



## **Solução Inteligente para Modelação Térmica de Edifícios**

**PAULO CÉSAR RODRIGUES SILVA**

Novembro de 2022

POLITÉCNICO DO PORTO  
INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO

---

# Solução Inteligente para Modelação Térmica de Edifícios

---

**Paulo César Silva**

Mestrado em Engenharia Electrotécnica e de Computadores  
Área de Especialização em Sistemas e Planeamento Industrial



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA  
Instituto Superior de Engenharia do Porto

Novembro, 2022



*Esta dissertação satisfaz, parcialmente, os requisitos que constam da Ficha de Unidade Curricular de Tese/Dissertação, do 2º ano, do Mestrado em Engenharia Electrotécnica e de Computadores, Área de Especialização em Sistemas e Planeamento Industrial.*

**Candidato:** Paulo César Silva, N.º 1200116, 1200116@isep.ipp.pt

**Orientação Científica:** Zita Vale, zav@isep.ipp.pt

**Coorientação Científica:** Luís Gomes, lfg@isep.ipp.pt



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA  
Instituto Superior de Engenharia do Porto  
Rua Dr. António Bernardino de Almeida, 431, 4200-072 Porto

Novembro, 2022



# Agradecimentos

Aproveito este espaço, dentro de um culminar de um percurso académico longo, composto por vários momentos e que nem sempre foram os momentos mais fáceis ao longo da vida, mas que de certo deixam sempre saudade e acima de tudo, conhecimento e desenvolvimento ao nível pessoal e intelectual. É o final de mais um curso de Engenharia, depois da licenciatura em Engenharia Mecânica, este Mestrado em Engenharia Eletrotécnica, abre-me outras portas e outros horizontes, assim como outros conhecimentos e áreas do saber, e que ainda me resta descobrir onde melhor posso aplicar todos estes conhecimentos adquiridos. Foram dois anos de esforço e dedicação, durante o qual existiu uma pandemia e existiu e existe um função laboral, uma casa e uma esposa para cuidar e à qual quero agradecer acima de tudo, pela paciência, esforço e auxílio durante estes anos. A ti Keily, um agradecimento do tamanho do mundo, e que seja apenas mais um degrau, na nossa enorme escadaria. Além disso, quero agradecer no geral à minha família, também por sempre me apoiarem em tudo o que decido avançar, e que apesar de há alguns anos ter terminado os estudos, não foi estranho para eles que eu voltasse, e quem sabe, se termino por aqui.

E por último, mas não menos importante, um agradecimento aos professores Zita Vale e Luís Gomes, pela sua ajuda e guiamentos, que de tanto serviram para que este estudo fosse possível.

No geral, estou orgulhoso de no final destes dois anos, ter chegado aqui, mesmo nunca pensando no final do meu secundário, que um dia estaria neste ponto do meu percurso académico.



# Resumo

Na era em que vivemos, em que cada vez mais a preocupação com a sustentabilidade energética se enaltece diariamente, importa realizar esforços nesse sentido, recorrendo às cada vez mais ferramentas existentes ao nosso redor. Uma das muitas formas de poder evoluir neste sentido, entre muitas outras, é obter uma modelação térmica dos espaços a estudar.

Modelar termicamente um edifício seria uma tarefa difícil há muitos anos atrás, no entanto nos dias de hoje, recorrendo sobretudo a ferramentas como o *Machine Learning* e Redes Neurais, essa tarefa pode tornar-se bastante mais fácil e eficaz. O objetivo desta dissertação centra-se no desenvolvimento de uma solução inteligente capaz de modelar termicamente edifícios onde se desconheçam os seus materiais de construção.

Este estudo enquadra-se no desenvolvimento de um conjunto de ferramentas capazes de efetuar a modelação térmica de um edifício, e para atingir esse objetivo foram identificados modelos matemáticos capazes de efetuar previsões de temperatura recorrendo a *datasets* de temperatura, assim como o desenvolvimento de uma aplicação baseada em *Machine Learning* e com a sua estrutura desenvolvida com base numa Rede Neuronal, apenas com dados reais utilizados para o treino da solução. Foram estudados quais os melhores modelos matemáticos e redes neuronais a utilizar, de forma a alcançar resultados os mais aproximados dos reais.

Os objetivos do desenvolvimento da solução foram alcançados, através da comparação dos resultados previsionais com os valores reais e ainda através de métricas de erro, capazes de identificar a precisão dos dois modelos de previsão. Concluiu-se ainda que os modelos matemáticos têm uma precisão bastante inferior quando comparados com o resultados obtidos através da aplicação desenvolvida com base em redes neuronais.

**Palavras-Chave:** *Deep Learning*, *IoT*, Modelação Térmica, *Machine Learning*, Redes Neurais, Temperaturas



# Abstract

In the era in which we live, in which the concern with energy sustainability is increasingly praised daily, it is important to make efforts in this direction, using the increasingly existing tools around us. One of the many ways to evolve in this direction, among many others, is to obtain a thermal modeling of the spaces to be studied.

Thermally modeling a building would have been a difficult task many years ago, however nowadays, using tools such as *Machine Learning* and Neural Networks, this task can become much easier and more effective.

The objective of this dissertation is focused on the development of an intelligent solution capable of thermally modeling buildings where their construction materials are unknown.

This study is part of the development of a set of tools capable of performing the thermal modeling of a building, and to achieve this objective mathematical models capable of making temperature predictions using temperature *datasets* were identified, as well as as the development of an application based on *Machine Learning* and with its structure developed based on a Neural Network, with only real data used to train the solution. The best mathematical models and neural networks to use were studied, in order to achieve results that are closest to the real ones.

The objectives of the solution development were achieved, through the comparison of the forecast results with the real values and also through error metrics, capable of identifying the precision of the two forecast models. It was also concluded that the mathematical models have a much lower precision when compared to the results obtained through the application developed based on neural networks.

**Keywords:** *Deep Learning, IoT, Machine Learning, Neural Networks, Temperatures, Thermal Modelling,*



# Índice

<b>Lista de Figuras</b>	<b>vii</b>
<b>Lista de Tabelas</b>	<b>ix</b>
<b>Lista de Acrónimos</b>	<b>xi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Contextualização . . . . .	1
1.2 Objetivos . . . . .	2
1.3 Calendarização . . . . .	3
1.4 Metodologia . . . . .	3
1.5 Estrutura da Dissertação . . . . .	3
<b>2 Estado da Arte</b>	<b>5</b>
2.1 Modelação Térmica de Edifícios . . . . .	5
2.2 Modelo <i>Grey-Box</i> . . . . .	8
2.3 Modelo Matemático . . . . .	9
2.3.1 Método das Funções de Transferência . . . . .	10
2.3.2 Cálculo da Carga Térmica . . . . .	10
2.3.3 Conversão da Carga Térmica em Temperatura Interior . . . . .	13
2.4 Inteligência Artificial . . . . .	15
2.5 <i>Machine Learning</i> . . . . .	16
2.6 <i>Internet of Things</i> . . . . .	17
2.7 <i>Machine Learning</i> através de <i>IoT</i> . . . . .	19
2.8 Controlo Térmico através de <i>Machine Learning</i> . . . . .	20
2.9 Redes Neurais . . . . .	21
2.9.1 Redes Neurais Recorrentes ( <i>Recurrent Neural Network (RNN)</i> ) . . . . .	23
<b>3 Implementação</b>	<b>25</b>
3.1 Arquitetura da Solução . . . . .	26
3.2 Sensores <i>IoT</i> . . . . .	27
3.3 <i>Dataset</i> . . . . .	28
3.4 <i>Machine Learning</i> . . . . .	30

3.5	Caso de Estudo . . . . .	32
3.6	Integração dos Parâmetros . . . . .	36
3.6.1	Integração dos Parâmetros com o Modelo Matemático . . . . .	41
3.6.2	Integração dos Parâmetros com as Redes Neuronais . . . . .	43
<b>4</b>	<b>Análise de Resultados</b>	<b>47</b>
4.1	Teste e Calibração de Sensores . . . . .	47
4.2	Análise de Resultados do Modelo Matemático . . . . .	48
4.3	Análise de Resultados da Rede Neuronal . . . . .	51
4.4	Dados Previstos <i>vs</i> Dados Reais . . . . .	54
4.5	Análise de Resultados . . . . .	56
4.6	Alternativas à Solução Desenvolvida . . . . .	60
<b>5</b>	<b>Conclusão</b>	<b>63</b>
5.1	Apreciação Final . . . . .	63
5.2	Trabalho Futuro . . . . .	65
	<b>Referências</b>	<b>67</b>
	<b>Anexo A Anexos</b>	<b>71</b>
A.1	Código da Aplicação integrada com Redes Neuronais . . . . .	71
A.2	Código da Aplicação para cálculo do Erro . . . . .	72

# Lista de Figuras

1.1	Calendarização da Dissertação. . . . .	3
2.1	Modelo Físico de Trocas de Energia [12] . . . . .	6
2.2	Comparação entre Modelos de Modelação Térmica por [13] . . . . .	8
2.3	Esquema do Modelo <i>Grey Box</i> [30] . . . . .	9
2.4	Esquema das transferências de energia existentes [23]. . . . .	11
2.5	Arquitetura das camadas do <i>IoT</i> [29]. . . . .	18
2.6	Esquema do modelo MCUNet [14] . . . . .	19
2.7	Esquema da plataforma proposta [16] . . . . .	20
2.8	Descrição dos vários tipos de Redes Neurais Artificiais [33] . . . . .	21
2.9	Esquema de um modelo não linear de um neurónio <i>Artificial Neural Network (ANN)</i> [27] . . . . .	22
2.10	Arquitetura de uma Rede Neuronal Recorrente [25] . . . . .	24
3.1	Arquitetura da Solução . . . . .	26
3.2	Sensor de Temperatura e Humidade <i>Xiaomi</i> . . . . .	27
3.3	Vista geral da aplicação <i>Mi Home</i> . . . . .	28
3.4	Estrutura da <i>Feedforward Multilayer Perceptron (FFMLP)</i> de três camadas [3]. . . . .	31
3.5	Vista geral do volume de estudo de [4] . . . . .	31
3.6	Planta da habitação onde se encontra inserido o volume de estudo. . . . .	33
3.7	Vista Interior da Habitação . . . . .	34
3.8	Vista Interior da Habitação . . . . .	34
3.9	Vista Geral do Interior da Habitação . . . . .	35
3.10	Exemplo da recolha de dados diretamente ao dispositivo por [5]. . . . .	38
3.11	Exemplo da recolha de dados diretamente para a <i>cloud</i> por [5]. . . . .	38
3.12	Radiação Global para Portugal Continental em Setembro de 2022 . . . . .	39
3.13	Temperatura Máx. e Min. entre os dias 3 e 17 de setembro de 2022 na estação meteorológica Porto - Serra do Pilar. . . . .	40
3.14	Temperatura obtida entre as 16:00 horas - 8 de setembro até às 14:00 horas - 11 de setembro através dos sensores <i>Internet of Things (IoT)</i> . . . . .	40
3.15	Sequência da Rede Neuronal de <i>AR Net</i> . . . . .	45

4.1	Ilustração das Cargas Térmicas e Ganhos Solares presentes no volume de estudo. . . . .	49
4.2	Temperatura prevista através do Modelo Matemático . . . . .	51
4.3	Estrutura da Rede Neuronal com <i>LSTM</i> . . . . .	53
4.4	Temperatura prevista através da Rede Neuronal . . . . .	54
4.5	Previsões de Temperatura <i>vs</i> Dados reais . . . . .	55
4.6	Erro calculado para os resultados obtidos. . . . .	57
A.1	Visualização da Aplicação . . . . .	73
A.2	Visualização da Aplicação . . . . .	74
A.3	Visualização da Aplicação . . . . .	75
A.4	Visualização da Aplicação . . . . .	76
A.5	Visualização da Aplicação . . . . .	77
A.6	Visualização da Aplicação . . . . .	78
A.7	Visualização da Aplicação . . . . .	79

# Lista de Tabelas

2.1	Correção Latitude-Mês para latitude 40°N . . . . .	12
2.2	Coefficientes da função de transferência normalizados . . . . .	15
3.1	<i>Dataset</i> obtido através da <i>MeteoBlue</i> . . . . .	29
3.2	Medidas dos elementos construtivos da divisão em estudo. . . . .	36
4.1	Erro calculado através de métricas simples. . . . .	58
4.2	Erro calculado através das métricas <i>RSME</i> e <i>MAE</i> . . . . .	58
4.3	Comparação do erro calculado através das métricas <i>RSME</i> com o estudo de [10]. . . . .	61
4.4	Comparação do erro calculado através das métricas <i>RSME</i> com o estudo de [10]. . . . .	61



# Lista de Acrónimos

<b>ANN</b>	<i>Artificial Neural Network</i>
<b>ASHRAE</b>	<i>American Society of Heating, Refrigerating and Air Conditioning Engineers</i>
<b>AVAC</b>	Aquecimento, Ventilação e Ar Condicionado
<b>CFD</b>	<i>Computacional Fluid Dynamics</i>
<b>CLF</b>	<i>Cooling Load Factor</i>
<b>DTE</b>	Diferença de Temperatura Equivalente
<b>DTS</b>	<i>Dynamic Thermal Simualtion</i>
<b>FFMLP</b>	<i>Feedforward Multilayer Perceptron</i>
<b>IoT</b>	<i>Internet of Things</i>
<b>IPMA</b>	Instituto Português do Mar e da Atmosfera
<b>LSTM</b>	<i>Long Short-Term Memory</i>
<b>MAE</b>	Mean Absolut Error
<b>MSHGF</b>	<i>Maximum Solar Heat Gain Factor</i>
<b>NAS</b>	<i>Neural Architecture Search</i>
<b>RMSE</b>	Root Mean Squared Error
<b>RNN</b>	<i>Recurrent Neural Network</i>
<b>SC</b>	<i>Shading Coefficient</i>



# Capítulo 1

## Introdução

*Neste capítulo pretende-se realizar uma breve introdução ao tema desta dissertação, definir os principais objetivos e requisitos envolvidos, apresentar a estrutura e o conteúdo de cada capítulo.*

### 1.1 Contextualização

Nos dias de hoje apesar dos equipamentos serem cada vez mais eficientes ao nível energético e apesar da existência e facilidade de instalação de geração de energia local renovável, o alcançar pleno da sustentabilidade nos edifícios não é simples de se atingir dado a dependência crescente de eletricidade. Além disso, o conforto térmico é um dos pontos mais procurados pela população, e isso faz-se notar tanto em termos de materiais de construção como em elementos de acabamento dos edifícios.

Não só pelos motivos mencionados, mas também pelo anseio de cada vez mais se automatizar e prever computacionalmente o maior número de dados possíveis, por forma a facilitar a vida humana e prevenir acidentes e gastos desnecessários, também nesta área da energia térmica, é crucial que se façam esforços para evoluir nesse sentido.

A tecnologia tem vindo a ser utilizada cada vez mais em *prol* do ser humano, em todas as vertentes para facilitar a sua vida. Isto também é verdade ao nível industrial e de maquinaria, e nesse sentido o *Machine Learning* tem vindo cada vez mais a impor-se no mundo atual, pois como próprio nome indica, consiste numa aprendizagem das máquinas, através da Inteligência Artificial, que auxilia em muitas tarefas

do dia a dia dos utilizadores. O conceito de *Machine Learning* tem sido alvo de um foco especial de atenção pela sua grande capacidade de prever com grande precisão um elevado número de fenómenos complexos, através da sua forma de adquirir conhecimento e aprendizagens através da leitura de dados em praticamente todas as áreas de conhecimento [1].

Através destas ferramentas, é possível também treinar uma máquina ou uma solução, para que seja também ela capaz de demonstrar resultados com base em acontecimentos passados. Hoje em dia, existem bastantes bases de dados e *datasets* com bastante informação de todo o tipo, desde dados de saúde até dados de meteorologia. No caso desta dissertação, os dados de meteorologia revelam-se imprescindíveis à boa conclusão deste trabalho, uma vez que eles são a base para que se consiga obter previsões aproximadas da realidade de modo a que se consiga visualizar a modelação térmica de um edifício sem conhecer os seus materiais de construção.

Ainda recorrendo às novas tecnologias, também os sensores *IoT* se revelam importantes nesta solução, uma vez que estes são responsáveis por registar e fornecer dados em tempo real de onde quer que os sensores estejam inseridos.

## 1.2 Objetivos

Nesta nova revolução da *internet* e da forma como interagimos com ela e com as máquinas, é de enorme importância a implementação de análises avançadas de dados para apoiar as tarefas de monitorização, previsão e otimização de quaisquer que sejam as tarefas a desenvolver.

O principal objetivo desta dissertação é desenvolver uma solução inteligente capaz de prever temperaturas dentro de um espaço temporal reduzido, para um determinado volume de estudo, recorrendo a modelos matemáticos e a redes neuronais.

De seguida são apresentados alguns dos subobjetivos deste trabalho:

- Obter um *dataset* com dados de temperatura exteriores, da localização do volume de estudo;
- Desenvolver um modelo matemático, capaz de prever a temperatura interior do local, recorrendo ao cálculo de cargas térmicas;
- Desenvolver uma aplicação recorrendo a uma Rede Neuronal, através de linguagem *python*, capaz de efetuar a previsão da temperatura interior do local de estudo;
- Analisar e comparar os dados obtidos;
- Calcular o erro associado a estes dados;

## 1.3 Calendarização

Por forma a organizar o estudo e a estrutura final da dissertação, é necessário passar por várias fases para que se alcance o resultado final deste trabalho. Nesse sentido, como mostra a figura 1.1, através de um diagrama é possível determinar as etapas cruciais do projeto e dentro de que espaço temporal elas se encontram.

Tarefa	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out
<b>Estudo da Dissertação</b>										
Estado da Arte										
Pesquisa de Dataset										
Estudo dos Modelos										
Estudo dos Sensores										
Elaboração da Aplicação em <i>python</i>										
Desenvolvimento da Dissertação										
Teste e Validação										
Conclusão da Dissertação										

Figura 1.1: Calendarização da Dissertação.

## 1.4 Metodologia

Na primeira fase do desenvolvimento desta dissertação existe uma ampla revisão de literatura sobre metodologias de *Machine Learning* e as diferentes arquiteturas utilizadas em treino de soluções inteligentes. Paralelamente, foram exploradas metodologias de modelação térmica de edifícios e modelos matemáticos também capazes de efetuar a previsão de temperaturas à semelhança dos modelos de *Machine Learning*.

Depois de um levantamento alusivo a estas metodologias e ferramentas, foram desenvolvidos métodos de treino de Redes Neurais através da leitura de dados pré-existentes e também através da leitura de dados reais obtidos através de sensores *IoT*. Adicionalmente foram implementadas funções para a visualização de dados de forma gráfica e conseqüentemente o cálculo dos erros associados à previsão de temperaturas.

Na fase final deste trabalho foram obtidas conclusões à cerca da comparação dos dados obtidos através de Modelos Matemáticos e através das Redes Neurais e uma breve descrição dos trabalhos futuros a realizar com base neste trabalho.

## 1.5 Estrutura da Dissertação

Esta dissertação é composta por cinco capítulos, cada um deles organizados em secções e subsecções.

**Capítulo 1: Introdução**

Neste primeiro capítulo pode-se encontrar a contextualização da dissertação, assim como os objetivos deste documento e uma estruturação da organização do mesmo.

**Capítulo 2: Estado da Arte**

O capítulo 2, apresenta um levantamento do estado da arte relativamente a modelação térmica através de modelos matemáticos e de modelos que assentam na tecnologia de *Machine Learning*, a nível de investigação. Faz-se ainda uma breve abordagem à junção do *Machine Learning* com os sensores *IoT* e Redes Neurais.

**Capítulo 3: Implementação**

No capítulo 3 apresenta-se a metodologia e arquitetura geral da solução construída, tentando justificar-se as escolhas quanto aos parâmetros e tecnologias utilizadas.

**Capítulo 4: Resultados**

No capítulo 4 são apresentados os resultados obtidos, assim como a análise aos dados e respetivas comparações entre modelos.

**Capítulo 5: Conclusão**

Por último, no capítulo 5 são apresentadas as conclusões e apreciações finais à cerca desta dissertação, assim como algumas ideias para trabalhos futuros a aplicar tendo como base esta dissertação.

## Capítulo 2

# Estado da Arte

*A modelação térmica de edifícios, no que se refere sobretudo à Inteligência Artificial, tem sido objeto de estudo e de desenvolvimento recentes. No estado da arte desta dissertação, pretende realizar-se a introdução de conceitos-chave bem como a revisão literária, no que diz respeito a Inteligência Artificial, dando especial relevo ao Machine Learning e Redes Neurais.*

### 2.1 Modelação Térmica de Edifícios

Para entender o conceito estudado, é necessário compreender de que forma funciona a modelação térmica e por conseguinte, esta em edifícios. O conceito de modelação térmica, baseia-se na transferência de energia térmica entre dois volumes ou locais, uma vez que esta é a responsável pelas diferenças de temperatura num determinado espaço. A modelação térmica nada mais é, que a definição do comportamento térmico de edifícios através da observação das transferência de energia resultado da aplicação de métodos e modelos, segundo [11].

Num edifício existem numerosas trocas de energia, quer pelas paredes, pela cobertura, pelas janelas, pelas portas, pelos equipamentos existentes dentro dele e até pelas pessoas que circulam no mesmo.

Segundo [12], as trocas de energia num edifício com uma janela instalada são várias e numerosas como ilustrado na Figura 2.1.

Observando a Figura 2.1, temos algumas representações, que são lidas da seguinte forma:

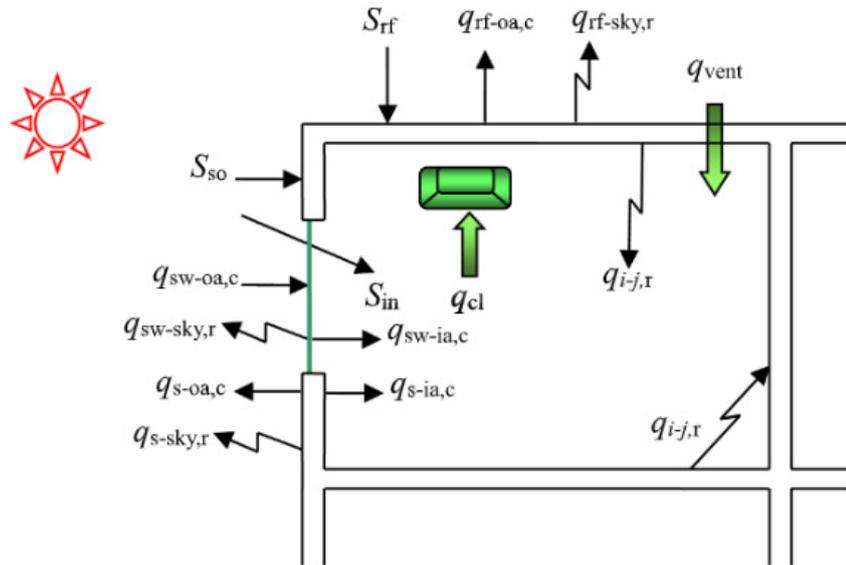


Figura 2.1: Modelo Físico de Trocas de Energia [12]

$q_{i-j, x}$  - Taxa de transferência de energia em modo  $x$ , entre a superfície  $i$  e  $j$  (onde  $x$ :  $r$  - radiação;  $c$  - convecção;  $cd$  - condução);

$S_i$  - Radiação solar absorvida pela superfície  $i$  (onde  $i$ :  $so$  - parede sul;  $in$  - superfície interior;  $rf$  - teto;  $oa$  - ar exterior;  $sky$  - céu);

Para trocas de energia, considera-se assim:

- **Radiação** - Como sendo radiação térmica, e sendo a energia emitada através de ondas eletromagnéticas por toda a matéria que tenha uma temperatura diferente do zero absoluto;
- **Convecção** - Como sendo a energia transferida por contacto de partículas elementares em movimento;
- **Condução** - Como sendo a energia transferida por contacto direto das partículas elementares;

Estes conceitos são cruciais para estudar a modelação térmica, uma vez que são estes fenómenos os responsáveis pela troca de energia entre superfícies ou meios. Existem vários modelos e métodos quando se fala de modelação térmica de edifícios, técnicas estas, que se baseiam em equações que descrevem o comportamento físico das variadas transferências de energia. Neste caso, importa destacar os que se consideram ser mais relevantes e baseado em [13], são destacados essencialmente três diferentes tipos de estudos para a modelação térmica de um edifício, sendo:

- **White-Box** - Neste tipo de abordagem, *Computacional Fluid Dynamics* (CFD) é a mais completa e foca-se em resolver equações de *Navier Stokes*. Na abordagem zonal, trata-se de uma simplificação da CFD, onde consiste em dividir

o espaço estudado em células menores. E por fim, o método dos nós, que consiste em assumir que a zona a estudar é um volume homogéneo definido por variáveis de estado uniformes. Por forma a melhor compreender este método, [13] destacou os seguintes exemplos:

- **CFD** - Nesta abordagem, uma célula é responsável por controlar um volume, com variáveis de estado local. Pode ser aplicado para a qualidade do ar interior e sistemas Aquecimento, Ventilação e Ar Condicionado (AVAC).
  - **Método Zonal** - Uma célula neste caso, divide uma divisão noutras menores e pode ser aplicada para controlar o conforto térmico interior.
  - **Método Nodal** - Consiste numa célula, ser apenas focada no controlo de uma divisão e é utilizada para a determinação do consumo total de energia.
- **Black-Box** - Este método baseia-se em métodos estatísticos e *machine learning*. Contrariamente às abordagens utilizadas no método *White-Box*, neste caso não são necessárias informações físicas sobre o edifício. Este modelo foca-se na implementação de uma função deduzida através de amostras de *data training* que são responsáveis por descrever o comportamento de um dado sistema. São várias as abordagens existentes no estudo deste campo, mas métodos de regressão linear múltipla e redes neurais artificiais, são os mais comuns e os mais relevantes para este caso. Alguns exemplos desta aplicação, segundo [13], são:
    - **Algoritmo Genético** - Inicia-se através da imposição da equação pelo utilizador e permite prever o consumo de energia, otimizando a carga que o equipamento emite.
    - **ANN** - Este método permite prever o consumo de energia e o seu uso.
  - **Grey-Box** - Por último, esta abordagem consiste numa abordagem híbrida das duas anteriormente mencionadas, uma vez que é um conjunto de técnicas baseadas em conceitos físicos, como no caso do método *White-Box* e em métodos estatísticos e *machine learning* como no método *Black-Box*. Ambos os modelos tem a sua complexidade, e o objetivo deste último é retirar o melhor dos dois e deixar para segundo plano aquilo que dificulta mais o processo em si, sem retirar a eficiência do estudo. Essencialmente, este método pode ser dividido em três passos [30]:
    - Construir a base para o sistema com um modelo de conhecimento simplificado;
    - Determinar os parâmetros físicos do sistema;

- Identificar o valor dos parâmetros do modelo a partir de dados reais.

De uma forma mais gráfica, pode ver-se na figura 2.2 uma comparação entre os modelos feita por [13].

Método	Geometria do Edifício	Dados para Treino	Interpretação Física
<b>White Box</b> ou Físico	É necessária uma descrição detalhada de geometria do edifício.	Não são necessários dados para treino da solução.	Os resultados podem ser interpretados em termos físicos.
<b>Black Box</b> ou Estatístico	Não é necessária uma descrição da geometria do edifício.	É necessária uma quantidade alargada de dados recolhidos durante um período.	Existem sérias dificuldades em interpretar os resultados em termos físicos.
<b>Grey Box</b> ou Híbrido	Uma descrição básica do edifício é suficiente.	Uma pequena quantidade de dados recolhida durante um curto período é suficiente.	Os resultados podem ser interpretados em termos físicos.

Figura 2.2: Comparação entre Modelos de Modelação Térmica por [13]

Num modo geral, e tendo como objetivo efetivamente o estudo de uma solução inteligente para a modelação térmica de edifícios, estes métodos encaixam na perfeição nesta situação, uma vez que é possível através de *machine learning* estimar os parâmetros físicos do edifício, além de ser ainda possível usar estatísticas de modo a implementar um modelo de aprendizagem que descreva o comportamento térmico do edifício e ainda aplicar os métodos estatísticos em situações em que os modelos físicos não são tão precisos.

## 2.2 Modelo *Grey-Box*

De um modo geral, e indo de encontro ao que já está referido, uma forma de efetuar estudos, quer matemáticos, estatísticos ou de modelação computacional, como é o caso, recorre-se normalmente a métodos já existentes, de forma a reutilizar recursos e a avançar mais rapidamente no sentido em que se quer levar a cabo o estudo. Neste caso, o modelo *Grey Box* revela-se o mais eficaz no estudo da modelação térmica de edifícios, uma vez que este combina partes de uma estrutura teórica, como é o caso do modelo matemático a utilizar, com uma outra componente de dados, tal como os *datasets* utilizados, para completar o estudo [13]. É um modelo utilizado para casos gerais não lineares, e geralmente torna-se uma junção de modelos *White Box*, que apenas fazem simulações teóricas, com modelos *Black Box* que fazem o processamento de dados reais.

O caso geral da utilização deste tipo de método, é um modelo não linear, que como já referido possui uma parte da sua estrutura que é teórica e outra parte que deriva de dados. A forma deste modelo se desenvolver é assente numa seleção de valores

que não sejam zero, e os coeficientes que restam são minimizados tendo em conta os dados que se fornecem. Finalmente, quando existe dados suficientes, eles vão sendo diminuídos até se chegar a um resultado com base nos mesmos, e este processo pode ser repetido quantos vezes quantas mais se queira aproximar do resultado inicial.

Este método pode ser validado com parâmetros extra, que sejam relevantes para o resultado final, para que se possa cada vez mais aproximar a solução final, dos valores que se tem em conta que são os dados relevantes para a solução.

De uma forma geral, este modelo resulta num esquema como representa a figura 2.3, obtida da análise do estudo de [30] para o mesmo tipo de aplicação do método *Grey Box*, em previsão de dados.

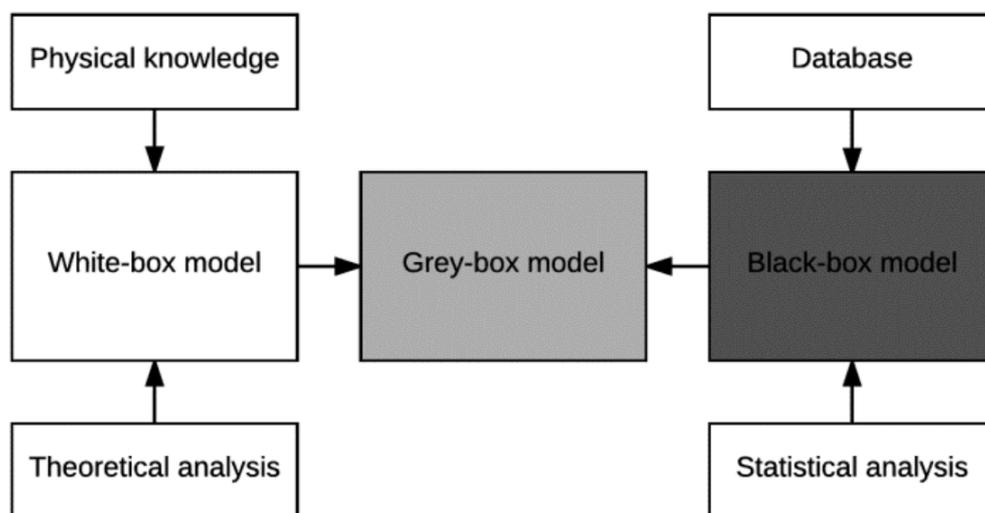


Figura 2.3: Esquema do Modelo *Grey Box* [30]

Resumindo, este modelo combina conhecimento prioritário de qualidade com quantidade de dados. É um dos casos em que aliar quantidade a qualidade, pode originar melhores resultados.

## 2.3 Modelo Matemático

Um dos objetivos desta solução, passa por efetuar a modelação térmica de um edifício recorrendo a um modelo matemático. Neste sentido, de onde melhor se pode partir numa situação destas, é através do cálculo das temperaturas interiores do volume de estudo, entrando naturalmente com todos os dados possíveis retirados de *datasets* existentes. Neste caso, e para efeitos de estudo, neste capítulo explica-se as bases do método simplificado para o cálculo das temperaturas, recorrendo a um método de simulação térmica, nomeadamente o Método das Funções de Transferência. Naturalmente este método requer grandes conhecimentos e recursos, e normalmente

não é utilizado em projetos em fase de estudo, por ser complexo de implementar, e nesse sentido é por isso que se recorre a um método simplificado.

A metodologia alcançada neste estudo, resulta de algumas simplificações ao método, que é utilizado em programas avançados de simulação térmica. No entanto, a função principal deste método é o cálculo da carga térmica nos espaços, mas apresenta um complemento na fase final, que permite determinar as variações de temperatura em espaços interiores.

Posto isto, este método centra-se em duas fases: a fase do cálculo da carga térmica e a segunda fase, da sua carga térmica em valores de temperatura interior.

### 2.3.1 Método das Funções de Transferência

Este método, é um dos primeiros métodos de cálculo preciso da carga térmica, tendo sido desenvolvido por Mitalas para a *American Society of Heating, Refrigerating and Air Conditioning Engineers (ASHRAE)*. Este método baseia-se assim em funções de transferência de energia para determinar a resposta do espaço às solicitações externas e internas. Uma função de transferência é uma série temporal, que relaciona o valor de uma variável, num determinado instante, com o seu próprio valor de outras variáveis, em instantes anteriores, e é geralmente obtida através de Fatores de Resposta. Assim sendo, aplicam-se dois tipos de funções, as funções de fluxo, que determinam o fluxo instantâneo de calor que chega à fronteira interna do espaço, que é por sua vez convertido em carga térmica pelas funções de carga. A carga térmica total é obtida através da soma de todos os valores obtidos por resolução das funções de transferência de carga [18].

A determinação Fatores de Resposta, mencionados anteriormente, é um processo bastante complexo, pelo que a sua determinação é normalmente através de processos iterativos, e nesse sentido neste passo, utilizam-se valores tabelados de situações típicas.

A segunda fase deste processo, passa assim por ser o recurso a uma outra função de transferência, ainda dentro deste mesmo método, que é responsável essencialmente por relacionar a carga térmica e o calor que é extraído do espaço, com a temperatura resultante. Como no regime estudado, a taxa de extração de calor é nula, a carga térmica é calculável, logo, a única incógnita é a temperatura do volume em estudo. Posto isto, no final extraem-se valores de temperatura interior, de carga térmica e de Fatores de Resposta.

### 2.3.2 Cálculo da Carga Térmica

A primeira fase, como já indicado, passa por determinar a carga térmica, pelo que importa explicitar alguns dos seus passos. Por carga térmica, entende-se a quantidade de calor que é necessário retirar ou inserir a um espaço, de modo que este

mantenha a sua temperatura constante. Como no caso deste trabalho a estação em que se encontra centrado o estudo é o verão, o fluxo de carga é do exterior para o interior, uma vez que a temperatura interior é inferior à exterior. Estas diferenças de temperatura, fazem com que exista um diferencial de carga térmica entre o volume de estudo e o exterior. O seu valor é o resultado da soma de várias componentes, como se pode ver na figura 2.4.

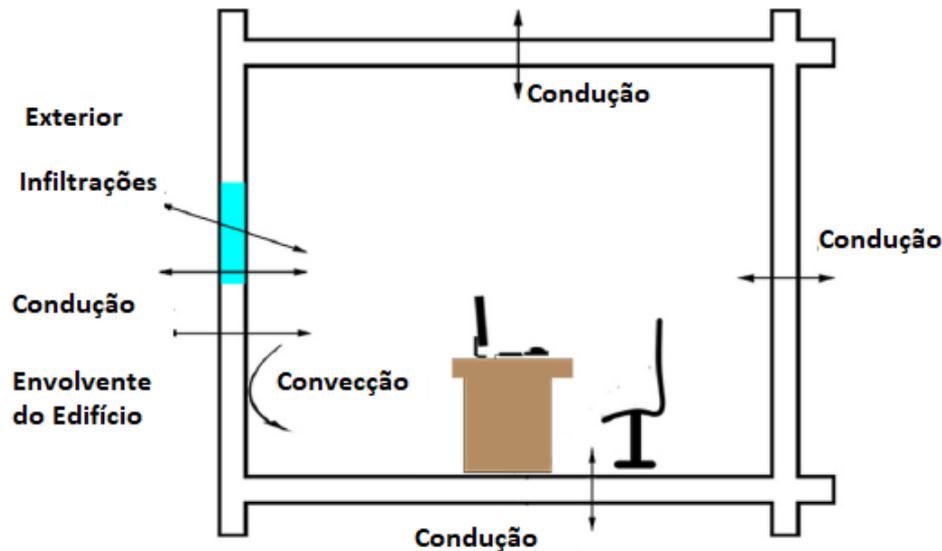


Figura 2.4: Esquema das transferências de energia existentes [23].

Com exceção dos ganhos internos, que neste caso são nulos, uma vez que o volume de estudo não conteve entrada/saída de pessoas, todas as restantes componentes, podem inverter o seu sentido consoante a temperatura exterior, seja superior ou inferior à interior [19]. Tendo em conta todas as componentes indicadas, o objetivo passar por encontrar o valores para a carga térmica relativamente à envoltura exterior e os ganhos solares através dos envidraçados.

Iniciando a análise pela condução através da envoltura exterior, nesta componente, considera-se todas as contribuições da condução pelas paredes, coberturas e envidraçados exteriores, que são tratados de forma semelhante. A equação que define a carga térmica destas componentes, é idêntica à equação da condução monodimensional em regime estacionário, em que a diferença de temperaturas entre o interior e exterior, é substituída por um valor fictício que permite contabilizar o facto do fenómeno não ser estacionário. Deste modo, denomina-se este valor por Diferença de Temperatura Equivalente (DTE), que corresponde à diferença de temperatura que deveria existir entre os dois lados de um elemento exterior, que em regime estacionário e na ausência de radiação solar, originaria o mesmo ganho que na situação real.

$$\dot{Q}_{\Theta} = k A \Delta T_{e\Theta} \quad (2.1)$$

- $\Delta T_{e\Theta}$  - Diferença de Temperaturas Equivalente;
- $A$  - Área em estudo;
- $k$  - Condutividade Térmica;

O valor da Diferença de Temperaturas Equivalente, deve ser corrigido sempre que seja pertinente, uma vez que este valor de referência foi obtido através do cálculo para os tipos de paredes mais usuais em Portugal, e baseado numa temperatura interior de 25°C e numa temperatura exterior de 25,5°C. Neste sentido, deve-se corrigir o valor, da seguinte forma:

$$\Delta T_{e_{\text{corrigido}}} = (\Delta T_e + LM) C + (25 - T_{\text{interior}}) + (T_{\text{exterior}} - 25,5) \quad (2.2)$$

Neste caso, é necessário, além dos valores de temperatura interior ( $T_{\text{interior}}$ ) e exterior ( $T_{\text{exterior}}$ ), os valores de LM (Correção Latitude-Mês), onde a sua função como o nome indica, é corrigir os valores tabelados da DTE para o local e mês a estudar. Como a latitude em Portugal Continental se situa entre os 38° a 42°N, considera-se um valor intermédio de 40°N. Para o valor de Latitude-Mês (LM), presente na equação 2.2, esses valores estão tabelados segundo [6], e essa tabela 2.1 é indicada abaixo. Esse valor, terá de ser encontrado para os intervalo de meses em estudo, e para a localização do volume de estudo, seja Norte (N), Noroeste (NE), Este (E), Sudoeste (SE) ou Sul (S). No caso do mês a que se refere o estudo (setembro), o valor pode ser considerado na tabela 2.1, para os valores de 40°N.

Tabela 2.1: Correção Latitude-Mês para latitude 40°N

Mês	N [°C]	NE [°C]	E [°C]	SE [°C]	S [°C]
Dez.	-3,3	-5,5	-5,5	0,0	5,5
Jan./Nov.	-2,7	-5,5	-5,0	0,5	6,1
Fev./Out.	-2,7	-4,4	-3,3	1,6	6,6
Mar./Set.	-2,2	-2,7	-1,6	2,2	5,5
Abr./Ago.	1,1	-1,1	0,0	1,1	2,2
Mai./Jul.	0,0	0,0	0,0	0,0	0,5
Jun.	0,5	0,5	0,5	0,0	-0,5

Para os valores de C (Correção de Cor), existem três valores atribuídos, consoante a cor que se esteja a analisar. Para cores claras o valor de 0,65, o valor de 0,83 para cores médias e 1 para cores escuras. Quando se trata de edifícios residenciais, opta-se por utilizar o valor para cores médias.

Para o cálculo do valor de carga térmica por condução através dos envidraçados, apenas existe a alteração dos valores da DTE, em que é considerado o valor de temperatura interior de 25,5 °C e o valor de temperatura exterior de 29,4 °C.

Para o cálculo da carga térmica por condução através da envolvente interior, esta é desprezada, uma vez que o volume de estudo se encontrou vazio de pessoas e equipamentos em funcionamento, durante o registo das temperaturas pelo IoT.

Deste modo, obtém-se assim as condições para o cálculo da carga térmica por condução através das diversas componentes indicadas. Resta agora indicar como calcular os ganhos solares através dos envidraçados.

Nesta componente, tem-se por objetivo explicitar a importância dos envidraçados, neste estudo em concreto. Estes, além de contribuírem para a componente da condução através da envolvente exterior, como já mencionado anteriormente, também permitem que a radiação solar entre no espaço, constituindo ganhos solares diretos. Parte da energia que atinge o envidraçado, é refletida para a atmosfera e apenas uma parte se transforma em carga térmica, sendo a restante energia absorvida pelas paredes, pavimento, etc., só sendo libertada para o ar interior mais tarde quando a temperatura do espaço começar a baixar.

O que tem vindo a ser demonstrado até agora, traduz-se na seguinte equação 2.3:

$$\dot{Q}_{\Theta} = A SC MSHGF CLF_{\Theta} \quad (2.3)$$

- *MSHGF* : Ganho Solar Instantâneo Máximo (*Maximum Solar Heat Gain Factor* (MSHGF)) - Representa o máximo fluxo instantâneo que é absorvido, por unidade de área, através do envidraçado de referência. É também neste caso, considerado o valor de referência [6] para vidro simples incolor;
- *SC* : Coeficiente de Sombreamento (*Shading Coefficient* (SC)) - É a razão entre o ganho solar instantâneo que entra por um determinado envidraçado e o que entra com o envidraçado de referência;
- *CLF* : Factor de Carga dos Ganhos Solares (*Cooling Load Factor* (CLF)) - traduz-se na parcela do ganho solar instantâneo que entra no espaço e que é convertida em carga térmica;

Todos os valores para os índices anteriormente mencionados, estão tabelados pela [6].

### 2.3.3 Conversão da Carga Térmica em Temperatura Interior

Alcançado o método para calcular todas as cargas térmicas presentes no volume de estudo, resta agora calcular a carga total para o espaço, somando todas as parcelas anteriormente descritas. Isto é feito para uma determinada hora do dia, permitindo

efetuar tantos cálculos quantas horas se pretenda obter a carga e temperatura desejada. Assim sendo, esta carga térmica total, designa-se por carga térmica de estudo. De notar ainda, que alguns valores tabelados não são os mais adequados ao tipo de construção a analisar, e por esse motivo, os valores de carga térmica estarão sobredimensionados nas horas de carga térmica elevada e subdimensionados nas restantes. Por forma a alcançar o objetivo final, de obter o valor da temperatura interior através de um modelo matemático, inicia-se a segunda fase deste método simplificado, e pretende-se transformar o perfil de cargas térmicas num perfil de temperaturas. Para que esta conversão seja feita, recorre-se a uma função de transferência. Esta equação [6] a usar 2.4 representa o equilíbrio entre a taxa de extração de calor (ER) e a carga térmica ( $\dot{Q}$ ) e por outro lado, a temperatura interior.

$$\sum_{i=1}^1 p_i (ER - \dot{Q}_{\Theta-i}) = \sum_{i=0}^2 g_{i,\Theta} (T_{interior} - T_{\Theta-i}) \quad (2.4)$$

Tendo em conta que o que se pretende estudar, é a temperatura interior do volume de estudo, a taxa de extração é nula, pelo que se pode simplificar a equação anterior, deixando de depender do valor da taxa de extração, e obtendo a seguinte equação 2.5:

$$g_{0,\Theta} * T_{\Theta} = T_{interior} * \sum_{i=0}^2 g_{i,\Theta} + \sum_{i=0}^1 p_i * \dot{Q}_{\Theta-i} - \sum_{i=1}^2 g_{i,\Theta} * T_{\Theta-i} \quad (2.5)$$

Tendo já todos os dados inseridos e obtidos na expressão, resta apenas obter a equação 2.6 em função da temperatura interior, que é na realidade, o objetivo deste desenvolvimento.

$$T_{\Theta} = \frac{I_{\Theta}}{g_{0,\Theta}} \quad (2.6)$$

Na equação 2.6, tem-se ainda de encontrar o valor para  $I_{\Theta}$ , que depende de várias componentes tabeladas, como se pode ver na equação 2.7.

$$I_{\Theta} = T_{interior} \sum_0^2 g_{i,\Theta} + p_0 \dot{Q}_{\Theta} + p_1 \dot{Q}_{\Theta-1} - g_{1,\Theta} T_{\Theta-1} - g_{2,\Theta} T_{\Theta-2} \quad (2.7)$$

Após a resolução das equações 2.7 e 2.6 conclui-se que se pode determinar a temperatura interior de um espaço, recorrendo a cinco diferentes coeficientes ( $g_0, g_1, g_2, p_0, p_1$ ), do valor da carga térmica na hora do cálculo e na hora anterior, e do valor da temperatura nas duas horas anteriores à hora do cálculo. Utiliza-se posteriormente, os dados de um dia completo, para o cálculo da temperatura interior.

De forma a concluir o estudo, resta apenas mencionar como obter os cinco coeficientes mencionados anteriormente, e que devem ser representativos do espaço que se pretende estudar. Neste caso, e como este estudo pretende apenas ser um modelo de referência em termos de comparação com outros, recorre-se novamente a valores tabelados 2.2, obtidos em espaços adiabáticos.

Tabela 2.2: Coeficientes da função de transferência normalizados

Inércia do Edifício	$g_0$ ( $W/m^2C$ )	$g_1$ ( $W/m^2C$ )	$g_2$ ( $W/m^2C$ )	$p_0$	$p_1$
Leve	9.54	-9.82	0.28	1.0	-0.82
Média	10.28	-10.73	0.45	1.0	-0.87
Pesada	10.50	-11.07	0.57	1.0	-0.93

Para finalmente implementar este método, resta assim aplicar as duas fases descritas passo a passo ao longo deste capítulo, e esta resolução depende basicamente da quantidade de dados disponíveis, em particular das medições de temperatura interior e exterior, para que se possa inicializar o método.

## 2.4 Inteligência Artificial

A maior base que se pode ter para se obter soluções inteligentes, de qualquer tipo que elas sejam, nos dias de hoje, parte sempre pela Inteligência Artificial.

Esta área de estudo tem vindo a ser desenvolvida cada vez mais e melhor, uma vez que esta é capaz de fazer com que uma máquina consiga reproduzir competências semelhantes às de um ser humano, tal como o raciocínio, a aprendizagem, o planeamento e a criatividade. A Inteligência Artificial permite que os sistemas técnicos percebam o ambiente que os rodeia, lidem com o que percebem e resolvam problemas, agindo no sentido de alcançar um determinado objetivo. O computador recebe dados, já preparados e muitas das vezes obtidos através dos seus próprios sensores, processa-os e responde. Estes sistemas são capazes de adaptar o seu comportamento através de uma análise dos efeitos das ações anteriores e de um trabalho autónomo. Essencialmente, a Inteligência Artificial, é um campo da ciência bastante abrangente, e os métodos que se seguem, são sub-campos deste. Nesse sentido, o *Machine Learning* é um sub-campo da Inteligência Artificial, e conseqüentemente, as Redes Neurais são um sub-campo do *Machine Learning* e por fim o *Deep Learning* é um sub-campo das Redes Neurais.

Partindo de um computador e entrando no campo da Inteligência Artificial, quando se pretende obter dados previsionais ou até encontrar formas de as máquinas realizarem tarefas idênticas às humanas, o caminho a percorrer passa por entrar no domínio do *Machine Learning* onde é crucial que se obtenha dados para aprender,

que resultam em previsões e por fim com os resultados, melhorar consecutivamente a sua *performance*.

Posto isto, de seguida explora-se um pouco mais estes conceitos referidos.

## 2.5 *Machine Learning*

Uma breve definição de *Machine Learning*, define-se como um ramo da Inteligência Artificial e ciência computacional que se foca no uso de dados e algoritmos para "imitar" a forma como os humanos pensam, melhorando a sua capacidade de acerto gradualmente. O *Machine Learning* é um componente importante na história do crescimento da ciência de dados, que através do uso de métodos estatísticos, os algoritmos são treinados para fazer classificações ou previsões, melhorando a sua eficácia, consoante vão armazenando dados e obtendo novos [31].

Este método, pode dividir-se em três partes:

- **Processo de decisão:** No geral, os algoritmos de *machine learning* são utilizados para realizar previsões ou classificações, baseados em alguns *inputs*, que podem ser rotulados ou não, e o algoritmo irá produzir uma estimativa à cerca do padrão encontrado nos dados;
- **Função de erro:** Uma função de erro serve para avaliar a previsão do modelo, isto é, se houverem exemplos conhecidos, uma função de erro pode fazer a comparação entre esses valores e os valores obtidos, para calcular a eficácia do modelo;
- **Processo de automatização do modelo:** Se o modelo puder ajustar-se melhor aos dados do conjunto de dados de treino, os pesos são ajustados para reduzir a discrepância entre os exemplos conhecidos e os exemplos estimados. O algoritmo irá repetir o processo de forma a avaliá-lo e melhorá-lo, atualizando os pesos autonomamente até um limite de eficácia ser encontrado.

O processo de *Machine Learning* é ainda dividido em três categorias principais, sendo:

- ***Machine Learning* Supervisionado:** Este conceito é definido pelo seu uso de *datasets* indentificados para treino de algoritmos que classificam dados ou previsões de *outputs* mais precisos. Um dado de *input* é o "alimento" para o modelo, que ajusta os seus pesos até o modelo estar ajustado corretamente. Isto ocorre como parte da validação cruzada para assegurar que o modelo evita sobredimensionamento ou subdimensionamento. Este método ajuda as organizações a resolver problemas do dia a dia, como por exemplo, classificação de *spam* em caixas de correio separadas. Alguns dos métodos utilizados

neste tipo de processo, são as Redes Neurais, Regressão Linear, Regressão Logística entre outros [32];

- ***Machine Learning Não Supervisionado***: Neste caso, este modelo é utilizado para analisar *datasets* não identificados. Estes algoritmos descobrem padrões escondidos ou grupos de dados sem necessitar de intervenção humana. A sua capacidade para descobrir similiaridades e diferenças na informação, faz com que este método seja ideal para explorar a análise de dados e estratégias de venda cruzada, por exemplo. Outro tipo de algoritmos utilizados neste tipo de análise, também são as Redes Neurais e Métodos de Probabilidades;
- ***Learning Semi-Supervisionado***: Este método, é algo entre os dois últimos referidos, uma vez que ele durante o treino utiliza uma pequena fração de dados identificados para guiar a classificação e a extração de dados, para um maior *dataset* de dados não identificados. Assim sendo, este processo pode resolver problemas em que não há dados identificados suficientes.

Algumas das interações possíveis desta ferramenta, são dentre de muitas outras a sua conexão com o meio académico, o meio audiovisual, a área da saúde e até a área dos videojogos. As suas interações são infinitas e as mais variadas possíveis, sendo uma ferramenta bastante abrangente em todas as áreas do conhecimento.

## 2.6 *Internet of Things*

O conceito de *IOT*, se traduzido literalmente, é chamado de Internet das Coisas o que no entanto, não está assim tão errado. Isto, porque na verdade, este conceito significa que todas as coisas têm acesso à internet, ou seja, todos os dispositivos que temos à nossa volta, devem ter acesso à internet. Não significa, por exemplo, que um computador que tem acesso à internet, sejam um dispositivo *IOT*, mas noutro caso, por exemplo, as câmeras de segurança, que necessitam desta *online* permanentemente de forma a que os seus dados estejam sempre disponíveis para os seus utilizadores. Além deste exemplo, existem muitos outros ao nosso redor, e muitas das vezes, mais até do que possamos imaginar, tais como uma simples balança de cozinha ou uma máquina de café, até ao mais complexa aeronave ou um automóvel.

Este conceito, não é válido apenas para entretenimento ou para aceder a conteúdos, mas sim para ajudar as pessoas no seu dia a dia, ou até para facilitar em algumas tarefas diárias, quer sejam a nível pessoal ou até a nível industrial ou de segurança. Cada vez mais, a Internet das Coisas está presente no nosso dia a dia, e muitas vezes sem notarmos a sua presença, e isto acontece cada vez mais e é válido para escritórios, hospitais, fábricas, entre outros. Alguns desses exemplos são:

- *Hospitais e Clínicas:* Neste caso, os pacientes já utilizam dispositivos *IOT* que monitorizam os batimentos cardíacos ou pressão sanguínea, e os dados recolhidos são enviados em tempo real para o sistema que controla os exames;
- *Agropecuária:* Existem já muitos sensores deste tipo, espalhados pelas plantações e enviam dados relevantes de temperatura, humidade do solo, probabilidade de chuvas, velocidade do vento, entre outras e fazem com que se aumente o rendimento deste tipo de atividade. Além destes, também já os animais possuem dispositivos deste tipo, para que se possa, por exemplo, localizar um animal;
- *Fábricas:* Nas fábricas este tipo de tecnologia facilita o trabalho dos operários e gestores, uma vez que podemos obter dados fornecidos em tempo real sobre a produtividade das máquinas, o seu histórico de manutenção, entre outro tipo de informações relevantes à atividade em causa.

Além destes setores supramencionados, existem muitos outros, e na maior parte deles, presentes no nosso dia a dia, que facilitam em muito as produtividades, evitam gastos e muitas vezes previnem doenças ou acidentes.

Para sustentar este tipo de aplicações *IoT* é necessário que por trás de toda esta tecnologia, exista um trabalho sustentável e organizado. Desta forma, podem ver-se na figura 2.5 as camadas que constituem a arquitetura da tecnologia *iot* [29].

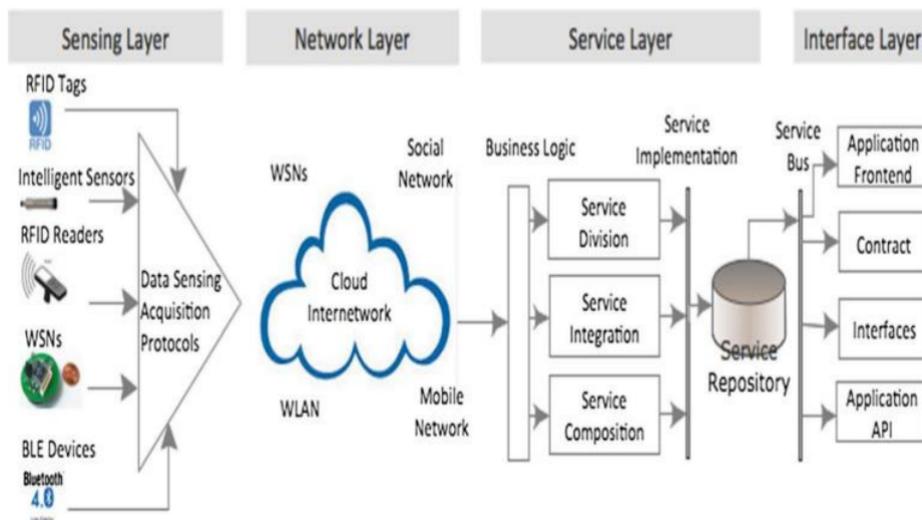


Figura 2.5: Arquitetura das camadas do *IoT* [29].

A divisão das camadas é dividida entre:

- Camada dos Sensores - Onde se encontram todo o tipo de sensores disponíveis para o efeito;

- Camada de *Network* - Onde se encontram as tecnologias possíveis de ser utilizadas para comunicação com a *internet*;
- Camada de Serviço - Onde acontece toda a integração dos dados registados pelos sensores e que chegam via *internet*;
- Camada de Interface - Onde finalmente existe a comunicação com o dispositivo de visualização dos dados.

## 2.7 Machine Learning através de IoT

Nos dias de hoje, é impossível pensar numa solução inteligente, que não aja cada vez mais da forma mais autónoma possível. Nesse sentido, a tecnologia mais avançada que podemos dispor neste momento no sentido de melhorar substancialmente o controlo humano e cada vez mais automatizarmos as nossas soluções, é através de *Machine Learning*. Tal como [14] menciona, a era dos pequenos dispositivos "*always on*", chegou. Com estes pequenos dispositivos, queremos dizer dispositivos *IoT* implementados também com a tecnologia de *Machine Learning*. Esta evolução, permite que existam poupanças ao nível de tempo e energia, assim como melhorias em termos de conforto e disponibilidade.

A melhor forma de implementar todas estas tecnologias numa só, e de modo a que se adapte ao nosso estudo, [14] descreve o MCUNet como um *framework* sistema modelo que permite através de *ImageNet* uma profunda aprendizagem em microcontroladores. Para otimizar este processo e para ter melhores resultados em termos de memória, é também implementado um modelo *TinyNAS* em conjunto com um modelo de *TinyEngine*. Este modelo *TinyNAS* consiste no método *Neural Architecture Search* (NAS) em duas fases, que permite gerir as restrições da pequena memória em vários microcontroladores.

De um modo geral, este sistema *MCUNet*, permite que seja feita uma busca mais aprofundada das imagens, uma vez que a memória dos microcontroladores é liberta através do *TinyEngine*, como mostra a figura 2.6.

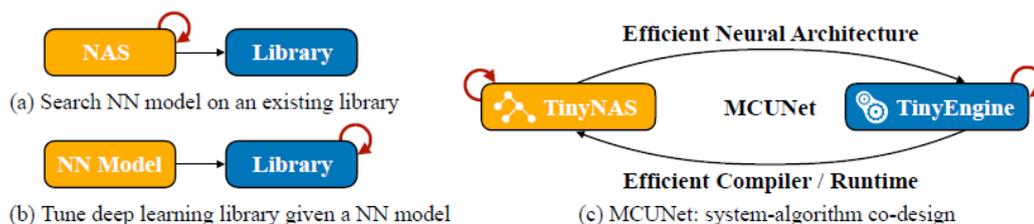


Figura 2.6: Esquema do modelo MCUNet [14]

Este modelo permite recorrer a *frameworks* já existentes, tais como *TensorFlow Lite Micro* ou *MicroTVM*, mas como estas possuem algumas limitações quanto ao seu

consumo de memória, é nesta situação que entra a importância do *design* eficiente da rede neuronal, que permite remover redundâncias e reduzir a complexidade da operação.

## 2.8 Controlo Térmico através de *Machine Learning*

Baseado na melhoria ativa do conforto de espaços interiores, onde a Agência da Proteção Ambiental [15] afirma que se passa 90% do nosso tempo e nesse sentido é essencial que se proporcione melhorias no ambiente interior dos edifícios. Vários estudos têm vindo a ser feitos por vários especialistas na matéria, desde melhorias em janelas a trocas de materiais de construção, mas neste caso em concreto [16], é estudada uma melhor ventilação e sistema de ar condicionado, aplicando um *retrofit*, com a ajuda de *Dynamic Thermal Simulation* (DTS) em conjunto com o *software* TRNSYS, por forma a comparar a *performance* de três sistemas diferentes.

A principal diferença encontrada entre estes métodos está entre a *performance* prevista, obtida computacionalmente, e a *performance* efetivamente medida nos edifícios. Após vários estudos e comparações entre casos anteriormente estudados, [17] concluíram que a radiação solar e a potência de aquecimento são os dados de entrada que mais influenciam os modelos de comportamento térmico. Desta forma, e para garantir uma temperatura ótima de arranque, é nesta fase que entra a ANN preditiva, com o objetivo de manter um controlo térmico interior. Esta fase de estudo, é crucial para o desenvolvimento da solução inteligente para modelação térmica de edifícios, uma vez que foi notada um grande desenvolvimento na previsão deste conforto, com recurso a um modelo de múltipla regressão linear aplicado num *smart space* recorrendo ao *IoT*, sendo nesta fase que se centra neste momento o estudo da solução inteligente.

O estudo foi dividido em três níveis, *Data Level*, *Core Platform Level* e *Config Level*, como mostra a figura 2.7.

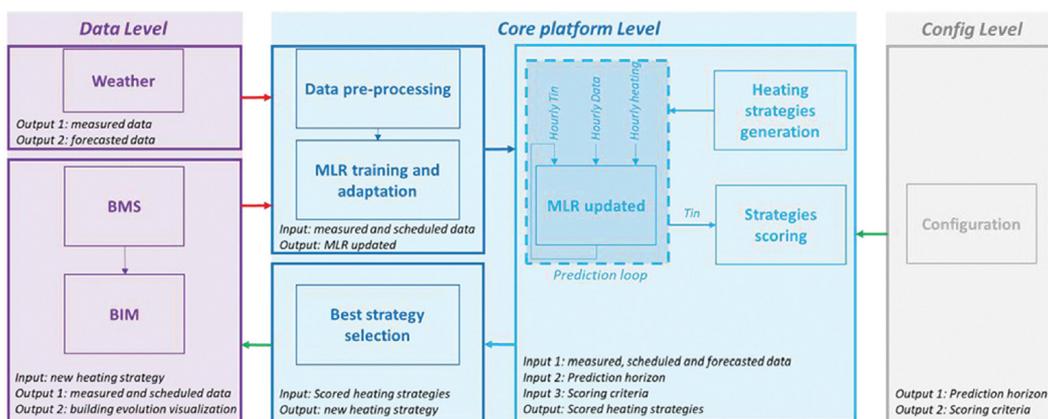


Figura 2.7: Esquema da plataforma proposta [16]

Analisando o diagrama apresentado, tem-se as seguintes fases:

- **Fase de Dados** - Recolha de dados e pré processamento dos dados medidos, tais como humidade relativa e os dados meteorológicos;
- **Fase de Configuração** - Definição das preferências do utilizador;
- **Fase da plataforma principal** - Teste do modelo de previsão com os dados recolhidos inseridos.

## 2.9 Redes Neurais

Uma das formas de efetuar a modelação térmica de um edifício, passa pela previsão da sua temperatura interior. Como se sabe, a temperatura é uma das formas de comprovar as alterações no interior de um edifício, no entanto, é uma variável complexa e não linear e como tal a sua previsão pode tornar-se uma tarefa difícil. O recurso a redes neuronais permite facilitar os problemas não lineares complexos. A sua vantagem comparada com métodos estatísticos está no facto de as redes neuronais não se basearem em suposições, o que por vezes poderia trazer alguma confusão e margens de erro maiores. As redes neuronais permitem exibir informação de processamento de forma bastante rápida e tempos de treino mais reduzidos, revelando-se assim um método bastante eficaz e vantajoso. Além disso, é uma ferramenta de natureza adaptativa, desenvolvendo um mapeamento dos *inputs* e *outputs*, baseando-se nos dados obtidos. Existem vários tipos de Redes Neurais, como mostra a figura 2.10.

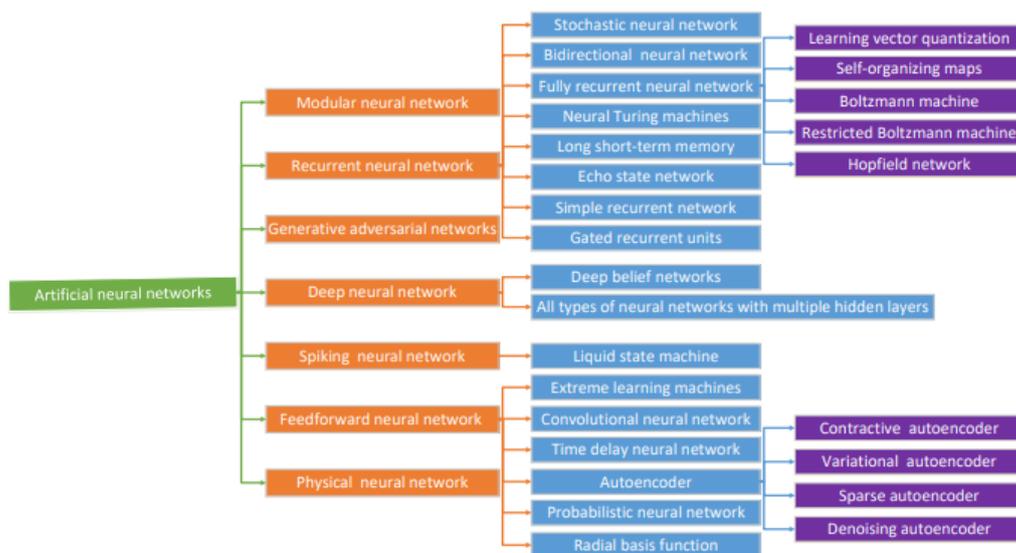


Figura 2.8: Descrição dos vários tipos de Redes Neurais Artificiais [33]

No entanto, para o fim a que se destina esta solução, recorre-se a Redes Neurais Artificiais (*ANN*) e dentro destas, as Redes Neurais Recorrentes (*Recurrent Neural Network (RNN)*), que têm a particularidade de poder reutilizar as suas próprias previsões de forma a melhorar constantemente os seus *outputs* [33].

Uma *ANN* consiste num elevado número de elementos de processamento interconectados, chamados neurónios, que trabalham em conjunto para resolver um problema específico. Estas redes neuronais, trabalham como o cérebro humano, em que recebem *inputs*, processam essa informação e dão origem a um determinado *output*. Em todo o processo, elas funcionam exatamente como o cérebro humano, onde o conhecimento é alcançado pela rede através do processo de aprendizagem e a força de conexão dos interneurónios é utilizada para armazenar o conhecimento. Assim sendo, estas redes neuronais são bastante úteis na medida em que são um modelo computacional capaz de aprender, generalizar e armazenar dados, e nesse sentido é uma ferramenta poderosa que auxilia na resolução de problemas complexos.

Na figura 2.9 podemos observar a constituição de uma rede neuronal artificial, que é constituída por três componentes básicos, dos quais o seu conjunto de pesos sinápticos (*Synaptic Weights*), a junção das somas (*Summing Junction*) com a componente de *Bias*, que é responsável por adicionar o seu valor ao da função de junção das somas, por forma a melhorar o resultado final, e por fim a função de ativação (*Activation Function*). Além dos componentes inseridos na sua conjuntura, podem ver-se também os sinais de entrada (*inputs*) e o respetivo resultado (*output*).

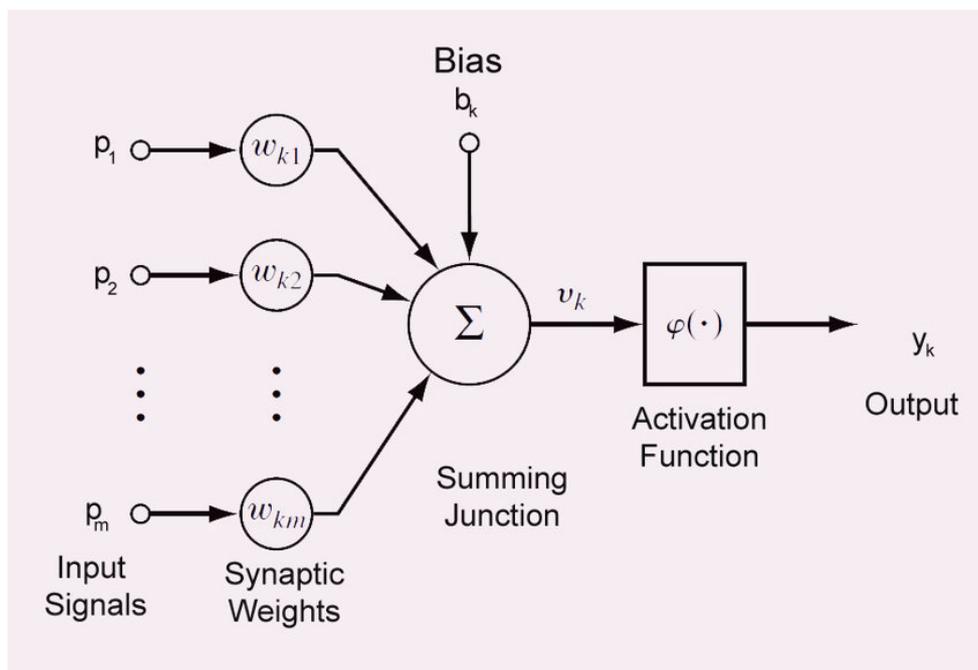


Figura 2.9: Esquema de um modelo não linear de um neurónio *ANN* [27]

Em termos de equações matemáticas, temos o seguinte:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.8)$$

$$v_k = u_k + b_k \quad (2.9)$$

$$y_k = \phi(v_k) \quad (2.10)$$

- $w_{kj}$  - peso sináptico do neurónio;
- $x_j$  - sinal de entrada (*input*);
- $u_k$  - sinal de saída resultante dos sinais de entrada;
- $v_k$  - potencial de ativação do neurónio;
- $b_k$  - constante adicionada à função (*bias*);
- $\phi$  - função de ativação;
- $y_k$  - sinal de saída;

Posto isto, o *output* de uma *ANN* é obtido aplicando a função de ativação no potencial de ativação do neurónio. A função de ativação é a responsável por comprimir a amplitude de saída de um neurónio dentro de um intervalo permitido. Quando um neurónio se conecta com outros neurónios, eles formam uma rede neuronal de simples ou multicamada. Uma *ANN* multicamada, consiste em três camadas: a camada de entrada, a camada de saída e a camada escondida ou invisível. Esta camada invisível é responsável por ser o interveniente entre os dados de entrada e os resultados de saída. O treino da rede neuronal é feito através dos *inputs* e os correspondentes *targets*, fazendo com que a rede aprenda a relacionar um *input* com um *output*. A rede é treinada até que as mudanças nos pesos sinápticos atinjam um valor mínimo, seguindo-se os testes à *ANN* para verificação da eficácia dos *outputs*.

### 2.9.1 Redes Neurais Recorrentes (*RNN*)

Com recurso ao *deep learning*, uma rede neuronal recorrente é utilizada para previsões num espaço temporal, reconhecimentos de voz, entre outros. Contrariamente às redes neuronais tradicionais, estas recorrem à sua memória, também chamado de estados, para prever uma série de *outputs*. Resumindo, é uma rede utilizada para prever acontecimentos futuros, baseado em acontecimentos passados. Abaixo, na figura 2.10, pode ver-se a diferença desta arquitetura, comparando com a Redes Neurais simples [25].

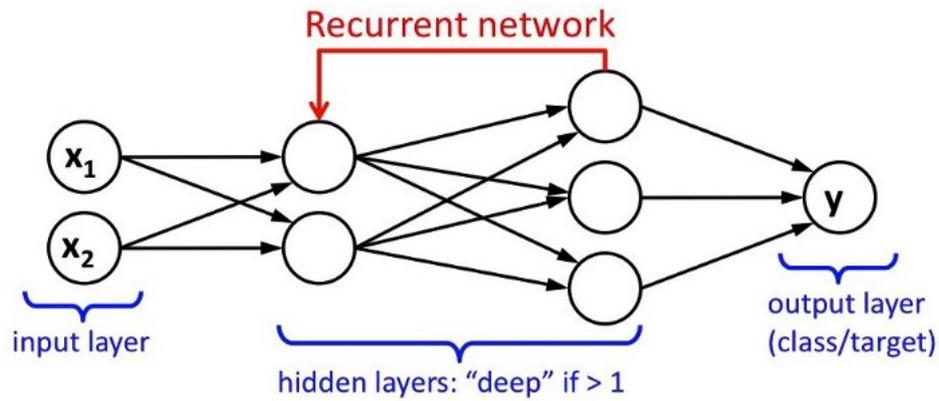


Figura 2.10: Arquitetura de uma Rede Neural Recorrente [25]

No caso, é exatamente o que se procura, visto que os acontecimentos passados são conhecidos e registados em *datasets*, e o que irá acontecer futuramente, é precisamente o que se pretende obter antecipadamente. Neste estudo, o recurso a esta ferramenta, será feito através da linguagem de programação *python*, onde se pretende a obtenção de uma solução que recorra aos *datasets* e que filtrada pela rede neuronal, disponha uma série de *outputs* futuros, com base nos *inputs* passados.

## Capítulo 3

# Implementação

*Nesta secção é abordada a forma como se vai enfrentar o problema inicialmente proposto. Tendo em conta o tema já anteriormente estudado por outros estudiosos na matéria, tem-se por base alguns métodos e conceitos que se podem adaptar e adoptar e por fim chegar a um melhoramento do que já está estudado até agora, e finalmente alcançar uma solução capaz de efetuar a modelação térmica de edifícios sem conhecer os seus materiais de construção.*

*A ideia desta dissertação, passa por aplicar modelos matemáticos, que simulam os efeitos dinâmicos da transferência de energia em edifícios, partindo assim do princípio da equação integral do balanço de energia. Não obstante desta equação fundamental, que nos leva a compreender as trocas de energia existentes, é essencial englobar esta equação e toda a solução, num método já mencionado no capítulo anterior, bastante utilizado para a modelação térmica de edifícios, neste caso, por ser o mais adequado, o modelo Grey-Box, que engloba tanto o modelo White-Box, que tem em conta os volumes estudados, mas também o modelo Black-Box que se baseia em métodos estatísticos e em machine learning, que aliados à tecnologia IoT constroem assim a solução final.*

### 3.1 Arquitetura da Solução

A solução que se pretende desenvolver, irá permitir modelar termicamente um edifício sem conhecer os seus materiais de construção. Como tal, um dos pilares deste sistema, será a previsão da temperatura interior de um determinado local de estudo. Para esse efeito, é necessário conhecer as temperaturas exteriores, de modo a que se possa ter uma comparação com outros locais de estudo, quando inseridos noutra localização, assim como é necessário implementar sensores que obtenham a temperatura interior do volume de estudo, para que também dessa forma se consiga comparar os valores obtidos através do estudo com os valores reais.

Além dos *inputs* mencionados, de forma a obter determinados valores previstos, recorre-se a ferramentas do campo de aplicação do *Machine Learning* e também a modelos matemáticos, sempre cruciais em qualquer tipo de estudo.

Assim sendo, os valores de temperatura exterior são obtidos através de *datasets* gerados por uma entidade independente que efetua previsões meteorológicas e os valores de temperatura interior são obtidos diretamente do *smartphone* através de uma aplicação que controla os sensores de temperatura e humidade.

Neste sentido, como arquitetura geral da solução, temos a estrutura apresentada na figura seguinte 3.1:

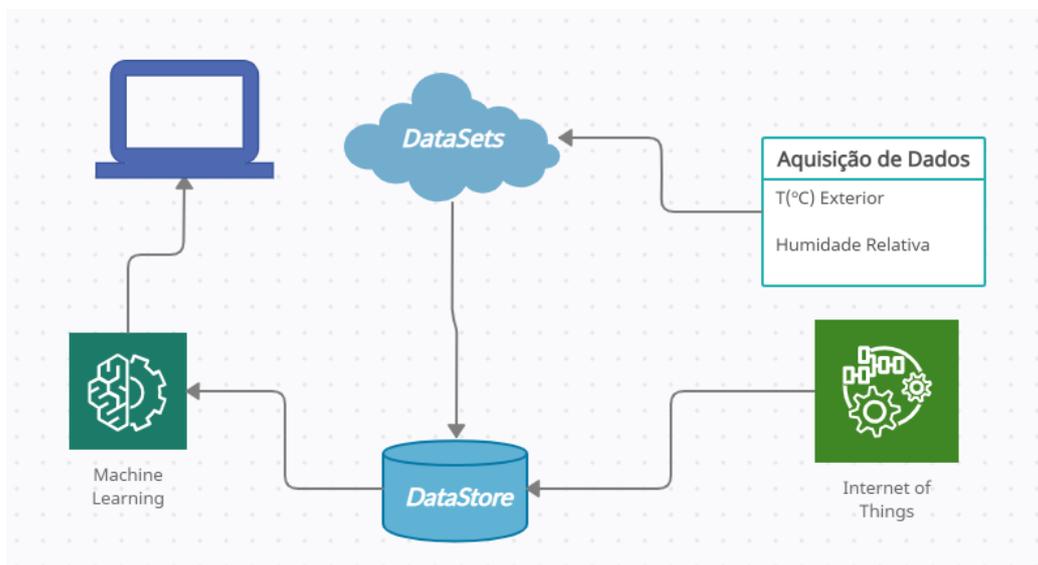


Figura 3.1: Arquitetura da Solução

Analisando a estrutura da solução, e iniciando da direita para a esquerda, podemos observar dois pontos iniciais, sendo o *Internet of Things*, que representa os dados obtidos através dos sensores ligados à internet e que disponibilizam dados de temperatura interna em tempo real. Já a aquisição de dados, presente no quadro no canto superior direito, representa os dados obtidos através de *datasets* já existentes, com dados de temperatura exterior e humidade relativa, da localização do volume

de estudo. Os dados de *IoT* e os valores dos *datasets* são armazenados, daí a importância do *datastore*, que após este armazenamento, fornece os dados à aplicação de *Machine Learning*, de forma a que esses dados sejam utilizados para treinar a solução, e no final apresentar os resultados.

## 3.2 Sensores *IoT*

Os sensores *IoT*, são como já referido, higrómetros e portanto obtém-se através dos mesmos, dados relativos a temperatura e humidade relativa de espaços interiores. Estes dispositivos, apresentados na figura 3.2, são do fabricante *Xiaomi*, e são a versão *Sensor Mi Temperature and Humidity Monitor 2*, sendo alimentados por meio de uma pilha.



Figura 3.2: Sensor de Temperatura e Humidade *Xiaomi*

Possuem ligação *Bluetooth 4.2* e um alcance de 10 metros com o dispositivo móvel que se pretende obter os dados. Estes componentes não estão 24h por dia ligados à internet, mas estão 24h por dia a registar dados, e através da ligação ao *smartphone* disponibilizam todos os dados registados, por dia e por hora.

Estes sensores revelam-se bastante eficazes e precisos, na medida em que na fase de testes destes sensores foram testados vários cenários, como abertura de janelas, presença de pessoas no local ou até mesmo equipamentos eletrónicos ligados, e em todos eles verificou-se uma alteração de temperatura e humidade quase instantâneas. Na figura 3.3 pode ver-se a vista geral da aplicação *Mi Home*, que pode ser obtida diretamente da loja de aplicações de qualquer dispositivo móvel *Android* ou *iOS*, e ainda de que forma são visualizados os dados obtidos. Ao clicar na *tab "History"* é possível ainda visualizar os dados desde que o sensor se encontra ligado.



Figura 3.3: Vista geral da aplicação *Mi Home*

A extração dos dados poderia ser uma tarefa mais simplificada e instantânea quando a sua utilização é do tipo científico ou de estudos, uma vez que todos os dados retirados da aplicação tiveram de ser registados em *excel* um a um e posteriormente criadas as tabelas e gráficos correspondentes.

### 3.3 Dataset

O objetivo deste trabalho é modelar termicamente um edifício onde se recorre à previsão de temperaturas do objeto, sem que se conheça os seus materiais de construção. Nesse sentido, é necessário conhecer as temperaturas exteriores ao edifício para que se possam adaptar os parâmetros do modelo matemático em qualquer zona que esta solução seja utilizada.

Para que esta solução seja possível e faça sentido, é necessário que se tenham dados relevantes para a solução final e que auxiliem a que o modelo alcance uma série de resultados considerados fiáveis e úteis para a sua aplicação. Como este modelo se baseia em dados existentes, para que possa também ele fornecer dados coerentes, é necessário recorrer a uma série de outros dados, neste caso de temperatura, para que a solução possa ser treinada tantas vezes quanto necessário, até que se aproxime do histórico dos dados que se lhe fornece. Como no caso dos humanos, quanto mais informação tivermos à nossa disposição, maior é a nossa taxa de acerto e

assertividade quando abordamos determinados assuntos. No caso desta solução, que também ela é baseada em *Machine Learning* com recurso a Redes Neurais e como já sabemos até aqui, este método baseia-se na maneira de agir de um cérebro humano, o que faz com que quanto maior a quantidade de informação disponibilizada, maior será o seu acerto. No caso dos humanos, aprendemos através da leitura, da audição ou da visualização de algum experimento, mas no caso desta solução inteligente, ela aprende através de *datasets*, que são nada mais nada menos, que a forma de estudo deste modelo.

O conjunto de dados obtidos através da *MeteoBlue* é composto por 30 amostras, divididas em duas classes, Temperatura Mínima e Temperatura Máxima, correspondentes cada uma delas a um dia como mostra na tabela 3.1.

Tabela 3.1: *Dataset* obtido através da *MeteoBlue*.

<b>Dia</b>	<b>Temperatura Mínima [°C]</b>	<b>Temperatura Máxima [°C]</b>
03 de setembro	14.2	23.9
04 de setembro	17.2	24.7
05 de setembro	18.4	21.9
06 de setembro	15.8	21.1
07 de setembro	16.4	19.8
08 de setembro	16.0	20.2
09 de setembro	15.9	22.0
10 de setembro	16.2	24.0
11 de setembro	16.9	24.1
12 de setembro	19.7	25.3
13 de setembro	18.0	20.6
14 de setembro	17.7	20.8
15 de setembro	18.3	24.3
16 de setembro	16.6	23.9
17 de setembro	17.9	29.9

Estes dados demonstram qual a gama de temperaturas a que o local de estudo está sujeito durante este conjunto de dias, e permite que se tenha uma noção do enquadramento a nível de carga térmica a que o volume de estudo é exposto e qual a influência que esta terá nos resultados finais.

Este *dataset* é utilizado para obter um conjunto de parâmetros essenciais para a integração do modelo matemático na solução, tais como valores de coeficiente ou de exposição solar. Além disso, estes dados podem ser ainda utilizados no mesmo modelo matemático, caso se pretendam prever temperaturas interiores nos dias seguintes, ao contrário do que é feito neste caso, nas horas seguintes.

### 3.4 *Machine Learning*

A tecnologia de *Machine Learning* tem vindo cada vez mais a ter uma preponderância maior nos nossos dias a todos os níveis. Um passo crucial deste trabalho, é o recurso a esta tecnologia, e que antes da programação do modelo em si, importa ter noção dos passos a adotar na implementação de um processo de *Machine Learning*. Os seguintes passos tencionam demonstrar o *workflow* base desta solução:

- Determinar a questão a resolver e determinar os dados necessários;
- Recolher todos os dados;
- Identificar e corrigir as anomalias ou os dados em falta;
- Preparar os dados de forma a que possam ser utilizados em *Machine Learning*, retirando informações irrelevantes;
- Estabelecer o modelo base de *Machine Learning*, neste caso Redes Neurais;
- Treinar o modelo com os dados adequados para esse efeito;
- Realizar previsões com os dados de teste;
- Comparar as previsões com os valores reais e calcular métricas de *performance*;
- Se a *performance* não for satisfatória, ajustar o modelo, recolher mais dados ou tentar uma tecnologia diferente;
- Interpretar o modelo e reportar os resultados visualmente e numericamente.

Esta tecnologia pode ser utilizada com recurso a vários tipos de modelos base, e pode não só ser usada para efetuar previsões, não só de temperatura, mas por exemplo de vida útil de uma máquina, e existem inúmeros modelos que podem ser utilizados para o efeito. Os mais comuns neste tipo de previsão, são os modelos com recurso a Redes Neurais, mas existem outros, como é o caso de [2] que recorreu ao método de simulação CFD, que é nada mais nada menos que uma simulação numérica de todos os processos físicos que apresentam escoamento, para prever também um modelo térmico e *performance* de energia.

Além destes, existem também modelos estatísticos e modelos numéricos como refere [3]. Neste caso é feito um *overview* com base num modelo em ANN, de três camadas FFMLP, em que a figura 3.4 demonstra a sua estrutura de uma forma geral, e descrevendo os pontos cruciais deste tipo de Rede Neuronal, de forma a que se entenda quais os estágios pelo qual é necessário passar para se atingir um resultado fiável.

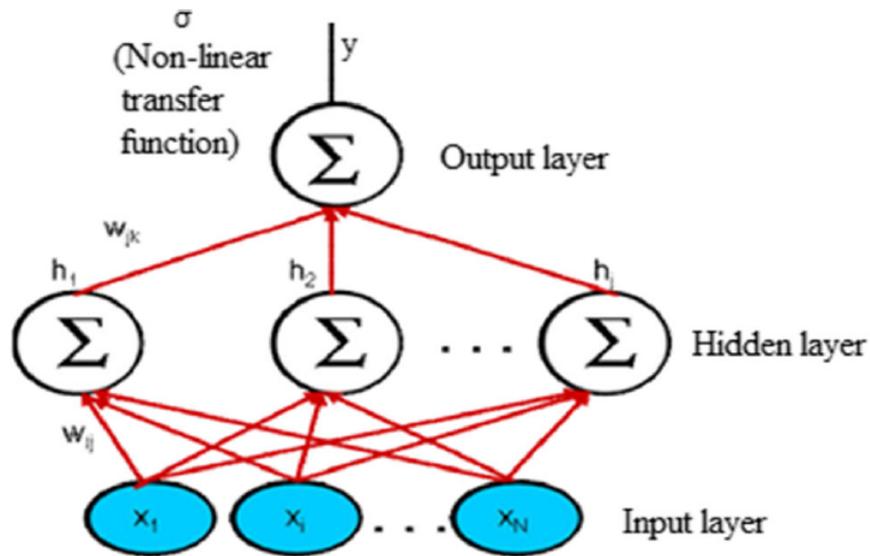


Figura 3.4: Estrutura da FFMLP de três camadas [3].

É referido ainda que a complexidade de cada Rede Neuronal é definida pelo número de camadas, número de neurónios em cada camada e os pesos de intercomunicação, como também já havia sido referido anteriormente. Além disso, a sua *performance* depende também do número de parâmetros de *inputs*, número de amostras e do número de neurónios escondidos em cada uma das camadas. Assim sendo, as Redes Neurais podem ser diversas e de diversas complexidades, no entanto quando se trata de prever temperaturas para as horas seguintes, pode-se reduzir a complexidade das mesmas.

Pode comparar-se com um modelo idêntico ao elaborado neste trabalho, elaborado para um pocilga [4], onde vista geral deste modelo, é demonstrada na figura 3.5.

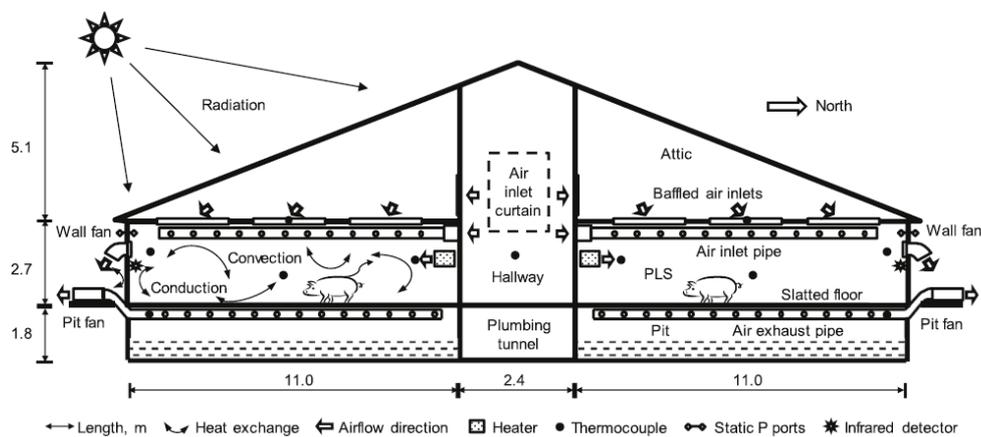


Figura 3.5: Vista geral do volume de estudo de [4]

Como se vê na imagem, existem variados componentes a interagir dentro do volume de estudo, todos eles são responsáveis por uma determinada energia, pelo que o objetivo inicialmente passa por determinar o balanço de energia presente neste volume. Além disso, tal como no caso deste trabalho, o primeiro passo é determinar os dados a serem utilizados, tanto os valores interiores de temperatura e valores de atividade realizada no volume de estudo, como os dados de meteorologia exteriores. À semelhança desta dissertação, também esses dados são organizados e tratados de forma numérica e visual, para que sejam passíveis de ser utilizados no modelo de *Machine Learning*.

O autor [4] recorre também ao método de Redes Neurais e ao simulador *Simulink*, para efetuar as previsões de temperatura do ar interior e simular as variações de energia térmica dentro do volume de estudo. Comparando com o estudo desta dissertação, são em tudo semelhantes com a exceção das simulações da variação da energia térmica, uma vez que dentro do volume de estudo não existiu atividade durante o registo dos dados, não havendo assim variações de energia, com exceção da energia adquirida pela radiação solar e condução, tal como já referido.

Em termos de resultados, os valores apresentados para a previsão de temperatura para a pocilga foram bastante satisfatórios, uma vez que se aproximaram bastante dos valores inicialmente registados pelos sensores presentes dentro do volume de estudo. Mais adiante neste estudo, faz-se a comparação destes resultados com os obtidos para este dissertação.

### 3.5 Caso de Estudo

Para o presente estudo, onde se pretende desenvolver uma solução inteligente para a modelação térmica de edifícios, é necessário, como em qualquer estudo, ter por base um objeto ou local de estudo.

Nesse sentido, para o caso de estudo desta dissertação, tem-se uma divisão de uma habitação unifamiliar. A localização do objeto de estudo é na zona de Olivais, Vila Nova de Gaia, norte de Portugal e de coordenadas 41.03988642324483, -8.542566630678431. A orientação solar do local, é sul e será relevante para o estudo, na medida em que os valores de coeficiente solar e radiação incidente no exterior do edifício tem de ser determinada, para que sejam englobados nas equações matemáticas. Como a exposição solar é bastante superior a um edifício orientado a norte, verifica-se que os valores de carga térmica são bastante diferentes, uma vez que os ganhos solares são superiores e a carga térmica absorvida pelas paredes e cobertura do edifício também o será. Apesar de apenas a cobertura e a parede que possui a janela inserida, serem as únicas que estão em contacto com o exterior, é nesse sentido que é feito o estudo.

Na figura 3.6 pode ver-se a planta da habitação onde está inserido o volume de estudo. Colorido a encarnado, encontra-se o volume de estudo, rodeado a cinza por outras divisões não contabilizadas para o estudo, mas que se considera sofrerem as mesmas alterações de temperatura que o volume de estudo, e colorido a verde, representa-se o exterior.



Figura 3.6: Planta da habitação onde se encontra inserido o volume de estudo.

O objeto de estudo, em termos dimensionais é uma divisão com 6 metros de largura por 10 metros de comprimento e 2,5 metros de altura. É composto por uma janela para o exterior, de  $5 m^2$  de área, com exposição solar durante as horas de sol do dia em questão, sensivelmente de 14 horas, considerando que existe sol neste altura desde as 6 horas da manhã até aproximadamente às 20 horas da noite, e tem também contacto direto com a cobertura da habitação, composto por placas de fibrocimento brancas. Em relação às restantes paredes, não estão em contacto com o exterior, mas sim com outras divisões da habitação, o que se revela importante, uma vez que não se consideram ganhos através destas paredes, tendo em conta que normalmente as outras divisões se encontram aproximadamente à mesma temperatura que esta, visto este local de estudo se inserir dentro de um apartamento, apenas com uma frente. A porta de entrada para este local, também está inserida dentro da habitação. Nas figuras 3.7 3.8 3.9 pode-se observar a constituição do local de estudo e além disso, circundados a vermelho e apontados por meio de uma seta, pode ver-se onde estão localizados os sensores *IoT* utilizados para efeitos de medição de temperatura interior e humidade relativa.

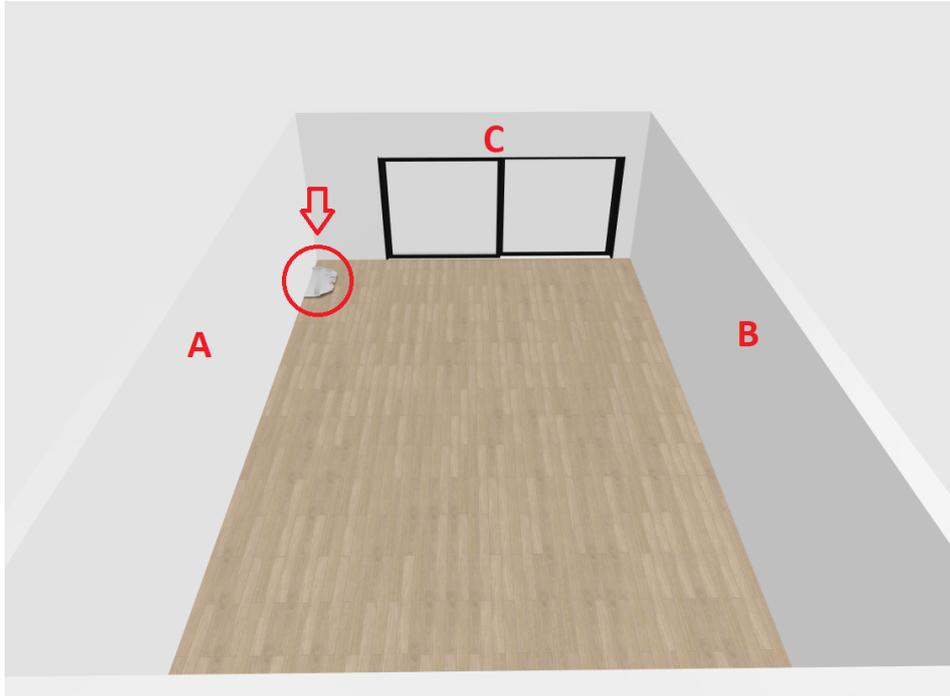


Figura 3.7: Vista Interior da Habitação

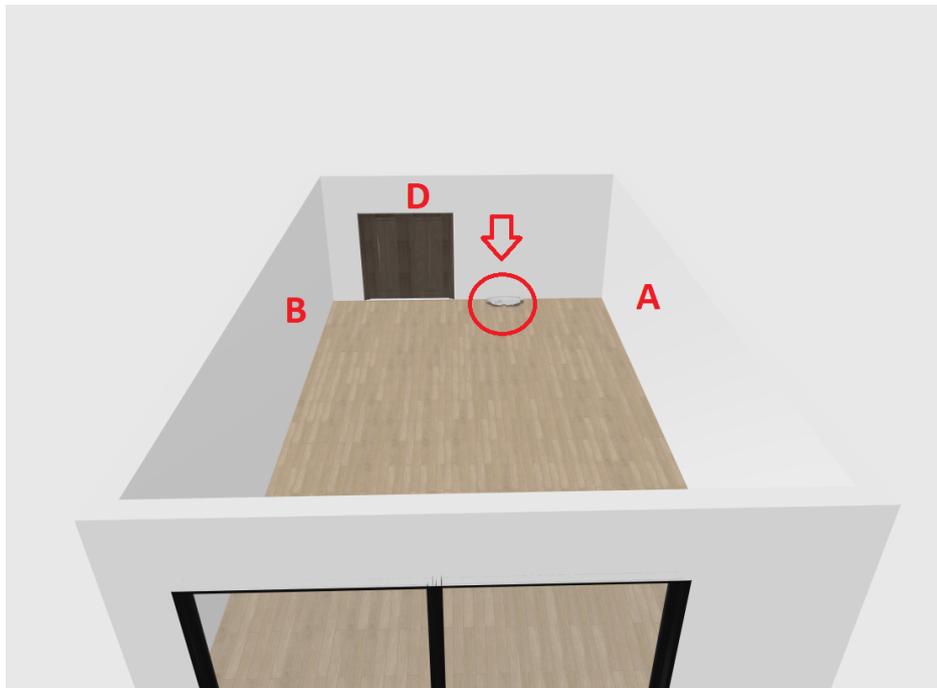


Figura 3.8: Vista Interior da Habitação

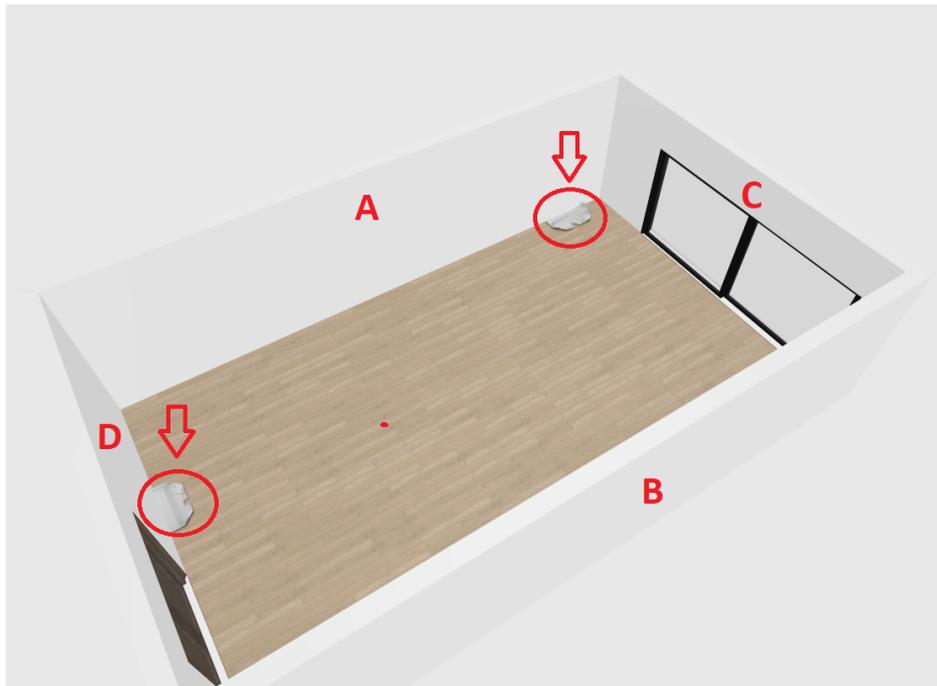


Figura 3.9: Vista Geral do Interior da Habitação

Os sensores foram colocados propositadamente em cada um dos extremos do volume de estudo, uma vez que a intenção será obter a modelação térmica deste local, o que se traduz no conhecimento das temperaturas no seu interior. Pode assim, considerar-se a média dos valores obtidos pelos sensores, a temperatura no centro do local de estudo, uma vez que eles se encontram exatamente à mesma distância do centro. Existem dados registados desde junho de 2022, e podem ser vistos em qualquer faixa horária dos dias em questão.

Como assinalado nas imagens, passa-se a designar os componentes da divisão pelo seguinte:

- Parede virada a sul em contacto com o exterior - Parede C
- Parede em contacto com outra divisão - Parede A
- Parede em contacto com outra divisão - Parede B
- Parede em contacto com outra divisão que contém a porta de entrada - Parede D

As dimensões do volume de estudo foram encontradas através da medição dos seus componentes estruturais, quer em comprimento como em altura. O piso é composto por cerâmica, a janela que dá acesso ao exterior é de vidro duplo e de caixilharia em alumínio, e a porta que dá acesso às outras divisões é composta por vidro simples e madeira. Estes dados relativos aos materiais de construção são irrelevantes neste

caso, mas podem ser importantes no caso de se analisar a influência dos mesmos na variação da temperatura e nesse caso teriam de ser conhecidos também os materiais de construção dos elementos estruturais da habitação.

Na tabela 3.2 apresentada de seguida, pode visualizar-se as dimensões dos elementos construtivos consituíntes da divisão da habitação.

Tabela 3.2: Medidas dos elementos construtivos da divisão em estudo.

Elemento Construtivo	Comprimento [m]	Altura [m]	Área Total [ $m^2$ ]
Parede A	8	2.5	25
Parede B	8	2.5	25
Parede C	6	2.5	15
Parede D	6	2.5	15
Janela	2.5	2	5
Porta	1.5	2	3
Cobertura	8	6	48

A divisão e os elementos apresentados, constituem assim o caso de estudo. Considerando que apenas na parede C e no telhado incide radiação solar, os *inputs* desta solução são a radiação solar e temperatura exterior, uma vez que são eles os principais fatores responsáveis pelos processos de transferência de calor no interior da divisão.

Além das informações sobre o edifício a nível dimensional, é também necessário referir que as cores da cobertura são claras, assim como as cores das paredes exteriores. Isto é relevante na medida em que também os valores tabelados necessários para o correto e mais preciso cálculo da previsão da temperatura recorrendo ao modelo matemático, necessitam deste tipo de informação. Ainda assim, este estudo continua a ser uma solução inteligente para a modelação térmica de edifícios sem conhecer os seus materiais de construção, porque estas características são visíveis a olho nú e sem nenhum tipo de conhecimento de engenharia civil, pelo que continua a poder ser utilizado em qualquer caso.

### 3.6 Integração dos Parâmetros

Nesta secção importa indicar como são escolhidos e quais são os parâmetros aplicados nesta solução. Em qualquer estudo que seja efetuado, a razão de tudo fazer sentido, parte sempre de dados. Normalmente, dados já existentes ou dados recolhidos de forma autónoma ou durante o estudo. Existem assim, várias formas de armazenar, registar ou utilizar dados, quer em *datasets*, quer em bases de dados ou até em simples tabelas, dependendo do efeito para que sejam esses dados. No caso deste estudo, a melhor forma de obter amostras de dados, é através de *datasets*, pois são conjuntos de dados específicos, que servem de amostra muitas das vezes para

algoritmos de inteligência artificial, como *Machine Learning*, ou para outros tipos de projetos de *Data Science*.

Estes dados, obtidos através desta especificação, são importados e processados através de bibliotecas específicas da linguagem de programação utilizada. Como este tipo de dados surgem normalmente em formato de linhas e colunas, pode-se ler de forma mais clara e transparente estes mesmos dados. Normalmente o tamanho do *dataset* influencia a qualidade da modelação final, uma vez que quanto maior for o seu tamanho, maior será a base em que se sustenta a aprendizagem da modelação. Neste caso em concreto, importa recorrer a *datasets* que digam respeito a temperatura interior e exterior do local a estudar. Para temperatura exterior, recorre-se a um conjunto de dados obtidos através da *MeteoBlue* que oferece dados relativamente a meteorologia de determinados locais. Recorrendo diretamente ao *website* *MeteoBlue*, podemos obter ficheiros em *xlsx* ou em *csv*, em que a diferença entre eles, rege-se pela diferença como a informação é disponibilizada.

No primeiro caso, trata-se de um ficheiro *excel* comum, em que são apresentados dados referentes à temperatura e data das mesmas, e que podem ser lidas normalmente ou tratando os dados através de gráficos. No caso do ficheiro *csv*, ele contém a mesma informação, mas neste caso a informação aparece de uma forma mais codificada, uma vez que os dados são apenas separados por vírgulas, e são este tipo de ficheiros que permitem que se englobe estes *datasets* numa solução inteligente, como no caso da aplicação de previsão de temperatura, para que o código responsável por implementar a solução, seja capaz de ler estes dados de uma forma rápida e eficaz. Em todo o caso, são utilizados os dois tipos de ficheiros, no caso do modelo matemático é utilizado o ficheiro *xlsx* retirado da *MeteoBlue* e no caso da aplicação das Redes Neurais, é utilizado o ficheiro *csv*, mas desta vez com os dados retirados dos sensores *IoT*.

Uma vez utilizados os dados referentes aos sensores *IoT*, pode efetuar-se uma comparação com outros estudos já realizados, como é o caso de [5] em que o objetivo desse estudo seria criar uma *framework* para previsão de temperaturas, mas neste caso apenas com dados referentes a sensores *IoT*. No caso de [5], o objetivo final seria reduzir o consumo de energia do edifício, no entanto o relevante neste estudo, é o modo de aquisição de dados. Os dados foram coletados em dois formatos, no entanto o modo de recolha, basea-se sempre nos sensores inteligentes, tal como nesta dissertação, para a aplicação com base em redes neurais.

Num primeiro caso, tal como mostra a figura 3.10, semelhante a este trabalho, em que os dados foram recolhidos pelos sensores termostátos e transferidos por *Wi-Fi* para o dispositivo de armazenamento, que conseqüentemente armazenou os dados, consolidou-os e processou-os, assim como os inseriu no seu Modelo Térmico de Entrega.

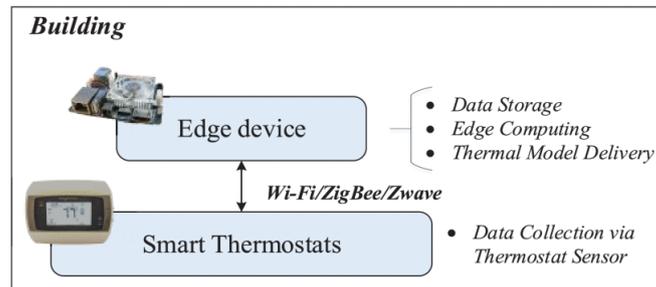


Figura 3.10: Exemplo da recolha de dados diretamente ao dispositivo por [5].

No segundo caso, como mostra a figura , os dados foram recolhidos de igual forma, mas desta feita foram armazenados para uma *cloud* do fabricante do sensor.

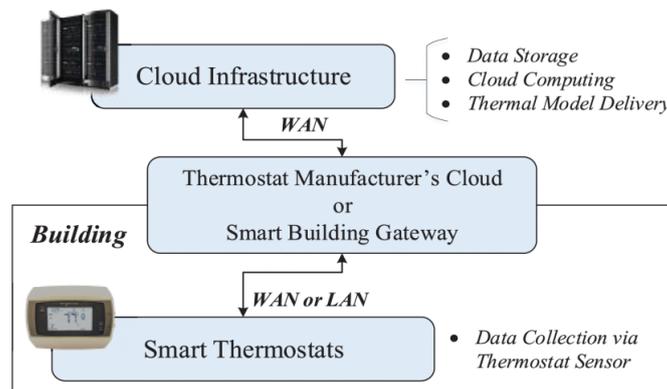


Figura 3.11: Exemplo da recolha de dados diretamente para a *cloud* por [5].

A forma de recolha de dados foi feita através de uma tabela, onde foram registadas informações tais como data, hora e temperatura. Finalmente, estes dados foram tratados, à semelhança do processo desta dissertação, em que primeiramente esses valores encontravam-se numa tabela, e de seguida foram processados de forma a que fossem inseridos num outro formato, também num modo separado por vírgulas, para que pudesse ser inserido no *framework* desenvolvido. Em tudo este processo é idêntico ao desta dissertação, apenas modificando o fim a que se destinam os dados, no entanto são processados e utilizados do mesmo modo em ambos os casos.

Assim sendo, tem-se em conta que a estação do ano em causa, é o verão, mais concretamente entre os meses de junho e setembro, e focando o mais especificamente no mês de setembro.

Devido à localização do objeto de estudo, os *datasets* utilizados são referentes à

estação meteorológica Porto - Serra do Pilar, que em termos geográficos é a estação que se encontra mais próxima do local do estudo, e que em o clima se assemelha mais ao estudo.

É uma zona bastante próxima do mar, pelo que também se sabe que normalmente existem diferenças de temperatura mais bruscas, uma vez que as alterações do mar influenciam bastante também as condições meteorológicas ao seu redor. No entanto, é exatamente por esse motivo e por todos os outros fatores que não podem ser controlados, tais como tempestades vindas de outros continentes, que a quantidade de dados deve ser o maior possível para treinar da melhor forma a solução.

Além deste, também o *dataset* referente à temperatura interior será utilizado para o respetivo treino da solução.

Como referido anteriormente, os *inputs* a utilizar em termos da radiação incidente, são obtidos pelo Instituto Português do Mar e da Atmosfera (IPMA) por interpolação, a partir dos apuramentos diários acumulados da radiação global da rede de estações automáticas do IPMA no Continente.

Considera-se o ponto de localização de estudo, circundado a azul na figura 3.12 e o valor de radiação global incidente de  $650 \text{ MJ/m}^2$ . Este valor de radiação, é igual tanto para a incidência na parede como no telhado do objeto de estudo.

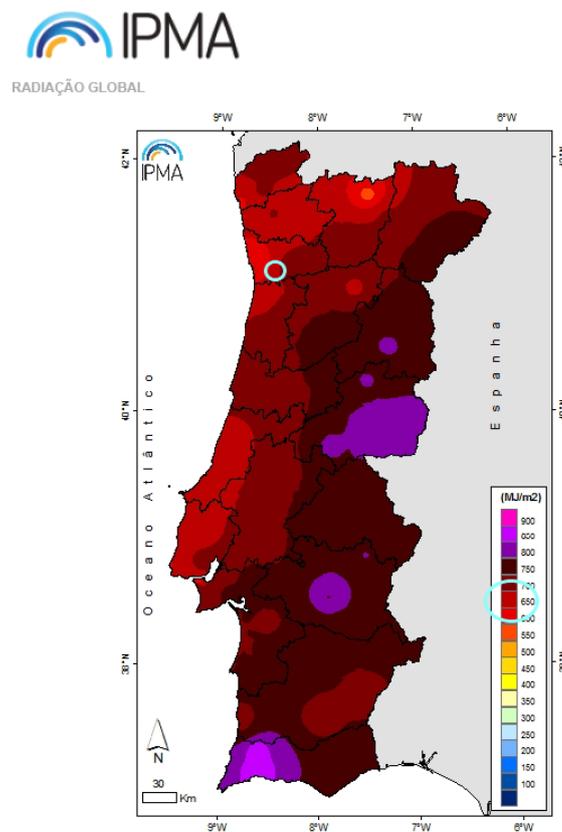


Figura 3.12: Radiação Global para Portugal Continental em Setembro de 2022

Relativamente ao *input* da temperatura exterior, esta é obtida pelo *MeteoBlue*, e é registada diariamente em termos de temperatura máxima e temperatura mínima referente a cada dia. Na figura 3.13 são mostrados os valores obtidos entre o dia 3 e 17 de setembro do ano 2022.

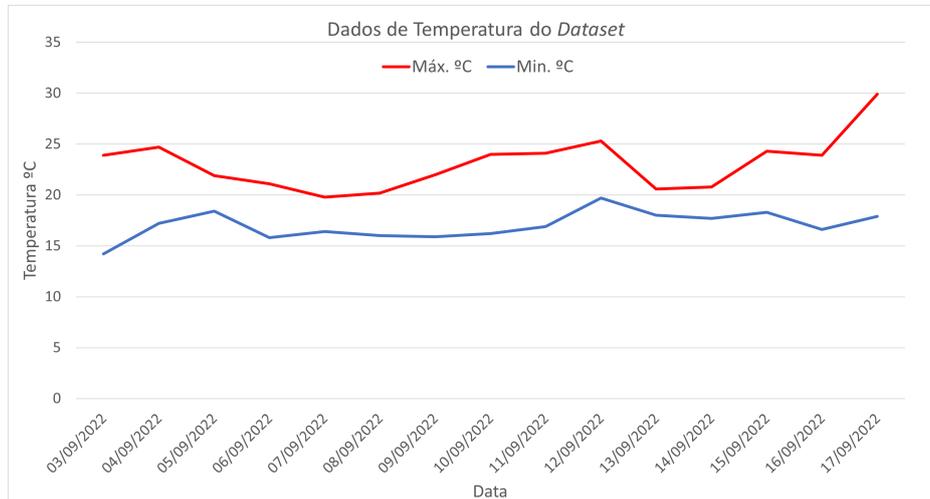


Figura 3.13: Temperatura Máx. e Min. entre os dias 3 e 17 de setembro de 2022 na estação meteorológica Porto - Serra do Pilar.

Em relação aos dados obtidos através do *IoT*, como já indicado, existem dados registados desde junho, mas para o efeito de cálculo e treino da solução, apenas se considera os valores de hora em hora, entre os dias 8 e 11 de setembro de 2022. No caso do *input* de temperatura interior, existem dados relativos a dois sensores, pelo que os dados apresentados na figura 3.14, são as médias das temperaturas obtidas para cada dia referido.

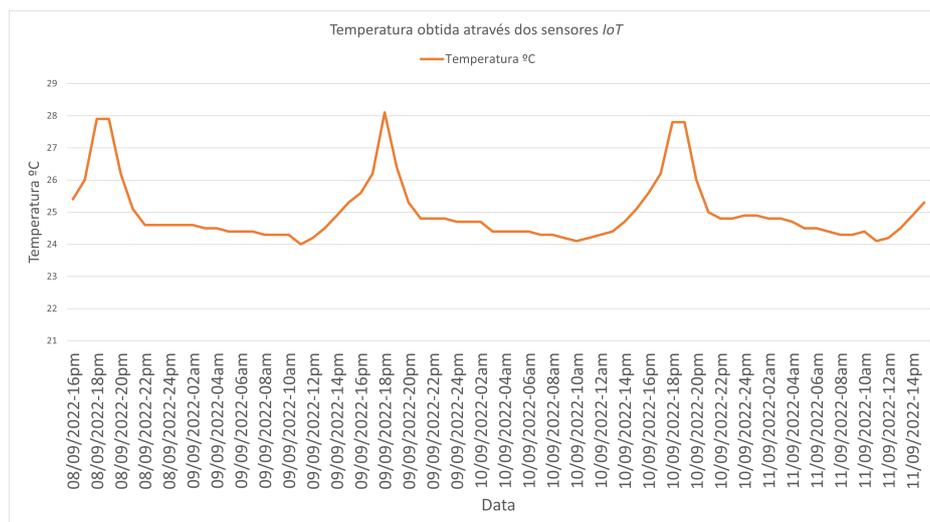


Figura 3.14: Temperatura obtida entre as 16:00 horas - 8 de setembro até às 14:00 horas - 11 de setembro através dos sensores *IoT*.

Estes dados são posteriormente inseridos num ficheiro *csv*, por forma a constituir o *dataset* necessário à implementação na solução final.

### 3.6.1 Integração dos Parâmetros com o Modelo Matemático

Apresentados todos os parâmetros necessários à implementação desta solução, importa nesta fase do estudo, perceber como são implementados os *inputs* nos respetivos modelos apresentados. O objetivo será obter a previsão da temperatura para um futuro próximo, no máximo de uma hora.

O ponto crucial, é a implementação dos parâmetros obtidos até agora, no modelo matemático simplificado, já descrito no capítulo anterior.

No entanto, como o objetivo é prever a temperatura interior do volume de estudo, sem ter em conta os fatores externos nem previsões externas, retira-se a componente da temperatura exterior das equações obtidas para obtenção da carga térmica, e assim obtém-se temperaturas interiores dentro de um pequeno período de tempo, sem influência dos fatores externos. Como referido, para obter a temperatura interior do espaço em estudo, terá de se calcular todas as cargas térmicas, e por ordem de descrição, inicia-se calculando o valor das cargas térmicas por condução através da envolvente exterior. É nesta fase que se recorre ao *dataset* de temperaturas exteriores, para conseguir obter os valores tabelados a inserir nas equações, e este conjunto de dados permite que se obtenham os valores tabelados mais corretos possíveis, tendo em conta o histórico da localização do objeto de estudo. Recuperando as equações 2.1 e 2.2, é necessário calcular os valores para as paredes exteriores, cobertura e envidraços exteriores. Nesse sentido, e recuperando os valores do volume de estudo descritos anteriormente, temos:

- Área ( $A_{pc}$ ) da parede C (retirando a área da janela) =  $10 \text{ m}^2$
- Área ( $A_{ee}$ ) da janela (envidraçado exterior) =  $5 \text{ m}^2$
- Área ( $A_c$ ) da cobertura =  $48 \text{ m}^2$

As paredes A, B e D, estão em contacto com a vizinhança, pelo que não se consideram para efeitos de cálculo, uma vez que teoricamente, a temperatura do outro lado da parede, é igual ou aproximada à do volume de estudo.

Ainda é necessário obter os valores de condutividade térmica e de DTE. Estes valores, ambos tabelados por [6], para a condutividade térmica das paredes, assume-se o valor de 1.15 (W/mK) e para a cobertura de 0.95 (W/mK). Já para os envidraçados, assume-se o valor de 1 (W/mK). Em relação aos valores de DTE, tendo em conta o horário das 12:00 horas, como a hora em que a temperatura é mais elevada, e a localização do volume de estudo, para as paredes exteriores assume-se o valor de 6, de 7 para a cobertura e do valor de 5 para os vidros.

Para o valor de LM, assumindo o mês de setembro como referência para o cálculo, este assume o valor de -2,2 e o de C, como já referido, assume o valor de 0,83. Além disso, escolhe-se o dia 10 de setembro, para efeitos de cálculo, uma vez que é necessário obter os valores de temperatura interior. Como se tem em conta o horário das 12:00 horas, assume-se também que é a hora de maior temperatura, e nesse caso, utiliza-se assim o valor de temperatura máxima obtido pelos *datasets*, no valor de 24.3 °C para a temperatura interior. No entanto, é necessário além deste valor, mais dois valores de temperatura interior, das duas horas anteriores, a este valor obtido, para futuramente se efetuarem previsões com maior taxa de acerto. Adotando a mesma lógica, que se adotou para a obtenção do valor para o dia 10 de setembro às 12:00 horas, tem-se a mesma ordem de ideias para as 11:00 horas e para as 10:00 horas, obtendo-se, respetivamente os valores de 24.2 °C e 24.1 °C para temperatura interior.

Tem-se em conta que para cada situação, o modo de corrigir o DTE é diferente, e passa-se a calcular de seguida.

- **Cálculo da carga térmica para as paredes exteriores**

$$\Delta T_{e_{\text{corrigido}}} = (6 + (-2.2)) * 0.83 + (25 - 24.3) = 3.854 \quad (3.1)$$

$$\dot{Q}_{pe} = 1.15 * 10 * 3.854 = 44.321 \text{ W} \quad (3.2)$$

$$\Delta T_{e_{\text{corrigido-1dia}}} = (6 + (-2.2)) * 0.83 + (25 - 24.2) = 3.954 \quad (3.3)$$

$$\dot{Q}_{pe-1hora} = 1.15 * 10 * 3.854 = 45.471 \text{ W} \quad (3.4)$$

- **Cálculo da carga térmica para a cobertura**

$$\Delta T_{e_{\text{corrigido}}} = (7 + (-2.2)) * 0.83 + (25 - 24.3) = 4.684 \quad (3.5)$$

$$\dot{Q}_c = 0.95 * 48 * 4.684 = 213.5904 \text{ W} \quad (3.6)$$

$$\Delta T_{e_{\text{corrigido-1hora}}} = (7 + (-2.2)) * 0.83 + (25 - 24.2) = 4.784 \quad (3.7)$$

$$\dot{Q}_{c-1hora} = 0.95 * 48 * 4.684 = 218.1504 \text{ W} \quad (3.8)$$

- **Cálculo da carga térmica para os envidraçados**

$$\Delta T_{e_{\text{corrigido}}} = (5 + (-2.2)) * 0.83 + (25.5 - 24.3) = 3.524 \quad (3.9)$$

$$\dot{Q}_e = 1 * 5 * 3.524 = 17.62 W \quad (3.10)$$

$$\Delta T_{e_{\text{corrigido-1hora}}} = (5 + (-2.2)) * 0.83 + (25.5 - 24.2) = 3.624 \quad (3.11)$$

$$Q_{e-1\text{hora}} = 1 * 5 * 3.524 = 18.12 W \quad (3.12)$$

Ainda para os envidraçados, como já mencionado anteriormente, existem, além de carga térmica por condução, ganhos solares através dos mesmos. Nesse sentido, e tendo em conta também a equação já apresentada e determinados os valores necessários para o seu cálculo, tem-se que os valores de *MSHGF* toma o valor segundo [6] de  $95 \text{ W/m}^2$  temos também que o valor de *SC* é de 0.9. Por último, existem três valores de *CLF*, para construções leves, médias e altas. Neste caso, utiliza-se o valor para construções médias, e tem-se o valor de 0.70. Posto isto, e retornando a equação 2.3 temos o seguinte:

$$\dot{Q}_\Theta = 5 * 0.9 * 95 * 0.70 = 299.25 W \quad (3.13)$$

Calculados os valores da carga térmica para o volume em estudo, resta converter os valores da carga térmica em temperatura interior. Assim sendo, e recorrendo à equação 2.7, é possível calcular o valor da temperatura interna, depois da mesma ser deduzida da equação 2.4. Antes de obter o valor final da temperatura interna, é necessário calcular o valor de  $I_\Theta$ . No entanto, é necessário ainda conhecer temperaturas interiores, de duas horas anteriores ao momento do cálculo. Nesse sentido, e tendo em conta os valores de 2.2, para a inércia média, tem-se a equação 3.16:

$$I_\Theta = (24.3 * 0) + (1 * 574.7814) + (-0.87 * 580.9914) - (-10.73 * 24.3) - (0.45 * 24.2) \quad (3.14)$$

$$I_\Theta = 319.1674 \text{ W/m}^2 \quad (3.15)$$

$$T_\Theta = \frac{296.104}{10.28} = 31.05 \text{ }^\circ\text{C} \quad (3.16)$$

### 3.6.2 Integração dos Parâmetros com as Redes Neurais

A Rede Neuronal utilizada, é do tipo Recorrente e assenta no tipo de memória *Long Short-Term Memory* (LSTM), um tipo de memória utilizada neste tipo de redes neurais, uma vez que esta tem a característica de ser bastante eficaz em problemas de

sequenciamento, como no caso de previsões temporais. Neste sentido, é necessário recorrer ao *dataset* com os dados anteriormente retirados dos sensores *IoT*. O objetivo deste trabalho intermédio, é que a solução seja capaz de ler os dados anteriores de forma correta e permitindo ainda que esse *dataset* seja extensível a qualquer momento, ou constantemente atualizado, conforme a necessidade do utilizador. Assim sendo, gera-se um ficheiro *csv*, com os dados de data e temperatura.

Em termos da integração dos parâmetros com a rede neuronal, são apenas estes os *inputs* necessários à sua implementação, no entanto os *outputs* daqui resultantes são os dados relevantes da solução.

Uma das formas mais eficazes e práticas de aplicar o conceito das Redes Neurais, é através da construção de uma aplicação. Uma das formas de o fazer, é iniciando através do *NeuralProphet* que consiste num modelo de série temporal baseado em *AR-Net*, que é uma rede neuronal autoregressiva simples para casos de séries temporais. Este conceito de *AR-Net* é essencialmente uma *framework* que combina o melhor dos métodos estatísticos tradicionais com redes neurais para modelação de previsões temporais. Esta ferramenta torna-se vantajosa uma vez que o modelo faz fortes suposições à cerca dos dados disponíveis. A aplicação consiste na previsão de temperatura através de redes neurais e com base em dados previamente adquiridos. Assim sendo, o seu funcionamento baseia-se na seguinte função 3.17:

$$y_t = c + \sum_{i=1}^p w_i y_{t-i} + e_t \quad (3.17)$$

- $y_t$  - Série temporal;
- $p$  - Valores anteriores;
- $w_i$  - Peso sináptico (Coeficiente AR);

De uma forma geral, também a Rede Neuronal, se baseia naturalmente em cálculos matemáticos, mas aplicados de forma diferente dos do Modelo Matemático e com outro tipo de dados. Neste caso, a Rede Neuronal baseia a sua ação nos dados anteriormente obtidos pelos *datasets* fornecidos, e tenta encontrar um peso sináptico, ou seja, tenta encontrar um coeficiente que multiplicado à serie temporal desejada e somando aos valores anteriormente observados, ela possibilita que se encontre um valor tanto mais próximo da realidade quanto mais o seu peso sináptico esteja ajustado, ou seja, que esteja treinado com o maior número de dados possíveis.

Este tipo de Rede Neuronal *Ar Net* possui uma estrutura diferente, pois cada rede possui a sua estrutura e sequência próprias, em que a última camada é uma camada totalmente conectada, assim como de seguida os valores são processados e repetidos  $n$  número de vezes, consoante seja definido pelo utilizador. Essa estrutura pode ser vista na figura 3.15.

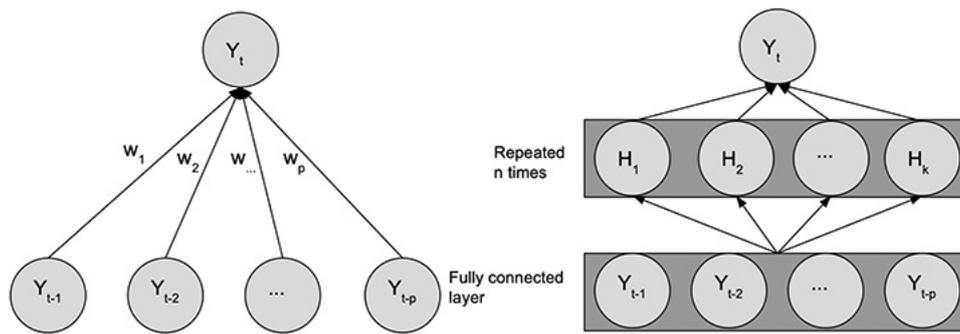


Figura 3.15: Sequência da Rede Neuronal de *AR Net*.

É assim instalada a biblioteca *Neural Prophet* e ainda outras bibliotecas imprescindíveis à aplicação deste tipo de solução, tais como *pandas*, utilizada para analisar dados e *Matplotlib* que nos permite visualizar os dados graficamente.

O ficheiro *csv* com os dados de temperatura retirados dos IoT é importado na fase seguinte da aplicação, e é importante que esses dados estejam devidamente organizados no ficheiro, e este *dataset* pode ser atualizado no futuro sempre que seja necessário, ou caso se implemente a solução em funcionamento *always on*.

É gerado um gráfico em que se visualiza as temperaturas obtidas no *dataset*, por forma a visualizar os valores de forma gráfica. Neste caso pode parecer que este passo é irrelevante, uma vez que os *inputs* foram demonstrados anteriormente e pode não se ver a necessidade destes voltarem a ser demonstrados, no entanto, neste caso estamos a trabalhar com um número pequeno de dados e dados anteriormente tratados e registados um a um, mas numa implementação desta solução a uma maior escala, estes dados não devem ser tratados individualmente, mas obtidos de forma automática, pelo que esta nova visualização e confirmação destes dados se revela importante na medida em que podem existir erros de dados que podem comprometer os resultados, e neste caso a aplicação revê todos os dados e verifica se eles são passíveis de ser utilizados no processamento, o que por outras palavras, se traduz numa correta inserção dos dados no *dataset*.

De seguida definem-se quais os dados a serem previstos, neste caso a temperatura para as próximas horas, e de hora em hora. O tempo de processamento revela-se menor e a eficácia é menor, uma vez que se efetua a previsão da temperatura apenas para as horas seguintes. O tempo de processamento será maior quanto maior foram as amostras de previsão, e a eficácia mantém-se alta, quantos maiores números de dados existirem para treinar a solução.

É ainda criada uma fração de código que nos permite visualizar o erro calculado, devido à comparação entre os valores obtidos através do cálculo da temperatura através do modelo matemático e os valores obtidos através da aplicação da Rede Neuronal.

Nos anexos pode visualizar-se o aspeto real da solução, assim como todos os seus

*outputs* e tempos de processamento. É utilizado como ambiente de desenvolvimento o *Google Colab*, uma vez que é um dos melhores ambientes para desenvolver aplicações em *python* e mais ainda, quando se trata de soluções que envolvam *Machine Learning* e análise de dados, como é o caso.

Posto isto, e definidos tanto o modelo matemático, como o desenvolvimento da aplicação para a previsão de temperaturas, inicia-se a análise aos resultados obtidos através destas soluções.

## Capítulo 4

# Análise de Resultados

*Por forma a obter-se resultados fidedignos a partir do sistema desenvolvido, inicialmente teve-se, obrigatoriamente de fazer uma pesquisa quanto aos sensores a utilizar e efetuar um teste para averiguar a sua viabilidade para este estudo. Após todo o sistema estar devidamente acondicionado no interior do volume de estudo e garantidas as condições de teste da solução, foram realizados os registos dos valores a utilizar na solução final. Finalmente, aplicando os conceitos documentados e desenvolvidos, registam-se os resultados obtidos e analisam-se de seguida.*

### 4.1 Teste e Calibração de Sensores

Com os testes efetuados pretendeu-se aferir a viabilidade de várias tecnologias existentes no mercado, para sensores de registo de temperaturas internas. Deste modo, procedeu-se inicialmente a uma avaliação dos sensores existentes no mercado, não só de sensores que efetuassem este tipo de medições, mas também de sensores que tivessem englobado a tecnologia *IoT*, isto porque no caso de sensores de temperatura apenas, existem variados e muito mais antigos no mercado, que permitem este tipo de medições, mas que não providenciam o mesmo tipo de *outputs*.

Inicialmente efetuou-se uma vasta pesquisa no mercado e avaliou-se o tipo de comportamento que estes ofereciam quando implementados no sistema desejado. Era importante que estes sensores fossem pequenos e discretos, uma vez que são dispositivos que têm de ficar bem expostos de forma a registarem corretamente os dados a que se propoem. Posto isto, e tendo em conta os vários *gadgets*, também com

a tecnologia *IoT* que esta marca *Xiaomi* proporciona, e com as enúmeras *reviews* também presentes em artigos quer profissionais quer particulares, os sensores anteriormente apresentados, revelavam-se os melhores do mercado não só em *performance* como numa relação custo-benefício.

Após a escolha dos sensores, foi importante testá-los de forma a que se tivesse um certo nível de confiança e segurança nos mesmos, e nesse sentido foram colocados durante 7 dias em ambiente controlado, encerrados dentro de uma caixa hermética e isolados termicamente, de forma a verificar que os seus valores de temperatura e humidade não se alteravam.

Verificou-se de facto que os valores se mantiveram inalterados, pelo que o teste e calibração dos mesmos, se verificou bem sucedido e podia-se considerar que estes sensores seriam adequados à solução. Além disso, a aplicação que estes sensores permitem aceder, é bastante intuitiva e permite obter os dados de uma forma bastante rápida e fluída, além de permitir visualizar estes dados de hora em hora, por dias e até por mês, em que naturalmente é efetuada uma média dos minutos, horas ou dias em questão, respetivamente.

Como já referido anteriormente, existem dados reais de temperatura interior do volume de estudo, registados desde junho e são considerados para este estudo, os dados entre as 16 horas do dia 8 de setembro até às 14 horas do dia 11 de setembro de 2022.

Os dados anteriormente demonstrados, não foram tratados nem estudados, uma vez que são dados reais obtidos através de sensores presentes 24 horas por dia no local de estudo, permanentemente conectados à *internet*, e que permitem obter dados em tempo real do estado do local onde eles estão inseridos, quer a nível de temperatura, quer a nível de humidade relativa, como também já mencionado anteriormente.

O objetivo desta solução, será que as soluções desenvolvidas se aproximem o mais possível destes valores, fazendo assim com que a solução seja bem sucedida.

## 4.2 Análise de Resultados do Modelo Matemático

Anteriormente calculou-se um valor de temperatura interior, através do modelo matemático, com base no *dataset* obtido através do *website MeteoBlue*, e com referência às temperaturas obtidas pelos sensores *IoT*.

As equações inicialmente propostas e obtidas através da análise do modelo proposto por [7], referem além cargas térmicas, referem também o valor dos ganhos solares. Posto isto, tem-se a noção que tratando-se de um estudo que engloba temperaturas dentro de um determinado volume, e que esse volume está sujeito a determinadas variações de temperatura, isso traduz-se numa análise da energia térmica que esse volume pode sofrer. Essas variações de energia térmica podem ser positivas ou negativas, consoante o local de estudo aumente ou diminua a sua temperatura, que

naturalmente está diretamente ligada com a temperatura exterior ou então com a geração de energia dentro do determinado espaço.

Sendo a estação do ano em causa, o verão e tendo em conta que Portugal é um país em que no verão se podem atingir temperaturas a rondar os 30 °C, é de esperar que existam ganhos de energia térmica dentro do determinado volume de estudo, isto porque o interior de uma habitação não deveria atingir estas temperaturas de modo a que se tenha conforto dentro da mesma. Tendo em conta a análise feita ao modelo matemático proposto, entende-se que existem ganhos de carga térmica através de diversos componentes estruturais da habitação, quer sejam pela cobertura, pelas paredes exteriores ou pelos envidraçados, se existirem. Como já demonstrado graficamente nos capítulos anteriores, tem-se a noção que estes ganhos de carga térmica se dão por condução e no caso dos envidraçados também existem ganhos solares por radiação. Todas estas equações matemáticas deduzidas da equação geral do balanço de energia, dão origem a equações em que o objetivo é determinar a carga térmica para as paredes exteriores, cobertura e envidraçados e para ganhos solares através dos mesmos.

Na figura 4.1 pode ver-se a representação de onde surgem as cargas térmicas e os ganhos solares.

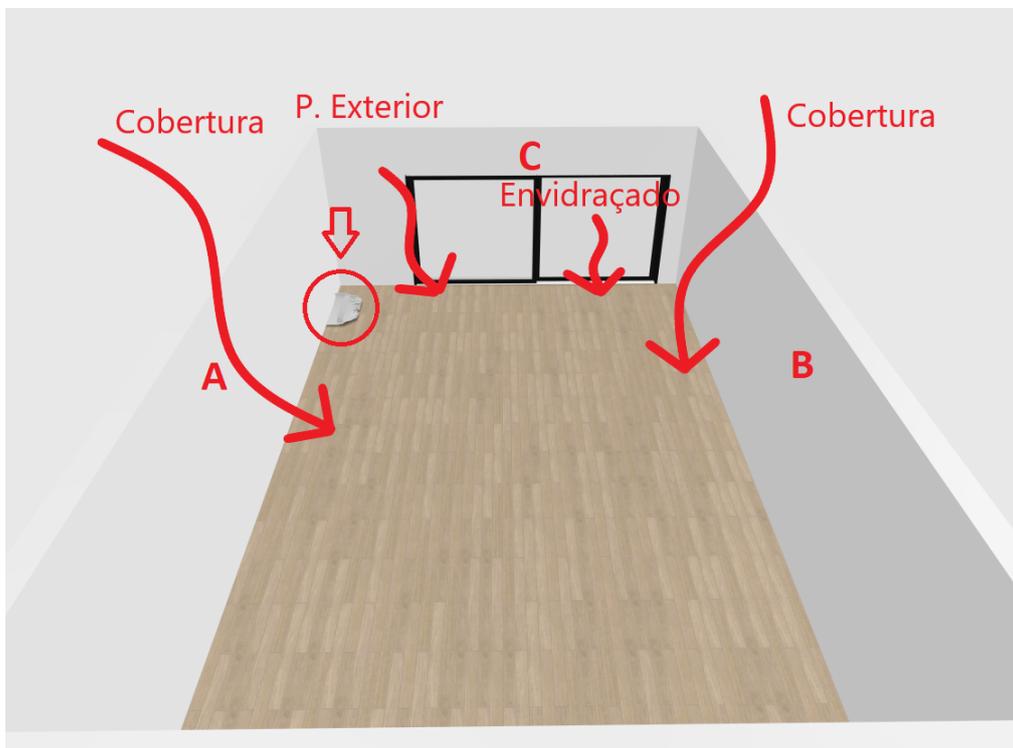


Figura 4.1: Ilustração das Cargas Térmicas e Ganhos Solares presentes no volume de estudo.

Através da cobertura e da parede exterior (C) temos cargas térmicas a serem transferidas para dentro do volume de estudo, tendo em conta a diferença de temperatura

existente. Nestas transferências de energia, existem resistências térmicas devido aos diferentes materiais de construção do edifício, no entanto é o objetivo deste estudo, que se consiga alcançar uma temperatura interior sem que se recorra a esses cálculos. Nas paredes A e B, que são paredes em contacto com outras divisões do edifício, não existem ganhos térmicos, por estarem à mesma temperatura que o volume de estudo e não terem contacto direto com o sol, e por esse mesmo motivo não é considerado os valores de carga térmica. Na janela, considerado o envidraçado, além de carga térmica, existem também ganhos solares, mas aqui por radiação, uma vez que sendo o vidro transparente, existe alguma energia solar que é transferida para o interior do local de estudo.

As equações inicialmente propostas tinham em conta o valor da temperatura exterior, uma vez que as previsões de temperatura eram feitas para vários dias e tendo em conta também que o volume de estudo sofria variações variadas de energia, quer através de pessoas quer através de equipamentos eletrónicos. No caso deste estudo, teve-se em conta apenas os valores de temperatura interior e os valores de temperatura exterior para obtenção de valores tabelados, como também já referido. Considerou-se que o volume de estudo não tinha perdas através da condução de ar, ou seja, que a habitação se encontra bem isolada termicamente, e que não existiram pessoas nem equipamentos durante o estudo, o que de facto não aconteceu na realidade.

Posto isto, após a substituição dos valores nas equações e feito o somatório, posteriormente com esse valor global de carga térmica, substitui-se na equação o que nos permite obter o valor de temperatura prevista, o valor de 31.05 °C, que é uma referência para o cálculo do valor da hora seguinte. Este valor só faz sentido, se for recalculado várias vezes e para as horas seguintes, de forma a se obter um padrão. No entanto, as restantes horas a partir desta primeira hora calculada, serão já calculadas com base na temperatura interior prevista, e não com base na temperatura real obtida pelos sensores. Assim, o que foi feito no capítulo transato, foi apenas tomar um valor inicial, para tomar como ponto de partida no modelo matemático. Assim sendo, as equações são inseridas num ficheiro *excel*, e recalculados os valores, para 10 horas seguintes a partir da hora inicial, as 12 horas do dia 10 de setembro de 2022. Como temperatura exterior, continua-se a utilizar os valores dos *datasets* obtidos através da *MeteoBlue*, apenas para a obtenção dos valores tabelados, uma vez que não se considerou a temperatura exterior no cálculo da temperatura interior. Os cálculos são omitidos nesta secção, uma vez que seria extenso colocar todos eles detalhadamente no documento, no entanto foi elaborado um ficheiro *excel* com todas as equações anteriormente designadas, de forma a mais facilmente se efetuarem estes cálculos e também de forma a que todos os valores fossem mais facilmente obtidos. Cada valor novo, é obtido através do valor obtido da hora anterior, pelo que apenas a primeira hora é calculada com maior certeza, e sendo os outros valores já calculados

sempre com uma base em horários previstos.

É apresentado o gráfico na figura 4.2, de forma a serem visualizados os valores de forma mais fácil.

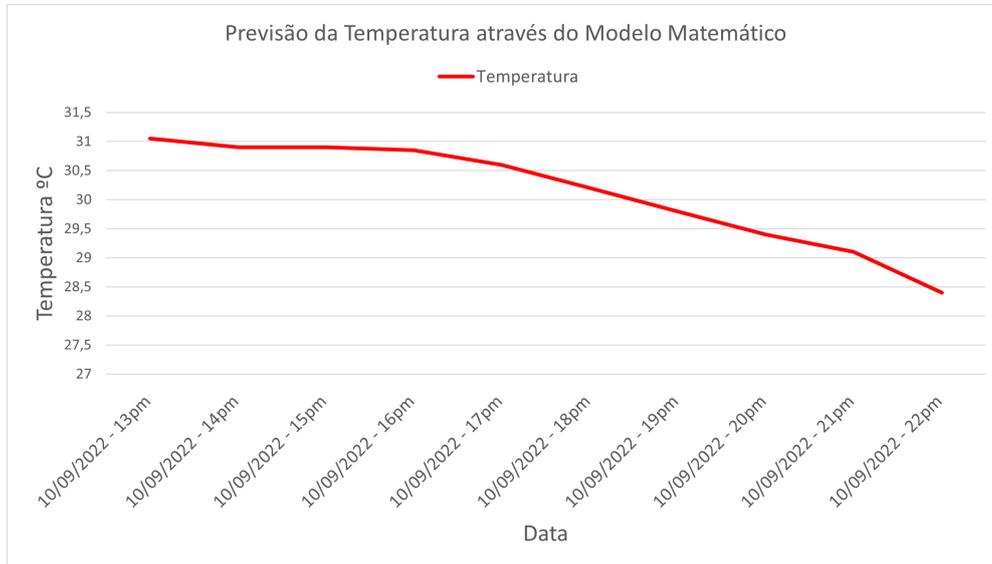


Figura 4.2: Temperatura prevista através do Modelo Matemático

Após análise do gráfico com os valores obtidos, verifica-se de facto que os valores têm um sentido decrescente, o que faz sentido tendo em conta o passar das horas do dia, em que se aproxima o pôr do sol, o que faz com que a carga térmica obtida pelo volume de estudo seja menor, uma vez que deixa de haver ganhos térmicos por condução e ganhos solares naturalmente.

Estes valores são analisados novamente na secção correspondente, de forma a poderem ser comparados com os valores reais e também com os valores obtidos através da aplicação da Rede Neuronal.

### 4.3 Análise de Resultados da Rede Neuronal

Tendo por base uma Rede Neuronal [8] das várias existentes, para previsões de temperatura, desenvolvida com base numa aplicação escrita em *python* e tendo por base as Redes Neurais Recorrentes, foi possível também obter uma variante desse tipo de aplicações, mas adaptada ao caso de estudo. Para conseguir correr de forma correta esta aplicação e com os dados corretos, foi, como já indicado nos capítulos anteriores, necessário tratar os dados obtidos, colocando-os dispostos em forma de *dataset* para que se tornassem limpos e universais, e para que seja possível ainda aos próximos utilizadores, alterarem esses *datasets* da forma que achem mais útil ao seu estudo e para que também se possa alargar esse conjunto de dados.

As condições seleccionadas os dados obtidos utilizados para a elaboração do *dataset* para este estudo foram as seguintes:

- *Ambiente* - A temperatura ambiente foi medida através de dois sensores de temperatura presentes no volume de estudo, e onde a média dos valores obtidos pelos sensores, foram os valores utilizados;
- *Temporização* - Foram medidos os valores durante cerca de 3 meses entre o mês de junho e o mês de setembro de 2022, obtendo valores de hora em hora neste período;
- *Envolvência* - O volume de estudo esteve interdito da presença de pessoas e de equipamentos eletrônicos, com as janelas sem coberturas ou estores;

Para o teste realizado para os sensores, as condições de teste, eram as seguintes:

- Todos os testes foram realizados no mesmo local do estudo final;
- Os valores inseridos no *dataset* foram obtidos através da aplicação *MiHome*, desenvolvida pelo fabricante, e enviada para o dispositivo móvel do utilizador;
- Os valores foram inseridos num ficheiro *excel*, obtidas as médias dos dois sensores, e tratados na sua forma final num ficheiro *csv*;
- Os testes foram realizados com os dados do mês de agosto de 2022, para períodos de hora em hora, e ainda para períodos de dia em dia;

Esta aplicação, inicialmente procura visualizar e confirmar os dados que adquire, que neste caso podem ser guardados diretamente no computador que está a correr a aplicação ou então diretamente numa *drive/cloud*, uma vez que a forma como foi desenvolvida a aplicação permite as duas formas de armazenamento. No caso em concreto da aplicação deste trabalho, os dados foram armazenados em *Google Drive*, uma vez que é mais seguro para que os dados não se percam e também porque permite que os dados fiquem acessíveis a qualquer pessoa que queira realizar o mesmo estudo para o este tipo de dados.

Depois da correta leitura de dados por parte da aplicação, a mesma utiliza esses mesmos dados para efetuar um treino da solução, que consiste em fornecer esse conjunto de dados à Rede Neuronal implícita na aplicação, que através das suas constantes tentativas de melhoramento e aproximação dos valores previstos aos valores reais, vai ajustando os seus pesos sináticos até que se observe uma aproximação desses valores. Naturalmente, quanto maior for o número de dados anteriores para o treino da solução, maior será a sua percentagem de acerto uma vez que a Rede Neuronal vai ajustando os seus pesos de forma a que se vá diminuindo a percentagem de erro. Na imagem seguinte 4.3, pode comparar-se esta aplicação com uma outra desenvolvida por [9].

Da mesma forma que [9], também este trabalho tem a mesma funcionalidade e correndo a aplicação baseada numa Rede Neuronal, ela é responsável assim por ler

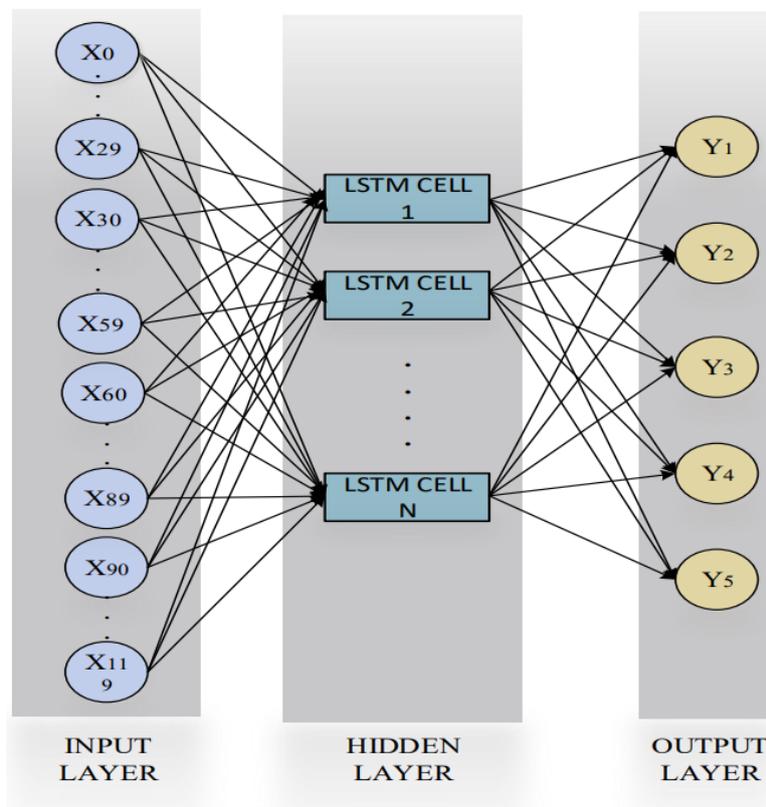


Figura 4.3: Estrutura da Rede Neuronal com *LSTM*.

os dados previamente inseridos num *dataset*, e organiza-os de forma a estes possuírem uma estrutura adequada à solução. Estes dados são retornados em forma de gráfico pela aplicação, para que o utilizador possa visualizar os mesmos e confirmá-los, se o desejar. Após estes procedimentos, entra a fase em que efetivamente se aplica a RNN e que consiste essencialmente numa camada de *input*, neste caso os dados obtidos através dos sensores *IoT*, uma camada escondida em *LSTM*, que consiste basicamente numa memória de curto prazo mas que envia *feedback* de volta para a camada de *input*, e é aqui em que esta Rede Neuronal se destaca, pois este *feedback* é o que permite que esta rede tenha resultados mais satisfatórios do que outros tipos. E por fim, a camada de *output*, que consiste no principal objetivo desta aplicação, os valores de temperatura.

Os valores na aplicação são retornados em forma de gráfico, distribuídos pelas horas seguintes à hora inicial do estudo.

Abaixo na imagem 4.4, é possível visualizar os resultados da aplicação da rede neuronal.

É possível visualizar uma oscilação dos valores, que poderiam ser anormais, tendo em conta que a aplicação treina a sua Rede Neuronal para que os valores se aproximem o máximo possível da realidade, mas como descrito anteriormente, a aplicação é treinada com um pequeno número de amostras, uma vez que se está a efetuar esta

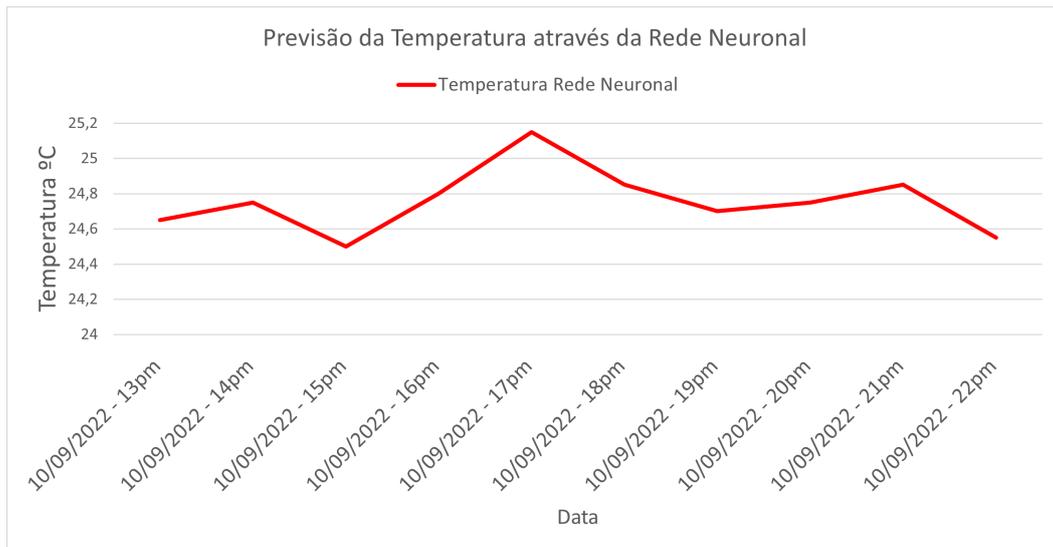


Figura 4.4: Temperatura prevista através da Rede Neuronal

previsão apenas para efeitos de estudo, e o que os dados obtidos nos podem estar a transmitir, é que de facto existem valores também eles discrepantes no *dataset* e que podem estar a distorcer o resultado final. No entanto, também como sabemos, no dia a dia existem valores discrepantes de temperatura por vezes, o que na realidade torna também esta previsão mais próxima da realidade.

Além destes valores de temperatura previstos, que são um valor médio de temperatura interior, tendo em conta que os sensores se encontram um em cada extremo da sala de estudo, considera-se que o valor médio será aproximadamente no centro do volume de estudo, e que nos extremos na zona da janela a temperatura será ligeiramente superior, devido aos ganhos solares e na extremidade mais afastada da janela, a temperatura será ligeiramente inferior. Isto pode em todo o caso ser consultado e verificado através dos valores obtidos nos sensores *IoT*, e além disso esta aplicação também pode ser treinada para valores de temperatura máxima e mínima, ou então para cada um dos sensores, o que neste caso em concreto não se verifica relevante, no entanto fica a nota de que este procedimento também é possível.

Na secção seguinte, efetua-se a comparação entre os dois métodos de previsão e o valor de dados reais, obtidos através dos sensores *IoT*.

#### 4.4 Dados Previstos *vs* Dados Reais

O objetivo deste estudo, é obter uma solução inteligente para a modelação térmica de edifícios, sem que se conheça os seus materiais de construção, e nesse sentido o objetivo crucial é conhecer as suas temperaturas interiores, de onde se pretende obter o estudo. Após se conhecer as dimensões e características estruturais do volume de estudo, desenvolve-se um modelo matemático que permita obter o valor da

temperatura do caso de estudo, conhecendo apenas o valor de temperatura exterior, e alguns coeficientes que se assumiu, tendo em conta as características dos edifícios em Portugal. Além do modelo matemático, foi desenvolvida de igual forma uma aplicação que também seja capaz de prever temperaturas, no entanto com alguns *inputs* diferentes. É crucial que se possa comparar os resultados obtidos através das duas formas, uma vez que ambas têm o mesmo objetivo final, no entanto com algumas nuances durante o seu processo. Na figura 4.5 é possível visualizar de forma geral os dados obtidos.

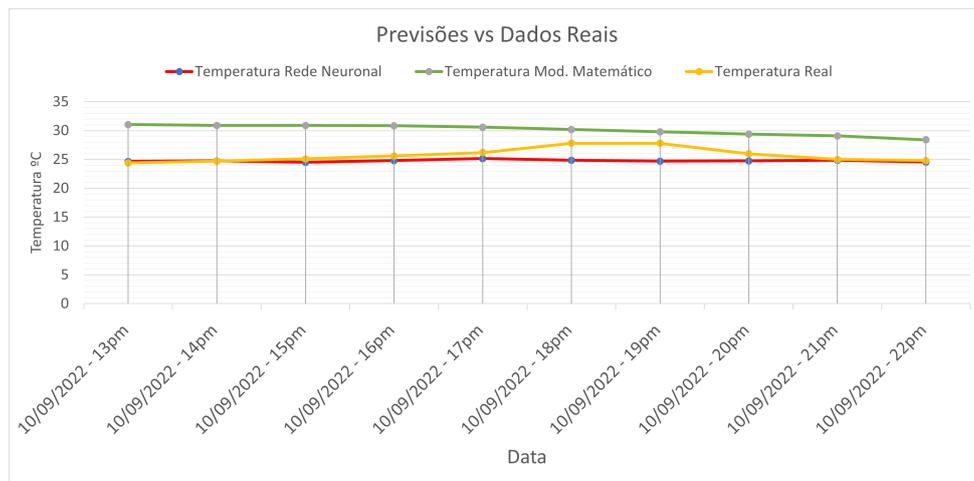


Figura 4.5: Previsões de Temperatura vs Dados reais

Esta aplicação, com recurso às Redes Neurais consegue efetuar uma previsão de valores de temperatura, para 10 horas seguintes, aos que se conhece os valores de temperatura reais.

São compilados todos os valores obtidos, quer experimentais, quer reais, na figura 4.5, de modo a que seja mais fácil a sua visualização e comparação. Pode ver-se que as temperaturas obtidas através do Modelo Matemático, são mais discrepantes do que as obtidas através da aplicação em Redes Neurais, em comparação, naturalmente, com os valores reais de temperatura, obtidos através dos sensores *IoT*.

Existem vantagens e desvantagens em utilizar um e outro método, e é com recurso aos dados obtidos através das mesmas que estas conclusões podem ser retiradas.

Resta analisar todos os valores obtidos, e fazer as devidas análises tendo em conta o objetivo principal da solução.

Tendo os resultados desejados sido calculados, resta efetuar uma comparação entre eles, de modo a que se obtenha uma conclusão à cerca da viabilidade do estudo e da sua real aplicação na prática. Este trabalho é bastante complexo, na medida em que podem ser sempre aplicadas mais variáveis, uma vez que existem muitas condicionantes dentro de um edifício. Quer seja ao nível de isolamento térmico, quer seja ao nível de presença de equipamentos e pessoas, quer até seja ao nível dos materiais de

construção. Nesse sentido, os cálculos efetuados para a dedução do Modelo Matemático, foram realizados no sentido de obter um valor aproximado de temperatura para um determinado horário. Nesse cálculo, foram considerados os ganhos solares através dos envidraçados, e a carga térmica obtida por condução, através da cobertura, envidraçados e da parede exterior, e não foi considerado os valores de carga térmica vindas das paredes vizinhas, uma vez que estas foram consideradas como idênticas em termos de carga térmica, às existentes e nesse sentido, considerada uma carga térmica nula. Posto isto, e após a análise do documento, é possível visualizar que foram assumidos vários valores durante este cálculo, como por exemplo para o Coeficiente de Sombra, quer para até o valor em que se encontra o local de estudo, em termos de geolocalização. Por fim, denota-se que os valores obtidos, são algo diferentes dos valores reais, em alguns casos em mais de 3 °C. Isto pode deve-se não só ao rigor do cálculo, mas como também aos valores assumidos e ainda à existência ou não de mais ou menos infiltrações de ar.

Em relação ao cálculo dos valores de temperatura interior, obtidos através da aplicação das Redes Neurais, pode ver-se através dos gráficos apresentados, que estes valores se aproximam bastante mais dos valores reais, quando comparados com os valores dos cálculos matemáticos.

## 4.5 Análise de Resultados

Como o fundamental deste trabalho se baseia em previsão de dados existem algumas métricas mais adequadas para avaliar os resultados deste estudo. Nesse sentido, aplicam-se duas métricas, nomeadamente *Root Mean Squared Error (RMSE)* e *Mean Absolut Error (MAE)*.

Estas métricas são similares na medida em que expressam o erro médio do modelo de previsão em relação aos dados reais. O objetivo da observação dos dados através desta métricas, é que quanto menor o valor calculado, melhor, na medida em que existe um erro menor.

Para o RMSE, que calcula a raiz quadrada média entre os valores reais e os valores previstos, temos a seguinte equação 4.1:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (4.1)$$

Para o MAE, que calcula o valor absoluto médio entre os mesmos valores, temos a seguinte equação 4.2:

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (4.2)$$

Em que:

- $n$  - número de casos;
- $y_j$  - valores reais;
- $\hat{y}_j$  - valores previstos;

No caso destas métricas, os valores obtidos através do *RMSE* serão sempre superiores aos valores do *MAE*, uma vez que o primeiro tem o benefício de penalizar os erros de maior magnitude, enquanto o segundo utiliza valores absolutos dos erros. Além disso, estas métricas tem a particularidade de no caso dos valores calculados pela *RMSE* serem entre 0 e 1 e menores ou iguais aos valores obtidos pela *MAE*, trata-se de um modelo de alta precisão. No entanto, isto é um caso muito difícil de acontecer, mas fica a nota de que quanto mais próximo o valor calculado pela *RMSE* for do valor calculado pela *MAE*, melhor será o modelo.

Posto isto, e antes de aplicar estas métricas, utilizou-se ainda uma métrica em *python* para cálculo de erros absolutos simples, de forma a que se consiga visualizar de uma forma mais gráfica e rápida a diferença entre os valores reais e previstos, mas neste caso para todos os períodos da previsão. No caso das métricas anteriores, elas contemplam os resultados da solução em geral, e neste caso contempla-se os períodos um a um, tal como se demonstra na figura 4.6.

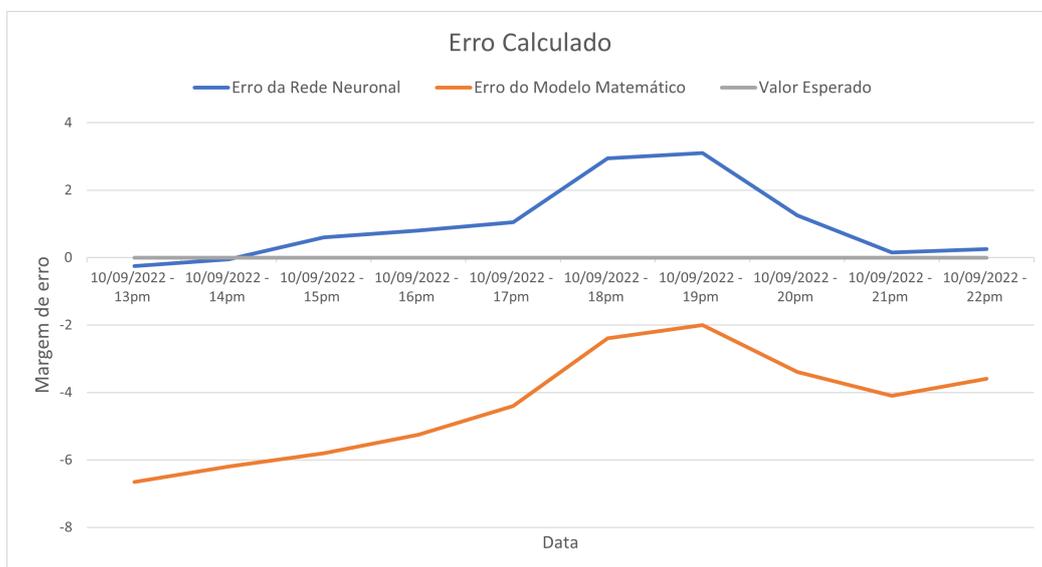


Figura 4.6: Erro calculado para os resultados obtidos.

Analisando o gráfico, e tendo em conta que a cinzento se encontra a linha dos dados reais e em que seria o caso perfeito, encontramos ainda a azul o valor de erro calculado para os valores obtidos através da Rede Neuronal e a laranja os valores obtidos através do Modelo Matemático, e observa-se que ambos os valores são algo

discrepantes em relação aos dados reais. No entanto, observa-se ainda que os dados obtidos pelo Modelo Matemático, são ainda mais diferentes dos valores reais, uma vez que a sua linha nunca se cruza ou toca, com a linha onde estão inseridos os valores obtidos através dos sensores *IoT*. Já no caso dos valores obtidos através da Rede Neuronal, observa-se que tanto no início como no final, as linhas se tocam ou cruzam, o que significa uma maior aproximação entre os valores reais e os valores previstos.

Analisados os valores do gráfico, obtém-se os seguintes valores de erro, para o dia 10 de setembro, entre as 13 e as 22 horas, apresentados na tabela 4.1:

Tabela 4.1: Erro calculado através de métricas simples.

<b>Hora</b>	Erro - Rede Neuronal	Erro - Modelo Matemático
<i>13 horas</i>	-0.25	-6.65
<i>14 horas</i>	-0.05	-6.19
<i>15 horas</i>	0.60	-5.79
<i>16 horas</i>	0.80	-5.25
<i>17 horas</i>	1.05	-4.40
<i>18 horas</i>	2.95	-2.39
<i>19 horas</i>	3.10	-2.00
<i>20 horas</i>	1.25	-3.39
<i>21 horas</i>	0.15	-4.10
<i>22 horas</i>	0.25	-3.59

Estes valores são utilizados para se poder efetuar uma comparação entre os dois modelos desenvolvidos nesta dissertação, e pode ver-se que os valores de erro calculados através de métricas simples, para efeitos de comparação entre estes dois métodos, mostram que o método da aplicação da Rede Neuronal, é bastante mais preciso do que o Modelo Matemático, em praticamente todos os períodos calculados. O maior valor de erro dos resultados da aplicação da Rede Neuronal, é de 3.10, enquanto o menor valor de erro dos resultados da aplicação do Modelo Matemático é de 2.00, verificando-se que mesmo nos piores casos da Rede Neuronal, os seus resultados são praticamente tão precisos quanto os melhores casos da aplicação do Modelo Matemático. Tem-se ainda os erros calculados pelas métricas *RSME* e *MAE* e os seus valores podem ser visualizados na tabela 4.2.

Tabela 4.2: Erro calculado através das métricas *RSME* e *MAE*.

<b>Modelo</b>	Erro - Rede Neuronal	Erro - Modelo Matemático
<i>RMSE</i>	1.913	14.989
<i>MAE</i>	0.605	4.740

Como esperado, os valores obtidos através da métrica *RSME* são superiores aos valores obtidos pela métrica *MAE* e ainda os valores obtidos para o erro calculado para

as previsões do Modelo Matemático superiores ao erro calculado para as previsões obtidas pela Rede Neuronal.

Estas diferenças podem ser explicadas pois os valores calculados através do Modelo Matemático, são na sua maior parte previstos com base em valores também eles já previstos, ou seja usam a sua referência anterior de previsão, para obter um novo valor de previsão. Não obstante, também alguns dos valores usados para os cálculos e que são obtidos através de tabelas, são também eles obtidos para casos genéricos e não estão na maioria dos casos adaptados ao caso real.

No caso da solução inteligente, observa-se que os dados são mais próximos da realidade e isso deve-se ao facto de a aplicação ser treinada previamente com dados reais obtidos através dos sensores *IoT*, sendo esses dados relativos ao espaço de estudo que se quer obter novos resultados e que naturalmente se aproximam mais da realidade. Esta aplicação pode ser mais complexa ainda do que a apresentada, englobando mais condicionantes, e também fornecendo à aplicação *datasets* com maior número de dados relevantes. Como se trata de uma aplicação que utiliza várias ferramentas de Inteligência Artificial, quanto mais dados e histórico esta aplicação tiver, maior eficácia ela terá, uma vez que esta aprendizagem se baseia em dados históricos do local em estudo. Posto isto, além de ser mais eficaz e rápido o uso desta aplicação, é também, como se pode observar, mais preciso que o modelo matemático.

Além da notória diferença dos valores obtidos, e visualizando que de facto o modelo matemático possuiu um erro bastante mais elevado do que a aplicação baseada em redes neuronais, ambas possuem vantagens e desvantagens.

Em relação ao modelo matemático e comparando-o com a aplicação, ele tem a vantagem de se poder efetuar a previsão da temperatura sem ter recurso a uma quantidade tão grande de dados, como no caso da Rede Neuronal. Isto, porque a aplicação necessita de um maior número de dados históricos e de dados para efeitos de treino, que o modelo matemático não necessita. Isto é vantajoso num caso em que não haja dados históricos para se efetuar uma previsão, e nesse sentido o modelo matemático é mais vantajoso.

Já no caso da rapidez de aplicação da solução, o modelo matemático é bastante mais demorado e trabalhoso, uma vez que se tem de recorrer a cálculos matemáticos, na maioria deles com bastantes componentes e no caso de se querer aplicar o método a outro tipo de construção bastante diferente da deste estudo, é necessário ainda recorrer a tabelas para definição de algumas variáveis para o correto cálculo da temperatura. Além disso, é necessário ter alguns conhecimentos matemáticos e tem-se uma maior probabilidade de errar, além dos arredondamentos que podem ser feitos e piorar a eficiência geral do cálculo. Em termos de rapidez, é notório que a Rede Neuronal se torna mais vantajosa.

Em todo o caso, a Rede Neuronal necessita, como já indicado, de um grande número de dados anteriores para que seja o mais eficaz possível, e isso pode ser um problema

em alguns casos. Além disso, é necessário também um computador com recurso a um ambiente de desenvolvimento, logo também alguns conhecimentos gerais de programação para que se possa aplicar esta solução sem problemas.

O objetivo desta solução é atingindo, uma vez que todo este desenvolvimento é bastante abrangente na medida em que caso se tenham bastantes dados históricos ou poucos, a solução continua a ser possível de ser utilizada, uma vez que tanto o modelo matemático como a Rede Neuronal, podem satisfazer as necessidades do utilizador, no entanto sempre com a salvaguarda de que com a Rede Neuronal a sua eficiência será maior.

Com esta solução, é possível modelar termicamente um edifício sem serem conhecidos os seus materiais de construção, uma vez que como se viu ao longo de toda esta dissertação, foi possível obter temperaturas bastante aproximadas da realidade, para as horas seguintes às dos dados inicialmente obtidos. Isto faz com que possamos modelar termicamente uma edifício ou uma divisão de uma habitação, ou outro volume de estudo à escolha, desconhecendo os materiais de construção, uma vez que todo este estudo foi desenvolvido apenas com recurso a dados de temperatura exterior do local, dados visuais que podem ser facilmente obtidos por qualquer pessoas através da observação do local de estudo e dados de temperatura interior do volume de estudo.

Essencialmente, o necessário para modelar termicamente qualquer edifício, é conhecer as suas temperaturas interiores, e desenhar um mapa com todas essas temperaturas conhecidas. No caso deste estudo, existem dados de cada um dos extremos do volume de estudo, o que faz com que seja possível entender que a temperatura no seu centro, será aproximadamente uma média entre as temperaturas dos dois sensores, sendo naturalmente mais elevada a temperatura do sensor próximo da janela, durante o verão, devido aos ganhos solares dos envidraçados, assim como menor temperatura durante o inverno, devido às temperaturas exteriores mais baixas que fazem com que existam perdas de carga térmica para o exterior.

## 4.6 Alternativas à Solução Desenvolvida

Um estudo só faz sentido, quando pode ser comparado com outros estudos dentro da mesma área de estudo ou quando ambos têm o mesmo fim, mesmo que para isso utilizem outros meios. Nesse sentido, esta dissertação, mesmo após comparando os valores entre os dois modelos desenvolvidos, só pode ser válida para efeitos de utilização futura, quando são aplicadas métricas universais, para o mesmo tipo de fundamentos e objetivos.

Tendo em conta o estudo de [10], onde o seu objetivo é prever a temperatura de um íman permanente num motor síncrono através de Redes Neurais, apesar de o estudo ter um destino final diferente, a essência do estudo, baseia-se de igual forma

na previsão de temperaturas por períodos de tempo, baseado em Redes Neurais. Posto isto, e já anteriormente ter chegado à conclusão que a previsão de temperaturas para este estudo é mais precisa quando utilizado a aplicação baseada em Redes Neurais, é assim de igual forma, importante comparar os resultados desta dissertação, com outras anteriormente já desenvolvidas que utilizem os mesmos conceitos e fundamentos, e que naturalmente tenham os seus resultados demonstrados através das mesmas métricas.

Para o cálculo do erro do estudo [10], foi também utilizada a métrica para cálculo de erro de *RMSE*. Neste caso, compara-se apenas os valores obtidos para a Rede Neuronal, os valores são apresentados na tabela 4.3.

Tabela 4.3: Comparação do erro calculado através das métricas *RSME* com o estudo de [10].

<b>Modelo</b>	<b>Erro Próprio</b>	<b>Erro do Estudo de [10]</b>
<i>RMSE</i>	1.913	0.2369

Pode ver-se que o erro obtido para o estudo desta dissertação é superior ao valor do erro obtido para o estudo de [10]. De forma a ter mais termos de comparação, existem ainda valores presentes no estudo de [10], para efeitos de comparação de resultados, desta feita com as duas métricas utilizadas nesta dissertação, e que pode demonstrar melhor os resultados finais deste trabalho.

Na tabela 4.4 são apresentados os valores obtidos através das métricas *RMSE* e *MAE*, para vários métodos de previsão além de Redes Neurais.

Tabela 4.4: Comparação do erro calculado através das métricas *RSME* com o estudo de [10].

<b>Método</b>	<i>RMSE</i>	<i>MAE</i>
<i>SVR<sup>2</sup></i>	0.5094	0.3996
<i>DecisionTree</i>	0.5817	0.4516
<i>Ridge</i>	0.2510	0.1731
<i>RandomForest</i>	0.4937	0.4203
<i>AdaBoosting</i>	0.4937	0.4354
<i>DNN [10]</i>	0.2368	0.1515
<i>Próprio</i>	1.9130	0.6050

Comparando assim os resultados obtidos por outros métodos de previsão de dados, através das mesmas métricas, pode concluir-se que os dados obtidos pelo estudo desenvolvido nesta dissertação, são superiores a todos os outros valores de outros métodos de previsão de dados.



## Capítulo 5

# Conclusão

### 5.1 Apreciação Final

Esta dissertação teve como objetivo, o estudo, desenvolvimento e teste de uma solução inteligente para a modelação térmica de edifícios, onde não se conhecesse os seus materiais de construção. Posto isto, foi efetuado um estudo e revisão bibliográfica ao tema, iniciando a pesquisa em temas como modelação térmica e inteligência artificial. Existem estudos e artigos dentro deste tema, nas mais variadas temáticas, entre a modelação térmica de edifícios até ao controlo térmico através de *Machine Learning*. Estes foram conceitos que foram abordados durante o desenvolvimento da solução, visto ter considerado serem o foco principal por onde o estudo deveria apontar, e que senti que seria uma mais valia concentrar esforços. Conclui-se que a melhor forma de abordar este tema, seria efetuar o estudo do volume de estudo em causa, em termos estruturais e nunca em termos de materiais da sua constituição. Conhecidos os valores das suas dimensões, a sua geolocalização e a sua orientação solar, foram deduzidos alguns valores tabelados, de forma a que pudessem estes ser aplicados no modelo matemático, também este deduzido de forma a encontrar um valor de temperatura interior do edifício, conhecendo apenas os valores de temperatura exterior obtidos através de *datasets* conhecidos.

Concluída a primeira abordagem, partiu-se para o essencial deste estudo, que se centrou em abordar o tema através da Inteligência Artificial, recorrendo assim ao

*Machine Learning* e consequentemente, às Redes Neurais e também ao *Deep Learning*. Estas ferramentas, permitiram treinar um algoritmo de forma a que se obtivessem temperaturas interiores do edifício, apenas também conhecendo os valores de temperatura exterior para a localização em causa.

De forma a comparar estes valores, entre o modelo matemático e as Redes Neurais, recorreu-se a sensores *IOT* de forma a que se pudesse ter uma monitorização 24 horas e em tempo real, da temperatura interior e dos valores de humidade relativa. Estes revelaram-se importantes não só pelo facto de fornecer dados em tempo real, como também foram cruciais para se obterem dados com o objetivo de treinar a aplicação elaborada com base em Redes Neurais.

Obtidos e analisados os dados anteriormente referidos, conclui-se que os valores obtidos pelas Redes Neurais, foram muito mais aproximados e precisos do que os obtidos através do Modelo Matemático. Pode dever-se este facto, devido à questão de no Modelo Matemático não serem consideradas todas as hipóteses de cargas térmicas e ganhos solares, uma vez que foram admitidos casos em que pudessem ter ou não influência, tais como ganhos através de equipamentos eletrónicos existentes ou através da circulação de ar, que neste caso tem a ver com a capacidade de isolamento da habitação em estudo. Além disto, foram também considerados valores tabelados para construções típicas em Portugal, e que neste caso, naturalmente não correspondem em total à verdade, uma vez que cada construção tem o seu tipo de características.

As Redes Neurais apenas tiveram em conta dados reais do volume de estudo, e apenas foi treinada com esses valores, e no resultado final demonstrou-se que de facto esses valores se aproximaram mais da realidade, sendo bastante precisos na sua obtenção. No entanto, estes quando comparados com os valores obtidos por outros métodos de previsão de dados, revelam-se ainda bastante distantes da precisão de outros métodos já desenvolvidos, não só baseados em Redes Neurais, como em cálculos matemáticos ou análise de decisão. Isto demonstra que o modelo pode e deve conter um maior número de amostras e um período mais elevado, de forma a que o treino da Rede Neuronal seja feito de forma mais eficaz e precisa, e para que cada vez mais os valores se aproximem da realidade e reduzam a taxa de erro.

Resta indicar, que de facto o recurso ao *Machine Learning* se revela vantajoso, de mais fácil e rápida resolução e obtenção de resultados. É uma ferramenta que pode e deve ser ainda mais explorada, e que merece ter tempo e dinheiro investido, uma vez que se revela uma vantajosa ferramenta para a modelação térmica de edifícios ou outros volumes que se queiram estudar.

Em todo os momentos do desenvolvimento deste estudo, foram encontrados alguns obstáculos, tais como as melhores Redes Neurais a aplicar neste tipo de estudo, uma vez que existem várias formas e várias arquiteturas deste tipo de ferramenta, em que cada um deles se adequa de melhor ou pior forma ao estudo em causa.

Além deste obstáculo, também a programação deste recurso requereu algum tempo e estudo, uma vez que todas as linhas de código tiveram de fazer sentido, além de que se teve de recorrer a algumas bibliotecas de *python* com recursos essenciais ao bom desenvolvimento da solução e à real obtenção de resultados.

Fica ainda a ressalva de que este projeto pode ainda ser mais interessante na medida em que se possam efetuar estas simulações com recurso a ambientes totalmente controlados, como por exemplo em sistemas adiabáticos e também em sistemas bastante utilizados no dia a dia em todos os sentidos, quer na entrada e saída de pessoas, quer em utilização de equipamentos eletrónicos e até em equipamentos de fornecimento de energia, tais como ar condicionados.

Além disso, também poderia ter sido interessante visualizar o volume de estudo num *software* de simulação de análise térmica e ser também esse mais um fator de comparação para com os valores já obtidos até aqui e visualizar de forma mais gráfica o que acontece também com estas variações de cargas térmicas e temperaturas, mas de uma forma mais visual.

De uma forma geral, foi enriquecedor e vantajoso todo este estudo, uma vez que me permitiu ter contacto com várias áreas e vertentes, desde a engenharia mecânica, a minha formação base, até à engenharia eletrotécnica, desde o estudo térmico e estrutural de um edifício até ao desenvolvimento e programação da solução inteligente. Desta forma, concluo assim mais um grande passo no meu percurso académico, e que seja apenas mais um passo, numa carreira recheada de desafios e novas aprendizagens.

## 5.2 Trabalho Futuro

Sem contabilizar o tempo e estudo investido neste trabalho, podem ser elaborados muitos outros pareceres e evoluções tendo em conta o trabalho feito até aqui. Como apresentado já anteriormente, existem vários estudiosos que fazem desta tema, o seu objeto de estudo central, e existem vários artigos elaborados neste sentido. Não obstante disso, o que se aborda aqui, em termos de utilidade e evolução tecnológica, é bastante relevante quer na área da engenharia mecânica e eletrotécnica, como na engenharia de computadores, uma vez que este estudo, aborda temas não só de Inteligência Artificial, como de desenvolvimento de aplicações que são relevantes quer a nível industrial, quer a nível doméstico, para várias aplicações, desde o conforto térmico até à melhoria da eficiência energética.

No futuro, pode ainda ser desenvolvido, com base nos avanços feitos até aqui, estudos e pareceres relativamente à previsão meteorológica, mas acima de tudo, podem ser desenvolvidas ferramentas que facilitem o trabalho na modelação térmica de edifícios, não só residenciais, como hospitalares e escritórios. Este tipo de trabalho, pode facilitar ainda outras áreas, como as áreas da engenharia civil, uma vez que sendo

previsível de antemão a modelação de um volume, sem ter conhecimento dos seus materiais de construção, pode poupar tempo e dinheiro quer no momento, quer no futuro.

Pode ainda ser feito um investimento neste sentido, para obtenção de novas ferramentas de *Machine Learning*, uma vez que cada vez mais este tipo de ferramenta está a ser explorado e tem cada vez mais preponderância a todos os níveis e promete ser uma das áreas mais relevantes ao redor de todo o nosso dia a dia, desde que acordamos até ao momento em que nos voltamos a deitar. Pode ser um investimento de tempo, estudo e monetário relevante, mas que será de certo recompensado pelos resultados finais.

# Referências

- [1] W. J. Murdoch, C. Singh, K. Kumbier, R. Abbasi-Asl, and B. Yu, “Definitions, methods, and applications in interpretable machine learning,” *Proceedings of the National Academy of Sciences*, vol. 116, pp. 22071–22080, oct 2019. [Citado na página 2]
- [2] Y. Chen, L. K. Norford, H. W. Samuelson, and A. Malkawi, “Optimal control of hvac and window systems for natural ventilation through reinforcement learning,” *Energy and Buildings*, vol. 169, pp. 195–205, 6 2018. [Citado na página 30]
- [3] J. Charles and S. D. Emmanuel, “Application of neural network in prediction of temperature: a review,” *Neural Computing and Applications*, 5 2021. [Citado nas páginas vii, 30 e 31]
- [4] X. Qiuju, N. Ji-Qin, B. Jun, and S. Zhongbin, “A thermal environmental model for indoor air temperature prediciton and energy comsuption in pig building,” *Building and Environment*, 4 2019. [Citado nas páginas vii, 31 e 32]
- [5] X. Zhang, M. Pipattanasomporn, T. Chen, and S. Rahman, “An iot-based thermal model learning framework for smart buildings,” *IEEE Internet of Things Journal*, vol. 7, no. 1, pp. 518–527, 2020. [Citado nas páginas vii, 37 e 38]
- [6] S. ed ASHRAE. Atlanta, 1989. [Citado nas páginas 12, 13, 14, 41, 43 e 71]
- [7] B. Artur, “Modelação do comportamento térmico de edifícios,” *Research Gate*, 6 2022. [Citado nas páginas 48 e 71]
- [8] K. Rohan, “Wheather forecasting with recurrent neural networks in python,” 12 2019. [Citado na página 51]
- [9] I. R. Rahayu Sri Ike, Djamal C Esmeralda, “Daily temperature prediction using recurrent neural networks and long-short term memory,” *IEOM Society International*, no. 1, pp. 518–527, 2020. [Citado na página 52]
- [10] H. Guo, Q. Ding, Y. Song, H. Tang, L. Wang, and J. Zhao, “Predicting temperature of permanent magnet synchronous motor based on deep neural network,” *Energies*, vol. 13, no. 18, 2020. [Citado nas páginas ix, 60, 61 e 71]

- 
- [11] E. Guelpa and L. Marincioni, “Automatic modelling of buildings and thermal substations for large district heating systems,” *Journal of Cleaner Production*, vol. 318, p. 128351, 10 2021. [Citado nas páginas 5 e 71]
- [12] B. Xu, X. Xie, and X. ni Chen, “Implicit method for solving building heat transfer model and its application in energy-saving materials,” *Applied Thermal Engineering*, vol. 206, p. 118062, 4 2022. [Citado nas páginas vii, 5, 6 e 71]
- [13] A. Fouquier, S. Robert, F. Suard, L. Stéphan, and A. Jay, “State of the art in building modelling and energy performances prediction: A review,” *Renewable and Sustainable Energy Reviews*, vol. 23, pp. 272–288, 7 2013. [Citado nas páginas vii, 6, 7, 8 e 71]
- [14] J. Lin, “Mcnnet : Tiny deep learning on iot devices,” pp. 1–12, 2020. T. Lin, “Deep Learning for IoT,” 2020 IEEE 39th International Performance Computing and Communications Conference (IPCCC), 2020, pp. 1-4, doi: 10.1109/IPCCC50635.2020.9391558. [Citado nas páginas vii, 19 e 71]
- [15] M. Abdellatif, J. Chamoin, J. M. Nianga, and D. Defer, “A thermal control methodology based on a machine learning forecasting model for indoor heating,” *Energy and Buildings*, vol. 255, p. 111692, 1 2022. [Citado nas páginas 20 e 71]
- [16] N. Ma, D. Aviv, H. Guo, and W. W. Braham, “Measuring the right factors: A review of variables and models for thermal comfort and indoor air quality,” *Renewable and Sustainable Energy Reviews*, vol. 135, p. 110436, 1 2021. [Citado nas páginas vii, 20 e 71]
- [17] J. W. Moon and S. K. Jung, “Algorithm for optimal application of the setback moment in the heating season using an artificial neural network model,” *Energy and Buildings*, vol. 127, pp. 859–869, 9 2016. [Citado nas páginas 20 e 71]
- [18] D. Mary, S. K., and B. Prashant, “Thermal modelling, exergy analysis, performance of bipv and bipvt: A review,” *Renewable and Sustainable Energy Reviews*, 2 2017. [Citado nas páginas 10 e 71]
- [19] X. Zhou, D. Lai, and Q. Chen, “Evaluation of thermal sensation models for predicting thermal comfort in dynamic outdoor and indoor environments,” *Energy and Buildings*, vol. 238, p. 110847, 5 2021. [Citado nas páginas 11 e 71]
- [20] F. Delorme *et al.*, “Butt-jointed DBR laser with 15 nm tunability grown in three MOVPE steps,” *Electron. Lett.*, vol. 31, no. 15, pp. 1244–1245, 1995. [Citado na página 71]
- [21] Y. Hou, M. Chen, R. Volk, and L. Soibelman, “Investigation on performance of rgb point cloud and thermal information data fusion for 3d building thermal

- map modeling using aerial images under different experimental conditions,” *Journal of Building Engineering*, vol. 45, p. 103380, 1 2022. [Citado na página 71]
- [22] “Evaluation of models and methods to simulate thermal radiation in indoor spaces,” *Building and Environment*, vol. 144, pp. 259–267, 10 2018. [Citado na página 71]
- [23] Y. Lu, Z. Yang, J. Yu, B. Chen, and K. Zhong, “Development of a second-order dynamic model for quantifying impact of thermal mass on indoor thermal environment,” *Journal of Building Engineering*, vol. 42, p. 102496, 10 2021. [Citado nas páginas vii, 11 e 71]
- [24] S. ed ASHRAE, “Machine learning,” 2022. [Citado na página 71]
- [25] C. C. Chatterjee, “Implementation of rnn, lstm and gru,” 2019. [Citado nas páginas vii, 23, 24 e 71]
- [26] Época Negócios, “6 aplicações da iot,” 2022. [Citado na página 71]
- [27] P. Kumar, P. Kashyap, and J. Ali, “Temperature forecasting using artificial neural networks (ann),” *Journal of Hill Agriculture*, vol. 4, pp. 110–112, 12 2013. [Citado nas páginas vii, 22 e 71]
- [28] Nomidl, “What is the future and scope of machine learning?,” 2021. [Citado na página 71]
- [29] P. Gokhale, O. Bhat, and S. Bhat, “Introduction to iot,” vol. 5, pp. 41–44, 01 2018. [Citado nas páginas vii, 18 e 71]
- [30] Z. Yang, D. Eddy, S. Krishnamurty, I. Grosse, P. Denno, Y. Lu, and P. Witherehell, “Investigating grey-box modeling for predictive analytics in smart manufacturing,” p. V02BT03A024, 08 2017. [Citado nas páginas vii, 7, 9 e 71]
- [31] Z. Ghahramani, “Probabilistic machine learning and artificial intelligence,” 02 2015. [Citado nas páginas 16 e 71]
- [32] T. Jiang, J. L. Gradus, and A. J. Rosellini, “Supervised machine learning: A brief primer,” *Behavior Therapy*, vol. 51, no. 5, pp. 675–687, 2020. [Citado nas páginas 17 e 71]
- [33] M. Chen, U. Challita, W. Saad, C. Yin, and m. Debbah, “Artificial neural networks-based machine learning for wireless networks: A tutorial,” 10 2017. [Citado nas páginas vii, 21, 22 e 71]



## Anexo A

# Anexos

[11][12][13][14][15][16][17][18][19][20][21][22][23][6][24][25][26][27][28][7][29][30][31][32][33][10]

### A.1 Código da Aplicação integrada com Redes Neurais

---

```
1 !pip install neuralprophet
2 import pandas as pd
3 from neuralprophet import NeuralProphet
4 from matplotlib import pyplot as plt
5 df = pd.read_csv("/content/drive/MyDrive/data.csv")
6 df.tail()
7 df.Date.unique()
8 df.columns
9 df.dtypes
10 df.reset_index().plot(x='Date', y=['Temperature'], figsize=(15,7),
    grid=True)
11 new_column = df[['Date', 'Temperature']]
12 new_column.dropna(inplace=True)
13 new_column.columns = ['ds', 'y']
14 new_column.tail()
15 n = NeuralProphet()
16 model = n.fit(new_column, freq='D')
17 future = n.make_future_dataframe(new_column, periods=10)
18 forecast = n.predict(future)
```

```
19 forecast.tail()
20 from google.colab import drive
21 drive.mount('/content/drive')
22 plot = n.plot(forecast)
```

---

## A.2 Código da Aplicação para cálculo do Erro

---

```
1 expected = [24.4, 24.7, 25.1, 25.6, 26.2, 27.8, 27.8, 26, 25,
              24.8]
2 predictions = [24.65, 24.75, 24.5, 24.8, 25.15, 24.85, 24.7,
                24.75, 24.85, 24.55]
3 forecast_errors = [expected[i]-predictions[i] for i in range(len(
                    expected))]
4 print('Forecast Errors: %s' % forecast_errors)
```

---

---

```
1 expected = [24.4, 24.7, 25.1, 25.6, 26.2, 27.8, 27.8, 26, 25,
              24.8]
2 predictions = [31.05, 30.9, 30.9, 30.85, 30.6, 30.2, 29.8, 29.4,
                29.1, 28.4]
3 forecast_errors = [expected[i]-predictions[i] for i in range(len(
                    expected))]
4 print('Forecast Errors: %s' % forecast_errors)
```

---





PredictTemperature.ipynb ☆

Arquivo Editar Ver Inserir Ambiente de execução Ferramentas Ajuda [Todas as alterações foram salvas](#)

+ Código + Texto

	Date	MaxTemperature	MinTemperature
27	22/09/2022	28.80	25.20
28	23/09/2022	28.25	24.35
29	24/09/2022	27.95	21.95
30	25/09/2022	27.40	23.40
31	26/09/2022	25.40	22.90

```
[ ] df.Date.unique()
array(['26/08/2022', '27/08/2022', '28/08/2022', '29/08/2022',
       '30/08/2022', '31/08/2022', '01/09/2022', '02/09/2022',
       '03/09/2022', '04/09/2022', '05/09/2022', '06/09/2022',
       '07/09/2022', '08/09/2022', '09/09/2022', '10/09/2022',
       '11/09/2022', '12/09/2022', '13/09/2022', '14/09/2022',
       '15/09/2022', '16/09/2022', '17/09/2022', '18/09/2022',
       '19/09/2022', '20/09/2022', '21/09/2022', '22/09/2022',
       '23/09/2022', '24/09/2022', '25/09/2022', '26/09/2022'],
      dtype=object)

[ ] df.columns
Index(['Date', 'MaxTemperature', 'MinTemperature'], dtype='object')

[ ] df.dtypes
Date          object
MaxTemperature  float64
MinTemperature  float64
dtype: object

[ ] df.reset_index().plot(x='Date', y=['MaxTemperature', 'MinTemperature'], figsize=(15,7), grid=True)
<matplotlib.axes._subplots.AxesSubplot at 0x7fe409974650>
```

29

MaxTemperature  
MinTemperature

Figura A.3: Visualização da Aplicação

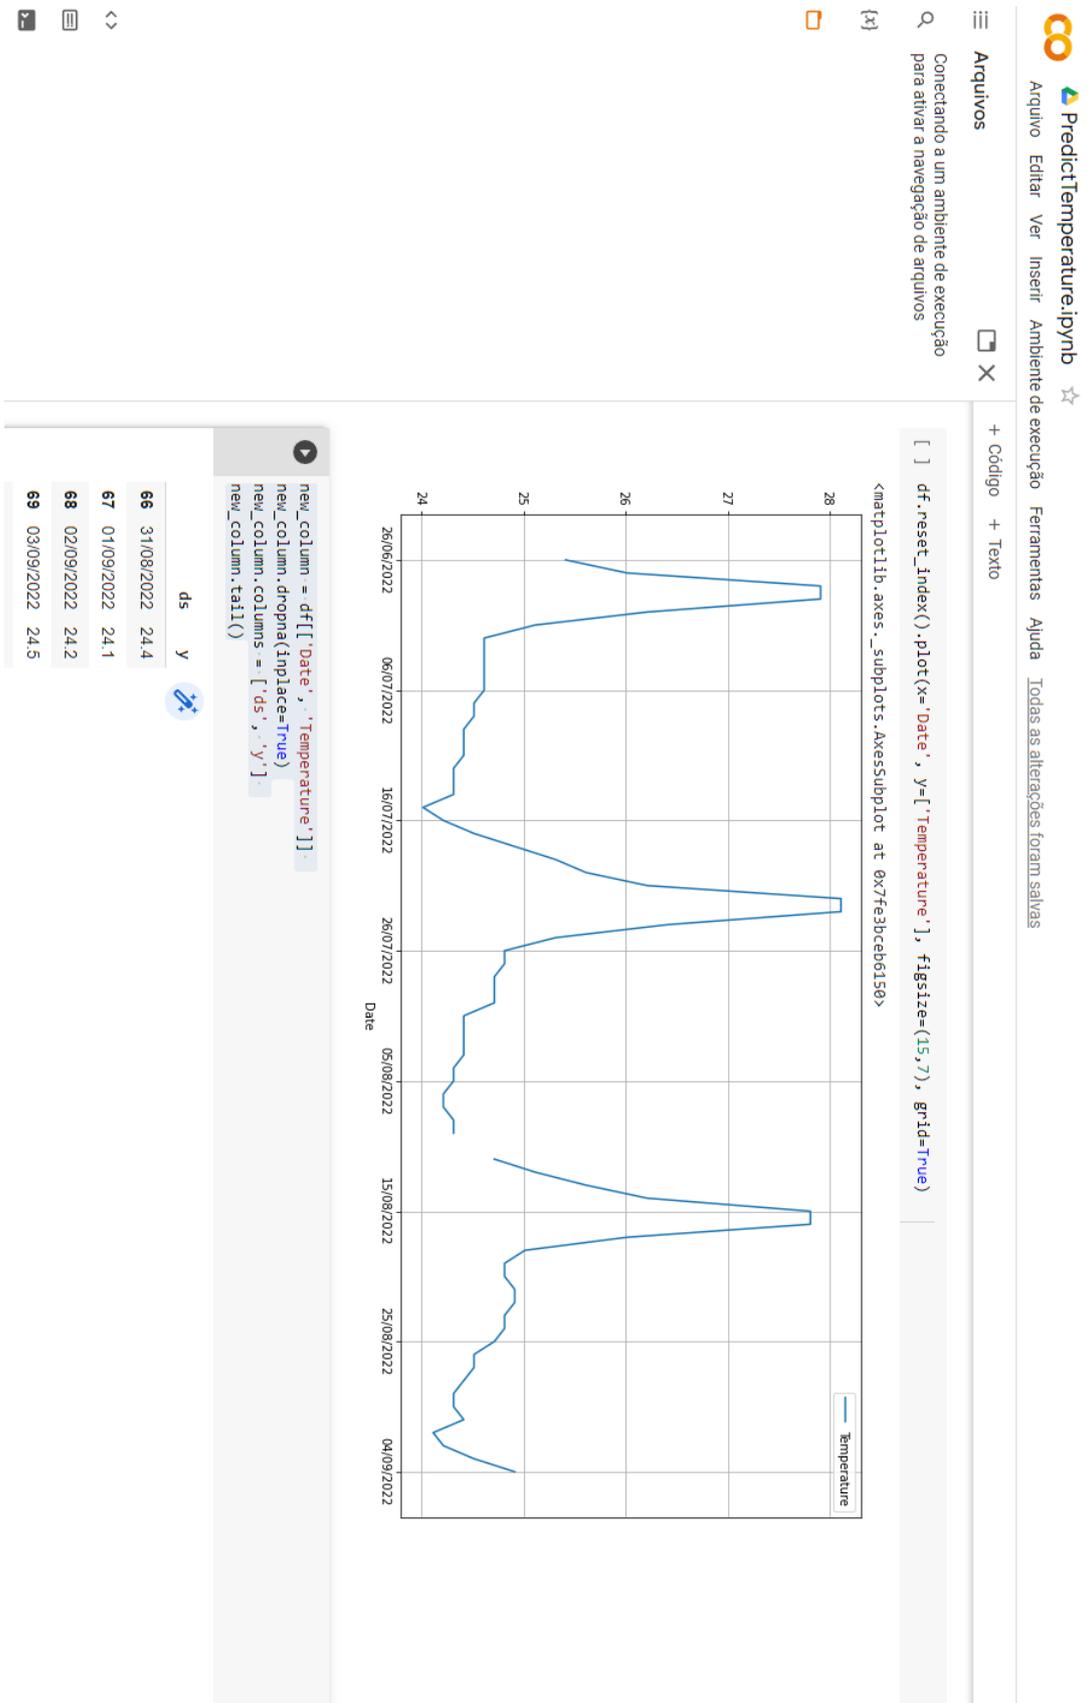


Figura A.4: Visualização da Aplicação



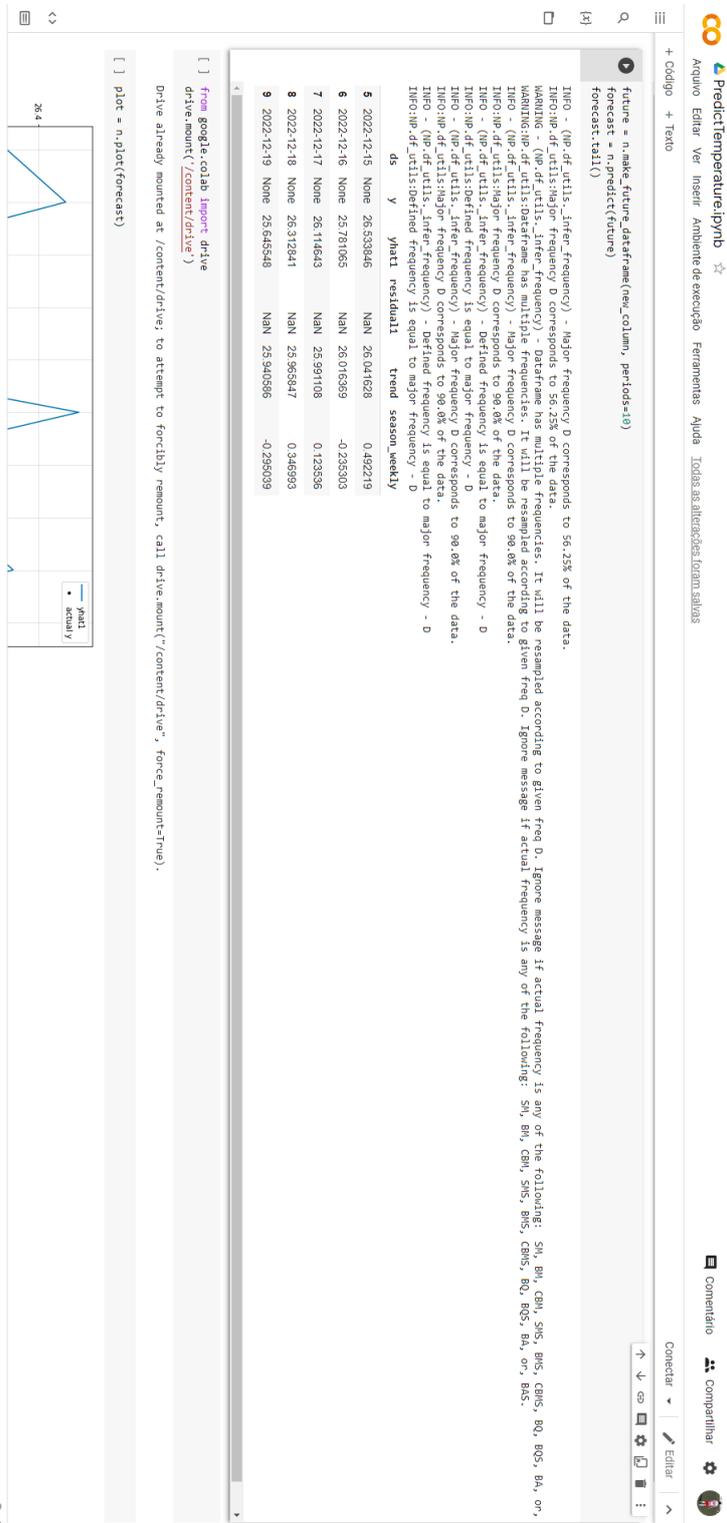


Figura A.6: Visualização da Aplicação

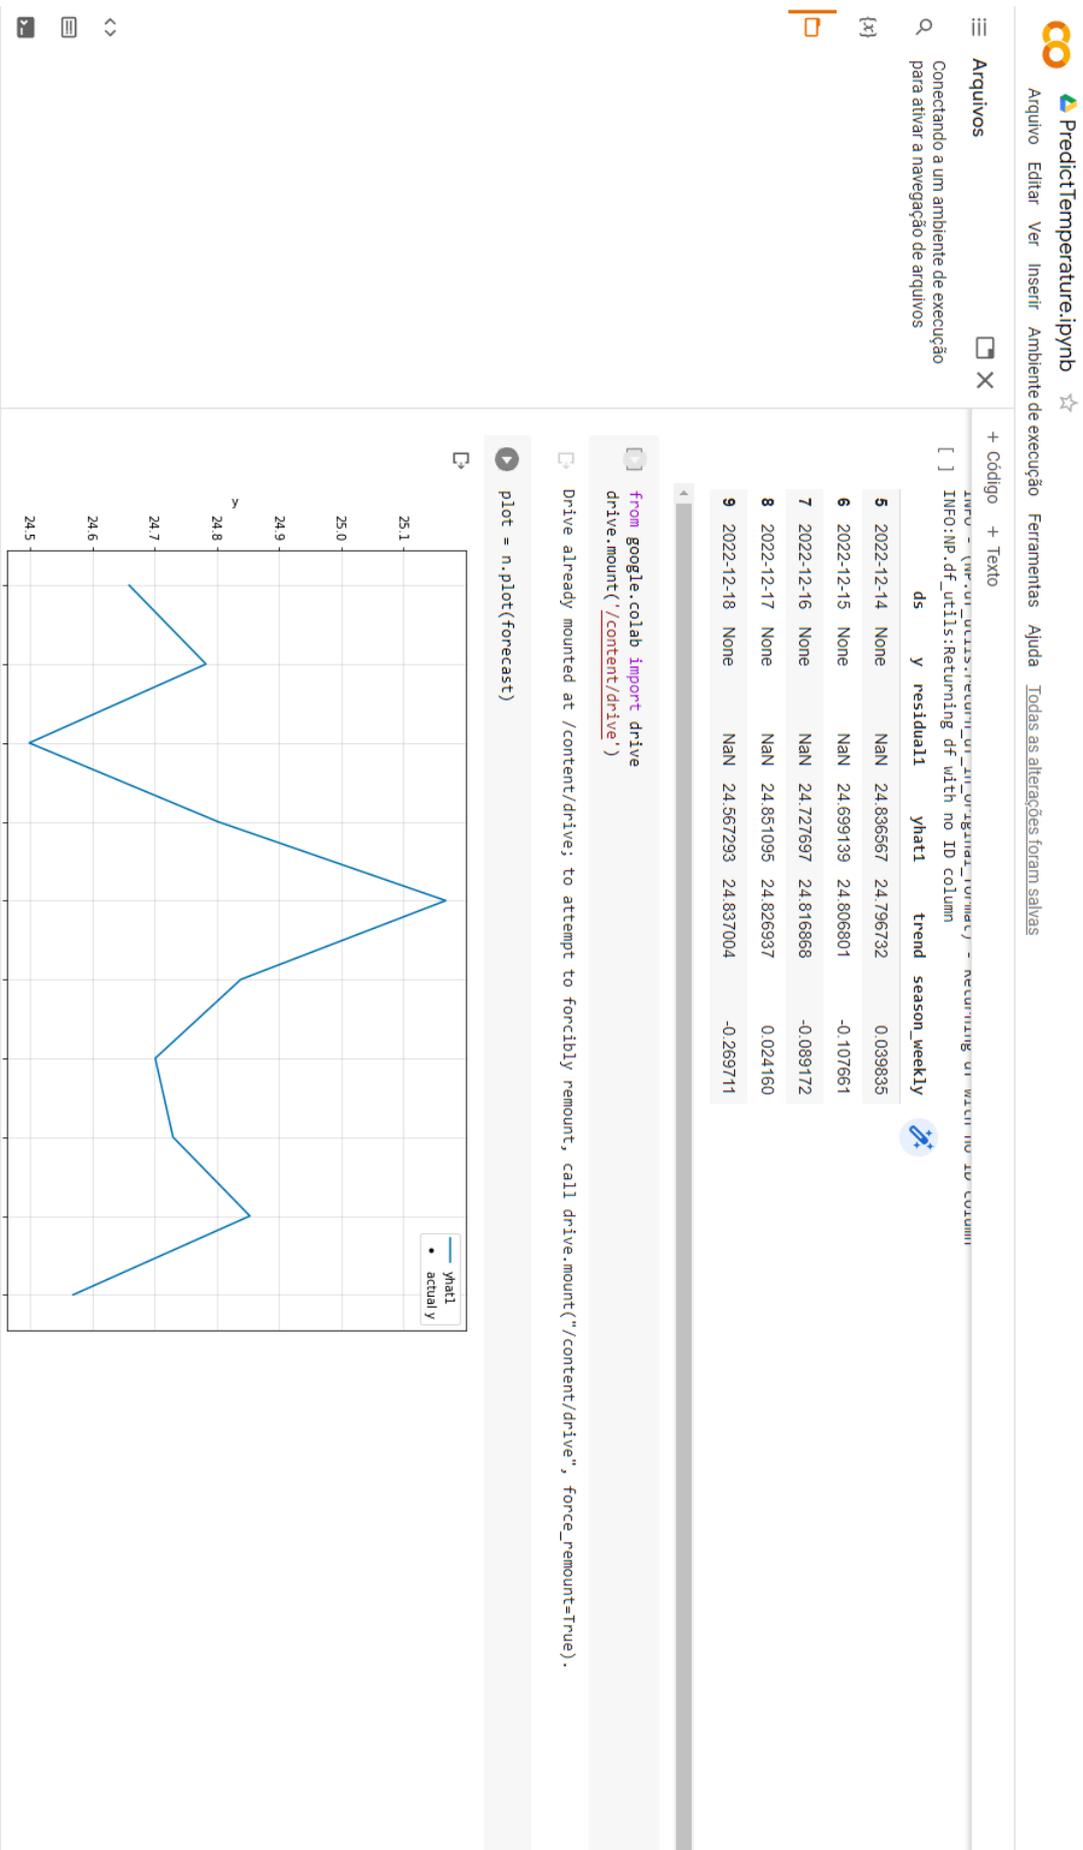


Figura A.7: Visualização da Aplicação