

Faculdade de Engenharia da Universidade do Porto



**Classificação da segurança de Sistemas
Interligados com Elevada Penetração Eólica com
Base em Rede Neurais Artificiais**

Gonçalo Amílcar Frias Azinheiro

Versão Final

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Electrotécnica e de Computadores
Major Energia

Orientadora: Prof. Doutora Maria Helena Osório Pestana de Vasconcelos

Junho de 2010

Resumo

Nesta dissertação são estudadas e aplicadas Redes Neurais Artificiais (ANN), com a finalidade de classificar de forma rápida e segura a segurança dinâmica de sistemas interligados que explorem elevadas penetrações eólicas, onde os requisitos de capacidade de sobreviver a cavas de tensão não tinham sido totalmente adoptados.

A qualidade dos resultados fornecidos pelas ANN foi avaliada por aplicação a um problema de segurança de uma rede interligada, já criada no âmbito dos trabalhos descritos em [1].

Para este efeito foram estudadas e aplicadas estruturas de ANN apropriadas para classificação, nomeadamente as *Multilayer Perceptron (MLP)* e as *Probabilistic Neural Networks (PNN)*, tendo estas técnicas sido escolhidas atendendo às funcionalidades disponibilizadas pela *toolbox* de ANN do *software* MATLAB.

A elaboração desta dissertação teve como base os trabalhos desenvolvidos em [1], tendo sido realizados na Faculdade de Engenharia da Universidade do Porto

Abstract

In this dissertation Artificial Neural Networks (ANN) are studied and tested with the propose to a fast and accurate classification of the dynamic security of interconnected power systems with a high wind power production, and where the fault ride through capabilities of theses power facilities have not been entirely adopted.

The quality of the results provided by the ANN's was evaluated by applying them to a security problem of an interconnected network, already created due the work done in [1].

In order to obtain accurate classification of the system security, regarding to the problem under analysis, Multilayer Perceptron Neural Networks (MLP) and Probabilistic Neural Networks were used. This ANN's were chosen regarding the capabilities of the Neural Networks toolbox of the software MATLAB.

This dissertation was based in the work developed in [1] and was carried out at FEUP (Faculdade de Engenharia da Universidade do Porto)

Résumé

Dans ce mémoire sont étudiés et appliqués les Réseaux de neurones artificiels (ANN), qui ont pour finalités de classer de façon rapide et certaine, la sécurité dynamique des systèmes électriques interconnectés qui intègrent des niveaux élevés de production éolienne, où celle-ci n'a pas la capacité de survivre aux baisses de tension, qui n'a pas été adopté par la totalité de la production.

La qualité des résultats fournis pour les ANN a été évaluée par une application de réseau interconnecté à un problème de sécurité. Déjà créé dans l'étude décrite en [1].

.A cet effet les structures ANN appropriées pour la classification ont été étudiées et appliquées, plus concrètement les *Multilayer Perceptron (MLP)* ainsi que les *Probabilistic Neural Networks (PNN)* ont été choisis, en attendant les fonctions disponibles pour la *Toolbox* des ANN du logiciel MATLAB.

L'élaboration du mémoire a eu comme base les travaux développés en [1], qui ont été réalisés dans la Faculté d'ingénierie de l'Université de Porto (FEUP).

Agradecimento

Em primeiro lugar gostaria de agradecer à minha orientadora, Professora Doutora Maria Helena Osório Pestana de Vasconcelos, pela confiança depositada em mim, pela sua disponibilidade demonstrada ao longo deste trabalho e a todo suporte técnico que disponibilizou.

Queria também agradecer aos meus pais e irmã pelo apoio e amor incondicional e pela paciência demonstrada.

Finalmente, um grande obrigado para os meus amigos e à minha namorada por terem estado presentes nesta caminhada.

*“Dar menos que o seu melhor
é sacrificar o dom que recebeu”*

Steve Fontaine

Índice

Resumo	i
Abstract.....	iii
Résumé	v
Agradecimento	vii
Índice.....	xi
Lista de Figuras	xiii
Lista de Tabelas	xxi
Abreviaturas e Símbolos	xxiii
Capítulo 1	1
Introdução.....	1
1.1 - Considerações Gerais.....	1
1.2 - Objectivos da Dissertação	3
1.3 - Estrutura da Dissertação.....	4
Capítulo 2	5
Problema de Segurança em Análise	5
2.1 - Introdução.....	5
2.2 - Rede Interligada de Teste	6
2.3 - Tipo de Perturbação Considerada.....	7
2.4 - Índices de Segurança	9
2.5 - Conjunto de Dados Gerado	9
2.6 - Vector das Variáveis de Entrada Candidatas	11
2.7 - Cenários Gerados para a Rede Interligada de Teste.....	13
Capítulo 3	17
Utilização de ANN para Classificação	17
3.1 - Introdução.....	17
3.2 - Estimativa do Erro de Classificação e de Regressão	18
3.3 - Redes Neurais Estudadas	23
3.3.1 - Multilayer Perceptrons (MLP).....	23
3.3.2 - Probabilistic Neural Networks (PNN).....	29

3.4 - Avaliação da capacidade generalização	32
3.5 - Comparação de desempenho entre as ANN estudadas	33
Capítulo 4	37
Resultados Obtidos do Treino das ANN	37
4.1 - Estudo do vector das variáveis de entrada.....	37
4.2 - Resultados da ANN treinadas para classificação	42
4.2.1 - Resultados das ANN do tipo MLP.....	42
4.2.2 - Resultados das ANN do tipo PNN.....	62
4.3 - Comparação de desempenho entre as ANN testadas	66
4.4 - Conclusão	84
Capítulo 5	87
Conclusões	87
5.1 - Considerações Finais	87
5.2 - Perspectivas Futuras	88
Referências	89
Anexos	91
Anexo 1: Resultados Obtidos para as Alternativas Treinadas para as ANN do Tipo MLP	93

Lista de Figuras

Figura 1.1 - Algoritmo proposto em [1]	3
Figura 2.1 - Rede em análise	7
Figura 2.2 - Descrição funcional do algoritmo de geração de dados [1]	9
Figura 2.3 - Número de cenários de operação seguros /inseguros gerados por linha de transmissão crítica	14
Figura 2.4 - Distribuição dos casos inseguros pelos conjuntos de dados	15
Figura 3.1 - Matriz confusão[5]	20
Figura 3.2 Estrutura de um neurónio de um MLP[9]	24
Figura 3.3 Exemplo das funções de activação usualmente utilizadas em MLP [10]	25
Figura 3.4 Estrutura de uma MLP (ex. com uma camada escondida)[7, 12]	26
Figura 3.5 Arquitectura da PNN utilizada	30
Figura 3.6 Função radial [10]	31
Figura 3.7 - Exemplo da distribuição utilizada num teste de hipóteses [2]	35
Figura 4.1 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 15-16	38
Figura 4.2 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 15-17	38
Figura 4.3 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 14 -18	39
Figura 4.4 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-4	39
Figura 4.5 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-6	40

Figura 4.6 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-18.....	40
Figura 4.7 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 20 - 21	41
Figura 4.8 - Comparação de desempenho entre as alt. A e B de saídas da ANN.....	41
Figura 4.9 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 15-16	43
Figura 4.10 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 15-17	44
Figura 4.11 - Erros(Global, MA e FA) das 50 ANN obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 14-18	44
Figura 4.12 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-4.....	45
Figura 4.13 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-6.....	45
Figura 4.14 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-18	46
Figura 4.15 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 20-21	46
Figura 4.16 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa C.....	48
Figura 4.17 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa D.....	49
Figura 4.18 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa E	50
Figura 4.19 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa F	51
Figura 4.20 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa G	52
Figura 4.21 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa H.....	53
Figura 4.22 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa I.....	54
Figura 4.23 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa J	55
Figura 4.24 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa L	56
Figura 4.25 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa M	57

Figura 4.26 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa N.....	58
Figura 4.27 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa O.....	59
Figura 4.28 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa B.....	61
Figura 4.29 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 15-16	62
Figura 4.30 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 15-17	63
Figura 4.31 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 14-18	63
Figura 4.32 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 16-4	64
Figura 4.33 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 16-6	64
Figura 4.34 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 16-18	65
Figura 4.35 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada <i>spread</i> da linha 20-21	65
Figura 4.36 - Comparação de desempenho entre as alt. C e D	67
Figura 4.37 - Comparação de desempenho entre as alt. E e F	68
Figura 4.38 - Comparação de desempenho entre as escolhas do T.H. 1 e 2	69
Figura 4.39 - Comparação de desempenho entre as alt. G e H.....	71
Figura 4.40 - Comparação de desempenho entre as alt. I e J	72
Figura 4.41 - Comparação de desempenho entre as escolhas do T.H. 4 e 5	73
Figura 4.42 - Comparação de desempenho entre as alt. L e M	75
Figura 4.43 - Comparação de desempenho entre as alt. N e O	76
Figura 4.44 - Comparação de desempenho entre as escolhas do T.H. 7 e 8	77
Figura 4.45 - Comparação de desempenho entre as escolhas do T.H. 6 e 9	79
Figura 4.46 - Comparação de desempenho entre as escolhas do T.H. 10 e 3	80
Figura 4.47 - Comparação de desempenho entre as escolhas do T.H. 10 e os resultados obtidos pelas PNN	82
Figura 4.48 - Comparação de desempenho entre as escolhas do T.H. 12 e os resultados obtidos pela alt. B	83

Figura A1.1 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 15-16	93
Figura A1.2 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 15-17	94
Figura A1.3 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 14-18	94
Figura A1.4 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-4.....	95
Figura A1.5 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-6.....	95
Figura A1.6 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-18	96
Figura A1.7 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 20-21	96
Figura A1.8 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 15-16	97
Figura A1.9 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 15-17	97
Figura A1.10 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 14-18	98
Figura A1.11 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-4.....	98
Figura A1.12 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-6.....	99
Figura A1.13 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-18	99
Figura A1.14 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 20-21	100
Figura A1.15 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 15-16	100
Figura A1.16 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 15-17	101
Figura A1.17 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 14-18	101
Figura A1.18 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-4.....	102
Figura A1.19 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-6.....	102
Figura A1.20 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-18	103

Figura A1.21 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 20-21	103
Figura A1.22 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 15-16	104
Figura A1.23 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 15-17	104
Figura A1.24 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 14-18	105
Figura A1.25 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-4	105
Figura A1.26 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-6	106
Figura A1.27 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-18	106
Figura A1.28 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 20-21	107
Figura A1.29 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 15-16	107
Figura A1.30 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 15-17	108
Figura A1.31 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 14-18	108
Figura A1.32 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-4	109
Figura A1.33 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-6	109
Figura A1.34 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-18	110
Figura A1.35 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 20-21	110
Figura A1.36 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 15-16	111
Figura A1.37 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 15-17	111
Figura A1.38 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 14-18	112
Figura A1.39 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-4	112
Figura A1.40 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-6	113

Figura A1.41 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-18	113
Figura A1.42 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 20-21	114
Figura A1.43 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 15-16	114
Figura A1.44 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 15-17	115
Figura A1.45 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 14-18	115
Figura A1.46 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-4.....	116
Figura A1.47 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-6.....	116
Figura A1.48 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-18	117
Figura A1.49 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 20-21	117
Figura A1.50 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 15-16	118
Figura A1.51 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 15-17	118
Figura A1.52 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 14-18	119
Figura A1.53 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-4.....	119
Figura A1.54 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-6.....	120
Figura A1.55 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-18	120
Figura A1.56 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 20-21	121
Figura A1.57 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 15-16	121
Figura A1.58 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 15-17	122
Figura A1.59 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 14-18	122
Figura A1.60 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-4.....	123

Figura A1.61 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-6	123
Figura A1.62 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-18	124
Figura A1.63 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 20-21	124
Figura A1.64 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 15-16	125
Figura A1.65 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 15-17	125
Figura A1.66 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 14-18	126
Figura A1.67 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-4	126
Figura A1.68 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-6	127
Figura A1.69 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-18	127
Figura A1.70 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 20-21	128
Figura A1.71 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 15-16	128
Figura A1.72 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 15-17	129
Figura A1.73 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 14-18	129
Figura A1.74 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-4	130
Figura A1.75 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-6	130
Figura A1.76 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-18	131
Figura A1.77 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 20-21	131

Lista de Tabelas

Tabela 2.1 - Corrente máxima admissível por linha de transmissão crítica.	14
Tabela 3.1 - Repartição do conjunto de dados da rede de teste, por tipo de ANN utilizada..	33
Tabela 4.1 - Alternativas testas para as ANN do tipo MLP	42
Tabela 4.2 - Quadro resumo do melhor <i>spread</i> e erros de classificação de cada linha de transmissão considerada crítica	66
Tabela 4.3 - Média e variância amostral dos erros globais de classificação obtidos com as alt C e D.....	67
Tabela 4.4 - Média e variância amostral dos erros globais de classificação obtidos com as alt E e F	68
Tabela 4.5 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 1 e 2	70
Tabela 4.6 - Média e variância amostral dos erros globais de classificação obtidos com as alt G e H	71
Tabela 4.7 - Média e variância amostral dos erros globais de classificação obtidos com as alt. I e J.....	72
Tabela 4.8 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 4 e 5	74
Tabela 4.9 - Média e variância amostral dos erros globais de classificação obtidos das alt. L e M.....	75
Tabela 4.10 - Média e variância amostral dos erros globais de classificação obtidos das alt. N e O	76
Tabela 4.11 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 7 e 8	78
Tabela 4.12 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 6 e 9	79
Tabela 4.13 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 10 e 3	81

Tabela 4.14 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 11 e os resultados obtidos pelas PNN 82

Tabela 4.15 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 12 e os resultados obtidos pela alt. B..... 83

Abreviaturas e Símbolos

Lista de abreviaturas (ordenadas por ordem alfabética)

ANN -Artificial Neural Network (Redes Neurais Artificiais)

LM - Levenberg-Marquardt

MLP - Multilayer Perceptron (Percepção Multi-Camada)

PNN - Probabilistic Neural Network (Redes Neurais Probabilísticas)

SCG - Scaled Conjugated Gradient

UCTE- Union for the Co-ordination of the Transmission of Electricity

Capítulo 1

Introdução

1.1 - Considerações Gerais

A classificação de segurança, em tempo real, incide sobre monitorizar o estado de operação actual do sistema, exigindo por isso, recursos computacionais que a realizem em tempos muito curtos. Esta classificação de segurança realiza-se sempre que as condições de operação que o sistema tem em tempo real (como as relativas aos perfis de consumo/produção, à estrutura da rede ou às das contingências com maior risco de ocorrência) sejam substancialmente diferentes das que tenham sido previstas durante o planeamento dos cenários de exploração da rede.

A classificação de segurança dinâmica, estudada nesta dissertação, consistiu em verificar se não são violados os limites considerados como aceitáveis para as condições de operação associadas ao comportamento dinâmico do sistema, na sequência da ocorrência de perturbações. Estes limites estão geralmente associados à gama de valores admissíveis para o comportamento transitório de frequência ou para a sobrecarga temporária de ramos da rede ou ainda, aos limites que garantem a não ocorrência de problemas de estabilidade transitória, de pequeno sinal ou de tensão.

Com a evolução que se tem vindo a verificar nos últimos anos no sector eléctrico, tem-se criado um conjunto de factores que exigem um maior rigor no processo de classificação de segurança. Dos factores, o considerado nesta dissertação, foi o crescente aumento da integração de produção distribuída, ou seja, o aumento de instalações de produção que se encontram ligadas directamente às redes de distribuição e que são, usualmente, geridas por entidades distintas dos operadores dessa rede. Nesta dissertação optou-se por estudar este factor, mas com a particularidade da produção distribuída ter como origem a energia eólica.

A tendência para o crescimento da integração da produção distribuída proveniente das energias renováveis e de cogeração, leva a uma situação de maior incerteza na previsão dos

cenários de produção, ou seja, das condições de despacho. Esta dificuldade é acrescida uma vez que a Directiva Europeia 2001/77/EC de promoção da produção de electricidade a partir de energias renováveis, faz com que toda a produção proveniente de energias renováveis seja aceite pela rede receptora.

Da forte aposta, nos últimos anos, em energia eólica para a produção de electricidade resulta:

- um agravamento da incerteza associada à previsão de cenários de operação, uma vez que a produção de electricidade, proveniente da energia eólica, resulta das condições do vento existentes em cada instante, que têm como característica principal a sua intermitência e a sua previsão limitada;
- a necessidade de se considerarem novos tipos de perturbações que podem pôr em causa a segurança dinâmica do sistema, como a perda de um grande volume de produção eólica devido à actuação dos relés mínimos de tensão, na sequência da ocorrência de um curto-circuito em determinadas zonas críticas da rede de transporte.

Outros factores a ter em conta, é o facto do consumo de electricidade ter sido confrontado com um crescimento forte, disto resulta a dificuldade de construção de infra-estruturas na rede de transporte (muito por causa de razões ambientais), e a liberalização do sector eléctrico. Estes factores fazem com que as redes de transporte sejam cada vez mais operadas perto dos seus limites, fazendo com que possam aparecer congestionamentos nos ramos de interligação, das redes de transportes dos sistemas interligados, que até então tinham sido dimensionados com o principal objectivo de disponibilizar apoio esporádico entre as redes vizinhas. Estas situações levam a que os operadores do sistema optem por adoptar medidas de exploração que adiem ao máximo novos investimentos na rede de transporte.

Uma forma que tem sido utilizada para tentar responder à crescente necessidade de avaliação de segurança dinâmica em tempo real, consiste na utilização de métodos analíticos convencionais através de sistemas de computação distribuída [1]. Em [1] é descrito que estes métodos exigem tempos de cálculo muito elevados. Sendo que esta avaliação é para ser feita em tempo real, este factor torna-se uma grande desvantagem. Em resposta a este métodos, surgem os métodos de aprendizagem automática (denominados na literatura anglo saxónica de, *Automatic Learning Methods*). Nesta dissertação o método deste tipo estudado foi as Redes Neurais Artificiais (denominadas na literatura anglo saxónica de, *Artificial Neural Networks*).

Devido à sua rapidez e bom desempenho a nível de precisão, estes métodos são adequados para serem aplicados em tempo real. Segundo a autora de [1], estes métodos são uma boa forma de substituir custos de investimento adicionais na rede, quando integrados nos centros de controlo. Estes custos têm como objectivo, por exemplo, dotar os antigos

geradores eólicos de capacidade *fault ride trough*, (que permita as condições mínimas de permanência em serviço deste tipo de geração na sequência de ocorrência de defeitos na rede), e expansão da rede de transporte. Estas exigências podem acarretar muitos custos quando comparados com os custos de integração de métodos computacionais nos centros de controlo.

1.2 - Objectivos da Dissertação

A presente dissertação teve como principal objectivo, a classificação de segurança de sistemas eléctricos interligados com elevada produção eólica recorrendo às ANN. Com este tipo de estrutura de aprendizagem automática pretendeu-se classificar, de forma rápida e precisa, a segurança dinâmica de operação de áreas de controlo de sistemas eléctricos interligados que explorem elevadas penetrações de produção eólica, onde os requisitos de capacidade de sobreviver a cavas de tensão não tenham sido totalmente adoptados.

A segurança dinâmica do sistema foi avaliada atendendo à ocorrência de sobrecargas em regime quasi-estacionário, em ramos da rede de transmissão, que violem os limites definidos como aceitáveis para sobrecargas temporárias.

Nesta dissertação partiu-se do trabalho já realizado em [1], onde se desenvolveu um sistema de avaliação e controlo de uma rede interligada, tendo capacidade de fornecer ao operador de rede, várias alternativas para a exploração do seu sistema que evitem perda de segurança na sequência da ocorrência de perturbações severas pré-definidas. Na figura 1.1 é apresentado o algoritmo proposto em [1]:




Figura 1.1 - Algoritmo proposto em [1]

Este trabalho, foi desenvolvido, somente sobre a parte de monitorização de segurança, ou seja classificar o cenário de operação de seguro/inseguro.

No trabalho desenvolvido em [1], as ANN, utilizadas para a parte de monitorização foram treinadas para regressão, surgindo então a hipótese que foi avaliada para este trabalho: ***uma ANN treinada para classificação consegue obter melhor precisão que uma ANN treinada para regressão.*** O presente trabalho foi então concebido para encontrar ANN que sejam apropriadas para classificação, para tentar validar a hipótese atrás referida.

Para realização deste trabalho foi utilizada uma rede interligada onde se explora uma elevada quantidade de produção eólica, para a qual já foi gerado um conjunto de dados que caracteriza os cenários a segurança de operação de uma das áreas de controlo do sistema interligado atendendo à ocorrência de uma perturbação pré-especificada. Todos estes dados provêm do trabalho realizado em [1].

1.3 - Estrutura da Dissertação

O trabalho realizado encontra-se estruturado em 5 capítulos. No capítulo 2 é apresentada uma descrição da rede interligada de teste que serviu de base para a classificação de segurança dinâmica, a partir da qual foram obtidos os dados utilizados para o treino das ANN. Neste capítulo é especificado o tipo de perturbação considerado assim como a variável considerada para distinguir um sistema como sendo seguro/inseguro. Por último é abordado o conjunto de características que foi utilizado como entrada para as ANN.

No capítulo 3 são expostos os conceitos de aprendizagem automática, com uma focalização sobre as ANN. Neste capítulo encontra-se também a descrição dos tipos de ANN utilizados, assim como o método utilizado para avaliar o desempenho das mesmas.

No capítulo 4 são apresentados os resultados obtidos a partir dos testes efectuados de treino dos diferentes tipos de ANN treinadas para classificação do problema de segurança em análise. Será, neste capítulo, também apresentadas as comparações de desempenho dos diferentes tipos de ANN treinadas.

Finalmente no capítulo 5, resumem-se as principais conclusões e contribuições que foram alcançadas na elaboração deste trabalho, bem como algumas sugestões que pareçam interessantes analisar em trabalhos futuros.

Capítulo 2

Problema de Segurança em Análise

2.1 - Introdução

Para avaliar o desempenho das metodologias de classificação de segurança estudadas ao longo desta dissertação, foi necessária a utilização de uma rede interligada de teste. A mesma descreve-se na secção 2.2. Esta rede foi adoptada de [1], e foi criada com intuito de obter um caso de estudo que reflectisse os procedimentos de dimensionamento que são usualmente adoptados. A rede interligada de teste criada foi baseada num sistema interligado real, no qual se espera que venham a ser explorados elevados volumes de eólica.

Na secção 2.3 é descrito o tipo de perturbação que foi considerada para rede de teste, e os problemas que advêm deste tipo de perturbação, para uma rede interligada com as mesmas características. Esta perturbação foi realizada tendo em conta vários cenários de operação do sistema, obtendo-se assim diferentes reacções do sistema, após o acontecimento do mesmo. Essas diferentes reacções vão criar os cenários base para o treino das ANN, sendo que cada cenário base é constituído pelas variáveis descritas na secção 2.6.

Como o problema analisado nesta dissertação, foi a classificação de segurança para redes interligadas com elevadas penetrações de produção eólica, é necessário criar um índice de segurança que permita distinguir o que se considera inseguro ou seguro. Este índice está justificado na secção 2.4.

A secção 2.5, descreve, em traços gerais, o trabalho realizado em [1], para obter o conjunto de dados necessários para treino das ANN.

A secção 2.7 descreve os cenários de operação que foram gerados, para constituírem o conjunto de dados para treino das ANN, a nível da sua característica de segurança, seguro/inseguro.

2.2 - Rede Interligada de Teste

O esquema unifilar da rede interligada utilizada no presente trabalho é apresentado na Figura 2.1 Esta rede foi adoptada de [1]. A presente rede é formada por duas áreas de controlo, em que na área de controlo 1 é considerado uma aproximação à rede de transporte portuguesa, sendo que a área de controlo 2 representa o sistema eléctrico espanhol assim como restante a rede da UCTE.

A área de controlo 1 é um sistema simplificado do que se pretendeu para a rede de transporte portuguesa durante o período 2002-2007 (de acordo com o Plano de Investimentos da Rede Nacional de Transporte 2002-2007), dado isto podemos então encontrar uma rede com três níveis de tensão (150, 220 e 400 kV) onde se encontram os seguintes elementos físicos:

- 24 barramentos, de entre os quais 11 abastecem a rede de distribuição e 9 dispõem de baterias de condensadores;
- 28 linhas de transmissão (podendo, cada uma, indicar um equivalente de linhas em paralelo);
- 7 transformadores de transmissão (podendo, cada um, corresponder ao equivalente de transformadores em paralelo);
- 14 geradores convencionais equivalentes (3 do tipo clássico, 2 do tipo térmico de turbina a gás e 9 do tipo hídrico), correspondendo, cada um, ao modelo equivalente do conjunto de geradores com iguais características e que se encontrem em serviço na mesma central;
- 10 Geradores eólicos equivalentes, correspondendo, cada um, ao modelo equivalente do conjunto de geradores eólicos com iguais características e que se encontrem em serviço e a partilhar o mesmo ponto de ligação à rede de transporte.

A área de controlo 2 é modelizada apenas por um único barramento, onde se encontram, geradores equivalentes de vários tipos (1 térmico, 1 hídrico, 1 nuclear e 1 eólico), uma bateria de condensadores e o consumo total dessa área de controlo.




Figura 2.1- Rede em análise

2.3 - Tipo de Perturbação Considerada

A rede interligada em estudo tem uma quantidade relevante de aproveitamentos eólicos. Estes aproveitamentos têm como característica estarem sujeitos a variações de produção não controláveis, o que por consequência vai alterar os parâmetros de operação da rede, podendo originar a ruptura de alguns limites técnicos dos componentes da rede. As variações de produção podem ter como origem os seguintes fenómenos:

- Intermitência do vento, que se pode traduzir na ocorrência de flutuações da produção de eólica como resultado de turbulências da velocidade do vento ou de oscilações de vento;
- Desligação de geradores eólicos, devido à velocidade do vento ultrapassar os limites mínimos ou máximos de operação destes;

- Desligação de parques eólicos, devido à ocorrência de curto-circuitos na rede receptora que façam com sejam actuadas as protecções de mínimo de tensão deste tipo de aproveitamentos.

De acordo com o descrito em [1], os dois primeiros tipos de fenómenos, devido à existência de muitos parques eólicos compostos por máquinas de potência reduzida, quando comparada com a das máquinas convencionais em serviço, e com localizações geográficas dispersas, têm a capacidade de suavizar, de forma muito significativa, as variações de produção de eólica que são sentidas pelo restante sistema de produção.

Relativamente ao último fenómeno, e como a rede em estudo considera uma grande penetração de produção eólica, se ocorrer um curto-circuito em determinadas zonas críticas da rede de transporte, as quedas de tensão por este provocadas podem levar à actuação dos relés de mínimo de tensão instalados para a protecção dos parques eólicos mais antigos que estejam próximos do defeito.

Devido à experiência de operação de sistemas reais, este tipo de perturbação pode levar à perda de segurança do sistema, por as perdas de produção poderem atingir valores bastante levados e em particular pode-se ultrapassar as margens de segurança do sistema usualmente usadas (garantia de robustez do sistema face à súbita perda do maior grupo gerador em serviço).

Os problemas dinâmicos que poderão surgir deste tipo de perturbações são os seguintes:

- 1) Problemas de estabilidade transitória, para os quais têm sido estudado em vários trabalhos de investigação a capacidade de aplicação de métodos de aprendizagem automática [1];
- 2) Para o nosso caso em estudo, redes interligadas, a ocorrência de sobrecargas temporárias nos ramos ultrapassem os limites de operacionalidade definidos para a sua capacidade de transmissão, as quais poderão colocar a segurança de operação em causa podendo fazer com que ocorram saídas de serviço em cascata [1].

No âmbito deste trabalho foi estudada a capacidade das ANN para classificar automaticamente como “segura/insegura” as linhas de transmissão, atendendo ao segundo problema descrito.

Nesta dissertação simulou-se um curto-circuito na extremidade mais próxima do barramento 15 de uma das duas linhas que se consideram estar em paralelo ligar os barramentos 15 e 16 (ver figura 2.1). Esta simulação foi efectuada na fase 6 do método utilizado para a geração de dados que se apresenta na figura 2.2 seguinte.

2.4 - Índices de Segurança

Ao tratar-se de um trabalho de classificação de segurança de linhas de transmissão após a ocorrência de um curto-circuito, teve-se de definir um índice onde se pudesse diferenciar o estado “seguro” ou “inseguro” da linha de transmissão. Para tal classificação adoptou-se o valor da intensidade de corrente que cada ramo de transmissão k terá, dois minutos (120 segundos) após a ocorrência da perturbação: $I(120)_k$. A partir destes índices, cada cenário de operação será classificado como “inseguro” se algum desses valores violar os limites definidos como aceitáveis para as sobrecargas temporárias em ramos de transmissão.

Devido às linhas de transmissão conseguirem suportar sobrecargas temporárias [1], *no presente trabalho considerou-se que a linha de transmissão só seria insegura se $I(120)_k > 1.2 \cdot I_z$, onde I_z é a corrente máxima admissível em regime permanente, considerando como seguros os restantes cenários.*

2.5 - Conjunto de Dados Gerado

Os dados utilizados para treino das ANN deste trabalho foram obtidos e tratados em [1], de acordo com a aplicação sucessiva de 6 fases como se descreve na figura 2.2




Figura 2.2 - Descrição funcional do algoritmo de geração de dados [1]

Os dados utilizados obedecem a 3 cenários base, os quais diferem entre si devido às condições de escalonamento e de despacho das máquinas convencionais da rede interligada de teste. Os cenários base considerados foram os seguintes:

- Cenário de Inverno: Este cenário base é caracterizado por ter uma produção de hídrica superior à térmica, ficando assim a seguinte ordem de mérito de entrada em serviço entre tipo de máquinas: 1) Nucleares; 2) Hídricas; 3) Térmicas.
- Cenário de Verão: Este cenário base é caracterizado por ter uma produção de térmica superior ao de hídrica, ficando assim a seguinte ordem de mérito de entrada em serviço entre tipo de máquinas: 1) Nucleares; 2) Térmicas; 3) Hídricas. Nas hídricas, sempre que possível foram mantidos os valores de carga nos mínimos técnicos e durante as horas do vazio só se ligaram a hídricas a fio-de-água.
- Cenário com elevada reserva girante hídrica: Este cenário base foi incluído devido a que o sistema em estudo é um sistema interligado com elevada penetração eólica. Isto faz com que a operação das reservas secundárias “rápidas” pudesse ser necessária para não comprometer a qualidade da acção de controlo dos sistemas AGC. Com este cenário as condições de operação que interferem no comportamento dinâmico em estudo podem variar. Com as especificações de este cenário foi constituída a seguinte ordem de mérito de entrada em serviço entre o tipo de máquinas: 1) Nucleares; 2) Hídricas; 3) Térmicas, e considerando que as hídricas que se encontram em serviço são exploradas com valores de carga próximos dos limites técnicos mínimos.

Após terem sido definidos as diferentes ordens de escalonamento e de despacho, para cada um dos 3 cenários de geração de dados atrás descritos, foi efectuada também a distinção entre horas de vazio, cheia e de ponta. Ficando assim 9 cenários que obedecem aos seguintes cenários base:

- Despacho típico de Inverno para as horas de vazio, horas cheias e de ponta;
- Despacho típico de Verão para as horas de vazio, horas cheias e de ponta;
- Despacho com elevada reserva girante hídrica para as horas de vazio, horas cheias e de ponta.

De acordo com [1], destes cenários base formaram **4596 cenários de operação**. Estes tiveram de passar por um processo de validação, de modo a garantir que em nenhum destes cenários ocorressem condições de operação, durante o regime permanente de pré-perturbação, que violassem alguma das seguintes restrições:

- Nenhuma das máquinas convencionais se encontra em sobrecarga;
- Em nenhum ramos, o trânsito de potências que nele transita viola a capacidade de transmissão em regime permanente;
- A tensão em todos os barramentos de MAT encontra-se dentro da gama de valores definida por $[0,93;1,1]$ p.u.

2.6 - Vector das Variáveis de Entrada Candidatas

O vector de variáveis candidatas a considerar como entrada das ANN, foi escolhido de modo a que este caracterize as condições de operação que o sistema eléctrico tem em regime estacionário prévio ao defeito. A formação deste vector parte da selecção, de entre o conjunto de variáveis, da qual se considera terem uma influência relevante no comportamento dinâmico em análise. Esta selecção é habitualmente efectuada de forma empírica, com base no conhecimento prévio sobre a relação causa/efeito existente entre as variáveis em jogo [1].

Nestas variáveis deverão fazer parte valores mesuráveis do sistema eléctrico. De entre a selecção, dever-se-á procurar não incluir características que estejam altamente relacionadas entre si, de forma a não criar um vector exageradamente grande, o que levaria possivelmente à existência de informação redundante. Na formação deste vector, foi tido ainda em consideração, que a associação de certas características poderá ter um efeito significativo na explicação na variação total do índice de segurança, mesmo quando cada uma das características que fosse apresentada separadamente à rede neuronal explicasse pouco dessa variação (como exemplo, temos as condições de despacho de uma central, que podem não ser muito reveladoras do fenómeno causa/efeito em análise, mas por consequência as condições de despacho de uma área de controlo podem condicionar fortemente a segurança dinâmica de explorações do sistema eléctrico).

Como variáveis de entradas candidatas, estão guardadas todas as informações sobre as condições de operação pré-perturbação. Deste modo, têm-se na base de dados as seguintes variáveis:

- $Pload, ac1$ (MW): consumo total da área de controlo 1;
- Nci : nº de máquinas em operação em cada gerador convencional equivalente i ;
- Pci (MW): produção de potência activa em cada gerador convencional equivalente i ;
- Vci (p.u.): valor de tensão especificado aos terminais de cada gerador convencional equivalente i ;
- Nwj : nº de máquinas em operação em cada gerador eólico equivalente j ;
- Pwj (MW): potência mecânica desenvolvida por cada gerador eólico equivalente j ;
- Qci (Mvar): produção de potência reactiva do gerador convencional equivalente i ;

- SR_{ci} (MW): reserva girante do gerador convencional equivalente i ;
- $P_{w,ac1}$ (MW): Potência mecânica total desenvolvida nos parques eólicos da área de controlo 1;
- $P_{CH,ac1}$ (MW): Produção total de potência activa hídrica da área de controlo 1;
- $P_{gT,ac1}$ (MW): Produção activa de térmica da área de controlo 1;
- $Imp, ac1$ (MW): Importação da área de controlo 1;
- $SR_{H, ac1}$ (MW): Reserva girante total hídrica da área de controlo 1;
- $SR_{T, ac1}$ (MW): Reserva girante total térmica da área de controlo 1;
- $I(0s)_k$ (A): intensidade de corrente no ramo de transmissão k , durante o regime estacionário pré-perturbação;
- $Temp$ (°C): Temperatura ambiente, cujo valor varia com a estação do ano do cenário em questão (15°C no Inverno e 30°C no Verão)

Nesta dissertação, testaram-se à partida dois conjuntos de características de entrada que advêm dos trabalhos efectuados em [1] e [2]. Estes testes realizaram-se, através do treino para regressão das ANN, sendo que o melhor destes 2 conjuntos de entradas foi utilizado para entrada das ANN treinadas para classificação. Desta forma partiu-se do pressuposto que um conjunto de características que melhore o desempenho de uma ANN treinada para regressão melhora também uma ANN que seja treinada para classificação. Assim sendo, de seguida são apresentadas as entradas que foram utilizadas no trabalho efectuado em [1].

- $P_{load, ac1}$ (MW): consumo total da área de controlo 1;
- N_{ci} : nº de máquinas em operação em cada gerador convencional equivalente i ;
- P_{ci} (MW): produção de potência activa em cada gerador convencional equivalente i ;
- V_{ci} (p.u.): valor de tensão especificado aos terminais de cada gerador convencional equivalente i ;
- N_{wj} : nº de máquinas em operação em cada gerador eólico equivalente j ;
- P_{wj} (MW): potência mecânica desenvolvida por cada gerador eólico equivalente j .

Deste conjunto de variáveis, resulta um vector de entrada com 63 variáveis, onde se excluem as variáveis que caracterizam a situação de despacho da área de controlo vizinha, ou seja as variáveis N_{ci} , P_{ci} , V_{ci} para os 3 geradores convencionais equivalentes da área de controlo 2 e as variáveis N_{wj} e P_{wj} para o gerador eólico equivalente da mesma área de controlo. Isto aconteceu visto que em [1], foi pretendido criar um sistema de monitorização de segurança, implicando assim que as informações disponíveis sejam apenas as da área de controlo em estudo, que neste caso é a área de controlo 1.

Com a intenção de melhorar a capacidade de previsão em [2], foi estudado um conjunto de características alternativas.

Relativamente às novas alternativas, o conjunto de entradas considerado em [1] foi alterado através da realização das seguintes substituições (estas substituições encontram-se devidamente justificadas em [2]).

- O consumo total da área de controlo 1 (PLoad, ac1), pela importação da área de controlo 1 (Impac1);
- A tensão especificada aos terminais de cada gerador convencional equivalente (V_c) foi substituída pela respectiva produção de potência reactiva (Q_g);
- O número de máquinas em operação em cada gerador convencional equivalente (N_c), foi substituída pela respectiva reserva girante.

Da alternativa que foi escolhida, no âmbito do trabalho da presente dissertação, foi acrescentada a temperatura (Temp). Esta temperatura foi utilizada uma vez que, como se descreve em [1], a capacidade de transporte de uma linha de transmissão depende da temperatura ambiente a que esta está sujeita, pelo que o limiar de segurança em termos de sobrecarga numa linha, corresponde a um valor que varia com esta condição externa, necessitando assim de ser monitorizada em tempo real.

Para esta temperatura foram utilizados dois valores (15°C no cenário de Inverno e 30°C no cenário de Verão), dizendo respeito aos valores usualmente considerados pela REN para dimensionamento das linhas de transmissão, tal como vem descrito em [3].

2.7 - Cenários Gerados para a Rede Interligada de Teste

De acordo com [1], e seguindo critério de segurança descrito atrás, 7 linhas de transmissão foram consideradas como sendo críticas, por a perturbação em análise provocar, para alguns dos cenários gerados, condições de operação que provoquem a violação do critério de segurança adoptado nessas linhas. Na tabela 2.1. estão apresentadas as correntes admissíveis de cada linha de transmissão (I_z), através das quais é calculado o critério de segurança.

Tabela 2.1 - Corrente máxima admissível por linha de transmissão crítica.

	Iz Verão (A)	Iz Inverno (A)
linha 15-16	524.8638811	776.798544
linha 15-17	469.7531736	695.2346969
linha 16-4	687.5716842	825.0860211
linha 16-6	700.6932812	840.8319375
linha 14-18	606.2177826	775.9587618
linha 16-18	986.7440964	1460.381263
linha 20-21	1166.247544	1411.159528

Na figura 2.3, pode observar-se o número de cenários de operação para os quais se detectou a ocorrência de condições de operação seguras e inseguras, para cada uma das 7 linhas que se identificam como sendo críticas. Como se pode verificar, à excepção da linha 20-21, as linhas que se consideram como críticas dizem respeito a ramos electricamente próximos da linha onde se simulou o defeito.




Figura 2.3 - Número de cenários de operação seguros /inseguros gerados por linha de transmissão crítica

Em [1] foi garantido que os valores obtidos do índice de segurança estudado $I(120s)_k$ para cada uma das 7 linhas de transmissão que se identificaram como sendo críticas para a perturbação em análise, seguiam uma boa distribuição para o índice de segurança, permitindo assim validar o processo de geração de dados seguido.

No âmbito deste trabalho, classificação de segurança recorrendo a ANN, e como irá ser explicado mais à frente foi necessário dividir o conjunto de dados em 3 conjuntos distintos, nomeadamente os seguintes:

- Learning set
- Validation set
- Testing set

Para isso foi necessário verificar se havia uma distribuição coerente de casos inseguros nos três conjuntos, para permitir a boa adaptação das ANN. Na figura 2.4 pode observar-se como essa distribuição ficou definida.




Figura 2.4 - Distribuição dos casos inseguros pelos conjuntos de dados

2.8 - Conclusões

Neste capítulo é descrita a rede interligada de teste, bem como a metodologia utilizada para a geração do conjunto de dados para este sistema eléctrico, metodologia utilizada em [1], de modo a caracterizar a sua segurança de operação em termos de sobrecarga nos ramos de transmissão durante o regime quasi-estacionário de pós-perturbação, na sequencia da ocorrência de uma perturbação pré-especificada, neste caso a ocorrência de um curto-circuito. Com este conjunto de dados foi possível treinar as ANN descritas no Capítulo 3.

Capítulo 3

Utilização de ANN para Classificação

3.1 - Introdução

As ANN fazem parte de uma classe de métodos designados por métodos de Aprendizagem Automática (AA). O termo AA é nos dias de hoje, utilizado para denominar uma área de investigação. Estas técnicas consistem na extracção de informação sintética de alto nível (conhecimento) de bases de dados com informação de baixo nível [4]. Nos anos 60 e 70 estas técnicas foram introduzidas na avaliação de sistemas de energia, utilizando o reconhecimento de padrões.

Dos métodos AA, diferenciam-se aqueles que realizam uma aprendizagem supervisionada (denominados, na literatura anglo-saxónica, *learning by example*) e pelos que realizam uma aprendizagem não supervisionada (denominados, na literatura anglo-saxónica, *unsupervised learning*), obedecendo às seguintes descrições gerais:

- Aprendizagem supervisionada: dado um conjunto de elementos, conjunto de aprendizagem (denominado, na literatura anglo-saxónica, *learning set*), de entradas/saídas associadas, é formada um modelo geral que possa ser usado para explicar, observar, e prever saídas aquando de entradas novas [4]. Na avaliação de sistemas de energia, o conjunto de exemplos consistem em cenários de operação. Os cenários de operação, elementos de entrada, devem ser constituídos por variáveis relevantes que descrevam o estado eléctrico do sistema e a sua topologia.
- Aprendizagem não supervisionada: ao contrário da aprendizagem supervisionada, a aprendizagem não supervisionada não se orienta para criar um modelo geral para

prever variáveis. Este tipo de aprendizagem tenta encontrar relações entre os cenários, através das variáveis de entradas.

Devido ao que se pretendia com este trabalho, foram utilizadas, como já foi dito atrás, ANN, que se integram nos métodos AA com aprendizagem automática. Neste capítulo descreve-se a metodologia seguida no presente trabalho, para a obtenção e avaliação do desempenho das ANN utilizadas para realizar a classificação de segurança do problema em análise, *ocorrência de sobrecargas em regime quasi-estacionário nos ramos de transmissão de uma área de controlo de um sistema eléctrico interligado, como consequência da ocorrência de uma perda de produção eólica nessa área de controlo*.

Na secção 3.2, são descritos quais os parâmetros que irão avaliar o desempenho de uma ANN, onde alguns destes parâmetros irão ser utilizados na secção 3.5, de forma a obter uma comparação entre as ANN utilizadas no presente trabalho. Na secção 3.3 são descritos os diferentes tipos de ANN utilizadas, justificando-se a escolha das diferentes estruturas e parâmetros escolhidos para a classificação do problema estudado para rede interligada de teste que se encontra descrita no capítulo 2. Na secção 3.4 está descrito o método utilizado que permite a generalização das ANN, generalização essa, que se define pela possibilidade das ANN apresentar um resultado com um aceitável grau de precisão, para um novo conjunto de entradas que lhe seja apresentado.

3.2 - Estimativa do Erro de Classificação e de Regressão

Quando se utilizam as ANN, é importante obter uma estimativa do erro para a avaliação do desempenho da própria rede. A obtenção dessa estimativa passa pela utilização de uma amostra de teste da qual se conhece o verdadeiro valor de saída [1]. A quantificação das estimativas para a precisão das ANN através de índices numéricos, só poderá ser feita usando o valor previsto/obtido pela rede neuronal e o verdadeiro valor da variável de saída.

Aquando de problemas de regressão, os índices numéricos denominam-se de erros de regressão. O mais utilizado de entre estes erros é o Erro Quadrático Médio [1], MSE, (denominado, na literatura anglo-saxónica, *Mean Squared Error*), calculando-se da seguinte forma:

$$MSE(f) = \frac{1}{ne} \sum_{i=1}^{ne} (y_i - y'_i(f))^2 \quad (3.1)$$

Onde:

$y'_i(f)$: previsão de y_i fornecida pela rede neuronal;

y_i : valor da variável a prever

ne : o número de exemplos da amostra utilizada.

- Erro Absoluto Médio, MAE (denominado, na linguagem anglo-saxónica, *Mean Absolute Error*), dado por:

$$MAE(f) = \frac{1}{ne} \sum_{i=1}^{ne} |y_i - y'_i(f)| \quad (3.2)$$

- Erro Quadrático Médio Relativo, RE, (denominado, na literatura anglo-saxónica, *Relative Mean Squared Error*), dado por:

$$RE(f) = \frac{MSE(f)}{MSE(\bar{y})} = \frac{\frac{1}{ne} \sum_{i=1}^{ne} (y_i - y'_i(f))^2}{\frac{1}{ne} \sum_{i=1}^{ne} (y_i - \bar{y})^2} \quad (3.3)$$

Onde:

$\bar{y} = \frac{1}{ne} \sum_{i=1}^{ne} y_i$: valor médio amostral de y ;

$MSE(\bar{y})$: desvio quadrado médio amostral de y .

Segundo [1], quando comparado com o MSE, o valor de MAE é menos sensível à existência de casos excepcionais para os quais a previsão do modelo se afaste, de forma substancial, do verdadeiro valor da variável de saída. O RE corresponde a um erro de previsão relativo, que pode alcançar como valor máximo 1, que calcula a razão do MSE com o valor que seria obtido se o valor de previsão obtido fosse igual ao da média amostral. Pode-se dizer então que um valor de RE inferior a 1 é indicador de uma rede neuronal com previsões mais precisas do que a simples utilização do valor médio de saída.

Nesta dissertação o objectivo primordial era a classificação de segurança de sistemas eléctricos através do uso de ANN, sendo que neste tipo de problemas é costume definir-se uma variável de saída binária, 1 (seguro) ou 0 (inseguro).

A figura 3.1 representa a matriz confusão, onde estão contidos os resultados em termos quantitativos de um classificador.

↓ actual \ predicted →	negative	positive
negative	a	b
positive	c	d

Figura 3.1 - Matriz confusão[5]

- a** – número de classificações correctas que o classificador considerou como cenário inseguro (i.e., número de cenários inseguros bem classificados);
- b**- número de classificações incorrectas que o classificador considerou como cenário seguro quando o cenário era inseguro (i.e. número de cenários inseguros mal classificados);
- c**- número de classificações incorrectas que o classificador considerou como cenário inseguro quando o cenário era seguro (i.e. número de cenários seguros mal classificados);
- d**- número de classificações correctas que o classificador considerou como cenário seguro (i.e. número de cenários seguros bem classificados).

Para estimar se as ANN estão a prever bem essa variável, é necessário recorrer ao cálculo dos seguintes erros de classificação, que são calculados através dos valores da matriz confusão, figura 3.1:

- Erro de classificação global (denominado, na literatura anglo-saxónica, *Global Classification Error*), dado por:

$$GCE(f) = \frac{n_{CE}(f)}{ne} \quad (3.4)$$

Onde:

$n_{CE}(f)$: número de exemplos da amostra que são mal classificados (i.e. a soma dos parâmetros **b+c** da matriz confusão, ver figura 3.1).

- Erro de Falso Alarme (denominado, na literatura anglo-saxónica, *False Alarm Error*), dado por:

$$FA(f) = \frac{n_{FA}(f)}{ne_S} \quad (3.5)$$

Onde:

$n_{FA}(f)$: número de exemplos seguros da amostra para os quais a rede neuronal forneceu uma classificação de “inseguro”, ou seja falsos alarme (i.e. parâmetro c da matriz confusão, figura 3.1);

ne_S : número de exemplos seguros da amostra.

- Erro de Falha de Alarme (denominado, na literatura anglo-saxónica, *Missed Alarm Error*), dado por:

$$MA(f) = \frac{n_{MA}(f)}{ne_I} \quad (3.6)$$

Onde:

$n_{MA}(f)$: número de exemplos inseguros da amostra para os quais a rede neuronal forneceu uma classificação de “seguro”, ou seja falha de alarmes (i.e. parâmetro b da matriz confusão);

ne_I : número de exemplos inseguros da amostra.

Além dos erros de classificação apresentados atrás, existem outros factores que possibilitam a avaliação do desempenho das ANN enquanto classificadores, como descrito em [6], [7] e [8], sendo eles os seguintes:

- Sensibilidade (denominados, literatura anglo-saxónica, *Sensitivity*) dá-nos a fracção de seguros bem classificados, sobre todos os que foram classificados com seguros.

$$SE(f) = \frac{n_S(f)}{n_S(f) + n_{MA}(f)} \quad (3.7)$$

Onde:

$n_S(f)$: número de exemplos seguros da amostra para os quais a rede neuronal forneceu uma classificação de “seguro”, seguros bem classificados (i.e. parâmetro d da matriz confusão, figura 3.1);

- Especificidade (denominados, na literatura anglo-saxónica, *Specificity*) dá-nos a fracção de inseguros bem classificados, sobre todos os que foram classificados com inseguros.

$$SP(f) = \frac{n_I(f)}{n_I(f) + n_{FA}(f)} \quad (3.8)$$

Onde:

$n_I(f)$: número de exemplos inseguros da amostra para os quais a rede neuronal forneceu uma classificação de “inseguro” (inseguros bem classificados), (i.e. parâmetro a da matriz confusão, figura 3.1);

- Exactidão do classificador (denominados, na literatura anglo saxónica, *Accuracy*) dá-nos a taxa de elementos bem classificados, sobre toda a amostra.

$$AC(f) = \frac{n_I(f) + n_S(f)}{n_I(f) + n_{FA}(f) + n_S(f) + n_{MA}(f)} \quad (3.9)$$

De acordo com [1], de entre todos estes factores para avaliar o desempenho das ANN, o MA acaba por ser o que têm maior relevância, uma vez que estima a taxa de ocorrência de situações em que as ANN não são capazes de detectar a perda de segurança do sistema eléctrico.

3.3 - Redes Neurais Estudadas

3.3.1 - Multilayer Perceptrons (MLP)

As MLP são consideradas como um dos métodos mais fiáveis dentro da aprendizagem automática. Este tipo de ANN pode ser utilizado numa vasta gama de problemas, podendo resolver problemas de classificação, principal objectivo deste trabalho, ou de regressão, podendo considerar uma ou mais variáveis de saída [1].

Um dos problemas mais citados da utilização deste tipo de modelo de aprendizagem automática é o elevado tempo exigido durante o processo de treino. Mas com a evolução do poder de cálculo e com a evolução dos algoritmos de treino, o problema do tempo de treino tem vindo a ser diminuído. Em relação aos tempos de cálculo, refira-se que foi treinada um ANN do tipo MLP com 63 entradas, 8 unidades escondidas e uma variável de saída, onde foram utilizados 2596 exemplos para o conjunto de treino, e 1000 exemplos para conjunto de validação, demorou-se cerca de 30 segundos. Para estes treinos foi utilizado o algoritmo de treino Levenberg-Marquardt, disponível na *Toolbox* de ANN do *software* MATLAB, tendo este decorrido num computador com as seguintes características: Windows 7, 4 Gb de RAM, Intel Pentium Core 2 duo 2.4 GHz. Estes poucos segundos podem parecer à partida, pouco tempo, mas o facto é que quando se trabalha com ANN o processo de treino de ANN pode dispensar muito mais tempo. Uma vez que na utilização de ANN é preciso fazer uma procura, de modo a que melhore o desempenho das mesmas, assim sendo é necessário que se testem várias alternativas, como as que envolvem a escolha:

- dos valores a considerar, previamente ao treino, para os parâmetros da ANN;
- da estrutura da ANN (número de camadas e unidade escondidas);
- do vector de variáveis de entrada;
- do algoritmo de treino a adoptar.

Todos estes elementos são obtidos de forma empírica, ou seja através da aprendizagem ao longo dos treinos efectuados, sendo que as fórmulas que existem provêm de inúmeros testes feitos ao longo do tempo.

Outro defeito deste tipo de ANN corresponde à dificuldade de extracção de regras justificativas das decisões tomadas pela rede, as quais representam o conhecimento adquirido durante o processo de treino, uma vez que os parâmetros (pesos e bias) não possuem significado físico. Por este motivo este tipo de ANN são designadas de “caixas pretas”.

Arquitectura da rede

As MLP são ANN complexas formadas por um elevado número de elementos de processamento simples, estes elementos são denominados de neurónios (denominando-se, na

literatura anglo-saxónica, *neurons*). A figura 3.2 representa a estrutura típica de um neurónio.




Figura 3.2 Estrutura de um neurónio de um MLP[9]

Como se observa na figura, cada neurónio de uma rede neuronal, vai realizar um conjunto de operações em função das suas variáveis de entradas x_i (para $i=1, \dots, n$), antes de produzir uma saída:

- soma pesada de todas as variáveis de entrada, dada por $\sum_{i=1}^n w_{ki} \times x_i$, onde cada parâmetro w_{ki} representa o peso da ligação (denominando-se, na literatura anglo-saxónica, *weight*), entre a variável de entrada i e o neurónio k ;
- ao resultado da operação anterior é somado um parâmetro, b_k , denominado de polarização do neurónio (denominando-se, na literatura anglo-saxónica, *bias*)
- finalmente, a saída do neurónio, resulta da aplicação de uma função de activação, onde como variável dependente temos as operações descritas nos dois pontos anteriores, ficando com a seguinte forma, $f(\sum_{i=1}^n w_{ki} \times x_i + b_k)$.

Relativamente à função de activação, no *software* MATLAB é possível encontrar, três funções. Cada uma destas é utilizada consoante o problema que se quer resolver, regressão ou classificação, sejam elas, a função tangente hiperbólica (em termos de notação do software, denomina-se, *tansig*), a função sigmóide logarítmica (em termos de notação do software, denomina-se, *hardlim*), e por fim a função linear pura (em termos de notação do software, denomina-se, *purelin*).

As duas primeira funções são do tipo sigmóide, ou seja, são funções monotonamente crescentes, com um ponto de inflexão, que realizam a transformação de uma grandeza com um domínio de valores no intervalo de $[-\infty, +\infty]$ para um domínio de valores, de $[-1, +1]$, no

caso da tangente hiperbólica e de $[0, +1]$ no caso da sigmóide logarítmica. Na figura 3.3 podem visualizar-se estas duas funções, assim como a função linear pura ($y=x$).




Figura 3.3 Exemplo das funções de activação usualmente utilizadas em MLP [10]

Relativamente à escolha da função de activação, dependendo do problema em estudo, temos que, para problemas de regressão é usualmente utilizada uma função não linear do tipo sigmóide para as unidades das camadas escondidas e a função linear pura para as unidades da camada de saída. Para problemas de classificação, as funções utilizadas para os neurónios são as funções do tipo sigmóide, uma vez que a sua saída ficará restrita. Uma vez que o problema em estudo será a classificação de segurança de redes interligadas, onde se quer uma saída binária, ou seja 1 se o sistema for seguro e 0 se o sistema for inseguro, seria empírico que se utilizasse a função sigmóide logarítmica para função de activação dos neurónios. No entanto e citando [11], será melhor utilizar a função tangente sigmóide, uma vez que os valores de saída da função activação são usados como um multiplicador na equação de actualização dos pesos (algoritmo de treino *Backpropagation*). Em virtude desta questão, uma faixa de valores de 0 e 1 significa um multiplicador pequeno, quando a soma total dos valores a serem considerados num determinado elemento de processamento possui um valor pequeno, ou um alto multiplicador para valores elevados dessa soma. Desta análise pode induzir-se à rede neuronal uma predisposição para aprender somente as saídas desejadas com valores altos (aproximados a 1) já que, as alterações nos pesos seriam maiores para valores altos da soma. No caso da tangente hiperbólica, esta leva a uma distribuição dos pesos que favoreça tanto os valores baixos da soma, como também os valores altos.

Na figura 3.4 apresenta-se a estrutura que representa tipicamente a ANN do tipo MLP. Como se pode observar a ANN é dividida em camadas, onde se pode observar que, à excepção da camada de entrada, todos os neurónios de uma camada posterior são alimentados por todos os neurónios da camada anterior. A alimentação destas ANN é sempre feita da camada de entrada para a de saída. Devido a isto, estas ANN denominam-se do tipo *feedforward*.




Figura 3.4 Estrutura de uma MLP (ex. com uma camada escondida)[7, 12]

Na figura 3.4, pode observar-se também a existência de três camadas, camada de entrada, camada escondida e uma camada de saída. Esta é a configuração mais comum relativamente ao número de camadas escondidas, ou seja com uma camada escondida, podendo, se assim for desejado, construir-se uma rede neuronal com várias camadas escondidas.

Relativamente ao número de camadas escondidas e ao número de neurónios em cada camada, estes são opções da estrutura que serão definidas pelo utilizador das MLP, antes de iniciar o processo de treino. Em [1], cita-se [13], como sendo uma referência onde se pode encontrar uma descrição de técnicas sugeridas por diversos autores, que visam ultrapassar o problema da definição da estrutura da MLP, sendo que todas estas técnicas são baseadas em pressupostos heurísticos. Uma alternativa à aplicação destas técnicas consiste na repetição dos treinos, através de um processo de tentativa/erro, de onde se selecciona a estrutura que fornece o melhor desempenho em termos de capacidade de generalização.

Em [1], afirma-se que uma rede neuronal com uma camada escondida pode aproximar-se a uma qualquer função contínua, com um desejado nível de precisão, desde que seja utilizado um número suficiente de neurónios. Na prática não é costume usar mais do que duas camadas escondidas.

Para o número de neurónios das camadas escondidas, utilizou-se como ponto de partida as equações definidas em [1]. Esta equação foi obtida através de um modo empírico, e descreve-se do seguinte modo:

$$nu = \left(\frac{ne}{k} - ns \right) \times \frac{1}{1+n+ns} \quad (3.10)$$

Onde:

nu: número de neurónios da camada escondida

ne: número de elementos do conjunto de treino

k: constante, cujo valor pode variar, aproximadamente em 5 e 10

ns: número de saídas da MLP

n: número de entradas da MLP

Treino das ANN do tipo MLP

Depois de definida a estrutura da MLP, o processo de treino visa encontrar os valores das polarizações e dos pesos que melhor se adaptam à amostra utilizada para o treino, tentando encontrar uma forma de generalizar a rede para o mesmo tipo de objectivo.

Os algoritmos de treino adoptados nesta dissertação, são algoritmos que visam encontrar os valores dos pesos e polarizações que minimizam a soma dos erros quadráticos médios [12], entre a saída alvo (target) e a saída presente nos exemplos usados para treino. Estes erros são definidos pela equação (3.3).

Nestes algoritmos cada peso w_{ki} vai sendo ajustado através da soma de um incremento, Δw_{ki} , a este, através da seguinte equação:

$$w_{ki}(t + 1) = w_{ki}(t) + \Delta w_{ki} \quad (3.11)$$

Onde:

t: época do treino.

No modo *batch*, o qual foi utilizado nesta dissertação, a actualização dos parâmetros é feita com base no erro de previsão resultante da consideração de todos os exemplos de treino, a época do processo iterativo é atingida quando todos os exemplos do conjunto de forem percorridos.

Para utilizar estes métodos no *software* MATLAB, é necessário escolher os critérios de paragem, para o qual o treino pára quando um destes é atingido, sendo que os considerados foram:

- A magnitude do erro de validação é inferior a 10^{-10} ;
- O erro de validação sofreu, pelo menos, 5 aumentos seguidos;
- O número de épocas foi atingido (no presente trabalho foram escolhidas 500 épocas).

A diferença entre os algoritmos escolhidos está na forma como Δw_{ki} é obtido. A escolha dos algoritmos para o treino foi feita tendo em conta as sugestões dadas por [7, 10] Foram então escolhidos os seguintes algoritmos de treino:

- Algoritmo de Levenberg-Marquardt, que se encontra descrito detalhadamente em [14]
- Scaled Conjugated Gradient, que se encontra descrito detalhadamente em [15]

O primeiro algoritmo foi também utilizado para treino de regressão, nomeadamente para decidir qual o melhor vector de variáveis de entrada a utilizar, problema descrito na secção 2.6, para o objectivo primordial deste trabalho, classificação de segurança de redes interligadas.

Inicialização das ANN do tipo MLP

Os algoritmos de treino utilizados recorrem ao cálculo do gradiente do erro de previsão, incremento, em função dos seus parâmetros. Os métodos de optimização que se baseiam no cálculo do gradiente correm o risco de convergir para mínimos locais [1]. Este risco é evidente no caso do treino deste tipo de ANN, uma vez que, sendo dotadas de funções de activação do tipo não linear, a hiper-superfície do erro de previsão estará povoada, com certeza, de mínimos locais, sendo que esta superfície está definida num sistema de eixos ortogonais, sendo um relativo ao erro de previsão e os restantes a cada parâmetro da ANN. Desta propriedade resulta o procedimento de realizar diversos treinos, onde de treino para treino, difere apenas a solução de valores iniciais para os parâmetros da ANN, sendo no final escolhida a ANN que forneceu melhores índices de desempenho, índices definidos na secção 3.2.

3.3.2 - Probabilistic Neural Networks (PNN)

As PNN foram introduzidas por Specht em 1990 [16]. As PNN constituem uma classe de ANN que combinam os melhores atributos de classificação de padrões e de ANN do tipo feedforward [17-18].

Estas já têm sido utilizadas para classificação das células no diagnóstico do cancro da mama [6], reconhecimento do roncar dos porcos [17], reconhecimento de plantas através da sua folha [19] e reconhecimento de distúrbios de potência [20].

As PNN são adoptadas em muitas circunstâncias devido às suas vantagens [21]. O treino é mais rápido do que o das ANN de *Backpropagation*. As PNN conseguem uma aproximação ao resultado óptimo de Bayes, sob certas condições encontradas. Estas ANN apresentam-se robustas aquando da apresentação de amostras com ruído.

A mais importante vantagem das PNN é o seu treino fácil e instantâneo. Os pesos não são “treinados” mas assimilados. Os pesos existentes nunca são alterados mas apenas novos vectores são inseridos nas matrizes dos pesos aquando do treino. Estas ANN podem então ser utilizadas em tempo real.

Arquitectura da rede

As PNN são ANN do tipo feedforward, como já foi indicado atrás, isto é, o sinal converge da camada de entrada para a camada de saída sem quaisquer ligações de “feedback”. As PNN são construídas em três camadas, camada de entrada, camada da função radial e camada competitiva.

A camada da função radial calcula as distâncias do vector de entradas para o vector de entrada de treino e cria um vector nos quais os elementos indicam o quão perto a entrada está dos dados de treino. Depois são somadas todas essas contribuições para cada classe de dados para produzir um vector de probabilidades. Finalmente, a camada competitiva, através da saída da camada anterior captura o máximo dessas probabilidades, e produz um 1 para essa classe e 0's para as outras classes.

A figura 3.5 mostra a arquitectura definida para PNN utilizada nesta dissertação, as notações usadas provêm do software MATLAB Neural Network Toolbox[10]




Figura 3.5 Arquitectura da PNN utilizada

R = número das variáveis de entrada

Número de pares da entrada/saída = número de neurónios da camada da função radial

L = número de classes dos dados de entrada = número de neurónios da camada de saída (camada competitiva)

Como foi dito atrás, as PNN são constituídas por três camadas. A descrição de cada camada será apresentada de seguida:

- Camada de entrada: consiste no vector de entrada. Na figura 3.5, este vector denomina-se de p e está representado pela barra preta. A sua dimensão é de $R \times 1$, sendo R é número de variáveis de entrada.
- Camada da função radial: nesta camada é calculada a distância entre o vector de entrada, p , e o vector de pesos obtido de cada coluna da matriz dos pesos, $IW1,1$. O vector distância é definido pelo produto escalar entre os 2 vectores. Sabendo que a matriz dos pesos têm dimensões $Q \times R$, Q é números de elementos da amostra. O produto escalar entre p e o i -ésima coluna de $IW1,1$ produz o i -ésimo elemento da distância $||IW1,1 - p||$, ficando este vector com dimensão $Q \times 1$, como indicado na figura 3.5. O símbolo “-”, indica que se trata de uma distância entre vectores. Em seguida, o vector de polarização (denominado, na literatura anglo-saxónica, *bias*), $b1$, é multiplicado elemento a elemento com $||IW1,1 - p||$, representado por “.” na figura 3.5, este resultado produz o vector $n = ||IW1,1 - p|| * b1$ de dimensões $Q \times 1$.

O vector n é então enviado para a função de transferência RadBas, definida pela seguinte equação:

$$\text{Radbas}(n) = e^{-n^2} \quad (3.12)$$

Cada elemento de $\mathbf{n}$ é substituído na equação 3.12 produzindo o elemento correspondente de $\mathbf{a1}$, sendo este a saída da camada da Função Radial. Pode-se representar o i -ésimo elemento de $\mathbf{a}$ como:

$$a_i^1 = \text{Radbas}(\|IW_{i,1} - p\|b_i1) \quad (3.13)$$

Onde os elementos do vector $\mathbf{a1}$ são obtidos pelo seguinte gráfico:




Figura 3.6 Função radial [10]

O i -ésimo elemento de $\mathbf{a}$ será igual a 1 se a entrada $\mathbf{p}$ for igual à i -ésima coluna da matriz dos pesos, $IW_{i,1}$. O neurónio da camada da função radial possuindo um vector dos pesos próximo ao vector de entrada $\mathbf{p}$ irá produzir um valor perto de 1 onde depois os pesos, na camada competitiva, irão passar na função competitiva, sendo este assunto discutido de seguida. Nesta rede é possível acontecer que alguns elementos de $\mathbf{a}$ estejam próximos de 1 desde que o padrão de entrada esteja perto dos padrões de treino.

Todos os valores do vector polarização, *bias*, desta camada são definidos como $\sqrt{\ln(0,5)}/s$, resultando funções que cruzam 0.5 quando os pesos de entrada são $\pm s$. s é denominado de *spread*, e é uma constante das PNN, que representa a largura da função transferência representada na figura 3.6 [22]. Este factor não pode ser escolhido ao acaso. Cada neurónio nesta camada responde com 0.5 ou mais para qualquer vector de entrada com a distancia de s do seu vector dos pesos. Se a escolha recair sobre um valor pequeno de s , pode resultar uma fraca generalização dos vectores de entrada/saída. Por outro lado, um valor grande de s vai gerar valores muito altos (perto de 1) para todas as entradas usadas na rede.

- **Camada competitiva:** Nesta camada o vector $\mathbf{a}$ é multiplicado pela matriz dos pesos $LW_{2,1}$, sendo $LW_{2,1}$ a matriz dos pesos da camada competitiva, de dimensão $L \times Q$, onde L é definido como o número de classes. Esta multiplicação vai gerar n^2 de dimensão $L \times 1$.

A função Competitiva, denominada de C na figura 3.5, vai produzir um 1 correspondendo ao maior elemento de n_2 , e 0's em todo o resto.

$$a^2 = \text{compet}(LW_{2,1}a^2) \quad (3.14)$$

Onde **compet** é a função de transferência da camada competitiva. Assim a rede neuronal classificou o vector de entrada para um vector específico de L classes, onde a classe que foi escolhida tinha a maior probabilidade de estar correcta. Então garante-se que vector de entrada vai ter uma classe definida à saída.

3.4 - Avaliação da capacidade generalização

A amostra utilizada durante o processo de treino das ANN denomina-se usualmente de conjunto de treino (denominando-se, na literatura anglo-saxónica, *Learning Set* ou *Training Set*). No caso das ANN estudadas, MLP e PNN, as primeiras passam por um processo de validação da precisão do modelo adoptado. Essa avaliação deverá ser feita com uma amostra de uma mesma população que não tenha sido usada para a construção do modelo, a qual se denomina conjunto de validação (denominando-se, na literatura anglo-saxónica, *Validation Set*). A escolha de um conjunto de validação que seja diferente do de treino poderá ser essencial, uma vez que permitirá obter um modelo com uma boa capacidade de generalização. Por outras palavras, pode-se dizer que a ANN vai obter uma capacidade de prever com precisão a saída de futuros exemplos pertencentes à mesma população do conjunto de treino mas que não tenham sido usados para treino. Nas ANN a obtenção de estimativas para o erro de previsão a partir do conjunto de treino traduz-se, geralmente, no fornecimento de valores optimistas (denominando-se, na literatura anglo-saxónica, *biased estimates*). Assim sendo, ao treinar-se ANN adoptando um critério de selecção que minimize os erros de treino, poder-se-á correr o risco de a rede ficar sobre-adaptada aos dados fornecidos durante o treino (fenómeno denominado na literatura anglo-saxónica de *overfitting*), podendo perder assim a capacidade de generalização aquando da apresentação de novos conjuntos.

Utilizando a mesma lógica, para avaliar a capacidade de generalização da rede neuronal resultante do processo de treino, ou seja, os pesos e os *bias* das ligações já definidos, é utilizada uma terceira amostra denominada de conjunto de teste (denominando-se, na literatura anglo-saxónica, *Testing Set*).

Seguindo [1], para o processo de avaliação de desempenho utilizou-se o método *Holdout*, pois segundo [1], esta técnica é a mais apropriada para amostras de grande dimensão. A técnica de Holdout consiste em dividir a amostra disponível em dois subconjuntos disjuntos, sendo que um dos conjuntos é utilizado para o processo de treino e o restante conjunto (o Holdout) para avaliação do desempenho final da rede neuronal treinada.

Ao fazer a partição dos conjuntos, necessária para a aplicação desta técnica, deve-se ter em atenção, que se a maior parte de exemplos for deixado para a avaliação do desempenho, de modo a garantir uma boa estimativa do erro de previsão, então a qualidade das ANN poderá ser reduzida. Por outro lado se a maioria dos exemplos for utilizada no processo de treino, então o erro de previsão poderá fornecer uma informação errada acerca da qualidade da rede neuronal. Atendendo a isto, usualmente utiliza-se cerca de 30% dos exemplos seleccionados para conjuntos de teste, ficando os restantes 70% para o conjunto de treino. No caso das MLP, onde é necessário um processo de avaliação, geralmente são escolhidos do conjunto de treino, 30% para o conjunto de validação, restando assim 70% para o conjunto de treino.

Em [1], é sugerido a seguinte fórmula, que foi obtida de modo empírico para a obtenção do conjunto de teste:

$$\#\{\text{conjunto de teste}\} = \min \{0.3 \times \#\{\text{amostra disponivel}\}, 1000\} \quad (3.15)$$

Nesta fórmula, está definido que o conjunto de teste deverá corresponder a 30% das amostras disponíveis, não sendo, no entanto, necessário mais de 1000 amostras para obter uma boa estimativa para o erro previsão.

Para o caso em estudo nesta dissertação, dos 4596 cenários de operação, definidos na secção 2.5, que foram gerados para a rede interligada de teste, 1000 destes cenários foram aleatoriamente seleccionados para o conjunto de teste, sendo que os restantes 3596 ficaram para o conjunto de treino. No caso particular das ANN do tipo MLP, de entre os 3596 cenários do conjunto de treino foram seleccionados aleatoriamente 1000 cenários para o conjunto de validação, tendo os restantes 2596 cenários sido utilizados para o conjunto de treino. Tendo isto, resultou deste processo a repartição de dados que se resume na tabela 3.1:

Tabela 3.1 - Repartição do conjunto de dados da rede de teste, por tipo de ANN utilizada

Tipo de ANN	MLP	PNN
Conjunto de treino	2596	3596
Conjunto de validação	1000	---
Conjunto de teste	1000	1000

3.5 - Comparação de desempenho entre as ANN estudadas

Ao longo deste trabalho vão ser testadas dois tipos de ANN nomeadamente as MLP e as PNN. No caso das primeiras, estas são fortemente influenciadas pelas variáveis de escolhidas para a sua construção. Sendo assim, é necessário ter cuidado quando se pretende analisar o

desempenho entre as diferentes escolhas. Esse cuidado envolve as escolhas da sua estrutura, do vector de variáveis de entrada ou de saída, ou ainda da escolha dos algoritmos de treino a adoptar, no caso do segundo tipo de ANN, o cuidado centra-se na escolha do *spread*.

Atendendo a estes aspectos, e no âmbito da busca da melhor ANN para o problema discutido nesta dissertação, classificação de segurança, vai-se realizar a comparação entre cada duas alternativas, A e B, para as diferentes escolhas efectuadas. Seguindo o procedimento de [1], foi realizado o teste de hipótese estatístico, para obtenção dessa comparação: teste à diferença entre os valores esperados de duas populações quaisquer. Neste procedimento foram seguidas as etapas que se descrevem a seguir:

- Etapa 1 - Treino

Esta etapa aplica-se apenas às ANN do tipo MLP, pois como foi dito na secção 3.3, as PNN não necessitam de treino, pois as variáveis não são treinadas mas sim assimiladas. Então para as ANN do tipo MLP foram treinadas 50 soluções diferentes de valores iniciais, resultando deste processo um conjunto de 50 ANN para cada alternativa, A e B, de configuração da ANN do tipo MLP escolhida.

- Etapa 2 - avaliação do desempenho

Nesta etapa é necessário, uma vez mais, distinguir o tipo de ANN utilizada.

Para as ANN do tipo MLP para cada conjunto, foi feita uma avaliação de desempenho de cada ANN treinada, através do cálculo de um índice numérico E que caracteriza o erro de previsão, se esta for treinada para regressão, e erro global de classificação, se esta for treinada para classificação, para os exemplos do conjunto de teste. A seguir, para cada conjunto de erros de previsão foi calculada a média amostral $\bar{E}$ e a variância amostral s_E^2 , nomeadamente, $\bar{E}_B$, $s_{E,A}^2$, $s_{E,B}^2$.

No caso das PNN, o erro a utilizar é o erro global de classificação para o melhor *spread*, sendo que a sua variância amostral é 0.

- Etapa 3 - Teste de hipóteses

Por fim, supondo que os valores esperados das duas populações desconhecidas de erros de previsão/classificação se designam $\mu_{E,A}$ e $\mu_{E,B}$, foi testada a seguinte hipótese:

$$H_0: \mu_{E,A} = \mu_{E,B} \quad (3.16)$$

na qual se considera que as duas alternativas fornecem erros de previsão/classificação semelhantes. Se for possível supor, com elevada probabilidade, que H_0 é falsa, então considera-se válida a seguinte hipótese alternativa:

$$H_1: \mu_{E,A} > \mu_{E,B} \quad (3.17)$$

a qual se considera que, de entre as duas alternativas, a A fornece pior desempenho de previsão.

Esta inferência foi realizada através do cálculo da seguinte estatística de teste:

$$ET = \frac{\bar{E}_A - \bar{E}_B}{\sqrt{\frac{s_{E,A}^2}{N_A} + \frac{s_{E,B}^2}{N_B}}} \quad (3.18)$$

onde N_A e N_B representam as dimensões das amostras de erros de previsão. Admitindo que H_0 é verdadeira, então ET segue uma distribuição Normal Padronizada, ou seja, com média zero e desvio padrão 1, $N(0,1)$, representado na figura 3.7.




Figura 3.7 - Exemplo da distribuição utilizada num teste de hipóteses [2]

Partindo deste pressuposto, será então possível obter, por consulta dos valores da distribuição $N(0,1)$, um valor crítico para ET, denominado $ET(\alpha)$, como sendo o valor para qual a variável ET tem uma probabilidade α de ter um valor superior a $ET(\alpha)$. Se o valor calculado para ET a partir da equação 3.18 for maior do que $ET(\alpha)$, então H_0 é rejeitada com um nível de confiança de $(1 - \alpha) \times 100\%$. Neste processo, α denomina-se nível de significância do teste. Ao maior α com o qual se pode rejeitar H_0 dá-se o nome de valor de prova. Quanto menor for o valor de prova, maior será a confiança com que se pode aceitar H_1 por consequência de se ter rejeitado H_0 . Neste tipo de testes é costume aceitar-se H_1 , se o valor de prova for, 1%, 5% ou 10 %. Na presente dissertação aceitou-se 10 % como o valor de prova, sendo que para maiores valores de prova a hipótese H_0 não é rejeitada, tornando assim o teste como inconclusivo.

3.6 - Conclusões

Neste capítulo foram abordadas os tipos de redes neuronais artificiais que irão ser utilizadas na classificação de segurança de sistemas eléctricos.

Foi descrito o processo de treino das rede neuronais a ser utilizado, assim como a forma que foi utilizada para avaliar o desempenho destas. Na secção 3.5 foi descrita a forma como se comparou as alternativas testadas, com a finalidade de escolher qual a estrutura de rede neuronal que melhora os resultados de classificação. Sendo que todos os testes e escolha das redes neuronais estão demonstrados no capítulo 5.

Capítulo 4

Resultados Obtidos do Treino das ANN

4.1 - Estudo do vector das variáveis de entrada

Na secção 2.6 foi explicado que antes de começar a treinar as ANN para classificação era necessário escolher o conjunto de características, para o vector das variáveis de entrada das ANN. Como não foi âmbito deste trabalho estudar qual o melhor conjunto de características, foram testadas duas alternativas definidas em trabalhos anteriores ([1-2]), para aplicar a hipótese de que *um conjunto de características que melhore uma rede treinada para regressão melhorará uma rede treinada para classificação.*

Relativamente ao vector de variáveis de entrada a considerar para o treino das ANN, foram testadas as seguintes alternativas:

- *Alternativa A:* uso do vector de variáveis de entrada utilizado no trabalho realizado em [1] e descrito na secção 2.6;
- *Alternativa B:* uso do vector de variáveis de entrada sugerido em [2] e descrito na secção 2.6.

Nos dois casos, o vector de variáveis de entrada foi constituído por um conjunto de 63 características candidatas. No caso da estrutura escolhida para a rede neuronal, a usada para este teste foi a mesma utilizada em ambos os trabalhos atrás referenciados, ou seja é utilizada apenas uma camada escondida. Relativamente à escolha de neurónios da camada escondida, a escolha recaiu sobre 8 neurónios, onde em ambos os trabalhos se utilizou a regra empírica definida na equação 3.10. Desta forma para ambas as ANN treinadas a estrutura adoptada foi do tipo 63-8-1 (nº de entradas - nº de unidades escondidas - nº de saídas).

Para a comparação de desempenho entre estas 2 alternativas foi utilizado o procedimento que se descreve na secção 3.5 e que consistiu na realização de um teste de hipóteses à

diferença entre os valores esperados dos erros de regressão dado por cada uma das alternativas. O erro de regressão utilizado foi o Erro Quadrático Médio que está definido na equação 3.3.

Através da execução deste procedimento obteve-se, para a previsão do índice de segurança, I (120s), de cada uma das 7 linhas de transmissão críticas, duas amostras de 50 erros de regressão (uma amostra por alternativa). Note-se que cada erro de regressão, RE, resulta da aplicação do conjunto de teste a cada uma das 50 ANN que foram treinadas mediante a adopção de cada uma das alternativas (A e B). Da figura 4.1 à 4.7 podem visualizar-se os gráficos correspondentes aos erros de regressão das 50 ANN, por aplicação do procedimento descrito a cada uma das linhas consideradas críticas, assim como o valor do erro de regressão médio (mean) e o seu desvio padrão (STD). Nestas figuras, cada barra corresponde ao valor de um erro de regressão, RE.




Figura 4.1 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 15-16




Figura 4.2 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 15-17




Figura 4.3 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 14 -18




Figura 4.4 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-4




Figura 4.5 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-6




Figura 4.6 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 16-18




Figura 4.7 - 50 erros de regressão obtidos com as alternativas A e B de variáveis de entrada da ANN - avaliação da linha 20 - 21

Após obtidos os erros de regressão das 50 ANN, torna-se possível comparar o desempenho das duas alternativas (Alternativa A e B). Na figura 4.8 está apresentado o gráfico de barras que permite visualizar o valor médio dos erros de regressão (mean (RE)) que estão contidos em cada uma das amostras que se apresentam da figura 4.1 à figura 4.7.




Figura 4.8 - Comparação de desempenho entre as alt. A e B de saídas da ANN

Na figura 4.8, na comparação entre cada 2 valores médios dos erros de regressão obtidos para a previsão de cada índice de segurança, é apresentado o grau de confiança (Conf.) com que se pode afirmar que o maior dos dois valores é efectivamente superior ao outro (resultado vindo do teste de hipóteses descrito na secção 3.5). Com base nos valores que se apresentam, pode afirmar-se com um nível de confiança superior a 90%, que a aplicação do conjunto de características da Alternativa B foi capaz de reduzir o erro de regressão das ANN para 5 linhas de transmissão críticas (linha 15-16, 15-17, 16-4, 14-18, 16-18). Para as restantes 2 linhas, como o nível de confiança é inferior a 90 % esta hipótese não pode ser aceite,

tornando-se o teste inconclusivo. Destes resultados pode concluir-se que o conjunto de características da alternativa B mostrou-se eficaz, visto que para a maior parte das linhas, esta foi capaz de melhorar os erros de regressão, sendo que para os outros casos a sua aplicação não correspondeu a uma pior previsão.

Tendo em conta estes resultados, para o treino das ANN para classificação, utilizou-se a alternativa B, sendo que, a esta alternativa irá ser acrescentada uma outra variável, a temperatura da estação do ano em que o cenário se encontra, já descrita na secção 2.6, devido a que esta está directamente ligada a capacidade de transmissão de uma linha, sendo por isso importante para o objectivo deste trabalho, classificação de segurança, tendo como saída uma variável binária “seguro/inseguro”.

4.2 - Resultados da ANN treinadas para classificação

Tendo sido já definido o conjunto de variáveis a utilizar nas ANN para classificação, através dos resultados obtidos na secção 4.1, nesta secção será apresentado os desempenhos obtidos para as alternativas testadas para este tipo de ANN. Esta secção será subdividida em duas, sendo que a primeira diz respeito às alternativas testadas para as ANN do tipo MLP e onde a segunda diz respeito às ANN do tipo PNN.

4.2.1 - Resultados das ANN do tipo MLP

Relativamente aos resultados das ANN do tipo MLP, a seguinte tabela mostra as alternativas estudadas, nomeadamente para a sua estrutura, funções de activação utilizadas na camada de saída e número de neurónios utilizados nas camadas escondidas.

Para as camadas escondidas foi sempre utilizada a função de activação **tansig**

Tabela 4.1 - Alternativas testadas para as ANN do tipo MLP

Nome da alternativa	Algoritmo de treino	Estrutura da rede (n-nu-(nu*)-1)	Função activação camada saída	Função activação camadas escondidas
Alternativa C	Levenberg-Marquardt (LM)	64-8-1	tansig	t a n s i g
Alternativa D		64-16-1	tansig	
Alternativa E		64-8-1	logsig	
Alternativa F		64-16-1	logsig	
Alternativa G	Scaled Conjugated Gradient (SCG)	64-8-1	tansig	
Alternativa H		64-16-1	tansig	
Alternativa I		64-8-1	logsig	
Alternativa J		64-16-1	logsig	
Alternativa L		64-8-8-1	tansig	
Alternativa M		64-16-16-1	tansig	
Alternativa N		64-8-8-1	logsig	
Alternativa O		64-16-16-1	logsig	

(nu*-utilizado se houver mais que uma camada escondida)

Tal como já foi devidamente explicado, todos os vectores de variáveis de entrada foram constituídos por um conjunto de 64 características candidatas. Relativamente à escolha de neurónios das camadas escondida, segundo a regra empírica definida na equação 3.10, a escolha recaiu sobre 8. A escolha de 16 neurónios, deveu-se ao facto de se querer testar o desempenho das ANN com um número de neurónios grande. Neste caso optou-se pelo dobro como se podia ter optado por outro número, visto que todas as regras existentes são obtidas de forma empírica. Os resultados apresentados de seguida para cada alternativa, serão o erro global de classificação (GCE), definido na equação 3.4, o erro de falso alarme (FA), definido na equação 3.5, o erro de alarme falhado (MA), definido na equação 3.6. Todos estes erros foram obtidos das 50 ANN testadas para cada alternativa. Cada alternativa será composta por 7 conjuntos de três gráficos, dizendo cada conjunto respeito a cada uma das linhas de transmissão críticas. Nos gráficos de barras, cada barra diz respeito ao valor de um erro, seja GCE, FA ou MA, aparecendo também as médias (mean) e os desvios padrões (STD) respeitantes a cada erro.

Alternativa C (LM;64-8-1;tansig)




Figura 4.9 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 15-16




Figura 4.10 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 15-17




Figura 4.11 - Erros(Global, MA e FA) das 50 ANN obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 14-18




Figura 4.12 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-4




Figura 4.13 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-6




Figura 4.14 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 16-18




Figura 4.15 - Erros(Global, MA e FA) das 50 ANN, obtidos com a alternativa C de parâmetros da ANN - avaliação da linha 20-21

Através da análise destes gráficos é possível observar a grande dependência dos valores iniciais das ANN, isto é, consegue-se observar uma variação da percentagem de erro de uma ANN para a outra. Obtendo-se tanto erros de baixo valor como erros de grande valor. Daí a importância de ter 50 amostra, para se conseguir obter conclusões para cada alternativa, uma vez que a inicialização por dos pesos por parte do *software* MATLAB é feita de modo aleatório.

Os gráficos acima representados são similares para todas as alternativas, assim como a interpretação de resultados. Por esse motivo os mesmos conjuntos de gráficos serão apresentados para as restantes alternativas no anexo A.

Para cada alternativa, no corpo deste trabalho, são a seguir apresentados 3 gráficos de colunas, sendo cada gráfico referente ao erro global (Global), erro de falso alarme (FA) e erro de alarme falhado (MA). Cada gráfico contém as médias (mean) e os desvios padrões (std) dos erros obtidos para cada linha de transmissão considerada crítica. De notar que as linhas de transmissão estão ordenadas por ordem decrescente de número de cenários inseguros contidos no conjunto de dados utilizado para treino e teste das ANN


Alternativa C (LM;64-8-1;tansig)

Figura 4.16 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa C




Alternativa D (LM; 64-16-1; tansig)

Figura 4.17 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa D


Alternativa E (LM; 64-8-1,logsig)

Figura 4.18 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa E




Alternativa F (LM; 64-16-1; logsig)

Figura 4.19 - Gráficos que representam as médias e os desvios padrões dos erros classificação (Global, FA e MA) para cada linha de transmissão, da alternativa F


Alternativa G (SCG;64-8-1; tansig)

Figura 4.20 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa G


Alternativa H (SCG; 64-16-1; tansig)

Figura 4.21 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa H


Alternativa I (SCG; 64-8-1; logsig)

Figura 4.22 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa I




Alternativa J (SCG; 64-16-1; logsig)

Figura 4.23 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa J


Alternativa L (SCG; 64-8-8-1; tansig)

Figura 4.24 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa L


Alternativa M (SCG; 64-16-16-1; tansig)

Figura 4.25 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa M


Alternativa N (SCG; 64-8-8-1; logsig)

Figura 4.26 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa N


Alternativa O(SCG; 64-16-16-1; logsig)

Figura 4.27 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa O

Da observação dos gráficos atrás representados, pode-se afirmar que a análise isolada do erro global (global) pode dar falsas conclusões sobre a capacidade de classificação da ANN, isto verifica-se nos casos em que existe um menor número de casos inseguros na amostra. Este observação pode retirar-se da análise da linha 20-21, que apresenta erros globais baixo,

mas quando se analisa o erro de alarme falhado (MA), observa-se que a ANN não conseguiu identificar grande parte dos casos inseguros desta linha, visto que o valor de MA é sempre elevado. Para exemplificar, esta situação, imagine-se uma amostra de 1000 casos, em que dentro destes existiam apenas 5 casos inseguros. Se a rede neuronal não identificasse nenhum caso como inseguro, a ANN iria ter um erro global de 0.5%, ou seja 99.5% de sucesso, pela equação 3.4, o que podia levar a crer, pela análise deste erro, que esta estava a classificar de forma acertada, sendo que na realidade esta não acertou nenhum caso inseguro. Nesta situação o erro de alarme falhado (MA) seria 100%.

Alternativa B (ANN do tipo MLP, treinada para regressão)

De seguida é apresentado o mesmo tipo de gráficos que foram representados, da figura 4.16 à 4.27, mas agora para a alternativa B. Mesmo não tendo sido treinada para classificação, é possível obter os erros de classificação. Estes erros são obtidos vendo se a variável que foi prevista por esta ANN, corrente em regime quasi-estacionário I(120s), ultrapassou o limiar de segurança descrito no capítulo 2, sendo que os resultados se tornam inseguros se esta ultrapassar e seguros se não ultrapassar. Esta análise é necessária para efectuar uma avaliação de desempenho entre este tipo de ANN e as que foram treinadas especificamente para classificação.




Figura 4.28 - Gráficos que representam as médias e os desvios padrões dos erros de classificação (Global, FA e MA) para cada linha de transmissão, da alternativa B

Pode-se, da observação da figura 4.28, desde já constatar que o erro global de classificação (global) foi com este tipo de ANN atenuado, em uma grande percentagem, quando comparando com os fornecidos pelas ANN para classificação, dando assim boas indicações para o teste de hipóteses, tratado mais à frente neste capítulo.

4.2.2 - Resultados das ANN do tipo PNN

Para obtenção dos resultados das ANN do tipo PNN, utilizou-se o mesmo vector de entrada já utilizado para as ANN do tipo MLP. Como já foi dito no capítulo 3, nas ANN deste tipo, o único parâmetro que o software MATLAB permite mudar é o *spread*. Desta forma foi utilizado um intervalo de *spread*, entre 0,01 e 1, para selecção do *spread* que permitia retirar os melhores resultados de classificação.

Os resultados obtidos, em termos de erros de classificação, para cada linha crítica de transmissão, apresentam-se da figura 4.29 à figura 4.35




Figura 4.29 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 15-16




Figura 4.30 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 15-17




Figura 4.31 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 14-18




Figura 4.32 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 16-4




Figura 4.33 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 16-6




Figura 4.34 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 16-18




Figura 4.35 - Gráficos que representam os erros de classificação (Global, FA e MA) para cada *spread* da linha 20-21

Da análise dos gráficos que representam os resultados das ANN do tipo PNN podemos observar que cada linha é um caso isolado de estudo. Efectivamente o valor de *spread* seleccionado como o que fornece melhores resultados de classificação foi diferente entre as linhas. Note-se ainda que para a linha 20-21, em vez de um valor de *spread*, foi seleccionado uma gama de valores de *spread*. Na seguinte tabela é representado este facto:

Tabela 4.2 - Quadro resumo do melhor *spread* e erros de classificação de cada linha de transmissão considerada crítica

Linha	Spread	Global (%)	Missed Alarm (%)	False Alarm (%)
15-16	0,2	4.20%	12.68%	1.91%
15-17	0,4	1.60%	23.53%	0.00%
16-4	0,3	0.60%	31.25%	0.10%
16-6	0,2	0.50%	21.43%	0.20%
14-18	0,3	1.00%	18.42%	0.31%
16-18	0,2	0.80%	43.75%	0.10%
20-21	[0,03,0.1]	0.50%	57.14%	0.10%

4.3 - Comparação de desempenho entre as ANN testadas

Para obter conclusões sobre, qual é a melhor ANN para classificação, foram realizados testes de hipóteses, segundo o que está descrito na secção 3.5, entre as várias alternativas estudadas. Destes testes de hipóteses retirou-se qual a melhor alternativa de ANN, de entre aquelas que foram treinadas, nomeadamente as seguinte: as alternativas presentes na tabela 4.1, as PNN e ainda a ANN treinada para regressão com as entradas adoptadas de [2].

Teste de Hipóteses 1

No teste de hipóteses 1 compararam-se as alternativas C (LM; 64-8-1; tansig) e D (LM;64-16-1;tansig). Deste retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com uma função de activação **tansig** à saída e que recorre ao método de treino **Levenberg-Marquardt**. Na figura 4.36 é feita a comparação de desempenho entres os valores médios obtidos para o erro global de classificação (variável Mean (Global)). Na tabela 4.3 apresentam-se os resultados antes descritos do valor médio (mean (Global)) e variância amostral (std (Global)) dos erros globais contidos em cada amostra de 50 ANN. Esta tabela apresenta ainda os resultados obtidos do teste de hipóteses efectuado entre as duas alternativas nomeadamente os valores da estatística de teste (ET), o grau de confiança com que se aceita como sendo melhor, a

alternativa que fornece menor erro global (conf.) e qual a alternativa que é aceite como sendo a melhor (Alternativa aceite). Para todos os testes de hipóteses realizados, foram colocados o mesmo tipo de gráficos.




Figura 4.36 - Comparação de desempenho entre as alt. C e D

Tabela 4.3 - Média e variância amostral dos erros globais de classificação obtidos com as alt C e D

Linha	Alternativa C		Alternativa D		ET(Global)	Conf.	Alternativa aceite
	mean(Erro Global)	std(Global)	mean(Erro Global)	std(Global)			
15-16	3.88%	4.72%	2.99%	0.81%	1.316	90.6%	Alternativa D
15-17	2.09%	2.47%	1.77%	1.11%	0.831	79.7%	Alternativa D
14-18	1.84%	1.25%	1.72%	1.27%	0.469	68.1%	Alternativa D
16-4	1.32%	0.96%	0.97%	0.41%	2.338	99.0%	Alternativa D
16-18	1.25%	0.39%	1.10%	0.33%	2.116	98.3%	Alternativa D
16-6	1.26%	1.74%	0.98%	0.41%	1.132	87.1%	Alternativa D
20-21	0.87%	0.74%	0.68%	0.25%	1.670	95.3%	Alternativa D

A partir destes resultados, pode-se concluir com um nível de confiança superior a 90%, que a utilização de 16 neurónios na camada escondida (seguindo a regra empírica 3.10) foi capaz de reduzir o erro para 4 das linhas de transmissão críticas (linha 15-16, 16-4, 16-18, 20-21).. Para as restantes 3 linhas, o nível de confiança com que se pode obter esta conclusão é inferior a 90 % pelo que esta hipótese não pode ser aceite. No entanto estes resultados permitem concluir que a utilização de 16 neurónios na camada escondida mostrou-se eficaz uma vez que, para a maior parte dos problemas de classificação, foi capaz de melhorar a

capacidade de classificação da ANN, sendo que a sua aplicação nunca provocou uma deterioração dessa capacidade.

Teste de Hipóteses 2

No teste de hipóteses 2 compararam-se as alternativas E (LM; 64-8-1; logsig) e F (LM; 64-16-1; logsig). Deste teste de hipóteses retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com uma função de activação **Logsig** à saída e que recorre ao método de treino **Levenberg-Marquardt**.

Os resultados obtidos apresentam-se na figura 4.37 e tabela 4.4.




Figura 4.37 - Comparação de desempenho entre as alt. E e F

Tabela 4.4 - Média e variância amostral dos erros globais de classificação obtidos com as alt E e F

Linha	Alternativa E		Alternativa F		ET(Global)	Conf.	Alternativa aceite
	mean(Erro Global)	std(Global)	mean(Global)	std(Global)			
15-16	21.30%	0.00%	21.30%	0.00%	0.0%	50.0%	Alternativa E
15-17	6.80%	0.00%	6.80%	0.00%	0.0%	50.0%	Alternativa E
14-18	1.60%	0.00%	1.60%	0.00%	0.0%	50.0%	Alternativa E
16-4	1.40%	0.00%	1.40%	0.00%	0.0%	50.0%	Alternativa E
16-18	3.80%	0.00%	3.80%	0.00%	0.0%	50.0%	Alternativa E
16-6	1.60%	0.00%	1.60%	0.00%	0.0%	50.0%	Alternativa E
20-21	0.70%	0.00%	0.70%	0.00%	0.0%	50.0%	Alternativa E

A partir destes resultados, verifica-se que o teste de hipótese, entre estas duas alternativas, demonstrou-se inconclusivo, visto que se obtiveram exactamente os mesmos resultados para as duas alternativas. Como se requer uma escolha, optou-se por guardar a opção E, ANN com 8 neurónios na camada escondida, visto que a equação usada para calcular tal número de neurónios, já foi testada noutros trabalhos.

Teste de Hipóteses 3

No teste de hipóteses 3 compararam-se as alternativas aceites do teste de hipótese 1 e 2, nomeadamente a alternativa D (LM; 64-16-1; tansig) e E (LM; 64-8-1; logsig). Deste teste de hipóteses retirou-se a função de activação da camada de saída que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com um método de treino Levenberg-Marquardt.

Os resultados obtidos apresentam-se na figura 4.38 e tabela 4.5.




Figura 4.38 - Comparação de desempenho entre as escolhas do T.H. 1 e 2

Tabela 4.5 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 1 e 2

Linha	Alternativas aceites do Teste de Hipoteses 1(T.H.1)		Alternativa aceites do Teste de Hipoteses 2 (T.H.2)		ET(Global)	Conf.	Alternativa aceite
	mean(Global)	std(Global)	mean (Global)	std(Global)			
15-16	2.99%	0.81%	21.30%	0.00%	160.347	100.0%	Alternativa D
15-17	1.77%	1.11%	6.80%	0.00%	32.135	100.0%	Alternativa D
14-18	1.72%	1.27%	1.60%	0.00%	0.681	75.2%	Alternativa E
16-4	0.97%	0.41%	1.40%	0.00%	7.380	100.0%	Alternativa D
16-18	1.10%	0.33%	3.80%	0.00%	57.815	100.0%	Alternativa D
16-6	0.98%	0.41%	1.60%	0.00%	10.800	100.0%	Alternativa D
20-21	0.68%	0.25%	0.70%	0.00%	0.517	69.7%	Alternativa D

A partir destes resultados, aceita-se a alternativa D, com um grau de confiança superior a 90% em 5 linhas de transmissão críticas (linha 15-16, 15-17, 16-4, 16-18 e 16-6. Na linha 14-18, através do teste de hipóteses, verifica-se que a alternativa E não piora os resultados. No entanto observa-se que a melhoria obtida em termo de erro global para estas linhas, por se optar pela alternativa E é pouco significativa. Para além disso este teste de hipóteses não demonstra a verdadeira qualidade da ANN da alternativa E, visto que esta não foi capaz de diferenciar os cenários inseguros dos seguros, classificando todos os casos como sendo seguros (ver figura 4.18). Tendo isto em conta, e apesar de o teste de hipóteses ter dado a alternativa E como melhor ANN para classificação no casos das linha 14-18, o autor deste trabalho vai aceitar, como sendo melhor a alternativa D em detrimento da alternativa E.

Teste de Hipóteses 4

No teste de hipóteses 4 compararam-se as alternativas G (SCG; 64-8-1; tansig) e H (SCG;64-16-1; tansig). Deste teste de hipóteses retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com uma função de activação **Tansig** à saída e que recorre ao método de treino **Scaled Conjugated Gradient**.

Os resultados obtidos apresentam-se na figura 4.39 e tabela 4.6.




Figura 4.39 - Comparação de desempenho entre as alt. G e H

Tabela 4.6 - Média e variância amostral dos erros globais de classificação obtidos com as alt G e H

Linha	Alternativa G		Alternativa H		ET(Global)	Conf.	Alternativa Aceite
	mean(Global)	std(Global)	mean(Global)	std(Global)			
15-16	1.97%	2.82%	2.50%	3.91%	0.775	78.1%	Alternativa G
15-17	1.06%	0.85%	1.39%	1.62%	1.261	89.6%	Alternativa G
16-4	0.49%	0.10%	0.58%	0.33%	1.784	96.3%	Alternativa G
16-6	0.48%	0.17%	0.49%	0.26%	0.046	51.8%	Alternativa G
14-18	0.79%	0.78%	0.80%	0.77%	0.077	53.1%	Alternativa G
16-18	0.53%	0.34%	0.55%	0.35%	0.262	60.3%	Alternativa G
20-21	0.46%	0.15%	0.44%	0.17%	0.552	71.0%	Alternativa H

A partir destes resultados, pode afirmar-se, com um nível de confiança superior a 90%, que a utilização de 8 neurónios na camada escondida (seguindo a regra empírica 3.10) foi capaz de reduzir o erro para uma das linhas de transmissão críticas (linha 16-4). Para as restantes linhas o teste foi inconclusivo. Para as restantes para 5 linhas de transmissão críticas (15-16,15-17,16-6,14-8,16-18) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 % pelo que esta hipótese não pode ser aceite. Apenas se aceitou esta alternativa visto que a utilização dos 8 neurónios melhorou os resultados. Já na última linha (20-21), apesar do nível de confiança ser inferior a 90%, aceitou-se a opção de utilização de 16 neurónios, visto que esta melhora ligeiramente os resultados da ANN. Ao ter-se a necessidade de utilizar 16 neurónios para linha 20-21, pode supor-se que nas situações em que existe um baixo número de cenários inseguros, a utilização de um maior número de neurónios possa ajudar a ANN a generalizar melhor (i.e., a evitar que fique sobre - adoptada)

Teste de Hipóteses 5

No teste de hipóteses 5 compararam-se as alternativas I (SCG; 64-8-1; logsig) e J (SCG; 64-16-1; logsig). Deste teste de hipóteses retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com uma função de activação **Logsig** à saída e que recorre ao método de treino **Scaled Conjugated Gradient**.

Os resultados obtidos apresentam-se na figura 4.40 e tabela 4.7.




Figura 4.40 - Comparação de desempenho entre as alt. I e J

Tabela 4.7 - Média e variância amostral dos erros globais de classificação obtidos com as alt. I e J

Linha	Alternativa I		Alternativa J		ET(Global)	Conf.	Alternativa aceite
	mean(Erro Global)	std(Global)	mean(Erro Global)	std(Global)			
15-16	2.12%	2.82%	1.73%	0.59%	0.963	83.2%	Alternativa J
15-17	1.03%	0.86%	0.99%	0.80%	0.266	60.5%	Alternativa J
14-18	0.58%	0.31%	0.77%	0.39%	2.706	99.7%	Alternativa I
16-4	0.59%	0.29%	0.54%	0.31%	0.830	79.7%	Alternativa J
16-18	0.81%	0.67%	1.13%	1.17%	1.660	95.2%	Alternativa I
16-6	0.68%	0.45%	0.76%	0.64%	0.647	74.1%	Alternativa I
20-21	0.47%	0.13%	0.59%	0.36%	2.193	98.6%	Alternativa I

A partir destes resultados, pode afirmar-se com um nível de confiança superior a 90%, que a utilização de 8 neurónios na camada escondida (seguindo a regra empírica 3.10) foi capaz

de reduzir o erro para 3 das linhas de transmissão críticas (linha 14-18, 16-18 e 20-21). Para as restantes linhas, o teste foi inconclusivo. Para uma linha crítica (16-6) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 %, tendo apenas se aceiteado esta alternativa visto que a utilização dos 8 neurónios melhorou os resultados. Já na linha (15-16, 15-17,16-4), aceitou-se a opção de utilização de 16 neurónios, visto que esta melhora os resultados da ANN, apesar do grau de confiança desta ser inferior a 90%

Teste de Hipóteses 6

No teste de hipóteses 6 compararam-se as alternativas aceites do teste de hipótese 4 (uso da função de activação tansig) e 5 (uso da função da activação logsig). Deste teste de hipóteses retirou-se a função de activação que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN com um método de treino **Scaled Conjugated Gradient**.

Os resultados obtidos apresentam-se na figura 4.41 e tabela 4.8.




Figura 4.41 - Comparação de desempenho entre as escolhas do T.H. 4 e 5

Tabela 4.8 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 4 e 5

Linha	Alternativas aceites do Teste de Hipoteses 4 (T.H.5)		Alternativa aceites do Teste de Hipoteses 5 (T.H.6)		ET(Global)	Conf.	Alternativa aceite
	mean(Global)	std(Global)	mean (Global)	std(Global)			
15-16	1.97%	2.82%	1.73%	0.59%	0.595	72.4%	Alternativa J
15-17	1.06%	0.85%	0.99%	0.80%	0.461	67.8%	Alternativa J
14-18	0.49%	0.10%	0.58%	0.31%	1.938	97.4%	Alternativa G
16-4	0.48%	0.17%	0.54%	0.31%	1.085	86.1%	Alternativa G
16-18	0.79%	0.78%	0.81%	0.67%	0.165	56.5%	Alternativa G
16-6	0.53%	0.34%	0.68%	0.45%	1.870	96.9%	Alternativa G
20-21	0.44%	0.17%	0.47%	0.13%	0.988	83.8%	Alternativa H

Legenda: Alternativa G (SCG; 64-8-1; tansig); Alternativa H (SCG; 64-16-1; tansig); Alternativa J (SCG; 64-16-1; logsig)

A partir destes resultados, pode afirmar-se com um nível de confiança superior a 90%, que a utilização da função de activação **tansig** foi capaz de reduzir o erro para 2 das linhas de transmissão críticas (linha 14-18, 16-6). Para as restantes linhas o teste foi inconclusivo. Para as outras linhas de transmissão críticas (16-18, 16-4, 20-21) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 % pelo que esta hipótese não pode ser aceite. Apenas se aceitou esta alternativa visto que a utilização da função de activação **tansig** melhorou os resultados. Já nas linhas (15-16, 15-17), aceitou-se a opção de utilização da função de activação **logsig**, visto que esta melhorou os resultados da ANN. Apesar de ser sem significado estatístico. Tendo em conta estes resultados não se pode validar a hipótese, de que com a utilização da função de activação **tansig**, o desempenho de classificação melhora, como descrito na secção 3.3.1.

Teste de Hipóteses 7

No teste de hipóteses 7 compararam-se as alternativas L (SCG; 64-8-8-1; tansig) e M (SCG; 64-16-16-1; tansig), nomeadamente duas ANN com 2 camadas escondidas. Deste teste de hipóteses retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma ANN duas camadas escondidas, com uma função de activação **Tansig** à saída e que recorre ao método de treino **Scaled Conjugated Gradient**.

Os resultados obtidos apresentam-se na figura 4.42 e tabela 4.9.




Figura 4.42 - Comparação de desempenho entre as alt. L e M

Tabela 4.9 - Média e variância amostral dos erros globais de classificação obtidos das alt. L e M

Linha	Alternativa L		Alternativa M		ET(Global)	Conf.	Alternativa aceite
	mean(Erro Global)	std(Global)	mean(Erro Global)	std(Global)			
15-16	2.33%	2.76%	3.33%	5.36%	1.179	88.1%	Alternativa L
15-17	1.42%	1.62%	1.23%	1.43%	0.601	72.6%	Alternativa M
14-18	0.57%	0.30%	0.47%	0.20%	1.940	97.4%	Alternativa M
16-4	0.54%	0.28%	0.49%	0.16%	1.165	87.8%	Alternativa M
16-18	0.84%	0.64%	0.90%	0.78%	0.393	65.3%	Alternativa L
16-6	0.56%	0.37%	0.54%	0.28%	0.182	57.2%	Alternativa M
20-21	0.50%	0.15%	0.44%	0.19%	1.555	94.0%	Alternativa M

A partir destes resultados, pode afirmar-se com um nível superior a 90%, que a utilização de 16 neurónios nas camadas escondidas foi capaz de reduzir o erro para 2 das linhas de transmissão críticas (linha 14-18, 20-21). Para as restantes linhas, o teste foi inconclusivo. Para 3 linhas de transmissão críticas (15-17, 16-4, 16-6) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 %. Apenas se aceitou esta alternativa visto que a utilização dos 16 neurónios melhorou os resultados (apesar de ser sem significado estatístico). Já nas linhas (15-16, 16-18), aceitou-se a opção de utilização de 8 neurónios, visto que esta opção melhorou os resultados da ANN (mesmo sem significado estatístico).

Teste de Hipóteses 8

No teste de hipóteses 8 comparam-se as alternativas N (SCG; 64-8-8-1; logsig) e O (SCG; 64-16-16-1; logsig). Deste teste de hipóteses retirou-se o número de neurónios que melhor classifica a segurança de cada linha de transmissão, aquando de uma rede com 2 camadas escondidas, com uma função de activação **Logsig** à saída e que recorre ao método de treino **Scaled Conjugated Gradient**.

Os resultados obtidos apresentam-se na figura 4.43 e tabela 4.10.




Figura 4.43 - Comparação de desempenho entre as alt. N e O

Tabela 4.10 - Média e variância amostral dos erros globais de classificação obtidos das alt. N e O

Linha	Alternativa N		Alternativa O		ET(Global)	Conf.	Alternativa aceite
	mean(Erro Global)	std(Global)	mean(Erro Global)	std(Global)			
15-16	3.92%	7.64%	2.52%	3.90%	1.155	87.6%	Alternativa O
15-17	1.62%	1.80%	1.43%	1.63%	0.547	70.8%	Alternativa O
14-18	0.53%	0.21%	0.67%	0.46%	1.904	97.2%	Alternativa N
16-4	0.47%	0.21%	0.62%	0.39%	2.359	99.1%	Alternativa N
16-18	0.84%	0.65%	1.02%	0.93%	1.125	87.0%	Alternativa N
16-6	0.59%	0.35%	0.71%	0.43%	1.551	94.0%	Alternativa N
20-21	0.72%	1.32%	0.52%	0.14%	1.055	85.4%	Alternativa O

A partir destes resultados, pode afirmar-se com um nível superior a 90%, que a utilização de 8 neurónios nas camadas escondidas foi capaz de reduzir o erro para 3 das linhas de

transmissão críticas (linha 14-18, 16-4 e 16-6). Para as restantes linhas, o teste foi inconclusivo. Para 1 linha de transmissão crítica (16-18), o nível de confiança com que se pode fazer esta afirmação é inferior a 90 %, pelo que apenas se aceitou esta alternativa visto que a utilização dos 8 neurónios melhorou os resultados (apesar de sem significado estatístico). Já nas linhas (15-16,15-17,20-21), aceitou-se a opção de utilização de 16 neurónios, visto que esta alternativa melhorou os resultados da ANN, apesar de ter sido sem significado estatístico.

Teste de Hipóteses 9

No teste de hipóteses 9 compararam-se as alternativas aceites do teste de hipótese 7 (função de activação tansig) e 8 (função de activação logsig). Deste teste de hipóteses retirou-se a função de activação que melhor classifica a segurança de cada linha de transmissão, aquando de uma rede que recorre ao método de treino **Scaled Conjugated Gradient**, contendo 2 camadas escondidas.

Os resultados obtidos apresentam-se na figura 4.44 e tabela 4.11.




Figura 4.44 - Comparação de desempenho entre as escolhas do T.H. 7 e 8

Tabela 4.11 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 7 e 8

Linha	Alternativas aceites do Teste de Hipoteses 7(T.H.7)		Alternativa aceites do Teste de Hipoteses 8 (T.H.8)		ET(Global)	Conf.	Alternativa aceite
	mean(Global)	std(Global)	mean (Global)	std(Global)			
15-16	2.33%	2.76%	2.52%	3.90%	0.281	61.1%	Alternativa L
15-17	1.23%	1.43%	1.43%	1.63%	0.638	73.8%	Alternativa M
14-18	0.47%	0.20%	0.53%	0.21%	1.343	91.0%	Alternativa M
16-4	0.49%	0.16%	0.47%	0.21%	0.424	66.4%	Alternativa N
16-18	0.84%	0.64%	0.84%	0.65%	0.031	51.2%	Alternativa L
16-6	0.54%	0.28%	0.59%	0.35%	0.694	75.6%	Alternativa M
20-21	0.44%	0.19%	0.52%	0.14%	2.377	99.1%	Alternativa M

Legenda: Alternativa L (SCG; 64-8-8-1; tansig); Alternativa M (SCG; 64-16-16; tansig); Alternativa N (SCG; 64-8-8-1; logsig)

A partir destes resultados, pode afirmar-se com um nível superior a 90%, que a utilização da função de activação **tansig** foi capaz de reduzir o erro para 2 das linhas de transmissão críticas (linha 14-18,20-21). Para as restantes linhas o teste foi inconclusivo. Para 4 linhas de transmissão críticas (15-16, 15-17,16-18, 16-6) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 % pelo, apenas se aceitou esta alternativa visto que a utilização da função de activação **tansig** melhorou os resultados (apesar de ser sem significado estatístico). Já na linha (16-4), aceitou-se a opção de utilização da função de activação **logsig**, visto que esta melhorou os resultados da ANN, apesar de ter sido sem significado estatístico. Tendo em conta estes resultados, pode-se tirar a mesma conclusão já obtida do teste de hipóteses 6, de que não se pode afirmar que a função tansig melhora a classificação.

Teste de Hipóteses 10

No teste de hipóteses 10 compararam-se as alternativas aceites do teste de hipótese 6 e 9 Deste de teste de hipóteses retirou-se o número de camadas escondidas que melhor classifica a segurança de cada linha de transmissão, aquando de uma rede que recorre ao método de treino **Scaled Conjugated Gradient**

Os resultados obtidos apresentam-se na figura 4.45 e tabela 4.12.




Figura 4.45 - Comparação de desempenho entre as escolhas do T.H. 6 e 9

Tabela 4.12 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 6 e 9

Linha	Alternativas aceites do Teste de Hipoteses 6(T.H.6)		Alternativa aceites do Teste de Hipoteses (T.H.9)		ET(Global)	Conf.	Alternativa aceite
	mean(Global)	std(Global)	mean (Global)	std(Global)			
15-16	1.73%	0.59%	2.33%	2.76%	1.498	93.3%	Alternativa J
15-17	0.99%	0.80%	1.23%	1.43%	1.069	85.8%	Alternativa J
14-18	0.49%	0.10%	0.47%	0.20%	0.499	69.1%	Alternativa M
16-4	0.48%	0.17%	0.47%	0.21%	0.264	60.4%	Alternativa N
16-18	0.79%	0.78%	0.84%	0.64%	0.350	63.7%	Alternativa G
16-6	0.53%	0.34%	0.54%	0.28%	0.161	56.4%	Alternativa G
20-21	0.44%	0.17%	0.44%	0.19%	0.000	50.0%	Alternativa I

Legenda: Alternativa G (SCG; 64-8-1; tansig); Alternativa I (SCG; 64-8-1; logsig); Alternativa J (SCG; 64-16-1; logsig); Alternativa M (SCG; 64-16-16-1; tansig); Alternativa N (SCG; 64-8-8-1; logsig)

A partir destes resultados, pode afirmar-se com um nível superior a 90%, que a utilização de uma camada escondida foi capaz de reduzir o erro para 1 linha de transmissão crítica (linha 15-16). Para 3 linhas de transmissão críticas (15-17, 16-18, 16-6) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 % pelo que apenas se aceitou esta alternativa visto que a utilização de uma camada escondida melhorou os resultados (apesar de sem significado estatístico). Nas restantes 2 linhas (14-18, 16-4), aceitou-se a opção de utilização de duas camadas escondidas, visto que melhora, apesar de sem significado estatístico, os resultados da ANN. Observa-se que na linha 20-21, o teste de hipóteses apresentou um grau

de confiança de 50%, sendo que qualquer uma das hipóteses podia ter sido escolhida. Apenas se aceitou a hipótese de uma camada escondida, visto ser a opção que, com maior frequência, melhora os resultados das ANN.

Teste de Hipóteses 11

No teste de hipóteses 11 compararam-se as alternativas aceites do teste de hipótese 10 (algoritmo de treino SCG) e 3 (algoritmo de treino LM). Deste teste de hipóteses retirou-se qual o melhor método de treino para ANN treinadas para classificação (**Scaled Conjugated Gradient ou Levenberg-Marquardt**).

Os resultados obtidos apresentam-se na figura 4.46 e tabela 4.13.




Figura 4.46 - Comparação de desempenho entre as escolhas do T.H. 10 e 3

Tabela 4.13 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 10 e 3

nome	Linha	Alternativas aceites do Teste de Hipoteses 10(T.H.10)		Alternativa aceites do Teste de Hipoteses 3(T.H.3)		ET(Global)	Conf.	Alternativa aceite
		mean(Global)	std(Global)	mean (Global)	std(Global)			
10	15-16	1.73%	0.59%	2.99%	0.81%	8.904	100.0%	Alternativa J
11	15-17	0.99%	0.80%	1.77%	1.11%	4.073	100.0%	Alternativa J
16	14-18	0.47%	0.20%	1.72%	1.27%	6.876	100.0%	Alternativa M
14	16-4	0.47%	0.21%	0.97%	0.41%	7.645	100.0%	Alternativa N
18	16-18	0.79%	0.78%	1.10%	0.33%	2.551	99.5%	Alternativa G
15	16-6	0.53%	0.34%	0.98%	0.41%	5.916	100.0%	Alternativa G
24	20-21	0.44%	0.17%	0.68%	0.25%	5.593	100.0%	Alternativa I

Legenda: Alternativa G (SCG; 64-8-1; tansig); Alternativa I (SCG; 64-8-1; logsig); Alternativa J (SCG; 64-16-1; logsig); Alternativa M (SCG; 64-16-16-1; tansig); Alternativa N (SCG; 64-8-8-1; logsig)

A partir destes resultados, pode afirmar-se com um nível de confiança 100%, que a utilização do método de treino **Scaled Gradient Conjugated** foi capaz de reduzir o erro para todas as linhas de transmissão. Tendo isto em conta pode concluir-se que este método de treino é o melhor para usar em problemas de classificação, sendo este o método aconselhado em [10] para estes problemas.

Teste de Hipóteses 12

No teste de hipóteses 12 compararam-se as alternativas aceites do teste de hipótese 11 (ANN do tipo MLP, treinadas para classificação) e os resultados obtidos da utilização da ANN do tipo PNN. Deste teste obteve-se qual o melhor tipo de ANN que foi treinado para classificação durante a realização deste trabalho.

Os resultados obtidos apresentam-se na figura 4.47 e tabela 4.14.




Figura 4.47 - Comparação de desempenho entre as escolhas do T.H. 10 e os resultados obtidos pelas PNN

Tabela 4.14 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 11 e os resultados obtidos pelas PNN

Linha	PNN		Alternativa aceites do Teste de Hipoteses 11 (T.H. 11)		ET(Global)	Conf.	Alternativa aceite
	Erro Global	std(Global)	mean (Global)	std(Global)			
15-16	4.20%	0.00%	1.73%	0.59%	29.841	100.0%	Alternativa J
15-17	1.60%	0.00%	0.99%	0.80%	5.434	100.0%	Alternativa J
14-18	0.60%	0.00%	0.47%	0.20%	4.349	100.0%	Alternativa M
16-4	0.50%	0.00%	0.47%	0.21%	0.876	81.0%	Alternativa N
16-18	1.00%	0.00%	0.79%	0.78%	1.901	97.1%	Alternativa G
16-6	0.80%	0.00%	0.53%	0.34%	5.528	100.0%	Alternativa G
20-21	0.50%	0.00%	0.44%	0.17%	2.291	98.9%	Alternativa I

Legenda: Alternativa G (SCG; 64-8-1; tansig); Alternativa I (SCG; 64-8-1; logsig); Alternativa J (SCG; 64-16-1; logsig); Alternativa M (SCG; 64-16-16-1; tansig); Alternativa N (SCG; 64-8-8-1; logsig)

A partir destes resultados, pode afirmar-se com um nível de confiança superior a 90%, que a utilização das ANN do tipo MLP foi capaz de reduzir o erro para 6 linhas de transmissão críticas (linha 15-16, 15-17, 14-18, 16-18, 16-6, 20-21). Para 1 linha crítica (16-4) o nível de confiança com que se pode fazer esta afirmação é inferior a 90 % pelo que esta hipótese não pode ser aceite. Apenas se aceitou esta alternativa visto que a utilização de um ANN do tipo MLP melhorou os resultados, apesar de ter sido só com 81% de nível de confiança. Tendo em conta estes resultados, pode-se afirmar que as ANN do tipo MLP são muito poderosas em

qualquer exercício, seja ele regressão ou classificação, mesmo quando comparadas com as ANN feitas especialmente para classificação, como são o caso das ANN do tipo PNN.

Teste de Hipóteses 13

O teste de hipóteses 13 compararam-se as alternativas aceites do teste de hipótese 12 (ANN do tipo MLP treinadas para classificação) e os resultados obtidos da alternativa B (ANN do tipo MLP treinada para regressão). Deste teste de hipóteses, validou-se a hipótese, se uma ANN treinada para classificação obtém melhores resultados de classificação do que uma ANN treinada para regressão.

Os resultados obtidos apresentam-se na figura 4.48 e tabela 4.15.




Figura 4.48 - Comparação de desempenho entre as escolhas do T.H. 12 e os resultados obtidos pela alt. B

Tabela 4.15 - Média e variância amostral dos erros globais de classificação obtidos com as escolhas do T.H 12 e os resultados obtidos pela alt. B

Linha	Alternativas aceites do Teste de Hipoteses 12(T.H.12)		Alternativa B		ET(Global)	Conf.	Alternativa aceite
	mean(Global)	std(Global)	mean (Global)	std(Global)			
15-16	1.73%	0.59%	0.84%	0.24%	9.899	100.0%	Alternativa B
15-17	0.99%	0.80%	0.25%	0.11%	6.475	100.0%	Alternativa B
14-18	0.47%	0.20%	0.58%	0.14%	3.071	99.9%	Alternativa M
16-4	0.47%	0.21%	0.31%	0.12%	4.718	100.0%	Alternativa B
16-18	0.79%	0.78%	0.39%	0.10%	3.613	100.0%	Alternativa B
16-6	0.53%	0.34%	0.14%	0.10%	7.933	100.0%	Alternativa B
20-21	0.44%	0.17%	0.14%	0.11%	10.602	100.0%	Alternativa B

A partir destes resultados, pode afirmar-se com um nível de confiança 100% que a utilização das ANN do tipo MLP treinadas para regressão foi capaz de reduzir o erro de classificação para 6 linhas de transmissão críticas (linha 15-16, 15-17, 16-18, 16-6, 20-21), sendo que para 1 linha crítica (14-18) aceita-se com um nível de superior a 90% as ANN do tipo MLP treinadas para classificação.

4.4 - Conclusão

Neste capítulo foram abordados os resultados obtidos ao longo deste trabalho. Na secção 4.1 foi estudado qual o melhor vector de entradas candidatas a usar nas ANN para classificação. De entre as escolhas possíveis estavam os vectores provenientes de trabalhos já efectuados, nomeadamente em [1-2]. Através ao teste de hipóteses, realizado na secção 4.1, aceitou-se que o vector de entradas das ANN a ser o utilizado seria o que provinha de [2]. Isto deve-se ao facto de este vector, melhorar o erro de regressão das ANN treinadas para regressão, neste caso uma ANN com a seguinte constituição: LM, 63-8-1, purelin.

Na secção 4.2 foram apresentados os resultados provenientes das ANN treinadas para classificação. Dos resultados da subsecção 4.2.1, pode concluir-se que para as ANN do tipo MLP é muito importante treiná-las várias vezes, na presente dissertação uma amostra de 50 ANN, visto que estas dependem muito dos valores iniciais dos pesos. Ainda nesta secção conclui-se a importância de calcular os três erros de classificação (nomeadamente Global, MA e FA), visto que a análise isolada do erro global pode levar a falsas conclusões sobre a qualidade de classificação das ANN. Na subsecção 4.2.2 foram apresentados os resultados das PNN. Nesta subsecção pode concluir-se a importância do parâmetro *spread*, nos resultados apresentados por este tipo de ANN. Pode concluir-se que se deve estudar este parâmetro isoladamente para cada caso de estudo, pois para todas as linhas de transmissão críticas existe, à excepção da linha 20-21 (nomeadamente a linha de transmissão com menos cenários inseguros), um valor de *spread* que melhora o erro global de classificação das PNN.

Na secção 4.3, foram efectuados os testes de hipóteses entre as diferentes alternativas estudadas, recorrendo a comparação dos seus erros de classificação globais. Destes testes de hipóteses pode-se retirar as seguintes conclusões:

- relativamente às ANN do tipo MLP treinadas para classificação, que recorram ao método de treino LM e com uma função de saída tansig, observou-se que a utilização de 16 neurónios na camada escondida melhorava os erros de classificação;
- relativamente às ANN do tipo MLP treinadas para classificação, que recorram ao método de treino LM e com uma função de saída logsig, observou-se que a utilização de 8 ou 16 neurónios na camada escondida mostrou-se indiferente;

- relativamente às ANN do tipo MLP treinadas para classificação, que recorram ao método de treino LM, conclui-se que a função de activação tansig melhorou os resultados em detrimento da função de activação logsig;
- dentro das ANN do tipo MLP, que recorram ao método de treino SCG, conclui-se que a escolha entre 1 ou 2 camadas escondidas, 8 ou 16 neurónios nas camadas escondidas e da função de activação da saída (tansig ou logsig) terá que ser analisada caso a caso, pois os resultados obtidos não conseguiram identificar uma das opções como sendo sempre a melhor;
- na escolha do melhor algoritmo de treino para as ANN do tipo MLP para classificação, pode concluir-se, através do teste de hipóteses 11 (comparação entre o algoritmo de treino SCG e o algoritmo de treino LM), que o SCG mostrou-se o melhor o algoritmo de treino para todas as linhas;
- relativamente à escolha do melhor método de ANN estudada para classificação, conclui-se que as ANN do tipo MLP demonstraram melhor desempenho para todas as linhas críticas de transmissão;
- relativamente a validação da hipótese : uma ANN treinada para classificação consegue obter melhor precisão que uma ANN treinada para regressão, conclui-se que à excepção de uma linha de transmissão crítica, esta hipótese não pode ser validada, levando a supor que sempre que se quer efectuar classificação que envolva saídas (comportamentos) que se possam traduzir em problemas de regressão, a melhor opção será treinar a rede neuronal para minimizar o seu erro de regressão (e não o de classificação).

Capítulo 5

Conclusões

5.1 - Considerações Finais

No presente trabalho foram abordadas as ANN com a finalidade de classificar a segurança em tempo real de sistemas eléctricos interligados que explorem elevadas penetrações de produção eólica onde ainda não se encontra a capacidade de sobreviver a cavas de tensão.

São diversos os problemas que se podem analisar, devido a penetrações de elevados volumes de produção eólica. De entre esses problemas, foi analisado o problema de segurança que consiste no aparecimento de sobrecargas em regime quasi-estacionário, em ramos de, transmissão que ultrapassem os limites de operacionalidade definidos como aceitáveis, como consequência da ocorrência de defeitos que envolvam uma perda significativa de produção eólica. Este problema pode ser criado através da ocorrência de um curto-circuito trifásico simétrico numa linha da rede transporte

A utilização das ANN deveu-se ao facto de estas já terem demonstrado uma superioridade em qualidade de resultados em relação a outros métodos de AA. Os aspectos construtivos e as opções de treino adoptadas descrevem-se no capítulo 3.

Para a utilização das ANN e para criar dados para que se pudessem treinar foi utilizada uma rede interligada, adoptada de [1]. O problema criado, para avaliar a capacidade das ANN para classificar o problema estudado, foi a ocorrência de um curto-circuito trifásico simétrico numa linha da rede transporte, sendo este eliminado pela saída de serviço da linha com defeito.

Nesta dissertação utilizaram-se ANN treinadas especialmente para classificação, sendo que o objectivo seria verificar se os erros de classificação diminuía em relação às ANN treinadas para regressão. O tipo de treino para classificação consiste na criação de um vector de saída por classes, no caso do presente trabalho foram utilizadas 2 classes, seguro/inseguro, sendo este vector criado tendo em conta os índices de segurança discutidos na secção 2.4. Em relação ao vector de variáveis de entrada o utilizado foi adoptado de [2],

tendo as variáveis constituintes deste vector sido escolhidas tendo em conta que nesta dissertação iria ser utilizadas ANN treinadas para regressão, tendo-se apenas acrescentado uma nova variável, temperatura (Temp), uma vez que esta variável tem influência directa na capacidade de transmissão das linhas de transporte.

Dos resultados obtidos pode-se constatar que cada caso deve ser estudado individualmente, ou seja cada linha deverá ser classificada por uma ANN específica, tendo-se concluído que método de treino **Scaled Conjugated Gradient (SCG)** é melhor no campo da classificação que o método **Levenberg-Marquardt (LM)**.

Dos resultados obtidos conclui-se que as ANN do tipo MLP foram melhores que as ANN do tipo PNN. As ANN do tipo MLP mostram-se assim muito poderosas para a resolução de vários problemas de classificação, mesmo quando comparadas com ANN, que são especialmente criadas para classificação, como são o caso das ANN do tipo PNN.

Os resultados obtidos permitem concluir que a utilização de ANN de classificação não melhorou de forma geral a classificação de segurança, à excepção da linha 14-18 (ver **teste de hipótese 13**, do capítulo 4), sendo que os melhores resultados foram obtidos através do treino para regressão das ANN. Mesmo assim pode-se concluir que as ANN treinadas para classificação levam a classificações boas pois observando, uma vez mais o **Teste de hipóteses 13** conclui-se que a diferença entre erros globais de classificação, entre as ANN de regressão e as ANN de classificação, não é muito significativo.

5.2 - Perspectivas Futuras

No presente trabalho foram abordados conceitos relativos à classificação de segurança de sistemas interligados com elevada penetração eólica, através de ANN criadas para o efeito, obtendo-se resultados satisfatórios neste campo. No entanto, visto que nesta dissertação as características adoptadas para o vector de entrada das ANN vieram de trabalhos [1-2], em que o interesse era o treino de ANN para regressão, seria de especial interesse fazer uma selecção de características especialmente realizada para classificação. Para este efeito é indicado [23], onde é apresentado um método de divisão de características inter-classe, medida-F, podendo este talvez melhorar os desempenhos das ANN para classificação.

Seria também interessante utilizar a *toolbox for fuzzy logic* do *software* MATLAB, testada em [24].

Em [24] encontram-se também citadas outras técnicas, nomeadamente os classificadores do tipo *k-Nearest Neighbor* (conceptualmente próximos das PNN), as árvores de decisão, os classificadores do tipo *Fuzzy Nearest Prototype* e as árvores de regressão de Kernel.

Referências

1. Vasconcelos, M.H., *Avaliação e Controlo de Segurança de Redes Interligadas com Grande Penetração Eólica com base em Métodos de Aprendizagem Automática*, in DEEC. 2007, FEUP: Porto
2. Araújo, R.M.S.F., *Seleção de Características para Avaliação de Segurança de Sistemas Eléctricos Interligados com Elevada Penetração Eólica Recorrendo a Rede Neurais Artificiais*. 2008, FEUP: Porto.
3. REN, *Manual de Procedimentos do Gestor do Sistema*. Junho 2006.
4. Wehenkel, L., *Automatic Learning Techniques in Power Systems*. 1998: Kluwer Academic Publishers.
5. R. KOHAVI, F.P., *Machine Learning*. 1998, Boston: Kluwer Academic Publishers.
6. Ali H. Al-Timemy, M.I.F.M.A.-N., Member IEEE, FIETE, Nebras H. Qaeeb, Member IEEE, *Probabilistic Neural Network for Breast Biopsy Classification*. Setembro 2009.
7. Ali Hussain, A.A., Fawzi M.Al Naima, *Comparison of Different Neural Network Approaches for the Prediction of Kidney Dysfunction*. International journal of Biological and Life Sciences 2010: p. 84-90.
8. Slva, F.C.d., *Análise ROC*. 2006: São José dos Campos.
9. Nune, R., *PATH PREDICTION AND PATH DIVERSION IDENTIFYING METHODOLOGIES FOR HAZARDOUS MATERIALS TRANSPORTED BY MALICIOUS ENTITIES*. 2007, faculty of the Virginia Polytechnic Institute: Virginia, EUA.
10. (www.mathworks.com), M.I., *Neural Network Toolbox™ User's Guide*. Vol. Version 6.0.4. 2010.
11. M. OlesKovicz, D.V.C., R.K. Aggarwal, *Redes Neurais Artificiais Aplicadas à Classificação Rápida de Falhas em sistemas Eléctricos de Potência*. SBA Controle & Automação, 2000. 11.
12. Semra Içer, S.K., Aysegül Güven *Comparison of multilayer perceptron training algorithms for portal venous doppler signals in the cirrhosis disease*. Expert Systems with Applications, 2006: p. 406-413.
13. Fidalgo, J.N., *Operação de Redes Eléctricas Isoladas com Produção Eólica- contributo das redes neurais* 1995, FEUP: Porto.
14. Ranganathan, A., *The Levenberg-Marquardt Algorithm*. 2004.
15. Møller, M.F., *A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning*. 1990.

16. Specht, D.F., *Probabilistic Neural Networks*. 1990. 109-118.
17. M. E. Pastell, M.K., *A Probabilistic Neural Network Model for Lameness Detection*, in *Journal of Dairy Science*. 2007. p. 2283-2292.
18. V.L. Georgiou, N.G.P., K.E. Parsopoulos, Ph.D. Alevizos, M.N. Vrahatis, *Optimizing the Performance of Probabilistic Neural Networks in a Bionformatics Task*, University of Patras Artificial Intelligence Research Center (UPAIRC): Patras.
19. Stephen Gang Wu, F.S.B., Eric You Xu, Yu-Xuan Wang, Yi-Fan Chang, Qiao-Liang Xiang, *A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network*. 2007.
20. Chau-Shing Wang, W.-R.Y., Jing-Hong Chen, and Guan-Yu Liao, *Power Disturbance Recognition Using Probabilistic Neural Networks*, in *International MultiConference of Engineers and Computer Scientists*. 2009.
21. T.Master, *Practical Neural Networks Recipes* 1993, Nova Iorque.
22. Zhiqiang Cheng, Y.M., *A Research about Pattern Recognition of Control Chart Using Probability Neural Network*, in *International Colloquium on Computing, Communication, Control, and Management*. 2008.
23. Lopes, J.A.P., *Estabilidade Transitória de Sistemas de Produção e Transporte de Energia*. 1988, FEUP.
24. M.A. Matos, J.A.P.L., M. Helena Vasconcelos. *Dynamic security assessment by fuzzy inference*. in *Proceedings of ACAI '99 Workshop on Applications of Machine Learning*. 1999. Chania - Greece.

Anexos

Anexo 1: Resultados Obtidos para as Alternativas Treinadas para as ANN do Tipo MLP

Alternativa D (LM; 64-16-1; tansig)




Figura A1.1 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 15-16




Figura A1.2 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 15-17




Figura A1.3 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 14-18




Figura A1.4 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-4




Figura A1.5 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-6




Figura A1.6 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 16-18




Figura A1.7 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa D de parâmetros da ANN - avaliação da linha 20-21


Alternativa E (LM; 64-8-1,logsig)

Figura A1.8 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 15-16




Figura A1.9 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 15-17




Figura A1.10 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 14-18




Figura A1.11 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-4




Figura A1.12 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-6




Figura A1.13 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 16-18




Figura A1.14 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa E de parâmetros da ANN - avaliação da linha 20-21

Alternativa F (LM; 64-16-1; logsig)




Figura A1.15 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 15-16




Figura A1.16 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 15-17




Figura A1.17 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 14-18




Figura A1.18 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-4




Figura A1.19 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-6




Figura A1.20 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 16-18




Figura A1.21 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa F de parâmetros da ANN - avaliação da linha 20-21

Alternativa G (SCG;64-8-1; tansig)




Figura A1.22 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 15-16




Figura A1.23 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 15-17




Figura A1.24 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 14-18




Figura A1.25 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-4




Figura A1.26 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-6




Figura A1.27 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 16-18




Figura A1.28 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa G de parâmetros da ANN - avaliação da linha 20-21

Alternativa H (SCG; 64-16-1; tansig)




Figura A1.29 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 15-16




Figura A1.30 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 15-17




Figura A1.31 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 14-18




Figura A1.32 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-4




Figura A1.33 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-6




Figura A1.34 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 16-18




Figura A1.35 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa H de parâmetros da ANN - avaliação da linha 20-21


Alternativa I (SCG; 64-8-1; logsig)

Figura A1.36 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 15-16




Figura A1.37 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 15-17




Figura A1.38 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 14-18




Figura A1.39 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-4




Figura A1.40 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-6




Figura A1.41 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 16-18




Figura A1.42 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa I de parâmetros da ANN - avaliação da linha 20-21

Alternativa J (SCG; 64-16-1; logsig)




Figura A1.43 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 15-16




Figura A1.44 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 15-17




Figura A1.45 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 14-18




Figura A1.46 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-4




Figura A1.47 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-6




Figura A1.48 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 16-18




Figura A1.49 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa J de parâmetros da ANN - avaliação da linha 20-21

Alternativa L (SCG; 64-8-8-1; tansig)




Figura A1.50 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 15-16




Figura A1.51 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 15-17




Figura A1.52 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 14-18




Figura A1.53 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-4




Figura A1.54 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-6




Figura A1.55 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 16-18




Figura A1.56 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa L de parâmetros da ANN - avaliação da linha 20-21

Alternativa M (SCG; 64-16-16-1; tansig)




Figura A1.57 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 15-16




Figura A1.58 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 15-17




Figura A1.59 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 14-18




Figura A1.60 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-4




Figura A1.61 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-6




Figura A1.62 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 16-18




Figura A1.63 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa M de parâmetros da ANN - avaliação da linha 20-21


Alternativa N (SCG; 64-8-8-1; logsig)

Figura A1.64 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 15-16




Figura A1.65 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 15-17




Figura A1.66 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 14-18




Figura A1.67 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-4




Figura A1.68 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-6




Figura A1.69 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 16-18




Figura A1.70 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa N de parâmetros da ANN - avaliação da linha 20-21

Alternativa O (SCG; 64-16-16-1; logsig)




Figura A1.71 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 15-16




Figura A1.72 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 15-17




Figura A1.73 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 14-18




Figura A1.74 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-4




Figura A1.75 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-6




Figura A1.76 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 16-18




Figura A1.77 - Erros (Global, MA e FA) das 50 ANN, obtidos com a alternativa O de parâmetros da ANN - avaliação da linha 20-21