



**Catarina Rebelo Tomás**

Mestrado em Engenharia Eletrotécnica e de Computadores

## **Ocupação Humana no Estabelecimento de Fluxos Energéticos em Edifícios**

Dissertação para obtenção do Grau de Mestre em  
Mestrado Integrado em Engenharia Eletrotécnica e de  
Computadores

Orientador: João Francisco Alves Martins,  
Professor Auxiliar, Faculdade de  
Ciências e Tecnologia da  
Universidade Nova de Lisboa

Júri:

Presidente: Prof. Doutor Tiago Oliveira de Figueiredo Cardoso

Arguente: Prof. Doutor João Miguel Murta Pina



FACULDADE DE  
CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE NOVA DE LISBOA



# Copyright

Modelização do Comportamento Humano no Estabelecimento de Fluxos Energéticos em Edifícios

Catarina Rebelo Tomás – Todos os direitos reservados

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



# Agradecimentos

Um muito obrigado a toda a minha família, principalmente aos meus pais e à minha irmã, por todo o apoio durante esta viagem que foi o ensino superior, pelas palavras apaziguadoras quando necessárias e pela dedicação.

Aos meus amigos de infância por todos os momentos de descontração e desabafo, por me ajudarem a relativizar e a ver de perspetivas diferentes.

Ao meu orientador Professor João Martins, por tentar sempre manter-me empenhada e focada na realização da presente dissertação, por me mostrar o rumo.

À Fundação Calouste Gulbenkian pela prontidão a ceder os dados necessários à realização desta dissertação, e pela disponibilidade dos seus colaboradores.



# Resumo

Nos últimos tempos, a preocupação ambiental, passou a ser um tema recorrente na sociedade. A consciência coletiva da limitação do planeta em recursos naturais tem mostrado a necessidade de alterar os comportamentos no sentido de reduzir desperdícios, e conseguir objetivos do dia-a-dia de forma mais eficiente e menos penalizadora do já frágil equilíbrio ecológico.

Os consumos energéticos, e especificamente os consumos em edifícios, contribuem de forma significativa para o desequilíbrio ambiental pelo que, cada vez mais, se assiste a um aumento da preocupação com a eficiência energética em edifícios e a consciência dos benefícios que daí podem resultar. A eficiência energética está intimamente relacionada com o não desperdício de energia. Para que não haja desperdício de energia é necessário saber onde essa energia é consumida bem como os fatores que influenciam o consumo.

Há já algum tempo que se fazem estudos cujo principal objetivo é prever o consumo de energia num edifício, através da análise de um conjunto de variáveis, normalmente meteorológicas. Mais recentemente começam a surgir novos estudos nesta área, que consideram outro tipo de variáveis, nomeadamente variáveis relacionadas com o comportamento humano, que devidamente tratadas podem modelizar esse mesmo comportamento. Conseguir prever o consumo de um edifício de uma forma mais rigorosa tendo em consideração, não só fatores construtivos ou meteorológicos, mas também fatores resultantes de comportamentos das pessoas, será uma ferramenta preciosa em termos de projeto ou de exploração dos edifícios.

Até que ponto a variável humana é importante na previsão de consumos energéticos? É a esta pergunta que a presente dissertação tenta responder. Para tal apresenta um método de estudo, que utiliza redes neuronais, dividido em etapas.

Primeiramente é necessário conhecer as variáveis existentes num edifício de estudo, selecionar quais as que são pertinentes na previsão dos consumos e porquê. Em seguida é preciso prever a energia consumida através da análise das variáveis.

Palavras-chave: Previsão de Consumos, Ocupação, Coeficientes de Correlação, Componentes Principais, Redes Neuronais.



# Abstract

In recent times, the environment awareness became a recurrent topic in the society. The global awareness of natural resources limitations has shown the need to change the behaviors to reduce waste and to achieve everyday goal in a more efficient and less damaging to the already fragile ecological balance.

Energetic consumption, and more specifically energetic consumption in buildings, contributes significantly to the environment imbalance, so, we are witnessing an increased concern with energy efficiency in buildings and awareness of the benefits that can result. The energetic efficiency is intimately connected to no waste of energy policy. To have no waste of energy it's necessary to know where that energy is being consumed and what are the factors affecting the consumption.

Since long time there have been many studies, where the main goal is to predict the energy consumption of a building through a set of variables, mainly related with weather. Lately begin to emerge new studies in this area that take into account a new kind of variables related to human behavior, that if correctly handled can modeling that behavior. To be able to predict the energy consumption of a building in a more accurate way, having in consideration not only constructive or weather factors, but also factors that result from human behavior, will be a precious tool when it comes to project or operation of buildings.

How important is the human variable in the prediction of energy consumption? This is the question that the present dissertation tries to answer. To do so a study method is presented, using neural networks, divided into stages.

First is necessary to know the variables available in a study building, then we need to select the important ones in the prediction on energy consumption and why. After we need to predict the energy consumption using the selected variables.

Keywords: Forecast of consumption, Occupation, Correlation Coefficients, Principal Component, Neural Networks.



# Índice de matérias

Copyright .....	iii
Agradecimentos.....	v
Resumo .....	vii
Abstract.....	ix
Índice de matérias .....	xi
Índice de figuras .....	xiii
Índice de tabelas .....	xvii
Acrónimos.....	xix
Introdução.....	2
Motivação .....	4
Objetivos.....	5
Estrutura .....	5
Estado de Arte.....	6
Metodologias .....	12
3.1 Redes Neurais Artificiais .....	12
3.2 Métodos de escolha de variáveis de entrada.....	15
3.2.1 Principal Component Analysis.....	15
3.2.2 Coeficientes de Correlação de <i>Perason</i> .....	15
Casos de estudo.....	18
4.1 Caracterização dos Edifícios.....	18
4.1.1 Edifício 10 da Faculdade de Ciências e Tecnologias .....	18
4.1.2 Edifício da Fundação Calouste Gulbenkian .....	19
4.2 Variáveis.....	19
4.2.1 Coeficientes de Correlação de <i>Pearson</i> .....	22
4.2.2 Principal Component Analysis.....	24
4.3 Redes Neurais Artificiais .....	26
4.3.1 Rede Neuronal Semanal .....	27

4.3.1 Rede Neuronal de Fim-de-semana.....	39
Discussão.....	50
Conclusão.....	56
Bibliografia.....	58

# Índice de figuras

Figura 3.1 - Modelo não-linear de um neurónio [15].....	13
Figura 3.2 - Arquitetura da rede neuronal usada em [5].....	14
Figura 3.3 - Gráficos exemplo dos diversos tipos de correlação [14].....	16
Figura 4.4 - Arquitetura da rede.....	26
Figura 4.5 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT.....	27
Figura 4.6 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT.....	28
Figura 4.7 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG.....	28
Figura 4.8 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013 FCT.....	29
Figura 4.9 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Setembro a Dezembro 2012 FCT.....	30
Figura 4.10 – Erro de Previsão, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Setembro a Dezembro 2012 FCT.....	31
Figura 4.11 – Consumo efetivo de energia vs consumo de energia previsto, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Fevereiro de 2013 FCT.....	31
Figura 4.12 – Erro de previsão, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Fevereiro de 2013 FCT.....	32
Figura 4.13 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Janeiro a Fevereiro de 2013, Teste Fevereiro de 2013 FCT.....	33
Figura 4.14 - Erro de previsão, Aprendizagem Janeiro a Fevereiro de 2013, Teste Fevereiro de 2013 FCT.....	33
Figura 4.15 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Janeiro a Fevereiro de 2013, Teste Setembro a Dezembro de 2012 FCT.....	34
Figura 4.16 – Erro de previsão, Aprendizagem Janeiro a Fevereiro de 2013, Teste Setembro a Dezembro de 2012 FCT.....	34
Figura 4.17 – Consumo efectivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT.....	35

Figura 4.18 – Erro de Previsão, Aprendizagem Setembro a Dezembro 2012, Treino Setembro a Dezembro 2012 FCT.....	36
Figura 4.19 – Consumo efectivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG.....	36
Figura 4.20 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT .....	37
Figura 4.21 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT.....	38
Figura 4.22 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012, FCG.....	38
Figura 4.23 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012, FCG.....	39
Figura 4.24 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT .....	40
Figura 4.25 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012.....	41
Figura 4.26 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013 .....	41
Figura 4.27 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013 .	42
Figura 4.28 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG .....	42
Figura 4.29 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT .....	43
Figura 4.30 – Erro de previsão, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT.....	44
Figura 4.31 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Fevereiro 2013 FCT.....	44
Figura 4.32 – Erro de previsão, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Fevereiro 2013 FCT .....	45
Figura 4.33 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Janeiro a Fevereiro 2013, Teste Fevereiro 2013 FCT .....	45
Figura 4.34 – Erro de previsão, Aprendizagem Janeiro a Fevereiro 2013, Teste Fevereiro 2013 FCT .....	46

Figura 4.35 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Janeiro a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT .....	47
Figura 4.36 – Erro de previsão, Aprendizagem Janeiro a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT .....	47
Figura 4.37 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT .....	48
Figura 4.38 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT .....	48



# Índice de tabelas

Tabela 4. 1 - Variáveis disponíveis FCT .....	20
Tabela 4. 2 - Ocupação Semanal do DEE .....	21
Tabela 4. 3 - Variáveis Disponíveis FCG .....	22
Tabela 4. 4 - Coeficientes de Correlação FCT .....	23
Tabela 4. 5 - Coeficientes de Correlação FCG .....	23
Tabela 4. 6 - Componentes e Variações FCT .....	24
Tabela 4. 7 - Componentes principais FCT .....	24
Tabela 4. 8 - Componentes e Variações FCG .....	25
Tabela 4. 9 - Componentes principais FCG .....	25
Tabela 5. 1 - Comparação dos Resultados das Redes Semanais FCT .....	50
Tabela 5. 2 - Comparação dos resultados das redes de fim-de-semana .....	522
Tabela 5. 3 - Comparação dos Resultados das Redes Semanais FCG .....	533
Tabela 5. 4 - Comparação dos Resultados das Redes de Fim de Semana FCG .....	544



# Acrónimos

AIE – Agência Internacional de Energia

ANFIS - Adaptive Network-based Fuzzy Inference System

ARIMA - Auto-regressive Integrated Moving Average

AVAC – Aquecimento, Ventilação, Ar Condicionado

DEE – Departamento de Engenharia Eletrotécnica

FCG – Fundação Calouste Gulbenkian

FCT – Faculdade de Ciências e Tecnologias

FNN - Fuzzy Neural Network

HANFIS - Hierarchical Adaptive Network-based Fuzzy Inference System

Hybrid GA-Hanfis Model - Hybrid Genetic Algorithm-hierarchical Adaptive Network-based Fuzzy Inference System

IEA – International Energy Agency

MLP – Multi-layer Perceptron

PCA – Principal Component Analysis

PT – Posto de Transformação

UTA – Unidade de Tratamento de Ar

WBCSD – The World Business Council for Sustainable Development



# Capítulo 1

## Introdução

A eficiência energética em edifícios é um tema cada vez mais pertinente e atual [1]. Temas como as alterações climáticas, a emissão de CO<sub>2</sub> e a garantia de uma continuidade no fornecimento global de energia, são temas que se encontram na ordem do dia para os governos mundiais.

As sociedades modernas estão a tornar-se cada vez mais dependentes de abastecimentos confiáveis e seguros de energia elétrica, de modo a poderem sustentar o crescimento económico e a prosperidade da sua comunidade [2]. Assim, prevê-se que a necessidade de energia global crescerá cerca de um terço até 2035. No entanto, cada vez mais, as políticas utilizadas podem influenciar este crescimento no sentido de o tornar sustentável e de ter um menor impacto ambiental. A procura cresce para todas as formas de energia, no entanto as fontes de energia com baixo índice de emissão de carbono tendem, elas próprias, a crescer (em cerca de 40%) [1].

Hoje em dia a diminuição dos consumos energéticos, bem como o caminho para um paradigma de sustentabilidade, é obrigatório. Dados recentes apontam para o facto de mais de 40% dos consumos de energia se deverem a gastos em edifícios [3]. Se considerarmos ainda o elevado crescimento ao nível da construção civil, quer na China, quer na Índia, este assunto requer uma especial atenção por parte dos governantes mundiais. Assim, é possível perceber que uma melhor gestão dos consumos de energia em edifícios terá um impacto significativo na redução desses mesmos consumos [3].

A Agência Internacional de Energia (AIE) prevê que, em 2030, o consumo de energia pelos edifícios compreenderá cerca de metade do consumo total em energia [3]. Além do investimento energético, uma adequada gestão de energia nos edifícios tem uma implicação direta na redução da emissão de CO<sub>2</sub> para a atmosfera. Ou seja, edifícios com uma eficiente gestão da energia limitam a emissão de CO<sub>2</sub>, melhoram a qualidade do ar interior bem como o bem-estar social [3], mostrando assim que a eficiência energética tem repercussões positivas a diversos níveis.

Para Portugal, a AIE refere, como objetivo, uma redução de 25% do consumo de energia primária até 2020, tendo este objetivo sido definido em 2013. Se considerarmos os dados disponíveis, nomeadamente no portal da PORDATA [4] percebemos que, desde 2005 (altura em que atingiu o valor mais elevado desde 2000) este consumo tem vindo a baixar (de 27.087 tep em 2005 para 22.496 tep em 2011). No entanto, para continuar na persecução deste objetivo, novas medidas terão de ser implementadas e novos esforços terão de ser feitos. Um outro dado de referir relativamente ao

consumo de energia primária tem a ver com o facto da produção de energias renováveis, que tem vindo a aumentar de 30,9% em 2000 para 47,6% em 2011 [4].

Como supracitado, o consumo de energia em edifícios apresenta valores bastantes elevados, a nível mundial. Em Portugal, se verificarmos os dados disponibilizados pela PORDATA, constatamos que, no que diz respeito ao consumo de energia elétrica, este tem vindo a aumentar de  $39 \times 10^9$  kWh para  $49 \times 10^{11}$  kWh. E, com uma observação mais cuidada, verificamos que 5,5% do consumo total de energia elétrica em Portugal, em 2011, se refere a Edifícios do Estado.

Assim, e tentando ir ao encontro das preocupações, não só nacionais como também mundiais, a presente dissertação procurou desenvolver um modelo com base nos dados disponíveis, que permitisse correlacionar o consumo de energia com um conjunto de dados disponíveis passíveis de influenciar os consumos energéticos do edifício em análise. A energia consumida num edifício é uma função dependente de vários fatores. Esses fatores podem ser tanto externos como internos, externos como por exemplo as condições meteorológicas e internos como por exemplo o comportamento dos utilizadores.

Existem já há bastante tempo programas capazes de fazer a previsão do consumo energético num edifício, tendo em conta os fatores meteorológicos, a novidade que tem vindo a ser explorada nos últimos anos é a introdução de uma nova variável, o comportamento humano [5, 6]. Variável essa bastante difícil de modelizar, uma vez que o nosso comportamento não é estático e que depende de muitos fatores. Para tal pode-se ter em conta o mais essencial, a presença ou não de utilizador.

Depois de se ter uma previsão precisa do consumo de energia num dado edifício é possível tomar decisões e delinear estratégias que viabilizem a redução dos consumos. Uma vez que o consumo de energia em edifícios está diretamente relacionado com o comportamento dos seus utilizadores, uma estratégia de sensibilização dos mesmos para questões como o impacto do consumo energético nos custos do edifício e no ambiente, poderá trazer uma utilização responsável.

# Motivação

O ponto de partida para a realização desta tese foi o facto de vivermos num mundo cada vez mais exigente em termos de consumos energéticos, por um lado, e em relação à otimização de recursos e à melhoria contínua da sua eficiente utilização, por outro.

A sociedade em que vivemos é uma sociedade cada vez mais preocupada com a utilização sustentada dos recursos de que dispomos, e por isso opta por, cada vez mais, pensar em formas eficazes de promover essa mesma utilização.

A eficiência energética em edifícios é um tema cada vez mais atual e uma preocupação mundial, presente em organismos como *The World Business Council for Sustainable Development* (WBCSD), do qual fazem parte 30 países que partilham compromissos com a promoção de um desenvolvimento sustentável, nomeadamente através da participação em diversos projetos (de entre os quais a Eficiência Energética em Edifícios) [3].

Tendo em conta que, tal como referido na introdução, os edifícios são responsáveis por mais de 40% do uso de energia e considerando que, no caso específico de Portugal, os edifícios do estado são responsáveis por 5,5% do consumo total de energia elétrica, e que reduzir este tipo de consumo energético requer que sejam ultrapassadas diversas barreiras, nomeadamente organizacionais, financeiras e comportamentais, parece um ponto de partida interessante para o desenvolvimento desta dissertação o estudo da previsão de consumos num determinado edifício, de forma a perceber quais os fatores que influenciam os consumos neste mesmo edifício.

Assim, considerando a importância desta temática, parece um importante passo a dar, poder canalizar alguns conhecimentos na área da energia, para um trabalho que tivesse, não só um propósito de aprofundamento de conhecimento teórico, mas também fosse em si um projeto que pudesse trazer alguma utilidade no que diz respeito à utilização sustentada da energia, ou seja que encerrasse em si uma componente teórica, de estudo mais aprofundado relativamente ao tema, e uma possibilidade de aplicação prática daí decorrente.

# Objetivos

O principal objetivo da presente dissertação é fazer a previsão do consumo energético de um edifício, tendo em conta um conjunto de variáveis, das quais se destaca a ocupação do mesmo. De forma a atingir o objetivo principal, existe primeiro um leque de objetivos a serem verificados.

Primeiramente é necessário verificar a influência de cada variável no consumo de um edifício, através de testes capazes de verificar a correlação existente. Em seguida é necessário aplicar o modelo escolhido às variáveis de entrada para prever uma variável de saída.

# Estrutura

A dissertação divide-se em capítulos e subcapítulos nos quais se vão descrevendo as diferentes etapas de execução da tese, apresentando explicações sempre que necessário.

O primeiro capítulo, que contém a introdução, motivação e objetivos, introduz o tema da dissertação, expondo o interesse e motivo pelo qual este tema foi escolhido como objeto de estudo. Nos objetivos descrevem-se as metas, o que se pretende alcançar com o presente estudo e consequente dissertação.

No capítulo do Estado de Arte são apresentados vários trabalhos já realizados na área do tema da dissertação, é possível ficar com uma perspetiva teórica do que tem sido feito nesta área e quais os pontos que se encontram em desenvolvimento.

Seguidamente são apresentadas as metodologias utilizadas para a dissertação..

Por último são dados a conhecer os resultados, no capítulo com o mesmo nome, onde são apresentados os testes utilizados, os respetivos resultados. Neste capítulo encontram-se também os comentários a esses mesmos resultados.

# Capítulo 2

## Estado de Arte

Por questões económicas e de sustentabilidade, nas últimas décadas, tem-se verificado um aumento da preocupação com a eficiência energética, o que levou a um incremento na realização de estudos capazes de prever os consumos de energia e logo melhorar a sua utilização. No que concerne aos edifícios, e em complemento de todas as ações de racionalização dos consumos, recentemente, começou a ser tomada em conta uma variável como tendo um papel crucial nos gastos energéticos: a ocupação dos mesmos.

A principal linha de orientação para o presente trabalho relaciona-se com a **previsão de consumos**. Para que seja possível prever os consumos energéticos têm vindo a ser realizados diversos estudos. Estes estudos consideram diferentes variáveis de entrada para poderem chegar a uma variável de saída. As “variáveis de saída” não terão de ser sempre as mesmas, muito embora todas tenham de se relacionar com os consumos energéticos. A título de exemplo refira-se que, em [7] é considerada como variável de saída o consumo diário de energia, em [8] o consumo energético mensal, em [9] a variável de saída é a carga de refrigeração num dia ou numa fração do dia e em [10] pretende-se apenas prever o consumo de ar condicionado.

Na previsão de consumos energéticos, existe uma grande variedade de métodos utilizados, desde lógica *fuzzy* a redes neuronais, ou mesmo sistemas híbridos que extraem o que de melhor há em dois ou mais métodos. Ultimamente, nota-se alguma preferência pelo uso de redes neuronais, devido ao facto de possuírem características particulares que são vantajosas para o objetivo. Em [11] e [5] destacam-se algumas dessas características, como por exemplo, quando se trabalha com um historial de dados incompleto, a capacidade de aprendizagem com exemplos (capacidade de adaptação), a não-linearidade e a sua robustez. Contudo, as redes neuronais não apresentam apenas vantagens. Como alguns pontos menos favoráveis, refira-se, a título de exemplo, limitações na utilização em sistemas lógicos e aritméticos [11].

Verifica-se uma vasta utilização de redes neuronais em estudos que têm como objetivo debruçar-se sobre a previsão de consumos de energia. Em [8] o método escolhido para fazer a previsão do consumo foi uma rede neuronal, em que a diferença para outros métodos foi o algoritmo de treino escolhido. Este método apresentou melhores resultados que outros, com erros na ordem dos 5%, uma vez que o número de parâmetros a alterar para construir o modelo foram menores.

Embora a grande maioria dos estudos se limite a considerar as condições meteorológicas, existem alguns que vão mais além e consideram outro tipo de variáveis de entrada, como nos casos de [10,

12, 13], Em [12] são consideradas como variáveis de entrada os parâmetros de previsão do tempo, os dias tipo e os dias com eventos especiais. Já em [10] são considerados os raios de humidade e a temperatura de bolbo seco<sup>1</sup> para o período de tempo em análise. Estes modelos incorporam características de outros modelos estudados, sendo então denominados por modelos híbridos.

O modelo híbrido apresentado em [10] é o Hybrid GA-Hanfis Model e baseia-se no ANFIS com um atributo extra – a hierarquia, e num algoritmo genético. Por ser um modelo híbrido, utiliza muitas características de modelos já conhecidos e acrescenta outras. As variáveis de entrada de cada camada são selecionadas com base no significado de cada uma para a previsão de energia. Assim, as três variáveis mais importantes são a temperatura média do dia e o consumo de ar-condicionado dos dois dias anteriores, que ficam assim colocadas na primeira camada. A temperatura média do dia anterior e o consumo de há três dias são as menos importantes e situam-se numa segunda camada. Por último, a temperatura do segundo e terceiro dias anteriores são as variáveis de entrada da terceira e última camada. A utilização de programação genética tem como objetivo minimizar os erros de previsão associados ao HANFIS, mas é devida à otimização que o HANFIS faz em cada submodelo que este modelo tem melhor desempenho em termos de capacidade de adaptação.

Em [12], onde se pretendem melhorar os resultados ao fazer uma maior especificação do tipo de dia, utilizou-se como modelo uma rede neuronal associada a lógica fuzzy (FNN). Contudo, nos últimos anos tem-se assistido a uma tendência de menor uso da lógica fuzzy. Trata-se de uma rede neuronal simples, de três camadas que utiliza o *backpropagation type gradient descent rule* como algoritmo de aprendizagem. Em vez de utilizar diferentes rede neuronais utiliza o fuzzy para diferenciar os vários tipos de dia. Os resultados foram melhores do que os apresentados em trabalhos anteriores, apresentando maior erro nos fins de semana, mas melhorando muito a previsão em feriados.

Um caso muito diferente dos descritos até agora acontece em [13] onde se combina o método *Dynamic Grey* com programação genética. Após avaliar o desempenho do novo método, conclui-se que supera os modelos nos quais se baseia, e outros, como o ARIMA, com uma melhor capacidade de previsão e um erro associado inferior.

Em [5] não é feita uma previsão total da energia necessária num edifício, mas sim da energia necessária para arrefecimento do mesmo. O método adotado foi uma rede neuronal. Existem vários modelos de redes neuronais e o escolhido neste caso particular foi o *multi-layer perceptron* (MLP).

O facto de se ter dividido o processo em três simulações, proporcionou uma melhor percepção do quanto importante são os dados sobre a ocupação do edifício, uma vez que a simulação que se aproximou mais com a realidade foi a terceira, ou seja aquela que incluía a ocupação do edifício como variável de entrada. Ainda assim é feita uma observação sobre a possibilidade de se

---

<sup>1</sup> Temperatura de bolbo seco é a temperatura medida por um termómetro vulgar de mercúrio, não sendo por isso influenciada pela humidade relativa do ar.

acrescentar o comportamento dos utilizadores aos fatores internos, com o intuito de obter ainda uma melhor precisão.

Em [6], tal como em [5], é feita uma previsão da energia necessária para o arrefecimento de um edifício universitário, em vez de uma estimativa para a energia total. Foi decidido, mais uma vez, utilizar uma rede neuronal de 3 camadas, sendo que a primeira é a camada de entrada, onde se encontram todas as variáveis de entrada, tanto externas, fatores climáticos externos ao edifício, como internas, variáveis dependentes do comportamento desempenhado pelos utilizadores dos edifícios. A segunda consiste na camada oculta onde se encontram os neurónios da rede, e, por último a terceira é a camada de saída, onde se pretende obter o consumo energético dos chillers. A rede neuronal adotada baseou-se no algoritmo Levenberg-Marquardt back-propagation.

Na realização de um modelo de previsão de consumo devem ter-se em consideração duas etapas fundamentais: a primeira consiste em decidir quais as variáveis passíveis de influenciar a variável dependente (a que queremos prever), neste caso o consumo de energia. A escolha das variáveis de entrada pode fazer a diferença entre uma boa e uma má previsão. Em seguida é necessário escolher o método a aplicar, para se conseguir obter um valor o mais preciso possível para a variável de saída.

Relativamente à escolha das variáveis de entrada, estas dividem-se em dois tipos: fatores externos e fatores internos. Grande parte da bibliografia considera apenas fatores externos para efeitos de previsão de consumos energéticos que descrevem as condições meteorológicas. Para tal, alguns fazem mesmo um levantamento exaustivo das mesmas. Por exemplo, em [7-9, 14, 15] consideram-se apenas variáveis de entrada relacionadas com as condições meteorológicas, variando em número e tipo, sendo a temperatura exterior comum a todos.

As variáveis de entrada podem variar de estudo para estudo. Em [7] verifica-se um maior número de variáveis de entrada (quatro): temperatura exterior, humidade relativa, radiação solar global e radiação solar difusa. A variável de saída é semelhante em todos os casos: consumo diário total. Através do estudo referido em [7] foi possível concluir que o uso de um maior número de variáveis de entrada diminui o erro entre o valor previsto pelo modelo e o valor efetivo. Relativamente ao método utilizado, a escolha recaiu numa rede neuronal artificial de três camadas. Este tipo de arquitetura é amplamente usado nos estudos de previsão de energia, como já foi referido anteriormente.

Já em [8], além de serem consideradas menos variáveis de entrada (temperatura, humidade relativa e radiação solar) foram também considerados os valores por mês, sendo a variável de saída o consumo energético mensal.

Em [14] considerou-se que a temperatura é a variável de entrada que tem o papel mais importante no que diz respeito à precisão de consumos. Assim, consideraram-se neste estudo, como variáveis de entrada, a temperatura máxima, média e mínima do dia de previsão, bem como a temperatura média do dia anterior

Também em [9] apenas se considerou a temperatura como variável de entrada. Neste caso consideraram-se medições horárias de temperatura nas 24h do dia anterior ao que se pretende prever. A variável de saída consiste na carga de refrigeração numa hora específica ou em todo o dia.

Numa abordagem semelhante a alguns casos já mencionados, em [10] consideraram-se como variáveis de entrada a temperatura média do dia a prever e dos três dias anteriores, acrescentando outra variável: o consumo do ar condicionado nos três dias anteriores. Neste caso, considerou-se como saída apenas o consumo do ar condicionado.

Em [12] às variáveis relacionadas com as condições meteorológicas, máximo e mínima da temperatura média e indicação de chuva, acrescentou-se a variação sazonal, o dia da semana e o efeito dia especial. Pretendeu-se assim melhorar os resultados ao fazer uma maior especificação do tipo de dia.

Por outro lado, em [13] as variáveis escolhidas são relativamente diferentes das mencionadas até agora, onde se considera apenas como variável de entrada os dados dos consumos anuais em determinado intervalo de tempo. Os resultados mostram melhorias relativamente a outros métodos utilizados.

Em [5] as variáveis de entrada são divididas em fatores externos e fatores internos. As variáveis foram utilizadas em 3 simulações distintas, sendo que na simulação 1 consideraram-se apenas os fatores externos, a temperatura exterior, a humidade relativa do ar, a chuva, a velocidade do vento e a duração de sol brilhante (tempo que a intensidade do sol excede um determinado valor previamente estabelecido de brilho) e ainda a radiação solar global. Na simulação 2 adicionaram-se aos fatores externos considerados na anterior, um fator interno, a área total de ocupação. Na simulação 3 juntou-se mais um fator interno, o consumo de energia das UTAs (Unidades de Tratamento de Ar) que tem como objetivo modelizar a taxa de ocupação. O objetivo, ao considerar esta variável, é estimar o número de pessoas dentro do edifício a qualquer hora do dia. Esta estimação é feita da seguinte forma: ao aumentar o número de pessoas no edifício, a concentração de CO<sub>2</sub> no ar que chega às UTAs é maior, logo estas terão de misturar mais ar novo, consumindo mais energia. Assim, quanto maior o número de pessoas, maior a energia utilizada pelas UTAs.

Em [6], tal como em [5] é feita uma previsão da energia necessária para arrefecer um edifício, conforme. Neste estudo, a escolha das variáveis de entrada foi dividida em fatores externos e fatores internos. Os fatores externos considerados foram: temperatura de bolbo seco, temperatura de bolbo húmido<sup>2</sup>, radiação solar global, claridade do céu, estado das nuvens, velocidade do vento e chuva. Foram considerados três fatores internos: o horário de funcionamento das UTAs, tipo-hora/tipo-dia e *occupancy space power demand*. Este último tem como objetivo representar o controlo do utilizador na iluminação artificial, nos equipamentos de escritório e na escolha de velocidade dos

---

<sup>2</sup>Temperatura de bolbo húmido é a temperatura mais baixa que o ar húmido pode atingir ao ser arrefecido apenas por evaporação de água.

ventiloconvectores. A medição desta variável é feita por um software de monitorização de energia, o BMPS. Tal como em [5] foram feitas várias simulações, tendo sido modificados, em cada uma, os parâmetros de entrada, de forma a perceber melhor qual o seu papel na previsão do consumo energético pretendido. As simulações foram também divididas em previsões horárias e diárias. Os resultados obtidos foram melhorando à medida que se acrescentavam variáveis de entrada, isto é, a simulação A teve os piores resultados, enquanto a D teve os melhores. Entre a simulação B e C existem algumas diferenças consoante o tipo de previsão, diária ou horária, na previsão horária a C teve um melhor coeficiente de correlação em relação a D, mas na previsão diária os valores são similares e não se nota uma diferença significativa. Tendo por base tal facto, é possível concluir que o uso da variável hora-tipo melhora os resultados. Por outro lado, o uso do dia-tipo melhora, uma vez que a carga de arrefecimento é praticamente constante nos dias de semana. Existe também uma diferença de precisão nos resultados, consoante seja verão ou inverno, sendo que no inverno é menos preciso enquanto no verão os resultados são mais satisfatórios. É possível verificar que, ainda que o método utilizado seja as redes neurais, a escolha das variáveis de entrada pode oscilar, o que terá posteriormente influência no desempenho do próprio modelo. Também foi possível concluir que o papel desempenhado pelo factor da ocupação humana dos edifícios é crucial na precisão da previsão do consumo energético de um edifício, uma vez que a ocupação dos edifícios implica uma maior ou menor utilização de recursos para que se mantenha o conforto dentro do próprio edifício.

A escolha das variáveis a considerar num determinado estudo é feita através de diversos métodos, métodos estes que permitem concluir quais as que mais influenciam a variável dependente (a que se pretende prever). Em [15], por exemplo, foram utilizados outros métodos além dos coeficiente de correlação para aferir quais as variáveis a considerar no estudo. Com a utilização desses métodos o autor concluiu que as variáveis de entrada a considerar no modelo seriam a temperatura média e a humidade mínima.

No caso das Redes Neurais, um outro aspeto importante a considerar é o treino das próprias redes, que pode ser efetuado através de diversos métodos.

Em [15] o método escolhido foi uma rede neuronal com o algoritmo de treino MLP *ensemble*. Os dados de treino foram divididos em quatro grupos, com o intuito de melhorar os resultados. De facto os resultados melhoraram. Esta melhoria notou-se, principalmente, nas diferenças entre os resultados do período de verão, que são melhores, e os do período de inverno.

A inovação apresentada em [14] consiste no método de escolha dos dias para treinar a rede. Embora use uma rede neuronal tradicional de três camadas, classifica os dias para a testar de acordo com dois índices: LAP, que caracteriza o tipo e nível de atividade esperada durante o dia, e CT, que caracteriza os dias de acordo com a temperatura. Assim, para prever o consumo de um dia, escolhe-se para treinar a rede os dias com os índices LAP e TC o mais perto possível do dia a prever. Em [7] dividiram-se os dados em duas redes neurais, uma dedicada a dias de semana e outra para fins-de-semana, o que melhorou os resultados. De uma forma semelhante ao que acontece em [14] dividem-se os dados por várias redes, neste caso 96, uma para cada quarto de hora do dia, sendo

possível obter resultados muito próximos da realidade devido ao extenso detalhe. Uma grande diferença neste estudo foi também a diferenciação da energia consumida, tendo sido feita uma divisão em dois grupos, a fortemente dependente da temperatura, como o HVAC, e a restante energia. Utiliza-se para alvo da rede não a energia total mas uma obtida através da agregação dos vários tipos.

Por outro lado, em [5] o algoritmo para treinar a rede em questão foi o Backpropagation. Para monitorizar e parar foi utilizado a *early-stop validation*. Para treinar e testar a rede usaram-se amostras diferentes, tal como é habitual quando se tratam de redes neuronais.

Em [6], para o processo de treino da rede, utilizou-se o método de *gradient descent*, cuja função é de ir atualizando os pesos das variáveis e os *bias values* de acordo com a otimização *Levenberg-Marquardt*, sendo assim possível minimizar os erros e tornar a rede o mais geral possível.

Do estado da arte apresentado, é possível notar a tendência para se considerar como variável de entrada predominante a temperatura, ou diferentes grandezas de temperatura, uma vez que esta influencia os consumos, principalmente o consumo destinado ao AVAC. Uma vez que a energia gasta pelo sistema de AVAC tem como principal objetivo o conforto das pessoas, é possível inferir que as pessoas, e a ocupação que as mesmas fazem dos edifícios, estão diretamente relacionadas com o consumo de energia.

Tendo em conta o apresentado, para a presente dissertação optou-se por estudar uma rede normal utilizando o algoritmo de treino Levenberg-Marquardt backpropagation.

# Capítulo 3

## Metodologias

Na realização da presente dissertação foi necessário considerar metodologias para as diferentes fases. Primeiro começou-se por definir qual o método a utilizar para fazer uma previsão energética, tendo em conta todas as características já referidas das redes neuronais e a sua vasta utilização na previsão de consumos optou-se por este método. Em seguida decidiu-se aliar este método ao uso dos coeficientes de correlação de *pearson* e do *principal component analysis*, para escolher as variáveis a utilizar.

Neste capítulo faz-se uma breve referência às metodologias utilizadas na presente dissertação.

### 3.1 Redes Neuronais Artificiais

As redes neuronais artificiais, são desta forma chamadas por terem como princípio de funcionamento o cérebro humano, mais especificamente os seus neurónios. Uma rede neuronal é um sistema constituído por unidades simples de processamento, os neurónios, que guardam conhecimento experimental e o tornam disponível para ser usado. São parecidas com o cérebro, pois adquirem o conhecimento do ambiente através de um processo de aprendizagem, guardando-o em pesos sinápticos. O processo de aprendizagem é conseguido através do algoritmo de treino. Embora existam vários, todos têm a mesma função, que consiste em modificar os pesos sinápticos ordenadamente com o intuito de obter o objetivo desejado [16].

Como é possível verificar na figura 3.1, num neurónio os sinais de entrada são multiplicados pelos pesos sinápticos sendo somados em seguida. Neste modelo também está incluído o *bias*, que é um parâmetro externo de um neurónio artificial e tem o efeito de aumentar ou diminuir a entrada da função de ativação. Assim os resultados da multiplicação dos sinais de entrada com os pesos sinápticos são somados entre si e ao *bias*. A função de ativação é responsável por gerar o valor de saída de um neurónio [16].




Figura 3.1 - Modelo não-linear de um neurônio [15]

As redes neurais encerram em si vários benefícios, como por exemplo a capacidade de adaptação que é conseguida através de ajustes automáticos dos seus pesos sinápticos a variações do ambiente. Outro benefício é o *input-output mapping*, em que a rede aprende a partir de exemplos, ao construir um mapa com entradas e saídas correspondentes [16].

Existem várias arquiteturas de redes neurais que se organizam em classes, geralmente três: *single-layer feedforward networks*, *multilayer feedforward networks* e *recurrent nwtworks*. Tendo em conta as referências presentes no estado de arte, pode-se afirmar que no tema da presente dissertação usam-se principalmente *multilayer feedforward networks*.

Na figura 3.2, encontra-se representada a arquitetura da rede utilizada em [5]. Trata-se de uma *multilayer feedforward network*, também se podendo chamar *multylayer perceptron* (MLP). Nesta classe, as redes são constituídas por uma ou mais camadas ocultas, uma camada de entrada e outra de saída. Estas estão ligadas entre si, ou seja, o sinal de saída de uma camada serve de entrada à camada seguinte. Cada camada tem várias unidades de processamento, os neurónios.

Esta arquitetura simula as relações entre os *inputs* e os *outputs*, baseando-se num historial de dados, tal como o nosso cérebro [5]. A adição de uma ou mais camadas ocultas permite à rede uma perspectiva global [16].

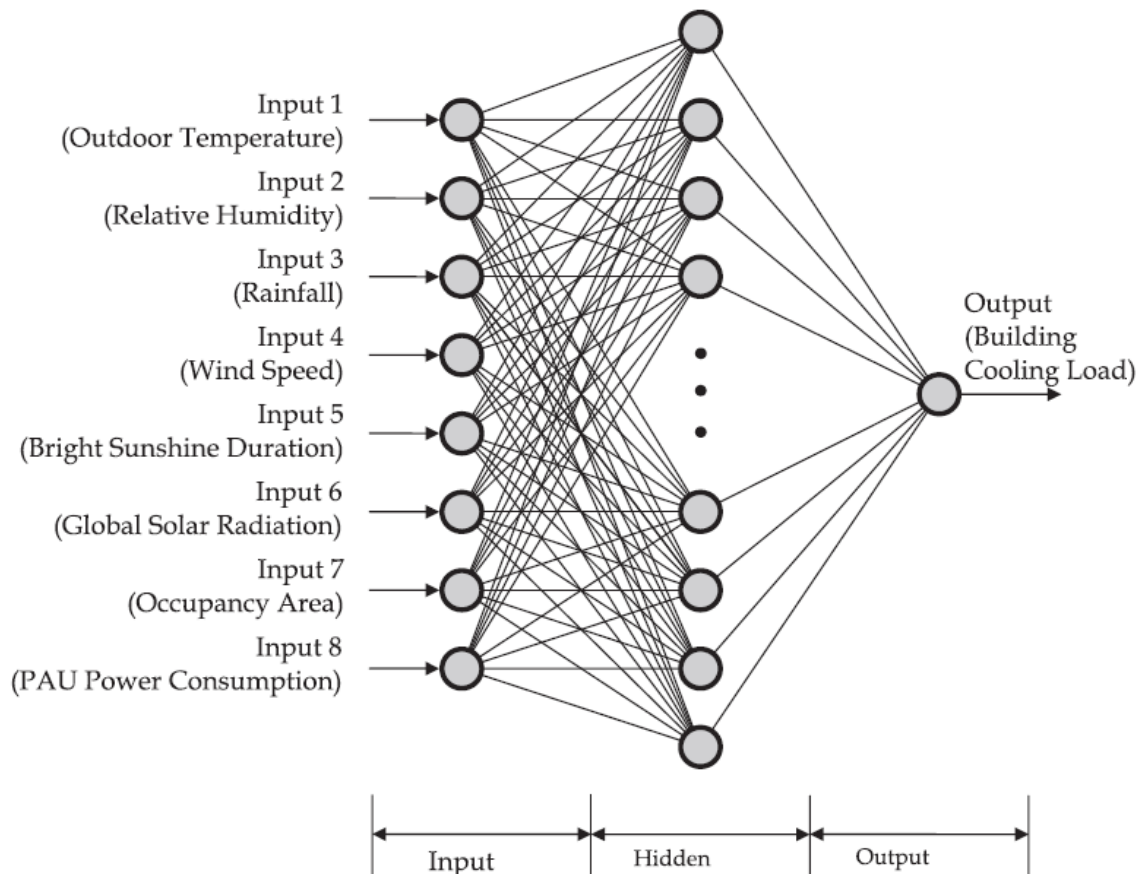


Figura 3.2 - Arquitetura da rede neuronal usada em [5]

Depois de definida a estrutura da rede, é preciso decidir qual o algoritmo de treino a usar. Existem vários, sendo o mais utilizado o algoritmo *back-propagation* [16].

O *back-propagation* é um algoritmo em que se distinguem duas fases: *forward* e *backward*. Na fase *forward*, a primeira, não existem alterações aos pesos sinápticos e os sinais da rede são passados camada a camada. Esta começa na camada oculta ao apresentar os valores de entrada e termina na camada de saída ao calcular o valor de erro (diferença entre o valor desejado e o valor de saída) para cada neurónio. Após a primeira iteração existem valores de erro, ou seja, o valor previsto difere do valor observado. Esse erro é uma função dos parâmetros livres, que são os pesos sinápticos e os *bias*. Na segunda fase, *backward*, o objetivo é minimizar o erro à custa de alterações dos parâmetros livres. Esta começa na camada de saída, fazendo passar os erros por toda a rede, atualizando recursivamente cada neurónio. [16] Este processo é repetido até existir um resultado satisfatório, sendo necessário um método de validação para monitorizar o algoritmo e fazê-lo parar. [5]

## 3.2 Métodos de escolha de variáveis de entrada

Ao realizar um estudo existem diversas variáveis a considerar, algumas têm maior importância que outras, na medida em que sem elas o estudo não faria sentido. Outras são um pouco mais redundantes, ou porque não têm interesse para o estudo em questão, ou porque de alguma forma estão correlacionadas com outras. Através do conhecimento, proveniente de estudos prévios, conseguimos excluir algumas variáveis que, logo à partida, são menos relevantes. No entanto, existem outras variáveis para as quais não é tão óbvia a sua exclusão ou manutenção no estudo, assim para evitar o uso de variáveis redundantes, podem ser utilizadas diferentes técnicas.

### 3.2.1 Principal Component Analysis

O PCA (*Principal Component Analysis*) é uma técnica que tem como objetivo simplificar a resolução de um dado problema através da redução do número de variáveis a ter em consideração.[17]

O PCA “transforma um conjunto de variáveis correlacionadas num conjunto menor de variáveis independentes, combinações lineares das variáveis originais, designadas por “componentes principais”. [18] Ao agruparmos as variáveis importantes em componentes principais conseguimos diminuir a complexidade da resolução de um dado problema.

De acordo com [18] e através de (3.1) consegue-se obter as componentes principais,  $\epsilon$ , tendo em conta as variáveis originais,  $X_1, X_2, \dots, X_p$ , e o peso das variáveis nas respetivas componentes,  $\gamma_{p1}, \gamma_{p2}, \dots, \gamma_{pp}$ , correspondendo o valor  $p$  ao número de variáveis originais.

$$\epsilon_p = \gamma_{p1}X_1 + \gamma_{p2}X_2 + \dots + \gamma_{pp}X_p \quad (3.1)$$

Como o  $\epsilon_p$  é conhecido, o  $\gamma_{pp}$  é o valor a calcular, resta saber como o PCA calcula os valores dos pesos atribuídos a cada variável. Para tal, é usada uma equação polinomial com  $p$  raízes, chamadas valores próprios da matriz variâncias-covariâncias de  $X$ . Aos valores próprios correspondem vetores próprios que representam as componentes.

### 3.2.2 Coeficientes de Correlação de *Perason*

Os coeficientes de correlação, ou medidas de associação, têm como principal objetivo medir a intensidade e direção da relação entre duas ou mais variáveis. Podem ser classificados segundo o

número de variáveis que envolvem, sendo correlações bivariadas as que envolvem apenas duas variáveis, e multivariadas quando envolvem mais do que duas. Os coeficientes de correlação podem ser positivos ou negativos, dependendo das variáveis em estudo. Positivos significa que as variáveis variam no mesmo sentido, ou seja, quando uma aumenta a outra também e vice-versa. Por outro lado, o sentido negativo caracteriza variáveis que variam em sentido oposto, ou seja, quando uma aumenta a outra diminuiu e vice-versa [18]. Caso a correlação seja igual a zero significa que quando uma variável aumenta a outra não tem tendência nem para aumentar nem para diminuir [19]. Na figura 3.3 é possível verificar graficamente o tipo de correlação segundo o comportamento das variáveis. No gráfico a) está representada uma correlação negativa, no b) não existe correlação, e no último encontra-se representada uma correlação positiva.




Figura 3.3 - Gráficos exemplo dos diversos tipos de correlação [14]

Existem vários coeficientes de correlação, a aplicação de um em específico depende das variáveis consideradas. Os mais usuais são o coeficiente de correlação de *Pearson*, o de *Spearman*, o *V* de *Cramer* e o *Phi*. [18]

De acordo com [18] o coeficiente de *Pearson* aplica-se quando as variáveis são lineares e é calculado através da Covariância entre duas variáveis  $X_1$  e  $X_2$ .

$$S_{X_1 X_2} \text{ ou } Cov(X_1, X_2) = \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{n-1} \quad (3.13)$$

$$R_{X_1 X_2} = \frac{S_{X_1 X_2}}{S_{X_1} S_{X_2}} = \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sqrt{\sum_{i=1}^n (x_{1i} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{2i} - \bar{x}_2)^2}} \quad (3.14)$$

Na equação (3.14) está presente o cálculo do coeficiente de *Pearson* através da standardização da Covariância pelos desvios-padrão das variáveis. Representa-se pela letra *R* e varia entre -1 e 1. Não existindo uma forma precisa de classificar as correlações, em [19] considera-se:

1.  $|R| < 0,25$  correlação fraca
2.  $0,25 \leq |R| < 0,5$  correlação moderada
3.  $0,5 \leq |R| < 0,75$  correlação forte
4.  $|R| \geq 0,75$  correlação muito forte

# Capítulo 4

## Casos de estudo

Tendo as metodologias a utilizar definidas segue-se a tarefa de selecionar os casos de estudo para aplicar as mesmas. Primeiramente seria realizado apenas um caso de estudo, mas para tornar possível uma maior abrangência de resultados, optou-se por estudar dois casos.

Neste capítulo encontram-se descritos e comentados todos os testes efetuados e as respetivas conclusões.

### 4.1 Caracterização dos Edifícios

Para realizar o estudo em causa escolheram-se dois edifícios com diferentes características: o edifício 10 da Faculdade de Ciências e Tecnologias da Universidade Nova de Lisboa e o edifício da Fundação Calouste Gulbenkian. O escolher de dois edifícios diferentes tornou possível enriquecer os resultados e respetivas conclusões.

#### 4.1.1 Edifício 10 da Faculdade de Ciências e Tecnologias

Este edifício tem funções exclusivamente académicas, sendo que a maioria das salas se classificam entre: salas de aula, gabinetes e laboratórios. É composto por uma cave e três pisos, respeitando um horário de funcionamento das 8h às 20h de segunda a sexta, podendo pessoas registadas entrar fora deste horário através de um cartão de identificação. A grande maioria de utilizadores fora de horas, ou seja, depois das 20h e ao fim de semana, são alunos que aproveitam para estudar no edifício.

Embora possa obter energia através de três fontes, PT (Posto de Transformação), painel fotovoltaico e turbina eólica, a grande maioria é obtida através do PT, já que as energias renováveis contribuem apenas com 1%. Assim, neste estudo considerou-se apenas a energia proveniente do PT. A energia consumida pelo edifício divide-se em dois grupos, climatização e o restante consumo. Uma vez que a climatização esteve desligada durante todo o período de estudo, a mesma não foi considerada.

### **4.1.2 Edifício da Fundação Calouste Gulbenkian**

As instalações da Sede e Museu da Fundação Gulbenkian, foram inauguradas em 1969. Integram áreas reservadas à administração e aos serviços, um Grande Auditório, espaços para exposições temporárias, uma Zona de Congressos, e um edifício próprio que alberga o Museu Calouste Gulbenkian, os serviços educativos do Museu e a Biblioteca de Arte.

Em 1983, foi inaugurado o Centro de Arte Moderna, que dispõe de um museu, galeria de exposições temporárias, uma sala polivalente e espaços administrativos.

Caracterização dos espaços e horários de funcionamento:

Área administrativa - 8h às 19h

Circulações

Área expositiva e exposições temporárias – todos os dias das 10h às 18h, encerram à segunda-feira

Zona de Congressos – a pedido

Espectáculos e ensaios – a pedido

Restauração

Zonas oficiais – 8h às 18h

Preparação de exposições – a pedido

### **4.2 Variáveis**

O primeiro passo no desenvolvimento de um modelo de previsão é a escolha das variáveis, tanto de entrada como de saída. Uma vez que o objetivo é prever a energia consumida pelo edifício, é naturalmente esta a variável de saída do modelo. Relativamente à escolha das variáveis de entrada já implica um processo um pouco mais complexo. Primeiro foi necessário fazer um levantamento das variáveis disponíveis, relativamente ao edifício 10 da FCT estas encontram-se na tabela 4.1.

Tabela 4. 1 - Variáveis disponíveis FCT

Variável	Unidade
<b>Data</b>	
<b>Hora</b>	
<b>Irradiância</b>	W/m <sup>2</sup>
<b>Velocidade do vento</b>	m/s
<b>Velocidade rajada</b>	m/s
<b>Direcção</b>	Graus
<b>Temperatura</b>	°C
<b>Ocupação</b>	número de salas
<b>Energia Consumida</b>	kWh

As variáveis meteorológicas foram obtidas através da estação meteorológica do edifício, a energia consumida através dos contadores de energia eléctrica instalados no mesmo. O que se revelou mais desafiador foi a escolha de uma variável capaz de modelar o comportamento humano. Foram consideradas várias hipóteses, entre elas, monitorizar a entrada dos carros, colocar em funcionamento um sensor capaz de contar entradas e saídas, mas, foram sempre encontrados obstáculos, ou a falta de rigor ou o reduzido período de tempo. Analisou-se então a permanência de alunos no departamento, e chegou-se à conclusão que quando havia um maior número de aulas havia também um maior número de pessoas. Foram considerados dois períodos de estudo, um contemplando o primeiro semestre do ano lectivo 2012/2013 (Setembro, Outubro, Novembro e Dezembro), e outro contemplando a época de exames do primeiro semestre de 2012/2013 (Janeiro e Fevereiro). No primeiro período contou-se através do horário do DEE o número de aulas a decorrer a cada hora do dia. Já no segundo período considerou-se a ocupação zero a todas as horas, uma vez que não havendo aulas e não se realizando exames neste edifício, as salas estariam livres. A ocupação considerada no primeiro período encontra-se na tabela 4.2, os zeros representam a não existência de aulas em determinada hora.

Tabela 4. 2 - Ocupação Semanal do DEE

<b>Horas</b>	<b>Segunda</b>	<b>Terça</b>	<b>Quarta</b>	<b>Quinta</b>	<b>Sexta</b>	<b>Sábado</b>	<b>Domingo</b>
<b>0</b>	0	0	0	0	0	0	0
<b>1</b>	0	0	0	0	0	0	0
<b>2</b>	0	0	0	0	0	0	0
<b>3</b>	0	0	0	0	0	0	0
<b>4</b>	0	0	0	0	0	0	0
<b>5</b>	0	0	0	0	0	0	0
<b>6</b>	0	0	0	0	0	0	0
<b>7</b>	0	0	0	0	0	0	0
<b>8</b>	1	2	4	3	4	0	0
<b>9</b>	3	7	9	5	12	0	0
<b>10</b>	3	6	9	5	12	0	0
<b>11</b>	6	4	11	8	10	0	0
<b>12</b>	5	3	11	7	10	0	0
<b>13</b>	1	3	4	3	4	0	0
<b>14</b>	6	10	0	12	9	0	0
<b>15</b>	9	12	0	12	10	0	0
<b>16</b>	10	11	0	11	8	0	0
<b>17</b>	9	9	0	10	4	0	0
<b>18</b>	5	8	0	9	2	0	0
<b>19</b>	3	7	0	6	2	0	0
<b>20</b>	0	0	0	0	0	0	0
<b>21</b>	0	0	0	0	0	0	0
<b>22</b>	0	0	0	0	0	0	0
<b>23</b>	0	0	0	0	0	0	0

Em seguida fez-se uma análise baseada apenas nos conhecimentos adquiridos em estudos prévios, tendo-se excluído a velocidade de rajada, a direção, a radiação solar e a data. Restando

agora apenas a velocidade do vento, a ocupação, a temperatura exterior e as horas, usou-se a energia consumida para aplicar alguns testes que têm como objetivo identificar o nível de relação entre diferentes variáveis.

Já no caso da Fundação Calouste Gulbenkian as variáveis de entrada disponíveis encontram-se na tabela 4.3. Optou-se por utilizar nos dois casos as mesmas condições, ou seja, iguais períodos de estudo e iguais variáveis para modelar o comportamento humano. De salientar que neste caso a ocupação apresenta uma variação muito maior quando comparada á FCT, uma vez que não se rege por um horário escolar mas sim por diversos eventos a acontecer ou não simultâneamente.

Tabela 4. 3 - Variáveis Disponíveis FCG

Variável	Unidade
Data	
Hora	
Humidade Relativa	%
Temperatura	°C
Ocupação	número de salas
Energia Consumida	W

#### 4.2.1 Coeficientes de Correlação de *Pearson*

O primeiro método aplicado para selecionar as variáveis importantes na previsão de consumos energéticos num edifício foi os coeficientes de correlação de *Pearson*, considerou-se as variáveis supracitadas e várias amostras das mesmas, tendo-se obtido, recorrendo ao software científico MATLAB, os resultados apresentados em seguida.

Tabela 4. 4 - Coeficientes de Correlação FCT

	Hora	Energia	Velocidade Vento	Ocupação	Temperatura
Hora	1,000	0,344	0,173	0,189	0,204
Energia	0,344	1,000	0,218	0,792	0,014
Velocidade Vento	0,173	0,218	1,000	0,148	-0,134
Ocupação	0,189	0,792	0,148	1,000	0,150
Temperatura	0,204	0,014	-0,134	0,150	1,000

O resultado é uma matriz 5x5 com uma diagonal de 1, pois representa a relação das variáveis com as próprias variáveis, e simétrica, uma vez que a relação de uma variável **a** com uma variável **b** é igual à relação inversa das mesmas. Analisando a matriz, tendo em conta o que foi dito no capítulo Metodologias, a energia e a ocupação apresentam uma correlação muito forte, também a energia e as horas apresentam uma correlação moderada.

Realizou-se o mesmo teste nos dados da FCG e o resultado encontra-se na tabela 4.5. Analisando a matriz conclui-se que a energia e a ocupação apresentam uma correlação forte, por outro lado tanto as horas e a ocupação como a humidade e temperatura apresentam uma relação moderada.

Tabela 4. 5 - Coeficientes de Correlação FCG

	Horas	Temperatura	Humidade	Energia	Ocupação
Horas	1,0000	0,0660	-0,1666	0,2178	0,2548
Temperatura	0,0660	1,0000	-0,2813	0,1209	-0,0507
Humidade	-0,1666	-0,2813	1,0000	-0,0331	-0,0058
Energia	0,2178	0,1209	-0,0331	1,0000	0,6452
Ocupação	0,2548	-0,0507	-0,0058	0,6452	1,0000

Tendo por base o método realizado e os dois casos de estudo considerar-se-ia como variáveis de entrada as horas e a ocupação.

## 4.2.2 Principal Component Analysis

Em seguida aplicou-se um segundo método de modo a selecionar as variáveis mais importantes neste estudo. O método escolhido foi o PCA e nas tabelas 4.6 e 4.7 encontram-se os resultados deste método quando aplicado ao caso de estudo da FCT. O *software* utilizado neste teste foi o *SPSS Statistics*.

Tabela 4. 6 - Componentes e Variações FCT

Componente	% de Variação
1	35,073
2	28,346
3	20,424
4	16,157

Tabela 4. 7 - Componentes principais FCT

	Componente	
	1	2
Hora	,738	,000
Velocidade Vento	,401	,784
Ocupação	,675	,059
Temperatura	,492	-,719

Na tabela 4.7 estão as duas componentes extraídas pelo SPSS, sendo a componente 1 composta por hora e ocupação e a componente 2 composta por velocidade do vento e temperatura. Na tabela 4.6 é possível verificar a percentagem de variação que cada componente é capaz de explicar, sendo o componente 1 o mais explicativo, com aproximadamente 35%.

Os resultados obtidos através deste método sustentam a utilização das horas e da ocupação como principais variáveis de entrada na previsão de consumos energéticos.

Realizou-se o mesmo método, mas desta vez para o caso de estudo da FCG, os resultados encontram-se nas tabelas 4.8 e 4.9. Analisando a tabela 4.9 que contém as duas componentes extraídas, conclui-se que a componente 1 é composta por hora e humidade, já a componente 2 é composta pela ocupação. Em ambas as componentes a temperatura aparece com relevância, o que faz sentido, uma vez que é uma das variáveis mais usada na previsão de consumos. A humidade aparece neste caso de estudo com uma grande relevância, uma vez que albergando várias exposições de obras de arte, a humidade é uma das grandes preocupações no que diz respeito à climatização dos espaços.

Tabela 4. 8 - Componentes e Variações FCG

<b>Componente</b>	<b>% de Variação</b>
<b>1</b>	34,499
<b>2</b>	29,529
<b>3</b>	18,880
<b>4</b>	17,091

Tabela 4. 9 - Componentes principais FCG

	<b>Componente</b>	
	<b>1</b>	<b>2</b>
<b>Hora</b>	,647	,463
<b>Temperatura</b>	,571	-,547
<b>Humidade</b>	-,688	,399
<b>Ocupação</b>	,402	,713

### 4.3 Redes Neurais Artificiais

O método utilizado para prever o consumo energético foi a rede neuronal artificial, através da ferramenta de redes neurais do Matlab foi possível criar diferentes redes capazes de explicar a relação entre o consumo de energia elétrica e as diferentes variáveis.

Usou-se, em todos os testes, uma rede neuronal feed-forward de três camadas, a de entrada, a oculta e a de saída. O algoritmo de treino é o Levenberg-Marquardt backpropagation e usaram-se 20 neurónios ocultos com função de ativação sigmoide, pois em várias experiências com um maior ou menor número não se verificou alterações importantes nos resultados. Foi necessário dividir os dados em três partes, uma para treino, uma para validação e finalmente uma para teste. O processo de treino é o mais importante e por isso mesmo deve conter o maior número de dados possível, assim considerou-se 70% como sendo de treino. Para o processo de validação e teste considerou-se para cada 15% dos dados. Na figura 4.4 é possível ver a arquitetura da rede descrita, nos vários testes a única variação é o número de variáveis de entrada.

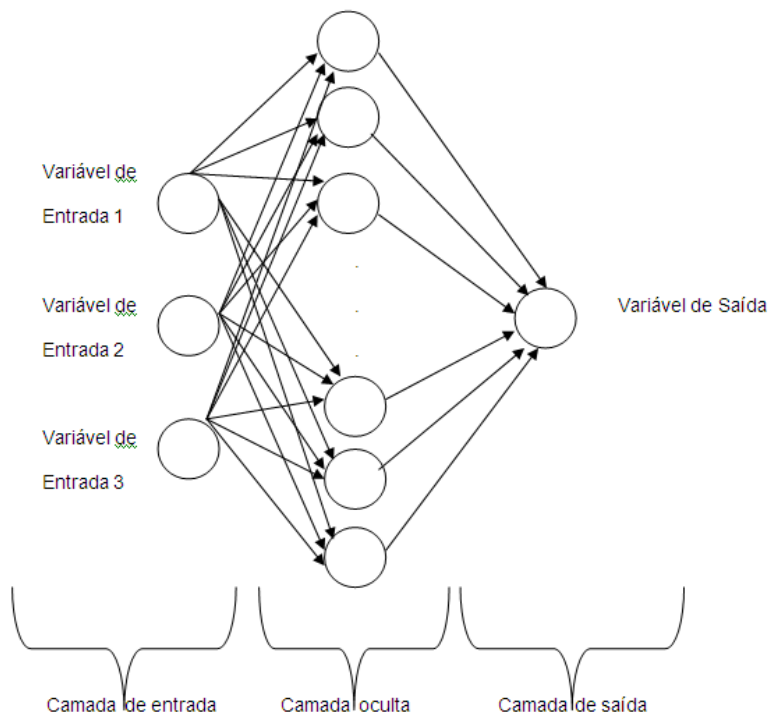


Figura 4.4 - Arquitetura da rede

### 4.3.1 Rede Neuronal Semanal

Começou-se por criar redes que correspondem-se a consumos semanais, onde apenas são considerados os cinco dias úteis da semana. As principais diferenças entre as diferentes redes criadas consistem nas variáveis de entrada e no período de dados utilizado para treino e para teste.

#### a) Três variáveis de entrada: hora, temperatura e ocupação do edifício

Primeiro criou-se uma rede utilizando, para treino, os dados de Setembro a Dezembro de 2012, sendo posteriormente submetida a vários testes. O primeiro teste está representado na figura 4.5, e consiste em comparar os valores previstos de energia, em duas semanas de Setembro a Dezembro de 2012, para os quais a rede não havia sido treinada, com os valores reais. A energia efetivamente consumida encontra-se representada pela cor azul e o consumo de energia previsto pelo modelo, pela cor vermelha.




Figura 4.5 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

É possível verificar através da análise da figura 4.5 que o consumo de energia previsto acompanha, maioritariamente, o consumo efetivo de energia, ocorrendo a principal diferença na primeira quinta-feira. Este resultado sustenta a capacidade de aprendizagem das redes neuronais, sempre que efetuado um treino com períodos de utilização semelhantes do edifício.

Calculou-se também o erro de previsão, estando representado na figura 4.6. Pode-se afirmar que não existem erros sistemáticos, ou seja, o modelo foi bem construído e existem apenas erros

aleatórios. O maior valor de erro ronda os 13kWh mas acontece poucas vezes, sendo os restantes próximos de zero.




Figura 4.6 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

O erro médio de previsão é de 3,6% e o seu desvio padrão de 8,7, valores que são considerados muito animadores e que traduzem uma boa precisão por parte do modelo.

Criou-se uma rede com as mesmas variáveis de entrada, mas desta vez para o caso de estudo FCG. Os resultados encontram-se na figura 4.7.




Figura 4.7 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG

Analisando a figura 4.7 pode-se concluir que embora o consumo previsto acompanhe o consumo efetivo, existem algumas diferenças, nomeadamente na primeira segunda-feira, onde é possível

notar a oscilação da rede ao tentar prever a energia. Tal dificuldade deve-se ao facto desta segunda-feira ser atípica quando comparada com as outras, normalmente este é o dia da semana com menor consumo uma vez que as exposições estão encerradas, mas nesta particular segunda-feira houve mais eventos o que provocou um aumento do consumo. O erro médio neste caso é de 7.4% e o desvio padrão de 24.4.

Com o intuito de perceber o comportamento das redes neuronais ao serem testadas com períodos diferentes dos quais foram treinadas, testou-se a rede cujo período de treino foi de Setembro a Dezembro de 2012 da FCT com uma semana de Fevereiro de 2013, que de acordo com o referido anteriormente, diverge consideravelmente do período de treino da rede. Assim, na figura 4.8 estão representados os consumos reais (cor azul) e previsto (cor vermelha) de uma semana de teste de Fevereiro 2013 numa rede de Setembro a Dezembro 2012.

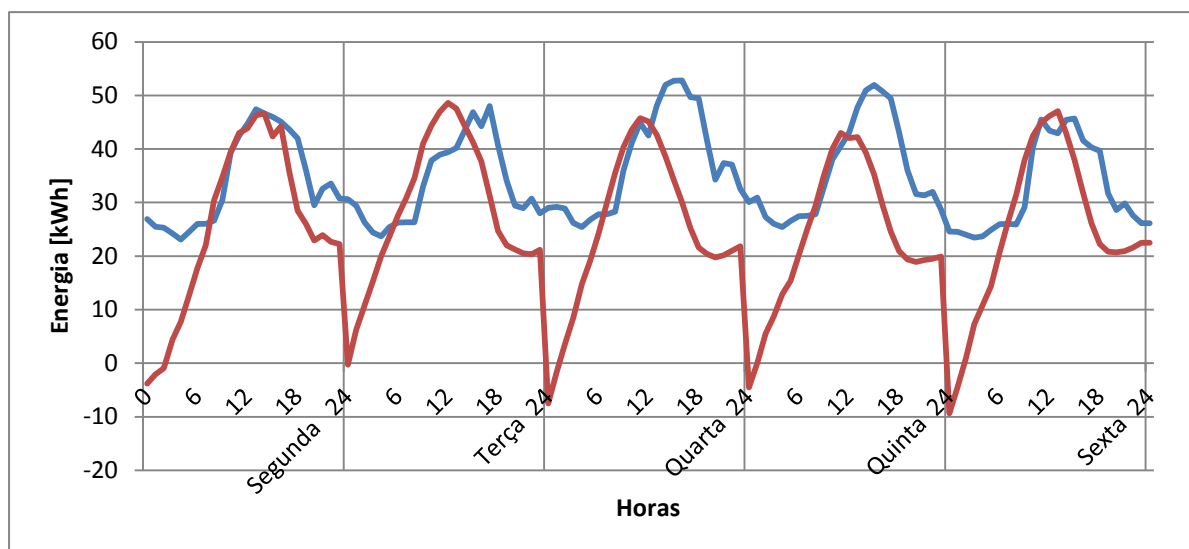


Figura 4.8 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013 FCT

Na figura 4.8 são claramente visíveis as diferenças entre a energia efetivamente consumida e a energia prevista pelo modelo, deixando claro que a rede não consegue prever situações às quais nunca foi submetida, uma vez que o período de treino é muito diferente do período de teste. O período de treino corresponde aos meses de Setembro a Dezembro de 2012, enquanto o período de teste corresponde a Fevereiro de 2013. Para além das diferenças climáticas, nomeadamente temperaturas diferentes, a maior diferença consiste em pertencerem a períodos escolares diferentes. O período de treino corresponde a aulas, por outro lado o período de teste corresponde a exames. A ocupação do edifício nestes períodos é muito diferente, quando estão a decorrer aulas existem muitos alunos a frequentar o edifício, em período de exames a ocupação é muito reduzida. Onde a rede demonstra maior dificuldade é no período noturno, prevendo valores negativos, neste período a ocupação está a zero quer nas semanas de Setembro a Dezembro quer em Fevereiro. É possível

então concluir que, as redes neuronais apresentam uma falta de capacidade de generalização quando se pretende a sua utilização para prever um período completamente distinto.

Face aos resultados anteriores, e à clara dificuldade das redes neuronais em prever o consumo de energia em períodos distintos daqueles para que foram treinadas, criou-se uma rede cujo período de aprendizagem corresponde aos meses entre Setembro de 2012 e Fevereiro de 2013. Assim, esta nova rede engloba tanto o primeiro semestre de 2012/2013 como o período de exames do mesmo e tem como objetivo superar a falta de capacidade de generalização evidenciada.

Na figura 4.9 encontram-se representados os resultados, consumos efetivos (azul) e consumos previstos pelo modelo (vermelho), ao testar a rede com duas semanas de Setembro a Dezembro 2012. Os resultados são semelhantes à rede cujo período de treino foi de Setembro a Dezembro 2012, ou seja, o consumo previsto de energia acompanha o consumo efetivo de energia, apresentando poucas diferenças. Estes resultados demonstram que a inclusão de um novo período de treino não afeta a aprendizagem anterior.

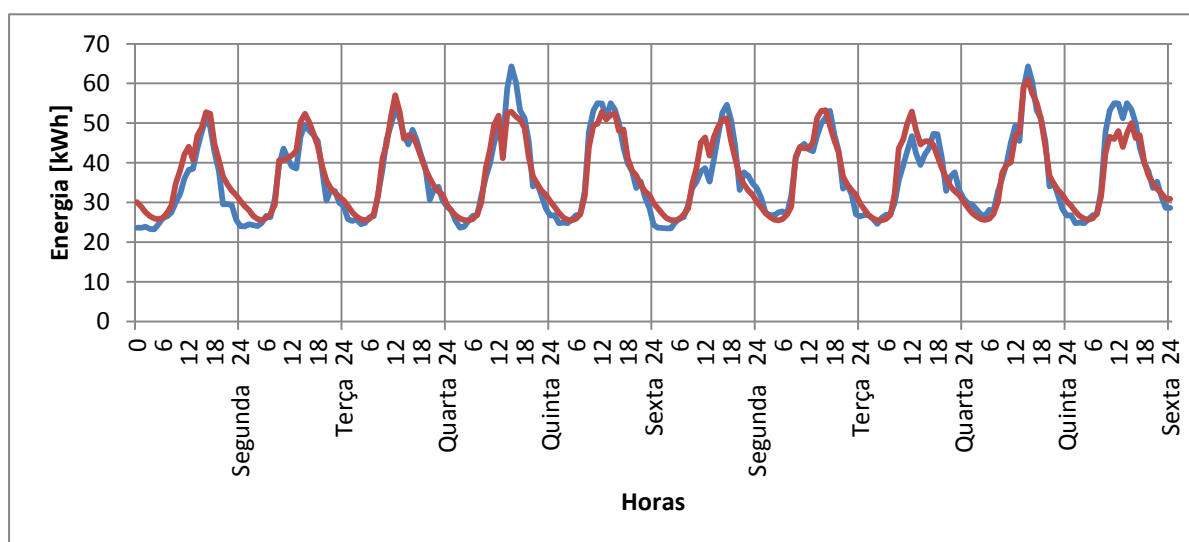


Figura 4.9 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Setembro a Dezembro 2012 FCT

Relativamente ao erro médio, ao analisar a figura 4.10, é possível notar a existência de erros aleatórios mas com valores não preocupantes ou que possam de alguma forma reduzir significativamente a precisão do modelo. O erro médio associado é de 2,7% e o seu desvio padrão de 8,7, valores bastante satisfatórios, e um pouco melhores em relação ao teste cujo treino foi de Setembro a Dezembro 2012 com semanas de teste de Setembro a Dezembro 2012.




Figura 4.10 – Erro de Previsão, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Setembro a Dezembro 2012 FCT

A mesma rede foi testada com uma semana de Fevereiro 2013, estando o resultado presente na figura 4.11. Uma vez que o período de treino desta rede já contém dados semelhantes aos dados de teste, o resultado melhorou significativamente, verificando-se que o consumo previsto de energia (cor vermelha) acompanha quase sempre a linha do consumo efetivo (cor azul).




Figura 4.11 – Consumo efetivo de energia vs consumo de energia previsto, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Fevereiro de 2013 FCT

Relativamente ao erro, presente na figura 4.12, verifica-se também uma grande melhoria não existindo erros sistemáticos e com valores próximos de 0. O erro médio neste teste é de 2,0% e o seu desvio padrão de 8,6, demonstrando uma previsão fidedigna.

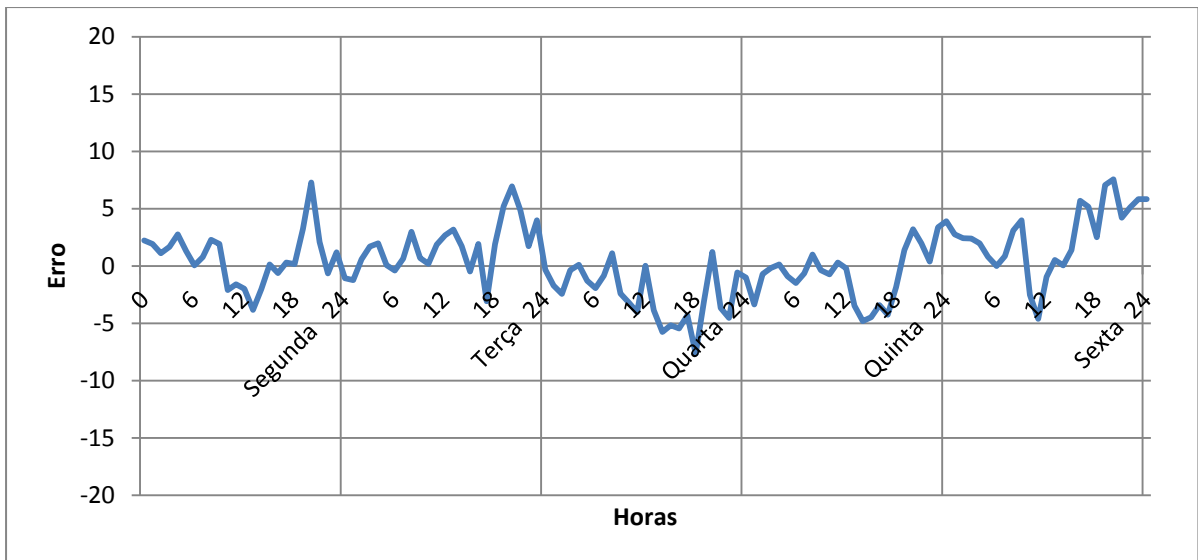


Figura 4.12 – Erro de previsão, Aprendizagem Setembro de 2012 a Fevereiro de 2013, Teste Fevereiro de 2013 FCT

Depois de uma rede que caracteriza o período de Setembro a Dezembro de 2012 e outra que caracteriza o período de Setembro 2012 a Fevereiro 2013, considerou-se pertinente a criação de uma terceira rede característica do período de Janeiro a Fevereiro de 2013. O principal objetivo na criação desta rede é verificar se o seu comportamento aos diferentes testes, é ou não igual ao da rede cujo treino corresponde ao período de Setembro a Dezembro de 2012. Embora este período de treino tenha menos um mês, é um período mais uniforme uma vez que a ocupação é constante, ou seja, com menos variações de consumo, e possivelmente um período mais fácil de prever.

Testou-se, em primeiro lugar, essa rede com uma semana de Fevereiro de 2013, estando o resultado na figura 4.13. Verifica-se que o consumo previsto pelo modelo (cor vermelha) não acompanha tão proximamente o consumo de energia efetivo (cor azul).




Figura 4.13 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Janeiro a Fevereiro de 2013, Teste Fevereiro de 2013 FCT

Na figura 4.14 encontra-se o gráfico do erro, que revela, mais uma vez, valores que rondam o zero. Para uma melhor precisão de análise destacam-se os valores do erro médio de 2,5% e o seu desvio padrão 9,8, corroborando que as diferenças entre a energia real e a prevista não são muitas.




Figura 4.14 - Erro de previsão, Aprendizagem Janeiro a Fevereiro de 2013, Teste Fevereiro de 2013 FCT

Em seguida testou-se a rede com duas semanas de Setembro a Dezembro, o resultado encontra-se na figura 4.15. Neste caso é possível encontrar diferenças significativas entre a energia real (azul) e a energia prevista (vermelho), ficando esta por várias vezes abaixo do que era esperado. As semanas escolhidas para teste foram duas semanas de Novembro de 2012. Este teste foi mais favorável do que o contrário (Aprendizagem Setembro a Dezembro, Teste Fevereiro) pois neste caso a rede tem dificuldade a prever quando a ocupação é diferente de zero, ou seja, ao longo do dia. Pela figura é possível notar que não consegue prever os picos de consumo que ocorrem durante o dia e que estão diretamente relacionados com o aumento do número de ocupação, os consumos previstos têm então uma amplitude muito menor, característica do período de Fevereiro de 2013.




Figura 4.15 – Consumo efetivo de energia vs Consumo previsto, Aprendizagem Janeiro a Fevereiro de 2013, Teste Setembro a Dezembro de 2012 FCT

Na figura 4.16 encontra-se o erro de previsão associado a este teste. Aqui é possível verificar que os valores ultrapassam, por vezes, os 10 kWh. O erro médio é de -2,3%, o que justifica o facto da energia prevista ficar muitas vezes abaixo da energia real, e o seu desvio padrão é de 12.7.




Figura 4.16 – Erro de previsão, Aprendizagem Janeiro a Fevereiro de 2013, Teste Setembro a Dezembro de 2012 FCT

### b) Duas variáveis de entrada: ocupação e hora

Uma vez que ambos os testes feitos às variáveis indicaram a ocupação e as horas como as variáveis que mais influenciam a energia, decidiu-se fazer uma rede cujas variáveis de entrada fossem ocupação e horas.

Foi então criada uma rede cujo período de treino foi de Setembro a Dezembro de 2013 e testou-se a referida rede com duas semanas do mesmo período. Na figura 4.17 verifica-se um resultado bastante satisfatório uma vez que a energia prevista (vermelho) e a energia real (azul) se aproximam bastante. Os resultados apoiam os testes de PCA e Coeficiente de *Pearson*, em que as duas variáveis de entrada são as que mais influenciam o consumo de energia. Por um lado temos a ocupação do edifício que varia de uma forma constante, os alunos e professores começam a chegar por volta das 8h em que existe um grande aumento do consumo, atingindo o seu pico por volta da hora de almoço 12h, a partir daí começa a descer até por volta das 20h quando termina o horário de aulas. Num edifício universitário em particular não se nota o período de almoço uma vez que não há um tempo definido, dependendo das aulas os alunos podem fazer diferentes horários de almoço, já num edifício de escritórios com uma hora de almoço fixa seria possível notar o decréscimo significativo de energia e novamente o seu aumento. A ocupação do edifício está diretamente relacionada com as horas do dia, assim podemos considerar que as duas variáveis de complementam, o que resulta num resultado bom.




Figura 4.17 – Consumo efectivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

Relativamente ao gráfico do erro, este encontra-se na figura 4.18, onde se verifica a existência de erros aleatórios sempre menores que 10 kWh. O valor do erro médio é de 2,5% e o seu desvio padrão de 7.6, valores esses que confirmam o que foi dito em cima, o consumo previsto pelo modelo acompanha o consumo efetivo sem grandes diferenças.




Figura 4.18 – Erro de Previsão, Aprendizagem Setembro a Dezembro 2012, Treino Setembro a Dezembro 2012 FCT

Em seguida fez-se o mesmo teste mas com uma rede da FCG. Os resultados encontram-se na figura 4.19, pode-se afirmar que, mais uma vez existe uma grande proximidade de valores entre a energia efetivamente consumida e a prevista, sendo novamente a segunda-feira o caso onde se nota maior dificuldade por parte da rede de prever. O erro médio apresenta um valor um pouco maior, 16% e um desvio padrão de 18,3. Este erro é claramente superior quando comparado com o caso de estudo FCT. Na FCG o consumo energético contou com a energia consumida na produção de água fria (chillers), enquanto no caso de estudo da FCT uma vez que o AVAC esteve fora de serviço, este não teve consumo associado. Como se sabe, o consumo do AVAC está muito relacionado com a temperatura exterior, a falta desse dado leva ao menor desempenho da rede quando são utilizadas apenas duas variáveis de entrada: ocupação e horas.

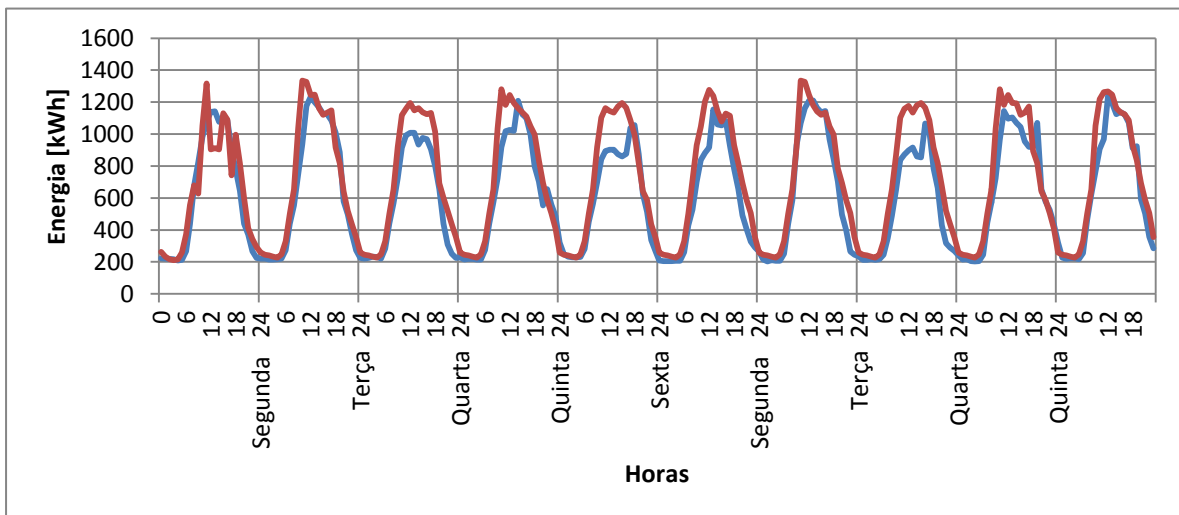


Figura 4.19 – Consumo efectivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG

### c) Uma variável de entrada: ocupação

Uma vez que o principal objetivo da presente dissertação é salientar a importância de se considerar a intervenção/comportamento humano nos consumos de energia e na previsão dos mesmos optou-se por criar mais uma rede, desta vez apenas com uma variável de entrada, a ocupação.

O período de treino da rede é de Setembro a Dezembro 2012 e considerou-se o mesmo período para este teste. Ao analisar a figura 4.20, que reflete o resultado do teste, verifica-se que o consumo efetivo (azul) e o consumo previsto pelo modelo (vermelho) apresentam algumas diferenças, principalmente no período noturno, quando a ocupação é igual a 0. Quando a ocupação tem valores diferentes de zero as diferenças não são tão significativas. Tal deve-se ao facto da rede ter apenas uma variável de entrada. Como esta variável tem períodos regulares de ocupação igual a zero, o processo de aprendizagem da rede considerou para ocupação igual a zero um valor médio de energia. Ao diminuirmos o número de variáveis, embora estejamos também a diminuir a complexidade do modelo, estamos a aumentar a possibilidade de erros. Ao fazer a sua aprendizagem com base em apenas uma variável de entrada, houve fatores que embora influenciem menos o consumo de energia, também representam um papel significativo, nomeadamente as condições meteorológicas e as horas. Ao analisar os dados de entrada a rede aprende que para ocupações iguais a zero o consumo é menor mas constante, não tem em consideração a descida e subida gradual do consumo à medida que o dia vai avançando. Ao introduzirmos a variável horas já é possível relacionar esse decréscimo e respetivo aumento com as horas de funcionamento do edifício, como é possível verificar no teste efetuado que tem como variáveis de entrada a ocupação mas também as horas.




Figura 4.20 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

Uma vez que os valores onde a ocupação é igual zero introduzem muitas diferenças, optou-se por apresentar um gráfico do erro, figura 4.21, apenas para valores de ocupação diferentes de zero, sendo assim possível analisar a precisão da rede.




Figura 4.21 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

Ao analisar a figura 4.21 verificamos que existem erros a rondar os 12 kWh, e variações acentuadas. O erro médio é de 1,9% e o seu desvio padrão de 12,6. Ao retirarmos os valores correspondentes a ocupação igual a zero temos um desempenho da rede muito bom, o que demonstra claramente a grande influência que a ocupação tem no consumo de um edifício.

Realizou-se o mesmo processo mas para a rede da FCG, apresentando-se os resultados em seguida.

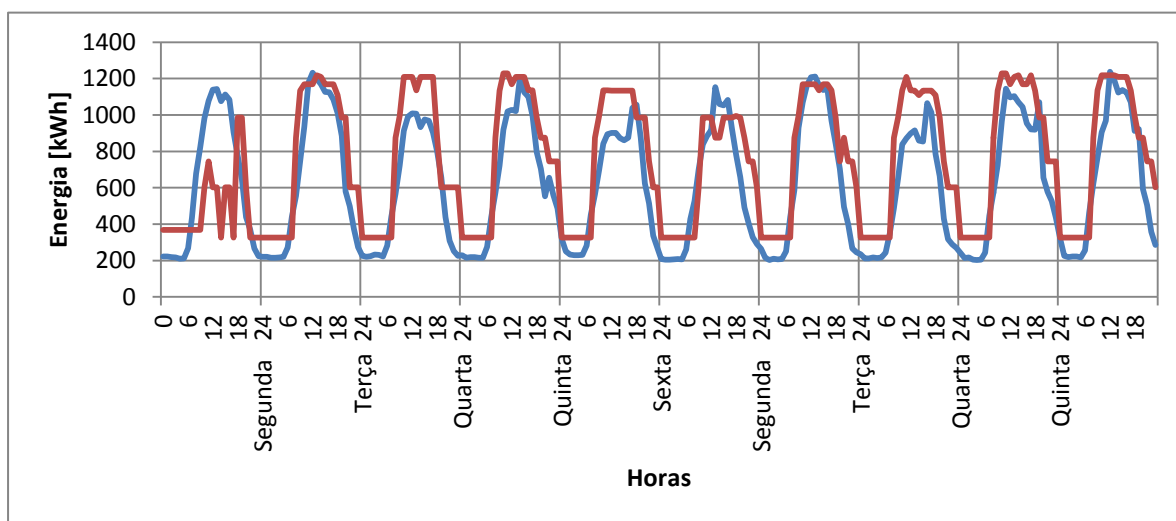


Figura 4.22 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012, FCG

Analisando o gráfico é possível tirar exatamente as mesmas conclusões quando se aplicou este processo à rede da FCT, ou seja, que para valores de ocupação iguais a zeros a rede calcula um valor médio de consumo de energia e repete-o. Como seria de esperar tal facto aumenta o valor de erro médio para 31,9%, sendo o desvio padrão 37,9.

#### d) Quatro variáveis de entrada: ocupação, hora, temperatura e humidade

Tendo em conta os resultados do PCA e dos coeficientes de correlação de Pearson para o caso de estudo FCG, realizou-se um teste considerando como variáveis de entrada as quatro disponíveis, ou seja, ocupação, hora, temperatura e humidade. Os resultados encontram-se na figura 4.23, onde é possível verificar que o consumo previsto pelo modelo (vermelho) é muito próximo ao consumo efetivo (azul). Este teste apresenta um erro de cerca de 10% e um desvio padrão de 28. Analisando estes valores pode-se considerar que a rede apresenta um bom desempenho. Ao introduzirmos uma nova variável estamos a aumentar a complexidade do modelo, aumentando também a probabilidade de errar.




Figura 4.23 – Consumo efetivo de energia vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012, FCG

#### 4.3.1 Rede Neuronal de Fim-de-semana

Verificou-se que tanto no caso de estudo FCT como FCG os fins-de-semana são completamente diferentes dos dias de semana. Na FCT não existem aulas, ou seja, o número de pessoas no edifício

é praticamente nulo, a que corresponde um consumo de energia elétrica muito inferior quando comparado com os dias de semana. Relativamente à FCG a grande diferença é o facto da maioria dos colaboradores da área administrativa não trabalhar ao fim de semana mas continuam a existir concertos ou outros eventos, e também as exposições estão abertas ao público. Assim considerou-se necessária a realização de redes dedicadas exclusivamente dedicadas aos fins-de-semana.

#### a) Três variáveis de entrada: hora, temperatura e ocupação do edifício

Primeiramente considerou-se as três variáveis de entrada, hora, temperatura e ocupação do edifício. O primeiro período de treino escolhido foi o de Setembro a Dezembro de 2012, sendo de seguida apresentados todos os testes realizados.

O primeiro teste consiste em testar a rede com dois fins-de-semana (6 e 7, 13 e 14 de Outubro) do mesmo período de treino, ou seja, Setembro a Dezembro de 2012. Os resultados encontram-se na figura 4.24.

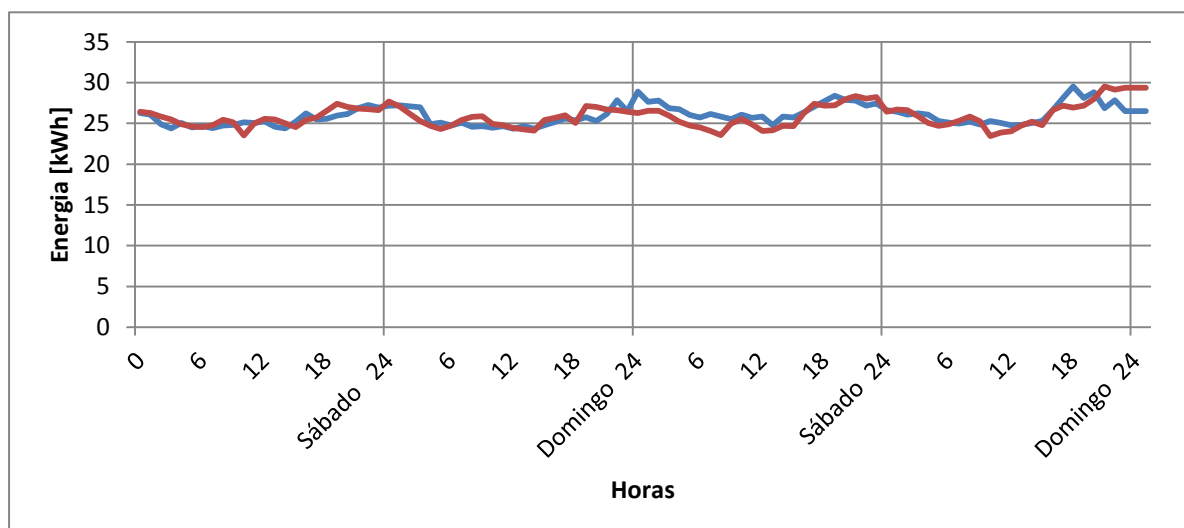


Figura 4.24 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

Ao analisar o gráfico presente na figura 4.24, nota-se que o consumo previsto pelo modelo (vermelho) não apresenta grandes diferenças em relação ao consumo efetivo (azul). Para ter uma melhor noção da relação entre as duas variáveis calculou-se o erro, que se encontra presente na figura 4.25. O valor de erro médio é -0,5% e o seu desvio padrão 3,8. Com base nestes valores pode-se concluir que o resultado deste teste é muito satisfatório pois apresenta poucos erros e desvios, o erro máximo é de 3kW.




Figura 4.25 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012

De seguida testou-se a mesma rede neuronal com um fim-de-semana de Fevereiro (2 e 3 de Fevereiro). O objetivo deste teste é novamente perceber até que ponto a rede consegue extrapolar tendo por base um período de treino diferente do teste a que vai ser sujeita. O resultado encontra-se na figura 4.26 e tal como esperado o consumo previsto pelo modelo (vermelho) não consegue acompanhar o consumo efetivo (azul).




Figura 4.26 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013

Na figura 4.27 encontramos o gráfico do erro inerente ao teste apresentado. É possível verificar a ocorrência de vários erros dos quais o valor máximo ultrapassa os 8kWh. O valor médio do erro é de

-5,7% e o seu desvio padrão 15.6, valores que evidenciam a impossibilidade de testar a rede com dados nada parecidos aos seus dados de treino.

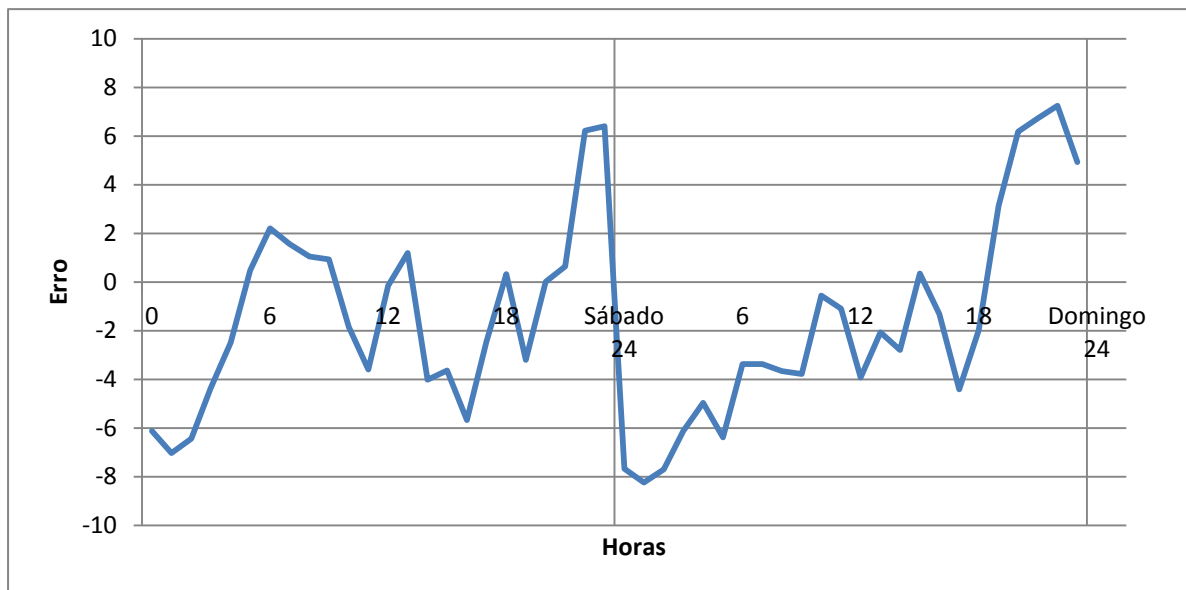


Figura 4.27 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Fevereiro 2013

Considera-se agora o segundo caso de estudo, a fundação Calouste Gulbenkian. Os resultados encontram-se na figura 4.28.

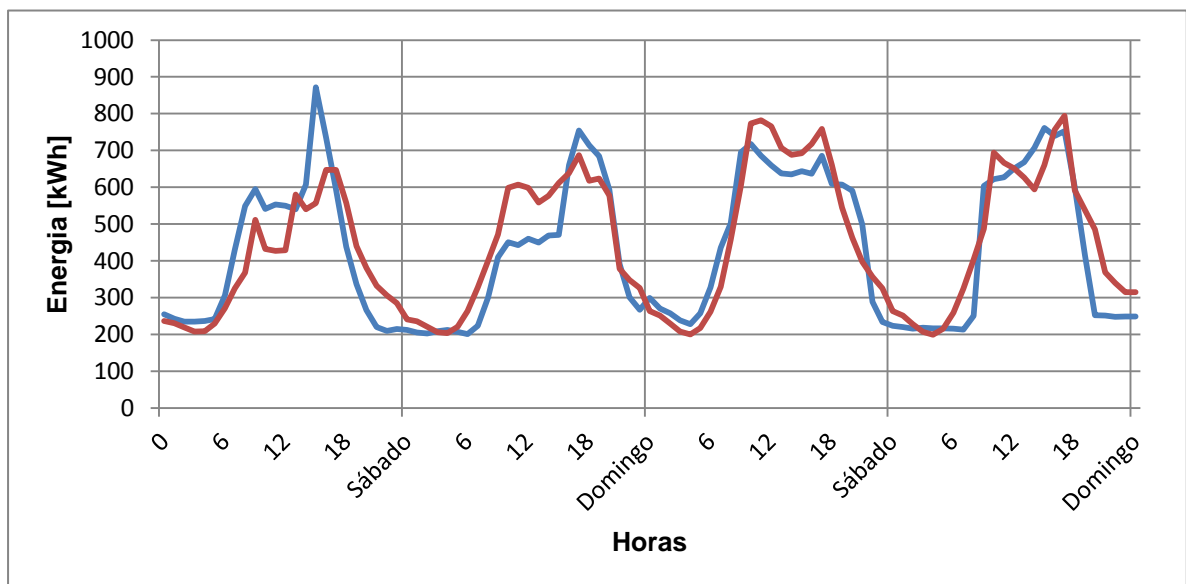


Figura 4.28 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCG

Analisando a figura verifica-se que a energia prevista pelo modelo aproxima-se da energia efetivamente consumida. Este teste apresentou um erro de 7,1% e um desvio padrão de 23.

Observa-se no entanto um pico inesperado na energia efetivamente consumida no primeiro sábado, este pico pode ser explicado através da necessidade dos dois *chillers* disponíveis na central térmica da FCG funcionarem durante um curto período de tempo. Dado que é uma situação que acontece com muito pouca frequência e que introduz uma variação de energia elétrica consumida abrupta inesperada a rede não conseguiu prever esta situação. De qualquer forma o resultado deste teste é bastante positivo, uma vez que além de ter tido um bom resultado serviu também para demonstrar a reação da rede a desvios abruptos a que nunca foi exposta.

O segundo período de treino considerado compreende os meses entre Setembro de 2012 e Fevereiro de 2013, período que engloba duas utilizações do edifício muito diferentes como foi supracitado.

Primeiramente testou-se a rede com um fim-de-semana de Setembro a Dezembro de 2012, apresentando-se o resultado na figura 4.29.




Figura 4.29 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT

Na figura 4.29 é possível notar que apesar de alguns desvios significativos o consumo previsto pelo modelo (vermelho) aproxima-se do consumo efetivo (azul). O erro encontra-se representado na figura 4.30, onde se pode verificar a existência de alguns erros, sendo o maior um pouco superior a 2kWh. O valor do erro médio é de 0,9% e o desvio padrão 3,0.




Figura 4.30 – Erro de previsão, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT

Ainda com o mesmo período de aprendizagem realizou-se um teste com uma semana de Fevereiro. O resultado encontra-se na figura 4.31, através do qual se pode concluir um bom comportamento por parte do consumo previsto pelo modelo (vermelho), uma vez que este acompanha o consumo efetivo (azul).

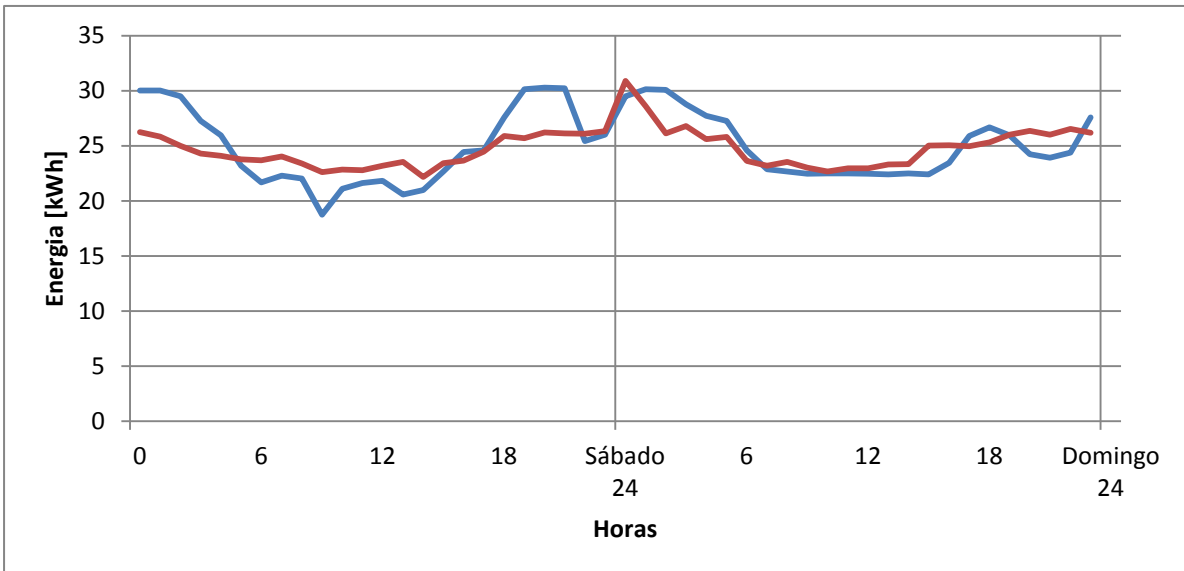


Figura 4.31 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Fevereiro 2013 FCT

Através do gráfico do erro de previsão, figura 4.32, nota-se a existência de erros, principalmente no sábado de teste onde ocorrem erros superiores a 4kWh. Apresenta um erro médio de -0,07% e um desvio padrão de 8,4.

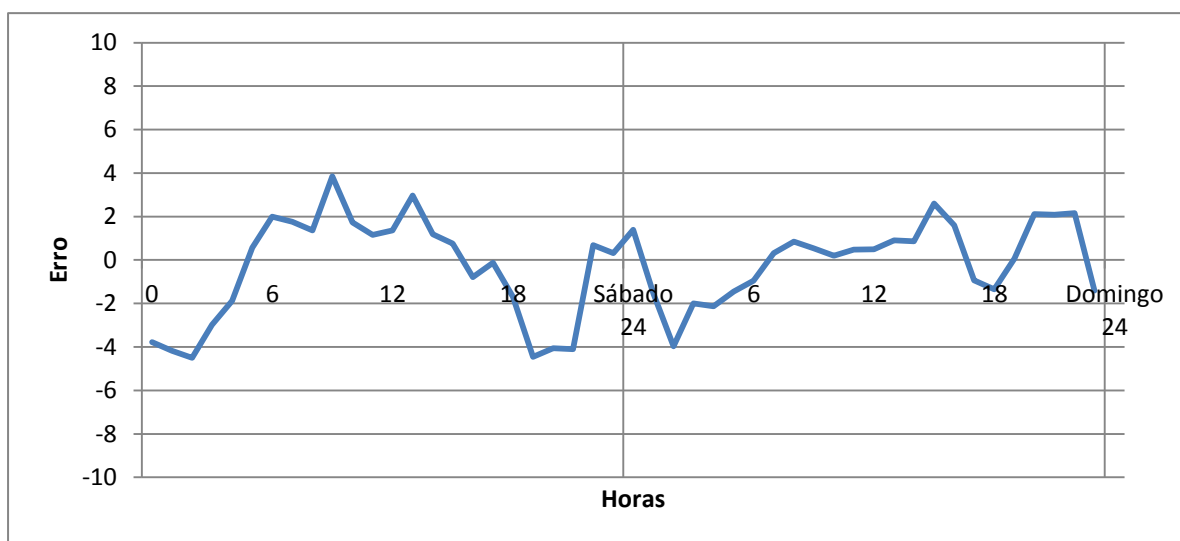


Figura 4.32 – Erro de previsão, Aprendizagem Setembro 2012 a Fevereiro 2013, Teste Fevereiro 2013 FCT

Considerando agora um período de treino de Janeiro a Fevereiro de 2013, realizou-se um teste com um fim-de-semana de Fevereiro de 2013, presente na figura 4.33. É possível notar algumas oscilações no consumo previsto pelo modelo (vermelho) ao tentar acompanhar o consumo efetivo (azul).




Figura 4.33 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Janeiro a Fevereiro 2013, Teste Fevereiro 2013 FCT

Relativamente ao erro presente neste teste encontra-se na figura 4.34. O seu valor máximo ronda os 8 kWh, o médio os 2,5% e o desvio padrão 10,1. Embora apresente alguns valores de erro superiores a 5, apresenta também valores de erro próximos de zero que não são significativos.




Figura 4.34 – Erro de previsão, Aprendizagem Janeiro a Fevereiro 2013, Teste Fevereiro 2013 FCT

Com o mesmo período de treino testou-se o modelo com uma semana de Setembro a Dezembro de 2012. O resultado encontra-se na figura 4.35 e, tal como esperado, demonstra a falta de capacidade da rede de generalizar. O consumo efetivo (azul) encontra-se na ordem dos 20 a 30 kWh, por outro lado o consumo previsto pelo modelo encontra-se entre os valores de 40 a 60 kWh. Ao ser confrontada com valores de entrada muito diferentes daqueles com que foi treinada, a rede ao fazer uma relação entre o que aprendeu e estes novos dados considerou que o consumo deveria ser muito maior do que é na realidade.




Figura 4.35 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Janeiro a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT

Relativamente ao gráfico do erro, encontra-se presente na figura 4.36. É possível verificar erros no valor de 30kWh e nunca próximos de zero. O erro médio é de 95,4% e o seu desvio padrão de 17,0. Pode-se concluir que este foi o teste que apresentou pior desempenho até agora.

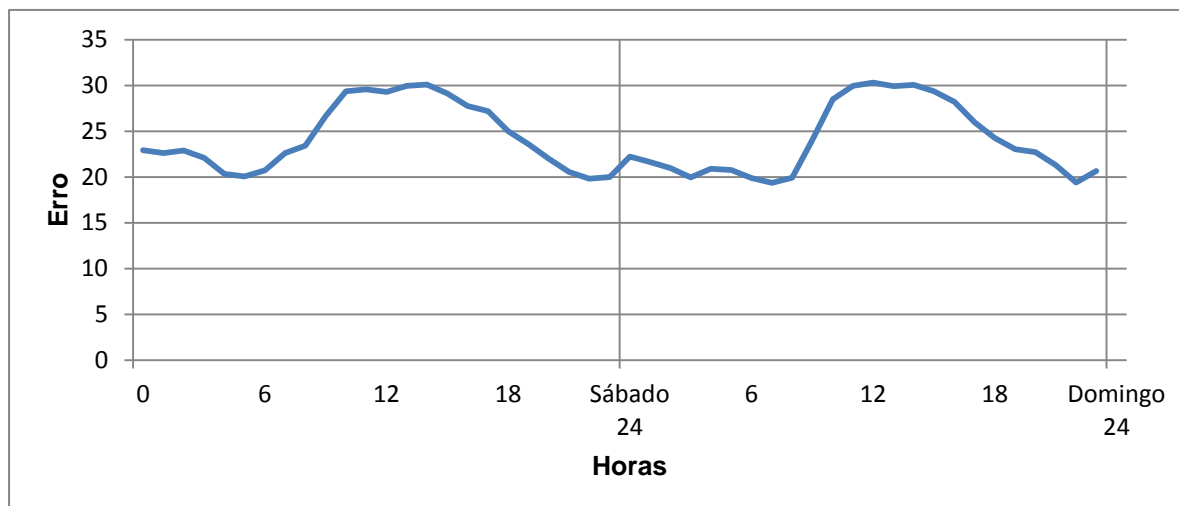


Figura 4.36 – Erro de previsão, Aprendizagem Janeiro a Fevereiro 2013, Teste Setembro a Dezembro 2012 FCT

#### b) Duas variáveis de entrada: ocupação e hora

Tal como no caso das redes neuronais de semana, decidiu-se fazer testes com as variáveis consideradas mais significativas pelos testes realizados (PCA e correlação de *Pearson*), ocupação e horas.

Realizou-se apenas um teste, em que tanto o período de treino como de teste é de Setembro a Dezembro de 2012. Na figura 4.37 é possível observar o resultado, embora apresente alguns erros e não seja tão uniforme como no caso das três variáveis de entrada, pode-se dizer que o consumo previsto pelo modelo (azul) acompanha o consumo efetivo (vermelho).




Figura 4.37 – Consumo efetivo vs Consumo previsto pelo modelo, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT

Relativamente ao erro resultante deste teste, encontra-se na figura 4.38, e apresenta erro máximo na ordem dos 3kWh. O valor de erro médio é de -0,8% e o seu desvio padrão 4,5.




Figura 4.38 – Erro de previsão, Aprendizagem Setembro a Dezembro 2012, Teste Setembro a Dezembro 2012 FCT



# Capítulo 5

## Discussão

Embora alguns dos resultados obtidos já fossem esperados no início da realização da presente dissertação, tais como a existência de um erro menor para testes em que o período de treino e o de teste coincidiam ou o facto do comportamento humano ser uma variável importante para a previsão do consumo energético, foi possível perceber até que ponto dependem as previsões de consumos de eletricidade de certas variáveis.

Tabela 5. 1 - Comparação dos Resultados das Redes Semanais FCT

<b>Rede Neuronal de Semana</b>		
<b>3 variáveis de entrada: ocupação, horas e temperatura</b>		
<b>Treino/Teste</b>	<b>Desvio Padrão</b>	<b>Erro Médio [%]</b>
<b>Treino Set. a Dez. 2012</b> <b>Teste Set. a Dez. 2012</b>	8,7	3,6
<b>Treino Set. a Dez. 2012</b> <b>Teste Fev. 2013</b>	n.c	n.c
<b>Treino Set. 2012 a Fev. 2013</b> <b>Teste Set. a Dez. 2012</b>	8,7	2,7
<b>Treino Set. 2012 a Fev. 2013</b> <b>Teste Fev. 2013</b>	<b>8.6</b>	<b>2.0</b>
<b>Treino Jan. a Fev. 2013</b> <b>Teste Fev. 2013</b>	9,8	2,5
<b>Treino Jan. a Fev. 2013</b> <b>Teste Set. a Dez. 2012</b>	12,7	-2,3

---

**2 variáveis de entrada: ocupação e horas**

<b>Treino Set. a Dez. 2012</b>	7,6	2,5
<b>Teste Set. a Dez. 2012</b>		

**1 variável de entrada: ocupação**

<b>Treino Set. a Dez. 2012</b>	12,6	1,9
<b>Teste Set. a Dez. 2012</b>		

Ao analisar a tabela 5.1, onde se encontram os valores que nos permitem caracterizar os diferentes resultados obtidos, é possível verificar que, ao considerar três variáveis de entrada, a rede que revela um erro médio menor é aquela cujo treino foi de Setembro de 2012 a Fevereiro de 2013 e em que o teste de Fevereiro de 2013. Esta rede é aquela cujo período de treino é maior, e na qual o período de teste apresenta maior uniformidade, uma vez que não há muitas variações na taxa de ocupação ao longo do dia. O menor valor de erro acontece ao ser considerada apenas uma variável de entrada, a ocupação. No entanto, este erro corresponde a valores de ocupação diferentes de zero, uma vez que para ocupação igual a zero a previsão da rede apresentava valores de erro consideráveis. Tal resultado suporta a importância da variável humana na previsão de consumos.

Por outro lado, o maior valor de erro acontece quando o período de treino é de Setembro a Dezembro de 2012 e o período de teste também. À primeira vista este poderia ser um resultado sem sentido uma vez que, sendo o período de treino igual a período de teste deveria apresentar um bom resultado. Tal não se verifica porque neste período existem diversas variações a todos os níveis, nomeadamente na ocupação que varia ao longo do dia e ao longo da semana, assim como a temperatura que no mês de Setembro é mais elevada e vai diminuindo gradualmente até Dezembro. Esta rede irá sempre apresentar maior variação do que uma rede com valores de ocupação e temperatura mais uniformes.

Relativamente às redes de fim-de-semana, a comparação entre todos os testes realizados encontra-se presente na tabela 5.2. Também neste caso a rede que revela um erro menor é a rede cujo treino foi de Setembro de 2012 a Fevereiro de 2013, apresentando um erro negativo de 0,07.

Tabela 5. 2 - Comparação dos resultados das redes de fim-de-semana FCT

<b>Rede Neuronal de Fim de Semana</b>		
<b>3 variáveis de entrada: ocupação, horas e temperatura</b>		
<b>Treino/Teste</b>	<b>Desvio Padrão</b>	<b>Erro Médio [%]</b>
<b>Treino Set. a Dez. 2012</b>	3,8	-0,5
<b>Teste Set. a Dez. 2012</b>		
<b>Treino Set. a Dez. 2012</b>	15,6	-5,7
<b>Teste Fev. 2013</b>		
<b>Treino Set. 2012 a Fev. 2013</b>	3,0	0,9
<b>Teste Set. a Dez. 2012</b>		
<b>Treino Set. 2012 a Fev. 2013</b>	8,4	<b>-0,07</b>
<b>Teste Fev. 2013</b>		
<b>Treino Jan. a Fev. 2013</b>	10,1	2,5
<b>Teste Fev. 2013</b>		
<b>Treino Jan. a Fev. 2013</b>	17,0	95,4
<b>Teste Set. a Dez. 2012</b>		
<b>2 variáveis de entrada: ocupação e horas</b>		
<b>Treino Set. a Dez. 2012</b>	4,5	-0,84
<b>Teste Set. a Dez. 2012</b>		

Assim, é possível perceber que vários fatores podem influenciar o comportamento de uma rede neuronal. Desses fatores destacam-se o período de treino e de teste e a uniformidade ou não dos dados.

Para aprofundar a questão levantada pela uniformidade dos dados disponíveis apresentam-se agora os resultados obtidos com o caso de estudo da FCG. O período de treino coincidiu com o período de teste, Setembro a Dezembro de 2012. Em ambos os testes, o erro foi sempre superior, quando comparado com o caso estudo da FCT. Tais resultados devem-se ao facto de haver muito mais oscilações no que diz respeito à ocupação uma vez que a existência de eventos na FCG não é constante no tempo, ou seja, num dia podem haver mais ou menos eventos independentemente do dia da semana ou da hora do dia. Assim, é mais difícil para a rede aprender através de exemplos, uma vez que os seus exemplos são bastante variáveis. Na tabela 5.3, onde constam todos os resultados da FCG, é possível observar que o menor valor de erro acontece na rede neuronal de 3 variáveis de entrada.

Tabela 5. 3 - Comparação dos Resultados das Redes Semanais FCG

<b>Rede Neuronal de Semana</b>		
<b>3 variáveis de entrada: ocupação, horas e temperatura</b>		
<b>Treino/Teste</b>	<b>Desvio Padrão</b>	<b>Erro Médio [%]</b>
<b>Treino Set. a Dez. 2012</b>	24,4	7,4
<b>Teste Set. a Dez. 2012</b>		
<b>2 variáveis de entrada: ocupação e horas</b>		
<b>Treino Set. a Dez. 2012</b>	18,3	16
<b>Teste Set. a Dez. 2012</b>		
<b>1 variável de entrada: ocupação</b>		
<b>Treino Set. a Dez. 2012</b>	37,9	31,9
<b>Teste Set. a Dez. 2012</b>		
<b>4 variáveis de entrada: ocupação, hora, temperatura e humidade</b>		
<b>Treino Set. a Dez. 2012</b>	28	10
<b>Teste Set. a Dez. 2012</b>		

Relativamente à rede de fim de semana da FCG optou-se por realizar apenas um teste utilizando três variáveis de entrada e o período de treino igual ao período de teste. O erro apresentado foi de 7.1%, inferior ao que se obteve na rede neuronal de semana com as mesmas características.

Tabela 5. 4 - Comparação dos Resultados das Redes de Fim de Semana FCG

<b>Rede Neuronal de Fim de Semana</b>		
<b>3 variáveis de entrada: ocupação, horas e temperatura</b>		
<b>Treino/Teste</b>	<b>Desvio Padrão</b>	<b>Erro Médio [%]</b>
<b>Treino Set. a Dez. 2012</b>	23	7,1
<b>Teste Set. a Dez. 2012</b>		



# Conclusão

No presente capítulo descrevem-se as conclusões da presente dissertação.

Esta dissertação teve como objetivo a apresentação de um método, com várias fases, capaz de prever os consumos de energia, considerando e destacando a variável humana e as vantagens da sua inclusão nos métodos preditivos de consumos energéticos.

O método apresentado consistiu, numa primeira fase, na escolha das variáveis de entrada com uma maior relevância para a previsão do consumo de energia. Para tal, usaram-se dois métodos, os coeficientes de correlação de *pearson* e as componentes principais. Os resultados foram os esperados, tendo ficado demonstrada a relação existente entre a ocupação dos espaços e o consumo de energia. Também é de salientar a relação entre as horas do dia e o consumo de energia, uma vez que, normalmente, os edifícios seguem horários semanais. Em edifícios como a FCT nota-se um aumento do consumo quando se inicia o horário de aulas e a sua diminuição quando este termina. Já no caso da FCG, além de se notar o início e fim do horário laboral através do respetivo aumento e diminuição do consumo de energia, pode acrescentar-se a hora de almoço, onde existe um pequeno decréscimo, e os dias de eventos onde, por vezes existe um aumento significativo do consumo de energia, ou não dependendo do tipo de evento. Mais notório no caso FCG foi a relação da energia com a humidade e a temperatura exterior. Estas variáveis influenciam o funcionamento dos produtores de energia térmica (*chillers*), cujo consumo é uma parte significativa da fatura energética de um edifício.

Em seguida, com as variáveis de entrada definidas, estabeleceu-se uma arquitetura de redes neuronais. A rede neuronal escolhida foi uma *multilayer feedforward* com o algoritmo de treino *levenberg-marquardt backpropagation*. Os resultados obtidos comprovam a adequação da rede e do algoritmo escolhido ao problema proposto. Com o objetivo de chegar a resultados abrangentes foram realizados diversos testes, tendo por base os dois edifícios de estudo, a Faculdade de Ciências e Tecnologias da Universidade Nova de Lisboa e a Fundação Calouste Gulbenkian.

A primeira conclusão a que se chegou, através dos resultados obtidos, foi o facto das redes neuronais só conseguirem prever situações para as quais foram treinadas, ou seja, se o período de treino e o de teste for diferente entre si os resultados não serão tão bons. Mas a uniformidade também tem um papel importante, caso a semana ou o fim de semana de teste consista num período muito uniforme sem grandes diferenças, pode melhorar os resultados mesmo sendo diferente do período de treino.

Ao introduzirmos mais um caso de estudo, neste caso a FCG, enriqueceram-se os resultados na medida em que foi possível verificar realmente a dificuldade que as redes neuronais têm em adaptar-se a diferenças bruscas que nunca tenham experienciado no período de treino.

É possível também concluir que ao aumentarmos o número de variáveis de entrada, diminuimos o erro de previsão, uma vez que embora existam variáveis mais pertinentes do que outras, todas explicam o consumo de energia.

Por fim, pode-se concluir que a presente dissertação conseguiu realizar aquilo a que se propôs, ou seja, demonstrar a importância da utilização da variável humana na previsão do consumo de energia em edifício.

Em trabalhos futuros seria necessário uma variável de ocupação humana mais precisa, como por exemplo, um contador de pessoas, assim seria possível saber a cada momento o número de pessoas presentes num edifício sem ser necessário estar a fazer uma estimativa.

# Bibliografia

- [1] International Energy Agency (2013), *World Energy Outlook 2013*. Acedido em 25 de março de 2014, em [www.iea.org](http://www.iea.org).
- [2] International Energy Agency(2014). *IEA Building Activities*. Acedido em 30 de abril de 2014, em: [www.iea.org](http://www.iea.org).
- [3] World Business Council for Sustainable Development (2008). *Energy Efficiency in Buildings - Business realities and opportunities*. WBSCD.
- [4] PORDATA (2014). *Ambiente, Energia e Território - Consumo de Energia Elétrica*. Acedido em 30 de abril de 2014, em: [www.pordata.pt](http://www.pordata.pt).
- [5] Kwok SSK, Yuen RKK, Lee EWM. An intelligent approach to assessing the effect of building occupancy on building cooling load prediction. *Building and Environment*. 2011;46:1681-90.
- [6] Leung MC, Tse NCF, Lai LL, Chow TT. The use of occupancy space electrical power demand in building cooling load prediction. *Energy and Buildings*. 2012;55:151-63.
- [7] Neto AH, Fiorelli FAS. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. *Energy and Buildings*. 2008;40:2169-76.
- [8] Dong B, Cao C, Lee SE. Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*. 2005;37:545-53.
- [9] Ben-Nakhi AE, Mahmoud MA. Cooling load prediction for buildings using general regression neural networks. *Energy Conversion and Management*. 2004;45:2127-41.
- [10] Li K, Su H. Forecasting building energy consumption with hybrid genetic algorithm-hierarchical adaptive network-based fuzzy inference system. *Energy and Buildings*. 2010;42:2070-6.
- [11] Kalogirou SA. Applications of artificial neural networks in energy systems. *Energy Conversion and Management*. 1999;40:1073-87.
- [12] Dipti S, Chang CS, Liew AC. Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting. *Power Systems, IEEE Transactions on*. 1995;10:1897-903.
- [13] Lee Y-S, Tong L-I. Forecasting nonlinear time series of energy consumption using a hybrid dynamic model. *Applied Energy*. 2012;94:251-6.
- [14] Escrivá-Escrivá G, Álvarez-Bel C, Roldán-Blay C, Alcázar-Ortega M. New artificial neural network prediction method for electrical consumption forecasting based on building end-uses. *Energy and Buildings*. 2011;43:3112-9.

- [15] Kusiak A, Li M, Zhang Z. A data-driven approach for steam load prediction in buildings. *Applied Energy*. 2010;87:925-33.
- [16] Haykin S. *Neural Networks: A Comprehensive Foundation* (1999).
- [17] *Principal Component Analysis*, Acedido em 3 de Janeiro de 2014, <http://support.sas.com/publishing/pubcat/chaps/55129.pdf>.
- [18] Marôco J. *Análise Estatística com o SPSS Statistics*, (2011).
- [19] *Pearson's Correlation*, Acedido em 9 de Janeiro de 2014, [www.statstutor.ac.uk/resources/uploaded/pearsons.pdf](http://www.statstutor.ac.uk/resources/uploaded/pearsons.pdf).