

# Utilização de Árvores de Regressão Híbridas na Monitorização da Segurança Dinâmica de Redes Isoladas com Grande Produção Eólica

J. A. Peças Lopes (1,2)

[jpl@riff.fe.up.pt](mailto:jpl@riff.fe.up.pt)

Maria Helena O. P. de Vasconcelos (2)

[hvasconcelos@inescn.pt](mailto:hvasconcelos@inescn.pt)

(1) - DEEC da Faculdade de Engenharia da Universidade do Porto

Rua dos Bragas - 4000 Porto, PORTUGAL

(2) - INESC-Porto, Instituto de Engenharia de Sistemas e Computadores

Praça da República, 93 - 4000 Porto, PORTUGAL

## Resumo

Neste artigo descreve-se de forma sintética a metodologia adoptada para definir estruturas de avaliação rápida da segurança dinâmica de redes isoladas com elevados níveis de integração de produção eólica. Esta metodologia recorre a árvores de regressão híbridas, permitindo quantificar o grau de robustez ligado ao comportamento dinâmico destas redes através da emulação do desvio mínimo de frequência que o sistema experimentará quando sujeito a uma perturbação pré-definida. Apresentam-se ainda novos procedimentos de geração automática de dados, explorados posteriormente na construção e medição de desempenho das estruturas de avaliação. O caso teste aqui descrito corresponde a um cenário de funcionamento da rede da ilha Terceira no arquipélago dos Açores.

## 1. Introdução

Em redes isoladas a produção de energia eléctrica é geralmente efectuada recorrendo a geradores Diesel queimando fuel. Aos custos, já de si elevados do fuel, acrescentam-se os de transporte do combustível, provocando elevados custos de produção de energia eléctrica. Desta forma, a integração de produção eólica nestas redes torna-se particularmente interessante dado conduzir a uma importante redução dos custos globais de produção de energia eléctrica.

Naturalmente essa redução será tanto maior quanto maior for o nível de integração que é possível obter. Contudo, o recurso eólico é caracterizado por nem sempre estar disponível e por apresentar, por vezes, rápidas variações em períodos de tempo muito curtos. As consequentes variações na potência eólica produzida devem ser compensadas, de forma rápida e eficiente, pelos geradores síncronos convencionais. Caso contrário a tensão e a frequência podem sofrer variações apreciáveis e em caso extremo conduzir ao colapso do sistema. A estratégia tradicional utilizada pelas empresas que exploram estes sistemas passa pela adopção de políticas de despacho pessimistas que subaproveitam a capacidade eólica instalada e acabam por originar custos de produção elevados por não proporcionarem a amortização rápida destes investimentos. Tais factos levam à necessidade de utilizar sistemas avançados de monitorização e controlo global da rede, associados a sistemas SCADA, por forma a maximizar a integração de produção eólica sem comprometer a segurança de exploração e a qualidade do serviço prestado aos consumidores finais [1].

Nos últimos anos, tem-se procedido ao desenvolvimento de investigação em vários domínios com vista a implementar este tipo de sistemas. Assim, é de referir nomeadamente o esforço posto no desenvolvimento de algoritmos de previsão de potência eólica a curto e médio prazo [2], de pré-despacho e despacho em sistemas de média e grande dimensão [2], e de avaliação rápida de segurança dinâmica [3][4]. A avaliação de segurança dinâmica assume uma importância fundamental nestes sistemas de controlo, dado que as decisões de pré-despacho e despacho e a avaliação *on-line* da robustez do sistema exigem a disponibilidade de procedimentos muito rápidos de avaliação da robustez. Estes procedimentos devem ser capazes de fornecer informação em tempo real sobre o comportamento dinâmico esperado do sistema face a um conjunto de perturbações

previsíveis, atendendo ou não a condições atmosféricas adversas, sem necessitar de resolver numericamente, no domínio do tempo, as equações de estado do sistema. Tal obriga à utilização de técnicas de aprendizagem automática a partir de exemplos, explorando conhecimento funcional sobre o comportamento do sistema, obtido por simulação “off-line”.

Nos últimos anos este problema foi tratado recorrendo a técnicas de reconhecimento de padrões [4], árvores de decisão [4] e redes neuronais [5]. Os trabalhos anteriormente desenvolvidos foram mais recentemente estendidos no âmbito do projecto Europeu do programa JOULE/THERMIE - CARE - "Advanced Control Advise for Power Systems with Large Scale Integration of Renewable Energy Sources" JOR3CT960119. Neste projecto procura-se estender o sistema avançado de controlo desenvolvido no anterior projecto JOU2-CT92-0053 (ilha de Lemnos) ao caso de redes isoladas de maior dimensão onde a produção eólica a integrar no sistema pode ser explorada por entidades privadas. Os casos de estudo são as redes das ilhas de Creta e Terceira.

Neste artigo apresentam-se resultados de aplicação de novos procedimentos para geração automática de conjuntos de dados explorados posteriormente por uma nova técnica de índole estatística - árvores de regressão híbridas [6] [8] com o objectivo de obter estruturas de avaliação rápida da segurança dinâmica do sistema. O caso de estudo descrito neste artigo foi o da rede eléctrica da ilha Terceira, no arquipélago dos Açores.

## 2. Rede da Ilha Terceira

Neste caso de estudo considerou-se a topologia e os níveis de consumo previstos para a rede eléctrica da ilha Terceira no ano de 1999. Esta rede apresenta como características principais uma rede de “transporte” a 30 kV, uma central Diesel (Belo Jardim) com 6 geradores totalizando 30,8 MW, uma pequena central hidroeléctrica com 0,72 MW e dois parques eólicos (a instalar futuramente) com 3 e 1,8 MW respectivamente. Os níveis de consumo foram considerados com variações entre 9.2 e 20 MW. O diagrama unifilar da rede sob análise, com as principais características do sistema pode ser observado na figura 1. Os geradores eólicos considerados correspondem a máquinas assíncronas de 300 kW com regulação “stall”.

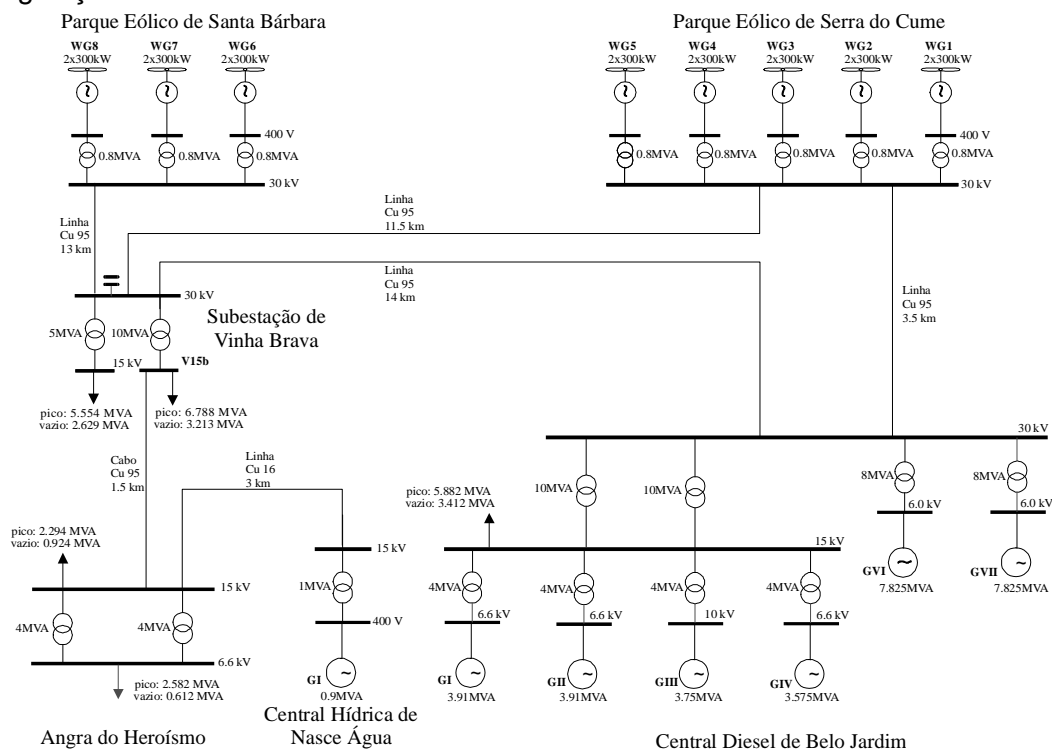



Figura 1 - Diagrama unifilar da rede eléctrica da ilha Terceira

Para esta rede desenvolveu-se uma estrutura de avaliação rápida da segurança dinâmica da rede para uma perturbação caracterizada por um curto-circuito, auto-extinto após 180 ms, situado nas proximidades do parque eólico de Santa Bárbara, seguido da saída de serviço do parque por actuação dos relés de protecção dos seus geradores. O índice de segurança escolhido para medir a robustez da rede, consiste no desvio de frequência mínima do sistema,  $\Delta f_{min}$ . Na figura 2 apresenta-se o tipo de comportamento temporal do sistema face à evolução da frequência, expressa como a frequência do centro de inércia da rede.



**Figura 2** - Evolução temporal da frequência (perturbação: c.c. com saída de serviço do parque eólico à plena carga)

A estrutura de avaliação de segurança poderá vir a ser integrada no software do sistema de controlo, quando este vier a ser instalado na rede eléctrica da ilha.

### 3. Geração de Conjuntos de Aprendizagem e Teste

O procedimento adoptado para a geração de um conjunto de dados, que traduz o conhecimento funcional sobre o comportamento da rede eléctrica da Terceira, adoptou o método de amostragem estruturado de Monte Carlo [9]. Parte deste conjunto de dados, denominado por conjunto de aprendizagem, foi utilizado para construir a estrutura da avaliação rápida da segurança dinâmica para a rede eléctrica da Terceira. Essa estrutura foi obtida através da resolução de um problema de regressão, por aplicação de uma técnica híbrida de aprendizagem automática – as árvores de regressão kernel. A restante parte do conjunto de dados, denominada por conjunto de teste, foi utilizada para avaliar o desempenho da estrutura construída.

O problema de regressão consiste em obter um *modelo funcional* que relacione a *resposta* de um sistema, quantificada através de uma variável contínua  $y$ , com o *ponto de operação* do mesmo, caracterizado por um vector  $[a_1, a_2, \dots, a_n]$ , em que cada elemento  $a_i$ , denominado por atributo, consiste num parâmetro do sistema. Esse modelo consiste numa função do tipo  $y=f(a_1, a_2, \dots, a_n)$ , sendo obtido através da exploração de um conjunto de *amostras do funcionamento do sistema* (i.e. de um conjunto de aprendizagem).

Fazendo a equivalência, da formulação de problema de regressão atrás definido, para o problema de avaliação de segurança dinâmica de redes eléctricas:

- O *modelo funcional* consiste numa estrutura de avaliação rápida de segurança dinâmica;
- A *resposta do sistema*  $y$  consiste num índice de segurança que quantifica/classifica a severidade/segurança do sistema face à ocorrência de uma perturbação pré-definida.
- O *ponto de operação do sistema* é caracterizado por variáveis de regime estacionário que definem as condições de exploração da rede antes da ocorrência da perturbação. Essas variáveis, denominadas por atributos candidatos, poderão consistir em valores medidos da rede (ex: potências geradas e consumidas, tensões, etc) ou em valores calculados com base nessas medidas (ex: penetração eólica, reserva girante, etc).

Para que se consiga obter uma estrutura com elevada qualidade é necessário que o conjunto de aprendizagem gerado represente de forma adequada o comportamento do sistema que se pretende observar. Para tal, é necessário que os pontos de operação amostrados cubram toda a gama de operação do sistema, com a melhor resolução possível

e, em especial, com boa resolução em torno das fronteiras de segurança do sistema. Outro factor crucial para a obtenção de uma estrutura de elevado desempenho, consiste na qualidade dos atributos seleccionados, devendo ser escolhidos todos os parâmetros cujo valor tem influência sobre a resposta do sistema.

#### Atributos seleccionados para a Terceira

Atendendo aos requisitos atrás referidos para o conjunto de aprendizagem, os atributos candidatos, seleccionados para a rede da Terceira, foram os seguintes:

1. Margem de vento em cada parque eólico;
2. Margem de vento total;
3. Penetração eólica total;
4. Reserva girante total;
5. Geração total de potência activa e reactiva na central Diesel e parques eólicos;
6. Geração total de potência reactiva nas baterias de condensadores;
7. Consumos activos e reactivos totais;
8. Perdas activas e reactivas totais;
9. Produção activa e reactiva, reserva girante e valor da tensão em cada gerador Diesel;
10. Produção activa e reactiva em cada gerador eólico.

#### Método de amostragem estruturado de Monte Carlo

O método de amostragem estruturado de Monte Carlo consiste numa geração de um conjunto de dados que permite obter pontos de operação com uma boa distribuição e resolução dentro da gama de operação definida para o sistema. O algoritmo de geração consiste num procedimento “off-line”, de elevado peso computacional, em que primeiro realiza a amostragem automática de pontos de operação do sistema, obtendo posteriormente a resposta do sistema,  $\Delta f_{min}$ , para cada ponto de operação através da realização de uma simulação dinâmica. Estas simulações dinâmicas são feitas recorrendo-se a ferramentas analíticas de cálculo tradicionais, que resolvem numericamente, no domínio do tempo, as equações de estado do sistema [10].

A aplicação deste método requer uma especificação inicial, abrangendo os seguintes aspectos:

- Definição do número de amostras a simular;
- Identificação dos parâmetros da rede aos quais deverá ser aplicado o método de amostragem – as variáveis de Monte Carlo;
- Identificação da gama de operação e definição da resolução pretendida para o conjunto de dados;
- Definição das restrições de operação do sistema a considerar.

A geração de um maior número de amostras aumenta a resolução e, como consequência, a qualidade do conjunto de dados. No entanto, poderá corresponder a um aumento inaceitável do tempo computacional do algoritmo de geração, pelo que o número de amostras a simular deverá ser definido num ponto de compromisso entre precisão e espaço computacional.

Os parâmetros da rede aos quais deverá ser aplicado o método de amostragem (i.e. as variáveis de Monte Carlo) deverão corresponder a todas as variáveis do sistema que influenciam a resposta que se pretende avaliar, mas cujos valores não dependam de restrições de operação. Devido a este último requisito, as variáveis de Monte Carlo terão que corresponder a dados de entrada de um problema de trânsito de potências, cujo comportamento não seja controlável pelos operadores da rede nem dependa de condições de operação da rede. Para a rede da Terceira foram identificadas as seguintes variáveis de Monte Carlo:

- potência mecânica disponível em cada gerador eólico,
- consumo de potência activa nos barramentos consumidores,

o que dá um total de 7 variáveis de Monte Carlo (2 para os parques eólicos e 5 para os barramentos de consumo).

Para cada variável de Monte Carlo  $v_i$ , é necessário identificar a gama de operação, i.e., os valores máximo  $v_{i,max}$  e mínimo  $v_{i,min}$  normalmente atingidos, ficando assim definida a gama de operação do sistema a amostrar.

Para cada variável de Monte Carlo  $v_i$ , é necessário também definir a resolução pretendida, i.e., o número de intervalos  $n_i$ , em que cada intervalo tem uma amplitude de  $(v_{i,max} - v_{i,min})/n_i$ . Através desta definição, a gama de operação do sistema a simular fica decomposta em intervalos (a uma dimensão), em células (a duas dimensões), em cubos (a três dimensões), e em hiper-células (a quatro ou mais dimensões). Cada hiper-célula corresponde a um ponto de operação do sistema a amostrar, sendo necessário garantir que estas não excedam o número máximo definido para as amostras. A decisão de quais os valores numéricos a amostrar dentro de cada hiper-célula, é realizada de forma “random”.

Antes de realizar a simulação dinâmica para cada ponto de operação amostrado, é necessário calcular as condições do sistema em regime estacionário, através da resolução de um problema de trânsito de potências, devendo estar verificadas as restrições de operação do sistema. Para a Terceira foram consideradas as seguintes restrições de operação:

- estratégias de pré-despacho e despacho realizadas (com consideração do critério de reserva girante, e das restrições de operação dos grupos Diesel, nomeadamente, dos limites de operação, das curvas de custo de produção e do programa de manutenção);
- sistema de compensação de factor de potência adoptado para os parques eólicos;
- sistema de controlo do factor de potência entre os grupos Diesel;
- diagramas de carga típicos para os barramentos de consumo;

Para a modelização destas restrições de operação, foi necessário considerar módulos de calculo adicionais entre o módulo de amostragem e o de simulação dinâmica.

### Resultado do Conjunto de Dados Gerado para a Rede Eléctrica da Terceira

Utilizando o método acima descrito de geração de conjunto de dados, obtiveram-se 1976 pontos de operação, dos quais 1186 foram enviados para o conjunto de aprendizagem e 790 para o conjunto de teste, através de um processo de envio sequencial de 3 pontos de operação para o conjunto de aprendizagem e de 2 para o conjunto de teste.

A distribuição de frequências obtido para os valores amostrados do índice de segurança  $\Delta f_{min}$ , apresenta-se no histograma da figura 3. Na mesma figura, também se apresenta um gráfico com o valor de  $\Delta f_{min}$  por amostra simulada.

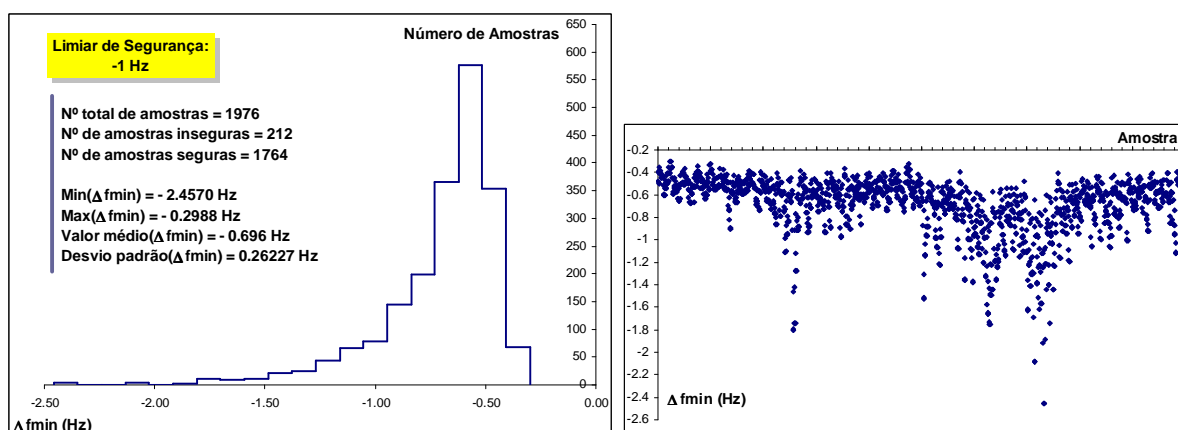


Figura 3 - Distribuição de frequências dos  $\Delta f_{min}$  amostrados/Valores de  $\Delta f_{min}$  por amostra simulada

#### 4. Utilização de Árvores de Regressão Kernel

A árvore de regressão Kernel (“kernel regression trees” - KRT) está associada a um método híbrido pertencente à área das técnicas de aprendizagem automática, que lida com variáveis alvo contínuas (i.e. consiste num método de resolução de problemas de regressão). Este método híbrido integra árvores de regressão [6] (“Regression Trees” - RT) com modelos de regressão Kernel [11] [12]. A primeira aplicação de RTs para a avaliação rápida da segurança dinâmica de sistemas de energia foi realizada por Wehenkel [13], em 1995, tendo sido aplicada em problemas de estabilidade de tensão. Recentemente, foi apresentada em [14] a aplicação de KRTs para a avaliação do mesmo tipo de problema de segurança. Este documento faz uma descrição sintética do método KRT utilizado, pela primeira vez, para a avaliação de segurança dinâmica de sistemas de energia no sentido de estabilidade transitória e de frequência [15]. O método utilizado para obter um modelo funcional KRT foi o descrito por Luís Torgo [8].

A RT consiste num método de aprendizagem automática, que permite obter funções de segurança que se traduzem em regras de fácil interpretação. Os modelos de regressão kernel consiste numa metodologia estatística não paramétrica que, apesar de fornecer modelo funcionais de difícil interpretação, é capaz de modelizar com grande precisão as não linearidades das funções de segurança dos sistemas de energia. Integrando estes modelos nas folhas da RT, consegue-se obter funções de segurança que mantêm a interpretabilidade das RTs, mas com maior precisão por aumento da não linearidade das funções utilizadas nas folhas da árvore.

##### A Estrutura Árvore de Regressão (RT)

A figura 4 apresenta uma hipotética RT, que consiste numa estrutura de segurança extraída de um conjunto de aprendizagem de um sistema de potência constituído por 1844 amostras. Cada ponto de operação é caracterizado por um vector [*Reserva Girante, Penetração Eólica*]. A resposta do sistema  $y$  que se pretende emular é o máximo valor absoluto atingido pelo desvio de frequência do sistema,  $|\Delta f|_{\max}$ , na sequência da saída de um parque eólico.

A RT consiste numa árvore binária, sendo constituída por nós e arcos. Cada nó contém armazenado amostras pertencentes ao conjunto de aprendizagem. A cada nó não terminal está associado um *teste de divisão*, que define a forma como o nó se divide (i.e., a qual dos dois nós sucessores irá pertencer cada uma das amostras armazenadas no nó). O primeiro nó (denominado por raiz) contém armazenado todo o conjunto de aprendizagem. Os nós terminais da árvore (que se denominam por *folhas*), definem a decomposição do conjunto de aprendizagem por regiões disjuntas, tal que em cada região a resposta do sistema é o mais constante possível. Na figura 4, a variável  $N$  corresponde ao nº de amostras armazenadas no nó. As variáveis  $Média$  e  $s^2$  correspondem ao valor médio e variância dos valores de  $y$  armazenados no nó.

Dado um novo ponto de operação  $P=[4MW,45\%]$ , para prever qual o valor de  $|\Delta f|_{\max}$  a ele associado, é realizado o seguinte procedimento:

- Encontrar a folha que verifica as condições de operação de  $P$ . Na figura 4, os arcos a *bold* mostram como o ponto de operação do nosso exemplo, partindo da raiz da RT, atravessa a árvore até atingir uma folha.
- Realização da previsão  $|\Delta f|_{\max}$  por aplicação de uma função aos valores de  $|\Delta f|_{\max}$  armazenados na folha. As diversas aplicações existentes diferem na função utilizada (ex: valor médio [6], função de regressão linear [7]). Por exemplo, considerando o valor médio de  $y$  como a função a aplicar nas folhas da árvore, conclui-se que para o ponto de operação apresentado  $|\Delta f|_{\max} = 1,2$  Hz.

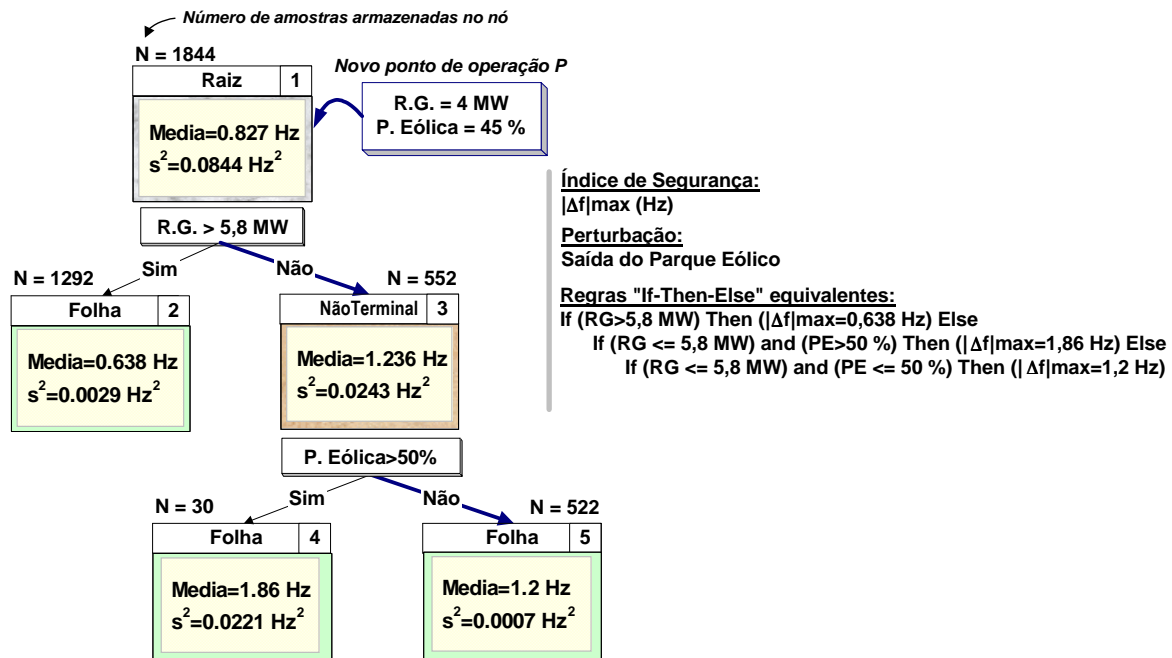


Figura 4 – Hipotética RT com regras “if-then-else” equivalentes

Considerando um limiar de segurança de 1 Hz, então a estrutura da RT apresentada pode ser transformada na seguinte regra de segurança de fácil interpretação:

*If (RG>5,8 MW) Then “seguro” Else “inseguro”.*

Este tipo de regras permite identificar:

- **quais** os parâmetros de operação que têm maior influência sobre o índice de segurança que se pretende avaliar;
  - **como** esses parâmetros influenciam o índice de segurança;
- fornecendo, assim, informações sobre a segurança do sistema que poderão ser utilizadas pelos operadores para a definição de melhores estratégias de planeamento e operação da rede.

#### Construção da Estrutura de Segurança Híbrida KRT

O processo de construção da estrutura de segurança KRT é composto pelas seguintes fases:

- *Construção da árvore de regressão (RT);*
- *Definição do modelo de regressão a aplicar nas folhas da árvore.*

#### Construção da RT

Como já foi atrás referido, a construção da RT consiste na decomposição do conjunto de aprendizagem por regiões disjuntas, de forma a que em cada região a resposta do sistema à perturbação seja o mais constante possível. Matematicamente, o objectivo consiste em minimizar a variância de  $y$ , i.e. a  $s^2(y)$ .

A construção da RT é determinada pelas seguintes questões:

- O teste de divisão óptimo;
- O critério de paragem.

Começando pelo raiz, a RT é construída através da sucessiva divisão dos seus nós. A regra de divisão de um nó é definido por um teste do tipo  $\{a_k(\text{amostra}) > u_k\}$  ?

em que,

$\left\{ \begin{array}{l} a_k(\text{amostra}) : \text{valor do atributo } k \text{ existente na amostra} \\ u_k : \text{valor de limiar a utilizar para o atributo } k \end{array} \right.$

Aplicando este teste, o nó é dividido através da criação de dois nós sucessores, correspondendo às duas instâncias do teste  $\{a_k(\text{amostra}) > u_k\}$  e  $\{a_k(\text{amostra}) \leq u_k\}$ . A divisão de cada nó  $n$  terá que ser realizada segundo o *teste de divisão ótimo*. Este teste corresponde à divisão  $d$  que permite reduzir ao máximo a variância do nó, ou seja, que maximiza:

$$\Delta s^2_{d,n}(y) = s^2_n(y) - P_{nE} \times s^2(y)_{nE} - P_{nD} \times s^2(y)_{nD}$$

em que

$\left\{ \begin{array}{l} s^2_n(y) : \text{variância de } y \text{ no nó " } n \text{"} \\ P_{nE} : \text{proporção de amostras que passam para o nó sucessor Esquerdo resultante da divisão " } d \text{"} \\ P_{nD} : \text{proporção de amostras que passam para o nó sucessor Direito resultante da divisão " } d \text{"} \\ s^2(y)_E \text{ e } s^2(y)_D : \text{variância de } y \text{ nos dois nós sucessores resultantes de divisão " } d \text{"} \end{array} \right.$

Uma vez encontrado o teste de divisão ótimo (através de um algoritmo exaustivo de procura) o passo seguinte consiste na criação definitiva os dois nós sucessores.

O procedimento de divisão prossegue até se verificar o critério de paragem para todos os nós ainda não divididos. Este critério corresponde à verificação de uma das seguintes regras de paragem:

- Regra 1: Não é possível reduzir a variância de uma forma estatisticamente significativa;
- Regra 2: A variância já foi suficientemente reduzida.

Este decide quando é que um nó deverá deixar de ser dividido, passando a consistir numa folha da árvore. A aplicação deste critério de paragem consiste numa forma de evitar o "overfitting" da estrutura construída relativamente ao conjunto de aprendizagem .

### Realizar Previsão com Modelos de Regressão Kernel nas Folhas da RT

Dado um novo ponto de operação  $P$ , cujo valor do índice de segurança  $y$  se pretende conhecer, a primeira coisa a fazer consiste em colocá-lo na folha da RT que verifica as suas condições de operação. Assim, ficam estabelecidas as condições para se poder proceder à previsão de  $y$  por aplicação do modelo de regressão kernel. Este modelo consiste no cálculo da média pesada dos valores de  $y$  pertencentes às amostras  $X_i$ , que são mais "semelhantes" a  $P$ . Por um lado, esta "semelhança" é definida pela utilização, para a previsão, de apenas amostras pertencentes à folha de  $P$ . Por outro lado, é também definida pela aplicação da regra dos  $k$  vizinhos mais próximos, em que apenas as  $k$  amostras mais próximas de  $P$  são utilizadas para realizar a previsão. A proximidade de  $P$  a cada amostra é medida através de uma função de distância Euclidiana  $D$  definida no hiper-espaço dos atributos (normalizados). O peso de cada amostra, é definido por uma função kernel,  $K(u) = e^{-u^2}$ , que confere maior peso a amostras menos distantes de  $P$ . Para a utilização de distâncias normalizadas, o algoritmo define ainda um parâmetro de fronteira  $h$ , de valor igual à distância do  $k$  vizinho mais próximo de  $P$ . Atendendo a estes factores, a previsão de  $y$  é dada por:

$$y_P = \frac{1}{\sum_{i=1}^k \left[ K\left(\frac{D(P, X_i)}{h}\right) \right]} \times \sum_{i=1}^k \left[ K\left(\frac{D(P, X_i)}{h}\right) \times y_{X_i} \right]$$



## 5. Resultados Numéricos

Da aplicação do método KRT, à rede eléctrica da Terceira, obteve-se a RT que se apresenta na figura 5. A forma utilizada para evitar o “overfitting” consistiu na aplicação de um algoritmo de podagem (descrito por Breiman et.al [6]), para além do critério de paragem referido acima. Por falta de espaço, não nos é possível explicar, neste documento, o algoritmo de podagem utilizado.

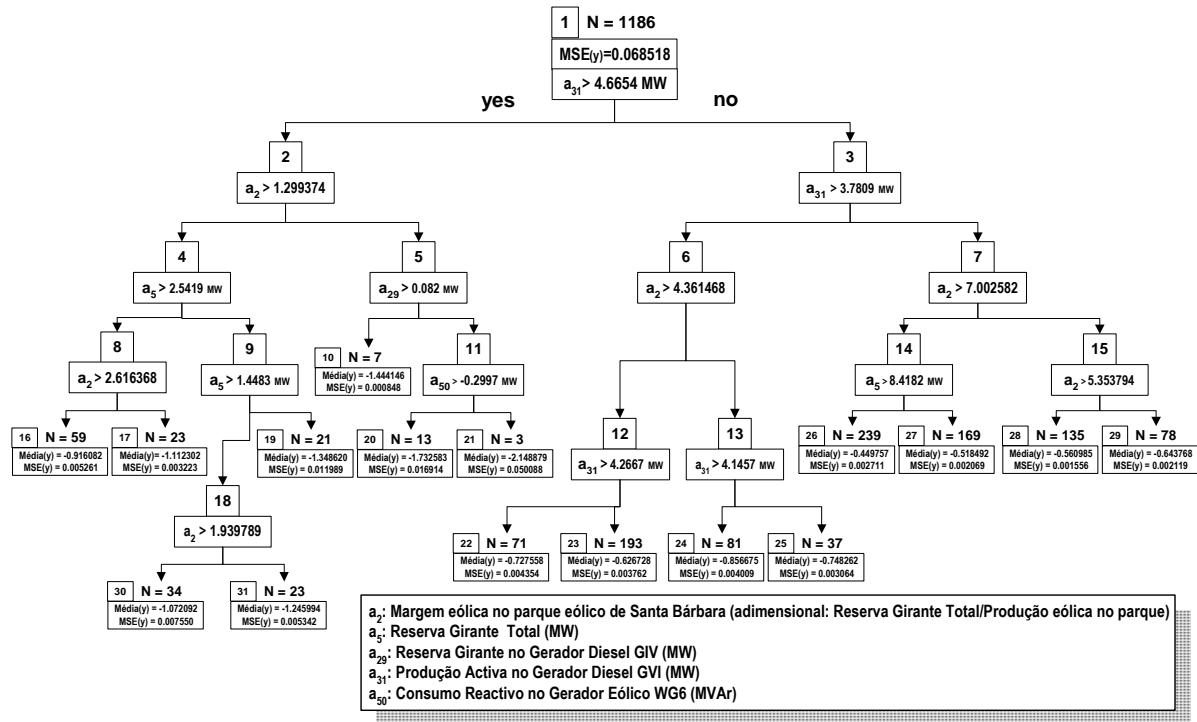


Figura 5 – Árvore de regressão obtida para a Terceira

Os índices apresentados no quadro 1, obtidos a partir da aplicação da estrutura KRT para avaliação de segurança dinâmica do conjunto de teste da Terceira, quantificam o erro de previsão da estrutura construída. O limiar de segurança utilizado para a classificação de um ponto de operação como seguro/inseguro foi o de  $\Delta f_{min} = -1$  Hz.

Média dos Desvios Absolutos (MAE)	0.03478641
Variância dos Desvios (MSE)	0.00229027
Erro de Classificação Global	1.65%
Erro de Falsos Alarmes	1.28%
Erro de Falha de Alarmes	4.60%

Quadro 1 – Avaliação do desempenho da estrutura KRT obtida para a Terceira

## 6. Conclusões

Esta comunicação apresentou a metodologia seguida para obter árvores de regressão híbridas destinadas a avaliar a segurança dinâmica de uma rede isolada com produção eólica.

As árvores de regressão híbridas obtidas mostraram um excelente desempenho e apresentam a dupla função de fornecerem um indicador contínuo do grau de robustez do sistema e apresentar regras de segurança interpretáveis, fornecendo explicações aos operadores sobre o grau de segurança esperado do sistema.

## Agradecimentos

Os autores encontram-se gratos à EDA (Electricidade dos Açores) pelos dados disponibilizados. Também se encontram gratos pelo apoio financeiro prestado pelo Ministério da Ciência e da Tecnologia, no âmbito do Subprograma Ciência e Tecnologia do 2º Quado Comunitário de Apoio, e à Comissão Europeia pelo apoio financeiro prestado para a execução do projecto JOR3CT960119.

## Referências

- [1] E. Nogaret et. al., "Development and implementation of an advanced control system for medium size wind-Diesel systems", Proc. European Wind Energy Conference, Thessaloniki, Grécia, Outubro de 1994.
- [2] Georges Kariniotakis, "Contribution au développement d'un système de contrôle pour les systèmes éolien-diesel autonomes", Thèse de Doctorat, École des Mines, Dezembro de 1996.
- [3] "Development and implementation of an advanced control system for the optimal operation and management of medium size power systems with a large penetration from renewable power sources", Relatório final do projecto Joule II (JOU2-CT92-0053), Junho de 1995. Report EUR 16686 EN. Relatório publicado em livro pela Comissão Europeia, Edição Março de 1996, ISBN 92-827-5007-8.
- [4] N. Hatzargyriou, J. A. Peças Lopes, S. Papathanassiou e V. Van Acker, "Pattern Recognition Versus Decision Trees Methods - A Case Study in Fast Dynamic Security Assessment of Autonomous Power Systems with a Large Penetration from Renewables", Proc. ISAP 94, Montpellier, Setembro de 1994.
- [5] J. N. Fidalgo, J. A. Peças Lopes e V. Miranda, "Neural Networks Applied to Preventive Control Measures for the Dynamic Security of Isolated Power Systems with Renewables", comunicação apresentada ao IEEE Winter Power Meeting em Baltimore, EUA, Janeiro de 1996, e publicada nas IEEE "Transactions on PWRS, Vol. 10, Novembro de 1996.
- [6] L. Breiman, et al., "Classification and Regression Trees", Wadsworth International, 1984.
- [7] A. Karalic, "Employing Linear Regression in Regression Tree Leaves", in proceedings of ECAI-92, Wiley & Sons, 1992.
- [8] Luís Torgo, "Kernel Regression Trees", Proceedings of European Conference on Machine Learning (ECML-97).
- [9] J. D. McCalley et al., "On-Line Visualization of transmission system operating constraints using intelligent information processing", May 1997.
- [10] Vincent Van Acker, "Steady State and Dynamic Behaviour Analysis of Isolated Power Systems with Wind Power Production", Master Theses, July 1995.
- [11] Watson, G.S., "Smooth Regression Analysis", Sankhya: The Indian Journal of Statistics, Series A, 26: 359-372, 1964.
- [12] Nadaraya, E.A., "On estimating regression", Theory of Probability and its Applications, 9:141-142, 1964.
- [13] L. Wehenkal, "Contingency severity assessment for voltage security using non-parametric regression techniques", IEEE Trans. on Power Systems, Vol 11, No. 1, February 1996.
- [14] J.A.Peças Lopes, Fernando Fernandes, "Fast Evaluation of Voltage Collapse Risk Using Machine Learning Techniques", Proc. of VI SEPOPE, S. Salvador da Baía, Brazil, May 1998.
- [15] N. Hatzargyriou, J. A. Peças Lopes, E. Karapidakis e Helena Vasconcelos, "On-line Dynamic Security Assessment of Power Systems in Large Islands with High Wind Power Penetration", Comunicação aceite para apresentação na 13th Power Systems Computation Conference, Trondheim, Noruega, Julho de 1999.