológicas distintas, optando por uma abordagem *offline*. Os autores optaram por subdividir os dados por mês, de modo a evitar a sazonalidade e aproximar os dados a uma distribuição gaussiana. Deste modo conseguiram obter melhorias face à persistência, sendo isto suportado pela redução do RMSE (*Root Mean Square Error*). Nesta publicação ainda referiram que para certos valores de vento o RMSE também era superior, revelando assim um certo grau de dependência entre o erro e a velocidade do vento.

Segundo Costa *et al.* [7] Madsen *et al.* [43] referiram a necessidade de definir um *benchmark* de avaliação de modo a ser possível comparar as previsões efectuadas pelos vários modelos. Neste sentido sugeriram um conjunto de medidas e fizeram sugestões para efectuar avaliações, entre elas: calcular o NBIAS (*Normalized BIAS*), calcular o NMAE (*Normalized Mean Absolut Error*) e calcular o NRMSE (*Normalized Root Mean Square Error*). Estas medidas de avaliação são, segundo os autores os valores essenciais para avaliar um modelo de previsão sendo que estes deveriam ser calculados por *time-step* e para toda a série de dados assim como para porções mais restritas da série de dados. Referem ainda que os valores necessários para efectuar uma avaliação dependem da necessidade.

Segundo Costa *et al.* [7] Nielsen *et al.* [44] propuseram um método baseado no modelo dos quartis das previsões dos erros. Este baseava-se na utilização de modelos de LQR (*Linear Quantile Regression*) e modelos aditivos paramétricos. Para aferir a sensibilidade e a distribuição dos erros entre o primeiro e terceiro quartil variaram a previsão de potência prevista pelo WPPT, horizontes temporais, dados do modelo HIRLAM (variando densidade do ar, superfícies, velocidade e direcção do vento a 10 metros) e influência do *meteo-risk index*. Concluíram que: a variável mais relevante era a previsão de potência, o *meteo-risk index* pareceu não ter influência no estudo dos quartis e o modelo aditivo paramétrico foi o adoptado devido à possibilidade de inclusão de diversas variáveis.

Segundo Costa *et al.* [7] Cenã [45] apresentou os resultados finais do estudo, que teve a duração de 13 meses, lançado pela Plataforma Empresarial Eólica que posteriormente foi alargado a 8 ferramentas de previsão eólica e a 7 parques eólicos das seguintes topologias: 2 parques estavam numa zona costeira, 1 estava num terreno plano, 2 estavam em terreno complexo e os últimos 2 estavam em terreno muito complexo. Deste estudo concluíram que: a precisão da previsão de ventos dependia da velocidade do vento. Aparentava existir um limite mínimo da NMAE de cerca de 25% para o valor de potência utilizando as técnicas e métodos actuais até à data. Contrariando o expectável o terreno não aparentava influenciar a qualidade das previsões. Os vários parques deveriam ser agregados de modo a reduzir os erros de previsão. A persistência poderia ter um erro associado relativamente menor que outros modelos para horizontes temporais a muito curto prazo de tempo e consoante os modelos NWP's (*Numerical Weather Prediction*), um modelo estatístico poderia ser suficientemente bom para efectuar previsões.

Em Fevereiro de 2006, durante a *European Wind Energy Conference*, foi organizado um *workshop* com o objectivo de informar sobre os desenvolvimentos do projecto ANEMOS. Segundo Costa *et al.* [7] uma das contribuições foi da responsabilidade de Martí *et al.* [46] que discutiram os resultados obtidos entre a distribuição dos erros de previsão e a previsão de potência, tendo em conta 4 valores distintos (viés, desvio padrão, assimetria e curtose). Também propuseram um método combinatório de

previsão que juntasse todas as previsões numa só, este era composto por 2 passos: o 1º passo consistia numa regressão, cujo objectivo seria melhorar as previsões através de uma regressão linear e o 2º passo consistia em escolher a melhor previsão entre estas.

Segundo Costa *et al.* [7] Costa *et al.* [47] informou sobre o projecto “*First results from a prediction project*” e “*Short-term wind prediction model at the Strait of Gibraltar based on a perfect prognosis statistical downscaling method*”, propondo a junção de um modelo matemático e um modelo físico. Esta junção denominada *Best Intersection point Tracking* ou *B.I.Tracking* baseava-se numa combinação de diversas previsões consoante a intersecção das curvas dos erros de previsão dos modelos. Deste modo, ao saber-se o ponto de intersecção dos erros dos modelos seria dado mais importância ao que tivesse menor erro associado do que o outro, melhorando assim a previsão final e juntando os dois modelos. Relativamente aos modelos em si propuseram uma discretização sectorial do problema, correcções orográficas de microescala e/ou correcções de instabilidades, sempre que isso trouxesse uma diminuição do valor do erro de previsão para um determinado sector. Por último os autores referiram que tinham intenção de acoplar um modelo de *Downscaling* dinâmico através de modelos de mesoscala (MM5, WRF) aos modelos físicos/matemáticos.

Cadenas *et al.* [48] compararam o desempenho dos métodos ARIMA (modelo SARIMA-*Seasonal AutoRegression Integrated Moving Average*) e ANN's (modelo ADALINE-*Adaptive Linear Neuron or later Adaptive Linear Element*) aplicados à previsão da velocidade do vento para a costa sul no estado de Oaxaca, México. Estes modelos utilizaram séries temporais de velocidade de vento para efectuar a calibração, sendo que a série de dados totaliza 6 anos de registos, e para efectuar a validação utilizaram uma série de dados anual de velocidade do vento. Este estudo concluiu que ambos os modelos conseguiam efectuar previsões válidas para o local de estudo sendo que o modelo SARIMA demonstrou um melhor desempenho.

Em Madrid, no ano de 2008, realizou-se o *3rd Joint Action Symposium on Forecasting: Optimal Use of Available Information in Wind Power Forecasting* que foi organizado pelo CENER, das quais resultaram as seguintes contribuições:

- Vincent [49] em “*Analysing Wind Fluctuations Using an Adaptive Spectral Method*” utilizou o método *Hilbert-Huang Transform* para analisar a variabilidade do vento no parque eólico de *Horns Rev* situado no mar do norte, em águas Dinamarquêsas. Para isso foram registadas observações de vento a cada 10 minutos e posteriormente foi analisada a variabilidade deste em função da direcção do vento, precipitação, estação do ano e outras. O estudo revelou que a variabilidade eólica depende da estação do ano, da precipitação e outros factores atmosféricos. O autor referiu ainda a intenção de utilizar um modelo de análise de dados físicos para avaliar a variabilidade espacial e temporal do vento assim como verificação de séries de previsão;
- Kariniotakis *et al.* [49] comentaram os projectos ANEMOS.PLUS e SAFEWIND. Estes dois teriam funções diferentes mas complementares já que o projecto ANEMOS servia para efectuar previsões de potência eólica e respectivos graus de incerteza facilitando assim a gestão da rede (planeamento de reservas, gestão de congestionamentos, planeamento de manutenção, compra/venda de electricidade no mercado, entre outros). O projecto SAFEWIND estava direccionado para a previsão de eventos extremos de eolicidade, ou seja a variabilidade temporal da PPE, (rampas, erros significativos de previsão, entre outros) a vários períodos de tempo (a minutos, a horas e a dias) a diversas escalas espaciais (escala local, regional e/ou continental) de modo a que se consiga antever estes acontecimentos e se consiga lidar com estes efectuando uma actualização de previsões a muito curto prazo (0-6 horas) e a médio prazo (1-vários dias). Os autores nas suas conclusões salientaram que o *state-of-the-art* da previsão de potência eólica incluía até à data: cálculo de valores de incerteza para modelos determinísticos, variados métodos combinatórios, variados modelos numéricos de previsão meteorológica assim como variados modelos de previsão de potência eólica e modelos combinatórios destes, incertezas de previsão (índices de incerteza) e previsão probabilística (Função de Distribuição de Densidade). Estes continuaram referindo que era necessário demonstrar e desenvolver novos métodos de apresentação de resultados aos utilizadores finais e que seria necessário desenvolver novos métodos estocásticos que tivessem em conta de forma coerente, diversas previsões assim como as suas incertezas;

- Ismael Sánchez [49] na sua apresentação deu uma visão global do SIPREÓLICO (uma ferramenta estatística de previsão eólica), nesta abordou o tema previsões adaptativas de modelos paramétricos e por último abordou o tema combinações adaptativas de previsões. O autor apresentou o SIPREÓLICO que efectuava previsões para mais de 500 parques eólicos a cada 15 minutos para horizontes temporais de 48 horas e *time-steps* de 1 hora com base em medições *online* de potência e com base em previsões meteorológicas de vento. Esta ferramenta utilizava diversos modelos que corriam em paralelo que seriam posteriormente combinados consoante o seu erro. O autor referiu que esta recorria a dados da persistência que eram usados em modelos auto regressivos a horizontes de 1-4 horas, modelos paramétricos dinâmicos ARX para horizontes de 4-10 horas e modelos que usavam apenas dados de vento para efectuar previsões a horizontes no intervalo 10-48 horas. Por outro lado referiu que este modelo utiliza modelos paramétricos para parques eólicos recentes ou para os quais não existem dados e modelos não paramétricos para parques que tenham séries de dados disponíveis. Ismael passou ao tema de combinações adaptativas referindo que estas podem ser de dois tipos: combinações de melhoria e combinação de adaptação. As combinações de melhoria serviriam para melhorar as previsões de base, sendo que, para estas sugeriu métodos estatísticos e para as combinações de adaptação sugeriu um novo método a que deu o nome de combinação adaptativa exponencial. Por último, referiu a I&D em curso: melhoria de métodos não paramétricos recursivos, procura e avaliação de novas agências meteorológicas, utilização de medições de vento em parques eólico *online*.

Duran *et al.* [50] optaram pela utilização de métodos estatísticos para efectuar previsões de potência devido a estes constituírem métodos amplamente estudados e testados. Para o presente estudo foram usados modelos AR (*AutoRegressive*) que utilizavam dados históricos de vento, sendo os resultados posteriormente comparados com a persistência. Assim, o modelo foi calibrado utilizando para isso dados de uma série anual e efectuaram-se previsões para diversos parques eólicos para horizontes temporais de 6 horas, 12 horas e 24 horas, já que estas podiam ser uteis para o mercado de energia. Os autores concluíram que: a série anual de calibração mostrou-se suficiente sendo que o uso de dados anteriores poderia até prejudicar as previsões. Verificou-se que para efectuar a calibração do modelo havia vantagens em utilizar não só dados reais mas também estimativas. O modelo apresentou uma melhoria de 15,6% face à persistência e apontaram como próximo passo para melhorar as previsões a incorporação de um modelo estatístico que utilizasse a velocidade de vento como *input* de dados.

Fugon *et al.* [51] efectuaram previsões para 3 parques eólicos a horizontes de 60 horas e *time-steps* de 3 horas utilizando variadas técnicas de prospecção de dados, utilizando como *input* dados de modelos meteorológicos de previsão. Entre os modelos estavam: modelos lineares (*Linear Regression*) e modelos não lineares (*Neural Networks, Random Forests e Support Vector Machines*), sendo que todos os modelos avaliados tiveram melhores desempenhos face à persistência e destes o que melhor desempenho teve foi o *Random Forests*.

Sánchez [52] propôs técnicas combinatórias adaptativas de previsão a que deu o nome de *Adaptive Exponential Combination* (AEC), este método é uma variação do método *Aggregated Forecast Through Exponential Re-weighting* (AFTER) proposto por Yang e consiste em escolher a cada instante de previsão uma combinação óptima das previsões feitas no instante anterior com menor erro associado. O autor propôs um método combinatório dividido em duas fases o que permitiria usar diferentes combinações e posteriormente escolher a que melhor se adaptava num determinado instante. Assim, numa primeira fase, este método recorria a diferentes métodos combinatórios de previsão para efectuar um conjunto de previsões dando a este processo o nome de *combination for improvement* e numa segunda fase efectuou uma combinação com as previsões que obtiveram um melhor desempenho com base num passado recente. Para a validação deste método foram utilizados dados registados em dois parques eólicos tendo este método efectuado previsões de potência com menores erros de previsão associados.

Kusiak *et al.* [53] efectuaram previsões a muito curto, a curto e a médio prazo. Para isso subdividiram os horizontes temporais em dois grupos e posteriormente fizeram a combinação dos dois grupos. O primeiro grupo contemplava um horizonte temporal até 12 horas e o segundo um horizonte temporal até 84 horas e ambos tinham *time-steps* horários. Para isso utilizaram cinco tipos diferentes de

algoritmos de prospecção de dados, previsões meteorológicas a vários horizontes, medições de SCADA e calcularam os erros de previsão. Neste estudo foram avaliados os algoritmos K-NN (*K-Nearest Neighbor algorithm*), MLP Network (*MultiLayer Perceptron Network*), SVMreg (*Support Vector Machine Regression*), RBF (*Radial Basis Function*), C&R Tree (*Classification and Regression Tree*) e *Random Forest*, sendo que o algoritmo MLP que efectuava previsões de velocidade de vento que eram depois utilizados como *input* no algoritmo K-NN, tendo este obtido o melhor desempenho em ambos os grupos (até 12 horas e até 84 horas). Os autores concluíram também que os modelos obtiveram desempenhos razoáveis em ambos os grupos, sendo que o erro destes estava dependente das previsões meteorológicas que eram utilizadas como *input*. Verificaram também que para horizontes temporais até 5 horas tornava-se mais vantajosa a utilização de dados de persistência, obtendo-se assim melhores resultados do que MLP network. Neste paper foi salientado o facto de que existia a desvantagem de não serem tidas em conta informações como a orografia do terreno, a localização do parque eólico, os grid points utilizados na previsão eólica, falta de informação essa que permita a explicação dos resultados obtidos pelas técnicas de prospecção de dados à luz das teorias actuais e o facto de apenas terem sido usados 3 meses de dados de SCADA deixando de fora a análise sazonal. Por último os autores defendem a incorporação de outros métodos como o *Cascade Neural Network* e *Fuzzy Logic* como forma de melhorar as previsões.

Yamaguchi *et al.* [54] utilizaram dados de modelos numéricos de previsão do tempo e dados de SCADA como *input* para efectuarem previsões a horizontes de 6 horas e 24 horas para 9 parques eólicos com recurso ao método ARXM (*AutoRegression with eXogenous input and Multi-timescale parameter*). Com o modelo proposto, a previsão de potência era calculada em separado para cada parque eólico sendo posteriormente somadas para obter a previsão de potência eólica regional. Os autores utilizando esta metodologia conseguiram reduzir o tempo de cálculo de algumas horas e utilizando diversos CPU em paralelo para apenas um CPU que demorava alguns segundos a efectuar os cálculos, sendo que obtiveram praticamente o mesmo erro que obtiveram com o modelo de mesoscala de resolução de 20 km.

Møller *et al.* [55] apresentaram um modelo baseado em *Time Adaptive Quantile Regression*. Este recorria ao algoritmo *Simplex* e uma optimização linear de um modelo regressivo dos quartis para efectuar previsões com base em observações passadas e necessitando menor memória física para efectuar os cálculos. O modelo recorreu a dados de previsão, a horizontes no intervalo das 18-36 horas com *time-steps* de 15 minutos, fornecidas pela *Wind Power Prediction Tool* (WPPT) para um parque eólico Dinamarquês. O modelo proposto foi posteriormente comparado com um modelo estático de *Quantile Regression* tendo obtido resultados mais precisos para todos os parâmetros considerados.

Ramirez-Rosado *et al.* [56] descreveram dois modelos o SGP system e o FORECAS.

- O FORECAS consistia num modelo que utilizava as últimas observações de SCADA e as previsões de velocidade média do vento feitas pelo modelo numérico de previsão meteorológica MM5 para efectuar previsões de potência a horizontes de 72 horas. Este modelo era composto por vários modelos PCM (*Power Curve Model*), um para cada turbina eólica. Estas eram representadas por uma MLP (*Multi Layer Perceptron*) que era composta por uma *hidden layer* que continha 13 neuróns que permitia efectuar as previsões de produção de potência para cada turbina utilizando dados de velocidade média e direcção do vento fornecidos pelo modelo MM5 e as observações de SCADA. Deste modo e embora fosse um modelo puramente estatístico permitia a incorporação de um modelo físico, nomeadamente um algoritmo de CFD (*Computed Fluid Dynamics*) para representar espacialmente a disposição das turbinas a partir de um conjunto de pontos da malha de previsão. O modelo era composto por mais 4 módulos: WFLM (*Wind Farm Losses Model*) que calculava o erro da produção de potência devido a orientação do vento e outras características, PAM (*Power Agregation Model*) responsável pela agregação dos vários modelos PCM e que contabilizava os resultados obtidos pelo WFLM, AR que utilizava observações de SCADA para efectuar previsões de observação a um determinado *time-step* e um último módulo a que deram o nome de NNAM que efectuava as previsões de produção de potência utilizando para isso os valores deduzidos pelos módulos PAM e AR;
- O SGP system recorria a dados fornecidos por um modelo numérico de previsão meteorológica (NWP) e a observações de SCADA para efectuar previsões de potência. As previsões

meteorológicas foram previamente tratadas com recurso a um Filtro de Kalman de modo a melhorar as previsões de vento. Este consistia num conjunto de modelos que funcionavam em conjunto de modo a efectuar previsões a horizontes de 72 horas. O sistema utilizava as observações *online*, as observações passadas e previsões meteorológicas como *input* para 11 modelos distintos (entre os quais um modelo ARMA, 9 modelos de redes neuronais dos quais: *Multi Layer Perceptron*; *Feed Forward Back Propagation neural network*; redes neuronais modulares) dos quais posteriormente eram feitas combinações de 3 destes modelos como *input* para um outro modelo FIS (*Fuzzy Inference System*) totalizando 9 modelos *Takagi-Sugeno-Kang* (TSK) FIS de primeira ordem. Estes serviam para efectuar combinações não lineares entre os 3 modelos escolhidos e efectuavam previsões a horizontes de 00hr30, 01hr00, 01hr30, 02hr00, 02hr30, 03hr00, 03hr30, 04hr00 e 04hr30. Paralelamente a estes modelos, o sistema possuía também outros três modelos especializados em efectuar previsões entre os seguintes horizontes temporais 05hr00-24hr00, 24hr30-48hr00 e 48hr30-72hr00.

- Os modelos foram testados para um parque eólico situado no norte de Portugal com terreno complexo. Estes alcançaram resultados significativos sendo que o que melhor desempenho teve de uma forma geral foi o *SGP system*;
- Actualmente tem-se focado no desenvolvimento de modelos de previsão de potência eólica que recorram a diversas previsões meteorológicas combinando-as para originar apenas uma, além disso tem-se focado também na utilização de observações para efectuar correcções de fase ou para emitir alertas devido a elevados riscos de incerteza.

Numa publicação a NERC (*North American Electric Reliability Corporation*) [57], os autores defendem que as rampas descendentes podem ser mais difíceis de prever do que as rampas ascendentes e que uma previsão de rampas se torna complicado já que ainda não existem modelos que consigam reproduzir completamente o comportamento do clima a escala desejada. Por outro lado, afirmam que a ocorrência de rampas se pode dever a factores distintos, separando os factores que proporcionam a ocorrência das denominadas rampas ascendentes das rampas descendentes. Segundo esta entidade as:

- Rampas ascendentes podem dever-se a: *passagem de frentes frias; thunderstorm outflow; rapid intensification of an area of low pressure; onset of mountain wave events (lee of mountain ranges); flow channeling; sea breeze; thermal stability/vertical mixing.*
- rampas descendentes podem dever-se a: *near-surface boundary layer stabilization at sunset/nightfall; relaxation of pressure gradient as high pressure moves in following cold front passage; pressure changes following the passage of thunderstorm complexes; a decrease in wind speed as a warm front passes.*

Mendes *et al.* [58] descrevem 5 definições distintas de cálculo de rampas, no entanto, afirmam que à data não existe consenso relativamente à sua definição. Apesar disto, os autores afirmam que uma rampa pode ser caracterizada pela sua: magnitude, direcção e duração. Os autores relataram ainda:

- Greaves *et al.* [59] definiram a ocorrência de rampas como variações de *output* de potência de um parque eólico na ordem de 50% de potência instalada durante um período igual ou inferior a 4 horas;
- O relatório AWS Truewind [60] refere que uma rampa ascendente importante ocorre se existir uma variação de *output* de potência de 20% de potência instalada no espaço de 1 hora. Por outro lado considera-se que uma rampa descendente importante ocorre se existir uma variação de *output* de potência de 15% da potência instalada no espaço de 1 hora;
- Potter *et al.* [61] consideram que ocorre uma rampa se em duas horas consecutivas ocorrer uma variação de *output* de potência igual ou superior a 10% da potência nominal de um parque eólico.

Amjady *et al.* [62] propuseram um novo modelo que recorria a multivariáveis para efectuar previsões de velocidade do vento. Assim o modelo baseava-se na interacção de certos parâmetros climatéricos como a velocidade do vento e temperatura para efectuar as previsões. Para efectuar as previsões utilizaram-se dados de velocidade de vento e temperatura anteriormente observados de 10 e

30 minutos para um parque eólico Espanhol e outro Iraniano assim como dados de previsão de velocidade de vento e temperatura para os mesmos locais. Os autores recorreram aos métodos: *modified relief*, *mutual information techniques* e redes neurais iterativas para elaborar o novo modelo de previsão. Os resultados obtidos foram posteriormente testados para as mesmas localidades tendo obtido resultados significativos de melhoria comparativamente com a bibliografia consultada para o efeito.

Peng *et al.* [63] propuseram um modelo, ARIMA-ARCH, baseado na teoria de séries temporais não estacionárias e em modelos ARCH (*AutoRegressive Conditional Heteroskedasticity*). Numa primeira fase as séries temporais da velocidade do vento são decompostas e reconstruídas nas séries aproximadas e séries detalhadas pelo método de wavelet analysis e numa segunda fase são utilizados modelos ARIMA (*AutoRegression Integrated Moving Average*) para analisar as séries tendo em conta o efeito de heteroscedasticidade dos erros. Para efectuar as previsões finais de velocidade de vento somava-se as previsões obtidas pelas séries aproximadas e pelas séries detalhadas obtendo-se assim previsões mais precisas de velocidade de vento. O modelo foi posteriormente testado demonstrando que conseguia melhorar as previsões de velocidade de vento.

Domínguez-Navarro *et al.* [64] compararam a percentagem de melhoria a vários horizontes temporais com distintos *time-steps* para velocidades de vento, utilizando para isso modelos regressivos. Posteriormente compararam os resultados obtidos sem serem filtrados ou sendo filtrados com recurso a vários modelos de *Wavelet*. Os resultados obtidos face à persistência foram expressivos sendo que as previsões se tornaram mais precisas após serem filtradas. Além disso os autores referiram que existiam modelos baseados em *Wavelet* que se adequavam melhor a certos horizontes temporais. Outro aspecto foi o facto de que após a aplicação do filtro as previsões apresentaram uma maior correlação com as observações.

Lydiaa *et al.* [65] abordaram a modelação da curva de potência característica de uma turbina eólica (*Wind Turbine Power Curve modeling*) no qual efectua uma comparação entre vários métodos paramétricos (*linearized segmented model*, *polynomial power curve*, *maximum principle method*, *dynamical power curve*, *probabilistic model*, *ideal power curve*, *four parameter logistic function* e *five parameter logistic function*) e modelos não-paramétricos (*copula power curve model*, *cubic spline interpolation technique*, *neural networks*, *fuzzy methods* e *data mining algorithms*) para calcular a curva de potência de uma turbina. Deste estudo concluíram que os métodos *4-parameter logistic function* e *5-parameter logistic function* foram os que melhor desempenho obtiveram.

3.2 PREVISAO DE POTÊNCIA EÓLICA (PPE)

Entende-se por PPE a Previsão de Potência Eólica em média durante um determinado intervalo de tempo a que se dá o nome de *time-step* (i), sendo que a PPE é efectuada num período anterior (t) ao período em que vigora a PPE com intervalos regulares, para um horizonte temporal (h). As necessidades do *Transmission System Operator* (TSO), determinam o horizonte temporal (h) a que se efectua as PPE assim como a duração do *time-step* (i). Desta forma, pode-se definir o horizonte temporal como $h = ni$, sendo n o número de *time-steps* que compõem um determinado horizonte temporal.

Assim, as previsões podem ser caracterizadas pelo número de *time-steps* (i), horizonte temporal (h) e número de actualizações/corridas.

- *Time-step* (i) - o menor intervalo de tempo de previsão (normalmente 10, 15, 30 ou 60 minutos);
- Horizonte temporal (h) – período em que vigoram as previsões. Pode-se definir horizonte temporal (h) como sendo a soma de todos os *time-steps* de uma corrida.




Fig. 7 –Relação entre *time-step* e o horizonte temporal.

- Actualização é o intervalo regular a que se efectuam actualizações das previsões e das observações. A actualização das previsões é efectuada enriquecendo os modelos com recurso a observações em tempo real e realizando novas corridas dos modelos. Isto implica que ocorra sobreposição de informação, no entanto isto não é necessariamente uma desvantagem já que os dados mais recentes tendem a ser os mais precisos e por outro lado a existência de diversas previsões pode ser benéfica para reduzir o erro de previsão através da sua combinação otimizada. Relativamente às actualizações das observações podem ser em tempo real (SCADA) e/ou estarem disponíveis com um determinado atraso, obtidos com recurso a contadores (METER).

A PPE é efectuada para vários horizontes temporais. Os limites da PPE são bastante variáveis [66]. No entanto, vários autores tendem a subdividir a PPE em PPE a Muito Curto Prazo (PPE-MCP), PPE a Curto Prazo (PPE-CP) e PPE a Médio Prazo (PPE-MP).

A PPE-MCP é variável. Alguns autores definem-na como sendo 4 horas [67], outros 6 horas e outros ainda referem que será 9 horas [66]. Este tipo de PPE é necessária para o mercado de energia diário, segurança de abastecimento com custos de geração mais baixos, gestão de cargas na rede e contribuí para uma melhor qualidade de serviço (Tabela 1).

A PPE-CP é variável, sendo que vários autores definem como sendo 36 horas, outros 48 horas e outros ainda referem que será 72 horas. Este tipo de PPE é necessária para o mercado de energia a um dia, manutenção dos grupos de geradores incluindo as próprias turbinas, manutenção de linhas de transmissão de energia, gestão de cargas na rede, planeamento de bombagem em períodos em que existem excedentes de energia produzida, segurança de abastecimento com custos de geração mais baixos e contribuí para uma melhor qualidade de serviço (Tabela 1).

A PPE-MP é variável, sendo que vários autores definem como sendo 3 dias e outros referem que será 7 dias. Este tipo de PPE é necessária principalmente para planeamento de manutenção de linhas e planeamento de utilização e manutenção de equipamentos envolvidos na geração de energia (Tabela 1).

Tabela 1- Relevância dos horizontes temporais por operador. Adaptado [66]

Time Horizons	GENCOs	SO
Very short-term (up to 9hr)	Intraday market Real-time market	Ancillary services management Unit commitment Economic dispatch Congestion management
Medium-term (up to 72hr)	Day-ahead market Maintenance planning for wind farms Wind farm and storage device coordination	Maintenance planning of network lines Congestion management Day-ahead reserve setting Unit commitment and economic dispatch
Short-term (up to 7 days)	Maintenance planning of wind farms Maintenance planning of conventional generation	Maintenance planning of network lines

Assim, a Previsão de Potência Eólica é de extrema relevância para o *Transmission System Operator*, (TSO), dado que uma maior potência instalada de energia eólica, associada a uma elevada variabilidade deste recurso, implica que seja necessário prever a energia produzida pelo vento a diferentes horizontes temporais. Todavia, há que ter em conta que quanto mais alargado for o prazo de PPE maior será o erro associado.

Por outro lado as PPE existem diversos fins/características de sistemas de PPE, os quais variam consoante os interesses e o papel da entidade em causa no mercado energético.

As possíveis entidades interessadas em efectuar PPE são: produtores independentes, promotores de parques eólicos, intervenientes do mercado bolsista e operadores de sistema.

As PPE podem ser bastante onerosas já que determinados parâmetros como maiores horizontes temporais, uma maior resolução espacial, um maior o número de *time-steps* e uma maior quantidade de actualizações das previsões, acarretam maiores custos. Assim, torna-se necessário definir qual a relação complexidade/custo pretendido do sistema de PPE. Os modelos podem ser classificados, consoante os horizontes temporais e os dados de entrada, em [66]:

- S – modelos que apenas recorrem a dados de SCADA para efectuar previsões de potência, normalmente só aplicável para efectuar previsões a horizontes inferiores a 6 horas;
- R NWP/S – modelos que recorrem a modelos numéricos de previsão do tempo regionais e actualizações com recurso a dados de SCADA, normalmente aplicável para efectuar previsões a horizontes no intervalo 03-24 horas;
- R NWP – modelos que recorrem a modelos numéricos de previsão do tempo regionais sem recurso a dados de SCADA, normalmente aplicável para efectuar previsões a horizontes no intervalo 12-72 horas (os dados de SCADA não acrescentam valor a esta gama de horizontes temporais);
- G NWP – modelos que recorrem a modelos numéricos de previsão do tempo globais, normalmente aplicável para efectuar previsões a horizontes no intervalo 72-168 horas. Estes modelos embora sejam os menos precisos são os únicos capazes de efectuar previsões a estes horizontes temporais.

Na Tabela 2 pode-se observar as diferentes aplicações da PPE assim como características dos tipos de modelos e relevância destes por entidade.

Tabela 2- Aplicações da PPE e características dos tipos de modelos. Nomenclatura: h- horizonte temporal; i-*time-step*; R-actualização. Adaptado [66]

Time horizons	GENCOs	ISO/RTO/TSO
S models (h up to 6hr) (i-10 min.) (R 10 to 60 min.)	Intraday market (1hr) Real-time market (1hr) Ancillary services management (10 min.)	Ancillary services management (10 min.) Unit commitment (up to 3hr) Economic dispatch (up to 3hr) Congestion management (up to 3hr)
R NWP/S models (h up to 72hr) (i-30 min.) (R 30 to 60 min.)	Intraday market (1hr) Wind farm and storage devices coordination (3hr to 72hr) Maintenance planning of wind farms (3hr to 72hr)	Unit commitment (3hr to 12hr) Economic dispatch (1hr to 12hr) Congestion management (1hr to 12hr)
R NWP models (h up to 72hr) (i-60 min.) (R 12hr)	Day-ahead market (>12hr) Maintenance planning of wind farms (12hr to 72hr)	Maintenance planning of network lines (12hr to 72hr) Congestion management (12hr to 72hr) Day-ahead reserve setting (12hr to 72hr) Unit commitment (12hr to 72hr)
G NWP models (up to 7 days) (h up to 7 days) (i-60 min.) (R 24hr)	Maintenance planning of wind farms (72hr to 168hr) Maintenance planning of conventional generation (72hr to 168hr)	Maintenance planning of network lines (72hr to 168hr)

Por outro lado, e dependendo do papel desempenhado pela entidade que necessita deste tipo de informação pode ser necessário fornecer não só previsões de potência mas também valores de incerteza associados às previsões de potência, de modo a efectuar-se uma gestão do risco associado às previsões e, por conseguinte, permitindo que estas possam ser correctamente interpretadas.

3.3 DADOS DE INPUT E OUTPUT DE MODELOS DE PREVISÃO

A qualidade dos dados de *input* é de extrema importância já que quanto maior qualidade estes tiverem, melhores serão as previsões finais de potência. Neste sentido é fulcral o tratamento dos dados utilizados como *input* no sistema de PPE. Este tratamento de dados pode ser efectuado em diversos pontos do processo de melhoramento: à entrada dos dados no algoritmo (Ex: aplicação de um filtro de Kalman para reduzir o ruído das previsões de velocidade do vento) e/ou refinamento das previsões finais com recurso a MOS e/ou entre os vários sub-modelos de previsão, conforme abordado em 3.4.5.

3.3.1 INPUT DE DADOS

Uma ferramenta de PPE pode recorrer a diversos tipos de dados e a diversas fontes, os quais poderão ter um papel mais ou menos relevante consoante são previsões de potência para uma turbina ou para efectuar previsões para um parque eólico ou efectuar previsões para uma determinada região. Independentemente disso, os dados utilizados para efectuar previsões de potência poderão ser:

- Previsões, estes dados poderão ser o *output* de modelos numéricos de previsão de tempo ou de modelos estatísticos ou de outro tipo de modelos. Estes dados podem ser valores de potência, dados meteorológicos relevantes (pressão, humidade, temperatura), dados de velocidade e direcção do vento;
- Observações actuais de SCADA para a potência assim como para dados meteorológicos relevantes (pressão, humidade, temperatura) e para dados de velocidade e direcção do vento disponíveis *online* com intervalos que podem variar entre 5 a 60 minutos;
- Dados de persistência, estes podem ser observações recentes SCADA ou METER com um determinado atraso e para alguns casos podem contribuir para efectuar uma melhor PPE;

- Séries de dados passados – observações registadas por sistema SCADA, previsões de modelos numéricos de previsão de tempo, previsões de modelos estatísticos, dados meteorológicos observados *in situ* (pressão, humidade, temperatura), velocidade e direcção do vento.

3.3.2 OUTPUT DE DADOS

Os dados de *output* de modelos de previsão podem ser de diferentes tipos, que poderão ser mais ou menos relevantes consoante a entidade, podendo assumir a seguinte denominação:

- Previsões meteorológicas (velocidade e direcção do vento, temperatura, humidade e pressão) – relevante nalguns casos, mas são considerados valores pouco relevantes e por isso mesmo dados secundários;
- Previsões de potência – estes são considerados dos dados de *output* mais importantes, fornecidos por uma ferramenta de PPE. São geralmente previsões de potência activa produzida e são uma média aritmética da potência activa, por um equipamento isolado ou por um conjunto de equipamentos, para um determinado *time-step*. As previsões de potência podem ser caracterizadas pelo horizonte temporal, pelo número de corridas efectuadas ao longo de um dia e pelo número de *time-step*;
- Estimação de incertezas de previsão – estes são considerados para diversas aplicações os dados de *output* mais importantes, fornecidos por uma ferramenta de PPE, já que uma previsão de potência sem a subsequente estimação dos erros é uma informação incompleta, por isso é importante monitorização do erro. A estimação do erro pode ser efectuada de forma probabilística (representação por: quantis, intervalos de previsão, função massa de probabilidade e função de densidade de probabilidade), índices de risco (*Meteo Risk Index*, *Prediction Risk Index*) e simulação de cenários (*Scenarios with temporal dependency*, *Scenarios with spatial/temporal dependency*).
- Previsão de rampas – estes são dados importantes já que permitem prever qual a variação súbita de produção de potência, este tipo de dados é de elevada importância para o operador de sistema já que permite fazer uma melhor gestão da rede. As previsões de rampas costumam fornecer dados da variação da potência e da duração da rampa;
- Previsão de eventos extremos – dependendo da entidade torna-se importante a previsão de eventos extremos, já que as variações elevadas de velocidade do vento, associadas a este tipo de eventos se situa na região de *cut-off* dos equipamentos podendo estes desligar para efeitos de protecção;
- Verificação de ocorrências – a verificação de ocorrências consiste em aferir sobre o valor das previsões. Isto permite fornecer uma informação adicional permitindo assim interpretar os dados de previsão com um maior detalhe possibilitando assim efectuar uma melhor gestão do sistema.

Tendo em conta a gestão da rede torna-se necessário distinguir previsão passiva (horizonte temporal, exemplo 6, 12, 18 e/ou 24 horas) de previsão adaptativa (a cada *time-step* ou a cada *n time-steps*) já que estas podem ser utilizadas com finalidades distintas e em conjunto permitir uma gestão de rede mais eficiente. A previsão adaptativa é uma previsão sistemática permitindo monitorizar com um determinado erro a ocorrência de erros, eventos meteorológicos extremos e previsões de rampas não previstas. Possibilitando emitir alertas e aconselhar o TSO sobre a atitude a tomar aquando este se depara com uma determinada ocorrência. Desta forma, torna-se possível responder de forma atempada a estes eventos, não previstos pela previsão passiva, com vista a uma gestão mais eficiente do sistema. A previsão passiva consiste na previsão efectuada a cada horizonte temporal tipicamente 6, 12, 18 e/ou 24 horas, ou seja, permite monitorizar os erros, calcular rampas e eventos meteorológicos extremos a um mínimo de 6 horas antes, no entanto, esta previsão á partida será sempre menos precisa do que a previsão adaptativa. Assim, a previsão passiva e a previsão adaptativa teriam como objectivo efectuar previsões de rampas, monitorização do erro e previsão de eventos extremos a diferentes escalas temporais complementando-se. Apesar disto, na presente dissertação apenas foi efectuada uma previsão passiva, pois esta é considerada o tipo de previsão mais importante. Isto porque, se pode efectuar uma gestão da

rede eficiente apenas com recurso à previsão passiva mas o mesmo não acontece relativamente à previsão adaptativa, já que a previsão passiva permite efectuar uma gestão eficiente da rede a muito curto prazo e a médio prazo.

3.4 METODOLOGIAS PARA O CÁLCULO DA PPE

Para se efectuarem PPE existem actualmente inúmeras abordagens, modelos, métodos e variações que permitem efectuar PPE com um maior/menor erro associado dependendo da razão desempenho/custo pretendido. Assim, consoante os dados de *output* pretendidos a metodologia de cálculo pode conter diversos tipos de módulos otimizados para a obtenção desses *outputs*. Além disso a forma como se processa a circulação da informação e o tipo de informação disponível é de elevada importância. Assim, deverá ter-se isto em conta quando se idealiza a arquitectura do sistema de PPE.

Actualmente já existem ferramentas de PPE bastante complexas que contemplam a obtenção dos vários dados de *output* descritos no capítulo 3.3.2. e não só, mas também, como interfaces gráficos e outros módulos que levem a uma melhor compreensão e interpretação pelo TSO dos dados assim como uma melhor desempenho aquando da operacionalidade do sistema e consequente diminuição do erro de previsão associado. Apesar disto, o presente capítulo irá focar-se em tipos de abordagens, tipos de fontes, módulos essenciais de acordo com a metodologia utilizada e como é que estes módulos se relacionam entre si.

3.4.1 FONTES DE DADOS E MODELOS

Existem vários tipos de fontes de dados que podem ser utilizados como *input* de modelos e ferramentas de PPE (velocidade e direcção do vento, pressão, humidade, temperatura, potência entre outros) conforme abordado no capítulo 3.3. Estes dados podem ser obtidos com recurso a modelos de previsão numérica do tempo, modelos estatísticos, observações em tempo real, valores de persistência e com recurso a séries de dados passados [66]. Além disso, quando se fala de fontes de dados torna-se necessário abordar o método de *data-mining* já que este tem um papel importante quando se recorrem a bases de dados para efectuar a PPE.

3.4.1.1 MODELOS NUMÉRICOS DE PREVISÃO DO TEMPO

Os modelos numéricos de previsão do tempo tentam reproduzir o melhor possível o comportamento dinâmico e físico da atmosfera a partir de leis da hidrodinâmica e da termodinâmica. Estes modelos são na verdade conjuntos de programas, cada um com a sua função específica e integram equações de evolução do estado da atmosfera ao longo do tempo no sentido de obter previsões futuras. Estes modelos necessitam de condições de fronteira e dados iniciais com a maior precisão possível. As corridas dos modelos meteorológicos necessitam no entanto de um determinado período de estabilização (*spin-up time*) por forma a fazer convergir o estado previsto para os modos físicos da atmosfera eliminando a resposta expúrea imediata a artefactos puramente numéricos. O *spin-up time* pode dever-se a vários factores [68] sendo que este pode ser reduzido com recurso a vários métodos entre eles recorrendo a filtros, efectuando corridas mais longas e desprezando os primeiros *time-steps* ou outros.

Os modelos numéricos de previsão do tempo podem fornecer previsões de temperatura, pressão, humidade, velocidade e direcção do vento e outros que sejam considerados relevantes para efectuar a previsão de potência.

Os modelos numéricos de previsão do tempo efectuam previsões do tempo com recurso a conjuntos de algoritmos que fazem extrapolações para vários *grid points* e que posteriormente através de modelos *downscaling* permitem efectuar previsões do tempo para os locais de interesse.

Os modelos numéricos de previsão do tempo podem ser modelos globais ou modelos regionais, estes tendem a diferir uns dos outros pela resolução espacial e pelo facto de os modelos regionais correrem sob forçamento de condições de fronteira fornecidas por modelos numéricos globais. No entanto, estes tendem a ter associados custos mais elevados quanto maior o detalhe exigido e quanto mais caras forem as fontes de informação a que recorrem (imagens satélite, sondas, e/ou outras fontes

de informação). Existem diferentes modelos globais e modelos regionais. Nas Tabelas 3 e 4 estão tabelados alguns modelos numéricos de previsão do tempo globais e regionais respectivamente.

Tabela 3- Alguns modelos numéricos de previsão do tempo globais. Adaptado [66]

Global model	Developed by
Global Forecast System (GFS) (http://www.emc.ncep.noaa.gov/modelinfo/)	National Oceanic and Atmospheric Administration (NOAA) (USA)
The Navy Operational Global Atmospheric prediction System (NOGAPS)	United States Navy (USN) (USA)
Global Environmental Multiscale Model (GEM) (http://collaboration.cmc.ec.gc.ca/science/rpn/gef_html_public/index.html)	Recherche en Prévision Numérique (RPN) Meteorological Research Branch (MRB) and the Canadian Meteorological Centre (CMC)
Integrated Forecast System (IFS) (http://www.ecmwf.int/research/)	European Centre for Medium-Range Weather Forecasts (based in England)
Unified Model (UM) (http://www.metoffice.gov.uk/science/creating/daysahead/nwp/um.html)	UK Met Office
German Global Meteorological Model (GME)	Deutscher Wetterdienst (DWD), the German Weather Service, Météo-France
ARPEGE	French Weather Service, Météo-France
Intermediate General Circulation Model (IGCM) (http://www.met.rdg.ac.uk/~mike/dny_models/igcm/)	University of Reading, Department of Meteorology (England)

Tabela 4- Alguns modelos numéricos de previsão do tempo regionais. Adaptado [66]

Regional model	Developed by
Weather Research and Forecasting Model (WRF) (http://www.wrf-model.org/index.php)	A partnership that includes the NOAA, NCAR, and more than 150 other organizations and universities
Regional Atmospheric Modeling System (RAMS) (http://rams.atmos.colostate.edu/)	Colorado State University
Fifth Generation Pen State/NCAR Mesoscale Model (MM5) (http://www.mmm.ucar.edu/mm5)	Mesoscale Prediction Group in the Mesoscale and Microscale Meteorology Division, NCAR
Advanced Region Prediction System (ARPS) (http://www.caps.ou.edu/ARPS/)	University of Oklahoma
High Resolution Limited Area Model (HIRLAM) (http://hirlam.org/)	International HIRLAM programme
Global Environmental Multiscale Limited Area Model (GEM-LAM)	Meteorological Service of Canada (MSC)
Limited Area, Dynamical Adaptation, International Development (ALADIN) (http://www.cnrm.meteo.fr/aladin/)	16 national meteorological services (EU)
COSMO	Consortium for Small-Scale Modeling (Germany, Switzerland, Italy, Poland and Greece)
Skiron/ Eta (http://forecast.uoa.gr/forecastnew.php)	Institute of Accelerating Systems and Applications – University of Athens (IASA)
MesoNH (http://mesonh.aero.obs-mip.fr/mesonh)	Laboratoire d'Aérodynamique (UMR 5560 UPS/CNRS) and CNRM-GAME (URA 1357 CNRS/Météo-France)
Rapid Update Cycle (RUC) (http://ruc.noaa.gov/)	NOAA (USA)
Eta model (ETA) (http://www.srh.noaa.gov/ssd/nwpmoel/html/eta.htm)	NOAA (USA)
North American Mesoscale Forecast System (NAM) (http://www.emc.ncep.noaa.gov/index.php?branch=NAM)	NOAA (USA)

3.4.1.2 MODELOS ESTATÍSTICOS DE PREVISÃO DO TEMPO E MODELOS ESTATÍSTICOS DE PREVISÃO DE POTÊNCIA

Os modelos estatísticos de previsão do tempo não se baseiam na integração temporal explícita das equações físicas. Ao invés tentam prever o tempo ou a potência eólica, capturando determinados padrões e regularidades estatísticas da hidrodinâmica da atmosfera, de forma a extrapolar (prever) certas

variáveis utilizando modelos estatísticos. Tal consegue-se com recurso a actualizações ou sem recurso a actualizações dos dados, respectivamente modelos *online* ou modelos *offline*. Os modelos *online* são mais precisos mas pelo facto de serem adaptativos em função do estado actual da atmosfera, necessitam de informação actualizada para efectuar recalibrações de modelos, o que nem sempre é possível, contrariamente os modelos *offline* são menos precisos e não necessitam de informação actualizada (observações).

Os modelos estatísticos de previsão do tempo são de vários tipos tentando prever a velocidade e direcção do vento. Os modelos estatísticos de previsão de potência recorrem a dados de potência passados para efectuar previsões.

Para efectuar previsões estatísticas pode ser tida em conta a sazonalidade, os regimes de circulação geral da atmosfera, o ciclo nocturno/diurno, dados históricos de potência ou meteorológicos e outros.

Nalguns casos poderão existir vantagens em efectuar previsões estatísticas directamente da potência eólica em vez de grandezas mais básicas (intensidade, direcção do vento, humidade, entre outros) integrando-a nas previsões finais.

Nas Tabelas 5 e 6 pode-se observar a diversidade de modelos e métodos já estudados ou em estudo para efectuar quer previsões de vento quer previsões de potência, consoante o horizonte temporal.

Tabela 5- Modelos estatísticos de previsão do tempo e de potência a muito curto prazo de tempo. Adaptado [66]

WIND SPEED FORECASTING	WIND POWER FORECASTING
Kalman Filter	Fuzzy Time Series
Grey Predictor	Self-exciting Threshold Autoregressive
Takagi-Sugeno	Smooth Transition Autoregressive
Discrete Hilbert Transform	Markov-switching Autoregressive
Abductive Networks (GMDH)	Adaptive Fuzzy Logic Models
ARIMA time series models	Adaptive Linear Models
Neural Networks	
Adaptive Fuzzy Inference System	

Tabela 6- Modelos estatísticos e computacionais de previsão a curto prazo de tempo. Adaptado [66]

METHODS
Neural Networks
Support Vector Machines
Regression Trees with Bagging
Random Forests
Adaptive Neural Fuzzy System
Mixture of Experts
Nearest Neighbor Search
Autoregressive with Exogenous Input (ARX)
Locally Recurrent Neural Networks
Local Polynomial Regression
Takagi-Sugeno FIS
Fuzzy Neural Networks
Autoregressive with Exogenous Input and Multi-timescale Parameter (ARXM)
Bayesian Clustering Dynamics (BCD)

3.4.1.3 PERSISTÊNCIA

A persistência não é mais do que uma repetição de valores observados anteriormente registados com recurso a um sistema SCADA (*Supervisory Control and Data Acquisition*) ou com recurso a contadores (METER) com um determinado atraso relativamente ao registo. Deste modo é o mesmo que dizer que a potência eólica para um determinado período futuro será a mesma que no presente. No

entanto, esta premissa assume que a previsão é inerente a um sistema estacionário o que não é de toda verdade. Logo, será normal que uma previsão por persistência com base num horizonte temporal a 15 minutos tenha um melhor desempenho do que um horizonte temporal a 6 horas. Assim, a persistência pode ser utilizada como um:

- Valor de referência [23], sendo que, os autores defendem que a persistência só deverá ser utilizada como um valor de referência até 3 horas sendo que posteriormente deverá ser utilizada uma média ponderada entre a persistência e a média da potência;
- Dado de *input* de modelos de previsão [66], sendo que os autores defendem que é a forma mais viável (a muito curto prazo) e com menores custos para calcular a PPE.

3.4.1.4 SÉRIES TEMPORAIS PASSADAS

O recurso a séries temporais passadas pode ser de elevada importância, já que podem ser utilizados para treinar modelos estatísticos de previsão do tempo [39] e afinar modelos MOS. No entanto, isto apresenta alguns desafios já que a existência destas bibliotecas em tempo real de modo a serem facilmente consultadas pressupõe que estas estejam tratadas de modo a serem facilmente acessíveis, não existem lacunas nem erros associados aos dados que possam induzir os modelos em erro, para alguns casos é necessário que os dados estejam devidamente categorizados, entre outros aspectos. Assim, é necessário algum cuidado quando se recorre a séries temporais passadas já que a utilização destas poderá ter efeitos contrários aos desejados.

3.4.1.5 DATA-MINING

Data-mining é uma área interdisciplinar relativamente recente, e por isso com fronteiras difusas, desenvolvida ao longo dos anos 90. Esta resulta da confluência de várias áreas do conhecimento [69]: (i) análise estatística; (ii) inteligência artificial; (iii) *machine learning*; (iv) bases de dados. A definição de *data-mining* é bastante variável em função da área de interesse do autor que a enuncia; no entanto, de uma forma geral, o método *data-mining* tem como objectivo extrair informação relevante associada a uma base de dados e transformá-la, por forma a ser facilmente interpretada/utilizada posteriormente. Os métodos *data-mining* têm vindo a ter um maior destaque devido à elevada quantidade de informação contida em bases de dados, a qual por diversos motivos requiere ser analisada em tempo útil.

Segundo [69] o método *data-mining* é parte integrante de um processo mais abrangente a que se dá o nome de KDD (*Knowledge Discovery in Databases*). A relação entre o processo de KDD e o método *data-mining* pode ser esquematizado a partir da Fig. 9. Em [70] o autor propôs a seguinte definição “*Knowledge discovery in databases is the non-trivial process of identifying valid, novel, potential useful, and ultimately understandable patterns in data*”.

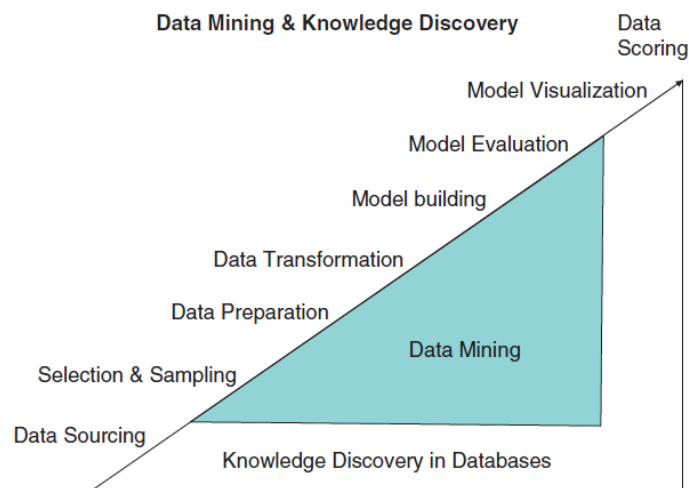


Fig. 8 – Relação entre KDD e *data-mining*. [69]

Em [69] os autores defendem que o método *data-mining* é uma mistura do método deductivo e indutivo. Considera-se deductivo dado que tenta encontrar relações entre os dados através de valores métricos e indutivo porque estes resultados são posteriormente interpretados para retirar conclusões. Desta forma o método *data-mining* é um método mais preciso do que um simples método estatístico. Isto porque, enquanto o método estatístico analisa dados passados para efectuar previsões, os métodos *data-mining* recorrem a dados passados e a consequências lógicas para determinar relações (padrões) entre os dados e assim efectuar previsões.

Existem distintas áreas de aplicação do método *data-mining*, as quais, segundo [69] que cita o trabalho de [71] são: (i) *Exploratory Data Analysis*; (ii) *Descriptive Modeling*; (iii) *Predictive Modeling*; (iv) *Discovering Patterns and Rules*; (v) *Retrieval by Content*.

Quando se recorre a métodos *data-mining*, Segundo [69] que cita [72], é necessário ter em conta questões importantes, as quais passam por: (i) *Mining of different kinds of information in databases*; (ii) *Interactive mining of knowledge at multiple levels of abstraction*; (iii) *Incorporation of background information*; (iv) *Data mining query languages and ad hoc data mining*; (v) *Presentation and visualization of data mining results*; (vi) *Handling “noisy” or incomplete data*; (vii) *Pattern evaluation*; (viii) *Efficiency and scalability of data mining algorithms*; (ix) *Parallel, distributed, and incremental mining algorithms*; (x) *Handling of relational and complex types of data*; (xi) *Mining information from heterogeneous and global information systems*.

A previsão numérica (*Predictive Modeling*) conforme anteriormente referido é uma área de aplicação do método *data-mining*. Quando se recorre a algoritmos de *data-mining* deve ser tido em conta que estes devem ser selecionados de acordo com as características dos dados (ex: correlação dos dados, entre outros), dado que, existem algoritmos que tendem a ser mais adequados à resolução de um determinado problema do que outros. Por outro lado, distintos tipos de algoritmos de *data-mining* associados a diferentes configurações tendem a ser mais adequados para encontrar padrões associados aos dados do que apenas um tipo de algoritmo com uma configuração. A utilização de vários algoritmos com diferentes configurações permitem a utilização de modelos combinatórios (*ensemble models*) para melhorar as previsões. Existem diversas técnicas combinatórias as quais poderão ser utilizadas em conjunto para assim melhorar o desempenho das previsões.

Os algoritmos passíveis de ser utilizados no método *data-mining* são bastante diversificados. Segundo [69] os algoritmos de *data-mining* mais simples podem ser baseados em: (i) *Association Rules*; (ii) *Automated Neural Networks*; (iii) *Generalized Additive Models (e.g., Regression Models)*; (iv) *General Classification/Regression Tree Models*; (v) *General CHAID Models*; (vi) *Generalized EM and k-Means Cluster Analysis*. De um outro modo, algoritmos mais complexos podem ser baseados em: (i) *Interactive Trees (CART or C&RT, CHAID)*; (ii) *Boosted Tree Classifiers and Regression*; (iii) *MARSplines (Multivariate Adaptive Regression Splines)*; (iv) *Random Forests for Regression and Classification*; (v) *Machine Learning (Bayesian, Support Vectors, Nearest Neighbor)*; (vi) *Sequence, Association, and Link Analysis*; (vii) *Independent Components Analysis*.

3.4.2 ABORDAGENS À PPE

A PPE pode ser efectuada com recurso a várias abordagens, entre as quais: previsão à turbina; parque a parque; sub-regional (Ex: distritos) e regional (Ex: Portugal). Estas diferentes abordagens devem ser empregues consoante o utilizador final das previsões, já que estas, consoante o tipo de abordagem, apresentam grande variabilidade de custos, de informação, precisão, entre outras. Isto é, quanto maior a resolução maior a necessidade computacional para as fazer, menor erro apresentam e maior será o custo dessas previsões; contrariamente, quanto menor a resolução, maior o erro e menores os custos associado às previsões. Assim, os dados de *output* das ferramentas de PPE, consoante a resolução escolhida, podem ser (ver Fig. 8):

- Previsão à turbina - este tipo de previsão é útil para entidades que possuam parques eólicos. A previsão à turbina acarreta uma elevada manipulação de dados, recursos computacionais e extensas bases de dados, sendo um tipo de previsão bastante moroso e com custos elevados. Esta abordagem efectua uma previsão individual para cada turbina, tendo em conta valores medidos ao nível da turbina, tornando-se assim impraticável para entidades que possuam um

elevado número de turbinas. Além disto, este método apresenta outras desvantagens, uma vez que não existe uma compensação do erro de previsão e, por conseguinte, é natural que este método apresente, em determinados momentos, erros elevados. Estes valores de previsão podem ser posteriormente agregados de forma a se obterem previsões de um determinado parque eólico com um menor erro de previsão associado;

- Previsão parque a parque - consiste numa previsão de vento para um determinado ponto situado no interior ou na periferia do parque eólico. No entanto, este método poderá não ser o mais indicado já que podem existir certas características orográficas ou da própria construção do parque que inviabilizem a escolha desse determinado ponto. Este tipo de previsão tem em conta o *output* das várias turbinas, a disponibilidade dos equipamentos, as perdas do parque eólico e o consumo interno do parque eólico. É ainda de se notar que esta previsão acarreta menores custos e necessita de menores recursos, contudo, é menos precisa do que a previsão de potência produzida por uma turbina;
- Previsão sub-regional ou *cluster* - implica agregar diversos parques consoante determinadas características de vento, equipamentos, clima, entre outros. Assim, torna-se necessário fazer um estudo aprofundado das várias regiões em que se inserem estes parques eólicos, não só mensal, mas também anual já que existem ciclos meteorológicos característicos para uma dada região. Este tipo de previsão é bastante útil para um *cluster* de parques eólicos, já que permite extrapolar a potência produzida por um conjunto de parques eólicos para os quais só se tem informação de parques eólicos de referência. Este tipo de informação necessita de menores recursos, mas poderá estar sujeita a erros de previsão, visto que depende de variáveis, como localização dos parques de referência, localização dos parques que compõem o *cluster* entre outras variáveis que podem ser difíceis de caracterizar;
- Previsão regional ou *upscaling* - este tipo de previsão apresenta menor resolução do que as previsões por *cluster*; contudo, nalguns casos esta poderá ser a abordagem mais indicada para efectuar a PPE. Este tipo de previsões pode ser utilizado para efectuar previsões a nível regional ou até mesmo a nível nacional, podendo ser realizada de diversas formas (ver capítulo 3.4.5.).




Fig. 9 – Síntese dos vários tipos de abordagens de organização para calcular a PPE. Adaptado [66]

3.4.3 DOWNSCALING

Quando se recorre a modelos que efectuem previsões para um determinado *grid point* como é o caso dos modelos de previsão numéricos do tempo, os quais podem não ser coincidentes com a localização do parque eólico, assim é necessário calcular os valores necessários ao cálculo da PPE para o local alvo. Isto é efectuado com recurso a um modelo de *downscaling*. Existem diversas técnicas de *downscaling* no entanto, estes podem distinguir-se entre [73] *downscaling* estatístico e *downscaling* dinâmico ou físico.

3.4.3.1 DOWNSCALING DINÂMICO OU FÍSICO

O downscaling dinâmico ou físico pode ser efectuado com recurso a modelos de microescala ou com recurso a *Computed Fluid Dynamics models* (modelos CFD).

Os modelos de microescala consistem em modelos que recorrem às previsões de modelos de mesoescala para utilizar como condições de fronteira. Estes modelos consistem em modelos de diagnóstico que foram inicialmente idealizados para calcular a dispersão de gases poluentes na atmosfera sendo posteriormente utilizados na previsão eólica. Estes modelos têm em conta a orografia e uso da terra para determinar o fluxo eólico. Exemplo disso são os modelos CALMET [74], [75], [76], MCSCIPUF e SWIFT [75].

Os modelos CFD são modelos que descrevem o escoamento de um fluido, normalmente para condições estacionárias de modo a simplificar o modelo. Estes recorrem a diferentes métodos matemáticos para resolver as equações de continuidade, equações de Navier-Stokes, equações de temperatura e equações de estado [77]. Os modelos CFD são normalmente acoplados a modelos de previsão numérica de globais ou de mesoescala isto porque necessitam de previsões efectuadas para um determinado grid-point. Exemplo disso é o modelo VENTOS@/M [78] e MASCOT [79].

Os modelos CFD e os modelos de microescala têm em comum o facto de necessitarem de informação mais detalhada acerca da topografia e do *layout* do parque eólico. Assim, estes tendem a ser utilizados para efectuar previsões para parques eólicos situados em terrenos complexos, onde os modelos lineares obtêm piores desempenhos [80]. Por outro lado, este tipo de *downscaling* pode apresentar vantagens para locais em que não existem medições de variáveis meteorológicas (velocidade e direcção do vento, humidade, pressão, etc) que possibilitem efectuar uma correcção das previsões [79] como é o caso de novos parques eólicos.

3.4.3.2 DOWNSCALING ESTATÍSTICO

O *downscaling* estatístico é efectuado com recurso a diversas técnicas. Entre as técnicas mais comuns está o *Delta method*, *Bias-correction method*, *Bias-Correction – Spatial Disaggregation* (BCSD), *Variant of BCSD: Statistical Asynchronous Regression* (SAR) e *Statistical DownScaling Model* (SDSM) [73] ou regressão múltipla [81]. Sendo que a interpolação com recurso a regressão linear múltipla tende a ser o método mais simples já que tem em conta os 4 pontos da malha mais próximos do local de interesse. Por outro lado os autores [81] em análises efectuadas para o projecto ANEMOS verificaram que a utilização dos valores dos gradientes de pressão em modelos de downscaling estatístico conseguiam reduzir o erro associado. Ainda no presente trabalho [81] os autores verificam que o downscaling estatístico, reduz o erro de forma substancial face a um modelo sem *downscaling* estatístico, especialmente para parques eólicos situados em terrenos complexos.

3.4.4 POWER CURVE MODELS (PCM'S)

Os *Power Curve Models* (PCM's) são responsáveis por converter os valores de velocidade do vento em potência eólica. Segundo [82] existem dificuldades na conversão de velocidade do vento em energia mecânica que se devem á:

(1) Ocorrência de turbulência, devida à TKE (*Turbulent Kinetic Energy*) – faz com que a velocidade do vento que passa através das pás da turbina não tenha um fluxo constante, isto tem como efeito uma variação da potência instantânea (Equação 1);

(2) Velocidade do vento incidente nas pás da turbina – o valor utilizado consiste num valor em média para um determinado período de tempo (*time-step*, neste caso 15 minutos, quando se utilizam modelos numéricos de previsão do tempo), além disso este valor é um valor previsto para a altura da *nacelle* pelo que quanto maior for o diâmetro da turbina maior poderá ser a diferença entre velocidades do vento incidente nas pás da turbina consoante a altura a que estas estão;

(3) Distância da turbina ao sensor meteorológico – para efectuar correcções de velocidade do vento utilizar é necessário medições de SCADA com recurso a um sensor meteorológico já que isto permite efectuar correcções da velocidade do vento *in situ*. No entanto, o sensor deverá por um lado estar á altura

da nacelle e por outro deverá estar a uma distância suficiente para não ficar sobre a esteira nem perturbar o fluxo de vento incidente nas turbinas.

Sendo que, [82] afirma que (1), (2) e (3) podem ter como efeito uma diminuição da correlação entre os valores de potência prevista e os valores de potência observada. Assim torna-se necessário ter em conta estes factores para efectuar uma modelação da curva de potência da turbina. Em [83] e [84] os autores procuraram responder as várias problemáticas abordadas em (1), (2) e (3) nos quais efectuaram recomendações para aumentar os valores de correlação e diminuir o erro associado às previsões.

Existem diversos métodos [65] e [85] passíveis de ser utilizados para converter velocidade do vento em potência alguns dos quais estão sintetizados na Tabela 7. A mesma fonte refere que a utilização da curva de potência característica de uma turbina (fornecida pelo fabricante) poderá não consistir no melhor método para converter velocidade do vento em potência eólica. Isto também pode ser observado pelas Fig. 5 e 6 em que existe uma elevada discrepância entre potência observada e potência prevista tendo em conta a curva de potência característica de uma turbina fornecida pelo fabricante. Embora em [86] os autores defendam que a forma mais simples de converter velocidade do vento em potência eólica consiste na utilização da curva de potência característica fornecida pelo fabricante. Assim, é de salientar que diferentes métodos estão associados a diferentes custos e diferentes precisões pelo que é necessário ter isto em conta quando se desenvolvem os PCM's. Além de diversos métodos, pode-se considerar que a metodologia de cálculo se pode subdividir entre *online* e *offline*. A diferença entre *online* e *offline* está na utilização de dados de SCADA para enriquecer os modelos (modelos *online*) ou na não utilização de dados de SCADA para enriquecer os modelos (modelos *offline*).

Tabela 7- Alguns métodos de modelação para calcular a curva de potência característica de uma turbina. Adaptado [65] e [85].

MÉTODOS DE MODELAÇÃO PARAMÉTRICOS	MÉTODOS DE MODELAÇÃO NÃO-PARAMÉTRICOS
Linearized segment model [65]	Copula power curve [65]
Polynomial power curve [65]	Cubic spline interpolation [65]
Maximum principle method [65]	Neural networks [65]
Dynamical power curve [65]	Fuzzy methods [65]
Probabilistic model [65]	Data mining algorithms [65]
Cubic power curve [85]	
Exponential power curve [85]	
Approximate cubic power curve [85]	
Ideal power curve [65]	
4-parameter logistic function [65]	
5-parameter logistic function [65]	

3.4.5 MODEL OUTPUT STATISTICS (MOS)

Os módulos MOS são modelos estatísticos utilizados para tratar previsões efectuadas com recurso a modelos numéricos de previsão do tempo. Assim, os módulos MOS são parte importante de um sistema de PPE já que permitem corrigir os erros sistemáticos que se verificam devido a imperfeições dos modelos numéricos de previsão do tempo [8], [15], [21], [51], [87], [88] e [89]. Por outro lado, os modelos MOS devem ser especificados para um dado modelo numérico de previsão do tempo, assim como para o horizonte temporal. Assim, a utilização de vários modelos MOS em vários pontos do sistema (à entrada de um modelo PCM e/ou após um modelo PCM e/ou após os vários módulos que compõem o sistema de previsão [90]) poderá ser vantajoso. No entanto, há que ter em conta que a utilização de vários modelos de tratamento MOS dinâmicos, em vários pontos de um sistema de previsão, pode dar azo a uma redução da correlação dos erros, o que se poderá traduzir numa maior incerteza associada ao desempenho de múltiplos processos de tratamento, usados com o intuito de melhorar as previsões. Assim, deve-se ter isto em conta quando se desenvolvem múltiplos modelos MOS dinâmicos para aplicar em diversos pontos do sistema de PPE.

Para desenvolver um módulo MOS é necessário ter em atenção que estes podem ter efeitos contrários ao desejável, reduzindo a qualidade das previsões efectuadas. Assim é necessário que os

módulos MOS sejam modelos operacionais, capítulo 3.4.8., já que poderão ocorrer erros relacionados com a operacionalidade do sistema que os inviabilizem (erros de calibração do modelo devido à fraca qualidade dos dados, etc) e erros com uma elevada variabilidade (caso de erros associados a múltiplos modelos MOS dinâmicos).

Existem diversos tipos de modelos MOS, sendo que se podem utilizar para o efeito diversos modelos já anteriormente abordados em 3.1., 3.4.1.2., 3.4.1.5., 3.4.4. e 3.4.5. No entanto, uma das técnicas mais utilizadas é baseada no método das regressões lineares.

3.4.6 UPSCALING

O *upscaling* é utilizado para extrapolar as previsões de potência eólica ao nível regional tendo por base a utilização de um número limitado de previsões [66]. À primeira vista a melhor opção para prever a potência eólica regional seria somar a previsão efectuada para todos os parques/turbinas eólicas, no entanto esta poderá não ser a melhor forma de determinar a previsão eólica ao nível regional, isto porque a previsão regional com recurso á soma das potências previstas por turbina/parque é de elevado custo, já que isto acarreta no caso de modelos físicos previsões para um elevado número de pontos geográficos e no caso de modelos estatísticos acarreta uma elevada manipulação de dados (sendo que os dados a que recorre podem não estar completos), poderão ainda existir problemas ao nível da qualidade das medições de dados SCADA (vento, humidade, temperatura, pressão) que são utilizados ao longo da cadeia do processo de previsão, deficiente caracterização do parque eólico (*layout*, curva de potência característica e outros), além disso poderão não existir dados suficientes para efectuar previsões para um determinado parque (Ex: novos parques eólicos) ou porque nalguns países não é obrigatório a instalação de sistemas SCADA para parques eólicos a partir de uma certa potência instalada sendo apenas obrigatória a instalação para grandes parques. [66]

Desta forma o *upscaling* torna-se um processo de cálculo de previsão eólica atractivo já que permite calcular a potência eólica nacional, recorrendo a um determinado conjunto de parques de referência e extrapolando o potencial eólico regional [66, 89]. Além disso, a agregação de parques eólicos parece reduzir o erro associado ao processo de *spatial smoothing* [66].

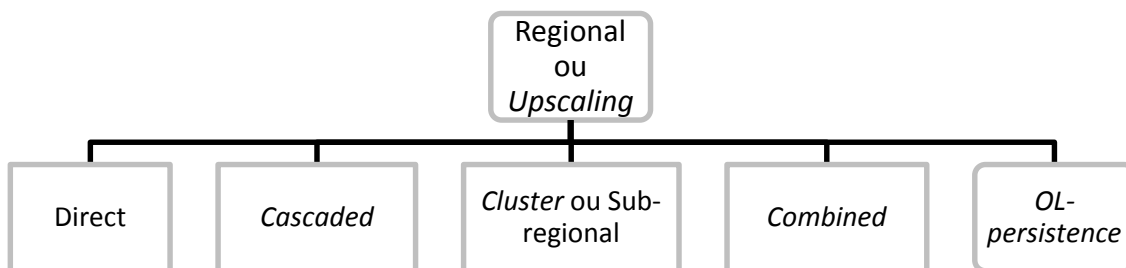


Fig. 10 – Tipos de *upscaling*. Adaptado [66].

Segundo [66] o *upscaling* pode ser efectuado pelos métodos (Fig. 10):

- *Direct* – este método recorre previsões efectuadas para parques eólicos de referência com recurso a modelos de previsão numérica, dados SCADA da potência regional e informação detalhada do parque de referência. Estes dados são posteriormente utilizados em conjunto para desenvolver um modelo de *upscaling* que consiga prever a potência eólica regional com base nos dados utilizados. Quando se efectua este método é necessário ter em conta que o modelo necessita ser actualizado sempre que se instalem novos parques eólicos.
- *Cascaded* – este método à semelhança do *direct* pode recorre a um ou mais do que um parque de referência. Para se efectuar este tipo de *upscaling* recorre-se a dados de modelos de previsão numérica e dados de SCADA para os parques de referência. Posteriormente é efectuado um modelo para cada parque de referência e na última fase é extrapolado o valor da potência eólica a nível regional.

- Cluster ou sub-regional – este método baseia-se em agregar parques nas proximidades do parque de referência ou agregar os parques em sub-regiões, sendo depois utilizadas previsões de modelos numéricos de previsão e dados de SCADA para um ou mais parques de referência sendo depois optimizado um modelo para prever a potência eólica associada ao *cluster* e numa fase final soma-se as potências eólica dos *clusters* de modo a obter-se a potência eólica regional.
- Combined – este método consiste numa combinação dos métodos *Direct* e/ou *Cascaded* e/ou *cluster* para obter a previsão de potência eólica regional. Este método permite que adequar o modelo de *upscaling* já que nem sempre é possível ter um modelo de *upscaling* puramente *direct* ou *cascaded* ou *cluster*.
- Online (OL) persistence for upscaling models – da mesma forma que se pode considerar que o valor de velocidade de vento, direcção, etc se mantêm no tempo ou seja que se pode prever estes valores por persistência também se pode prever a potência eólica regional por persistência. A persistência é utilizada como série de referência para avaliar o desempenho de modelos de previsão. No entanto, para utilizar a previsão por persistência torna-se necessário ter medições de SCADA para os vários parques eólicos, sendo que, isto apenas se torna vantajoso quando se utilizam modelos de previsão com melhores desempenhos que a persistência, como é o caso de modelos que recorrem a dados *online*. Este método apresentado em [91] e abordado em [66] parte do princípio que um dado parque eólico irá manter a mesma percentagem de potência eólica que num período passado. Assim, para utilizar este método para efectuar o *upscaling* de potência P_{i+k}^{reg} para um determinado *time-step* futuro (k) é necessário ter: potência nominal de todos os parques eólicos situados na região ($\sum_{v=1}^n P_v^{nom}$), potência eólica nominal de todos os parques de referência situados na região ($\sum_{j=1}^r P_{ref,j}^{nom}$), valores de SCADA da potência eólica para os parques de referência situados na região $\sum_{j=1}^r P_{ref,j}^{wf}(i)$ num determinado *time-step* (i).

$$P_{i+k}^{reg} = \left(\frac{\sum_{v=1}^n P_v^{nom}}{\sum_{j=1}^r P_{ref,j}^{nom}} \right) \sum_{j=1}^r P_{ref,j}^{wf}(i) \quad (2)$$

3.4.7 ENSEMBLE MODEL OUTPUT STATISTICS (EMOS)

O módulo *ensemble* consiste numa variação do modelo MOS sendo por isso denominado EMOS (*Ensemble Model Output Statistics*) ou EPS (*Ensemble Prediction System*). Os módulos *ensemble* efectuam um conjunto de previsões [92] e [93], contrariamente a apenas uma previsão.

Estes métodos estão em fase operacional há já algum tempo em modelos de previsão a médio prazo. Sendo que, os métodos mais comuns para isto são EnKF (*Ensemble Kalman Filter*) e singular breeding vectors [92].

Relativamente à PPE, este módulo tem um papel importante já que permite quantificar a incerteza do erro associado a uma determinada previsão, assim como, melhorar a precisão de previsões determinísticas [66], [92], [93]. O que é de elevada importância para o TSO.

Existem quatro métodos distintos de *ensemble*:

- Os modelos são inicializados com poucas variações das condições iniciais, por forma a avaliar o impacto de algumas alterações iniciais (*butterfly effect*);
- *Multi-scheme ensemble* com recurso a dados idênticos mas com recurso a variações do mesmo modelo. Ou seja, a utilização de diferentes módulos com diferentes métodos para produzir um espectro de previsões futuras;
- *Multi-model ensemble* com recurso a diferentes diferentes modelos de previsão numérica;
- Utilização das várias corridas efectuadas, retirando partido da sobreposição de previsões efectuadas com recurso a um modelo de previsão numérica (Ex: se um modelo efectua corridas

a cada 6 horas implica que se efectuar previsões a 48 horas existem 7 previsões sobrepostas) [93].

Posteriormente é necessário efectuar cálculos sobre o conjunto de previsões efectuadas por forma a obter uma única previsão e/ou por forma a obter valores de incerteza associados às previsões.

3.4.8 OPERACIONALIDADE DO SISTEMA

A operacionalidade do sistema é uma característica de elevada importância, na medida em que é necessário que o sistema de PPE se consiga comportar de forma satisfatória em episódios adversos, quer devido a factores meteorológicos, quer devido a factores logísticos de informação. Existem alguns erros que podem ocorrer e que têm de ser tidos em conta para operacionalizar uma ferramenta de PPE. Estes são:

- Aumentos súbitos de potência (rampas);
- Eventos meteorológicos extremos (rajadas);
- Erros de modelo (erros de fase, de magnitude e de variação);
- Falência do sistema de PPE;
- Erros de sensores;
- Existência de ficheiros corrompidos;
- Previsões não chegarem a tempo;
- Outras dificuldades técnicas. [66]

Por outro lado, existem informações complementares que permitem ao operador do sistema efectuar uma gestão da rede mais eficaz, entre elas:

- Cálculo de incertezas e qual a probabilidade de se verificar;
- Cálculo de rampas e qual a probabilidade de se verificar;
- Cálculo de erros de modelo e qual a probabilidade de se verificar. [66]

Estas informações têm de estar disponíveis em tempo útil para serem tidas em conta para a tomada de decisões e têm de estar explícitas de uma forma simples fomentando uma fácil interpretação.

Assim para um sistema ser operacional é necessário dotá-lo de ferramentas que o torne adaptável a vários tipos de cenários. Além disso, é necessário dotá-lo de modelos que recorram a dados *online*, mas também dotá-lo de modelos *offline* que tenham bons desempenhos e modelos que facultem informação relevante para o TSO. É de salientar ainda a necessidade de os dados serem apresentados de modo a possibilitar uma fácil interpretação e compreensão pelo TSO.

3.4.9 ARQUITECTURA DE UM SISTEMA DE PPE

A arquitectura de um sistema de previsão é bastante variável podendo ser composto por diferentes módulos com vista á sua operacionalidade.

Em primeiro lugar quando se desenvolve uma ferramenta de PPE deverá ser tido em conta o requerente das previsões, especificando o *output* das previsões á necessidade deste. Posto isto deverá ser tida em conta a abordagem que é efectuada à problemática da previsão já que isto poderá condicionar a arquitectura do sistema. Por outro lado, torna-se necessário ter em conta as fontes de dados disponíveis, já que a obtenção destas é geralmente de elevado custo, devendo por isso extrair-se o máximo potencial destas, pois podem determinar o desempenho do sistema de PPE. As fontes de dados, definem se um modelo é *online* (recorre a dados de SCADA para enriquecer modelos) ou *offline* (não recorre a dados de SCADA para enriquecer modelos), se consiste num modelo físico (utilização de modelos de previsão numérica do tempo), matemático/estatístico ou híbrido (combinação de modelo físico e modelo matemático/estatístico), os quais tendem a apresentar vantagens e desvantagens entre si. Assim [66]

defende uma combinação destes modelos por forma a retirar o máximo partido destes. Além de diferentes fontes os modelos podem recorrer a um conjunto de módulos distintos (*downscaling*, PCM's, MOS, *upscaling*, EMOS e outros), estando alguns descritos no presente capítulo 3, por forma a alcançar as especificidades pretendidas pelo requerente da PPE.

Actualmente, encontram-se no mercado diversos sistemas operacionais com vista a PPE. Estes sistemas tendem a ser bastante diversificados, como se pode observar pelo anexo F, onde estão enunciados alguns sistemas de previsão actualmente em fase comercial [66]. Por outro lado, ao longo da revisão literária são referidos sistemas de PPE [13], [16], [17], [21], [25], [26], [27], [30], [35], [37], [38], [41], [49], [56] e [57], assim como as técnicas a que recorrem e as funcionalidades destes sistemas. Assim, verifica-se que a arquitectura dos sistemas de PPE são bastante variados, no entanto, têm em comum certos módulos com vista a alcançarem certos objectivos, por exemplo modelos menos complexos tendem a ter: um módulo de *downscaling*; um módulo para efectuar previsões de potência e um módulo de *upscaling*. Sistemas de PPE mais avançados são adaptativos, recorrendo a dados *online* e *offline*, podendo consistir numa abordagem: física, estatística ou híbrida. Estes tendem a ser compostos por: módulos complementares para reduzir o erro associado às previsões; módulos com vista a fornecer informações complementares (valor das previsões); módulo de monitorização dos erros; módulo de previsão de rampas; modelo PCM; modelos MOS e outros que permitam uma melhor gestão do sistema quer por obtenção de previsões mais precisas quer através de informações complementares fornecidas ao TSO de forma compreensível e facilmente interpretável.

3.4.9.1 MODELOS ESTATÍSTICOS

Os métodos estatísticos são compostos por modelos que, com um determinado erro, calculam ou fazem previsões da intensidade, direcção do vento e/ou PPE com base em diversos parâmetros como a pluviosidade, pressão, temperatura, humidade, etc. Assim, os modelos estatísticos tentam capturar padrões que ocorrem na atmosfera por forma a efectuar previsões.

São propostas diversas metodologias consoante os horizontes temporais assim, e segundo estes, podem ser usados vários modelos lineares e/ou não lineares em conjunto de modo a melhorar a previsão.

A PPE com recurso a métodos estatísticos pode usar vários sistemas de previsão como os denominados sistemas *Black-Box* ou *offline*, *Grey-Box* ou *online* e analíticos.

Os sistemas *Black-Box* são sistemas independentes de dados externos para efectuar previsões, sendo autónomos. São por isso vantajosos em situações de ruptura do sistema; entre os tipos de modelos que compõem estes sistemas podemos encontrar os sistemas de inteligência artificial como as *Neural Networks* (NN's) e as denominadas *Support Vector Machine* (SVM's).

Os sistemas *Grey-Box* são sistemas que dependem de um *input* de dados consoante as necessidades do próprio modelo, aprendendo, por isso, com a experiência e podendo ser treinados/calibrados. Os modelos que compõem estes tipos de sistemas segundo vários autores têm uma maior precisão quando comparados aos modelos de *Black-Box*, tendo no entanto como desvantagem a sua elevada sensibilidade a eventos de ruptura do sistema.

Os sistemas Analíticos consistem em sistemas capazes de receber um *input* de dados, sendo capazes de os transformar de modo a obter novos dados, os quais são mais viáveis do que os dados originais. Entre estes podem-se encontrar os modelos como os baseados em *Kernel Density Estimation* (KDE) e em *Probability Density Function* (PDF).

Os métodos estatísticos podem utilizar dados para melhorar as PPE efectuadas com recurso a este método. Estes podem ser medições *in situ* e/ou previsões de vento para um conjunto de *grid points* com recurso a um ou mais modelos numéricos de previsão climatérica.

Existem variados modelos de previsão climatérica, que tendem de uma forma geral a caracterizar o solo, a atmosfera, a vegetação e outros intervenientes que possam intervir na PPE. O esquema genérico de um modelo estatístico é apresentado na Fig. 11.

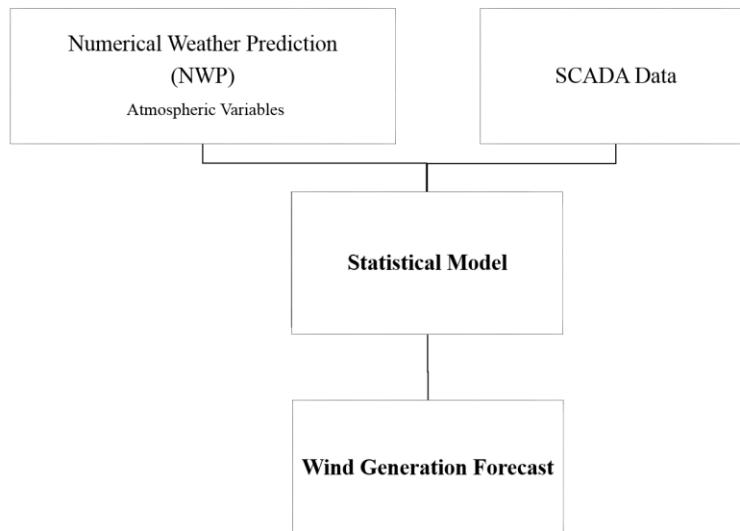


Fig. 11 – Principais passos para efectuar uma previsão de potência pelo método estatístico. Adaptado [66]

3.4.9.2 MODELOS FÍSICOS

Este método depende de dados de modelos de previsão globais. Os modelos de previsão globais visam reproduzir os processos hidrodinâmicos que ocorrem naturalmente no planeta Terra. Numa primeira fase, estes modelos efectuem previsões para nós de uma malha de previsão que cobre o planeta. Posteriormente, são efectuadas transformações, entre as quais *downscaling*, tendo em conta o local de instalação da turbina assim como a altura a que esta se encontra do solo e a direcção do vento. Sintetizando, o método simplificado pode ser subdividido em três: fases uma primeira fase – na qual o vento é modelado tendo em conta: a localização geográfica do parque eólico, a altura da *nacell*, rugosidade da área envolvente, orografia e perfil da direcção do vento – a segunda fase - que consiste em converter a velocidade do vento em potência com recurso a curva de potência característica do equipamento – e, finalmente, a fase três que corresponde a um módulo MOS (*Model Output Statistics*) para efectuar correcções sistemáticas do erro (Fig. 12).

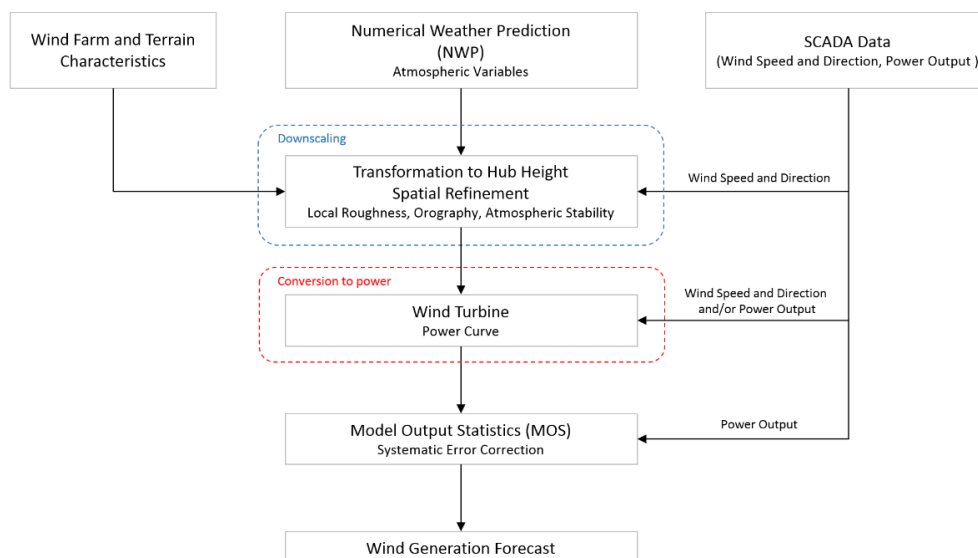


Fig. 12 – Principais passos para efectuar uma previsão de potência pelo método físico. Adaptado [66]

3.4.9.3 HÍBRIDO

O método híbrido trata-se na verdade da fusão de dois métodos: o físico e estatístico. Esta fusão tem como objectivo retirar o melhor partido da combinação destes dois métodos. Assim, esta metodologia consegue efectuar previsões mais precisas já que recorre a modelos matemáticos para efectuar previsões a muito curto prazo (horizontes de 3/6/9 horas); além disso, recorre a modelos numéricos para efectuar previsões mais precisas a curto médio prazo (horizontes no intervalo das 3/6/9 a 72 horas). Importa ainda referir que poderão ser utilizados dados *online* e/ou séries de dados históricos com vista a melhoramento das PPE. Na Fig. 13 encontra-se sintetizada a metodologia híbrida.

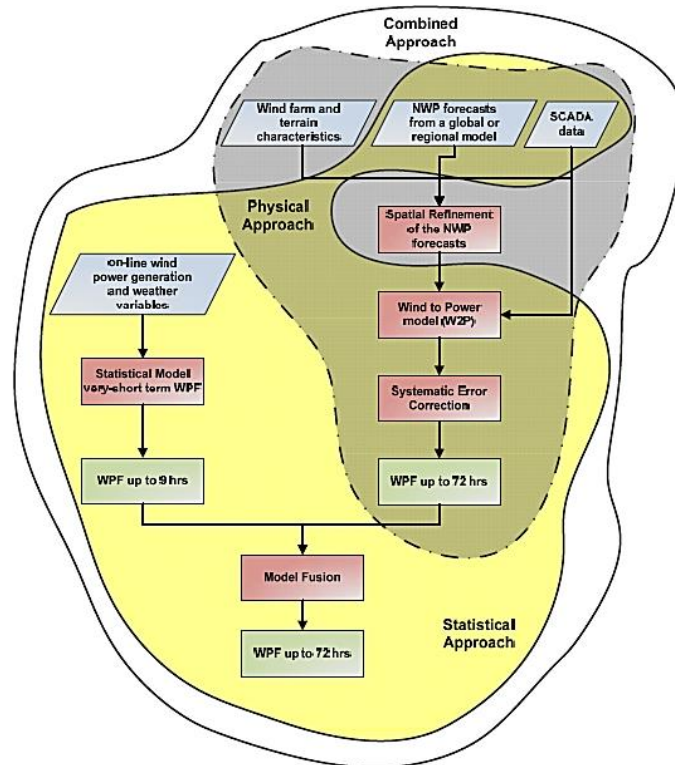


Fig. 13 – Síntese dos vários tipos de metodologias para calcular a PPE. [66]

3.4.10 PREVISÕES DE BASE E DADOS UTILIZADOS

Embora se tenha optado pela nomenclatura MM5, WRF, WRF-ST5 e ALADIN. As previsões de base resultam não só de modelos numéricos de previsão do tempo mas também de outros módulos já anteriormente descritos (*downscaling*, PCM e *upscaling*). No entanto, optou-se por esta nomenclatura por facilitar a distinção entre as várias previsões de base e pelo facto de ser isto que distingue verdadeiramente as várias previsões de base, pois os restantes módulos que compõem a PPE são comuns.

Devido às previsões de base utilizadas na presente dissertação resultarem de serviços externos contratados pela REN pode não ser possível caracterizar de forma completa os processos utilizados. No entanto, recorreu-se a bibliografia disponível para caracterizar o melhor possível estas transformações.

Os dados utilizados pela presente dissertação são valores de potência. Estes foram obtidos após várias fases de cálculo:

1ª fase - recorrendo a um determinado modelo de previsão numérica do tempo (MM5, WRF e ALADIN) obtêm-se previsões de velocidade e direcção do vento, etc para um conjunto de nós à altura da turbina (próximos do local de interesse);

2ª fase - recorrendo a uma ferramenta de *downscaling* estatístico (interpolação) calcula-se a velocidade do vento para um determinado parque eólico;

3ª fase – a velocidade do vento é convertida em potência com recurso á curva de potência característica fornecida pelo fabricante e parametrização do parque eólico (ver Fig. 14);

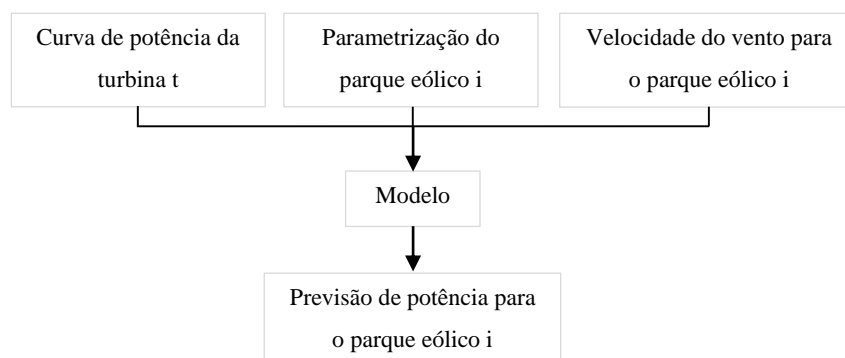


Fig. 14 – Simplificação do modelo PCM utilizado. Adaptado [94]

4ª fase – é efectuado o *upscaling* regional das previsões recorrendo ao método combined (abordado no capítulo 3.4.6.).

Após este processo obtêm-se as previsões de base MM5, WRF, WRF-STS e ALADIN com as seguintes características:

- MM5 – modelo com 4 corridas diárias (lançadas de 6 em 6 horas às 00TU, 06TU, 12TU e 18TU) e que fornece previsões, com *time-steps* de 15 minutos para um máximo de 7 dias;
- WRF - modelo com 4 corridas diárias (lançadas de 6 em 6 horas às 00TU, 06TU, 12TU e 18TU) e que fornece previsões, com *time-steps* de 15 minutos para um máximo de 7 dias;
- ALADIN – modelo com 2 corridas diárias (lançadas de 12 em 12 horas às 00TU e 12TU) e que está a fornecer previsões, com *time-steps* de 60 minutos para um máximo de 2 dias;
- WRF-STS – modelo com 2 corridas diárias (lançadas de 12 em 12 horas às 00TU e 12TU) e que está a fornecer previsões com *time-steps* de 60 minutos para um máximo de 7 dias.

Para além de previsões de potência, a REN possui:

- Medições registadas por um módulo SCADA, este fornece dados *online* da potência eólica instantânea injectada na rede, em tempo real;
- Medições registadas pelos contadores (METER) *in situ*. Esta contagem é feita de 15 em 15 minutos, estando os dados disponíveis de 24 em 24 horas;
- Valores da potência eólica instalada no território nacional.

3.4.10.1 MM5

O modelo MM5 ou *Fifth-generation PSU/NCAR (Penn State University/National Center for Atmospheric Research) Mesoscale Model* é um modelo de mesoescala que efectua a previsão do tempo para uma determinada área delimitada. Este é um modelo de mesoescala que tem a sua origem na década de 70 do século passado. Desde então sofreu mudanças profundas com vista a melhorar a qualidade das previsões. Entre estas mudanças [95] incluem-se: domínios de integração aninhados com resoluções distintas, dinâmica não hidrostática, assimilação variacional 4DVAR (*Nudging* Newtoniano), capacidade de integração de diversos módulos de física. Portabilidade em diversas plataformas computacionais incluindo sistemas OpenM e MPI.

Segundo [96], o modelo MM5 em utilização para efectuar previsões de velocidade do vento utilizadas pela REN é a versão MM5_V3_7.3.1 (2005). O modelo recorre a 3 domínios distintos (81, 27 e 9 km) aninhados para efectuar o *downscaling*, como este é um modelo LAM (*Local Area Model*) é

inicializado pelo GFS (*Global Forecast System*) da NWS (U.S.A) (*United States National Weather Service*) com comunicação nos dois sentidos (*two way nesting*) (ver Fig. 15), efectuando 4 corridas diárias correspondendo às 00hr00, 06hr00, 12hr00 e 24hr00 para horizontes temporais até sete dias com *time-steps* de 15 minutos.




Fig. 15 – Fluxo do modelo MM5.

3.4.10.2 WRF

O *World Research Forecast* (WRF) é um modelo de mesoescala semelhante o modelo MM5 composto por vários programas. Este modelo começou a ser desenvolvido na década de 90 e resultou da colaboração do NCAR (*National Center for Atmospheric Research*), NOAA (*National Oceanic and Atmospheric Administration*), AFWA (*Air Force Weather Agency*), *Naval Research Laboratory*, *University of Oklahoma* e FAA (*Federal Aviation Administration*). O modelo WRF foi desenvolvido para ser utilizado em investigação atmosférica e para obter previsões operacionais [97].

As previsões efectuadas com recurso ao modelo WRF foram obtidas com recurso a [98] dois domínios distintos com a dimensão de 25 e 5 km. A configuração do modelo consiste em 27 níveis verticais com comunicação nos dois sentidos (*two way nesting*) para efectuar 4 corridas diárias correspondentes às 00hr00, 06hr00, 12hr00 e 18hr00 para horizontes temporais até sete dias com *time-steps* de 15 minutos. As previsões com recurso a este modelo são inicializadas pelas condições de fronteira fornecidas pelo modelo GFS (*Global Forecast System*) o qual opera com uma resolução horizontal de 0,5°latitude e 0,5°longitude.

3.4.10.3 WRF-STS

O modelo WRF-STS consiste no modelo WRF acoplado a um modelo MOS. Este recorre às previsões efectuadas com recurso a mesma configuração do modelo WRF (anteriormente abordado no capítulo 3.4.10.3.) e aplica transformações estatísticas às previsões, obtidas pelo modelo WRF por forma a obter novas previsões. Entre as transformações estatísticas, contam-se:

- Quando existe histórico de previsões, esse histórico é utilizado para treinar vários modelos baseados em redes neuronais para cada parque;
- Quando não existe histórico de previsões, recorre-se à curva de potência característica para transformar as previsões em potência;
- Ajuste dinâmico na saída da rede;
- Agregação da potência global REN e é efectuado o *upscaling* das previsões eólicas, por forma a calcular a potência eólica nacional.

3.4.10.4 ALADIN

O modelo ALADIN [99] e [100] é um modelo relativamente recentemente, desenvolvido a partir do código ARPEGE/IFS (*Action de Recherche Petite Echelle Grande Echelle/Integrated Forecasting System*) para o qual contribuíram diversos grupos da Europa e Norte de África com coordenação da *Météo-France*. Este é um modelo de previsão numérica do tempo de área limitada, tendo sido desenvolvido para efectuar previsões até 72 horas, o qual tem sido eficaz na última década para prever o tempo, que se tornou bastante popular por ser um programa relativamente leve com bons resultados obtidos. Ao contrário de outros modelos numéricos de previsão do tempo o modelo ALADIN é um modelo espectral embora recorra a equações e parametrizações usuais em sistemas de grelha.

As previsões efectuadas com recurso ao modelo ALADIN foram efectuadas [100] para horizontes temporais de 72 horas com *time-steps* de 60 minutos, para uma área geográfica delimitada pelos paralelos 47°-28°N e pelos meridianos 37°-0°W, com uma resolução de 46 níveis verticais e com uma resolução horizontal de 9 km. Sendo os principais parâmetros: pressão à superfície, pressão atmosférica ao nível médio do mar, temperatura e humidade relativa do ar a 2 metros, temperatura máxima e temperatura mínima do ar a 2 metros, temperatura e humidade do solo, vento zonal e meridional a 10 metros, rajada a 10 metros, cobertura nebulosa, precipitação convectiva e precipitação de larga escala, precipitação de neve, altura da isotérmica de 0°C, índice CAPE, geopotencial, temperatura, vento zonal, vento meridional, velocidade vertical, humidade relativa.

3.4.10.5 DADOS DE PERSISTÊNCIA

Os dados de persistência (PERS) são valores calculados por persistência. Os dados de PERS foram calculados com recurso à série de dados SCADA, a qual tinha registado os valores de *output* de potência eólica para o território nacional a cada 10 minutos. Assim, os dados de PERS são valores em atraso dos registos de SCADA com um atraso relativamente ao observado de 06hr00, 12hr00, 18hr00 e 24hr00. Os dados de PERS podem ser utilizados como valor de referência ou como valor de *input* de modelos de previsão, conforme abordado em 3.4.2.3.

3.4.10.6 DADOS DE SCADA

Os dados SCADA são relativos á média da potência eólica instantânea produzida em 10 minutos para o território continental. Assim, na presente dissertação utilizaram-se valores médios de potência eólica instantânea a cada 10 minutos. Este sistema embora não seja tido como a medição oficial é tida como uma boa aproximação da observação. Quando não era possível utilizar os dados de METER recorria-se aos dados de SCADA para extrapolar a melhor combinação de modelos e enriquecer os modelos utilizados.

3.4.10.7 DADOS DE METER

O METER é a medida mais precisa e oficial do *output* eólico para o território continental. Este é registado com recurso a contadores instalados entre os parques eólicos e a rede. No entanto, o METER não está disponível em tempo real pelo que não pode ser utilizado para determinar qual a melhor combinação de modelos e enriquecer os modelos utilizados (exceptuando aqueles que recorrem a dados históricos, ex: módulo SLR/MLR-1 do módulo ALFA1). Desta forma o METER foi utilizado principalmente para avaliar o desempenho dos modelos *á posteriori*.

3.4.11 MODELO REN

O modelo REN recorre aos dados resultantes após a 4ª fase (descrito em 3.4.10.), nomeadamente as previsões de base MM5 e WRF, além disso, recorre a dados de potência eólica registados com recurso ao sistema SCADA para efectuar previsões para o horizonte temporal 00-3 dias.

Para efectuar previsões de potência eólica para o horizonte temporal 00-06hr o modelo REN efectua uma média pesada entre os dados de SCADA, previsões de base MM5 e WRF.

Para efectuar previsões de potência eólica para o horizonte temporal 06hr-3dias o modelo REN efectua uma média aritmética entre as previsões de base MM5 e WRF.

4. METODOLOGIA

No presente capítulo quando se recorre à nomenclatura MM5, WRF, WRF-STS e ALADIN refere-se às previsões de base (após 4ª fase, descrita em 3.4.10.). Sendo que, o processo de cálculo das várias previsões de base e dados de PERS, dados de SCADA e dados de METER foram abordados no capítulo 3.4.10.

No presente capítulo quando se refere a séries de previsão refere-se às previsões de base (MM5, WRF, WRF-STS e ALADIN) e aos dados de persistência (PERS).

4.1 MEDIDAS DE CARACTERIZAÇÃO E AVALIAÇÃO DAS PREVISÕES

As medidas de caracterização estatística e avaliação descritas permitem avaliar a qualidade dos dados e consequente desempenho dos modelos. As medidas descritas neste capítulo são utilizadas para descrever a forma da distribuição dos erros, quantificação do erro e tipos de erro. Na presente dissertação optou-se por caracterizar a amostra em média para um dado período (descrição estatística) e em média para um determinado período em função do *time-step* (medidas de avaliação). Embora as medidas de avaliação sejam variações de medidas de descrição optou-se por manter as medidas de descrição estatística e de avaliação de potência já que estas foram utilizadas de forma complementar para avaliar as séries dos erros de previsão. Assim, com recurso às medidas de descrição estatística pretende-se avaliar a forma da distribuição amostral assim como a dispersão dos dados já que isto será igualmente importante para avaliar o desempenho. Relativamente às medidas de avaliação de potência, estas são constituídas por medidas aconselhadas a utilizar [43] e [66] com vista a avaliar o desempenho de uma dada previsão. Desta forma recorre-se a este tipo de medidas para escolher a melhor opção relativamente a um modelo (processo de enriquecimento), comparar desempenhos (processo de enriquecimento, calibração e avaliação do desempenho *à posteriori*), observar a progressão do erro e inferir sobre a estabilidade do erro (avaliação do desempenho *à posteriori*).

Como se pretende avaliar o erro e consequentemente o desempenho de um dado modelo ou tratamento, o primeiro passo do processo é transformar uma previsão numa série amostral do erro. Isto é, com recurso à série de previsões a analisar e à série de dados das observações (SCADA para enriquecer modelos ou METER para avaliar o desempenho final) calcula-se a série amostral do erro associado às séries das previsões. Desta forma o erro (E) é uma medida que permite avaliar a precisão de uma dada previsão, e calcula-se subtraindo a previsão (x) à observação (y) para um determinado *time-step* (i). Assim, é possível obter-se o erro associado a uma previsão para uma dada observação, estando este cálculo expresso na Equação 3.

$$E_i = x_i - y_i \quad (3)$$

Calcularam-se as estatísticas dos erros recorrendo a duas metodologias distintas: I) erros médios calculados sobre todos os *time-steps* dos horizontes temporais de 00-6hr, 06-12hr, 12-18hr, 18-24hr; II) erros instantâneos, válidos para cada *time-step* particular (Ex: 18º *time-step* de uma previsão, ou seja para a 4ª hora. Isto teve como objectivo avaliar o desempenho de uma determinada previsão em média para um determinado horizonte temporal (00-06hr, 06-12hr, 12-18hr e 18-24hr) e avaliar o desempenho de uma dada previsão para cada *time-step* (1-96 *time-step*).

Na Tabela 8 apresenta-se a lista sumária de estatísticas dos erros e que são descritas nos sub-capítulos seguintes.

Tabela 8- Síntese das medidas de caracterização do erro utilizadas.

Metodologia	Medidas da caracterização estatística dos erros
I) Descrição estatística	Média (\bar{E});
	Moda;
	Mediana (\tilde{E});
	Curtose (K);
	Assimetria (As_1 e As_2);
	Desvio padrão (σ);
	Variância (Var);
	Covariância (cov);
	Correlação de Pearson ($\rho_{x,y}$);
	Quantis e percentis (Q_1, Q_3, P_{10} e P_{90});
	Máximo (Max);
Mínimo (Min);	
II) Medidas de avaliação da previsão de potência	MAE;
	RMSE;
	BIAS;
	SDE;
	NMAE;
	NRMSE;
	NBIAS;
	NSDE;
Grau de melhoria (IMP);	

4.1.1 DESCRIÇÃO ESTATÍSTICA

A estatística descritiva consiste num conjunto de valores que permitem caracterizar uma dada amostra e, a partir destes, analisar e retirar conclusões.

4.1.1.1 MÉDIA ARITMÉTICA

A média aritmética pode ser interpretada como um valor de equilíbrio dos valores de uma dada série amostral. Existem vários tipos de médias, entre os quais estão a média aritmética, média ponderada, média harmónica, média quadrática, média geométrica e outras.

A forma mais simples de cálculo desta medida estatística é a média aritmética. Esta é um parâmetro importante para a caracterização da distribuição de probabilidade de uma amostra [101], sendo seguidamente descrita pela Equação 4:

$$\bar{E} = \frac{\sum_{i=1}^n E_i}{n} \quad (4)$$

4.1.1.2 MEDIANA

Em estatística a mediana [101] é o valor médio dos dados (ou dado) centrais (l) da série ordenada, indiferentemente por ordem crescente ou decrescente. Para calcular este valor, numa primeira fase, organizam-se os dados de forma crescente ou decrescente. Posteriormente, se o número de dados da série amostral for ímpar a mediana corresponde ao valor central da amostra e se o número de dados da série amostral for par faz-se a média dos dois valores centrais. Estando este cálculo descrito na Equação 5.

$$\tilde{E} = \begin{cases} E \left\lceil \frac{(n+1)}{2} \right\rceil & \text{se } n \text{ ímpar} \\ \frac{E \left\lceil \frac{n}{2} \right\rceil + E \left\lfloor \frac{n}{2} \right\rfloor}{2} & \text{se } n \text{ par} \end{cases} \quad \text{para } n \text{ dados} \quad (5)$$

4.1.1.3 MODA

Em estatística a moda [101] é o valor que ocorre na amostra com maior frequência. A moda pode ter um, dois ou mais valores. Caso existam dois valores que ocorram com a mesma frequência diz-se que a série de dados é bimodal; se a série de dados tiver mais do que dois valores que ocorrem com o mesmo número de frequência diz-se que a série de dados é multimodal.

4.1.1.4 QUANTIS (QUARTIL E PERCENTIL)

Em estatística o quartil corresponde [101] a qualquer valor que divide a série amostral ordenada em quatro partes iguais. Assim, o quartil pode subdividir-se em $Q_{25\%}$, $Q_{50\%}$ e $Q_{75\%}$, caso subdivida, respectivamente, a série amostral ordenada em 25%, 50% e 75%. O $Q_{50\%}$ corresponde ao valor da mediana.

De forma análoga, pode-se definir o percentil [101]. Este varia entre 1% e 100%. Com o percentil podemos descrever de uma forma mais exacta como a série de dados da amostra se comporta. A $P_{25\%}$, $P_{50\%}$ e $P_{75\%}$ correspondem respectivamente a $Q_{25\%}$, $Q_{50\%}$ e $Q_{75\%}$. Este cálculo pode-se descrever com recurso à Equação 6.

$$Q = \begin{cases} E_{[np+1]} & \text{se } np \text{ não é inteiro} \\ \frac{E_{[np]} + E_{[np+1]}}{2} & \text{se } np \text{ é inteiro} \end{cases} \quad \text{para } n \text{ elementos e } p \text{ percentagem} \quad (6)$$

4.1.1.5 DESVIO PADRÃO

Em estatística o desvio padrão [101] é uma medida de dispersão dos dados que nos permite avaliar a dispersão destes relativamente à média amostral. Assim, um desvio padrão pequeno indica que os valores estão próximos da média da amostra. Por outro lado, um valor elevado para o desvio padrão indica que os valores estão relativamente distantes da média. Isto pode ser descrito pela Equação 7.

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (E_i - \bar{E})^2} \quad (7)$$

A lei da distribuição normal de Gauss [101] refere que para uma série amostral elevada e simétrica em torno da média tem a seguinte função de densidade, que é descrita pela Equação 8.

$$f(E) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \left(\frac{E-\bar{E}}{\sigma} \right)^2} \quad (8)$$

4.1.1.6 VARIÂNCIA

A variância é [101] uma medida de dispersão estatística para dados quantitativos que indica o desvio entre o resultado esperado e o resultado obtido. Na teoria de probabilidade e estatística diz-se que a variância resulta da média do quadrado da diferença entre um valor obtido e o valor esperado.

Sendo \bar{E} a média de uma variável aleatória E , e significa o operador de esperança matemática associada a uma determinada lei de probabilidade. A partir da seguinte Equação 9 calcula-se a variância de uma variável aleatória de E .

$$Var = e[(E - \bar{E})^2] \quad (9)$$

No caso de cálculo de variâncias em matrizes a variância é calculada com recurso à Equação 10.

$$Var = e[(E - \bar{E})(E - \bar{E})^T] \quad (10)$$

4.1.1.7 COVARIÂNCIA

A covariância é [101] uma medida de dispersão estatística para dados quantitativos entre duas variáveis aleatórias reais, x e y , que nos indica qual a correlação entre elas. Na teoria de probabilidade e estatística diz-se que a covariância resulta da multiplicação da diferença entre duas variáveis aleatórias, uma referente ao obtido (x) e a outra referente ao valor esperado (y).

Para efeito de cálculo as séries x é referente á série de previsão e y é relativa á série das observações (geralmente dados de SCADA) e é utilizada para calibrar os modelos. Assim, tendo em conta que x e y são variáveis aleatórias, que \bar{x} e \bar{y} são as médias dessas duas variáveis aleatórias pode-se então calcular a covariância estando o processo de cálculo exposto na Equação 11.

$$cov(x, y) = \sigma_{x,y} = e[(x - \bar{x})(y - \bar{y})] \quad (11)$$

Dependendo do valor da covariância pode-se retirar conclusões sobre as variáveis aleatórias, sendo isso uma forma de analisar as variáveis aleatórias. Conforme representado na Fig. 16:




Fig. 16 – Interpretação dos vários tipos de dispersão para valores de covariância. Sendo que: a) $cov(x, y) > 0$; b) $cov(x, y) = 0$; c) $cov(x, y) < 0$.

Assim, consoante o valor da covariância podemos avaliar a dispersão das duas variáveis bem como se: a) as variáveis aleatórias são directamente correlacionáveis; b) as variáveis aleatórias são independentes; c) as variáveis aleatórias são inversamente correlacionáveis.

4.1.1.8 COEFICIENTE DE CORRELAÇÃO DE PEARSON

O coeficiente de correlação é [101] uma medida importante, dado que nem sempre a medida da covariância pode ser interpretada de uma forma fidedigna, pois poderá ocorrer uma mudança da escala. Assim, recorre-se ao cálculo do coeficiente de correlação, usufruindo do facto de este ser adimensional, estando este cálculo enunciado na Equação 12.

$$\rho_{x,y} = \frac{cov(x,y)}{\sqrt{Var(x)Var(y)}} \quad -1 \leq \rho_{xy} \leq 1 \quad (12)$$

O coeficiente de correlação de Pearson é tanto mais forte quanto mais próximo do valor de 1 ou -1, e mais fraco quanto mais próximo de zero for o valor da correlação, assim:

- $\rho_{x,y} = -1$ Correlação perfeita negativa
- $-1 > \rho_{x,y} > 0$ Correlação negativa
- $\rho_{x,y} = 0$ Correlação nula
- $0 < \rho_{x,y} < 1$ Correlação positiva
- $\rho_{x,y} = 1$ Correlação perfeita positiva

4.1.1.9 CURTOSE

Em estatística descritiva a curtose [101] e [102] indica qual o grau de achatamento da distribuição de probabilidade de uma dada amostra. Em qualquer amostra, quanto mais próximos os pontos de inflexão estiverem da média, mais os valores da amostra se concentram em torno da média e mais alongada é a distribuição normal, caracterizando estes casos de distribuição leptocúrtica, Fig. 17 (a). Por outro lado, quanto mais afastados os pontos de inflexão estiverem da média mais os valores da amostra se dispersam em torno da média e mais achatada é a distribuição normal, referenciando estes casos de distribuição platicúrtica, Fig. 17 (c). Aos casos intermédios dá-se o nome de distribuição mesocúrtica, Fig. 17 (b).




Fig. 17 – Ilustração da variação da curtose: a) leptocúrtica, b) mesocúrtica, c) platicúrtica. Adaptado [102]

A curtose pode ser definida [101] através do momento central, conforme enunciado na Equação 13.

$$K' = \frac{m_4}{\sigma^4} = \frac{\frac{1}{n} \sum_{i=1}^n (E_i - \bar{E})^4}{\left(\sqrt{\frac{1}{n-1} \sum_{i=1}^n (E_i - \bar{E})^2} \right)^4} - 3 \quad (13)$$

Assim quando:

- $K' > 0$, indica que a distribuição é leptocúrtica
- $K' = 0$, indica que a distribuição é mesocúrtica
- $K' < 0$, indica que a distribuição é platicúrtica

Por outro lado, a curtose pode ser definida [102] através dos quantis da série amostral (Equação 14), sendo este o método de cálculo utilizado para calcular a curtose na presente dissertação. Neste método Q_1 e Q_3 são referentes ao primeiro e terceiro quartil respectivamente e P_{10} e P_{90} são referentes ao percentil 10 e ao percentil 90 respectivamente.

$$K = \frac{Q_3 - Q_1}{2(P_{90} - P_{10})} \quad (14)$$

Os resultados do cálculo da equação anterior podem ser interpretados da seguinte forma:

- Se $K < 0,263$ leptocúrtica
- Se $K = 0,263$ mesocúrtica
- Se $K > 0,263$ platicúrtica

4.1.1.10 ASSIMETRIA

Em estatística descritiva a assimetria [101] e [102] possibilita analisar uma distribuição com base nas relações entre a média, mediana e moda de uma dada distribuição. Quando a média, a moda e a mediana são coincidentes diz-se que a distribuição é simétrica, Fig. 18 b), analogamente, quando tal não se verifica diz-se que a distribuição é assimétrica. A assimetria pode ser ainda positiva ou negativa consoante a distribuição apresente uma cauda alongada para a direita e, neste caso, a assimétrica positiva caracteriza-se por uma cauda alongada para a direita, Fig. 18 a), ou caso a distribuição apresente uma cauda alongada para a esquerda a amostra apresenta uma assimetria negativa, Fig. 18 c).




Fig. 18 – Ilustração dos tipos de simetria: a) Assimétrica negativa; b) Simétrica; c) Assimétrica positiva. Adaptado [102]

A assimetria pode ser definida [101] através do momento central, conforme enunciado na Equação 15.

$$As' = \frac{m_3}{\sigma^3} = \frac{\frac{1}{n} \sum_{i=1}^n (E_i - \bar{E})^3}{\left(\sqrt{\frac{1}{n-1} \sum_{i=1}^n (E_i - \bar{E})^2} \right)^3} \quad (15)$$

Assim quando:

- $As' > 0$, indica que a distribuição é assimétrica positiva
- $As' = 0$, indica que a distribuição é simétrica
- $As' < 0$, indica que a distribuição é assimétrica negativa

Por outro lado, a assimetria segundo [102] pode ser definida através das equações 16 e 17. Sendo estas as equações que foram utilizadas. A equação 16 permite avaliar se a série amostral é assimétrica positiva, negativa ou simétrica. A Equação 17 permite avaliar se a série amostral é simétrica, assimétrica moderada ou forte.

$$As_1 = \bar{E} - Moda \quad (16)$$

Assim, caso:

- $As_1 = 0$ simétrica
- $As_1 < 0$ assimétrica negativa
- $As_1 > 0$ assimétrica positiva

A simetria ainda pode ser categorizada [102] entre simétrica, assimétrica forte e assimétrica moderada a partir dos resultados obtidos por aplicação da Equação 17 e consequente interpretação destes.

$$As_2 = \frac{3(\bar{E} - \tilde{E})}{\sigma} \quad (17)$$

Assim se:

- $|As_2| < 0,15$ simétrica
- $0,15 < |As_2| < 1$ assimétrica moderada
- $|As_2| \geq 1$ assimétrica forte

4.1.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

A escolha das medidas de avaliação da potência foi efectuada com recurso á consulta bibliográfica [43], [66] e [96]. Assim, optou-se por utilizar medidas de RMSE, MAE, BIAS, SDE, NMAE, NRMSE, NBIAS, NSDE e Grau de melhoria (IMP).

4.1.2.1 RAIZ DO ERRO MÉDIO QUADRÁTICO (REMQU) OU *ROOT MEAN SQUARE ERROR (RMSE)*

A raiz do erro médio quadrático (REMQU) é uma medida que permite avaliar a precisão de uma dada previsão, esta deriva do cálculo do MSE (*Mean Square Error*) ou Erro Médio Quadrático (EMQ), o qual é calculado com recurso á Equação 18.

$$MSE = \frac{\sum_{i=1}^n E_i^2}{n} \quad (18)$$

No entanto, é comum utilizar-se antes o RMSE já que é uma medida do erro expressa nas unidades de MW contrariamente ao MSE que é expresso nas unidades $[MW]^2$. Assim, de modo a facilitar a interpretação dos resultados e de modo a poder-se efectuar um paralelismo aproximado á realidade é

mais frequente utilizar-se a medida de RMSE. O processo de cálculo desta medida é representado pela Equação 19.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n E_i^2}{n}} \quad (19)$$

4.1.2.2 ERRO MÉDIO ABSOLUTO (EMA) OU *MEAN ABSOLUT ERROR* (MAE)

O erro médio absoluto (EMA) ou *Mean Absolute Error* (MAE) é uma medida que permite avaliar a precisão de uma dada previsão. O EMA não indica se a previsão está subestimada ou sobrestimada, já que não tem em conta o sinal do erro. De uma forma geral MAE toma valores inferiores aos valores de RMSE, isto porque o RMSE, devido à potência quadrático dos erros, atribui maior importância aos valores extremos do erro, tanto por sub-estimação como por sobre-estimação). O cálculo do EMA está expresso na Equação 20 para n dados.

$$MAE = \frac{\sum_{i=1}^n |E_i|}{n} \quad (20)$$

4.1.2.3 DESVIO PADRÃO DOS ERROS (DPE) OU *STANDARD DEVIATION ERROR* (SDE)

O desvio padrão dos erros (DPE) ou *Standard Deviation Error* (SDE) consiste no cálculo dos erros *a posteriori* tendo em conta o erro médio de uma série. Isto torna-se relevante já que permite desprezar os erros sistemáticos e, assim, estabelecer uma melhor comparação entre vários resultados. O cálculo deste está expresso pela Equação 21:

$$SDE = \sqrt{\frac{\sum_{i=1}^n (E_i - \bar{E})^2}{n}} \quad (21)$$

4.1.2.4 VIÉS OU BIAS

O viés consiste num erro sistemático sendo, por isso mesmo, uma tendência. Ainda assim, por vezes torna-se necessário, para produzir melhores análises comparativas, anular o viés. Como é possível verificar pela Equação 22 o cálculo do RMSE desviesado pode ser facilmente calculado bastando-nos somar e subtrair o BIAS quadrado.

$$RMSE^2 = BIAS^2 + SDE^2 \quad (22)$$

O SDE^2 pode ainda ser decomposto nas medidas de $disp^2$ e $sdbias^2$. O valor $disp$ indica qual a dispersão associada às previsões e o valor $sdbias$ indica qual a variabilidade. Assim o SDE pode ser calculado com base na equação 23, onde: $\sigma(x)$ é o desvio padrão das previsões, $\sigma(y)$ é o desvio padrão das observações, $\rho_{x,y}$ é o coeficiente de correlação de Pearson entre as observações (y) e as previsões (x).

$$SDE^2 = disp^2 + sdbias^2$$

$$SDE^2 = \left(\sqrt{2\sigma(x)\sigma(y)(1 - \rho_{x,y})} \right)^2 + (\sigma(x) - \sigma(y))^2 \quad (23)$$

Assim, o cálculo do viés pode ser efectuado com recurso á Equação 24. Este valor indica a média da série amostral do erro, ou seja, se em média as previsões de um modelo estão sub ou sobre-estimadas, conforme $BIAS < 0$ ou $BIAS > 0$.

$$BIAS = \frac{1}{N} \sum_{i=1}^N (E_i) \quad (24)$$

4.1.2.5 COMPARAÇÃO ENTRE PREVISÕES

As medidas de comparação são calculadas normalizando os valores de desempenho dos modelos/sistemas de PPE através da potência eólica instalada. Isto tem como objectivo, efectuar comparações em percentagem da potência instalada. No entanto, isto não é suficiente para efectuar uma comparação fidedigna entre modelos/sistemas de PPE já que o mesmo modelo situado em terreno complexo e em terreno plano provavelmente não irá alcançar um desempenho semelhante. Por outro lado, quando se efectua uma comparação entre modelos/sistemas de PPE, é necessário ter em conta que as previsões devem ser efectuadas para o mesmo período, por forma a reduzir os erros associados aos ciclos anuais e à sazonalidade, e desta forma possibilitando a comparação fidedigna das previsões. Assim, quando se efectuam comparações entre modelos/sistemas de PPE é necessário ter em conta os erros associados aos dados que esses sistemas/modelos utilizam como *input* assim como o período em que o desempenho dos sistemas/modelos de PPE é avaliado.

As medidas de comparação mais utilizadas são: MAE, RMSE, MSE e BIAS. Assim deverão ser usados valores (em percentagem) como: NRMSE (*Normalized Root Mean Square Error*), NSDE (*Normalized Standard Deviation Error*), NBIAS (*Normalized BIAS*), NMAE (*Normalized Mean Absolut Error*) dado que permitem calcular o erro normalizado pela potência instalada. Estes encontram-se descritos pelas Equações 25-28, sendo que a POT_{INST} refere-se á potência instalada ao momento em que se efectuam as previsões.

$$NRMSE = \frac{1}{POT_{INST}} \sqrt{\frac{\sum_{i=1}^n (E_i)^2}{n}} \times 100 \quad (25)$$

$$NMAE = \frac{1}{POT_{INST}} \frac{\sum_{i=1}^n |E_i|}{n} \times 100 \quad (26)$$

$$NSDE = \frac{1}{POT_{INST}} \sqrt{\frac{\sum_{i=1}^n (E_i - \bar{E})^2}{n}} \times 100 \quad (27)$$

$$NBIAS = \frac{1}{POT_{INST}} \frac{1}{N} \sum_{i=1}^N E_i \times 100 \quad (28)$$

4.1.2.5.1 QUANTIFICAÇÃO DO GRAU DE MELHORIA

Deverão ser utilizadas medidas que possibilitem avaliar o grau de melhoria das várias previsões com base num valor de referência. Uma das medidas possíveis é a quantificação do grau de melhoria (IMP), esta pode ser descrita pela Equação 29, sendo que o critério de avaliação (CA) e o critério de avaliação de referência (CA_{REF}) poderão ser NMAE, NRMSE e NSDE (Equações 25-27) ou MAE, RMSE e SDE (Equações 19-21 e 24) para, respectivamente, o modelo a avaliar e o modelo de referência.

$$IMP = \frac{CA_{REF} - CA}{CA_{REF}} \quad (29)$$

4.2 PREVISÕES DE BASE E OBSERVAÇÕES DE POTÊNCIA

A série de dados cedidos pela REN, e que foram utilizados para realizar a presente dissertação, são referentes ao período entre Janeiro de 2011 e a Abril de 2012 inclusivé (rejeitou-se os dados referentes a janeiro de 2012, devido a pouca qualidade de algumas séries de previsão).

4.2.1 SÉRIE DE DADOS E SUBDIVISÃO DE DADOS

A série de dados a ser utilizada como *input* dos modelos foi subdividida de modo a verificar-se a independência entre os vários períodos necessários. Tendo isto em conta, a série de dados foi subdividida em três períodos distintos, seguidamente descritos e esquematizados na Fig. 19.

1. Calibração (i∈[0,365]U[397,407] dias) – neste período os modelos efectuem as calibrações estatísticas necessárias (1/1/2011 a 31/12/2011 e de 1/2/2012 a 11/2/2012), designados no contexto da presente dissertação como período de calibração ALFA1 e ALFA2;
 - Cálculo dos coeficientes regressivos do modelo STEPWISE-LR e calibração da janela móvel de avaliação de dimensão fixa, ver capítulo 4.3.2.3. e anexo B;
 - Cálculo dos coeficientes regressivos dos modelos SLR/MLR, ver capítulo 4.3.2.1, 5.2.1. e 5.2.2.;
 - Cálculo da melhor previsão com recurso à variação do Filtro de Kalman (KF), ver capítulo 4.3.2.2;
 - Cálculo da melhor combinação de previsões efectuadas com recurso a ALFA1, ALFA2 (excepto KF) e MOSF com recurso ao modelo MIX, ver capítulo 4.3.3;
 - Cálculo da melhor combinação das taxas de aprendizagem associadas ao modelo KF, ver capítulo 4.3.3.
2. Validação (i∈ [408,446] dias) - neste período os modelos efectuem as últimas calibrações necessárias (11/2/2012 a 22/3/2012);
 - Calibração do critério de inclusão sucessiva de predictores da STEPWISE-LR
3. Teste (i∈[447,486] dias) – neste período os modelos são testados (22/3/2012 a 30/4/2012). Período independente dos períodos de calibração e validação.



Fig. 19 – Esquematização da subdivisão da série de dados.

4.2.2 DADOS DAS PREVISÕES E OBSERVAÇÕES

Existem várias entidades independentes que fornecem previsões à REN. Os dados que resultam destas previsões provêm de diferentes modelos, sendo posteriormente transformadas de modo a obter previsões em valor de potência para o território nacional. As previsões de base utilizadas têm as seguintes características:

1. MM5 – fornecida com uma resolução de 15 minutos com quatro corridas diárias (lançadas às 00, 06, 12 e 18 TU) e com horizontes de previsões até 7 dias;
2. WRF – fornecida com uma resolução de 15 minutos com quatro corridas diárias (lançadas às 00, 06, 12 e 18 TU) e com horizontes de previsões até 7 dias;
3. WRF-STS – fornecida com uma resolução de 60 minutos com duas corridas diárias (lançadas às 00 e 12 TU) e com horizontes de previsões até 7 dias;
4. ALADIN – fornecida com uma resolução de 60 minutos com duas corridas diárias (lançadas às 00 e 12 TU) e com horizontes de previsões até 2 dias.

Como se pode observar foram utilizadas previsões lançadas em diferentes momentos, já que o modelo MM5 efectua 4 corridas diárias e os modelos WRF-STS e ALADIN apenas efectuam duas corridas diárias. Além disso como se pode observar as previsões de base WRF-STS e ALADIN são fornecidas com uma resolução de 60 min enquanto que as previsões MM5 e WRF são fornecidas com uma resolução de 15 min.

A resolução temporal das observações utilizadas, assim como a resolução temporal das previsões, não foi a mesma, sendo que:

1. A observação de potência instantânea produzida (METER) é registada com recurso a contadores. Esta é considerada a contagem oficial já que é sobre estes valores que a REN é remunerada, é a medida de potência produzida mais fidedigna devendo ser utilizada sempre que possível para: calibrar modelos; aferir a qualidade dos modelos e dos métodos. Estas observações têm uma resolução de 15 minutos. No entanto, não estão disponíveis em tempo real;
2. O sistema SCADA regista medições em tempo real de potência instantânea produzida. No entanto, a série de dados SCADA é referente a potência instantânea média a cada 10 minutos. Assim, este sistema apresenta uma resolução de 10 min, ou seja, os valores de SCADA utilizados não são coincidentes com os valores de *output* dos modelos de previsão de base (MM5, WRF, WRF-STS e ALADIN) nem dos valores de METER.

4.2.3 ORGANIZAÇÃO E PRÉ TRATAMENTO DOS DADOS

Todos os ficheiros cedidos pela REN, e utilizados no decorrer deste estudo, apresentam os dados em valores de potência (MW). As previsões obtidas pelos modelos foram enviadas para a REN em valores de (m/s) e a REN aplicou sobre eles um módulo de *downscaling*, as curvas de potência dos

aerogeradores e um módulo de *upscaling*, de modo a conseguir transformar as previsões em valores de potência.

Os ficheiros cedidos não são homogêneos, apresentando diferentes resoluções de previsão (diferente número de *time-steps* para o mesmo horizonte temporal) consoante a fonte, pelo que foi necessário interpolar os dados para terem todos o mesmo número de *time-steps* por horizonte temporal considerado. Assim, calculou-se os *time-steps* intermédios para os quais não existiam valores (aumentou-se a resolução das previsões de base) com recurso a uma interpolação simples. Este processo foi efectuado para as séries de dados SCADA, WRF-STS e ALADIN por forma a terem resoluções com *time-steps* de 15 minutos.

Verificou-se também a existência de lacunas que embora esporádicas eram mais comuns para horizontes temporais associados a maiores horizontes temporais de previsão (Ex: 18-24hr). Assim, quando isto se verificava, foi efectuada uma interpolação linear simples por forma a calcular as previsões de potência correspondentes às lacunas. Por outro lado, verificou-se que a maior ocorrência de lacunas foi registada no período de teste.

4.2.4 CARACTERIZAÇÃO DOS DADOS DE SCADA

Com esta caracterização e subsequente análise pretendeu-se avaliar a qualidade dos dados obtidos com recurso ao sistema SCADA (após aumento da resolução com recurso a interpolação simples), relativamente aos valores observados com recurso a contadores (METER). A caracterização dos dados de SCADA foi efectuada para os períodos: calibração ALFA2, validação e teste.

O cálculo da série de erros dos dados de SCADA foi efectuada com recurso à Equação 3. Seguidamente procedeu-se a caracterização da série de erros dos dados de SCADA com recurso aos indicadores anteriormente descritos no capítulo 4.1.

4.2.4.1 DESCRIÇÃO ESTATÍSTICA

Tabela 9- Descrição estatística dos erros da série de dados SCADA.

	SCADA
\bar{E}	-21,50
\tilde{E}	-15,20
Moda	-13,50
As ₁	-8,00
σ	31,19
Var	9,7E+02
K	0,26
As ₂	-0,61
Min	-133,70
Max	182,10
Q ₁	-41,20
Q ₃	0,10
P ₉₀	11,91
P ₁₀	-67,10
$\rho_{x,y}$	1,00

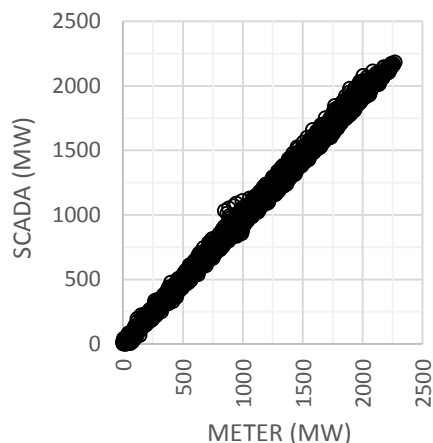


Fig. 20 – Gráfico das observações SCADA Vs. observações METER.

Como se pode observar a série de erros dos dados de SCADA apresentam uma média negativa ou seja, em média o registo de SCADA apresenta-se subestimado face ao METER. Por outro lado verifica-se que a moda assume um valor negativo, isto em conjunto com o valor da média também ele negativo e com recurso a Equação 16, conclui-se que a distribuição dos erros é assimétrica ($As_1 = \bar{E} - \text{Moda} < 0$). Verifica-se também com recurso Equação 17, que a assimetria toma um valor em módulo entre 0,15 e 1. Pelo que isto indica que a distribuição dos erros do SCADA é uma distribuição assimétrica negativa moderada. Por outro lado, verifica-se que a curtose (calculada com recurso a Equação 14 tem um valor inferior a 0,263, ou seja a distribuição dos erros é uma distribuição leptocúrtica. Isto indica que os erros estão mais concentrados em torno da moda, relativamente à distribuição normal com a mesma variância. Por outro lado, tendo em conta a relação exposta na Equação 22, que recorre à média e à variância (desvio padrão ao quadrado), verifica-se que o RMSE em média é de cerca 35 MW. O último valor da Tabela 9, indica que a correlação entre as previsões e as observações arredondada é perfeita. Isto vai ao encontro da Fig. 20 e 21 em que se verifica uma forte correlação entre a série de dados SCADA e a série de dados METER.




Fig. 21 – Histograma dos erros dos dados de SCADA.

O histograma exposto na Fig. 21 é referente a um gráfico alisado. Este foi calculado com uma resolução de 2.5 MW. Dada a baixa resolução aqui usada, tal pode não ser indicativo da moda rigorosa.

Como se pode observar pela Fig. 21, verifica-se que o histograma dos erros vai ao encontro da Tabela 9, com reservas. Isto porque a moda deveria ser o valor com maior frequência e com base no gráfico verifica-se que a moda toma o valor zero. Isto pode estar relacionado com o valor de resolução do histograma e devido a este ter sido alisado.

4.2.4.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

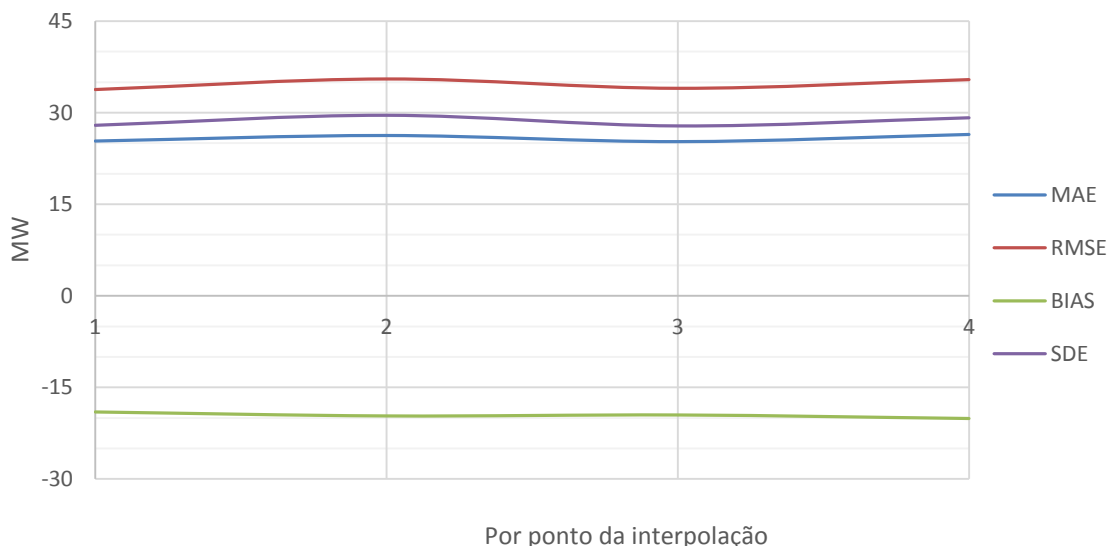


Fig. 22 – Medidas de avaliação do SCADA por *time-step* da interpolação.

Como se pode observar pela Fig. 22, os valores do erro referentes aos vários pontos de interpolação vão ao encontro das medidas do erro em média para a série de dados (exposto no capítulo 4.2.4.1.). Assim, verifica-se que o erro não variou de forma substancial ao longo dos vários pontos de interpolação. Por outro lado, observa-se que o valor de SDE (que tem em conta o valor da média ou viés) teve um valor inferior ao RMSE, no entanto a utilização da média não reduziu o valor de SDE à proporção, o que com base na Equação 23 poderá indicar uma variabilidade do erro ($sdbias$) e/ou uma dispersão substancial dos valores de previsão e observação ($disp$). Isto pode dever-se ao método utilizado para calcular os valores intermédios de SCADA. Assim, a interpolação simples poderá não ter sido o melhor método, no entanto, devido ao reduzido valor de erro, à elevada correlação dos dados de SCADA com as observações (METER) e ao facto de futuramente se poder aceder à biblioteca SCADA para os *time-steps* pretendidos não se efectuaram outros estudos.

4.2.5 CARACTERIZAÇÃO DAS PREVISÕES DE BASE E DADOS DE PERS

As previsões de base são valores de potência prevista, conforme anteriormente abordado em 3.4.10. Estas conforme descrito no capítulo 3.4.10. resultam da transformação dos valores de previsão tempo em valores de potência. Os dados de PERS são um desfasamento das observações de SCADA, conforme descrito em 3.4.10.

O presente capítulo efectua uma análise das previsões de base para o período de calidação do módulo ALFA2 e para o período de validação face aos valores observados com recurso a contador (METER).

4.2.5.1 DESCRIÇÃO ESTATÍSTICA

Tabela 10- Descrição estatística das séries dos erros das previsões para o horizonte temporal 00-06hr.

	MM5	WRF	WRF-ST5	ALADIN	PERS
--	-----	-----	---------	--------	------

\bar{E}	6,63	17,44	-138,76	-219,24	-17,93
\hat{E}	14,65	14,80	-82,73	-178,65	-22,50
Moda	-20,00	20,00	-28,00	-66,00	-330,10
As_1	26,63	-2,56	-110,76	-153,24	312,17
σ	185,27	192,46	227,80	216,68	391,21
Var	3,4E+04	3,7E+04	5,2E+04	4,7E+04	1,5E+05
K	0,20	0,20	0,28	0,30	0,25
As_2	-0,13	0,04	-0,74	-0,56	0,04
Min	-642,60	-982,90	-1048,85	-953,80	-1328,60
Max	700,80	721,20	334,70	490,00	1436,20
Q_1	-82,78	-79,05	-283,56	-368,36	-268,50
Q_3	98,63	101,25	38,95	-38,38	203,90
P_{90}	224,41	255,83	99,50	19,00	445,31
P_{10}	-222,64	-195,99	-470,22	-528,08	-493,13
$\rho_{x,y}$	0,94	0,93	0,93	0,93	0,71

Como se pode observar pela Tabela 10 os valores da média são bastante variáveis entre os vários modelos, estes variam entre -17 e 17 MW para as previsões de base MM5, WRF e PERS, -138 e -220MW para as previsões de base WRF-STS e ALADIN.

Os dados PERS têm uma média do erro dentro do que é expectável, sendo devida apenas à variabilidade amostral. De facto, o viés é cerca de 4% do desvio padrão. Por outro lado com recurso à Equação 16 verifica-se que para as previsões de base WRF, WRF-STS e ALADIN ($As_1 = \bar{E} - \text{Moda} < 0$) o que indica que a distribuição dos erros é assimétrica negativa. Contrariamente e com recurso à mesma equação (Equação 16) verifica-se que a distribuição dos erros das previsões de base MM5 e PERS são assimétricas positivas ($As_1 = \bar{E} - \text{Moda} > 0$). Continuando a análise da simetria da distribuição dos erros das previsões de base com recurso ao valor da assimetria (Equação 17) verifica-se que distribuição dos erros: das previsões de base MM5, WRF e PERS são simétricas; do WRF-STS e ALADIN são assimétricas moderadas. Por outro lado através do valor da curtose (Equação 14) verifica-se que a distribuição dos erros das previsões de base MM5, WRF e PERS assume a forma leptocúrtica e que a distribuição dos erros das previsões de base WRF-STS e ALADIN apresenta uma forma platicúrtica.

Tendo em conta os valores do desvio padrão e/ou as variâncias presentes na Tabela 10 verifica-se existe uma elevada variabilidade de valores para as diferentes previsões de base. As previsões de base MM5 e WRF têm valores de desvio padrão entre 185 e 192 MW, enquanto que as previsões de base WRF-STS e ALADIN têm valores de desvio padrão que oscilam entre 216 e 227 MW e os dados de PERS têm um desvio padrão associado de 391 MW. Com recurso à relação descrita pela Equação 22 pode-se calcular em média o RMSE para as várias previsões de base. Efectuando-se o cálculo e ordenando os valores de RMSE de forma crescente das previsões de base, isto é, do menor para o maior RMSE, verifica-se a seguinte ordem MM5, WRF, WRF-STS, ALADIN e PERS. Por outro lado, tendo em conta os valores da correlação de Pearson da Tabela 10 ($\rho_{x,y}$) verifica-se uma forte correlação entre as observações (METER) e as previsões de base. Verificando-se uma maior correlação para as previsões de base MM5, WRF, WRF-STS, ALADIN e uma correlação inferior para os dados de PERS. O que indica a existência de uma elevada dispersão do erro para os dados de PERS.

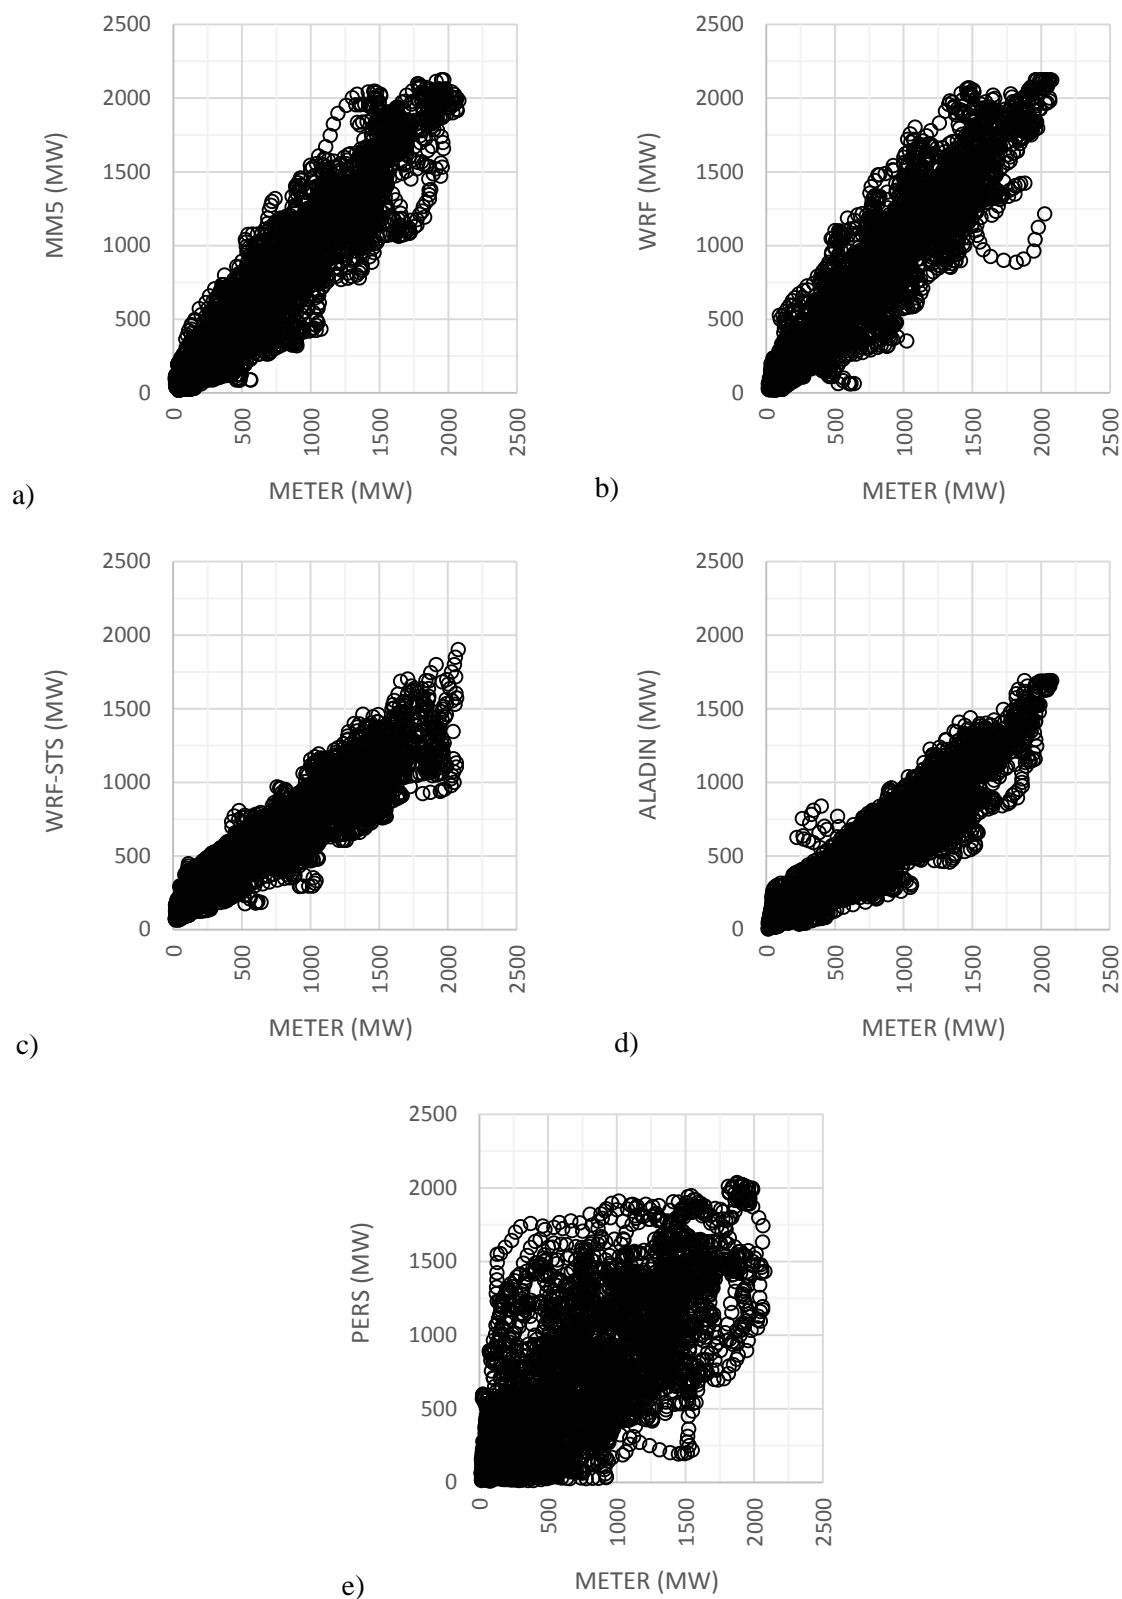


Fig. 23 – Gráficos das séries de previsões do horizonte temporal 00-06hr vs observação (METER). Na figura estão representadas as séries de dados: a) MM5, b) WRF, c) WRF-ST5, d) ALADIN e e) PERS.

A Fig. 23 a), b), c), d) e e) vai ao encontro dos valores \bar{E} e $\rho_{x,y}$ presentes na Tabela 10. Verificando-se um erro reduzido para as previsões de base MM5 e WRF; relevante para as previsões de base WRF-STs e ALADIN; os dados de PERS têm associado o erro mais elevado, o que é de esperar dado que esta previsão é unicamente baseada na memória de curto prazo sem inclusão de qualquer previsão física ou estatística. Por outro lado, verifica-se que as Fig. 23 c) e d) que os erros das previsões de base são heterocedásticos ou seja o viés e a variância dos erros, condicionais aos valores das observações não são constantes, i.e. variam com elas (e.g. o viés condicional da previsão ALADIN é sempre negativo mas menor em módulo para valores elevados das observações). Se este fosse um erro sistemático poderia ser efectuado um tratamento de dados por sectores, isto é, viés condicional a cada sub-intervalo, no entanto não se sabe qual a evolução deste pelo que um tratamento deste tipo poderia não ser vantajoso. Por outro lado verifica-se nas Fig. 23 a), b), c), d) e e) a ocorrência de extremos (*outliers*), que representam picos de erro.

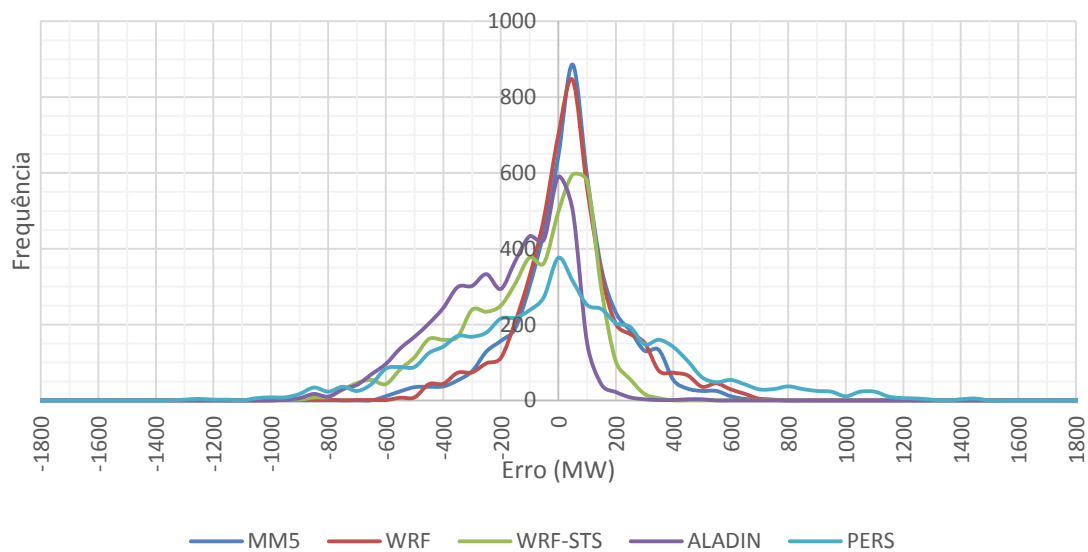


Fig. 24 – Histograma dos erros das séries das previsões de base para o horizonte temporal 00-06hr.

O histograma exposto na Fig. 24 é referente a um gráfico alisado. Este foi calculado com uma resolução de 50 MW. Dada a baixa resolução aqui usada, tal pode justificar uma certa discrepância entre a moda do histograma (Fig. 24) e a moda dada na Tabela 10, calculada como o valor mais frequente com a resolução de 0.1 MW ou ainda menos nalguns casos.

A Fig. 24 é consistente com a Tabela 10 e das Fig. 23 a), b), c), d) e e). Tendo em conta as estatísticas listadas na Tabela 10, às Fig. 23 a), b), c), d) e e) e Fig. 24 verifica-se que para o período analisado as previsões de base MM5 e WRF são muito semelhantes entre si. Verifica-se que as previsões de base WRF-STs e ALADIN têm uma qualidade inferior às previsões de base MM5 e WRF conforme se verifica pelos maiores valores quer do valor absoluto da média do erro, quer da variância do erro. Verifica-se que os dados de PERS são os que menor qualidade têm para prever a potência eólica devido à elevada variância do erro, e portanto em última análise devido à fraca persistência (memória) dos dados. Todavia dado que o erro da persistência (PERS) é a diferença entre o METER e o SCADA desfasados no tempo seguindo uma semelhante distribuição de probabilidade, é de esperar um valor teórico nulo da assimetria, bem como da média, mediana e moda, o que é corroborado pelos baixos valores obtidos na prática. Isto porque, os dados de PERS são um atraso da observação, assim, teoricamente, com uma amostra suficientemente grande, dever-se-á obter uma distribuição simétrica do erro da persistência. Desse modo a obtenção de um bias e um coeficiente de assimetria diferentes de zero são resultado de flutuações amostrais. Relativamente, à reduzida qualidade destes dados de previsão deve-se a esta ser uma série de previsão que resulta de uma observação em atraso contrariamente a uma série de previsão física, estatística ou híbrida.

Tabela 11- Descrição estatística das séries dos erros das previsões para o horizonte temporal 06-12hr.

	MM5	WRF	WRF-STS	ALADIN	PERS
\bar{E}	-56,53	6,21	-226,92	-273,92	-18,47
\tilde{E}	-41,50	-9,35	-166,75	-251,23	-29,25
Moda	-82,50	-8,50	-627,60	-301,50	-18,00
As ₁	25,97	14,71	400,68	27,58	-0,47
σ	243,81	267,63	289,26	234,80	525,94
Var	5,9E+04	7,2E+04	8,4E+04	5,5E+04	2,8E+05
K	0,23	0,23	0,33	0,30	0,24
As ₂	-0,18	0,17	-0,62	-0,29	0,06
Min	-820,50	-745,00	-1085,90	-948,55	-1674,40
Max	662,10	960,70	329,90	374,70	1696,00
Q ₁	-196,90	-156,83	-456,81	-442,71	-349,73
Q ₃	82,50	153,00	23,55	-77,28	298,83
P ₉₀	256,00	362,33	95,61	-0,44	675,21
P ₁₀	-358,32	-318,45	-643,27	-614,02	-696,08
$\rho_{x,y}$	0,90	0,88	0,90	0,93	0,47

Analisando a Tabela 11 verifica-se uma degradação da qualidade das séries de previsão relativamente às da Tabela 10 o que era expectável já que os dados são referentes ao horizonte temporal seguinte (06-12hr). Observando a Tabela 11 verifica-se, que de uma forma geral a média dos erros (viés dos erros) das previsões de base piorou relativamente à Tabela 10, no entanto verifica-se que a média dos erros da previsão WRF toma um valor mais próximo de zero. Com recurso à Tabela 11 observa-se que a média do erro da PERS e WRF são semelhantes entre si, que a média do erro da previsão de base MM5 é ligeiramente superior a estas e que os valores da média do erro das previsões de base WRF-STS e ALADIN são substancialmente mais elevadas (em módulo) relativamente às restantes. Com base nos indicadores de forma da distribuição dos erros verificaram-se algumas alterações. Sendo que a forma da distribuição dos erros da previsão de base:

- MM5 é assimétrica positiva (Equação 16) moderada (Equação 17) assumindo uma forma leptocúrtica (Equação 14);
- WRF é assimétrica positiva (Equação 16) moderada (Equação 17) assumindo uma forma leptocúrtica (Equação 14);
- WRF-STS é assimétrica positiva (Equação 16) moderada (Equação 17) assumindo a forma platicúrtica (Equação 14);
- ALADIN é assimétrica positiva (Equação 16) moderada (Equação 17) assumindo uma forma platicúrtica (Equação 14);
- PERS é assimétrica negativa (fortuito) tendo em conta o critério calculado com recurso à Equação 16 no entanto com recurso ao valor da assimetria (Equação 17) verifica-se que é teoricamente simétrica. Tendo em conta, que esta série consiste num desfasamento da observação, a distribuição do erro deveria ser simétrica, a não verificação desta ocorrência poderá dever-se a variabilidade e/ou a dimensão da amostra. Com base na análise do valor da curtose verifica-se que esta assume uma forma leptocúrtica (Equação 14).

Relativamente à quantificação do erro com base na Tabela 11 verifica-se que em média o desvio padrão se tornou mais homogéneo, não havendo uma discrepância tão pronunciada entre as previsões de base MM5, WRF, WRF-STS e ALADIN. Relativamente à PERS o mesmo não se verifica já que este apresentou um desvio padrão destacadamente mais elevado. Tendo em conta o valor do desvio padrão e da variância e com recurso a relação descrita pela Equação 22 verifica-se para o horizonte temporal 06-12hr, a seguinte ordem de RMSE (por ordem crescente) MM5, WRF, ALADIN, WRF-STS e PERS. No entanto é necessário ter em conta que uma elevada componente do erro das previsões de base ALADIN e WRF-STS é devido a terem um viés ou média elevada.

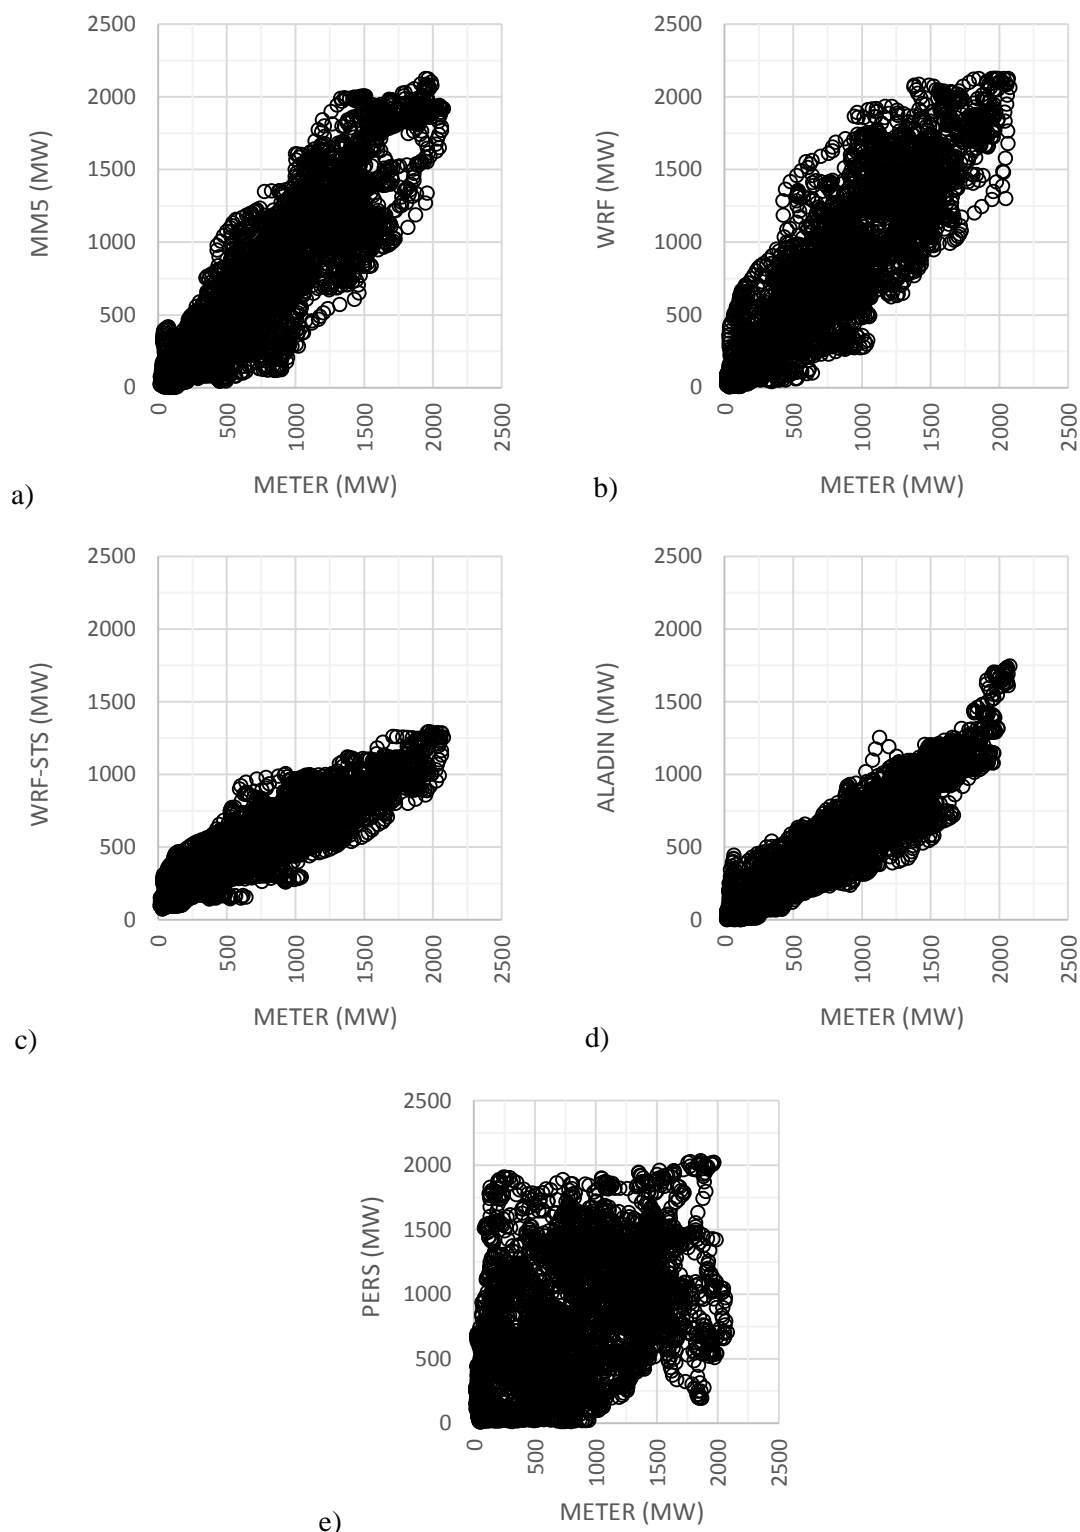


Fig. 25 – Gráficos das séries de previsões do horizonte temporal 06-12hr vs observação (METER). Na figura estão representadas as séries de dados: a) MM5, b) WRF, c) WRF-ST5, d) ALADIN e e) PERS.

Relativamente ao coeficiente de correlação ($\rho_{x,y}$) exposto na Tabela 11 verifica-se de uma forma geral uma elevada correlação entre estas. Tendo as previsões de base MM5, WRF, WRF-ST5 e ALADIN valores $\rho_{x,y}$ semelhantes entre si o que é justificável pela não dependência $\rho_{x,y}$ face ao valor

da média. Os dados de PERS apresentam um valor significativamente inferior a estas, tendo o pior valor $\rho_{x,y}$.

A Fig. 25 a), b), c), d) e e) vai ao encontro dos valores de viés e de $\rho_{x,y}$ presentes na Tabela 11. Verificando-se um erro reduzido para as previsões de base MM5 e WRF; relevante (para o período considerado) para as previsões de base WRF-STS e ALADIN; já os dados de PERS verifica-se um erro elevado. Por outro lado, verifica-se através das Fig. 25 c) e d) que os erros das previsões de base são heterocedásticos ou seja o viés e a variância dos erros, condicionais aos valores das observações não são constantes, i.e. variam com elas (e.g. o viés condicional da previsão ALADIN é sempre negativo mas menor em módulo para valores elevados das observações). Se este fosse um erro sistemático poderia ser efectuado um tratamento de dados por sectores, no entanto não se sabe qual a evolução deste pelo que um tratamento deste tipo poderia não ser vantajoso. Por outro lado verifica-se nas Fig. 25 a), b), c), d) e e) a ocorrência de *outliers* (que representam picos de erro). Por outro lado, com recurso a comparação entre as Fig. 23 e a Fig. 25 verifica-se que de uma forma geral ocorreu uma maior dispersão entre o valor previsto e o observado. Isto foi mais relevante para os dados de PERS, no entanto também se verifica para as previsões de base MM5 e WRF embora em menor expressão, já para as previsões de base WRF-STS e ALADIN parece não se verificar alteração.

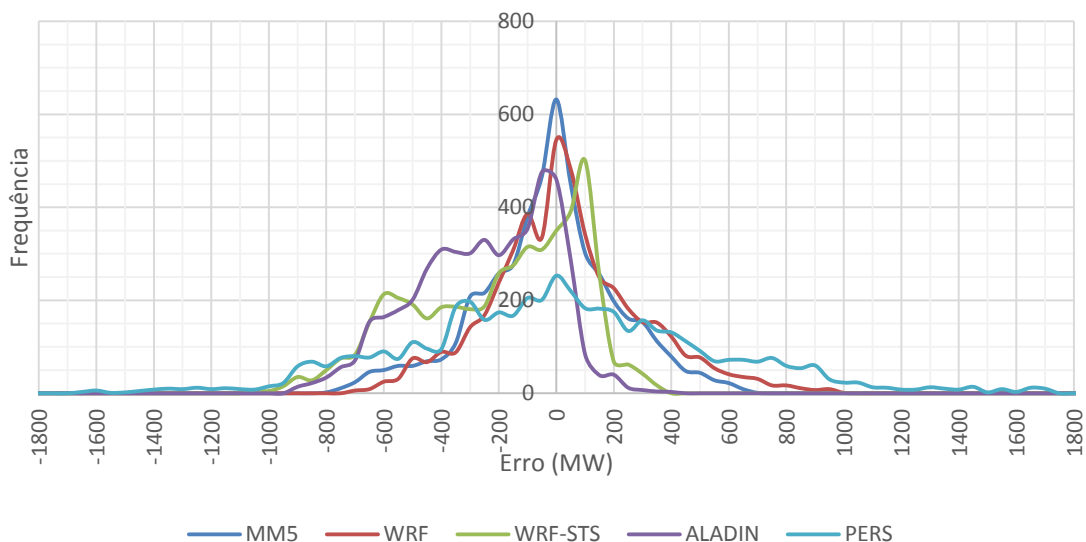


Fig. 26 – Histograma dos erros das séries das previsões de base para o horizonte temporal 06-12hr.

O histograma exposto na Fig. 26 é referente a um gráfico alisado. Este foi calculado com uma resolução de 50 MW. Tal como nas estatísticas e histograma referentes ao horizonte 00-06hr, a moda do histograma parece depender da resolução do histograma.

A Fig. 26 é consistente com a Tabela 11 e das Fig. 25 a), b), c), d) e e). Tendo em conta as estatísticas listadas na Tabela 11 e as Fig. 25 a), b), c), d) e e) e Fig. 26 verifica-se que para o período analisado as previsões de base MM5 e WRF são semelhantes entre si. Verifica-se que as previsões de base WRF-STS e ALADIN têm uma qualidade inferior às previsões de base MM5 e WRF conforme se verifica pelos maiores valores quer do valor absoluto da média do erro, quer da variância do erro. Verifica-se que os dados de PERS são os que menor qualidade têm para prever a potência eólica devido à elevado variância do erro, e portanto em última análise devido à fraca persistência (memória) dos dados. Todavia dado que o erro da persistência (PERS) é a diferença entre o METER e o SCADA desfasados no tempo seguindo uma semelhante distribuição de probabilidade, é de esperar um valor teórico nulo da assimetria, bem como da média, mediana e moda, o que é corroborado pelos baixos valores obtidos na prática. Além disto verifica-se a ocorrência valores frequentes de erros de previsão negativos até -600 MW.

Analisando as Fig. 24 e Fig. 26 observa-se que a distribuição do erro entre as várias previsões de base convergiu. Facto que vai ao encontro da análise da Tabela 11.

Tabela 12- Descrição estatística das séries dos erros das previsões para o horizonte temporal 12-18hr.

	MM5	WRF	WRF-STS	ALADIN	PERS
\bar{E}	-71,38	19,57	-230,03	-284,75	-21,96
\tilde{E}	-58,25	-5,45	-159,63	-236,90	-7,60
Moda	-11,00	34,00	-186,00	-56,00	290,20
As_1	-60,38	-14,43	-44,03	-228,75	-312,16
σ	247,91	294,62	294,91	277,21	504,12
Var	6,1E+04	8,7E+04	8,7E+04	7,7E+04	2,5E+05
K	0,23	0,22	0,32	0,30	0,26
As_2	-0,16	0,25	-0,72	-0,52	-0,09
Min	-849,60	-760,10	-1055,50	-1592,80	-1335,00
Max	784,70	1062,40	391,70	336,55	1557,10
Q_1	-215,20	-159,00	-465,99	-471,46	-354,65
Q_3	66,93	182,05	17,14	-61,94	301,83
P_{90}	228,50	429,46	95,52	20,10	583,79
P_{10}	-380,62	-344,92	-657,97	-667,61	-694,07
$\rho_{x,y}$	0,89	0,86	0,89	0,87	0,51

Analisando a Tabela 12 verifica-se uma degradação da qualidade das séries de previsão relativamente às da Tabela 11 o que era expectável já que os dados são referentes ao horizonte temporal seguinte (12-18hr).

Observando a Tabela 12 verifica-se que a média dos erros das previsões de base manteve a mesma dinâmica observada na Tabela 11. Sendo que os erros dos dados de PERS e a previsão de base WRF tiveram uma média entre -22 e 20 MW, a previsão de base MM5 obteve um maior valor de média (em módulo), relativamente ao WRF e PERS, com 71 MW e que por outro lado as médias dos erros associados às previsões de base WRF-STS e ALADIN tiveram valores entre -230 e -284 MW.

Com base nos indicadores de forma da distribuição dos erros verificaram-se algumas alterações. Sendo que a forma da distribuição dos erros da previsão de base:

- MM5 é assimétrica negativa (Equação 16) moderada (Equação 17) assumindo uma forma leptocúrtica (Equação 14);
- WRF é assimétrica negativa (Equação 16) moderada (Equação 17) assumindo uma forma leptocúrtica (Equação 14);
- WRF-STS é assimétrica negativa (Equação 16) moderada (Equação 17) assumindo a forma platicúrtica (Equação 14);
- ALADIN é assimétrica negativa (Equação 16) moderada (Equação 17) assumindo uma forma platicúrtica (Equação 14);
- PERS é assimétrica negativa (fortuitamente) tendo em conta o critério calculado com recurso à Equação 16 no entanto com recurso ao valor da assimetria (Equação 17) verifica-se que é simétrica. Tendo em conta, que esta série consiste num desfasamento da observação, a distribuição do erro deveria ser simétrica, a não verificação desta ocorrência poderá dever-se a variabilidade e/ou a dimensão da amostra. Com base na análise do valor da curtose verifica-se que esta assume uma forma leptocúrtica (Equação 14).

Relativamente à quantificação do erro com base na Tabela 12 verifica-se que o desvio padrão seguiu a tendência anteriormente verificada tornando-se mais homogéneo comparativamente à Tabela 10 e Tabela 11, não havendo uma discrepância tão pronunciada entre as previsões de base MM5, WRF, WRF-STS e ALADIN. Relativamente à PERS o mesmo não se verifica já que este apresentou um desvio padrão destacadamente mais elevado. Relativamente ao RMSE e com recurso à relação demonstrada pela Equação 22 em média verifica-se por ordem crescente de RMSE as previsões de base MM5, WRF, WRF-STS, ALADIN e PERS.

Relativamente à correlação, valor $\rho_{x,y}$, entre as observações e previsões de base verifica-se um valor sucessivamente mais reduzido, quando comparando os valores do $\rho_{x,y}$ das Tabela 10, Tabela 11 e Tabela 12. Tendo as previsões de base MM5, WRF, WRF-STS e ALADIN correlações semelhantes entre si o que é justificável pela não dependência do $\rho_{x,y}$ face ao bias (média dos erros). Os dados de PERS apresentam um valor significativamente inferior a estas, tendo o pior valor de $\rho_{x,y}$. O valor de $\rho_{x,y}$ para a PERS indica que esta não consegue prever o valor de potência eólica.

A Fig. 27 a), b), c), d) e e) vai ao encontro dos valores de viés e de $\rho_{x,y}$ presentes na Tabela 12. Verificando-se um erro reduzido para as previsões de base MM5 e WRF; relevante que aparenta ser sistemático (para o período considerado) para as previsões de base WRF-STS e ALADIN; já os dados de PERS verifica-se um erro elevado. Por outro lado, verifica-se através das Fig. 27 c) e d) que os erros das previsões de base são heterocedásticos ou seja o viés e a variância dos erros, condicionais aos valores das observações não são constantes, i.e. variam com elas (e.g. o viés condicional da previsão ALADIN é sempre negativo mas menor em módulo para valores elevados das observações). Se este fosse um erro sistemático poderia ser efectuado um tratamento de dados por sectores, no entanto não se sabe qual a evolução deste pelo que um tratamento deste tipo poderia não ser vantajoso. Por outro lado, verifica-se nas Fig. 27 a), b), c), d) e e) a ocorrência de *outliers* (que representam picos de erro). Os valores da Fig. 27 d) com previsões de 0 MW poderá dever-se à ausência de previsão. Por outro lado, com recurso à comparação entre as Fig. 23, Fig. 25 e Fig. 27 verifica-se que de uma forma geral ocorreu uma maior dispersão entre previsto e observado. Isto foi mais relevante para os dados de PERS, isto também se verifica para as previsões de base MM5 e WRF embora em menor expressão, já para as previsões de base WRF-STS e ALADIN parece não se verificar alteração.

O histograma exposto na Fig. 28 é referente a um gráfico alisado. Este foi calculado com uma resolução de 50 MW. Dada a baixa resolução aqui usada, tal pode justificar uma certa discrepância entre a moda do histograma (Fig. 28) e a moda dada na tabela 12, calculada como o valor mais frequente com a resolução de 0.1 MW ou ainda menos nalguns casos.

A Fig. 28 é consistente com a Tabela 12 e as Fig. 27 e 24. Tendo em conta as estatísticas listadas na Tabela 12 e as Fig. 27 a), b), c), d) e e) e Fig. 28, verifica-se que para o período analisado as previsões de base MM5 e WRF são semelhantes entre si. Verifica-se que as previsões de base WRF-STS e ALADIN têm uma qualidade inferior às previsões de base MM5 e WRF conforme se verifica pelos maiores valores quer do valor absoluto da média do erro, quer da variância do erro. Verifica-se também que os dados de PERS são os que menor qualidade têm para prever a potência eólica devido à elevada variância do erro, e portanto em última análise devido à fraca persistência (memória) dos dados. Todavia dado que o erro da persistência (PERS) é a diferença entre o METER e o SCADA desfasados no tempo seguindo uma semelhante distribuição de probabilidade, é de esperar um valor teórico nulo da assimetria, bem como da média, mediana e moda, o que é corroborado pelos baixos valores obtidos na prática. Além disto verifica-se a ocorrência de uma anomalia na distribuição do erro da série WRF-STS.

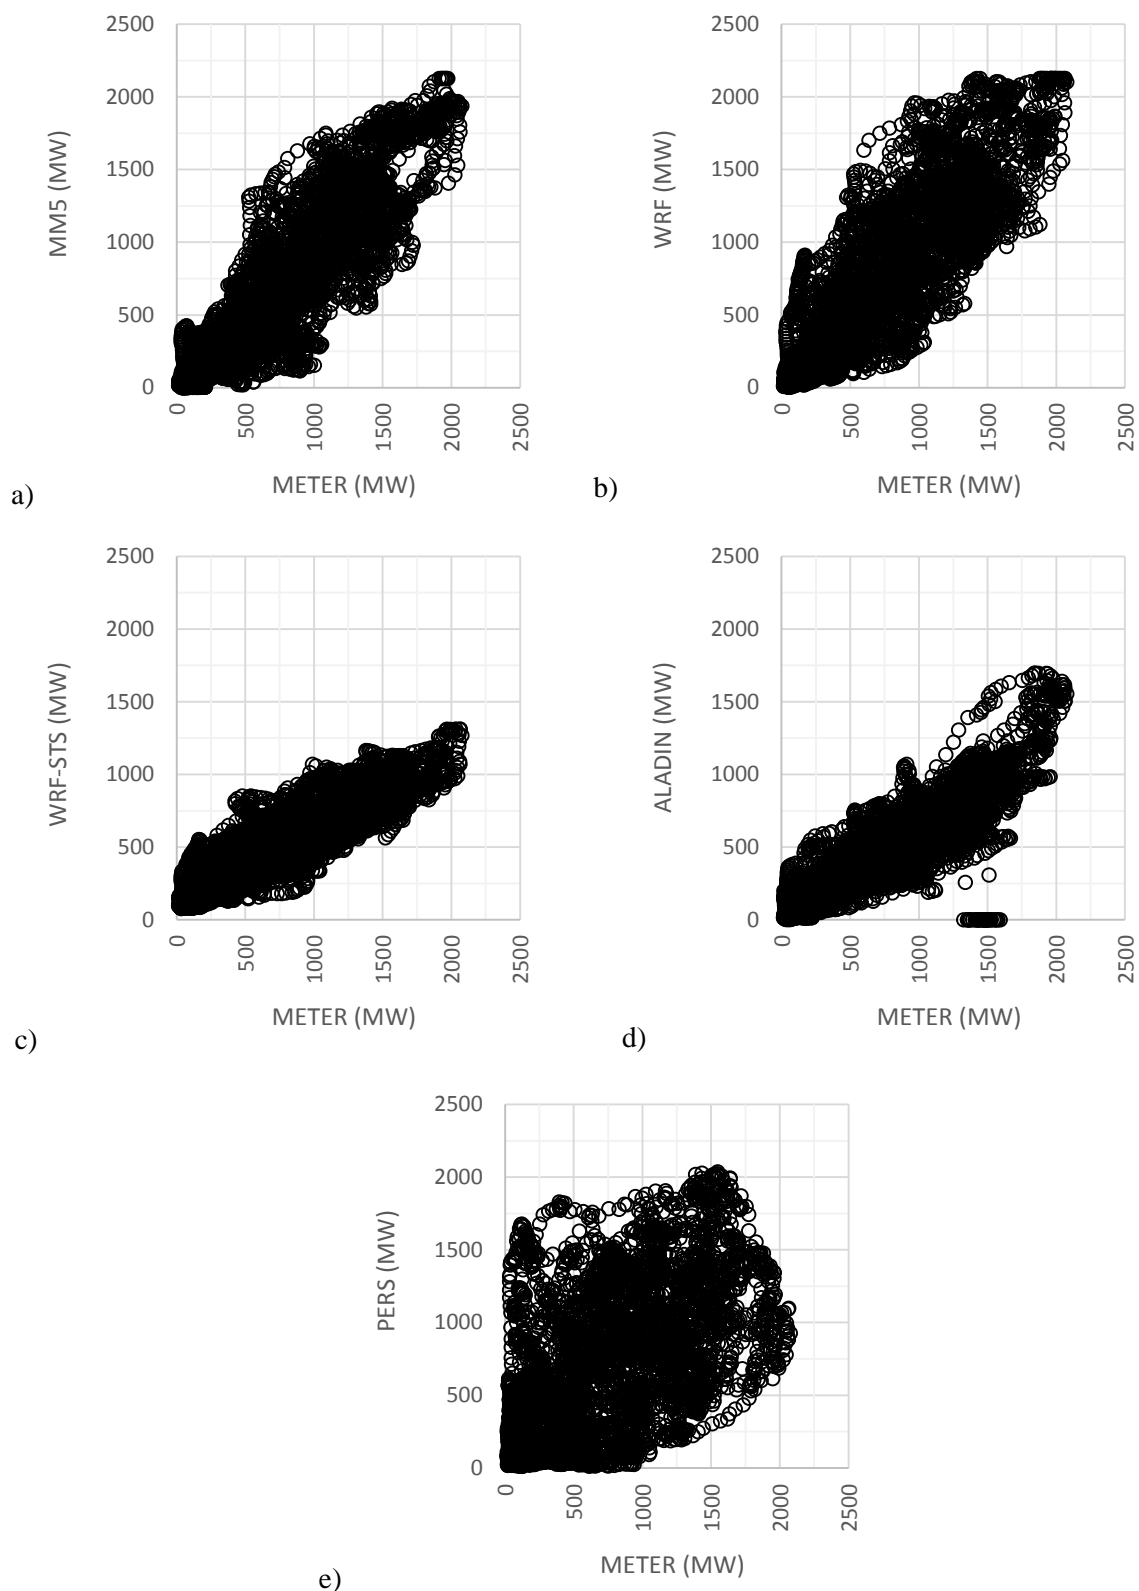


Fig. 27 – Gráficos das séries de previsões do horizonte temporal 12-18hr vs observação (METER). Na figura estão representadas as séries de dados: a) MM5, b) WRF, c) WRF-ST5, d) ALADIN e e) PERS.

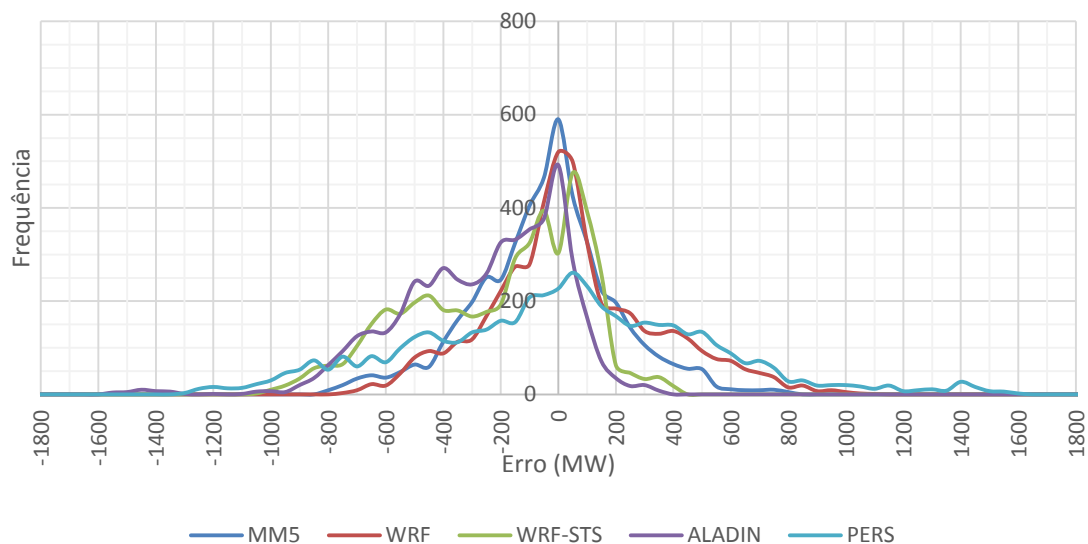


Fig. 28 – Histograma dos erros das séries das previsões de base para o horizonte temporal 12-18hr.

Tabela 13- Descrição estatística das séries dos erros das previsões para o horizonte temporal 18-24hr.

	MM5	WRF	WRF-STs	PERS
\bar{E}	-59,28	22,73	-223,00	-27,13
\tilde{E}	-50,50	1,85	-153,73	-21,10
Moda	-163,10	-154,60	2,00	71,00
As ₁	103,82	177,33	-225,00	-98,13
σ	255,29	302,74	301,09	461,81
Var	6,5E+04	9,2E+04	9,1E+04	2,1E+05
K	0,23	0,22	0,32	0,26
As ₂	-0,10	0,21	-0,69	-0,04
Min	-812,20	-885,80	-1105,20	-1619,90
Max	923,40	1109,70	544,20	1607,10
Q ₁	-218,80	-163,15	-464,44	-316,80
Q ₃	71,95	191,43	23,93	255,53
P ₉₀	257,02	441,17	107,32	530,70
P ₁₀	-376,98	-352,34	-656,66	-588,89
$\rho_{x,y}$	0,89	0,85	0,88	0,59

Analisando a Tabela 13 verifica-se uma degradação da qualidade das séries de previsão relativamente às da Tabela 12 o que era expectável dado que a variância do erro cresce sempre quanto maior o horizonte, independentemente do modelo. No entanto, verifica-se que para determinados modelos, o valor absoluto da média, da assimetria e ainda a curtose podem decrescer para certos horizontes de previsão.

Observando a Tabela 13 verifica-se que, em módulo, a média dos erros das previsões de base relativamente ao módulo da média da Tabela 12 diminuiu para a previsão de base MM5 e WRF-STs, aumentando para a previsão de base WRF e para os dados de PERS.

Com base nos indicadores de forma (assimetria e curtose) da distribuição dos erros verificaram-se algumas alterações. Sendo que a forma da distribuição dos erros da previsão de base:

- MM5 é assimétrica positiva com recurso à Equação 16. No entanto com recurso à Equação 17 verifica-se que esta é simétrica pelo que nada se pode aferir neste sentido. Apesar disto esta deve estar entre os dois casos considerados. Com base no valor da curtose (Equação 14) verifica-se que esta tem uma forma leptocúrtica;

- WRF é assimétrica positiva (Equação 16) moderada (Equação 17) assumindo a forma leptocúrtica (Equação 14);
- WRF-STS é assimétrica negativa (Equação 16) moderada (Equação 17) assumindo a forma platicúrtica (Equação 14);
- PERS é teoricamente simétrica, no entanto o valor amostral da assimetria é puramente fortuito. A qual é assimétrica negativa tendo em conta o critério calculado com recurso à Equação 16 no entanto com recurso ao valor da assimetria (Equação 17) verifica-se que é simétrica. Tendo em conta, que esta série consiste num desfasamento da observação, a distribuição do erro deveria ser simétrica, a não verificação desta ocorrência poderá dever-se a variabilidade e/ou a dimensão da amostra. Com base na análise do valor da curtose verifica-se que esta assume uma forma mesocúrtica (Equação 14).

Relativamente à quantificação do erro com base na Tabela 13 verifica-se que o desvio padrão manteve a mesma homogeneidade observada na Tabela 12, não havendo uma discrepância pronunciada entre as previsões de base MM5, WRF e WRF-STS. Relativamente à PERS o mesmo não se verifica já que este apresentou um desvio padrão bastante elevado. Relativamente ao RMSE e com recurso à relação demonstrada pela Equação 22 em média verifica-se por ordem crescente de RMSE as previsões de base MM5, WRF, WRF-STS e PERS.

Relativamente à correlação entre as observações e previsões de base verifica-se uma diminuição do valor $\rho_{x,y}$ (coeficiente de correlação de Pearson). Tendo as previsões de base MM5, WRF, WRF-STS correlações semelhantes entre si o que é justificável pela não dependência de $\rho_{x,y}$ e a média da série dos erros. Os dados de PERS apresentam um valor significativamente inferior a estas, tendo o pior valor de $\rho_{x,y}$. O valor da $\rho_{x,y}$ para a PERS indica que esta não consegue prever o valor de potência eólica.

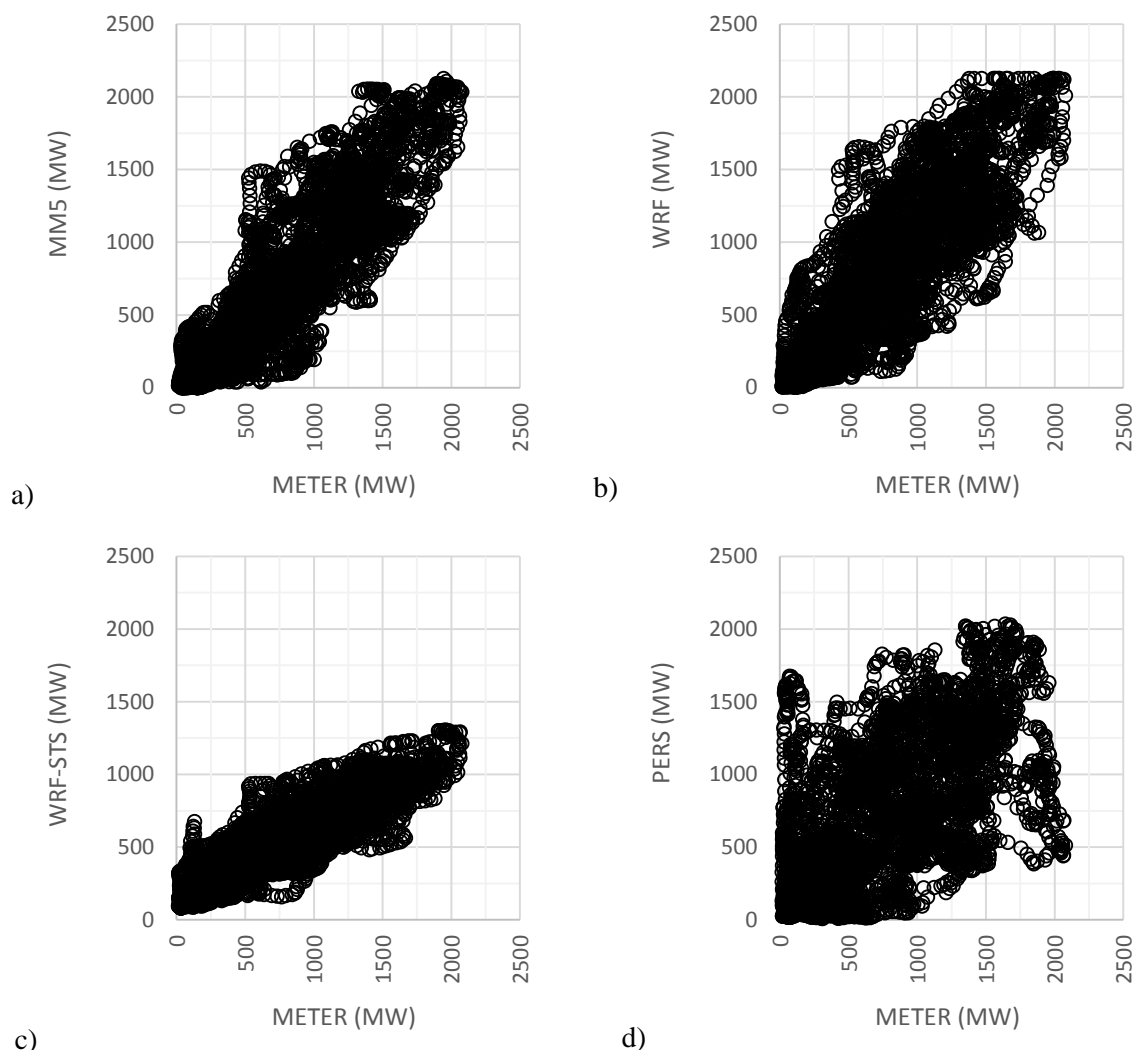


Fig. 29 – Gráficos das séries de previsões do horizonte temporal 18-24hr vs observação (METER). Na figura estão representadas as séries de dados: a) MM5, b) WRF, c) WRF-STs e d) PERS.

As Fig. 29 a), b), c) e d) vão ao encontro dos valores de média e de $\rho_{x,y}$ presentes na Tabela 13. Verificando-se um erro reduzido para as previsões de base MM5 e WRF; relevante que aparenta ser sistemático (para o período considerado) para as previsões de base WRF-STs; já os dados de PERS verifica-se um erro elevado, no entanto, não se consegue verificar um erro sistemático. Por outro lado, verifica-se através da Fig. 29 c) que os erros da previsão de base são heterocedásticos ou seja o viés e a variância dos erros, condicionais aos valores das observações não são constantes, i.e. variam com elas (e.g. o viés condicional da previsão WRF-STs é sempre negativo mas menor em módulo para valores elevados das observações). Se este fosse um erro sistemático poderia ser efectuado um tratamento de dados por sectores, no entanto não se sabe qual a evolução deste pelo que um tratamento deste tipo poderia não ser vantajoso.

Por outro lado verifica-se nas Fig. 29 a), b), c) e d) a ocorrência de *outliers* (que representam picos de erro). Por outro lado, com recurso a comparação entre as Fig. 23, Fig. 25, Fig. 27 e Fig. 29 verifica-se que de uma forma geral o aumento da dispersão, observada entre valores previstos e observados, foi gradual ao longo dos horizontes temporais. O mesmo não se verificou para a Fig. 29 d) que comparativamente com a Fig. 28 e) se observa uma menor dispersão.

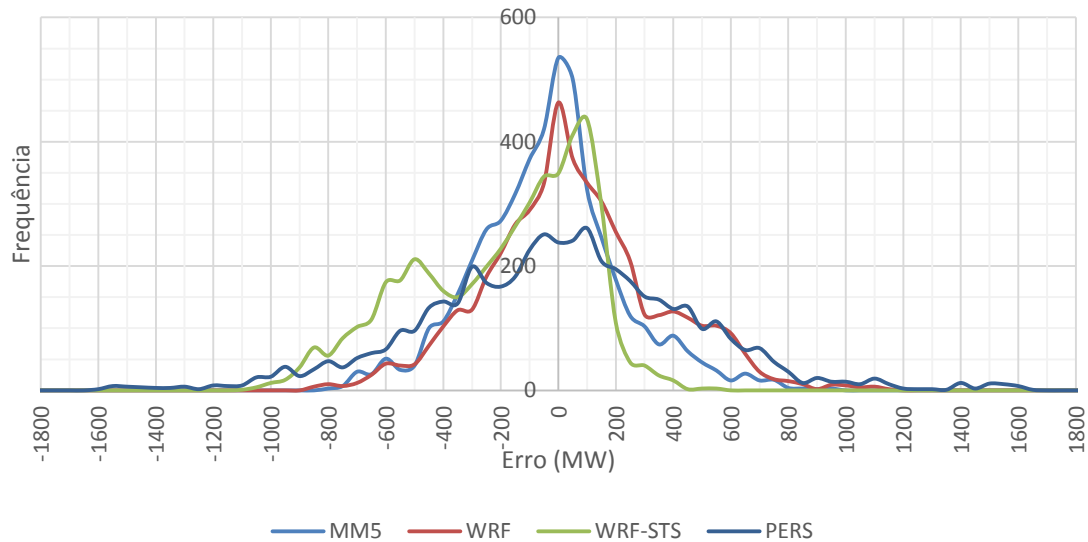


Fig. 30 – Histograma dos erros das séries das previsões de base para o horizonte temporal 18-24hr.

O histograma exposto na Fig. 30 é referente a um gráfico alisado. Este foi calculado com uma resolução de 50 MW. Dada a baixa resolução aqui usada, tal pode justificar uma certa discrepância entre a moda do histograma (Fig. 30) e a moda dada na Tabela 13, calculada com a resolução de 0.1 MW ou ainda menos nalguns casos.

A Fig. 30 é consistente com a Tabela 13 e das Fig. 29 a), b), c) e d). Tendo em conta as estatísticas listadas na Tabela 13, as Fig. 29 a), b), c) e d) e Fig. 30 verifica-se que para o período analisado as previsões de base MM5 e WRF são semelhantes entre si, no entanto, verifica-se alguma diferença entre os histogramas relativos às duas previsões de base (MM5 e WRF). Por outro lado, verifica-se que as previsões de base WRF-STs têm uma qualidade inferior às previsões de base MM5 e WRF conforme se verifica pelos maiores valores quer do valor absoluto da média do erro, quer da variância do erro. Verifica-se também que os dados de PERS são os que menor qualidade têm para prever a potência eólica devido à elevada variância do erro, e portanto em última análise devido à fraca persistência (memória) dos dados. Todavia dado que o erro da persistência (PERS) é a diferença entre o METER e o SCADA desfasados no tempo seguindo uma semelhante distribuição de probabilidade, é de esperar um valor teórico nulo da assimetria, bem como da média, mediana e moda, o que é corroborado pelos baixos valores obtidos na prática. Além disto verifica-se à semelhança da Fig. 29 a ocorrência de uma anomalia na distribuição do erro da série WRF-STs.

Comparando as Fig. 24, Fig. 26, Fig. 28 e Fig. 30 observa-se um gradual aumento do ruído pelo que isto poderá dever-se à dimensão reduzida da série de erros aliado ou por se ter recorrido a um elevado número de intervalos para efectuar o histograma dos erros ou a uma maior dispersão do erro observado pelas Fig. 23, Fig. 25, Fig. 27 e Fig. 29 e sustentado pelas Tabelas 10-13.

4.2.5.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA




Fig. 31 – Gráfico síntese do valor de MAE das séries dos erros das previsões para o horizonte temporal 00-24hr.

Analisando a Fig. 31 verifica-se que esta vai ao encontro das medidas de descrição estatística expostas em 4.2.5. A Fig. 31 apresenta valores, em média, para cada *time-step* (de 15 minutos) para o horizonte temporal 00-24hr. Pelo facto, de esta apresentar valores mais detalhados, consegue-se verificar a ocorrência de anomalias específicas para um determinado *time-step* ou seja conseguem-se identificar padrões de erro específicos para as várias previsões de base para um determinado *time-step*.

Analisando a Fig. 31 verifica-se que o erro não evolui como seria expectável, ou seja, um crescimento monótono do erro, não necessariamente de forma uniforme. O expectável para as previsões de base (MM5, WRF, WRF-STs e ALADIN), seria um crescimento acentuado do erro para as primeiras 6 horas que posteriormente iria estabilizar e por outro um pequeno decréscimo do erro para os *time-steps* 25, 49 e 73 devido a inicializações dos modelos, em princípio mais precisas devido à maior quantidade de dados assimilados usados para a construção dos estados iniciais. Isto porque as previsões iniciais são aquelas que são mais recentes e que têm em conta dados mais actuais sendo que isto vai diminuindo com o aumento dos valores de *time-step* e porque a cada 6 horas a inicialização dos modelos é enriquecida na fase de assimilação de dados com mais observações.

Em parte verifica-se o esperado, no entanto, registam-se algumas anomalias, provavelmente devidas à logística do tratamento das previsões, como:

- O decréscimo do erro da previsão de base MM5 para os *time-steps* (18-24) relativamente aos anteriores *time-steps* (21-24). Verifica-se ainda um ligeiro aumento do erro para o *time-step* 25 relativamente ao *time-step* seguinte, a partir do qual se verifica uma evolução referida como expectável. Verifica-se também à semelhança da previsão de base WRF um aumento do erro associado ao *time-step* 25 seguido de uma diminuição, a partir se verifica um comportamento ligeiramente oscilatório do erro mas que em média parece ser estável;
- O pico do erro da previsão de base WRF para o primeiro *time-step* seguido de uma diminuição e posterior aumento do erro. No mesmo horizonte temporal verifica-se ainda um decréscimo acentuado do erro nos *time-steps* (21-24). Verifica-se ainda um ligeiro aumento do erro para o *time-step* 25 relativamente ao *time-step* seguinte, a partir do qual se verifica uma evolução referida como expectável;

- O pico elevado da previsão de base WRF-STS nos primeiros *time-steps* 1-5, isto é 00h15min-1h15min, este depois decresce rapidamente até atingir um mínimo (*time-step* 9) para depois crescer rapidamente;
- A estabilidade do elevado erro da previsão de base ALADIN nos primeiros *time-steps* (1-13) seguindo-se uma diminuição pronunciada do erro (14-17) e posterior aumento do erro de forma acentuada. Por outro lado, verificou-se um ligeiro aumento do erro para os *time-steps* 25 e 49.

Relativamente à série de PERS verifica-se um comportamento expectável, já que para os *time-steps* 1-24 se verifica o menor erro, corresponde a um desfasamento mais recente. Relativamente aos *time-steps* 25-48 verifica-se um erro mais elevado, o que também seria expectável já que é um desfasamento em contra ciclo (ciclo nocturno versus ciclo diurno) e relativamente ao *time-step* 73-96 verifica-se outra diminuição relativamente aos *time-step* anteriormente considerados pois é relativo a um ciclo próximo daquele a que se está a prever. Por outro lado, como os dados de PERS são relativos a um desfasamento de 6hr, 12hr, 18hr e 24hr ainda se trata em geral de um regime sinóptico semelhante àquele que se quer prever, já que a instalação de um regime sinóptico típico demora mais tempo do que esse. No entanto, ao longo desse período poderão ocorrer mudanças bruscas do regime de ventos (ex. passagem de um sistema frontal seguida de uma situação anticiclónica), tornando totalmente inútil uma previsão por persistência como se verifica em geral em situações não estacionárias.

Relativamente aos erros elevados associados aos primeiros *time-steps* verificado para às previsões WRF e WRF-STS pode dever-se a uma categorização incompleta dos dados relacionados com o período de *spin-up time* dos modelos. Relativamente aos decréscimos acentuados pode dever-se a uma extração de dados menos correcta ou a outras transformações anteriores à extração de dados.




Fig. 32 – Gráfico síntese do valor de RMSE das séries dos erros das previsões para o horizonte temporal 00-24hr.

Relativamente à Fig. 32 verifica-se a mesma evolução do erro observado através da Fig. 31 pelo que a análise efectuada para a Fig. 31 pode ser utilizada para a Fig. 32. Isto era expectável tendo em conta a semelhança entre o cálculo destes dois indicadores (anteriormente representadas pelas Equações 19 e 20. No entanto, esta é considerada a medida de avaliação de potência mais fidedigna, pois, conforme a relação demonstrada pela Equação 22, tem em conta o viés, a variabilidade e a dispersão do erro (Equação 23).




Fig. 33 – Gráfico síntese do valor de BIAS das séries dos erros das previsões para o horizonte temporal 00-24hr.

Como se pode observar pela Fig. 33 (que apresenta o valor dos vieses ou BIAS para os 96 *time-steps*), as séries de dados apresentam valores bastante distintos de viés (cálculo representado pela Equação 24). Esta vai ao encontro da análise efectuada anteriormente com recurso às Tabelas 10, 11, 12 e 13 em que se verificava um valor de viés negativo elevado para as previsões de base WRF-STS e ALADIN, um valor mais reduzido em valor absoluto para as previsões de base MM5 e WRF e um valor de viés próximo de zero para os dados de PERS. Verifica-se ainda que o valor do viés não foi constante para os vários *time-steps*, sendo igualmente dependente da amostra usada. Tal é patente na tese quando se mostrar as várias estatísticas de erro avaliadas nos diferentes períodos de teste e de validação. No entanto verifica-se que este foi mais estável para *time-steps* 25-73 (ALADIN), 25-96 (WRF-STS), 1-96 (WRF) entre os horizontes temporais 1-24, 25-48, 49-72 e 73-96 (MM5). Verifica-se ainda que o viés das previsões de base WRF-STS e ALADIN para o horizonte temporal 00-06hr foi variável.




Fig. 34 – Gráfico síntese do valor de SDE das séries dos erros das previsões para o horizonte temporal 00-24hr.

Analisando a Fig. 34 verifica-se que o erro SDE é menor que o valor de RMSE e que em média ocorreu uma aproximação do erro entre as várias previsões de base utilizadas, sendo que relativamente aos dados de PERS não se verificou alteração. Tendo em conta as Equações 19 e 21 verifica-se que a diferença entre RMSE e SDE é que SDE tem em conta a média do erro (viés) da amostra. Isto em conjunto com as Tabelas 10 a 13 e Fig. 23 a 30 pode indicar que as previsões de base têm um erro sistemático, sendo sucessivamente efectuadas previsões sobrestimadas ou subestimadas. Por outro lado, de uma forma geral o valor de SDE é elevado pelo que poderá indicar uma variabilidade e/ou uma dispersão do erro (Equação 23).

4.3 ALGORITMO DESENVOLVIDO (MOSF+EMOS)

Tendo em conta o subcapítulo 4.2.5. e os objectivos presentes no Capítulo 1 desenvolveu-se o algoritmo exposto no presente capítulo. O algoritmo desenvolvido é composto por 3 fases distintas. Contemplando um módulo MOS (1ª fase) e um módulo EMOS (2ª e 3ª Fase). Estas têm funções distintas mas complementares com vista a:

- 1ª Fase – melhorar as séries de previsões relativamente às séries de previsões de base com recurso a métodos estáticos e dinâmicos;
- 2ª Fase - efectuar um espectro de previsões de potência recorrendo a um conjunto de algoritmos com base em métodos lineares e não lineares com diferentes períodos de calibração;
- 3ª Fase - efectuar uma escolha para cada *time-step* dos modelos de previsão de potência óptimos com recurso á avaliação do desempenho destes.

Além disto, recorre-se aos modelos e respectivos desempenhos para estudar avaliar quais as melhorias possíveis futuras a implementar e tendo em conta a bibliografia consultada.

Assim, foi desenvolvido um modelo estatístico de melhoramento de previsão de potência eólica com vista a alcançar os objectivos propostos. O qual pode ser descrito da seguinte forma: as previsões de base (MM5, WRF, WRF-STS e ALADIN) e dados de PERS são melhoradas com recurso ao tratamento de dados (MOSF); é calculado o espectro de previsões com recurso aos modelos que compõem os módulos ALFA1 (calibração de coeficientes regressivos com base numa janela móvel/fixa com a dimensão de um ano) e ALFA2 (calibração de coeficientes regressivos com base numa janela móvel com a dimensão fixa (até 10 dias) ou dimensão variável até 10 dias antecedentes ao instante de lançamento da previsão), sem utilizar o modelo KF. Além disso, quando os modelos recorriam a uma janela contendo dados relativos a um passado recente, para avaliar o melhor modelo, esta tinha uma dimensão variável (até 10 dias); é efectuada a agregação do espectro de previsões com recurso ao modelo MIX (uma variação do método *B.I. Tracking*), este tem como *input* as previsões efectuadas com recurso aos modelos que compõem os módulos ALFA1, ALFA2 (sem utilizar o modelo KF) e previsões melhoradas após MOSF, ver anexo C; são calculadas as previsões com recurso ao modelo KF (variando as taxas de aprendizagem), o qual tem como *input* de dados, as previsões resultantes da primeira passagem pelo modelo MIX (uma variação do método *B.I. Tracking*); é efectuada a escolha da melhor taxa de aprendizagem do modelo KF com recurso ao modelo MIX (uma variação do método *B.I. Tracking*). Assim, pode-se esquematizar o modelo desenvolvido (MOSF+EMOS) de forma simplificada na Fig. 35.

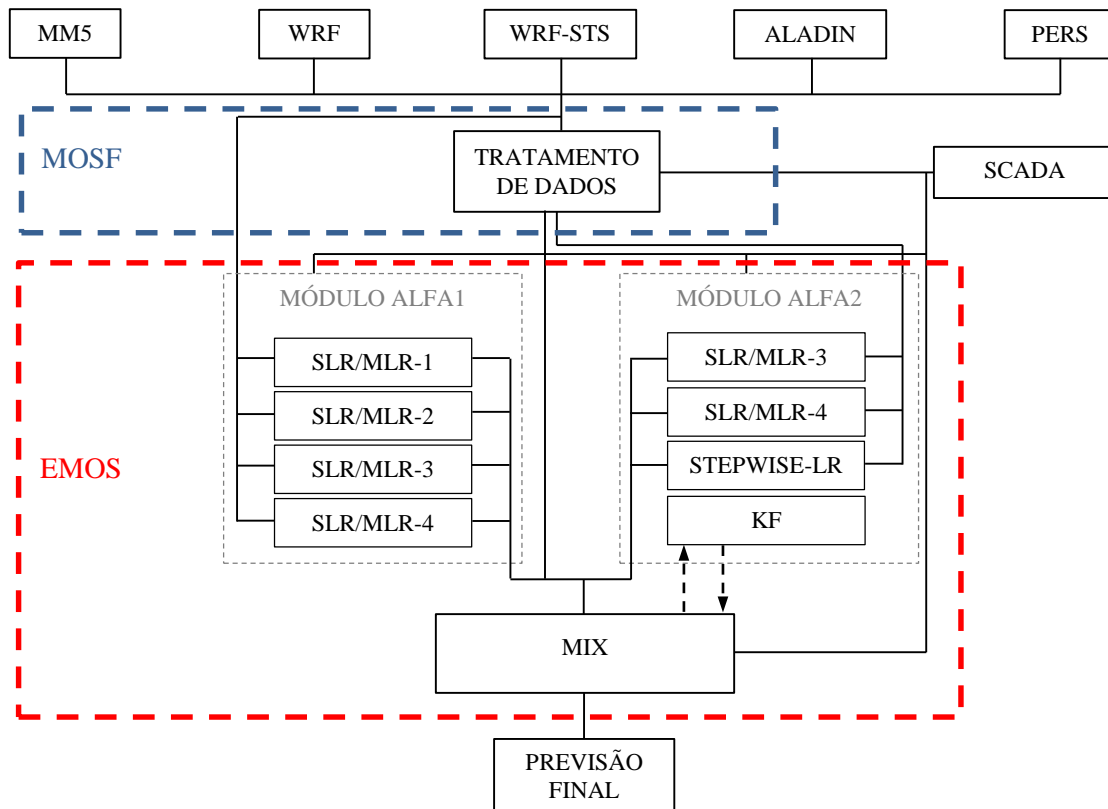


Fig. 35 – Arquitectura do sistema de melhoramento de previsão.

4.3.1 TRATAMENTO DE DADOS-MOS (1ªFASE)

Considerando a caracterização dos dados efectuada em 4.2.5. e tendo em vista os objectivos estabelecidos para a presente dissertação enunciados no capítulo 1, optou-se por um conjunto de tratamentos de dados que fossem dinâmicos ao longo do tempo e que se conseguissem adaptar a vários cenários. Assim, optou-se por uma metodologia que tivesse em conta: 1) a correlação entre observações e previsões; 2) a eliminação de picos e depressões, extremos positivos e/ou negativos do erro (*outliers*); 3) previsão de viés, já que as previsões poderiam ter associado um viés variável; 4) regressão quantílica de modo a se conseguir modificar a magnitude das previsões, já que por vezes se verificou uma diferença de magnitude entre as previsões e as observações. Dado que esses tratamentos pareciam contemplar as várias necessidades de tratamento das previsões de base, já abordados em 4.2.5., por forma a melhorar a sua qualidade, seleccionaram-se as metodologias apresentadas na secção 4.3.1.

O tratamento dos dados foi desenvolvido com vista a ser um modelo de melhoramento dinâmico das previsões, isto é não estático no tempo. O tratamento dos dados recorre a diferentes métodos com as variações descritas no anexo A, sendo os seguintes:

- Coeficiente de correlação de Pearson (MOS1);
- Média móvel (MOS2);
- Previsão adaptativa do viés (MOS3);
- Regressão quantílica adaptativa (MOS4);
- Combinação dos tratamentos de dados MOS1 a MOS3 (MOSF).

4.3.1.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON (MOS1)

Este tratamento permite correlacionar os dados de uma melhor forma com as observações. A aplicação deste tratamento deve-se ao facto de uma elevada componente do erro ser a dispersão, conforme verificado em 4.2.5. Este tratamento tem como objectivo reduzir os valores de dispersão dos erros de previsão.

Este tratamento foi aplicado com recurso ao cálculo do valor do coeficiente de correlação de Pearson (descrito pela Equação 12) e multiplicando esse coeficiente pelas séries de previsão correspondentes para o horizonte temporal. Este tratamento pode ser visto como uma regressão linear sub-ótima usando como preditor uma das previsões de base.

Na presente dissertação, este método de tratamento de dados tem a nomenclatura “ $x_h - MOS1$ ”. Este processo de tratamento pode ser descrito pela Equação 30. Sendo que:

- $x_h - MOS1$ é a série de previsão x para um determinado horizonte temporal h após tratamento com recurso ao coeficiente de correlação de Pearson;
- $\rho_{x,y,h}$ é o coeficiente de correlação de Pearson da série de previsão x para um determinado horizonte temporal h , y é a observação METER;
- x_h é a série de previsão x para um determinado horizonte temporal h .

$$x_h - MOS1 = \rho_{x,y,h} \times x_h \quad (30)$$

4.3.1.2 MÉDIA MÓVEL (MOS2)

Este tratamento permite suavizar as séries de previsões de base e portanto, diminuir os picos de erro, sendo dada como uma média móvel das previsões centradas no *time-step* a prever. Este cálculo é descrito pela Equação 31, sendo que:

- $x_{h,i} - MOS2$ é referente à série de previsão x , para o horizonte temporal h , para o *time-step* i após tratamento MOS2;
- $x_{h,i,k}$ é a série de previsão x para um determinado horizonte temporal h , para um determinado *time-step* $(i+k)$.

$$x_{h,i} - MOS2 = \frac{1}{2m + 1} \sum_{k=-m}^m x_{h,i+k} \quad (31)$$

Para se efectuar este tratamento é necessário escolher a dimensão $(2m+1)$ da janela móvel sobre a qual se irá fazer a média. Caso a janela seja demasiado grande, o alisamento é demasiado e perde-se qualidade. Caso a janela seja demasiado pequena não efectuará uma atenuação dos extremos. Desse modo, torna-se necessário chegar a um compromisso e optar por uma janela de dimensão adequada. Nos resultados mostraremos que obtemos bons resultados com $m=3$ ou seja uma janela centrada com dimensão de 1h45m.

4.3.1.3 PREVISÃO ADAPTATIVA DO VIÉS (MOS3)

Este tratamento tem como objectivo prever o viés para um determinado período futuro com base num período passado. Este é efectuado com recurso a uma janela móvel de dimensão fixa em função do horizonte temporal sobre a qual o viés, associado aos dados de previsão, foi avaliado para um passado recente e assumindo-se que este se mantém num futuro próximo.

Assim, admitindo que x é uma determinada previsão de base, h o horizonte temporal, seja i o *time-step*, p um determinado intervalo passado. Ou seja, existe um viés que minimiza o RMSE para um

período passado, de modo que esse viés será o viés inerente ao período seguinte, na nova previsão. Assim este método pode-se descrever com recurso à Equação 32. Sendo que:

- $x_{h,i}$ – MOS3 é referente à série de previsão x , para o horizonte temporal h , para o *time-step* i após tratamento MOS3;
- $x_{h,i+k}$ é a série de previsão x para um determinado horizonte temporal h , para um determinado *time-step* $(i+k)$;
- y_{i+k} é a observação (SCADA) para o *time-step* $(i+k)$;
- $BIAS_{x,h,p}$ é o viés calculado em média associado à série de previsão x , para o horizonte temporal h , tendo em conta uma janela móvel p de dimensão fixa referente a um passado recente.

$$x_{h,i} - \text{MOS3} = x_{h,i} - BIAS_{x,h,p} \quad (32)$$

Sendo que o cálculo de $BIAS_{x,h,p}$ pode ser representado pela equação 33:

$$BIAS_{x,h,p} = \frac{\sum_{k=-t}^{-t'} (x_{h,i+k} - y_{i+k})}{t' - t + 1} \quad (33)$$

Assim, assumiu-se que o viés é constante ao longo do horizonte temporal o que embora não seja verdade, conforme se pode observar pelo capítulo 4.2.5. (Fig. 34) consiste numa aproximação á realidade observada.

4.3.1.4 REGRESSÃO QUANTÍLICA ADAPTATIVA (MOS4)

A regressão quantílica é um método de análise empírica [103] e [104], sendo que este método foi indicado por vários autores [44] e [55], como sendo um método viável para efectuar/tratar previsões com base em previsões e observações. Além disso, este método tem como vantagens o facto de:

- Ser mais robusta a *outliers* do que um simples método dos mínimos quadrados (anexo E);
- Poder ser utilizada tanto para distribuições gaussianas como para distribuições não gaussianas;
- Apresentar melhores resultados quando se calcula coeficientes do que o método dos mínimos quadrados;
- Conseguir apresentar mais informação já que é possível representar um determinado quantil da amostra;
- Poder ser aplicada em amostras que variam de forma logarítmica, exponencial ou outra.

A regressão quantílica adaptativa permite aproximar a distribuição de densidade dos dados de previsão à distribuição de densidade das observações, isto consegue-se inflacionando ou deflacionando a série de dados das previsões por forma a aproximar a distribuição das previsões se aproximar da distribuição das observações. Para isso, são utilizados como *input* de previsão as previsões de base (MM5, WRF, WRF-STS e ALADIN) e dados de PERS, como observações os dados de SCADA. Assim este método permitiria reduzir os valores de dispersão do erro, assim como uma redução do viés os quais são as componentes do indicador RMSE, tido como o mais importante dentro dos vários utilizados para avaliar a potência eólica prevista.

A regressão quantílica pode descrever-se da seguinte forma. Seja $F_p(x)$ a função de distribuição acumulada das previsões e $F_o(x')$ a função de distribuição acumulada das observações. Assim dada a série de previsão x , procura-se a previsão conjugada de modo a satisfazer a igualdade $F_p(x) = F_o(x')$, sendo que $x' = F(x)$, ou seja $\text{Prob}(p < x) = F_p(x) = \text{Prob}(o < x') = F_o(x')$.




Fig. 36 – Representação das funções cumulativas das observações e das previsões.

Seja $F(x)$ a função de regressão quantílica de um determinado quantil q , para um horizonte temporal h da série amostral N . A regressão quantílica adaptativa (MOS4), tal como a previsão adaptativa do viés (MOS3), é executada ao longo do tempo, isto é adaptativamente usando dados de previsão num conjunto de dias antecedentes. A regressão quantílica adaptativa (MOS4) minimiza o erro quadrático (RMSE) ou seja $F(x)$ é tal que:

$$F_{x,h,p} = \min \left\{ \frac{\sum_{k=-t'}^{-t} [G(x_{h,i+k}) - y_{i+k}]^2}{t' - t + 1} \right\} \quad (34)$$

Sendo que:

- $G(x_{h,i+k})$ é a transformada da série de previsão x , para o horizonte temporal h , para o *time-step* $i+k$;
- t' e t são valores passados, tal que, $t' > t$;
- y_{i+k} são as observações de SCADA para o *time-step* $i+k$.

No caso do algoritmo desenvolvido baseado neste método foram testadas algumas variações por forma a avaliar a melhor variação, por exemplo, testando várias dimensões da janela de regressão quantílica adaptativa ou fazendo a optimização para cada *time-step*, sendo que, as variações estudadas assim como a variação utilizada estão expostos em detalhe no anexo A.

Para se utilizar este método foi obtida, numa primeira fase, a distribuição dos dados para que estes possam ser avaliados consoante o seu quantil; numa segunda fase foram extrapoladas novas previsões com base na função densidade de probabilidade, quer das previsões, quer das observações.

Assim este método pode ser traduzido pela Equação 35. Sendo que:

- $x_{h,i}$ – MOS4- é referente à série de previsão x , para o horizonte temporal h , para o *time-step* i após tratamento MOS4;
- $x_{h,i}$ é a série de previsão x para um determinado horizonte temporal h , para um determinado *time-step* i ;
- $BIAS_q$ é o viés calculado para um determinado quantil da função de distribuição calculado com recurso a uma janela móvel de dimensão fixa contendo dados referentes a um passado recente da série de previsão x , para o horizonte temporal h ;
- $F_{x,h,p}$ encontra-se definida na Equação 34.

$$x_{h,i} - \text{MOS4} = F_{x,h,p} = x_{h,i} - BIAS_q \quad (35)$$

4.3.1.5 COMBINAÇÃO DE TRATAMENTOS (MOSF)

A combinação de tratamentos de dados teve como objectivo retirar o máximo partido dos vários métodos utilizados. A qual foi efectuada recorrendo de forma cumulativa e sequencial aos métodos MOS1, MOS2 e MOS3, descritos no presente capítulo (4.3.1), conforme descrito no esquema representado na Fig. 37. Sendo que:

- x_h é a série de previsão x , para o horizonte temporal h ;
- $x_h - \text{MOSF}$ é a série de previsão x após tratamento MOSF, para o horizonte temporal h ;
- MOS1 é o tratamento com recurso ao coeficiente de correlação de Pearson;
- MOS2 é o tratamento com recurso média móvel;
- MOS3 é o tratamento com recurso à previsão adaptativa do viés.




Fig. 37 – Representação cumulativa do processo de tratamento MOSF.

4.3.2 PREVISÃO POTÊNCIA (2ªFASE)

Esta é a primeira etapa do módulo EMOS. Nesta etapa efectua-se um espectro de previsões com vista a posterior selecção na 3ªfase. Esta etapa (2ªFase) recorre aos módulos ALFA1 e ALFA2 (excepto KF) tendo como *input*, respectivamente, as séries de previsão não tratadas (MM5, WRF e PERS) e as séries de previsão tratadas com recurso a MOSF (MM5-MOSF, WRF-MOSF, WRF-STS-MOSF, ALADIN-MOSF e PERS-MOSF).

Os módulos ALFA (ALFA1 e ALFA2), diferenciam-se entre si pelo período de calibração dos coeficientes regressivos, sendo que ALFA1 recorre a 12 meses e ALFA2 recorre até 10 dias para esse efeito. Além disso, quando os módulos que compõem os módulos ALFA1 e ALFA2 recorrem a uma janela, de dados relativos a um passado recente, para avaliar o desempenho dos modelos, e assim escolher o melhor modelo, tem uma dimensão variável até 10 dias. O cálculo da melhoria é descrito pela Equação 29. Assim o módulo:

- ALFA1 recorre a uma janela de dados históricos com a dimensão de 1 ano, ou seja, estes modelos recorrem a uma série de dados referentes a um ano para efectuar a calibração dos

coeficientes regressivos. Além disso, alguns dos módulos que compõem ALFA1 podem recorrer a uma janela de dimensão variável, até 10 dias, para avaliar os modelos;

- ALFA2 recorre a uma janela móvel de dados históricos com um intervalo de 0-10 dias variável, ou seja, estes modelos recorrem a uma série de dados até 10 dias antecedentes para calibrar os coeficientes regressivos. Além disso, os módulos que compõem o módulo ALFA2 quando recorrem a uma janela, para avaliar os vários modelos, e assim escolher o melhor modelo do módulo, esta é de dimensão variável até 10 dias (ex: SLR/MLR-4) ou fixa (ex: STEPWISE-LR).

A previsão de potência foi efectuada para um horizonte temporal máximo de 24 horas, sendo efectuadas a cada 6 horas. Desta forma, a todo o momento existem 4 previsões distintas sobrepostas, com horizontes temporais de 00-6hr, 06-12hr, 12-18hr e 18-24hr.

4.3.2.1 REGRESSÃO LINEAR SIMPLES (SLR), MULTI-LINEAR (MLR) E REGRESSÃO POLINOMIAL

Segundo [105] a análise com recurso ao método regressivo linear assume as seguintes condições linearidade, independência dos erros, homocedasticidade, distribuição normal dos erros e colinearidade. Sendo que estas deverão ser respeitadas para efectuar uma análise com sucesso. Sendo que, se verificam estas condições através da análise efectuada em 4.2.5.

O método regressivo é utilizado para efectuar previsões de velocidade do vento, conforme abordado no capítulo 3 e referido pelos autor [66], segundo [51], [87], [93] e [106] este método também pode ser utilizado como modelo MOS acoplado a um modelo de previsão numérica do tempo. O cálculo dos coeficientes pode ser feito com recurso ao método dos mínimos quadrados (anexo E); contudo este método apresenta como desvantagem o facto de utilizar valores das médias das observações e das previsões. Desse modo, quanto maior a variabilidade destas medidas maior erro associado às previsões. Assim, há que ter isto em conta para efectuar previsões com recurso ao método dos mínimos quadrados.

Os modelos efectuados foram SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 que são módulos que contêm as várias combinações possíveis de predictores, contendo regressões lineares simples e regressões lineares múltiplas. Estas, dependendo se recorrem ou não a uma janela por forma a avaliar o desempenho dos modelos podem constituir métodos não lineares ou lineares respectivamente. O desempenho dos modelos (quando necessário) foi avaliado com recurso a uma janela móvel de dimensão variável (até 10 dias) contendo dados históricos relativos a um passado recente, por forma a determinar qual o modelo com melhor desempenho em média nesse período tendo por base o valor de RMSE e, assim, supor para um futuro próximo qual o melhor modelo. De um outro modo, pode tratar-se apenas a combinação dos modelos sem serem avaliados nessa fase e serem avaliados posteriormente com utilização do modelo MIX. Assim, pode-se descrever os modelos da seguinte forma:

- SLR/MLR-1: este módulo calcula os coeficientes regressivos com recurso a uma janela fixa e não recorre a uma janela móvel, de valores passados, para avaliar o desempenho dos modelos, e assim extrapolar o melhor modelo futuro. Apenas utilizado no módulo ALFA1;
- SLR/MLR-2: este módulo calcula os coeficientes regressivos com recurso a uma janela fixa e recorre a uma janela móvel de dimensão variável (até 10 dias), de valores passados, para avaliar o desempenho dos modelos, e assim extrapolar o melhor modelo futuro. Apenas utilizado no módulo ALFA1;
- SLR/MLR-3: este módulo calcula os coeficientes regressivos com recurso a uma janela móvel de dimensão fixa (ALFA1) ou variável (ALFA2) e não recorre a uma janela móvel de valores passados para avaliar o desempenho dos modelos, e assim extrapolar o melhor modelo futuro;
- SLR/MLR-4: este módulo calcula os coeficientes regressivos com recurso a uma janela móvel de dimensão fixa (ALFA1) ou variável (ALFA2) e recorre a uma janela móvel de dimensão variável (até 10 dias) de valores passados para avaliar o desempenho dos modelos, e assim extrapolar o melhor modelo futuro;

Tabela 14- Síntese das variações dos métodos SLR/MLR.

MÓDULOS	CALIBRAÇÃO DOS COEFICIENTES REGRESSIVOS			CRITÉRIO DE AVALIAÇÃO (Equação 29)		
	Janela de calibração	Dimensão da janela		Janela móvel	Dimensão da janela	
		ALFA1	ALFA2		ALFA1	ALFA2
SLR/MLR-1	Fixa	Fixa	Não estudado	Não	-	-
SLR/MLR-2	Fixa	Fixa	Não estudado	Sim	Variável	Não estudada
SLR/MLR-3	Móvel	Fixa	Variável	Não	-	-
SLR/MLR-4	Móvel	Fixa	Variável	Sim	Variável	Variável

REGRESSÃO LINEAR SIMPLES (SLR)

A SLR usa-se para prever o comportamento de uma variável aleatória através de uma variável e outras constantes. Assim, e sabendo-se as constantes b , α e considerando uma dada uma variável aleatória, pode-se determinar a outra variável aleatória em função destas, tal como se encontra demonstrado na seguinte equação. No entanto, esta apresenta um erro associado, pois nem todos os casos apresentam uma correlação óptima. Torna-se assim necessário acrescentar o erro associado para cada medição relativamente à recta de optimização (E_i).

$$y_i = \alpha x_i + b + E_i \quad i = 1, \dots, n \quad (36)$$

Na figura seguinte encontra-se exemplificada a SLR com todos os parâmetros associados descritos na equação anterior.




Fig. 38 – Exemplo de uma RLS com o pormenor de cálculo para um ponto individual.

REGRESSÃO LINEAR MULTIPLA (MLR)

A regressão multilinear é a generalização da SLR para um número arbitrário de predictores. Difere da regressão linear simples pelo número de predictores. Assim, podemos definir a regressão multilinear a partir da seguinte equação:

$$y_i = b + e_i + \sum_{j=1}^n \alpha_j x_{ji} \quad i = 1, \dots, n \quad (37)$$

REGRESSÃO POLINOMIAL (RP)

As RP usam-se para prever o comportamento de um polinómio de regressão através de uma variável e outras constantes.

As RP podem ter vários graus sendo que quanto mais graus de liberdade do modelo mais o polinómio se adequará aos dados existentes, no entanto quantos mais graus de liberdade mais específico se torna para um determinado caso. No entanto, de modo a evitar sobre-ajustamento, (overfitting) o número de coeficientes (grau do polinómio) deverá ser muito inferior ao tamanho n da amostra. As RP podem ser de segundo grau (Quadráticas-RLQ), terceiro grau (cúbicas-RLC) entre outros.

A RP de 2º grau para um determinado ponto pode ser expressa pela seguinte equação,

$$y_i = \alpha x_i^2 + \beta x_i + B + E_i \quad i = 1, \dots, n \quad (38)$$

A RP de 3º grau para um determinado ponto pode ser expressa pela seguinte equação,

$$y_i = \alpha x_i^3 + \beta x_i^2 + \delta x_i + B + E_i \quad i = 1, \dots, n \quad (39)$$

Na figura seguinte encontra-se exemplificada a RP de 2º grau e a RP de 3º grau com todos os parâmetros associados descritos na equação anterior.




Fig. 39 – Exemplo de uma RP de 2º grau e RP de 3º grau com o pormenor de cálculo para um ponto.

4.3.2.2 FILTRO DE KALMAN (KF)

Os KF são amplamente utilizados, desempenhando um papel importante na econometria, tecnologia de radar, aplicações espaciais, militares, telecomunicações, limpeza de ruído de rádios FM, entre outras aplicações.

Os KF são baseados em sistemas dinâmicos lineares e amplamente utilizados na previsão de vento [66] e [56] e de potência eólica [10]. Estes são sistemas recursivos que consistem num conjunto de equações complexas que permitem antever uma determinada posição para um determinado intervalo de tempo. Assim, os KF produzem estimativas a partir de grandezas reais medidas, conseguindo prever intervalos de estimação e erros associados. Tais resultados conseguem-se realizando cálculos sequenciais e utilizando esses novos valores para cálculos seguintes, estabelecendo uma relação entre o estado anterior, o estado seguinte e calculando o erro associado.

Assim, assumindo que:

- x_i é um vector de estado para um determinado instante i (ou seja, no nosso caso um determinado *time-step*);
- y_i é um vector das observações para um determinado instante i (ou seja, no nosso caso um determinado *time-step*);
- w_{i-1} é o erro do propagador para um determinado instante $i-1$;

- v_i é o ruído das observações para um determinado instante $i-1$;
- u_i é um vector de variáveis de controle para um determinado instante i ;
- $A, B, H \in \mathbb{R}$;
- I e a matriz identidade;
- Q é a matriz covariância dos erros de previsão x ;
- R é a matriz covariância dos erros da observação y ;
- P_i é a matriz covariância do erro do vector de estado x para um determinado instante i ;
- K_i é o *Kalman Gain* para um determinado instante i ;
- A notação $+$ indica o futuro;
- A notação $-$ indica o passado;

$$\begin{aligned}x_i &= Ax_{i-1} + Bu_{i-1} + w_{i-1} \\y_i &= Hx_i + v_i\end{aligned}\tag{40}$$

Os processos de cálculo do KF podem ser subdivididos em 4 fases distintas:

1. Fase: Estimação - é nesta fase que calculam e introduzem os parâmetros necessários para inicializar o sistema;

$$\begin{aligned}P_{i-1}^+ \\x_{i-1}^+\end{aligned}$$

2. Fase: Predição - é nesta fase que se efectuam previsões do vector de estado e da matriz de covariância do erro;

Equação de estado previsto

$$x_i^- = Ax_{i-1}^+ + Bu_{i-1}\tag{41}$$

Covariância do erro previsto

$$P_i^- = AP_{i-1}^+A^T + Q\tag{42}$$

3. Fase: Correção - é nesta fase que se efectuam as correcções às previsões efectuadas na 2ª Fase; Cálculo da matriz *Kalman Gain*

$$K_i = P_i^-H^T(HP_i^-H^T + R)^{-1}\tag{43}$$

Cálculo do novo valor de estado (x_i^+) com recurso valor observado (x_i^-)

$$x_i^+ = x_i^- + K_i(y_i - Hx_i^-)\tag{44}$$

Cálculo da nova covariância do erro

$$P_i^+ = (I - K_iH)P_i^-\tag{45}$$

4. Fase: Actualização - é nesta fase que se actualizam os parâmetros necessários para efectuar previsões.

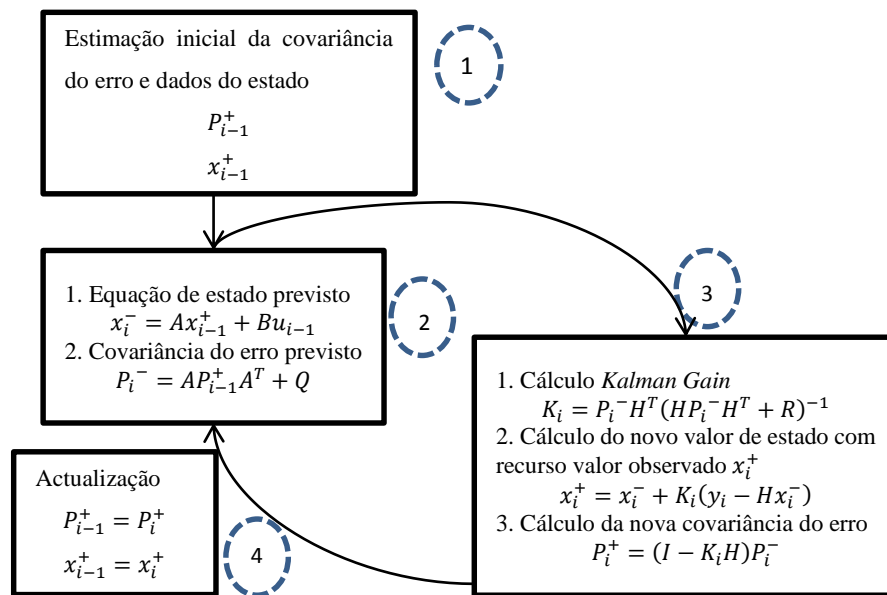


Fig. 40 – Esquema do fluxo de cálculo de um Filtro de Kalman.

Para desenvolver a metodologia adoptada foi estudada qual a melhor opção para efectuar previsões de potência com recurso a uma variação de Filtro de Kalman, tendo sido estudados Filtros de Kalman: com recurso a manipulação do peso do *Kalman Gain*; com cálculo do erro, recorrendo a uma janela móvel de dados passados; sem cálculo do erro e sem manipulação do *Kalman Gain*. A metodologia que tinha em conta os valores do erro, calculados com base numa janela móvel de dados passados, foi abandonada por não ter um bom desempenho, isto pode ser justificado com a variabilidade do recurso energético. A opção que não tinha em conta o erro dos modelos nem manipulava o *Kalman Gain* também foi abandonada por não alcançar um bom desempenho, isto pode ser justificado pela variabilidade do erro de previsão. Das metodologias estudadas a que alcançou um melhor desempenho foi aquela que não tinha em conta os valores do erro das previsões e em que se manipulava o *Kalman Gain*.

Na prática usámos uma versão sub-ótima do KF, adaptada à estrutura dos dados. Para implementar o KF considerámos:

- x_i a previsão após primeira utilização do modelo MIX, descrito em 4.3.3., (0-96 *time-steps*)
- y_i a observação SCADA (0 *time-step*) e a previsão após KF (1-96 *time-step*);
- $w_{i-1} = x_{i-1} - x_{i-2}$;
- $v_i = 0$;
- $A=1, B=0, H=1$ e $I=1$;
- $Q = \text{var}(ww^T)$;
- $R = \mu Q$, onde $\mu \in [-2, 2]$;
- $K_i = \gamma(P_i^-H^T(HP_i^-H^T + R)^{-1})$, onde $\gamma \in [-2, 2]$.

Assim, na prática com a utilização de γ e μ simulámos a variância das observações e a taxa de aprendizagem do KF. Por outro lado, com recurso à 2ª passagem pelo modelo MIX (após KF), uma variação do método *B.I. Tracking* descrito em 4.3.3., modelámos a taxa de aprendizagem do modelo de uma forma mais adequada.

Desta forma, o módulo desenvolvido (KF) consiste em vários modelos (combinação de $N_\gamma \times N_\mu$) em que se manipula a matriz *Kalman Gain*. Este procedimento tem como consequência a alteração da taxa de aprendizagem dos modelos que compõem o módulo KF. Com posterior agregação das variações

do modelo KF, efectuado com recurso ao modelo MIX consegue-se aproximar o valor previsto, por este modelo, do valor observado pelo sistema SCADA, conforme iremos demonstrar no capítulo 5.

4.1.1.1 REGRESSÃO LINEAR PASSO A PASSO (STEPWISE-LR)

A regressão linear passo a passo é um caso particular da regressão multi-linear. A qual, consiste na inclusão sucessiva de predictores (a partir do melhor destes) com redução estatisticamente significativa do erro.

A regressão linear passo a passo ou STEPWISE-LR é um método bastante utilizado para efectuar previsões de velocidade do vento [89], [107] e [108] e de potência [49] e [109].

Recorrendo a este método, o conjunto de predictores e o seu número é adaptado dinamicamente ao longo do período de calibração. No entanto, este método apresenta diversas desvantagens já que o número de modelos possíveis é maior do que o número de graus de liberdade e/ou predictores por forma a reduzir o tempo de cálculo. Assim, o algoritmo pode excluir modelos que têm melhores desempenhos por ter excluído um determinado grau de liberdade e/ou predictores. Outra fonte de erro poderá dever-se ao tipo de teste para determinar a inclusão ou rejeição tradicionais (testes f, p, chi-quadrado e outros [110]), dado que estes não têm em conta o viés e a variância da amostra. Tendo isto em conta utilizou-se o erro médio quadrático (RMSE) em modo de validação para cada um dos predictores consecutivos pois este considera o viés e a variância da série amostral (conforme demonstrado pela Equação 22).

No caso do algoritmo desenvolvido, o mesmo foi baseado na regressão linear tendo como critério de inclusão a percentagem de melhoria do RMSE antes e após inclusão do predictor. Para desenvolver o presente modelo, este foi primeiramente calibrado numa janela móvel de dimensão fixa (em função do horizonte temporal) contendo dados de um passado recente (até 10 dias). Numa segunda fase, foi calibrado o critério de inclusão.

O algoritmo desenvolvido pode ser resumido pelo seguinte esquema:

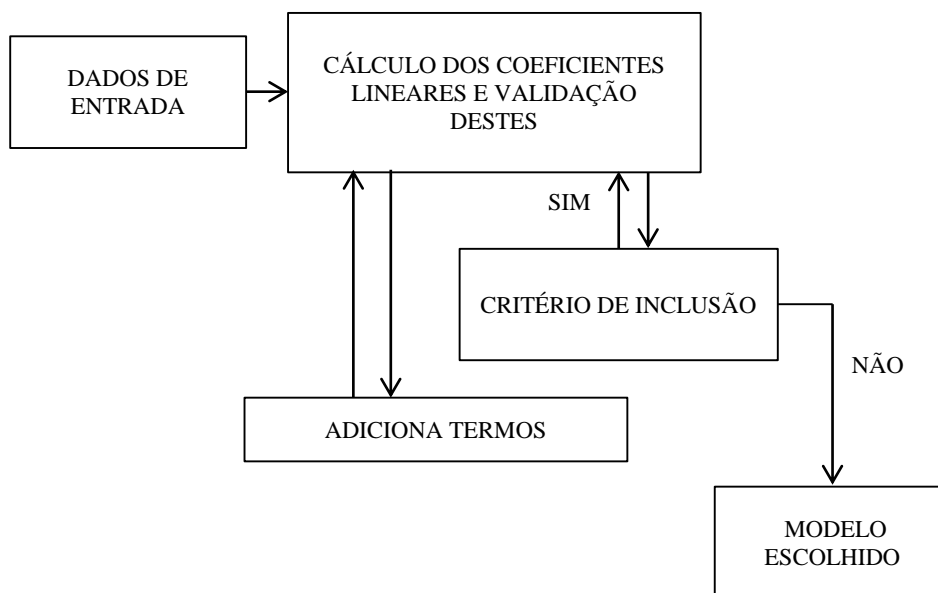


Fig. 41 – Esquema do fluxo de cálculo do modelo STEPWISE-LR.

4.3.3 MIX (3ªFASE)

O modelo MIX é uma variação do método *Best Intersection Point Tracking (B. I. Tracking)* foi sugerido para efectuar previsões em tempo real [47], este escolhe o melhor modelo com base na curva dos erros de potência. Na presente dissertação este foi utilizado em dois momentos distintos: primeiro para refinar as previsões utilizadas como *input* no modelo KF e segundo para escolher a melhor taxa de

aprendizagem para um determinado *time-step*. As previsões utilizadas como *input* no KF foram efectuadas com recurso aos modelos ALFA1 e ALFA2 (excepto KF). Posteriormente este modelo foi utilizado para escolher qual a melhor taxa de aprendizagem do modelo KF para um determinado *time-step*. Este modelo foi ainda utilizado para efectuar o estudo presente no anexo C, o qual tinha como objectivo avaliar a viabilidade da utilização das várias previsões de base disponíveis ao momento quer para originar uma nova série de previsão que pudesse ser combinada com as restantes previsões de base nos módulos ALFA1 e ALFA2 quer utilizada directamente para efectuar previsões de potência por si só.

Este modelo apresentou um ruído considerável pelo que os dados de *output* deste modelo foram tratados com recurso a uma média móvel, conforme descrito em 4.3.1.2.

O modelo MIX pode ser descrito da seguinte forma: seja $\{x_{h,i,z}\}$ um determinado conjunto de previsões, indexados por z e válidos para o horizonte temporal h e *time-step* i , escolhe-se o modelo que minimiza o erro médio quadrático (RMSE) numa janela móvel até $p=10$ dias antecedentes de previsões ao *time-step* a prever, isto é, o melhor modelo para o *time-step* i será aquele que obteve um menor valor de RMSE para os mesmos *time-steps* i do mesmo horizonte temporal num passado recente, até 10 dias. Assim, essa previsão depende de h , i e do desempenho (com base no RMSE) alcançado pelo modelo num passado recente p , sendo a previsão após modelo MIX representada por $x_{h,i,final}$.

5. RESULTADOS PRÁCTICOS

No presente capítulo optou-se pela nomenclatura MM5, WRF, WRF-STS e ALADIN, no entanto, estes são referentes às previsões em potência dos respectivos modelos após as várias transformações com vista a obterem-se previsões eólicas em valor de potência, conforme descrito no capítulo 3.4.10. Além disso optou-se também por PERS para referir o desfasamento da potência observada de 6, 12, 18 e 24 horas com recurso ao sistema SCADA, conforme descrito no capítulo 3.4.10.5.

No presente capítulo quando se refere a séries de previsões refere-se às previsões de base (MM5, WRF, WRF-STS e ALADIN) e aos dados de persistência (PERS).

Na presente tese optou-se por adoptar a denominação de módulo para conjuntos de modelos que podem ser baseados em métodos semelhantes ou, no caso de serem diferentes, que recorrem a um conjunto de dados semelhantes (Ex: módulo ALFA1, composto pelos módulos SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4, e módulo SLR/MLR-1 do módulo ALFA1, composto por um número de modelos igual ao número de combinações possíveis dos vários predictores entre si).

De modo a avaliar-se os modelos/módulos em causa foi efectuada uma comparação entre os resultados obtidos por estes e as observações registadas por contadores (METER).

Tal como já anteriormente foi referido, a presente tese sugere um algoritmo de tratamento estatístico a três fases (contemplando um módulo MOS e um EMOS emparelhados) para reduzir o erro associado às previsões de potência eólica para Portugal continental e para retirar o máximo partido destes. Tendo isto em conta, o presente capítulo encontra-se subdividido tendo em conta as várias fases consideradas. Assim:

- Os resultados relativos à primeira fase – etapa que tem como objectivo melhorar a qualidade das previsões de base de forma individual recorrendo aos métodos anteriormente descritos em 4.3.1- encontram-se no capítulo 5.1;
- Os resultados relativos à segunda fase – etapa que tem como objectivo efectuar várias previsões de potência recorrendo aos métodos anteriormente descritos em 4.3.2- encontram-se no capítulo 5.2. Sendo que, os resultados presentes neste capítulo são referentes ao modelo (STEPWISE) e à agregação, com recurso ao modelo MIX, dos vários modelos dentro de cada módulo, por exemplo, os resultados relativos ao módulo SLR/MLR-1 (ALFA1) são relativos à agregação dos vários modelos que o compõem com recurso ao modelo MIX;
- Os resultados relativos à terceira fase – etapa que tem como objectivo agregar as várias previsões efectuadas na segunda fase e primeira fase (após verificada a mais valia com recurso ao estudo

presente no anexo D) conforme descrito anteriormente em 4.3.3- encontram-se no capítulo 5.3. Neste o desempenho obtido pelo modelo desenvolvido (MOSF+EMOS) no período de validação é comparado no período de teste;

- Os resultados relativos aos desempenhos obtidos pelo modelo desenvolvido (MOSF+EMOS) e pelo modelo REN encontram-se no capítulo 5.4. Neste o desempenho dos dois modelos é comparado no período de validação assim como no período de teste.

Tal como foi referido no Capítulo 4.2.1, os dados foram subdivididos em três períodos distintos: calibração, validação e teste. Assim, de modo a respeitar essa subdivisão, por forma a garantir a independência dos períodos, os valores necessários para efectuar o tratamento de dados, isto é, coeficientes de calibração estatística e amplitude das janelas móveis, foram calculados no período de calibração. Posteriormente, os valores foram utilizados para tratar séries de previsão nos períodos de validação e de teste.

Recorrendo a esta metodologia pretende-se reduzir o erro de uma forma mais eficaz, dado que, tal como seria de esperar, os modelos de previsão de potência são muito dependentes dos dados a que recorrem comprometendo a viabilidade destes. Por outro lado, esta análise permite especificar os tratamentos necessários às séries previsão, independentemente dos horizontes temporais. É ainda de salientar que com a utilização desta metodologia pretende-se retirar o maior partido dos vários modelos desenvolvidos.

5.1 TRATAMENTO DE DADOS-MOS (1ªFASE)

Devido ao facto de não existirem previsões de base efectuadas com recurso aos modelos WRF-STS e ALADIN, no período de calibração ALFA1 (com dimensão amostral de 1 ano), não foi possível calcular o coeficiente de correlação de Pearson para estas previsões de base (neste período), já que este foi calculado no período de calibração ALFA1 (Fig. 19).

Os resultados obtidos com MOS1, MOS2, MOS3, MOS4 e MOSF (sequência MOS1 a MOS3) foram comparados com as previsões de base para o período de validação. MOSF foi ainda comparado com a respectiva previsão de base para o período de teste por forma a avaliar-se a robustez destes tratamentos num período independente.

O objectivo do tratamento de dados foi o de alcançar distribuições de previsões de potência, melhor comparáveis à distribuição da potência observada, isto é, mais simétricas, com menor RMSE, com forma leptocúrtica, com valores de $\rho_{x,y}$ (coeficiente de correlação de Pearson) mais elevados relativamente às séries de previsão iniciais (MM5, WRF, WRF-STS, ALADIN e PERS). Sendo que as medidas mais relevantes são a diminuição do valor da média (em valor absoluto) e a diminuição do desvio padrão (conforme demonstrado pela relação exposta pela Equação 22).

5.1.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON (MOS1)

Foi realizado um estudo no qual se efectuou o cálculo do coeficiente de correlação de Pearson para as várias variações presentes no anexo A. As várias metodologias tiveram erros variados, sendo que a metodologia que alcançou um melhor desempenho para o período de validação foi o cálculo com recurso a metodologia de janela fixa com a dimensão de um ano. Isto poderá dever-se ao facto da série de dados anual conter um maior número de dados e por isso, tem em conta um maior número de erros possíveis. Por outro lado a obtenção de melhores resultados no período de calibração com recurso a janela fixa poderá prender-se com o facto dos dados relativos ao mês de janeiro terem sido rejeitados, devido ao aumento do erro associado para este período o qual se pode ter devido à sazonalidade e/ou factores de calibração dos modelos.

Nesta variação o coeficiente de correlação de Pearson foi calculado uma vez por ano, sendo esse utilizado para o ano seguinte conforme descrito pela Equação 30. Os resultados obtidos para essa metodologia estão expostos no presente capítulo, utilizando a nomenclatura MOS1 para referir os dados após tratamento.

5.1.1.1 DESCRIÇÃO ESTATÍSTICA

Tabela 15- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 00-06hr.

	MM5-MOS1	MM5	WRF-MOS1	WRF	PERS-MOS1	PERS
\bar{E}	-37,90	6,63	-26,48	17,44	-171,61	-17,93
\tilde{E}	-21,04	14,65	-22,23	14,80	-146,17	-22,50
Moda	39,96	-20,00	-114,66	20,00	-257,56	-330,10
As ₁	-77,86	26,63	88,18	-2,56	85,95	312,17
σ	179,32	185,27	186,08	192,46	368,29	391,21
Var	3,2E+04	3,4E+04	3,5E+04	3,7E+04	1,4E+05	1,5E+05
K	0,22	0,20	0,20	0,20	0,26	0,25
As ₂	-0,28	-0,13	-0,07	0,04	-0,21	0,04
Min	-704,78	-642,60	-1037,35	-982,90	-1374,19	-1328,60
Max	589,20	700,80	619,26	721,20	1096,11	1436,20
Q ₁	-126,63	-82,78	-117,14	-79,05	-417,42	-268,50
Q ₃	57,90	98,63	58,69	101,25	44,83	203,90
P ₉₀	166,21	224,41	191,11	255,83	258,55	445,31
P ₁₀	-261,98	-222,64	-246,34	-195,99	-642,95	-493,13
$\rho_{x,y}$	0,94	0,94	0,93	0,93	0,71	0,71

Analisando a Tabela 15 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 16, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5 e WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve. Relativamente ao desvio padrão verifica-se que este diminuiu. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de base MM5 e WRF e aumentou para os dados de PERS.

Tabela 16- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 00-06hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS1	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	183,28	Diminui
MM5		Positiva	Simétrica	Leptocúrtica			185,39	
WRF-MOS1	Aumenta	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	187,95	Diminui
WRF		Negativa	Simétrica	Leptocúrtica			193,25	
PERS-MOS1	Aumenta	Positiva	Moderada	Mesocúrtica	Diminui	Mantém-se	406,31	Aumenta
PERS		Positiva	Simétrica	Leptocúrtica			391,62	

Tabela 17- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 06-12hr.

	MM5-MOS1	MM5	WRF-MOS1	WRF	PERS-MOS1	PERS
\bar{E}	-117,75	-56,53	-61,63	6,21	-318,12	-18,47
\tilde{E}	-85,59	-41,50	-48,98	-9,35	-284,27	-29,25
Moda	-20,19	-82,50	0,61	-8,50	#N/A	-18,00
As ₁	-97,56	25,97	-62,24	14,71	#N/A	-0,47
σ	232,55	243,81	253,39	267,63	461,18	525,94
Var	5,4E+04	5,9E+04	6,4E+04	7,2E+04	2,1E+05	2,8E+05
K	0,24	0,23	0,24	0,23	0,27	0,24
As ₂	-0,41	-0,18	-0,15	0,17	-0,22	0,06
Min	-873,37	-820,50	-860,28	-745,00	-1752,37	-1674,40
Max	490,81	662,10	823,09	960,70	956,68	1696,00
Q ₁	-254,82	-196,90	-220,94	-156,83	-630,16	-349,73
Q ₃	18,61	82,50	79,55	153,00	3,89	298,83
P ₉₀	157,44	256,00	255,09	362,33	231,52	675,21
P ₁₀	-419,31	-358,32	-382,06	-318,45	-936,43	-696,08
$\rho_{x,y}$	0,90	0,90	0,88	0,88	0,47	0,47

Analisando a Tabela 17 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 18, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5 e WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve. Relativamente ao desvio padrão verifica-se que este diminuiu para as previsões consideradas. Tendo em conta o valor médio do RMSE verifica-se que de forma marginal diminuiu para a previsão de base WRF, aumentou de forma marginal para a previsão de base MM5 e aumentou para os dados de PERS.

Tabela 18- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 06-12hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS1	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	260,66	Aumenta
MM5		Positiva	Moderada	Leptocúrtica			250,28	
WRF-MOS1	Aumenta	Negativa	Simétrica	Leptocúrtica	Diminui	Mantém-se	260,78	Diminui
WRF		Positiva	Moderada	Leptocúrtica			267,70	
PERS-MOS1	Aumenta	#N/A	Moderada	Platicúrtica	Diminui	Mantém-se	560,26	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			526,26	

Tabela 19- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 12-18hr.

	MM5-MOS1	MM5	WRF-MOS1	WRF	PERS-MOS1	PERS
\bar{E}	-136,73	-71,38	-58,12	19,57	-384,52	-21,96
\bar{E}	-106,80	-58,25	-53,60	-5,45	-314,03	-7,60
Moda	-156,00	-11,00	-97,20	34,00	#N/A	290,20
As ₁	19,27	-60,38	39,08	-14,43	#N/A	-312,16
σ	235,69	247,91	275,43	294,62	444,98	504,12
Var	5,6E+04	6,1E+04	7,6E+04	8,7E+04	2,0E+05	2,5E+05
K	0,24	0,23	0,21	0,22	0,28	0,26
As ₂	-0,38	-0,16	-0,05	0,25	-0,48	-0,09
Min	-898,82	-849,60	-871,89	-760,10	-1649,65	-1335,00
Max	660,28	784,70	892,76	1062,40	734,75	1557,10
Q ₁	-277,55	-215,20	-220,43	-159,00	-700,34	-354,65
Q ₃	1,89	66,93	87,16	182,05	-55,50	301,83
P ₉₀	130,01	228,50	306,24	429,46	116,16	583,79
P ₁₀	-450,84	-380,62	-426,97	-344,92	-1015,80	-694,07
$\rho_{x,y}$	0,89	0,89	0,86	0,86	0,51	0,51

Analisando a Tabela 19 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 20, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5 e WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve. Relativamente ao desvio padrão verifica-se que este diminuiu para as previsões consideradas. Tendo em conta o valor médio do RMSE verifica-se que de forma marginal diminuiu para a previsão de base WRF e aumentou para a previsão de base MM5 e para os dados de PERS.

Tabela 20- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 12-18hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS1	Aumenta	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	272,48	Aumenta
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOS1	Aumenta	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	281,50	Diminui
WRF		Negativa	Moderada	Leptocúrtica			295,27	
PERS-MOS1	Aumenta	#N/A	Moderada	Platicúrtica	Diminui	Mantém-se	588,10	Aumenta
PERS		Negativa	Simétrica	Mesocúrtica			504,60	

Tabela 21- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 18-24hr.

	MM5-MOS1	MM5	WRF-MOS1	WRF	PERS-MOS1	PERS
\bar{E}	-133,22	-59,28	-66,87	22,73	-412,29	-27,13
\tilde{E}	-106,17	-50,50	-48,97	1,85	-374,63	-21,10
Moda	-242,31	-163,10	-458,85	-154,60	#N/A	71,00
As ₁	109,09	103,82	391,98	177,33	#N/A	-98,13
σ	240,24	255,29	280,50	302,74	423,18	461,81
Var	5,8E+04	6,5E+04	7,9E+04	9,2E+04	1,8E+05	2,1E+05
K	0,25	0,23	0,22	0,22	0,29	0,26
As ₂	-0,34	-0,10	-0,19	0,21	-0,27	-0,04
Min	-875,56	-812,20	-961,98	-885,80	-1852,03	-1619,90
Max	768,58	923,40	922,40	1109,70	725,26	1607,10
Q ₁	-285,50	-218,80	-237,52	-163,15	-713,06	-316,80
Q ₃	6,98	71,95	88,83	191,43	-99,43	255,53
P ₉₀	141,71	257,02	294,96	441,17	71,87	530,70
P ₁₀	-446,21	-376,98	-442,71	-352,34	-971,74	-588,89
$\rho_{x,y}$	0,89	0,89	0,85	0,85	0,59	0,59

Analisando a Tabela 21 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 22, de forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5 e WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve. Relativamente ao desvio padrão verifica-se que este diminuiu para as previsões consideradas. Tendo em conta o valor médio do RMSE verifica-se que de forma marginal diminuiu para a previsão de base WRF e aumentou para a previsão de base MM5 e para os dados de PERS.

Tabela 22- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS1 para o horizonte temporal 18-24hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE
MM5-MOS1	Aumenta	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	274,70
MM5		Positiva	Simétrica	Leptocúrtica			262,08
WRF-MOS1	Aumenta	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	288,36
WRF		Positiva	Moderada	Leptocúrtica			303,59
PERS-MOS1	Aumenta	#N/A	Moderada	Platicúrtica	Diminui	Mantém-se	590,82
PERS		Negativa	Simétrica	Mesocúrtica			462,61

5.1.1.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

De modo a avaliar-se de que forma o tratamento de dados MOS1 modificou as séries de previsão fez-se uma descrição estatística do erro associado às previsões de base. No entanto, estes apresentam valores em média, sendo que não se consegue ter uma noção de como o erro variou ao longo dos *time-steps* dos vários horizontes temporais. Assim, efectuou-se a avaliação do SDE (Fig. 42 S-1 a S-3), BIAS (Fig. 42 B-1 a B-3), MAE (Fig. 43 M-1 a M-3) e RMSE (Fig. 43 R-1 a R-3) para os vários *time-steps* considerados.

Com base nas figuras 42 verifica-se que o valor de viés (BIAS) é menor em módulo do que o SDE. Assim e segundo a relação descrita pela Equação 22 o SDE consiste a maior componente do erro. Por outro lado observa-se um aumento do viés para uma diminuição da medida de SDE para o *time-step* correspondente. O aumento do viés aparenta ser uma consequência da redução do valor de SDE, já que o recurso a MOS1 teve uma influência gradual sucessivamente maior para reduzir o SDE associado aos vários *time-steps*, já o viés tendeu a aumentar de forma gradual e sucessiva para os vários horizontes temporais. Assim de uma forma geral observa-se que o valor de SDE tendeu a ser inferior após

tratamento face aos valores anteriores ao tratamento. Por outro lado observa-se que o viés tendeu a aumentar após tratamento MOS1. Isto vai ao encontro dos valores presentes nas Tabelas 15-22 reforçando assim os valores presentes nestas.

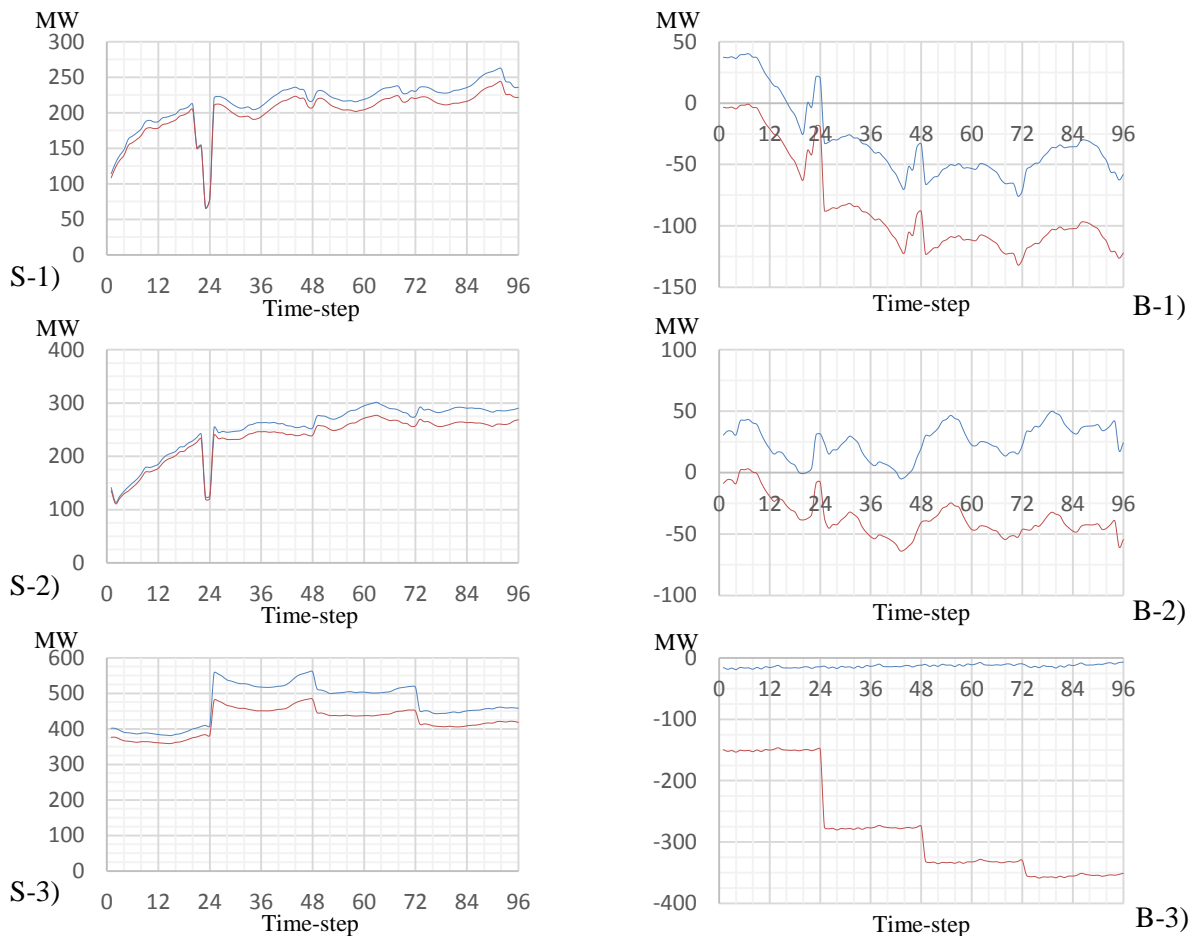


Fig. 42 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS1 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS1; -2) WRF e WRF-MOS1; -3) PERS e PERS-MOS1.

Com base nas Fig. 42 B-1) a B-3) verifica-se que o valor de viés (BIAS) foi o que mais variou comparativamente com os valores de SDE expostos nas Fig. 43 S-1) a S-3). Isto deve-se a natureza do tratamento MOS1, o qual efectua um achatamento dos dados, diminuindo assim o desvio padrão dos erros e aumentando os valores de viés.

Nas figuras 42 e 43 constata-se anomalias já anteriormente observadas no capítulo 4.2.5 sendo aí analisadas. No entanto verifica-se que estas de uma forma geral não sofreram alteração após tratamento MOS1.

Na Fig. 42 B-3) observa-se um viés em “escada” isto deve-se à natureza do tratamento MOS1 aliado a uma diferença substancial de valores do coeficiente de correlação de Pearson, o qual foi calculado como sendo 0.794, 0.597, 0.510 e 0.476 para os horizontes temporais 00-06hr, 06-12hr, 12-18hr e 18-24hr respectivamente. Já para as previsões MM5 e WRF, os coeficientes de correlação de Pearson são mais estáveis, tomando valores para as previsões de base: MM5 (0.942, 0.913, 0.905 e 0.894 para os horizontes temporais 00-06hr, 06-12hr, 12-18hr e 18-24hr) e WRF (0.943, 0.911, 0.900 e 0.885 para os horizontes temporais 00-06hr, 06-12hr, 12-18hr e 18-24hr) os coeficientes de correlação foram substancialmente mais estáveis. Por outro lado, sendo o viés associado aos dados de PERS sensivelmente constante quando se multiplica esses dados por uma percentagem variável consoante o horizonte temporal mas constante para os *time-steps* (pertencentes ao mesmo horizonte temporal) é de esperar que o resultado seja semelhante àquele da Fig. 42 B-3).

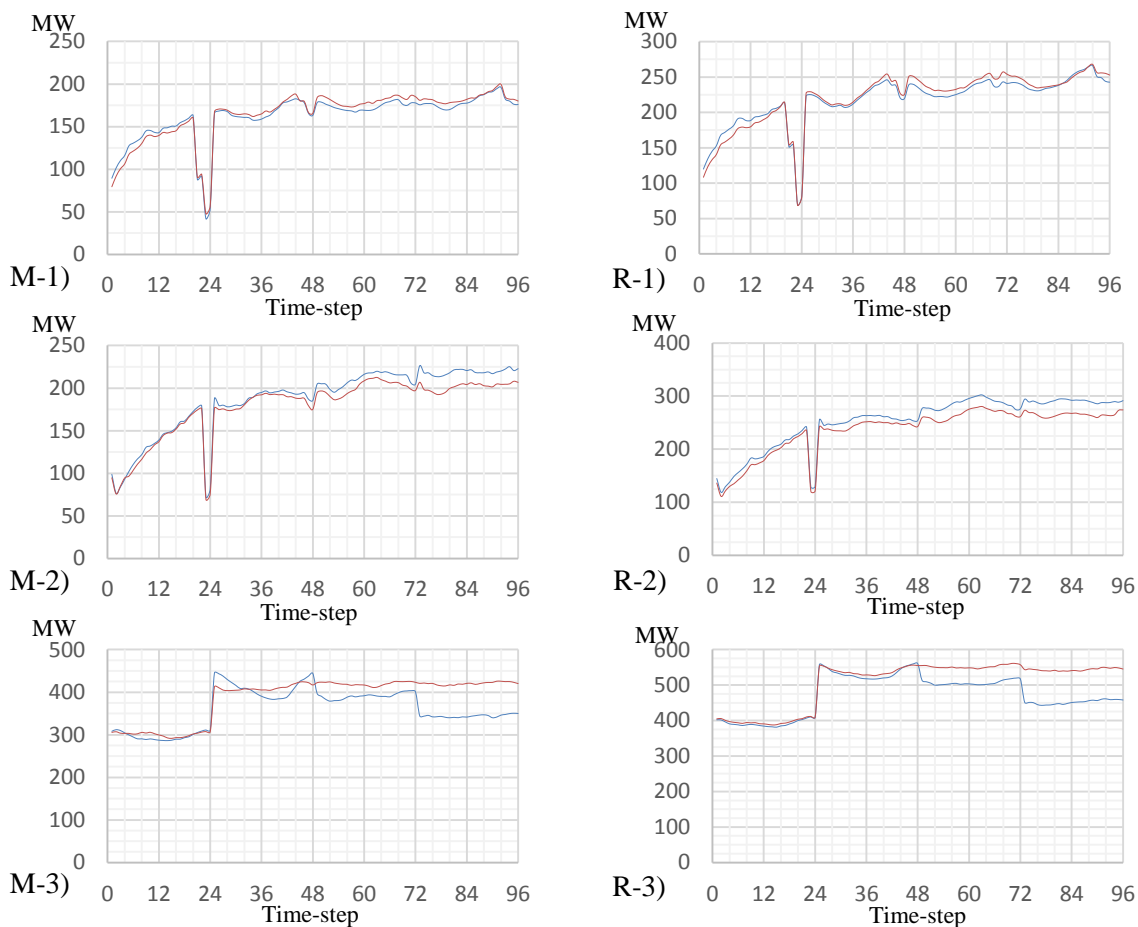


Fig. 43 – Gráfico do valor de MAE (M) e RMSE (R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS1 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS1; -2) WRF e WRF-MOS1; -3) PERS e PERS-MOS1.

Na Fig. 43 está representado o valor de MAE (M-1 a M-3) e de RMSE (R-1 a R-3) para os vários *time-steps*. Analisando a Fig. 43, verifica-se que o valor de MAE calculado para um determinado *time-step* é inferior ao valor calculado de RMSE para o mesmo *time-step*, o que era expectável devido diferença do cálculo para obter os valores de MAE (Equação 20) e RMSE (Equação 19).

Recorrendo à Fig. 43 verifica-se que a previsão de base WRF foi a que mais beneficiou do tratamento MOS1, sendo que isto vai ao encontro da análise efectuada nas Tabelas 15-22. Observando-se a Fig. 43 M-3) e a Fig. 43 R-3) verifica-se que o tratamento MOS1 estabilizou o erro para os horizontes temporais 06-24hr. Relativamente à previsão de base MM5 e aos dados de PERS verifica-se que o tratamento MOS1 não conseguiu reduzir o erro de forma constante verificando-se que para alguns *time-steps* se verifica uma melhoria marginal e para outros observa-se que este teve o efeito contrário piorando as séries de previsão (analisadas).

5.1.2 MÉDIA MÓVEL (MOS2)

O efeito conseguido com recurso à média móvel assemelha-se a um filtro passa-baixo, pelo que permite suavizar a série de dados, assim com a aplicação deste pretendia-se suavizar os erros associados às séries os quais se verificou a ocorrência anteriormente em 4.2.5.

Neste sentido realizaram-se os estudos referentes no anexo A, mais concretamente variação da janela móvel. Com isto, verificou-se que a dimensão da janela não poderia ser muito grande nem muito pequena, já que uma janela com uma elevada dimensão iria suavizar demasiado a série de dados e uma janela diminuta não iria ter o efeito de suavização desejado. Por outro lado, estudou-se a posição relativa da janela móvel face ao valor a calcular. Tendo em conta o estudo realizado, optou-se por uma janela

móvel com a dimensão de sete *time-steps* (01hr45min), centrada no *time-step* a calcular, conforme abordado em 4.3.1.2.

No presente capítulo encontram-se expostos os resultados obtidos, para a metodologia adoptada do cálculo da média móvel. Esta encontra-se representada pela terminologia MOS2, sendo que, este método foi descrito no capítulo 4.3.1.

5.1.2.1 DESCRIÇÃO ESTATÍSTICA

Tabela 23- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 00-06hr.

	MM5-MOS2	MM5	WRF-MOS2	WRF	WRF-STS-MOS2	WRF-STS	ALADIN-MOS2	ALADIN	PERS-MOS2	PERS
\bar{E}	6,94	6,63	17,97	17,44	-138,99	-138,76	-219,43	-219,24	-17,95	-17,93
\hat{E}	14,29	14,65	15,20	14,80	-88,96	-82,73	-182,33	-178,65	-20,60	-22,50
Moda	2,10	-20,00	54,90	20,00	-289,46	-28,00	-356,44	-66,00	-316,73	-330,10
As ₁	4,84	26,63	-36,93	-2,56	150,47	-110,76	137,01	-153,24	298,78	312,17
σ	176,73	185,27	186,69	192,46	223,21	227,80	214,23	216,68	388,63	391,21
Var	3,1E+04	3,4E+04	3,5E+04	3,7E+04	5,0E+04	5,2E+04	4,6E+04	4,7E+04	1,5E+05	1,5E+05
K	0,21	0,20	0,20	0,20	0,29	0,28	0,30	0,30	0,25	0,25
As ₂	-0,12	-0,13	0,04	0,04	-0,67	-0,74	-0,52	-0,56	0,02	0,04
Min	-642,60	-642,60	-941,47	-982,90	-1048,85	-1048,85	-953,80	-953,80	-1328,60	-1328,60
Max	677,54	700,80	721,20	721,20	300,01	334,70	492,89	490,00	1420,96	1436,20
Q ₁	-78,83	-82,78	-76,53	-79,05	-284,56	-283,56	-367,61	-368,36	-264,11	-268,50
Q ₃	96,39	98,63	101,21	101,25	38,69	38,95	-41,06	-38,38	202,40	203,90
P ₉₀	216,47	224,41	247,20	255,83	98,36	99,50	18,51	19,00	442,14	445,31
P ₁₀	-209,70	-222,64	-192,96	-195,99	-460,20	-470,22	-519,79	-528,08	-491,19	-493,13
$\rho_{x,y}$	0,94	0,94	0,94	0,93	0,94	0,93	0,94	0,93	0,71	0,71

Analisando a Tabela 23 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 24, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5, WRF, WRF-STS, ALADIN e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5 e para os dados de PERS após tratamento, por outro lado verifica-se que este valor aumentou para as previsões de base WRF, WRF-STS e ALADIN. Relativamente ao desvio padrão verifica-se que este diminuiu de uma forma generalizada. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, WRF, WRF-STS, ALADIN e para os dados de PERS após tratamento.

Tabela 24- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 00-06hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS2	Aumenta	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	176,87	Diminui
MM5		Positiva	Simétrica	Leptocúrtica			185,39	
WRF-MOS2	Aumenta	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	187,55	Diminui
WRF		Negativa	Simétrica	Leptocúrtica			193,25	
WRF-STS-MOS2	Aumenta	Positiva	Moderada	Platicúrtica	Diminui	Aumenta	262,95	Diminui
WRF-STS		Negativa	Moderada	Platicúrtica			266,73	
ALADIN-MOS2	Aumenta	Positiva	Moderada	Platicúrtica	Diminui	Aumenta	306,67	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOS2	Aumenta	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	389,04	Diminui
PERS		Positiva	Simétrica	Leptocúrtica			391,62	

Tabela 25- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 06-12hr.

	MM5-MOS2	MM5	WRF-MOS2	WRF	WRF-STS-MOS2	WRF-STS	ALADIN-MOS2	ALADIN	PERS-MOS2	PERS
\bar{E}	-56,22	-56,53	6,44	6,21	-226,93	-226,92	-273,96	-219,24	-18,48	-18,47
\hat{E}	-41,50	-41,50	-8,50	-9,35	-167,11	-166,75	-249,93	-178,65	-31,29	-29,25
Moda	58,70	-82,50	-8,50	-8,50	-20,71	-627,60	-218,36	-66,00	124,30	-18,00
As ₁	-114,92	25,97	14,94	14,71	-206,22	400,68	-55,60	-153,24	-142,78	-0,47
σ	240,84	243,81	265,22	267,63	289,14	289,26	234,61	216,68	523,61	525,94
Var	5,8E+04	5,9E+04	7,0E+04	7,2E+04	8,4E+04	8,4E+04	5,5E+04	4,7E+04	2,7E+05	2,8E+05
K	0,23	0,23	0,23	0,23	0,33	0,33	0,30	0,30	0,23	0,24
As ₂	-0,18	-0,18	0,17	0,17	-0,62	-0,62	-0,31	-0,56	0,07	0,06
Min	-803,93	-820,50	-745,00	-745,00	-1080,54	-1085,90	-957,17	-953,80	-1658,86	-1674,40
Max	664,96	662,10	960,70	960,70	322,60	329,90	337,10	490,00	1685,77	1696,00
Q ₁	-193,26	-196,90	-155,20	-156,83	-457,00	-456,81	-443,04	-368,36	-347,21	-349,73
Q ₃	82,06	82,50	154,27	153,00	22,95	23,55	-77,44	-38,38	294,36	298,83
P ₉₀	248,50	256,00	360,10	362,33	96,09	95,61	-0,43	19,00	674,31	675,21
P ₁₀	-355,37	-358,32	-311,70	-318,45	-641,56	-643,27	-615,16	-528,08	-693,40	-696,08
$\rho_{x,y}$	0,90	0,90	0,88	0,88	0,91	0,90	0,93	0,93	0,47	0,47

Analisando a Tabela 25 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 26, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5, WRF, WRF-STS, ALADIN e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5 e para os dados de PERS após tratamento, por outro lado verifica-se que este valor aumentou para as previsões de base WRF, WRF-STS e ALADIN. Relativamente ao desvio padrão verifica-se que este diminuiu de uma forma generalizada. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, ALADIN, para os dados de PERS e que para a previsão de base WRF-STS piora em média após tratamento.

Tabela 26- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 06-12hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE
MM5-MOS2	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	247,31
MM5		Positiva	Moderada	Leptocúrtica			250,28
WRF-MOS2	Aumenta	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	265,30
WRF		Positiva	Moderada	Leptocúrtica			267,70
WRF-STS-MOS2	Mantém-se	Negativa	Moderada	Platicúrtica	Diminui	Aumenta	367,56
WRF-STS		Positiva	Moderada	Platicúrtica			367,65
ALADIN-MOS2	Aumenta	Negativa	Moderada	Platicúrtica	Aumenta	Mantém-se	360,69
ALADIN		Negativa	Moderada	Platicúrtica			308,25
PERS-MOS2	Mantém-se	Negativa	Simétrica	Leptocúrtica	Diminui	Mantém-se	523,94
PERS		Negativa	Simétrica	Leptocúrtica			526,26

Tabela 27- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 12-18hr.

	MM5-MOS2	MM5	WRF-MOS2	WRF	WRF-STS-MOS2	WRF-STS	ALADIN-MOS2	ALADIN	PERS-MOS2	PERS
\bar{E}	-71,85	-71,38	19,26	19,57	-230,03	-230,03	-284,81	-284,75	-21,77	-21,96
\tilde{E}	-57,60	-58,25	-4,90	-5,45	-160,10	-159,63	-236,92	-236,90	-7,53	-7,60
Moda	-155,30	-11,00	184,19	34,00	37,94	-186,00	-218,35	-56,00	-193,50	290,20
As ₁	83,45	-60,38	-164,93	-14,43	-267,97	-44,03	-66,46	-228,75	171,73	-312,16
σ	245,70	247,91	291,81	294,62	294,80	294,91	276,21	277,21	502,20	504,12
Var	6,0E+04	6,1E+04	8,5E+04	8,7E+04	8,7E+04	8,7E+04	7,6E+04	7,7E+04	2,5E+05	2,5E+05
K	0,23	0,23	0,22	0,22	0,32	0,32	0,30	0,30	0,25	0,26
As ₂	-0,17	-0,16	0,25	0,25	-0,71	-0,72	-0,52	-0,52	-0,09	-0,09
Min	-849,60	-849,60	-755,70	-760,10	-1055,50	-1055,50	-1592,80	-1592,80	-1305,70	-1335,00
Max	766,97	784,70	1062,40	1062,40	387,74	391,70	330,34	336,55	1541,90	1557,10
Q ₁	-212,84	-215,20	-159,54	-159,00	-468,00	-465,99	-470,16	-471,46	-353,03	-354,65
Q ₃	65,39	66,93	178,33	182,05	16,79	17,14	-61,66	-61,94	294,59	301,83
P ₉₀	222,03	228,50	434,21	429,46	94,71	95,52	19,62	20,10	581,80	583,79
P ₁₀	-377,43	-380,62	-345,37	-344,92	-656,19	-657,97	-669,46	-667,61	-696,43	-694,07
$\rho_{x,y}$	0,89	0,89	0,86	0,86	0,89	0,89	0,87	0,87	0,52	0,51

Analisando a Tabela 27 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 28, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5 e ALADIN, que se manteve em módulo para a previsão WRF-STS, diminuiu para a previsão de base WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5, WRF, WRF-STS e ALADIN e que para os dados de PERS este valor aumentou após tratamento. Relativamente ao desvio padrão verifica-se que este diminuiu de uma forma generalizada embora de forma marginal. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, WRF, WRF-STS e ALADIN assim como para os dados de PERS após tratamento.

Tabela 28- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 12-18hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE
MM5-MOS2	Aumenta	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	255,99
MM5		Negativa	Moderada	Leptocúrtica			257,98
WRF-MOS2	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	292,44
WRF		Negativa	Moderada	Leptocúrtica			295,27
WRF-STS-MOS2	Mantém-se	Negativa	Moderada	Platicúrtica	Diminui	Mantém-se	373,93
WRF-STS		Negativa	Moderada	Platicúrtica			374,01
ALADIN-MOS2	Aumenta	Negativa	Moderada	Platicúrtica	Diminui	Mantém-se	396,75
ALADIN		Negativa	Moderada	Platicúrtica			397,40
PERS-MOS2	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	502,67
PERS		Negativa	Simétrica	Mesocúrtica			504,60

Tabela 29- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 18-24hr.

	MM5-MOS2	MM5	WRF-MOS2	WRF	WRF-STSMOS2	WRF-STSMOS2	PERS-MOS2	PERS
\bar{E}	-59,82	-59,28	22,47	22,73	-223,00	-223,00	-26,96	-27,13
\tilde{E}	-52,57	-50,50	2,66	1,85	-152,84	-153,73	-18,11	-21,10
Moda	-322,50	-163,10	-66,00	-154,60	-599,30	2,00	174,27	71,00
As ₁	262,68	103,82	88,47	177,33	376,30	-225,00	-201,23	-98,13
σ	252,74	255,29	300,25	302,74	300,80	301,09	460,36	461,81
Var	6,4E+04	6,5E+04	9,0E+04	9,2E+04	9,0E+04	9,1E+04	2,1E+05	2,1E+05
K	0,23	0,23	0,23	0,22	0,32	0,32	0,25	0,26
As ₂	-0,09	-0,10	0,20	0,21	-0,70	-0,69	-0,06	-0,04
Min	-812,20	-812,20	-893,39	-885,80	-1104,16	-1105,20	-1599,70	-1619,90
Max	907,11	923,40	1097,70	1109,70	486,47	544,20	1585,53	1607,10
Q ₁	-215,26	-218,80	-164,07	-163,15	-465,25	-464,44	-314,20	-316,80
Q ₃	70,74	71,95	190,99	191,43	24,13	23,93	254,79	255,53
P ₉₀	252,36	257,02	434,61	441,17	107,99	107,32	529,89	530,70
P ₁₀	-372,80	-376,98	-351,73	-352,34	-655,97	-656,66	-589,31	-588,89
$\rho_{x,y}$	0,89	0,89	0,85	0,85	0,88	0,88	0,59	0,59

Analisando a Tabela 29 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 30, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro não se alterou significativamente. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5, que se manteve em módulo para a previsão WRF-STSMOS2, diminuiu para a previsão de base WRF e para os dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5, WRF, WRF-STSMOS2 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este diminuiu de uma forma generalizada embora de forma marginal. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, WRF, WRF-STSMOS2 e para os dados de PERS após tratamento.

Tabela 30- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS2 para o horizonte temporal 18-24hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE
MM5-MOS2	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	259,72
MM5		Positiva	Simétrica	Leptocúrtica			262,08
WRF-MOS2	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	301,09
WRF		Positiva	Moderada	Leptocúrtica			303,59
WRF-STSMOS2	Mantém-se	Positiva	Moderada	Platicúrtica	Diminui	Mantém-se	374,45
WRF-STSMOS2		Negativa	Moderada	Platicúrtica			374,68
PERS-MOS2	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Mantém-se	461,15
PERS		Negativa	Simétrica	Mesocúrtica			462,61

5.1.2.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

De modo a avaliar-se de que forma o tratamento de dados MOS2 modificou as séries de previsão fez-se uma descrição estatística do erro associado às previsões de base, recorrendo aos indicadores descritos no capítulo 4.1. No entanto, estes apresentam valores em média, sendo que não se consegue ter uma noção de como o erro variou ao longo dos *time-steps* dos vários horizontes temporais. Assim, efectuou-se a avaliação do SDE (Fig. 44 S-1 a S-5), BIAS (Fig. 44 B-1 a B-5), MAE (Fig. 45 M-1 a M-5) e RMSE (Fig. 45 R-1 a R-5) para os vários *time-steps* considerados.

Com base na Fig. 44 observa-se que o valor de viés (BIAS) é menor em módulo do que o SDE. O tratamento MOS2 teve um impacto semelhante nas previsões de base MM5, WRF, WRF-STSMOS2, ALADIN e dados de PERS verificando-se que este tendeu a reduzir o ruído associado ao viés. Verifica-se que por

vezes o viés (em módulo) aumentou e noutras este diminuiu (Fig. 44 B-1) a B-5)). Tendo em conta o valor de SDE verifica-se que este teve um comportamento semelhante ao longo dos vários horizontes temporais, de uma forma geral verificou-se que quando este valor diminuía/aumentava o valor do viés aumentava/diminuía. Assim, verifica-se que este tratamento modificou as séries de previsão suavizando-a, sendo consequência disso uma suavização do BIAS e do SDE associado a estas.

Na Fig. 45 está representado o valor de MAE (M-1 a M-5) e de RMSE (R-1 a R-3) para os vários *time-steps*. Analisando a Fig. 45, verifica-se que o valor de MAE calculado para um determinado *time-step* é inferior ao valor calculado de RMSE para o mesmo *time-step*, o que era expectável devido diferença do cálculo para obter os valores de MAE (Equação 20) e RMSE (Equação 19).

Recorrendo à Fig. 45 verifica-se que não ocorreram reduções significativas do erro (MAE e RMSE). Isto seria expectável, pois como se pode observar pela Fig. 44 não ocorreu uma diminuição significativa das medidas BIAS e SDE. No entanto, observa-se que o tratamento MOS2 tendeu a suavizar o erro das séries de previsão, isto vai ao encontro da Fig. 44 em que se verificou esta tendência.

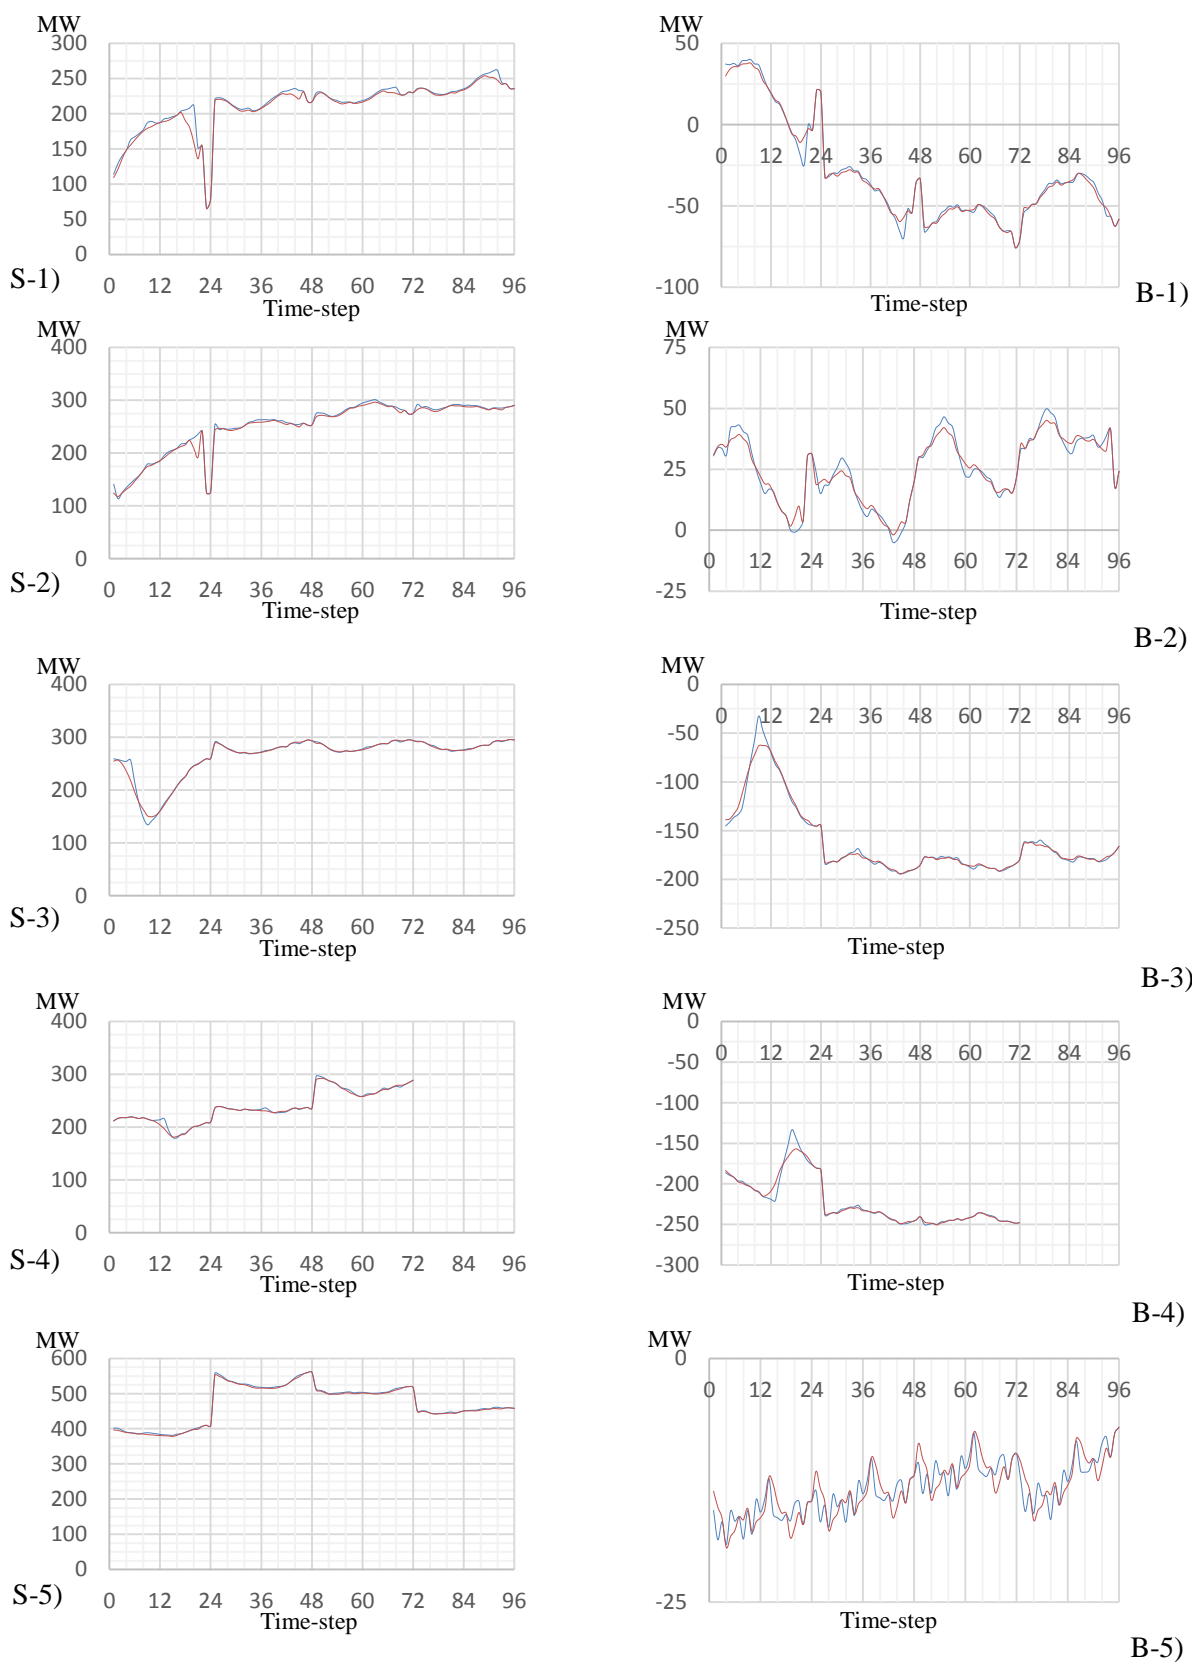


Fig. 44 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS2 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS2; -2) WRF e WRF-MOS2; -3) WRF-STC e WRF-STC-MOS2; -4) ALADIN e ALADIN-MOS2; -5) PERS e PERS-MOS2.

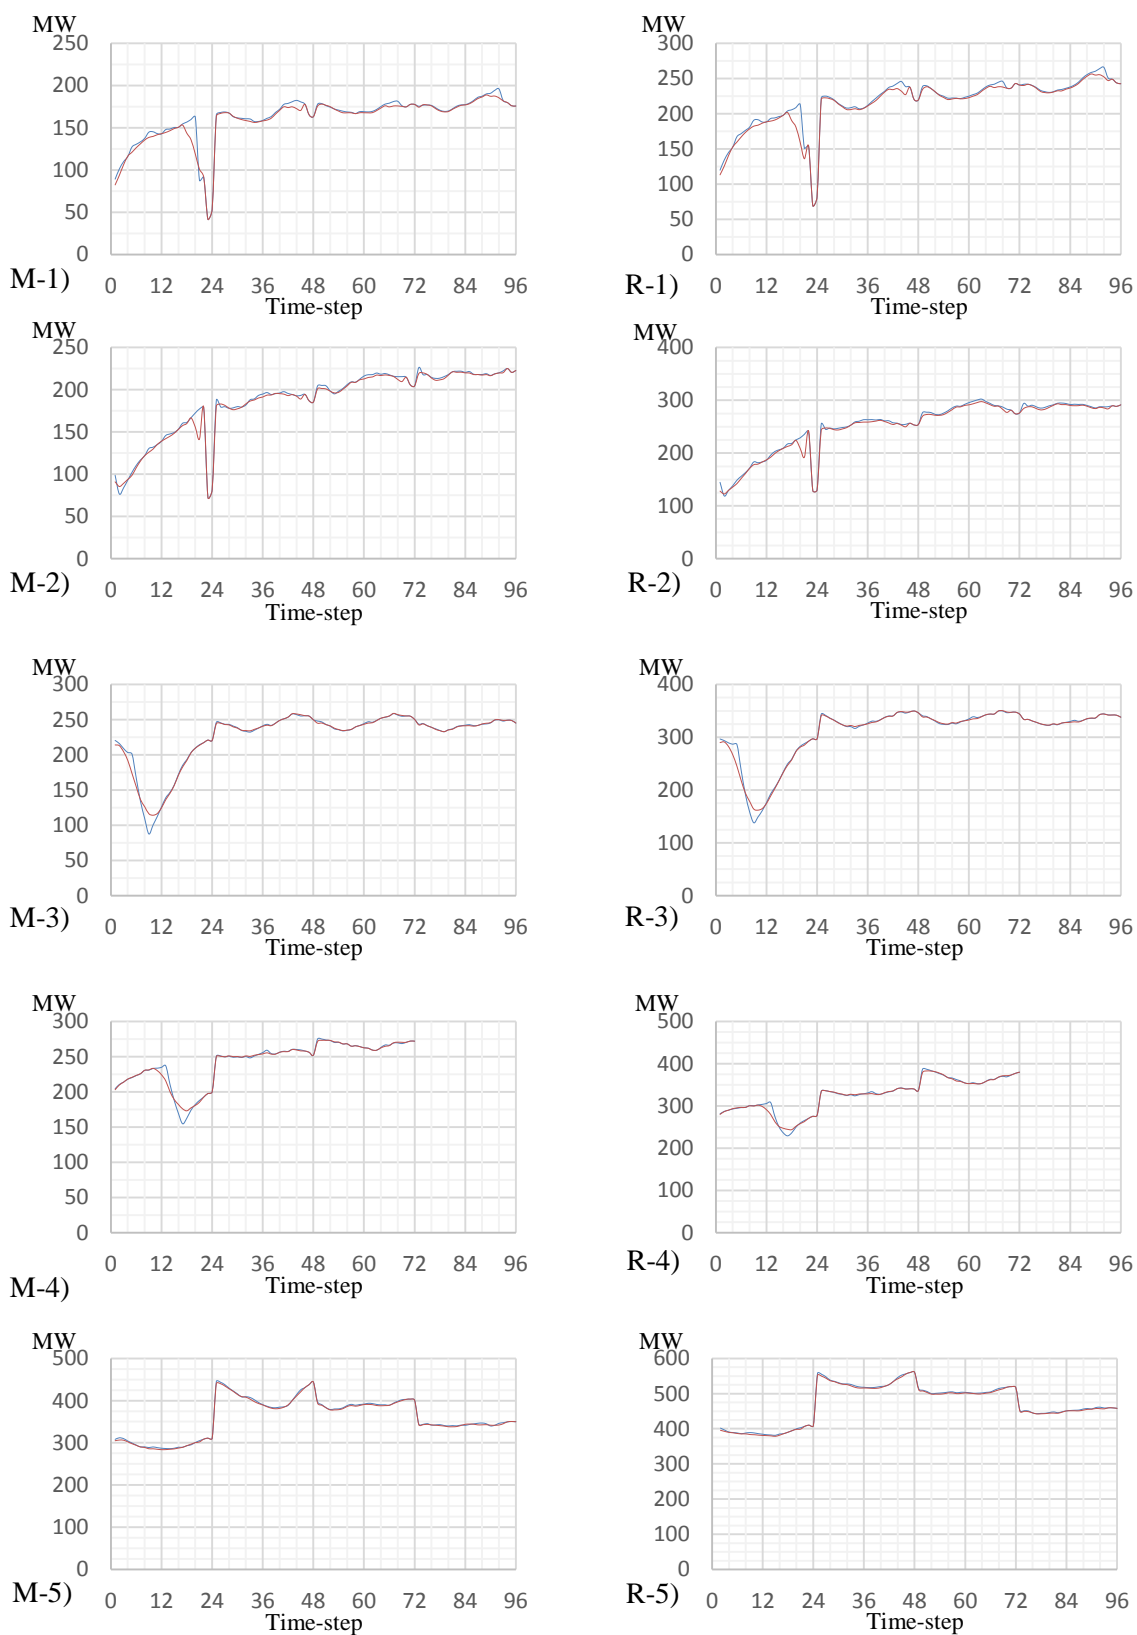


Fig. 45 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS2 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS2; -2) WRF e WRF-MOS2; -3) WRF-STC e WRF-STC-MOS2; -4) ALADIN e ALADIN-MOS2; -5) PERS e PERS-MOS2.

5.1.3 PREVISÃO ADAPTATIVA DO VIÉS (MOS3)

A previsão adaptativa do viés tem como objectivo prever o valor aproximado da subestimação/sobrestimação das previsões, face ao valor observado, conforme descrito em 4.3.1.

Com o objectivo de implementar um módulo de previsão de viés foram estudadas várias variações deste método, presentes no anexo A. A metodologia adoptada, presente no anexo A e descrita em 4.3.1 foi a variação do modelo, das variações estudadas, que melhor desempenho obteve em média para o período de validação. Os resultados expostos no presente capítulo são referentes á variação adoptada.

No presente capítulo optou-se por avaliar as previsões de base (MM5, WRF, WRF-STS e ALADIN) e dados de PERS antes e após tratamento para o período de validação por forma a conseguir-se comparar a eficácia deste.

Neste capítulo optou-se pela nomenclatura MOS3, conforme referido em 4.3.1. para identificar a série de dados tratada com recurso ao modelo desenvolvido e utilizando a metodologia adoptada.

5.1.3.1 DESCRIÇÃO ESTATÍSTICA

Tabela 31- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 00-06hr.

	MM5-MOS3	MM5	WRF-MOS3	WRF	WRF-STS-MOS3	WRF-STS	ALADIN-MOS3	ALADIN	PERS-MOS3	PERS
\bar{E}	-9,85	6,63	-14,00	17,44	-20,31	-138,76	-26,58	-219,24	26,66	-17,93
\hat{E}	-0,55	14,65	-5,60	14,80	-5,35	-82,73	-16,00	-178,65	7,00	-22,50
Moda	-2,00	-20,00	41,00	20,00	-130,70	-28,00	-1,00	-66,00	15,00	-330,10
As ₁	-7,85	26,63	-55,00	-2,56	110,39	-110,76	-25,58	-153,24	11,66	312,17
σ	183,77	185,27	194,80	192,46	216,00	227,80	188,29	216,68	437,40	391,21
Var	3,4E+04	3,4E+04	3,8E+04	3,7E+04	4,7E+04	5,2E+04	3,5E+04	4,7E+04	1,9E+05	1,5E+05
K	0,24	0,20	0,22	0,20	0,22	0,28	0,24	0,30	0,23	0,25
As ₂	-0,15	-0,13	-0,13	0,04	-0,21	-0,74	-0,17	-0,56	0,13	0,04
Min	-729,20	-642,60	-907,90	-982,90	-799,00	-1048,85	-685,15	-953,80	-1475,70	-1328,60
Max	750,80	700,80	836,20	721,20	663,80	334,70	695,00	490,00	1493,70	1436,20
Q ₁	-106,68	-82,78	-118,85	-79,05	-138,28	-283,56	-144,49	-368,36	-217,50	-268,50
Q ₃	95,90	98,63	94,15	101,25	97,99	38,95	83,38	-38,38	285,18	203,90
P ₉₀	200,24	224,41	218,07	255,83	233,48	99,50	209,85	19,00	596,09	445,31
P ₁₀	-229,05	-222,64	-263,79	-195,99	-297,89	-470,22	-268,50	-528,08	-508,83	-493,13
$\rho_{x,y}$	0,94	0,94	0,93	0,93	0,91	0,93	0,93	0,93	0,70	0,71

Analisando a Tabela 31 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 32, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu algumas alterações, verificando-se uma melhoria na forma da distribuição do erro para as previsões de base WRF-STS e ALADIN, relativamente às restantes não se registaram grandes alterações. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5, WRF, para os dados de PERS e que o módulo da média das previsões de base WRF-STS e ALADIN diminuiu após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5 e ALADIN após tratamento, por outro lado verifica-se que este valor aumentou para a previsão de base WRF e que diminuiu para a previsão de base WRF-STS e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este diminuiu para as previsões de base MM5, WRF, WRF-STS e ALADIN, por outro lado verifica-se que este valor aumentou para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, que aumentou de forma marginal para o WRF, que diminuiu de forma substancial para as previsões de base WRF-STS e ALADIN, que aumentou de forma substancial para os dados de PERS após tratamento.

Tabela 32- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 00-06hr.

	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS3	Aumenta	Negativa	Simétrica	Leptocúrtica	Diminui	Mantém-se	184,03	Diminui
MM5		Positiva	Simétrica	Leptocúrtica			185,39	
WRF-MOS3	Diminui	Negativa	Simétrica	Leptocúrtica	Aumenta	Mantém-se	195,30	Aumenta
WRF		Negativa	Simétrica	Leptocúrtica			193,25	
WRF-STS-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Diminui	216,95	Diminui
WRF-STS		Negativa	Moderada	Platicúrtica			266,73	
ALADIN-MOS3	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	190,16	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOS3	Aumenta	Positiva	Simétrica	Leptocúrtica	Aumenta	Diminui	438,21	Aumenta
PERS		Positiva	Simétrica	Leptocúrtica			391,62	

Tabela 33- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 06-12hr.

	MM5-MOS3	MM5	WRF-MOS3	WRF	WRF-STS-MOS3	WRF-STS	ALADIN-MOS3	ALADIN	PERS-MOS3	PERS
\bar{E}	-14,07	-56,53	-6,24	6,21	-39,37	-226,92	-37,96	-219,24	15,97	-18,47
\bar{E}	-12,95	-41,50	-5,05	-9,35	-22,13	-166,75	-25,05	-178,65	-19,75	-29,25
Moda	-119,00	-82,50	-24,00	-8,50	-205,50	-627,60	-87,00	-66,00	-299,00	-18,00
As_1	104,93	25,97	17,76	14,71	166,13	400,68	49,04	-153,24	314,97	-0,47
σ	234,09	243,81	260,03	267,63	263,00	289,26	208,11	216,68	589,22	525,94
Var	5,5E+04	5,9E+04	6,8E+04	7,2E+04	6,9E+04	8,4E+04	4,3E+04	4,7E+04	3,5E+05	2,8E+05
K	0,23	0,23	0,22	0,23	0,24	0,33	0,24	0,30	0,23	0,24
As_2	-0,01	-0,18	-0,01	0,17	-0,20	-0,62	-0,19	-0,56	0,18	0,06
Min	-881,60	-820,50	-803,40	-745,00	-843,30	-1085,90	-688,20	-953,80	-1794,60	-1674,40
Max	797,10	662,10	946,40	960,70	704,90	329,90	502,70	490,00	2082,30	1696,00
Q_1	-143,85	-196,90	-159,15	-156,83	-214,20	-456,81	-163,74	-368,36	-364,05	-349,73
Q_3	131,68	82,50	137,25	153,00	122,59	23,55	100,00	-38,38	364,45	298,83
P_{90}	271,79	256,00	325,93	362,33	295,80	95,61	218,35	19,00	824,02	675,21
P_{10}	-314,70	-358,32	-350,84	-318,45	-394,95	-643,27	-325,16	-528,08	-729,18	-696,08
$\rho_{x,y}$	0,91	0,90	0,89	0,88	0,87	0,90	0,92	0,93	0,44	0,47

Analisando a Tabela 33 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 34, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu algumas alterações, verificando-se um melhoria na forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS e ALADIN, relativamente aos dados de PERS verifica-se uma ligeira degradação. Por outro lado observa-se que ocorreu uma degradação do valor da média para as previsões de base MM5, WRF, para os dados de PERS e que o módulo da média das previsões de base WRF-STS e ALADIN diminuiu após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5 e ALADIN após tratamento, por outro lado verifica-se que este valor aumentou para a previsão de base WRF e que diminuiu para a previsão de base WRF-STS e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este diminuiu para as previsões de base MM5, WRF, WRF-STS e ALADIN, por outro lado verifica-se que este valor aumentou para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que diminuiu de forma marginal para as previsões de MM5, que aumentou de forma marginal para o WRF, que diminuiu de forma substancial para as previsões de base WRF-STS e ALADIN, que aumentou de forma substancial para os dados de PERS após tratamento.

Tabela 34- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 06-12hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS3	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	234,51	Diminui
MM5		Positiva	Moderada	Leptocúrtica			250,28	
WRF-MOS3	Aumenta	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	260,10	Diminui
WRF		Positiva	Moderada	Leptocúrtica			267,70	
WRF-STS-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Diminui	265,93	Diminui
WRF-STS		Positiva	Moderada	Platicúrtica			367,65	
ALADIN-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Diminui	211,54	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	589,44	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			526,26	

Tabela 35- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 12-18hr.

	MM5-MOS3	MM5	WRF-MOS3	WRF	WRF-STS-MOS3	WRF-STS	ALADI N-MOS3	ALADI N	PERS-MOS3	PERS
\bar{E}	-15,25	-71,38	14,34	19,57	-49,72	-230,03	-57,58	-284,75	29,91	-21,96
\tilde{E}	-11,10	-58,25	1,00	-5,45	-41,73	-159,63	-29,70	-236,90	-2,55	-7,60
Moda	91,00	-11,00	-1,60	34,00	42,50	-186,00	62,00	-56,00	-143,50	290,20
As ₁	-106,25	-60,38	15,94	-14,43	-92,22	-44,03	-119,58	-228,75	173,41	-312,16
σ	245,52	247,91	281,42	294,62	262,52	294,91	253,31	277,21	560,77	504,12
Var	6,0E+04	6,1E+04	7,9E+04	8,7E+04	6,9E+04	8,7E+04	6,4E+04	7,7E+04	3,1E+05	2,5E+05
K	0,23	0,23	0,22	0,22	0,24	0,32	0,24	0,30	0,25	0,26
As ₂	-0,05	-0,16	0,14	0,25	-0,09	-0,72	-0,33	-0,52	0,17	-0,09
Min	-903,50	-849,60	-827,20	-760,10	-806,10	-1055,50	-1232,80	-1592,80	-1608,30	-1335,00
Max	932,20	784,70	930,40	1062,40	769,60	391,70	565,65	336,55	1817,50	1557,10
Q ₁	-147,08	-215,20	-139,50	-159,00	-214,80	-465,99	-197,94	-471,46	-356,03	-354,65
Q ₃	125,08	66,93	172,95	182,05	116,05	17,14	104,28	-61,94	372,65	301,83
P ₉₀	276,69	228,50	367,84	429,46	281,30	95,52	251,18	20,10	804,99	583,79
P ₁₀	-318,07	-380,62	-336,79	-344,92	-414,00	-657,97	-377,38	-667,61	-657,28	-694,07
$\rho_{x,y}$	0,90	0,89	0,87	0,86	0,87	0,89	0,88	0,87	0,51	0,51

Analisando a Tabela 35 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 36, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu algumas alterações, verificando-se um melhoria na forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS e ALADIN, relativamente aos dados de PERS verifica-se uma ligeira degradação. Por outro lado observa-se que em módulo ocorreu uma diminuição do valor da média para as previsões de base MM5, WRF, WRF-STS e ALADIN, que para os dados de PERS em módulo a média aumentou após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para os dados de PERS, aumentou para as previsões de base MM5, WRF e ALADIN, que por outro lado este valor diminuiu para a previsão de base WRF-STS. Relativamente ao desvio padrão verifica-se que este diminuiu para as várias previsões de base e aumentou para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que diminuiu para as previsões de MM5, WRF, WRF-STS e que aumenta para os dados de PERS após tratamento.

Tabela 36- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 12-18hr.

	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS3	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	245,99	Diminui
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOS3	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	281,79	Diminui
WRF		Negativa	Moderada	Leptocúrtica			295,27	
WRF-ST5-MOS3	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Diminui	267,19	Diminui
WRF-ST5		Negativa	Moderada	Platicúrtica			374,01	
ALADIN-MOS3	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	259,77	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			397,40	
PERS-MOS3	Aumenta	Positiva	Moderada	Leptocúrtica	Aumenta	Mantém-se	561,57	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			504,60	

Tabela 37- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 18-24hr.

	MM5-MOS3	MM5	WRF-MOS3	WRF	WRF-ST5-MOS3	WRF-ST5	PERS-MOS3	PERS
\bar{E}	-5,25	-71,38	17,66	19,57	-58,51	-230,03	36,62	-284,75
\tilde{E}	-8,50	-58,25	13,40	-5,45	-42,00	-159,63	2,15	-236,90
Moda	9,00	-11,00	-47,00	34,00	-320,50	-186,00	-154,00	-56,00
As_1	-14,25	-60,38	64,66	-14,43	261,99	-44,03	190,62	-228,75
σ	260,86	247,91	294,33	294,62	267,94	294,91	556,35	277,21
Var	6,8E+04	6,1E+04	8,7E+04	8,7E+04	7,2E+04	8,7E+04	3,1E+05	7,7E+04
K	0,23	0,23	0,22	0,22	0,24	0,32	0,26	0,30
As_2	0,04	-0,16	0,04	0,25	-0,18	-0,72	0,19	-0,52
Min	-788,20	-849,60	-960,60	-760,10	-852,00	-1055,50	-1789,90	-1592,80
Max	899,10	784,70	1062,10	1062,40	710,90	391,70	1852,10	336,55
Q ₁	-154,08	-215,20	-148,38	-159,00	-238,00	-465,99	-314,35	-471,46
Q ₃	138,30	66,93	176,38	182,05	114,76	17,14	410,48	-61,94
P ₉₀	299,98	228,50	374,76	429,46	287,47	95,52	754,53	20,10
P ₁₀	-340,18	-380,62	-352,84	-344,92	-434,40	-657,97	-617,57	-667,61
$\rho_{x,y}$	0,89	0,89	0,86	0,86	0,86	0,89	0,53	0,87

Analisando a Tabela 37 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 38, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu algumas alterações, verificando-se um melhoria na forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5 e ALADIN, relativamente aos dados de PERS verifica-se uma ligeira degradação. Por outro lado observa-se que em módulo ocorreu uma diminuição do valor da média para as previsões de base MM5, WRF, WRF-ST5, ALADIN e dados de PERS após tratamento. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este se manteve para as previsões de base MM5 e WRF, por outro lado, verifica-se que diminuiu para os dados de PERS e previsão de base WRF-ST5. Relativamente ao desvio padrão verifica-se que este diminuiu para as várias previsões de base e aumentou para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que diminuiu para as previsões de WRF e WRF-ST5, por outro lado verifica-se que em média aumentou para a previsão de base MM5 e para os dados de PERS após tratamento.

Tabela 38- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS3 para o horizonte temporal 18-24hr.

	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS3	Diminui	Negativa	Simétrica	Leptocúrtica	Aumenta	Mantém-se	260,91	Aumenta
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOS3	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	294,86	Diminui
WRF		Negativa	Moderada	Leptocúrtica			295,27	
WRF-ST5-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Diminui	274,25	Diminui
WRF-ST5		Negativa	Moderada	Platicúrtica			374,01	
PERS-MOS3	Diminui	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	557,55	Aumenta
PERS		Negativa	Moderada	Platicúrtica			397,40	

5.1.3.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

De modo a avaliar-se de que forma o tratamento de dados MOS3 modificou as séries de previsão fez-se uma descrição estatística do erro associado às séries de previsão. No entanto, estes apresentam valores em média, sendo que não se consegue ter uma noção de como o erro variou ao longo dos *time-steps* dos vários horizontes temporais. Assim, efectuou-se a avaliação do SDE (Fig. 46 S-1 a S-5), BIAS (Fig. 46 B-1 a B-5), MAE (Fig. 47 M-1 a M-5) e RMSE (Fig. 47 R-1 a R-5) para os vários *time-steps* considerados.

Com base na Fig. 46 verifica-se que o valor de viés (BIAS) é menor em módulo do que o SDE. Assim e segundo a relação descrita pela Equação 22 o SDE consiste a maior componente do erro. Tendo em conta as Fig. 47 S-1) a S-5) observa-se que o valor de SDE sofreu pouca alteração, sendo que para alguns *time-steps* pertencentes as previsões de base MM5, WRF, WRF-ST5, ALADIN e dados de PERS obteve menores valores de SDE e para outros este valor aumentou. Isto fez com que nem sempre fosse vantajoso efectuar o tratamento MOS3 para todas as séries de previsão. No entanto, verifica-se que a diminuição do valor de SDE se fez notar mais para as previsões de base WRF-ST5 e ALADIN, já as previsões de base MM5 e WRF verifica-se que o valor de SDE foi bastante semelhante antes e após MOS3, analisando os dados de PERS observa-se que este não conseguiu melhorar a qualidade dos dados após tratamento MOS3. Tendo em conta os valores de BIAS (Fig. 46 B-1) a B-5)) observa-se que este valor após MOS3 se aproximou de zero para as previsões de base MM5, WRF, WRF-ST5 e ALADIN. Não se tendo verificado o mesmo para os dados de PERS que tenderam a piorar. Assim será expectável na Fig. 47 observar uma redução e/ou aumento do erro associado às previsões de base MM5 e WRF, redução generalizada do erro para as previsões de base WRF-ST5 e ALADIN, aumento generalizado do erro associado aos dados de PERS.

Na Fig. 47 está representado o valor de MAE (M-1 a M-5) e de RMSE (R-1 a R-5) para os vários *time-steps*. Analisando a Fig. 47, verifica-se que o valor de MAE calculado para um determinado *time-step* é inferior ao valor calculado de RMSE para o mesmo *time-step*, o que era expectável devido diferença do cálculo para obter os valores de MAE (Equação 20) e RMSE (Equação 19).

Observando-se a Fig. 47 verifica-se o expectável, anteriormente referidos, com recurso a análise da Fig. 46. Assim, na Fig. 47 verifica-se que o tratamento MOS3 conseguiu melhorar em média de forma pouco significativa as previsões de base MM5 e WRF, conseguiu melhorar de forma significativa as previsões de base WRF-ST5 e ALADIN, não conseguiu melhorar os dados de PERS.

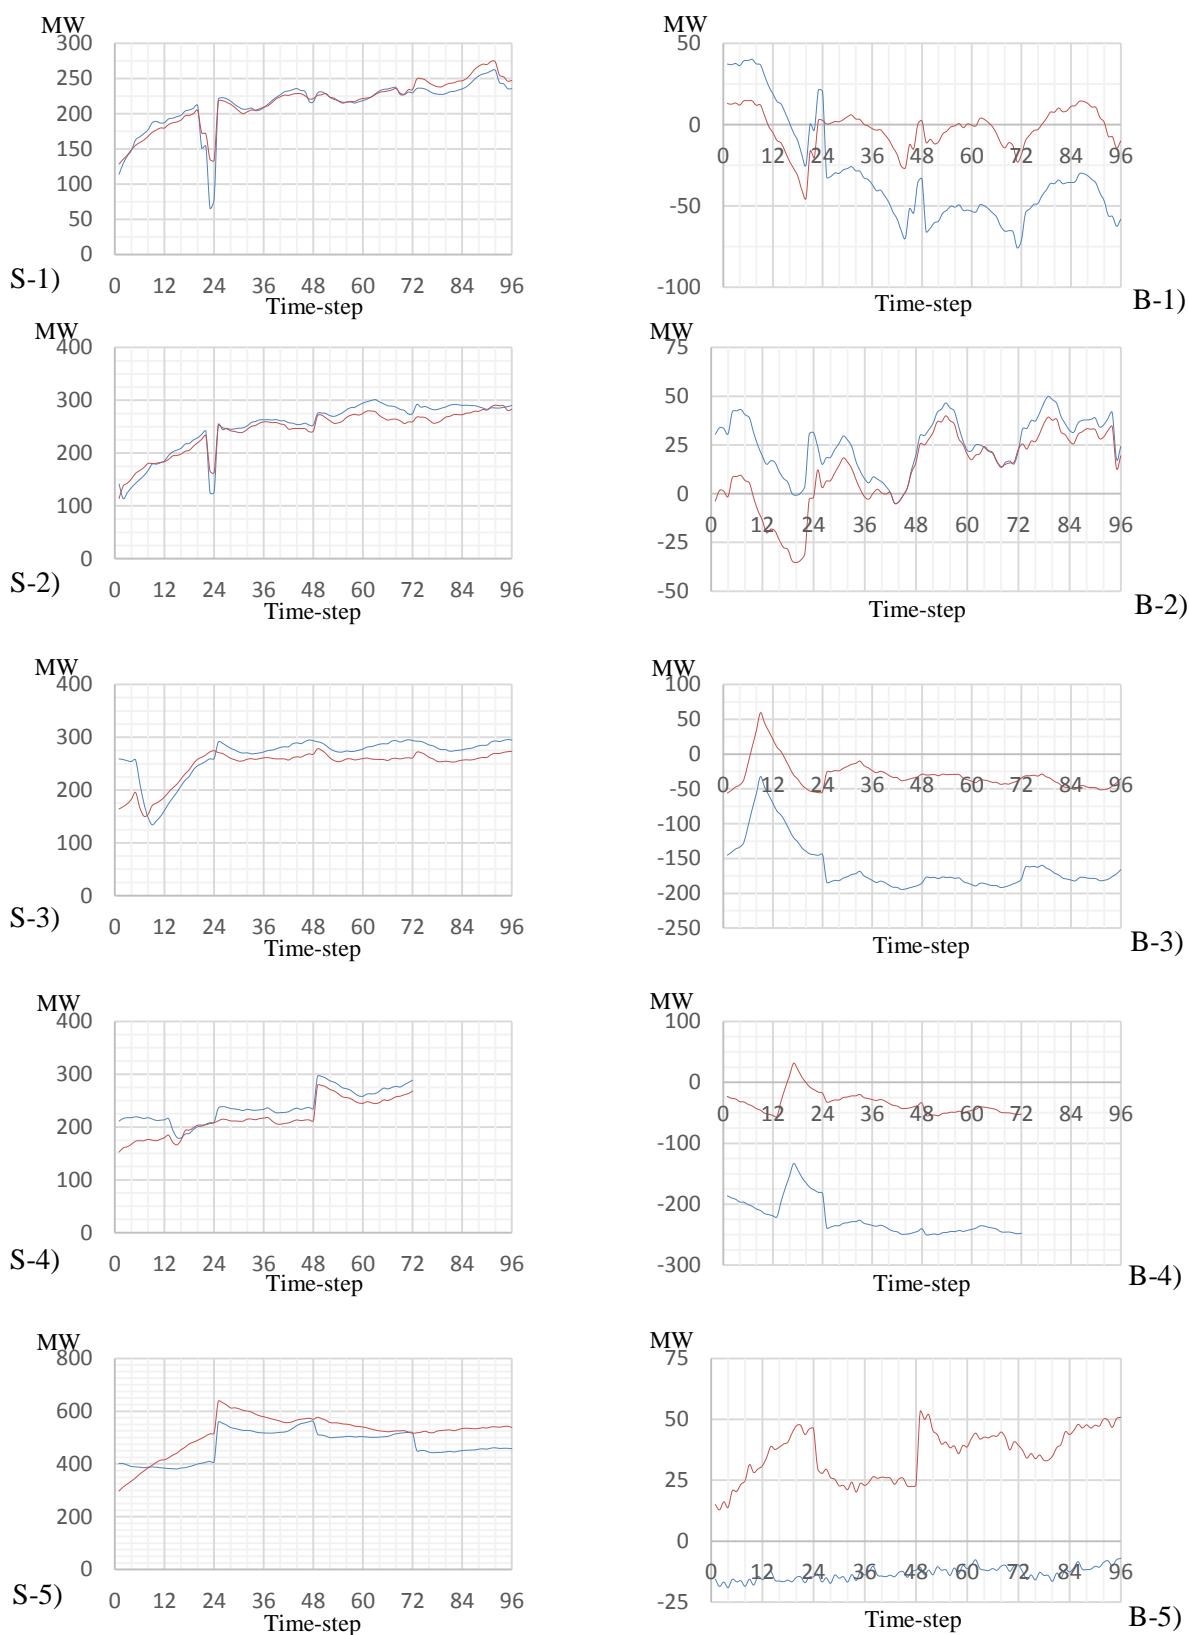


Fig. 46 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS3 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS3; -2) WRF e WRF-MOS3; -3) WRF-STC e WRF-STC-MOS3; -4) ALADIN e ALADIN-MOS3; -5) PERS e PERS-MOS3.

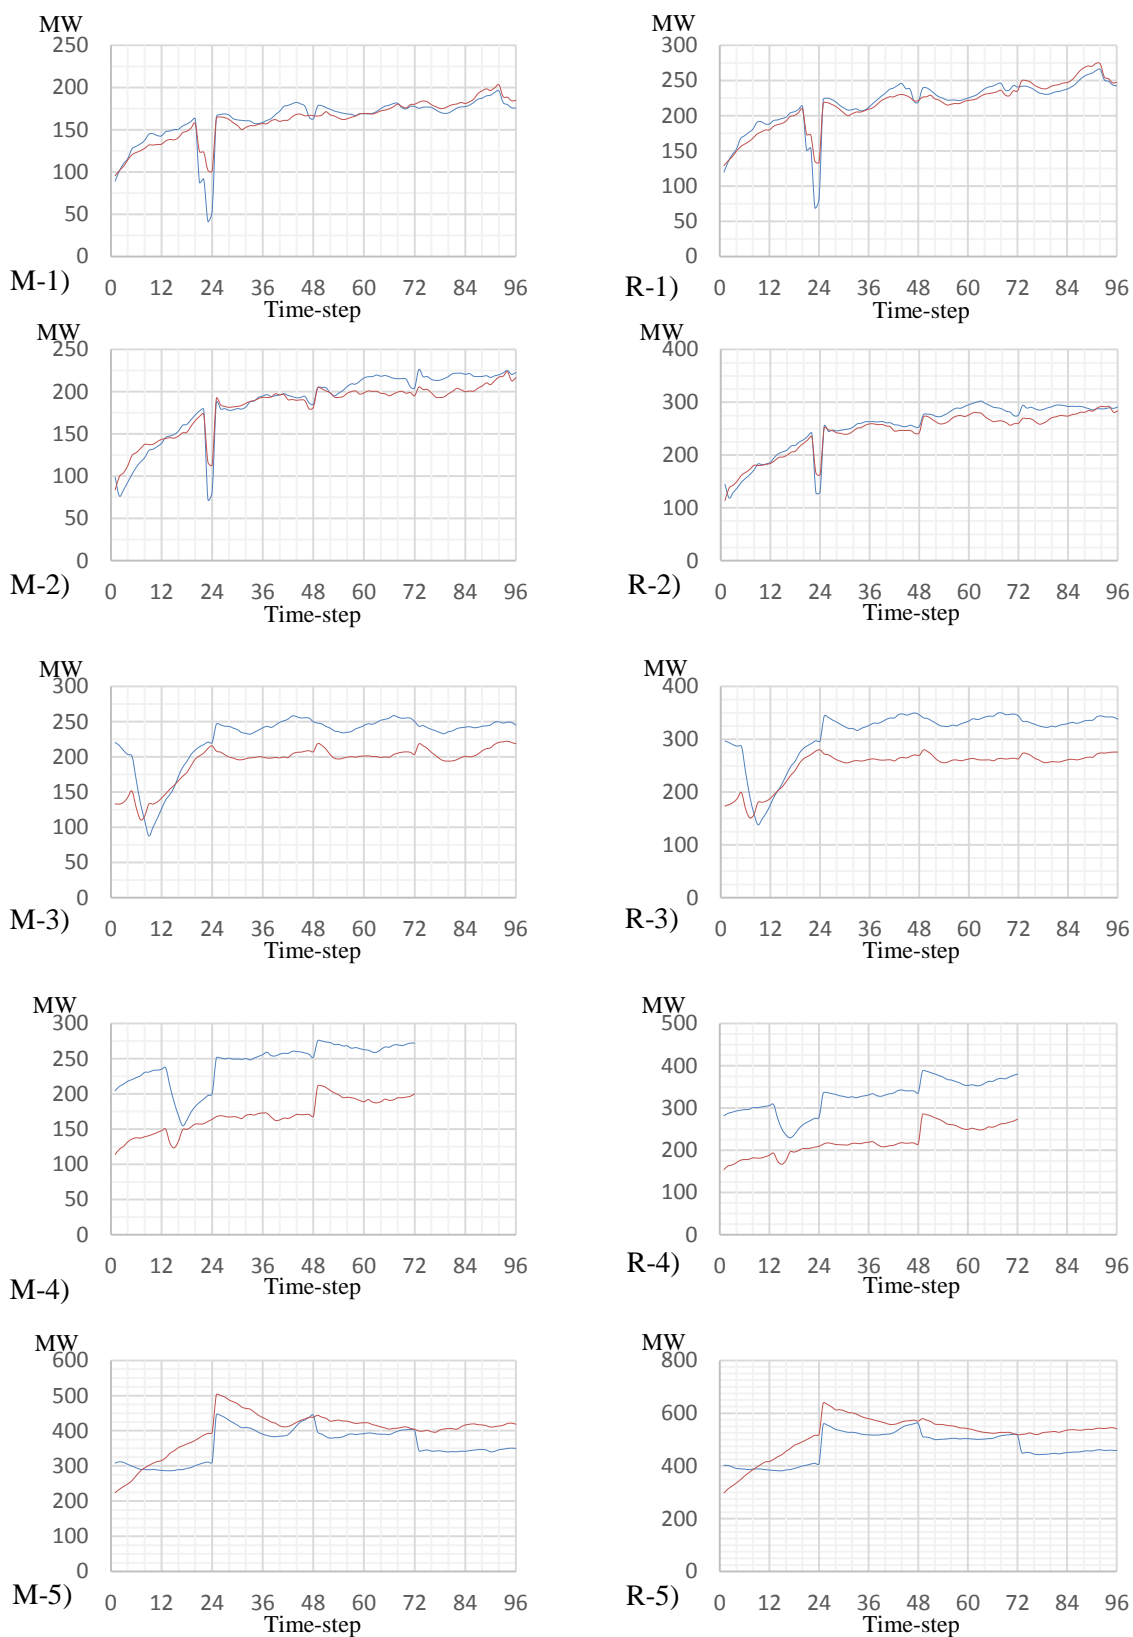


Fig. 47 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS3 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS3; -2) WRF e WRF-MOS3; -3) WRF-STC e WRF-STC-MOS3; -4) ALADIN e ALADIN-MOS3; -5) PERS e PERS-MOS3.

5.1.4 REGRESSÃO QUANTÍLICA ADAPTATIVA (MOS4)

A implementação do modelo desenvolvido baseado na regressão quantílica é um processo que tem como objectivo aproximar a distribuição de densidade de probabilidade da série de dados á distribuição de densidade de probabilidade da série das observações (conforme abordado no capítulo 4.3.1.).

Neste sentido, foi efectuado um estudo, com as variações presentes no anexo A, por forma a avaliar as vantagens ao aplicar a regressão quantílica adaptativa à série de dados. No presente capítulo estão expostos os resultados obtidos para o período de validação com recurso á metodologia adoptada a qual recorre a janelas móveis de dimensão variável, em função do horizonte temporal. O presente método de tratamento de dados encontra-se representado pela terminologia MOS4.

5.1.4.1 DESCRIÇÃO ESTATÍSTICA

Tabela 39- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 00-06hr.

	MM5-MOS4	MM5	WRF-MOS4	WRF	WRF-STS-MOS4	WRF-STS	ALADI N-MOS4	ALADI N	PERS-MOS4	PERS
\bar{E}	-60,06	6,63	-56,39	17,44	-154,87	-138,76	-225,10	-219,24	-86,74	-17,93
\bar{E}	31,80	14,65	31,10	14,80	-43,90	-82,73	-123,60	-178,65	-31,00	-22,50
Moda	123,00	-20,00	67,50	20,00	97,10	-28,00	-464,00	-66,00	110,50	-330,10
As ₁	-183,06	26,63	-123,89	-2,56	-251,97	-110,76	238,90	-153,24	-197,24	312,17
σ	411,11	185,27	420,49	192,46	404,45	227,80	381,25	216,68	510,93	391,21
Var	1,7E+05	3,4E+04	1,8E+05	3,7E+04	1,6E+05	5,2E+04	1,5E+05	4,7E+04	2,6E+05	1,5E+05
K	0,16	0,20	0,15	0,20	0,24	0,28	0,25	0,30	0,24	0,25
As ₂	-0,67	-0,13	-0,62	0,04	-0,82	-0,74	-0,80	-0,56	-0,33	0,04
Min	-1881,10	-642,60	-1881,10	-982,90	-1881,10	-1048,85	-1881,10	-953,80	-1881,10	-1328,60
Max	857,60	700,80	863,60	721,20	545,20	334,70	562,50	490,00	1200,30	1436,20
Q ₁	-119,10	-82,78	-124,30	-79,05	-302,30	-283,56	-382,50	-368,36	-351,50	-268,50
Q ₃	144,70	98,63	147,40	101,25	105,90	38,95	19,60	-38,38	235,10	203,90
P ₉₀	310,42	224,41	336,62	255,83	207,48	99,50	129,02	19,00	500,94	445,31
P ₁₀	-535,84	-222,64	-546,98	-195,99	-647,90	-470,22	-675,90	-528,08	-730,58	-493,13
$\rho_{x,y}$	0,66	0,94	0,66	0,93	0,60	0,93	0,64	0,93	0,43	0,71

Analisando a Tabela 39 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 40, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu algumas alterações, verificando-se um degradação da forma da distribuição do erro para as previsões de base MM5, WRF e dados de PERS relativamente às previsões de base WRF-STS e ALADIN verifica-se uma ligeira melhoria. Por outro lado observa-se que em módulo o valor da média aumenta para as previsões de base MM5, WRF, WRF-STS, ALADIN e para os dados de PERS. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este diminuiu as previsões de base MM5, WRF, WRF-STS, ALADIN e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor aumentou para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este teve um aumento substancial para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS.

Tabela 40- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 00-06hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	415,47	Aumenta
MM5		Positiva	Simétrica	Leptocúrtica			185,39	
WRF-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	424,25	Aumenta
WRF		Negativa	Simétrica	Leptocúrtica			193,25	
WRF-STS-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	433,09	Aumenta
WRF-STS		Negativa	Moderada	Platicúrtica			266,73	
ALADIN-MOS4	Aumenta	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	442,74	Aumenta
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	518,24	Aumenta
PERS		Positiva	Simétrica	Leptocúrtica			391,62	

Tabela 41- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 06-12hr.

	MM5-MOS4	MM5	WRF-MOS4	WRF	WRF-STS-MOS4	WRF-STS	ALADIN-MOS4	ALADIN	PERS-MOS4	PERS
\bar{E}	-113,18	-56,53	-74,66	6,21	-216,28	-226,92	-263,05	-219,24	-85,27	-18,47
\bar{E}	-31,20	-41,50	-7,10	-9,35	-116,50	-166,75	-183,10	-178,65	-41,00	-29,25
Moda	-5,00	-82,50	81,00	-8,50	-149,50	-627,60	-153,00	-66,00	36,00	-18,00
As ₁	-108,18	25,97	-155,66	14,71	-66,78	400,68	-110,05	-153,24	-121,27	-0,47
σ	414,73	243,81	440,72	267,63	413,07	289,26	381,51	216,68	597,03	525,94
Var	1,7E+05	5,9E+04	1,9E+05	7,2E+04	1,7E+05	8,4E+04	1,5E+05	4,7E+04	3,6E+05	2,8E+05
K	0,17	0,23	0,19	0,23	0,29	0,33	0,24	0,30	0,26	0,24
As ₂	-0,59	-0,18	-0,46	0,17	-0,72	-0,62	-0,63	-0,56	-0,22	0,06
Min	-1881,10	-820,50	-1881,10	-745,00	-1881,10	-1085,90	-1881,10	-953,80	-1881,10	-1674,40
Max	974,00	662,10	1005,70	960,70	520,90	329,90	477,20	490,00	1369,90	1696,00
Q ₁	-219,40	-196,90	-200,30	-156,83	-440,20	-456,81	-430,90	-368,36	-464,10	-349,73
Q ₃	94,60	82,50	165,60	153,00	88,00	23,55	-22,10	-38,38	308,80	298,83
P ₉₀	307,04	256,00	373,40	362,33	178,62	95,61	108,42	19,00	661,02	675,21
P ₁₀	-623,14	-358,32	-585,22	-318,45	-729,92	-643,27	-732,04	-528,08	-849,52	-696,08
$\rho_{x,y}$	0,67	0,90	0,65	0,88	0,58	0,90	0,65	0,93	0,27	0,47

Analisando a Tabela 41 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 42, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS, ALADIN e dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média aumenta para as previsões de base MM5, WRF, ALADIN e para os dados de PERS e verifica-se que em módulo a média da previsão de base WRF-STS diminui de forma marginal. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este diminuiu de forma substancial para as previsões de base MM5, WRF, WRF-STS, ALADIN e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor aumentou para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este teve um aumento substancial para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS.

Tabela 42- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 06-12hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	429,90	Aumenta
MM5		Positiva	Moderada	Leptocúrtica			250,28	
WRF-MOS4	Aumenta	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	447,00	Aumenta
WRF		Positiva	Moderada	Leptocúrtica			267,70	
WRF-ST5-MOS4	Diminui	Negativa	Moderada	Platicúrtica	Aumenta	Diminui	466,27	Aumenta
WRF-ST5		Positiva	Moderada	Platicúrtica			367,65	
ALADIN-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	463,41	Aumenta
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	603,09	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			526,26	

Tabela 43- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 12-18hr.

	MM5-MOS4	MM5	WRF-MOS4	WRF	WRF-ST5-MOS4	WRF-ST5	ALADIN-MOS4	ALADIN	PERS-MOS4	PERS
\bar{E}	-132,58	-71,38	-68,77	19,57	-216,35	-230,03	-268,23	-284,75	-85,43	-21,96
\bar{E}	-53,20	-58,25	-5,10	-5,45	-109,80	-159,63	-176,40	-236,90	-26,70	-7,60
Moda	17,50	-11,00	126,00	34,00	-27,50	-186,00	-113,00	-56,00	-383,50	290,20
As ₁	-150,08	-60,38	-194,77	-14,43	-188,85	-44,03	-155,23	-228,75	298,07	-312,16
σ	410,44	247,91	452,21	294,62	413,81	294,91	406,66	277,21	574,45	504,12
Var	1,7E+05	6,1E+04	2,0E+05	8,7E+04	1,7E+05	8,7E+04	1,7E+05	7,7E+04	3,3E+05	2,5E+05
K	0,17	0,23	0,17	0,22	0,29	0,32	0,26	0,30	0,27	0,26
As ₂	-0,58	-0,16	-0,42	0,25	-0,77	-0,72	-0,68	-0,52	-0,31	-0,09
Min	-1881,10	-849,60	-1881,10	-760,10	-1881,10	-1055,50	-1881,10	-1592,80	-1881,10	-1335,00
Max	855,10	784,70	1139,90	1062,40	584,70	391,70	598,30	336,55	1434,30	1557,10
Q ₁	-235,10	-215,20	-195,50	-159,00	-443,40	-465,99	-471,30	-471,46	-459,70	-354,65
Q ₃	75,60	66,93	161,90	182,05	80,30	17,14	-7,90	-61,94	293,10	301,83
P ₉₀	274,34	228,50	416,16	429,46	181,58	95,52	135,42	20,10	572,42	583,79
P ₁₀	-643,22	-380,62	-624,38	-344,92	-736,64	-657,97	-760,02	-667,61	-824,96	-694,07
$\rho_{x,y}$	0,67	0,89	0,63	0,86	0,58	0,89	0,60	0,87	0,35	0,51

Analisando a Tabela 43 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 44, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5, ALADIN e dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média aumenta para as previsões de base MM5, WRF e para os dados de PERS e verifica-se que em módulo a média das previsões de base WRF-ST5 e ALADIN diminui. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este diminuiu de forma substancial para as previsões de base MM5, WRF, WRF-ST5, ALADIN e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor aumentou para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este teve um aumento substancial para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN) assim como para os dados de PERS.

Tabela 44- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 12-18hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	431,32	Aumenta
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOS4	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	457,41	Aumenta
WRF		Negativa	Moderada	Leptocúrtica			295,27	
WRF-ST5-MOS4	Diminui	Negativa	Moderada	Platicúrtica	Aumenta	Diminui	466,95	Aumenta
WRF-ST5		Negativa	Moderada	Platicúrtica			374,01	
ALADIN-MOS4	Diminui	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	487,15	Aumenta
ALADIN		Negativa	Moderada	Platicúrtica			397,40	
PERS-MOS4	Aumenta	Positiva	Moderada	Platicúrtica	Aumenta	Diminui	580,77	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			504,60	

Tabela 45- Descrição estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 18-24hr.

	MM5-MOS4	MM5	WRF-MOS4	WRF	WRF-ST5-MOS4	WRF-ST5	PERS-MOS4	PERS
\bar{E}	-126,87	-71,38	-59,52	19,57	-208,22	-230,03	-85,91	-284,75
\bar{E}	-47,80	-58,25	-4,00	-5,45	-99,20	-159,63	-32,50	-236,90
Moda	-154,50	-11,00	-108,00	34,00	-87,10	-186,00	99,40	-56,00
As ₁	27,63	-60,38	48,48	-14,43	-121,12	-44,03	-185,31	-228,75
σ	417,86	247,91	457,81	294,62	417,27	294,91	539,68	277,21
Var	1,7E+05	6,1E+04	2,1E+05	8,7E+04	1,7E+05	8,7E+04	2,9E+05	7,7E+04
K	0,16	0,23	0,19	0,22	0,28	0,32	0,24	0,30
As ₂	-0,57	-0,16	-0,36	0,25	-0,78	-0,72	-0,30	-0,52
Min	-1881,10	-849,60	-1881,10	-760,10	-1881,10	-1055,50	-1881,10	-1592,80
Max	839,70	784,70	1153,40	1062,40	632,70	391,70	1466,40	336,55
Q ₁	-222,80	-215,20	-212,70	-159,00	-437,50	-465,99	-384,90	-471,46
Q ₃	84,80	66,93	190,00	182,05	82,90	17,14	240,00	-61,94
P ₉₀	293,12	228,50	466,00	429,46	211,74	95,52	540,16	20,10
P ₁₀	-652,42	-380,62	-610,36	-344,92	-726,26	-657,97	-783,44	-667,61
$\rho_{x,y}$	0,66	0,89	0,63	0,86	0,57	0,89	0,40	0,87

Analisando a Tabela 45 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 46, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5 e dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média aumenta para as previsões de base MM5 e WRF verifica-se que em módulo a média das previsões de base WRF-ST5 e para os dados de PERS diminui. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este diminuiu de forma substancial para as previsões de base MM5, WRF, WRF-ST5 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor aumentou para todas as previsões de base (MM5, WRF e WRF-ST5) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este teve um aumento substancial para todas as previsões de base (MM5, WRF e WRF-ST5) assim como para os dados de PERS.

Tabela 46- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOS4 para o horizonte temporal 18-24hr.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE
MM5-MOS4	Aumenta	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	436,70
MM5		Negativa	Moderada	Leptocúrtica			257,98
WRF-MOS4	Aumenta	Positiva	Moderada	Leptocúrtica	Aumenta	Diminui	461,66
WRF		Negativa	Moderada	Leptocúrtica			295,27
WRF-ST5-MOS4	Diminui	Negativa	Moderada	Platicúrtica	Aumenta	Diminui	466,34
WRF-ST5		Negativa	Moderada	Platicúrtica			374,01
PERS-MOS4	Diminui	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	546,48
PERS		Negativa	Moderada	Platicúrtica			397,40

5.1.4.1 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

De modo a avaliar-se de que forma o tratamento de dados MOS4 modificou as séries de previsão fez-se uma descrição estatística do erro associado às séries de previsão. No entanto, estes apresentam valores em média, sendo que não se consegue ter uma noção de como o erro variou ao longo dos *time-steps* dos vários horizontes temporais. Assim, efectuou-se a avaliação do SDE (Fig. 48 S-1 a S-5), BIAS (Fig. 48 B-1 a B-5), MAE (Fig. 49 M-1 a M-5) e RMSE (Fig. 49 R-1 a R-5) para os vários *time-steps* considerados.

Com base na Fig. 48 verifica-se que o valor de viés (BIAS) é menor em módulo do que o SDE. Assim e segundo a relação descrita pela Equação 22 o SDE consiste a maior componente do erro. Tendo em conta as Fig. 48 S-1) a S-5) observa-se que o valor de SDE aumentou para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN), relativamente aos dados de PERS verifica-se que o valor se manteve para as primeiras 6 horas (primeiros 24 *time-steps*) e que após isto se verifica uma ligeira diminuição. Assim, este método (MOS4) com as variações efectuadas aparenta não ser vantajoso para tratar as previsões de base, sendo apenas vantajoso utilizar este método para tratar os dados de PERS. Tendo em conta os valores de BIAS (Fig. 48 B-1) a B-5)) observa-se que este valor após MOS4 foi inferior para as previsões de base WRF-ST5 e ALADIN, relativamente as previsões de base MM5, WRF e dados de PERS verifica-se que este método piorou os valores de viés. Assim será expectável na Fig. 49 observar uma redução e/ou aumento do erro associado aos dados de PERS, um aumento do erro associado às previsões de base MM5 e WRF, uma redução do erro associado às previsões de base WRF-ST5 e ALADIN.

Na Fig. 49 está representado o valor de MAE (M-1 a M-5) e de RMSE (R-1 a R-5) para os vários *time-steps*. Analisando a Fig. 49 verifica-se que o valor de MAE calculado para um determinado *time-step* é inferior ao valor calculado de RMSE para o mesmo *time-step*, o que era expectável devido diferença do cálculo para obter os valores de MAE (Equação 20) e RMSE (Equação 19).

Observando-se a Fig. 49 verifica-se o expectável, anteriormente referido, com recurso a análise da Fig. 48. Assim, na Fig. 49 verifica-se que o tratamento MOS4 não conseguiu melhorar as previsões de base MM5 e WRF, não conseguiu melhorar as previsões de base WRF-ST5, ALADIN e dados de PERS nas primeiras 6 horas conseguindo apenas melhorá-las de forma pouco significativa após as primeiras 6 horas.

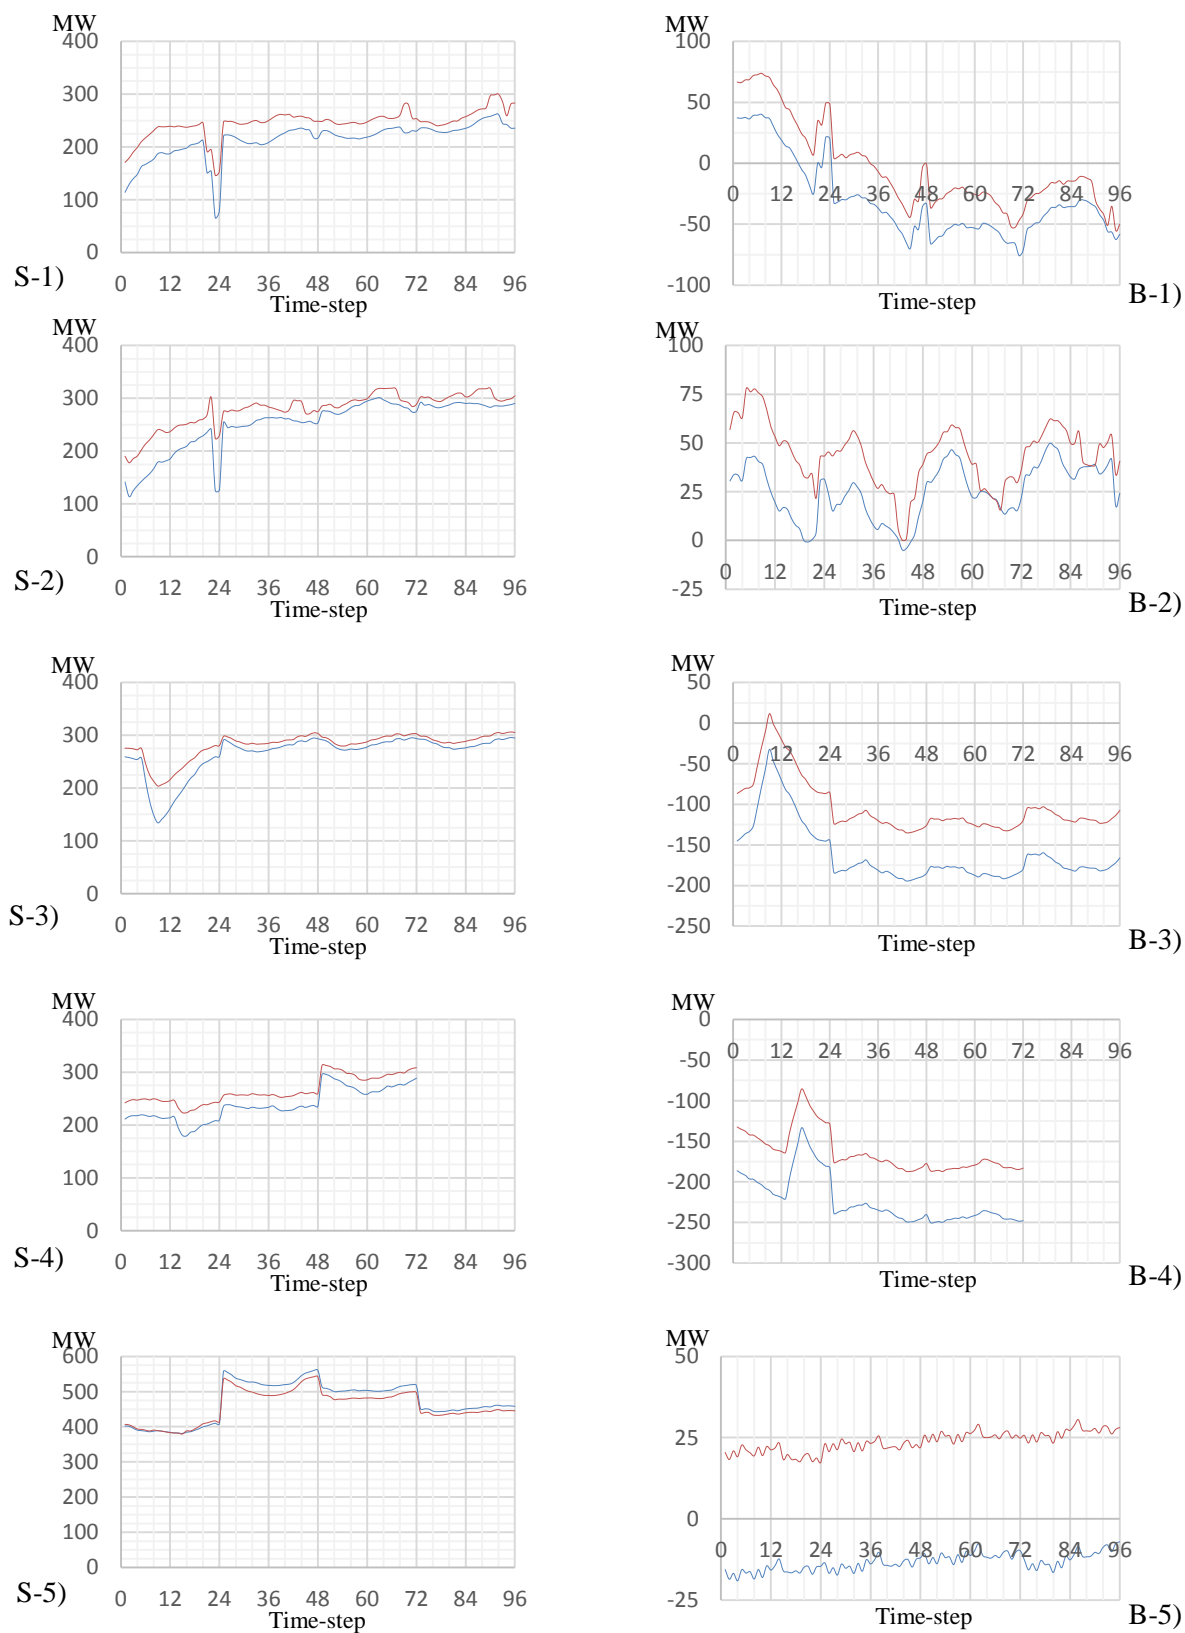


Fig. 48 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS4 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS4; -2) WRF e WRF-MOS4; -3) WRF-STC e WRF-STC-MOS4; -4) ALADIN e ALADIN-MOS4; -5) PERS e PERS-MOS4.

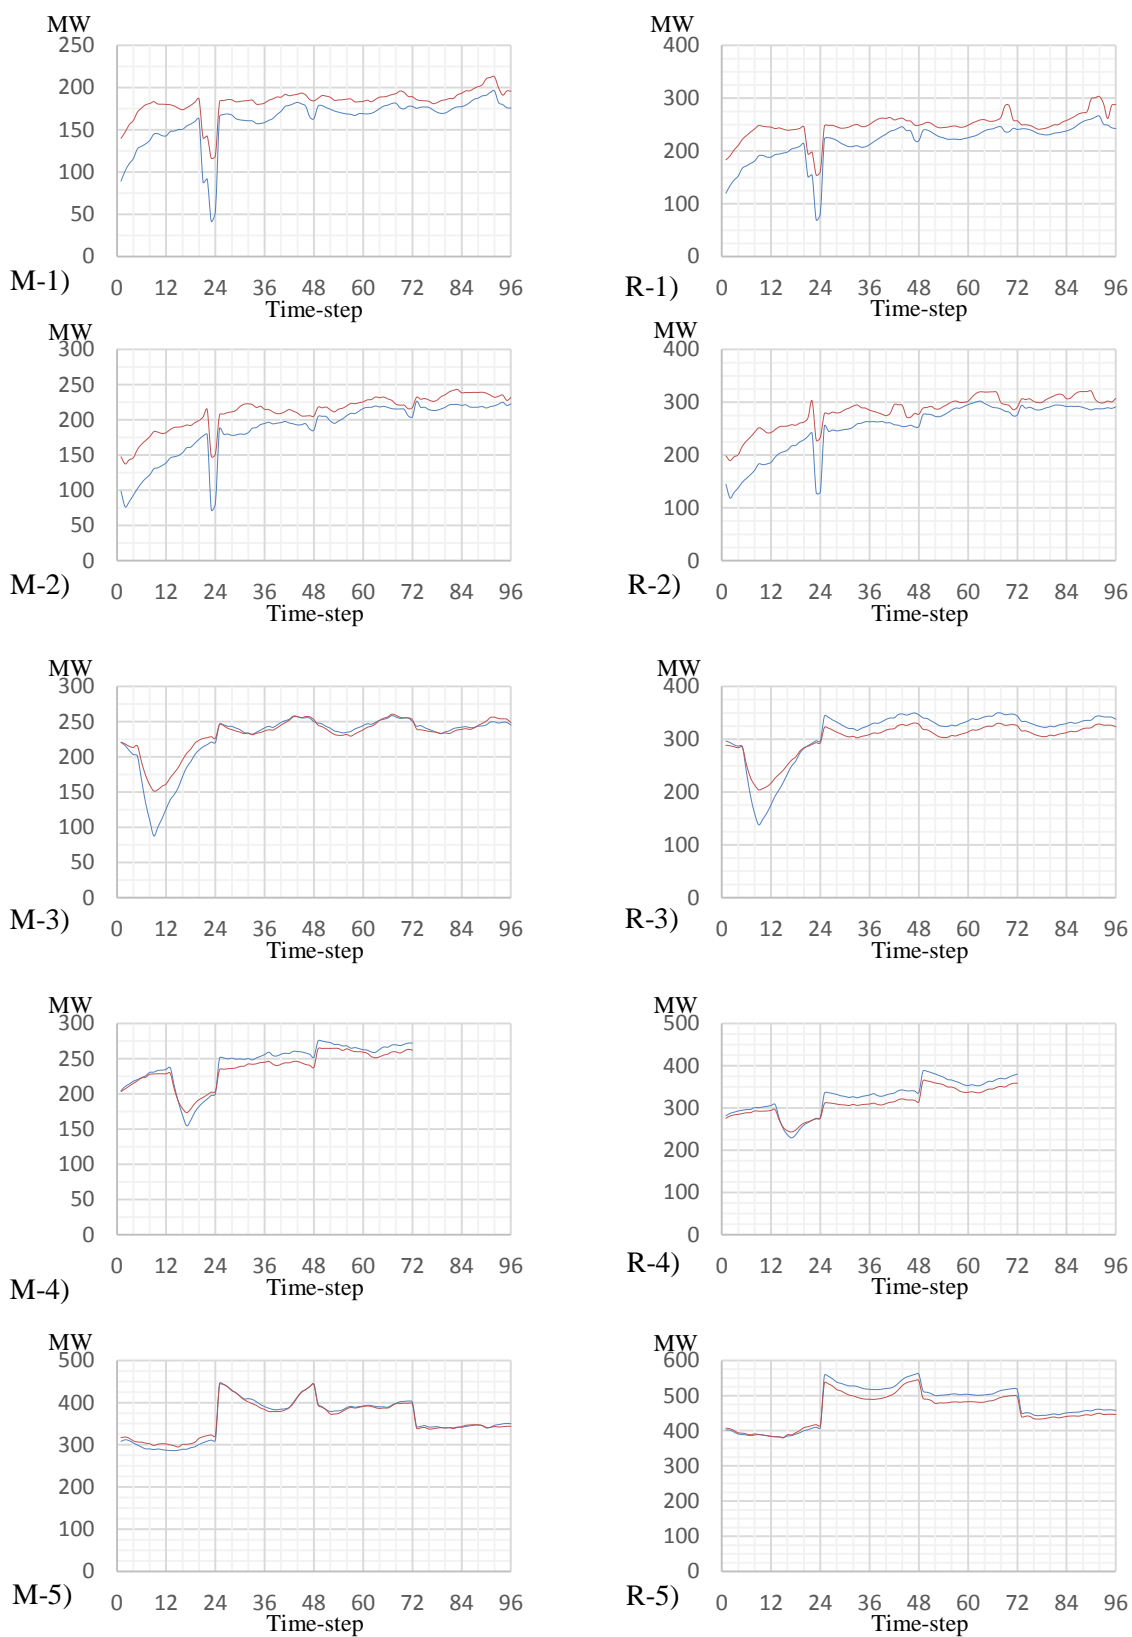


Fig. 49 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOS4 para o horizonte temporal 00-24hr. Na figura estão representadas as séries: -1) MM5 e MM5-MOS4; -2) WRF e WRF-MOS4; -3) WRF-STC e WRF-STC-MOS4; -4) ALADIN e ALADIN-MOS4; -5) PERS e PERS-MOS4.

5.1.5 COMBINAÇÃO DE TRATAMENTOS (MOSF)

Este método consiste no tratamento final e resulta da combinação dos tratamentos descritos anteriormente em 4.3.1., exceptuando a regressão quantílica adaptativa (MOS4). A combinação dos processos de tratamento anteriormente abordados resulta da melhor combinação obtida, das várias estudadas, para o período de validação. O modelo adoptado recorre ao tratamento com base no coeficiente de correlação de Pearson (MOS1), ao tratamento com recurso á média móvel (MOS2) e à previsão adaptativa do viés (MOS3). Os quais são utilizados de forma consecutiva para originar o MOSF, conforme descrito em 4.3.1.

Para identificar qual a melhor metodologia para combinar os vários métodos foram analisadas várias metodologias (ver anexo A), sendo que a metodologia adoptada é referente aquela que melhor desempenho alcançou com base na medida de avaliação RMSE em média no período de validação. Os resultados expostos no presente capítulo são referentes ao desempenho alcançado pela metodologia adoptada no período de validação e teste. Sendo que, a série de previsão após tratamento é representada pela terminologia MOSF.

5.1.5.1 DESCRIÇÃO ESTATÍSTICA

Tal como anteriormente referido em 4.2.1. os dados foram subdivididos em três intervalos distintos (calibração, validação e teste) por forma a garantir a independência destes e avaliar correctamente os vários módulos. Assim, os modelos foram calibrados no período de calibração, validados no período de validação e testada a sua robustez no período de teste. Assim, optou-se por analisar os resultados obtidos com recurso ao módulo de tratamento de dados (módulo MOSF) no período de validação e comparar com os resultados obtidos no período de teste por forma a avaliar a sua robustez.

- Período de validação

Tabela 47- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de validação.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-STS-MOSF	WRF-STS	ALADI N-MOSF	ALADI N	PERS-MOSF	PERS
\bar{E}	-26,49	6,63	-21,78	17,44	-16,55	-138,76	-17,57	-219,24	-11,99	-17,93
\bar{E}	-17,41	14,65	-19,63	14,80	-2,86	-82,73	-1,44	-178,65	-22,54	-22,50
Moda	47,20	-20,00	54,90	20,00	3,07	-28,00	-6,10	-66,00	3,60	-330,10
As ₁	-73,69	26,63	-76,68	-2,56	-19,62	-110,76	-11,47	-153,24	-15,59	312,17
σ	163,34	185,27	167,93	192,46	198,61	227,80	188,66	216,68	384,80	391,21
Var	2,7E+04	3,4E+04	2,8E+04	3,7E+04	3,9E+04	5,2E+04	3,6E+04	4,7E+04	1,5E+05	1,5E+05
K	0,23	0,20	0,22	0,20	0,21	0,28	0,23	0,30	0,24	0,25
As ₂	-0,17	-0,13	-0,04	0,04	-0,21	-0,74	-0,26	-0,56	0,08	0,04
Min	-664,17	-642,60	-947,75	-982,90	-853,85	-1048,85	-690,15	-953,80	-1175,26	-1328,60
Max	700,80	700,80	665,18	721,20	549,55	334,70	627,89	490,00	1331,05	1436,20
Q ₁	-108,23	-82,78	-107,71	-79,05	-119,33	-283,56	-130,98	-368,36	-248,52	-268,50
Q ₃	62,37	98,63	63,46	101,25	98,95	38,95	96,86	-38,38	205,51	203,90
P ₉₀	150,18	224,41	169,28	255,83	229,86	99,50	223,20	19,00	451,91	445,31
P ₁₀	-216,41	-222,64	-226,16	-195,99	-282,78	-470,22	-268,21	-528,08	-488,34	-493,13
$\rho_{x,y}$	0,95	0,94	0,95	0,93	0,93	0,93	0,93	0,93	0,73	0,71

Analisando a Tabela 47 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 48, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS, ALADIN e dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média aumenta para as previsões de base MM5, WRF e verifica-se que em módulo a média das previsões de base WRF-STS, ALADIN e para os dados de PERS diminui. Tendo em conta o valor de $\rho_{x,y}$, observa-

se que este aumenta para as previsões de base MM5, WRF e para os dados de PERS, já as restantes previsões de base (WRF-STS e ALADIN) observa-se que este valor se mantém. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE, verifica-se que este diminuiu para todas as séries de previsão avaliadas (MM5, WRF, WRF-STS, ALADIN e PERS).

Tabela 48- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de validação.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	165,47	Diminui
MM5		Positiva	Simétrica	Leptocúrtica			185,39	
WRF-MOSF	Aumenta	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	169,34	Diminui
WRF		Negativa	Simétrica	Leptocúrtica			193,25	
WRF-STS-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	199,30	Diminui
WRF-STS		Negativa	Moderada	Platicúrtica			266,73	
ALADIN-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	189,48	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	384,99	Diminui
PERS		Positiva	Simétrica	Leptocúrtica			391,62	

Tabela 49- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de validação.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-STS-MOSF	WRF-STS	ALADI N-MOSF	ALADI N	PERS-MOSF	PERS
\bar{E}	-46,36	-56,53	-31,73	6,21	-64,01	-226,92	-17,21	-219,24	-11,43	-18,47
\hat{E}	-28,86	-41,50	-25,30	-9,35	-34,11	-166,75	-7,31	-178,65	-36,24	-29,25
Moda	-40,20	-82,50	40,70	-8,50	-288,95	-627,60	-83,00	-66,00	-3,00	-18,00
As ₁	-6,16	25,97	-72,43	14,71	224,94	400,68	65,79	-153,24	-8,43	-0,47
σ	212,54	243,81	237,32	267,63	258,61	289,26	212,94	216,68	487,24	525,94
Var	4,5E+04	5,9E+04	5,6E+04	7,2E+04	6,7E+04	8,4E+04	4,5E+04	4,7E+04	2,4E+05	2,8E+05
K	0,22	0,23	0,25	0,23	0,28	0,33	0,24	0,30	0,23	0,24
As ₂	-0,25	-0,18	-0,08	0,17	-0,35	-0,62	-0,14	-0,56	0,15	0,06
Min	-818,48	-820,50	-764,61	-745,00	-814,36	-1085,90	-699,61	-953,80	-1391,51	-1674,40
Max	709,90	662,10	834,64	960,70	622,60	329,90	559,75	490,00	1682,30	1696,00
Q ₁	-160,10	-196,90	-182,82	-156,83	-256,74	-456,81	-146,37	-368,36	-316,71	-349,73
Q ₃	78,07	82,50	112,98	153,00	110,14	23,55	119,52	-38,38	266,83	298,83
P ₉₀	208,26	256,00	257,72	362,33	258,35	95,61	250,98	19,00	650,06	675,21
P ₁₀	-342,70	-358,32	-345,66	-318,45	-405,94	-643,27	-311,89	-528,08	-615,96	-696,08
$\rho_{x,y}$	0,92	0,90	0,90	0,88	0,88	0,90	0,91	0,93	0,54	0,47

Analisando a Tabela 49 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 50, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS e ALADIN foi bastante semelhante antes e após tratamento, já para os dados de PERS verifica-se uma ligeira melhoria. Por outro lado observa-se que em módulo o valor da média aumenta para a previsão de base WRF e verifica-se que em módulo a média das previsões de base MM5, WRF-STS, ALADIN e para os dados de PERS diminui. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para as previsões de base MM5, WRF e para os dados de PERS, já as restantes previsões de base (WRF-STS e ALADIN) observa-se que este valor diminui. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE, verifica-se que este diminuiu para todas as séries de previsão avaliadas (MM5, WRF, WRF-STS, ALADIN e PERS).

Tabela 50- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de validação.

	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	217,54	Diminui
MM5		Positiva	Moderada	Leptocúrtica			250,28	
WRF-MOSF	Aumenta	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	239,43	Diminui
WRF		Positiva	Moderada	Leptocúrtica			267,70	
WRF-ST5-MOSF	Diminui	Positiva	Moderada	Platicúrtica	Diminui	Diminui	266,41	Diminui
WRF-ST5		Positiva	Moderada	Platicúrtica			367,65	
ALADIN-MOSF	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Diminui	213,63	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			308,25	
PERS-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	487,37	Diminui
PERS		Negativa	Simétrica	Leptocúrtica			526,26	

Tabela 51- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de validação.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-ST5-MOSF	WRF-ST5	ALADI N-MOSF	ALADI N	PERS-MOSF	PERS
\bar{E}	-18,81	-71,38	-0,32	19,57	-38,08	-230,03	-49,40	-284,75	-29,48	-21,96
\bar{E}	-21,98	-58,25	-20,97	-5,45	-19,99	-159,63	-29,53	-236,90	-26,13	-7,60
Moda	-189,70	-11,00	-143,70	34,00	-151,95	-186,00	-5,70	-56,00	508,20	290,20
As_1	170,89	-60,38	143,38	-14,43	113,87	-44,03	-43,7	-228,75	-537,68	-312,16
σ	227,67	247,91	271,09	294,62	266,36	294,91	252,16	277,21	470,84	504,12
Var	5,2E+04	6,1E+04	7,3E+04	8,7E+04	7,1E+04	8,7E+04	6,4E+04	7,7E+04	2,2E+05	2,5E+05
K	0,22	0,23	0,22	0,22	0,24	0,32	0,25	0,30	0,26	0,26
As_2	0,04	-0,16	0,23	0,25	-0,20	-0,72	-0,24	-0,52	-0,02	-0,09
Min	-751,55	-849,60	-828,77	-760,10	-775,15	-1055,50	-1307,80	-1592,80	-1435,96	-1335,00
Max	859,66	784,70	985,20	1062,40	747,74	391,70	571,57	336,55	1417,50	1557,10
Q_1	-150,55	-215,20	-158,34	-159,00	-209,06	-465,99	-182,90	-471,46	-356,69	-354,65
Q_3	105,30	66,93	143,62	182,05	123,99	17,14	117,66	-61,94	275,40	301,83
P_{90}	279,58	228,50	360,74	429,46	303,35	95,52	246,87	20,10	579,90	583,79
P_{10}	-295,95	-380,62	-327,51	-344,92	-392,19	-657,97	-359,14	-667,61	-620,37	-694,07
$\rho_{x,y}$	0,91	0,89	0,87	0,86	0,86	0,89	0,88	0,87	0,56	0,51

Analisando a Tabela 51 efectuou-se uma síntese dos resultados obtidos mais relevantes na Tabela 52 por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5, ALADIN e para os dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média aumenta para os dados de PERS e verifica-se que em módulo a média diminui quando se trata das previsões de base MM5, WRF, WRF-ST5, ALADIN. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para as previsões de base MM5, WRF, ALADIN e para os dados de PERS, sendo que para a previsão de base WRF-ST5 observa-se que este valor diminui. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE, verifica-se que este diminuiu para todas as séries de previsão avaliadas (MM5, WRF, WRF-ST5, ALADIN e PERS).

Tabela 52- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de validação.

	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	228,45	Diminui
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOSF	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Aumenta	271,09	Diminui
WRF		Negativa	Moderada	Leptocúrtica			295,27	
WRF-ST5-MOSF	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Diminui	269,07	Diminui
WRF-ST5		Negativa	Moderada	Platicúrtica			374,01	
ALADIN-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	256,95	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			397,40	
PERS-MOSF	Aumenta	Negativa	Simétrica	Mesocúrtica	Diminui	Aumenta	471,76	Diminui
PERS		Negativa	Simétrica	Mesocúrtica			504,60	

Tabela 53- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de validação.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-ST5-MOSF	WRF-ST5	PERS-MOSF	PERS
\bar{E}	-5,86	-71,38	4,61	19,57	-22,36	-230,03	-31,67	-284,75
\tilde{E}	-7,52	-58,25	-6,04	-5,45	-14,79	-159,63	-24,72	-236,90
Moda	-45,20	-11,00	-2,30	34,00	-294,10	-186,00	-109,20	-56,00
As_1	39,34	-60,38	6,91	-14,43	271,74	-44,03	77,53	-228,75
σ	233,00	247,91	280,29	294,62	274,21	294,91	470,31	277,21
Var	5,4E+04	6,1E+04	7,9E+04	8,7E+04	7,5E+04	8,7E+04	2,2E+05	7,7E+04
K	0,24	0,23	0,23	0,22	0,24	0,32	0,26	0,30
As_2	0,02	-0,16	0,11	0,25	-0,08	-0,72	-0,04	-0,52
Min	-755,57	-849,60	-919,43	-760,10	-847,50	-1055,50	-1619,90	-1592,80
Max	878,40	784,70	983,25	1062,40	840,01	391,70	1607,10	336,55
Q ₁	-153,69	-215,20	-153,72	-159,00	-195,46	-465,99	-317,69	-471,46
Q ₃	120,76	66,93	165,42	182,05	138,41	17,14	271,95	-61,94
P ₉₀	281,01	228,50	361,97	429,46	331,15	95,52	523,55	20,10
P ₁₀	-289,08	-380,62	-342,52	-344,92	-376,89	-657,97	-605,69	-667,61
$\rho_{x,y}$	0,90	0,89	0,86	0,86	0,85	0,89	0,58	0,87

Analisando a Tabela 53 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 54, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, embora se observem ligeiras melhorias para todas as séries avaliadas, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5, ALADIN e para os dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média diminui para todas as séries avaliadas (previsões de base MM5, WRF, WRF-ST5 e dados de PERS). Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para a previsão de base MM5, mantém-se para a previsão de base WRF e que diminui para a previsão de base WRF-ST5 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF e WRF-ST5) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE, verifica-se que este diminuiu para todas as séries de previsão avaliadas (MM5, WRF e WRF-ST5), sendo a excepção os dados de PERS em que verifica um aumento substancial.

Tabela 54- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de validação.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Aumenta	233,07	Diminui
MM5		Negativa	Moderada	Leptocúrtica			257,98	
WRF-MOSF	Diminui	Positiva	Simétrica	Leptocúrtica	Diminui	Mantém-se	280,33	Diminui
WRF		Negativa	Moderada	Leptocúrtica			295,27	
WRF-ST5-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Diminui	275,12	Diminui
WRF-ST5		Positiva	Moderada	Platicúrtica			374,01	
PERS-MOSF	Diminui	Positiva	Simétrica	Mesocúrtica	Diminui	Diminui	471,38	Aumenta
PERS		Negativa	Moderada	Platicúrtica			397,40	

- Período de teste

Tabela 55- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de teste.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-ST5-MOSF	WRF-ST5	ALADI N-MOSF	ALADI N	PERS-MOSF	PERS
\bar{E}	-57,54	-33,79	-61,12	-41,38	-23,72	-195,10	-26,96	-214,27	-26,18	-28,26
\bar{E}	-30,70	-5,05	-32,59	-11,45	3,44	-138,15	-12,60	-159,20	6,91	7,70
Moda	-50,50	-50,50	-3,90	38,90	-93,70	67,70	-5,20	-49,50	9,90	64,00
As ₁	-7,04	16,71	-57,22	-80,28	69,98	-262,8	-21,76	-164,77	-36,08	-92,26
σ	176,69	193,82	172,78	190,26	205,06	268,45	184,17	228,19	316,26	316,62
Var	3,1E+04	3,7E+04	2,9E+04	3,6E+04	4,2E+04	7,2E+04	3,3E+04	5,2E+04	1,0E+05	1,0E+05
K	0,22	0,21	0,22	0,23	0,24	0,30	0,25	0,30	0,23	0,25
As ₂	-0,46	-0,44	-0,50	-0,47	-0,40	-0,64	-0,23	-0,72	-0,31	-0,34
Min	-807,59	-815,30	-822,23	-902,30	-874,20	-972,55	-732,20	-1025,80	-1582,35	-1564,70
Max	575,20	660,40	486,31	608,40	506,88	246,30	562,74	272,80	828,52	814,00
Q ₁	-144,32	-118,55	-144,63	-127,08	-144,18	-390,51	-140,16	-377,90	-204,98	-220,05
Q ₃	45,44	75,93	36,76	71,63	102,40	32,33	93,56	-31,45	160,11	169,05
P ₉₀	134,82	173,30	121,60	154,44	214,17	103,21	205,46	35,76	341,16	341,23
P ₁₀	-292,49	-289,46	-286,59	-284,36	-291,46	-594,51	-260,61	-532,93	-438,73	-438,24
$\rho_{x,y}$	0,97	0,96	0,97	0,96	0,95	0,95	0,96	0,95	0,89	0,89

Analisando a Tabela 55 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 56, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5, ALADIN e para os dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média diminui para as previsões de base WRF-ST5, ALADIN e dados de PERS, por outro lado observa-se que as previsões de base MM5 e WRF tiveram um aumento do módulo da média. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para a previsão de base MM5, WRF e ALADIN, este se mantém para a previsão de base WRF-ST5 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN) assim como para os dados de PERS. Tendo em conta o valor médio do RMSE, verifica-se que este diminuiu para todas as séries de previsão avaliadas (MM5, WRF, WRF-ST5, ALADIN e PERS).

Tabela 56- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 00-06hr no período de teste.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	185,82	Diminui
MM5		Positiva	Moderada	Leptocúrtica			196,75	
WRF-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	183,27	Diminui
WRF		Positiva	Moderada	Leptocúrtica			194,71	
WRF-STS-MOSF	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Mantém-se	206,43	Diminui
WRF-STS		Negativa	Moderada	Platicúrtica			331,86	
ALADIN-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	186,13	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			313,02	
PERS-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Mantém-se	317,35	Diminui
PERS		Negativa	Moderada	Leptocúrtica			317,88	

Tabela 57- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de teste.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-STS-MOSF	WRF-STS	ALADIN-MOSF	ALADIN	PERS-MOSF	PERS
\bar{E}	-76,65	-109,08	-73,29	-73,15	-138,92	-299,38	-33,77	-263,31	-60,28	-28,26
\bar{E}	-46,14	-66,00	-49,71	-44,55	-122,88	-253,23	-24,10	-209,65	-27,90	7,70
Moda	-1,90	62,00	20,50	33,00	115,00	13,10	36,45	-36,00	301,50	64,00
As ₁	-74,75	-171,08	-93,79	-106,15	-253,92	-312,48	-70,22	-227,31	-361,78	-92,26
σ	224,33	252,37	224,20	265,31	286,27	348,06	217,36	261,45	453,86	316,62
Var	5,0E+04	6,3E+04	5,0E+04	7,0E+04	8,2E+04	1,2E+05	4,7E+04	6,8E+04	2,0E+05	1,0E+05
K	0,23	0,24	0,22	0,20	0,30	0,35	0,25	0,30	0,24	0,25
As ₂	-0,41	-0,51	-0,32	-0,32	-0,17	-0,40	-0,13	-0,62	-0,21	-0,34
Min	-997,56	-971,40	-817,59	-910,40	-1055,05	-1084,80	-863,94	-1189,80	-1971,53	-1564,70
Max	660,15	679,70	737,73	815,10	693,09	390,30	583,82	292,10	1173,23	814,00
Q ₁	-190,51	-240,70	-193,47	-198,33	-346,31	-614,79	-180,82	-448,03	-308,38	-220,05
Q ₃	58,81	43,90	51,59	70,20	69,33	13,76	97,83	-46,55	211,27	169,05
P ₉₀	156,13	147,21	174,84	214,44	186,91	110,56	254,59	32,61	453,41	341,23
P ₁₀	-376,11	-442,03	-386,76	-456,16	-498,71	-776,66	-296,50	-631,02	-622,63	-438,24
$\rho_{x,y}$	0,94	0,93	0,94	0,92	0,93	0,94	0,95	0,93	0,77	0,89

Analisando a Tabela 57 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 58, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-STS e para os dados de PERS foi bastante semelhante antes e após tratamento, contrariamente a esta tendência foi a previsão de base ALADIN que teve uma ligeira melhoria. Por outro lado observa-se que em módulo o valor da média diminui para as previsões de base MM5, WRF-STS e ALADIN, por outro lado observa-se que a previsão de base WRF e dados de PERS tiveram um aumento do módulo da média. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para a previsão de base MM5, WRF e ALADIN, este diminui para a previsão de base WRF-STS e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-STS e ALADIN), contrariamente verifica-se que este valor aumenta para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este diminuiu para todas as previsões base (MM5, WRF, WRF-STS e ALADIN), por outro lado verifica-se que este valor aumentou para os dados de PERS.

Comparando o valor de $\rho_{x,y}$ para o horizonte temporal das 06-12hr para o período de validação e período de teste verifica-se uma elevada variabilidade deste valor, já que, para o período de validação o valor de $\rho_{x,y}$ foi determinado como sendo 0.47 e no período de teste $\rho_{x,y} = 0.89$. A variabilidade elevada pode dever-se ao facto de ambos os períodos analisados (validação e teste) serem demasiado reduzidos.

Tabela 58- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 06-12hr no período de teste.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	237,07	Diminui
MM5		Negativa	Moderada	Leptocúrtica			274,94	
WRF-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	235,87	Diminui
WRF		Negativa	Moderada	Leptocúrtica			275,21	
WRF-ST5-MOSF	Diminui	Negativa	Moderada	Platicúrtica	Diminui	Diminui	318,19	Diminui
WRF-ST5		Negativa	Moderada	Platicúrtica			459,10	
ALADIN-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	219,97	Diminui
ALADIN		Negativa	Moderada	Platicúrtica			371,06	
PERS-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	457,84	Aumenta
PERS		Negativa	Moderada	Leptocúrtica			317,88	

Tabela 59- Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de teste.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-ST5-MOSF	WRF-ST5	ALADIN-MOSF	ALADIN	PERS-MOSF	PERS
\bar{E}	-47,09	-107,66	-17,77	-68,96	-104,29	-308,07	-49,23	-250,28	-79,37	-29,81
\bar{E}	-23,03	-65,90	-15,49	-41,60	-93,23	-271,70	-27,19	-203,83	-25,67	-3,70
Moda	-76,40	-14,50	-15,40	9,00	174,87	-948,65	107,72	-535,00	8,00	-3,50
As ₁	29,31	-93,16	-2,37	-77,96	-279,16	640,58	-156,95	284,72	-87,37	-26,31
σ	249,61	281,62	254,55	300,82	306,36	363,09	251,07	275,76	547,93	546,18
Var	6,2E+04	7,9E+04	6,4E+04	9,0E+04	9,3E+04	1,3E+05	6,3E+04	7,6E+04	3,0E+05	2,9E+05
K	0,25	0,23	0,25	0,21	0,28	0,34	0,24	0,30	0,23	0,22
As ₂	-0,29	-0,44	-0,03	-0,27	-0,11	-0,30	-0,26	-0,51	-0,29	-0,14
Min	-1006,12	-1052,80	-996,18	-971,40	-1157,45	-1125,40	-914,17	-1189,60	-2065,30	-1911,30
Max	675,52	770,10	910,98	937,40	917,47	553,00	725,40	528,15	1487,50	1487,50
Q ₁	-186,88	-250,13	-160,97	-234,10	-291,98	-628,18	-213,84	-447,73	-356,00	-307,43
Q ₃	105,94	52,35	141,19	88,20	85,32	11,90	96,13	-45,15	225,57	266,75
P ₉₀	241,56	187,94	297,28	283,04	227,76	117,96	270,59	55,11	510,27	611,74
P ₁₀	-354,50	-478,85	-313,85	-487,01	-453,68	-810,02	-382,26	-611,99	-746,05	-700,36
$\rho_{x,y}$	0,93	0,91	0,93	0,90	0,90	0,93	0,93	0,92	0,66	0,67

Analisando a Tabela 59 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 60, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF, WRF-ST5, ALADIN e para os dados de PERS foi bastante semelhante antes e após tratamento. Por outro lado observa-se que em módulo o valor da média diminui para as previsões de base MM5, WRF-ST5 e ALADIN, por outro lado observa-se que a previsão de base WRF e dados de PERS tiveram um aumento do módulo da média. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para a previsão de base MM5, WRF e ALADIN, este diminui para a previsão de base WRF-ST5 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor diminuiu para todas as previsões de base (MM5, WRF, WRF-ST5 e ALADIN), contrariamente verifica-se que este valor aumenta para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este diminuiu para todas as previsões base (MM5, WRF, WRF-ST5 e ALADIN), por outro lado verifica-se que este valor aumentou para os dados de PERS.

Tabela 60- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 12-18hr no período de teste.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Aumenta	254,01	Diminui
MM5		Negativa	Moderada	Leptocúrtica			301,50	
WRF-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Diminui	Aumenta	255,17	Diminui
WRF		Negativa	Moderada	Leptocúrtica			308,62	
WRF-ST5-MOSF	Diminui	Negativa	Simétrica	Platicúrtica	Diminui	Diminui	323,63	Diminui
WRF-ST5		Positiva	Moderada	Platicúrtica			476,18	
ALADIN-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	255,86	Diminui
ALADIN		Positiva	Moderada	Platicúrtica			372,41	
PERS-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	553,65	Aumenta
PERS		Negativa	Simétrica	Leptocúrtica			546,99	

Tabela 61 - Descrição estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de teste.

	MM5-MOSF	MM5	WRF-MOSF	WRF	WRF-ST5-MOSF	WRF-ST5	PERS-MOSF	PERS
\bar{E}	-30,72	-103,88	-19,12	-56,79	-46,42	-304,07	-83,72	-25,22
\bar{E}	-14,77	-58,25	0,89	-5,45	-30,81	-159,63	-28,61	-236,90
Moda	5,00	-11,00	-52,50	34,00	-41,80	-186,00	28,50	-56,00
As ₁	-35,72	-92,88	33,38	-90,79	-4,62	-118,07	-112,22	30,78
σ	284,61	247,91	279,48	294,62	323,22	294,91	619,68	277,21
Var	8,1E+04	6,1E+04	7,8E+04	8,6E+04	1,0E+05	8,7E+04	3,8E+05	7,6E+04
K	0,25	0,23	0,23	0,22	0,23	0,32	0,20	0,30
As ₂	-0,17	-0,16	-0,21	0,25	-0,14	-0,72	-0,27	-0,52
Min	-1043,95	-849,60	-978,83	-760,10	-1211,30	-1055,50	-2085,82	-1592,80
Max	856,41	784,70	1020,23	1062,40	1111,06	391,70	1594,90	336,55
Q ₁	-192,87	-215,20	-157,71	-159,00	-210,18	-465,99	-378,94	-471,46
Q ₃	156,52	66,93	140,08	182,05	112,02	17,14	233,32	-61,94
P ₉₀	304,74	228,50	290,80	429,46	298,82	95,52	652,61	20,10
P ₁₀	-387,95	-380,62	-358,71	-344,92	-410,53	-657,97	-870,56	-667,61
$\rho_{x,y}$	0,92	0,89	0,92	0,86	0,88	0,89	0,57	0,87

Analisando a Tabela 61 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 62, por forma a facilitar a interpretação do processo de tratamento. Nesta verifica-se que a forma da distribuição do erro sofreu poucas alterações, observando-se que a forma da distribuição do erro para as previsões de base MM5, WRF e para os dados de PERS foi bastante semelhante antes e após tratamento, verificando-se uma ligeira melhoria para a previsão de base WRF-ST5. Por outro lado observa-se que em módulo o valor da média diminui para as previsões de base MM5, WRF e WRF-ST5, por outro lado observa-se os dados de PERS tiveram um aumento do módulo da média. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para a previsão de base MM5 e WRF, este diminui para a previsão de base WRF-ST5 e para os dados de PERS. Relativamente ao desvio padrão verifica-se que este valor diminuiu para as previsões de base MM5 e WRF, contrariamente verifica-se que este valor aumenta para a previsão de base WRF-ST5 e para os dados de PERS. Tendo em conta o valor médio do RMSE verifica-se que este diminuiu para as previsões base WRF e WRF-ST5, por outro lado verifica-se que este valor aumentou para a previsão de base MM5 e para os dados de PERS.

Tabela 62- Síntese da avaliação estatística das séries dos erros das previsões antes e após tratamento MOSF para o horizonte temporal 18-24hr no período de teste.

	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
MM5-MOSF	Diminui	Negativa	Moderada	Leptocúrtica	Diminui	Aumenta	286,26	Aumenta
MM5		Negativa	Moderada	Leptocúrtica			268,79	
WRF-MOSF	Diminui	Positiva	Moderada	Leptocúrtica	Diminui	Aumenta	280,13	Diminui
WRF		Negativa	Moderada	Leptocúrtica			300,04	
WRF-ST5-MOSF	Diminui	Negativa	Simétrica	Leptocúrtica	Aumenta	Diminui	326,54	Diminui
WRF-ST5		Negativa	Moderada	Platicúrtica			423,59	
PERS-MOSF	Aumenta	Negativa	Moderada	Leptocúrtica	Aumenta	Diminui	625,31	Aumenta
PERS		Positiva	Moderada	Platicúrtica			278,35	

5.1.5.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

De modo a avaliar-se de que forma o tratamento de dados MOSF modificou as séries de previsão fez-se uma descrição estatística do erro associado às previsões de base. No entanto, estes apresentam valores em média, sendo que não se consegue ter uma noção de como o erro variou ao longo dos vários *time-steps* que compõem os vários horizontes temporais. Assim, efectuou-se a avaliação do SDE (Fig. 50 S-1 a S-5), BIAS (Fig. 50 B-1 a B-5), MAE (Fig. 51 M-1 a M-5) e RMSE (Fig. 51 R-1 a R-5) para os vários *time-steps* considerados para o período de validação e uma avaliação do tratamento MOSF para o período de teste tendo em atenção os mesmos valores do erro SDE (Fig. 50 S-1 a S-5), BIAS (Fig. 50 B-1 a B-5), MAE (Fig. 51 M-1 a M-5) e RMSE (Fig. 51 R-1 a R-5). Isto tinha como objectivo avaliar o tratamento de dados para um período independente, por forma a analisar a viabilidade deste.

Com base na Fig. 50 verifica-se que o valor de viés (BIAS) é menor em módulo do que o SDE. Assim e segundo a relação descrita pela Equação 22 o SDE consiste a maior componente do erro. Tendo em conta a Fig. 50 S-1) a S-5) observa-se que com recurso ao tratamento MOSF se conseguiu reduzir ou manter o valor de SDE para todas as previsões de base. Por outro lado verifica-se que não foi eficaz em reduzir as anomalias sentidas para as previsões de base MM5 e WRF. No entanto verifica-se que conseguiu atenuar as anomalias associadas às previsões de base WRF-ST5, ALADIN e aos dados de PERS. Ainda recorrendo à Fig. 50 B-1) a B-5) verifica-se que de uma forma geral a diminuição do valor de SDE foi acompanhado por uma diminuição em módulo, do valor do viés (BIAS). Nestes, observa-se que a maior redução do viés foi obtida para as previsões de base WRF-ST5 e ALADIN, verifica-se também que este conseguiu melhorar o valor do viés para as restantes previsões de base (MM5 e WRF) para a maioria dos horizontes temporais analisados, conforme analisado nas Tabelas 47 a 62. Relativamente aos dados de PERS verifica-se que o valor do viés após MOSF teve uma ligeira diminuição para os horizontes 00-06hr e 06-12hr, por outro lado sofreu um ligeiro aumento desse mesmo valor para os horizontes temporais 12-18hr e 18-24hr. Tendo ainda em conta a mesma figura verifica-se que o tratamento MOSF conseguiu estabilizar o valor de viés associado às previsões de base WRF-ST5 e ALADIN.

Na Fig. 51 está representado o valor de MAE (M-1 a M-5) e de RMSE (R-1 a R-5) para os vários *time-steps*. Analisando a Fig. 51, verifica-se que o valor de MAE calculado para um determinado *time-step* é inferior ao valor calculado de RMSE para o mesmo *time-step*, o que era expectável devido diferença do cálculo para obter os valores de MAE (Equação 20) e RMSE (Equação 19).

Observando-se a Fig. 51 verifica-se que de uma forma geral ocorreu uma redução do valor de MAE e RMSE para os vários *time-steps*. Nestas observa-se que se conseguiu reduzir a anomalia do erro registada aquando da análise das previsões de base (capítulo 4.2.5) para as previsões de base WRF-ST5, ALADIN e dados de PERS, o mesmo não se verificou para as previsões de base MM5 e WRF que mantiveram uma anomalia em muito semelhante aquela descrita no mesmo capítulo.

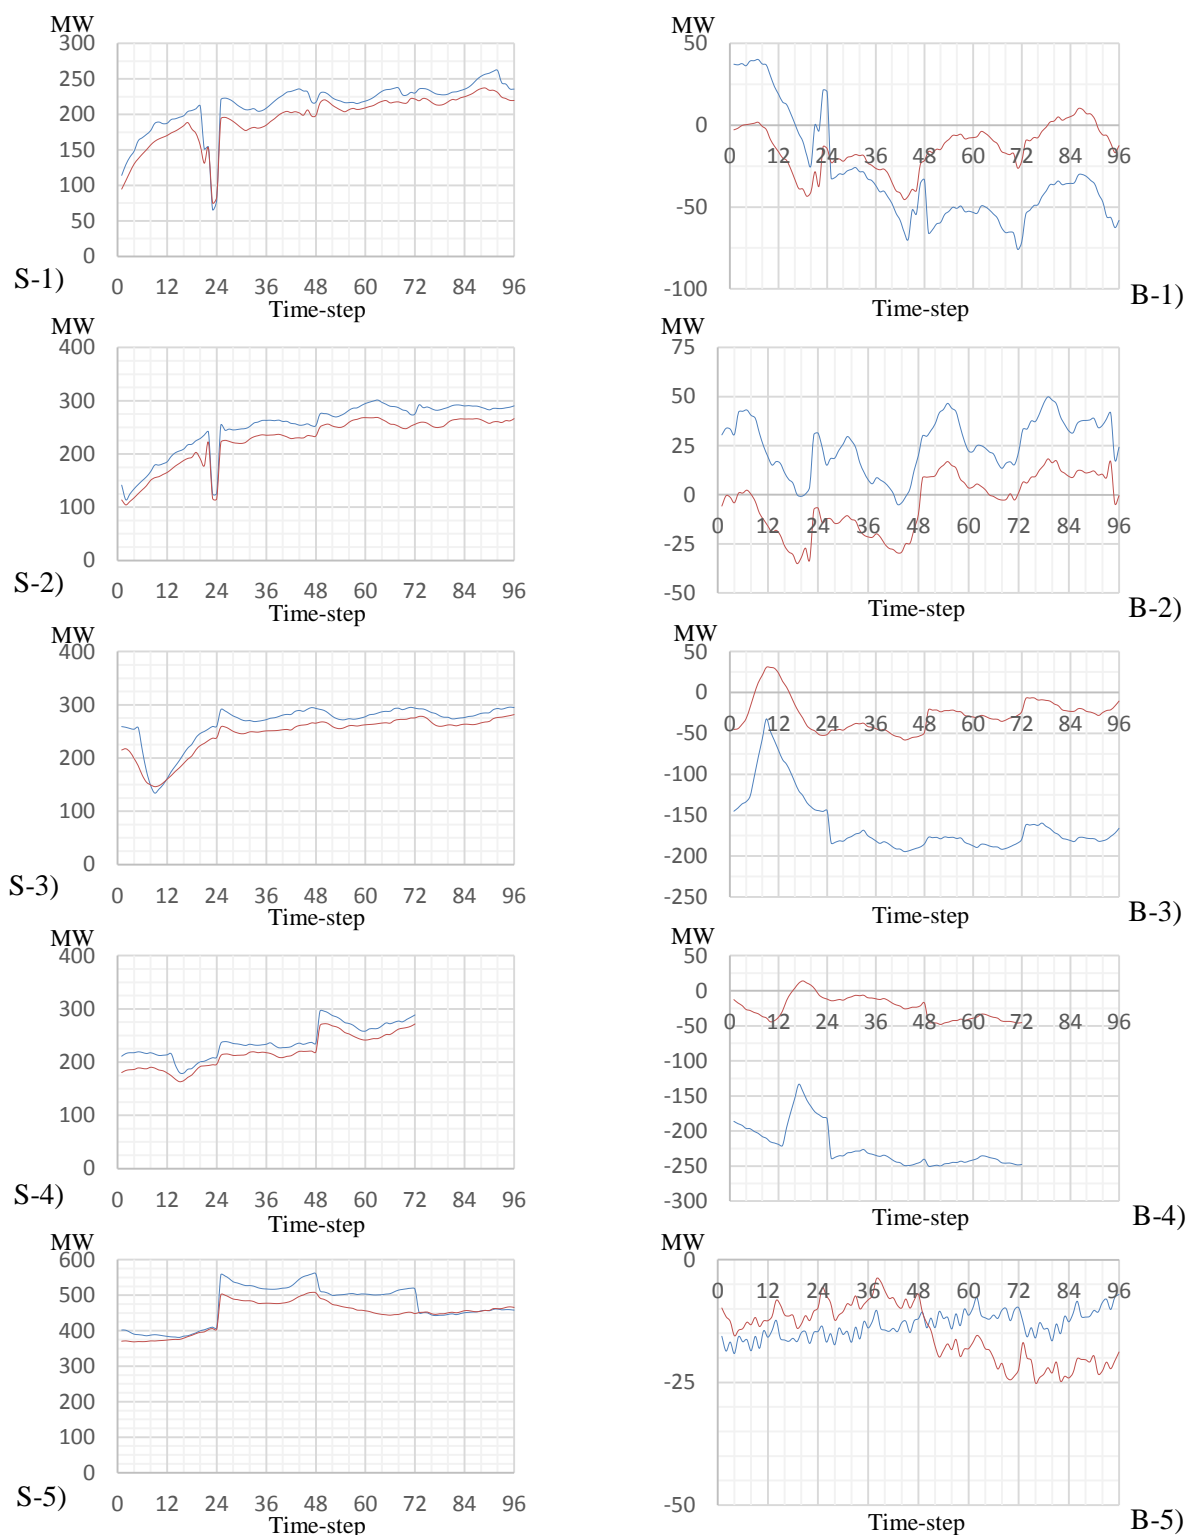


Fig. 50 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de validação. Na figura estão representadas as séries: -1) MM5 e MM5-MOSF; -2) WRF e WRF-MOSF; -3) WRF-STS e WRF-STS-MOSF; -4) ALADIN e ALADIN-MOSF; -5) PERS e PERS-MOSF.

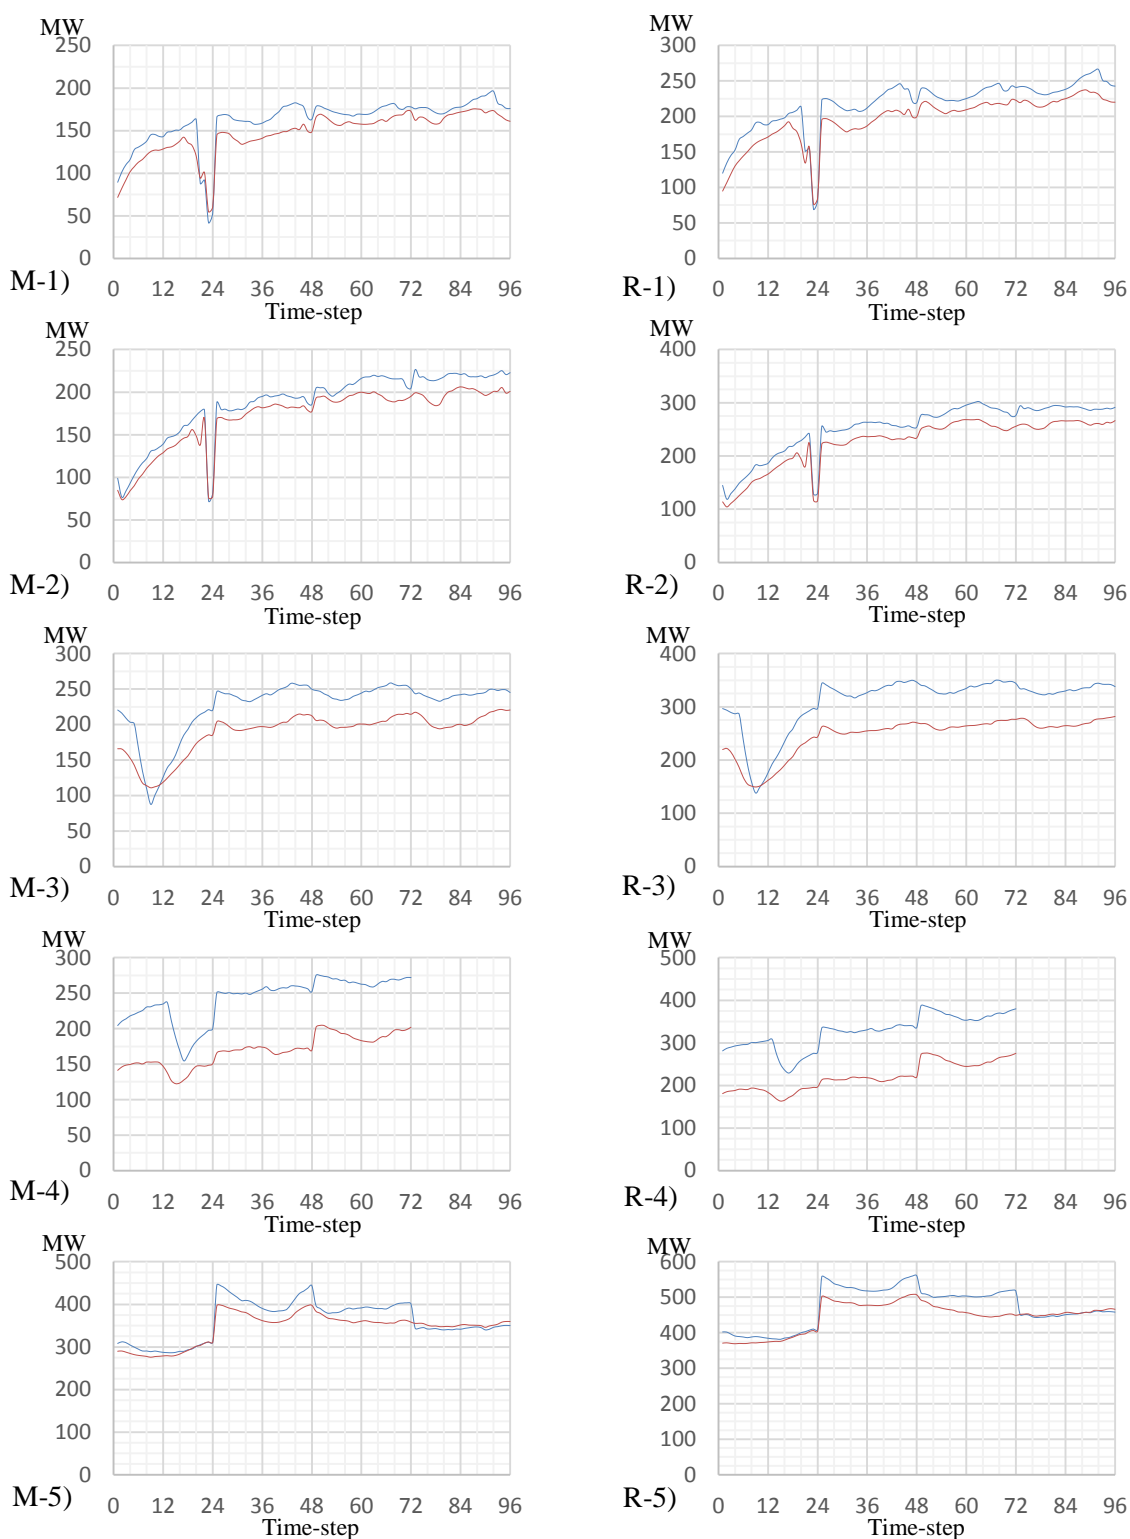


Fig. 51 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de validação. Na figura estão representadas as séries: -1) MM5 e MM5-MOSF; -2) WRF e WRF-MOSF; -3) WRF-STS e WRF-STS-MOSF; -4) ALADIN e ALADIN-MOSF; -5) PERS e PERS-MOSF.

As Fig. 52 e 53 são referentes às medidas SDE (Fig. 52 S-1 a S-5), BIAS (Fig. 52 B-1 a B-5), MAE (Fig. 53 M-1 a M-5) e RMSE (Fig. 53 R-1) a R-5)) associados às séries de previsão (MM5, WRF, WRF-STS, ALADIN e PERS) no período de teste.

Tal como anteriormente observado verifica-se que o SDE toma valores superiores ao BIAS (em módulo), assim sendo e tendo em conta a relação expressa pela Equação 22 verifica-se que esta medida consiste na maior componente do erro associado às séries de previsão de base e dados de PERS.

Tendo em conta a Fig. 52 S-1) a S-5) em que se encontra exposto o valor de SDE para as várias séries analisadas, verifica-se que se manteve a tendência anteriormente observada para o período de validação através da análise efectuada, com base na Fig. 50 S-1) a S-5), após tratamento MOSF. Por outro lado, analisando a Fig. 52 S-1) a S-5) observa-se que o valor de SDE para as previsões de base MM5 e WRF foi muito semelhante entre si mas diferente relativamente ao período de validação (Fig. 50). Sendo que isto também se verificou para as restantes previsões de base WRF-STs, ALADIN e dados de PERS.

Tendo em conta a Fig. 52 B-1) a B-5), observa-se que o tratamento MOSF nem sempre conseguiu reduzir, em módulo, o valor do viés, isto é evidente na observação das Fig. 52 B-1) e B-2) em que se verifica que para o horizonte temporal 00-06hr e na Fig. 52 B-5) em que se verifica que para os vários horizontes temporais (0-06hr, 06-12hr, 12-18hr e 18-24hr) não se conseguiu reduzir em módulo o valor do viés. Relativamente às Fig. 52 S-3) e S-4) observa-se que o tratamento MOSF foi eficaz para por um lado reduzir o valor de viés associado (em módulo), e por outro para suavizar a progressão do viés ao longo dos vários *time-steps*.

Relativamente à Fig. 53, verifica-se uma progressão do erro (MAE e RMSE) ao longo dos *time-steps* distinto daquele observado na Fig. 51 relativo ao período de calibração o que era expectável através da análise da Fig. 52 onde também aí se verificou uma progressão diferente do erro (SDE e BIAS) relativamente à Fig. 50. Analisando a Fig. 53 verifica-se que o tratamento MOSF conseguiu reduzir o erro associado (MAE e RMSE) às previsões de base MM5, WRF, WRF-STs e ALADIN para os vários horizontes temporais. Apesar de MOSF ter conseguido melhorar a qualidade das várias previsões de base o mesmo não se sucedeu para os dados de PERS que pouca alteração tiveram, verificando-se por vezes para um determinado *time-step* ligeiras melhorias e para outros uma ligeira degradação dos dados. Por outro lado, observa-se que relativamente às previsões de base a menor redução do erro foi obtida para o horizonte temporal 00-06hr e para os restantes horizontes temporais verifica-se que este conseguiu reduzir o erro de forma eficaz no período de teste para as previsões de base MM5 e WRF, tendo em conta as restantes previsões de base (WRF-STs e ALADIN) verifica-se que o tratamento MOSF conseguiu reduzir o erro associado a estas de forma eficaz para todos os horizontes temporais no período de teste.

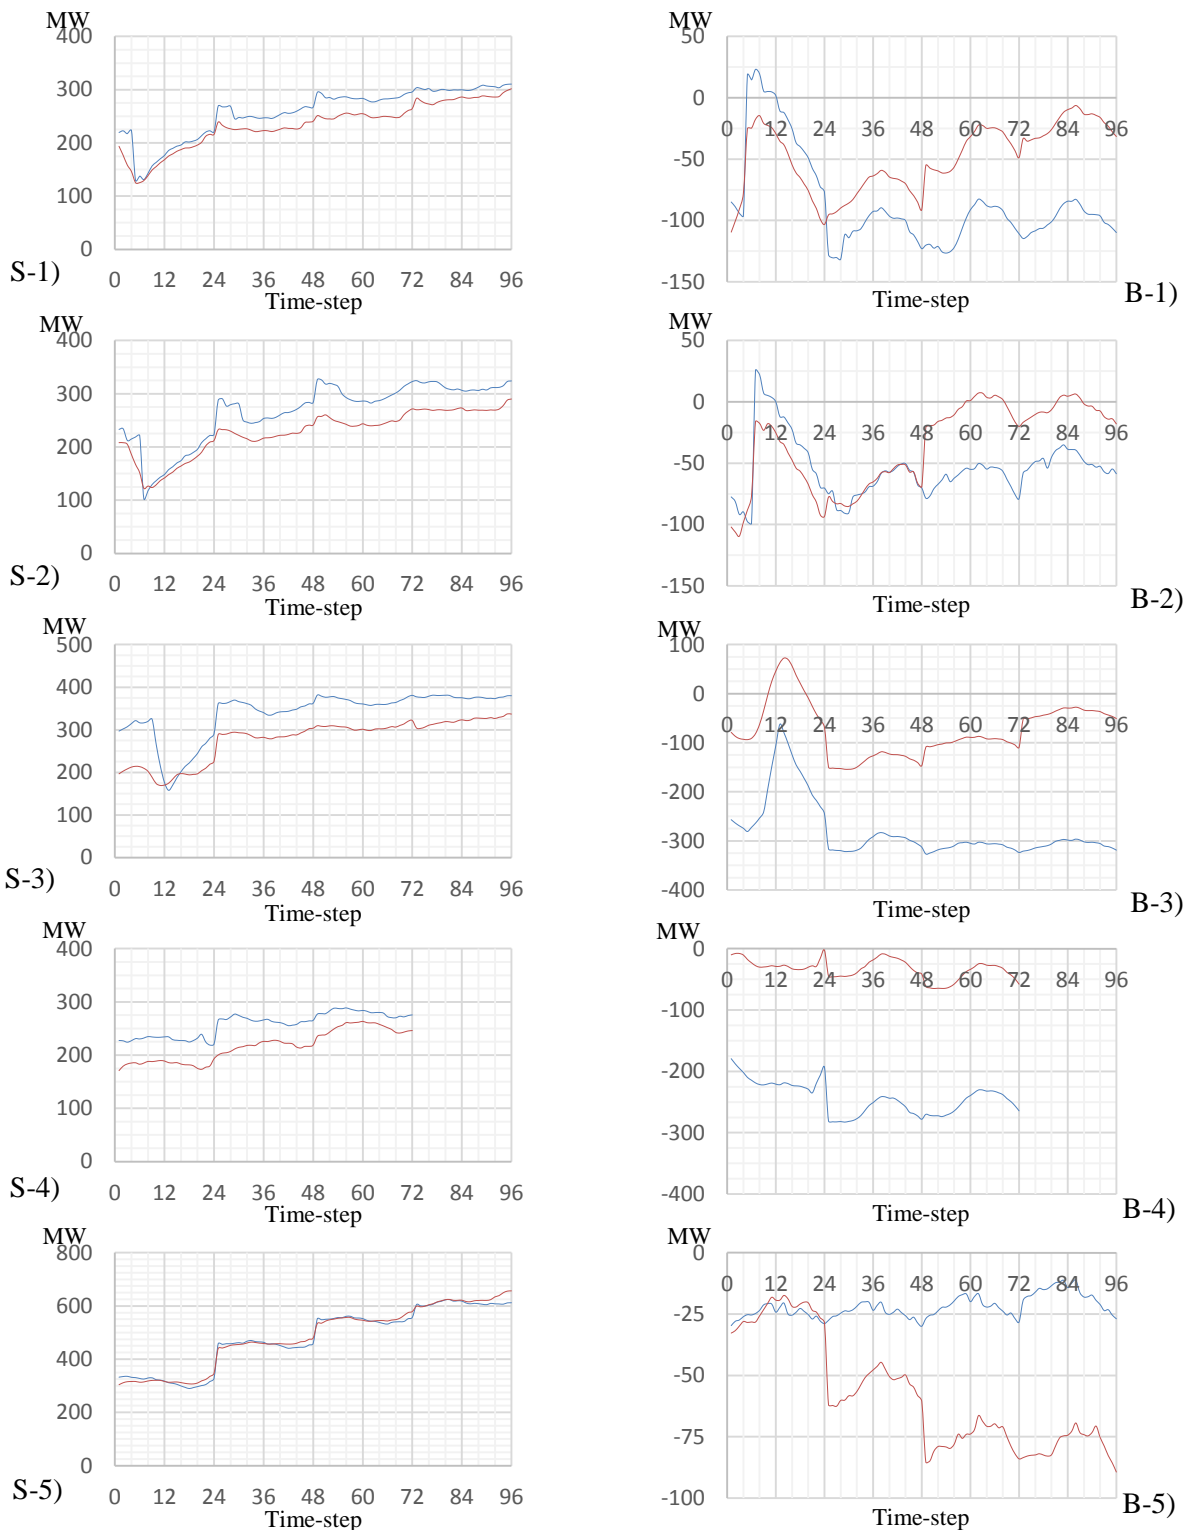


Fig. 52 – Gráfico do valor de SDE S) e BIAS B) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de teste. Na figura estão representadas as séries: -1) MM5 e MM5-MOSF; -2) WRF e WRF-MOSF; -3) WRF-STS e WRF-STS-MOSF; -4) ALADIN e ALADIN-MOSF; -5) PERS e PERS-MOSF.

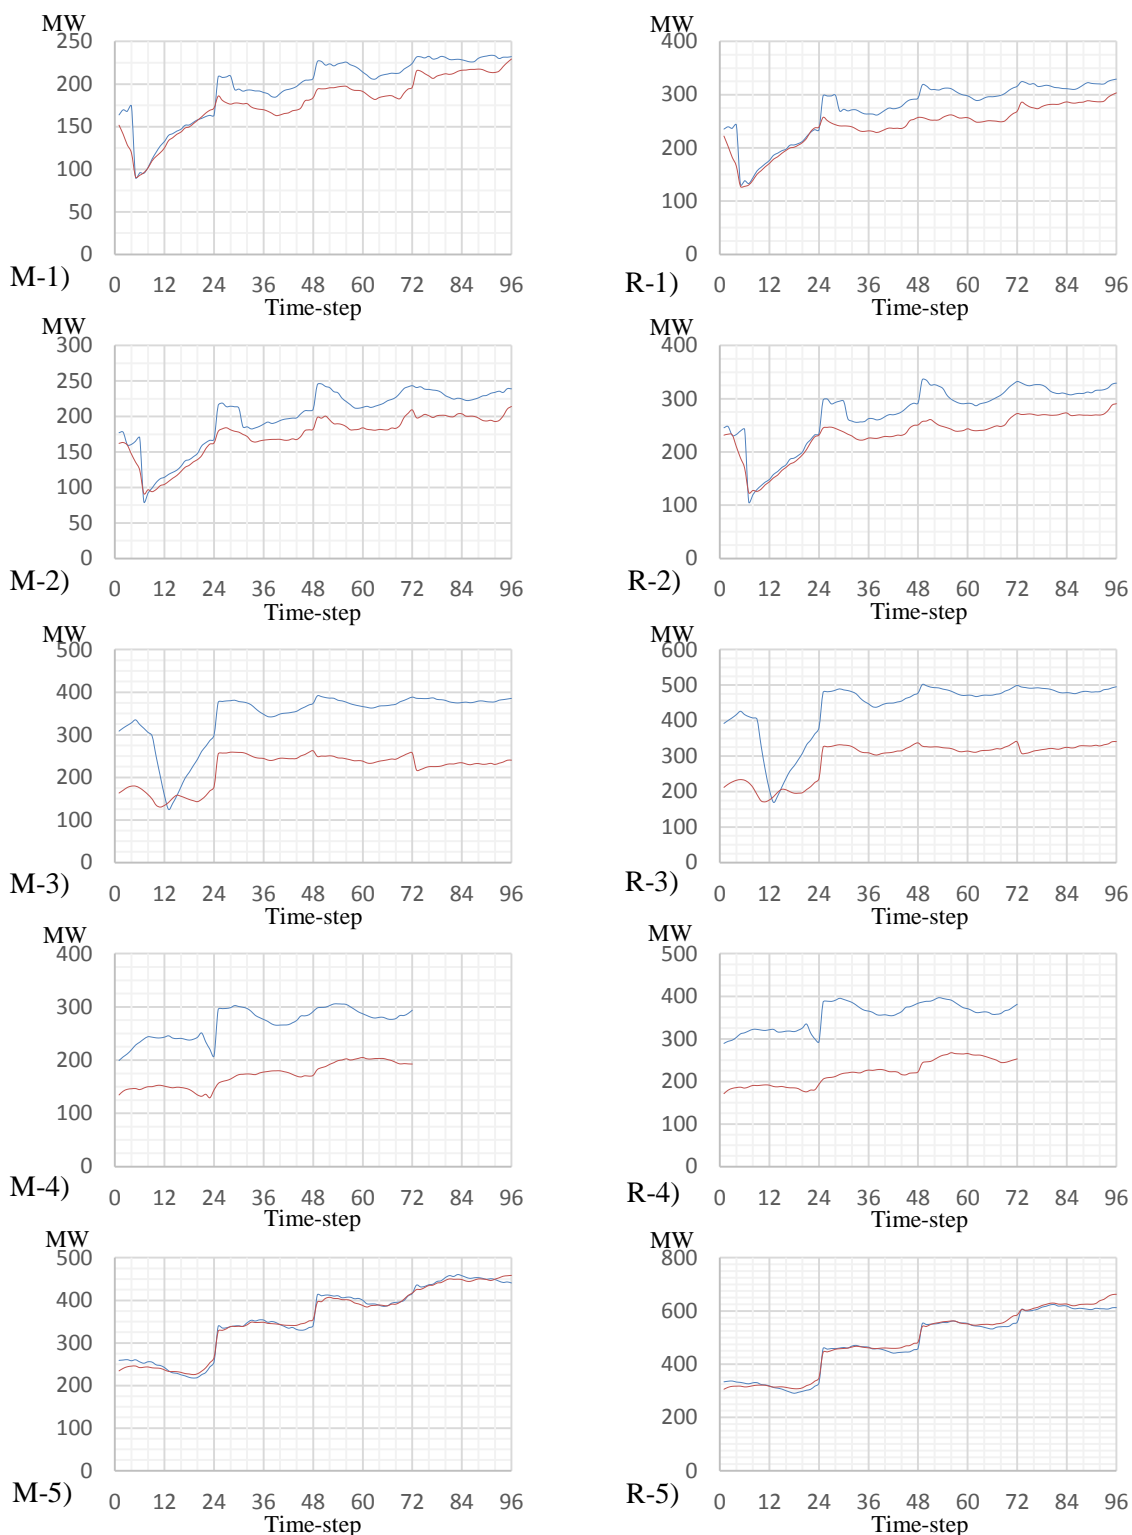


Fig. 53 – Gráfico do valor de MAE M) e RMSE R) das séries dos erros das previsões antes (azul) e após (vermelho) tratamento MOSF para o horizonte temporal 00-24hr no período de teste. Na figura estão representadas as séries: -1) MM5 e MM5-MOSF; -2) WRF e WRF-MOSF; -3) WRF-ST5 e WRF-ST5-MOSF; -4) ALADIN e ALADIN-MOSF; -5) PERS e PERS-MOSF.

5.2 PREVISÃO DE POTÊNCIA - MOSF+ALFA2 E ALFA1 (2ªFASE)

Conforme descrito no capítulo 4.3.2, é na segunda fase que se efectua um espectro de previsões possíveis combinando os vários predictores (previsões de base e dados de PERS) por forma a prever o predictante (METER ou SCADA).

Os resultados presentes neste capítulo são referentes à agregação dos vários modelos que compõem os módulos (SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4) do módulo ALFA1 e os módulos (SLR/MLR-3, SLR/MLR-4 e KF) do módulo ALFA2, além disso no presente capítulo são apresentados os resultados obtidos com recurso ao modelo STEPWISE-LR. A agregação dos vários modelos de cada módulo foi efectuada com recurso ao modelo MIX (uma variação do método *B. I.Tracking*) que foi introduzido no Capítulo 4.3.3.

Com o desenvolvimento dos módulos ALFA1 e ALFA2 pretendeu-se avaliar qual a viabilidade de aplicação de um sistema que recorre a diferentes períodos de calibração. Assim, o módulo ALFA1 teria como objectivo efectuar previsões para períodos imediatamente seguintes a períodos de carência (de dados necessários para efectuar as previsões) quando acontecem uma das 2 situações: 1) recorrem a enriquecimento de dados SCADA; 2) necessitam de previsões relativas a um passado recente por forma a calibrar os coeficientes regressivos. Nessas circunstâncias os modelos abrangidos por essas situações estariam mais vulneráveis, dada a sua funcionalidade de calibração dos coeficientes regressivos com recurso a uma série de dados relativos a um passado recente. O módulo ALFA2 teria como objectivo efectuar previsões de uma forma adaptativa com recurso a actualização dos coeficientes regressivos e com recurso a actualizações de dados SCADA. Por outro lado, pretendia-se avaliar se para horizontes temporais mais longos o módulo ALFA1 era mais preciso do que o módulo ALFA2, isto porque os valores de SCADA podem não ser uma mais-valia para calibrar, avaliar e determinar a combinação do melhor modelo para todos os horizontes temporais conforme referido por [23]. Finalmente, pretendeu-se avaliar qual o limite a partir do qual o enriquecimento com recurso a dados de SCADA deixaria de ser vantajoso.

5.2.1 ALFA1

Os resultados expostos no presente capítulo são referentes à agregação dos vários modelos que compõem os módulos SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4, com recurso à variação do modelo *B.I. Tracking* que se deu o nome de MIX (conforme descrito no capítulo 4.3), após isto os modelos foram avaliados para os períodos de validação e de teste.

O módulo ALFA1 é composto por variações do método de regressão linear podendo ser regressão linear simples (SLR) e/ou regressão linear múltipla (MLR), dependendo da combinação de predictores (MM5, WRF e PERS). Os coeficientes calculados pelos modelos que compõem o módulo ALFA1 são calibrados com recurso a uma janela móvel/fixa, de dimensão fixa, de dados equivalentes a um ano de dados históricos. Por outro lado, existe outra variação que permite com base numa janela móvel de dimensão variável (até 10 dias), avaliar qual o melhor desempenho e escolher esse modelo para as próximas horas. Assim, definiram-se 4 módulos o SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4, conforme referido pela Tabela 14, e estando o cálculo matemático exposto através das Equações 36 e 37.

- O módulo SLR/MLR-1 recorre a uma janela fixa, de dimensão fixa, para calibrar os coeficientes regressivos e não recorre a uma janela móvel, contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho. Este módulo é composto por um número de modelos igual ao número de possíveis combinações dos vários predictores (MM5, WRF e PERS);
- O módulo SLR/MLR-2 recorre a uma janela fixa, de dimensão fixa, para calibrar os coeficientes regressivos e recorre a uma janela móvel de dimensão variável (até 10 dias), contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho. Este modelo é composto por um número de modelos igual ao número de janelas de avaliação utilizadas para avaliar qual o melhor modelo;

- O módulo SLR/MLR-3 recorre a uma janela móvel, de dimensão fixa, para calibrar os coeficientes regressivos e não recorre a uma janela móvel, contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho. Este módulo é composto por um número de modelos igual ao número de possíveis combinações dos vários predictores (MM5, WRF e PERS);
- O módulo SLR/MLR-4 recorre a uma janela móvel, de dimensão fixa, para calibrar os coeficientes regressivos e recorre a uma janela móvel de dimensão variável (até 10 dias), contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho. Este modelo é composto por um número de modelos igual ao número de janelas de avaliação utilizadas para avaliar qual o melhor modelo;

Atendendo ao facto de que não existiam dados históricos dos modelos ALADIN e WRF-STS para o ano 2011, havendo apenas para o ano de 2012, não se utilizaram no módulo ALFA1. Tendo isto em conta e sendo ALFA1 um módulo que recorre a uma janela de calibração com dados históricos relativos a um ano, só foram utilizadas as previsões de base MM5, WRF e dados de PERS para efectuar previsões com recurso a este módulo. Por outro lado, tendo em conta que não se teve acesso a dados de previsão relativos a um período anterior não foi possível efectuar o tratamento para as previsões de base (MM5 e WRF) e dados de PERS utilizados como *input* nos modelos dos módulos que compõem o módulo ALFA1. Assim os dados de previsão utilizados como *input* nos modelos dos módulos que compõem o módulo ALFA1 são dados não tratados.

Por forma, a atingir-se os objectivos propostos com a metodologia ALFA1 e ALFA2 avaliou-se o módulo ALFA1 e o módulo ALFA2 para os períodos de validação e de teste, sendo que os resultados expostos no presente capítulo são referentes aos períodos de validação e teste, alcançados pelo módulo ALFA1. Além disso pretendeu-se avaliar se as previsões com recurso aos vários métodos que compõem o módulo ALFA1 conseguiam obter previsões com erros distintos para que quando estes fossem utilizados em conjunto conseguissem reduzir o erro de forma eficaz.

5.2.1.1 DESCRIÇÃO ESTATÍSTICA

Tal como anteriormente referido em 4.2.1. os dados foram subdivididos em três intervalos distintos (calibração, validação e teste) por forma a garantir a independência destes e avaliar correctamente os vários módulos. Assim, os modelos foram calibrados no período de calibração, validados no período de validação e testada a sua robustez no período de teste. Assim, optou-se por analisar os resultados obtidos com recurso aos modelos que compõem o módulo de ALFA1 no período de validação e comparar com os resultados obtidos no período de teste por forma a avaliar a sua robustez.

- Período de validação

Tabela 63- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 00-06hr no período de validação.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-21,91	-16,69	-10,36	-3,28
\tilde{E}	-9,49	-6,40	-3,39	4,02
Moda	#N/A	#N/A	#N/A	#N/A
As_1	#N/A	#N/A	#N/A	#N/A
σ	137,25	156,34	148,68	152,03
Var	1,88E+04	2,44E+04	2,21E+04	2,31E+04
K	0,21	0,21	0,21	0,21
As_2	-0,27	-0,20	-0,14	-0,14
Min	-574,82	-873,79	-799,87	-756,19
Max	540,83	611,06	581,80	657,41
Q_1	-89,87	-87,43	-76,03	-77,57
Q_3	47,49	59,80	61,11	69,27
P_{90}	133,65	150,95	149,84	169,05
P_{10}	-190,64	-198,71	-177,81	-186,65
$\rho_{x,y}$	0,96	0,95	0,95	0,95

Como se pode observar, com recurso à Tabela 63 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem decrescente (do módulo da média) se constata a ordem SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4.

Relativamente à assimetria, verifica-se que SLR/MLR-1 e SLR/MLR-2 apresentam uma distribuição do erro assimétrica moderada enquanto que SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,95 e 0,96 sendo bastante semelhantes. Sendo que a variação SLR/MLR-1 apresenta maior valor de $\rho_{x,y}$ (0,96).

Relativamente ao desvio padrão, verifica-se que SLR/MLR-1 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-1, SLR/MLR-3, SLR/MLR-4 e SLR/MLR-2. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-1 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-1, SLR/MLR-3, SLR/MLR-4 e SLR/MLR-2.

Tabela 64- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 06-12hr no período de validação.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-12,36	-17,94	-26,27	-26,52
\hat{E}	15,95	13,71	-18,39	-15,68
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	190,44	195,48	221,41	231,33
Var	3,63E+04	3,82E+04	4,90E+04	5,35E+04
K	0,23	0,25	0,22	0,23
As ₂	-0,45	-0,49	-0,11	-0,14
Min	-707,53	-760,16	-726,81	-869,86
Max	601,95	605,94	690,47	837,69
Q ₁	-113,55	-134,99	-155,99	-163,11
Q ₃	94,28	97,72	100,13	106,24
P ₉₀	191,67	201,95	262,07	269,26
P ₁₀	-258,61	-268,05	-307,22	-319,10
$\rho_{x,y}$	0,92	0,92	0,90	0,89

Como se pode observar, com recurso à Tabela 64 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem decrescente (do módulo da média) se constata a ordem SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4.

Relativamente à assimetria, verifica-se que SLR/MLR-1 e SLR/MLR-2 apresentam uma distribuição do erro assimétrica moderada enquanto que SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,92 e 0,89 sendo bastante semelhantes. Sendo que as variações SLR/MLR-1 e SLR/MLR-2 apresentam maior valor de $\rho_{x,y}$ (0,92).

Relativamente ao desvio padrão, verifica-se que SLR/MLR-1 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-1 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4.

Tabela 65- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 12-18hr no período de validação.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-27,18	-23,56	-40,49	-36,82
\tilde{E}	-2,14	3,38	-38,34	-40,68
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	202,07	214,32	235,30	229,90
Var	4,08E+04	4,59E+04	5,54E+04	5,29E+04
K	0,22	0,22	0,22	0,22
As ₂	-0,37	-0,38	-0,03	0,05
Min	-684,66	-799,54	-1061,80	-921,45
Max	599,99	721,00	766,47	792,69
Q ₁	-140,03	-134,11	-168,00	-170,44
Q ₃	84,51	95,18	74,19	76,08
P ₉₀	213,96	221,83	253,20	257,15
P ₁₀	-296,32	-308,80	-302,84	-304,56
$\rho_{x,y}$	0,91	0,90	0,89	0,89

Como se pode observar, com recurso à Tabela 65 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem decrescente (do módulo da média) se constata a ordem SLR/MLR-2, SLR/MLR-1, SLR/MLR-4 e SLR/MLR-3.

Relativamente à assimetria, verifica-se que SLR/MLR-1 e SLR/MLR-2 apresentam uma distribuição do erro assimétrica moderada enquanto que SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,91 e 0,89 sendo bastante semelhantes. Sendo que a variação SLR/MLR-1 apresenta maior valor de $\rho_{x,y}$ (0,91).

Relativamente ao desvio padrão, verifica-se que SLR/MLR-1 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-1 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4.

Tabela 66- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 18-24hr para o período de validação.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-16,49	-4,53	-14,37	-36,70
\hat{E}	10,97	19,87	13,75	-24,05
Moda	#N/A	#N/A	#N/A	#N/A
As_1	#N/A	#N/A	#N/A	#N/A
σ	213,08	219,76	216,83	235,34
Var	4,54E+04	4,83E+04	4,70E+04	5,54E+04
K	0,23	0,23	0,24	0,22
As_2	-0,39	-0,33	-0,39	-0,16
Min	-715,72	-810,19	-715,72	-855,56
Max	864,67	887,38	864,67	836,49
Q ₁	-135,39	-126,24	-134,42	-169,33
Q ₃	102,05	115,28	103,31	88,42
P ₉₀	215,41	234,84	207,42	243,24
P ₁₀	-296,58	-286,13	-295,31	-331,22
$\rho_{x,y}$	0,90	0,90	0,90	0,89

Como se pode observar, com recurso à Tabela 66 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem decrescente (do módulo da média) se constata a ordem SLR/MLR-2, SLR/MLR-3, SLR/MLR-1 e SLR/MLR-4.

Relativamente à assimetria, verifica-se que SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro assimétrica moderada.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,90 e 0,89 sendo bastante semelhantes. Sendo que as variações SLR/MLR-1, SLR/MLR-2 e SLR/MLR-3 apresentam maior valor de $\rho_{x,y}$ (0,90).

Relativamente ao desvio padrão, verifica-se que SLR/MLR-1 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-1 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4.

- Período de teste

Tabela 67- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 00-06hr no período de teste.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-60,36	-62,90	-48,10	-50,02
\hat{E}	-35,45	-38,10	-25,30	-23,01
Moda	#N/A	#N/A	#N/A	#N/A
As_1	#N/A	#N/A	#N/A	#N/A
σ	162,59	168,15	164,13	166,84
Var	2,64E+04	2,83E+04	2,69E+04	2,78E+04
K	0,24	0,23	0,23	0,24
As_2	-0,46	-0,44	-0,42	-0,49
Min	-870,87	-854,52	-854,52	-854,52
Max	476,39	473,13	536,75	496,61
Q_1	-150,53	-150,03	-135,82	-135,58
Q_3	37,51	37,47	45,45	49,20
P_{90}	115,89	114,41	130,04	121,47
P_{10}	-274,66	-288,63	-258,39	-268,97
$\rho_{x,y}$	0,97	0,97	0,97	0,97

Como se pode observar, com recurso à Tabela 67 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem crescente (do módulo da média) se constata a ordem SLR/MLR-3, SLR/MLR-4, SLR/MLR-1 e SLR/MLR-2.

Relativamente à assimetria, verifica-se que SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro assimétrica moderada.

Observando o valor da curtose verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes toma o valor de 0,97 para as variações SLR/MLR-1, SLR/MLR-2 e SLR/MLR-3.

Relativamente ao desvio padrão, verifica-se que SLR/MLR-1 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-1, SLR/MLR-3, SLR/MLR-4 e SLR/MLR-2. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-3 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-3, SLR/MLR-1, SLR/MLR-4 e SLR/MLR-2.

Tabela 68- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 06-12hr no período de teste.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-85,61	-89,39	-69,12	-75,26
\tilde{E}	-52,95	-53,20	-53,94	-53,26
Moda	-30,17	-30,17	#N/A	#N/A
As ₁	-55,44	-59,22	#N/A	#N/A
σ	229,25	231,12	217,41	223,41
Var	5,26E+04	5,34E+04	4,73E+04	4,99E+04
K	0,24	0,23	0,21	0,23
As ₂	-0,43	-0,47	-0,21	-0,30
Min	-865,65	-865,65	-836,30	-935,01
Max	629,20	621,38	629,03	635,97
Q ₁	-203,04	-210,51	-174,57	-192,41
Q ₃	63,57	64,95	56,52	60,61
P ₉₀	153,91	155,98	178,10	171,37
P ₁₀	-410,12	-430,60	-359,94	-385,33
$\rho_{x,y}$	0,94	0,94	0,95	0,94

Como se pode observar, com recurso à Tabela 68 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem crescente (do módulo da média) se constata a ordem SLR/MLR-3, SLR/MLR-4, SLR/MLR-1 e SLR/MLR-2.

Relativamente à assimetria, verifica-se que SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro assimétrica moderada.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo a o valor $\rho_{x,y}$, observa-se que toma valores entre 0,94 e 0,95. Sendo que, a variação SLR/MLR-3 foi a que alcançam um maior valor de $\rho_{x,y}$.

Relativamente ao desvio padrão, verifica-se que SLR/MLR-3 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-3, SLR/MLR-4, SLR/MLR-1 e SLR/MLR-2. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-3 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-3, SLR/MLR-4, SLR/MLR-1 e SLR/MLR-2.

Tabela 69- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 12-18hr no período de teste.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-96,10	-96,97	-80,88	-89,69
\tilde{E}	-53,53	-58,63	-65,10	-62,08
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	259,34	263,41	257,01	281,79
Var	6,73E+04	6,94E+04	6,61E+04	7,94E+04
K	0,24	0,24	0,21	0,22
As ₂	-0,49	-0,44	-0,18	-0,29
Min	-938,07	-913,86	-991,59	-1158,20
Max	677,24	649,24	847,44	854,38
Q ₁	-242,96	-244,47	-203,02	-216,97
Q ₃	78,57	76,34	53,14	61,51
P ₉₀	194,84	205,43	202,81	214,60
P ₁₀	-470,43	-476,23	-403,63	-418,25
$\rho_{x,y}$	0,92	0,92	0,93	0,91

Como se pode observar, com recurso à Tabela 69 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos módulos SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem crescente (do módulo da média) se constata a ordem SLR/MLR-3, SLR/MLR-4, SLR/MLR-1 e SLR/MLR-2.

Relativamente à assimetria, verifica-se que SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro assimétrica moderada.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que toma valores entre 0,91 e 0,93. Sendo que, a variação SLR/MLR-3 foi a que alcançou o maior valor de $\rho_{x,y}$.

Relativamente ao desvio padrão, verifica-se que SLR/MLR-3 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-3, SLR/MLR-1, SLR/MLR-2 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-3 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-3, SLR/MLR-1, SLR/MLR-2 e SLR/MLR-4.

Tabela 70- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA1 para o horizonte temporal 18-24hr no período de teste.

	SLR/MLR-1	SLR/MLR-2	SLR/MLR-3	SLR/MLR-4
\bar{E}	-98,13	-89,07	-97,72	-89,40
\tilde{E}	-58,03	-55,08	-57,57	-64,54
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	278,44	271,40	276,14	288,89
Var	7,75E+04	7,37E+04	7,63E+04	8,35E+04
K	0,25	0,24	0,25	0,21
As ₂	-0,43	-0,38	-0,44	-0,26
Min	-1028,17	-945,26	-1028,17	-1156,72
Max	763,10	714,43	771,79	974,18
Q ₁	-255,63	-240,91	-252,82	-215,93
Q ₃	88,79	93,01	89,24	54,58
P ₉₀	202,55	211,29	198,05	200,46
P ₁₀	-494,06	-482,78	-493,38	-444,96
$\rho_{x,y}$	0,91	0,92	0,91	0,91

Como se pode observar, com recurso à Tabela 70 não foi possível determinar o valor da moda para nenhuma das variações do modelo SLR/MLR.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos módulo SLR/MLR para o módulo ALFA1 foram subestimadas face aos valores observados com recurso ao METER, sendo que por ordem crescente (do módulo da média) se constata a ordem SLR/MLR-2, SLR/MLR-4, SLR/MLR-3 e SLR/MLR-1.

Relativamente à assimetria, verifica-se que SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 apresentam uma distribuição do erro assimétrica moderada.

Observando o valor da curtose, verifica-se que que todas as variações do modelo SLR/MLR apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados às variações SLR/MLR apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que toma valores entre 0,91 e 0,92. Sendo que, a variação SLR/MLR-2 foi a que alcançam um maior valor de $\rho_{x,y}$.

Relativamente ao desvio padrão, verifica-se que SLR/MLR-2 apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão SLR/MLR-2, SLR/MLR-3, SLR/MLR-1 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela equação 34, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que a variação SLR/MLR-2 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-2, SLR/MLR-3, SLR/MLR-1 e SLR/MLR-4.

Analisando as Tabelas 63 a 70 seria expectável que a variação SLR/MLR-1 apresentasse valores semelhantes nos períodos de validação e de teste já que todos os cálculos necessários a este são efectuados no período de calibração, no entanto o mesmo não acontece, verificando-se um aumento significativo do erro. Relativamente às restantes variações (SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4) seria expectável ocorrer um determinado erro já que existem cálculos efectuados externos ao período de calibração ALFA1.

5.2.1.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

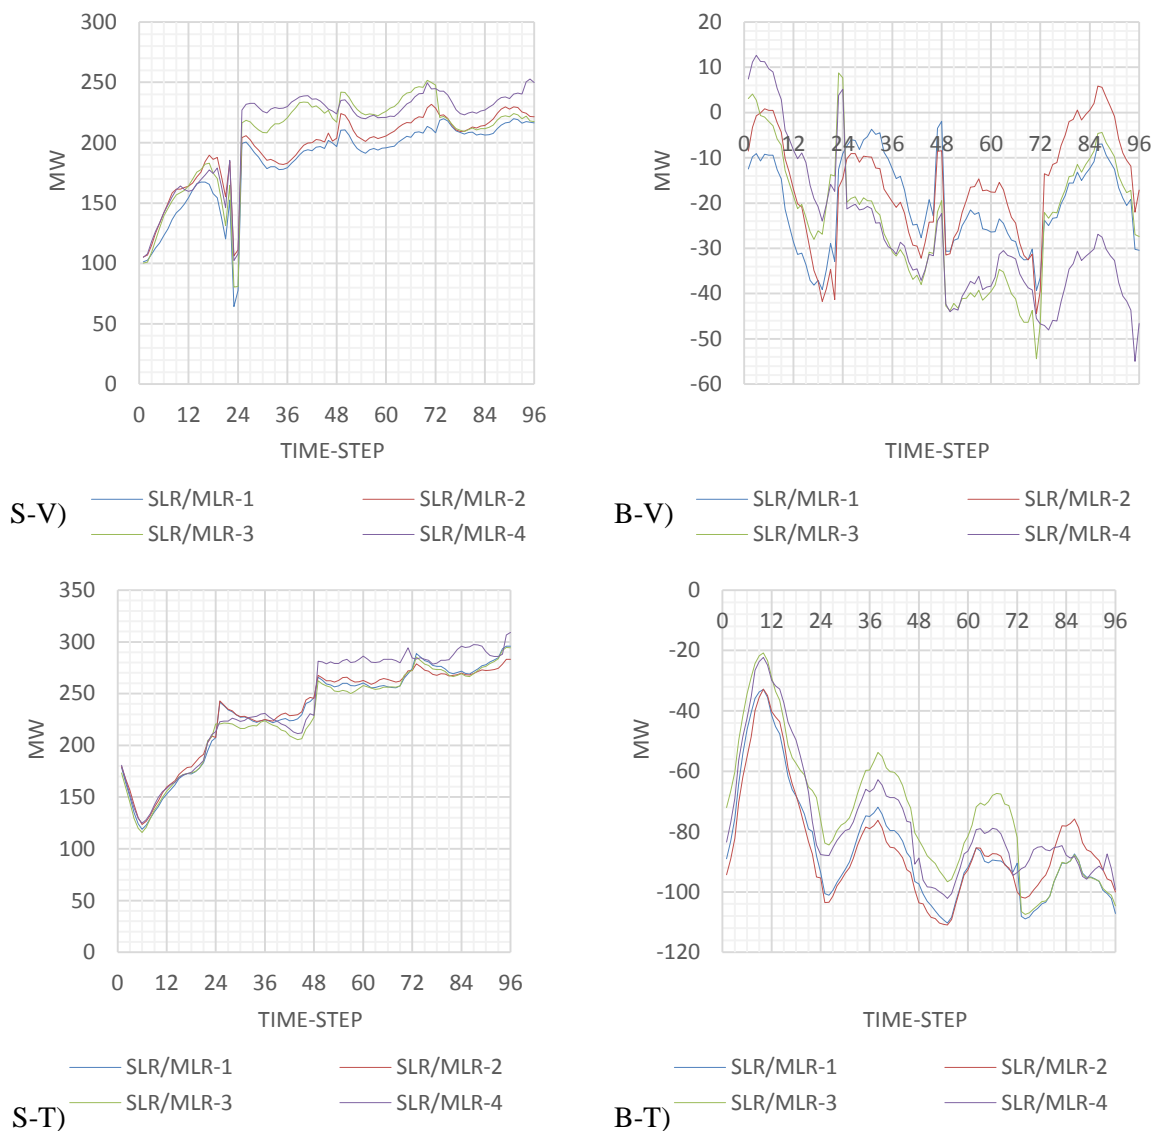


Fig. 54 – Gráfico síntese do valor de BIAS (B) e SDE (S) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA1 para o horizonte temporal 00-24hr nos períodos de validação (-V) e de teste (-T).

Como se pode observar através das Fig. 54 B-V) e S-V) as previsões efectuadas com recurso às variações SLR/MLR tiveram evoluções do viés e do SDE semelhantes entre si. Por outro lado observa-se que a variação com menor valor de viés e/ou SDE não foi constante ao longo dos vários *time-steps* analisados, observando-se assim que para o período de validação estes alternaram entre si, embora se consiga observar que a variação SLR/MLR-1 foi a que melhor desempenho teve com base nos valores BIAS e SDE para o período de validação. Analisando as Fig. 54 B-T) e S-T) verifica-se que a evolução quer do BIAS quer do SDE são distintos relativamente às Fig. 54 B-V) e S-V). Além disso verifica-se que a variação SLR/MLR-1 já não é aquela que tem melhores desempenhos. Assim, não existe uma variação do modelo SLR/MLR pertencente ao módulo ALFA1 que seja melhor do que os outros, pelo contrário verifica-se que estes tendem a alternar entre si. Continuando a comparação dos valores do BIAS e SDE para os períodos de validação e teste observa-se que no período de teste as previsões tiveram uma menor qualidade para prever a potência eólica, já que de uma forma geral os valores de BIAS (em módulo) e SDE foram substancialmente superiores aos obtidos no período de validação.

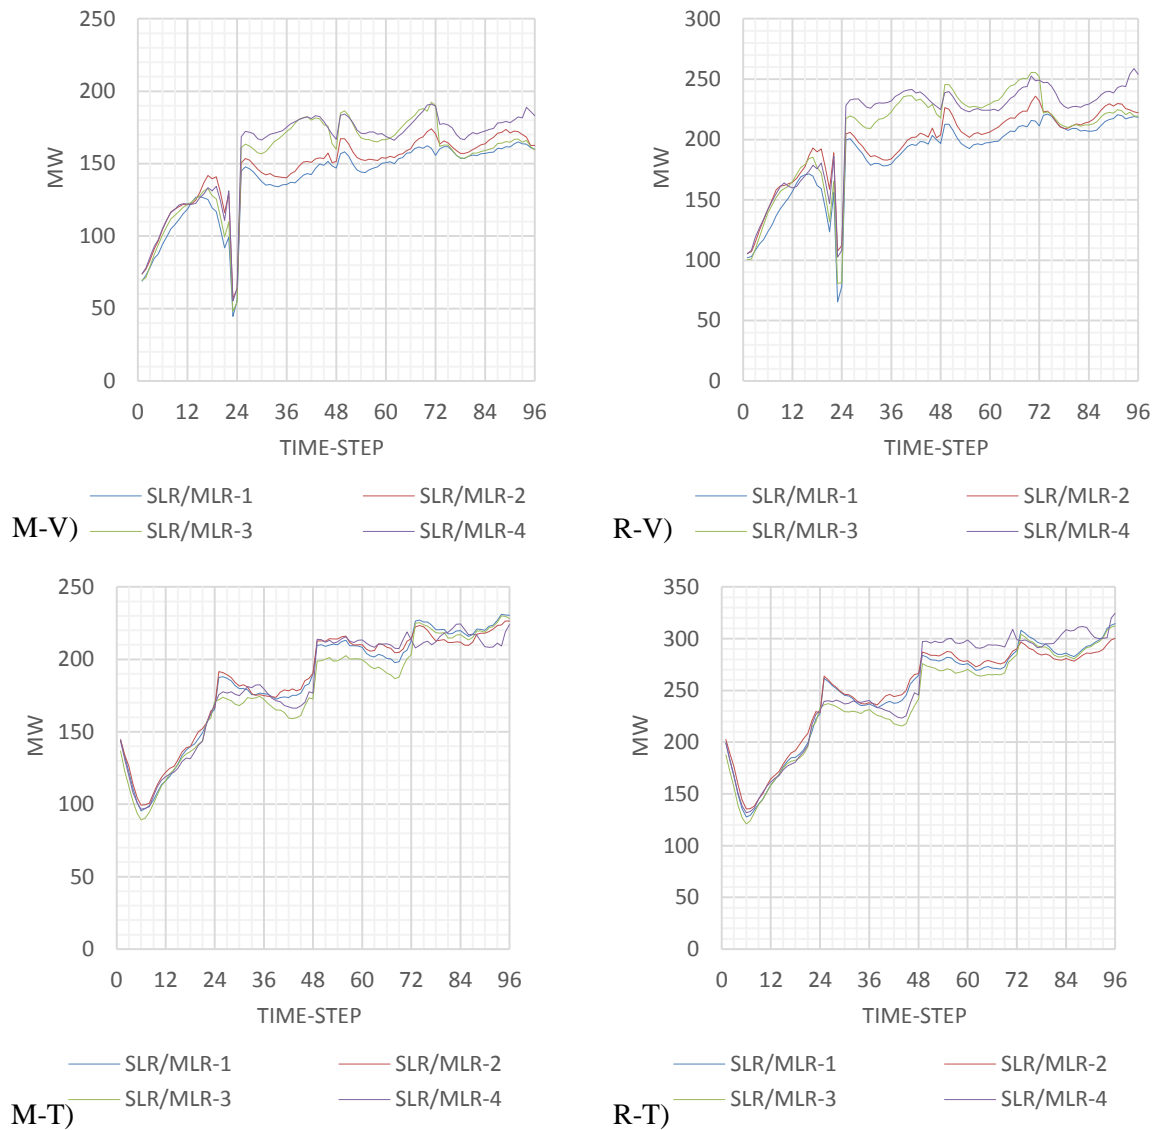


Fig. 55 – Gráfico síntese do valor de MAE (M) e RMSE (R) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA1 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).

Como seria expectável pela diferença de cálculo dos valores de MAE e RMSE expresso nas Equações 20 e 19, respectivamente, verifica-se que estes são muito semelhantes embora os valores de MAE sejam de uma forma geral menores do que os erros associados ao RMSE, isto é corroborado através da comparação das Fig. 55 entre as figuras referentes à validação (M-V) e R-V)) e entre as figuras referentes ao período de teste (M-T) e R-T)).

Recorrendo à análise da Fig. 55, constata-se que a variação com menor erro de RMSE associado foi a variação SLR/MLR-1 para o período de validação, no entanto, verifica-se que o mesmo não aconteceu no período de teste. Sendo que, no período de teste as variações com menor valor de RMSE para um determinado *time-step* alternaram entre si.

Analisando as Fig. 55 consegue-se observar que a progressão do MAE e RMSE não foi semelhante no período de validação e no período de teste, verificando até anomalias de progressão do erro. Isto consegue-se observar comparando as Fig. 55 R-V) e R-T) onde as maiores diferenças, entre estes, se encontram entre os *time-steps* 1 ao 24.

Analisando a Fig. 55 R-T), verifica-se que no período de teste ocorreu uma menor diferença entre os vários modelos exceptuando o modelo SLR/MLR-4 para o horizonte temporal 12-18hr que teve um pior desempenho relativamente aos outros modelos para o mesmo período. Isto poderá dever-se a uma maior variabilidade do recurso eólico associado ao facto de que o modelo, está constantemente a recalibrar os coeficientes regressivos ao mesmo tempo efectua a escolha do melhor modelo.

Observando-se as Fig. 54 e 55, verifica-se que os modelos que compõem ALFA1 obtiveram um desempenho semelhante para os primeiros *time-steps* (1-24) referentes às primeiras 6 horas e que o mesmo não aconteceu para os restantes horizontes temporais, isto poderá indicar que as variações efectuadas não foram suficientes ao ponto de efectuar um espectro diversificado de previsões o que pode inviabilizar a eficácia do algoritmo.

Com recurso á Fig. 55 R-V), verificou-se através da comparação do valor do RMSE que as previsões efectuadas com recurso a uma janela móvel para calcular os coeficientes regressivos (SLR/MLR-3 e SLR/MLR-4), obtiveram de uma forma geral piores resultados do que o modelo que recorre a uma janela fixa para calcular os coeficientes (SLR/MLR-1 e SLR/MLR-2). Por outro lado, com recurso á Fig 55 R-T) verificou-se que os modelos que efectuam previsões com recurso a uma janela móvel para calibrar os coeficientes regressivos obteve valores de erro competitivos com os modelos que efectuam previsões com recurso a uma janela fixa para calibrar os coeficientes regressivos.

Recorrendo á Fig. 55, verifica-se que as previsões efectuadas com recurso às variações do modelo SLR/MLR que recorrem a uma janela móvel para avaliar o desempenho do melhor modelo num período passado (SLR/MLR-1 e SLR/MLR-3) *versus* modelo sem recurso a avaliação (SLR/MLR-2 e SLR/MLR-4) obtiveram para o período de teste um erro semelhante e para o período de teste um erro distinto.

5.2.2 ALFA2

O módulo ALFA2 é composto por variações do método de regressão linear podendo ser regressão linear simples (SLR) e/ou regressão linear múltipla (MLR), dependendo do numero de predictores (MM5-MOSF, WRF-MOSF, WRF-STS-MOSF, ALADIN-MOSF, PERS-MOSF) a que recorre; pelo método regressão linear passo a passo (STEPWISE-LR) e pelo método baseado no Filtro de Kalman (KF).

- O módulo SLR/MLR-3 recorre a uma janela móvel de dimensão variável (até 10 dias) para calcular os coeficientes regressivos e não recorre a uma janela, contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho; ou seja, este módulo é composto pelas várias combinações possíveis dos predictores. Este método foi anteriormente exposto no capítulo 4.3.2.1. estando o cálculo matemático exposto através das Equações 36 e 37.
- O módulo SLR/MLR-4 recorre a uma janela móvel de dimensão variável (até 10 dias) para calcular os coeficientes regressivos e recorre a uma janela móvel de dimensão variável (até 10 dias), contendo dados relativos a um passado recente, para avaliar qual o modelo com melhor desempenho; ou seja, este modelo é composto por um número de modelos igual ao número de janelas de avaliação utilizadas para avaliar qual o melhor modelo. Este método foi anteriormente exposto no capítulo 4.3.2.1. estando o cálculo matemático exposto através das Equações 36 e 37.
- O módulo KF é composto por diversos modelos baseados em KF em que se varia a capacidade de aprendizagem do algoritmo. Este método foi anteriormente exposto no capítulo 4.3.2.2. Os resultados expostos no presente capítulo são referentes ao modelo KF em que a taxa de aprendizagem foi calibrada para o horizonte temporal 00-06hr e não calibrada para os horizontes temporais seguintes, estando o cálculo matemático exposto através das Equações 40-45. Este módulo recorre a tantos modelos quantas taxas de aprendizagem utilizadas;
- O modelo STEPWISE-LR recorre a uma janela móvel de dimensão fixa, para calcular os coeficientes regressivos, e recorre a uma janela móvel de dimensão fixa, de dados passados, para prever qual será a melhor combinação de predictores num futuro próximo, conforme foi

exposto no capítulo 4.3.2.3. Este modelo exigiu uma calibração de dados específica com o objectivo de otimizar o desempenho do mesmo. A calibração do modelo consistiu numa avaliação do desempenho das várias combinações dos modelos possíveis, com recurso a uma janela móvel variável de dados de um passado recente, com o objectivo de determinar a dimensão dessa janela móvel. Por outro lado, foi necessário calibrar o critério de inclusão do modelo. Isto foi conseguido variando o critério de inclusão e observando o desempenho do modelo. Estando o estudo da calibração deste modelo demonstrada no anexo B. Através do estudo efectuado estabeleceu-se a janela móvel sobre a qual se avaliou o desempenho do modelo, sendo que, esta foi definida com uma dimensão variável em função do horizonte temporal (conforme descrito no anexo B), sendo a mesma visível nos gráficos em que se variou a dimensão da janela móvel sobre a qual é calculado o desempenho dos modelos. Por vezes observou-se que, para janelas móveis de menores dimensões, os modelos têm um melhor desempenho, no entanto, esta nunca foi considerada como sendo uma possibilidade já que devido à sua dimensão pode ser demasiado adaptativa pelo que anularia as variações benéficas inerentes aos dados, sendo que, com recurso a uma janela de dimensões mais reduzidas o modelo poderia escolher em atraso o melhor modelo. Por outro lado, verificou-se que o critério de inclusão do modelo (C_i) foi variável em função do horizonte temporal (conforme descrito no anexo B) para o qual existiria um menor erro associado. Assim com recurso ao anexo B verificou-se que o critério de inclusão se verificou bastante conservativo (exigente), o que implica que de uma forma geral que apenas um ou dois predictores sejam incluídos na regressão, estando o cálculo matemático exposto através das Equações 29, 36 e 37.

Os valores presentes neste capítulo são referentes à agregação dos vários modelos que compõem os módulos do módulo ALFA2 com recurso ao modelo MIX, sendo a excepção o modelo STEPWISE-LR que é apenas um modelo e por isso não foi agregado.

O módulo ALFA2 tem como objectivo efectuar previsões com recurso a coeficientes de regressão menos estáticos do que os utilizados pelo módulo ALFA1. Tal como ALFA1, o módulo ALFA2 também recorre a modelos lineares e não lineares sem/com avaliação do desempenho, respectivamente, num passado recente por forma a escolher a melhor combinação.

Com recurso à agregação das variações pretendeu-se avaliar se as previsões com recurso aos vários métodos que compõem o módulo ALFA2 conseguiam obter previsões com erros distintos para que quando estes fossem utilizados em conjunto conseguissem reduzir o erro de forma eficaz, isto é, se a melhor combinação dos vários modelos (dentro de cada módulo) era semelhante ou por outro lado distinta entre si.

5.2.2.1 DESCRIÇÃO ESTATÍSTICA

Tal como anteriormente referido em 4.2.1. os dados foram subdivididos em três intervalos distintos (calibração, validação e teste) por forma a garantir a independência destes e avaliar correctamente os vários módulos. Assim, os modelos foram calibrados no período de calibração, validados no período de validação e testada a sua robustez no período de teste. Assim, optou-se por analisar os resultados obtidos com recurso aos modelos que compõem o módulo de ALFA2 no período de validação e comparar com os resultados obtidos no período de teste por forma a avaliar a sua robustez.

- Período de validação

Tabela 71- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 00-06hr no período de validação.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-2,95	9,17	-8,80	-8,93
\hat{E}	17,24	3,60	-3,97	-3,84
Moda	#N/A	0,26	#N/A	#N/A
As_1	#N/A	8,91	#N/A	#N/A
σ	162,29	282,72	135,25	127,43
Var	2,63E+04	7,99E+04	1,83E+04	1,62E+04
K	0,23	0,19	0,23	0,22
As_2	-0,37	0,06	-0,11	-0,12
Min	-683,00	-1064,73	-643,40	-622,54
Max	553,36	1286,41	642,67	608,64
Q_1	-92,76	-121,82	-78,39	-73,42
Q_3	91,25	106,61	60,18	50,03
P_{90}	184,41	288,71	138,93	129,42
P_{10}	-221,93	-299,86	-167,85	-157,06
$\rho_{x,y}$	0,94	0,83	0,96	0,96

Como se pode observar, com recurso à Tabela 71 não foi possível determinar o valor da moda para as variações SLR/MLR-3, STEPWISE-LR e KF. Assim apenas se pode avaliar o modelo SLR/MLR-4 com base na moda e na média, sendo que este apresenta uma assimetria moderada.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos modelos SLR/MLR-4 foram sobrestimadas e que os restantes modelos obtiveram previsões subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que o modelo STEPWISE-LR apresenta uma assimetria moderada e que os modelos SLR/MLR-3, SLR/MLR-4 e KF apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,83 e 0,96 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtido pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo KF apresenta o menor valor para as variações. Observando-se por ordem crescente do desvio padrão KF, SLR/MLR-3, STEPWISE-LR e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que o modelo KF apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem KF, SLR/MLR-3, STEPWISE-LR e SLR/MLR-4.

Tabela 72- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 06-12hr no período de validação.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-33,48	15,84	-4,76	-30,26
\hat{E}	-25,23	6,10	6,01	-20,77
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	197,00	326,40	201,23	300,23
Var	3,88E+04	1,07E+05	4,05E+04	9,01E+04
K	0,24	0,19	0,21	0,21
As ₂	-0,13	0,09	-0,16	-0,09
Min	-679,11	-1231,05	-760,43	-2450,40
Max	605,56	1478,68	926,66	1281,70
Q ₁	-156,52	-131,24	-107,83	-170,51
Q ₃	75,92	123,71	99,49	110,70
P ₉₀	203,89	356,46	231,86	293,40
P ₁₀	-277,53	-321,93	-252,93	-383,46
$\rho_{x,y}$	0,91	0,78	0,91	0,80

Como se pode observar, com recurso à Tabela 72 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos vários modelos.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos modelos SLR/MLR-4 foram sobrestimadas e que os restantes modelos obtiveram previsões subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que o modelo SLR/MLR-3 apresenta uma assimetria moderada e que os modelos STEPWISE-LR, SLR/MLR-4 e KF apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,78 e 0,91 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo STEPWISE-LR apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que o modelo STEPWISE-LR apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4.

Tabela 73- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 12-18hr no período de validação.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-1,23	120,92	8,43	-28,95
\tilde{E}	9,60	-13,06	-6,09	-22,12
Moda	#N/A	202,25	#N/A	#N/A
As ₁	#N/A	-81,33	#N/A	#N/A
σ	246,21	864,47	218,79	454,51
Var	6,06E+04	7,47E+05	4,79E+04	2,07E+05
K	0,23	0,23	0,23	0,22
As ₂	-0,13	0,46	0,20	-0,05
Min	-874,17	-1890,24	-814,34	-2012,66
Max	810,49	5043,83	790,85	2762,29
Q ₁	-133,97	-244,48	-111,06	-251,58
Q ₃	145,59	243,64	138,03	190,97
P ₉₀	294,32	567,62	293,11	451,29
P ₁₀	-313,85	-493,19	-245,43	-554,34
$\rho_{x,y}$	0,86	0,39	0,90	0,55

Como se pode observar, com recurso à Tabela 73 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos métodos STEPWISE-LR, SLR/MLR-3 e KF, tendo apenas valor da moda para o modelo SLR/MLR-4. A partir da moda e da média verifica-se que o modelo SLR/MLR-4 apresenta uma assimetria negativa.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos modelos SLR/MLR-4 e SLR/MLR-3 foram sobrestimadas e que os restantes modelos obtiveram previsões subestimadas relativamente ao METER.

Relativamente à assimetria verifica-se, que o modelo SLR/MLR-3 e SLR/MLR-4 apresentam uma assimetria moderada e que os modelos STEPWISE-LR e KF apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,39 e 0,90 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo SLR/MLR-3 apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão SLR/MLR-3, STEPWISE-LR, KF e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE verifica-se que o modelo SLR/MLR-3 apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem SLR/MLR-3, STEPWISE-LR, KF e SLR/MLR-4.

Tabela 74- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 18-24hr no período de validação.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-30,03	166,73	-8,12	-43,45
\tilde{E}	-33,30	-8,79	-17,90	-5,10
Moda	#N/A	202,25	#N/A	#N/A
As ₁	#N/A	-35,52	#N/A	#N/A
σ	209,45	1004,93	226,13	416,08
Var	4,39E+04	1,01E+06	5,11E+04	1,73E+05
K	0,22	0,23	0,24	0,23
As ₂	0,05	0,52	0,13	-0,28
Min	-753,59	-1885,08	-784,86	-1351,60
Max	768,23	5811,35	847,27	1911,87
Q ₁	-146,74	-286,55	-143,89	-263,31
Q ₃	77,26	276,89	115,08	200,72
P ₉₀	229,64	655,30	279,38	422,25
P ₁₀	-279,30	-566,35	-266,57	-605,81
$\rho_{x,y}$	0,91	0,34	0,89	0,59

Como se pode observar, com recurso à Tabela 74 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos métodos STEPWISE-LR, SLR/MLR-3 e KF, tendo apenas valor da moda para o modelo SLR/MLR-4. A partir da moda e da média verifica-se que o modelo SLR/MLR-4 apresenta uma assimetria negativa.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso ao modelo SLR/MLR-4 foram sobrestimadas e que os restantes modelos obtiveram previsões subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que os modelos SLR/MLR-4 e KF apresentam uma assimetria moderada e que os modelos STEPWISE-LR e SLR/MLR-3 apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,34 e 0,91 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo STEPWISE-LR apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE, verifica-se que o modelo STEPWISE-LR apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4.

- Período de teste

Tabela 75- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 00-06hr no período de teste.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-20,59	-10,67	-26,14	-24,24
\hat{E}	-3,76	6,10	-17,67	-11,41
Moda	#N/A	#N/A	#N/A	#N/A
As_1	#N/A	#N/A	#N/A	#N/A
σ	172,71	253,15	161,42	145,51
Var	2,98E+04	6,41E+04	2,61E+04	2,12E+04
K	0,26	0,21	0,23	0,23
As_2	-0,29	-0,20	-0,16	-0,26
Min	-738,44	-1578,83	-652,41	-711,96
Max	580,62	1755,56	843,18	798,02
Q_1	-124,00	-122,72	-110,86	-97,99
Q_3	91,76	102,98	61,73	54,26
P_{90}	180,55	231,09	156,98	134,55
P_{10}	-239,92	-298,32	-219,03	-198,92
$\rho_{x,y}$	0,97	0,93	0,97	0,98

Como se pode observar, com recurso à Tabela 75 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos vários modelos.

Tendo em conta o valor da média, observa-se que as previsões efectuadas foram todas subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que as previsões efectuadas com recurso aos vários modelos apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,93 e 0,98 sendo que a variação SLR/MLR-4 apresenta o menor valor relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo KF apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão KF, STEPWISE-LR, SLR/MLR-3 e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE, verifica-se que o modelo KF apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem KF, STEPWISE-LR, SLR/MLR-3 e SLR/MLR-4.

Tabela 76- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 06-12hr no período de teste.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-24,97	-13,61	-29,50	-33,78
\tilde{E}	-22,54	5,75	-31,40	-32,93
Moda	#N/A	#N/A	#N/A	#N/A
As ₁	#N/A	#N/A	#N/A	#N/A
σ	215,40	265,08	212,80	205,15
Var	4,64E+04	7,03E+04	4,53E+04	4,21E+04
K	0,25	0,21	0,22	0,24
As ₂	-0,03	-0,22	0,03	-0,01
Min	-861,83	-1004,80	-907,80	-744,03
Max	786,70	1651,29	736,46	799,18
Q ₁	-163,57	-146,70	-143,63	-161,56
Q ₃	101,79	101,23	76,60	87,93
P ₉₀	258,58	258,65	220,52	224,26
P ₁₀	-275,90	-331,04	-270,92	-293,03
$\rho_{x,y}$	0,95	0,93	0,95	0,95

Como se pode observar, com recurso à Tabela 76 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos vários modelos.

Tendo em conta o valor da média, observa-se que as previsões efectuadas foram todas subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que na sua maioria as previsões efectuadas com recurso aos vários modelos apresentam uma distribuição do erro simétrica, a excepção a esta tendência foram as previsões efectuadas com recurso ao modelo SLR/MLR-4.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,93 e 0,95 sendo que a variação SLR/MLR-4 apresenta o menor valor relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo KF apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão KF, SLR/MLR-3, STEPWISE-LR e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE, verifica-se que o modelo KF apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem KF, SLR/MLR-3, STEPWISE-LR e SLR/MLR-4.

Tabela 77- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 12-18hr no período de teste.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-27,31	-62,14	-15,74	-17,82
\tilde{E}	-5,63	-34,11	-26,14	-4,92
Moda	#N/A	649,10	#N/A	#N/A
As ₁	#N/A	-711,24	#N/A	#N/A
σ	238,22	527,35	249,10	349,75
Var	5,67E+04	2,78E+05	6,21E+04	1,22E+05
K	0,24	0,23	0,25	0,25
As ₂	-0,27	-0,16	0,13	-0,11
Min	-1005,06	-1796,27	-1238,94	-1522,01
Max	561,50	1629,65	1287,48	1736,41
Q ₁	-168,17	-320,99	-152,14	-226,39
Q ₃	120,64	221,13	97,99	178,80
P ₉₀	278,35	482,50	242,94	367,46
P ₁₀	-327,39	-721,84	-262,20	-432,38
$\rho_{x,y}$	0,94	0,70	0,93	0,86

Como se pode observar, com recurso à Tabela 77 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos métodos STEPWISE-LR, SLR/MLR-3 e KF, tendo apenas valor da moda para o modelo SLR/MLR-4. A partir da moda e da média verifica-se que o modelo SLR/MLR-4 apresenta uma assimetria negativa.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos vários modelos foram subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que o modelo STEPWISE-LR e SLR/MLR-4 apresentam uma assimetria moderada e que os modelos SLR/MLR-3 e KF apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,70 e 0,94 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo STEPWISE-LR apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE, verifica-se que o modelo STEPWISE-LR apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4.

Tabela 78- Descrição estatística das séries dos erros das previsões que compõem o módulo ALFA2 para o horizonte temporal 18-24hr no período de teste.

	STEPWISE-LR	SLR/MLR-4	SLR/MLR -3	KF
\bar{E}	-51,13	-75,27	-8,62	-22,40
\hat{E}	-44,07	-37,02	2,23	-8,44
Moda	311,52	311,85	#N/A	#N/A
As ₁	-362,65	-387,12	#N/A	#N/A
σ	278,88	549,06	295,60	375,18
Var	7,78E+04	3,01E+05	8,74E+04	1,41E+05
K	0,24	0,22	0,21	0,25
As ₂	-0,08	-0,21	-0,11	-0,11
Min	-1076,12	-1914,03	-1332,04	-1290,52
Max	1054,07	1483,50	1378,59	1474,14
Q ₁	-198,88	-353,63	-145,20	-249,02
Q ₃	117,03	198,73	130,59	190,81
P ₉₀	277,21	486,26	312,18	394,09
P ₁₀	-372,65	-749,40	-349,69	-486,58
$\rho_{x,y}$	0,92	0,67	0,90	0,84

Como se pode observar, com recurso à Tabela 78 não foi possível determinar o valor da moda para as previsões efectuadas com recurso aos métodos SLR/MLR-3 e KF, tendo-se apenas obtido valor da moda para o modelo SLR/MLR-4 e STPWISE-LR. A partir da moda e da média verifica-se que os modelos STEPWISE-LR e SLR/MLR-4 apresenta uma assimetria negativa.

Tendo em conta o valor da média, observa-se que as previsões efectuadas com recurso aos vários modelos foram subestimadas relativamente ao METER.

Relativamente à assimetria, verifica-se que o modelo SLR/MLR-4 apresenta uma assimetria moderada e que os restantes modelos apresentam uma distribuição do erro simétrica.

Observando o valor da curtose, verifica-se que todos os modelos apresentam uma distribuição leptocúrtica. Assim tendo em conta os valores de assimetria, curtose e média verifica-se que os erros associados aos vários modelos apresentam erros concentrados em torno da média.

Atendendo ao valor $\rho_{x,y}$, observa-se que estes tomam valores entre 0,67 e 0,92 sendo que a variação SLR/MLR-4 apresenta o menor valor, o qual é bastante inferior relativamente aos valores de $\rho_{x,y}$ obtidos pelos restantes modelos.

Relativamente ao desvio padrão, verifica-se que o modelo STEPWISE-LR apresenta o menor valor para o horizonte temporal analisado. Observando-se por ordem crescente do desvio padrão STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4. Por outro lado, se for tida em conta a relação exposta pela Equação 22, que tem em conta o valor da média e do desvio padrão para calcular o RMSE, verifica-se que o modelo STEPWISE-LR apresenta o valor mais baixo. Sendo que, por ordem crescente de RMSE, se verifica a seguinte ordem STEPWISE-LR, SLR/MLR-3, KF e SLR/MLR-4.

5.2.2.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

Como se pode observar através das Fig. 56 B-V) e S-V) as previsões efectuadas com recurso aos modelos que compõem ALFA1 tiveram evoluções do viés e do SDE variáveis, o que seria de esperar tendo em conta a análise efectuada com recurso às Tabelas 71 a 78. Além disto com recurso á Fig. 56 observa-se que os modelos STEPWISE-LR e SLR/MLR-3 tiveram evoluções do SDE semelhantes ao longo dos vários horizontes temporais, alternando entre si qual o melhor modelo para os horizontes temporais 06-12hr, 12-18hr e 18-24hr. O modelo KF calibrado para o horizonte temporal 00-06hr foi o que melhor desempenho obteve para esse horizonte, o mesmo já não se verificou para os restantes horizontes temporais. O modelo com piores valores de SDE foi de uma forma geral o modelo SLR/MLR-4. Relativamente ao viés associado aos modelos no período de validação verifica-se que este foi bastante variável entre si. O que poderá indicar em conjunto com a evolução do valor de SDE ao longo dos *time-steps* analisados que existe um bom espectro de previsões.

Analisando a Fig. 56 S-T) e B-T) verifica-se a mesma tendência verificada com recurso às Fig. 56 S-V) e B-V), em que se observou a progressão do erro variável entre os vários modelos desenvolvidos. Por outro lado, observa-se um elevado número de anomalias sendo que os modelos SLR/MLR-3 e STEPWISE-LR são os que menos anomalias de progressão apresentam.

Tendo ainda em atenção á variação brusca de potência eólica prevista, verifica-se que o modelo com menor anomalias registadas foram os modelos STEPWISE-LR e SLR/MLR-3. Relativamente aos restantes verifica-se um elevado número de anomalias.

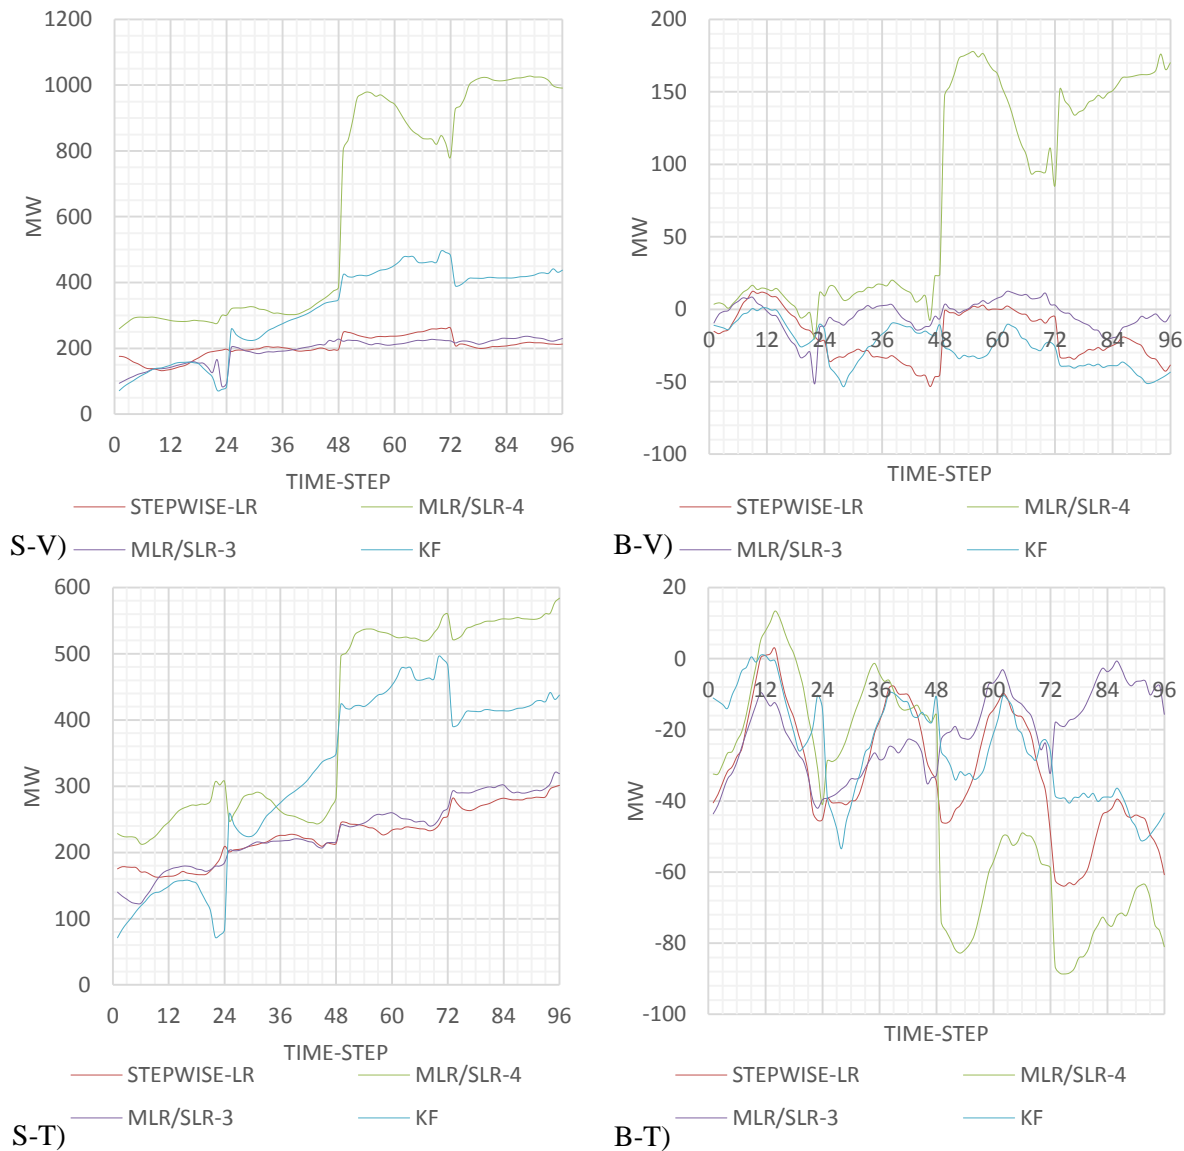


Fig. 56 – Gráfico síntese do valor de BIAS B) e SDE S) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA2 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).

Efectuando uma comparação entre Fig. 56 S-V) e S-T) observa-se que o valor de SDE teve uma progressão semelhante no período de validação e no período de teste, embora ligeiramente pior no período de teste. Por outro lado, comparando as Fig. 56 B-V) e B-T) observa-se que o a progressão do erro associado ao viés no período de teste foi distinto daquele observado no período de validação, no entanto, é de salientar que os modelos mantiveram um valor de viés semelhante entre si comparando os períodos de validação e de teste.

Atendendo á análise efectuada com recurso á Fig. 56 e tendo em conta a relação representada pela Equação 22, será expectável que o modelo KF seja o melhor modelo para o horizonte temporal das 00-06hr e que após este período os modelos SLR/MLR-3 e STEPWISE-LR alternem entre si como o melhor modelo.

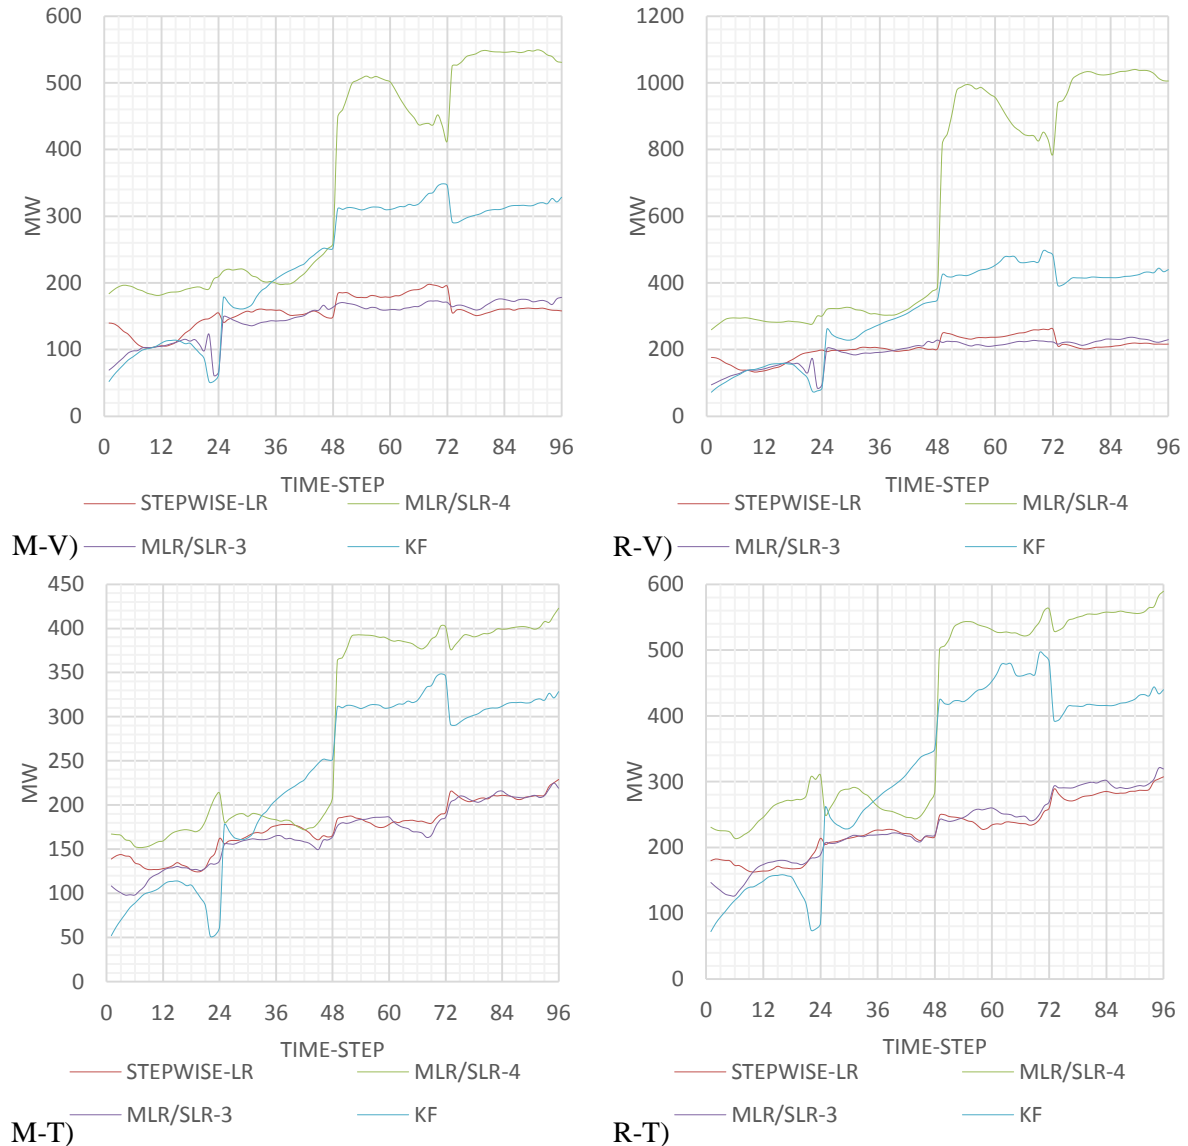


Fig. 57 – Gráfico síntese do valor de MAE M) e RMSE R) para as séries dos erros das previsões efectuadas com recurso ao módulo ALFA2 para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).

Como seria expectável pela diferença de cálculo dos valores de MAE e RMSE expresso nas Equações 20 e 19, respectivamente, verifica-se que estes são muito semelhantes embora os valores de MAE sejam de uma forma geral menores do que os erros associados ao RMSE, isto é corroborado através da comparação das Fig. 55 entre as figuras referentes à validação (M-V) e R-V)) e entre as figuras referentes ao período de teste (M-T) e R-T)).

Recorrendo à análise da Fig. 57, da Fig. 56 e à relação representada pela Equação 22 que o modelo com menor erro de MAE e RMSE associado foi o modelo KF para o horizonte temporal 00-06hr, relativamente aos restantes horizontes temporais os modelos SLR/MLR-3 e STEPWISE-LR alternaram entre si como o melhor modelo.

Analisando a Fig. 57 consegue-se observar que a progressão dos valores MAE e RMSE não foi semelhante no período de validação e no período de teste, recorrendo á observação da mesma figura verificam-se anomalias de progressão do erro, anteriormente verificadas com recurso á Fig. 56. Isto consegue-se observar analisando os primeiros *time-steps* (1-24) relativos ao primeiro horizonte temporal (00-06hr) e observando as previsões nos períodos de transição entre os horizontes temporais.

Comparando as Fig. 57 M-V) e M-T) ou Fig. 57 R-V) e R-T) observa-se que os modelos mantiveram a mesma progressão do erro, embora pior no período de teste, o que seria expectável já que todas as escolhas são efectuadas no período de calibração e validação. Verificando-se assim a robustez dos modelos.

Analisando as Fig. 56 e 57 verifica-se valores de BIAS, SDE, MAE e RMSE distintos para *time-step* consoante o modelo o que poderá indicar um espectro de previsões variado, o que poderá viabilizar a 3ª fase do modelo desenvolvido (2ª fase do módulo EMOS).

5.3 MODELO DESENVOLVIDO - MOSF+EMOS (3ª FASE)

No presente capítulo estão expostos os resultados obtidos com recurso ao emparelhamento do MOSF e EMOS, conforme descrito no capítulo 4.3, os quais consistem em: tratamento de previsões de base com recurso a MOSF; cálculo do espectro de previsões com recurso aos modelos que compõem os módulos ALFA1 e ALFA2 (sem recurso ao modelo KF); posterior agregação do espectro de previsões com recurso ao modelo MIX, que é uma variação do método *B.I. Tracking* abordado em 4.3.3, este tem como *input* as previsões efectuadas com recurso aos modelos que compõem os módulos ALFA1, ALFA2 (sem recurso ao modelo KF) e séries de previsão após MOSF, ver anexo C; cálculo de previsões com recurso ao módulo KF (variando as taxas de aprendizagem), que tem como *input* de dados, as previsões resultantes da primeira passagem pelo modelo MIX, que é uma variação do método *B.I. Tracking* abordado em 4.3.3; escolha da melhor taxa de aprendizagem do módulo KF, por *time-step*, com recurso ao modelo MIX, que é uma variação do método *B.I. Tracking* abordado em 4.3.3.

Tal como anteriormente referido em 4.2.1. os dados foram subdivididos em três intervalos distintos (calibração, validação e teste) por forma a garantir a independência destes e avaliar correctamente o modelo desenvolvido (MOSF+EMOS). Assim, os modelos foram calibrados no período de calibração, validados no período de validação e testada a sua robustez no período de teste. Assim, optou-se por analisar os resultados obtidos com recurso ao modelo desenvolvido no período de validação e comparar com os resultados obtidos no período de teste por forma a avaliar a sua robustez.

5.3.1 DESCRIÇÃO ESTATÍSTICA

Tabela 79- Descrição estatística das séries dos erros das previsões MOSF+EMOS para os vários horizontes temporais nos períodos de validação e de teste.

	00-06hr		06-12hr		12-18hr		18-24hr	
	Validação	Teste	Validação	Teste	Validação	Teste	Validação	Teste
\bar{E}	5,39	-22,91	-5,11	-21,25	-5,37	-21,24	9,44	-36,06
\tilde{E}	3,92	-15,72	5,46	-15,30	6,98	-16,59	16,58	-24,89
Moda	#N/A	#N/A	#N/A	-31,10	#N/A	-31,10	#N/A	#N/A
As_1	#N/A	#N/A	#N/A	9,85	#N/A	9,86	#N/A	#N/A
σ	127,71	124,94	172,65	176,37	183,35	186,44	204,51	236,78
Var	1,6E+04	1,6E+04	3,0E+04	3,1E+04	3,4E+04	3,5E+04	4,2E+04	5,6E+04
K	0,22	0,24	0,21	0,23	0,21	0,23	0,23	0,24
As_2	0,03	-0,17	-0,18	-0,10	-0,20	-0,07	-0,10	-0,14
Min	-643,40	-610,88	-606,01	-750,38	-989,10	-1039,38	-626,61	-983,64
Max	637,39	734,99	704,59	538,92	703,44	663,40	782,67	782,55
Q_1	-64,62	-94,87	-99,88	-118,58	-104,10	-123,97	-116,68	-166,52
Q_3	61,03	46,20	82,47	79,95	87,71	81,81	119,53	100,73
P_{90}	151,13	114,90	204,90	182,13	217,70	200,16	261,35	237,81
P_{10}	-138,15	-176,46	-222,98	-241,00	-228,84	-249,93	-254,94	-328,32
$\rho_{x,y}$	0,97	0,98	0,94	0,97	0,93	0,96	0,91	0,94

Analisando a Tabela 79 efectuou-se uma síntese dos resultados obtidos mais relevantes, apresentados na Tabela 80, por forma a facilitar a interpretação dos resultados obtidos com recurso ao modelo desenvolvido nos períodos de validação e teste para os vários horizontes temporais (00-06hr, 06-12hr, 12-18hr, 18-24hr). Assim, analisando as Tabelas 79 e 80, verifica-se que a forma da distribuição do erro obtido com recurso ao modelo desenvolvido sofreu poucas entre o período de validação e teste para os vários horizontes temporais avaliados. Por outro lado, observa-se que em módulo o valor da média aumenta no período de teste para todos os horizontes temporais. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este aumenta para no período de teste para os vários horizontes temporais. Relativamente ao desvio padrão, verifica-se que este valor diminuiu no período de teste para o horizonte temporal 00-06hr e que este mesmo valor aumenta para os restantes horizontes temporais estudados. Tendo em conta o valor médio do RMSE verifica-se que este aumenta no período de teste para todos os horizontes temporais avaliados.

Tendo em conta a análise efectuada é expectável que o modelo desenvolvido tenha piores desempenhos, por *time-step*, no período de teste do que no período de validação.

Tabela 80- Síntese da avaliação estatística das séries dos erros das previsões MOSF+EMOS para os vários horizontes temporais entre os períodos de validação e de teste.

Horizonte	Período	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
00-06hr	Validação	Aumenta	#N/A	Simétrica	Leptocúrtica	Diminui	Aumenta	127,82	Aumenta
	Teste		#N/A	Moderada	Leptocúrtica			127,02	
06-12hr	Validação	Aumenta	#N/A	Moderada	Leptocúrtica	Aumenta	Aumenta	172,72	Aumenta
	Teste		Positiva	Simétrica	Leptocúrtica			177,65	
12-18hr	Validação	Aumenta	#N/A	Moderada	Leptocúrtica	Aumenta	Aumenta	183,43	Aumenta
	Teste		Positiva	Simétrica	Leptocúrtica			187,64	
18-24hr	Validação	Aumenta	#N/A	Simétrica	Leptocúrtica	Aumenta	Aumenta	204,72	Aumenta
	Teste		#N/A	Moderada	Leptocúrtica			239,51	

5.3.2 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

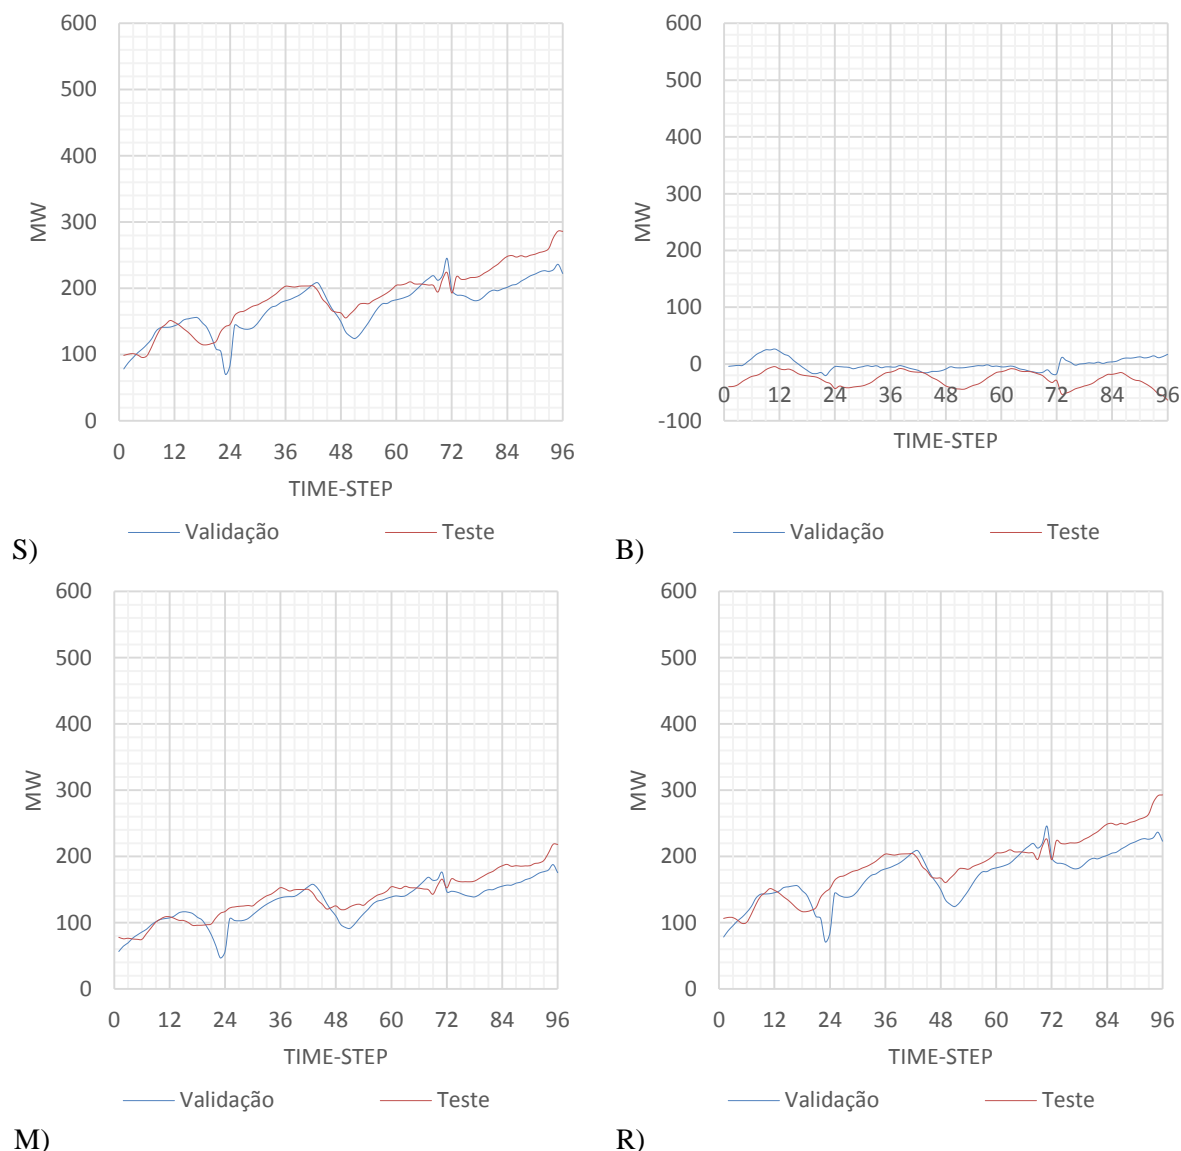


Fig. 58 – Gráfico síntese do valor de BIAS B), SDE S), MAE M) e RMSE R) para as séries dos erros das previsões MOSF+EMOS para o horizonte temporal 00-24hr nos períodos de validação e de teste.

Como se pode observar pela Fig. 58, verifica-se um ligeiro aumento dos erros (MAE, RMSE, BIAS e SDE) no período de teste face ao período de validação. Isto já era expectável através da análise efectuada com recurso às medidas de avaliação estatística.

Com recurso á Fig. 58, verifica-se que o modelo desenvolvido alcançou em média desempenhos semelhantes no período de validação e teste sendo que a maior diferença no desempenho entre estes dois períodos independentes foi para o horizonte temporal com maior tempo de vida, ou seja, o horizonte temporal 18-24hr. Analisando a progressão do erro (RMSE), verifica-se a ocorrência de anomalias ao longo dos horizontes temporais analisados, sendo que isto se torna prejudicial para efectuar uma correcta gestão do sistema.

Comparando as Fig. 58, observa-se que o modelo desenvolvido obteve piores desempenhos no período de teste do que no período de validação. O que era expectável, já que as escolhas com vista ao desenvolvimento do modelo (MOSF+EMOS) foram efectuada no período de calibração mas também

no período de validação. A maior diferença é observada para o horizonte temporal 18-24hr, sendo que, foi neste horizonte temporal que se verificou de forma mais frequente a ocorrência de lacunas.

5.4 COMPARAÇÃO ENTRE O MODELO DESENVOLVIDO (MOSF+EMOS) E MODELO REN

No presente capítulo pretende-se efectuar uma avaliação comparativa entre o modelo desenvolvido (MOSF+EMOS) face ao modelo REN no período de validação e no período de teste por forma a avaliar a robustez deste.

5.4.1 DESCRIÇÃO ESTATÍSTICA

Tabela 81- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 00-06hr nos períodos de validação e de teste.

	Validação		Teste	
	MOSF+EMOS	REN	MOSF+EMOS	REN
\bar{E}	5,39	20,00	-22,91	-34,84
\hat{E}	3,92	22,65	-15,72	-11,30
Moda	#N/A	65,50	#N/A	-99,00
As_1	#N/A	-45,5	#N/A	64,16
σ	127,71	163,48	124,94	165,57
Var	1,6E+04	2,7E+04	1,6E+04	2,7E+04
K	0,22	0,20	0,24	0,23
As_2	0,03	-0,05	-0,17	-0,43
Mín	-643,40	-548,20	-610,88	-775,00
Max	637,39	678,80	734,99	477,40
Q_1	-64,62	-59,08	-94,87	-106,10
Q_3	61,03	97,68	46,20	54,40
P_{90}	151,13	217,32	114,90	129,78
P_{10}	-138,15	-178,49	-176,46	-225,42
$\rho_{x,y}$	0,97	0,95	0,98	0,97

Analisando a Tabela 81, efectuou-se uma síntese dos resultados obtidos mais relevantes na Tabela 82 por forma a facilitar a comparação entre o modelo desenvolvido (MOSF+EMOS) e o modelo REN para o horizonte temporal 00-06hr nos períodos de validação e teste. Assim, analisando as Tabelas 81 e 82 verifica-se que a forma da distribuição dos erros relativos aos dois modelos foi muito semelhante quer no período de validação quer no período de teste. Por outro lado, observa-se que em módulo o valor da média foi menor para o modelo desenvolvido no horizonte temporal considerado para os períodos de validação e período de teste. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este valor é maior para o modelo desenvolvido nos vários períodos analisados. Relativamente ao desvio padrão, verifica-se que este valor era menor para o modelo desenvolvido nos vários períodos analisados. Tendo em conta o valor médio do RMSE para o horizonte temporal 00-06hr, verifica-se que este foi menor para o modelo desenvolvido quer no período de validação quer no teste.

Tabela 82- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 00-06hr nos períodos de validação e de teste.

Período	Modelo	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
Validação	MOSF+EMOS	Menor	N#A	Simétrica	Leptocúrtica	Menor	Maior	127,82	Menor
	REN		Negativa	Simétrica	Leptocúrtica			164,70	
Teste	MOSF+EMOS	Menor	N#A	Moderada	Leptocúrtica	Menor	Maior	127,02	Menor
	REN		Positiva	Moderada	Leptocúrtica			169,20	

Tabela 83- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 06-12hr nos períodos de validação e de teste.

	Validação		Teste	
	MOSF+EMOS	REN	MOSF+EMOS	REN
\bar{E}	-5,11	-12,13	-21,25	-88,91
\bar{E}	5,46	-10,00	-15,30	-54,60
Moda	#N/A	10,50	-31,10	-44,30
As ₁	#N/A	-22,63	9,85	-44,61
σ	172,65	217,42	176,37	241,76
Var	3,0E+04	4,7E+04	3,1E+04	5,8E+04
K	0,21	0,22	0,23	0,22
As ₂	-0,18	-0,03	-0,10	-0,43
Min	-606,01	-720,10	-750,38	-937,40
Max	704,59	683,90	538,92	714,10
Q ₁	-99,88	-136,38	-118,58	-207,65
Q ₃	82,47	109,58	79,95	55,60
P ₉₀	204,90	278,52	182,13	176,46
P ₁₀	-222,98	-278,34	-241,00	-433,94
$\rho_{x,y}$	0,94	0,91	0,97	0,94

Analisando a Tabela 83, efectuou-se uma síntese dos resultados obtidos mais relevantes na Tabela 84 por forma a facilitar a comparação entre o modelo desenvolvido (MOSF+EMOS) e o modelo REN para o horizonte temporal 06-12hr nos períodos de validação e teste. Assim, analisando as Tabelas 83 e 84 verifica-se que a forma da distribuição dos erros relativos aos dois modelos diferente no período de validação e no período de teste, sendo que, no período de validação o modelo REN teve uma melhor distribuição dos erros e no período de teste o modelo desenvolvido alcançou uma melhor distribuição. Por outro lado, observa-se que em módulo o valor da média foi menor para o modelo desenvolvido no horizonte temporal considerado para os períodos de validação e período de teste. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este valor é maior para o modelo desenvolvido nos vários períodos analisados. Relativamente ao desvio padrão, verifica-se que este valor era menor para o modelo desenvolvido nos vários períodos analisados. Tendo em conta o valor médio do RMSE para o horizonte temporal 06-12hr, verifica-se que este foi menor para o modelo desenvolvido quer no período de validação quer no teste.

Tabela 84- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 06-12hr nos períodos de validação e de teste.

Período	Modelo	$ \bar{E} $	As ₁	As ₂	K	σ	$\rho_{x,y}$	RMSE	
Validação	MOSF+EMOS	Menor	N#A	Moderada	Leptocúrtica	Menor	Maior	172,72	Menor
	REN		Negativa	Simétrica	Leptocúrtica			217,76	
Teste	MOSF+EMOS	Menor	Positiva	Simétrica	Leptocúrtica	Menor	Maior	177,65	Menor
	REN		Negativa	Moderada	Leptocúrtica			257,59	

Tabela 85- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 12-18hr nos períodos de validação e de teste.

	Validação		Teste	
	MOSF+EMOS	REN	MOSF+EMOS	REN
\bar{E}	-5,37	-12,72	-21,24	-85,03
\tilde{E}	6,98	-22,90	-16,59	-49,00
Moda	#N/A	16,00	-31,10	-5,50
As_1	#N/A	-28,72	9,86	-79,53
σ	183,35	236,59	186,44	272,46
Var	3,4E+04	5,6E+04	3,5E+04	7,4E+04
K	0,21	0,21	0,23	0,21
As_2	-0,20	0,13	-0,07	-0,40
Min	-989,10	-746,10	-1039,38	-999,90
Max	703,44	864,20	663,40	737,10
Q_1	-104,10	-146,80	-123,97	-213,95
Q_3	87,71	112,40	81,81	73,30
P_{90}	217,70	303,95	200,16	218,78
P_{10}	-228,84	-299,51	-249,93	-466,54
$\rho_{x,y}$	0,93	0,89	0,96	0,92

Analisando a Tabela 85, efectuou-se uma síntese dos resultados obtidos mais relevantes na Tabela 86 por forma a facilitar a comparação entre o modelo desenvolvido (MOSF+EMOS) e o modelo REN para o horizonte temporal 12-18hr nos períodos de validação e teste. Assim, analisando as Tabelas 85 e 86 verifica-se que a forma da distribuição dos erros relativos aos dois modelos diferente no período de validação e no período de teste, sendo que, no período de validação o modelo REN teve uma melhor distribuição dos erros e no período de teste o modelo desenvolvido alcançou uma melhor distribuição. Por outro lado, observa-se que em módulo o valor da média foi menor para o modelo desenvolvido no horizonte temporal considerado para os períodos de validação e período de teste. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este valor é maior para o modelo desenvolvido nos vários períodos analisados. Relativamente ao desvio padrão, verifica-se que este valor era menor para o modelo desenvolvido nos vários períodos analisados. Tendo em conta o valor médio do RMSE para o horizonte temporal 06-12hr, verifica-se que este foi menor para o modelo desenvolvido quer no período de validação quer no teste.

Tabela 86- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 12-18hr nos períodos de validação e de teste.

Período	Modelo	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
Validação	MOSF+EMOS	Menor	N#A	Moderada	Leptocúrtica	Menor	Maior	183,43	Menor
	REN		Negativa	Simétrica	Leptocúrtica			236,93	
Teste	MOSF+EMOS	Menor	Positiva	Simétrica	Leptocúrtica	Menor	Maior	187,64	Menor
	REN		Negativa	Moderada	Leptocúrtica			285,42	

Tabela 87- Descrição estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 18-24hr nos períodos de validação e de teste.

	Validação		Teste	
	MOSF+EMOS	REN	MOSF+EMOS	REN
\bar{E}	9,44	-0,86	-36,06	-76,65
\hat{E}	16,58	-6,50	-24,89	-44,30
Moda	#N/A	62,00	#N/A	-68,50
As_1	#N/A	-62,86	#N/A	-8,15
σ	204,51	247,68	236,78	285,43
Var	4,2E+04	6,1E+04	5,6E+04	8,1E+04
K	0,23	0,22	0,24	0,22
As_2	-0,10	0,07	-0,14	-0,34
Min	-626,61	-730,80	-983,64	-960,50
Max	782,67	1015,90	782,55	820,80
Q_1	-116,68	-143,88	-166,52	-223,80
Q_3	119,53	136,15	100,73	87,80
P_{90}	261,35	325,96	237,81	248,46
P_{10}	-254,94	-301,18	-328,32	-472,80
$\rho_{x,y}$	0,91	0,89	0,94	0,91

Analisando a Tabela 87, efectuou-se uma síntese dos resultados obtidos mais relevantes na Tabela 88 por forma a facilitar a comparação entre o modelo desenvolvido (MOSF+EMOS) e o modelo REN para o horizonte temporal 18-24hr nos períodos de validação e teste. Assim, analisando as Tabelas 87 e 88, verifica-se que a forma da distribuição dos erros relativos aos dois modelos foi muito semelhante quer no período de validação quer no período de teste. Por outro lado observa-se que em módulo o valor da média foi menor para o modelo desenvolvido no horizonte temporal considerado para os períodos de validação e período de teste. Tendo em conta o valor de $\rho_{x,y}$, observa-se que este valor é maior para o modelo desenvolvido nos vários períodos analisados. Relativamente ao desvio padrão, verifica-se que este valor era menor para o modelo desenvolvido nos vários períodos analisados. Tendo em conta o valor médio do RMSE para o horizonte temporal 06-12hr, verifica-se que este foi menor para o modelo desenvolvido quer no período de validação quer no teste.

Tabela 88- Síntese da comparação estatística das séries dos erros das previsões MOSF+EMOS e REN para o horizonte temporal 18-24hr nos períodos de validação e de teste.

Período	Modelo	$ \bar{E} $	As_1	$ As_2 $	K	σ	$\rho_{x,y}$	RMSE	
Validação	MOSF+EMOS	Menor	N#A	Simétrica	Leptocúrtica	Menor	Maior	204,72	Menor
	REN		Negativa	Simétrica	Leptocúrtica			247,68	
Teste	MOSF+EMOS	Menor	N#A	Moderada	Leptocúrtica	Menor	Maior	239,51	Menor
	REN		Negativa	Moderada	Leptocúrtica			295,54	

5.4.1 MEDIDAS DE AVALIAÇÃO DA PREVISÃO DE POTÊNCIA

Como se pode observar através das Fig. 59 B-V) e S-V) as previsões efectuadas com recurso ao modelo desenvolvido (MOSF+EMOS) e as previsões efectuadas com recurso ao modelo REN tiveram evoluções do BIAS e do SDE variáveis, sendo que os valores de SDE foram mais variáveis para o modelo desenvolvido ao longo dos horizontes temporais avaliados do que para o modelo REN. Por outro lado, relativamente ao BIAS verifica-se que a metodologia adoptada alcançou um valor de BIAS mais estável e menor em módulo, ao longo dos horizontes temporais, do que o modelo REN. O que seria expectável com recurso à análise efectuada com recurso às Tabelas 81-88.

Analisando a Fig. 59 S-T) e B-T), verifica-se de uma forma geral a mesma tendência observada no período de validação e confirmada através da descrição estatística efectuada com recurso às Tabelas 81-88.

Efectuando uma comparação entre Fig. 59 S-V) e S-T), observa-se que o valor de SDE teve uma progressão semelhante no período de validação e no período de teste para o modelo desenvolvido e diferente para o modelo REN. Da mesma forma, comparando as Fig. 59 B-V) e B-T), observa-se que o a progressão do erro associado ao BIAS no período de validação foi semelhante á progressão desta medida de erro no período de teste.

Atendendo á análise efectuada com recurso á Fig. 59 e tendo em conta a relação representada pela Equação 22, será expectável que o modelo desenvolvido (MOSF+EMOS) seja o melhor modelo para os horizontes temporais avaliados 00-24hr.

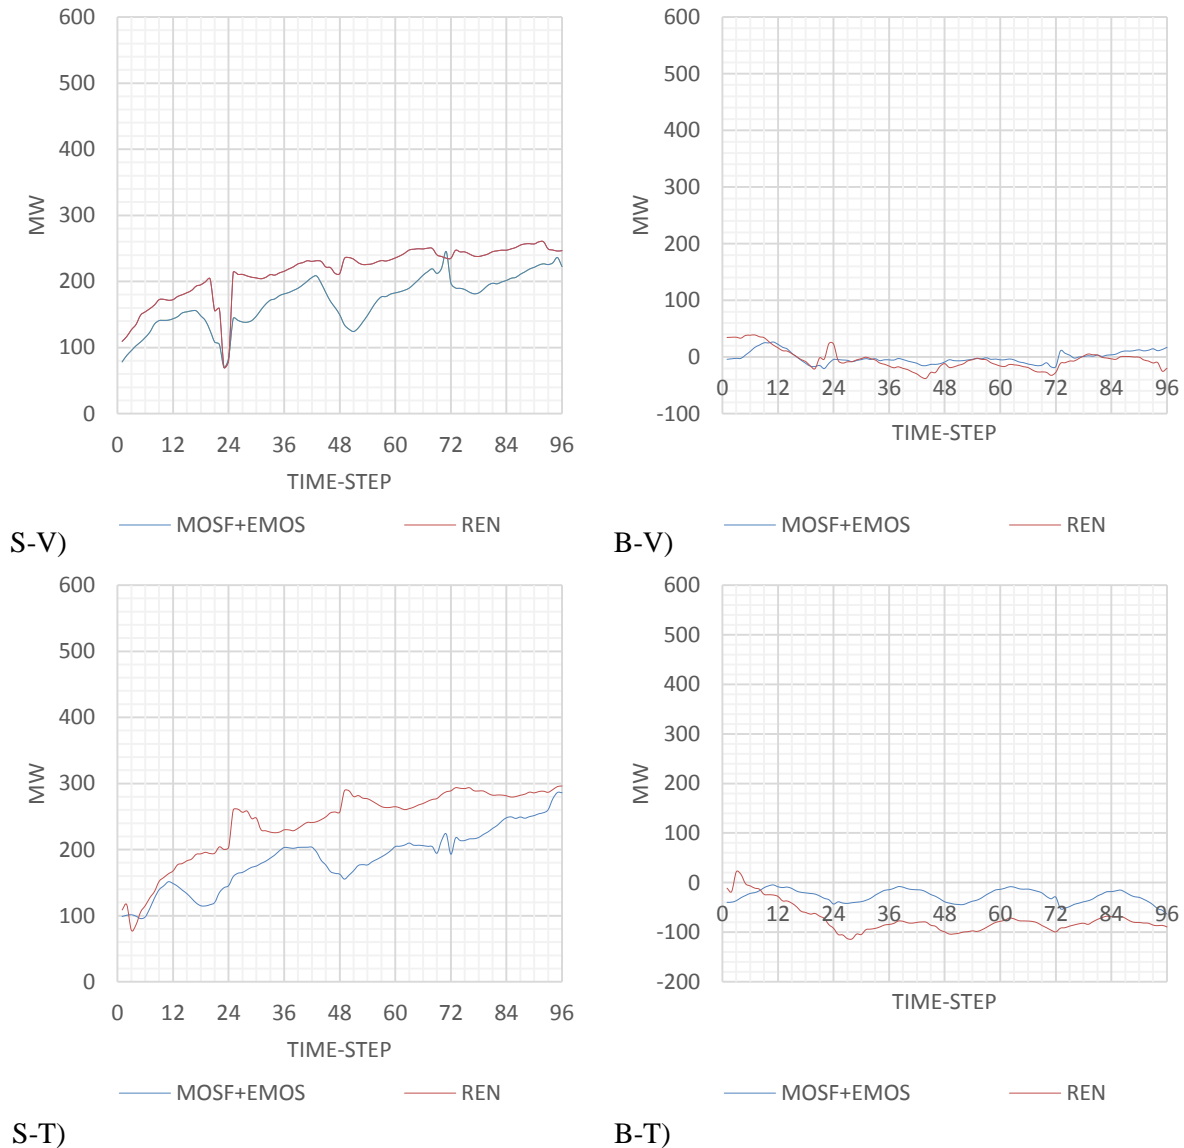


Fig. 59 – Gráfico síntese do valor de BIAS B) e SDE S) comparativamente entre as séries dos erros das previsões efectuadas com recurso ao modelo MOSF+EMOS e modelo REN para o horizonte temporal 00-24hr nos períodos de validação -V) e de teste -T).

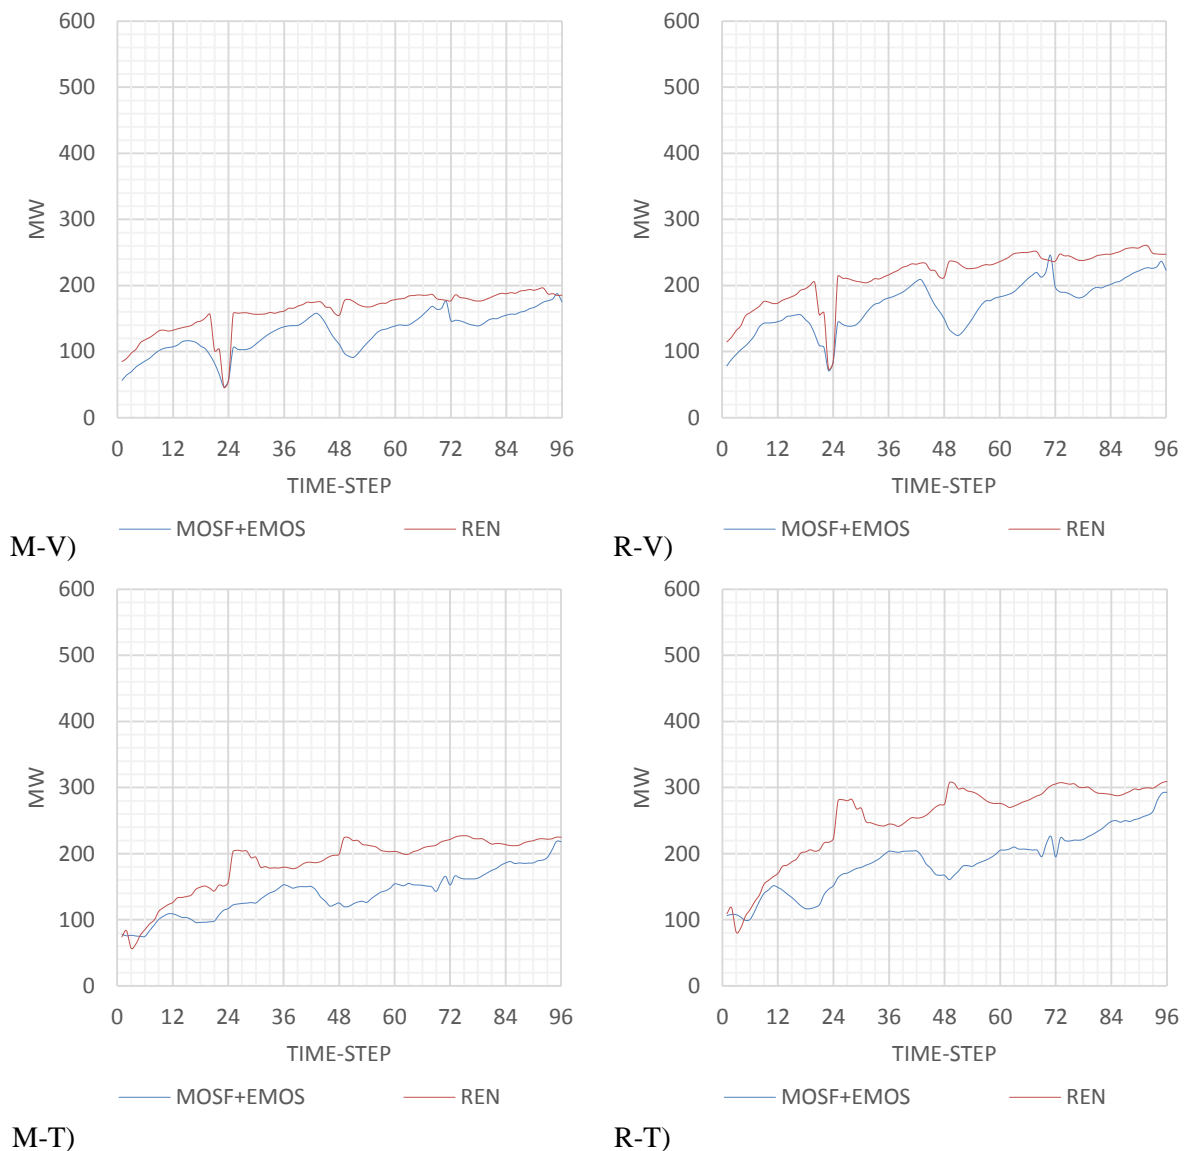


Fig. 60 – Gráfico síntese do valor de MAE (M) e RMSE (R) comparativamente entre as séries dos erros das previsões efectuadas com recurso ao modelo MOSF+EMOS e modelo REN para o horizonte temporal 00-24hr nos períodos de validação (-V) e de teste (-T).

Com recurso á análise das Fig. 59 e 60, verifica-se a robustez do modelo desenvolvido (MOSF+EMOS) já que se verificaram melhorias relativamente ao modelo REN no período de teste e no período de validação.

Comparando as Fig. 59 M-V) e M-T) ou Fig. 59 R-V) e R-T), observa-se que os modelos obtiveram piores desempenhos no período de teste do que no período de validação. Isto seria expectável para o modelo desenvolvido, já que as escolhas com vista ao desenvolvimento do modelo (MOSF+EMOS) foram efectuadas no período de calibração mas também no período de validação, conforme enumerado em 4.2. Relativamente ao modelo REN o mesmo já não se aplica e não obstante o modelo REN também apresenta piores resultados no período de teste relativamente ao período de validação.

Por outro lado quantificou-se em média a melhoria obtida com recurso ao modelo desenvolvido face ao modelo REN.

Tabela 89- Síntese das medidas de avaliação de potência em média e em função do horizonte temporal para o modelo desenvolvido (MOSF+EMOS) e para o modelo REN no período de teste.

	00-06hr		06h-12hr		12h-18hr		18h-24hr	
	MOSF + EMOS	REN	MOSF + EMOS	REN	MOSF + EMOS	REN	MOSF + EMOS	REN
MAE (MW)	93,98	117,52	132,12	186,16	139,19	207,59	177,98	216,27
RMSE (MW)	127,02	169,20	177,65	257,59	187,64	285,42	239,51	295,54
BIAS (MW)	-22,91	-34,84	-21,25	-88,91	-21,24	-85,03	-36,06	-76,65
SDE (MW)	124,94	165,57	176,37	241,76	186,44	272,46	236,78	285,43
NMAE (%)	3,65	4,56	5,13	7,23	5,40	8,06	6,91	8,39
NRMSE (%)	4,93	6,57	6,89	10,00	7,28	11,08	9,30	11,47
NBIAS (%)	-0,89	-1,35	-0,82	-3,45	-0,82	-3,30	-1,40	-2,97
NSDE (%)	4,85	6,43	6,85	9,38	7,24	10,57	9,19	11,08

A partir da tabela 89 e com recurso à Equação 29, efectuou-se os cálculos presentes na tabela 90. A qual é referente à comparação do modelo desenvolvido com o modelo REN para o período de teste.

Tabela 90- Síntese da comparação, das medidas de avaliação mais relevantes, do modelo desenvolvido (MOSF+EMOS) face ao modelo REN no período de teste.

	00h-06hr	06-12hr	12-18hr	18-24hr
MAE (IMP%)	23,59	21,39	23,37	15,66
RMSE (IMP%)	22,39	20,68	22,58	17,34
SDE (IMP%)	21,88	20,59	22,50	17,43

Intrepretando a Tabela 90 o modelo desenvolvido obteve, no período de teste, em percentagem de melhoria face ao modelo REN:

- Para o horizonte temporal 00-06hr em percentagem para as medidas de avaliação de previsão de potência NMAE (23,59%), NRMSE (22,39%) e NSDE (21,88%);
- Para o horizonte temporal 06-12hr em percentagem para as medidas de avaliação de previsão de potência NMAE (21,39%), NRMSE (20,68%) e NSDE (20,59%);
- Para o horizonte temporal 12-18hr em percentagem para as medidas de avaliação de previsão de potência NMAE (23,37%), NRMSE (22,58%) e NSDE (22,50%);
- Para o horizonte temporal 18-24hr em percentagem para as medidas de avaliação de previsão de potência NMAE (15,66%), NRMSE (17,34%) e NSDE (17,43%).

Como se pode observar pelas Tabelas 89 e 90 o modelo desenvolvido (MOSF+EMOS) alcançou um melhor desempenho do que o modelo REN, sendo isto suportado no período de teste pelos vários indicadores calculados para os vários horizontes temporais considerados.

Tabela 91- Síntese das medidas de avaliação de potência em média e em função do horizonte temporal para o modelo desenvolvido e para o modelo REN no período de validação.

	00-06hr		06h-12hr		12h-18hr		18h-24hr	
	MOSF + EMOS	REN	MOSF + EMOS	REN	MOSF + EMOS	REN	MOSF + EMOS	REN
MAE (MW)	91,03	119,13	128,35	163,27	135,13	176,34	156,32	185,35
RMSE (MW)	127,82	164,70	172,72	217,76	183,43	236,93	204,72	247,68
BIAS (MW)	5,39	20,00	-5,11	-12,13	-5,37	-12,72	9,44	-0,86
SDE (MW)	127,71	163,48	172,65	217,42	183,35	236,59	204,51	247,68
NMAE	3,53	4,62	4,98	6,34	5,24	6,84	6,07	7,19
NRMSE	4,96	6,39	6,70	8,45	7,12	9,20	7,95	9,61
NBIAS	0,21	0,78	-0,20	-0,47	-0,21	-0,49	0,37	-0,03
NSDE	4,96	6,35	6,70	8,44	7,12	9,18	7,94	9,61

A partir da tabela 89 e com recurso à Equação 29, efectuou-se os cálculos presentes na Tabela 90. A qual é referente à comparação do modelo desenvolvido com o modelo REN para o período de validação.

Tabela 92- Síntese da comparação, das medidas de avaliação mais relevantes, do modelo desenvolvido (MOSF+EMOS) face ao modelo REN no período de validação.

	00h-06hr	06-12hr	12-18hr	18-24hr
MAE (IMP%)	20,03	29,03	32,95	17,71
RMSE (IMP%)	24,93	31,03	34,26	18,96
SDE (IMP%)	24,54	27,05	31,57	17,05

Intrepretando as Tabelas 91 e 92 o modelo desenvolvido obteve, no período de validação:

- Para o horizonte temporal 00-06hr em percentagem para as medidas de avaliação de previsão de potência NMAE (20,03%), NRMSE (24,93%) e NSDE (24,54%);
- Para o horizonte temporal 06-12hr em percentagem para as medidas de avaliação de previsão de potência NMAE (29,03%), NRMSE (31,03%) e NSDE (27,05%);
- Para o horizonte temporal 12-18hr em percentagem para as medidas de avaliação de previsão de potência NMAE (32,95%), NRMSE (34,26%) e NSDE (31,57%);
- Para o horizonte temporal 18-24hr em percentagem para as medidas de avaliação de previsão de potência NMAE (17,71%), NRMSE (18,96%) e NSDE (17,05%).

Como se pode observar pelas Tabelas 91 e 92 o modelo desenvolvido (MOSF+EMOS) alcançou um melhor desempenho do que o modelo REN, sendo isto suportado no período de validação pelos vários indicadores calculados para os vários horizontes temporais considerados.

6. CONCLUSÕES

No presente capítulo optou-se pela nomenclatura MM5, WRF, WRF-STS e ALADIN, no entanto, estes são referentes às previsões em potência dos respectivos modelos após as várias transformações com vista a obterem-se previsões eólicas em valor de potência, conforme descrito no capítulo 3.4.10. Além disso optou-se também por PERS para referir o desfasamento da potência observada de 6 horas com recurso ao sistema SCADA, conforme descrito no capítulo 3.4.6.

No presente capítulo quando se refere a séries de previsões refere-se às previsões de base (MM5, WRF, WRF-STS e ALADIN) e aos dados de persistência (PERS).

6.1 PREVISÕES DE BASE, DADOS DE PERS E DADOS DE SCADA

6.1.1 DADOS DE SCADA

A série de dados SCADA foi calculada para a resolução estudada (*time-steps* de 15 minutos) com recurso a uma interpolação simples, conforme abordado em 4.2.3, já que apresentava uma resolução diferente (*time-steps* de 10 minutos), conforme referido no capítulo 4.2.

O método utilizado poderá não consistir no melhor método, no entanto, não foram estudados outros métodos para modificar a resolução da série de dados, isto porque o sistema SCADA regista dados em tempo real. Assim, no futuro poderá utilizar-se a média da potência eólica instantânea para os *time-steps* pretendidos (15 minutos). Desta forma o erro observado através da análise efectuada em 4.2.4. poderá em parte ser justificado pelo modo como é obtida a série de dados SCADA utilizada.

Outra fonte de erro poderá dever-se a problemas que se prendem com o próprio registo de dados (*software* e/ou *hardware*) e com problemas de transmissão e manutenção do serviço. Neste caso, os dados poderão ficar corrompidos inviabilizando a utilização de parte destes ou até mesmo uma perda generalizada, ainda que momentânea. Esta hipótese foi por poucas vezes verificada e embora esta acabe por não ter expressão na análise efectuada, já que não é um tipo de erro que ocorra de forma sistemática (pelo que o erro fica diluído), o mesmo poderá não acontecer no caso das previsões efectuadas com recurso a modelos enriquecidos com dados SCADA, pelo que este tipo de erro poderá comprometer o correcto funcionamento destes e até inviabilizá-los.

Apesar dos erros observados e apesar de se ter modificado a resolução dos dados de SCADA com recurso a interpolação simples, a série de SCADA modificada apresenta uma elevada qualidade, sendo em larga medida uma boa aproximação aos dados METER, conforme analisado no capítulo 4.2.4. No entanto, tendo em conta a análise efectuada em 4.2.4., verificou-se que a série de dados SCADA modificada foi ligeiramente subestimada face aos valores observados (METER) no período de validação (este período é descrito em 4.2.1.). Este facto poderá induzir os modelos executados posteriormente em erro, podendo assim diminuir a precisão dos mesmos.

6.1.2 PREVISÕES DE BASE

Quando se extraiu os dados, verificou-se que o horizonte temporal dos dados extraídos nem sempre correspondia ao horizonte temporal pretendido, isto porque se verificou a ocorrência de lacunas. Assim, por vezes, os dados extraídos eram referentes a horizontes de previsão com maiores tempos de vida. Embora se tenham verificado lacunas de dados isto ocorreu de forma esporádica.

A caracterização dos dados foi efectuada para o período de validação, pelo que não se sabe se estes erros se repetem ao longo da série de dados utilizada.

Verificou-se com recurso a análise efectuada em 4.2.5. que a qualidade dos dados de base é bastante variável. Sendo que, como seria expectável as previsões efectuadas para os horizontes temporais relativos a um futuro próximo apresentam um menor erro associado do que as previsões efectuadas para um futuro mais afastado.

Os predictores (MM5, WRF, WRF-STS e ALADIN) e os predictantes (SCADA e METER) estão bem correlacionados, tendo uma maior correlação para previsões com curtos tempos de vida (Ex:00-06hr) e menores para previsões com maiores tempos de vida (Ex:18-24hr), o que seria expectável. A excepção a isto foi a série de dados de PERS que apresentou de uma forma geral um valor baixo de correlação.

Na análise efectuada, verificou-se que a maior componente do erro (RMSE) associado às previsões foi a medida de dispersão SDE (Equação 22). Por outro lado observou-se que: os modelos MM5 e WRF apresentaram valores de RMSE, MAE, BIAS e SDE semelhantes entre si, o que se poderá dever ao facto de recorrerem ao mesmo modelo numérico de previsão global (GFS); o modelo WRF-STS embora recorra às previsões efectuadas com o mesmo modelo que o WRF, tem um módulo MOS acoplado o que permitiu efectuar previsões distintas das efectuadas com recurso ao modelo WRF. Além disso

verificou-se que o modelo WRF-STS apresentava valores de SDE competitivos com os valores de SDE dos modelos MM5, WRF e ALADIN; o modelo ALADIN foi o modelo numérico de previsão do tempo que apresentou os piores valores de MAE, RMSE e BIAS, no entanto, apresentava valores de SDE semelhantes ao MM5 e WRF; os dados de PERS foram a série de dados utilizada para efectuar previsões com piores indicadores de MAE, RMSE e SDE, no entanto apresentava valores de BIAS em módulo bastante reduzidos, o que seria expectável já que é o desfasamento da série de SCADA.

Por outro lado observam-se diferentes progressões e anomalias de progressão do erro semelhantes para os modelos MM5 e WRF e distintas destes para os restantes. Relativamente às diferentes progressões do erro estas poderão dever-se às configurações dos modelos numéricos utilizadas para efectuar previsões (uso do terreno, camada limite, ou outras), características dos modelos, número de corridas diárias e tipos de sensores a que recorrem para enriquecer os modelos de previsão. Atendendo às anomalias de progressão não se conseguiu identificar a causa exacta para todas as ocorrências, no entanto, ao interpretar os gráficos MAE, RMSE, BIAS e SDE (Fig. 31-34) regista-se a ocorrência do erro RMSE anormalmente elevado para os modelos WRF (*time-steps* 1-2), WRF-STS (*time-steps* 1-10), ALADIN (*time-steps* 1-18), sendo que isto se poderá dever a uma má extração de dados dos ficheiros fornecidos pela REN. Esta ocorrência ainda poderá ser justificada pela exclusão deficiente do *spin-up time* aquando da escolha dos dados a serem utilizados como *input* no modelo PCM, isto parece ser o caso dos modelos WRF-STS e WRF que têm uma anomalia semelhante, embora a anomalia observada referente ao modelo WRF seja em muito menor escala do que a observada para o modelo WRF-STS.

6.2 MÓDULO DE TRATAMENTO DE DADOS-MOS (1ªFASE)

Tendo em conta a análise efectuada em 5.1. verificou-se que o modelo MOSF alcançou em média um melhor desempenho do que os restantes modelos, no entanto, com recurso a uma análise mais aprofundada (observação das séries de previsão) verificou-se que por vezes este não seria o melhor, assim conclui-se que não existe um modelo de tratamento óptimo, assim seria desejável correr vários modelos de tratamento em paralelo e posteriormente agregar os vários modelos tendo em conta o seu desempenho (Ex: modelo MIX que é uma variação do método *B.I. Tracking*).

Verificou-se com recurso á Equação 22 que a maior componente do erro RMSE era o valor de SDE, no entanto, os modelos MOS estudados (MOS1, MOS2, MOS3 e MOS4) e o modelo MOS utilizado (MOSF) embora tenham conseguido reduzir os valores de SDE, não conseguiram reduzir da mesma forma que reduziram o viés, assim é necessário estudar outros modelos de tratamento com vista uma redução mais significativa deste valor do erro.

6.2.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON (MOS1)

O tratamento com recurso ao cálculo da correlação de Pearson tinha como objectivo reduzir a dispersão associada às previsões de base (conforme se constatou através da análise efectuada no capítulo 4.2.5.), no entanto este teve várias consequências entre elas um redução generalizada do valor de SDE com a consequência de um respectivo aumento do BIAS o que seria expectável, já que com recurso a MOS1 (representado pela Equação 30) se está a achatar a série de previsões. Ainda assim, regra geral, conseguiu-se uma ligeira melhoria na qualidade dos dados (ver Fig. 42 e 43), a qual foi sentida em maior escala por ordem decrescente para as previsões de base WRF e MM5, já os dados de PERS verifica-se que o tratamento não conseguiu atingir o objectivo pretendido, isto porque apresentava um coeficiente de correlação de Pearson reduzido.

Assim este tratamento de dados poderá nem sempre ser benéfico já que o coeficiente é calculado sobre uma série de dados históricos, que poderá não ter uma boa correspondência com o período actual, uma vez que não tem em conta acontecimentos esporádicos (ex: ciclos anuais, tempestades, etc). Além disso, não deverá ser utilizado um coeficiente demasiado baixo já que poderá ter o efeito contrário. Tendo isto em conta o coeficiente de correlação de Pearson não deverá ser utilizado só por si para efectuar o tratamento dos dados, nem deverá ser utilizado para séries de previsão com baixas correlações relativamente às observações. No entanto, quando aplicado correctamente este método apresenta melhorias marginais de MAE, RMSE e SDE face às previsões de base por outro lado torna-se apelativo,

visto que permitir efectuar o tratamento de dados sem recurso a actualizações de dados de SCADA, já que recorre a séries de dados históricas de previsão e valores de METER.

6.2.2 MÉDIA MÓVEL (MOS2)

O tratamento de dados com recurso a média móvel teve um impacto positivo mas marginal na melhoria da qualidade dos dados de previsão de base, conforme descrito pela análise efectuada em 5.1.2.

Com recurso á análise efectuada e efectuando uma comparação visual entre as previsões antes e após tratamento relativamente á potência observada verificou-se que o tratamento MOS2 melhorou a qualidade os dados no sentido em que atenuou os erros associados às previsões, possibilitando assim uma diminuição do erro associado em média para os horizontes temporais. Ainda assim, é de salientar que dependendo do modelo de previsão, o erro aumentou para certos *time-steps*, sendo que isto se consegue observar através das Fig. 44 e 45. Concluindo-se assim que o desempenho do MOS2 para melhorar a qualidade das previsões de base não foi homogénea ao longo dos *time-steps*.

Atendendo ao método de cálculo, exposto pela Equação 31 verifica-se que MOS2 apresenta como vantagem o facto de não precisar de ser enriquecido com dados de SCADA ou METER, necessitando apenas como *input* dados de previsão. Por outro lado tendo em conta o método de cálculo verifica-se que o presente método tem como desvantagem o facto de modificar as previsões tendo apenas por base os *time-steps* vizinhos modificando as piores previsões assim como as melhores previsões tendo como consequência suavizar as séries de dados. Tendo isto em conta e embora se tenham alcançado melhores previsões após tratamento este poderá nem sempre ser o mais adequado pelo que se deverá estudar os benefícios da média móvel face a outros tipos de filtro com vista a reduzir o erro associado às previsões com piores desempenhos sem detrimento das melhores previsões.

6.2.3 PREVISÃO ADAPTATIVA DO VIÉS (MOS3)

Verificou-se que o correcto funcionamento deste modelo variava em função da dimensão da janela móvel sobre a qual o viés era avaliado. Assim, verificou-se que para horizontes temporais com menores tempos de vida (Ex: 00-06hr) era necessária uma janela móvel reduzida e que para horizontes temporais com maiores tempos de vida era necessária uma janela móvel com maiores dimensões (Ex: 18-24hr). Assim, a variação que apresentou melhor desempenho foi aquela que recorria a uma janela móvel de dimensão variável, em função do horizonte temporal, sobre a qual os dados, pertencentes a um passado recente, eram avaliados.

Este modelo apresenta como desvantagem necessitar de enriquecimento de dados de SCADA para funcionar correctamente, pelo que isto deverá ser tido em conta, aquando do processo de implementação com vista á sua operacionalidade.

Verificou-se que o modelo de previsão do viés obtinha, por vezes, valores desfazados da realidade, isto porque, em certas ocasiões previa potências produzidas superiores à potência instalada e outras vezes previa potências eólicas negativas. Isto ocorreu quando os valores de potência a serem tratadas eram ou muito próximas de zero ou muito próximas da potência instalada. Assim, quando isto se verificava assumiu-se que as previsões eram desviesadas, isto é, assumiu-se que os dados de previsão não tinham viés e por isso mesmo não era necessário serem tratados.

Regra geral, MOS3 mostrou ser adequado para melhorar a qualidade dos dados de previsão para os vários horizontes temporais (Fig. 46 e 47). Desta forma, este método e respectiva variação demonstraram alcançar um bom desempenho mesmo para horizontes temporais com maiores tempos de vida (Ex: 18-24hr), quando os dados de SCADA utilizados para enriquecer o modelo estavam mais “distantes” dos dados de previsão a tratar. No entanto, verificou-se que o MOS3 obteve melhores desempenhos para tratar as previsões com menores tempos de vida, o que seria expectável.

Atendendo à eficácia do tratamento, verificou-se que, este não conseguiu melhorar a qualidade dos dados na mesma magnitude, sendo que, tendo em conta as medidas de avaliação da previsão MAE, RMSE, BIAS e SDE (Fig. 46 e 47) e a descrição estatística presente nas Tabelas 31 a 38, conclui-se que o modelo desenvolvido MOS3 alcançou um melhor desempenho para tratar as séries WRF-STS e ALADIN. Relativamente às previsões de base MM5 e WRF, conseguiu melhorar a qualidade das

previsões de base marginalmente e que tendo o modelo foi de uma forma geral incapaz de melhorar a qualidade dos dados, em média, conseguindo apenas melhorar os dados para os primeiros *time-steps*.

6.2.4 REGRESSÃO QUANTÍLICA ADAPTATIVA (MOS4)

O desempenho deste algoritmo foi bastante variável (Tabelas 39-46 e Fig. 48-49). Regra geral este processo não diminuiu o erro de forma significativa, tendo em muitos casos o efeito contrário ao desejado, já que se observa ou um aumento substancial do erro para algumas das séries de previsão de base ou de forma marginal um maior/menor valor do erro (MAE, RMSE, BIAS e SDE) das previsões. Isto verifica-se pela descrição estatística do erro (Tabelas 39-46), pelas medidas de avaliação (Fig. 47-48) e consequente análise efectuada em 5.1.4. Assim optou-se pela não utilização deste modelo só por si nem em conjunto com os restantes métodos de tratamento já que não se conseguiu obter melhorias significativas.

A metodologia adoptada é referente ao tratamento com recurso a janela móvel com a dimensão reduzida mas variável, consoante o horizonte temporal, compreendida entre 9-10 dias. Também se efectuou o estudo para janelas móveis com dimensão variável entre 2-3 dias e 4-5 dias. Com isso, verificou-se que quanto menor a dimensão da janela móvel mais a distribuição de densidade de probabilidade da série de previsão pós-tratamento (MOS4) se modificava, induzindo o modelo em erro, já que a consequência era semelhante a provocar um desfasamento da série das previsões á semelhança do efectuado para cálculo da série de dados de PERS. Por outro lado, quando se recorria a uma janela móvel de grandes dimensões as previsões de base e dados de PERS, antes e após tratamento eram muito semelhantes. Assim verificou-se que: com o aumento da dimensão da janela móvel, o algoritmo de tratamento perdia adaptatividade, não se conseguindo adaptar; com a recurso a janela móvel reduzida o modelo desenvolvido não conseguia determinar com sucesso a distribuição de densidade de probabilidade óptima para tratar a série de dados, sendo que isto, se poderá dever á variabilidade da produção de potência associada a este recurso energético e por isso levar a uma correspondência deficiente das várias distribuições de densidades de probabilidades. Desta forma, torna-se necessário aprofundar o estudo relacionado com a conjugação deste método com outras variações, como por exemplo; recorrer a uma biblioteca de previsões e observações contendo regimes sinópticos semelhantes e recorrendo a esses para definir a distribuição de densidade de probabilidade das previsões assim como das observações; variação especificando o tratamento por *time-step*; variação de *bootstrap*; utilização de *thresholds* mais conservativos; outras variações.

6.2.5 COMBINAÇÃO DE TRATAMENTOS (MOSF)

Verificou-se que o modelo alcançou uma redução dos valores de MAE, RMSE, BIAS e SDE para os vários *time-steps* pelo que se verifica uma certa adaptação do algoritmo de combinação dos tratamentos de dados.

Com a utilização da combinação dos tratamentos de dados obtiveram-se de uma forma geral melhorias na qualidade das previsões de base e dados de PERS o que é confirmado pela análise efectuada em 5.1. com recurso às Tabelas 47-62 e Fig. 50-53. Por outro lado, verifica-se que o modelo MOSF alcançou um melhor desempenho do que os outros tipos de tratamento obtiveram, em média, individualmente para o período de validação, sendo isto, também confirmado pela análise efectuada em 5.1. com recurso às Tabelas 47-62 e Fig. 50-53. Tal facto, indica que os vários modelos que compõem este modelo actuaram de forma distinta mas complementar sobre as previsões de base e dados de PERS.

Com a análise efectuada para o período de teste verificou-se que, neste ocorreu um aumento do valor de MAE, RMSE e SDE para os *time-steps* iniciais associados aos modelos MM5 e WRF que não se observava anteriormente no período de validação. Isto poderá dever-se a: ter sido efectuada uma rejeição menos adequada do *spin-up time* associado aos modelos de previsão; poderá relacionar-se, com uma extração deficiente durante o processo de extração de dados, dos ficheiros cedidos pela REN; outros erros de processamento de dados. Ainda assim e tendo em conta que se observou uma degradação das previsões no período de teste verificou-se a robustez do modelo já que, de uma forma geral, as previsões de base (MM5, WRF, WRF-STS e ALADIN) tratadas com recurso ao modelo desenvolvido (MOSF), alcançaram melhores valores de desempenho (MAE, RMSE, BIAS e SDE), em média, para o período

de validação e período de teste face às mesmas séries não tratadas. Também isto foi confirmado pela análise efectuada em 5.1.5. para as séries de previsão antes e após tratamento MOSF e para os horizontes temporais avaliados nos períodos de validação e teste.

Relativamente ao viés associado, verificou-se que o viés associado às previsões de base apresentava uma distribuição aproximada à distribuição normal, embora com algum erro, que se poderá dever ao reduzido número da amostra conforme se pode observar através da Fig. 61.

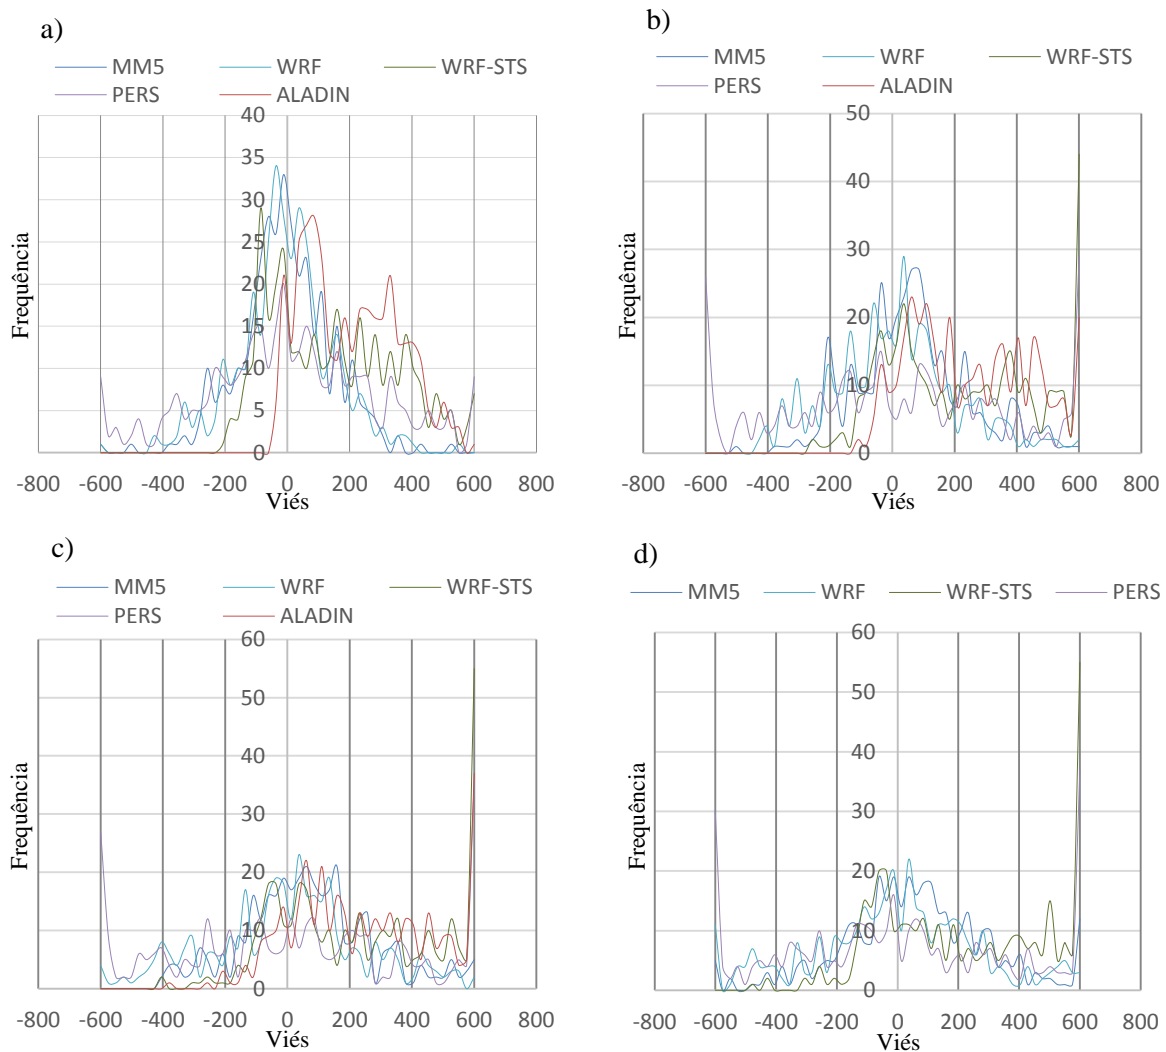


Fig. 61 – Histograma do valor do viés previsto para cada série de previsão em função do horizonte temporal: a) 00-06hr, b) 06-12hr, c) 12-18hr e d) 18-24hr.

Recorrendo á Fig. 61, consegue-se observar picos de valores de viés em que o viés associado às previsões toma por vezes valores de -600 e +600 MW, que tendem a ser mais pronunciados para horizontes temporais mais longos e para as séries de dados PERS, WRF-STTS e ALADIN, embora também ocorram para as séries de dados MM5 e WRF. A justificação para estas ocorrências é variável consoante a série de dados de previsão. Tendo em conta as séries MM5, WRF, WRF-STTS e ALADIN, estes picos surgem com o aumento do tempo de vida das previsões. Isto prende-se com o facto de se terem observado lacunas de dados e com o processo de cálculo das previsões para preencher essas lacunas conforme abordado no capítulo 4.2.2. Considerando a série de dados de PERS, a ocorrência de picos prende-se com o facto de existir uma considerável variabilidade de potência produzida num curto espaço de tempo que está associada á variabilidade do recurso energético, pelo que isto tem como consequência um maior viés entre as observações e as previsões.

Verificou-se que o modelo MOSF, á semelhança do modelo de previsão adaptativa do viés (MOS3) obtinha, por vezes, valores desfazados da realidade, isto porque, em certas ocasiões previa potências

eólicas superiores à potência instalada e outras vezes previa potências eólicas negativas. Isto ocorreu quando os valores de potência a serem tratadas eram ou muito próximas de zero ou muito próximas da potência instalada. Assim, quando isto se verificava assumiu-se que as previsões eram desviesadas, isto é, assumiu-se que os dados de previsão não tinham viés e por isso mesmo não era necessário serem tratados com recurso a MOSF.

6.3 PREVISÕES DE POTÊNCIA (2ªFASE)

Poderá ser vantajoso inserir outros módulos em que se varia a dimensão da janela móvel sobre a qual são calculados os coeficientes regressivos, dado que, em certa medida, os mesmos permitem uma maior adaptatividade dos modelos às previsões, podendo não ser tão dependentes dos valores da persistência. Isto é, um módulo que calibre os coeficientes regressivos em janela de dimensão variável (entre 1 ano e 10 dias), já que isto poderá concentrar o que de melhor tem o módulo ALFA1 (nomeadamente, a relativa independência dos dados de SCADA, pois o melhor modelo foi regra geral o que continha um maior número de predictores), e o que de melhor tem o módulo ALFA2 (adaptatividade). Assim, será necessário efectuar um estudo que recorra aos mesmos dados em que se varia a janela de cálculo dos coeficientes regressivos (ex: 1, 3, 6, 9 e 12 meses).

O módulo ALFA1 pode ser vantajoso para períodos pós-carência de dados em que não existam dados suficientes dos vários modelos para escolher qual o melhor modelo ou calibrar os coeficientes regressivos para um determinado futuro próximo, ou seja, para efectuar previsões de potência para horizontes temporais que recorram a períodos que contenham parte ou totalmente períodos de carência das previsões.

Não se conseguiu atingir todos os objectivos a que se propunha o estudo da combinação módulo ALFA1 com o módulo ALFA2, já que o módulo ALFA1 recorreu a dados não tratados e o módulo ALFA2 recorreu a dados tratados, além disso o módulo ALFA2 teve a possibilidade de utilizar as previsões de base ALADIN e WRF-STS como *input* contrariamente ao módulo ALFA1.

Apesar de não se ter utilizado todas as séries de dados de previsão consideradas na presente dissertação no módulo ALFA1, verificou-se que os modelos que o compõem alcançaram desempenhos competitivos relativamente aos modelos que compõem o módulo ALFA2 para previsões com maiores tempos de vida (12-24hr). Além disso, a comparação entre o desempenho dos módulos SLR/MLR de ALFA1 e ALFA2, leva a acreditar que caso os módulos SLR/MLR do módulo ALFA1, recorressem às previsões tratadas e a um número igual de predictores a que recorre o módulo ALFA2, então os módulos SLR/MLR do módulo ALFA1 poderiam obter melhores resultados para horizontes temporais com maiores tempos de vida.

Verificou-se que os modelos do módulo ALFA1 que recorriam a vários predictores para efectuar uma previsão foram os que melhor desempenho alcançaram; ou seja, regra geral, o modelo tinha melhores desempenhos consoante o número de predictores a que recorria. Contrariamente a isso, no módulo ALFA2 os modelos que melhor desempenho alcançaram nem sempre recorriam a vários predictores. A justificação para isto, prende-se com dimensão reduzida da janela móvel em que se efectuou o cálculo dos coeficientes regressivos, sendo possível inferir que quanto maior o número de predictores mais específica era a previsão, pelo que, numa fase futura, perdia valor (ocorria um *overfitting*).

Verificou-se que os módulos ALFA1 e ALFA2 conseguiram efectuar um espectro alargado de previsões.

A agregação dos vários modelos que compõem os módulos verificou-se benéfica já que permitiu melhorar as previsões de cada módulo. Contudo, com a utilização deste método de agregação verificou-se um elevado aumento do ruído do sinal, pelo que este foi tratado com recurso à média móvel. Este procedimento demonstrou ser benéfico já que eliminou o ruído em larga medida. No entanto, este método apresenta como desvantagem a modificação o sinal da previsão, pelo que a utilização de filtros poderá trazer mais benefícios do que uma simples média móvel.

Com recurso ao estudo efectuado no anexo C verificou-se que era vantajoso utilizar as previsões tratadas (após MOSF) como *input* no modelo MIX (variação do método *B.I. Tracking*). Assim, as

previsões de base tratadas com recurso a MOSF foram á semelhança das previsões efectuadas com recurso ao módulo ALFA1 e ALFA2 utilizadas como *input* na primeira passagem pelo modelo *B.I. Tracking*.

A previsão de potência à saída de alguns módulos teve alterações abruptas ao longo do tempo, o que não é desejável, devendo ser tido em conta para efectuar um sistema operacional. É importante a consideração destas variações, dado que as mesmas não ocorrem com esta magnitude num intervalo tão curto. Por outro lado, para efectuar um sistema operacional deverá ter-se em conta estas especificidades já que retiram valor às previsões.

6.3.1 MÓDULO ALFA1

Como seria expectável, as previsões efectuadas com recurso ao módulo ALFA1 obtiveram melhores desempenhos do que os dados que utilizaram como *input*, verificando-se a viabilidade da metodologia adoptada para melhorar as previsões.

Os modelos SLR/MLR consistem em combinações de predictores com variações do método e com variação da metodologia comuns entre si. Tendo isto em conta e efectuando-se uma análise dos vários modelos que compõem um módulo SLR/MLR verificou-se que o melhor modelo que compõem um determinado módulo SLR/MLR do módulo ALFA1 tinha tendência a ser aquele que incluía o maior número de predictores disponíveis á data independentemente da variação utilizada.

Os resultados obtidos com os módulos SLR/MLR-1, SLR/MLR-2, SLR/MLR-3 e SLR/MLR-4 não foram constantes ao longo dos vários horizontes temporais nem foram constantes nos períodos de validação e teste. No entanto, os modelos, após agregação, obtiveram de uma forma geral desempenhos muito semelhantes entre si nos vários horizontes temporais estudados assim como nos períodos de validação e teste.

Com base na análise efectuada em 5.2. verifica-se que, o enriquecimento dos modelos que compõem ALFA1, com recurso a dados de SCADA não influenciou, de forma significativa, a previsão final. Isto poderá ser a consequência dos modelos serem variações do mesmo método, não apresentando variações significativas entre si.

Verificou-se que nem todos os modelos contribuíram, da mesma forma, para alargar/diversificar o espectro de previsão.

Verificou-se que não existe um melhor modelo em detrimento dos restantes modelos. Isto poderá indicar que o módulo ALFA1 efectua um espectro de previsões deficiente. Além disso, poderá indicar que as melhores previsões de cada módulo são muito semelhantes entre si.

O cálculo dos coeficientes regressivos com recurso a janela móvel é mais exigente a nível computacional, pelo que os benefícios em efectuar previsões com recurso a janela móvel poderá não justificar, o possível, melhor desempenho. Assim, poderá ser preferível a utilização de outros métodos distintos por forma a diversificar o espectro de previsão necessário para o correcto funcionamento do módulo desenvolvido.

A utilização dos dados de PERS nem sempre foi benéfico, tendo uma má qualidade. No entanto, a utilização destes nos modelos SLR/MLR (ALFA1) trouxe melhorias marginais face à não utilização destes dados, isto porque o melhor modelo tendia a incluir este predictor.

O módulo ALFA1 tem como desvantagem recorrer a uma série de dados, relativas a um ano de dados históricos, pelo que necessita que exista uma prestação de serviços de pelo menos um ano o que nem sempre é viável. Assim, este modelo apenas poderá ser viável quando se têm contratos celebrados á pelo menos um ano.

6.3.2 MÓDULO ALFA2

Seria expectável, as previsões efectuadas com recurso ao módulo ALFA2 obtivessem melhores desempenhos do que os dados que utilizaram como *input*, no entanto, o mesmo não se verificou para todos os modelos. O que se poderá dever a uma má calibração (KF) ou ao tipo de variação utilizada

(SLR/MLR-4). Por outro lado, verificou-se que os modelos que obtiveram o melhor desempenho no período de validação foram diferentes dos que obiveram um melhor desempenho no período de teste.

Os modelos que compõem o módulo ALFA2 verificaram-se mais precisos quando se utilizava valores de *input* mais precisos, pelo que se verificou a vantagem de tratar os dados com recurso ao módulo MOSF e utilizar como *input* os dados tratados resultantes deste modelo para efectuar previsões.

O módulo SLR/MLR-3 obteve um bom desempenho a par do STEPWISE-LR, obtendo um melhor desempenho relativamente ao STEPWISE-LR para os primeiros *time-steps* no período de validação. Isto pode dever-se ao critério de selecção inerente ao modelo STEPWISE-LR que não permite que este atribua o peso necessário às observações de SCADA, podendo ser esta a razão pela qual o STEPWISE-LR obteve um melhor desempenho do que o modelo SLR/MLR-3 para horizontes temporais com maiores tempos de vida. Apesar de os dois modelos terem obtido desempenhos com base no RMSE muito semelhantes o módulo SLR/MLR-3 resulta das várias combinações possíveis dos predictores, pelo contrário o STEPWISE-LR consiste num modelo que efectua a melhor combinação *a priori* pelo que não acarreta as necessidades computacionais inerentes ao modelo SLR/MLR-3, devido a isso o modelo STEPWISE-LR poderá ser o mais vantajoso com base no rácio desempenho/necessidades computacionais.

O modelo com pior desempenho foi o módulo SLR/MLR-4, sendo que este obteve o pior desempenho em todos os horizontes temporais. Isto poderá dever-se à variabilidade do recurso aliado à forma definida para efectuar a escolha da melhor previsão no período anterior para o futuro próximo.

Verificou-se que nem todos os modelos contribuíram, da mesma forma, para alargar/diversificar o espectro de previsão.

A calibração do modelo STEPWISE-LR (escolha da janela móvel e critério de inclusão presente no anexo B) mostrou ser adequada já que se verificou que o modelo teve desempenhos competitivos relativamente a outros modelos, por outro lado verificou-se que este modelo alcançou valores de erro semelhantes no período de validação e no período de teste, verificando-se a sua robustez.

A inclusão de predictores pelo modelo STEPWISE-LR foi bastante conservadora tal pode ser explicado pela dimensão reduzida da janela móvel sobre a qual são calculados os coeficientes regressivos, já que quanto menor a dimensão da janela maior a adaptatividade, o que nem sempre é benéfico, devido á variabilidade do recurso eólico. Isto é visível pela calibração do critério de inclusão. Assim, tendencialmente foram escolhidos um a dois predictores e muito raramente foram excedidos os 3 predictores.

Com recurso a análise efectuada em 5.2.2 verifica-se que o KF poderá ter sido beneficiado por utilizar dados de previsão mais precisos. Por outro lado as variações do modelo KFem que se manipulava a taxa de aprendizagem correctamente, alcançou de uma forma geral melhores desempenhos que os restantes modelos. No entanto, é necessário estudar outras taxas de aprendizagem para os vários horizontes temporais, já que com isto se poderá alcançar melhores desempenhos. Da mesma forma, outras taxas de aprendizagem poderão ser utilizadas por forma a suavizar as variações de potência abruptas verificadas pela análise efectuada em 5.3. Por outro lado, verificou-se que a taxa de aprendizagem não era constante ao longo do mesmo horizonte temporal. Assim conclui-se que não existiu uma taxa de aprendizagem que prevalecia sobre as restantes, sendo que a utilização de várias taxas de aprendizagem se mostrou complementar, isto pode ser verificado através da Fig. 62.

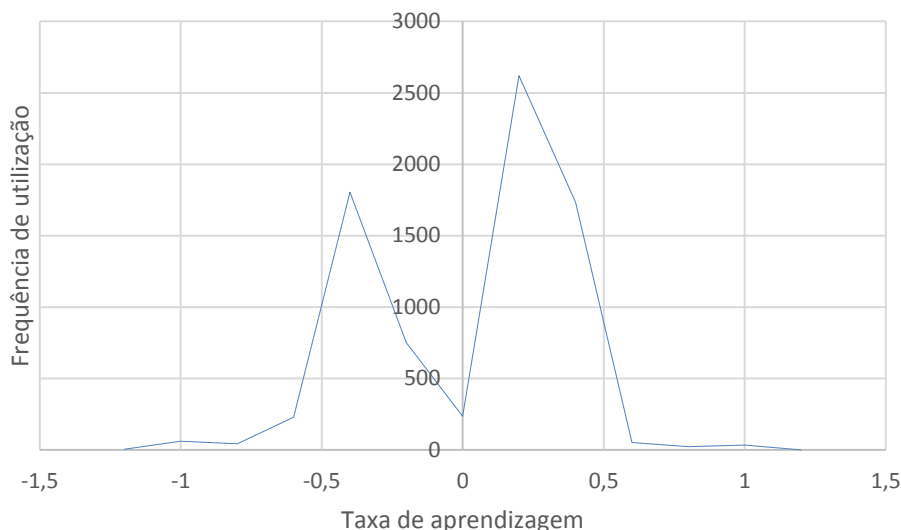


Fig. 62 – Taxa de aprendizagem utilizada para o horizonte temporal 18-24hr.

Tendo em conta a análise efectuada em 5.2.2. referentes á variação desenvolvida do modelo KF. Verificou-se que os resultados obtidos no período de teste foram consistentes com os resultados obtidos no período de validação. É de realçar a eficácia do modelo para reduzir o erro obtido associado aos primeiros *time-steps*, já anteriormente abordado.

Por outro lado, verificou-se que a variação do Filtro de Kalman desenvolvido (KF) utilizado conseguiu reduzir o SDE e o BIAS de forma eficaz. Além disso, a variação do modelo utilizada parece ter uma relativa independência dos dados de SCADA quando comparado com outros modelos que compõem ALFA2 mas mais dependente do que o modelo SLR/MLR-1 pertencente ao módulo ALFA1.

Tendo em conta os resultados obtidos pelo modelo KF acoplado ao modelo MIX, verificou-se que através da simulação da variância das observações se conseguiu obter melhores resultados do que através dos modelos que recorriam à calibração dos coeficientes regressivos acoplado ao modelo MIX.

Com base na análise efectuada em 5.2.2. verifica-se que o módulo ALFA2 apresenta uma maior variabilidade do erro do que o modulo ALFA1, assim isto poderá significar um espectro alargado de previsões de potência, o que poderá por sua vez melhorar o desempenho do modelo desenvolvido.

6.3.3 ESTUDO DA CONTRIBUIÇÃO DE VÁRIOS MODELOS (MOSF+MIX)

O modelo MIX conforme já abordado anteriormente no capítulo 4.3.3. recorre às várias previsões disponíveis ao momento de previsão, independentemente do modelo e do horizonte temporal, para efectuar a melhor previsão para um dado *time-step*. Este modelo demonstrou que por vezes as previsões a horizontes temporais mais longos têm um melhor desempenho do que as previsões optimizadas para o horizonte temporal. Deste modo, constata-se que será benéfico efectuar combinações de vários predictores independentemente do tempo de vida das previsões utilizadas, assim confirmou-se que a utilização de previsões a diferentes tempos de vida poderia ser benéfico para alargar o espectro de previsões o qual foi abordado em 3.4 e defendido em [93].

O modelo MIX (variação de *B.I. Tracking* 4.3.) foi o que obteve melhor rácio desempenho/necessidades computacionais. Este modelo não alcançou um desempenho constante ao longo dos vários horizontes temporais, sendo que obteve melhores desempenhos para horizontes temporais 00-06hr e 18-24hr e piores desempenhos para os horizontes temporais 06-12hr e 12-18hr.

Como se pode verificar através das Tabela 94-95, a configuração do modelo MIX utilizada pelos restantes modelos foi adequada ao estudo da contribuição dos vários modelos, isto porque se conseguiu obter melhores resultados do que os predictores a que recorre individualmente.

Por outro lado, comparando as Tabelas 94-95 com as Tabelas 81-88 verifica-se que este modelo acoplado ao módulo MOS alcançou previsões com desempenhos semelhantes ao modelo REN.

Tendo em conta o estudo presente no anexo C, verificou-se que, a série de previsão após MOSF+MIX não foi utilizada da melhor forma, já que esta nova série pode ser utilizada como *input* nos módulos ALFA e assim retirar o máximo partido desta. Assim, numa próxima etapa isto deverá ser tido em conta por forma a enriquecer estes módulos.

6.4 MIX (3ªFASE)

Tendo em conta o estudo no anexo C verificou-se que a utilização do modelo MIX para efectuar uma nova previsão era vantajoso, assim, na primeira passagem pelo modelo MIX utilizaram-se como *input* previsões as previsões efectuadas com recurso aos módulos ALFA1, ALFA2 e previsões tratadas com recurso a MOSF.

O modelo MIX teve uma elevada importância para viabilizar o módulo EMOS já que efectuou a agregação das previsões após tratamento (MOSF), previsões ALFA1 e previsões ALFA2, posteriormente foi responsável pela escolha da melhor taxa de aprendizagem para um determinado *time-step* (conforme descrito em 4.3.). No entanto, esta variação pode anular as variações positivas dos modelos, pelo que será desejável estudar diferentes métodos de agregação ou variações de selecção. Por exemplo, avaliar o desempenho com recurso a duas janelas móveis, a primeira de dimensão longa responsável por filtrar as previsões que em média apresentam melhor desempenho e uma segunda de reduzidas dimensões com vista a prever qual a melhor previsão dentro dessas.

Este modelo apresenta como principal desvantagem a ocorrência de ruído, pelo que foi necessário efectuar o tratamento do *output* dos dados do modelo. Isto foi efectuado com recurso a média móvel. No entanto, esta poderá não ser a forma mais correcta de eliminar o ruído já que isto tem como consequência uma alteração da forma do sinal das previsões, pois é uma média aritmética dos valores contidos na janela móvel. Assim, será desejável efectuar um estudo sobre qual a melhor forma de eliminar o ruído.

6.5 COMPARAÇÃO ENTRE MODELO MOSF+EMOS E MODELO REN

A comparação entre o modelo REN e o modelo desenvolvido (MOSF+EMOS) foi efectuada nos períodos de validação e teste. No entanto, por forma a manter a independência dos dados, a comparação entre estes para definir qual o melhor modelo deve ser efectuada apenas no período de teste. No entanto, apresentam-se valores relativos ao período de validação.

A melhoria não foi constante ao longo dos vários horizontes temporais. Verificando-se que, para o horizonte temporal 18-24hr ocorreu uma melhoria das previsões em menor escala do que para os restantes horizontes de previsão analisados.

Caso se desenvolvesse um módulo MOS específico para efectuar o tratamento das previsões finais, poderia-se obter um melhor desempenho, isto porque, verificou-se algum ruído associado ao modelo desenvolvido.

6.6 CONCLUSÕES GERAIS

Com o recurso a várias previsões de base e dados de PERS conseguiu-se obter melhores resultados do que utilizando apenas um deles individualmente ou até rejeitando só os dados de PERS.

A análise com recurso às medidas de avaliação de potência foram ao encontro das medidas de avaliação. A análise efectuada com recurso á metodologia adoptada foi complementar, conseguindo-se caracterizar o erro de forma adequada para o período analisado.

O período de teste foi de reduzidas dimensões pelo que será necessário avaliar qual o desempenho deste num período de previsão mais longo, isto porque a energia eólica apresenta uma elevada variabilidade ao longo de um ano. Além disso, é necessário avaliar como o modelo se comporta em

períodos de carência e noutros períodos em que se verifiquem os vários tipos de erros susceptíveis de ocorrer e que ponham em causa o modelo desenvolvido.

Põe-se em hipótese ter um ocorrido um erro durante o processo de extração de dados dos ficheiros cedidos pela REN. O qual se pode ter devido a alguns ficheiros estarem na hora civil e outros na hora aparente para Portugal continental.

A presente dissertação alcançou os objectivos pretendidos (enunciados no capítulo 1) já que permitiu com a modelo desenvolvido (MOSF+EMOS) reduzir o erro associado para os vários horizontes temporais.

Do ponto de vista da operacionalidade do sistema poderão advir vantagens se se desenvolver um módulo que efectue previsões com recurso a previsões desfasadas, quer positivamente quer negativamente. Isto terá como objectivo capturar os erros inerentes à previsão que estão associados com o momento exacto a partir do qual essas previsões entram em vigor. Assim, com recurso a um módulo deste género conseguir-se-ia melhorar a operacionalidade do sistema sempre que ocorressem erros de fase.

Na presente dissertação efectua-se uma previsão passiva, isto é, as previsões foram efectuadas periodicamente a cada 6 horas, no entanto, com vista a alargar as funcionalidades do modelo desenvolvido poderá ser interessante efectuar uma previsão adaptativa (a cada n *time-steps*). Isto porque, permitiria melhorar a operacionalidade do modelo, já que seria possível identificar possíveis erros e assim emitir alertas e aconselhar o TSO sobre medidas a tomar quando estes ocorressem, ou seja, melhorar a gestão do sistema, conforme abordado em 3.3.2.

O modelo desenvolvido abre a porta a monitorização dos erros, de forma probabilística. Isto porque o módulo EMOS efectua um variado espectro de previsões. Assim, as previsões efectuadas com recurso a este módulo poderão ser utilizadas no futuro para efectuar uma melhor gestão do sistema mais coerente.

7. TRABALHO FUTURO

Com vista à implementação do modelo desenvolvido deverá ser iniciado o processo de debugging. Durante o processo de debugging deverá ser dada especial atenção ao modo como o modelo reage aos tipos de erros: aumentos súbitos de potência (rampas), rajadas, eventos extremos, erros de modelo (erros de fase, de magnitude e de variação), erros de sensores, carência de dados e outras dificuldades técnicas pertinentes. O processo de debugging deverá ser efectuado para o sistema de previsão sempre que se adicione um novo módulo de previsão, por forma a verificar se existe conflito.

No contexto da melhoria das previsões de base e das observações, utilizadas pelo modelo desenvolvido:

- Requisitar a todos os fornecedores, quando possível, a mesma resolução dos modelos numéricos de previsão do tempo;
- Caso não existam, medições *in situ* de velocidade e direcção do vento á altura da turbina, instalar sensores que permitam medir estes parâmetros à altura da turbina;
- Estudar vários métodos com vista à modelação da curva de potência característica, recorrendo a diferentes tipos de dados *online* (Ex: velocidade e direcção do vento e/ou densidade do ar e/ou *output* de potência e/ou pressão, etc);
- Utilização de módulos MOS em vários pontos do sistema com vista à redução dos erros sistemáticos, especialmente à entrada do modelo de conversão de potência (PCM);
- Utilizar dados de SCADA referentes à média da potência eólica instantânea no *time-step* adequado, isto é, referente ao *time-step* dos modelos numéricos de previsão do tempo.

No contexto da optimização do Módulo MOSF, apresentado na presente dissertação, seria vantajoso:

- Estudar a aplicabilidade de MOS4 com recurso a biblioteca de previsões e observações categorizadas;
- Estudar outras técnicas de tratamento MOS que permitam reduzir o valor de SDE, enriquecendo o módulo MOS;
- Estudar tipos métodos de agregação/cominação com vista a desenvolver um sistema MOS, com uma maior adaptatividade do que MOSF, que permita identificar qual a melhor combinação de modelos MOS para um determinado *time-step*;
- Desenvolver uma variação do modelo *B.I. Tracking* que permita identificar qual a melhor combinação de modelos MOS para um determinado *time-step*, e assim dotar o módulo MOS de uma certa adaptatividade.

No contexto da optimização do Módulo EMOS, apresentado na presente dissertação, seria vantajoso:

- Aplicar o modelo MIX para efectuar uma nova série de previsões com recurso ao *input* dos restantes modelos numéricos de previsão após MOSF. Desta forma, poderia-se utilizar esta nova série de dados para enriquecer o módulo ALFA;
- Estudar a aplicabilidade do modelo STEPWISE-LR no módulo ALFA1;
- Estudar a aplicabilidade do método dos mínimos quadrados para o módulo ALFA1;
- Melhorar a taxa de aprendizagem do módulo KF;
- Estudar a utilização de diferentes valores estatísticos para aferir o desempenho dos modelos; isto é, a avaliação dos modelos teve por base a medida de RMSE em média para um determinado intervalo passado, sendo que este consiste no valor mais relevante. No entanto, outros valores estatísticos (distância interquartil, entre outros) poderão melhorar essa escolha;
- Estudar diferentes módulos “ALFA” com diferentes períodos de calibração e diferentes configurações daqueles desenvolvidos;
- Desenvolver um módulo “BETA” que recorra à combinação de diferentes previsões com diferentes tempos de vida para efectuar previsões de potência;
- Estudar outras técnicas que permitam agregar as várias previsões, tais como as que foram anteriormente mencionadas no capítulo 3.1, nomeadamente a AEC, a AFTER e outras.

No contexto de alargamento das funcionalidades do modelo desenvolvido MOSF+EMOS, apresentado na presente dissertação, seria vantajoso:

- Efectuar uma previsão adaptativa a par da previsão passiva;
- Estudar a aplicabilidade de um módulo “GAMMA” que efectuasse previsões com recurso a séries de previsões desfazadas no tempo. Ao dotar o sistema de previsão de um módulo deste, poderia estar-se a dotar o sistema de uma ferramenta operacional, já que as previsões podem estar desfazadas da realidade. Assim, um módulo deste género permitiria por um lado identificar esta ocorrência, alertando o TSO e, por outro, poderia efectuar previsões viáveis com recurso às séries desfazadas;
- Estudar um módulo “TETA” com vista à monitorização do erro de forma probabilística, o que permitiria por um lado fornecer ao TSO dados sobre a viabilidade, precisão ou valor das previsões, aconselhando o TSO. Por outro lado, permitiria dotar o sistema com repostadas adequadas, emitir alertas de erro e aconselhar o TSO sobre as medidas a tomar face a um determinado erro;
- Estudar um módulo “PHI” com vista a previsão de rampas ascendentes, assim como rampas descendentes, já que para se efectuar uma correcta gestão do sistema é necessário ter em conta as variações abruptas de potência eólica.

Assim, tendo em conta as prioridades do TSO, que deverão ser estabelecidas, por exemplo em função do rácio custo/desempenho, deverá ser efectuado um plano tendo em vista a implementação faseada de parte das medidas aqui apresentadas. Uma primeira fase poderá passar pela implementação do modelo desenvolvido ao mesmo tempo que se põem em prática os pontos referentes a “melhoria das previsões de base e das observações”.

REFERÊNCIAS

- [1] Comissão das Comunidades Europeias. (2013, Janeiro). “Duas vezes 20 até 2020 - as alterações climáticas, uma oportunidade para a Europa. U.E.,” Disponível: <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2008:0030:FIN:PT:PDF>
- [2] Redes Energéticas Nacionais S.A.. (2013, Janeiro). Disponível: <https://www.ren.pt>.
- [3] Redes Energéticas Nacionais S.A. (2013, Janeiro). Plano de Desenvolvimento e Investimento da Rede Nacional de Transporte de Electricidade 2012-2017 (2022). Disponível: [http://www.centrodeinformacao.ren.pt/PT/publicacoes/PlanoInvestimentoRNT/PDIRT%202012-2017%20\(2022\)/PDIRT%202012-2017%20\(2022\)%20-%20Julho%202011.pdf](http://www.centrodeinformacao.ren.pt/PT/publicacoes/PlanoInvestimentoRNT/PDIRT%202012-2017%20(2022)/PDIRT%202012-2017%20(2022)%20-%20Julho%202011.pdf)
- [4] Wind Energy Handbook. (2013, Janeiro). Gurit. Disponível: <http://www.gurit.com/wind-energy-handbook-1.aspx>
- [5] Enercon GMBH. (2013, Abril). Disponível:<http://www.enercon.de/>. (http://www.enercon.de/p/downloads/ENERCON_PU_en.pdf)
- [6] A.R. Trancoso, J. Delgado Domingos, Pedro Torres, Rui Pestana (Janeiro, 2013), Online Monitoring and Prediction of Wind Power: Portuguese Transmission System Operator’s Methodology. Disponível: http://meteo.ist.utl.pt/public/publicacoes/ENER06_ISTREN.pdf
- [7] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, E. Feitosa, “A review on the young history of the wind power short-term prediction,” *Renewable and Sustainable Energy Reviews*, vol. 12, pp. 1725-1744, Agosto de 2008.
- [8] C. Notis, D. Trettel, J. Aquino, T. Piazza Taylor, D. Trask, et al. Learning to forecast wind at remote sites for wind energy applications. PNL-4318, Pacific Northwest Laboratory, 1983.
- [9] H. Wegley, M. Kosorok, W. Formica, Subhourly wind forecasting techniques for wind turbine operations. PNL-4894, Pacific Northwest Laboratory, 1984.
- [10] H. Geerts, “Short range prediction of windspeeds: a system-theoretic approach,” in: Palz W, *Proceedings of European wind energy conference*, Hamburg, Germany, pp. 594-9, 1984.
- [11] E. Bossanyi, “Short-term wind prediction using Kalman filters”, *Wind Eng*, 1985.
- [12] B. Bailey, R. Stewart, “Wind forecasting for wind power stations,” in: *Proceedings of the ninth British wind energy association conference*, Edinburgh, 1987.
- [13] I. Troen, L. Landberg, “Short term prediction of local wind conditions,” in: *Proceedings of European community wind energy conference*, Madrid, Spain, pp. 76-78, 1990.
- [14] A. Fellows, D. Hill, “Wind and load forecasting for integration of wind power into a meso-scale electrical grid,” in: *Proceedings of European community wind energy conference*, Madrid, Spain, pp. 636-40, 1990.
- [15] S. Watson, J. Halliday, L. Landberg,, “Assessing the economic benefits of numerical weather prediction model wind forecasts to electricity generating utilities,” in: Clayton B, *Proceedings of wind energy conversion*, pp. 291-297, Nottingham, UK, 1992.
- [16] U. Jensen, E. Pelgrum, H. Madsen, “The development of a forecasting model for the prediction of wind power production to be used in central dispatch centres,” in: Tsipouridis J, editor. *Proceedings of European wind energy conference*, pp. 353-356. Thessaloniki-Macedonia, Greece, 1994.
- [17] H. Madsen, “Models and methods for predicting wind power,” Denmark: IMM, ELSAM, SEP, 1996.
- [18] L. Lin, J. Eriksson, H. Vihriala, L. Soderlund, “Predicting wind behaviour with neural networks,” in: Zervos A, Ehmann H, Helm P, editors. *Proceedings of European union wind energy conference*, pp. 655-658. Goteborg, Sweden, 1996.

- [19] A. J. Bowen, N.G. Mortensen, “Exploring the limits of WASP: the Wind Atlas Analysis and Application Program,” in: Proceedings of the 1996 European Union Wind Energy Conference, Goteborg, Sweden, 20-24 May, 1996.
- [20] E. Akylas, M. Tombrou, J. Panourgias, D. Lalas, “The use of common meteorological predictions in estimating short term wind energy production in complex terrain,” in: Proceedings of European wind energy conference, pp. 329-332, Dublin Castle, Ireland, 1997.
- [21] B. Bailey, M. Brower, J. Zack, “Short-term wind forecasting—development and application of a mesoscale model,” in: Proceedings of European wind energy conference, Nice, 1999.
- [22] H. Beyer, D. Heinemann, H. Mellinshoff, K. Monnich, H. Waldl, “Forecast of regional power output of wind turbines,” in: Proceedings of European wind energy conference, Nice, 1999.
- [23] T. Nielsen, A. Joensen, H. Madsen, L. Landberg, G. Giebel, “A new reference for wind power forecasting”, *Wind Energy*, vol. 1, pp-29-34, 1999.
- [24] A. Sfetsos, “A comparison of various forecasting techniques applied to mean hourly wind speed time series,” *Renewable Energy*, vol. 20, pp-23-25, 2000
- [25] M. Lange, H. Waldl, Assessing the uncertainty of wind power predictions with regard to specific weather situations. In: Proceedings of European wind energy conference, Copenhagen, 2001.
- [26] R. Watson, L. Landberg, R. Costello, D. McCoy, P. O'Donnell, “Evaluation of the Prediktor wind power forecasting system in Ireland,” in: Proceedings of European wind energy conference, Copenhagen, 2001.
- [27] G. Giebel, L. Landberg, T. Nielsen, H. Madsen, “The Zephyr-Project—the next generation prediction system,” in: Proceedings of European wind energy conference, Copenhagen, 2001.
- [28] L. Marti, T. Nielsen, H. Madsen, J. Navarro, A. Roldan, D. Cabezon, et al. “Prediction models in complex terrain,” in: Proceedings of European wind energy conference, Copenhagen, 2001.
- [29] U. Focken, M. Lange, K. Monnich, H. Waldl, H. Beyer, A. Luig, A., “Short-term prediction of the aggregated power output of wind farms—a statistical analysis of the reduction of the prediction error by spatial smoothing effects,” *J Wind Eng Ind Aerodyn*, vol.3, pp-231-236, 2002
- [30] A. Costa, A. Crespo, E. Migoya, “First results from a prediction project,” in: Proceedings of European wind energy conference, Madrid, 2003.
- [31] A. Palomares, M. de Castro, “Short-term wind prediction model at the Strait of Gibraltar based on a perfect prognosis statistical downscaling method,” in: Proceedings of European wind energy conference, Madrid, 2003.
- [32] T. Lozano, “Prediction and planning of wind energy production,” in: Proceedings of European wind energy conference, Madrid, 2003.
- [33] W. Yuan-kang, H. Jing-Shan, “Alternative review of forecasting technology in the world,” unpublished.
- [34] Y. V. Makarov, D. L. Hawkins, E. Leuze, J. Vidov, “California ISO Wind Generation Forecasting Service Design And Experience,” in: Proc. of the 2002 AWEA Windpower Conference, Portland, Oregon, June 2-5, 2002.
- [35] C. Gallardo, M. Gaertner, C. Tejada, N. Martinez, S. Calabria, N. Martinez, N., et al. “The Casandra project: first results of a new wind power operational forecasting system in Spain,” in: Proceedings of European wind energy conference, Madrid, 2003.
- [36] P. Pinson, G. N. Kariniotakis, “Wind Power Forecasting using Fuzzy Neural Networks Enhanced with On-line Prediction Risk Assessment”, 2003.
- [37] G. Giebel, L. Landberg, G. Kariniotakis, R. Brownsword, “State-of-the-Art on Methods and Software Tools for Short-Term Prediction of Wind Energy Production”, 2003.

- [38] H. Madsen, G. Kariniotakis, H. Nielsen, T. Nielsen, P. Pinson, "A protocol for standardizing the performance evaluation of short-term wind power prediction models," in: Proceedings of global windpower conference and exhibition, Chicago, 2004.
- [39] E. Bustamante, A. Cofino, J. Navarro, J. Gutierrez, A. Roldan, "Wind speed downscaling combining mesoscale and neural autoregressive models," in: Proceedings of European wind energy conference, London, 2004.
- [40] P. Pinson, G. Kariniotakis, "On-line assessment of prediction risk for wind power production forecasts," *Wind Energy* 2004, vol.7, pp. 119-32.
- [41] G. Kariniotakis, I. Martí, D. Casas, P. Pinson, T. Nielsen, H. Madsen, G. Giebel, J. Usaola, I. Sanchez, A. M. Palomares, R. Bownsword, J. Tambke, U. Focken, M. Lange, P. Louka, G. Kallos, C. Lac, G. Sideratos, G. Descombes, "What performance can be expected by short-term wind power prediction models depending on site characteristics?," in: Proceedings of European wind energy conference, London, 2004.
- [42] J. Torres, A. Garcia, M. De Bias, A. De Francisco, "Forecast of hourly average wind speed with ARMA models in Navarre (Spain)," *Solar Energy*, vol.79, pp-65-77, 2005
- [43] H. Madsen, P. Pinson, G. Kariniotakis, H. Nielsen, T. Nielsen, "Standardizing the performance evaluation of short-term wind power prediction models," *Wind Energy*, vol.29, pp.475-89, 2005.
- [44] H. Nielsen, H. Madsen, T. Nielsen. "Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts," *Wind Energy*, vol. 9, pp. 95-108, 2006.
- [45] A. Cenã, "Avanzando en la gestionabilidad. Eólica 2006," Asociación Empresarial Eólica, Madrid, 2006.
- [46] I. Martí, G. Kariniotakis, P. Pinson, I. Sanchez, T. S. Nielsen, H. Madsen, G. Giebel, J. Usaola, A.M. Palomares, R. Brownsword, J. Tambke, U. Focken, M. Lange, G. Sideratos, G. Descombes. (2013, Janeiro). Evaluation of Advanced Wind Power Forecasting Models – Results of the Anemos Project.
Disponível:http://www.researchgate.net/publication/47417632_Evaluation_of_Advanced_Wind_Power_Forecasting_Models_Results_of_the_Anemos_Project
- [47] A. Costa, A. Crespo, J. Navarro, A. Palomares, H. Madsen, "Modelling the integration of mathematical and physical models for short-term wind power forecasting," in: Proceedings of European wind energy conference, Athens, 2006.
- [48] E. Cadenasa, W. Riverab, "Wind speed forecasting in the South Coast of Oaxaca," *Renewable Energy*, vol. 32, pp.2116-2128, 2007.
- [49] IEA. (2013, Janeiro). 3rd Joint Action Symposium on Forecasting: Optimal Use of Available Information in Wind Power Forecasting, Disponível: http://www.ieawind.org/Task_11/joint_action/Forecasting_3.pdf
- [50] M. J. Duran, D. Cros, J. Riquelme. (2013, Fevereiro). Short-term wind power prediction based on AR models, sd. Disponível: <http://www.aedie.org/9CHLIE-paper-send/374-DURAN.pdf>
- [51] L. Fugon, J. Juban, G. Kariniotakis, "Data mining for Wind Power Forecasting," in European Wind Energy Conference, Brussels 2008.
- [52] I. Sánchez, "Adaptive combination of forecasts with application to wind energy," *International Journal of Forecasting*, vol. 24, pp. 679-693, 2008.
- [53] A. Kusiak, H. Zheng, Z. Song, "Wind Farm Power Prediction: A Data-Mining Approach," *Wind Energy*, vol. 12, pp-275-293, 2008.
- [54] A. Yamaguchi, T. Ishihara, K. Sakai, T. Ogawa, Y. Fujino, "A Physical-Statistical Approach for the Regional Wind Power Forecasting," unpublished.
- [55] J. K. Møller, H. A. Nielsen., H. Madsen, "Time-adaptive quantile regression," *Computational Statistics & Data Analysis*, vol. 52, pp. 1292-1303, 2007.

- [56] I. J. Ramirez-Rosado, L. A. Fernandez-Jimenez, C. Monteiro, J. Sousa, R. Bessa, “Comparison of two new short-term wind-power forecasting systems,” *Renewable Energy*, Vol.34, pp. 1848-1854, Jul. 2009.
- [57] NERC, “Variable Generation Power Forecasting for Operations,” North American Electric Reliability Corporation, Princeton, 2010.
- [58] J. Mendes, R. J. Bessa, H. Keko, J. Sumaili, V. Miranda, C. Ferreira, J. Gama, A. Botterud, Z. Zhou, J. Wang, “Development and Testing of Improved Statistical Wind Power Forecasting Methods,” Argonne National Laboratory and INESC, Argonne, 2011.
- [59] B. Greaves, J. Collins, J. Parkes, A. Tindal, “Temporal Forecast Uncertainty for Ramp Events,” unpublished.
- [60] AWS Truewind-LLC, “AWS Truewind's Final Report for the Alberta Forecasting Pilot Project,” Alberta, Canada, 2008.
- [61] C. W. Potter, E. Gritmit, B. Niyssen, “Potencial Benefits of a Dedicated Probabilistic Rapid Ramp Event Forecast Tool,” IEEE, Seattle, 2009, pp. 1-5.
- [62] N. Amjady, F. Keynia, H. Zareipour, “A new hybrid iterative method for short-term wind speed forecasting,” *Electrical Power*, vol. 21, pp. 581-595, 2010.
- [63] Lv Peng, Y. Lili, “Short term wind speed forecasting based on non-stationary time series analysis and ARCH model,” *Multimedia Technology (ICMT)*, Hangzhou, 2011.
- [64] J. A. Dominguez Navarro, J. S. Artal, H. Bludswit, J. L. Bernal-Augustin, R. Fufo, “Improved wind forecasting with wavelets,” in: *International Conference on Renewable Energies and Power Quality*, Santiago de Compostela, 2012.
- [65] M. Lydia, S. S. Kumar, A. I. Selvakumar, G. E. P. Kumar. A comprehensive review on wind turbine power curve modeling techniques. *Renewable and Sustainable Energy Reviews*, vol. 30, pp. 452-460, 2014.
- [66] C. Monteiro, R Bessa, V. Miranda, “Wind Power Forecasting: State-of-the-Art 2009,” Decision and Information Sciences Division, Argonne National Laboratory, Argonne, Illinois, 2009.
- [67] J. Usaola, J. Angarita. (2013, Janeiro). Benefits of short term wind power prediction programs for the integration of wind energy in electricity markets. Disponível: http://proceedings.ewea.org/ewec2006/allfiles2/640_Ewec2006fullpaper.pdf
- [68] T. Montmerle, “Data Assimilation Strategies for Operational NWP at Meso-scale and Implication for Nowcasting,” WMO/WWRP Workshop on Use of NWP for Nowcasting. UCAR, Boulder, CO, USA, 24-26 Outubro de 2011
- [69] *Statistical Analysis and data-mining applications*. Elsevier Inc. London. 2009.
- [70] U. Fayyad, G. Piatetsky-Shapiro, P. Smyth, R. Uthurusamy, “Advances in Knowledge Discovery and Data Mining,” Menlo Park, CA: AAAI Press. 1996.
- [71] D. Hand, H. Mannila, P. Smyth. *Principles of Data Mining*. Cambridge, MA and London, England: The MIT Press: A Bradford Book. 2001.
- [72] J. Han, M. Kamber. *Data Mining: Concepts and Techniques* (2nd ed.). Morgan Kaufmann. San Francisco, 2006.
- [73] U. Bhatt, J. Zhang, J. Walsh, J. Krieger, S. Bourne, A. Liljedahl (2013, Fevereiro). Atmospheric downscaling techniques and applications. IARC Modeling Summer School. Disponível: (http://www.iarc.uaf.edu/sites/default/files/summerschool/2012/presentations/7-18/Uma_Bhatt.pdf)
- [74] *A user's guide for the CALMET meteorological model*. Earth Tech, Inc. Concord, MA, 1999.
- [75] R. M. Cox, J. Sontowski, C. M. Dougherty, “An evaluation of three diagnostic wind models (CALMET, MCSCIPUF, and SWIFT) with wind data from the Dipole Pride 26 field experiments,” *Meteorol. Appl.* vol.12, pp.329–341, 2005

- [76] J. Palma, A. R. Trancoso, D. Domingos (2013, Fevereiro). Spatial Resolution Optimization for Wind Forecast. Disponível: http://meteo.ist.utl.pt/public/publicacoes/Valencia_2005.pdf
- [77] O. Undheim. “The non-linear microscale flow solver 3DWind,” PhD Dissertation, Department of Energy and Process Engineering, Norwegian University of Science and Technology, Trondheim, Norwegian, 2005.
- [78] A. Ely, P. Stuart, M. Zhu, J. Palma, C. Rodrigues, R. Chertovskih, “Mesoscale and CFD coupling: an improved technique for predicting microscale wind,” unpublished.
- [79] S. Al-Deen, Y. Atsushi, I. Takeshi, “A Physical Approach to Wind Speed Prediction for Wind Energy Forecasting,” in: The fourth international symposium on Computational wind engineering, Yokohama. 2006.
- [80] V. D. Jothiprakasham, E. Dupont, B. Carissimo, “Towards a new methodology for wind resource downscaling with CFD in complex terrain,” unpublished.
- [81] S. Nielsen, H. Madsen, H. Aa. Nielsen, P. Pinson, G. Kariniotakis, N. Siebert, I. Marti, M. Lange, U. Focken, L. von Bremen, P. Louka, G. Kallos, G. Galanis, “Short-term Wind Power Forecasting Using Advanced Statistical Methods,” unpublished.
- [82] C. Brown, “Fast Verification of Wind Turbine Power Curves: Summary of Project Results,” M.S. thesis. Informatics and Mathematical Modeling, Technical University of Denmark, Denmark, 2012.
- [83] R. Wagner, “Accounting for the speed shear in wind turbine power performance measurement,” PhD dissertation, Wind Energy Division, Risø National Laboratory for Sustainable Energy, Technical University of Denmark, Denmark, 2010.
- [84] Power performance measurement procedure, Version 5, MEASNET Organization. 2009.
- [85] C. Carrillo, A. F. Obando Montañó, J. Cidrás, E. Díaz-Dorado, “Review of power curve modelling for wind turbines,” *Renewable and Sustainable Energy Reviews*, vol. 21, pp. 572-581, 2013.
- [86] G. Kariniotakis, P. Pinson, N. Siebert, G. Giebel, R. Barthelmie, “The state of the Art in Short-term Prediction of Wind Power-From an Offshore Perspective,” in: Ocean Energy Conference ADEME-IFREMER, Brest, France, 2004.
- [87] M. Ranaboldo, “Multiple linear regression MOS for short-term wind power forecast,” M.S. thesis, Universitat de Barcelona, Barcelona, sd.
- [88] G. Giebel, R. Brownsword, G. Kariniotakis, M. Denhard, C. Draxl “The State of the Art in Short-Term Prediction of Wind Power A Literature Overview,” ANEMOS.plus and SafeWind, 2011.
- [89] K. A. Hart, W. J. Steenburgh, D. J. Onton, A. J. Siffert, “An Evaluation of Mesoscale-Model-Based Model Output Statistics (MOS) during the 2002 Olympic and Paralympic Winter Games,” *Weather And Forecasting*, vol. 19, pp. 200-218, 2003.
- [90] L. Landberg, H. Waldl, G. Giebel, U. Focken, M. Lange, K. Mönnich, H. G. Beyer, “Short-term Prediction of Regional Wind Power Production,” Contract JOR3-CT97-0272 PL971254, Final Report, 1999.
- [91] P. Pinson, N. Siebert, G. Kariniotakis, “Forecasting of Regional Wind Generation by a Dynamic Fuzzy-Neural Networks Based Upscaling Approach,” in: European Wind Energy Conference & Exhibition EWEC, Madrid 2003.
- [92] S. Lang, C. Möhrlen, J. Jørgensen, B. Ó. Gallachóir, E. McKeogh, “Forecasting total wind power generation on the Republic of Ireland grid with multi-scheme ensemble prediction system,” 2006.
- [93] G. Giebel, L. Landberg, J. Badge, K. Sattler, H. Feddersen, T. S. Nielsen, H. A. Nielsen, H. Madsen, “Using ensemble forecasting for wind power,” in: EWECJ, Madrid, 2003.

- [94] A. R. Trancoso, R. Pestana, J. D. Domingos, “Comparative Study of Forecasts,” in: 4th Meeting MM5 Redelberica, Aveiro, 2007.
- [95] J. Dudhia, D. Gill, K. Mannin, W. Wang, C. Bruyere, “PSU/NCAR Mesoscale Modeling System, Tutorial Class Notes and Users' Guide (MM5 Modeling System Version 3),” Mesoscale and Microscale Meteorology Division, National Center for Atmospheric Research, Boulder, Colorado, USA.
- [96] A. R. Trancoso, J. D. Domingos, R. Pestana, “Previsibilidade da Energia Eólica,” in: XXIX Jornadas Científicas da Asociación Meteorológica Española e 7º Encontro Hispano-Luso de Meteorologia, 24-26 April, Pamplona, Spain. 2006.
- [97] WRF. (2013, Outubro). The Weather Research & Forecasting Model. Disponível: <http://wrf-model.org/index.php>
- [98] Grupo de Meteorologia e Climatologia da Universidade de Aveiro. (2013, Dezembro). Previsão de Tempo. Disponível: <http://climetua.fis.ua.pt/weather/explanation>
- [99] ALADIN Consortium. (2013, Novembro). ALADIN. Disponível: <http://www.cnrm.meteo.fr/aladin/>
- [100] Instituto Português do Mar e da Atmosfera. (2013, Dezembro). IPMA. Disponível: <https://www.ipma.pt/>
- [101] M. J. Smith (2013, Janeiro), Statistical Analysis Handbook. Disponível: <http://www.statsref.com/HTML/>.
- [102] P. Alessio (2012, Maio). Medidas de Forma: Assimetria e Curtose. Disponível: http://pessoal.utfpr.edu.br/wilensilva/arquivos/Notas_de_aula_07.pdf
- [103] K. Roger, K. F. Hallock, “Quantile Regression An Introduction,” unpublished.
- [104] B. dos Santos, “Modelos de regressão quantílica,” M.S. thesis. Instituto de Matemática e Estatística da Universidade de São Paulo, São Paulo, 2012.
- [105] J. W. Osborne, E. Waters. Four assumptions of multiple regression that researchers should always test. Disponível: <http://www-psychology.concordia.ca/fac/kline/495/osborne.pdf>
- [106] M. S. Antolik. (2013, Outubro). Meteorological Development Laboratory Statistical, Modeling Branch, NOAA/National Weather Service. Model Output Statistics (MOS) - Objective Interpretation of NWP Model Output. University of Maryland. Disponível: http://www.atmos.umd.edu/~miyoshi/class/201201/aosc630/guests/Antolik_ppt.pdf
- [107] A. A. Munot, K. K. Kumar, “Long range prediction of Indian summer monsoon rainfall,” Earth System Science, vol. 116, pp. 73-79, 2007.
- [108] J. H. Barrett, “Peak Wind Tool for General Forecasting Phase II,” ENSCO, Inc., Cocoa Beach, Florida, 2010.
- [109] Y. Watanabe, S. Wakao, T. Takinami, K. Oishi. (2013, Janeiro). Application of Non-linear Modeling Methods to Wind Power Estimation Disponível: http://proceedings.ewea.org/ewec2007/allfiles2/261_Ewec2007fullpaper.pdf
- [110] D. D. Pestana e S. F. Velosa, Introdução à Probabilidade e à Estatística. ed.4. Vol. I. Fundação Calouste Gulbenkian. 2008.
- [111] TrueWind Solutions LLC, AWS Scientific Inc., “Overview of Wind Energy Generation Forecasting,” TrueWind Solutions, New York State Energy Research and Development Authority, New York State Independent System Operator, New York .2003
- [112] S. S. Soman, H. Zareipour, O. Malik, P. Mandal, “A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons,” in: North American Power Symposium (NAPS), Arlington, TX, 2010.

[113] D. de Carvalho, P. Lucio, “Downscaling Estocástico para Extremos Climáticos via Regressão Quantílica e Interpolação Espacial dos Parâmetros das Distribuições de Valores Extremos (GEV e GPD),” unpublished.

[114] C. Ferreira, J. Gama, L. Matias, A. Botterud, J. Wang, “A Survey on Wind Power Ramp Forecasting,” Argonne National Laboratory, Argonne, Illinois, 2010.

ANEXO A – VARIACÕES ESTUDADAS E VARIACÕES UTILIZADAS PELOS MODELOS MOS

Tabela 93- Síntese dos estudos efectuados para os modelos MOS.

Tratamento de dados			
Métodos	Discretização de dados	Cálculos	Implementação no algoritmo
Coeficiente de correlação de Pearson (MOS1)	(1) (2) (3)	(4) (5)	(3) e (4) (MOS1)
Média móvel (MOS2)	(3)	(5)	(3) e (5) (MOS2)
Previsão dinâmica do viés (MOS3)	(1) (2) (3)	(4) (5)	(3) e (5) (MOS3)
Regressão quantílica (MOS4)	(2) (3)	(4) (5)	(3) e (5) (MOS4)
Combinação (MOSF)	(6)		MOS1+ MOS2+ MOS3

As variações (1), (2), (3), (4) e (5) têm como objectivo identificar a melhor abordagem de cálculo para reduzir os erros associados às séries de previsão. Entre as abordagens estudadas contam-se:

- *Time-step* (1) – de modo a efectuar-se este estudo ordenaram-se as séries de previsão nos *time-steps* por ordem crescente de antiguidade (1-96). Seguidamente foi efectuado um estudo específico para cada *time-step*;
- Ciclo nocturno-diurno (2) - de modo a efectuar-se este estudo subdividiram-se as séries de previsão em duas séries, série diurna (06-18h) e série nocturna (18-06h). Seguidamente foi efectuado um estudo específico para cada série;
- Horizonte temporal (3) - de modo a efectuar-se este estudo recorreu-se às séries de previsão para cada horizonte temporal. Seguidamente foi efectuado um estudo específico para cada horizonte temporal;
- Janela fixa (4) - de modo a efectuar-se este estudo recorreu-se às séries de previsão com uma das variações (1-3) e caso fosse necessário recorrer a uma janela fixa, para calcular coeficientes ou avaliar o desempenho, então recorria-se a uma janela fixa;
- Janela móvel de dimensão fixa (5) - de modo a efectuar-se este estudo recorreu-se às séries de previsão com uma das variações (1-3) e caso fosse necessário recorrer a uma janela móvel, para calcular coeficientes ou avaliar o desempenho com recurso a uma janela, isto seria efectuado recorrendo a uma janela móvel de dimensãofixa.
- Ordem de tratamentos (6) – de modo a obter-se o melhor tratamento final MOSF, efectuaram-se vários estudos alterando a ordem de tratamentos, ou seja, várias combinações dos modelos MOS1, MOS2 e MOS3.

ANEXO B – CALIBRAÇÃO DO MODELO STEPWISE-LR

Neste anexo demonstra-se a metodologia de calibração do modelo STEPWISE-LR. Esta calibração foi efectuada nos períodos de calibração (dimensão da janela móvel para calibrar os coeficientes regressivos) e validação (calibração do critério de inclusão).

A metodologia de calibração foi subdividida em duas fases. Uma primeira fase em que se efectuou a calibração da janela móvel sobre a qual os coeficientes regressivos foram calibrados e uma segunda fase em que se calibrou o critério de inclusão de novos predictores em modo de validação. Os coeficientes utilizados pelo modelo foram calibrados com recurso a uma janela móvel de dimensão entre 0-10 dias dependendo do horizonte temporal. A medida de avaliação do desempenho adoptada foi o erro médio quadrático (RMSE), referida em 4.1., já que este indicador é a medida de avaliação mais relevante para calcular o desempenho quantitativo do modelo.

Para calibrar a dimensão da janela móvel de dados passados, sobre a qual os modelos eram avaliados, foi feito um estudo variando a dimensão desta e observando o desempenho dos modelos consoante a dimensão da janela. Após isto, foi calculado o valor do critério de inclusão mais favorável aos modelos. Para tal, foi efectuada um estudo variando o valor do critério de inclusão e observando o desempenho do modelo em função deste.

Esta metodologia foi reproduzida para os vários horizontes temporais.

Assim após o cálculo dos coeficientes das várias combinações procedeu-se a calibração do modelo.

- 1ª Fase: cálculo da janela móvel sobre a qual é efectuada a escolha do melhor modelo.




Fig. 63 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 00-06hr.

Como se pode observar pela Fig. 63, existe uma concentração generalizada do erro (RMSE) para as várias combinações possíveis do modelo STEPWISE-LR para janelas com a dimensão de 3-4 dias. Assim para o horizonte temporal 00-06hr foi adoptada uma janela móvel com a dimensão de 3,5 dias para calibrar os coeficientes regressivos.




Fig. 64 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 06-12hr.

Como se pode observar pela Fig. 64, existe uma concentração generalizada do erro (RMSE) para as várias combinações possíveis do modelo STEPWISE-LR para janelas com a dimensão de 1 dia. No entanto, uma janela destas dimensões poderia induzir o modelo em erro. Por outro lado, observa-se outra concentração do erro para janelas com a dimensão entre 2,75-4 dias. Assim para o horizonte temporal 06-12hr foi adoptada uma janela móvel com a dimensão de 3,5 dias para calibrar os coeficientes regressivos.




Fig. 65 – Desempenho, com base na medida de avaliação erro medio quadrático RMSE, das várias combinações possíveis contempladas pelo modelo STEPWISE-LR para o horizonte temporal 12-18hr.

Como se pode observar pela Fig. 65, existe uma concentração generalizada do erro (RMSE) para as várias combinações possíveis do modelo STEPWISE-LR para janelas com a dimensão de 1 dia. No entanto, uma janela destas dimensões poderia induzir o modelo em erro. Por outro lado, observa-se outra concentração do erro para janelas com a dimensão entre 2,75-3,5 dias. Assim para o horizonte temporal 12-18hr foi adoptada uma janela móvel com a dimensão de 3 dias para calibrar os coeficientes regressivos.

$$Ci = \frac{RMSE_n - RMSE_{n+1}}{RMSE_n} \times 100 \quad (46)$$

Assim foi efectuado um estudo do desempenho do modelo em função do valor do critério de inclusão (Ci) adoptado.




Fig. 67 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 00-06hr.

Assim, com recurso a análise da Fig. 67 optou-se por um critério de inclusão que igual a 30% para o horizonte temporal 00-06hr, ou seja, a inclusão de um novo predictor só ocorreria caso este tivesse contribuído num período passado com uma melhoria igual ou superior a 30%.




Fig. 68 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 06-12hr.

Assim, com recurso a análise da Fig. 68 optou-se por um critério de inclusão que igual a 30% para o horizonte temporal 06-12hr, ou seja, a inclusão de um novo predictor so ocorreria caso este tivesse contribuído num período passado com uma melhoria igual ou superior a 30%.




Fig. 69 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 12-18hr.

Assim, com recurso a análise da Fig. 69 optou-se por um critério de inclusão que igual a 40% para o horizonte temporal 12-18hr, ou seja, a inclusão de um novo predictor so ocorreria caso este tivesse contribuído num período passado com uma melhoria igual ou superior a 40%.




Fig. 70 – Desempenho, com base na variação do valor do critério de selecção, do modelo STEPWISE-LR para o horizonte temporal 18-24hr.

Assim, com recurso a análise da Fig. 70 optou-se por um critério de inclusão que igual a 10% para o horizonte temporal 18-24hr, ou seja, a inclusão de um novo predictor so ocorreria caso este tivesse contribuído num período passado com uma melhoria igual ou superior a 10%.

ANEXO C – ESTUDO DA CONTRIBUIÇÃO DE DIFERENTES HORIZONTES TEMPORAIS COM RECURSO AO MODELO MIX

O modelo MIX é uma variação baseada no modelo *B.I. Tracking* conforme descrito em 4.3.3. Este avalia as várias previsões disponíveis até a data, para com base num passado recente extrapolar qual a melhor combinação de predictores num futuro próximo.

Com este estudo pretendeu-se avaliar qual a contribuição do modelo mix para por um lado efectuar previsões de potência tendo como *input* de dados as previsões de base e por outro avaliar se existiriam mais-valias em utilizar os vários horizontes temporais dos vários modelos disponíveis á data de se efectuarem as previsões.

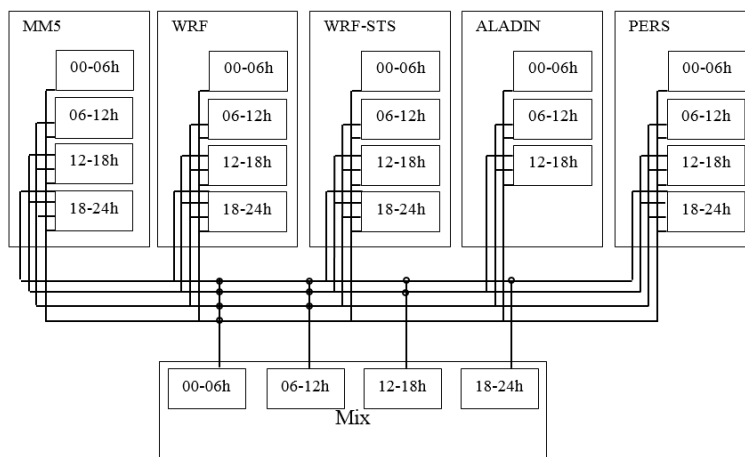


Fig. 71 – Esquematização do *input* de dados utilizados para efectuar previsões com recurso ao modelo MIX para os vários horizontes temporais.

• DESCRIÇÃO ESTATÍSTICA

Tabela 94- Descrição estatística das previsões efectuadas com recurso ao modelo MIX no período de validação.

	Horizonte temporal			
	00-06hr	06-12hr	12-18hr	18-24hr
\bar{E}	-17,51	-18,32	-9,87	-17,53
\tilde{E}	-8,77	-8,89	-8,69	-7,37
Moda	15,5	-42,5	-108,7	67,3
As_1	-17,51	-18,32	-9,87	-17,53
σ	153,48	213,73	249,42	231,87
Var	2,36E+04	4,57E+04	6,22E+04	5,38E+04
K	0,22	0,24	0,23	0,24
As_2	-0,17	-0,13	-0,01	-0,13
Min	-931,31	-801,79	-1273,6	-1291,64
Max	654,16	979,98	933,04	1058,07
Q_1	-89,56	-145,4	-147,13	-152,26
Q_3	60,05	103,25	131,89	116,74
P_{90}	143,09	243,34	300,98	260,74
P_{10}	-191,47	-276,19	-295,35	-307,24
$\rho_{x,y}$	0,95	0,90	0,87	0,88

Tabela 95- Descrição estatística das previsões efectuadas com recurso ao modelo MIX no período de teste.

	Horizonte temporal			
	00-06hr	06-12hr	12-18hr	18-24hr
\bar{E}	-33,4	-49,76	-30,58	-38,58
\tilde{E}	-18,78	-28,41	-20,7	-23,47
Moda	-9,5	16,7	#N/A	111,8
As_1	-33,4	-49,76	-30,58	-38,58
σ	158,32	241,36	289,89	281,01
Var	2,51E+04	5,83E+04	8,40E+04	7,90E+04
K	0,24	0,23	0,25	0,23
As_2	-0,28	-0,27	-0,1	-0,16
Min	-756,7	-1999,66	-1450,63	-1199,49
Max	628,67	832,76	803,44	996,82
Q_1	-115,72	-174,15	-173,36	-176,51
Q_3	55,29	80,8	155,47	108,05
P_{90}	140,9	220,07	304,08	252,56
P_{10}	-222,74	-344,68	-351,9	-368,87
$\rho_{x,y}$	0,97	0,94	0,91	0,91

• MEDIDAS DE AVALIAÇÃO DAS PREVISÕES

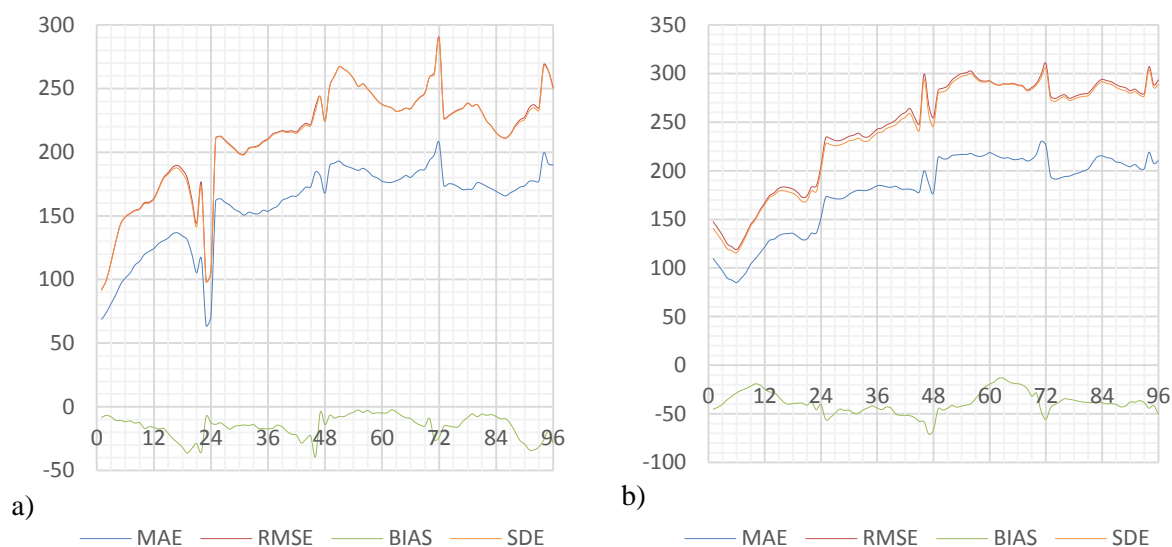


Fig. 72 – Gráfico comparativo do valor da agregação das previsões, tratadas com recurso a, MOSF com recurso ao modelo MIX, sendo as medidas de avaliação referentes aos períodos de a) validação e b) teste.

ANEXO D – COEFICIENTES REGRESSIVOS DO MODELO SLR/MLR-1 DO MÓDULO ALFA1

Tabela 96- Valores dos coeficientes regressivos calculados com recurso ao modelo SLR/MLR-1 (ALFA1) por combinação de séries de previsão e por horizonte temporal.

Horizonte temporal	MM5	WRF	PERS
00-06hr	0,456172	0,516894	0,013762
	0,460158	0,525777	0
	0,919971	0	0,077067
	0,992669	0	0
	0	0,932112	0,039188
	0	0,96832	0
	0	0	0,916405
06-12hr	0,48496	0,416915	0,098963
	0,480592	0,502328	0
	0,873848	0	0,150087
	1,001569	0	0
	0	0,865847	0,095944
	0	0,944755	0
	0	0	0,836827
12-18hr	0,492833	0,420829	0,0812
	0,506037	0,47225	0
	0,895778	0	0,120454
	0,994217	0	0
	0	0,8636	0,092276
	0	0,935779	0
	0	0	0,801625
18-24hr	0,514633	0,390813	0,087245
	0,535709	0,438115	0
	0,892155	0	0,121262
	0,989553	0	0
	0	0,843752	0,105429
	0	0,924013	0
	0	0	0,78788

ANEXO E – MÉTODO DOS MÍNIMOS QUADRADOS

O método dos mínimos quadrados pressupõe o cálculo dos coeficientes de linearização de modo a que o valor da Soma dos Quadrados dos Desvios (SQD), medidos na vertical, entre os valores observados e os valores estimados seja mínimo. Assim podemos calcular com base na equação seguinte:

$$SQD = \sum_{i=1}^n E_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (47)$$

Podendo o valor de y ser calculado das diversas formas consoante seja uma SLR, ELR, RP, LLR.

Vendo para o caso específico da SLR, a equação de cálculo será a seguinte:

$$\hat{y}_i = \alpha \hat{x}_i + \hat{B} \quad (48)$$

Sendo que o valor correspondente as somas finitas será calculado da seguinte forma:

$$\begin{aligned} S_{xx} &= \sum_{i=1}^n x_i^2 - n\bar{x}^2 \\ S_{yy} &= \sum_{i=1}^n y_i^2 - n\bar{y}^2 \\ S_{xy} &= \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \end{aligned} \quad (49)$$

Assim usamos as equações anteriores para calcular os coeficientes da SLR conforme demonstrado pelas equações seguintes

$$\begin{aligned} \alpha &= \frac{S_{xy}}{S_{xx}} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \\ \hat{B} &= \bar{y} - \alpha \bar{x} \end{aligned} \quad (50)$$

Assim, com recurso a 50 e 48, pode-se representar o método dos mínimos quadrados através da Equação 51:

$$\hat{y}_i = \left(\frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right) \hat{x}_i + \left[\bar{y} - \left(\frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right) \bar{x} \right] \quad (51)$$

ANEXO F – SISTEMAS DE PPE COMERCIAIS

Tabela 97- Sistemas de PPE operacionais disponíveis em mercado. [66]

Model	Developer, Country	Approach	Key Features
Prediktor	Risø, Denmark	Physical	Provides local refinement of the NWP forecasts; has wind power curve modeling, including wake effects.
Previento	University Oldenburg/EMSYS, Germany	Hybrid	Uses approach similar to Prediktor, but with regional forecasting and uncertainty estimation.
LocalPred/ RegioPred	CENER, Spain	Hybrid	Regional forecasting; developed especially for complex terrain (microscale modeling); very-short-term forecasting with ARMA models.
WPPT	IMM.DTU/ENFOR, Denmark	Statistical	It provides point and uncertainty forecasts for a single wind farm, for a group of wind farms, or for a wide region; has a time-adaptive process to cope with a nonstationary process; takes autocorrelation and diurnal variations into account.
Zephyr	Risø and IMM.DTU, Denmark	Hybrid	A combination of WPPT and Prediktor models in which each wind farm is assigned a forecast model according to the available data.
Casandra	University of Castilla-La Mancha/Gamesa, Spain	Physical	Statistical downscaling method that corrects systematic errors on the mesoscale forecasts; employs multivariate regression to estimate wind farm power curve; features automatic update of power curves.
AWPPS	ARMINES, France	Statistical	Very-short-term models based on the statistical time-series approach, in which short-term models are based on fuzzy neural networks; combines forecasts by an intelligent weighting of very-short and short-term forecasts; its upscaling prediction model is based on dynamic fuzzy neural networks, and uses cascaded and cluster approaches with reference wind farms; includes uncertainty estimation of confidence intervals; performs assessment of prediction risk indices based on weather stability.
WPMS	ISET, Germany	Statistical	It calculates the current power for all wind farms by using the measurements of only a few wind farms (on-line monitoring); provides day-ahead and short-term wind power forecasts for single wind farms, control areas, and subregions; a multi-NWP that combines the forecasts of three different NWP models from different providers or MSEPS the use forecasts of different members of the ensemble.
WEPROG	WEPROG, Germany	Hybrid	Two main models: a weather prediction system running every 6 hours and a power prediction system that uses on- and off-line SCADA measurements. In the first model a multi-scheme ensemble prediction limited-area NWP model produces 75 different forecasts (ensembles), which forecast uncertainty and improve forecast accuracy.
Sipreólico	University Carlos III of Madrid, Spain	Statistical	The model was built to deal with different levels of available data; several adaptive statistical models are used in order to produce a final forecast by using an adaptive combination of the alternative predictions; the two main features are: (i) its adaptability to changes in the operation of the wind farms or in the NWP model; (ii) easy and fast adaptability for different wind farms; no pre-calibration required.
GH Forecaster	Garrard Hassan, UK	Statistical	Uses multi-parameter statistical regression routines to transform global NWPs with appropriate geographical resolution and site data (provided by SCADA systems and/or site measurements) into site-specific models, the site-specific models can be any user-defined transformation between NWP and the site.

Tabela 98- Sistemas de PPE operacionais disponíveis em mercado (cont.). [66]

Model	Developer, Country	Approach	Key Features
SOWIE	Eurowind GmbH, Germany	Physical	Uses high-resolution, 3-D wind and temperature forecasts as inputs, together with a database of all German wind energy turbines; provides uncertainty estimation and regional forecasting.
EPREV	INESC Porto/INEGI/CEsA/CGUL, Portugal	Statistical	Combines autoregressive models for very-short-term forecasting, with NNs for short-term forecasting; each wind turbine is modelled individually, thus enabling the identification of the availability of each wind turbine; the system provides uncertainty forecasts.
AleaWind	AleaSoft, Spain	Statistical	The model is capable of providing national, regional, or single wind farm forecasts; it is based on the exclusive AleaSoft forecasting model; the parameters of an NN with a SARIMA structure are estimated on-line.
Scirocco	Aeolis Forecasting Services, Netherlands	Hybrid	The wind power forecast is an output of a model chain with consecutive steps from physical and statistical procedures; the system adapts itself to local geographical circumstances and wind farm characteristics during the first months of operation.
MeteoLógica	MeteoLógica, Spain	Physical	The NWP forecasts are downscaled by an advanced statistical downscaling system that uses local meteorological measurements.
eWind	AWS Truewind Inc., USA	Hybrid	Runs the ForeWind NWP as a mesoscale model using boundary conditions from a regional weather model; several models are used with different initializations in order to create an ensemble of high resolution NWP prediction; the output from the ensemble, along with the meteorological data, are used to train statistical models to produce forecasts at the meteorological tower sites and correct systematic errors; an “ensemble compositing model” transforms the ensemble of forecasts into a single probabilistic or deterministic forecast ; the model provides uncertainty forecast.
Visionpoint	3TIER, USA	Statistical	It provides hourly forecasts for 7 days and 84 hours ahead; the best of six different configurations of NWP models (WRF or MM5) is chosen to forecast the weather variables; the power forecast uncertainty is estimated using quantile regression or conditional onpower curve location; a weather forecast ensemble is employed by using a series of NWP simulations, each obtained from different initial conditions or NWP models; the system provides hourly forecasts for a time horizon up to 10 hours where historical day-ahead forecasts and weather variables of other sites are used.
Precise Stream	Precision Wind, USA	Physical	Is based in meso-microscale atmospheric models (CFD techniques). The main feature is the ability to capture a full 17 km of vertical model depth and hundreds of kilometers of resolution in the horizontal direction. The model uses three grids with different horizontal resolutions to define a large area around the site. The training method is a post-processing step that requires only 3 months’ worth of data. Uncertainty estimation is also provided in the form of maximum and minimum wind generation values that vary according to current and forecasted weather conditions
WEFS	AMI Environmental Inc., USA	Hybrid	In order to account for the local topography and microscale effects, the NWP predictions of MM5 or WRF are coupled with a Diagnostic Wind Model developed by AMI; an adaptive statistical model is used to account for the systematic errors without requiring long sampling times and extensive monitoring of data.
WindCast	WSI, USA	-	Provides hourly wind speed and power forecasts for single wind farms up to 7 days. The forecasts can be updated 7 times a day

