



José Miguel Costa de Barros Ferreira

Licenciado em
Ciências da Engenharia Eletrotécnica e de Computadores

Previsão Fotovoltaica: Utilização de Modelos Neuronais para previsões a 24 horas

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

Orientador: João Murta Pina, Professor Auxiliar, FCT UNL

Coorientador: Luís Miguel Vieira Rebelo Bernardes, Eng. Eletrotécnico

Júri:

Presidente: Doutor Tiago Oliveira Cardoso – FCT UNL

Arguentes: Doutor Pedro Ribeiro Pereira – FCT UNL

Vogais: Doutor João Murta Pina – FCT UNL



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

12 de Dezembro, 2016

Previsão Fotovoltaica: Utilização de modelos neuronais para previsões a 24 horas

Copyright © José Miguel Costa de Barros Ferreira, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

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

Gostaria de começar por agradecer ao meu orientador, o Professor João Pina, por me ter dado a oportunidade de trabalhar neste tema e pela ajuda fornecida.

Agradeço também ao meu coorientador, o Engenheiro Luís Bernardes, por me ter possibilitado a utilização de dados reais para o desenvolvimento do trabalho.

Seguidamente gostaria de agradecer à minha família, em particular aos meus pais, à minha irmã e aos meus avós por todo o apoio e ajuda que me forneceram ao longo desta jornada.

Aos meus colegas e aos meus amigos, em particular ao Fábio, ao Neto, ao Gomes, ao Gonçalo, ao Rúben, ao André, ao Aquino e ao Gustavo pela amizade e apoio dados.

Resumo

Nos anos recentes, tem-se verificado um aumento no investimento e desenvolvimento de energias renováveis, nomeadamente a energia fotovoltaica.

Os maiores problemas relacionados com a produção deste tipo de energia, estão associados à imprevisibilidade das alterações climáticas, constituindo este fator um dos que mais impacto tem na produção, quer através do sombreamento dos painéis quer por variações de temperatura ambiente.

Para colmatar o impacto negativo que estes fatores têm na produção energética, pode-se recorrer a técnicas de previsão de produção. Estas técnicas permitem, entre outros aspetos, melhorar o planeamento do consumo energético.

Nesta tese foram utilizados modelos baseados em redes neuronais para efetuar a previsão de produção de uma instalação fotovoltaica num horizonte de 24 horas, tendo sido comparados os resultados obtidos de 20 modelos diferentes referentes ao ano de 2015.

Palavras-chave: Energia Fotovoltaica, Redes Neuronais, Previsão de produção.

Abstract

In the recent years there has been an increase in the investment and development of renewable energies, namely in photovoltaic energy.

The biggest issue associated with the production of this type of energy is the unpredictability of weather conditions, namely the cloud coverage and changes in air temperature.

To counteract the negative impact that these possible shifts in power production might have, there are several production prediction techniques that can be used. By using these, it is possible to obtain an improvement in the energy management for consumption, among other benefits.

In this thesis, several neural network based models were used to predict photovoltaic production within a 24 hour horizon, comparing the results obtained from 20 different models with data referring to the year of 2015.

Keywords: Photovoltaic Energy, Neural Networks, Production prediction.

Conteúdo

1. INTRODUÇÃO.....	13
1.1. ENQUADRAMENTO	13
1.2. MOTIVAÇÃO	14
1.3. OBJETIVOS.....	14
1.4. CONTRIBUIÇÕES.....	15
2. REVISÃO BIBLIOGRÁFICA.....	16
2.1. REDES NEURONAIS	16
2.1.1. Componentes internos de um neurónio artificial	17
2.1.2. Tipos de redes neuronais.....	19
2.1.3. Treino de uma rede neuronal.....	20
2.1.4. Perigos pós-treino de uma rede neuronal.....	21
2.2. MODELOS DE PREVISÃO DE CONDIÇÕES ATMOSFÉRICAS.....	22
2.2.1. Método de previsão Total Sky Imagery.....	23
2.2.2. Vetores de movimento de nuvens com base em satélites.....	25
2.2.3. Métodos baseados em técnicas de aprendizagem estocásticas.....	27
2.2.4. Métodos de previsão meteorológicos numéricos.....	27
2.2.5. Pós-processamento de modelos NWP.....	28
2.3. ENERGIA FOTOVOLTAICA.....	31
3. METODOLOGIA UTILIZADA.....	34
3.1. OBTENÇÃO E TRATAMENTO DE DADOS.....	34
3.2. CRIAÇÃO DOS MODELOS DE PREVISÃO	36
3.2.1. Ferramenta utilizada.....	36
3.2.2. Modelos.....	37

3.3. MÉTRICAS DE COMPARAÇÃO	39
4. ESTUDO DE CASO: COMPANHIA NACIONAL DE CARNES.....	41
4.1. INSTALAÇÃO.....	41
4.2. ASSUNÇÕES PRÉVIAS.....	44
4.3. MODELOS CRIADOS	44
4.4. ESTUDO DOS MODELOS EFETUADOS.....	45
4.4.1. Janeiro.....	45
4.4.2. Fevereiro.....	50
4.4.3. Março.....	55
4.4.4. Abril.....	59
4.4.5. Maio.....	63
4.4.6. Junho.....	67
4.4.7. Julho	71
4.4.8. Agosto.....	75
4.4.9. Setembro.....	79
4.4.10. Outubro.....	83
4.4.11. Novembro	87
4.4.12. Dezembro.....	91
4.5. UTILIZAÇÃO DO MODELO PARA REALIZAR PREVISÕES A 24 HORAS	95
4.6. ESTUDO GERAL DO MODELO	97
5. CONCLUSÕES E TRABALHO FUTURO	102
REFERÊNCIAS BIBLIOGRÁFICAS	107

Índice de Figuras

FIGURA 1 - EXEMPLO DE NEURÓNIO ARTIFICIAL (PHILIPP, 1994).....	17
FIGURA 2 - EXEMPLO DE UM NEURÓNIO ARTIFICIAL EM DETALHE	17
FIGURA 3 - EXEMPLO DE UMA REDE NEURONAL MULTICAMADA	20
FIGURA 4- EXEMPLO DE UM EQUIPAMENTO <i>WHOLE SKY IMAGER</i> (“DRIVE DATABASE,” N.D.).....	24
FIGURA 5 - EXEMPLO DE UMA IMAGEM DE CLOUD MOTION VECTOR (FONTE: HTTP://SATELLITE.IMD.GOV.IN/ARCHIVE/).....	26
FIGURA 6 - IMAGEM COM PREVISÕES OBTIDA ATRAVÉS DE UM MODELO NWP (FONTE: HTTP://POLAR.NCEP.NOAA.GOV/WAVES/WEB/).....	28
FIGURA 7- ILUSTRAÇÃO DO FUNCIONAMENTO DE UMA CÉLULA FOTOVOLTAICA (HERSCH & ZWEIBEL, 1982).....	32
FIGURA 8 - PAINÉIS NA INSTALAÇÃO FOTOVOLTAICA EM ESTUDO.....	35
FIGURA 9 - INTERFACE DE CRIAÇÃO DE REDES NEURONAIS NA <i>TOOLBOX</i>	36
FIGURA 10 - INTERFACE DE TREINO DE REDES NEURONAIS NA <i>TOOLBOX</i>	37
FIGURA 11 - LOCALIZAÇÃO DA INSTALAÇÃO FOTOVOLTAICA EM ESTUDO.....	42
FIGURA 12 - EXEMPLO DE CORTE NA PRODUÇÃO DA INSTALAÇÃO	43
FIGURA 13- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE JANEIRO DE 2015.....	46
FIGURA 14 - PERÍODOS DE ESTUDO PARA O MÊS DE JANEIRO.....	47
FIGURA 15 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE JANEIRO	48
FIGURA 16 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE JANEIRO	48
FIGURA 17- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE FEVEREIRO DE 2015	51
FIGURA 18- PERÍODOS DE ESTUDO PARA O MÊS DE FEVEREIRO.....	52
FIGURA 19 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE FEVEREIRO	52
FIGURA 20 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE FEVEREIRO.....	53
FIGURA 21- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE MARÇO DE 2015.....	55
FIGURA 22- PERÍODOS DE ESTUDO PARA O MÊS DE MARÇO.....	56

FIGURA 23 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE MARÇO	57
FIGURA 24 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE MARÇO	57
FIGURA 25- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE ABRIL DE 2015	59
FIGURA 26- PERÍODOS DE ESTUDO PARA O MÊS DE ABRIL	60
FIGURA 27 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE ABRIL	61
FIGURA 28 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE ABRIL	61
FIGURA 29- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE MAIO DE 2015	63
FIGURA 30- PERÍODOS DE ESTUDO PARA O MÊS DE MAIO	64
FIGURA 31 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE MAIO	64
FIGURA 32 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE MAIO	65
FIGURA 33- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE JUNHO DE 2015	67
FIGURA 34- PERÍODOS DE ESTUDO PARA O MÊS DE JUNHO	68
FIGURA 35 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE JUNHO	69
FIGURA 36 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE JUNHO	69
FIGURA 37- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE JULHO DE 2015	71
FIGURA 38- PERÍODOS DE ESTUDO PARA O MÊS DE JULHO	72
FIGURA 39 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE JULHO	73
FIGURA 40 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE JULHO	73
FIGURA 41- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE AGOSTO DE 2015	75
FIGURA 42- PERÍODOS DE ESTUDO PARA O MÊS DE AGOSTO	76
FIGURA 43 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE AGOSTO	77
FIGURA 44 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE AGOSTO	77
FIGURA 45- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE SETEMBRO DE 2015	79
FIGURA 46- PERÍODOS DE ESTUDO PARA O MÊS DE SETEMBRO	80
FIGURA 47 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE SETEMBRO	81
FIGURA 48 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE SETEMBRO	81
FIGURA 49- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE OUTUBRO DE 2015	83
FIGURA 50- PERÍODOS DE ESTUDO PARA O MÊS DE OUTUBRO	84
FIGURA 51 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE OUTUBRO	85
FIGURA 52 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE OUTUBRO	85
FIGURA 53- PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE NOVEMBRO DE 2015	87
FIGURA 54- PERÍODOS DE ESTUDO PARA O MÊS DE NOVEMBRO	88
FIGURA 55 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE NOVEMBRO	89
FIGURA 56 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE NOVEMBRO	89
FIGURA 57 - PRODUÇÃO ENERGÉTICA HORÁRIA AO LONGO DO MÊS DE DEZEMBRO DE 2015	91
FIGURA 58- PERÍODOS DE ESTUDO PARA O MÊS DE DEZEMBRO	92

FIGURA 59 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO ESTÁVEL DE DEZEMBRO	93
FIGURA 60 - COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 5 HORAS NO PERÍODO INSTÁVEL DE DEZEMBRO.....	93
FIGURA 61 - PERÍODOS DE MAIO E AGOSTO DE 2015 ESCOLHIDOS PARA REALIZAR A PREVISÃO A 24 HORAS	95
FIGURA 62 - RESULTADOS DA PREVISÃO A 24 HORAS NO PERÍODO DE MAIO	96
FIGURA 63 - RESULTADOS DA PREVISÃO A 24 HORAS NO PERÍODO DE AGOSTO	96
FIGURA 64 - CONJUNTO DE DADOS NORMALIZADOS ESCOLHIDOS PARA TESTAR OS MODELOS ANUAIS.....	97
FIGURA 65 - RESULTADOS OBTIDOS PELOS MODELOS DE COMPARAÇÃO DO CONJUNTO DE DADOS ESCOLHIDOS.....	98
FIGURA 66 - PERÍODOS DE ESTUDO PARA O CASO DE ESTUDO DE ATUALIZAÇÃO DE PREVISÃO	99
FIGURA 67- COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 10HORAS NO PERÍODO ESTÁVEL DO CASO COMPARATIVO DE ATUALIZAÇÃO DE PREVISÃO.....	100
FIGURA 68- COMPORTAMENTO DOS MODELOS COM UM HISTÓRICO DE 10HORAS NO PERÍODO INSTÁVEL DO CASO COMPARATIVO DE ATUALIZAÇÃO DE PREVISÃO.....	100

Índice de Tabelas

TABELA 1 – CARACTERÍSTICAS DOS PAINÉIS FOTOVOLTAICOS UTILIZADOS.....	42
TABELA 2 - CARACTERÍSTICAS DOS INVERSORES UTILIZADOS.....	43
TABELA 3 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE JANEIRO.....	49
TABELA 4 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE JANEIRO.....	50
TABELA 5 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE FEVEREIRO.....	54
TABELA 6 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE FEVEREIRO.....	54
TABELA 7 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE MARÇO.....	58
TABELA 8- COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE MARÇO.....	58
TABELA 9 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE ABRIL	62
TABELA 10 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE ABRIL.....	62
TABELA 11 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE MAIO.....	66
TABELA 12 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE MAIO.....	66
TABELA 13 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE JUNHO.....	70
TABELA 14 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE JUNHO.....	70
TABELA 15 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE JULHO.....	74
TABELA 16 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE JULHO.....	74
TABELA 17 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE AGOSTO.....	78
TABELA 18 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE AGOSTO.....	78
TABELA 19 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE SETEMBRO.....	82
TABELA 20 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE SETEMBRO.....	82

TABELA 21 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE OUTUBRO	86
TABELA 22 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE OUTUBRO	86
TABELA 23 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE NOVEMBRO	90
TABELA 24 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE NOVEMBRO	90
TABELA 25 - COMPARAÇÃO DO ERRO MÉDIO PARA OS MODELOS COM UM HISTÓRICO DE 5 HORAS PARA O MÊS DE DEZEMBRO.....	94
TABELA 26 - COMPARAÇÃO DO ERRO MÉDIO PARA OS CASOS ÓTIMOS EM CADA UM DOS TIPOS DE MODELO DIFERENTES PARA O MÊS DE DEZEMBRO	94
TABELA 27 – ERROS OBTIDOS NAS PREVISÕES DURANTE OS PERÍODOS ESCOLHIDOS.....	97
TABELA 28- ERROS PERCENTUAIS MÉDIOS DOS MODELOS NORMALIZADOS E NÃO NORMALIZADOS PARA O INTERVALO DE ESTUDO	99
TABELA 29 - CONFIGURAÇÕES COM OS MELHORES RESULTADOS PARA CADA MÊS DE 2015	104

1.Introdução

Neste capítulo elaborámos um enquadramento genérico dos benefícios associados à previsão de produção de energia fotovoltaica, sendo também referidas a motivação e objetivos desta tese, aos quais se junta contribuições futuras que este trabalho possa fornecer relativamente à previsibilidade de produção de energia fotovoltaica.

1.1. Enquadramento

A energia é vital em todas as economias. Constitui um fator básico em praticamente todos os processos produtivos e uma rubrica importante no consumo das famílias. As características estruturais em termos de produção e consumo de energia, bem como alterações nos preços e acessibilidade desta, têm um forte impacto na maior parte das variáveis económicas de um país.

No contexto das energias alternativas ou renováveis, a energia fotovoltaica é das que maior crescimento tem tido nos últimos anos, sendo que em alguns países europeus a produção corresponde a 30% do valor total em condições climáticas apropriadas(Pelland, Remund, Kleissl, Oozeki, & Brabandere, 2013).

Apesar do crescimento que se tem assistido, a utilização da energia fotovoltaica apresenta alguns problemas incontornáveis, destacando-se a imprevisibilidade de produção devido às variações das condições atmosféricas.

A incerteza da produção de uma instalação fotovoltaica pode ser atenuada recorrendo a técnicas de previsão de produção de energia. Estas técnicas abrangem uma série de algoritmos e modelos diferentes para a previsão do recurso solar existente num dado horizonte de previsão. A utilização destes métodos permite não só realizar uma melhor gestão dos recursos energéticos em instalações que utilizam energia fotovoltaica, como também realizar uma melhor estruturação e planeamento no mercado energético, caso a energia produzida se destine a ser comercializada.

O presente trabalho tem como objeto a previsão de produção de energia elétrica em instalações fotovoltaicas.

1.2. Motivação

A motivação para a elaboração deste trabalho fundamenta-se na atualidade do tema, na procura crescente de exploração de energias renováveis e a sua otimização, considerando os benefícios associados à escala global.

Outro dos motivos para a escolha do tema prende-se com a otimização do rendimento e consumo energético em instalações fotovoltaicas com vista à comercialização de energia, ou à sua utilização para fins industriais.

O problema proposto e a metodologia também contribuíram para a motivação, pretendendo-se aprofundar conhecimentos na área de modelação de sistemas de controlo e da sua otimização através da manipulação do conjunto de dados disponibilizados e dos parâmetros do modelo escolhido para o sistema final.

1.3. Objetivos

Esta tese tem como objetivo criar e desenvolver um conjunto de sistemas de previsão de produção de energia fotovoltaica para escalas geográficas reduzidas, considerando-se um horizonte de previsão de 24 horas.

Para este fim, recorreu-se a uma base de dados histórica de uma instalação fotovoltaica, pertencente a uma fábrica de transformação de produtos alimentares situada na Quinta do Anjo, no concelho de Palmela. A base de dados engloba leituras diárias, referentes à produção dos anos 2014 e 2015.

Os resultados obtidos a partir dos vários sistemas foram comparados para identificar o modelo mais favorável.

Após a comparação dos resultados, foi elaborado um conjunto de observações sobre o comportamento geral dos modelos, tendo sido realizada uma apreciação geral sobre os resultados obtidos, a partir dos vários modelos e a forma como estes poderiam ser melhorados.

1.4. Contribuições

Com a criação de um modelo baseado em redes neurais para a previsão de produção energética, elaborou-se um método generalizado de previsões para instalações fotovoltaicas de escalas geográficas reduzidas em que se utilizam apenas dados históricos de produção.

Estes modelos podem ser utilizados no estudo da inclusão de informação exógena no sistema e na inclusão em sistemas de previsão híbridos. Podem também ser aplicados em estudos mais aprofundados sobre o comportamento da variação dos parâmetros internos de um modelo baseado em redes neurais ou nos efeitos de diferentes conjuntos de treino e validação obtidos do mesmo conjunto de dados.

O trabalho efetuado pode também ser utilizado no campo de investigação de informação não exógena relevante na criação e treino de modelos previsão de produção, utilizando os mesmos métodos seguidos mas alterando os parâmetros de entrada, podendo substituir ou adicionar variáveis na formação do conjunto de treino.

2. Revisão Bibliográfica

Nesta secção vão ser referidas as bases teóricas nas quais o trabalho assenta, abrangendo o funcionamento de redes neuronais e o seu treino, alguns modelos de previsão de condições meteorológicas atualmente utilizados e o funcionamento de células fotovoltaicas.

2.1.Redes Neuronais

As redes neuronais apresentam uma elevada capacidade de resolução de problemas. Baseiam-se em conceitos simples e devido à sua natureza matemática permitem obter resultados satisfatórios.

No entanto para a obtenção de resultados positivos é necessário compreender a sua arquitetura e princípios básicos, nomeadamente a identificação dos parâmetros internos mais apropriados com vista a otimizar o funcionamento destas.

Uma rede neuronal é constituída pela associação de um número variável de neurónios artificiais, podendo estes agrupar-se de várias maneiras. Este agrupamento é submetido a um algoritmo de treino para se adaptar a um dado problema(Fausett, 2014).

O funcionamento dos neurónios artificiais baseia-se no modo como os neurónios biológicos funcionam e realizam a distribuição e processamento de informação.

Na criação de uma rede neuronal a escolha dos seus parâmetros internos influencia significativamente os resultados obtidos, sendo preciso compreender o funcionamento dos algoritmos internos associados ao processamento da informação bem como dos vários componentes internos da rede.

Na figura 1 pode-se observar um exemplo de um neurónio artificial. Este módulo permite processar a informação que tem na sua entrada através de um conjunto de parâmetros internos.




Figura 1 - Exemplo de neurónio artificial (Philipp, 1994)

2.1.1. Componentes internos de um neurónio artificial

Como foi referido anteriormente, uma rede neuronal consiste na associação de neurónios artificiais e na forma como estes estão associados entre si.

A figura 2 ilustra a matriz de funcionamento de um neurónio artificial. Assim verificamos que um neurónio artificial é composto por um vetor de entrada de tamanho variável, uma matriz de pesos com um tamanho correspondente ao vetor de entrada, um somador, um vetor de *bias* e uma função de ativação.

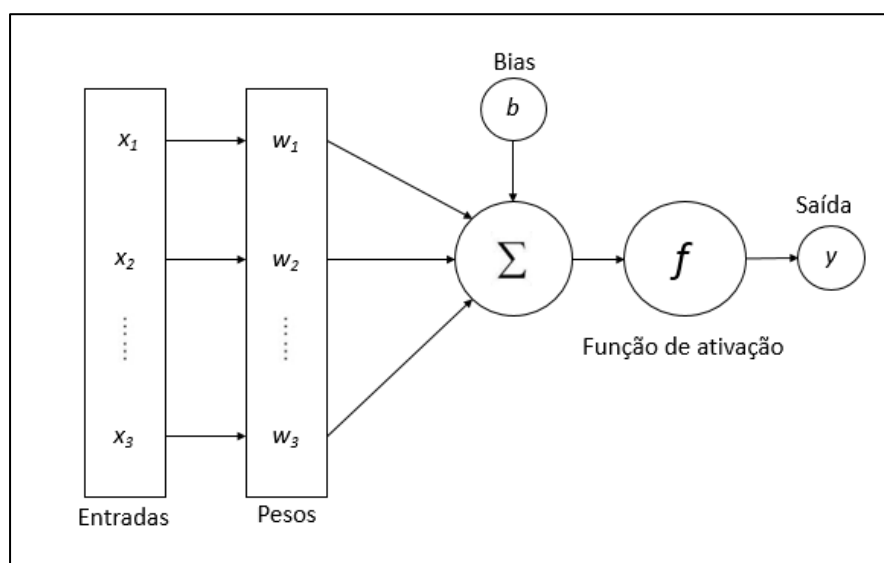


Figura 2 - Exemplo de um neurónio artificial em detalhe

O vetor de peso no neurónio vai funcionar como um fator multiplicativo para informação. Assim sendo, toda a informação x_i é multiplicada pelo peso w_i correspondente. Este peso de transferência pode assumir qualquer valor, sendo considerado excitatório se for positivo ou inibitório caso seja negativo.

O conjunto da informação recebida pelo neurónio vai ser toda somada após a influência dos diversos pesos, sendo-lhe posteriormente acrescentado um *bias*. Este, constitui uma constante com a função de gerar um sinal de saída no neurónio, caso não existam valores de entrada.

O resultado do processamento da informação recebida vai depender destes valores e da função de ativação do neurónio. O processamento da informação pode ser traduzido pela equação (1):

$$a = f \left\{ \sum (x_{ii} * w_{ii}) + b \right\} \quad (1)$$

Na equação (1) a representa o valor à saída do neurónio, f representa a função de transferência associada ao neurónio, x_{ii} representa o vetor de entrada, w_{ii} representa o conjunto de pesos associado à entrada e b representa o valor do *bias* associado.

A função de transferência associada ao neurónio vai controlar os limites dos valores de saída do mesmo. Esta particularidade do funcionamento dos neurónios artificiais, está associada ao modo como os neurónios biológicos estão, de uma certa forma, permanentemente ativos apresentando um valor “ativo” de saída apenas quando o valor de entrada está acima de um determinado limite. Tendo em conta este método de ativação, o valor de saída de um neurónio vai ser mais sensível a pequenas alterações no valor de entrada perto do limite de ativação.

A função de ativação mais comum nas redes neuronais é a função logística sigmóide, traduzida pela equação (2):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Em (2) a variável x representa o valor de entrada após terem sido aplicadas as influências dos pesos e do *bias*. Através da análise desta equação geral, os valores de saída vão estar limitados entre 0 e 1. Isto permite escalar a função facilmente em termos de limites podendo-se também multiplicar x por um fator λ para manipular a sensibilidade da função.

Existem várias outras funções de transferência para os neurónios artificiais, tais como tangentes hiperbólicas, senos e funções gaussianas, entre outras. No entanto a função sigmóide é a mais comum devido aos benefícios que apresenta para a aprendizagem baseada em *backpropagation*, sendo a função linear normalmente utilizada na última camada da rede neuronal, garantindo um intervalo de saída dos valores da rede não limitado.

Apesar de estas funções conseguirem limitar os valores de saída a um intervalo fixo independentemente dos valores tomados pelos dados na entrada da rede, é importante realizar um pré-processamento da informação para otimizar os resultados obtidos, devido á influência que os limites impostos pelas funções têm nas ligações internas da rede.

2.1.2. Tipos de redes neuronais

Tal como anteriormente foi referido, um neurónio artificial é uma parametrização de uma função não linear, sendo que uma rede neuronal consiste na ligação de dois ou mais neurónios. O modo como estes estão ligados influencia o tipo de resultados obtidos para o mesmo conjunto de dados, sendo que pode ser feita uma divisão inicial das configurações existentes, tanto quanto ao número de camadas internas existentes na rede, como relativamente ao sentido dos valores de saídas das camadas internas da rede.

Em termos do primeiro tipo de classificação referido, é possível criar redes monocamada ou multicamada. Em redes monocamada não existem camadas ocultas no interior da rede, existindo apenas um nível de processamento. Consoante o modo como as entradas estão ligadas com a camada de saída, a rede pode ser completamente interligada ou apenas uma rede parcialmente interligada.

No caso de uma rede multicamada existem várias camadas de neurónios “ocultas”, presentes no interior da rede, estando nos extremos da rede, as camadas de introdução de informação e a camada de saída de informação.

No exemplo apresentado na figura 3, verifica-se a existência de uma camada oculta em que os neurónios estão todos interligados, sendo por essa razão classificada como uma rede completamente interligada. Não existe um número de camadas ocultas limite, aumentando a complexidade da rede com o número destas.

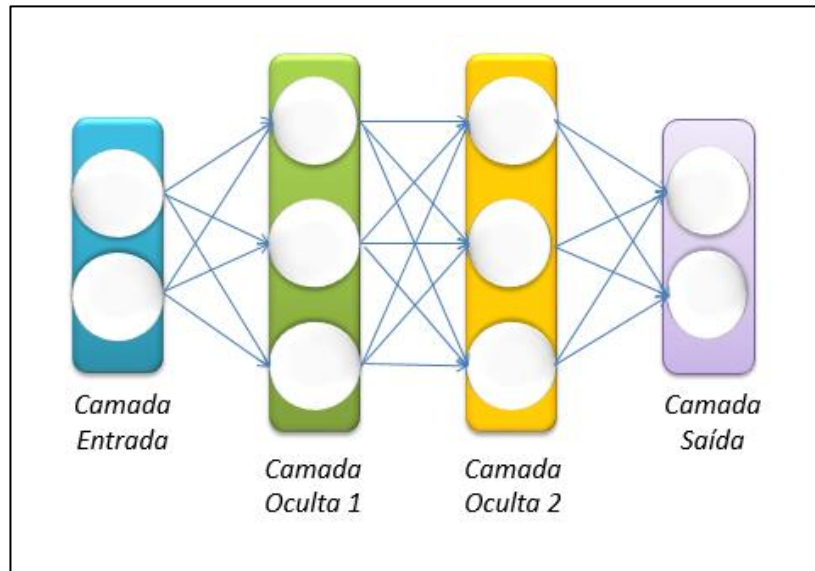


Figura 3 - Exemplo de uma rede neuronal multicamada

Caso se opte por utilizar a classificação no sentido tomado pelos valores das camadas da rede, é possível ter camadas proactivas ou retroativas. No caso das redes proactivas a informação de entrada só avança para as camadas seguintes até alcançar a camada de saída, apresentando assim apenas um sentido possível.

Em redes retroativas, para além das ligações proactivas coexistem ligações para camadas “anteriores” na rede, formando um sistema neuronal recorrente. Este tipo de rede permite que a informação transite em ambos os sentidos. Este tipo de redes integra implicitamente na sua conceção o conceito temporal, sendo impossível que um neurónio tenha como entrada a sua própria função, podendo no entanto ter como entrada os seus valores de saída passados.

2.1.3. Treino de uma rede neuronal

Um dos fatores que mais influência a qualidade dos resultados obtidos de uma rede neuronal é o seu “treino”. Este processo induz que a rede realize um processo de “aprendizagem” correto para o problema apresentado.

No entanto o processo de aprendizagem não tem um método direto para realizar o treino da rede neuronal, tornando-se difícil obter uma definição específica do procedimento. Este modo de aprendizagem consiste num processo iterativo em que os parâmetros internos da rede são ajustados entre iterações, variando assim os pesos das ligações e os *bias* da rede, dependendo dos valores de entrada da rede e dos valores desejados na sua saída.

Neste contexto, a rede neuronal consegue-se adaptar a padrões na relação entre as entradas e as saídas da rede, conseguindo assim ser treinada por um conjunto de exemplos, detetando as relações existentes no problema apresentado. Segundo este método de aprendizagem, a rede irá eventualmente alcançar uma solução com um erro mínimo para o problema em estudo. Quando este valor é alcançado ou quando não é possível minimizar mais o erro obtido, o treino da rede termina.

De um modo simples, pode-se explicar o processo de treino de uma rede neuronal através dos seguintes passos:

- É realizada uma comparação entre o resultado obtido pela rede para uma dada entrada e entre o resultado que seria expectável obter por essa entrada;
- O erro obtido na comparação é utilizado para atualizar os valores dos vários pesos e *bias* na rede neuronal (Fausett, 2014).

Devido à natureza dos diversos algoritmos de aprendizagem, os resultados obtidos utilizando o mesmo conjunto de treino e a mesma rede inicial pode nem sempre produzir os mesmos resultados finais.

Considerando estes fatores é importante distinguir qual é a informação disponibilizada para o treino da rede e qual é o conjunto de regras que a rede utiliza ao realizar a atualização dos pesos. Dever-se-á referir que a topologia utilizada e o algoritmo de treino escolhido vão ter influência nos resultados finais do treino da rede neuronal.

2.1.4. Perigos pós-treino de uma rede neuronal

Tendo em conta o método como as redes neuronais processam a informação, é importante realçar que dependendo do conjunto de parâmetros utilizado no algoritmo de treino da rede é possível criar um sistema afetado por *overfitting*.

Este fenômeno consiste num sistema incapaz de realizar operações com resultados de qualidade, com um conjunto diferente do conjunto de treino. Por norma ocorre quando se tenta minimizar o erro no treino de uma rede de um modo excessivo, ficando os parâmetros internos da rede demasiado adaptados ao conjunto de treino. Desta forma não se obtêm resultados com a qualidade desejável, em conjuntos de dados que apresentem variações comportamentais quando comparados com o conjunto de treino.

Para evitar que esta situação aconteça, pode-se recorrer à utilização de algoritmos que estudam a evolução do erro do treino, suspendendo o processo antes de ocorrer um treino excessivo da rede, ou ainda limitando o número de ciclos de treino da rede.

Outro método possível para evitar este fenômeno passa pela criação de uma rede generalizada, tentando simplificá-la de forma a reduzir a probabilidade de ocorrer um ajustamento em excesso ao conjunto de treino.

O problema inverso, i.e. o *underfitting* também se encontra associado a um treino mal parametrizado, sendo que neste caso a rede é incapaz de detetar todos os comportamentos existentes no conjunto de treino, por estar demasiado generalizada.

2.2. Modelos de previsão de condições atmosféricas

O modelo e a metodologia a aplicar para se realizar uma previsão depende de vários fatores, dividindo-se os métodos de desenvolvimento de modelos existentes, em métodos físicos ou métodos estatísticos. A principal diferença entre estes métodos reside na origem dos dados utilizados para a sua conceção. Os métodos físicos focam-se em modelos fotovoltaicos e solares para criar o modelo de previsão, enquanto os métodos estatísticos focam-se na utilização de informação histórica para realizar um treino dos modelos matemáticos.

Para a elaboração de um modelo baseado em métodos físicos recorre-se à informação de previsões meteorológicas e a um conjunto de parâmetros do sistema. O conjunto de variáveis utilizado depende dos algoritmos escolhidos. Neste sentido, considera-se que os fatores que mais influenciam as previsões são a radiação solar, o ângulo formado entre a irradiação e o painel fotovoltaico e a di-

ferença entre a temperatura ambiente e os painéis fotovoltaicos. Apesar de existirem métodos que consideram maior variedade de parâmetros, alguns modelos que consideram menos variáveis conseguem obter resultados eficazes. Dependendo da informação relevante sobre a instalação existente na altura da criação do modelo de previsão, os parâmetros relevantes podem ser obtidos através das especificações dos fabricantes dos componentes, ou através de dados históricos da instalação.

Na criação de métodos estatísticos não são utilizados dados de previsões meteorológicas, mas somente dados da instalação. Este conjunto de dados é usado na inicialização de um algoritmo de treino que vai produzir como resultado final um modelo de previsão baseado nos dados inseridos. Estes modelos conseguem obter uma maior precisão em termos de resultados se no seu treino inicial, for utilizado um conjunto de treino com um maior alcance temporal.

Foram realizados estudos comparativos (Huang et al., 2010) e (Kudo, Takeuchi, Nozaki, Endo, & Sumita, 2009) dos métodos descritos, i.e estatísticos e físicos, concluindo-se que os métodos puramente estatísticos fornecem resultados ligeiramente mais precisos.

Alguns dos métodos utilizados na atualidade são os seguintes: *Total Sky Imagery*, métodos de vetores de movimento de nuvens com base em satélites, métodos de aprendizagem estocásticos e modelos de previsão meteorológicos numéricos (NWP). Seguidamente descrevemos de forma sumária os métodos referidos.

2.2.1. Método de previsão *Total Sky Imagery*

Este método apresenta a capacidade de realizar previsões solares, podendo ser dividido em quatro componentes.

A fase inicial consiste na aquisição de uma imagem do céu numa zona próxima do local onde se vai realizar a previsão, sendo esta normalmente obtida através de um instrumento de captura de imagem designado como *Whole Sky Imager (WSI)*, semelhante ao apresentado na figura 4. Esta imagem vai ser posteriormente analisada para identificar as nuvens presentes numa determinada área. Os dados obtidos nesta fase são utilizados para estimar os vetores de movi-

mento das nuvens, recorrendo à informação extraída de um conjunto de fotografias sucessivas. Utilizando a combinação dos vetores de movimento das nuvens e a localização destas, é possível criar uma previsão de cobertura de nuvens e radiação solar a curto prazo. (Ghonima et al., 2012)



Figura 4- Exemplo de um equipamento *Whole Sky Imager* ("Drive Database," n.d.)

As previsões realizadas através deste método apresentam como vantagem o nível de detalhe da informação relevante associada à previsão, incluindo o tamanho, estrutura e os vetores de movimento das nuvens. A escala espacial desta previsão está limitada ao campo de captação de imagem do WSI, podendo-se no entanto aumentar a área efetiva da previsão através da utilização de múltiplas câmaras em localizações geográficas diferentes. Os maiores problemas associados a este tipo de previsão residem na dissipação, desenvolvimento e variações do tipo de nuvens, fatores que o algoritmo de previsão não incorpora. Outro problema identificado neste método reside no cálculo dos vetores de movimento de camadas diferenciadas de nuvens, uma vez que as nuvens localizadas em altitudes superiores da atmosfera podem ser ocultadas por nuvens mais baixas. Esta situação dificulta o cálculo correto dos vetores de movimento de ambas as camadas.

O próprio horizonte de previsão do modelo vai depender de vários fatores, tais como os vetores de movimento e a altura das formações, sendo que para casos em que as nuvens estejam baixas e com velocidades elevadas, as previsões rondam os 3 minutos, enquanto para as condições opostas, i.e. velocidades lentas e altitudes elevadas rondam os 30 minutos. Em condições normais as previsões têm um alcance entre 5 e 20 minutos. Mesmo que os vetores de movimento e a forma das nuvens fossem detetados com grande precisão, a qualidade da previsão continuaria a depender da evolução do perfil de nuvens existente, mantendo-se o problema do desenvolvimento e dissipação de nuvens.

2.2.2. Vetores de movimento de nuvens com base em satélites

Do ponto de vista conceptual, este método de previsão é semelhante ao utilizado no método *Total Sky Imagery*, recorrendo a sensores baseados em satélites para a captura de imagens que permitam a deteção de padrões de nuvens. Um exemplo de uma imagem capturada e tratada segundo este método está presente na figura 5. Comparando ambos os métodos, este apresenta como vantagem uma escala espacial maior, sendo as imagens disponibilizadas continuamente. Este método é utilizado extensivamente no mapeamento do recurso solar, como por exemplo no estudo realizado por Cebecauer (Cebecauer, Šúri, & Perez, 2010).

Os vetores de movimento de nuvens são determinados através da utilização de imagens consecutivas, podendo ser realizadas aproximações diferentes para o cálculo destes. Segundo um estudo realizado por Leese (Leese, Novak, & Bruce B. Clark, 1971), assumindo que as características geométricas das nuvens mantêm-se constantes entre imagens, é possível identificar os vetores de movimento das nuvens através da deteção de pontos-chave em imagens consecutivas. Outro estudo realizado por Hammer (Hammer, Heinemann, Lorenz, & Lückehe, 1999), foi utilizado um método estatístico baseado em probabilidades condicionadas para realizar o mapeamento solar com horizontes de previsão de duas horas. Foi também demonstrado por Bosch (Bosch, Zheng, & Kleissl, 2013) que os vetores de movimento de nuvens podem ser estimados com base nos valores de radiância ao nível do solo.




Figura 5 - Exemplo de uma imagem de Cloud Motion Vector (Fonte: <http://satellite.imd.gov.in/archive/>)

Este método apresenta a vantagem dos vetores de movimento de nuvens calculados poderem ser utilizados em modelos numéricos com vista ao melhoramento dos resultados obtidos. Em estudos realizados por James Goerss (GOERSS, Velden, & HAWKINS, 1998), demonstrou-se que os resultados alcançados através do sistema *Geostationary Operational Environmental Satellites*, foram positivamente influenciados pelos resultados numéricos resultantes dos vetores de movimento de nuvens. Para horizontes de previsão superiores aplica-se o inverso, i.e. a utilização de modelos baseados em modelos de previsão meteorológicos numéricos podem ser utilizados para melhorar o cálculo de vetores de movimento de nuvens em imagens recentes.

Devido á escala espacial associada ás imagens obtidas através dos sensores em satélites, com algumas exceções relativas a nuvens de maior dimensão, verifica-se não ser possível detetar e localizar com precisão nuvens mais pequenas, sendo que apenas se pode identificar a localização geográfica genérica em que

estas se encontram. Para além deste fator, é necessário notar que o tempo de obtenção e a frequência de imagens é menor quando comparado com o método WSI, o que se traduz num tempo de atualizações de previsões e de cálculos de vetores de movimento mais lento.

2.2.3. Métodos baseados em técnicas de aprendizagem estocásticas

Para horizontes de previsão mais curtos, variando entre períodos inferiores a 1 hora e até 3 horas, as técnicas de aprendizagem estocásticas sem utilização de informação exógena na criação de modelos, permitem a obtenção de resultados de elevada qualidade e precisão, sendo relativamente fáceis de criar e instalar. Não obstante, a inclusão de informação exógena relevante ao modelo de previsão permite aumentar a precisão e qualidade das previsões efetuadas pelos modelos.

Presentemente, tem aumentado a tendência da utilização de algoritmos matemáticos na conceção destes modelos. Um exemplo deste tipo de algoritmos de otimização aplica-se a modelos baseados em redes neuronais. Este método realiza a escolha da tipologia, dos pesos iniciais e dos coeficientes internos da rede, utilizando para este fim processos evolutivos, como um algoritmo genético, por exemplo.

2.2.4. Métodos de previsão meteorológicos numéricos

Os modelos NWP baseiam-se em equações dinâmicas com a capacidade de prever a evolução do estado da atmosfera para horizontes de vários dias após a sua inicialização, como se pode observar na figura 6, onde está presente uma previsão com um horizonte de 120 horas para condições de vento e de ondulação. Os modelos que servem de base para os restantes têm uma escala global, cobrindo toda a superfície terrestre. As equações e as entradas das mesmas são obtidas através da parametrização de um conjunto de coordenadas geográficas.

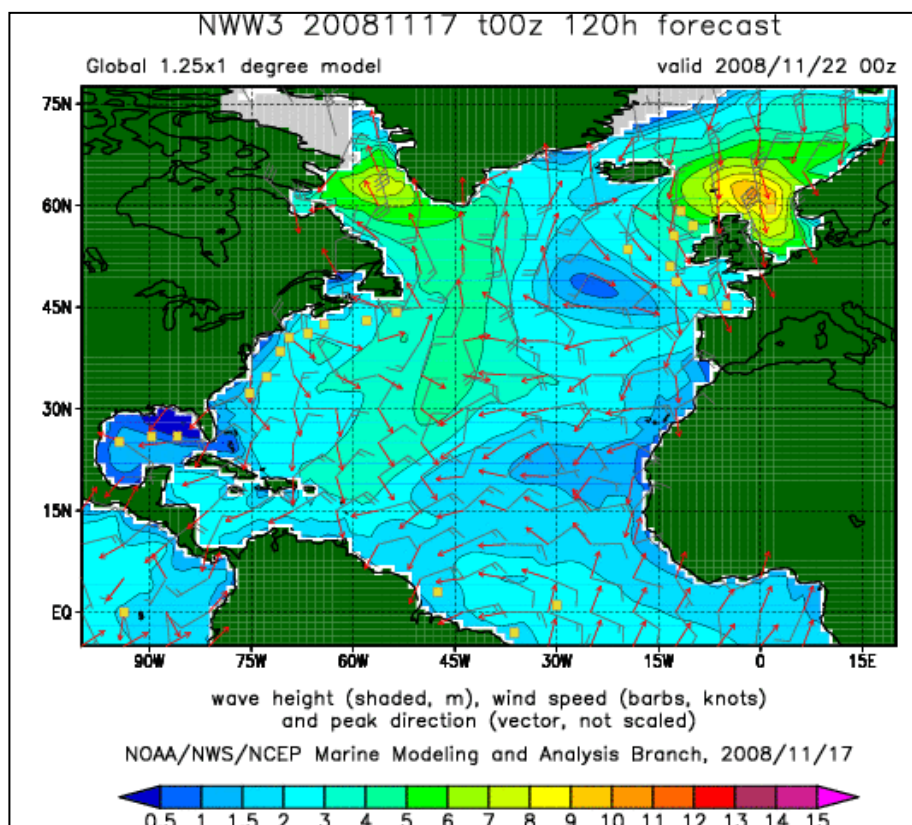


Figura 6 - Imagem com previsões obtida através de um modelo NWP (Fonte: <http://polar.ncep.noaa.gov/waves/WEB/>)

Devido à natural complexidade e intensidade computacional associada ao uso dos sistemas de escala global, atualmente apenas estão disponíveis 14 sistemas. Estes modelos são geralmente inicializados entre 2 a 4 vezes por dia. As variáveis de entrada são obtidas através de uma série de sensores e posteriormente processadas para o interior da grade de coordenadas que estes sistemas utilizam. Para tentar diminuir a complexidade computacional requerida por estes modelos, a escala da grade pode variar entre os 40 e os 90 km (Tranmüller & Steinmaurer, 2010).

2.2.5. Pós-processamento de modelos NWP

Neste tipo de modelos é possível melhorar a qualidade dos resultados obtidos utilizando-se um método de comparação com um conjunto de dados de treino. Este tipo de aproximação é designado por *Model Output Statistics* (MOS).

Atualmente existem vários métodos MOS. Esta área encontra-se em expansão e em grande desenvolvimento, podendo os métodos existentes ser utilizados tanto individualmente como em conjunto.

Interpolação espaço temporal

Considerando que as previsões obtidas através de modelos NWP são geradas em pontos discretos da grelha tridimensional, a sua utilização em zonas específicas requer o recurso à interpolação, utilizando os resultados de pontos especificados.

Dentro destes métodos o mais simples consiste na utilização do método designado como *nearest neighbor*, utilizando os valores de previsão do ponto da grelha mais próximo do local de previsão desejado. Outras variações deste método consistem na interpolação de previsões dos pontos circundantes da área desejada.

De acordo com estudos diferentes, o método que obtém os melhores resultados varia e depende do modelo NWP utilizado, verificando-se que os métodos de interpolação espacial são os que apresentam resultados mais precisos.

Para além da interpolação espacial, existe ainda um método de otimização baseado em interpolação temporal, sendo este método requerido em situações em que o modelo utilizado tenha uma escala temporal menor do que a desejada.

Combinação de vários modelos NWP

Este método de otimização de modelos NWP consiste na utilização de diferentes sistemas de previsão para obter uma estimativa conjunta da previsão final. Também pode utilizar previsões obtidas por diferentes modelos, sendo os modelos inicializados com um conjunto variado de parametrizações por um modelo NWP para obter resultados de previsões estatísticos.

Este método conseguiu obter melhorias ligeiras em previsões efetuadas ao realizar a média de um pequeno conjunto de modelos NWP, de acordo com o estudo realizado por Perez (Perez et al., 2011).

Analogamente com modelos estocásticos, num estudo efetuado por (Chaouachi, Kamel, & Nagasaka, 2010), observou-se que a média da previsão de

3 redes neurais diferentes conseguiu obter melhores resultados que modelos neurais individuais.

MOS para melhorar modelos individuais

Após a geração das previsões, estas podem ser melhoradas através da comparação dos resultados obtidos com um conjunto de dados que foram medidos durante o período de treino em que o modelo foi desenvolvido. Este método obtém melhores resultados quando as previsões são atualizadas recursivamente ao longo do tempo e testadas para várias condições atmosféricas. A maioria dos erros nas previsões efetuadas nos modelos NWP deve-se a condições atmosféricas, à existência de teto de nuvens, à estação do ano. Devido a estes fatores, os modelos devem ser atualizados e modificados frequentemente, de forma a adaptar as previsões aos fatores atmosféricos existentes e à estação do ano.

No contexto deste método, um modo simples mas eficaz de realizar a melhoria do sistema consiste na correção de erros sistemáticos existentes nas previsões, também designado por “remoção de *bias*”. Este método foi aplicado em alguns estudos, como por exemplo no estudo realizado por Mathiesen(Mathiesen & Kleissl, 2011) , onde foram determinadas estruturas de *bias* diferentes para vários modelos NWP. A remoção do *bias* é mais importante em previsões para áreas geográficas maiores, onde este contribui para a geração de grande parte do erro, uma vez que os erros pontuais têm a tendência para se cancelarem com a extensão da área da previsão.

Existem outros estudos dentro da mesma área com aproximações diferentes, tais como modelos autorregressivos desenvolvidos por Bacher (Bacher, Madsen, & Nielsen, 2009) e Tao, Shanxu(Tao, Shanxu, & Changsong, 2010). Existem também modelos de inteligência artificial, como por exemplo um estudo por Huang (Huang et al., 2010) em que foram utilizadas múltiplas saídas de modelos NWP em sistemas baseados em *Autoregressive Neural Networks* (ANN). Refere-se ainda a utilização recorrente de redes neurais por Cao (Cao & Lin, 2008) para obter previsões com horizontes que variam entre um dia a vários dias.

Na modulação destes métodos, os autores utilizaram uma tipologia de dados diferente para valores de entrada para os sistemas, dando-se como exemplos

os valores obtidos através de previsões de modelos NWP, valores medidos a partir de sensores localizados em satélites, valores adquiridos a partir de estações terrestres de medições meteorológicas e ainda variáveis relacionadas com as condições solares.

2.3. Energia Fotovoltaica

Tal como foi referido anteriormente, a energia fotovoltaica é gerada através do aproveitamento da energia presente no espectro visível da radiação solar recorrendo à utilização de células fotovoltaicas. A célula fotovoltaica é construída com base em materiais semicondutores, que por sua vez têm a particularidade de conseguir direcionar energia em condições específicas, não funcionando como isoladores ou como condutores. O material mais comum utilizado na construção das células fotovoltaicas é a sílica, que normalmente é combinada com outro tipo de materiais para melhorar a sua condutividade. Este processo é designado por *doping*, e consiste na adição de quantidades controladas de materiais iónicos de impurezas específicas ao semicondutor em estado quase puro (Hersch & Zweibel, 1982).

Dependendo da impureza adicionada ao material, pode-se formar um semicondutor positivo, do tipo “P”, ou um semicondutor negativo, do tipo “N”. Semicondutores do tipo “P” formam materiais aceitantes de eletrões que capturam os eletrões livres no meio. Estes materiais sem eletrões livres, criam um estado elétrico carregado positivamente designado por “lacuna” que se move pelo material. Semicondutores do tipo “N” funcionam como dadores de eletrões, tendo um excesso destes em movimento.

Ambos os tipos de semicondutores influenciam o comportamento do fluxo elétrico em células fotovoltaicas. A geração de lacunas e eletrões livres através da exposição dos semicondutores à luz, é um dos processos centrais no contexto da geração de energia fotovoltaica embora o processo não se limite a este fenómeno, uma vez que por si só, a geração de lacunas não produz corrente elétrica.

As células fotovoltaicas estão munidas de uma barreira que separa ambos os materiais semicondutores, sendo que a exposição à luz vai aumentar o número de lacunas no material tipo “P” e o número de eletrões livres no material tipo

“N” em lados opostos da barreira. Este fenómeno vai criar uma diferença de potencial nas extremidades da célula fotovoltaica, podendo ser utilizada para criar uma corrente elétrica num circuito externo conforme representado na figura 7.




Figura 7- Ilustração do funcionamento de uma célula fotovoltaica (Hersch & Zweibel, 1982)

3. Metodologia utilizada

Seguidamente vão ser explicitados os passos utilizados na elaboração e comparação dos sistemas de previsão criados para o desenvolvimento do presente trabalho. Os sistemas de previsão desenvolvidos baseiam-se em redes neuronais, tendo-se recorrido ao conjunto de ferramentas disponibilizadas pela *toolbox mntool* existente no *software MatlabR2010a*. Devido às características inerentes ao tipo de dados e ao tipo de previsões efetuadas optou-se por utilizar modelos ANN.

3.1. Obtenção e tratamento de dados

Considerando o modelo ANN, escolhido para realizar a previsão, foi necessário realizar um pré-processamento dos dados disponibilizados para serem introduzidos no treino da rede. Os dados utilizados para este propósito tiveram origem na instalação fotovoltaica utilizada no estudo e descrita anteriormente, sendo visível parte da instalação na figura 8. Estes dados representam a energia produzida diariamente na instalação fotovoltaica, tendo o registo sido iniciado no ano de 2014. Os valores abrangem o período que decorre entre 1 de Janeiro de 2014 até 31 de Dezembro de 2015.



Figura 8 - Painéis na instalação fotovoltaica em estudo

A informação disponível foi organizada em períodos temporais. Foram criadas redes com base nos valores fornecidos e redes com valores normalizados, para que se possa comparar os resultados.

Considerando que as redes neurais utilizam apenas os valores históricos da produção e que a informação refere-se à energia produzida pelo sistema fotovoltaico num determinado intervalo de tempo, considerou-se não ser necessário manipular as unidades de potência dos dados. A unidade de potência utilizada foi o kWh.

Os valores existentes fora do intervalo de tempo entre as 8 e as 18 horas de cada dia, não foram considerados para a criação e teste dos modelos desenvolvidos, uma vez que a quantidade de energia produzida no período de tempo referido é de valor praticamente nulo. Por outro lado, considerou-se que esses dados influenciariam negativamente o comportamento dos sistemas desenvolvidos uma vez que iriam aumentar consideravelmente a complexidade da rede neuronal, sem acrescentar informação relevante.

A fim de disponibilizar um conjunto alargado de resultados e estudar a influência que o conjunto de treino tem no produto final, as redes desenvolvidas

utilizam parâmetros de entrada com um intervalo de tempo variável, designadamente as últimas 5, 10, 15 e 20 horas antes de a previsão ser efetuada.

3.2. Criação dos modelos de previsão

3.2.1. Ferramenta utilizada

A *toolbox* utilizada apresenta capacidades tanto de criar como de treinar redes neuronais com uma interface simples, facilitando o processo de gerar os modelos necessários.

Na figura 9 encontra-se a interface gráfica da ferramenta *nntool* para a componente de criação de modelos neuronais. Como é possível notar, a variação dos parâmetros internos da rede, bem como a sua topologia geral podem facilmente ser variados, bastando fornecer um conjunto de informação de entrada e um conjunto de informação alvo.

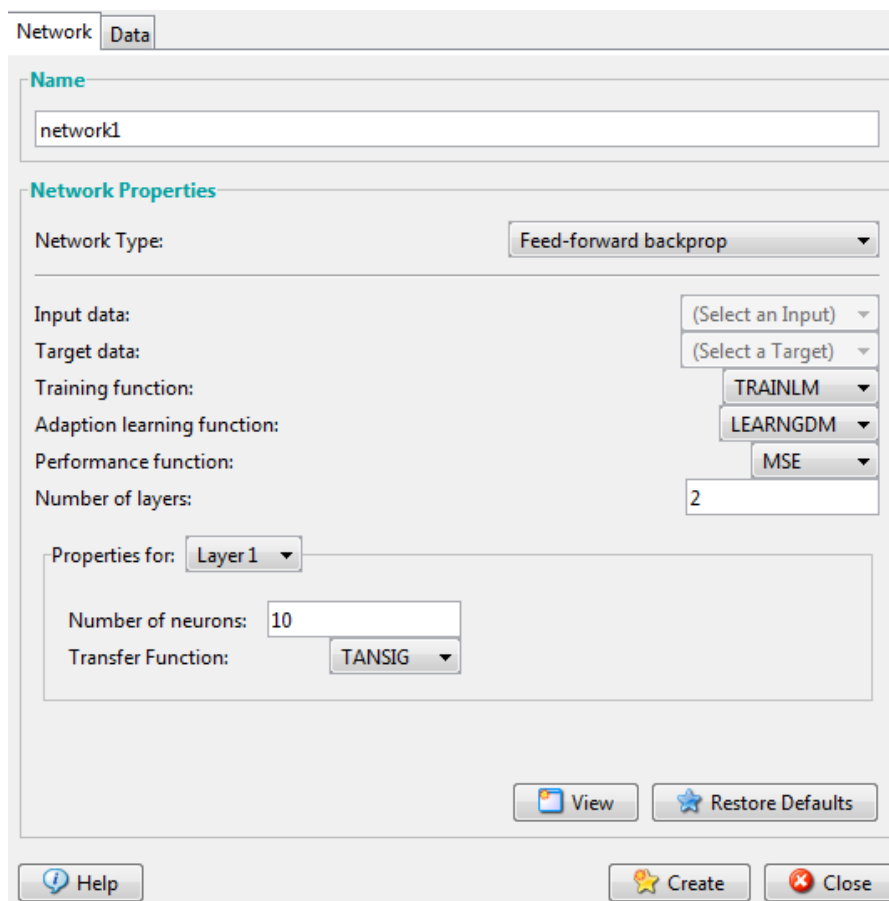


Figura 9 - Interface de criação de redes neuronais na *toolbox*

Os conjuntos de dados fornecidos consistem num conjunto de valores de entrada e num conjunto de valores de saída para que os neurónios constituintes da rede se adaptem às dimensões dos vetores de entrada e de saída da rede. Esta interface permite ainda escolher o número de neurónios ocultos por camada e a sua respetiva função de ativação.

Esta ferramenta tem uma interface diferente para realizar o treino da rede neuronal, que está na figura 10. Nesta parte é possível variar os diversos parâmetros de paragem do algoritmo de treino que foi escolhido para a rede, sendo também selecionados os conjuntos de valores a utilizar para realizar o treino, sendo que estes têm de concordar com as dimensões das matrizes definidas na criação da rede.

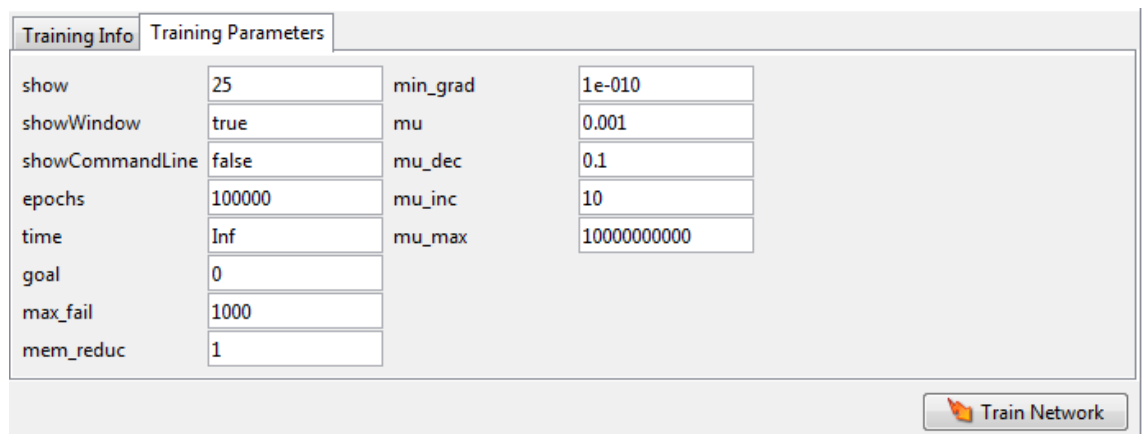


Figura 10 - Interface de treino de redes neuronais na *toolbox*

Deste modo, para realizar o processo de criação e treino da rede foram criados os conjuntos de treino para as redes, tendo estes sido fornecidos tanto na sua criação para estipular as dimensões dos neurónios como no processo de treino para fazer as alterações nos valores das matrizes internas da rede, sendo que os restantes parâmetros de treino e de criação da rede são selecionados nos menus apresentados.

3.2.2. Modelos

Como já foi referido, na criação dos modelos de redes neuronais, foram utilizados dois conjuntos de dados. O conjunto de dados da produção de 2014 foi utilizado para o treino dos modelos, e o de 2015 foi utilizado para os validar. Tanto o conjunto de treino como o de validação representam todo o espectro

comportamental que a instalação fotovoltaica pode produzir. Para além disso, o volume de informação utilizada previne a existência de discrepâncias entre os comportamentos observados entre o conjunto de treino e o de validação.

No desenvolvimento das diversas redes neuronais foram adotados os mesmos parâmetros internos na criação da rede em termos de camadas internas e na função de transferência utilizada pela rede, para que fosse possível traçar um paralelismo válido na comparação dos resultados obtidos nestes, sendo importante a escolha destes parâmetros para garantir o máximo de fidelidade possível nos resultados e observações finais.

Observando a complexidade do conjunto de dados a aprender pelas redes, optou-se por utilizar como função de transferência para a camada interna da rede, a função tangente hiperbólica sigmoidal devido ao escalamento que esta permite. Para a camada de saída utilizou-se a função linear, evitando-se um aumento na complexidade dos modelos criados.

Considerando a influência do número de camadas internas na complexidade de uma rede neuronal e da correlação existente com a possibilidade de ocorrer *overfitting* no treino, optou-se por utilizar uma camada oculta nos modelos, para que a rede tenha a capacidade de aprender os padrões existentes no conjunto de treino, em vez de ficar demasiado adaptada aos dados fornecidos.

Considerando a influência do número de neurónios existentes nas camadas ocultas da rede, para melhor dimensionar os efeitos que estes têm foi realizada uma comparação em redes com parâmetros de treino iguais e com o mesmo conjunto de treino e validação, mas alterando o número de neurónios existentes. Assim com a finalidade de se obter uma boa gama de valores diferenciados e alargados para efeitos de comparação foram testadas redes com 5, 10, 15, 20 e 25 neurónios presentes na camada oculta.

Em termos de métodos de treino para as redes criadas recorreu-se ao algoritmo de *Levenberg-Marquardt*, tendo-se adaptado os critérios de paragem do algoritmo de treino quer em termos de verificação, quer em termos de número de épocas máximas que o treino pode durar, de forma a evitar a ocorrência de *overfitting* ou de *underfitting* do sistema.

Os modelos de previsão têm um horizonte de uma hora, sendo posteriormente os resultados utilizados recursivamente para obter horizontes de previsão maiores. Para referências futuras, devido aos intervalos de tempo que as redes consideram, os modelos com uma entrada de 10, 20 ou 30 horas correspondem a uma entrada histórica de 1, 2 ou 3 dias respetivamente.

3.3. Métricas de comparação

Para efeitos de comparação de resultados foram utilizadas diferentes métricas em que conjuntos de modelos diferentes são comparados entre si, no sentido de se identificar o método que induz o menor erro na previsão.

Os diversos modelos anuais em termos de número de neurónios e de intervalos de entrada, foram divididos em períodos mensais e comparados em termos de erro absoluto médio e erro percentual médio. Esta metodologia permitiu identificar os efeitos na previsão da produção ao longo do ano.

Para identificação do impacto da normalização no modelo desenvolvido foram comparados os resultados obtidos pelo modelo anual com a configuração interna que obteve os melhores resultados, com um modelo com a mesma configuração interna mas desenvolvido com base num conjunto de dados normalizado.

Nas previsões mensais foram escolhidos períodos de tempo em que o histórico de produção apresentava resultados estáveis. Foram também selecionados períodos com alterações de produção devido a condições externas (alterações meteorológicas ou ainda questões relacionadas com a produção industrial da fábrica). Esta metodologia permitiu aferir a solidez dos modelos criados em condições meteorológicas favoráveis, como também em condições imprevistas, sendo possível retirar conclusões sobre constrangimentos e pontos fortes dos diversos modelos criados.

Para cada um dos meses do ano foi elaborado um conjunto de quatro gráficos e duas tabelas.

- O primeiro gráfico sintetiza o registo de produção energética da instalação fotovoltaica no decurso do mês. Este gráfico foi utilizado

para observar o perfil de produção elétrica e eventuais variações de comportamentos devidos a fatores exógenos.

- O segundo gráfico apresenta dois conjuntos de dados de produção elétrica correspondentes a um período de produção contínua de 20 horas, e destinam-se a analisar e comparar o comportamento de um período estável e um instável.
- O terceiro e quarto gráficos representam o comportamento dos diversos modelos com uma entrada de leituras referentes a uma produção de 5 horas, para os períodos escolhidos. Foram analisados os modelos que comportam 5, 10, 15, 20 e 25 neurónios na camada oculta da rede.
- A primeira apresenta o erro médio absoluto e o erro médio percentual dos modelos com entradas de 5 horas.
- A segunda tabela apresenta a configuração dos diversos modelos com entradas que variam entre 5, 10, 20 e 30 horas que obtiveram os menores erros médio absoluto e percentual.

4. Estudo de caso: Companhia Nacional de Carnes

Neste capítulo descrevemos a instalação que forneceu os dados para a realização deste estudo e as suas condições de funcionamento. Posteriormente é apresentada a análise dos resultados obtidos pelos vários controladores criados e comparada a qualidade das previsões e opções existentes para a melhoria das previsões realizadas.

4.1. Instalação

A instalação fotovoltaica referida é propriedade da Companhia Nacional de Carnes, situada na Quinta do Anjo, no concelho de Palmela, podendo-se ver em detalhe na figura 9. A energia produzida é utilizada para alimentar a fábrica.

A potência nominal da instalação fotovoltaica é 60 kW e a potência instalada nos painéis fotovoltaicos é de 65,66 kW. A instalação é composta por 268 módulos fotovoltaicos *BYD Europa245P6-30* e por 4 inversores *SMA STP15000TL*.



Figura 11 - Localização da instalação fotovoltaica em estudo

As tabelas 1 e 2 apresentam as especificações dos painéis fotovoltaicos e dos inversores utilizados.

Tabela 1 - Características dos painéis fotovoltaicos utilizados

Características dos Painéis Fotovoltaicos BYD Europa 245P6-30			
Potência Máxima Nominal	P_{max}	245	Wp
Intensidade no ponto de máxima potência	I_{mp}	8,15	A
Tensão no ponto de máxima potência	V_{mp}	30,1	V
Intensidade de curto-circuito	I_{sc}	8,94	A
Tensão de circuito aberto	V_{oc}	37,8	V
Número de células		60	

Tabela 2 - Características dos inversores utilizados

Características dos inversores SMA STP 15000TL	
Potência Nominal	15kW
Tensão de entrada CC	360-800V _{cc}
Tensão de saída CA	3x 230V _{ca}
Frequência de saída CA	50/60 Hz
Eficiência máxima	98,2%

A instalação fotovoltaica está dotada de um mecanismo com capacidade de controlar os seus níveis de produção de eletricidade, limitando a energia máxima que pode ser produzida. Este mecanismo tem quatro patamares de funcionamento que correspondem a uma capacidade de produção de 100%, 60%, 30% e inversores desligados. O sistema previne a injeção de energia na rede e limita a energia produzida em situações em que a fábrica não esteja a consumir toda a produção da instalação. O gráfico da figura 12 ilustra uma situação de corte, notando-se a alteração do patamar de funcionamento pela súbita alteração do nível de energia produzido a meio do intervalo demonstrado.




Figura 12 - Exemplo de corte na produção da instalação

A localização da instalação fotovoltaica dentro da fábrica foi concebida de forma a evitar o sombreamento dos painéis fotovoltaicos por obstáculos artificiais e naturais. Todas as perdas de produção relacionadas com o sombreamento

dos painéis que devem-se somente à formação de tetos de nuvens que eventualmente possam ter impacto na produção de energia.

4.2. Assunções Prévias

Nos procedimentos efetuados não foram considerados os fatores meteorológicos do local da instalação da fábrica, os dados de consumo energético desta bem como os eventuais períodos de manutenção da instalação fotovoltaica em que a produção fosse suspensa.

Tendo em conta a natureza dos modelos criados, o grau de precisão para as previsões efetuadas para um horizonte de 24 horas vai depender de algumas condições, nomeadamente que as condições meteorológicas se mantenham constantes ao longo do período da previsão. É também desejável que as variações no teto de nuvens sejam mínimas ou inexistentes e que a instalação tenha um patamar de funcionamento estável, nomeadamente quanto a possíveis cortes de energia por razões de natureza fabril.

O problema da previsão pode ser atenuado através de atualizações periódicas. Os modelos criados foram concebidos para realizarem previsões de produção horárias, sendo a previsão a 24 horas obtida através da utilização recursiva dos valores obtidos na previsão horária.

Os maiores erros de previsão ocorrem nas transições de produção diárias, devido ao intervalo de tempo que decorre entre o final e o início de cada dia que não foi incorporado nos modelos. Assim, existe um período de 14 horas durante as quais o sistema ignora a possível variação das condições atmosféricas, sendo que a previsão só engloba os valores produzidos a partir das 8 horas de cada dia.

4.3. Modelos Criados

Nesta secção vai ser feita uma breve apresentação dos modelos criados e da informação utilizada para os criar. Para o treino dos modelos neuronais foram utilizados os valores da produção do ano de 2014 enquanto para a validação destes foram utilizados os da produção do ano de 2015.

Foram criados 24 modelos anuais com parâmetros internos diferentes para se observarem os comportamentos diferentes que estes apresentam sobre as mes-

mas condições, tendo sido criado ainda um modelo anual com os valores de produção normalizados, para que se consiga estudar o efeito da normalização dos dados nos resultados obtidos. Estas comparações vão permitir tirar conclusões sobre o formato mais apropriado que um sistema de previsão baseado em redes neuronais.

Para a criação dos vários modelos utilizou-se a *toolbox nntools* presente no *software matlabr2010a*, que permite realizar a criação e treino de vários tipos de modelos de redes neuronais de uma forma simplificada, permitindo também manipular as condições de treino de modo a que estas estejam adaptadas para o problema em estudo.

4.4. Estudo dos Modelos efetuados

Nesta secção vão ser estudados os vários modelos criados, sendo feito o mesmo procedimento de comparações para cada um dos meses do ano, tal como for referido anteriormente. Isto vai permitir obter uma análise mais compreensiva e objetiva da qualidade das previsões e das suas capacidades. Todas as comparações vão ser efetuadas com os valores de produção efetuada na instalação no ano de 2015.

4.4.1. Janeiro

O mês de janeiro de 2015 apresentou o perfil de produção energético representado na figura 13.




Figura 13- Produção energética horária ao longo do mês de janeiro de 2015

Considerando o limite de produção da instalação de 60 kW e as condições meteorológicas inerentes ao mês de Janeiro, é possível observar que, durante este mês a instalação esteve a funcionar em média aproximadamente a cerca de 30% da sua capacidade total, ou seja, uma produção média de 18 kWh. Analisando o gráfico da figura 13 pode-se inferir que os dias de produção mais baixa devem-se provavelmente ao impacto das condições meteorológicas na instalação uma vez que não se observa nenhuma mudança de perfil de funcionamento da instalação que indique a produção de energia é superior ao seu consumo. Para efeitos de comparação e de avaliação da qualidade dos resultados foram seleccionados os conjuntos de dados representados no gráfico da figura 13




Figura 14 - Períodos de estudo para o mês de janeiro

Estudando os dois períodos de produção selecionados, nota-se um comportamento cíclico no início do período estável, não existindo nenhuma variação súbita nos valores da produção. No final deste período verificou-se uma queda geral na produção. A análise do período instável revelou algumas variações súbitas na produção, nomeadamente no início e a meio do intervalo. Nota-se a mesma queda geral da produção no final do período.

Observando o comportamento dos modelos de previsão com entradas de 5 horas em que o modelo é atualizado horariamente, obtêm-se os gráficos das figuras 12 e 13:




Figura 15 - Comportamento dos modelos com um histórico de 5 horas no período estável de Janeiro

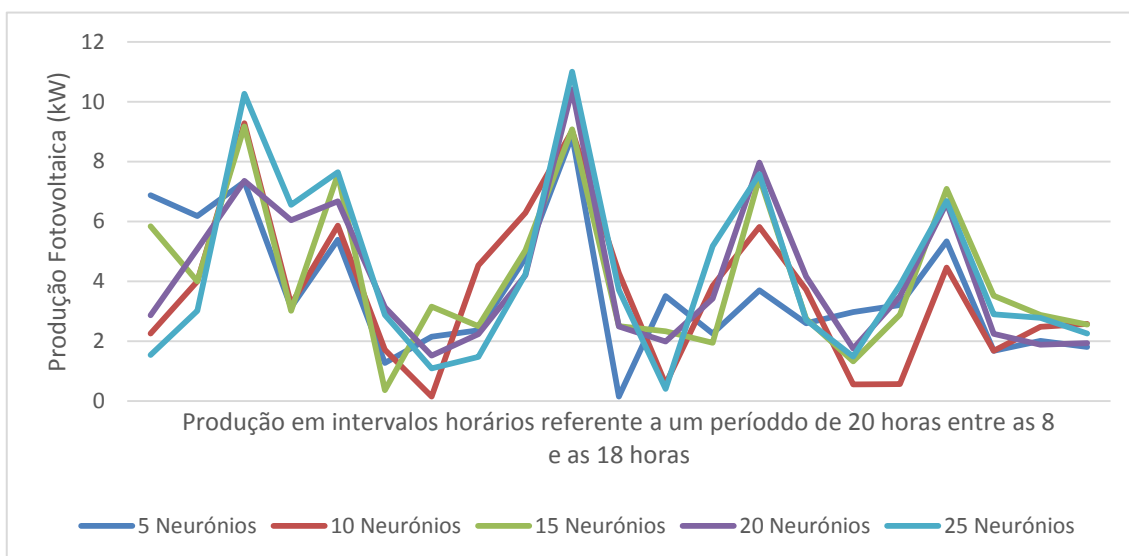


Figura 16 - Comportamento dos modelos com um histórico de 5 horas no período instável de Janeiro

Dos resultados obtidos infere-se que os erros residem essencialmente na transição diária. Os modelos não apresentam a capacidade de realizar a previsão com precisão de valores quase nulos de produção que ocorrem no início e final do dia, apresentando também respostas atrasadas na previsão a curto prazo no caso de se verificar uma grande variação na produção devido, por exemplo, ao

ensombramento por nuvens, como se pode notar no pico que existe no caso desfavorável e na resposta obtida pelos modelos nesse momento.

Na tabela 3, dentro dos modelos criados com entradas de 5 horas, o modelo que apresenta melhores resultados é o que comporta 10 neurónios ocultos. Este modelo apresenta também o menor erro médio absoluto e percentual, rondando cerca de 9,8%. Com um aumento da complexidade da rede a partir deste ponto, a precisão da rede diminuiu conseguindo-se observar um aumento gradual dos erros que é praticamente proporcional ao aumento do número de neurónios presentes na camada oculta.

Tabela 3 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Janeiro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	4,99	10,17
10	4,80	9,78
15	5,15	10,50
20	5,13	10,44
25	5,39	10,99

Realizando este processo comparativo com os restantes modelos com intervalos de entrada diferentes, obtêm-se os modelos apresentados na tabela 4 que resume os melhores resultados em cada um dos níveis:

Tabela 4 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Janeiro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	4,8033	9,78
10	20	3,9814	8,10
20	10	7,4444	15,15
30	10	8,5684	17,44

A configuração ótima da rede no mês de janeiro utilizou a combinação de 10 horas e de 20 neurónios na camada oculta. Verificou-se também um aumento considerável do erro médio com o aumento do intervalo de entrada a partir das 10 horas, verificando-se que a inclusão de vários dias na entrada do modelo prejudica gravemente a precisão deste. Este aumento nota-se na transição do modelo com um histórico de 10 horas para um de 20 horas, em que o erro percentual quase duplica. O número de neurónios interno em cada uma das redes que apresenta o melhor resultado varia de caso para caso, notando-se que os valores mais precisos são obtidos em média, com 10 neurónios na camada oculta. No entanto, no caso do modelo com o histórico de 10 horas o melhor resultado obtido foi com 20 neurónios na camada oculta.

Os resultados menos favoráveis obtidos com intervalos de entrada superior a 10 horas, justificam-se pelo treino ser mais complexo devido a inexistência de um padrão fixo ao longo do mês de janeiro, mas também pela provável existência de teto de nuvens.

4.4.2. Fevereiro

O mês de fevereiro de 2015 apresenta o perfil de produção energético, conforme o gráfico representado na figura 17.




Figura 17- Produção energética horária ao longo do mês de fevereiro de 2015

Considerando as condições meteorológicas típicas associadas ao mês de fevereiro, ainda no pico do inverno, infere-se que os dias de menor produção se devem a fatores meteorológicos, uma vez que o decréscimo da produção não coincide com o tipo de pico negativo de produção associado aos cortes energéticos no contexto da gestão da fábrica. Através da observação deste gráfico concluímos que ao longo do mês, a instalação funcionou em média a cerca de 30% da sua capacidade de produção, sendo esta de aproximadamente 22 kWh com alguns picos em que a energia produzida ficou perto da capacidade máxima da instalação. Para efeitos de comparação e de avaliação da qualidade dos resultados foram escolhidos os seguintes conjuntos de dados representados no gráfico da figura 18.




Figura 18- Períodos de estudo para o mês de fevereiro

Relativamente ao gráfico da figura 18, o comportamento da produção no período estável não apresenta variações súbitas, apresentando um formato cíclico. Relativamente ao comportamento instável identifica-se um decréscimo da produção na parte final do período, não se observando picos na produção.

Observando o comportamento dos modelos de previsão com uma entrada de 5 horas e uma atualização horária da previsão, obtêm-se os resultados representados nos gráficos das figuras 17 e 18:




Figura 19 - Comportamento dos modelos com um histórico de 5 horas no período estável de Fevereiro




Figura 20 - Comportamento dos modelos com um histórico de 5 horas no período instável de Fevereiro

Verificamos que em ambos os casos de estudo, os modelos apresentam a capacidade de acompanhamento da evolução das previsões, existindo no entanto alguns problemas relacionados com a transição diária relacionados com valores de produção muito baixos. Em nenhum dos casos existem transições bruscas devido a cortes na produção ou a cobertura da instalação por nuvens.

Na tabela 5 referente a uma entrada de 5 horas, o modelo que apresenta os melhores resultados é o que foi desenvolvido com 25 neurónios na camada oculta, apresentando um erro percentual médio de 11,4%. Neste caso não existe nenhuma tendência com a alteração dos parâmetros internos do modelo, verificando-se que o erro flutua com a variação do número de neurónios na camada oculta. Este comportamento pode dever-se ao ponto de inicialização aleatório associado á utilização do método de treino utilizado.

Tabela 5 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Fevereiro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	6,18	11,59
10	6,09	11,43
15	6,35	11,90
20	6,37	11,95
25	6,08	11,40

Realizando este processo com os restantes modelos e entradas diferenciadas, obtêm-se os resultados apresentados na tabela 6:

Tabela 6 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Fevereiro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	25	6,08	11,40
10	15	5,44	10,20
20	10	5,25	9,85
30	5	5,15	9,66

Dos resultados obtidos o modelo que obtém os melhores resultados para este conjunto de dados é o que foi desenvolvido com uma entrada de 3 dias, com 5 neurónios na camada oculta. Nota-se também que neste caso não surgiu o mesmo pico de erro que surgiu em janeiro. Nestas condições o erro manteve-se praticamente constante nos diversos modelos desenvolvidos, verificando-se também que o número de neurónios na camada oculta que fornece o menor erro possível também varia, não tendo sido detetada qualquer tendência de variação nos diferentes modelos.

4.4.3. Março

O perfil de produção energética de março de 2015 é apresentado no gráfico da figura 21.




Figura 21- Produção energética horária ao longo do mês de março de 2015

Relativamente aos valores referentes ao mês de março conclui-se que a instalação esteve a funcionar em média aproximadamente a 50% da sua capacidade de produção máxima, com um valor de 24,5 kWh, com alguns períodos de produção nula. Este fato pode dever-se a cortes na produção industrial ou inclusivamente situações de manutenção do sistema fotovoltaico. Os picos energéticos em que estes eventos aconteceram são mais pronunciados do que os verificados em situações de ensombramento da instalação, verificando-se também alguns destes casos ao longo do mês. Para os efeitos de comparação e de avaliação da qualidade dos resultados foram escolhidos os seguintes conjuntos de dados agrupados no gráfico da figura 22.




Figura 22- Períodos de estudo para o mês de março

Nos conjuntos de dados selecionados para a comparação deste mês, nota-se uma discrepância nos valores intermédios entre os períodos, tendo-se verificado uma queda súbita na produção a meio do intervalo. Excluindo esta variação, verificou-se que os comportamentos em ambos os casos apresentam um padrão semelhante entre si. No caso da produção estável, verificou-se a tendência para um comportamento cíclico, sem grandes alterações nos valores máximos produzidos.

Observando o comportamento dos modelos de previsão referentes a entradas de 5 horas com atualização horária do modelo obtêm-se os gráficos apresentados nos gráficos nas figuras 21 e 22:




Figura 23 - Comportamento dos modelos com um histórico de 5 horas no período estável de Março




Figura 24 - Comportamento dos modelos com um histórico de 5 horas no período instável de Março

Como se pode observar nos gráficos comportamentais dos modelos, não existe grande variação entre comportamentos. Os maiores erros associados às previsões ocorrem quando nas transições entre dias, havendo também maior variação nos resultados obtidos quando ocorrem picos, quer positivos quer negativos, de produção de energia.

Observando os resultados obtidos nos diversos modelos com o historial de 5 horas, presentes na tabela 7, observamos que o erro médio não tem nenhuma distribuição uniforme e com a variação do número de neurónios. O modelo que fornece o menor erro médio é o de 10 neurónios. Devido ao comportamento constante da produção energética ao longo do mês não se notou nenhum pico de erro nos diversos modelos.

Tabela 7 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Março

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	5,53	10,12
10	5,12	9,37
15	5,26	9,63
20	5,30	9,70
25	5,16	9,44

Realizando este processo com os restantes modelos com uma entrada diferente, obtêm-se os resultados constantes na tabela 8:

Tabela 8- Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Março

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	5,12	9,37
10	25	4,63	8,47
20	5	4,74	8,67
30	5	4,60	8,42

O modelo que produz menos erro é o que tem uma entrada de 3 dias com 5 neurónios. Nota-se novamente a inexistência de padrão do erro na variação dos parâmetros dos modelos. Como se pode notar na oscilação do número de neurónios que produzem o menor erro e na variação entre os diferentes modelos com

historiais diferentes. Esta inconsistência pode-se atribuir ao comportamento cíclico existente na produção ao longo do mês, sendo um perfil mais simples de realizar a previsão fotovoltaica.

4.4.4. Abril

O mês de abril apresentou um perfil de produção energética conforme o gráfico da figura 25.




Figura 25- Produção energética horária ao longo do mês de Abril de 2015

A produção média de abril é cerca de 40% da capacidade máxima da instalação, com um valor de 25 kWh. Constatamos alguns períodos em que a produção da instalação foi bastante limitada. A situação deve-se muito provavelmente a períodos de corte na produção industrial e eventualmente a fatores meteorológicos responsáveis pela formação de tetos de nuvens. As quedas de produção, por si só não permitem explicitar qual dos casos se trata. Para os efeitos de comparação e de avaliação da qualidade dos resultados foram selecionados os dados compilados no gráfico da figura 26.

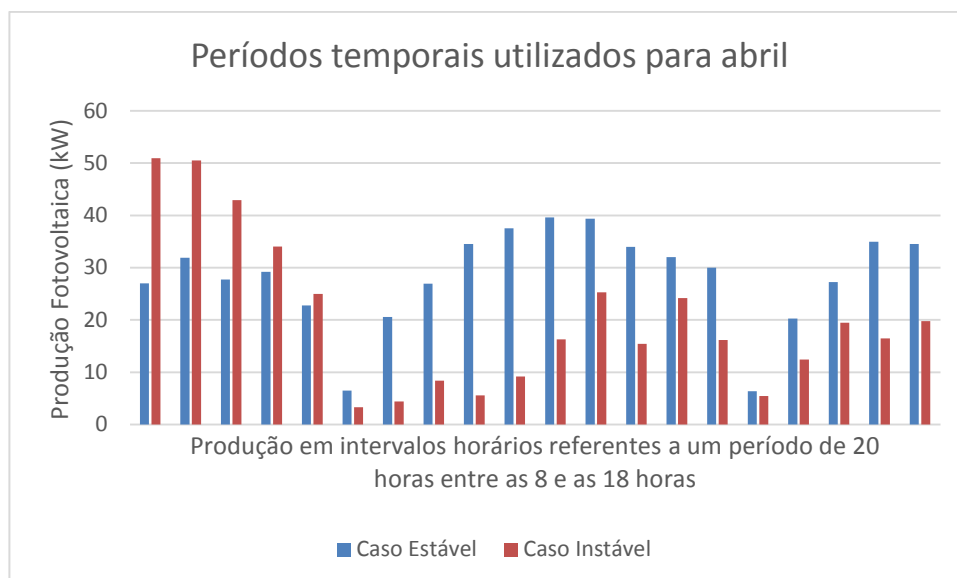


Figura 26- Períodos de estudo para o mês de abril

Nota-se no intervalo estável um comportamento constante, sem grandes variações de produção.

No período instável o comportamento é consistente com uma limitação de produção, sensivelmente a meio do período. Identifica-se uma queda de produção decorrido o primeiro terço do período temporal.

Observando o comportamento dos modelos de previsão com uma *entrada* de 5 horas e atualizações horárias obtêm-se os resultados representados nos gráficos das figuras 25 e 26.




Figura 27 - Comportamento dos modelos com um histórico de 5 horas no período estável de Abril




Figura 28 - Comportamento dos modelos com um histórico de 5 horas no período instável de Abril

Observando ambos os gráficos é possível inferir que os pontos mais significativos de divergência correspondem a previsões efetuadas com valores mais baixos, que ocorreram na transição entre dias ou em alturas em que a produção oscilou com valores mais baixos. Os modelos elaborados conseguiram acompanhar algumas discrepâncias na previsão, desde que as mesmas não fossem muito relevantes.

Nos resultados obtidos para os modelos com entradas de 5 horas, presentes na tabela 9, a configuração que proporcionou os melhores resultados para este conjunto de dados é o modelo que tem 10 neurónios. Nota-se uma diminuição no erro no modelo elaborado com 25 neurónios., sendo os restantes três modelos ligeiramente menos precisos. A inexistência de uma tendência no erro médio pode dever-se ao conjunto de dados utilizado não ter nenhum comportamento demasiadamente complexo ao longo deste.

Tabela 9 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Abril

Número de neurónios	Erro Absoluto Médio kW	Erro Percentual Médio %
5	6,46	11,86
10	6,30	11,56
15	6,43	11,82
20	6,50	11,94
25	6,38	11,72

A tabela 10 representa os resultados obtidos a partir da aplicação no modelo de entradas horárias e número de neurónios diferenciados.

Tabela 10 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Abril

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	5	6,46	11,86
10	15	5,51	10,11
20	15	5,31	9,75
30	5	5,73	10,53

O modelo que proporciona o menor erro médio tem um histórico de 2 dias e 15 neurónios na camada oculta da rede neuronal. Neste caso consegue-se observar um ligeiro aumento do erro de previsão com a diminuição do intervalo da

entrada da rede, não havendo no entanto um padrão específico na preferência do número de neurónios. Esta inconsistência pode-se novamente atribuir ao conjunto de dados utilizado, principalmente devido a natureza cíclica do modelo, sendo que as variações no treino dos diversos modelos originaram as pequenas discrepâncias na qualidade dos sistemas criados.

4.4.5. Maio

O mês de maio apresentou o perfil de produção energético conforme o gráfico da figura 29.




Figura 29- Produção energética horária ao longo do mês de Maio de 2015

A produção de maio rondou em média 50% da capacidade total de produção, na ordem de 31,5 kWh, verificando-se também momentos em que a produção da instalação é nula. No início do mês verificou-se uma queda de produção, inferior a 20 KW. Após esta alteração o padrão de produção foi constante e geralmente variou entre os 40 e 50 kW nos momentos de pico de produção. Os dias em que a produção é menor devem-se provavelmente a um nível reduzido de cobertura de nuvens, não se verificando valores de produção que indiquem cortes por motivos industriais.

Para os efeitos de análise comparativa e qualitativa foram selecionados os dados apresentados no gráfico da figura 30.




Figura 30- Períodos de estudo para o mês de maio

Em maio a produção teve um comportamento cíclico com algumas variações nos momentos de maior produção, apresentando no entanto um comportamento estável em termos globais. Não se verificaram variações nos picos de produção ao longo do período. No intervalo instável, sensivelmente meio do período identifica-se uma quebra de produção, com uma redução de cerca de 50%.

Utilizando uma entrada com um valor de 5 horas e atualizações horárias, obtivemos os resultados compilados nos gráficos das figuras 29 e 30.




Figura 31 - Comportamento dos modelos com um histórico de 5 horas no período estável de Maio




Figura 32 - Comportamento dos modelos com um histórico de 5 horas no período instável de Maio

Neste caso verificámos que o comportamento dos diversos modelos apresentou bastantes semelhanças em condições de maior produção, apresentando maiores variações associados aos períodos de transição diária ou em possíveis situações de corte de produção. Comparando com os casos já estudados nota-se uma maior variação dos valores de produção superiores entre os diversos modelos.

Tendo os resultados obtidos em consideração exibidos na tabela 11, nota-se um erro bastante inferior aos casos já estudados, podendo isto dever-se as condições de produção de energia e do conjunto de dados apresentarem um comportamento favorável para o modo como os modelos foram treinados. O modelo com uma entrada de 5 horas e 10 neurónios é o que apresenta melhores resultados no conjunto das comparações. Nota-se novamente uma tendência fixa no método como os resultados variam de acordo com o número de neurónios. Verifica-se um ligeiro aumento do erro médio, com o afastamento gradual da configuração em que se obtiveram os melhores resultados.

Tabela 11 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Maio

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	4,46	8,47
10	3,87	7,35
15	3,94	7,47
20	4,09	7,76
25	4,23	8,04

Recorrendo ao mesmo processo com os restantes modelos e entradas diferenciadas, obtiveram-se os resultados compilados na tabela 12:

Tabela 12 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Maio

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	3,87	7,35
10	10	2,60	4,93
20	15	2,63	5,00
30	5	2,57	4,87

O modelo que apresenta o melhor conjunto de resultados foi elaborado com uma entrada de 3 dias e 5 neurónios. Nota-se num decréscimo grande no erro médio obtido, quando comparado com os casos de estudo anteriores, podendo isto atribuir-se ao conjunto de dados utilizado, sendo que este apresenta um formato e comportamento adaptado aos modelos anuais, ou seja, apresenta um comportamento cíclico, praticamente constante e sem grandes variações. O conjunto de modelos que apresentou os piores resultados foi elaborado com entradas de 5 horas. Eventualmente o modelo não realizou as previsões com precisão devido à sua simplicidade. Nota-se ainda uma discrepância no número de neurónios na camada interna que produzem os resultados mais precisos, podendo este

fato dever-se também ao conjunto de dados estar em condições perto do ideal/ de produção cíclicas com valores elevados.

4.4.6. Junho

O registo da produção energética de junho está representado no gráfico da figura 33.




Figura 33- Produção energética horária ao longo do mês de Junho de 2015

À semelhança do mês anterior, no decurso do mês de junho, a instalação produziu em média perto de 50% da sua capacidade, com um valor de 31 kWh. Verificaram-se períodos em que a produção da instalação esteve mais limitada, podendo a situação dever-se ao consumo fabril. Em alguns dias verificaram-se decréscimos na produção correspondentes a cortes totais, com várias situações deste tipo no mesmo dia. Por outro lado é também possível inferir que em alguns dias a produção foi afetada devido à passagem ou formação de tetos de nuvens sobre a instalação. Nestas situações a produção não é tão limitada nem sofre picos com a mesma magnitude que nos casos em que a produção é limitada pela fábrica.

O gráfico da figura 34 apresenta os dados selecionados para efeitos de comparação.




Figura 34- Períodos de estudo para o mês de junho

O perfil de produção energética em ambas as situações apresenta uma ligeira discrepância no final dos intervalos. Esta variação consiste numa produção mais baixa no período instável, notando-se no final do conjunto de dados uma variação de produção mais significativa entre ambos os casos. No restante conjunto, ambos os intervalos apresentam um comportamento semelhante, sem grandes variações nos valores produzidos, observando-se uma conduta cíclica.

Os gráficos 33 e 34 representam o comportamento dos modelos de previsão com entradas de 5 horas e atualizações horárias.




Figura 35 - Comportamento dos modelos com um histórico de 5 horas no período estável de Junho




Figura 36 - Comportamento dos modelos com um histórico de 5 horas no período instável de Junho

Nos resultados apurados voltamos a notar uma ligeira discrepância nas previsões efetuadas com valores mais baixos e no final de ascensões, sendo que alguns dos modelos apresentam um ligeiro pico na previsão, antes de estabilizarem. Manteve-se a situação dos períodos com maior erro corresponderem às transições diárias, sendo também esse o ponto de maior discrepância entre os diversos modelos.

Na análise dos modelos com um histórico de 5 horas, exibidos na tabela 13, constatamos que o modelo com a configuração que fornece o erro mínimo foi elaborado com 10 neurónios ocultos. O erro aumenta quando nos afastámos da configuração que forneceu os melhores resultados, sendo que este incremento corresponde também à diminuição do número de neurónios existentes na camada oculta. Este fenómeno foi também observado em casos anteriores e foi atribuído ao comportamento apresentado pelo conjunto de dados utilizado para realizar as previsões.

Tabela 13 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Junho

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	4,89	9,22
10	4,19	7,91
15	4,32	8,16
20	4,57	8,63
25	4,65	8,78

Realizando o mesmo processo com os restantes modelos e variando as entradas, obtiveram-se os resultados apresentados na tabela 14.

Tabela 14 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Junho

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	4,19	7,91
10	15	3,21	6,06
20	15	3,31	6,25
30	5	3,51	6,64

Observando os resultados das comparações finais verifica-se novamente um erro médio ligeiramente menor do que em outros casos, podendo a situação

atribuir-se ao comportamento perto do ideal apresentado no conjunto de dados, i.e. um comportamento cíclico com pouca variação. Dentro dos modelos estudados, o que obteve os melhores resultados é o modelo com um histórico de 1 dia e com 15 neurónios na camada oculta. Observa-se também uma tendência para o erro aumentar com o afastamento do intervalo dos valores de entrada na rede, notando-se um aumento superior para valores inferiores ao valor ótimo do que para valores superiores. Não se identificaram tendências específicas na distribuição dos neurónios verificando-se apenas pequenas variações de resultados, que podem ser atribuídas ao número de neurónios utilizado.

4.4.7. Julho

O mês de julho de 2015 apresenta o perfil de produção identificado no gráfico da figura 37




Figura 37- Produção energética horária ao longo do mês de Julho de 2015

Em julho, a produção da instalação rondou os 50% da sua capacidade, cerca de 33 kWh. É possível identificar um corte prolongado produção comparativamente com períodos anteriores de suspensão de produção, desconhecendo-se o motivo específico para esta situação particular ter ocorrido. São perceptíveis algumas variações de produção provocadas eventualmente por cobertura de nuvens, uma vez que os níveis energéticos produzidos não correspondem a interrupções na produção da fábrica.

Para efeitos de análise e comparação dos resultados foram selecionados os dados, constantes nos gráfico da figura 38.




Figura 38- Períodos de estudo para o mês de julho

Observando os períodos do mês em estudo, observa-se um comportamento cíclico sem grandes variações na qualidade da produção ao longo do caso estável.

No caso instável nota-se um comportamento atípico a meio do intervalo, observando-se um corte completo na produção.

Relativamente ao comportamento dos modelos de previsão, foi realizado uma entrada de com um histórico de 5 horas e atualizações horárias, obtendo-se os resultados representados nos gráficos das figuras 37 e 38.




Figura 39 - Comportamento dos modelos com um histórico de 5 horas no período estável de Julho




Figura 40 - Comportamento dos modelos com um histórico de 5 horas no período instável de Julho

No período em que a produção energética é nula por um período de tempo alargado, os modelos apresentaram um comportamento errático, não se adaptando a este cenário. Verificaram-se comportamentos diferentes, dependendo dos seus parâmetros internos. Também foram assinaladas discrepâncias no comportamento dos modelos em situações de alterações súbitas na produção quer se trate de aumentos ou decréscimos da mesma.

Estudando os resultados obtidos dos vários modelos com entradas de 5 horas, presentes na tabela 15, constatou-se que o modelo que apresentou melhores resultados tem 10 neurónios na camada oculta, apresentando a mesma distribuição do erro verificada em alguns casos anteriores. O incremento no erro é maior com a simplificação da rede do que nos casos em que a rede é mais complexa. É de notar que o erro médio é inferior a uma parte significativa dos outros casos estudados, mas já volta a aumentar, provavelmente devido a condições atmosféricas, como se pode observar no gráfico completo em que a variação da produção máxima varia entre certos dias.

Tabela 15 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Julho

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	4,86	9,09
10	4,12	7,70
15	4,29	8,03
20	4,55	8,51
25	4,65	8,69

Realizando este processo com os restantes modelos e diferentes entradas históricas, obtêm-se os resultados apresentados na tabela 16.

Tabela 16 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de julho

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	4,12	7,70
10	10	3,34	6,24
20	15	3,46	6,47
30	5	3,55	6,55

Dos resultados obtidos destaca-se o modelo que utilizou 1 dia de histórico e 10 neurónios como entrada. Nota-se novamente variações nas tendências de erro quando alteramos o número de horas no histórico da rede, sendo que este partilha as mesmas tendências que os meses com melhores resultados em termos do comportamento da evolução do erro. Também não foi identificado um padrão de comportamento nos diversos modelos em termos de consistência do número de neurónios da camada interna.

4.4.8. Agosto

O mês de agosto apresentou o perfil de produção energética, conforme o gráfico representado na figura 41.




Figura 41- Produção energética horária ao longo do mês de Agosto de 2015

Mais uma vez a produção ronda cerca de 50% da capacidade máxima instalada, por volta dos 31,5 kWh. Da análise efetuada verificamos a existência de um conjunto elevado de períodos em que a produção energética foi limitada pela fábrica como se pode notar nos picos em que a energia produzida reduz de forma significativa, voltando posteriormente a subir para o patamar anterior ao corte. Estes períodos de tempo são demasiado curtos e intensos para que a sua causa possa ser atribuída à cobertura da instalação por nuvens. Este último caso também se verificou, sendo que o impacto nos níveis de produção não foi tão elevado como no caso da limitação induzida pela fábrica.

Para efeitos de comparação e de avaliação dos resultados foram analisados no gráfico da figura 42.




Figura 42- Períodos de estudo para o mês de agosto

A produção no decurso de agosto apresentou um comportamento semelhante em ambas as situações, residindo a diferença na quantidade de energia produzida. No caso estável nota-se um comportamento cíclico com produções constantes nos momentos de produção máxima, não tendo existido variações bruscas ao longo do período.

No caso instável nota-se uma queda na quantidade de energia produzida no final do intervalo de tempo.

Observando o comportamento dos modelos com uma entrada de 5 horas com e atualizações horárias, obtiveram-se os resultados representados nos gráficos das figuras 41 e 42.




Figura 43 - Comportamento dos modelos com um histórico de 5 horas no período estável de Agosto




Figura 44 - Comportamento dos modelos com um histórico de 5 horas no período instável de Agosto

Como se pode observar através dos comportamentos dos modelos, os momentos em que existem maiores variações continuam a estar associados a alterações súbitas de produção energética. As variações entre os sistemas são maiores nas alturas em que a produção é mais baixa, sendo mais visíveis nas transições diárias ou em períodos de limitação da energia produzida por parte da instalação. Nos restantes casos os modelos apresentam resultados semelhantes, com ligeiras discrepâncias nas transições.

Como podemos observar na tabela 17, que agrupa os resultados obtidos, a configuração que apresenta o menor erro médio é a que dispõem de 15 neurónios na camada oculta verificando-se novamente o mesmo padrão distinto de distribuição do erro de previsão já existente em casos anteriores. Os erros maiores ocorrem nos modelos mais simples. Verificou-se um incremento no erro médio maior nos modelos em que foram utilizados 5 e 10 neurónios comparativamente aos modelos que utilizavam mais que 15 neurónios.

Tabela 17 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Agosto

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	4,91	9,08
10	4,29	7,95
15	4,27	7,89
20	4,45	8,24
25	4,47	8,27

Realizando este processo com os restantes modelos e entradas históricas diferentes, obtêm-se os resultados agrupados na tabela 18.

Tabela 18 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Agosto

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	15	4,27	7,89
10	15	3,64	6,73
20	15	3,61	6,68
30	5	3,60	6,66

O modelo que apresenta os melhores resultados é a rede que utiliza um histórico de 3 dias e 5 neurónios internos. Notou-se um decréscimo no erro médio à medida que aumentámos a quantidade de informação na entrada do modelo.

Assim, podemos inferir que através do comportamento geral do conjunto de dados que este apresenta uma estrutura simples e cíclica, sem grandes variações nos picos de produção energética. Nota-se ainda tendências diferentes no número de neurónios existentes na camada oculta entre os diversos tipos de modelos diferentes, sendo que para os modelos com intervalos de entrada menores é favorecido um número intermédio de neurónios na camada interna.

4.4.9. Setembro

O mês de setembro apresentou o perfil de produção energética representado no gráfico da figura 45.




Figura 45- Produção energética horária ao longo do mês de Setembro de 2015

À semelhança dos meses anteriores, a produção de setembro foi em média cerca de 50 % da capacidade, cerca de 29,5 kWh. À semelhança dos meses anteriores verificaram-se algumas variações em termos de produtividade da instalação. Foi efetuado um corte na produção por um período de tempo mais prolongado do que o normal, verificando-se que os dias de menor produção são provavelmente devidos a cobertura por teto de nuvens ou condições meteorológicas menos favoráveis., que tiveram impacto em termos de variações mais ou menos significativas na produção.

O gráfico da figura 46 representa a análise de resultados obtidos em setembro.




Figura 46- Períodos de estudo para o mês de setembro

O caso da produção estável apresenta um comportamento cíclico, sem variações em níveis de produção de máxima.

No caso instável nota-se um corte na produção aproximadamente a meio do intervalo, sendo que o restante período de tempo apresenta uma produção semelhante ao caso estável.

À semelhança dos casos de estudo anteriores foi efetuada uma entrada de 5 horas com atualizações horárias, obtendo-se os resultados explicitados nos gráficos das figuras 45 e 46.




Figura 47 - Comportamento dos modelos com um histórico de 5 horas no período estável de Setembro




Figura 48 - Comportamento dos modelos com um histórico de 5 horas no período instável de Setembro

Verificou-se uma grande discrepância nos valores previstos nos períodos em que a produção teve valores reduzidos ou nulos. Nos momentos anteriores e posteriores a estes acontecimentos verificou-se um aumento progressivo da variação nos valores de previsão com a aproximação da zona de corte energético, notando-se uma recuperação mais rápida do que na destabilização. Nos restantes momentos os modelos apresentam comportamentos semelhantes.

Observando os erros presentes na tabela 19 nota-se que os melhores resultados provêm dos modelos com 10 neurónios ocultos, verificando-se mais uma vez uma distribuição de erro semelhante à que foi observada nos casos estudados anteriormente, verificando-se novamente que o erro cresce mais lentamente com o aumento da complexidade da rede. O aumento do erro médio comparado com os casos anteriores pode-se justificar pelas condições atmosféricas associadas ao conjunto de dados e ao seu comportamento geral, registando-se variações maiores em todo o conjunto.

Tabela 19 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Setembro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	5,79	10,72
10	5,32	9,83
15	5,55	10,26
20	5,43	10,04
25	5,57	10,31

Realizando o mesmo processo com os restantes modelos e entradas históricas diferente, obtiveram-se -se os resultados apresentados na tabela 20.

Tabela 20 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Setembro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	10	5,32	9,83
10	15	5,12	9,46
20	10	4,68	8,66
30	10	4,97	9,19

Da análise efetuada verificamos que a configuração do modelo que fornece os valores mais favoráveis tem uma entrada de 2 dias de histórico e 10 neurónios

na camada interna, ao mesmo tempo que constatamos a existência do mesmo nível de incremento do erro presente em casos testados anteriormente nas diversas configurações possíveis. Notou-se algum paralelismo no número de neurónios presentes na camada interna da rede, sendo que para este conjunto de dados valores entre os 10 e os 20 neurónios na camada oculta fornecem os melhores resultados.

4.4.10. Outubro

O mês de outubro apresentou o perfil de produção energética exposto no gráfico da figura 49.




Figura 49- Produção energética horária ao longo do mês de Outubro de 2015

O valor médio da produção em outubro foi substancialmente inferior aos valores registados nos meses anteriores, na ordem dos 30% da sua capacidade instalada, com uma produção média de 18 kWh. Constatam-se alguns picos de produção que chegaram a atingir 50 kW em determinados dias. Dos dados disponíveis infere-se que a produção reduzida ao longo do mês foi afetada pela meteorologia, i.e. cobertura de nuvens, uma vez que no caso de uma limitação da produção da instalação por necessidades fabris os períodos temporais iriam ser menores. No início do mês verificaram-se alguns períodos de corte com duração superior ao normal, sendo os restantes de duração intermédia, e espaçados ao longo de todo o mês.

Para os efeitos de comparação e de avaliação da qualidade dos resultados foi elaborado o gráfico da figura 50.




Figura 50- Períodos de estudo para o mês de outubro

Analisando os períodos escolhidos para outubro nota-se um comportamento cíclico e constante no caso estável, não apresentando nenhuma variação acentuada na produção.

No caso instável, a produção é muito reduzida ao longo de todo o intervalo em causa.

À semelhança dos casos anteriores foi efetuada uma entrada de 5 horas e realizadas atualizações horárias, obtendo-se os gráficos das figuras 49 e 50




Figura 51 - Comportamento dos modelos com um histórico de 5 horas no período estável de Outubro




Figura 52 - Comportamento dos modelos com um histórico de 5 horas no período instável de Outubro

Da análise efetuada verifica-se que os modelos apresentam uma maior discrepância quando se verificam decréscimos súbitos na produção. Estas situações concorrem para aumentar a dificuldade na realização de previsões de maior precisão. Verificaram-se novamente ligeiras discrepância nas previsões efetuadas em momentos de baixa produção, correspondentes às transições diárias. Os resultados obtidos foram agrupados na tabela 21.

Tabela 21 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Outubro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	7,10	13,42
10	7,11	13,44
15	7,34	13,87
20	7,22	13,64
25	7,24	13,69

O modelo que apresentou os resultados com maior precisão tem 5 neurónios ocultos sendo que os restantes modelos apresentaram erros ligeiramente superiores a este. Neste caso não existe um único sentido para o erro aumentar, existindo um declive no erro médio do modelo com 20 neurónios ocultos, antes do mesmo voltar a aumentar. A situação descrita pode dever-se ao comportamento mais complexo dos modelos em conjunção com a natureza pseudoaleatória do algoritmo de treino utilizado.

Realizando este processo com os restantes modelos e entradas históricas diferentes obtêm-se os seguintes os resultados agrupados na tabela 22.

Tabela 22 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Outubro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	5	7,10	13,42
10	15	6,56	12,40
20	5	6,29	11,88
30	5	6,34	11,98

O modelo que obteve os melhores resultados no contexto deste perfil tem 2 dias de histórico e 5 neurónios na camada oculta da rede. Ao estudar o comportamento dos modelos diferentes, constatou-se um aumento do erro médio dos

modelos com a diminuição do histórico da rede. Este fato pode ser atribuído ao comportamento geral apresentado no conjunto de dados, sendo mais fácil de detectar o padrão geral de comportamento quando utilizamos um historial maior. Em termos de distribuição do número de neurónios na camada oculta, não existe nenhum padrão consistente com o seu comportamento.

4.4.11. Novembro

O gráfico da figura 53 apresenta a produção de energia elétrica correspondente ao mês de novembro.




Figura 53- Produção energética horária ao longo do mês de Novembro de 2015

Tal como no mês anterior a produção de novembro foi aproximadamente 30% da capacidade máxima da instalação, apresentando uma produção média de 20 kWh. Da análise efetuada constatou-se a existência de um alguns dias no início do mês em que a produção é muito baixa quando comparada com os restantes dias de novembro. Esta situação poderá ter sido causada por condições meteorológicas adversas, ou mesmo limitações da própria fábrica. No decurso do resto do mês a produção elétrica estabilizou, obtendo um padrão estável, com alguns dias a obterem maior rendimento, provavelmente devendo-se esta situação a condições meteorológicas mais favoráveis.

O gráfico da figura 54 representa os períodos de variação mais significativos relativamente à estabilidade de produção elétrica.




Figura 54- Períodos de estudo para o mês de novembro

Em novembro verificou-se um corte significativo na produção no caso instável, sendo que a produção no final deste período sofre um pico negativo após apresentar um comportamento perto do normal.

No caso estável nota-se um comportamento cíclico com valores máximos de produção semelhantes ao longo do intervalo.

O comportamento dos modelos de previsão com uma entrada dos dados referentes a um período com um histórico de 5 e atualizações horárias estão representados nos gráficos das figuras 53 e 54.




Figura 55 - Comportamento dos modelos com um histórico de 5 horas no período estável de Novembro




Figura 56 - Comportamento dos modelos com um histórico de 5 horas no período instável de Novembro

Observando o comportamento apresentado pelos modelos nos 2 casos apresentados, nota-se que existe pouca variação entre os diversos modelos durante a maior parte do período em estudo. As maiores variações ocorreram nos momentos de menor produção, estejam os mesmos relacionados com fatores exógenos ou questões de produção fabril.

Os resultados apurados relativamente ao erro médio dos modelos foram sintetizados na tabela 23.

Tabela 23 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Novembro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5	5,73	11,27
10	5,84	11,48
15	6,34	12,47
20	6,33	12,44
25	6,36	12,50

O modelo que obteve os melhores resultados, assinalado a cor verde, é o que utilizou 5 neurónios ocultos. Neste modelo a evolução do erro não evoluiu de uma forma uniforme com a variação do número de neurónios tendo-se registado o valor nos 20 neurónios.

Repetindo o processo com os restantes modelos e entradas históricas diferentes obtêm-se os seguintes os resultados apresentados na tabela 24.

Tabela 24 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Novembro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	5	5,73	11,27
10	15	5,15	10,11
20	10	5,15	10,12
30	10	4,96	9,75

Os resultados mais favoráveis assinalados a verde, correspondem ao modelo com uma entrada histórica de 3 dias e com 10 neurónios na camada interna. Esta configuração foi a que apresentou o menor erro médio para este conjunto de dados. Verificou-se que o erro tem tendência a aumentar com a diminuição do

intervalo de tempo na entrada do modelo, justificando-se esta situação através do comportamento geral do conjunto. O comportamento geral do modelo é mais fácil de identificar quando se utiliza como entrada um historial maior.

4.4.12. Dezembro

O registo dos resultados da produção elétrica do mês de dezembro é apresentado no gráfico da figura 57.




Figura 57 - Produção energética horária ao longo do mês de Dezembro de 2015

Ao observar o comportamento da produção apresentada pela instalação neste mês. O mês de dezembro apresentou os valores mais baixos de produção de todo o ano, registando-se uma média na ordem dos 20% da capacidade total, com uma produção média de 13 kWh. Para este fato contribuíram as condições meteorológicas próprias do inverno, e também o número diário de horas de sol ser em média 7 horas. Como esta situação acontece ao longo de todo o mês é pouco provável que possa ter origem em necessidades de gestão de produção da fábrica.

Para efeitos de comparação dos resultados em situações de alteração de estabilidade de produção energética foi elaborado o gráfico da figura 58.




Figura 58- Períodos de estudo para o mês de dezembro

A produção na situação estável apresenta um comportamento cíclico, sendo praticamente nula em momentos de transição, não se observando nenhuma variação no seu comportamento.

No caso instável nota-se uma queda na produção no final do intervalo e um pico na produção a meio deste.

Como nos casos anteriores, foi utilizada uma entrada referente à produção com histórico de 5 horas e atualizações horários, tendo-se obtido como resultado os gráficos das figuras 57 e 58.




Figura 59 - Comportamento dos modelos com um histórico de 5 horas no período estável de Dezembro




Figura 60 - Comportamento dos modelos com um histórico de 5 horas no período instável de Dezembro

Neste caso, verificou-se uma discrepância de valores ligeiramente superior do que nos casos anteriormente analisados no que respeita aos períodos de transição entre as produções mais elevadas e mais baixas podendo associar-se este fator aos níveis baixos de energia que existem entre estes pontos. Nota-se ainda que os períodos em que existe uma maior discrepância nas previsões efetuadas são os momentos de transição diária.

Observando os dados exibidos na tabela 25, nota-se que o modelo que apresentou menor erro médio é o que utilizou 5 neurónios. Constatou-se que os erros não variam uniformemente com as alterações ao número de neurónios, podendo este facto dever-se ao método de treino da rede. Nota-se um mínimo local em termos de erro obtido, no modelo que utilizou 20 neurónios.

Tabela 25 - Comparação do erro médio para os modelos com um histórico de 5 horas para o mês de Dezembro

Número de neurónios	Erro Absoluto Médio (kW)	Erro Percentual Médio (%)
5 Neurónios ocultos	5,04	11,01
10 Neurónios ocultos	5,18	11,32
15 Neurónios ocultos	5,55	12,13
20 Neurónios ocultos	5,38	11,76
25 Neurónios ocultos	5,60	12,25

Foi realizado o mesmo processo para os restantes modelos, utilizando entradas históricas diferentes, obtendo-se os resultados apresentados na tabela 26

Tabela 26 - Comparação do erro médio para os casos ótimos em cada um dos tipos de modelo diferentes para o mês de Dezembro

Número de horas de histórico na rede	Número de neurónios na camada interna	Erro médio absoluto (kW)	Erro médio percentual (%)
5	5	5,04	11,01
10	15	4,57	9,98
20	15	4,41	9,64
30	5	4,27	9,40

O modelo que apresentou os resultados mais favoráveis foi o que utilizou um histórico de 3 dias e 5 neurónios na sua camada interna. Neste caso, notou-se um aumento constante do erro médio com a diminuição do conjunto de informação na entrada do modelo. Este comportamento justifica-se através do conjunto

Nos gráficos das figuras 60 e 61 apresentam-se os resultados da previsão realizada para a produção a um horizonte de 24 horas, sendo os resultados encontrados comparados com a produção real no mesmo período de tempo.




Figura 62 - Resultados da previsão a 24 horas no período de maio




Figura 63 - Resultados da previsão a 24 horas no período de agosto

Analisando os resultados obtidos verifica-se uma discrepância nos resultados nos momentos de produção mais elevada, não havendo grandes complicações nas transições diárias. Nota-se uma ligeira variação nos resultados no dia final de maio, devido ao método de recorrência utilizado, que não consegue prever nem incorporar comportamentos irregulares.

A tabela 27 regista os erros médios absolutos e percentuais em ambas as situações.

Tabela 27 - Erros obtidos nas previsões durante os períodos escolhidos

Mês	Erro Médio Absoluto (kW)	Erro Médio Percentual (%)
Maio	3,73	7,89
Agosto	3,85	8,29

Dos resultados obtidos, inferimos que em condições de produção estáveis o modelo de previsão obtém resultados eficazes, demonstrando um erro médio inferior a 10% em ambos os casos exemplificados. É de notar que a qualidade dos resultados está associada á estabilidade das condições temporais e fabris, sendo que a atualização da previsão diminui o erro médio.

4.6. Estudo geral do modelo

Para estudar o efeito da normalização no modelo, foi utilizado um conjunto de dados com o historial de produção num sistema de previsão com uma entrada de 1 dia e com 10 neurónios na camada oculta.

Foi escolhido um período entre 13 e 15 de julho, que se encontra no gráfico da figura 64.




Figura 64 - Conjunto de dados normalizados escolhidos para testar os modelos anuais

Considerando este conjunto de dados, observamos um comportamento estável ao longo do intervalo, sendo que não existem variações no comportamento da produção ou nos valores máximos observados no decurso dos diversos dias.

A resposta do modelo normalizado e do modelo anual com resultados normalizados com uma atualização horária é comparada através do gráfico da figura 65. A este gráfico foram também acrescentados os valores de produção normalizados referentes ao mesmo intervalo de tempo.




Figura 65 - Resultados obtidos pelos modelos de comparação do conjunto de dados escolhidos.

Observando o comportamento geral de ambos os modelos, verifica-se que apresentam resultados semelhantes entre si, com variações mínimas ao longo de todo o intervalo de previsão.

As variações nos resultados obtidos podem-se dever ao treino da rede neuronal, sendo que o conjunto de dados utilizado para ambos os casos apresenta o mesmo comportamento, diferindo apenas na escala.

A título de demonstração das variações entre estes modelos, na tabela 28 apresentam-se os erros percentuais médios obtidos pelos dois modelos no mesmo intervalo de tempo.

Tabela 28- Erros percentuais médios dos modelos normalizados e não normalizados para o intervalo de estudo

Tipo de Modelo	Erro Percentual Médio (%)
Não Normalizado	1,82
Normalizado	3,07

Pode-se inferir através destes resultados que a normalização do conjunto de dados tem uma influência mínima nas previsões obtidas, notando-se um erro ligeiramente superior no modelo normalizado.

Para estudar o efeito de uma atualização do conjunto de dados a meio de uma previsão recursiva com um horizonte de 20 horas, foram utilizados os conjuntos de dados estáveis e instáveis representados na figura 66. Os dados utilizados referem-se aos períodos de 17 a 19 de setembro para o caso instável e de 4 a 6 de agosto para o caso estável.




Figura 66 - Períodos de estudo para o caso de estudo de atualização de previsão

O caso estável utilizado apresenta um comportamento cíclico em que os picos de produção têm valores semelhantes. O intervalo instável apresenta um comportamento regular na produção ao longo do período com exceção da parte final, onde é visível um corte completo.

Nestes casos foram obtidas as respostas representadas nos gráficos das figuras 65 e 66, utilizando um modelo com um historial de 1 dia e com 10 neurónios na camada oculta da rede neuronal, sendo um dos modelos atualizado a cada hora enquanto o outro realiza uma previsão utilizando recursivamente os valores que se prevêem obter a um horizonte de 24 horas.




Figura 67- Comportamento dos modelos com um histórico de 10horas no período estável do caso comparativo de atualização de previsão




Figura 68- Comportamento dos modelos com um histórico de 10horas no período instável do caso comparativo de atualização de previsão

No caso estável nota-se uma ligeira discrepância nos resultados obtidos entre os modelos em questão, sendo esta mais pronunciada nos momentos de transição. No caso instável o modelo que realiza as previsões recursivamente ignora completamente o momento em que ocorre o corte da produção, continuando a realizar a previsão como se fosse um caso estável, enquanto o modelo atualizado horariamente realiza o seguimento desta ocorrência.

Tendo em conta os resultados obtidos com as atualizações ao longo do período de previsão consegue-se concluir que a atualização frequente das previsões em casos mais complexos permite obter resultados muito mais fiáveis, sendo que os modelos não conseguem incorporar a sua própria reação a certos conjuntos, exibindo comportamentos negativos para uma previsão dos resultados eficaz.

5. Conclusões e trabalho futuro

O objetivo do trabalho consistiu em criar um conjunto de sistemas de previsão de produção fotovoltaica para escalas geográficas reduzidas, para um horizonte de previsão de 24 horas, utilizando os dados históricos disponibilizados e comparar os resultados obtidos.

Nesse sentido foram utilizados os dados disponíveis da produção energética de 2014, e de 2015. Os dados referentes a 2014 foram utilizados para o conjunto de treino das várias redes neuronais e os dados de 2015 foram utilizados para o conjunto de validação e comparação das mesmas redes. Foram criados 24 modelos anuais com parâmetros internos diferentes que permitiram identificar os diferentes comportamentos de previsão. Foi ainda criado um modelo anual com os valores de produção normalizados, para estudar o efeito da normalização dos dados nos resultados obtidos.

A organização e manipulação dos dados disponibilizados, correspondentes a 2 anos de produção energética detalhada, constituíram um desafio. Não obstante consideramos que o detalhe e o volume dos dados disponibilizados reforçam a análise dos resultados e conclusões que podem ser inferidas.

Dever-se-á referir que a ausência do registo de informação sobre as condições meteorológicas no local onde a fábrica se situa, da ocorrência de paragens na produção industrial da própria fábrica e eventuais alterações de produção energética devidas à manutenção do sistema fotovoltaico, constituíram óbices

para a interpretação das causas prováveis quanto a alterações da produção energética, uma vez que não foi possível cruzar outros dados com o registo disponibilizado.

De uma forma geral, infere-se que a produção energética da instalação teve um comportamento concordante com as condições climatéricas associadas a cada mês, sendo que a produção média nos meses de inverno é na ordem dos 20% e nos meses de verão ronda os 50%. Como seria expectável, a produção energética no verão foi menos afetada por fatores meteorológicos e portanto com valores mais previsíveis, quando comparada com os meses de inverno.

Considerando os diversos resultados obtidos pelos vários modelos criados, conseguem-se tirar algumas conclusões em relação ao funcionamento dos mesmos. Verificou-se que os modelos de previsão obtêm melhores resultados quando a instalação está a funcionar em condições estáveis, com o mínimo de interferência por parte de fatores exógenos e um consumo fabril regular.

Agrupando os melhores resultados obtidos em cada mês na tabela 29, inferimos que a configuração da rede geral que maioritariamente obtêm os melhores valores consiste num modelo com uma entrada de 30 horas, repetindo-se esta situação em 6 casos. Os modelos com 10 e 20 horas tiveram o mesmo número de situações em que obtiveram o menor erro, i.e. 3 ocorrências cada um. Os modelos que utilizaram um histórico de 5 horas nunca registaram os melhores valores.

Tabela 29 - Configurações com os melhores resultados para cada mês de 2015

Mês	Entrada Histórica (horas)	Número de Neurónios	Erro Médio Percentual (%)
Janeiro	10	20	8,10
Fevereiro	30	5	9,66
Março	30	5	8,42
Abril	20	15	9,75
Maio	30	5	4,87
Junho	10	15	6,06
Julho	10	10	6,24
Agosto	30	5	6,66
Setembro	20	10	8,66
Outubro	20	5	11,88
Novembro	30	10	11,27
Dezembro	30	5	9,40

A distribuição de resultados pode-se justificar pelo tipo de modelo criado, ou seja, como a única fonte de informação da rede é o histórico de produção, intervalos maiores fornecem uma contextualização melhor do comportamento da produção atual.

Relativamente ao número de neurónios na camada oculta, verificou-se uma tendência inversa relativamente à distribuição quantitativa dos mesmos, i.e. os melhores resultados estão maioritariamente associados a redes com um número menor de neurónios.

Nos casos estudados notou-se a ocorrência de 6 situações em que redes com 5 neurónios obtiveram os melhores resultados; 3 situações com 10 neurónios; 2 situações com 15 neurónios e apenas um caso em que 20 neurónios obtiveram o menor erro.

A situação justifica-se pela complexidade acrescida que o incremento do número de neurónios impõe na rede, tendo o aumento de complexidade um impacto negativo nos resultados finais.

Os resultados obtidos através da utilização recursiva de entradas de dados no modelo, permitiu concluir que as previsões efetuadas têm melhor qualidade quando ocorrem nos intervalos de condições estáveis, notando-se a incapacidade do modelo para incorporar previsões com variações súbitas na produção, como se verificou no exemplo efetuado relativas às previsões do dia 23 de maio.

Considerando os comportamentos analisados em eventos mais instáveis, é recomendado que as previsões para horizontes temporais maiores sejam atualizadas frequentemente devido ao risco de alterações imprevistas na produção durante o período em análise.

O modelo desenvolvido apenas comporta em termos de variáveis o histórico da produção. A inclusão de outras variáveis no tratamento dos resultados, tais como a utilização de sistemas de previsão meteorológicas em conjunção com o modelo pode beneficiar a precisão do produto final.

No que concerne a este estudo de caso, também se podem incorporar variáveis quanto às exigências do consumo energético fabril, nomeadamente devido a cortes de energia que possam afetar os resultados da previsão.

Apesar das dificuldades que o modelo apresentou para condições mais irregulares de produção, considera-se que o mesmo providencia um método de desenvolvimento simples, bastando ter acesso a um conjunto de dados históricos da produção com uma extensão de pelo menos um ano. A utilização de conjuntos maiores permite obter um modelo de previsão mais preciso.

A utilização deste método de modelação permite criar sistemas de previsão de produção fotovoltaica com horizontes temporais que podem ir até 24 horas com resultados precisos em condições meteorológicas e de consumo energético industrial estáveis. Considerando os resultados obtidos nas diversas redes, este tipo de modelos pode ser utilizado em zonas que tenham um longo histórico de produção energética para implementar um sistema de previsão simples com um baixo custo económico de instalação que não necessitem de uma precisão elevada nas previsões efetuadas.

Como recomendações futuras, sugere-se um estudo onde se incluam outras variáveis, tais como condições meteorológicas nos modelos de previsão bem como a utilização conjunta de outros modelos para se conseguir estudar o impacto que estes têm nos resultados finais e nos horizontes de previsão possíveis.

Referências Bibliográficas

- Bacher, P., Madsen, H., & Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar Energy*, 83(10), 1772–1783.
<http://doi.org/10.1016/j.solener.2009.05.016>
- Bosch, J. L., Zheng, Y., & Kleissl, J. (2013). Deriving cloud velocity from an array of solar radiation measurements. *Solar Energy*, 87(1), 196–203.
<http://doi.org/10.1016/j.solener.2012.10.020>
- Cao, J., & Lin, X. (2008). Study of hourly and daily solar irradiation forecast using diagonal recurrent wavelet neural networks. *Energy Conversion and Management*, 49(6), 1396–1406.
<http://doi.org/10.1016/j.enconman.2007.12.030>
- Cebecauer, T., Šúri, M., & Perez, R. (2010). High Performance MSG Satellite Model for Operational Solar Energy Applications. *Proc. of American Solar Energy Society Annual Conference*, 5–9.
- Chaouachi, a, Kamel, R., & Nagasaka, K. (2010). Neural Network Ensemble-Based Solar Power Generation Short-Term Forecasting. *JACIII*, 3(6), 41–46.
- Drive Database. (n.d.). Retrieved from
<http://www.isi.uu.nl/Research/Databases/DRIVE/>
- Fausett, L. (2014). Fundamentals of Neural Networks. *Igarss 2014*, (1), 1–5.
<http://doi.org/10.1007/s13398-014-0173-7.2>
- Ghonima, M. S., Urquhart, B., Chow, C. W., Shields, J. E., Cazorla, A., & Kleissl,

- J. (2012). Techniques A method for cloud detection and opacity classification based on ground based sky imagery, 2881–2892. <http://doi.org/10.5194/amt-5-2881-2012>
- GOERSS, J. S., Velden, C. S., & HAWKINS, J. D. (1998). The Impact of Multispectral GOES-8 Wind Information on Atlantic Tropical Cyclone Track Forecasts in 1995. Part II: NOGAPS Forecasts. *Monthly Weather Review*, 126, 1219–1227. [http://doi.org/10.1175/1520-0493\(1998\)126<1202:TIOMGW>2.0.CO;2](http://doi.org/10.1175/1520-0493(1998)126<1202:TIOMGW>2.0.CO;2)
- Hammer, A., Heinemann, D., Lorenz, E., & Lückehe, B. (1999). Short-term forecasting of solar radiation: a statistical approach using satellite data. *Solar Energy*, 67(1-3), 139–150. [http://doi.org/10.1016/S0038-092X\(00\)00038-4](http://doi.org/10.1016/S0038-092X(00)00038-4)
- Hersch, P., & Zweibel, K. (1982). Basic photovoltaic principles and methods. *Antimicrobial Agents and Chemotherapy*, 58(12), 7250–7. <http://doi.org/10.2172/5191389>
- Huang, Y., Lu, J., Liu, C., Xu, X., Wang, W., & Zhou, X. (2010). Comparative study of power forecasting methods for PV stations. In *2010 International Conference on Power System Technology* (pp. 1–6). <http://doi.org/10.1109/POWERCON.2010.5666688>
- Kudo, M., Takeuchi, A., Nozaki, Y., Endo, H., & Sumita, J. (2009). Forecasting Electric Power Generation in a Photovoltaic Power System for an Energy Network. *Electrical Engineering in Japan*, 167, 16–23. <http://doi.org/10.1002/ej.20755>
- Leese, J. A., Novak, C. S., & Bruce B. Clark. (1971). An Automated Technique for obtaining Cloud Motion From Geosynchronous Satellite Data Using Cross Correlation. *Journal of Applied Meteorology*, 10, 118–132. [http://doi.org/10.1175/1520-0450\(1972\)011<0752:COATFO>2.0.CO;2](http://doi.org/10.1175/1520-0450(1972)011<0752:COATFO>2.0.CO;2)
- Mathiesen, P., & Kleissl, J. (2011). Evaluation of numerical weather prediction for intra-day solar forecasting in the continental United States. *Solar Energy*, 85(5), 967–977. <http://doi.org/10.1016/j.solener.2011.02.013>
- Pelland, S., Remund, J., Kleissl, J., Oozeki, T., & Brabandere, K. De. (2013). Photovoltaic and Solar Forecasting: State of the Art. *International Energy Agency: Photovoltaic Power Systems Programme, Report IEA PVPS T14*, 1–40. Retrieved from https://www.researchgate.net/publication/259717376_Photovoltaiic_and_

Solar_Forecasting_State_of_the_Art

- Perez, R., Beauharnois, M., Karl Hemker Jr., Kivalov, S., Lorenz, E., Pelland, S., ... Knowe, G. Van. (2011). Evaluation of numerical weather prediction solar irradiance forecasts in the US. *American Solar Energy Society – Proc. ASES Annual Conference*.
- Philipp, K. (1994). Combining Genetic Algorithms and Neural Networks : The Encoding Problem. *Thesis ANN P 67*, (December), 1-67.
- Tao, C., Shanxu, D., & Changsong, C. (2010). Forecasting power output for grid-connected photovoltaic power system without using solar radiation measurement. *2nd IEEE Int. Symposium on Power Electronics for Distributed Generation Systems (PEDG)*, 773-777.
<http://doi.org/10.1109/PEDG.2010.5545754>
- Tranmüller, W., & Steinmaurer, G. (2010). Solar irradiance forecasting, benchmarking of different techniques and applications of energy meteorology. *Eurosun 2010*, 2-3.