



Dissertação

Mestrado em Engenharia Eletrotécnica

***Avaliação económica do impacto da precisão
em previsão de consumos***

Tiago Paulo Ferreira

Leiria, setembro de 2014



Dissertação

Mestrado em Engenharia Eletrotécnica

***Avaliação económica do impacto da precisão
em previsão de consumos***

Tiago Paulo Ferreira

Dissertação de Mestrado realizada sob a orientação do Doutor Luís Miguel Pires Neves, Professor da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria e coorientação do Doutor João Miguel Charrua de Sousa, Professor da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria.

Leiria, *setembro* de 2014

Agradecimentos

Ao Professor Doutor Luís Miguel Pires Neves pelos conhecimentos valiosos, principalmente na parte teórica, e pela criação de metas intermédias desde o início à conclusão da dissertação, sem os quais seria inexequível o seguimento da dissertação ao longo do ano. Com o seu apoio, simpatia e disponibilidade, permitiu-me elaborar a dissertação com maior confiança.

Ao Professor Doutor João Miguel Charrua de Sousa pela preciosa ajuda na parte prática e experimental do trabalho. Agradeço a sua total disponibilidade e apoio prestado ao longo de todo este caminho.

A todos os professores, amigos e colegas do Mestrado em Engenharia Eletrotécnica que me ajudaram na correção de falhas e compreensão de software, todo ele necessário para a elaboração do trabalho.

À Doutora Ana Claro, do OMIClear, por todos os esclarecimentos e informações prestadas relativamente aos preços de mercado futuro e preços de compensação.

À empresa EDP pelos dados históricos de consumos disponibilizados nas subestações da zona de Leiria.

À Base Aérea N°5 de Monte Real pela disponibilização dos dados meteorológicos da zona de Leiria.

A toda a minha família pela compreensão e apoio dados, sem que nada me faltasse para a conclusão da dissertação.

UM MUITO OBRIGADO A TODOS!

Resumo

Com as recentes preocupações em reduzir consumos, emissões poluentes e custos associados à produção de energia elétrica, o papel das empresas operadoras tem-se tornado de extrema importância no ponto de vista da gestão e utilização dos recursos de forma otimizada, para fazer face à crescente procura de energia.

Contudo, para que seja possível diminuir custos operacionais é necessário conhecer previamente o consumo de energia elétrica para uma determinada hora, semana ou mês. Com base nos dados obtidos, será possível colocar em funcionamento as unidades de produção de energia mais económicas, tornando clara a importância da utilização de modelos e técnicas que permitam reduzir os erros associados à previsão dos consumos.

O principal objetivo deste trabalho passa pelo estudo do impacto económico originado pelos erros de previsão, através da aplicação de métodos e técnicas de previsão de consumos. Estas técnicas permitem reduzir o erro associado à diferença entre a energia prevista e a energia que foi efetivamente consumida. Como retorno irá possibilitar uma melhoria das condições de operacionalidade e funcionamento do sistema elétrico. Foram utilizados três métodos, o primeiro baseado em modelos estatísticos clássicos, a regressão linear múltipla, e dois métodos baseados em inteligência artificial, as redes neuronais artificiais e as máquinas de suporte vetorial.

A amostra utilizada é relativa à Subestação de Andrinos, com saída para Pombal, constituída por uma linha de 30kV na zona de Leiria. Os resultados obtidos para uma previsão a uma semana são bastante promissores e apelativos, principalmente ao nível da combinação de métodos de previsão com um erro médio absoluto percentual (MAPE) de 5,95%. Para uma utilização isolada de cada método, os erros MAPE oscilam entre 6,05% e 7,71%. Em termos de avaliação económica, as penalizações variam entre 8667,7€ e 10424€ para cada método isoladamente e de 8532,2€ pela combinação dos vários métodos.

Palavras-chave: *Impacto económico dos erros de previsão, Redes Neuronais, Regressão linear múltipla, Máquinas de Suporte Vetorial*

Abstract

Recent concerns in reducing fuel consumption, emissions and costs associated with electricity production, the role of the operating companies has become extremely important in view of the management and use of resources optimally, to meet the growing demand for energy.

However, it is possible to reduce operating costs it is necessary to know the power consumption for a given hour, week or month. Based on the obtained data can be put into operation units producing more economic power, making clear the importance of using models and techniques that will reduce fuel consumption associated with forecasting errors.

The main objective of this work involves the study of the economic impact caused by errors in forecasting, through the application of methods and techniques for forecasting consumption. These techniques reduce the error associated with the difference between the predicted energy and the energy that was actually consumed. In return will enable improvement of operating conditions and system operation eléctrico. Three methods were used, the first based on classical statistical models, linear regression, and two artificial intelligence based methods, artificial neural networks and support vector machines.

The sample is on the substation Andrinós, with connection to Pombal, consists of a 30kV line in Leiria. The results for a prediction one week are quite promising and appealing, especially in terms of the combination of forecasting methods with a mean absolute percentage error (MAPE) of 5.95%. For a single use of each method, the MAPE errors range between 6.05% and 7.71%. In terms of economic evaluation, the range is from 10,424€ and 8667.7€ for each method alone and 8,532.2€ by the combination of several methods.

Key-Words: *Economic impact of forecast errors, Neural Networks, Multiple Linear Regression, Support Vector Machines*

Índice de Figuras

Figura 1 – Consumo previsto e real (Ortega-Vazquez & Kirschen, 2006).....	4
Figura 2 – Reserva girante requerida e real (Ortega-Vazquez & Kirschen, 2006)	5
Figura 3 – Incremento dos custos de despacho e EENS (Ortega-Vazquez & Kirschen, 2006).....	6
Figura 4 – Representação de um neurónio (http://www.infoescola.com/sistema-nervoso/neuronios/)	9
Figura 5 – Modelo de um neurónio de uma rede neuronal artificial.....	9
Figura 6 – Exemplo de arquitetura do tipo multicamada de uma rede neuronal	12
Figura 7 – Arquitetura do tipo “ <i>feed-forward</i> ”	13
Figura 8 – Hiperplanos possíveis (castanho) e hiperplano ótimo (verde) (Gunn, 1998)	20
Figura 9 – (a) ajuste excessivo, (b) ajuste insuficiente, (c) aproximação adequada	21
Figura 10 – Margem de tolerância ao erro (ϵ) na regressão (Pai & Hong, 2005)	21
Figura 11 – Processo de transformação entre espaço original e espaço dimensional	23
Figura 12 – Estrutura do mercado ibérico Pólo português	27
Figura 13 – Carga prevista e verificada (Fonte: www.ren.pt)	28
Figura 14 – Janela inicial da “Toolbox Neural Network”	33
Figura 15 – Configuração da rede neuronal	34
Figura 16 – Reinicialização dos pesos e desvios	35
Figura 17 – Treino de uma rede neuronal.....	35
Figura 18 – Evolução do erro do conjunto de treino e validação.....	36
Figura 19 – Fluxograma da aplicação das SVM	38
Figura 20 – Dados de consumo com anomalias.....	43
Figura 21 – Dados de consumo corrigidos	44

Figura 22 – Autocorrelação verificada na série temporal considerada	45
Figura 23 – Arquitetura do tipo multivariável (Hora seguinte).....	47
Figura 24 – Arquitetura do tipo multimodelo (Dia seguinte).....	47
Figura 25 – Arquitetura do tipo multimodelo (Semana seguinte).....	48
Figura 26 – Gráfico de distribuição de dados da hora seguinte	48
Figura 27 – Distribuição dos dados de treino e validação da hora seguinte	49
Figura 28 – Gráfico de distribuição de dados do dia seguinte	50
Figura 29 – Distribuição dos dados de treino e validação do dia seguinte	50
Figura 30 – Gráfico de distribuição de dados da semana seguinte	51
Figura 31 – Distribuição dos dados de treino e validação da semana seguinte	52
Figura 32 - Erros absolutos percentuais da previsão da hora seguinte das redes neuronais.....	56
Figura 33 - Erros absolutos percentuais da previsão do dia seguinte das redes neuronais	56
Figura 34 - Erros absolutos percentuais da previsão da semana seguinte das redes neuronais	57
Figura 35 – Erros absolutos percentuais da previsão da hora seguinte de regressão linear	58
Figura 36 - Erros absolutos percentuais da previsão do dia seguinte de regressão linear	58
Figura 37 - Erros absolutos percentuais da previsão da semana seguinte de regressão linear	58
Figura 38 – Metodologia da previsão das máquinas de suporte vetorial	62
Figura 39 – Funcionamento genérico do algoritmo.....	63
Figura 40 - Erros absolutos percentuais da previsão da hora seguinte das máquinas de suporte vetorial	64
Figura 41 - Erros absolutos percentuais da previsão do dia seguinte das máquinas de suporte vetorial	64
Figura 42 - Erros absolutos percentuais da previsão da semana seguinte das máquinas de suporte vetorial	65
Figura 43 - Erros absolutos percentuais da previsão da hora seguinte dos múltiplos métodos de previsão	65
Figura 44 - Erros absolutos percentuais da previsão do dia seguinte dos múltiplos métodos de previsão	66
Figura 45 - Erros absolutos percentuais da previsão da semana seguinte dos múltiplos métodos de previsão	66
Figura 46 – Resultado final obtido que minimiza o erro MAPE	69

Figura 47 – Preços da energia no mercado spot, mercado futuro e de compensação para o período compreendido entre 15/08/2009 a 27/09/2009.....	72
Figura 48 – Penalizações associadas às redes neuronais artificiais.....	75
Figura 49 - Penalizações associadas à regressão linear	75
Figura 50 - Penalizações associadas às máquinas de suporte vetorial	75
Figura 51 – Penalização associada à conjugação de métodos (RNA+RL+SVM)	77

Índice de Tabelas

Tabela 1 – Funções de Kernel típicas (Madeo, Lima, & Peres, 2012)	24
Tabela 2 – Número de neurónios na camada de entrada e saída em função do tipo de previsão .	53
Tabela 3 – Número de neurónios na camada oculta para a hora seguinte	53
Tabela 4 – Número de neurónios na camada oculta para o dia seguinte	54
Tabela 5 – Número de neurónios na camada oculta para a semana seguinte	55
Tabela 6 – Erros MAPE obtidos em função do tipo de previsão	59
Tabela 7 – Erros MAPE obtidos em função do método de previsão para a semana seguinte	69
Tabela 8 – Penalizações do período de teste associadas aos métodos de previsão para a semana seguinte	74
Tabela 9 – Penalizações totais (real > previsto e previsto > real) para os vários métodos.....	76
Tabela 10 – Penalizações totais (real > previsto e previsto > real) para a combinação de métodos	77
Tabela 11 – Relação entre penalização do erro e o custo total da energia	77

Lista de Siglas

ACF	Funções de autocorrelação
PACF	Funções parciais de autocorrelação
ARIMA	Modelo autorregressivo integrado de média móvel
ARMAX	Modelo autorregressivo de média móvel com variáveis exógenas
CCP	Órgão central de compensação de contrapartidas
EENS	Energia esperada não fornecida
ENS	Energia não fornecida
LTLF	Previsão da carga a longo prazo
MAPE	Erro médio absoluto percentual
MAPSTD	Normalização do tipo média nula e variância unitária
MIBEL	Mercado Ibérico de Eletricidade
MSE	Erro médio quadrático
MTLF	Previsão da carga a médio prazo
OMIE	Operador de mercado ibérico de eletricidade, polo espanhol
OMIP	Operador de mercado ibérico de eletricidade, polo português
RL	Regressão Linear
RNA	Redes neuronais artificiais
SA	Simulated Annealing
SR	Reserva Girante
STLF	Previsão da carga a curto prazo

SVM	Support Vector Machines
VOLL	Valor de carga perdida

Índice

1	INTRODUÇÃO	1
1.1	ENQUADRAMENTO GERAL	1
1.2	OBJETIVOS	2
1.3	ORGANIZAÇÃO DO TRABALHO	2
2	REVISÃO DA LITERATURA	3
2.1	IMPORTÂNCIA ECONÓMICA DA PREVISÃO DE CONSUMOS.....	3
2.2	FATORES QUE INFLUENCIAM O CONSUMO	7
2.3	MODELOS DE PREVISÃO DE CONSUMOS	8
2.3.1	<i>Redes Neurais.....</i>	9
2.3.2	<i>Métodos de regressão.....</i>	17
2.3.3	<i>Métodos baseados em máquinas de suporte vetorial</i>	19
2.4	QUANTIFICAÇÃO E VALORIZAÇÃO DOS ERROS DE PREVISÃO	26
3	METODOLOGIA.....	29
3.1	DEFINIÇÃO DO PROBLEMA.....	29
3.2	RECOLHA DE DADOS.....	30
3.3	ANÁLISE PRELIMINAR	30
3.4	SELEÇÃO DOS MODELOS.....	30
3.5	UTILIZAÇÃO E AVALIAÇÃO DE UM MODELO DE PREVISÃO	31
3.5.1	<i>Aplicação de Redes Neurais Artificiais no MATLAB.....</i>	32
3.5.2	<i>Aplicação de Métodos de Regressão Linear no MATLAB</i>	36
3.5.3	<i>Aplicação de Métodos baseados em Máquinas de Suporte Vetorial no MATLAB.....</i>	37
4	ESTUDO DE CASO.....	41
4.1	RECOLHA DE DADOS.....	41
4.2	ANÁLISE PRELIMINAR	42
4.3	APLICAÇÃO DOS MODELOS DE PREVISÃO	44
4.3.1	<i>Redes Neurais.....</i>	45
4.3.2	<i>Regressão linear múltipla.....</i>	57
4.3.3	<i>Máquinas de Suporte Vetorial com seleção de parâmetros pelo Simulated Annealing.....</i>	60
4.3.4	<i>Comparação entre métodos de previsão</i>	65
4.3.5	<i>Combinação de métodos de previsão</i>	67
5	DISCUSSÃO DE RESULTADOS ECONÓMICOS DA PREVISÃO DE CONSUMOS	71
5.1	RECOLHA DE DADOS.....	71
5.2	AVALIAÇÃO ECONÓMICA DO IMPACTO DA ACUIDADE NA PREVISÃO SEMANAL	72
6	CONCLUSÃO	79
7	ANEXOS	83
8	BIBLIOGRAFIA.....	117

1 Introdução

1.1 Enquadramento Geral

Com a liberalização dos mercados de energia elétrica tornou-se possível, a qualquer consumidor no espaço ibérico, adquirir energia elétrica a qualquer produtor ou comercializador que atue em Portugal ou em Espanha. Nesse sentido, surgiu o mercado ibérico de eletricidade MIBEL, como sendo uma iniciativa conjunta dos governos de Portugal e Espanha para a construção de um mercado regional de eletricidade, os quais definem os preços da energia elétrica.

Essa gestão de preços do MIBEL é da competência do operador de mercado ibérico de eletricidade, pólo espanhol, designado de OMIE. As propostas e ofertas de preços por parte dos agentes vão depois a leilão, definindo o preço da eletricidade para o dia e/ou hora seguinte. O pólo português, designado de OMIP, tem como um dos principais objetivos disponibilizar instrumentos eficientes da gestão de risco, i.e., que os contratos já estabelecidos procurem responder às necessidades de cobertura de riscos na variação dos preços.

No mercado spot de eletricidade realizam-se as transações onde participam os intervenientes nas sessões do mercado diário e intradiário, agregando os países da península ibérica do MIBEL. As negociações no mercado diário efetuam-se com base num leilão diário, definindo os preços em todas as horas do dia seguinte, tanto para Portugal como para Espanha. Podem ocorrer diferenças de preços entre os dois países uma vez que, para uma dada hora do dia, as interligações dos países podem estar demasiado sobrecarregadas ou congestionadas, não existindo capacidade suficiente para acautelar todos os trânsitos de energia elétrica. Nestas situações, o preço a pagar pela disponibilidade de energia poderá ser bastante superior ao habitual.

Para além das sessões diárias, existem também sessões no mercado intradiário pela transação de energia elétrica para as várias horas do dia. Tipicamente, recorre-se a este mercado quando não existe capacidade de produção suficiente num país para acautelar picos elevados de consumo e/ou falhas de unidades geradoras. Por essa razão, os preços tendem a ser superiores, uma vez que a energia é transacionada praticamente em simultâneo com o consumo.

1.2 Objetivos

Face a todos os custos inerentes aos erros de previsão da energia elétrica para uma determinada hora, semana ou mês, é indispensável colocar em funcionamento as unidades de produção de energia elétrica mais económicas. Torna-se clara a importância da utilização de modelos e técnicas que permitam reduzir os erros associados à previsão dos consumos a curto, médio ou longo prazo, reduzindo os custos para as empresas operadoras e consumidores finais.

O objetivo deste trabalho passa pelo estudo do impacto económico originado pelos erros de previsão, através da aplicação de métodos e técnicas de previsão de consumos no setor elétrico português, nomeadamente na subestação de Andrinos, situada em Leiria. Serão realizadas previsões a curto e médio prazo, com base em métodos de inteligência artificial como as redes neuronais artificiais e máquinas de suporte vetorial, e métodos estatísticos clássicos como a regressão linear múltipla.

No final será possível agir de acordo com os melhores dados fornecidos, facilitando a tomada de decisão por parte dos agentes envolvidos e permitindo a otimização, redução dos custos e penalizações inerentes aos erros de previsão obtidos.

1.3 Organização do trabalho

O trabalho encontra-se dividido ao longo de seis capítulos. No presente capítulo é apresentada uma breve introdução e os objetivos gerais do trabalho.

No capítulo 2 é apresentada uma revisão literária do tema, incluindo a importância económica na previsão, os fatores que a influenciam, os modelos de previsão de consumos a utilizar e a quantificação em termos monetários dos erros associados à previsão.

A metodologia adotada para a previsão dos consumos é apresentada no capítulo 3, onde é definido o problema a resolver, a recolha dos dados, a sua análise preliminar, a seleção dos modelos a utilizar, a sua implementação e a avaliação de cada modelo.

No capítulo 4 são apresentados os dados e as amostras necessárias para o estudo de caso pelos perfis de consumos, o tratamento dos dados recolhidos e a aplicação dos métodos de previsão.

No capítulo 5 serão apresentados e discutidos os resultados obtidos para cada um dos métodos, bem como a avaliação económica resultante dos erros obtidos em cada caso.

No sexto e último capítulo são apresentadas as conclusões do trabalho e perspectivas futuras.

2 Revisão da literatura

Neste capítulo será apresentada uma revisão literária na área da previsão de consumos, principalmente ao nível do impacto económico que a previsão tem na operação diária do sistema elétrico.

2.1 Importância económica da previsão de consumos

A previsão da carga tem um papel fundamental na segurança e planeamento de um sistema de energia elétrica. Por definição, trata-se da previsão do consumo de energia elétrica ao longo de um determinado período de tempo. Requer uma precisão elevada tanto da previsão da magnitude do consumo como da localização geográfica das cargas.

Por um lado, se a carga efetiva for superior à previsão, poderá não existir capacidade disponível, incluindo reserva girante¹ (SR) suficiente, para fazer face ao consumo. Nestes casos, através das interligações com os outros países, poder-se-á importar energia elétrica, mas como esta energia é negociada quase em simultâneo com o fornecimento, poderá resultar em custos bastantes avultados. Em alternativa poderão existir contratos de potência interruptível em que os consumidores aceitam desligar cargas em caso de necessidade, sendo compensados por essa disponibilidade.

Por outro lado, se num determinado período, a carga for inferior à previsão, alocaram-se mais unidades de geração (UC) para além das necessárias, sem que houvesse necessidade para tal, o que reduz a eficiência global do sistema. Em algumas barragens, para existir queda de água disponível nas horas de ponta, poderá ter existido necessidade de efetuar a bombagem da água durante os períodos de vazio. Algumas unidades de geração podem ter sido arrancadas sem necessidade, resultando em custos elevados e desnecessários.

Na Figura 1 encontra-se o consumo previsto e atual ao longo de um dia. É possível verificar o erro nas horas de vazio, principalmente das 4 às 8 horas, resultante do excesso de consumo face ao previsto, e o erro nas horas cheias, nomeadamente das 16 às 20 horas, originado pelo défice de previsão.

¹ A reserva girante, do inglês “spinning reserve”, corresponde à diferença entre a potência ativa que é possível solicitar a um grupo e a potência ativa que esse grupo está a fornecer.

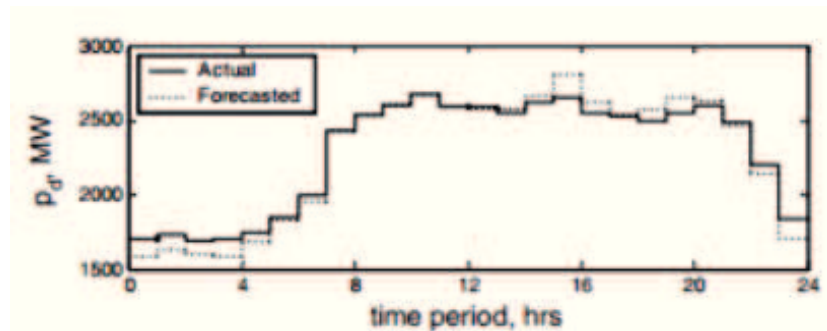


Figura 1 – Consumo previsto e real (Ortega-Vazquez & Kirschen, 2006)

Ortega-Vazquez & Kirschen, 2006 analisaram o impacto económico do erro na previsão da carga, considerando a SR e o valor esperado da energia não fornecida² (EENS). Para situações em que existam pequenas variações no consumo, as unidades geradoras (UC) estão preparadas para fazer face a essas pequenas oscilações, pelo aumento ou diminuição da produção com base na sua SR disponível.

A SR é fundamental para proteger o sistema contra eventos imprevistos, tais como aumentos repentinos do consumo, perdas nos geradores ou falhas nas linhas de transmissão. A sua alocação influencia a decisão e o funcionamento das unidades geradoras, principalmente devido ao custo que têm associado, que idealmente deve ser mínimo. A SR pode ser ajustada nas unidades geradoras, mantendo os arranques, as paragens e os custos operacionais no mínimo. Por essa razão, a SR tem de ser considerada nos cálculos de despacho económico juntamente com os custos de produção.

Quando o sistema requer um aumento súbito de SR, o custo de afetação das unidades geradoras aumenta pelo facto de as unidades não serem usadas da forma mais económica até que sejam cumpridos os requisitos mínimos. Por outro lado, se existir um grande aumento de SR, o custo da energia não fornecida diminui, pois passa a existir capacidade de produção excessiva. Deste modo, se existir uma subestimação da carga, o risco do sistema aumenta devido há possibilidade de não ter SR disponível. Caso a carga seja estimada em excesso, o operador do sistema paga os custos associados ao excesso de alocação de SR e de não operar de forma otimizada.

Na Figura 2 encontra-se um gráfico com a SR requerida e atual do sistema. Destaca-se a diminuição do fornecimento SR face à requerida no período noturno, que poderá originar interrupções em casos de aumentos repentinos do consumo.

² O valor esperado da energia não fornecida (EENS) corresponde ao consumo que seria verificado caso não ocorressem falhas nas unidades geradoras.

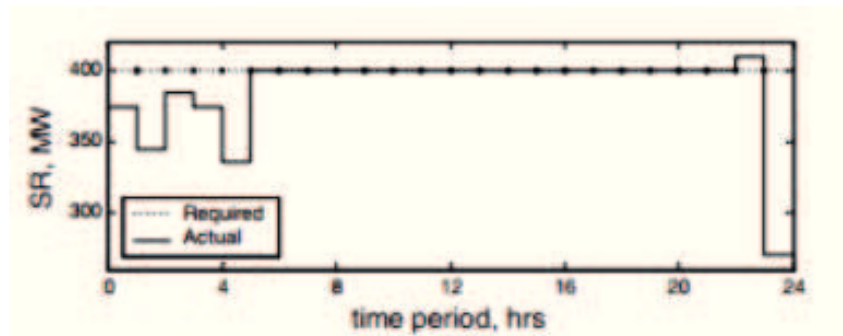


Figura 2 – Reserva girante requerida e real (Ortega-Vazquez & Kirschen, 2006)

Os custos associados a incidentes originados por interrupções no fornecimento de energia, são determinados pelo produto da energia não fornecida (ENS) por um coeficiente designado de valor de carga perdida (VOLL). O VOLL representa o valor médio que os consumidores atribuem à perda acidental de 1MWh de energia. Geralmente este valor é determinado com base em inquéritos aos consumidores.

Determinar antecipadamente a energia que não pode ser fornecida devido a uma interrupção em particular, é um processo bastante difícil porque essa quantidade de energia depende de várias circunstâncias. Contudo, Billinton & N. Allan, 1984 utilizaram uma técnica padrão para calcular um valor esperado de energia não fornecida (EENS). Esta técnica tem em conta as unidades geradoras ligadas ao sistema elétrico, a probabilidade de interrupção forçada de cada unidade, a quantidade de SR que estas unidades podem proporcionar e a carga a ser fornecida. Assim, o custo EENS é dado como:

$$EENS = ENS \times VOLL \quad (1)$$

O custo EENS estará dependente da quantidade de SR fornecida ao sistema. Se existirem grandes quantidades de SR fornecida, a probabilidade de não satisfazer o fornecimento necessário é reduzida, diminuindo o custo EENS. Por outro lado, se a SR é pequena e uma ou mais unidades geradoras são interrompidas, as restantes unidades sincronizadas com a rede podem não ter capacidade suficiente para repor a carga, aumentando o custo EENS.

Assim, ao reduzir o fornecimento de SR é possível diminuir os custos de despacho, mas o custo EENS aumenta significativamente dado que as unidades geradoras ficam mais sobrecarregadas, aumentando a probabilidade de não satisfazer a carga em caso de interrupção. Por outro lado, nos períodos em que a carga é estimada por excesso, os custos de despacho aumentam devido a uma maior geração de energia elétrica do que aquela que seria necessária, originando um custo marginal superior.

Para satisfazer os consumos e os requisitos de SR poderão existir situações em que é necessário efetuar um novo despacho para as unidades geradoras. Esta situação ocorre quando a capacidade atual das unidades de geração é insuficiente para fazer face ao consumo, como é possível observar-se na Figura 3.

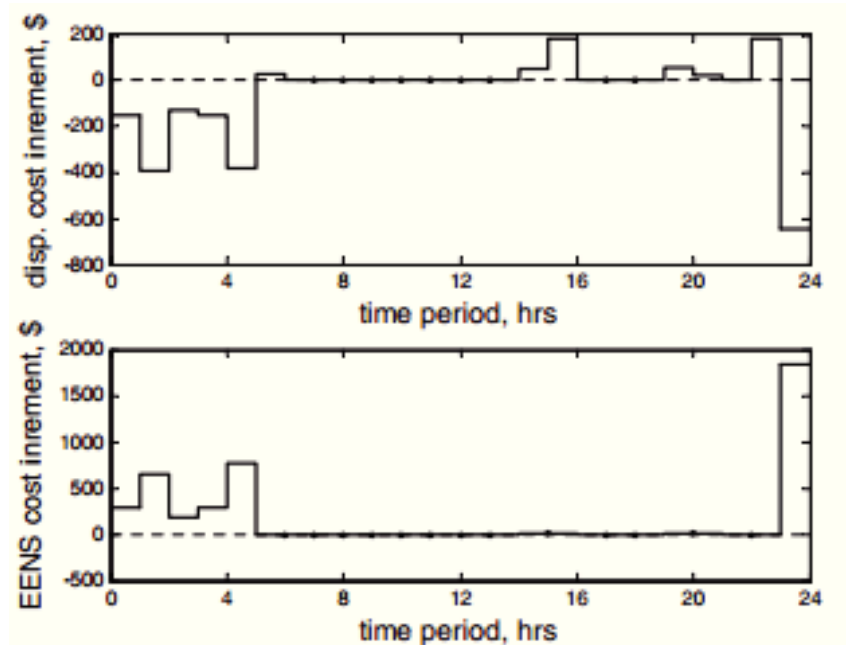


Figura 3 – Incremento dos custos de despacho e EENS (Ortega-Vazquez & Kirschen, 2006)

De acordo com Gross & Galiana, 1987, a previsão da carga pode ser efetuada de hora em hora, diariamente, semanalmente ou mensalmente.

Srinivasan & Lee, 1995 classificaram a previsão da carga em termos de duração do planeamento futuro, desde um dia para uma previsão a curto prazo (STLF), um ano para uma previsão a médio prazo (MTLF) e dez anos como uma previsão a longo prazo (LTLF).

A capacidade de previsão da carga constitui um grande potencial de poupança para as empresas. Segundo Bunn & Farmer, 1985 estas poupanças são realizadas quando as informações da carga são utilizadas nas operações de controlo e de decisão sobre o despacho das unidades geradoras.

2.2 Fatores que influenciam o consumo

A previsão da carga é um processo altamente complexo e trabalhoso, principalmente devido à natureza aleatória da mesma. Devido a diversos fatores, não é possível prevê-la com exatidão de 100%, o que limita a eficiência do sistema elétrico. Esses fatores podem ser classificados como fatores económicos, fatores sazonais e fatores ambientais, tais como as condições meteorológicas, entre outros.

Não sendo possível prever a carga com exatidão de 100%, existem diversos métodos e técnicas que permitem atenuar o erro. A informação de carga obtida por estas técnicas é depois utilizada para a coordenação e escalonamento das unidades geradoras, colocando em funcionamento as unidades mais económicas.

Os consumos industriais estão essencialmente associados aos níveis de produção das empresas. Este facto torna a carga bastante constante, pelo que seria expectável que simplificasse a previsão da mesma em função dos níveis de produção. Contudo, do ponto de vista do operador da rede, as unidades industriais acrescentam incertezas à previsão. O problema está sobretudo na ocorrência de eventos inesperados, como avarias e interrupções ou greves, que originam variações intempestivas no consumo.

No caso particular dos consumidores finais de energia elétrica, os fatores para determinar os seus consumos ainda se tornam mais difíceis de definir. A principal dificuldade reside no facto de cada consumidor decidir individualmente a forma de satisfazer as suas necessidades individuais. Geralmente estão associados fatores ambientais e comportamentais como forma de justificar estes consumos particulares, por exemplo, feriados, épocas festivas ou grandes eventos. (Gross & Galiana, 1987)

Sendo uma grande parte do consumo associado aos utilizadores domésticos, a melhor forma de prever os seus consumos é estimar a carga de acordo com os diferentes tipos de utilizadores, diminuindo o número de fatores que podem ser levados em conta para cada consumidor.

De acordo com Gross & Galiana, 1987, os fatores mais relevantes são diferentes a curto prazo e a longo prazo. A curto prazo, estão associadas as condições meteorológicas, que podem originar grandes flutuações no consumo de energia elétrica. Fatores como a temperatura e humidade relativa também influenciam o consumo (Chow & Leung, 1996). A longo prazo, estão associadas as condições económicas e demográficas, geralmente ligadas à evolução da procura da eletricidade, como a gestão da procura em zonas rurais ou urbanas, crescimento industrial e alterações de tarifários. Os fatores temporais também têm um papel essencial na previsão da carga, principalmente devido a feriados legais e épocas religiosas.

Para além de todos os fatores classificados poderão existir ainda fatores aleatórios, que isoladamente podem ter pouco significado mas, que em grande escala poderão originar complicações. Exemplos deste tipo de situações podem existir com grandes eventos sociais ou grande afluência de telespetadores televisivos numa determinada situação.

Todavia, apenas serão abordadas situações a curto e médio prazo, sendo as ocorrências que apresentam os maiores problemas e discrepâncias, bem como maiores desafios às novas tendências, funcionalidades e descobertas neste domínio de pesquisa.

2.3 Modelos de previsão de consumos

Na previsão do consumo de energia elétrica existem inúmeras metodologias e técnicas que podem ser utilizadas para prever o consumo, dependendo da aplicação que se pretende, podendo ser a curto, médio e longo prazo. As previsões a curto prazo são necessárias por motivos operacionais quando nos encontramos próximos de uma hora específica. A médio prazo é necessária para definir as necessidades futuras. As previsões a longo prazo estão associadas a planeamento estratégico, como instalações e aglomerados urbanos a serem desenvolvidos futuramente. Para isso, recorre-se principalmente a métodos matemáticos e computacionais, como forma de obter melhores resultados e diminuição dos erros associados.

Moghram & Rahman, 1989, classificaram as técnicas de previsão da carga que refletem as tendências das pesquisas em cinco categorias:

1. Regressão linear múltipla;
2. Suavização exponencial;
3. Previsão de carga adaptativa;
4. Série temporal estocástica;
5. Sistemas no campo da inteligência artificial.

Nas secções seguintes serão abordados os vários métodos de previsão selecionados, cuja base científica já se encontra bastante aprofundada.

2.3.1 Redes Neurais

As redes neuronais são ferramentas matemáticas inspiradas na forma como o cérebro humano processa as informações. Os neurónios do cérebro humano são essencialmente constituídos pelo corpo celular, dendritos e axónio (Figura 4). São responsáveis pela circulação dos impulsos do sistema nervoso, onde procuram dar resposta aos estímulos, como a luz e o calor, transmitindo as informações ao cérebro humano para que este se adapte às condicionantes.

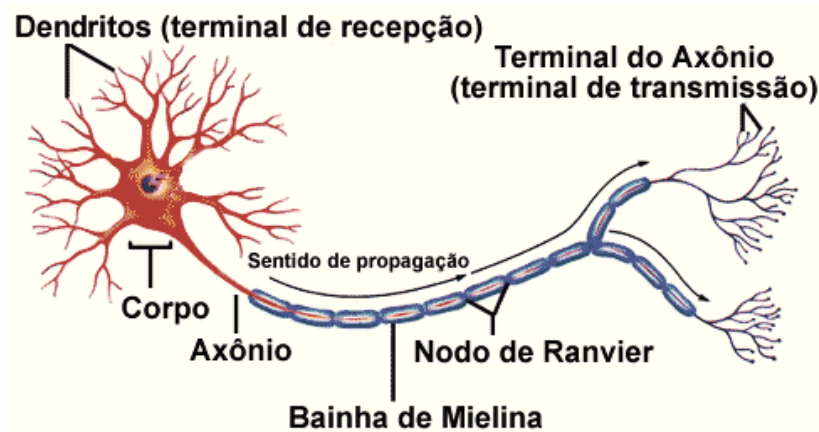


Figura 4 – Representação de um neurónio (<http://www.infoescola.com/sistema-nervoso/neuronios/>)

De forma análoga aos neurónios biológicos, os neurónios artificiais recebem informações, neste caso numéricas, através de um número de nós de entrada. Internamente processam toda a informação, originando uma resposta na saída. Geralmente o processamento é efetuado com base em duas etapas. Na primeira etapa, os valores das entradas são combinados de forma linear sendo o resultado utilizado como argumento de uma função de ativação não linear. Essa combinação linear utiliza os pesos atribuídos a cada ligação e um termo de polarização/desvio constante, representados na Figura 5 como “ w_{ik} ” e “ b_k ” respetivamente.

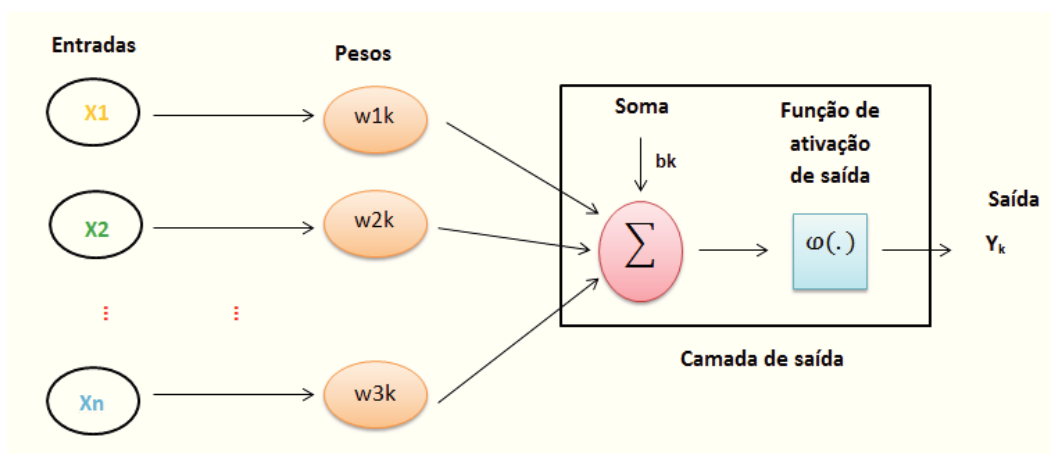


Figura 5 – Modelo de um neurónio de uma rede neuronal artificial

O valor da saída (y_k) é dado por:

$$y_k = \varphi \left(\sum_{i=1}^n w_{ik} x_i + b_k \right) \quad (2)$$

Onde,

x_i são os nós de entrada da rede;

w_{ik} são os pesos atribuídos a cada ligação;

b_k são os termos de polarização/desvios;

$\varphi(\cdot)$ é a função de ativação;

y_k é a saída da rede neuronal.


O valor obtido pelo somador é submetido a uma função de ativação que limita o valor superiormente e inferiormente. Estes valores são limitados a intervalos de $[0,1]$ ou $[-1,1]$.

As redes neurais têm sido muito utilizadas para a previsão de consumos em vários trabalhos científicos, podendo citar a título de exemplo os trabalhos de Hippert, Pedreira, & Souza, 2001 e Raza & Baharudin, 2012.


Funções de ativação

Nas camadas ocultas e na camada terminal, a saída é definida com base numa função de ativação que determina o estado de ativação de cada neurónio, com base na relação de linearidade/não linearidade entre entradas e saídas. Esta função tem um papel importante na convergência dos algoritmos utilizados e deve ser selecionada com base na natureza dos dados de entrada. As funções de ativação mais utilizadas são:


1. **Linear**, onde $f(x) = x$



2. **Tansig**, onde $f(x) = 2 \times \frac{1}{1+e^{-x}} - 1$



3. **Logsig**, onde $f(x) = \frac{1}{1+e^{-x}}$



sendo x a soma dos sinais de entrada ponderados pelo respetivo peso w_{ik} .

Arquiteturas das redes neuronais

As redes neuronais distinguem-se de acordo com o número de camadas que detêm, por redes de camada única e redes do tipo multicamada. As redes de camada única são constituídas pelos neurónios de entrada e saída, não sendo definida nenhuma camada oculta. São designadas de camadas ocultas, as camadas que se encontram entre os nós de entrada e de saída. As redes do tipo multicamada possuem pelo menos uma camada intermédia ou oculta, situada entre a camada de entrada e a camada de saída. Em cada uma das camadas os neurónios podem partilhar as mesmas entradas, sem que estejam ligados entre si.

Na Figura 6 encontra-se uma arquitetura do tipo multicamada constituída por quatro nós de entrada, três neurónios na camada oculta e um neurónio na camada de saída.

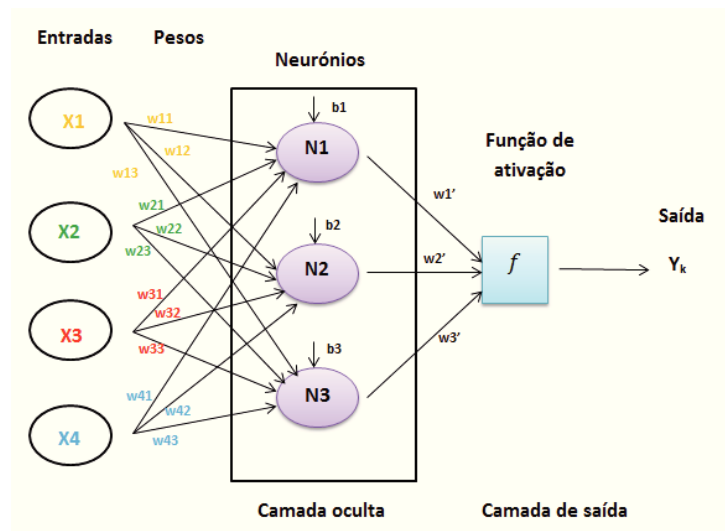


Figura 6 – Exemplo de arquitetura do tipo multicamada de uma rede neuronal

Dependendo da natureza da previsão que se está a efetuar, o número de neurónios na camada de entrada e de saída pode ser variável. Na camada de entrada, o número de neurónios depende do número de entradas que se pretende para o modelo, enquanto o número dos nós de saídas depende do tipo de previsão, podendo ser dividido em diferentes categorias:

- Previsão do tipo camada única com uma saída, geralmente utilizada para uma previsão para a hora seguinte,
- Previsão do tipo multivariável, onde são considerados múltiplos nós de saída, por exemplo para prever os consumos para as diversas horas do dia em vinte e quatro saídas,
- Previsão do tipo multimodelo, utilizando várias redes neuronais em paralelo, por exemplo representando uma hora específica do dia seguinte, evitando assim o uso de redes com demasiados parâmetros.

As redes neuronais onde as saídas de uma camada são utilizadas como entradas da camada seguinte são designadas de “*feed-forward*”, i.e. propagação em frente. Na Figura 7 é possível observar outro exemplo deste tipo de arquitetura com uma camada oculta e uma camada de saída, juntamente com quatro nós de entrada e dois neurónios de saída. Os parâmetros desta rede neuronal são a matriz dos pesos de entrada w_{ij} (que contém os pesos $w_{i,j}$ que interligam a entrada i ao neurónio j), a matriz dos pesos de saída u_{ij} e o vetor de polarização Θ .

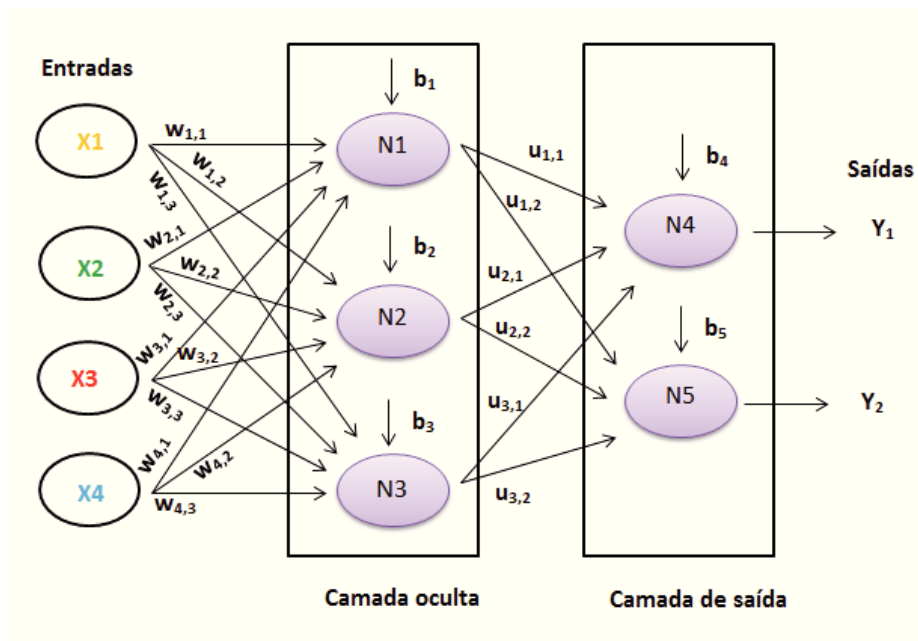


Figura 7 – Arquitetura do tipo “feed-forward”

Torna-se evidente que à medida que o número de entradas e neurónios aumenta, a rede neuronal fica mais complexa com mais parâmetros e pesos a determinar. Não existindo uma regra concreta sobre qual o melhor número de neurónios e camadas a utilizar, é necessário estabelecer um número adequado que permita à rede ter alguma flexibilidade de manipulação dos dados sem grandes tempos de processamento, aquando do processo de treino efetivo. Uma das medidas mais usuais passa pelo teste de diferentes arquiteturas de forma a poder inferir qual a que se adequa melhor à previsão em causa. Assim, torna-se fundamental estabelecer um compromisso entre a capacidade da rede apreender todos os parâmetros necessários no conjunto de treino e a capacidade de resposta do sistema perante os novos dados apresentados.

Para uma utilização e aplicação cuidada das redes neuronais artificiais, Hippert et al., 2001 definiram as tarefas de projeto de uma rede neuronal em quatro categorias:

- A. Pré-processamento dos dados;
- B. Conceção da rede neuronal;
- C. Implementação da rede neuronal;
- D. Validação.

Esta subdivisão em etapas do desenvolvimento das redes neuronais é de alguma forma artificial, uma vez que estas etapas na prática tendem a sobrepor-se. Contudo, uma organização e desenvolvimento cuidadoso devem procurar segui-las o mais possível.

A. Pré-processamento dos dados

Antes de serem definidos os dados de entrada para uma rede neuronal, é necessário efetuar o seu pré-processamento, seja pelas suas grandes dimensões que originaria um crescimento exponencial na complexidade, ou até mesmo para eliminar alguns dados atípicos ou “*outliers*” tais como valores inesperados ou em falta. Todas estas situações implicariam resultados imprevisíveis, dado que uma rede neuronal é bastante sensível a dados defeituosos.

Para casos em que o número de dados seja elevado, existem algumas técnicas que permitem acelerar todo este processo, seja através da filtragem das irregularidades com filtros de Kalman (Connor, 1996) ou através de processos heurísticos para normalizar os dados (Kirtzis, Zoumas, Theocharis, Bakirtzis, & Petridis, 1997; Piras, Germond, Buchenel, Imhof, & Jaccard, 1996).

Existindo diferenças significativas entre perfis de dias da semana e perfis dos fins de semana, será útil que a previsão tenha a capacidade de distinguir entre dias da semana e fim de semana, por forma a utilizar os dados corretos. Os períodos de férias são um problema especial, podendo ser aproximados a fins de semana ou agrupados numa classe específica, determinando uma heurística aproximada para essas situações. O segundo fator mais importante é a meteorologia, dado que os dias podem ser classificados também de acordo com o estado do tempo, influenciando os consumos de energia elétrica. Estes podem ser acautelados e/ou previstos com medidas estatísticas (Drezga & Rahman, 1998) e métodos “*fuzzy*” (Daneshdoost, Lotfalian, Bumroonggit, & Ngoy, 1998).

B. Conceção da rede neuronal

Geralmente, o primeiro passo a tomar é selecionar a arquitetura correta para a rede neuronal. Muitos tipos de arquiteturas já foram utilizadas e testadas nas redes neuronais, com as principais a centrarem-se nas redes do tipo “*feed-forward propagation*”. Este tipo de arquitetura surgiu na sequência do trabalho de Rumelhart, Hinton, & Williams, 1986, o qual permitiu resolver o problema da adaptação de pesos na camada oculta da rede e lidar com funções de ativação não-lineares, sendo esta uma das grandes potencialidades das redes neuronais artificiais atualmente. O problema da adaptação de pesos residia no facto dos pesos das ligações na arquitetura tradicional “*feed-forward propagation*” não serem atualizados ao longo do tempo, não permitindo minimizar as diferenças entre os valores das saídas reais e das saídas desejadas.

Depois de escolhida o tipo de arquitetura, deve-se decidir o número de nós de entrada, o número de camadas ocultas, o número de neurónios por camada e o tipo de funções de ativação. Zhang, Eddy Patuwo, & Y. Hu, 1998, demonstraram que, para o número de camadas ocultas, a utilização de uma camada é suficiente para aproximar qualquer função contínua. Quanto às funções de ativação, estas devem ser diferenciáveis e não decrescentes. A maioria dos autores utilizaram funções tangente hiperbólicas, não sendo claro se a sua utilização teve efeito na precisão das previsões.

O número de neurónios de saída depende essencialmente da previsão que se pretende efetuar. Para os casos da previsão para a hora seguinte, é comum utilizar-se processos baseados em redes de camada única. As previsões do tipo multivariável utilizam vinte e quatro neurónios de saída, onde cada neurónio corresponde a uma hora específica do dia seguinte. Para previsões do tipo multimodelo são utilizadas vinte e quatro redes neuronais em paralelo, cada uma das redes com um neurónio de saída, onde cada neurónio corresponde a uma hora a prever no dia seguinte.

Depois de selecionado o número de neurónios de saída e o número de camadas necessárias, é necessário determinar o número de nós de entradas. Existem muitos fundamentos teóricos para a sua determinação. Contudo, se existir um bom conhecimento a priori sobre o comportamento do sistema em estudo, bem como os fatores que influenciam a saída, a sua seleção torna-se intuitiva de acordo com a tarefa de previsão requerida.

Alguns autores tentaram adaptar a metodologia de “Jenkins³” na montagem de modelos autorregressivos integrados de média móvel (ARIMA), para permitir verificar quais as variáveis que teriam maior influência na saída. Para isso, utilizaram funções de autocorrelação (ACF) e funções parciais de autocorrelação (PACF) (Chen, Yu, & Moghaddamjo, 1992; C. N. Lu, Wu, & Vemuri, 1993).

No entanto, ao aplicar esta metodologia corre-se o risco de desprezar variáveis que não mostraram correlação linear significativa com a carga, mas que poderiam ser igualmente importantes. Drezga & Rahman, 1998, utilizaram um sistema embebido de desfasamento no espaço que representa o sistema com uma variável desfasada, capaz de ajudar a determinar quais os valores em atraso das séries de entrada que devem ser utilizados.

³ A metodologia de “Jenkins” refere-se a um método sistemático de identificação, montagem, verificação e utilização integrada de modelos auto regressivos integrados de média móvel (ARIMA) de séries temporais. Mais informações podem ser consultadas em <http://www.mathworks.com/help/econ/box-jenkins-methodology.html>

Nos países onde existem grandes variações de temperaturas, as previsões de consumos tornam-se mais difíceis, uma vez que os consumos aumentam nos dias mais frios. Isto deve-se principalmente ao uso de ar condicionado, aquecimento de água e utilização de aquecedores elétricos. A função que relaciona a temperatura do ar com a carga é claramente não-linear, sendo esta uma das principais motivações para o uso das redes neuronais uma vez que permitem lidar com este tipo de problemas. Índices como a humidade e velocidade do vento também podem originar alguma sensação de desconforto térmico, podendo levar à utilização de equipamentos elétricos. Porém, alguns autores concluíram que a variável mais significativa e que tem maior impacto na previsão de consumos é a temperatura do ar (Bakirtzis, Petridis, Kiartzis, Alexiadis, & Maissis, 1996; Kiartzis et al., 1997).

Determinar o número de neurónios na camada oculta é um processo mais difícil. Existe alguma base teórica para o auxílio na decisão a tomar, havendo muito poucas heurísticas que tenham sido utilizadas com sucesso (Zhang et al., 1998). A sua determinação torna-se num processo semelhante à escolha do número de harmónicos num modelo de Fourier para a aproximação de uma função. Se os harmónicos forem em pequena quantidade, o modelo não será suficientemente flexível para modelar todos os dados, caso contrário, o modelo fica sobrecarregado. Na maioria dos casos a determinação do número correto acaba por se consumir numa escolha baseada em tentativa em erro, realizando várias simulações e escolhendo aquela que apresente melhor desempenho.

C. Implementação da rede neuronal

Após a conceção da rede e determinação dos dados procede-se ao treino da rede neuronal, determinando os parâmetros da respetiva rede. Durante este processo são atribuídos valores aos pesos das ligações e aos desvios, onde à medida que o processo decorre vão sendo ajustados de forma a minimizar os erros entre os valores reais e os valores estimados.

Existem um conjunto de regras de aprendizagem, distinguindo-se aprendizagem com supervisão e aprendizagem sem supervisão. Uma vez que serão utilizados dados de um conjunto de entradas e saídas conhecidos, a escolha recai sobre o tipo de aprendizagem supervisionada.

Tipicamente utiliza-se o modelo “feed-forward propagation” de aprendizagem supervisionada, onde são definidos os critérios de paragem para a rede.

Para o modelo “feed-forward propagation”, o processo de treino obedece aos seguintes critérios de paragem:

- Atingir do número máximo de épocas (iterações);
- Excedido o tempo máximo;
- O erro da previsão for igual ou inferior ao desejado;
- O gradiente for menor do que o valor definido;
- A variável de adaptação ou convergência do algoritmo exceder o seu valor máximo;
- O processo de validação cruzada atinja o valor estabelecido.

Geralmente, os processos de paragem mais verificados estão associados ao número máximo de épocas (iterações) ou pelo processo de validação cruzada. Este processo é bastante útil permitindo averiguar se o processo de treino se encontra em fase de perda de generalização. Geralmente este erro para dados de validação diminui numa fase inicial. À medida que se perde capacidade de generalização o erro começa a subir, guardando os dados relativos à última iteração. Após o incremento ininterrupto do erro de validação durante as iterações seguintes, o processo de treino termina.

D. Validação

A fase final é denominada de validação cruzada, onde é definido um conjunto de dados como forma de validar o comportamento da rede. Desta forma, a rede neuronal simulada deve ter adquirido o conhecimento necessário para que esta seja capaz de encontrar novas soluções para dados de entrada que lhe sejam desconhecidos. Geralmente, os dados utilizados para validação estão entre 10% e 25% do conjunto total de amostras disponíveis.

2.3.2 Métodos de regressão

Os métodos de regressão são técnicas de análise da relação entre uma variável dependente contínua (y) e uma ou mais variáveis independentes ($x_1, x_2, x_3, \dots, x_k$). A regressão é uma das técnicas estatísticas mais utilizadas que trata os dados de uma forma linear. O principal objetivo desta análise passa por encontrar uma função que permita descrever essa relação entre variáveis, onde o valor da variável dependente é estimado com base nas variáveis independentes e nos parâmetros de regressão associados a cada variável.

Nos métodos de regressão linear múltipla, o valor da carga é determinado com base em variáveis independentes, como o estado do tempo e outras variáveis que influenciam o consumo.

Segundo Amral, Ozveren, & King, 2007, o modelo de regressão linear múltipla que descreve a relação entre a variável dependente (y) e as variáveis independentes ($x_1, x_2, x_3, \dots, x_k$), é expresso por:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3)$$

Onde,

y é o valor da carga a prever;

x_i são os fatores afetos ao consumo, fatores meteorológicos, temperatura, vento, etc;

β_i são os parâmetros de regressão em relação a x_i ;

ε é o termo associado ao erro.

Segundo Murteira, Ribeiro, Silva, & Pimenta, 2007, o método mais utilizado para determinar os parâmetros de regressão, passa por minimizar a soma dos quadrados dos desvios, com base nos dados de treino. Dado que a soma dos erros elevado ao quadrado é função dos coeficientes de regressão, extrai-se a seguinte equação:

$$\sum_{i=1}^k \varepsilon_k^2 = \sum_{j=1}^k (y_j - \beta_0 - \beta_j x_j)^2 \quad (4)$$

Depois de encontrados todos os parâmetros de regressão e a respetiva matriz, são efetuados os testes aos novos dados de entrada, estimando o valor da carga elétrica para uma determinada hora, dia ou semana seguinte. Para esse processo é utilizada a seguinte expressão:

$$Yt_{[m \times n]} = Xt_{[m \times k]} \times \beta_{[k \times n]} \quad (5)$$

Onde,

$Yt_{[m \times n]}$ corresponde à matriz dos dados de teste a obter na saída;

$Xt_{[m \times k]}$ corresponde à matriz dos dados de teste a simular;

$\beta_{[k \times n]}$ corresponde à matriz que contém os coeficientes de regressão determinados;

2.3.3 Métodos baseados em máquinas de suporte vetorial

As máquinas de suporte vetorial (SVM) foram desenvolvidas por Vapnik⁴ e seus colegas (Cortes & Vapnik, 1995). De forma análoga às redes neurais artificiais e à regressão linear múltipla, surgem como um conjunto de métodos de aprendizagem supervisionada, com capacidade de se adaptar a entradas não conhecidas para prever as futuras saídas. Existe também a possibilidade de se recorrer a SVM para aprendizagem não supervisionada, quando aplicadas para classificação.

Na aprendizagem supervisionada é fornecido ao modelo um conjunto de entradas e saídas conhecidas a partir das quais é possível extrair o conhecimento necessário para estimar corretamente as saídas correspondentes a futuros dados de entrada.

Na aprendizagem não supervisionada é o modelo que infere as diferenças entre dados, por exemplo por determinação de agrupamentos, não existindo presença de agentes externos. Este tipo de aprendizagem é utilizada quando existem padrões e/ou tendências para determinados dados de entrada complexos (Gunn, 1998).

As SVM têm sido aplicadas com sucesso para resolver problemas de regressão não linear e problemas de séries temporais. Contudo, o uso deste método ainda é escasso, principalmente devido às poucas experiências desenvolvidas até ao momento, embora seja uma nova técnica promissora de classificação e regressão com enorme potencial.

Em comparação com as redes neurais, que são baseadas no princípio empírico da minimização do risco, as SVM implementam o princípio estruturado da minimização do erro, permitindo obter uma solução ótima global para um conjunto de dados e não para uma situação específica. Uma das suas grandes vantagens passa pela definição de uma tolerância máxima para o erro de generalização, ao contrário das redes neurais que minimizam o erro para o conjunto de dados treinados. O processo de treino das SVM é definido através de uma função de programação quadrática, associada a restrições lineares, o que permite garantir uma solução única e globalmente ótima (Abbas & Arif, 2006; Guo, Niu, & Chen, 2006).

⁴ Vladimir Naumovich Vapnik é um matemático russo, sendo um dos principais membros no desenvolvimento das máquinas de suporte vetorial

A. Problema de Classificação

O processo de classificação das SVM recebe um conjunto de dados e para cada entrada, prevê a classe a que pertence. Obtidos os dados de treino, cada ponto fica atribuído a uma de duas categorias e o algoritmo de treino determina um novo modelo, atribuindo novos exemplos à correspondente categoria.

O objetivo é separar as duas classes através de uma função, estabelecendo uma classificação com boa capacidade de generalização. Considerando o exemplo da Figura 8, é possível verificar a existência de muitas funções lineares possíveis que permitem separar os dados (linhas de cor castanho). Contudo, existe apenas uma possibilidade que maximiza a margem (linha de cor verde), i.e. maximiza a distância entre a função e o ponto mais próximo entre dados. Gunn, 1998, afirma que este classificador linear considera-se como o hiperplano ótimo ou hiperplano ideal, dado que esta função terá maior capacidade de generalização para os novos dados, face a outras possíveis opções, permitindo uma maior tolerância entre os diferentes subconjuntos de dados ilustrados.

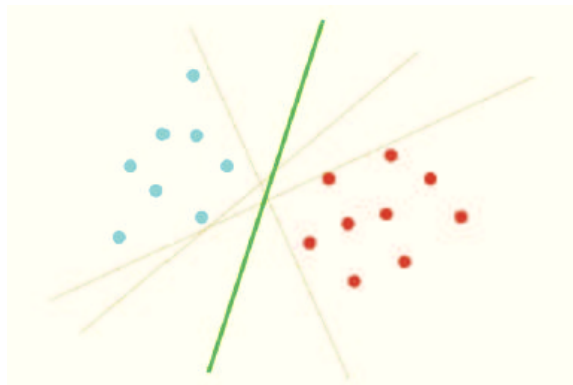


Figura 8 – Hiperplanos possíveis (castanho) e hiperplano ótimo (verde) (Gunn, 1998)

B. Problema de Regressão

O processo de regressão das SVM surge como a etapa seguinte ao processo de classificação dos dados, como forma de prever um novo conjunto de dados com base nos dados de treino aplicados. Este processo tem como grande vantagem a minimização de uma tolerância máxima para o erro de generalização (\mathcal{E}), ao contrário das redes neuronais que atuam com base no princípio da minimização do erro associado aos dados de treino (Pai & Hong, 2005).

Todavia, é necessário impor restrições ao problema para que exista boa capacidade de generalização para os novos dados. Mesmo que uma função tenha uma grande capacidade de generalizar os novos dados, não existe a garantia de que ela seja capaz de se comportar de igual forma aos novos dados de entrada. A minimização do erro no processo de treino não implica uma minimização do erro no processo de teste.

Num problema de regressão podem ocorrer fenómenos de ajuste excessivo (“*overfitting*”), onde a complexidade da função obtida é superior à do problema em causa. Por outro lado, existe o fenómeno de ajuste insuficiente (“*underfitting*”), onde a complexidade da função obtida é inferior à necessidade do problema. Torna-se evidente a necessidade de estabelecer um compromisso entre a precisão dos resultados e a flexibilidade do modelo. A Figura 9 demonstra a ocorrência de todos estes fenómenos, onde a azul encontram-se os dados de treino e a vermelho os dados de teste.




Figura 9 – (a) ajuste excessivo, (b) ajuste insuficiente, (c) aproximação adequada

A margem de tolerância ε deve ser estabelecida *a priori*, de acordo com o grau de precisão pretendido. Na Figura 10 encontra-se exemplificado o conceito referido anteriormente.

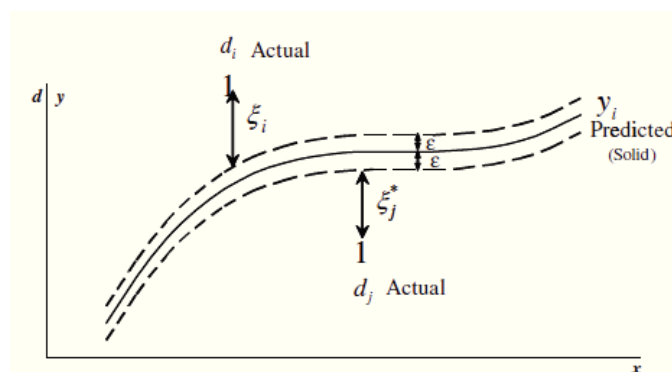


Figura 10 – Margem de tolerância ao erro (ε) na regressão (Pai & Hong, 2005)

Um problema de regressão linear, pode ser considerado por uma função f dado por:

$$f(x) = \sum_{i=1}^n (w_i \times x_i) + b \quad (6)$$

Onde,

w_i é o vetor dos coeficientes associados a cada variável;

x_i é o vetor de variáveis independentes;

b é o vetor de desvios;

Considerando que se pretende ter uma grau de precisão ε , a determinação dos coeficientes w_i é realizada pela minimização de uma função objetivo dada por:

$$\frac{1}{2} \cdot \|w\|^2 + C \cdot \sum_{i=1}^m |y_i - f(x_i)| \quad (7)$$

onde o termo $\frac{1}{2} \cdot \|w\|^2$ está associado ao processo de classificação, devendo ser minimizado para reduzir a complexidade do problema (Guo et al., 2006). A segunda parcela $C \cdot \sum_{i=1}^m |y_i - f(x_i)|$ está associada à penalização atribuída ao erro, através de um fator C. Este parâmetro C é especificado *a priori*, encontrando-se associado ao erro que ultrapasse a tolerância ε especificada.

Para incorporar a possibilidade de ultrapassagem dos limites do erro são definidas duas novas variáveis ξ_i e ξ_i^* , designadas variáveis de folga ou do inglês “*slack*”, representando a distância entre o valor real e os correspondentes valores limitativos associados à tolerância ε . As expressões matemáticas são dadas por:

$$y_i - f(x_i) \leq \varepsilon + \xi_i \quad (8)$$

$$f(x_i) - y_i \leq \varepsilon + \xi_i^* \quad (9)$$

Com base nas expressões apresentadas anteriormente, é possível estabelecer um problema de otimização, sujeito às respectivas restrições, dado por:

$$\min \left[\frac{1}{2} \|w\|^2 + C \cdot \sum_{i=1}^m (\xi_i + \xi_i^*) \right] \quad (10)$$

sujeito às equações (8) e (9), com:

$$\xi_i, \xi_i^* \geq 0 \quad (11)$$

Torna-se evidente que para situações em que o erro ξ_i e ξ_i^* é inferior à margem de tolerância ε estabelecida, as variáveis ξ_i e ξ_i^* são nulas (Guo et al., 2006).

A maioria dos problemas reais não são claramente lineares, sendo necessário resolver problemas de regressão não-linear. A ideia base passa por mapear um espaço dimensional não linear num espaço dimensional F de menores dimensões e linear aplicando posteriormente a regressão linear a F . Para contornar essa dificuldade, são utilizadas funções de *Kernel*⁵ $F(x)$ que permite transformar as variáveis num espaço de maior dimensão, eliminando as não linearidades do espaço original.

Na Figura 11 encontra-se ilustrado o processo de transformação entre um espaço não linearmente separável, num espaço linearmente separável, com base numa função de *Kernel*.

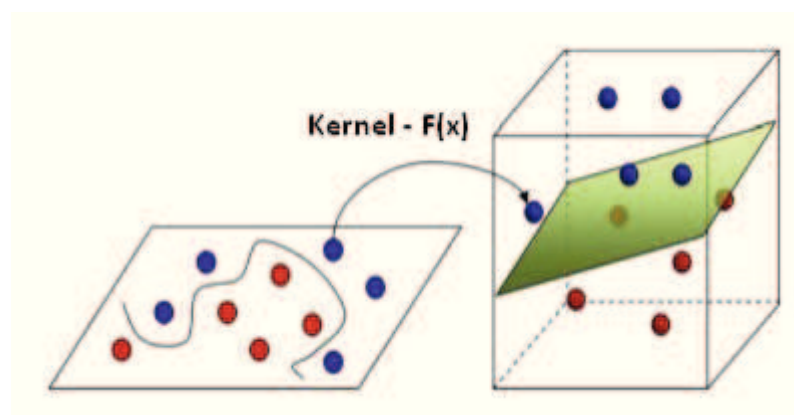


Figura 11 – Processo de transformação entre espaço original e espaço dimensional

⁵ Uma função de Kernel permite transformar uma ou mais variáveis num espaço de maior dimensão, eliminando as não linearidades do espaço original.

Na Tabela 1 encontram-se as funções de *Kernel* que podem ser utilizadas. A escolha mais comum e mais utilizada pelos investigadores para os problemas de previsão de consumos recai sobre a função de base radial, tipicamente caracterizados por grandes não linearidades (Guo et al., 2006; Pai & Hong, 2005).

Tabela 1 – Funções de Kernel típicas (Madedo, Lima, & Peres, 2012)

Designação da função de Kernel	Definição da função
Polinomial	$(\langle x_i \cdot x_j \rangle + 1)^p$
Base Radial	$\exp\left(\frac{\ x_i - x_j\ ^2}{2\delta^2}\right)$
Percetrão multicamada	$\tanh(\delta(\langle x_i \cdot x_j \rangle) + k)$

Segundo Guo et al., 2006, a função de base radial, também denominada de função Gaussiana, pode igualmente ser definida por:

$$k(x, y) = \exp(-\gamma \|x - y\|^2) \quad (12)$$

onde o parâmetro γ é uma constante especificada *a priori*, estabelecida com base no processo de previsão utilizado e nos dados aplicados ao modelo.

A expressão (10) pode ser transformada de acordo com a teoria não linear *primal-dual*, através da inserção dos multiplicadores de Lagrange α_i e α_i^* , sendo equivalente à seguinte expressão:

$$\max \left[-\frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x_i, x_j) - \varepsilon \sum_{i=1}^m (\alpha_i - \alpha_i^*) + \sum_{i=1}^m (\alpha_i - \alpha_i^*) y_i \right] \quad (13)$$

sujeito a:

$$\sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \quad (14)$$

$$\alpha_i, \alpha_i^* \in [0, C] \quad (15)$$

A função que define o valor resultante da regressão linear, será dada por:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) k(x_i, x_j) + b \quad (16)$$

onde o parâmetro b corresponde a um vetor de desvios.

Por fim, para que todo o processo tenha um bom grau de precisão de resultados, é necessário definir os parâmetros (ϵ, C e γ) correspondentes à margem de tolerância ao erro, ao fator de penalização e ao parâmetro da função Gaussiana, respetivamente (Guo et al., 2006). O problema chave das SVM passa pela seleção desses parâmetros. Os parâmetros podem ser definidos com base em processos combinatórios entre eles, mas levará a grandes tempos de resposta e não confirmação de que aqueles dados são à partida as melhores combinações possíveis.

Devido à dificuldade inerente a todo o processo de seleção e confirmação dos parâmetros para cada situação, é usual recorrer-se a métodos baseados em metas heurísticas, habitualmente utilizadas para otimização de problemas de natureza combinatória, quando o número de soluções possíveis é de tal forma elevado que a sua solução direta ou a sua exploração sistemática são inviáveis em tempo útil. Estes algoritmos são inspirados em técnicas utilizadas na otimização dos dados. É possível encontrar diversas variantes ao longo da literatura existente. Com base em todas as mais-valias já estudadas e aplicadas, este estudo basear-se-á no método de otimização *Simulated Annealing*⁶, como meta-heurística que irá auxiliar na seleção dos parâmetros de entrada em cada caso.

⁶ O processo de seleção das entradas pelo método *Simulated Annealing* será apresentado no Capítulo 4.

2.4 Quantificação e valorização dos erros de previsão

Os custos associados às possíveis falhas de operação das unidades geradoras originam custos avultados para as próprias empresas produtoras, sendo refletidos na recusa ou aceitação dos preços de oferta, por parte dos fornecedores de energia que vão a mercado.

Nos mercados de energia elétrica competitivos, os fornecedores de energia elaboram as suas propostas em termos de quantidades e preços de oferta junto do operador de mercado, tipicamente até um dia antes da operação em tempo real. Segundo Mohammadi-Ivatloo, Zareipour, Ehsan, & Amjady, 2011, os fornecedores fazem as suas propostas através da resolução de dois problemas. O primeiro é conhecido como o despacho ótimo, onde a empresa produtora determina as unidades geradoras mais económicas para entrarem em funcionamento no dia seguinte, de forma a maximizar o seu lucro. O segundo problema, conhecido como oferta estratégica, a empresa produtora define uma licitação eficiente estratégica que se traduz nos horários operacionais ótimos das ofertas preço-quantidade, maximizando a probabilidade de que essas ofertas sejam apuradas no mercado. Estes problemas podem ter variações dependendo das características das próprias empresas produtoras. No entanto, existe uma característica comum que todos os operadores devem levar em conta, como o comportamento histórico dos preços de mercado e a previsão das variações futuras dos preços.

Zhai et al., 1994 demonstraram o efeito do erro na previsão da carga para avaliar o risco inerente ao funcionamento das unidades geradoras, utilizando o modelo de carga Gauss-Markov, estimando a probabilidade de não possuir capacidade suficiente de geração para compensar as falhas das unidades ou variações inesperadas no consumo.

Ranaweera, Karady, & Farmer, 1997, abordam uma análise do impacto económico da previsão da carga. Neste artigo é demonstrada a influência que os erros na previsão da carga têm na operação anual do sistema, utilizando simulações pelo método de Monte Carlo.

Os erros de previsão, para além de todas as penalizações adjacentes referidas, e do não funcionamento de forma otimizada, também se poderão refletir em compensações/penalizações para as próprias empresas gestoras. A unidade responsável por essas compensações é a OMIClear, que está internamente associada ao OMIP e ao OMIE (50% cada um).

A OMIClear desempenha as funções de órgão central de compensação de contrapartidas (CCP) nas operações em si registadas, de forma a garantir o cumprimento das obrigações de ambas as partes envolvidas. Uma vez registada uma operação, a OMIClear procede à gestão das posições resultantes, assumindo-se como compradora face ao vendedor e como vendedora face ao comprador, controlando o risco assumido pelos participantes.

Na Figura 12 encontra-se estruturado o papel de cada entidade, bem como todos os agentes e participantes que fazem parte.



Figura 12 – Estrutura do mercado ibérico Pólo português⁷

Segundo a OMIClear⁸ os principais riscos das operações incluem:

- Riscos de crédito, quando uma parte não honra os seus compromissos contratuais face à outra;
- Riscos de liquidação, que asseguram os débitos e créditos em dinheiro, de forma multilateral;
- Riscos operacionais, atendendo aos procedimentos e mecanismos de controlo e supervisão de mercado;
- Risco sistémico, atendendo ao facto de introduzir as operações de compensação de natureza multilateral.

⁷ Mais informações podem ser consultadas na seguinte página Web:
<http://www.omip.pt/MarketInfo/ModelodeMercado/tabid/75/language/pt-PT/Default.aspx>

⁸ Mais informações podem ser consultadas na seguinte página Web:
<http://www.omiclear.pt/OMIClear/TermsOfUse/tabid/131/language/pt-PT/Default.aspx>

Para efeitos de cálculos serão consideradas duas situações distintas, nomeadamente situações onde a previsão seja inferior ao consumo verificado e situações onde a previsão seja excessiva face ao consumo.

Na Figura 13 é possível verificar a existência das situações referidas anteriormente. Destaca-se o período matinal onde se verificou um carga prevista inferior à carga verificada (Situação I - Previsão por defeito) e no período de madrugada onde se verificou uma carga prevista superior à carga verificada (Situação II- Previsão por excesso).




Figura 13 – Carga prevista e verificada (Fonte: www.ren.pt)

Situação I ($\Delta P1$) – Compra do diferencial de potência sujeito ao preço spot de mercado.

$$\Delta P1 = \Delta P \times \text{Custo}(\text{Spot}) \quad (17)$$

Situação II ($\Delta P2$) – Verificar diferencial de potência e sujeitar ao preço aquando da data de negociação (preço futuro), de 15 dias ou até 1 mês da data.

$$\Delta P2 = \Delta P \times \text{Custo}(\text{futuro}) \quad (18)$$

No quinto capítulo serão abordados os resultados da avaliação económica.

3 Metodologia

Neste capítulo são apresentados os métodos utilizados e todos os passos necessários para a realização de uma tarefa de previsão bem formulada (Makridakis & Wheelwright, 1978), através dos seguintes passos:

1. Definição do problema;
2. Recolha de dados;
3. Análise preliminar;
4. Seleção de modelos;
5. Utilização e avaliação de um modelo de previsão.

3.1 Definição do problema

Como referido anteriormente, o papel das empresas operadoras tem adquirido grande importância no ponto de vista da gestão e utilização dos recursos de forma otimizada com vista à diminuição dos custos operacionais, satisfazendo necessidades e acautelando eventos imprevistos.

Conhecendo previamente o consumo de energia eléctrica expectável para uma determinada hora, semana ou mês, é possível diminuir os custos associados à produção da energia eléctrica para que, com base nos dados obtidos, sejam colocadas em funcionamento as unidades de produção mais económicas.

Dependendo do horizonte de previsão, podem ser efetuadas previsões a curto, médio e longo prazo. A curto prazo a previsão é definida para a hora ou dia seguinte, sendo o preço da energia normalmente superior, uma vez que a energia é transacionada quase em simultâneo com o consumo, implicando maiores custos pela disponibilidade. Por essa razão as previsões devem ser efetuadas com alguma antecedência, procurando preços da energia inferiores mas assumindo maior grau de incerteza.

Para fazer face ao problema, utilizam-se modelos e técnicas que permitam reduzir os erros associados à previsão dos consumos, reduzindo os custos para as empresas operadoras e consumidores finais. Depois de determinadas as previsões dos consumos, procede-se ao cálculo e análise do impacto económico originado pelos erros de previsão obtidos.

3.2 Recolha de dados

Para a recolha dos dados necessários, procede-se inicialmente a uma averiguação das variáveis que afetam de forma mais significativa o consumo de energia elétrica. Como referido no capítulo 2, subcapítulo 2.2, os fatores meteorológicos, como a temperatura e humidade, são os que mais influenciam o consumo de energia a curto prazo. Fatores temporais, como períodos festivos ou feriados, também surgem como eventos que introduzem maior incerteza na tarefa de previsão.

3.3 Análise preliminar

Depois de recolhidos os dados de consumo para amostra, é necessário verificar a existência de anomalias nos dados recolhidos e forma de os corrigir, para evitar erros atípicos nos dados resultantes da aplicação dos modelos e técnicas de previsão. Essa análise e retificação de possíveis irregularidades nos dados serão apresentadas no próximo capítulo.

3.4 Seleção dos modelos

Com base na literatura existente, verificou-se que normalmente são utilizados dois métodos a fim de obter uma forma de comparação do desempenho entre eles, e porventura, uma combinação de métodos para diminuição do erro, sendo comum uma utilização de um método baseado em inteligência artificial e outro baseado em modelos estatísticos.

Face a todos os pontos descritos anteriormente, optou-se pela conjugação de dois métodos baseados em inteligência artificial, redes neuronais artificiais (RNA) e máquinas de suporte vetorial (SVM), e um método baseado em modelos estatísticos clássicos, regressão linear múltipla (RL).

Para a elaboração dos métodos e modelos foi utilizado o programa *Matlab*⁹ juntamente com o apoio do programa Microsoft Excel¹⁰ para o tratamento da informação e elaboração de gráficos ilustrativos.

⁹ O *Matlab*, de MATrix LABoratory, desenvolvido pela MathWorks, é um software interativo de alto desempenho direcionado para o cálculo numérico.

¹⁰ O *Microsoft Excel*, desenvolvido pela Microsoft, é um software que permite a criação de tabelas, cálculo e análise de dados. Por essa razão, é geralmente designado de folha de cálculo.

3.5 Utilização e avaliação de um modelo de previsão

Nesta secção serão definidos os modelos de previsão que vão ser utilizados para a tarefa de previsão, redes neuronais artificiais (RNA), regressão linear (RL) e máquinas de suporte vetorial (SVM). Como referido, o horizonte de previsão é de uma semana, sendo os preços inferiores à medida que nos distanciamos do dia alvo de previsão. Também serão efetuados testes de previsão baseados na hora e dia seguinte, para situações ocasionais em que seja necessário intervir próximo da ocorrência. Nestas situações os preços tendem a aumentar, penalizando os operadores pela disponibilidade quase imediata entre a procura e a oferta.

Para a utilização dos vários métodos foi estabelecida uma normalização do tipo média nula e variância unitária (MAPSTD), que permite transformar um determinado conjunto de dados (entradas e saídas) num novo conjunto normalizado. Esta técnica é bastante utilizada em modelos para manter os valores de consumos de energia numa determinada escala, utilizando a média e a variabilidade dos dados (Beale, Hagan, & Demuth, 2014). A normalização dos dados é efetuada no algoritmo desenvolvido para os testes na rede neuronal, através do comando “mapstd()¹¹” disponível no Matlab. A expressão utilizada para a normalização é a seguinte:

$$NORM^{MAPSTD} = \frac{x_i - mean(x_i, x_n)}{\sigma(x_i, x_n)}, \quad (19)$$

em que,

$NORM^{MAPSTD}$ corresponde ao conjunto de dados normalizados,

x_i corresponde ao valor específico a normalizar,

$mean(x_i, x_n)$ corresponde à média do conjunto de dados iniciais,

$\sigma(x_i, x_n)$ corresponde ao desvio padrão do conjunto de dados iniciais,

Por fim, para avaliar o desempenho do método, determinaram-se os erros de previsão obtidos com base neste método, utilizando o erro percentual absoluto para cada hora específica, como também o erro médio absoluto percentual (MAPE). No quinto capítulo serão apresentados os resultados económicos e respetivos erros obtidos.

¹¹ Para mais detalhes acerca desta e outro tipo de funções, pode ser consultada a documentação <http://www.mathworks.com/help/nnet/>

O erro MAPE é determinado pela seguinte expressão (N. Lu, Zhou, He, & Liu, 2009):

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y - x}{x} \right|}{n} \times 100\%, \quad (20)$$

em que,

<i>MAPE</i>	corresponde ao erro obtido em percentagem,
<i>x</i>	corresponde ao valor de consumo real,
<i>y</i>	corresponde ao valor de consumo previsto,
<i>n</i>	corresponde ao número total de dados considerados,

3.5.1 Aplicação de Redes Neurais Artificiais no MATLAB

Segundo Beale, Hagan, & Demuth, 2014, a aplicação das redes neurais artificiais no programa Matlab passa por sete etapas principais:

1. Recolher dados;
2. Criar a rede neuronal;
3. Configurar a rede;
4. Inicializar os pesos e os desvios;
5. Treinar a rede;
6. Validar a rede;
7. Utilizar a rede.

Na primeira etapa procede-se à recolha dos dados necessários para a rede neuronal, averiguando as variáveis que influenciam de forma mais significativa o consumo de energia elétrica e os períodos homólogos a utilizar como dados históricos. No próximo capítulo serão definidas as entradas reais a utilizar de acordo com a amostra escolhida para o estudo de caso.

A criação da rede neuronal decorre assim da definição de entradas e saídas, ou seja, a caracterização dos dados de entrada e dos dados que deverão resultar da previsão. Com esta informação e a opção sobre a restante configuração da rede, incluindo a definição de camadas intermédias, é criado o modelo através da *'toolbox neural network'* do Matlab, onde é efetuado todo o processo de treino e simulação da rede. Esta ferramenta inclui um interface gráfico que permite definir, parametrizar e treinar modelos de redes neurais.

A partir deste momento, é possível carregar na toolbox os dados que foram definidos anteriormente. Na Figura 14 encontra-se uma imagem ilustrativa da janela inicial com os respectivos dados já definidos.

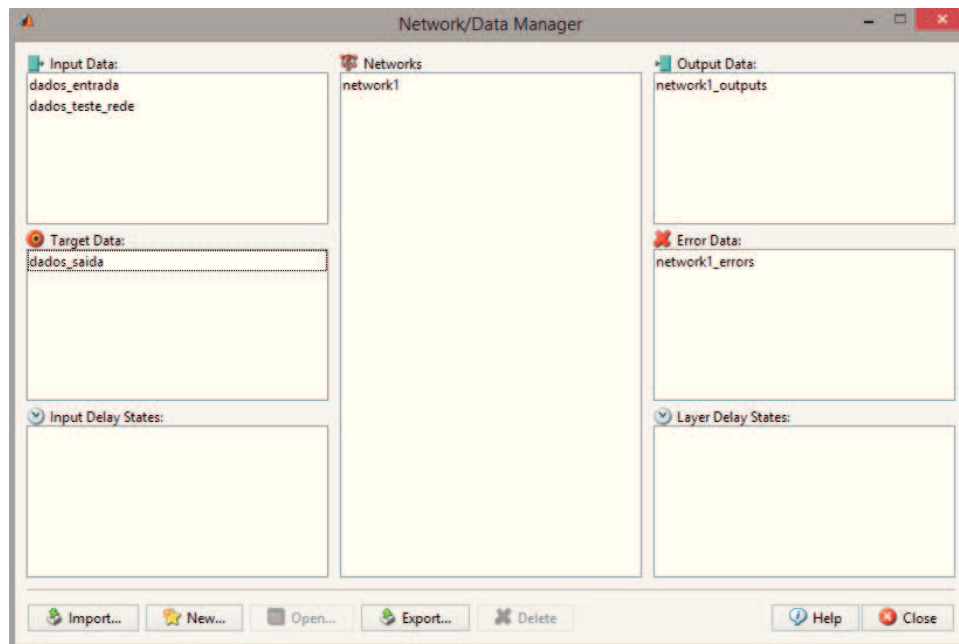


Figura 14 – Janela inicial da “Toolbox Neural Network”

No processo de criação da rede, os dados de entradas são divididos em três conjuntos. O primeiro conjunto corresponde aos dados de treino, que são utilizados para o treino efetivo da rede pela atualização dos pesos e desvios da rede. O segundo conjunto corresponde aos dados de validação, que permitem conferir o erro obtido à medida que ocorre todo o processo de treino. Tipicamente este erro tende a diminuir numa fase inicial, onde ainda não existe generalização dos dados e os pesos e desvios da rede não se encontram ajustados. Após o erro ser diminuto, tende a existir perda de generalização (*overfitting*), onde a melhoria dos dados de treino, não se traduz numa melhoria para os dados fora do conjunto de treino.

Deste modo, para que os dados de treino e validação da rede não se apresentem de forma sequencial é necessário alterar a sua ordenação. Os comandos que permitem efetuar o carregamento separado dos dados de treino, validação e teste são os seguintes:

- ✓ `network1.divideFcn = 'divideind'`
- ✓ `network1.divideParam.trainInd = [treino]`
- ✓ `network1.divideParam.valInd = [validação]`
- ✓ `network1.divideParam.testInd = [teste]`

A criação da rede neuronal concretiza-se com a seleção dos seguintes parâmetros:

- Nome da rede neuronal
- Tipo de rede a adotar
- Dados de entrada
- Dados de saída
- Função de treino
- Função de aprendizagem
- Função de avaliação do desempenho
- Número de camadas ocultas
- Número de neurónios em cada camada oculta
- Funções de ativação entre camadas da rede neuronal

O tipo de rede a selecionar é “Feed-forward backprop” de percetção multicamada, o algoritmo de treino “TRAINLM” designado de ‘Levenberg-Marquardt’, a função de adaptação de aprendizagem pelo método do gradiente “LEARNGDM” e a função de otimização do erro médio quadrático “MSE”. O número de camadas está dependente da amostra em causa, bem como as características para cada camada em relação ao número de neurónios e respetiva função de ativação.

O resultado final de todas as opções definidas é apresentado na Figura 15.

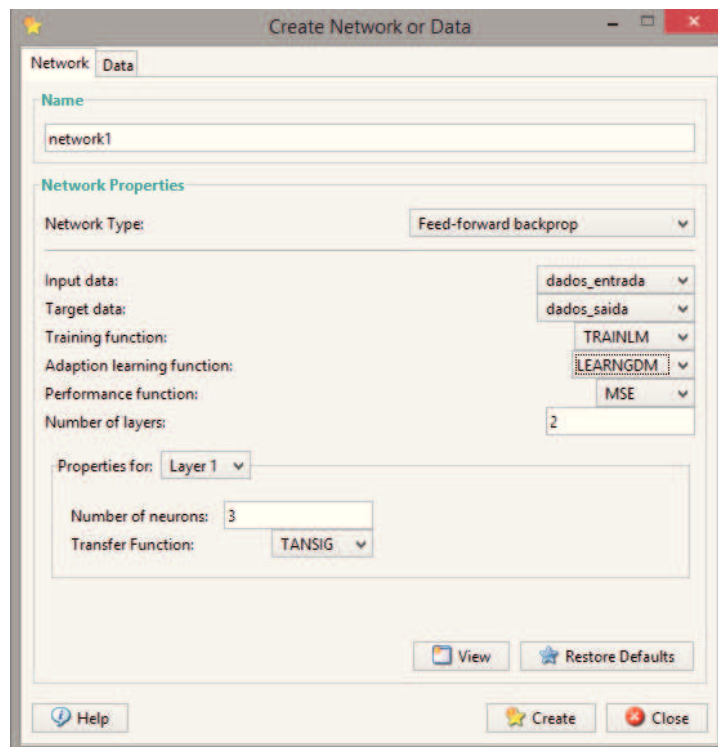


Figura 15 – Configuração da rede neuronal

Antes de proceder ao treino de cada rede neuronal é necessário reinicializar os pesos e desvios atribuídos à rede, efetuado após criar a rede e antes da sua simulação, conforme ilustrado na Figura 16.

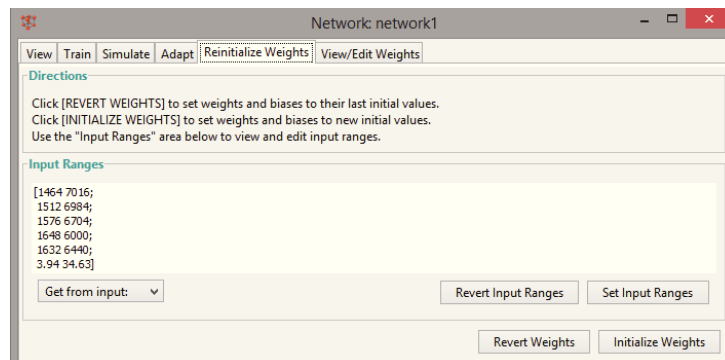


Figura 16 – Reinicialização dos pesos e desvios

Após todas as configurações, é efetuado o treino da rede neuronal em causa. O processo de treino da rede passa pela verificação de todas as variáveis incluídas na rede, até que alguma das condições de paragem da rede neuronal seja verificada. Na Figura 17 encontra-se o processo de treino de uma rede neuronal, onde se destaca a paragem do treino pelo critério de validação cruzada.

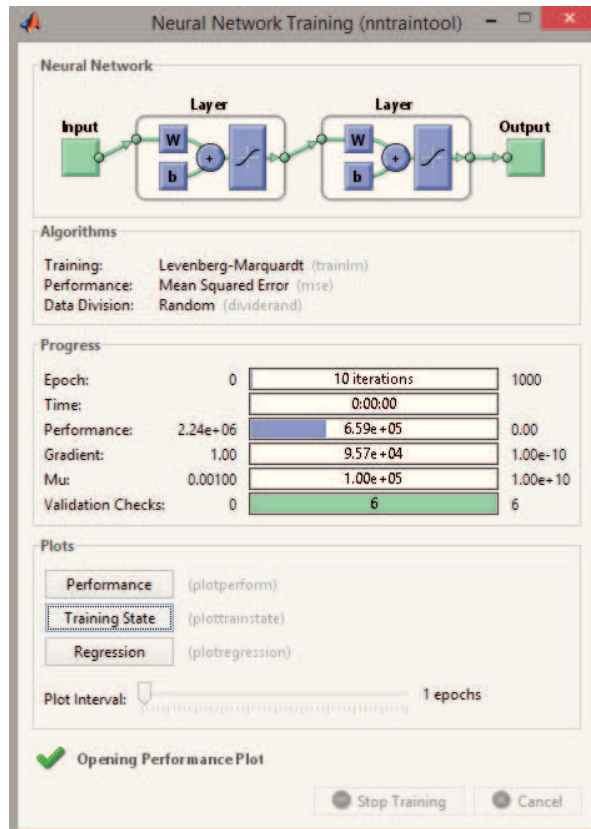


Figura 17 – Treino de uma rede neuronal

Na figura seguinte encontra-se um dos gráficos gerados pela 'toolbox'. No gráfico 'performance' verifica-se a evolução do erro para o conjunto de treino e validação ao longo do tempo (épocas), cujo erro mínimo no conjunto de dados de validação foi obtido para a quarta época.

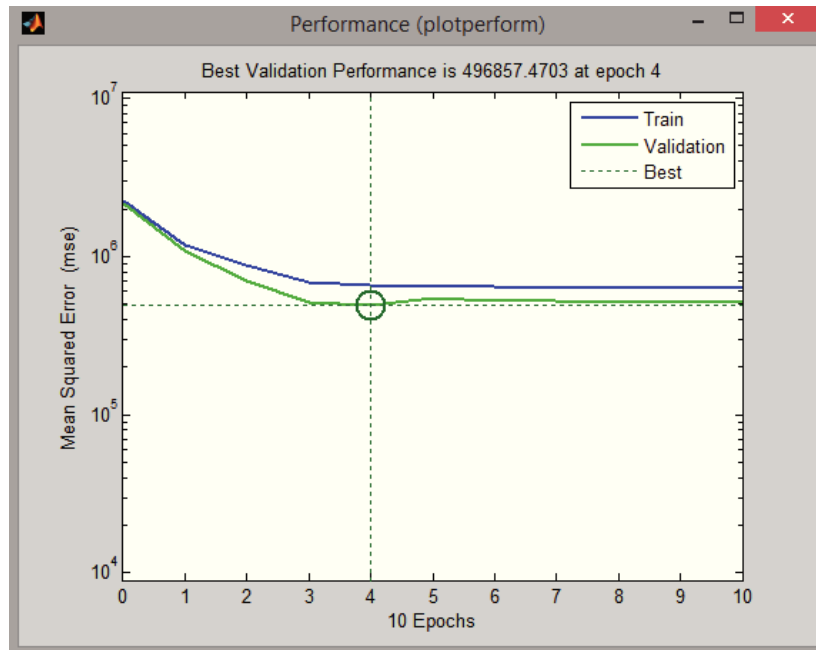


Figura 18 – Evolução do erro do conjunto de treino e validação

3.5.2 Aplicação de Métodos de Regressão Linear no MATLAB

Para a aplicação do método de regressão linear no Matlab adotaram-se as seguintes etapas:

1. Recolha dos dados para entradas e saídas;
2. Normalização dos dados;
3. Cálculo dos pesos/parâmetros de regressão;
4. Cálculo dos dados de previsão;
5. Recuperação dos dados;
6. Determinar erro de previsão.

Na primeira etapa procede-se à recolha de todos os dados necessários para a utilização do método de regressão linear. Devem ser carregados os dados das entradas e saídas alvo da rede, bem como os dados das entradas e saídas de teste.

Após a recolha, é necessário efetuar uma normalização de todos os dados carregados, o que não acontecia com as redes neuronais, pelo facto de a 'toolbox' já efetuar todo o processo internamente. De forma análoga às redes neuronais, optou-se também por uma normalização do tipo média nula e variância unitária (MAPSTD).

Posteriormente, são determinados os parâmetros de regressão, também designados de pesos, a partir dos dados de entrada e de saída. Para realizar esta tarefa foi utilizado o comando "regress(y,x)".

Obtidos os parâmetros de regressão, é possível determinar os dados de saída de teste do método, pela multiplicação das entradas de teste utilizadas com os parâmetros calculados.

Para obter os dados de consumo reais é necessário proceder a uma recuperação dos dados de saída a partir de dados normalizados. Para isso, são utilizadas as definições estabelecidas anteriormente aquando da normalização das mesmas saídas de teste.

3.5.3 Aplicação de Métodos baseados em Máquinas de Suporte Vetorial no MATLAB

Para a aplicação do método baseado nas máquinas de suporte vetorial, estabeleceram-se as seguintes etapas:

1. Recolha dos dados para entradas e saídas;
2. Normalização dos dados;
3. Divisão dos dados;
4. Cálculo dos parâmetros;
5. Cálculo dos dados de previsão;
6. Recuperação dos dados a partir dos dados normalizados;
7. Determinação dos erros de previsão.

De seguida é apresentado um fluxograma exemplificativo de todo o processo inerente à aplicação das SVM.

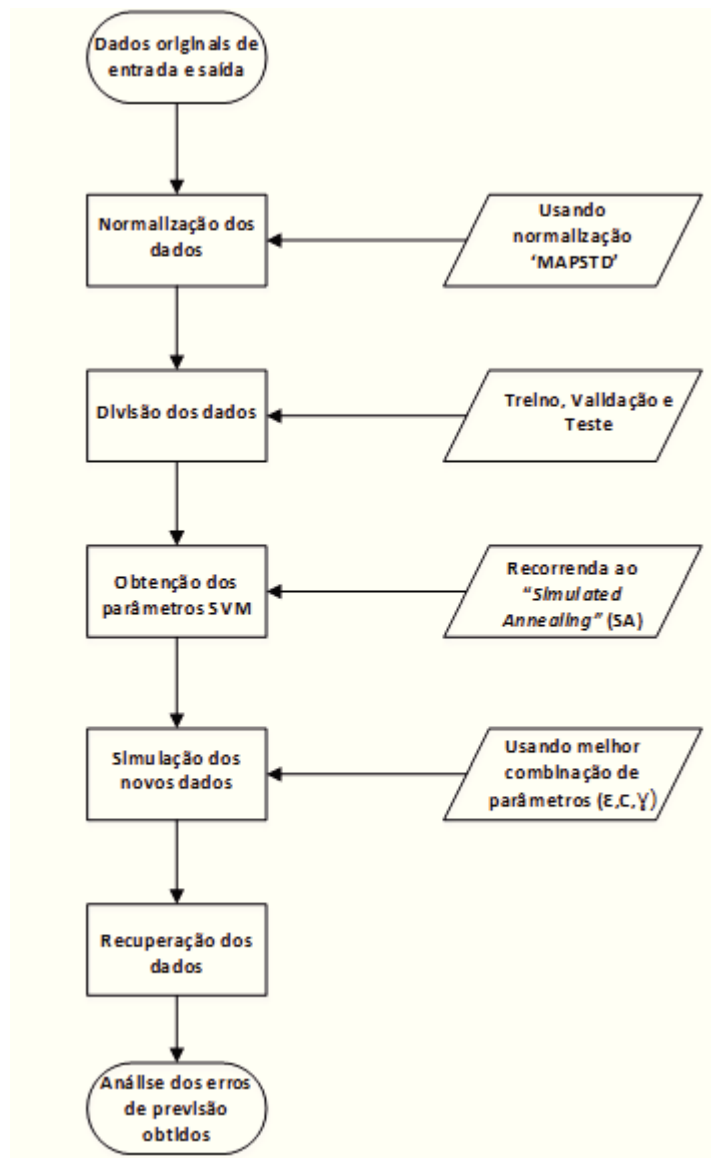


Figura 19 – Fluxograma da aplicação das SVM

Na primeira etapa procede-se à recolha de todos os dados necessários. Devem ser carregados os dados de entrada e saídas alvo da rede, bem como os dados das entradas e saídas de teste.

Após a recolha, é necessário efetuar a normalização de todos os dados carregados. De forma análoga às redes neuronais e à regressão linear, optou-se também por uma normalização do tipo MAPSTD.

Como referido nas redes neuronais, a divisão dos dados permite definir manualmente os dados a colocar no conjunto de treino, validação e teste. Desta forma, permite evitar que os dados de validação permanecessem logo após os dados de treino, intercalando os dados de treino com os dados de validação. Evitam-se situações de dias e semanas fora do comum, que viessem a afetar o desempenho dos métodos.

Posteriormente, será utilizado o método de otimização *Simulated Annealing*¹², como meta-heurística que irá auxiliar na seleção dos parâmetros de entrada em cada caso. Os parâmetros (ϵ , C e γ) correspondem à margem de tolerância ao erro, ao fator de penalização e ao parâmetro da função Gaussiana, respectivamente.

Obtidos os parâmetros, é possível determinar os novos dados de saída de teste do método, e efetuada a recuperação dos respectivos dados normalizados.

Por fim, para avaliar o desempenho do método, determinaram-se os erros percentuais absolutos para cada hora específica, como também o índice de desempenho MAPE.

¹² O processo de seleção das entradas pelo método *Simulated Annealing* será apresentado no Capítulo 4.

4 Estudo de caso

A metodologia proposta foi aplicada a um conjunto de dados históricos de consumo e de temperatura relativos à zona centro do país, para os quais se procurou prever o consumo de energia elétrica para um determinado período temporal. Este capítulo descreve o processo, iniciando pela recolha dos dados, a sua análise preliminar seguida da aplicação dos modelos de previsão aos dados recolhidos.

4.1 Recolha de dados

Para a recolha dos dados necessários para o presente estudo, procedeu-se inicialmente a uma averiguação das variáveis que afetam de forma mais significativa o consumo de energia elétrica. Como referido no capítulo 2, subcapítulo 2.2, os fatores meteorológicos, como a temperatura e humidade, são os que mais influenciam o consumo de energia a curto prazo. Os vários tipos de previsões baseiam-se em dados históricos de consumos de energia elétrica e, eventualmente, em dados meteorológicos.

Os dados históricos de consumo de que se dispunha, cedidos pela empresa EDP, são relativos à zona centro do país, particularmente à zona de Leiria, incluindo as subestações de Andrinos, Azóia, Ortigosa e Pinheiros. Os dados foram selecionados com base num critério que acolhesse um grande número de aglomerados populacionais e situações atípicas como épocas festivas, suscetíveis de maiores consumos e, conseqüentemente, maiores erros na previsão. De acordo com os critérios enunciados, foi selecionada a subestação de Andrinos com saída para Pombal, constituída por uma linha de 30kV, para o período compreendido entre 1 de julho de 2008 a 27 de setembro de 2009.

Para além dos dados de consumo históricos, foi possível obter dados meteorológicos de temperatura, fornecidos pela estação meteorológica da Base Aérea N°5, localizada em Monte Real. Foram efetuados testes com dados meteorológicos para um determinado período temporal, de forma a inferir se os resultados obtidos eram favoráveis e apresentavam melhorias. Criou-se um cenário de introdução de erro à variável da temperatura de forma a distinguir um registo real de um registo resultante de uma previsão meteorológica. Os valores considerados registaram-se em torno de uma aproximação [- desvio padrão/2; + desvio padrão/2].

Dado que o consumo depende da temperatura real e não da temperatura prevista, foi necessário proceder a um fator de temperatura de forma a obter dados próximos dos obtidos para o período temporal tratado. Para além disso, os dados de temperatura num determinado local não se refletem para todos os locais.

Verificou-se que a sua inclusão dos dados meteorológicos como entradas dos modelos não contribuía de forma significativa para uma melhoria do erro MAPE final, optando pela não utilização dos mesmos. Estudos recentes demonstram que a inclusão da temperatura nos processos de previsão não melhora significativamente os resultados (Fidalgo & Matos, 2007).

4.2 Análise preliminar

Como referido anteriormente no capítulo 3, é necessário verificar a existência de anomalias nos dados recolhidos e encontrar uma forma de os corrigir, para evitar erros atípicos nos dados resultantes da aplicação dos modelos e técnicas de previsão.

Inicialmente procurou-se diferenciar as entradas e saídas da subestação, tornando-as mais perceptíveis para o utilizador. Atendeu-se ao nível de tensão superior (entrada da subestação) e nível de tensão inferior (saída da subestação) como forma de despistar dados anómalos e ter a noção se os dados são coerentes, com base na energia ativa de entrada e a energia ativa de saída da subestação.

Após a verificação das entradas e saídas da subestação, foi necessário determinar a média dos dados para cada hora, visto que os aparelhos de monitorização guardam os dados a cada quinze minutos. Para a conversão dos dados para uma hora específica foi utilizada a seguinte expressão matemática:

$$Ph = \frac{p^0 + p^{15} + p^{30} + p^{45}}{4}, \quad (21)$$

em que,

Ph corresponde à hora específica a determinar;

$p^0, p^{15}, p^{30}, p^{45}$ corresponde à potência verificada aos minutos 0, 15, 30 e 45 respetivamente.

Após a retificação dos dados verificou-se a existência de irregularidades, especialmente a existência de picos bastante elevados face à tendência, ou ainda pela existência de dados nulos. A principal causa para estas anomalias está associada aos sistemas de contagem que armazenaram dados incorretos para determinados períodos horários da amostra.

Tratando-se de consumos de energia elétrica ao longo de um determinado período de tempo, a forma mais simples de analisar os dados passa pela sua análise gráfica. Na Figura 20 observa-se a amostra total dos dados disponíveis, destacando-se a existência de quatro casos irregulares face à tendência verificada

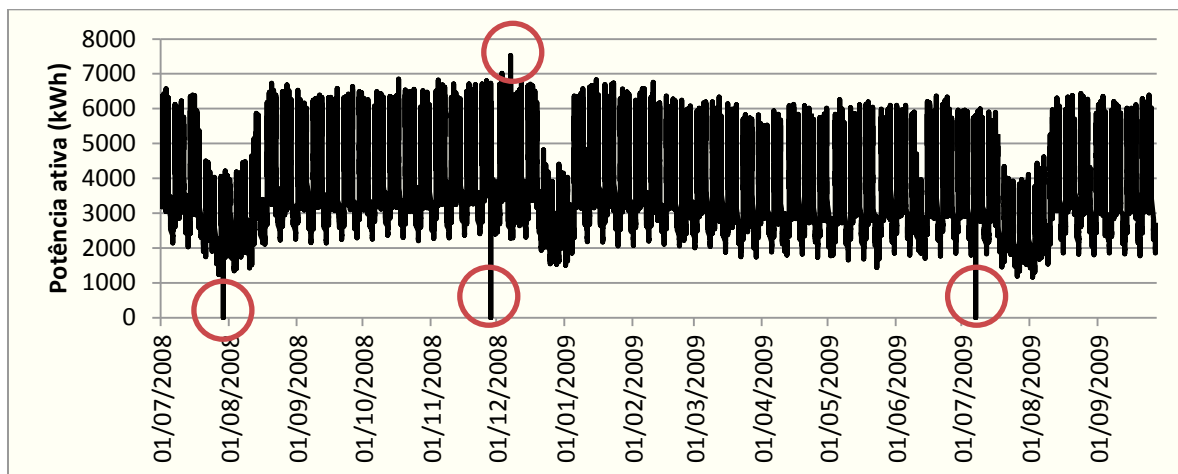


Figura 20 – Dados de consumo com anomalias

Uma possível forma de correção dos dados passa por considerar os consumos verificados na semana anterior, semana seguinte, dia anterior e dia seguinte. A correção foi efetuada manualmente através do Excel. A expressão utilizada para o cálculo dos novos dados foi a seguinte:

$$y = 0.7 \times \left(\frac{s1 + s2}{2} \right) + 0.3 \times \left(\frac{d1 + d2}{2} \right), \quad (22)$$

em que,

- y corresponde aos dados de consumos a corrigir,
- $s1$ corresponde aos dados de consumo verificados na semana anterior a y ,
- $s2$ corresponde aos dados de consumo verificados na semana seguinte a y ,
- $d1$ corresponde aos dados de consumo verificados no dia anterior a y ,
- $d2$ corresponde aos dados de consumo verificados no dia seguinte a y .

A percentagem de correção dos dados foi cerca de 2% dos dados disponíveis na amostra. Na Figura 21 e após a correção dos dados, verifica-se que a tendência dos dados se encontra dentro do esperado. Destacam-se as zonas de consumos mais baixos, correspondentes às épocas de férias de 2008 e 2009 e época natalícia de 2008, provocados essencialmente pela paragem das grandes indústrias, responsáveis por um grande consumo de energia elétrica. Nesta fase a amostra encontra-se organizada e preparada para serem efetuados os testes com os modelos e técnicas de previsão.




Figura 21 – Dados de consumo corrigidos

4.3 Aplicação dos modelos de previsão

As entradas para os vários modelos são selecionadas com base nos dados históricos em períodos homólogos. Para essa seleção é necessário verificar as entradas nas quais exista uma grande correlação entre os dados, i.e. as que apresentem uma aproximação mais apropriada para o horizonte de previsão escolhido.

Na Figura 22 encontra-se um gráfico ilustrativo de análise de autocorrelação onde se destaca a existência de diversos registos anteriores que poderão ser utilizados para os modelos. Nas zonas assinaladas, correspondentes aos dados relativos às duas semanas anteriores, verifica-se uma grande correlação entre os dados, podendo ser uma boa opção considerar estas variáveis como entradas nos modelos.

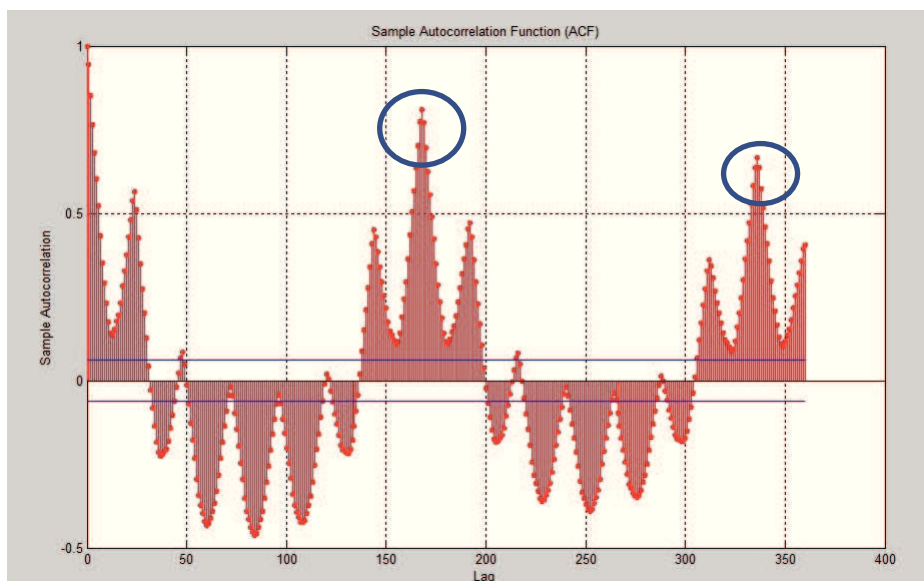


Figura 22 – Autocorrelação verificada na série temporal considerada

Durante períodos festivos, feriados, e outras ocasiões similares, os dados tendem a ser bastante oscilatórios e incertos, originando situações de erros para além dos esperados. A amostra em causa contempla um período festivo realizado em finais do mês de julho (Festas do Bodo), o qual poderá ser interessante adotar uma variável externa que representa os dias atípicos, inserindo um peso adicional para esses casos. Na situação específica deste estudo, verificou-se através da sua análise gráfica que esta época não tinha uma influência significativa no comportamento do consumo para a amostra de dados recolhida, optando por não dificultar em demasia a complexidade do modelo em proveito de uma diminuição insignificante no erro final.

4.3.1 Redes Neurais

Após a seleção da saída da subestação Andrinos-Pombal, para o qual se possuíam dados para o período de 1 de julho de 2008 a 27 de setembro de 2009, procedeu-se à aplicação das redes neurais com base nos seguintes passos:

1. Preparação de dados para entradas e saídas da rede neuronal;
2. Escolher horizonte de previsão;
3. Estratégia a adotar (camada única/multivariável/multimodelo);
4. Segmentação dos dados (Treino, Validação e Teste);
5. Ensaio de previsão.

Para tornar o processo de previsão o mais apropriado e ajustado possível, foram efetuadas 5 simulações de previsão para vários tipos de rede neuronais, realizando no final a média das 5 simulações. A razão para tal, é o facto de que a cada treino da rede, os valores dos pesos iniciais podem não ser os mais adequados, o que tornaria o processo bastante dependente de apenas uma única simulação.

O horizonte de previsão será baseado na hora, dia e semana seguinte. Espera-se que os erros aumentem de acordo com um horizonte temporal maior, mas também é verdade que os custos de energia nos mercados futuros são bastante inferiores face aos preços negociados praticamente em simultâneo, designados de preços spot. Apesar desses factos, serão efetuados testes para a hora e dia seguinte, uma vez que em situações de emergência, poderá ser necessário efetuar ajustes mais próximos do dia ou hora específica.

✓ Hora Seguinte

O ensaio de previsão para a hora seguinte (h), será baseado nas três horas anteriores conhecidas (h-2, h-3 e h-4)¹³, na própria hora e hora anterior da semana anterior (h-1(d-7)) e h(d-7) e com a própria hora e hora anterior nos quinze dias anteriores (h-1(d-14)) e h(d-14).

✓ Dia Seguinte

O ensaio de previsão para o dia seguinte (d), será baseado nos dados de consumo verificados no dia anterior h(d-2)¹⁴, horas adjacentes na semana anterior (h-1)(d-7), h(d-7) e (h+1)(d-7) e nas horas há quinze dias (h-1)(d-14), h(d-14) e (h+1)(d-14).

✓ Semana Seguinte

O ensaio de previsão para um dia da semana seguinte (s), o principal alvo deste estudo, será baseado nos dados de consumo relativos às horas adjacentes verificados na semana anterior, para prever as horas correspondentes a cada dia específico. Assim, para prever a hora (h) foram utilizados dados relativos à semana anterior (h-2)(d-7), (h-1)(d-7), h(d-7), (h+1)(d-7) e (h+2)(d-7). O passo temporal estabelecido é análogo às situações anteriores, de uma hora.

¹³ O registo associado à hora (h-1) não é utilizado, porque não é efetivamente ainda conhecido.

¹⁴ Os registos associados ao dia (d-1) não são utilizados, porque não são efetivamente ainda conhecidos.

A estratégia adotada para os ensaios de previsão da hora seguinte será baseada num modelo único multivariável, cujos dados de entrada são compostos por dados históricos de consumo e na saída são apresentados os dados de consumo para uma determinada hora do dia.

Para a previsão do dia seguinte e semana seguinte, os modelos foram definidos com base em previsão multimodelo, onde cada modelo corresponde a uma hora específica do dia seguinte.

As arquiteturas referidas encontram-se nas figuras seguintes.

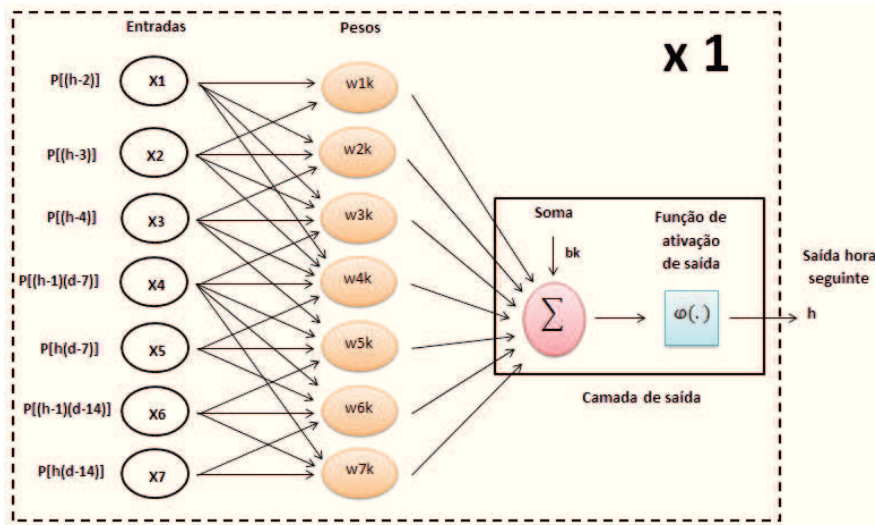


Figura 23 – Arquitetura do tipo multivariável (Hora seguinte)

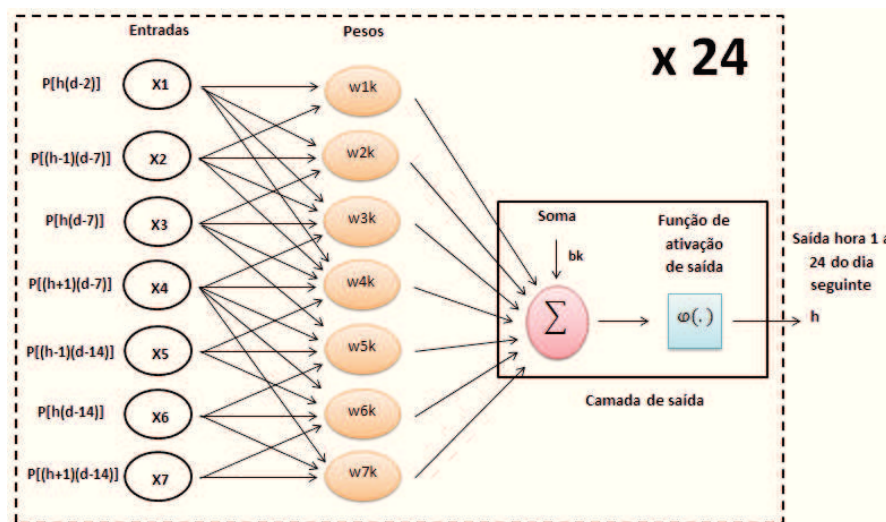


Figura 24 – Arquitetura do tipo multimodelo (Dia seguinte)

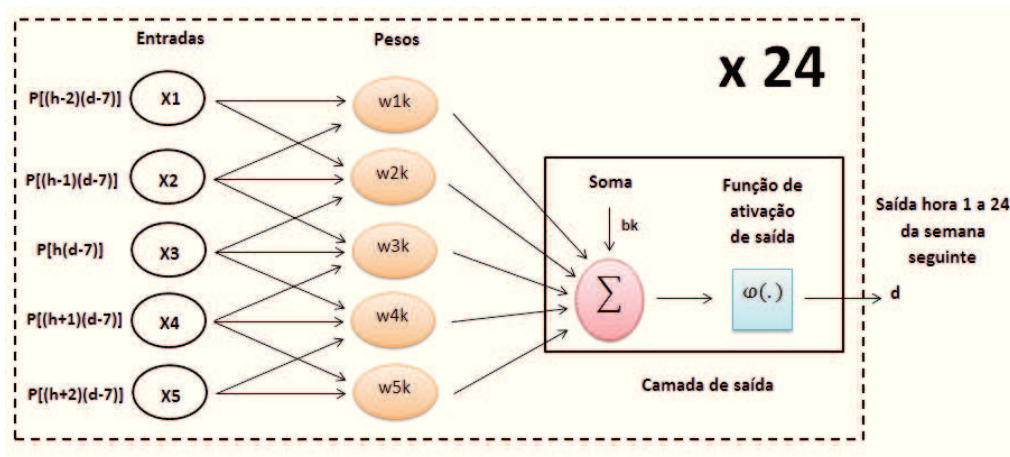


Figura 25 – Arquitetura do tipo multimodelo (Semana seguinte)

Definida a estratégia, é necessário efetuar a segmentação dos dados, dividindo a amostra entre dados de treino, validação e teste da rede. Procedeu-se inicialmente à contagem total dos dados, entre o período de 1 de julho de 2008 a 27 de setembro de 2009, obtendo um total de 10896 dados de consumo. Contudo, não pode ser utilizado o conjunto total de dados para treino, validação e teste, sendo necessário ter dados históricos para utilizar como entradas da rede. Assim, estabeleceu-se como período inicial de utilização de dados, o dia 1 de agosto de 2008.

Para a previsão da **hora seguinte** estabeleceu-se para treino e validação o período entre 1 de agosto de 2008 e 14 de agosto de 2009, e para teste e simulação da rede o período de 15 de agosto de 2009 a 27 de setembro de 2009. Perante isto, ficaram alocados 9096 registos para treino e validação e 1056 registos para teste. Entre os dados de treino e validação, escolheram-se 80% dos 9096 registos para treino e 20% para validação, ou seja, 7276 registos para treino efetivo da rede e 1820 registos para validação. No gráfico seguinte encontram-se os pesos finais atribuídos a cada subconjunto.

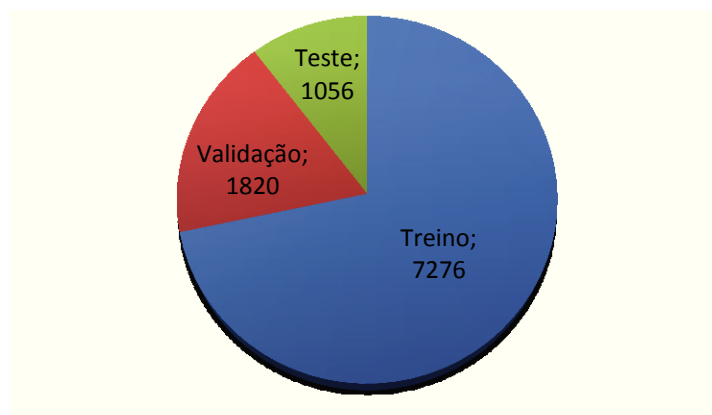


Figura 26 – Gráfico de distribuição de dados da hora seguinte

Para evitar que os dados de validação permanecessem após os dados de treino, foi elaborada uma estratégia de dados de validação intercalados com os dados de treino, evitando que dias e semanas fora do comum viessem a afetar o desempenho da rede neuronal. Foram estabelecidos 10 blocos de dados com 182 registos cada, e colocados de forma intercalada ao longo dos 7276 registos de treino.

No gráfico seguinte encontra-se a distribuição efetuada. Para estabelecer combinações de dados mais perceptivas, colocaram-se 676 dados na primeira amostra de treino, permanecendo as restantes equilibradas.




Figura 27 – Distribuição dos dados de treino e validação da hora seguinte

Os dados de entrada e os respetivos comandos a colocar no programa “Matlab”, foram os seguintes:

- ✓ **net.divideFcn='divideind'** (Permite definir o conjunto de dados de treino, validação e teste pelo utilizador)
- ✓ **net.divideParam.trainInd=[1:676;859:1518;1701:2360;2543:3202;3385:4044;4227:4886;5069:5728;5911:6570;6753:7412;7595:8254;8437:9096]** (Define os intervalos dos dados de entrada a considerar para treino da rede)
- ✓ **net.divideParam.valInd=[677:858;1519:1700;2361:2542;3203:3384;4045:4226;4887:5068;5729:5910;6571:6752;7413:7594;8255:8436]** (Define os intervalos dos dados de entrada a considerar para validação)
- ✓ **net.divideParam.testInd=[];** (Define como nulo os parâmetros relativos a teste)

Para a previsão do **dia seguinte** estabeleceu-se o mesmo período de dados de treino e validação, entre 1 de agosto de 2008 a 14 de agosto de 2009, e para teste e simulação da rede, o período de 15 de agosto de 2009 a 27 de setembro de 2009. Perante isto, ficaram alocados 379 registos para treino e validação e 44 registos para teste, para cada hora específica do dia seguinte. Entre os dados de treino e validação, escolheram-se 80% dos 379 registos para treino e 20% para validação, ou seja, 303 registos para treino efetivo da rede e 76 registos para validação.




Figura 28 – Gráfico de distribuição de dados do dia seguinte

Para a estratégia de dados de validação intercalados com os dados de treino foram estabelecidos 4 blocos de dados com 19 registos cada, e colocados de forma intercalada ao longo dos 303 registos de treino. Para estabelecer combinações de dados mais perceptivas, colocaram-se 63 dados na primeira amostra de treino, permanecendo as restantes equilibradas.




Figura 29 – Distribuição dos dados de treino e validação do dia seguinte

Os dados de entrada e os respetivos comandos a colocar no programa “Matlab”, foram os seguintes:

- ✓ **net.divideFcn='divideind'** (Permite definir o conjunto de dados de treino, validação e teste pelo utilizador)
- ✓ **net.divideParam.trainInd=[1:63;83:142;162:221;241:300;320:379]** (Define os intervalos dos dados de entrada a considerar para treino da rede)
- ✓ **net.divideParam.valInd=[64:82;143:161;222:240;301:319]** (Define os intervalos dos dados de entrada a considerar para validação)
- ✓ **net.divideParam.testInd=[];** (Define como nulo os parâmetros relativos a teste)

Para a previsão da **semana seguinte** estabeleceu-se o mesmo período de dados de treino e validação, entre 1 de agosto de 2008 a 14 de agosto de 2009, e para teste e simulação da rede, o período de 15 de agosto de 2009 a 27 de setembro de 2009. Perante isto, ficaram alocados 379 registos para treino e validação e 44 registos para teste, para cada hora específica do dia seguinte. Entre os dados de treino e validação, escolheram-se 80% dos 379 registos para treino e 20% para validação, ou seja, 303 registos para treino efetivo da rede e 76 registos para validação.

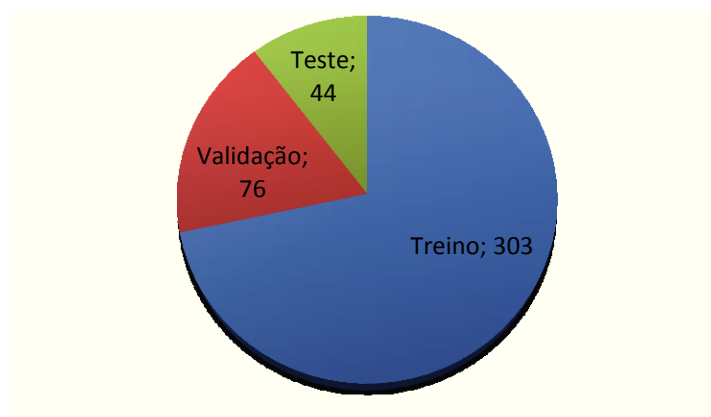


Figura 30 – Gráfico de distribuição de dados da semana seguinte

Para a estratégia de dados de validação intercalados com os dados de treino foram estabelecidos 4 blocos de dados com 19 registos cada, e colocados de forma intercalada ao longo dos 303 registos de treino. Para estabelecer combinações de dados mais perceptivas, colocaram-se 63 dados na primeira amostra de treino, permanecendo as restantes equilibradas.




Figura 31 – Distribuição dos dados de treino e validação da semana seguinte

Os dados de entrada e os respetivos comandos a colocar no programa “Matlab”, foram os seguintes:

- ✓ **net.divideFcn='divideind'** (Permite definir o conjunto de dados de treino, validação e teste pelo utilizador)
- ✓ **net.divideParam.trainInd=[1:63;83:142;162:221;241:300;320:379]** (Define os intervalos dos dados de entrada a considerar para treino da rede)
- ✓ **net.divideParam.valInd=[64:82;143:161;222:240;301:319]** (Define os intervalos dos dados de entrada a considerar para validação)
- ✓ **net.divideParam.testInd=[];** (Define como nulo os parâmetros relativos a teste)

Como referido no capítulo anterior, os ensaios de previsão de consumos das redes neuronais são realizados com base no interface gráfico que acompanha a ‘*toolbox*’ existente no Matlab. Este processo é útil para situações de aprendizagem e ambientação, mas tornar-se-ia pouco eficiente para situações onde a quantidade de dados a utilizar seja demasiado extensa. Por essa razão, foi elaborado um algoritmo que cumpre exatamente o mesmo processo, mas utilizando linhas de código no Matlab.

O algoritmo começa com a inicialização das variáveis de entrada e saída da rede. Houve a necessidade de transpor os dados das matrizes carregadas no programa, uma vez que para a aplicação do método, os dados devem estar na forma $M_{n \times m}$, onde ‘n’ corresponde às entradas totais do modelo e ‘m’ corresponde aos registos correspondentes a cada entrada.

Após o tratamento dos dados é necessário definir o número de neurónios da camada de entrada e da camada de saída. O número de neurónios na camada de entrada é definido de acordo com a complexidade do problema em causa e o número de neurónios da camada de saída é definido com base no tipo de resposta que se pretende obter. Na Tabela 2 encontra-se a divisão estabelecida para cada tipo de previsão, em função do número de modelos, número de neurónios na camada de entrada e número de neurónios na camada de saída. Nestas situações, o número de neurónios em ambas as camadas é fixo, dado que se trata de um modelo único do tipo multivariável para a hora seguinte, e de um modelo do tipo multimodelo para o dia e semana seguinte.

Tabela 2 – Número de neurónios na camada de entrada e saída em função do tipo de previsão

Amostra	Tipo de previsão	Número de modelos	Número de neurónios	
			Camada entrada	Camada saída
Andrinos - Pombal	Hora seguinte	1	7	1
	Dia seguinte	24	7	1
	Semana seguinte	24	6	1

Para determinar a melhor opção quanto ao número de neurónios na camada oculta, foram estabelecidos vários treinos da rede para cada hora específica, incrementando o número de neurónios da camada oculta e determinando o erro médio absoluto percentual (MAPE) para os dados de treino e teste. Efetuaram-se cinco treinos, de um a dez neurónios para o dia e semana seguinte e de um a vinte neurónios para a hora seguinte, avaliando a tendência dos resultados para cada treino. A escolha do número de neurónios incidiu sobre o treino que apresentou o menor erro MAPE para os dados de teste. No Anexo I, encontram-se os resultados para cada treino efetuado, de acordo com o erro MAPE e a escolha corresponde para cada hora. Na Tabela 3, Tabela 4 e Tabela 5 são apresentados os resultados obtidos, de forma resumida, em função do tipo de previsão.

Tabela 3 – Número de neurónios na camada oculta para a hora seguinte

Tipo de previsão	Hora	Número de neurónios	Menor MAPE (%) verificado para teste
Hora seguinte	1 a 24	2	5,019%

Tabela 4 – Número de neurónios na camada oculta para o dia seguinte

Tipo de previsão	Hora	Número de neurónios	Menor MAPE (%) verificado para teste
Dia seguinte	1	1	7,552
	2	1	7,648
	3	6	8,230
	4	2	7,838
	5	3	8,463
	6	4	8,984
	7	1	7,597
	8	1	8,636
	9	2	8,095
	10	8	7,849
	11	1	8,157
	12	1	8,394
	13	9	7,490
	14	10	6,543
	15	10	6,017
	16	7	6,903
	17	4	6,260
	18	7	7,578
	19	6	7,203
	20	6	6,253
	21	9	6,495
	22	8	6,272
	23	3	6,919
	24	8	7,021

Tabela 5 – Número de neurónios na camada oculta para a semana seguinte

Tipo de previsão	Hora	Número de neurónios	Menor MAPE (%) verificado para teste
Semana seguinte	1	2	6,898
	2	7	6,588
	3	4	6,994
	4	2	6,151
	5	9	7,766
	6	3	7,410
	7	4	6,696
	8	6	9,162
	9	6	8,498
	10	9	9,420
	11	10	8,718
	12	3	8,039
	13	1	7,066
	14	2	7,570
	15	3	8,100
	16	9	9,031
	17	5	8,386
	18	3	8,483
	19	10	8,647
	20	3	6,797
	21	5	6,804
	22	2	5,946
	23	7	6,201
	24	5	6,722

Nos modelos do Anexo I, encontram-se destacados os menores erros MAPE para treino (cinzento claro) e para teste (cinzento escuro) de acordo com o número de neurónios. Os dados relativos ao menor MAPE de treino da previsão da semana seguinte, poderiam ser utilizados como termo de comparação de custo final entre o período de treino e o período de teste. Tal não foi possível, pelo facto de não ter disponível os dados relativos aos preços de mercado futuro relativamente a Portugal.

Concluído todo o processo da seleção do número de neurónios e da respetiva rede, procedeu-se à análise dos erros obtidos. Nas figuras seguintes encontram-se os gráficos relativos aos erros absolutos percentuais obtidos para cada tipo de previsão. Destacam-se alguns picos de maior relevância, originados principalmente devido ao período natalício em causa. Uma possível forma de correção seria considerar diferentes parâmetros de entrada para estas situações atípicas, como uma variável binária para distinguir a ocorrência destes dias atípicos, induzindo a rede a ter um comportamento diferenciado para estes eventos.

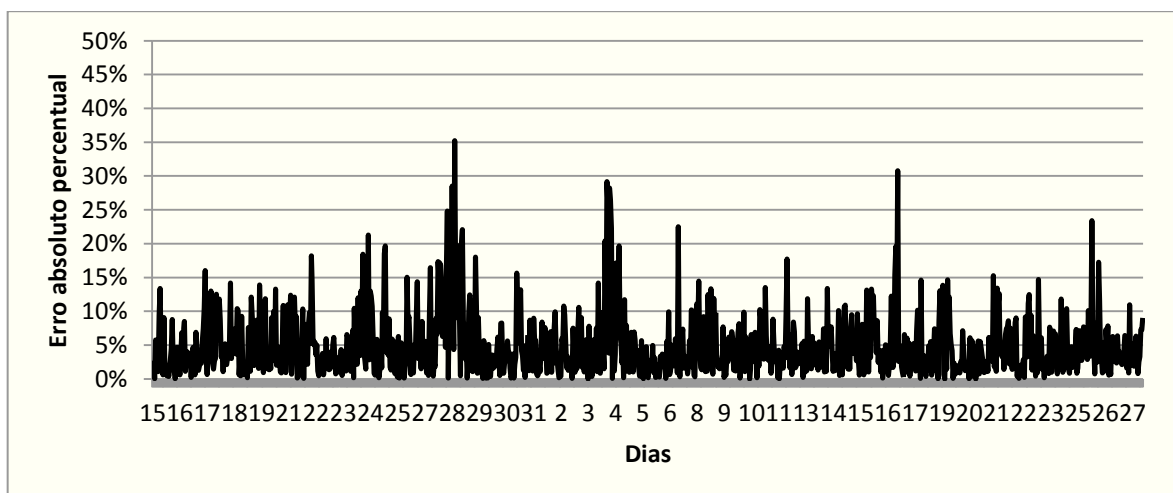


Figura 32 - Erros absolutos percentuais da previsão da hora seguinte das redes neuronais




Figura 33 - Erros absolutos percentuais da previsão do dia seguinte das redes neuronais




Figura 34 - Erros absolutos percentuais da previsão da semana seguinte das redes neuronais

4.3.2 Regressão linear múltipla

Os mesmos dados foram usados para testar uma aplicação do método de regressão linear múltipla.

Como referido no capítulo 3, subcapítulo 3.5.2, este processo implica normalizar os dados, determinar os parâmetros de regressão, calcular os novos dados de teste e recuperar os novos dados a partir dos dados normalizados obtidos.

No algoritmo desenvolvido para este método optou-se por abordar duas situações distintas. A primeira passa pela utilização da totalidade dos dados de treino disponíveis. A segunda passa por utilizar apenas 80% dos dados de treino para determinar os parâmetros, tornando o processo mais aproximado aos testes efetuados tanto pelas redes neuronais artificiais como também pelas máquinas de suporte vetorial, onde existe a divisão em dados de treino e dados de validação. Tratando-se de um método linear, consequentemente menos robusto, é expectável que os erros aumentem de acordo com um menor número de dados disponíveis como entradas do método. Contudo, existem situações onde acontece a situação inversa, uma vez que os dados considerados na amostra total podem influenciar negativamente os cálculos dos parâmetros. Os resultados obtidos para cada tipo de previsão, em termos de erros absolutos percentuais para os dois tipos de divisão de dados de treino, encontram-se nas figuras seguintes.

As entradas selecionadas para este método são análogas às descritas anteriormente pelo método das redes neuronais.




Figura 35 – Erros absolutos percentuais da previsão da hora seguinte de regressão linear




Figura 36 - Erros absolutos percentuais da previsão do dia seguinte de regressão linear




Figura 37 - Erros absolutos percentuais da previsão da semana seguinte de regressão linear

Os resultados obtidos, em termos de erro MAPE, encontram-se na Tabela 6. Destaca-se uma diminuição do erro na semana seguinte face ao dia seguinte. Esta situação pode ocorrer de acordo com as entradas selecionadas para cada tipo de previsão, as quais poderão influenciar negativamente o processo.

Tabela 6 – Erros MAPE obtidos em função do tipo de previsão

Tipo de previsão	Percentagem de utilização de dados	Erro MAPE (%)
Hora seguinte	80%	6,04
	100%	6,03
Dia seguinte	80%	7,24
	100%	8,06
Semana seguinte	80%	6,99
	100%	7,71

Tratando-se de método linear, não existindo processos iterativos como nas RNA, os parâmetros determinados para o conjunto de entradas e saídas testadas são iguais para um número infinito de simulações, não sendo necessário efetuar reinicializações de pesos ou desvios. Ao contrário das RNA e SVM, as simulações finais obtidas pelo método de regressão linear múltipla correspondem efetivamente aos dados a utilizar para determinar os erros finais e respetivo impacto económico.

4.3.3 Máquinas de Suporte Vetorial com seleção de parâmetros pelo Simulated Annealing

Por último foram ainda aplicados modelos baseados em máquinas de suporte vetorial (SVM). A configuração das SVM para a previsão de consumos recorreu a uma otimização através de uma abordagem baseada na meta heurística *Simulated Annealing*. Esta meta heurística é constituída por um software específico, que corre em paralelo com o programa.

Tal como nos casos anteriores, foi necessário normalizar os dados, dividir os dados, determinar os parâmetros com recurso ao *Simulated Annealing*, calcular os novos dados de teste e recuperar os novos dados a partir dos resultados normalizados obtidos.

Para uma perceção mais clara deste método à amostra em causa, foram definidos alguns passos importantes como:

1. Descrição da meta-heurística *Simulated Annealing*
2. Utilização do Simulated Annealing na previsão
3. Determinar novos dados de simulação

Simulated Annealing (SA) é uma das técnicas mais antigas, entre as metas heurísticas, e um dos primeiros algoritmos com uma estratégia explícita para precaver os ótimos locais (Dorigo, 2004). A ideia base de todo o processo passa por aceitar algumas soluções que pioram a função objetivo, de modo a afastar-se de ótimos locais.

O algoritmo é inicializado por uma solução inicial (X_0), geralmente aleatória, e pela definição de uma temperatura inicial (T_0). A solução atual é substituída por uma nova solução vizinha e o conceito da procura de uma nova solução é baseada na temperatura do processo. São aceites novas soluções $f(s')$ que resultem numa melhoria da função objetivo, havendo a possibilidade de aceitar, de acordo com uma determinada probabilidade, soluções que resultem numa degradação da função objetivo, ou seja, é aceite uma nova solução se $f(s') < f(s)$, ou no caso de $f(s') \geq f(s)$ mas apenas para alguns casos, de acordo com probabilidade de aceitação. A probabilidade é calculada a partir da distribuição de Boltzmann (Dorigo, 2004), através da seguinte expressão, no caso de objetivo a minimizar:

$$p = \exp \frac{-(f(s')-f(s))}{T} , \quad (23)$$

em que,

- p corresponde à probabilidade de aceitação de uma nova solução,
- $f(s')$ corresponde à nova solução,
- $f(s)$ corresponde à solução atual,
- T corresponde à temperatura do processo,

No início de todo o processo da procura de novas soluções, a temperatura (T) é elevada, pelo que a probabilidade de aceitação é também ela elevada. Com o decorrer do processo, a temperatura vai diminuindo gradualmente, convergindo para um algoritmo iterativo de aperfeiçoamento do processo. Com todas as mais-valias já referidas, é possível contornar os ótimos locais e analisar um espaço de soluções mais vasto. Porém, não existe a garantia de que se trata de um ótimo local ou de um ótimo global, sendo necessário efetuar a repetição do processo. Para evitar este problema existe um processo designado de *reannealing*, que permite executar uma dispersão dos dados para procurar novas soluções no espaço dimensional, melhorando a função objetivo e respetiva aceitação de novas soluções.

Uma possível abordagem ao algoritmo SA encontra-se esquematizada da seguinte forma:

- **Definir solução inicial aleatória X_0**
- **Definir temperatura inicial T_0**
- **Cálculo da função objetivo $f(X_T)=f(X_0)$**
- **Enquanto as condições de paragens não forem cumpridas**
 - Escolha de solução vizinha X_{T+1}
 - Cálculo da nova função objetivo $f(X_{T+1})$
 - Se nova solução $f(X_{T+1}) < f(X_T)$ ou se n° aleatório $[0;1] < \left(\frac{1}{1+\exp \frac{f(X_{t+1})-f(X_t)}{T}} \right)$:
 - $X_T = X_{T+1}$
 - Senão:
 - $X_T = X_T$
 - Atualização da temperatura: $T_{t+1} = T_0 \times 0.95^{n^\circ \text{ combinações}}$
- **Fim do processo**

No algoritmo exemplificado verifica-se o decréscimo da temperatura do processo (enquanto não existir a operação de *reannealing*) à medida que vão sendo testadas novas soluções. A probabilidade de aceitação das novas soluções tende a ser mais elevada quando a diferença entre soluções consecutivas é pequena ou quando a temperatura do processo ainda permanece em valores elevados. Com a diminuição da temperatura, o termo de Boltzmann tende para infinito, diminuindo a possibilidade de aceitação da nova solução. Para temperaturas diminutas, este processo garante uma aproximação mais ajustada a um determinado mínimo local, com um número de iterações considerável.

O principal objetivo da utilização do SA no processo de previsão de consumos, passa por encontrar a melhor combinação de parâmetros para as SVM, nomeadamente a margem de tolerância ao erro (ϵ), fator de penalização (C) e parâmetro da função gaussiana (γ). Estes parâmetros são depois utilizados nas máquinas de suporte vetorial, permitindo obter os melhores resultados para os dados que estão sujeitos ao modelo. Na Figura 38 encontra-se a metodologia adotada para as SVM.

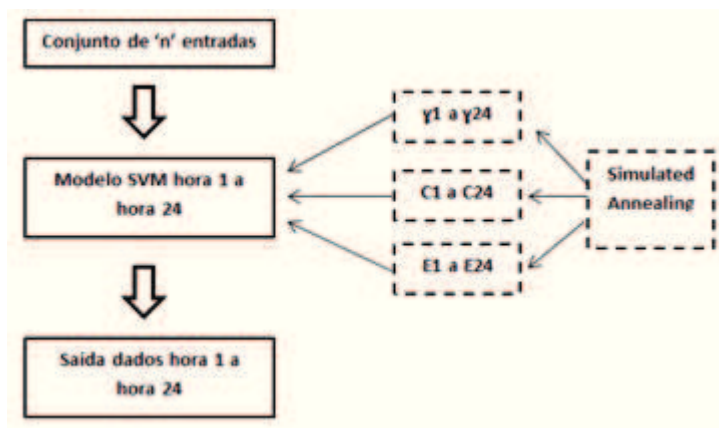


Figura 38 – Metodologia da previsão das máquinas de suporte vetorial

Foram estabelecidos três algoritmos de acordo com o tipo de previsão pretendida, hora seguinte (HS), dia seguinte (DS) e semana seguinte (SS). Cada um dos três algoritmos possui três ficheiros de código. O primeiro corresponde ao ficheiro principal, designado de '*Simula_SVM*', que inclui uma parte inicial com o carregamento de todos os dados necessários da amostra e onde é efetuada a normalização e segmentação dos dados, utilizando a mesma estratégia utilizada nas redes neuronais para tornar o processo comparável. A segunda parte usa o SA para apurar os parâmetros. A parte final diz respeito ao processo de retorno ao ficheiro principal já com os melhores parâmetros determinados, correspondendo assim à execução do processo de previsão.

O segundo ficheiro, designado de '*SimulatedAnnealing*', corresponde à função específica da meta-heurística do SA, utilizando a função '*simulannealbnd()*'¹⁵ específica do Matlab, e estabelecendo as opções pretendidas para o processo. Como opções é estabelecida a temperatura inicial do processo, o número de iterações para o '*reannealing*', o número máximo de iterações, a solução inicial e a gama de variação relativamente aos parâmetros a estimar. O terceiro e último ficheiro, designado de '*Apura_erroes_SVM*', implementa o apuramento dos erros relativos a cada iteração do processo de SA, guardando os melhores parâmetros encontrados ao longo das iterações.

Na Figura 39 encontra-se ilustrada toda a estrutura do algoritmo explicado anteriormente.

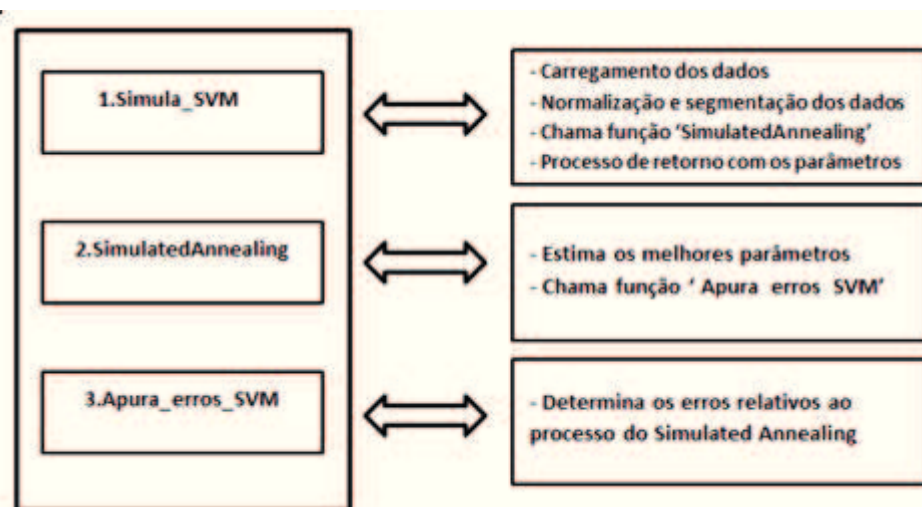


Figura 39 – Funcionamento genérico do algoritmo

As opções tomadas para o processo do SA, que tornam o processo mais ajustado possível à situação pretendida, contemplam as seguintes características:

- **Temperatura inicial:** 1000
- **Intervalo de '*reannealing*':** 50 iterações
- **Número máximo de iterações:** variável
- **Solução inicial para o parâmetro da função Gaussiana (γ) :** 2*numero aleatório entre 0 e 1
- **Solução inicial para o fator de penalização (C):** 15*numero aleatório entre 0 e 1
- **Solução inicial para a margem de tolerância ao erro (ϵ):** 0.5*numero aleatório entre 0 e 1
- **Gama de variação dos parâmetros:** $\gamma \in [0;2]$, $C \in [0;15]$ e $\epsilon \in [0;0.5]$

¹⁵ Para mais informações acerca da função '*simulannealbnd*', poderá consultar a seguinte página web: <http://www.mathworks.com/help/gads/simulannealbnd.html>

Quanto ao número máximo de iterações foram efetuados testes para 100, 300 e 500 iterações, selecionando a opção com os melhores resultados em função do erro MAPE.

Após a aquisição dos parâmetros apropriados, correspondentes à margem de tolerância ao erro (ϵ), ao fator de penalização (C) e ao parâmetro da função Gaussiana (γ), procedeu-se à simulação dos novos dados.

No Anexo II encontram-se os erros MAPE obtidos em função do tipo de previsão. O erro MAPE mais baixo para a hora seguinte (HS) ficou em 4,75% para 300 iterações, para o dia seguinte (DS) ficou em 5,89% correspondendo a 500 iterações e para a semana seguinte (SS) ficou em 6,05% correspondendo a 300 iterações. Nas figuras seguintes são apresentados os resultados graficamente, dos melhores resultados obtidos para as SVM.




Figura 40 - Erros absolutos percentuais da previsão da hora seguinte das máquinas suporte vetorial

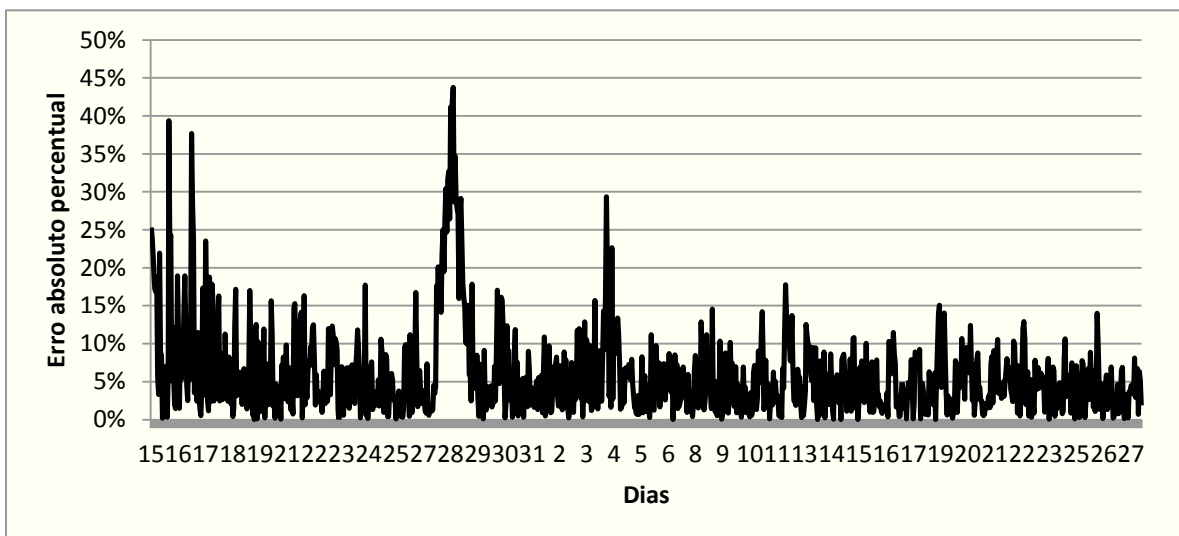


Figura 41 - Erros absolutos percentuais da previsão do dia seguinte das máquinas suporte vetorial

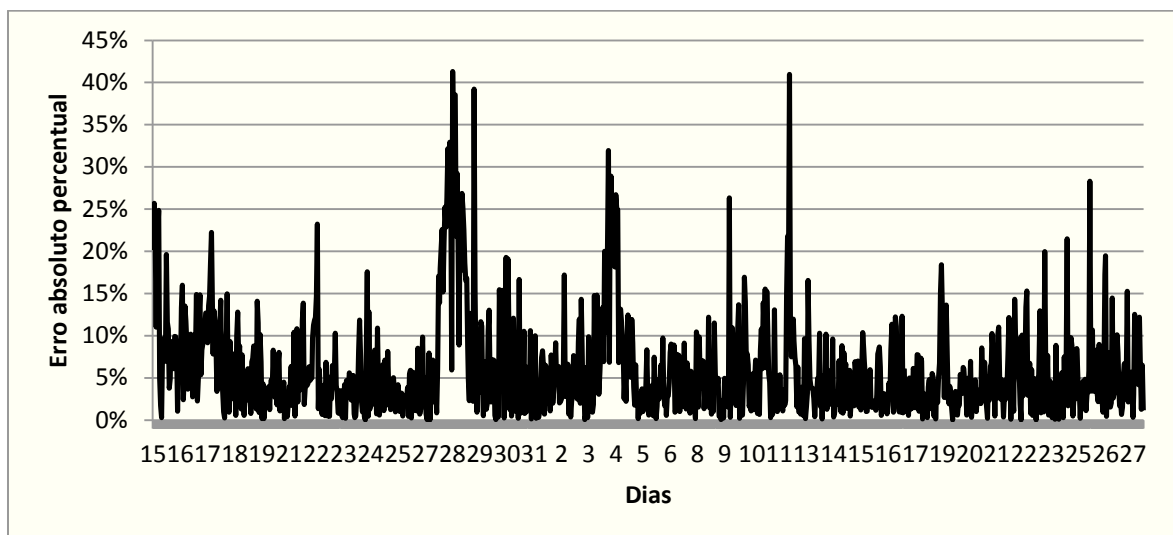


Figura 42 - Erros absolutos percentuais da previsão da semana seguinte das máquinas suporte vetorial

Também nas máquinas de suporte vetorial são visíveis picos de erros, provocados principalmente pelos períodos festivos.

4.3.4 Comparação entre métodos de previsão

Nas figuras seguintes encontram-se os resultados para a hora seguinte, dia seguinte e semana seguinte para os diversos métodos de previsão com os correspondentes erros MAPE para cada situação. A nomenclatura 'RL' significa regressão linear, 'RNA' corresponde a redes neuronais artificiais e 'SVM' a máquinas de suporte vetorial.




Figura 43 - Erros absolutos percentuais da previsão da hora seguinte dos múltiplos métodos de previsão




Figura 44 - Erros absolutos percentuais da previsão do dia seguinte dos múltiplos métodos de previsão

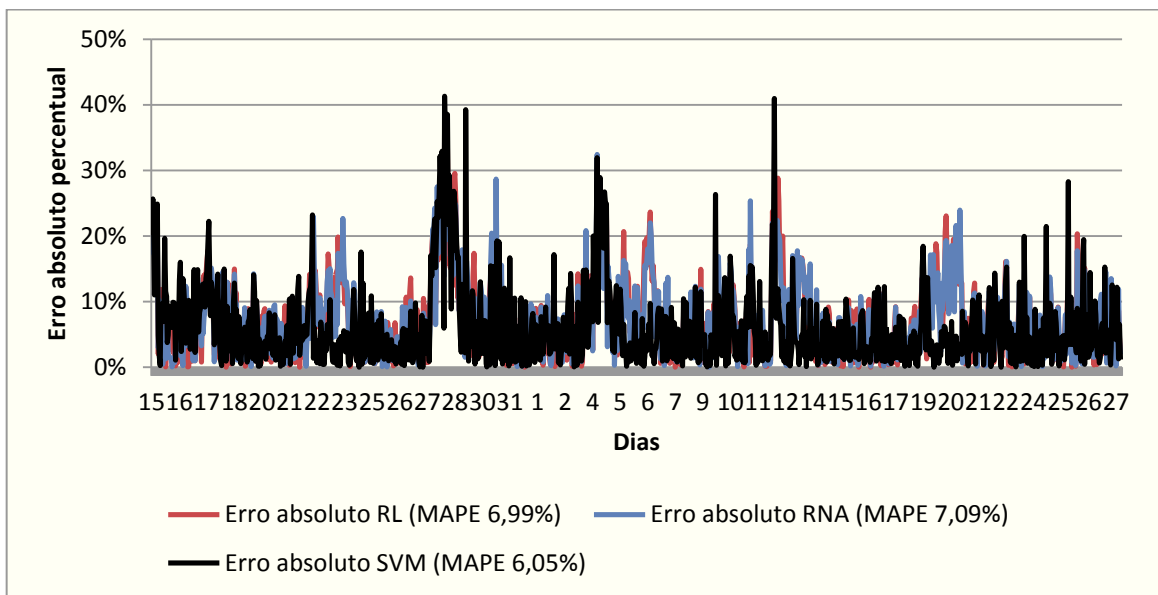


Figura 45 - Erros absolutos percentuais da previsão da semana seguinte dos múltiplos métodos de previsão

Após a análise dos gráficos comparativos verificou-se que os resultados se encontram dentro do esperado, sendo possível concluir que o erro MAPE aumenta de acordo com o aumento do horizonte temporal. Os erros absolutos do método de regressão linear (RL) tendem a ser superiores aos erros absolutos das redes neurais artificiais (RNA), que por vez são superiores aos erros absolutos das máquinas de suporte vetorial (SVM). Também se verifica um aumento dos erros absolutos nos períodos festivos, como o Natal e os meses de férias de julho e agosto, que contribuem significativamente para o aumento do erro MAPE final em cada método.

4.3.5 Combinação de métodos de previsão

Depois de estudados e aplicados os métodos de previsão propostos, optou-se por testar se eventuais combinações dos resultados de consumos dos métodos utilizados para a semana seguinte permitiria reduzir o erro final MAPE, e porventura, também os custos associados à penalização final.

Num primeiro passo foram testados vários ponderadores para cada método. Foi estabelecida a nomenclatura 'RNAp' para o ponderador correspondente às redes neuronais artificiais, 'RLp' para a regressão linear e 'SVMp' para as máquinas de suporte vetorial. Dado que o erro MAPE é mais reduzido nas máquinas de suporte vetorial, é expectável que uma maior percentagem relativa aos dados obtidos pelas SVM corresponda a um melhor resultado final. Analiticamente, foram testadas algumas combinações por forma a ter uma perceção da evolução dos resultados, determinando o consumo total pela multiplicação dos respetivos ponderadores pelos métodos. A expressão utilizada foi a seguinte:

$$f = (RNA_j \times RNA_p) + (RL_j \times RL_p) + (SVM_j \times SVM_p), \quad (24)$$

em que,

f	corresponde ao resultado obtido pela combinação dos métodos ,
$RNA_j \times RNA_p$	corresponde à multiplicação do ponderador 'p' pelo consumo 'j' obtido a partir de modelos baseados em redes neuronais artificiais,
$RL_j \times RL_p$	corresponde à multiplicação do ponderador 'p' pelo consumo 'j' obtido a partir de modelos baseados em regressão linear,
$SVM_j \times SVM_p$	corresponde à multiplicação do ponderador 'p' pelo consumo 'j' obtido a partir de modelos baseados em máquinas de suporte vetorial,

Após a experiência com alguns ponderadores de teste, procedeu-se à elaboração de um algoritmo no Matlab que permitisse realizar todo o processo de procura dos ponderadores que levam à solução ótima, apresentando o erro MAPE inferior. Para isso foi utilizada novamente a meta heurística *Simulated Annealing*, como processo idêntico ao utilizado nas máquinas de suporte vetorial.

O algoritmo elaborado inclui uma parte inicial onde são carregados os dados relativos aos consumos da semana seguinte das redes neuronais artificiais, regressão linear e máquinas de suporte vetorial. Depois é iniciado o processo de procura dos parâmetros com *Simulated Annealing*, que minimizam o erro MAPE de acordo com a melhor solução possível. À medida que vão sendo testados novos parâmetros, é necessário garantir que a soma dos respetivos ponderadores é unitária, obtendo resultados fiáveis e ajustados ao caso. Para garantir esta situação cada ponderador deve ser dividido pela soma dos três ponderadores.

As opções tomadas para o processo do SA, que tornam o processo mais ajustado possível à situação pretendida, contemplam as seguintes características:

- **Temperatura inicial:** 500
- **Intervalo de *'reannealing'*:** 20 iterações
- **Número máximo de iterações:** 1000
- **Solução inicial para RNA_p :** número aleatório entre 0 e 1
- **Solução inicial para RL_p :** número aleatório entre 0 e 1
- **Solução inicial para SVM_p :** número aleatório entre 0 e 1
- **Gama de variação dos parâmetros:** $RNA_p \in [0;1]$, $RL_p \in [0;1]$ e $SVM_p \in [0;1]$

Neste caso específico, onde os ponderadores a encontrar se aproximam mais rapidamente de um mínimo local, optou-se por uma temperatura inicial inferior, um intervalo de *reannealing* inferior e um número de iterações superior, face ao uso de SA para determinação de parâmetros em modelos SVM. A gama de variação dos ponderadores encontra-se entre 0 e 1, cuja soma será unitária, correspondendo a uma percentagem a atribuir a cada método na previsão final do conjunto dos métodos.

Na Figura 46 encontra-se uma ilustração do decorrer do processo de SA, apresentando o resultando final que permitiu minimizar o erro MAPE até se atingir o número máximo de iterações estabelecido. A designação '*Best Point*' representa o melhor resultado até ao instante atual, '*Current Point*' representa o resultado atual dos ponderadores, '*Best function level*' corresponde ao melhor resultado obtido para o erro MAPE, '*Current function level*' corresponde ao valor atual do erro MAPE e '*Current temperature*' representa a temperatura atual do processo que é inicializada a cada opção de *reannealing*. Destaca-se uma grande contribuição dos dados relativos às SVM face aos restantes métodos, dado que as SVM já possuíam o erro MAPE mais baixo no conjunto dos métodos.

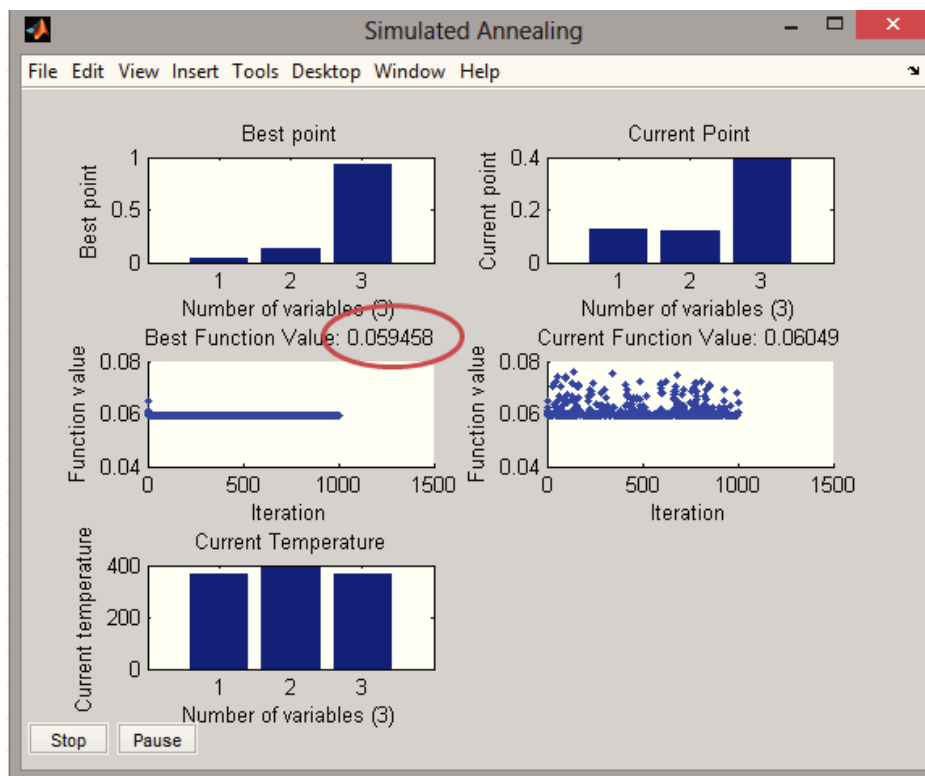


Figura 46 – Resultado final obtido que minimiza o erro MAPE

Os ponderadores finais obtidos que resultam no erro MAPE minimizado, foram os seguintes:

- RNAp \approx 0,037
- RLp \approx 0,123
- SVMp \approx 0,840

Na Tabela 7 encontram-se os resultados finais obtidos relativamente à previsão da semana seguinte pela conjugação dos métodos, que permitiu obter um erro MAPE inferior face à utilização de cada método isoladamente.

Tabela 7 – Erros MAPE obtidos em função do método de previsão para a semana seguinte

Método de previsão	Erro MAPE (%)
Redes neuronais artificiais (RNA)	7,08
Regressão linear (RL)	7,71
Máquinas de suporte vetorial (SVM)	6,05
Combinação de métodos (RNA+RL+SVM)	5,95

5 Discussão de resultados económicos da previsão de consumos

Neste capítulo serão apresentados e discutidos os resultados obtidos da avaliação económica resultante dos erros obtidos para a previsão semanal.

5.1 Recolha de dados

Antes da avaliação do impacto económico, resultante dos erros decorrentes da utilização dos métodos de previsão exemplificados anteriormente, é necessário efetuar a recolha dos dados relativos aos preços da energia no mercado spot e os preços da energia nos mercados futuros, cujos dados foram retirados do mercado ibérico de eletricidade, pólo português¹⁶ (OMIP). Serão igualmente retirados os preços de compensação pela entidade responsável (OMIClear), também designados de preços de *clearing*¹⁷. Porém, a sua fundamentação e abordagem não ficaram totalmente explícitas e claras para o fim pretendido, não desprezando eventuais penalizações adicionais que possam surgir da utilização dos preços de compensação.

Depois de retirados todos os dados necessários, através de folhas de cálculo *Excel*, foi necessário analisar e organizar os dados de acordo com o horizonte temporal pretendido, de 15 de agosto de 2009 a 27 de setembro de 2009, correspondendo aos 44 dias do período de teste que serão alvo da avaliação económica.

Por fim, elaborou-se um gráfico comparativo com os preços spot, futuros e compensação de modo a observar e despistar eventuais dados nulos ou dados muito superiores ao esperado. O gráfico obtido encontra-se na Figura 47.

¹⁶ Para a recolha dos preços spot e preços dos mercados futuros poderá aceder à seguinte página web: <http://www.omip.pt/Downloads/tabid/104/language/pt-PT/Default.aspx>

¹⁷ Para a recolha dos preços de *clearing* poderá aceder à seguinte página web: <http://www.omiclear.pt/Downloads/tabid/170/language/pt-PT/Default.aspx>




Figura 47 – Preços da energia no mercado spot, mercado futuro e de compensação para o período compreendido entre 15/08/2009 a 27/09/2009

Com base na figura anterior, verifica-se que não existem anomalias com os dados retirados. Destaca-se a variação dos preços spot ao longo dos vários dias, dado que este preço é estabelecido para a hora seguinte através dos preços e condições de mercado anteriores, resultando numa oscilação do preço ao longo de todo o período. Os preços dos mercados futuros tendem a ser estabelecidos num período não inferior a uma semana, representando a tendência dos consumos e respetivos preços para uma determinada semana. Os preços de compensação representam as penalizações para as empresas, resultantes dos erros de previsão por defeito ou por excesso.

5.2 Avaliação económica do impacto da acuidade na previsão semanal

Dado que os preços tendem a ser superiores à medida que nos aproximamos da data de entrega e negociação da energia transacionada, serão analisados os impactos económicos na previsão semanal de acordo com os métodos utilizados, nomeadamente as redes neuronais, regressão linear e máquinas de suporte vetorial. Serão também alvo de avaliação os resultados obtidos pela conjugação dos três métodos utilizados.

Para o cálculo do custo associado ao erro de previsão para a semana seguinte proveniente do método baseado nas redes neuronais, inicialmente determinou-se a diferença de energia entre o valor real e o valor previsto, em MWh. Posteriormente determinou-se o custo, em €, associado a essa diferença. Para o cálculo do custo é necessário ter em consideração se o valor previsto é em excesso ou por defeito, face ao consumo verificado.

Se o valor previsto for superior ao consumo real, isso significa que a energia negociada na semana anterior será excessiva face à realidade verificada, sendo esse excesso contabilizado no preço comercializado à data. Caso o valor previsto seja inferior ao consumo real, isso significa que a energia negociada na semana anterior foi inferior às necessidades, sendo necessário efetuar nova transação ao preço verificado no momento, o preço spot.

A expressão a utilizar perante uma situação em que a previsão é superior ao valor real é a seguinte:

$$c1 = (\text{valor}_{\text{previsto}} - \text{valor}_{\text{real}}) \times \text{preço}_{\text{futuro}} \quad (25)$$

em que,

$c1$ corresponde ao custo associado ao erro por excesso, em € ,

$\text{valor}_{\text{real}}$ corresponde ao valor real verificado, em *MWh*,

$\text{valor}_{\text{previsto}}$ corresponde ao valor previsto, em *MWh*,

$\text{preço}_{\text{futuro}}$ corresponde ao preço da energia no mercado futuro, em €/MWh.

A expressão a utilizar perante uma situação em que a previsão é inferior ao valor real é a seguinte:

$$c2 = (\text{valor}_{\text{real}} - \text{valor}_{\text{previsto}}) \times \text{preço}_{\text{spot}} \quad (26)$$

em que,

$c2$ corresponde ao custo associado ao erro por defeito, em € ,

$\text{valor}_{\text{real}}$ corresponde ao valor real verificado, em *MWh*,

$\text{valor}_{\text{previsto}}$ corresponde ao valor previsto, em *MWh*,

$\text{preço}_{\text{spot}}$ corresponde ao preço spot da energia, em €/MWh.

Com base nas expressões definidas anteriormente, procedeu-se aos cálculos necessários para apurar a penalização associada à previsão da semana seguinte das redes neuronais artificiais, regressão linear e máquinas de suporte vetorial. Na tabela seguinte encontram-se os resultados do impacto económico obtido para cada método separadamente.

Tabela 8 – Penalizações do período de teste associadas aos métodos de previsão para a semana seguinte

Método de previsão	Penalização (€)
Redes neuronais artificiais	9715
Regressão linear	10424
Máquinas de suporte vetorial	8667,7

Com base na Tabela 8, verifica-se que a penalização resultante das máquinas de suporte vetorial é bastante inferior aos restantes métodos. Seria expectável que tal situação se verificasse, dado que o erro final MAPE obtido também era inferior. Contudo, poderão existir situações em que os erros obtidos não se reflitam necessariamente em penalizações inferiores, uma vez que os preços spot e preços de mercado futuro sofrem oscilações ao longo do período, ocorrendo situações em que pequenos erros originam grandes penalizações e situações em que erros elevados originem pequenas penalizações. Estas situações resultam na tendência do aumento dos preços ao longo do período diurno e uma pequena diminuição ao longo do período noturno.

Para avaliar de forma mais pormenorizada todos os acontecimentos referidos anteriormente e verificar os dias/semanas em que se ocorrem as maiores penalizações, procedeu-se à análise gráfica dos dados para cada método de previsão, ao longo dos 44 dias. No Anexo III encontram-se gráficos ilustrativos para períodos de quatro horas ao longo dos dias, para que seja possível analisar de forma mais adequada as influências das penalizações ao longo das várias horas do dia.




Figura 48 – Penalizações associadas às redes neuronais artificiais




Figura 49 - Penalizações associadas à regressão linear




Figura 50 - Penalizações associadas às máquinas de suporte vetorial

Analisando de forma mais pormenorizada as penalizações correspondentes a cada método, para as situações real > previsto e previsto > real, foram determinadas as penalizações totais associadas a cada situação separadamente. Na Tabela 9 encontram-se os resultados obtidos.

Tabela 9 – Penalizações totais (real > previsto e previsto > real) para os vários métodos

Situação	Preço utilizado	RNA	RL	SVM
Real > Previsto	Spot	5144,3€	5157,9€	4971,9€
Previsto > Real	Futuro	4570,6€	5266,0€	3695,8€
Total		9715€	10424€	8667,7€

Na tabela anterior é possível verificar que as maiores penalizações e maiores diferenças, ocorrem maioritariamente quando o consumo real é superior à previsão efetuada, à exceção da regressão linear onde as penalizações se tendem a aproximar.

Determinados os ponderadores ótimos para a situação em que o erro MAPE é o mais baixo possível, procedeu-se ao cálculo e análise económica pela conjugação dos três métodos.

O erro MAPE obtido foi de 5,95%, inferior a qualquer um dos métodos separadamente. O custo final obtido fixou-se em 8532,2€, também ele inferior ao melhor dos casos para a utilização de apenas um método isoladamente. Os resultados em termos dos custos/penalizações associadas no conjunto de dados, encontra-se na Figura 51. Verifica-se a permanência de alguns picos semelhantes aos apresentados anteriormente. Contudo, pela combinação de métodos foi possível mitigar esses mesmos erros, tornando a opção de combinação de métodos de previsão bastante útil para diminuição de custos para as empresas e otimização de todo o processo inerente à própria previsão.




Figura 51 – Penalização associada à conjugação de métodos (RNA+RL+SVM)

Na tabela seguinte encontram-se os resultados das penalizações para as duas situações, previsão por defeito e por excesso. Na combinação de métodos mantém-se a tendência de custos superiores para situações em que o consumo real se encontra superior ao previsto.

Tabela 10 – Penalizações totais (real > previsto e previsto > real) para a combinação de métodos

Situação	RNA+RL+SVM
Real > Previsto	4811,5€
Previsto > Real	3720,8€
Total	8532,2€

Em termos de relação entre as penalizações dos erros obtidos e os custos totais da energia (contabilizados ao custo spot de mercado), obtiveram-se os resultados apresentados na tabela seguinte.

Tabela 11 – Relação entre penalização do erro e o custo total da energia

	Custo total energia	Custo penalização	Relação
RNA	143884,3€	9715€	6,75%
RL		10424€	7,24%
SVM		8667,7€	6,02%
RNA+RL+SVM		8532,2€	5,93%

Na Tabela 11 verifica-se claramente a influência que os erros obtidos pela previsão de consumos originam na operação diária do setor elétrico. Percentagens entre 5% a 7% do custo total da energia vendida, correspondem efetivamente a custos que podem ser precavidos pela aplicação de técnicas que permitam reduzir ao máximo essas diferenças. Demonstra-se que é possível poupar cerca de 1% pela utilização de um método mais eficaz relativamente ao pior dos casos, existindo margem para melhorar os resultados com erros inferiores aos obtidos.

Para avaliar de forma mais pormenorizada todos os acontecimentos referidos anteriormente e verificar as horas do dia em que ocorrem as maiores penalizações, procedeu-se à análise gráfica dos dados de previsão, ao longo dos 44 dias. No Anexo IV encontram-se gráficos ilustrativos para todas as horas dos vários dias, para que seja possível analisar de forma mais pormenorizada as influências das penalizações ao longo das várias horas do dia. Verificam-se maiores penalizações nos períodos diurnos, principalmente devido aos maiores consumos e maiores preços nesses períodos, onde pequenos erros originam custos superiores.

6 Conclusão

O objetivo deste trabalho passava pelo estudo do impacto económico originado pelos erros de previsão com base na aplicação de métodos e técnicas de previsão de consumos do setor elétrico português, usando como estudo de caso os consumos medidos na subestação de Andrinos, situada em Leiria. Efetuaram-se previsões a curto e médio prazo, com base em métodos estatísticos, como a regressão linear, e em métodos de inteligência artificial, como as redes neuronais artificiais e máquinas de suporte vetorial. Utilizaram-se dados históricos de consumo de energia elétrica da subestação, no período compreendido entre 1 de julho de 2008 a 27 de setembro de 2009.

Os dados meteorológicos foram também testados para um determinado período temporal, de forma a inferir se os resultados obtidos eram favoráveis e apresentavam melhorias. Verificou-se que a sua inclusão dos dados meteorológicos como entradas dos modelos não contribuía de forma significativa para uma melhoria do erro MAPE final, optando pela não utilização dos mesmos. Com base em artigos científicos e estudos recentes, verificou-se também que a influência da temperatura nos processos de previsão não melhorou significativamente os resultados (Fidalgo & Matos, 2007).

A amostra em causa caracterizava-se por corresponder a um elevado aglomerado populacional com algum significado e períodos festivos, tornando o comportamento de um utilizador em particular pouco expressivo nos resultados da previsão.

Para uma correta tarefa de previsão de consumos é fundamental efetuar uma análise preliminar da amostra em causa, detetando eventuais anomalias nos dados recolhidos e forma de os corrigir, evitando erros atípicos nos dados obtidos. Foi necessário proceder à correção de algumas anomalias, adotando uma estratégia de tratamento de dados com base em dados de períodos homólogos. Esta tarefa pode tornar-se complicada em situações mais complexas, devendo procurar-se uma forma de minimizar as consequências destes fenómenos sem este pré-processamento, ou através de uma forma sistemática de o fazer. Um trabalho futuro pode assim passar pela definição desta estratégia.

Os métodos de previsão propostos aplicados ao caso de estudo permitiram obter melhores resultados para a hora seguinte e dia seguinte nas máquinas de suporte vetorial, seguido das redes neuronais artificiais e da regressão linear. Já na previsão da semana seguinte obtiveram-se melhores resultados também para as máquinas de suporte vetorial, e com uma ligeira melhoria da regressão linear face às redes neuronais artificiais.

Esta ocorrência deve-se essencialmente à escolha das entradas para os modelos, onde para a previsão da semana seguinte, as entradas selecionadas na regressão linear encontraram-se mais ajustadas ao horizonte temporal estabelecido. Uma abordagem para trabalho futuro seria a aplicação da meta-heurística '*Simulated Annealing*' na seleção das entradas para os modelos de previsão, por forma a avaliar a importância destas técnicas em conjunto com os modelos de previsão.

Como seria expectável, os melhores resultados para a semana seguinte, foram obtidos pela combinação dos métodos de previsão utilizados no estudo, permitindo agregar as capacidades das redes neuronais artificiais e máquinas de suporte vetorial em lidar com não linearidades, com as vantagens próprias da regressão linear. Para a determinação dos ponderadores percentuais a atribuir a cada método, utilizou-se a meta-heurística '*Simulated Annealing*'.

No que respeita a resultados para a previsão da semana seguinte, em termos de erro MAPE obteve-se 5,95% por combinação de métodos, sendo inferior a qualquer um dos métodos utilizados separadamente. Nas redes neuronais artificiais obteve-se 7,08%, na regressão linear 7,71% e nas máquinas de suporte vetorial 6,05%. Tendo em consideração a natureza da amostra e o horizonte de previsão mais alargado, os erros podem ser considerados como aceitáveis, de acordo com os obtidos por Ghanbari, Hadavandi, & Abbasian-Naghneh, 2010.

Em relação aos custos inerentes aos erros obtidos para o período compreendido entre 15 de agosto de 2009 a 27 de setembro de 2009, obteve-se um total de 9715,0€ para as redes neuronais artificiais, 10424,0€ para a regressão linear, 8667,7€ para as máquinas de suporte vetorial e 8532,2€ pela combinação de métodos. Estes custos correspondem na totalidade a erros originados pela previsão de consumos, de acordo com o método utilizado, na qual não sendo possível eliminá-los, é possível reduzi-los e minimizá-los o quanto possível pelo estudo e aplicação de novas técnicas e métodos promissores.

O valor total da energia vendida, no período de 15 de agosto de 2009 a 27 de setembro de 2009 para os 44 dias do período de teste, foi contabilizado em 143884,3€. Com estes dados, para as redes neuronais artificiais verificou-se que a penalização correspondia a 6,75% do valor total da energia, para a regressão linear cerca de 7,24%, para as máquinas de suporte vetorial cerca de 6,02% e pela combinação de métodos permaneceu em 5,93%. Verifica-se claramente a influência que os custos associados às penalizações podem ter na operação diária de um sistema elétrico de energia, com valores a variar 5 e 7% do valor total da energia vendida, correspondendo a uma parcela significativa para as empresas e consumidores.

Ao longo do trabalho foi mencionada a importância que os preços de compensação podem originar uma parcela complementar de penalização, para além da própria penalização inerente ao erro. Neste estudo não foram utilizados estes dados de compensação, dado que a sua fundamentação e abordagem não ficaram totalmente explícitas e claras, bem como a sua recolha e utilização para o fim pretendido. Contudo, não se deve descorar eventuais custos que podem advir deste facto, uma vez que podem representar valores acima de 10% de penalização sobre o valor total da energia, contabilizando a penalização do erro e a penalização associada às compensações.

Como trabalho futuro, seria interessante aplicar novas técnicas resultantes das novas tendências atuais, nomeadamente no campo da inteligência artificial e de métodos híbridos que têm vindo a demonstrar resultados promissores ao nível da previsão de consumos. Seria também importante utilizar um maior número de amostras em causa de forma a poder melhor generalizar os resultados, avaliando e comparando as diversas técnicas e introduzindo forma de corrigir eventuais anomalias.

7 Anexos

ANEXO I – Número de neurónios na camada oculta

Modelo Hora seguinte

Neurónios	Dados	Treino					Média
		1	2	3	4	5	
1	Treino	0,070819	0,071106	0,071017	0,072585	0,072525	7,161%
	Teste	0,061149	0,061438	0,061244	0,062043	0,062089	6,159%
2	Treino	0,070348	0,069117	0,066005	0,068906	0,065821	6,804%
	Teste	0,061201	0,06176	0,055942	0,060663	0,05531	5,897%
3	Treino	0,06692	0,065105	0,066064	0,063705	0,06235	6,483%
	Teste	0,058663	0,054434	0,056021	0,053774	0,054542	5,549%
4	Treino	0,063691	0,063278	0,066647	0,060992	0,063367	6,359%
	Teste	0,054305	0,053506	0,057326	0,054488	0,053944	5,471%
5	Treino	0,060894	0,06041	0,061811	0,060797	0,06051	6,088%
	Teste	0,055174	0,052625	0,054111	0,049532	0,053654	5,302%
6	Treino	0,060291	0,059749	0,059262	0,06287	0,061064	6,065%
	Teste	0,052143	0,052131	0,052243	0,054687	0,051789	5,260%
7	Treino	0,061287	0,059235	0,058663	0,060937	0,058074	5,964%
	Teste	0,053808	0,05052	0,050656	0,051848	0,050101	5,139%
8	Treino	0,063593	0,057627	0,060515	0,058787	0,058778	5,986%
	Teste	0,056078	0,05096	0,052364	0,051396	0,050299	5,222%
9	Treino	0,059031	0,058985	0,059169	0,057993	0,06092	5,922%
	Teste	0,049529	0,050371	0,051349	0,05167	0,052164	5,102%
10	Treino	0,057713	0,059257	0,05786	0,058718	0,060112	5,873%
	Teste	0,049936	0,049732	0,049852	0,049839	0,052137	5,030%
11	Treino	0,055929	0,058296	0,058306	0,058169	0,057888	5,772%
	Teste	0,050455	0,05251	0,049355	0,05117	0,050232	5,074%
12	Treino	0,057136	0,058098	0,058767	0,058363	0,057676	5,801%
	Teste	0,050108	0,051231	0,0496	0,050838	0,051626	5,068%
13	Treino	0,057631	0,058423	0,057092	0,05726	0,057294	5,754%
	Teste	0,050784	0,050404	0,050291	0,050385	0,050258	5,042%
14	Treino	0,058882	0,058157	0,057815	0,057751	0,057564	5,803%
	Teste	0,052494	0,049973	0,049813	0,051278	0,052683	5,125%

Neurónios	Dados	Treino					Média
		1	2	3	4	5	
15	Treino	0,056232	0,055464	0,056949	0,057359	0,059447	5,709%
	Teste	0,051777	0,050502	0,05007	0,049231	0,050203	5,036%
16	Treino	0,056511	0,05745	0,057279	0,056117	0,057344	5,694%
	Teste	0,05196	0,052129	0,051514	0,051357	0,05196	5,178%
17	Treino	0,059413	0,05836	0,056924	0,056841	0,055756	5,746%
	Teste	0,051583	0,050528	0,050565	0,050168	0,049242	5,042%
18	Treino	0,057725	0,056619	0,057663	0,055683	0,058094	5,716%
	Teste	0,049659	0,049335	0,051202	0,050567	0,050483	5,025%
19	Treino	0,057205	0,057306	0,060329	0,057171	0,057366	5,788%
	Teste	0,04895	0,051112	0,054494	0,049245	0,05141	5,104%
20	Treino	0,058062	0,058818	0,056101	0,057117	0,056133	5,725%
	Teste	0,049925	0,051769	0,048421	0,050935	0,049915	5,019%

Modelo Dia seguinte

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
1	1	Treino	0,11475	0,124535	0,112461	0,11535	0,12265	11,795%
		Teste	0,073138	0,078202	0,072046	0,073764	0,08044	7,552%
	2	Treino	0,12412	0,111884	0,116751	0,13333	0,109673	11,915%
		Teste	0,08797	0,085826	0,087016	0,096727	0,08282	8,807%
	3	Treino	0,118657	0,110558	0,12385	0,107238	0,110167	11,409%
		Teste	0,070499	0,082273	0,100106	0,082789	0,096574	8,645%
	4	Treino	0,109917	0,104745	0,113535	0,142351	0,115954	11,730%
		Teste	0,097357	0,075428	0,078038	0,109712	0,08784	8,968%
	5	Treino	0,127836	0,115586	0,118237	0,116474	0,122197	12,007%
		Teste	0,073204	0,090772	0,07115	0,07826	0,101414	8,296%
	6	Treino	0,157428	0,109757	0,108511	0,136474	0,141978	13,083%
		Teste	0,117	0,086675	0,056658	0,116149	0,108012	9,690%
	7	Treino	0,145925	0,111457	0,097609	0,119149	0,112779	11,738%
		Teste	0,11139	0,087845	0,075024	0,085941	0,077165	8,747%
	8	Treino	0,124331	0,096959	0,112687	0,10448	0,096326	10,696%
		Teste	0,102242	0,076213	0,084811	0,078523	0,088723	8,610%
	9	Treino	0,117745	0,104071	0,093358	0,113192	0,126834	11,104%
		Teste	0,08158	0,082748	0,081539	0,079428	0,114642	8,799%
	10	Treino	0,102252	0,107453	0,10435	0,122117	0,130059	11,325%
		Teste	0,089067	0,09724	0,083655	0,085237	0,08761	8,856%
2	1	Treino	0,098583	0,102642	0,098195	0,098826	0,102841	10,022%
		Teste	0,076154	0,078333	0,07457	0,074745	0,078617	7,648%
	2	Treino	0,098676	0,098309	0,106648	0,120298	0,098538	10,449%
		Teste	0,073381	0,075336	0,080331	0,100059	0,07442	8,071%
	3	Treino	0,098995	0,086242	0,126711	0,132216	0,104272	10,969%
		Teste	0,077283	0,086646	0,109269	0,110971	0,083226	9,348%
	4	Treino	0,101974	0,112317	0,107618	0,091337	0,086413	9,993%
		Teste	0,08601	0,09473	0,09163	0,073196	0,084886	8,609%
	5	Treino	0,104752	0,102589	0,126193	0,09761	0,098509	10,593%
		Teste	0,089024	0,084126	0,124305	0,087511	0,086285	9,425%
	6	Treino	0,094041	0,101114	0,103675	0,084531	0,114417	9,956%
		Teste	0,073343	0,079949	0,088481	0,084273	0,109569	8,712%
	7	Treino	0,114994	0,110061	0,098563	0,084401	0,113646	10,433%
		Teste	0,09111	0,091026	0,096173	0,107395	0,094769	9,609%
	8	Treino	0,105206	0,130158	0,099919	0,125346	0,103424	11,281%
		Teste	0,082671	0,117827	0,075547	0,103299	0,090621	9,399%
	9	Treino	0,096459	0,098405	0,090848	0,127596	0,09588	10,184%
		Teste	0,088141	0,092348	0,072226	0,122498	0,084136	9,187%
	10	Treino	0,098792	0,085312	0,096623	0,116524	0,086627	9,678%
		Teste	0,09744	0,086649	0,082389	0,093092	0,071837	8,628%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
3	1	Treino	0,107376	0,103596	0,120635	0,107094	0,103166	10,837%
		Teste	0,089902	0,073179	0,101583	0,076484	0,073056	8,284%
	2	Treino	0,102675	0,107472	0,123933	0,114645	0,103401	11,043%
		Teste	0,089292	0,076097	0,099401	0,106694	0,078647	9,003%
	3	Treino	0,097808	0,10324	0,124019	0,108297	0,096689	10,601%
		Teste	0,082852	0,077691	0,096308	0,081833	0,080465	8,383%
	4	Treino	0,099955	0,107137	0,097754	0,102714	0,116318	10,478%
		Teste	0,089499	0,092151	0,083074	0,07207	0,083666	8,409%
	5	Treino	0,094863	0,090411	0,09251	0,10631	0,108587	9,854%
		Teste	0,078295	0,078552	0,095226	0,101934	0,072746	8,535%
	6	Treino	0,095556	0,101839	0,083098	0,094991	0,088813	9,286%
		Teste	0,088356	0,074873	0,079872	0,08344	0,084946	8,230%
	7	Treino	0,089818	0,132126	0,112484	0,097428	0,102125	10,680%
		Teste	0,091827	0,123807	0,091007	0,092334	0,08012	9,582%
	8	Treino	0,078761	0,092715	0,102636	0,13027	0,103044	10,148%
		Teste	0,087512	0,078464	0,091739	0,083619	0,088008	8,587%
	9	Treino	0,088629	0,07757	0,10534	0,125585	0,080013	9,543%
		Teste	0,079072	0,09505	0,087952	0,095433	0,085584	8,862%
	10	Treino	0,081008	0,085267	0,126287	0,10111	0,108723	10,048%
		Teste	0,083165	0,088976	0,103435	0,104163	0,07841	9,163%
4	1	Treino	0,114936	0,105914	0,095663	0,120887	0,098003	10,708%
		Teste	0,089245	0,079854	0,074408	0,098736	0,075111	8,347%
	2	Treino	0,090882	0,101958	0,101207	0,10906	0,104127	10,145%
		Teste	0,073131	0,075383	0,077932	0,077552	0,0879	7,838%
	3	Treino	0,100346	0,095752	0,102269	0,095955	0,098381	9,854%
		Teste	0,073735	0,08188	0,075783	0,091473	0,072347	7,904%
	4	Treino	0,106838	0,095391	0,104263	0,127268	0,095583	10,587%
		Teste	0,08077	0,075358	0,079581	0,079359	0,081828	7,938%
	5	Treino	0,096424	0,084653	0,114445	0,12554	0,105199	10,525%
		Teste	0,077333	0,076287	0,089721	0,08804	0,077782	8,183%
	6	Treino	0,09454	0,091993	0,114076	0,095027	0,134865	10,610%
		Teste	0,082026	0,071571	0,080393	0,082975	0,101999	8,379%
	7	Treino	0,099312	0,119571	0,120638	0,088532	0,118978	10,941%
		Teste	0,077852	0,074982	0,115974	0,079089	0,103092	9,020%
	8	Treino	0,089546	0,080963	0,090862	0,099486	0,107539	9,368%
		Teste	0,089635	0,081209	0,09205	0,084343	0,109079	9,126%
	9	Treino	0,097856	0,091361	0,097735	0,078034	0,109566	9,491%
		Teste	0,081627	0,102938	0,111798	0,08687	0,120844	10,082%
	10	Treino	0,092527	0,116823	0,113085	0,096998	0,077379	9,936%
		Teste	0,094222	0,112958	0,084733	0,091098	0,075586	9,172%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
5	1	Treino	0,111368	0,108451	0,099823	0,101992	0,107367	10,580%
		Teste	0,090227	0,088963	0,078141	0,082578	0,085074	8,500%
	2	Treino	0,101441	0,13307	0,098302	0,114966	0,109179	11,139%
		Teste	0,088912	0,124916	0,087473	0,087655	0,09217	9,622%
	3	Treino	0,116225	0,094094	0,101496	0,107601	0,110434	10,597%
		Teste	0,089872	0,085631	0,085066	0,084601	0,077982	8,463%
	4	Treino	0,136012	0,103388	0,091445	0,096103	0,097861	10,496%
		Teste	0,134129	0,098742	0,0944	0,0892	0,07594	9,848%
	5	Treino	0,108618	0,130159	0,105633	0,107924	0,082016	10,687%
		Teste	0,096131	0,123577	0,097161	0,112625	0,074554	10,081%
	6	Treino	0,084338	0,107618	0,08949	0,096932	0,116524	9,898%
		Teste	0,084813	0,095344	0,084249	0,105019	0,099116	9,371%
	7	Treino	0,084134	0,088577	0,087604	0,113872	0,097371	9,431%
		Teste	0,09128	0,084852	0,074492	0,106131	0,074404	8,623%
	8	Treino	0,154655	0,104189	0,098437	0,084053	0,103807	10,903%
		Teste	0,15834	0,097337	0,077242	0,093428	0,082334	10,174%
	9	Treino	0,091014	0,089361	0,069429	0,108182	0,095974	9,079%
		Teste	0,076916	0,086876	0,078612	0,118283	0,08811	8,976%
	10	Treino	0,094753	0,122515	0,10004	0,106232	0,079745	10,066%
		Teste	0,085728	0,090155	0,096325	0,103659	0,082917	9,176%
6	1	Treino	0,110396	0,101657	0,104722	0,101047	0,104264	10,442%
		Teste	0,107466	0,083487	0,105324	0,098343	0,09625	9,817%
	2	Treino	0,097714	0,094648	0,088671	0,089399	0,090894	9,227%
		Teste	0,095869	0,088791	0,095296	0,095815	0,097009	9,456%
	3	Treino	0,09131	0,088593	0,08725	0,091713	0,123899	9,655%
		Teste	0,119172	0,104458	0,092497	0,102601	0,108193	10,538%
	4	Treino	0,097737	0,088136	0,094903	0,09128	0,090538	9,252%
		Teste	0,096887	0,08599	0,089266	0,093475	0,083606	8,984%
	5	Treino	0,096364	0,093157	0,106511	0,084222	0,09287	9,462%
		Teste	0,117463	0,085832	0,091514	0,079375	0,082979	9,143%
	6	Treino	0,088983	0,105041	0,094436	0,108602	0,10126	9,966%
		Teste	0,090427	0,098845	0,086635	0,123321	0,10023	9,989%
	7	Treino	0,1191	0,1279	0,093588	0,084554	0,10144	10,532%
		Teste	0,107659	0,10496	0,098938	0,086033	0,119155	10,335%
	8	Treino	0,102217	0,115239	0,103282	0,112228	0,097292	10,605%
		Teste	0,100882	0,13441	0,087036	0,133105	0,093498	10,979%
	9	Treino	0,087684	0,08958	0,084432	0,081337	0,118066	9,222%
		Teste	0,083226	0,075489	0,080698	0,099607	0,140587	9,592%
	10	Treino	0,076843	0,115305	0,098045	0,10089	0,118453	10,191%
		Teste	0,087384	0,13263	0,099765	0,099351	0,090226	10,187%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
7	1	Treino	0,120468	0,107727	0,104259	0,104735	0,105861	10,861%
		Teste	0,095957	0,073019	0,069883	0,070677	0,070321	7,597%
	2	Treino	0,094229	0,105923	0,11533	0,129458	0,107213	11,043%
		Teste	0,070547	0,073828	0,077185	0,112944	0,092548	8,541%
	3	Treino	0,144837	0,10592	0,112102	0,113614	0,112119	11,772%
		Teste	0,122118	0,075016	0,11601	0,106102	0,086061	10,106%
	4	Treino	0,114635	0,111623	0,092566	0,100957	0,101558	10,427%
		Teste	0,086991	0,076291	0,072311	0,07301	0,072543	7,623%
	5	Treino	0,115432	0,108691	0,096556	0,128556	0,078761	10,560%
		Teste	0,117904	0,105345	0,087487	0,094892	0,071216	9,537%
	6	Treino	0,094158	0,135713	0,099442	0,105254	0,139619	11,484%
		Teste	0,070102	0,124699	0,076711	0,087551	0,134015	9,862%
	7	Treino	0,130511	0,098743	0,125733	0,115993	0,097283	11,365%
		Teste	0,102289	0,09894	0,109554	0,096088	0,08494	9,836%
	8	Treino	0,098264	0,13608	0,098495	0,100681	0,103951	10,749%
		Teste	0,082601	0,145593	0,096978	0,070539	0,090418	9,723%
	9	Treino	0,107885	0,14418	0,10371	0,092972	0,10712	11,117%
		Teste	0,08606	0,103515	0,078552	0,083426	0,081064	8,652%
	10	Treino	0,107502	0,13827	0,115202	0,100811	0,144108	12,118%
		Teste	0,083416	0,113983	0,122194	0,094897	0,114595	10,582%
8	1	Treino	0,159156	0,131631	0,130806	0,13978	0,141447	14,056%
		Teste	0,104728	0,07183	0,077062	0,087005	0,091175	8,636%
	2	Treino	0,157985	0,144679	0,171427	0,163186	0,120088	15,147%
		Teste	0,116707	0,087671	0,137288	0,142836	0,071132	11,113%
	3	Treino	0,163327	0,212056	0,189602	0,191552	0,14844	18,100%
		Teste	0,11272	0,210685	0,151809	0,197462	0,113944	15,732%
	4	Treino	0,109877	0,156469	0,136879	0,146884	0,135489	13,712%
		Teste	0,072102	0,136018	0,095811	0,096191	0,082146	9,645%
	5	Treino	0,156866	0,172183	0,132858	0,111245	0,243135	16,326%
		Teste	0,149526	0,129921	0,107338	0,069174	0,213384	13,387%
	6	Treino	0,117545	0,132125	0,212873	0,123683	0,113541	13,995%
		Teste	0,071779	0,104201	0,186225	0,075911	0,088559	10,534%
	7	Treino	0,14269	0,112252	0,122003	0,149668	0,114568	12,824%
		Teste	0,124458	0,075897	0,081176	0,127951	0,074795	9,686%
	8	Treino	0,132776	0,10988	0,122588	0,146787	0,140362	13,048%
		Teste	0,113597	0,093874	0,093636	0,11662	0,105175	10,458%
	9	Treino	0,133615	0,168478	0,100659	0,146329	0,11172	13,216%
		Teste	0,107824	0,144225	0,077278	0,109026	0,066751	10,102%
	10	Treino	0,105429	0,141936	0,129031	0,130997	0,175617	13,660%
		Teste	0,066284	0,111543	0,074567	0,104265	0,146671	10,067%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
9	1	Treino	0,155549	0,225078	0,164876	0,15973	0,143586	16,976%
		Teste	0,082232	0,196971	0,091575	0,117552	0,065159	11,070%
	2	Treino	0,145662	0,123621	0,159962	0,162597	0,158622	15,009%
		Teste	0,070212	0,056572	0,11237	0,095368	0,070225	8,095%
	3	Treino	0,15448	0,127528	0,124073	0,18094	0,150506	14,751%
		Teste	0,086621	0,063318	0,066847	0,145635	0,089246	9,033%
	4	Treino	0,175604	0,142106	0,144535	0,166928	0,129364	15,171%
		Teste	0,131834	0,074664	0,07806	0,113801	0,074716	9,462%
	5	Treino	0,13899	0,135086	0,154581	0,133126	0,175929	14,754%
		Teste	0,089182	0,074355	0,083593	0,080682	0,145823	9,473%
	6	Treino	0,133247	0,14541	0,11517	0,121756	0,183941	13,990%
		Teste	0,06823	0,08363	0,077077	0,098927	0,16084	9,774%
	7	Treino	0,138759	0,148253	0,16532	0,149645	0,156538	15,170%
		Teste	0,105184	0,087817	0,122925	0,081129	0,10743	10,090%
	8	Treino	0,207272	0,155466	0,131781	0,127973	0,111046	14,671%
		Teste	0,191387	0,123438	0,065613	0,068379	0,077966	10,536%
	9	Treino	0,119349	0,119453	0,120932	0,126779	0,134956	12,429%
		Teste	0,078948	0,102733	0,075714	0,077817	0,076116	8,227%
	10	Treino	0,129834	0,120268	0,180543	0,115582	0,142052	13,766%
		Teste	0,093261	0,067594	0,111517	0,089933	0,075616	8,758%
10	1	Treino	0,150511	0,151417	0,145041	0,166651	0,225643	16,785%
		Teste	0,076703	0,080547	0,061831	0,130094	0,207192	11,127%
	2	Treino	0,206417	0,146624	0,133023	0,175706	0,144439	16,124%
		Teste	0,144834	0,07274	0,065413	0,136549	0,051156	9,414%
	3	Treino	0,199379	0,176202	0,16855	0,152826	0,138605	16,711%
		Teste	0,175207	0,145759	0,09798	0,079059	0,066129	11,283%
	4	Treino	0,130058	0,15034	0,138735	0,145645	0,152298	14,342%
		Teste	0,08435	0,079174	0,057846	0,095451	0,110254	8,541%
	5	Treino	0,242978	0,166284	0,148243	0,130531	0,149413	16,749%
		Teste	0,227143	0,117497	0,059194	0,085955	0,114078	12,077%
	6	Treino	0,119347	0,122292	0,126836	0,170257	0,147735	13,729%
		Teste	0,073331	0,067033	0,079832	0,141029	0,093654	9,098%
	7	Treino	0,153995	0,132426	0,111319	0,126181	0,121272	12,904%
		Teste	0,108326	0,096798	0,085944	0,074676	0,066227	8,639%
	8	Treino	0,118255	0,141754	0,125447	0,119576	0,146916	13,039%
		Teste	0,078681	0,059185	0,080366	0,074532	0,099683	7,849%
	9	Treino	0,160537	0,117604	0,132836	0,182819	0,118279	14,242%
		Teste	0,137904	0,101572	0,066552	0,14675	0,092078	10,897%
	10	Treino	0,15755	0,123032	0,132809	0,12262	0,129327	13,307%
		Teste	0,102587	0,07654	0,106635	0,067339	0,095357	8,969%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
11	1	Treino	0,178826	0,136751	0,14358	0,139982	0,141176	14,806%
		Teste	0,147113	0,05687	0,076296	0,057724	0,06987	8,157%
	2	Treino	0,140506	0,128845	0,178215	0,122204	0,144947	14,294%
		Teste	0,069973	0,060729	0,148293	0,070896	0,071836	8,435%
	3	Treino	0,155061	0,133966	0,132503	0,162817	0,167052	15,028%
		Teste	0,094268	0,076581	0,086474	0,134345	0,132381	10,481%
	4	Treino	0,170574	0,156412	0,126625	0,131965	0,1673	15,058%
		Teste	0,147469	0,083995	0,068978	0,102252	0,142325	10,900%
	5	Treino	0,134814	0,123358	0,161309	0,204814	0,115977	14,805%
		Teste	0,075653	0,083651	0,112344	0,180891	0,08021	10,655%
	6	Treino	0,151884	0,140878	0,146863	0,167907	0,119266	14,536%
		Teste	0,109882	0,080747	0,079054	0,132082	0,073435	9,504%
	7	Treino	0,155743	0,129736	0,140356	0,185055	0,167955	15,577%
		Teste	0,071969	0,063067	0,11041	0,127332	0,105503	9,566%
	8	Treino	0,117701	0,180786	0,112878	0,18239	0,122236	14,320%
		Teste	0,085765	0,160732	0,077525	0,163427	0,087051	11,490%
	9	Treino	0,135398	0,136278	0,142771	0,111365	0,111055	12,737%
		Teste	0,092703	0,104945	0,097838	0,074061	0,095322	9,297%
	10	Treino	0,130797	0,123035	0,166515	0,133465	0,133382	13,744%
		Teste	0,08459	0,094118	0,121248	0,068004	0,086523	9,090%
12	1	Treino	0,142369	0,144446	0,134819	0,17521	0,139981	14,736%
		Teste	0,062753	0,087962	0,057467	0,139127	0,072391	8,394%
	2	Treino	0,128439	0,121981	0,14234	0,165214	0,209255	15,345%
		Teste	0,059177	0,061851	0,084977	0,107376	0,190308	10,074%
	3	Treino	0,130263	0,178991	0,170746	0,145604	0,150492	15,522%
		Teste	0,078743	0,118973	0,136548	0,061613	0,089104	9,700%
	4	Treino	0,169153	0,136601	0,143542	0,124594	0,158725	14,652%
		Teste	0,108799	0,083041	0,089557	0,067718	0,112042	9,223%
	5	Treino	0,134104	0,108588	0,145369	0,149521	0,120995	13,172%
		Teste	0,087491	0,074669	0,111146	0,103944	0,072634	8,998%
	6	Treino	0,113859	0,194134	0,121447	0,14087	0,113853	13,683%
		Teste	0,084086	0,176126	0,0961	0,097564	0,10465	11,171%
	7	Treino	0,186345	0,123906	0,147766	0,176468	0,144478	15,579%
		Teste	0,148469	0,060623	0,118421	0,148332	0,095393	11,425%
	8	Treino	0,11413	0,148096	0,125965	0,145443	0,133741	13,347%
		Teste	0,074105	0,094043	0,100359	0,106462	0,086859	9,237%
	9	Treino	0,129082	0,224285	0,114489	0,131521	0,134978	14,687%
		Teste	0,082853	0,225147	0,080812	0,075245	0,091593	11,113%
	10	Treino	0,106133	0,149876	0,162302	0,130943	0,119971	13,385%
		Teste	0,096023	0,097432	0,154724	0,090594	0,074622	10,268%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
13	1	Treino	0,16793	0,131266	0,162277	0,126227	0,144709	14,648%
		Teste	0,142008	0,072259	0,125066	0,081035	0,109228	10,592%
	2	Treino	0,118595	0,136055	0,149425	0,115946	0,154992	13,500%
		Teste	0,061706	0,095343	0,11333	0,050644	0,113687	8,694%
	3	Treino	0,114273	0,106341	0,112796	0,10713	0,116585	11,143%
		Teste	0,054605	0,066656	0,056081	0,063634	0,059288	6,005%
	4	Treino	0,122763	0,106759	0,130895	0,11843	0,135145	12,280%
		Teste	0,077929	0,059101	0,098701	0,052668	0,093199	7,632%
	5	Treino	0,13136	0,195381	0,138193	0,114761	0,11768	13,947%
		Teste	0,100614	0,162716	0,095516	0,069008	0,05719	9,701%
	6	Treino	0,183342	0,140021	0,12539	0,096056	0,11137	13,124%
		Teste	0,1465	0,104138	0,068677	0,073847	0,063813	9,139%
	7	Treino	0,195592	0,122683	0,113098	0,103775	0,118124	13,065%
		Teste	0,160112	0,105076	0,082942	0,063486	0,069021	9,613%
	8	Treino	0,09222	0,164962	0,145893	0,095191	0,11614	12,288%
		Teste	0,073606	0,130819	0,115717	0,07467	0,056155	9,019%
	9	Treino	0,125212	0,164722	0,089513	0,104016	0,102157	11,712%
		Teste	0,066294	0,093608	0,073495	0,057883	0,083229	7,490%
	10	Treino	0,097333	0,096977	0,143816	0,106127	0,11076	11,100%
		Teste	0,068802	0,065969	0,100397	0,102559	0,082779	8,410%
14	1	Treino	0,129362	0,182352	0,138821	0,136977	0,145547	14,661%
		Teste	0,068997	0,13556	0,08382	0,083674	0,095682	9,355%
	2	Treino	0,143418	0,152557	0,140914	0,12411	0,137695	13,974%
		Teste	0,098111	0,088011	0,086857	0,062892	0,086221	8,442%
	3	Treino	0,123704	0,136376	0,123383	0,153532	0,12863	13,312%
		Teste	0,058208	0,083659	0,054498	0,101549	0,086824	7,695%
	4	Treino	0,173845	0,120287	0,175246	0,149288	0,182385	16,021%
		Teste	0,136727	0,072556	0,132887	0,106995	0,146247	11,908%
	5	Treino	0,106782	0,140852	0,134657	0,121671	0,11958	12,471%
		Teste	0,055682	0,0817	0,07734	0,054145	0,067371	6,725%
	6	Treino	0,138508	0,146675	0,120156	0,170168	0,114211	13,794%
		Teste	0,10097	0,097599	0,057171	0,129833	0,061958	8,951%
	7	Treino	0,111968	0,102906	0,121217	0,132026	0,15454	12,453%
		Teste	0,068435	0,06966	0,076244	0,085214	0,097205	7,935%
	8	Treino	0,098824	0,095203	0,123557	0,123012	0,131197	11,436%
		Teste	0,070884	0,063105	0,059007	0,075556	0,075292	6,877%
	9	Treino	0,140279	0,120186	0,11122	0,146293	0,159925	13,558%
		Teste	0,084567	0,059221	0,066204	0,107115	0,124695	8,836%
	10	Treino	0,126743	0,124765	0,115925	0,11897	0,118737	12,103%
		Teste	0,075764	0,073591	0,051441	0,06665	0,059721	6,543%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
15	1	Treino	0,169579	0,166873	0,142979	0,145306	0,142742	15,350%
		Teste	0,100309	0,092233	0,057366	0,058788	0,054432	7,263%
	2	Treino	0,132263	0,134348	0,143863	0,170107	0,164655	14,905%
		Teste	0,056163	0,060458	0,086722	0,103301	0,111198	8,357%
	3	Treino	0,161982	0,171845	0,133921	0,139544	0,142233	14,991%
		Teste	0,10126	0,121655	0,05174	0,051264	0,074555	8,009%
	4	Treino	0,145048	0,178211	0,179552	0,147941	0,13431	15,701%
		Teste	0,075301	0,104626	0,136395	0,067821	0,060461	8,892%
	5	Treino	0,116371	0,119386	0,155117	0,12239	0,141326	13,092%
		Teste	0,058219	0,061503	0,103113	0,060904	0,05257	6,726%
	6	Treino	0,117729	0,140566	0,158545	0,144744	0,124691	13,725%
		Teste	0,064412	0,079367	0,073006	0,095707	0,06071	7,464%
	7	Treino	0,151035	0,138009	0,130774	0,12097	0,130844	13,433%
		Teste	0,093352	0,059048	0,07761	0,064552	0,067839	7,248%
	8	Treino	0,131568	0,121573	0,124907	0,133091	0,200259	14,228%
		Teste	0,060914	0,067711	0,056514	0,083269	0,148593	8,340%
	9	Treino	0,135861	0,141251	0,156373	0,14374	0,132964	14,204%
		Teste	0,080524	0,075083	0,104606	0,076405	0,059663	7,926%
	10	Treino	0,116155	0,122222	0,116099	0,13029	0,135985	12,415%
		Teste	0,057282	0,053285	0,057546	0,048164	0,084573	6,017%
16	1	Treino	0,150161	0,13983	0,153297	0,161081	0,154988	15,187%
		Teste	0,083877	0,068634	0,075766	0,089808	0,087381	8,109%
	2	Treino	0,124039	0,131579	0,140038	0,142033	0,145076	13,655%
		Teste	0,059494	0,069495	0,082312	0,092097	0,071866	7,505%
	3	Treino	0,132242	0,175187	0,139292	0,158273	0,129936	14,699%
		Teste	0,06242	0,128813	0,064711	0,109118	0,072127	8,744%
	4	Treino	0,123614	0,139333	0,146829	0,127183	0,12792	13,298%
		Teste	0,060394	0,076688	0,077237	0,06855	0,070046	7,058%
	5	Treino	0,134772	0,121544	0,152261	0,119105	0,155022	13,654%
		Teste	0,061848	0,069433	0,112076	0,068864	0,08925	8,029%
	6	Treino	0,122225	0,119649	0,138307	0,114509	0,118673	12,267%
		Teste	0,074151	0,067931	0,070289	0,064298	0,072141	6,976%
	7	Treino	0,126473	0,135672	0,122812	0,132015	0,132201	12,983%
		Teste	0,058672	0,066614	0,064897	0,084503	0,070466	6,903%
	8	Treino	0,127202	0,190815	0,184398	0,126847	0,167968	15,945%
		Teste	0,068475	0,087109	0,137956	0,061576	0,113593	9,374%
	9	Treino	0,139922	0,128184	0,143216	0,113112	0,126237	13,013%
		Teste	0,072798	0,062449	0,072165	0,062808	0,081552	7,035%
	10	Treino	0,150469	0,125995	0,101937	0,156002	0,142291	13,534%
		Teste	0,080888	0,06846	0,069211	0,088392	0,077681	7,693%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
17	1	Treino	0,143267	0,156217	0,14645	0,215324	0,161363	16,452%
		Teste	0,07948	0,099987	0,086681	0,18327	0,106343	11,115%
	2	Treino	0,171096	0,138505	0,209023	0,163341	0,128295	16,205%
		Teste	0,134257	0,097885	0,168961	0,117157	0,078795	11,941%
	3	Treino	0,135091	0,154056	0,123402	0,153502	0,145098	14,223%
		Teste	0,071496	0,11701	0,065096	0,075185	0,090269	8,381%
	4	Treino	0,117687	0,116581	0,128641	0,116645	0,128287	12,157%
		Teste	0,061563	0,068019	0,054995	0,062023	0,066385	6,260%
	5	Treino	0,146246	0,131524	0,179812	0,129592	0,126489	14,273%
		Teste	0,110568	0,070376	0,115935	0,081659	0,081191	9,195%
	6	Treino	0,120313	0,110876	0,11274	0,154981	0,112019	12,219%
		Teste	0,074882	0,078218	0,062516	0,114128	0,06988	7,992%
	7	Treino	0,184405	0,15196	0,105284	0,11566	0,115314	13,452%
		Teste	0,129442	0,113886	0,082275	0,063093	0,067516	9,124%
	8	Treino	0,129242	0,176878	0,119962	0,129741	0,114372	13,404%
		Teste	0,087644	0,141945	0,064415	0,063846	0,078172	8,720%
	9	Treino	0,121664	0,161395	0,110808	0,157578	0,13027	13,634%
		Teste	0,071591	0,103007	0,06764	0,105704	0,066984	8,299%
	10	Treino	0,171232	0,13941	0,144602	0,147652	0,129811	14,654%
		Teste	0,091171	0,094172	0,103188	0,077003	0,084654	9,004%
18	1	Treino	0,271795	0,169747	0,144631	0,13768	0,132909	17,135%
		Teste	0,284557	0,146923	0,095968	0,10304	0,093283	14,475%
	2	Treino	0,1474	0,153682	0,138998	0,111615	0,139969	13,833%
		Teste	0,128144	0,08987	0,113782	0,069529	0,114093	10,308%
	3	Treino	0,127193	0,138289	0,102112	0,151547	0,133695	13,057%
		Teste	0,079232	0,116189	0,053456	0,133663	0,098012	9,611%
	4	Treino	0,148027	0,132461	0,107261	0,118747	0,104686	12,224%
		Teste	0,096892	0,107914	0,052742	0,059573	0,068644	7,715%
	5	Treino	0,134396	0,113223	0,116433	0,153425	0,12078	12,765%
		Teste	0,070702	0,072551	0,06727	0,112751	0,077477	8,015%
	6	Treino	0,121247	0,106996	0,123977	0,10489	0,123099	11,604%
		Teste	0,088068	0,075631	0,080237	0,070843	0,078844	7,872%
	7	Treino	0,119431	0,133955	0,119156	0,126138	0,115239	12,278%
		Teste	0,081923	0,086341	0,068106	0,078673	0,063874	7,578%
	8	Treino	0,208026	0,110309	0,136341	0,102788	0,122095	13,591%
		Teste	0,170491	0,058934	0,101292	0,067327	0,066877	9,298%
	9	Treino	0,229966	0,121964	0,108128	0,125617	0,105145	13,816%
		Teste	0,237702	0,086156	0,068216	0,089767	0,083779	11,312%
	10	Treino	0,132351	0,113632	0,110668	0,130448	0,233874	14,419%
		Teste	0,100212	0,060801	0,0739	0,097355	0,248814	11,622%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
19	1	Treino	0,13954	0,109666	0,123331	0,153343	0,145494	13,427%
		Teste	0,099481	0,079979	0,098559	0,157115	0,128151	11,266%
	2	Treino	0,101295	0,110338	0,107445	0,111114	0,105889	10,722%
		Teste	0,070983	0,085609	0,073503	0,082429	0,066666	7,584%
	3	Treino	0,111917	0,095406	0,111764	0,110568	0,129424	11,182%
		Teste	0,084047	0,061958	0,084346	0,092426	0,060093	7,657%
	4	Treino	0,108391	0,104148	0,13722	0,110931	0,12093	11,632%
		Teste	0,065381	0,06158	0,133262	0,083041	0,112545	9,116%
	5	Treino	0,137264	0,098627	0,115735	0,093721	0,124491	11,397%
		Teste	0,116635	0,055937	0,09018	0,061496	0,096522	8,415%
	6	Treino	0,117472	0,099206	0,1055	0,099144	0,113456	10,696%
		Teste	0,070416	0,065067	0,076086	0,064705	0,083888	7,203%
	7	Treino	0,112321	0,097074	0,105713	0,105926	0,117741	10,775%
		Teste	0,105379	0,076447	0,074758	0,07261	0,104401	8,672%
	8	Treino	0,103579	0,101527	0,111949	0,10864	0,117547	10,865%
		Teste	0,066109	0,073228	0,092862	0,09356	0,097732	8,470%
	9	Treino	0,124559	0,091743	0,108253	0,115399	0,110003	10,999%
		Teste	0,114534	0,07191	0,07213	0,093737	0,073762	8,521%
	10	Treino	0,118002	0,117343	0,116601	0,105743	0,097528	11,104%
		Teste	0,091664	0,08739	0,080933	0,080441	0,069427	8,197%
20	1	Treino	0,115113	0,136723	0,125945	0,132559	0,102653	12,260%
		Teste	0,090072	0,117369	0,081886	0,100411	0,062151	9,038%
	2	Treino	0,141636	0,11811	0,110811	0,102514	0,111752	11,696%
		Teste	0,12218	0,084707	0,066814	0,057654	0,060849	7,844%
	3	Treino	0,103519	0,125612	0,122629	0,110982	0,102511	11,305%
		Teste	0,070646	0,099906	0,088818	0,05886	0,063287	7,630%
	4	Treino	0,090888	0,103737	0,126212	0,105127	0,111643	10,752%
		Teste	0,054219	0,074422	0,080508	0,049677	0,081221	6,801%
	5	Treino	0,101795	0,099043	0,116544	0,108728	0,114676	10,816%
		Teste	0,062977	0,08325	0,082728	0,068581	0,077276	7,496%
	6	Treino	0,094227	0,10092	0,108275	0,089036	0,090684	9,663%
		Teste	0,054743	0,055275	0,078026	0,063297	0,06132	6,253%
	7	Treino	0,090086	0,096894	0,083151	0,100994	0,093672	9,296%
		Teste	0,05761	0,060006	0,083696	0,064447	0,070899	6,733%
	8	Treino	0,082794	0,098507	0,1098	0,087976	0,095428	9,490%
		Teste	0,067456	0,094635	0,068874	0,06347	0,06669	7,222%
	9	Treino	0,113563	0,089816	0,08133	0,093632	0,135119	10,269%
		Teste	0,0832	0,057618	0,070013	0,067019	0,114824	7,853%
	10	Treino	0,097936	0,105402	0,099665	0,131352	0,106836	10,824%
		Teste	0,074496	0,066542	0,055239	0,075409	0,064776	6,729%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
21	1	Treino	0,106997	0,108197	0,116621	0,117551	0,108128	11,150%
		Teste	0,091606	0,09166	0,106224	0,111214	0,08599	9,734%
	2	Treino	0,102585	0,099524	0,097573	0,092877	0,100546	9,862%
		Teste	0,082764	0,0662	0,052985	0,057426	0,076571	6,719%
	3	Treino	0,11554	0,120679	0,101276	0,096904	0,095975	10,607%
		Teste	0,067911	0,099358	0,073422	0,066923	0,062659	7,405%
	4	Treino	0,103846	0,088222	0,131813	0,116543	0,11157	11,040%
		Teste	0,074298	0,057791	0,094116	0,089602	0,083598	7,988%
	5	Treino	0,091815	0,086099	0,090493	0,097256	0,124489	9,803%
		Teste	0,060444	0,076765	0,04396	0,058017	0,104346	6,871%
	6	Treino	0,08343	0,111844	0,139303	0,090968	0,100523	10,521%
		Teste	0,067065	0,098559	0,11931	0,054778	0,08488	8,492%
	7	Treino	0,094972	0,101537	0,100647	0,09283	0,086199	9,524%
		Teste	0,069408	0,094255	0,078274	0,055306	0,049077	6,926%
	8	Treino	0,085808	0,125089	0,087035	0,12104	0,100225	10,384%
		Teste	0,057369	0,090333	0,072749	0,123022	0,071497	8,299%
	9	Treino	0,07126	0,094255	0,090291	0,093256	0,098971	8,961%
		Teste	0,064163	0,070888	0,058599	0,075184	0,05593	6,495%
	10	Treino	0,143779	0,096754	0,092156	0,130392	0,094839	11,158%
		Teste	0,157426	0,064197	0,061275	0,137695	0,072055	9,853%
22	1	Treino	0,093779	0,092012	0,109222	0,082274	0,080547	9,157%
		Teste	0,072592	0,066352	0,087524	0,062933	0,059874	6,986%
	2	Treino	0,095871	0,108887	0,130204	0,104919	0,077216	10,342%
		Teste	0,083934	0,128173	0,087705	0,10017	0,06445	9,289%
	3	Treino	0,07676	0,091001	0,091807	0,090943	0,122394	9,458%
		Teste	0,070219	0,069127	0,081987	0,08187	0,147178	9,008%
	4	Treino	0,095788	0,079028	0,06867	0,08409	0,13406	9,233%
		Teste	0,087769	0,061237	0,042279	0,093425	0,114131	7,977%
	5	Treino	0,085806	0,102427	0,107391	0,101238	0,092432	9,786%
		Teste	0,079178	0,085198	0,107976	0,083003	0,071666	8,540%
	6	Treino	0,070929	0,121668	0,084237	0,087553	0,067264	8,633%
		Teste	0,0615	0,079996	0,0418	0,089864	0,064271	6,749%
	7	Treino	0,097553	0,091115	0,079184	0,109531	0,131273	10,173%
		Teste	0,060397	0,061188	0,055272	0,106859	0,139491	8,464%
	8	Treino	0,07668	0,072447	0,079547	0,078838	0,079819	7,747%
		Teste	0,056631	0,051157	0,074672	0,061105	0,070057	6,272%
	9	Treino	0,071699	0,123675	0,068822	0,120274	0,069764	9,085%
		Teste	0,063563	0,097789	0,055471	0,103473	0,058828	7,582%
	10	Treino	0,072561	0,07028	0,094094	0,063365	0,101048	8,027%
		Teste	0,06782	0,051374	0,074638	0,057218	0,089995	6,821%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
23	1	Treino	0,120525	0,135785	0,126902	0,11425	0,107292	12,095%
		Teste	0,100567	0,09632	0,099166	0,083725	0,081553	9,227%
	2	Treino	0,111458	0,101998	0,098682	0,106162	0,102416	10,414%
		Teste	0,082196	0,070682	0,065132	0,084823	0,070919	7,475%
	3	Treino	0,09091	0,099644	0,118244	0,096199	0,095476	10,009%
		Teste	0,057963	0,064397	0,095231	0,071924	0,05644	6,919%
	4	Treino	0,100479	0,108213	0,13848	0,116137	0,103181	11,330%
		Teste	0,064966	0,090617	0,117174	0,084432	0,067121	8,486%
	5	Treino	0,107876	0,129428	0,150826	0,118011	0,104877	12,220%
		Teste	0,081156	0,10659	0,13236	0,089482	0,077748	9,747%
	6	Treino	0,10106	0,124799	0,0967	0,105287	0,110233	10,762%
		Teste	0,064634	0,09945	0,073238	0,076076	0,080186	7,872%
	7	Treino	0,111896	0,081973	0,119524	0,119455	0,110841	10,874%
		Teste	0,077539	0,05157	0,102198	0,111907	0,095639	8,777%
	8	Treino	0,141797	0,100851	0,104287	0,0829	0,08358	10,268%
		Teste	0,141336	0,08183	0,071615	0,062809	0,0572	8,296%
	9	Treino	0,083265	0,080751	0,094797	0,139344	0,081129	9,586%
		Teste	0,069079	0,048579	0,05772	0,118494	0,071873	7,315%
	10	Treino	0,13718	0,079324	0,10585	0,110689	0,091775	10,496%
		Teste	0,055895	0,053781	0,104093	0,07676	0,067409	7,159%
24	1	Treino	0,117191	0,121798	0,126451	0,128237	0,121132	12,296%
		Teste	0,062903	0,074624	0,072023	0,084068	0,071427	7,301%
	2	Treino	0,121772	0,129669	0,129894	0,121746	0,120712	12,476%
		Teste	0,080082	0,082987	0,074407	0,082332	0,080192	8,000%
	3	Treino	0,123339	0,123207	0,112509	0,120833	0,130851	12,215%
		Teste	0,072047	0,07299	0,063892	0,079473	0,084228	7,453%
	4	Treino	0,124854	0,124036	0,124709	0,138849	0,115109	12,551%
		Teste	0,102204	0,07059	0,07865	0,087618	0,068511	8,151%
	5	Treino	0,11436	0,138005	0,118572	0,121259	0,169264	13,229%
		Teste	0,075671	0,080416	0,084085	0,072511	0,12501	8,754%
	6	Treino	0,138253	0,113448	0,134778	0,151905	0,122344	13,215%
		Teste	0,089031	0,064025	0,107626	0,119819	0,08376	9,285%
	7	Treino	0,125338	0,12415	0,125902	0,129175	0,144379	12,979%
		Teste	0,08683	0,078921	0,092965	0,090181	0,105804	9,094%
	8	Treino	0,103096	0,107534	0,122191	0,130289	0,100332	11,269%
		Teste	0,068838	0,070207	0,090618	0,059844	0,061556	7,021%
	9	Treino	0,147322	0,115353	0,09929	0,113478	0,186434	13,238%
		Teste	0,11301	0,08537	0,063633	0,058355	0,156685	9,541%
	10	Treino	0,120547	0,155937	0,122353	0,146269	0,129935	13,501%
		Teste	0,064651	0,133707	0,06522	0,123839	0,082693	9,402%

Modelo Semana seguinte

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
1	1	Treino	0,122603	0,150016	0,119585	0,128783	0,115754	12,735%
		Teste	0,073942	0,109924	0,074914	0,080468	0,06761	8,137%
	2	Treino	0,107826	0,111462	0,130688	0,112472	0,111922	11,487%
		Teste	0,064552	0,062054	0,0865	0,062843	0,068956	6,898%
	3	Treino	0,113716	0,121764	0,123035	0,149506	0,114366	12,448%
		Teste	0,076245	0,082278	0,078916	0,115219	0,076923	8,592%
	4	Treino	0,123315	0,16297	0,10542	0,113026	0,114128	12,377%
		Teste	0,08071	0,134637	0,071194	0,076226	0,075824	8,772%
	5	Treino	0,11542	0,123622	0,138204	0,103369	0,121258	12,037%
		Teste	0,083713	0,07891	0,1005	0,087805	0,072904	8,477%
	6	Treino	0,102788	0,101228	0,120452	0,123899	0,123547	11,438%
		Teste	0,066276	0,06519	0,09258	0,080221	0,071587	7,517%
	7	Treino	0,109714	0,101609	0,114228	0,110641	0,114826	11,020%
		Teste	0,074862	0,080237	0,07743	0,071163	0,074741	7,569%
	8	Treino	0,129987	0,10127	0,106565	0,133797	0,118852	11,809%
		Teste	0,085695	0,071808	0,076034	0,108165	0,075509	8,344%
	9	Treino	0,123062	0,109193	0,105084	0,113288	0,111894	11,250%
		Teste	0,078232	0,064231	0,077141	0,075302	0,08002	7,499%
	10	Treino	0,102397	0,102108	0,133812	0,127423	0,110232	11,519%
		Teste	0,10177	0,067408	0,107693	0,093994	0,061522	8,648%
2	1	Treino	0,109776	0,116254	0,118119	0,116502	0,107139	11,356%
		Teste	0,072389	0,075163	0,093976	0,080447	0,072564	7,891%
	2	Treino	0,10485	0,103016	0,105077	0,111459	0,109075	10,670%
		Teste	0,069511	0,066256	0,064069	0,097282	0,06227	7,188%
	3	Treino	0,097506	0,107706	0,128661	0,096776	0,115019	10,913%
		Teste	0,065815	0,071302	0,104731	0,063278	0,062091	7,344%
	4	Treino	0,111603	0,151111	0,095974	0,11155	0,097823	11,361%
		Teste	0,078256	0,115831	0,066791	0,079868	0,066163	8,138%
	5	Treino	0,104873	0,092106	0,096555	0,125363	0,130164	10,981%
		Teste	0,072994	0,067022	0,059653	0,095216	0,086935	7,636%
	6	Treino	0,096334	0,093142	0,105557	0,093621	0,112205	10,017%
		Teste	0,060942	0,075332	0,076228	0,068167	0,074566	7,105%
	7	Treino	0,102376	0,124998	0,099572	0,097433	0,104866	10,585%
		Teste	0,068252	0,083489	0,056969	0,056739	0,063927	6,588%
	8	Treino	0,11098	0,102206	0,096532	0,095784	0,099546	10,101%
		Teste	0,078965	0,071315	0,065129	0,061955	0,077284	7,093%
	9	Treino	0,098627	0,106458	0,1122	0,104579	0,107585	10,589%
		Teste	0,067925	0,074637	0,084237	0,074262	0,071483	7,451%
	10	Treino	0,097397	0,094045	0,093512	0,112294	0,125145	10,448%
		Teste	0,071385	0,069896	0,063565	0,074309	0,083986	7,263%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
3	1	Treino	0,10796	0,109985	0,115009	0,13387	0,10618	11,460%
		Teste	0,064495	0,068517	0,074802	0,090766	0,06722	7,316%
	2	Treino	0,111266	0,11312	0,124999	0,109937	0,10133	11,213%
		Teste	0,067151	0,071212	0,098687	0,067432	0,060646	7,303%
	3	Treino	0,11373	0,105617	0,10089	0,105723	0,103287	10,585%
		Teste	0,08312	0,067419	0,06676	0,065392	0,071015	7,074%
	4	Treino	0,108992	0,106663	0,105184	0,105854	0,100863	10,551%
		Teste	0,069715	0,06308	0,070955	0,079063	0,066868	6,994%
	5	Treino	0,118927	0,099445	0,099631	0,137124	0,127124	11,645%
		Teste	0,081756	0,068405	0,071921	0,098618	0,0898	8,210%
	6	Treino	0,120888	0,130657	0,126083	0,123124	0,104141	12,098%
		Teste	0,09381	0,08994	0,088823	0,087048	0,069648	8,585%
	7	Treino	0,095074	0,093889	0,097928	0,107706	0,102256	9,937%
		Teste	0,067293	0,061181	0,065834	0,079559	0,076599	7,009%
	8	Treino	0,101257	0,099357	0,113967	0,09966	0,087775	10,040%
		Teste	0,079107	0,077977	0,08831	0,061812	0,080758	7,759%
	9	Treino	0,10052	0,13029	0,122429	0,11444	0,130085	11,955%
		Teste	0,079786	0,083673	0,081678	0,076635	0,088102	8,197%
	10	Treino	0,094977	0,108585	0,097649	0,104099	0,097558	10,057%
		Teste	0,072504	0,079648	0,069655	0,079186	0,074701	7,514%
4	1	Treino	0,099567	0,101513	0,104774	0,097862	0,108145	10,237%
		Teste	0,060924	0,060035	0,058732	0,059803	0,070255	6,195%
	2	Treino	0,101562	0,098462	0,093291	0,098653	0,102921	9,898%
		Teste	0,067457	0,061435	0,058204	0,056488	0,063975	6,151%
	3	Treino	0,114758	0,091242	0,093798	0,091237	0,093923	9,699%
		Teste	0,07185	0,058114	0,068437	0,059612	0,067985	6,520%
	4	Treino	0,100266	0,090728	0,107916	0,100062	0,101405	10,008%
		Teste	0,061835	0,063539	0,078043	0,059962	0,060532	6,478%
	5	Treino	0,116065	0,110012	0,090713	0,10988	0,097196	10,477%
		Teste	0,070892	0,077058	0,062358	0,072045	0,061107	6,869%
	6	Treino	0,103482	0,093589	0,121194	0,096846	0,092708	10,156%
		Teste	0,069639	0,055263	0,102944	0,065414	0,060555	7,076%
	7	Treino	0,088783	0,106741	0,120803	0,092721	0,125491	10,691%
		Teste	0,061491	0,067117	0,085511	0,061332	0,085931	7,228%
	8	Treino	0,086709	0,098032	0,137106	0,093381	0,101061	10,326%
		Teste	0,080547	0,087458	0,113643	0,062624	0,064412	8,174%
	9	Treino	0,093312	0,097782	0,095636	0,090091	0,101024	9,557%
		Teste	0,057667	0,069074	0,060214	0,070484	0,067135	6,491%
	10	Treino	0,134053	0,089217	0,089182	0,110437	0,101229	10,482%
		Teste	0,095482	0,082353	0,076636	0,077124	0,07112	8,054%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
5	1	Treino	0,107687	0,119487	0,103648	0,103012	0,117529	11,027%
		Teste	0,087823	0,075853	0,091523	0,076827	0,088265	8,406%
	2	Treino	0,103385	0,098653	0,10751	0,11805	0,123788	11,028%
		Teste	0,083713	0,075868	0,063072	0,099339	0,099298	8,426%
	3	Treino	0,098738	0,097595	0,104747	0,131075	0,09989	10,641%
		Teste	0,079914	0,076642	0,07944	0,119825	0,084777	8,812%
	4	Treino	0,111334	0,13498	0,093314	0,0965	0,109697	10,916%
		Teste	0,081647	0,129534	0,070935	0,072054	0,091082	8,905%
	5	Treino	0,096151	0,099763	0,122527	0,093808	0,094221	10,129%
		Teste	0,0802	0,070482	0,098174	0,070566	0,073128	7,851%
	6	Treino	0,09412	0,091885	0,095363	0,107927	0,112651	10,039%
		Teste	0,071076	0,085963	0,077583	0,076473	0,092436	8,071%
	7	Treino	0,123965	0,090391	0,119755	0,10622	0,092776	10,662%
		Teste	0,098012	0,086236	0,093684	0,095024	0,078526	9,030%
	8	Treino	0,093753	0,096585	0,088292	0,100639	0,119136	9,968%
		Teste	0,076832	0,072763	0,084328	0,078911	0,082583	7,908%
	9	Treino	0,099097	0,091681	0,095442	0,099714	0,091244	9,544%
		Teste	0,080381	0,076446	0,073725	0,084696	0,073047	7,766%
	10	Treino	0,100458	0,088991	0,09253	0,124442	0,100353	10,135%
		Teste	0,074786	0,091459	0,081085	0,104355	0,091503	8,864%
6	1	Treino	0,12323	0,101936	0,106663	0,111236	0,139595	11,653%
		Teste	0,083911	0,084376	0,068891	0,11215	0,112018	9,227%
	2	Treino	0,098313	0,106676	0,094885	0,098344	0,101134	9,987%
		Teste	0,073153	0,092742	0,080722	0,077975	0,07525	7,997%
	3	Treino	0,102831	0,101707	0,111321	0,095142	0,097148	10,163%
		Teste	0,07228	0,059046	0,096208	0,068982	0,073967	7,410%
	4	Treino	0,122232	0,105411	0,109651	0,097082	0,131858	11,325%
		Teste	0,091813	0,098363	0,089967	0,06371	0,093806	8,753%
	5	Treino	0,110369	0,098289	0,104891	0,091333	0,08982	9,894%
		Teste	0,093071	0,08564	0,057798	0,072775	0,095285	8,091%
	6	Treino	0,126033	0,112333	0,111748	0,100641	0,163176	12,279%
		Teste	0,100988	0,074486	0,079457	0,080883	0,124797	9,212%
	7	Treino	0,102514	0,087357	0,096917	0,090198	0,152284	10,585%
		Teste	0,075683	0,064636	0,087694	0,088377	0,119178	8,711%
	8	Treino	0,093195	0,092918	0,107327	0,100859	0,099844	9,883%
		Teste	0,068426	0,084939	0,079392	0,079662	0,083217	7,913%
	9	Treino	0,101428	0,094038	0,094736	0,103981	0,096101	9,806%
		Teste	0,093128	0,085297	0,105425	0,086358	0,061488	8,634%
	10	Treino	0,099275	0,090132	0,099967	0,098722	0,104436	9,851%
		Teste	0,089925	0,080209	0,085115	0,08302	0,095034	8,666%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
7	1	Treino	0,113329	0,123552	0,139213	0,125272	0,130961	12,647%
		Teste	0,065256	0,079405	0,099651	0,078479	0,108994	8,636%
	2	Treino	0,168806	0,147348	0,105542	0,113865	0,118799	13,087%
		Teste	0,121131	0,100882	0,07614	0,07187	0,073353	8,868%
	3	Treino	0,10449	0,128099	0,138149	0,119542	0,096518	11,736%
		Teste	0,055889	0,081122	0,124666	0,06827	0,06008	7,801%
	4	Treino	0,092889	0,107793	0,112302	0,105893	0,097625	10,330%
		Teste	0,077635	0,074058	0,066937	0,059683	0,056499	6,696%
	5	Treino	0,118207	0,141095	0,125122	0,091647	0,097705	11,476%
		Teste	0,076959	0,084331	0,084537	0,078304	0,076517	8,013%
	6	Treino	0,095143	0,099294	0,104501	0,092372	0,0988	9,802%
		Teste	0,078432	0,066775	0,072478	0,081545	0,060865	7,202%
	7	Treino	0,098539	0,107976	0,108832	0,192994	0,12327	12,632%
		Teste	0,063202	0,07992	0,070815	0,164158	0,086966	9,301%
	8	Treino	0,095753	0,104028	0,099721	0,0907	0,093075	9,666%
		Teste	0,077855	0,069162	0,069878	0,078509	0,087671	7,662%
	9	Treino	0,096334	0,112336	0,086815	0,08972	0,091808	9,540%
		Teste	0,070172	0,06588	0,102459	0,095236	0,074104	8,157%
	10	Treino	0,121392	0,096578	0,134037	0,124143	0,113877	11,801%
		Teste	0,090378	0,077087	0,102491	0,073106	0,069394	8,249%
8	1	Treino	0,135992	0,152237	0,163741	0,150877	0,167684	15,411%
		Teste	0,084144	0,106685	0,124144	0,098571	0,136993	11,011%
	2	Treino	0,1416	0,133887	0,135299	0,172639	0,138269	14,434%
		Teste	0,088236	0,084572	0,085558	0,151412	0,118123	10,558%
	3	Treino	0,122496	0,165631	0,215575	0,118462	0,155301	15,549%
		Teste	0,080954	0,138154	0,179988	0,086552	0,12967	12,306%
	4	Treino	0,157131	0,143424	0,127218	0,159741	0,152764	14,806%
		Teste	0,131303	0,100772	0,096406	0,115992	0,129219	11,474%
	5	Treino	0,132635	0,138686	0,171264	0,121476	0,156942	14,420%
		Teste	0,096294	0,098807	0,131754	0,113302	0,117405	11,151%
	6	Treino	0,137425	0,128005	0,127245	0,141109	0,124505	13,166%
		Teste	0,085905	0,089052	0,077112	0,100863	0,105155	9,162%
	7	Treino	0,121081	0,123388	0,123096	0,124031	0,130204	12,436%
		Teste	0,086531	0,091774	0,11137	0,110692	0,086519	9,738%
	8	Treino	0,147685	0,178426	0,158034	0,157186	0,178959	16,406%
		Teste	0,144487	0,15059	0,114624	0,129439	0,133879	13,460%
	9	Treino	0,130269	0,134578	0,143212	0,133601	0,124557	13,324%
		Teste	0,109755	0,118605	0,156001	0,102093	0,102083	11,771%
	10	Treino	0,133594	0,160171	0,12834	0,16078	0,137688	14,411%
		Teste	0,131563	0,126936	0,113412	0,109273	0,120716	12,038%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
9	1	Treino	0,150233	0,212391	0,177416	0,155901	0,174406	17,407%
		Teste	0,09415	0,216181	0,110578	0,100128	0,136473	13,150%
	2	Treino	0,156071	0,148897	0,216301	0,22884	0,162209	18,246%
		Teste	0,101421	0,090239	0,209427	0,188819	0,104239	13,883%
	3	Treino	0,157527	0,182936	0,139693	0,137465	0,133537	15,023%
		Teste	0,092358	0,14973	0,089148	0,091904	0,075537	9,974%
	4	Treino	0,147178	0,155002	0,154165	0,159256	0,130295	14,918%
		Teste	0,088052	0,110297	0,099132	0,117097	0,07541	9,800%
	5	Treino	0,146751	0,135154	0,137151	0,1518	0,132572	14,069%
		Teste	0,090613	0,085624	0,114244	0,079982	0,094389	9,297%
	6	Treino	0,152989	0,162392	0,133112	0,131691	0,138535	14,374%
		Teste	0,078702	0,07635	0,081926	0,085036	0,102908	8,498%
	7	Treino	0,158751	0,139695	0,174491	0,133263	0,1312	14,748%
		Teste	0,084234	0,103994	0,113545	0,093966	0,097875	9,872%
	8	Treino	0,131014	0,18546	0,17913	0,136092	0,131919	15,272%
		Teste	0,103281	0,187846	0,116327	0,087839	0,068084	11,268%
	9	Treino	0,126027	0,128421	0,167531	0,13095	0,132033	13,699%
		Teste	0,111701	0,104111	0,127797	0,100245	0,094483	10,767%
	10	Treino	0,134489	0,13184	0,141752	0,135407	0,152167	13,913%
		Teste	0,075579	0,076374	0,104213	0,077059	0,109407	8,853%
10	1	Treino	0,165322	0,155455	0,153777	0,139485	0,163513	15,551%
		Teste	0,115515	0,114185	0,11316	0,086214	0,121418	11,010%
	2	Treino	0,170653	0,141444	0,138271	0,143839	0,173234	15,349%
		Teste	0,138529	0,093373	0,048855	0,093431	0,151238	10,509%
	3	Treino	0,204945	0,144639	0,149574	0,143666	0,206984	16,996%
		Teste	0,192659	0,074844	0,107679	0,094557	0,176756	12,930%
	4	Treino	0,146017	0,217758	0,127764	0,147835	0,136295	15,513%
		Teste	0,083147	0,18018	0,08669	0,093551	0,083196	10,535%
	5	Treino	0,128036	0,141489	0,148445	0,151573	0,17066	14,804%
		Teste	0,09361	0,100488	0,066943	0,106762	0,148163	10,319%
	6	Treino	0,137492	0,140261	0,15761	0,155169	0,151528	14,841%
		Teste	0,100592	0,085357	0,076323	0,100184	0,115236	9,554%
	7	Treino	0,171334	0,135932	0,142424	0,150078	0,134852	14,692%
		Teste	0,174044	0,091794	0,115779	0,097538	0,064682	10,877%
	8	Treino	0,13001	0,134762	0,144364	0,142947	0,142372	13,889%
		Teste	0,093416	0,123607	0,083588	0,082609	0,114363	9,952%
	9	Treino	0,138052	0,150163	0,139753	0,130062	0,18128	14,786%
		Teste	0,107333	0,096626	0,092424	0,095587	0,079026	9,420%
	10	Treino	0,208511	0,190032	0,130233	0,156682	0,163382	16,977%
		Teste	0,173674	0,149939	0,116468	0,109395	0,131968	13,629%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
11	1	Treino	0,167198	0,170608	0,197426	0,139463	0,153839	16,571%
		Teste	0,12864	0,136827	0,175669	0,085005	0,110977	12,742%
	2	Treino	0,162026	0,13836	0,187006	0,142685	0,132469	15,251%
		Teste	0,1583	0,091545	0,155192	0,089117	0,071061	11,304%
	3	Treino	0,155199	0,133631	0,161446	0,161629	0,155234	15,343%
		Teste	0,120928	0,089646	0,135809	0,126399	0,110549	11,667%
	4	Treino	0,148812	0,141171	0,154837	0,145726	0,138991	14,591%
		Teste	0,110122	0,089247	0,109074	0,102978	0,092353	10,075%
	5	Treino	0,159531	0,22337	0,155788	0,164138	0,142738	16,911%
		Teste	0,126565	0,206045	0,116894	0,107917	0,112984	13,408%
	6	Treino	0,146365	0,124443	0,137845	0,142834	0,150805	14,046%
		Teste	0,129586	0,070937	0,102259	0,108165	0,093626	10,091%
	7	Treino	0,116498	0,134781	0,16332	0,133697	0,140067	13,767%
		Teste	0,068882	0,081818	0,173535	0,080696	0,09132	9,925%
	8	Treino	0,142335	0,151709	0,147954	0,144534	0,150597	14,743%
		Teste	0,099214	0,131199	0,089572	0,107198	0,09644	10,472%
	9	Treino	0,132067	0,133218	0,219802	0,155375	0,128863	15,387%
		Teste	0,082852	0,098569	0,163125	0,133449	0,074971	11,059%
	10	Treino	0,136597	0,141695	0,131183	0,124659	0,134995	13,383%
		Teste	0,101876	0,092795	0,081112	0,058376	0,101726	8,718%
12	1	Treino	0,14486	0,150733	0,174018	0,151279	0,157549	15,569%
		Teste	0,088037	0,107138	0,136495	0,105769	0,106289	10,875%
	2	Treino	0,138133	0,207649	0,12915	0,129207	0,142774	14,938%
		Teste	0,085821	0,194869	0,08402	0,085059	0,087047	10,736%
	3	Treino	0,157615	0,143702	0,147846	0,129898	0,132621	14,234%
		Teste	0,061928	0,082562	0,095432	0,085911	0,076104	8,039%
	4	Treino	0,151703	0,175335	0,132991	0,131967	0,133162	14,503%
		Teste	0,096292	0,087679	0,084721	0,087434	0,089264	8,908%
	5	Treino	0,143145	0,135546	0,168185	0,127961	0,171159	14,920%
		Teste	0,131149	0,118931	0,10383	0,076074	0,101304	10,626%
	6	Treino	0,141106	0,123407	0,140205	0,182998	0,178868	15,332%
		Teste	0,091098	0,09397	0,107171	0,080082	0,134087	10,128%
	7	Treino	0,19338	0,187642	0,131405	0,144458	0,1222	15,582%
		Teste	0,109672	0,184466	0,133098	0,099616	0,12733	13,084%
	8	Treino	0,129568	0,126076	0,120308	0,130894	0,124247	12,622%
		Teste	0,104804	0,063979	0,100503	0,101131	0,090178	9,212%
	9	Treino	0,144456	0,160024	0,153125	0,151367	0,145056	15,081%
		Teste	0,10697	0,143067	0,138998	0,085645	0,101889	11,531%
	10	Treino	0,125496	0,13698	0,137795	0,179133	0,14975	14,583%
		Teste	0,083681	0,069753	0,119412	0,189002	0,12393	11,716%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
13	1	Treino	0,118448	0,120443	0,116059	0,14167	0,123539	12,403%
		Teste	0,062374	0,066227	0,057381	0,095561	0,071746	7,066%
	2	Treino	0,132079	0,141198	0,136495	0,116578	0,129817	13,123%
		Teste	0,083572	0,081221	0,09351	0,067812	0,075665	8,036%
	3	Treino	0,130945	0,118055	0,114369	0,172541	0,121933	13,157%
		Teste	0,099155	0,083696	0,077563	0,14619	0,080859	9,749%
	4	Treino	0,122379	0,159683	0,117606	0,146231	0,114293	13,204%
		Teste	0,082125	0,133842	0,075096	0,112013	0,059179	9,245%
	5	Treino	0,124345	0,112545	0,113048	0,123297	0,146873	12,402%
		Teste	0,080782	0,111802	0,085735	0,089914	0,129448	9,954%
	6	Treino	0,125577	0,111613	0,11192	0,158023	0,114623	12,435%
		Teste	0,072673	0,075489	0,092806	0,137788	0,072114	9,017%
	7	Treino	0,203958	0,121021	0,136793	0,14225	0,114954	14,380%
		Teste	0,182475	0,070123	0,108922	0,12606	0,09203	11,592%
	8	Treino	0,13108	0,115157	0,119085	0,117414	0,134087	12,336%
		Teste	0,089419	0,078174	0,063173	0,085508	0,098598	8,297%
	9	Treino	0,168315	0,138976	0,162393	0,134468	0,107185	14,227%
		Teste	0,141542	0,085234	0,109223	0,079612	0,076553	9,843%
	10	Treino	0,113215	0,178965	0,147629	0,117664	0,112235	13,394%
		Teste	0,108499	0,129693	0,127268	0,095061	0,090208	11,015%
14	1	Treino	0,145246	0,140797	0,132355	0,156688	0,153006	14,562%
		Teste	0,084005	0,089896	0,067817	0,10956	0,09618	8,949%
	2	Treino	0,133643	0,139622	0,141648	0,130175	0,132536	13,552%
		Teste	0,0725	0,082238	0,086199	0,069481	0,068089	7,570%
	3	Treino	0,145018	0,141172	0,161716	0,129569	0,198805	15,526%
		Teste	0,080502	0,090811	0,118378	0,069349	0,162101	10,423%
	4	Treino	0,166836	0,131878	0,157471	0,126951	0,13234	14,310%
		Teste	0,143744	0,067028	0,098913	0,074646	0,095481	9,596%
	5	Treino	0,196909	0,128066	0,129323	0,129264	0,181649	15,304%
		Teste	0,177843	0,09448	0,081872	0,091444	0,080359	10,520%
	6	Treino	0,138865	0,134636	0,151857	0,142905	0,129393	13,953%
		Teste	0,095724	0,087337	0,120562	0,086163	0,108316	9,962%
	7	Treino	0,127337	0,152074	0,149563	0,136123	0,16069	14,516%
		Teste	0,086306	0,12246	0,130006	0,096871	0,109337	10,900%
	8	Treino	0,125437	0,133484	0,123559	0,144918	0,142678	13,402%
		Teste	0,082462	0,096149	0,104159	0,120052	0,09188	9,894%
	9	Treino	0,127858	0,133053	0,128884	0,124014	0,127216	12,821%
		Teste	0,078914	0,082172	0,098912	0,069414	0,079566	8,180%
	10	Treino	0,135694	0,135739	0,127962	0,161152	0,158993	14,391%
		Teste	0,072002	0,077973	0,085438	0,165774	0,118829	10,400%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
15	1	Treino	0,14419	0,167959	0,144443	0,146189	0,168855	15,433%
		Teste	0,085925	0,118877	0,08466	0,087981	0,120731	9,963%
	2	Treino	0,143908	0,149238	0,171901	0,144863	0,15999	15,398%
		Teste	0,076912	0,082613	0,141122	0,097676	0,112035	10,207%
	3	Treino	0,143485	0,143286	0,1819	0,157796	0,141352	15,356%
		Teste	0,084321	0,087096	0,102705	0,071708	0,059184	8,100%
	4	Treino	0,139144	0,141522	0,138748	0,145953	0,144729	14,202%
		Teste	0,095207	0,094327	0,072264	0,079611	0,063773	8,104%
	5	Treino	0,137376	0,139733	0,213702	0,182775	0,153537	16,542%
		Teste	0,103132	0,094467	0,161157	0,100354	0,1165	11,512%
	6	Treino	0,157993	0,156967	0,152595	0,15262	0,16523	15,708%
		Teste	0,102403	0,122791	0,084062	0,126302	0,142659	11,564%
	7	Treino	0,190221	0,166902	0,22661	0,200592	0,139597	18,478%
		Teste	0,193445	0,131068	0,218582	0,161627	0,085864	15,812%
	8	Treino	0,168299	0,159735	0,14948	0,239833	0,176635	17,880%
		Teste	0,129142	0,086451	0,080481	0,211758	0,134391	12,844%
	9	Treino	0,181357	0,161262	0,140864	0,136952	0,179351	15,996%
		Teste	0,115389	0,103802	0,070828	0,060606	0,10429	9,098%
	10	Treino	0,147159	0,167633	0,245614	0,144777	0,145527	17,014%
		Teste	0,109839	0,130399	0,189713	0,10478	0,077295	12,241%
16	1	Treino	0,146528	0,165109	0,145748	0,145826	0,180591	15,676%
		Teste	0,092258	0,107631	0,091046	0,088186	0,135705	10,297%
	2	Treino	0,13785	0,152668	0,166851	0,145851	0,155452	15,173%
		Teste	0,083245	0,07144	0,111924	0,092902	0,103454	9,259%
	3	Treino	0,165863	0,156314	0,166882	0,155265	0,171676	16,320%
		Teste	0,116399	0,081638	0,114526	0,085524	0,120498	10,372%
	4	Treino	0,147984	0,142916	0,142911	0,169634	0,146012	14,989%
		Teste	0,106749	0,104126	0,094684	0,141311	0,113058	11,199%
	5	Treino	0,177686	0,160877	0,157691	0,139814	0,141048	15,542%
		Teste	0,127711	0,086819	0,125288	0,073656	0,102416	10,318%
	6	Treino	0,141109	0,163142	0,164976	0,217456	0,166178	17,057%
		Teste	0,088414	0,098983	0,113384	0,184376	0,122115	12,145%
	7	Treino	0,130043	0,166584	0,142418	0,143515	0,174749	15,146%
		Teste	0,085553	0,131993	0,093317	0,109878	0,139241	11,200%
	8	Treino	0,233089	0,170746	0,144424	0,140764	0,17559	17,292%
		Teste	0,24301	0,140801	0,094458	0,086713	0,138623	14,072%
	9	Treino	0,142353	0,143045	0,164106	0,138331	0,130581	14,368%
		Teste	0,089458	0,086517	0,102142	0,088601	0,084841	9,031%
	10	Treino	0,164499	0,147709	0,136896	0,177635	0,138683	15,308%
		Teste	0,113566	0,110252	0,087129	0,105641	0,077476	9,881%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
17	1	Treino	0,148609	0,19593	0,133843	0,160338	0,180111	16,377%
		Teste	0,100323	0,17245	0,084453	0,120384	0,162799	12,808%
	2	Treino	0,143228	0,129178	0,164329	0,140558	0,14077	14,361%
		Teste	0,099208	0,088216	0,079073	0,076807	0,088813	8,642%
	3	Treino	0,125332	0,147639	0,140682	0,138153	0,146462	13,965%
		Teste	0,076283	0,109971	0,079094	0,099753	0,089534	9,093%
	4	Treino	0,142629	0,125195	0,12446	0,138869	0,1485	13,593%
		Teste	0,095727	0,079387	0,076488	0,096417	0,097316	8,907%
	5	Treino	0,130775	0,127448	0,135867	0,149247	0,134848	13,564%
		Teste	0,086237	0,080433	0,090608	0,085216	0,0768	8,386%
	6	Treino	0,150525	0,16238	0,132974	0,130539	0,15222	14,573%
		Teste	0,106216	0,094931	0,10912	0,087904	0,087071	9,705%
	7	Treino	0,157583	0,188337	0,147249	0,184058	0,143198	16,408%
		Teste	0,117681	0,157626	0,118784	0,162848	0,069393	12,527%
	8	Treino	0,154031	0,143348	0,123114	0,131261	0,133962	13,714%
		Teste	0,069002	0,112041	0,090399	0,08694	0,069242	8,552%
	9	Treino	0,123432	0,140171	0,171166	0,14672	0,156811	14,766%
		Teste	0,098674	0,093088	0,099996	0,104931	0,071808	9,370%
	10	Treino	0,126078	0,122365	0,160429	0,116185	0,24211	15,343%
		Teste	0,069551	0,084599	0,12607	0,101657	0,206909	11,776%
18	1	Treino	0,159728	0,128064	0,142094	0,15126	0,137498	14,373%
		Teste	0,137323	0,097182	0,119957	0,11058	0,110641	11,514%
	2	Treino	0,174665	0,116874	0,140633	0,183391	0,127115	14,854%
		Teste	0,145352	0,078704	0,117042	0,163372	0,100244	12,094%
	3	Treino	0,113384	0,126184	0,114115	0,13719	0,137256	12,563%
		Teste	0,074607	0,077342	0,089522	0,105783	0,076877	8,483%
	4	Treino	0,12118	0,166784	0,110316	0,118701	0,114002	12,620%
		Teste	0,086767	0,15433	0,078947	0,075105	0,087155	9,646%
	5	Treino	0,11146	0,142887	0,175463	0,125513	0,222358	15,554%
		Teste	0,093316	0,149834	0,136886	0,097247	0,195399	13,454%
	6	Treino	0,108161	0,137523	0,111146	0,108598	0,113256	11,574%
		Teste	0,107654	0,107234	0,081413	0,0757	0,090643	9,253%
	7	Treino	0,111379	0,140741	0,124167	0,109929	0,11283	11,981%
		Teste	0,093287	0,152966	0,128235	0,086344	0,10766	11,370%
	8	Treino	0,131459	0,112367	0,225975	0,122543	0,241505	16,677%
		Teste	0,112418	0,078351	0,245211	0,112867	0,266924	16,315%
	9	Treino	0,109231	0,112696	0,136154	0,156228	0,116419	12,615%
		Teste	0,096549	0,07897	0,08549	0,1493	0,110163	10,409%
	10	Treino	0,1219	0,144592	0,119776	0,121088	0,110363	12,354%
		Teste	0,121929	0,09643	0,122782	0,105767	0,087615	10,690%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
19	1	Treino	0,11306	0,143855	0,14614	0,120674	0,158821	13,651%
		Teste	0,099707	0,12	0,154515	0,100348	0,150601	12,503%
	2	Treino	0,128757	0,137489	0,120987	0,132922	0,106638	12,536%
		Teste	0,097224	0,142112	0,115174	0,128625	0,085126	11,365%
	3	Treino	0,11115	0,118555	0,147142	0,154027	0,126724	13,152%
		Teste	0,096396	0,111139	0,132208	0,121453	0,121176	11,647%
	4	Treino	0,154089	0,103694	0,124932	0,113444	0,135081	12,625%
		Teste	0,146808	0,090785	0,105992	0,079794	0,115715	10,782%
	5	Treino	0,155911	0,118636	0,108535	0,125988	0,137842	12,938%
		Teste	0,126651	0,119223	0,092758	0,13362	0,142711	12,299%
	6	Treino	0,143987	0,105322	0,130246	0,108552	0,134026	12,443%
		Teste	0,117951	0,116829	0,113253	0,094613	0,121217	11,277%
	7	Treino	0,107854	0,093489	0,143158	0,110439	0,129785	11,694%
		Teste	0,118355	0,101974	0,125649	0,11311	0,097171	11,125%
	8	Treino	0,162378	0,12299	0,179841	0,112239	0,137375	14,296%
		Teste	0,190734	0,094513	0,151417	0,112576	0,161962	14,224%
	9	Treino	0,134491	0,109394	0,110303	0,105808	0,1289	11,778%
		Teste	0,1262	0,097423	0,086455	0,114825	0,087201	10,242%
	10	Treino	0,127743	0,119493	0,112055	0,116379	0,138711	12,288%
		Teste	0,084823	0,077454	0,077854	0,086796	0,105433	8,647%
20	1	Treino	0,106476	0,108086	0,140848	0,120748	0,113472	11,793%
		Teste	0,070403	0,074528	0,115542	0,083305	0,088864	8,653%
	2	Treino	0,114698	0,119137	0,110646	0,112549	0,113359	11,408%
		Teste	0,071096	0,086159	0,080917	0,074592	0,064009	7,535%
	3	Treino	0,100527	0,119109	0,097522	0,099347	0,107429	10,479%
		Teste	0,069335	0,075039	0,060939	0,063779	0,070766	6,797%
	4	Treino	0,12824	0,128871	0,100651	0,104883	0,10351	11,323%
		Teste	0,070454	0,091683	0,067269	0,067571	0,076525	7,470%
	5	Treino	0,092833	0,108629	0,094515	0,117573	0,096869	10,208%
		Teste	0,092204	0,073928	0,07019	0,080476	0,06912	7,718%
	6	Treino	0,097464	0,12196	0,103646	0,093062	0,101931	10,361%
		Teste	0,069442	0,089427	0,067921	0,058528	0,082079	7,348%
	7	Treino	0,159126	0,098983	0,139679	0,11328	0,089064	12,003%
		Teste	0,101289	0,062642	0,065546	0,093355	0,096722	8,391%
	8	Treino	0,11773	0,099367	0,100563	0,097941	0,120055	10,713%
		Teste	0,104042	0,071248	0,101442	0,078643	0,087889	8,865%
	9	Treino	0,097248	0,108588	0,128093	0,091768	0,095954	10,433%
		Teste	0,080706	0,060323	0,127553	0,075258	0,062476	8,126%
	10	Treino	0,1035	0,097508	0,108495	0,139522	0,090117	10,783%
		Teste	0,083465	0,089338	0,093492	0,103159	0,088024	9,150%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
21	1	Treino	0,09357	0,096598	0,123073	0,105614	0,102827	10,434%
		Teste	0,053478	0,067713	0,101305	0,087109	0,069453	7,581%
	2	Treino	0,123021	0,116645	0,092695	0,091241	0,109149	10,655%
		Teste	0,077201	0,096428	0,056629	0,052229	0,058409	6,818%
	3	Treino	0,145395	0,102276	0,100774	0,102008	0,135392	11,717%
		Teste	0,101365	0,078584	0,07042	0,081407	0,09788	8,593%
	4	Treino	0,086757	0,090992	0,110481	0,10786	0,113817	10,198%
		Teste	0,073487	0,065967	0,083	0,060686	0,09604	7,584%
	5	Treino	0,113982	0,085733	0,104869	0,096176	0,092913	9,873%
		Teste	0,083642	0,055177	0,082139	0,059485	0,059751	6,804%
	6	Treino	0,116905	0,088112	0,099745	0,159801	0,094542	11,182%
		Teste	0,066052	0,06725	0,07235	0,087634	0,062788	7,121%
	7	Treino	0,113303	0,099411	0,107904	0,104003	0,099269	10,478%
		Teste	0,076379	0,068734	0,083879	0,085291	0,068276	7,651%
	8	Treino	0,084678	0,146153	0,113531	0,089293	0,092671	10,527%
		Teste	0,057122	0,106475	0,073979	0,065391	0,068669	7,433%
	9	Treino	0,09532	0,109368	0,130415	0,141961	0,102148	11,584%
		Teste	0,054313	0,079575	0,096352	0,117811	0,061856	8,198%
	10	Treino	0,135296	0,124006	0,087978	0,083185	0,082746	10,264%
		Teste	0,101291	0,128353	0,05912	0,069817	0,061217	8,396%
22	1	Treino	0,091258	0,082945	0,094715	0,086933	0,082623	8,769%
		Teste	0,080106	0,063297	0,058393	0,068529	0,063028	6,667%
	2	Treino	0,089432	0,092373	0,092797	0,097262	0,081327	9,064%
		Teste	0,061209	0,074089	0,063768	0,040728	0,057502	5,946%
	3	Treino	0,083564	0,082388	0,083262	0,101183	0,110736	9,223%
		Teste	0,053938	0,052962	0,057083	0,093943	0,076624	6,691%
	4	Treino	0,081029	0,092093	0,109136	0,079434	0,095301	9,140%
		Teste	0,06315	0,082782	0,110723	0,058913	0,077126	7,854%
	5	Treino	0,095727	0,113604	0,079126	0,086972	0,076593	9,040%
		Teste	0,071977	0,092725	0,052067	0,064126	0,057904	6,776%
	6	Treino	0,093805	0,097667	0,12288	0,074822	0,076988	9,323%
		Teste	0,084138	0,08466	0,112016	0,060472	0,058112	7,988%
	7	Treino	0,101261	0,076807	0,093352	0,088447	0,086088	8,919%
		Teste	0,059152	0,055645	0,074928	0,067635	0,065857	6,464%
	8	Treino	0,083784	0,100106	0,112908	0,084247	0,081037	9,242%
		Teste	0,06594	0,089134	0,102873	0,062523	0,061533	7,640%
	9	Treino	0,120368	0,085987	0,123069	0,086957	0,07794	9,886%
		Teste	0,071666	0,061781	0,09459	0,067745	0,056755	7,051%
	10	Treino	0,081844	0,078328	0,087869	0,096655	0,094541	8,785%
		Teste	0,061358	0,069591	0,073799	0,056456	0,071703	6,658%

Hora	Neurónios	Dados	Treino					Média
			1	2	3	4	5	
23	1	Treino	0,126125	0,105571	0,108075	0,109544	0,108521	11,157%
		Teste	0,090263	0,073839	0,078026	0,079788	0,081873	8,076%
	2	Treino	0,100675	0,109861	0,111502	0,105652	0,13464	11,247%
		Teste	0,071851	0,074985	0,087787	0,079115	0,11632	8,601%
	3	Treino	0,098729	0,102357	0,091615	0,091307	0,10768	9,834%
		Teste	0,05724	0,067018	0,059994	0,067473	0,07957	6,626%
	4	Treino	0,099396	0,10533	0,114357	0,1059	0,113691	10,773%
		Teste	0,068289	0,060647	0,08386	0,064974	0,083013	7,216%
	5	Treino	0,090043	0,08934	0,091486	0,146868	0,105368	10,462%
		Teste	0,071108	0,054364	0,057142	0,099693	0,076881	7,184%
	6	Treino	0,087551	0,095019	0,094052	0,115158	0,096172	9,759%
		Teste	0,057877	0,062724	0,068042	0,072296	0,055897	6,337%
	7	Treino	0,111735	0,087219	0,093982	0,087772	0,092162	9,457%
		Teste	0,071622	0,05371	0,063888	0,05869	0,062117	6,201%
	8	Treino	0,095776	0,119709	0,088679	0,101893	0,100119	10,124%
		Teste	0,062009	0,088092	0,05662	0,071801	0,062244	6,815%
	9	Treino	0,09489	0,120221	0,092039	0,11279	0,090615	10,211%
		Teste	0,068481	0,110125	0,068939	0,084263	0,072362	8,083%
	10	Treino	0,127249	0,086517	0,08684	0,103635	0,094748	9,980%
		Teste	0,131929	0,055071	0,069559	0,078248	0,070586	8,108%
24	1	Treino	0,12164	0,126487	0,140659	0,119403	0,126156	12,687%
		Teste	0,07257	0,080226	0,086892	0,065939	0,075544	7,623%
	2	Treino	0,130478	0,131657	0,117941	0,119843	0,132906	12,656%
		Teste	0,084229	0,083602	0,060725	0,070794	0,092594	7,839%
	3	Treino	0,120575	0,111109	0,171347	0,10693	0,164332	13,486%
		Teste	0,075764	0,073283	0,133442	0,072911	0,117611	9,460%
	4	Treino	0,105138	0,111768	0,129029	0,108014	0,105843	11,196%
		Teste	0,057185	0,066293	0,086721	0,076029	0,068952	7,104%
	5	Treino	0,108773	0,099803	0,138666	0,114768	0,104192	11,324%
		Teste	0,058414	0,060126	0,081279	0,073465	0,062792	6,722%
	6	Treino	0,13783	0,101542	0,162913	0,097588	0,160144	13,200%
		Teste	0,096625	0,066584	0,099089	0,065881	0,147552	9,515%
	7	Treino	0,111003	0,11063	0,108571	0,128338	0,111055	11,392%
		Teste	0,060012	0,064354	0,08256	0,082664	0,06968	7,185%
	8	Treino	0,111885	0,108963	0,106993	0,119678	0,102405	10,998%
		Teste	0,07654	0,073921	0,07196	0,083991	0,067741	7,483%
	9	Treino	0,102955	0,142517	0,104107	0,101204	0,12264	11,468%
		Teste	0,067266	0,090148	0,076433	0,072481	0,100812	8,143%
	10	Treino	0,123228	0,110139	0,109834	0,107191	0,089815	10,804%
		Teste	0,091198	0,061025	0,066413	0,071353	0,093461	7,669%

ANEXO II – Erros MAPE obtidos em função do tipo de previsão para as máquinas de suporte vetorial

Modelo Hora seguinte (HS)

Número máximo de iterações	100	300	500
Erro MAPE (%)	4,752%	4,748%	4,809%

Modelo Dia seguinte (DS)

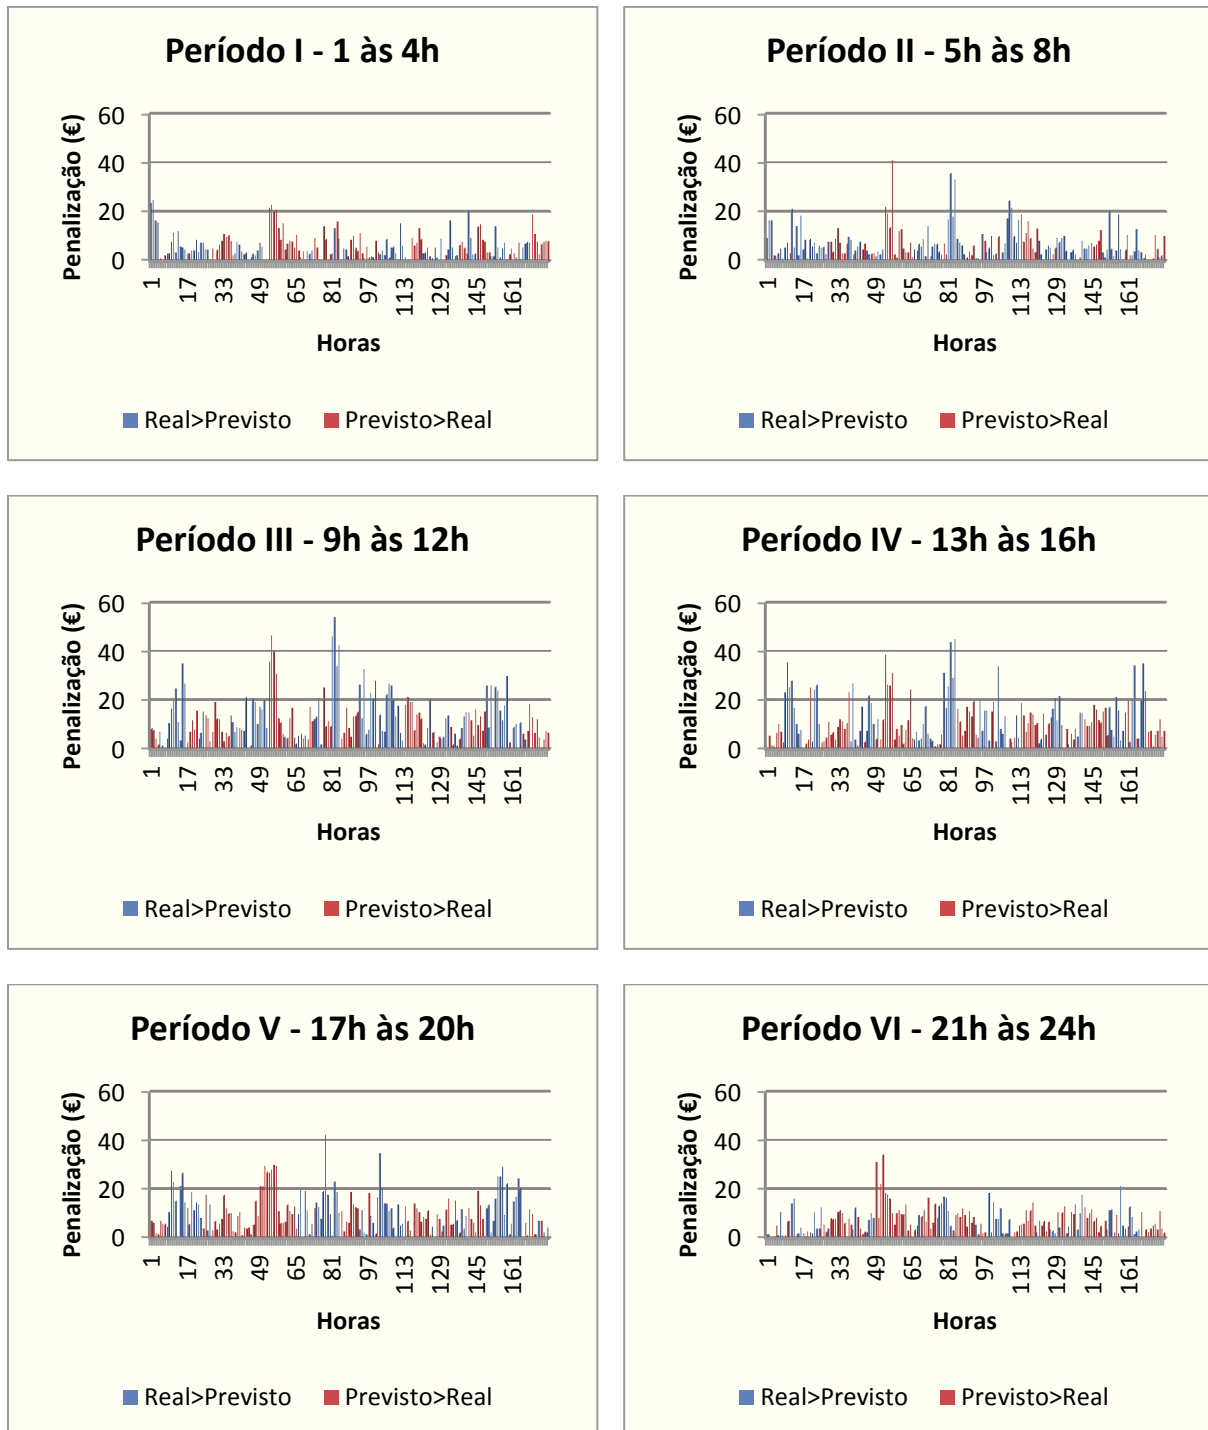
Número máximo de iterações	100	300	500
Erro MAPE (%)	6,244%	6,078%	5,887%

Modelo Semana seguinte (SS)







Número máximo de iterações	100	300	500
Erro MAPE (%)	6,157%	6,048%	6,128%

ANEXO III - Análise económica para diferentes períodos horários

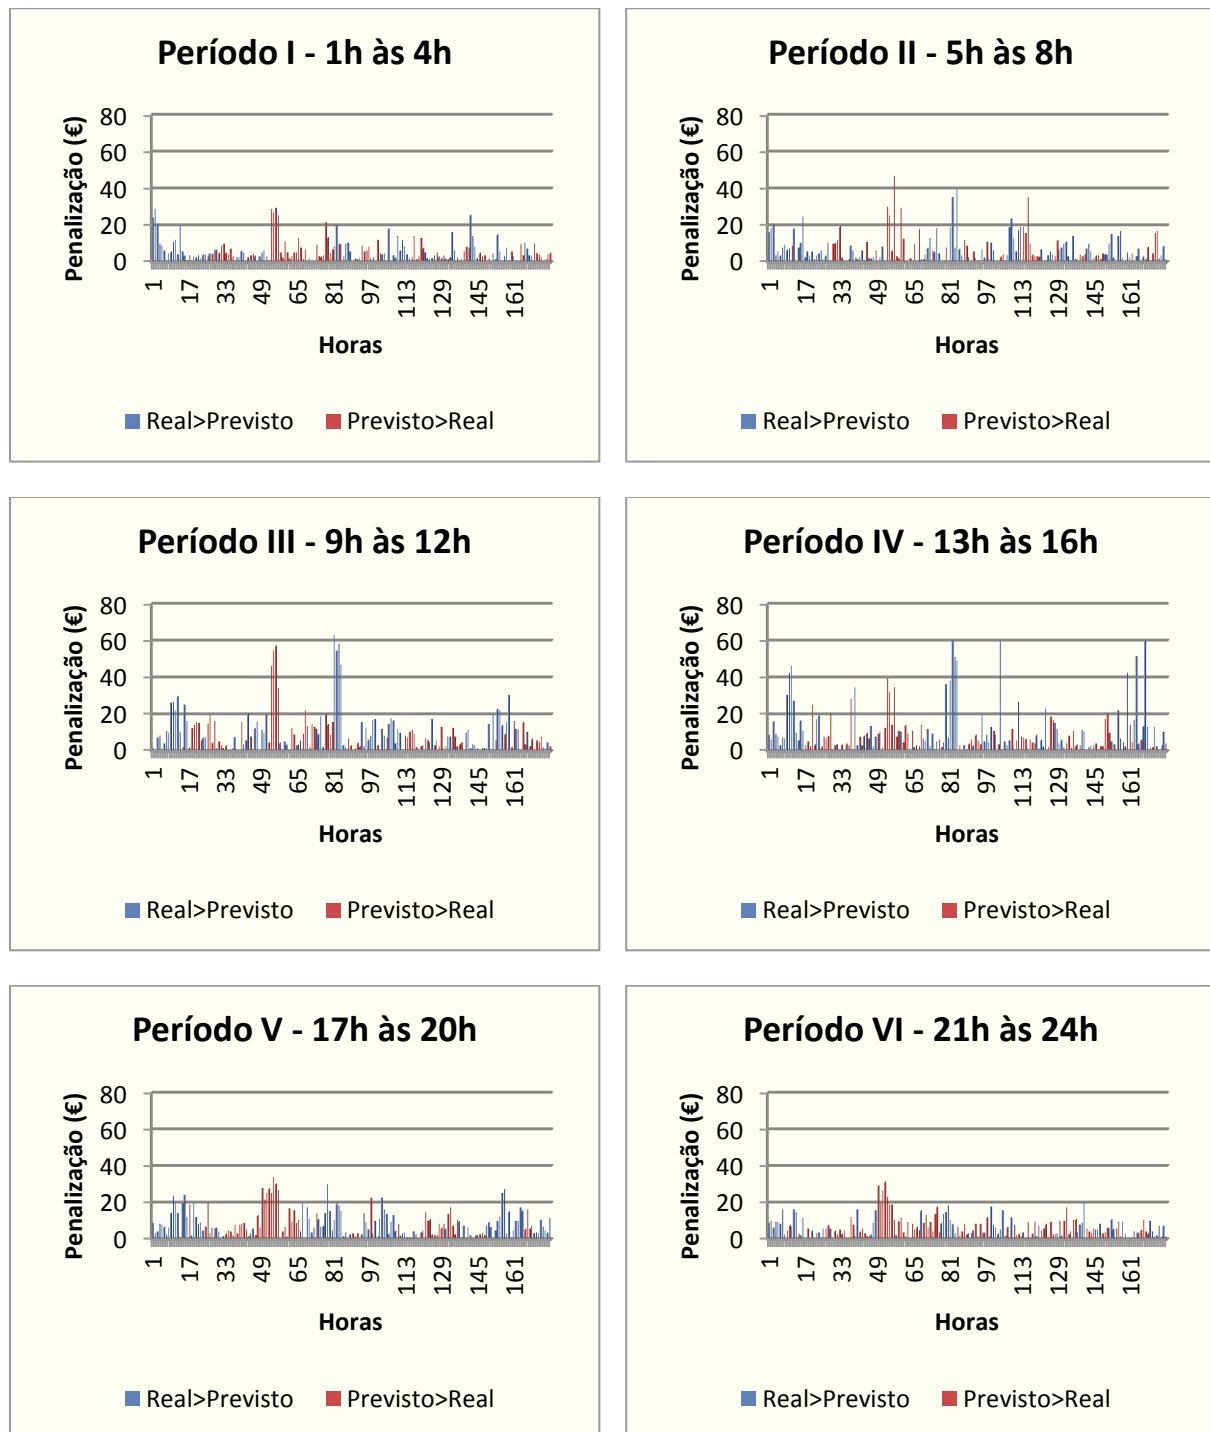
Resultados das redes neuronais artificiais (RNA)



Resultados da regressão linear (RL)









Resultados das máquinas de suporte vetorial (SVM)









ANEXO IV - Análise económica da combinação de métodos para todas as horas dos dias

Resultados da combinação dos métodos redes neuronais artificiais, regressão linear e máquinas de suporte vetorial (RNA+RL+SVM)







Período da 1 às 6 horas









Período das 7 às 12 horas



Período das 13 às 18 horas



Período das 19 às 24 horas



8 Bibliografia

- Abbas, S. R., & Arif, M. (2006). Electric Load Forecasting Using Support Vector Machines Optimized by Genetic Algorithm. In *IEEE Multitopic Conference, 2006. INMIC '06* (pp. 395–399). doi:10.1109/INMIC.2006.358199
- Bakirtzis, A. G., Petridis, V., Kiartzis, S. J., Alexiadis, M. C., & Maissis, A. H. (1996). A neural network short term load forecasting model for the Greek power system. *IEEE Transactions on Power Systems*, *11*(2), 858–863. doi:10.1109/59.496166
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2014). *Neural Network Toolbox - User's Guide*. MathWorks. Retrieved from http://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf
- Billinton, R., & N. Allan, R. (1984). *Reliability evaluation of power systems* (Vol. 2.). New York: Plenum Press.
- Bunn, D. W., & Farmer, E. D. (1985). Review of Short-term Forecasting Methods in the Electric Power Industry. *New York Wiley*, 13–30.
- Chen, S.-T., Yu, D. C., & Moghaddamjo, A. R. (1992). Weather sensitive short-term load forecasting using nonfully connected artificial neural network. *IEEE Transactions on Power Systems*, *7*(3), 1098–1105. doi:10.1109/59.207323
- Chow, T. W. S., & Leung, C. T. (1996). Nonlinear autoregressive integrated neural network model for short-term load forecasting. *Generation, Transmission and Distribution, IEE Proceedings-*, *143*(5), 500–506. doi:10.1049/ip-gtd:19960600
- Connor, J. T. (1996). A robust neural network filter for electricity demand prediction. *Journal of Forecasting*, *15*(6), 437–458. doi:10.1002/(SICI)1099-131X(199611)15:6<437::AID-FOR634>3.0.CO;2-H
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, *20*(3), 273–297. doi:10.1007/BF00994018

- Daneshdoost, M., Lotfalian, M., Bumroonggit, G., & Ngoy, J. P. (1998). Neural network with fuzzy set-based classification for short-term load forecasting. *IEEE Transactions on Power Systems*, 13(4), 1386–1391. doi:10.1109/59.736281
- Dorigo, M. (2004). Metaheuristics Network web site. Retrieved from <http://www.metaheuristics.net/>
- Drezga, I., & Rahman, S. (1998). Input variable selection for ANN-based short-term load forecasting. *IEEE Transactions on Power Systems*, 13(4), 1238–1244. doi:10.1109/59.736244
- Fidalgo, J. N., & Matos, M. A. (2007). Forecasting Portugal Global Load with Artificial Neural Networks. In J. M. de Sá, L. A. Alexandre, W. Duch, & D. Mandic (Eds.), *Artificial Neural Networks – ICANN 2007* (pp. 728–737). Springer Berlin Heidelberg. Retrieved from http://link.springer.com/chapter/10.1007/978-3-540-74695-9_75
- Ghanbari, A., Hadavandi, E., & Abbasian-Naghneh, S. (2010). Comparison of Artificial Intelligence Based Techniques for Short Term Load Forecasting. In *2010 Third International Conference on Business Intelligence and Financial Engineering (BIFE)* (pp. 6–10). doi:10.1109/BIFE.2010.12
- Gross, G., & Galiana, F. D. (1987). Short-term load forecasting. *Proceedings of the IEEE*, 75(12), 1558–1573. doi:10.1109/PROC.1987.13927
- Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS Technical Report 14*.
- Guo, Y.-C., Niu, D., & Chen, Y.-X. (2006). Support Vector Machine Model in Electricity Load Forecasting. In *2006 International Conference on Machine Learning and Cybernetics* (pp. 2892–2896). doi:10.1109/ICMLC.2006.259076
- Hippert, H. S., Pedreira, C. E., & Souza, R. C. (2001). Neural networks for short-term load forecasting: a review and evaluation. *IEEE Transactions on Power Systems*, 16(1), 44–55. doi:10.1109/59.910780
- Kiartzis, S. J., Zoumas, C. E., Theocharis, J. B., Bakirtzis, A. G., & Petridis, V. (1997). Short-term load forecasting in an autonomous power system using artificial neural networks. *IEEE Transactions on Power Systems*, 12(4), 1591–1596. doi:10.1109/59.627863

- Lu, C. N., Wu, H.-T., & Vemuri, S. (1993). Neural network based short term load forecasting. *IEEE Transactions on Power Systems*, 8(1), 336–342. doi:10.1109/59.221223
- Lu, N., Zhou, J., He, Y., & Liu, Y. (2009). Simulated Annealing Theory Based Particle Swarm Optimization for Support Vector Machine Model in Short-Term Load Forecasting. In *International Conference on Information Engineering and Computer Science, 2009. ICIECS 2009* (pp. 1–4). doi:10.1109/ICIECS.2009.5366400
- Madeo, R. C. B., Lima, C. A. M., & Peres, S. M. (2012). A Review on Temporal Reasoning Using Support Vector Machines. In *2012 19th International Symposium on Temporal Representation and Reasoning (TIME)* (pp. 114–121). doi:10.1109/TIME.2012.15
- Makridakis, S. G., & Wheelwright, S. C. (1978). *Forecasting: methods and applications*. Wiley.
- Moghram, I. S., & Rahman, S. (1989). Analysis and evaluation of five short-term load forecasting techniques. *IEEE Transactions on Power Systems*, 4(4), 1484–1491. doi:10.1109/59.41700
- Mohammadi-Ivatloo, B., Zareipour, H., Ehsan, M., & Amjady, N. (2011). Economic impact of price forecasting inaccuracies on self-scheduling of generation companies. *Electric Power Systems Research*, 81(2), 617–624. doi:10.1016/j.epsr.2010.10.022
- Murteira, B., Ribeiro, C. S., Silva, J. A., & Pimenta, C. (2007). *Introdução à Estatística*. McGraw-Hill.
- Ortega-Vazquez, M. A., & Kirschen, D. S. (2006). Economic impact assessment of load forecast errors considering the cost of interruptions. In *IEEE Power Engineering Society General Meeting, 2006* (p. 8 pp.–). doi:10.1109/PES.2006.1709231
- Pai, P.-F., & Hong, W.-C. (2005). Support vector machines with simulated annealing algorithms in electricity load forecasting. *Energy Conversion and Management*, 46(17), 2669–2688. doi:10.1016/j.enconman.2005.02.004
- Piras, A., Germond, A., Buchenel, B., Imhof, K., & Jaccard, Y. (1996). Heterogeneous artificial neural network for short term electrical load forecasting. *IEEE Transactions on Power Systems*, 11(1), 397–402. doi:10.1109/59.486124
- Ranaweera, D. K., Karady, G. G., & Farmer, R. G. (1997). Economic impact analysis of load forecasting. *IEEE Transactions on Power Systems*, 12(3), 1388–1392. doi:10.1109/59.630486

- Raza, M. Q., & Baharudin, Z. (2012). A review on short term load forecasting using hybrid neural network techniques. In *2012 IEEE International Conference on Power and Energy (PECon)* (pp. 846–851). doi:10.1109/PECon.2012.6450336
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533–536. doi:10.1038/323533a0
- Srinivasan, D., & Lee, M. A. (1995). Survey of hybrid fuzzy neural approaches to electric load forecasting. In , *IEEE International Conference on Systems, Man and Cybernetics, 1995. Intelligent Systems for the 21st Century* (Vol. 5, pp. 4004–4008 vol.5). doi:10.1109/ICSMC.1995.538416
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks:: The state of the art. *International Journal of Forecasting*, *14*(1), 35–62. doi:10.1016/S0169-2070(97)00044-7