



Marcelo Gil Silvestre dos Santos

Licenciatura em Bioengenharia: Ramo de Biomédica

SYPEC: Desenvolvimento de Classificadores para Identificação Automática da Postura de Sentado

Dissertação para obtenção do Grau de Mestre em
Engenharia Biomédica

Orientador: Doutor Pedro Vieira, Professor Auxiliar,
FCT - UNL

Co-orientadora: Doutora Cláudia Quaresma, Investigadora
CEFITEC, FCT - UNL

Júri:

Presidente: Professor Doutor Mário António Forjaz Secca
Arguente: Professora Doutora Carla Maria Quintão Pereira



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Março 2013

UNIVERSIDADE NOVA DE LISBOA
FACULDADE DE CIÊNCIAS E TECNOLOGIA
Licenciatura em Bioengenharia: Ramo de Biomédica

**SYPEC: Desenvolvimento de Classificadores para
Identificação Automática da Postura de Sentado**

MARCELO GIL SILVESTRE DOS SANTOS

Dissertação para Obtenção do Grau de Mestre em Engenharia Biomédica

Orientador: Doutor Pedro Vieira, Professor Auxiliar, FCT-UNL

Co-orientadora: Doutora Cláudia Quaresma, Investigadora CEFITEC,
FCT - UNL

Júri:

Presidente: Prof. Doutor Mário António Forjaz Secca
Arguente(s): Prof. Doutora Carla Maria Quintão Pereira

Março
2013

SYPEC: DESENVOLVIMENTO DE CLASSIFICADORES PARA IDENTIFICAÇÃO AUTOMÁTICA DA POSTURA DE SENTADO

Copyright @ Marcelo Gil Silvestre dos Santos, FCT /UNL, UNL

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

AGRADECIMENTOS

Desde já gostaria de agradecer a todos aqueles que contribuíram de forma directa ou indirecta para a realização desta dissertação.

À professora Adelaide de Jesus pela concepção da ideia do projecto SYPEC.

Aos meus orientadores, Professor Pedro Vieira e Professora Cláudia Quaresma pela orientação e conselhos prestados para a realização desta dissertação e por mostrarem sempre disponibilidade para o que precisasse. Obrigado por permitirem que fizesse parte de um projecto aliciante como este.

Um agradecimento especial ao meu colega de trabalho Leonardo Martins cuja ajuda foi imprescindível e por sempre se mostrar disponível para ajudar no que fosse preciso. Aos colegas João Belo e Rui Lucena, também eles inseridos no projecto SYPEC, cujos conselhos foram uma mais-valia ao longo de todo o trabalho. O trabalho em equipa foi fundamental para a resolução de problemas encontrados e para discussão de ideias.

Ao Professor José Fonseca pelo tempo disponibilizado para esclarecer as dúvidas encontradas no âmbito dos algoritmos de classificação.

Por fim, resta-me agradecer a todos aqueles que, de alguma forma, contribuíram para a realização desta dissertação e para terminar esta etapa da minha vida.

Aos meus pais, irmã e avós, cujo apoio foi fundamental a todos os níveis. Sem eles não teria sido possível.

À Maria, a minha namorada, por toda a paciência e todos conselhos prestados. Pelo apoio incondicional e por nunca me deixar desanimar.

A todos os meus amigos que sempre estiveram presentes e com quem sempre pude contar em todos os momentos, por vezes menos bons.

RESUMO

Actualmente, a postura de sentado é a postura mais adoptada pela sociedade em geral. O aumento das profissões que exigem longos períodos de tempo na postura de sentado e o estilo de vida sedentário são as principais causas. A adopção de posturas incorrectas na postura de sentado traz consequências a longo prazo, podendo desenvolver patologias ao nível da coluna.

É no sentido de minimizar os problemas de saúde que se enquadra o projecto SYPEC (*System for Posture Evaluation and Correction*), cujo objectivo é desenvolver um sistema de avaliação e correcção postural incorporado numa cadeira. O protótipo do sistema SYPEC consiste numa cadeira de escritório convencional cujo assento e costas possuem bolsas de ar. Cada bolsa de ar possui um circuito independente de ar contendo um transdutor de pressão, um compressor de ar e uma electroválvula. Através deste sistema é possível medir os valores de pressão no interior das bolsas.

O presente trabalho consistiu na detecção automática da postura de sentado, com base nas medidas de pressão. Foi necessário desenvolver algoritmos de classificação, baseado em dados previamente treinados. Foram estudadas 11 posturas diferentes e realizados testes a 30 sujeitos. Desenvolveram-se dois classificadores, um baseado em redes neuronais e outro no Teorema de *Bayes*, o *Naive Bayes*. Foram testados vários parâmetros para as redes neuronais, tendo obtido os melhores resultados com o treino *Resilient Backpropagation*, com uma camada interna e 15 neurónios, obtendo uma classificação média de 75% para os 30 sujeitos. Para o *Naive Bayes*, foram usados dois tipos de distribuições, a normal e a *kernel*, obtendo uma classificação média de 70%. Conseguiram-se resultados de 90% para alguns sujeitos.

Com recurso à aplicação móvel e à adaptação das redes neuronais feita em trabalhos a decorrer em paralelo, é possível identificar em tempo real a postura em que o utilizador se encontra.

Palavras-chave: Postura de sentado; Avaliação Postural; Classificação; Redes Neuronais; *Naive Bayes*.

ABSTRACT

Long periods of seated posture are required by actual jobs and sedentary lifestyle, making the seated posture the main posture adopted by nowadays society. The adoption of incorrect postures can bring long-term effects and may develop diseases on spinal column.

SYPEC (*System for Evaluation and Posture Correction*) was developed to minimize these health problems. The aim of this project is to develop a system incorporated in a chair capable of posture detection and correction. The prototype consists in a conventional office chair with 8 air bladders, each one connected to an independent air circuit containing a pressure transducer, an air compressor and an electrovalve. This system is capable of pressure measurement inside the bladder and it is able to change their conformation.

The main goal of this work is to achieve the automatic detection of a seated posture based on pressure measurements. In order to achieve this goal, we developed classification algorithms based on previously trained data carried out on 30 subjects and based on the identification of 11 different standard postures. Two different classifiers were developed for this work, one based on neural networks and another one based on Bayes' theorem, the Naive Bayes. For neural networks classifier we tested various parameters in order to reach the best overall classification. The best results were obtained using the training algorithm *Resilient Backpropagation* with an inside layer and 15 neurons, getting an average rating of 75% for 30 subjects. For Naive Bayes we used two kinds of distributions, normal and kernel, obtaining an average score of 70%.

This work led to the possibility of detecting the real-time posture of a user using a mobile application and a neural network classifier, which was done in collaboration with another work. This classifier achieved an overall classification of over 90% for 8 different postures.

Key-words: Seated Posture; Posture Detection; Classification; Neural Networks; Naive Bayes.

ÍNDICE

Capítulo 1	1
Introdução	1
1.1. Enquadramento Teórico	1
1.2. Objectivos	4
1.3. Estrutura da Tese.....	4
Capítulo 2	5
Revisão da Literatura	5
2.1. Estado da Arte	5
2.2. Anatomia da Coluna Vertebral.....	7
2.3. Posição de sentado	9
2.4. <i>Machine Learning</i>	10
Capítulo 3	13
Classificadores Estudados	13
3.1. Redes Neurais.....	13
3.1.1. Desempenho da rede neuronal	17
3.2. <i>Naive Bayes</i>	17
Capítulo 4	19
Metodologia	19
4.1. Protótipo SYPEC	19
4.2. Procedimento Experimental	21
4.2.1. Experiência A.....	23
4.2.1.1. <i>Neural Network Pattern Recognition ToolTM (nprtool)</i>	28
4.2.1.2. <i>NaiveBayes.fit</i>	32
4.2.2. Experiência B	33
Capítulo 5	35
Resultados e Discussão	35
5.1. Experiência A.....	36
5.1.1. Rede Neuronal.....	36
5.1.1.1. Testes Iniciais.....	36
5.1.1.2. Testes Finais.....	38
5.1.2. <i>Naive Bayes</i>	41
5.2. Experiência B	42

5.3. Análise Comparativa dos Classificadores	44
Capítulo 6.....	47
Conclusões e Trabalho Futuro.....	47
Bibliografia	49
Anexo I	52
Anexo II.....	53
Anexo III	54

ÍNDICE DE FIGURAS

Figura 1.1 - Diagrama representativo do sistema SYPEC [2].....	2
Figura 2.1 - Imagem representativa da coluna vertebral, adaptada de [16].	8
Figura 2.2 – Posição de referência, posição “Direito”.	9
Figura 3.1 - Esquema ilustrativo do funcionamento de uma rede neuronal.....	13
Figura 3.2 - Exemplo de uma rede neuronal com apenas um neurónio [37].....	14
Figura 3.3 - Função transferência: sigmóide (a), linear (b) e <i>tansig</i> (c) [37].	15
Figura 4.1 - Primeiro protótipo do sistema SYPEC.	19
Figura 4.2 - Distribuição das bolsas de ar no assento da cadeira. 1-BL; 2-BR; 3-FL; 4-FR [2].	20
Figura 4.3 - Distribuição das bolsas de ar nas costas da cadeira. 5-UL; 6-UR; 7-LL; 8-LR [2].	21
Figura 4.4 - Mapas de pressão do assento da cadeira sem tratamento efectuado (<i>BL - Back Left; BR - Back Right; FL - Front Left; FR - Front Right</i>).....	22
Figura 4.5 - Mapas de pressão das costas da cadeira sem tratamento efectuado (<i>UL - Up Left; UR - Up Right; DL - Down Left; DR - Down Right</i>).....	23
Figura 4.6 - Representação gráfica das posições referidas na Tabela 4.3.	26
Figura 4.7 - Programa para tratamento de dados.....	27
Figura 4.8 - Gráfico dos 4 sensores do assento da cadeira.....	27
Figura 4.9 - Janela representativa do treino da rede neuronal com duas camadas de 15 neurónios com a função de treino <i>trainrp</i>	29
Figura 4.10 - Gráfico do desempenho da rede neuronal.	31
Figura 4.11 - Histograma dos erros da rede neuronal.	31
Figura 4.12 - Gráfico da regressão linear da rede neuronal.	32
Figura 5.1 - Esquema representativo dos procedimentos efectuados para obtenção da classificação postural.....	35
Figura 5.2 - Matriz de confusão da rede neuronal com treino <i>trainrp</i> com uma camada e 15 neurónios.	41
Figura 5.3 - Diagrama de caixa de bigodes das posições 1, 2, 3 e 4.	42
Figura 5.4 - Diagrama de caixa de bigodes das posições 5, 6 e 7.	43
Figura 5.5 - Diagrama de caixa de bigodes das posições 8, 9, 10 e 11.	43

ÍNDICE DE TABELAS

Tabela 4.1 - Resumo das características principais da cadeira. Adaptado de [2].....	21
Tabela 4.2 - Dados relativos aos sujeitos das experiências A e B.....	22
Tabela 4.3 - Posturas a adoptar no estudo e respectiva descrição.	25
Tabela 5.1 - Classificação do erro do teste da postura estática com diferentes camadas e diferentes neurónios para os treinos <i>trainlm</i> , <i>trainscg</i> e <i>trainrp</i>	36
Tabela 5.2 - Classificação do erro do teste da postura dinâmica com diferentes camadas e diferentes neurónios para os treinos <i>trainlm</i> , <i>trainscg</i> e <i>trainrp</i>	37
Tabela 5.3 - Classificação do teste da postura dinâmica e estática com diferentes camadas e diferentes neurónios para o treino <i>trainrp</i> com o método <i>leave-one-out</i>	38
Tabela 5.4 - Classificação do erro do teste da postura estática com o método <i>leave-one-out</i>	39
Tabela 5.5 - Classificação do erro do teste da postura dinâmica com o método <i>leave-one-out</i> ..	39
Tabela 5.6 - Classificação resultante da junção do teste da postura dinâmica e da estática, com o método <i>leave-one-out</i>	40
Tabela 5.7 - Classificação obtida com o método <i>leave-one-out</i> para o classificador <i>Naive Bayes</i> , com a distribuição normal e <i>kernel</i> para o teste da postura dinâmica, estática e a junção dos dois.	41
Tabela 5.8 - Classificação em tempo real para cada posição. Adaptada de [47].....	44

ABREVIATURAS/SIGLAS

ADC	<i>Analog-to-Digital Converter</i>
BL	<i>Back Left</i>
BR	<i>Back Right</i>
FEDER	<i>Fundo Europeu de Desenvolvimento Regional</i>
FL	<i>Front Left</i>
FR	<i>Front Right</i>
FSRs	<i>Force Sensitive Resistors</i>
LL	<i>Low Left</i>
LR	<i>Low Right</i>
MSE	<i>Mean Square Error</i>
SYPEC	<i>System for Posture Evaluation and Correction</i>
Trainlm	<i>Levenberg-Marquardt</i>
Trainrp	<i>Resilient Backpropagation</i>
Trainscg	<i>Scaled Conjugate Gradient</i>
UL	<i>Up Left</i>
UR	<i>Up Right</i>

CAPÍTULO 1

INTRODUÇÃO

1.1. ENQUADRAMENTO TEÓRICO

Nos dias que correm, continua a aumentar a necessidade de adoptar uma posição sentada para realizar as funções exigidas no local de trabalho. Desta forma, as cadeiras devem ser desenvolvidas para o utilizador trabalhar de forma saudável, confortável e em segurança. Para tal, o *design* da cadeira incluindo o ajuste da mesma, o suporte lombar e a folga na zona posterior do joelho, são algumas das características a ter em conta na elaboração da mesma.

Para obter uma cadeira que consiga englobar estas características é necessário ter em consideração o local de trabalho, as actividades e posturas a que cada utilizador está sujeito, considerando que uma boa postura de sentado no local de trabalho deve minimizar a carga na coluna vertebral e na musculatura envolvente [1].

Para minimizar os problemas de saúde e as consequências sócio-económicas relacionadas com uma postura incorrecta de sentado, a NGNS – Ingenious Solutions, Lda. em parceria com a Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, com o apoio do Fundo Europeu de Desenvolvimento Regional (FEDER), através do Quadro de Referência Estratégico Nacional (QREN) e do Programa Operacional Regional de Lisboa (PORLisboa), propuseram o desenvolvimento e produção de um sistema de avaliação e correcção postural (SYPEC – *System for Posture Evaluation and Correction*) que, aplicado numa cadeira ou incorporado na mesma, permite a avaliação e correcção automática da postura do utilizador.

De uma forma geral, o projecto SYPEC compreende três princípios: mapeamento das pressões do assento e das costas da cadeira, classificação postural e correcção postural, como se pode observar no esquema da Figura 1.1. Cada uma destas etapas corresponde à construção de um novo protótipo.



Figura 1.1 - Diagrama representativo do sistema SYPEC [2].

O desenvolvimento do sistema SYPEC envolve a construção de três protótipos. Segundo o que foi estabelecido com as entidades financiadoras do projecto, o primeiro protótipo consistiu em encontrar a cadeira e os sensores de pressão adequados e implementar a electrónica necessária para recolher a informação dos sensores. Inicialmente estava previsto incorporar na cadeira almofadas de hidrogel acopladas aos sensores de pressão, mas optou-se por utilizar bolsas de ar que permitiram tornar mais simples o sistema e reduzir os custos associados. Definiu-se o número de bolsas e as suas localizações, com base em literatura [2].

O segundo protótipo consiste em desenvolver uma interface que possa ser instalada num computador ou num dispositivo móvel por forma a conseguir alertar o utilizador, com recurso a meios visuais ou auditivos, no caso de este se encontrar numa posição incorrecta. Ainda neste protótipo estava previsto desenvolver um dispositivo sem fios que permitisse a comunicação entre o computador e a cadeira, no entanto este foi desenvolvido ainda no primeiro protótipo por Belo (2012) [3]. Os testes que serão executados com este protótipo irão permitir aferir com exactidão se a posição considerada correcta pelo sistema corresponde, na realidade, a uma posição correcta.

Para o terceiro protótipo, estava definido incluir no sistema de actuação a possibilidade de alterar a rigidez e conformação das superfícies da cadeira, de forma a corrigir automaticamente a postura do utilizador. No entanto, devido a alterações que ocorreram na estrutura do projecto estas modificações foram implementadas no primeiro protótipo. Com o utilizador sentado correctamente, a cadeira adoptará a forma mais ergonómica através de um ajuste personalizado.

Até à data existe uma grande lacuna no mercado de sistemas de correcção postural automáticas e inteligentes. Existem apenas cadeiras ergonómicas, sem interacção com o utilizador, e construídas para a média dos utilizadores (ou seja, sem apoios lombares e cervicais com a altura e relevo adequados para cada utilizador).

Para atingir o objectivo final da construção do sistema SYPEC e do seu lançamento no mercado, várias metas parciais terão de ser atingidas, nomeadamente:

- Determinação, com base nos conhecimentos mais actualizados de Biomecânica, do modelo de postura correcto;
- Determinação, com base num protótipo de alta densidade de sensores e medida numa população alargada e por períodos alargados de tempo, das pressões exercidas na posição de sentado;
- Desenvolvimento de uma interface com o utilizador para indução voluntária da postura, através da utilização de esquemas e alarmes de posturas correctas que o utilizador deve adoptar.
- Integração dos resultados, especificação e construção do modelo de pré-produção (construção de uma pequena série de equipamentos); testes e estudos em indivíduos sem patologias associadas;
- Preparação de toda a produção/documentação técnica e comercial para a produção em massa do sistema;
- Certificação CE do sistema pelo Instituto de Soldadura e Qualidade;
- Certificação do sistema por entidades credenciadas, nomeadamente pela Faculdade de Motricidade Humana (Laboratório de Biomecânica);
- Identificação das áreas de interesse no mercado e colocação faseada do produto no mercado;
- Divulgação dos resultados por: registo de patente; comunicação em eventos científico-tecnológicos apropriados, publicação em revistas científico-tecnológicas apropriados.

O protótipo existente possui uma aplicação, desenvolvida em ambiente *MATLAB*®, que permite a sua ligação a um computador através de um cabo USB, a aquisição e o registo temporal dos mapas de pressão e a monitorização dos centros de pressão do assento e das costas da cadeira [2]. Em paralelo com a presente dissertação foi desenvolvido um sistema de comunicação sem

fos, via *Bluetooth* e uma interface para um dispositivo móvel (*tablet*), sendo possível controlar a cadeira à distância através deste mesmo dispositivo [3].

1.2. OBJECTIVOS

O estudo das posturas adoptadas, assim como, a classificação automática das mesmas constitui o principal objectivo desta dissertação, que será uma importante ferramenta para o objectivo final deste projecto, o de corrigir a postura, de uma posição incorrecta para uma que se considera, com base trabalhos anteriores, uma postura correcta.

Para tal, é necessário efectuar alguns procedimentos, os quais fazem parte dos objectivos desta dissertação:

- Identificação das diferentes posturas a estudar;
- Identificação da postura correcta de sentado;
- Elaborar um protocolo para aquisição dos dados;
- Recolha e análise dos mapas de pressão;
- Construção dos algoritmos de classificação da postura com base nos mapas de pressão;
- Teste da fiabilidade dos classificadores.

1.3. ESTRUTURA DA TESE

A presente dissertação está estruturada em seis capítulos, que serão descritos de seguida.

No capítulo 1 é feita uma breve introdução ao tema em estudo, nomeadamente à problemática da postura de sentado, são referidos os objectivos a alcançar e a motivação que levou à realização do projecto SYPEC.

O capítulo 2 consiste na revisão da literatura do tema, abordando os trabalhos desenvolvidos na área de detecção e avaliação postural, assim como os métodos de classificação utilizados.

O terceiro capítulo diz respeito aos classificadores estudados para a detecção automática das diferentes posturas em estudo. São abordados conceitos gerais acerca dos mesmos, assim como a sua implementação em termos de funcionamento.

No capítulo 4 são descritos os métodos utilizados para a realização do trabalho. São enunciadas as posturas adoptadas e as ferramentas utilizadas para efectuar a recolha dos dados.

No Capítulo 5 são apresentados e discutidos os resultados obtidos.

No Capítulo 6 são referidas as conclusões retiradas do trabalho efectuado, bem como apresentadas algumas sugestões para trabalho futuro.

CAPÍTULO 2

REVISÃO DA LITERATURA

No século XIX, a postura de sentado num assento horizontal com as costas direitas é descrita como sendo a postura correcta a adoptar. No século XX, há uma maior consciência das consequências da posição de sentado, provavelmente devido ao aumento das profissões exigirem longos períodos de tempo na posição de sentado e devido ao aumento de raquialgias da população em geral [1].

A sociedade actual prefere adoptar uma posição sentada, uma vez que requer um menor esforço por parte dos músculos do que em pé e devido ao facto das profissões continuarem a exigir, cada vez mais, um maior tempo nessa posição. Contudo, adoptar uma postura de sentado durante um longo período de tempo pode trazer consequências a longo prazo. Por esta razão, é necessário que haja movimento, sendo por isso importante não passar longos períodos de tempo sentado e adoptar uma postura o mais correcta possível que permita desempenhar as funções necessárias com o maior conforto possível [4, 5].

2.1. ESTADO DA ARTE

A adopção de posturas incorrectas na posição de sentado assim como os longos períodos de tempo em que estas são mantidas, provocam o desenvolvimento de patologias ao nível da coluna. São muitos os grupos de investigação que se têm debruçado sobre este tema de forma a perceber qual a posição ideal a adoptar na posição de sentado e como consequência, nos últimos

anos têm sido publicados diversos trabalhos relacionados com a detecção e avaliação postural na posição de sentado, utilizando cadeiras com transdutores de pressão que permitem obter mapas de pressão, cujos dados são posteriormente tratados em função do estudo que se pretende.

Slivovsky et al. (2000) [6], Tan et al. (2001) [7], Zhu et al. (2003) [8] e Mota e Picard (2003) [9] utilizaram uma cadeira equipada com duas matrizes *Body Pressure Measurement System* (BPMS) fabricadas pela *Tekscan*® de forma a obter os mapas de pressão. Cada uma dessas matrizes foi colocada no assento e nas costas da cadeira.

Tan et al. (2001) sugeriram um algoritmo baseado no método de Análise de Componentes Principais (PCA), de forma a reduzir a quantidade de dados obtidos, e usaram um classificador de vizinhança, *Nearest Neighbour*. Este sistema foi desenvolvido para testar 14 posições estáticas e foram efectuados testes a 30 sujeitos. Foi obtida uma eficácia de 96% para sujeitos familiares, isto é, pessoas que já tinham realizado os testes anteriormente e cujos dados tinham sido recolhidos. Para sujeitos que realizaram o teste pela primeira vez obtiveram uma eficácia de 79% [7].

Zhu et al. (2003) construíram um algoritmo baseado no método de *Sliced Inverse Regression* e *Linear Discriminant Analysis* que consiste em procurar vectores no espaço de dados que melhor distinguem as diferentes classes. Estes testes foram realizados em 50 pessoas para 10 posturas diferentes [8].

Mota e Picard (2003) desenvolveram um sistema que reconhece a postura relativa a um determinado estado emocional/de interesse das crianças enquanto realizam uma determinada tarefa. As posturas são extraídas usando uma mistura de 4 gaussianas e uma rede neural com 3 camadas. Foram estudadas 9 posturas em 10 crianças, 5 das quais foram usadas para treino e as outras 5 para teste. A eficácia obtida foi de 87,6% quando testada com novos sujeitos [9].

Em 2007, Mutlu et al. desenvolveram um algoritmo que utilizava as amostras recolhidas por Tan et al. [7] e estudaram diferentes distribuições de sensores por forma a determinar qual o local mais indicado para os colocar numa cadeira *Herman Miller Aeron*. Foi obtida uma classificação com uma eficácia de 78% usando 19 transdutores de pressão (FSRs) e 87% com 31 FSRs num conjunto de treino para classificar 10 posturas estáticas [10].

Wong e Wong (2007) [11] colocaram acelerómetros e marcadores ao longo da coluna dos sujeitos para detectar as diferentes posturas com base nas alterações das curvaturas da coluna, sem recorrer a sensores embutidos na cadeira.

Zheng e Morrell (2010) definem as tuberosidades isquiais, a região da coxa perto do joelho, a região lombar da coluna vertebral e as omoplatas, como sendo os locais mais relevantes para a colocação dos transdutores de pressão para classificação postural. Para tal, construíram um

sistema semelhante ao de Tan e Mutlu, que utiliza 7 sensores de pressão (FSRs) introduzidos numa cadeira de escritório e 6 actuadores vibrotácteis com o propósito de corrigir a postura do utilizador e para *feedback*. Caso o utilizador se encontre numa postura incorrecta, um ou mais actuadores vibram, no sentido de induzir o utilizador a adoptar a postura pretendida. O sistema desenvolvido obteve uma eficácia de 86.4% para 10 posições estáticas e 93.8% para 4 posições estáticas [5].

Lucena (2012), construiu uma cadeira capaz de medir a pressão exercida pelo utilizador e alterar a sua conformação e rigidez por forma a detectar e corrigir a postura. Esta é a cadeira utilizada para o presente estudo e as suas características, assim como testes realizados, serão descritos no Capítulo 4 [2].

2.2. ANATOMIA DA COLUNA VERTEBRAL

A coluna vertebral possui quatro partes funcionais: a coluna cervical, a coluna torácica, a coluna lombar e o sacro (Figura 2.1). A pélvis encontra-se ligada ao sacro e este fixo à região lombar, qualquer rotação da pélvis influencia a forma da coluna lombar [12]. Qualquer condição que produza uma alteração numa das curvaturas da coluna irá provocar alterações compensatórias nas restantes curvaturas por forma a manter o equilíbrio e a conservar a energia muscular [13]. Além de ser o local do centro de massa do corpo, a pélvis serve como ponto de fixação para os 20 grupos principais de músculos, que têm como função iniciar o movimento e contrabalançar as forças gravitacionais na parte superior e inferior do corpo [13].

Passar de uma posição de pé para sentado, provoca uma rotação posterior da pélvis fazendo com que a lordose lombar diminua, e chegue mesmo a assumir a forma de cifose, resultando num aumento da pressão dos discos intervertebrais [14] tal como num aumento da actividade muscular enquanto o corpo tenta restaurar o equilíbrio [13]. Isto resulta em fadiga e desconforto para a pessoa que tem de realizar este tipo de movimentos ao longo de um dia de trabalho [15].

Além disso, a lordose lombar varia de pessoa para pessoa, logo a quantidade de carga que a pélvis tem de suportar para manter o alinhamento individual da coluna também varia. Se não houver suporte suficiente fornecido pela cadeira, a pélvis irá realizar um movimento de rotação para dentro e achatam a coluna lombar. Se o suporte for em demasia pode provocar uma lordose lombar exagerada, que será compensada por um aumento da cifose torácica e da lordose cervical para manter o equilíbrio. Assim sendo, poderá provocar desconforto e raquialgias uma vez que há um aumento da actividade muscular e da pressão dos discos intervertebrais [13, 14].




Figura 2.1 - Imagem representativa da coluna vertebral, adaptada de [16].

As raquialgias surgem de diversas fontes, entre elas, posturas adoptadas durante longos períodos de tempo [17]. A contribuição dos músculos das costas para o aumento de raquialgias é de extrema importância, uma vez que estes aplicam pressão nos discos intervertebrais. Variar esta pressão nos discos é benéfico uma vez que os discos intervertebrais obtêm nutrientes através das alterações de pressão. Se a pressão for mantida durante um longo período de tempo os discos intervertebrais, que se deformam quando sujeitos a carga, vão aumentando gradualmente a sua convexidade que ao longo do tempo pode causar ruptura ou produzir pressão nos nervos da coluna vertebral. Assim sendo, é necessário ir alternando a postura e não estar longos períodos de tempo na mesma posição, de forma a possibilitar a recuperação dos discos intervertebrais sem afectar as actividades de trabalho [1].

A pressão na coluna vertebral não resulta apenas dos músculos envolventes, mas também da gravidade a que estamos sujeitos e da conformação da coluna. Quando o tronco está na posição vertical, particularmente quando o sujeito se encontra em pé, o peso da parte superior do corpo produz um momento muito pequeno para deslocar o tronco, permitindo que os músculos de apoio do tronco relaxem e ajam apenas para contrabalançar a oscilação. Isto oferece uma menor carga para os discos intervertebrais, para qualquer postura vertical. Mantendo uma flexão anterior do tronco há um aumento da contribuição dos músculos do tronco por forma a suportar o mesmo [18].

2.3. POSIÇÃO DE SENTADO

Define-se como postura convencional de sentado manter as costas direitas, com apoio lombar, e flexão das coxas a 90° [1]. Esta postura corresponde à posição de referência ou posição “Direito”, que se encontra ilustrada na Figura 2.2.



Figura 2.2 – Posição de referência, posição “Direito”.

A postura “neutra” da coluna vertebral é a aquela em que os músculos estão mais relaxados. As forças musculares geradas à medida que se afasta desta posição têm a função de fazer a coluna retornar à sua postura cuja carga imposta é menor.

Quando adoptada uma postura de sentado, considerada normal, não se está consciente se essa é, ou não, uma postura correcta, sendo que muitas vezes não se usa o apoio das costas da cadeira. Sem o apoio das costas da cadeira, uma postura direita não consegue ser mantida durante muito tempo e há uma tendência para flectir o tronco para a frente. Isto pode provocar um aumento da curvatura normal da coluna (hipercifose torácica) [19]. Nesta posição, há um maior esforço por parte dos ligamentos que suportam a coluna, que podem deformar e provocar problemas ao nível da coluna e das articulações. O apoio lombar permite resolver de certa forma estes problemas pois estabiliza as posturas, reduz as cargas musculares e as cargas dos discos intervertebrais ajudando a promover o conforto [20].

Trabalhos sedentários, isto é, que não permitem ao indivíduo movimentar-se com frequência, são tão prejudiciais quanto os ditos trabalhos “pesados”. Posturas incorrectas causam alterações degenerativas crónicas na coluna cervical, torácica, lombar e sacro-lombar [21–24]. Profissões que exigem posturas estáticas durante longos períodos de tempo são propícias a desenvolver problemas ao nível da mobilidade dos discos intervertebrais [25].

A razão pela qual é tão importante que haja mobilidade ao longo do dia, deve-se ao facto da coluna vertebral, a partir dos 10 anos, perder a habilidade de captar nutrientes e de eliminar

resíduos. A partir desta idade, este processo é efectuado através de trocas passivas realizadas na osmose que é induzida pelo movimento [26–28]. É por estas razões que não se deve manter a mesma posição durante longos períodos de tempo, mas sim ir alternando entre posições, principalmente a posição de direito, inclinado para a frente e recostado para trás, que são ao menos prejudiciais à saúde e que sujeitam a coluna a uma menor pressão [20].

2.4. MACHINE LEARNING

A detecção automática da postura de sentado envolve algoritmos de classificação, de reconhecimento de padrões, baseado em dados previamente treinados. Para tal, são necessárias máquinas que se adaptem ao ambiente e aprendam através do exemplo, sendo este processo de aprendizagem denominado por *Machine Learning* [29]. Aplicações como os motores de busca de internet, reconhecimento facial, de voz, de escrita, entre outros, são exemplos de *Machine Learning*.

Reconhecimento de padrões é um termo que abrange os estados de investigação desde a formulação de problemas e recolha de dados até à sua discriminação, classificação e interpretação. Quando se pretende recorrer ao reconhecimento de padrões para um determinado tipo de estudo, há que ter em conta alguns passos [29]:

1. Formulação do problema: definem-se os objectivos da investigação e são estruturadas as restantes etapas – Adopção de posturas incorrectas no local de trabalho;
2. Recolha de dados: são efectuados os procedimentos necessários para obter as medições respeitantes às variáveis em estudo – Elaboração do protocolo de aquisição;
3. Análise preliminar dos dados: são efectuados cálculos estatísticos e gerados gráficos de forma a ter uma visão de como estruturar o classificador – Tratamento dos dados, normalização e processamento para construção nos classificadores;
4. Selecção ou extracção de atributos: são seleccionadas variáveis a partir do conjunto de dados que se consideram apropriadas para a tarefa a realizar. Estas novas variáveis podem ser obtidas através de uma transformação linear ou não linear do conjunto de dados iniciais – Selecção da zona de interesse, ou zona estável a estudar;
5. Classificação de padrões ou *clustering* sem supervisão: pode ser uma forma de pré-processamento dos dados para uma classificação supervisionada;
6. Aplicar procedimentos de discriminação ou regressão conforme for apropriado. O classificador é construído usando um conjunto de treino de padrões exemplo – Rede Neuronal e *Naive Bayes*;

7. Acesso aos resultados: pode envolver a aplicação do classificador treinado a um conjunto independente de teste de padrões rotulados;

8. Interpretação dos resultados.

A extração de atributos tem como função modificar, através de transformações lineares ou não lineares, o conjunto de variáveis originais para um conjunto menor. Uma técnica muito usada para este efeito é a Análise de Componentes Principais (PCA) que permite reduzir a dimensão dos dados obtidos. Essa redução pode ser feita identificando as variáveis que não contribuem para a classificação e removê-las do conjunto. Com um conjunto de treino bem definido pode-se otimizar o critério de ajuste e validar o desempenho do classificador [29].

Um classificador automático é um programa capaz de analisar um conjunto de atributos que descrevem algo e classificá-lo dentro de um conjunto finito de possibilidades, às quais se dá o nome de classes. Existem dois tipos de classificação, supervisionada e sem supervisão. Na classificação supervisionada, tem-se um conjunto de dados de amostras associados a diferentes classes. No caso da classificação sem supervisão, os dados não estão associados a classes e procura-se encontrar grupos no conjunto dos dados e atributos que distingam um grupo do outro [29].

Existem diversos tipos de classificadores, entre eles podem-se nomear alguns:

Classificadores baseados em exemplos: Quando se pretende estimar a classe de um novo exemplo, pode-se procurar o exemplo mais parecido e atribuir a esse exemplo a sua classe. Este tipo de classificadores denomina-se por *nearest neighbor* [30, 31]. Este tipo de classificadores não envolve muito processamento e baseia-se na distância (ex. distância euclidiana) entre grupos [32].

Classificadores baseados em árvores de decisão: Árvores de decisão são diagramas que possibilitam enumerar todas as possibilidades lógicas de uma sequência de decisões e ocorrências incorrectas. Numa árvore de decisão cada nó representa uma decisão entre um número limitado de opções e cada folha uma classificação, atribuindo uma classe [33].

Naive Bayes: Baseado no Teorema de *Bayes*, atribui a classe mais provável a um determinado exemplo descrito pelo seu vector característico. A aprendizagem deste tipo de classificadores pode ser simplificada assumindo que os atributos são independentes dada uma determinada classe, não existindo relação entre eles, isto é, $P(X|C) = \prod_{i=1}^n P(X_i|C)$, onde $X = (X_1, \dots, X_n)$ é o vector do atributo e C a classe [34].

Support Vector Machine: Baseado na ideia de maximizar a margem, ou seja, maximizar a distância mínima do hiperplano de separação do exemplo mais próximo. Estão entre os mais robustos e cujo sucesso de classificação é maior [35].

Classificadores baseados em algoritmos genéticos: Algoritmos genéticos são baseados na teoria de Darwin sobre a evolução das espécies, que diz que os mais adaptados sobrevivem enquanto os menos adaptados são eliminados. A ideia base é gerar aleatoriamente uma “população” de exemplos onde os mais aptos se reproduzem e os menos aptos são eliminados [32].

Redes neuronais: O funcionamento de uma rede neuronal assemelha-se ao funcionamento do cérebro humano pois o conhecimento é adquirido a partir do ambiente envolvente através de processos de aprendizagem e as ligações entre os neurónios, conhecidas como pesos sinápticos, são usados para guardar conhecimento.

Uma rede neuronal é, tipicamente, formada por neurónios, que estão divididos em três tipos de camadas. Neurónios da camada de entrada que têm como função introduzirem os dados na rede, neurónios das camadas internas e os neurónios da camada de saída que geram o resultado. A cada neurónio da camada de saída é normal atribuir uma classe e a função da rede é conseguir, na presença de um determinado exemplo, associar a saída correspondente à classe a que esse exemplo pertence [32, 36].

Os exemplos inseridos no conjunto de treino são introduzidos na rede e é calculada a diferença entre a saída obtida e a desejada. Esse valor de erro é propagado para a camada de entrada (método de retropropagação) e é efectuado um ajuste dos valores dos pesos e das *biases* dos neurónios das várias camadas por forma a diminuir o erro obtido. Este é o método de aprendizagem mais conhecido, no entanto existem métodos alternativos [32, 36].

CAPÍTULO 3

CLASSIFICADORES ESTUDADOS

3.1. REDES NEURONAIS

A função da rede é determinada em grande parte pelas ligações (pesos) entre elementos e pode ser treinada para desempenhar uma determinada função através do ajuste dos valores dessas ligações entre elementos. Este ajuste é feito através da comparação entre a saída e o objectivo até que a saída corresponda ao objectivo. O esquema da Figura 3.1 permite observar o funcionamento de uma rede neuronal [31, 32].

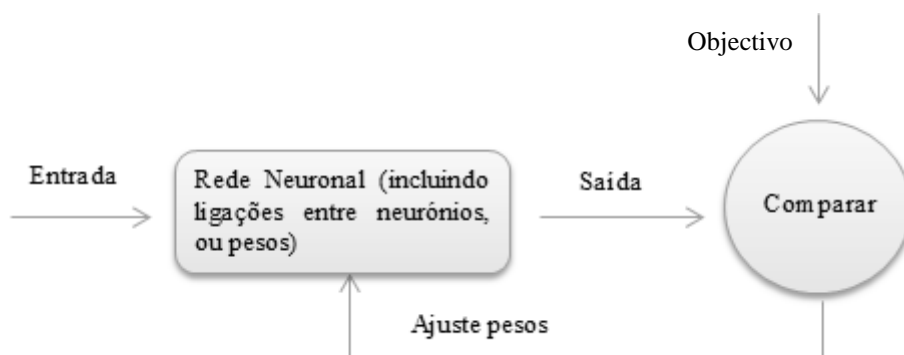


Figura 3.1 - Esquema ilustrativo do funcionamento de uma rede neuronal.

Para a construção de uma rede neuronal devem-se seguir os seguintes sete passos [37]:

1. Recolha de dados;
2. Criar a rede neuronal;
3. Configurar a rede;
4. Inicializar os pesos e as *biases*;
5. Treinar a rede neuronal;
6. Validar a rede neuronal;
7. Testar a rede neuronal.

Após criada a rede neuronal é necessário configurá-la e treiná-la. A configuração da rede consiste em adaptar a mesma de forma a ser compatível com o problema em estudo. O passo seguinte corresponde ao ajuste dos pesos e das *biases*, onde a *bias* tem a função de aumentar o grau de liberdade da função de transferência e por consequência a capacidade de aproximação da rede. Permite ainda que um neurónio apresente sempre uma saída não nula, ainda que as suas entradas sejam nulas. Estes parâmetros devem ser ajustados para que se possa otimizar o desempenho da rede. O processo de ajuste destes parâmetros está incluído no treino da rede neuronal e, para tal, é necessário fornecer à mesma um conjunto de dados que sirva de exemplo [37].

De forma a perceber o funcionamento geral de uma rede neuronal simples, a Figura 3.2 ilustra uma rede constituída por apenas uma entrada e um neurónio.




Figura 3.2 - Exemplo de uma rede neuronal com apenas um neurónio [37].

Podem-se observar três operações distintas. Primeiro a entrada p (pode-se tratar de um vector) é multiplicada pelo peso correspondente w formando o produto wp . De seguida, a esse produto é somada uma constante, a *bias* b , constituindo assim, a entrada da rede n . Por fim, essa entrada passa por uma função transferência f , que gera uma saída a . Os parâmetros w e b , correspondentes ao peso e *biases*, respectivamente, podem ser ajustados consoante o que se pretenda estudar, como referido anteriormente [37].

O valor de excitação E de cada neurónio calcula-se de acordo com a Eq.1,

$$\mathbf{E} = \sum_i \mathbf{w}_i \mathbf{p}_i + \mathbf{b} \quad \text{Eq. 1}$$

É efectuada a soma das entradas multiplicadas pelos respectivos pesos, w_p , somando também o valor da *bias*. Para determinar a resposta aplica-se este valor à função transferência do sistema. Uma das funções de transferência mais comuns é a função sigmóide representada na Figura 3.3-a) e 3.3-c), a função **logsig** (Figura 3.3-a)) é dada pela Eq.2. Enquanto o valor de entrada \mathbf{E} pode variar entre $[-\infty, +\infty]$, o valor da sua saída \mathbf{S} está limitado entre 0 e 1 [32, 37].

$$\mathbf{S} = \frac{1}{e^{-\mathbf{E}} + 1} \quad \text{Eq. 2}$$

Existem outras funções transferência para além desta, como por exemplo a função transferência linear (Figura 3.3-b)) e a função transferência **tansig** (Figura 3.3-c)), que se usam consoante o problema em estudo.




Figura 3.3 - Função transferência: sigmóide (a), linear (b) e **tansig** (c) [37].

As funções transferência sigmóide são muito usadas para reconhecimento de padrões, entre elas a função **logsig** que é muito utilizada em redes com várias camadas cujas saídas estão compreendidas no intervalo $[0,1]$.

Várias camadas de neurónios com funções transferência não lineares permitem que a rede reconheça relações não lineares entre os vectores de entrada e de saída. A camada que gera a saída da rede chama-se camada de saída e o número de neurónios presente nesta camada é determinado pelo número de elementos no vector objectivo. Todas as outras camadas são camadas internas e a função transferência aplicada, por omissão, é a **tansig**. A estas camadas vão ser atribuídos pesos tal como é feito às entradas da rede.

Existem dois tipos de vectores de entrada, vectores concorrentes (que ocorrem em simultâneo), sem nenhuma sequência temporal, e os que ocorrem sequencialmente no tempo. O caso em estudo diz respeito aos primeiros e nestes a ordem não é importante.

A configuração da rede consiste em analisar os dados de entrada e do objectivo e definir os tamanhos das entradas e das saídas. Esta configuração é feita, geralmente, através da função de treino.

Existem dois tipos diferentes de treino: treino por incremento e treino por *batch*. No primeiro, os pesos e as *biases* da rede são actualizados sempre que uma entrada é adicionada à rede. No treino por *batch* (treino utilizado neste estudo), os pesos e as *biases* só são actualizados depois de todas as entradas terem sido adicionadas na rede. Este tipo de treino é significativamente mais rápido e produz erros menores que o treino por incremento [37].

No que diz respeito aos algoritmos usados no treino das redes neuronais, o algoritmo de retropropagação é o mais usado em redes neuronais com várias camadas [38] e consiste em ajustar os pesos da rede neuronal da camada de saída até à camada de entrada, tendo por base o método do gradiente descendente. Este método consiste em ajustar os pesos de tal forma que o erro quadrático médio da rede seja minimizado, isto é, procura a direcção onde se verifica uma maior diminuição do erro, onde este diminui mais rapidamente. Uma iteração deste algoritmo pode ser escrita da seguinte forma, $\mathbf{x}_{k+1} = \mathbf{x}_k - a_k \mathbf{g}_k$, onde x_k é o vector de pesos e de *biases* actuais, g_k é o gradiente actual e a_k é a taxa de aprendizagem. Esta equação é iterada até a rede convergir.

Ao treinar uma rede neuronal com várias camadas é aconselhável dividir os dados em 3 subconjuntos, nomeadamente, conjunto de treino, conjunto de validação e conjunto de teste. Quanto ao primeiro, é usado para calcular o gradiente e actualizar os pesos e as *biases* da rede. O conjunto de validação permite ter uma percepção do erro, isto é, o erro de validação tende a decrescer durante a fase inicial do treino, tal como o erro do conjunto de treino. Se ocorrer *overfitting* (sobreajustamento), o erro do conjunto de validação aumenta e os pesos e as *biases* da rede são guardados com o menor valor do erro do conjunto de validação. O erro do conjunto de teste é usado para avaliar o desempenho do classificador [37].

O erro associado ao *overfitting* pode ser pequeno mas ao adicionar novos dados à rede aumenta a percentagem desse mesmo erro. Isto deve-se ao facto da rede memorizar os exemplos do treino mas não aprender a generalizar para novas situações, caso em que se adiciona informação à rede. Para reduzir a probabilidade de ocorrência de *overfitting* a paragem do treino deve ser configurada tendo em conta alguns parâmetros, entre eles, a magnitude do gradiente e o número de verificações de validação que são usados para terminar o treino. O gradiente irá tornar-se muito pequeno à medida que o seu desempenho atinge um valor mínimo, que pode ser definido pelo utilizador, caso a magnitude do gradiente seja menor que esse valor o treino pára. O número de verificações de validação representa o número de iterações sucessivas sem o desempenho diminuir. Se este número for igual ao valor estabelecido, o treino pára. Aumentar o número de neurónios nas camadas internas aumenta a eficácia da rede mas requer mais cálculo computacional e é possível que cause *overfitting* [37].

3.1.1. Desempenho da rede neuronal

Pode-se estimar a qualidade de um classificador através do seu erro, conforme representado na Eq.3:

$$\text{Percentagem de erro} = \frac{\text{Número de erros}}{\text{Número de casos testados}} \quad \text{Eq. 3}$$

O *cross-validation* é, provavelmente, o método mais simples e mais usado para avaliar a capacidade de generalização de um modelo a partir de um conjunto de dados, estimando assim o erro associado [39]. Este método consiste em dividir o conjunto de dados em n subconjuntos e a percentagem de erro é calculada fazendo a média do erro associado a cada subconjunto [40].

O *leave-one-out* é um caso extremo do *cross-validation*, onde n é igual ao número de amostras em estudo e permite estimar a percentagem de erro através do uso de $n-1$ amostras do conjunto de treino, testando as restantes amostras. Isto repete-se para todos os n subconjuntos de tamanho $n-1$. Uma das desvantagens do *leave-one-out* é o facto de requerer elevado cálculo computacional [29, 39].

A matriz de confusão é uma ferramenta que permite avaliar o desempenho da rede neuronal uma vez que fornece o número de classificações reais em função das classificações previstas. Cada coluna representa a Classe Prevista (1-11) e cada linha a Classe Real (1-11) [41].

Outra forma de avaliar o desempenho de um classificador é através da curva ROC (*Receiver Operating Characteristic curve*). Esta serve para caracterizar o desempenho de um classificador que envolva duas classes de forma a seleccionar o *threshold* apropriado para a decisão do classificador. A curva ROC consiste num gráfico que possui no eixo vertical os verdadeiros positivos e no eixo horizontal os falsos positivos, ou seja, fornece a probabilidade de detecção verdadeira contra a probabilidade de detecções falsas, respectivamente. A área sob a curva ROC é uma medida que permite obter o desempenho do classificador [29].

3.2. NAIVE BAYES

O Teorema de *Bayes* considera que a probabilidade de um evento X dado um evento C depende da relação entre os eventos X e C e da probabilidade de ocorrência de cada um deles. Isto é determinado de acordo com a Eq.4.

$$P(X|C) = \frac{P(C|X)P(X)}{P(C)} \quad \text{Eq. 4}$$

Onde $P(X|C)$ designa a probabilidade da hipótese X sabendo a classe a que pertence um determinado conjunto de treino. Designa-se como *posterior probability*, pois reflecte a probabilidade da hipótese X depois de observar a classe a que pertence o conjunto de treino. $P(C)$ e $P(X)$ são as probabilidades iniciais da classe a que pertence o conjunto de treino C e do atributo X . Por fim, a probabilidade $P(C|X)$ fornece a probabilidade de observar a classe C em função de um determinado atributo X .

Uma dificuldade na aplicação de métodos *bayseanos* consiste no facto de exigirem conhecimento prévio de probabilidades. Quando estas probabilidades não são conhecidas têm de ser estimadas com base em dados e suposições acerca da forma de distribuição.

O *Naive Bayes* tem por base o Teorema de *Bayes*. A aprendizagem deste tipo de classificadores pode ser simplificada assumindo que os atributos são independentes, dada uma determinada classe, não existindo relação entre eles, isto é, $P(X|C) = \prod_{i=1}^n P(X_i|C)$, onde $X = (X_1, \dots, X_n)$ é o vector do atributo e C a classe. Atribuindo a classe mais provável a um determinado exemplo descrito pelo seu vector característico [34]. Trata-se, portanto, de um classificador supervisionado, tal como as redes neuronais.

Este método permite classificar os dados em dois passos:

Treino – a partir do conjunto de treino são estimados os parâmetros da distribuição de probabilidade, assumindo que os atributos são condicionalmente independentes dada a classe;

Previsão – Para todas as amostras que ainda não foram testadas, este método calcula a probabilidade dessa amostra pertencer a cada classe. De seguida é atribuída a classe mais provável.

As distribuições de probabilidade relacionam, matematicamente, os valores de um determinado atributo com a probabilidade de ocorrência desses mesmos valores na amostra. Os atributos podem ser discretos ou contínuos, isto é, no caso de serem discretos apenas podem assumir certos valores (1, 2, 3,...), no caso de serem contínuos podem assumir qualquer valor de uma escala contínua [29].

O facto de se assumir que os atributos são condicionalmente independentes dada a classe simplifica o treino, uma vez que se consegue estimar a densidade de cada classe individualmente [43]. Apesar de este algoritmo não considerar dependências que possam existir, daí o nome *naive* (ingénuo), trabalhos anteriores, como por exemplo para classificação de textos, diagnóstico médico e sistemas de gestão, demonstram que na prática este método funciona bem e que consegue competir com algoritmos mais sofisticados [44].

CAPÍTULO 4

METODOLOGIA

4.1.PROTÓTIPO SYPEC

O protótipo do sistema SYPEC, desenvolvido por Lucena (2012) [2] consiste numa cadeira de escritório convencional cujo assento e costas possuem bolsas de ar. Cada bolsa de ar possui um circuito independente de ar contendo um transdutor de pressão, um compressor de ar e uma electroválvula. O transdutor de pressão possibilita medir os valores de pressão do ar no interior da bolsa, sendo possível a elaboração dos mapas de pressão da cadeira, que se encontra ilustrada na Figura 4.1.



Figura 4.1 - Primeiro protótipo do sistema SYPEC.

Para controlar o ar no interior de cada bolsa é usado um minicompressor e uma electroválvula que permitem injectar ou retirar ar das bolsas alterando, desta forma, a rigidez e a conformação do assento e das costas da cadeira. As bolsas, o circuito de ar e o transdutor de pressão formam o sistema de medição de pressão e de actuação [2].

Os transdutores de pressão utilizados para medir a pressão de ar no interior das bolsas são transdutores de pressão, relativa à pressão atmosférica, do tipo piezoresistivo. Uma vez que no assento a pressão exercida é maior, foram usados transdutores de 15 psi cuja sensibilidade é de 15mV/psi. Nas costas da cadeira foram usados transdutores de 5 psi com uma sensibilidade de 21mV/psi.

As zonas cuja relevância para a identificação postural é maior são as tuberosidades isquiais, a região da coxa perto do joelho, a região lombar da coluna vertebral e as omoplatas. Com base nisto, colocaram-se as bolsas de ar de forma que cada bolsa ocupasse apenas uma região de interesse [5].

No assento foram colocadas 4 bolsas de ar, tal como mostra a Figura 4.2. As bolsas *Back Left* (BL) e *Back Right* (BR) abrangem as tuberosidades isquiais esquerda e direita, respectivamente. As almofadas *Front Left* (FL) e *Front Right* (FR) abrangem a região da coxa perto do joelho esquerda e direita, respectivamente.



Figura 4.2 - Distribuição das bolsas de ar no assento da cadeira. 1-BL; 2-BR; 3-FL; 4-FR [2].

Nas costas da cadeira, tal como no assento, foram colocadas 4 bolsas de ar, distribuídas de acordo com a Figura 4.3. As bolsas *Up Left* (UL) e *Up Right* (UR) estão dispostas de forma a abranger a omoplata esquerda e direita, respectivamente, enquanto as almofadas *Low Left* (LL) e *Low Right* (LR) preenchem a região lombar, esquerda e direita, respectivamente.



Figura 4.3 - Distribuição das bolsas de ar nas costas da cadeira. 5-UL; 6-UR; 7-LL; 8-LR [2].

No que diz respeito às principais características da cadeira, estas podem ser observadas na Tabela 4.1. A interface de comunicação através do protocolo *Bluetooth* foi desenvolvida por Belo (2012) [3], que possibilitou controlar a cadeira remotamente.

Tabela 4.1 - Resumo das características principais da cadeira. Adaptado de [2].

Características	Descrição
Alimentação	100 – 240 VAC, 47 – 63Hz, 35W
Interface de comunicação	USB 2.0 <i>Full Duplex e Bluetooth</i>
Resolução ADC	10 bit
Frequência de amostragem	2,82 – 57,4 Hz
Envio de dados	Manual/Automático
Outros	Protecção contra excesso de pressão (regulável)

4.2. PROCEDIMENTO EXPERIMENTAL

A parte experimental deste trabalho consistiu na realização de duas experiências distintas. A experiência **A** consistiu na elaboração de um protocolo de aquisição para recolha dos mapas de pressão das bolsas para as 11 posições em estudo e na construção dos algoritmos de classificação, nomeadamente as redes neuronais e o *Naive Bayes*. As posições em estudo estão definidas na Tabela 4.3 e na Figura 4.6 e foram escolhidas com base em trabalhos anteriores [5, 45, 46].

A experiência **B** serviu para testar o classificador em tempo real usando uma aplicação móvel desenvolvida por Belo (2012) [3]. Esta experiência decorreu em paralelo com outro trabalho, no âmbito de uma bolsa de investigação realizada por Martins [47], cujo objectivo da presente dissertação foi apenas participar na avaliação do classificador e identificar eventuais limitações do mesmo.

Para a realização de ambas as experiências foram utilizados 30 sujeitos, cujos dados são apresentados na Tabela 4.2. Dos 30 sujeitos utilizados na experiência **B**, metade fizeram parte

da experiência **A**, sendo que a outra metade permitiu testar o classificador em tempo real para sujeitos não familiarizados e que não se encontravam nos dados utilizados para treinar o classificador. A escolha do número de sujeitos foi baseada em trabalhos anteriores [5, 46].

Tabela 4.2 - Dados relativos aos sujeitos das experiências A e B.

Experiência	Nº de sujeitos (M/F) *	Idade (anos) **	Peso (Kg) **	Altura (cm) **
A	30 (15/15)	20.9±2.4	67.8±13.3	172.0±8.1
B	30 (15/15)	20.5±2.0	68.9±12.4	172.3±8.7

* - M (Masculino) e F (Feminino)

** - Valores da média e do desvio padrão.

O protocolo utilizado para realizar este trabalho, foi elaborado com base em testes iniciais efectuados a 37 sujeitos que permitiram identificar falhas ao nível da calibração efectuada e da própria cadeira.

Nestes testes iniciais a calibração das bolsas foi feita manualmente duas a duas, de modo a que ambas as bolsas de um dado par tivessem valores semelhantes de pressão podendo, assim, iniciar a recolha dos dados. No decorrer dos testes verificou-se que se perdia bastante tempo a calibrar as bolsas manualmente e que existia alguma discrepância nos valores de cada par de bolsas, uma vez que estas eram insufladas manualmente. A par disto, observou-se também que as bolsas superiores das costas da cadeira nem sempre eram utilizadas devido ao facto dos utilizadores possuírem alturas diferentes e se sentarem de forma diferente.

A Figura 4.4 e a Figura 4.5 representam, respectivamente, os gráficos dos mapas de pressão do assento e das costas da cadeira sem tratamento efectuado, para um teste simples de aquisição de dados.

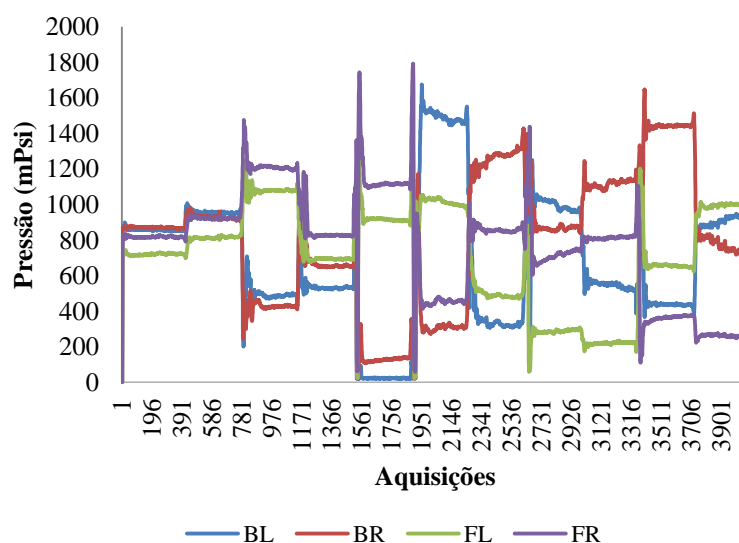


Figura 4.4 - Mapas de pressão do assento da cadeira sem tratamento efectuado (BL - Back Left; BR - Back Right; FL - Front Left; FR - Front Right)

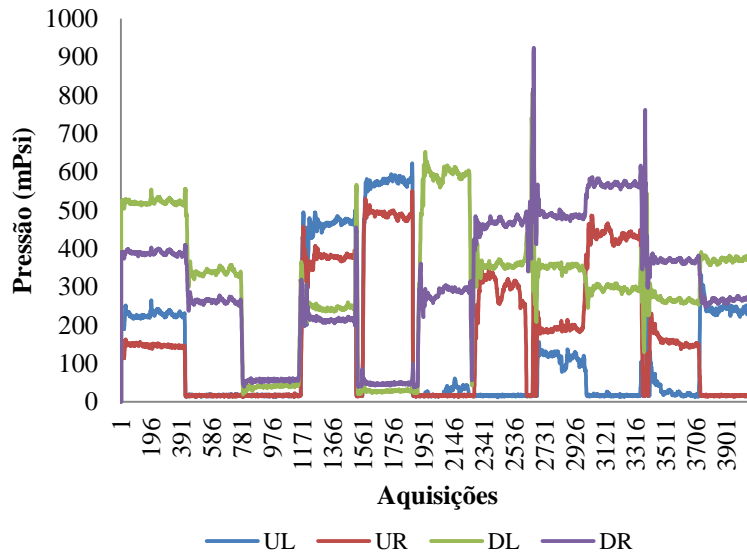


Figura 4.5 - Mapas de pressão das costas da cadeira sem tratamento efectuado (UL - Up Left; UR - Up Right; DL - Down Left; DR - Down Right)

Através da análise de gráficos semelhantes a estes foi possível verificar que os mapas de pressão variavam muito de sujeito para sujeito. Por vezes, diferentes testes ao mesmo sujeito também não apresentavam resultados semelhantes nem se conseguiam identificar padrões o que levou mais uma vez à conclusão de que o erro poderia estar na calibração e na concepção do protótipo.

Ainda para os testes iniciais foram desenvolvidos dois classificadores, um com base em redes neuronais e outro baseado no Teorema de *Bayes*, o *Naive Bayes*, onde foram testados diversos parâmetros por forma a tentar obter a melhor classificação possível. Estes classificadores serão explicados em pormenor ainda neste capítulo. Esta parte do trabalho foi realizada em conjunto com o bolseiro Leonardo Martins, tendo o presente trabalho incidido nestes dois classificadores e o do Leonardo noutros dois, o *Nearest Neighbour* e *Support Vector Machine*.

Identificadas as limitações ao nível da recolha dos dados, recorreu-se à aplicação móvel desenvolvida por Belo (2012) [3] que permitiu fazer uma nova aquisição de dados utilizando uma calibração automática com tempos pré-definidos que irão ser explicados mais à frente. Esta calibração automática permite uma maior rapidez e diminui o erro associado a uma calibração manual, sendo que assim, para todos os sujeitos os tempos de insuflação das bolsas é o mesmo.

4.2.1. Experiência A

Antes de dar início à aquisição dos dados, é efectuada a calibração da cadeira e dos sensores. Para tal, enchem-se as bolsas duas a duas com o mesmo tempo de enchimento, quatro segundos, com excepção das bolsas superiores das costas da cadeira cujo tempo de insuflação são cinco segundos, uma vez que são as que apresentam menores valores de pressão devido à própria

conformação da cadeira e por serem as menos usadas. Estes tempos foram escolhidos pois permitem obter resultados possíveis de interpretar não causando desconforto para o sujeito que está a realizar o teste.

A altura do assento da cadeira é ajustada até à altura poplíteia (distância vertical desde o chão até à zona posterior do joelho), de forma que o sujeito fique na posição “Direito” (Face posterior do tronco encostada às costas da cadeira, com as coxas e os joelhos a 90°) e os pés totalmente assentes no chão [5].

O protocolo consiste em dois testes distintos, um para a postura estática onde os sujeitos repetiram as posições e se levantavam da cadeira entre repetições e diferentes posições e outro que consistiu em adquirir os dados da postura dinâmica, isto é, mudar de posição sem se levantar da cadeira adquirindo, também, os dados relativos às transições. Apenas foi estudada a zona estável.

Teste da postura Dinâmica: Depois de calibrar, cada sujeito deve sentar-se na cadeira, sem objectos nos bolsos, adoptando cada uma das 11 posturas definidas na Tabela 4.3, sem se levantar da cadeira e permanecendo em cada posição durante 20 segundos. Este processo é feito com o auxílio de uma apresentação em *PowerPoint* que explica como os sujeitos se devem sentar ao mesmo tempo que mostra a imagem da posição em questão.

Teste da postura Estática: Tal como para o caso da Postura Dinâmica, também para a Postura Estática é necessário efectuar a calibração da cadeira e dos sensores. Cada sujeito deve sentar-se na cadeira, sem qualquer objecto nos bolsos e adoptar cada uma das 11 posturas definidas na Tabela 4.3, permanecendo em cada posição durante 20 segundos, começando sempre na posição “Direito”. Após os 20 segundos o sujeito deve levantar-se da cadeira e voltar à mesma posição, num total de duas repetições. É pedido ao sujeito que caminhe para um local pré-determinado quando este se levanta, voltando a sentar-se novamente na cadeira quando indicado.

Assim como para a Postura Dinâmica, a realização dos ensaios é feita com o auxílio de uma apresentação em *PowerPoint*.

Tabela 4.3 - Posturas a adoptar no estudo e respectiva descrição.

Ordem da Postura	Postura	Descrição
1	Direito	Face posterior do tronco encostada às costas da cadeira, com as coxas e os joelhos a 90°
2	Relaxado	Mantendo o apoio da região lombar fazer a anteriorização da cintura escapular
3	Inclinado para a frente	Mantendo a face posterior do tronco na vertical fazer a flexão do tronco sem apoio lombar
4	Inclinado para trás	Extensão do tronco
5	Inclinado para trás, apenas com apoio dorsal	Sentar com apoio da região do sacro mantendo o apoio da região dorsal
6	Inclinado para a direita	Flexão lateral do tronco para a direita cerca de 20°, com o antebraço direito apoiado na coxa
7	Inclinado para a esquerda	Flexão lateral do tronco para a esquerda cerca de 20°, com o antebraço esquerdo apoiado na coxa
8	Perna esquerda cruzada	Face externa da tibiotársica esquerda apoiada no joelho direito, sentado na posição de repouso, flexão da coxa e joelho esquerdo de forma a permitir o apoio face externa da tibiotársica esquerda apoiada no joelho direito
9	Perna esquerda cruzada, e inclinado para a direita	Face externa da tibiotársica esquerda apoiada no joelho direito fazendo a flexão lateral do tronco para a direita cerca de 20°, com o antebraço direito apoiado na coxa
10	Perna direita cruzada	Face externa da tibiotársica direita apoiada no joelho esquerdo sentado na posição de repouso, flexão da coxa e joelho direito de forma a permitir o apoio face externa da tibiotársica direita apoiada no joelho esquerdo
11	Perna direita cruzada, e inclinado para a esquerda	Face externa da tibiotársica direita apoiada no joelho esquerdo fazendo a flexão lateral do tronco para a esquerda cerca de 20°, com o antebraço esquerdo apoiado na coxa




Figura 4.6 - Representação gráfica das posições referidas na Tabela 4.3.

Após adquiridos os dados dos 30 sujeitos, analisou-se cada um de forma a escolher os valores que correspondiam à parte estável dos dados. Para tal, desenvolveu-se uma aplicação em *MATLAB*® que permite visualizar os gráficos correspondentes a cada bolsa e fazer a respectiva normalização. A Figura 4.7 ilustra a aplicação mencionada.

O tempo durante o qual o sujeito se manteve na posição indicada foi de 20 segundos, uma vez que se verificou ser suficiente para adquirir dados possíveis de interpretar não sendo demasiado exaustivo para a pessoa que está a realizar o teste. Desses 20 segundos, optou-se por escolher aproximadamente 13 segundos estáveis que correspondem a 240 aquisições. A série temporal de 240 aquisições (por pessoa e por posição) foi repartida em 6 conjuntos (mapas de pressão) de 40 aquisições, por forma a conseguir obter uma classificação de, aproximadamente, 2 em 2 segundos, de acordo com o projectado. Isto é, a cada 2 segundos é feita a média das 40

aquisições. Isto permite obter 720 mapas para cada postura (30 sujeitos \times 4 repetições \times 6 mapas de pressão) fazendo um total de 7920 mapas de pressão para as 11 posturas.

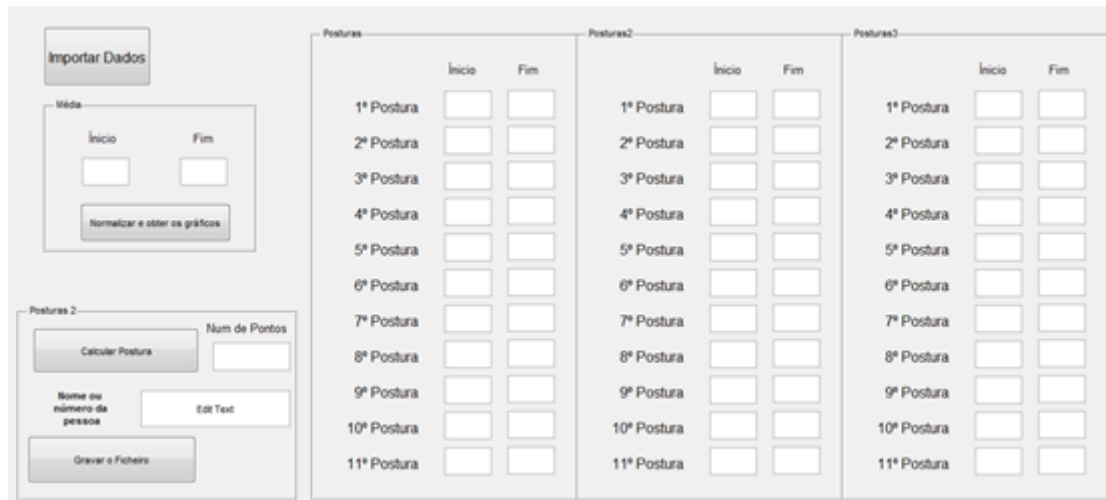


Figura 4.7 - Programa para tratamento de dados.

A Figura 4.8 representa o gráfico que se obtém através do programa referido anteriormente, respeitante ao assento da cadeira, com os 4 sensores representados com a zona estável em destaque. A zona estável corresponde às 240 aquisições, tendo analisado cada postura individualmente de forma a obter, dos 20 segundos, os 13 segundos com menores oscilações para cada sujeito.




Figura 4.8 - Gráfico dos 4 sensores do assento da cadeira.

A avaliação postural é feita subtraindo ao valor médio dos mapas de pressão correspondentes a um determinado período (que contém informação relativa a uma dada posição), o valor de pressão da posição de referência.

A normalização dos dados é feita através da média das aquisições obtidas de forma a obter as diferenças de pressão relativas em relação à primeira posição, a posição de referência “Direito”, a qual foi definida como sendo uma postura correcta de sentado. Os 7920 mapas de pressão foram normalizados por forma a obter uma entrada num intervalo [-1,1] para introduzir estes dados no classificador desenvolvido.

De forma a conseguir classificar as posturas em estudo recorreu-se então, a dois métodos distintos de classificação, as Redes Neurais e o *Naive Bayes*, utilizados em trabalhos anteriores e cujos resultados se mostraram bastante satisfatórios [9, 10, 34, 35].

Para cada um deles a plataforma escolhida, para desenvolver estes classificadores, foi o *MATLAB*®. No caso da rede neuronal utilizou-se uma *toolbox* do *MATLAB*®, *Neural Network Pattern Recognition Tool*TM (*nprtool*) que permitiu construir uma rede capaz de desempenhar as funções pretendidas. No caso do *Naive Bayes*, recorreu-se à função *NaiveBayes.fit*.

4.2.1.1. *Neural Network Pattern Recognition Tool*TM (*nprtool*)

Tal como explicado anteriormente, para poder construir a rede neuronal foi necessário efectuar algum processamento aos dados de entrada por forma a transformá-los num formato que a rede pudesse interpretar e treinar de forma mais eficiente. Como as funções transferência saturam para valores muito elevados, foi necessário recorrer à função *mapminmax* para normalizar os dados de entrada em valores compreendidos entre [-1,1] [37]. Como se trata de um classificador supervisionado é necessário atribuir classes às posições. Para tal, criou-se um vector binário onde a posição do bit cujo valor é 1 identifica a classe a que pertence a posição em questão.

Depois de efectuado o processamento prévio dos dados, passou-se então à construção da rede. Foi necessário alterar alguns parâmetros, como as camadas e os neurónios da rede, as funções de treino e os conjuntos utilizados para treino, validação e teste.

A Figura 4.9 representa a janela gerada ao treinar uma rede neuronal com duas camadas internas com 15 neurónios cada e cuja função transferência de ambas é a função *tansig*. Também a camada de saída, com 11 neurónios, correspondentes às 11 posturas em estudo, tem como função transferência a *tansig*.

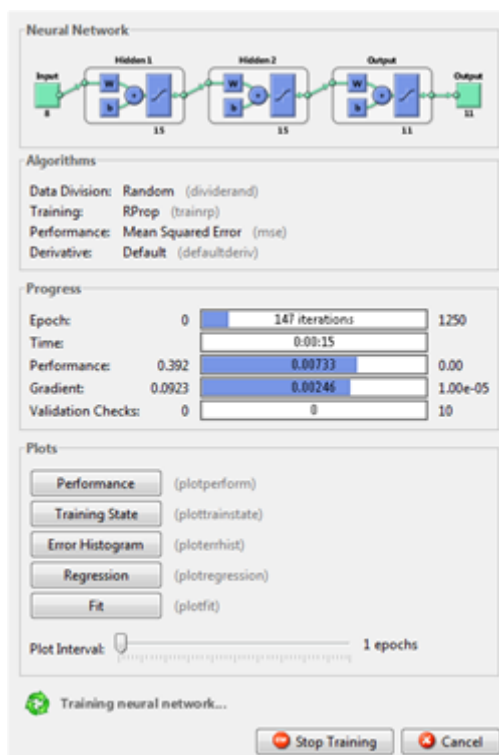


Figura 4.9 - Janela representativa do treino da rede neuronal com duas camadas de 15 neurónios com a função de treino *trainrp*.

Como se pode observar, esta janela possui informações distintas, uma correspondente à rede propriamente dita, outra relativa aos algoritmos envolvidos no treino, uma que permite visualizar, em forma de barra, a evolução da rede e uma última que possibilita gerar gráficos que dizem respeito ao desempenho da rede.

Relativamente à área respeitante aos algoritmos é fornecida informação acerca dos dados, do treino e do desempenho da rede.

Os dados são divididos em 3 subconjuntos que diz respeito à função *dividerand*.

Para o treino de redes neuronais com uma dimensão significativa e com o objectivo de reconhecer padrões, como é o caso, foram usados algoritmos de treino, representados pelas funções *trainlm*, *trainscg* e *trainrp* da *toolbox* do MATLAB®, *Neural Network Pattern Recognition Tool™ (nprtool)*, uma vez que se tratam de boas opções para este tipo de estudo [37]. No entanto, o *trainlm* (*Levenberg-Marquardt*), que tem por base o método do gradiente descendente normal, explicado no Capítulo 3, não possui um desempenho tão bom em reconhecimento de padrões e requer mais memória que o *trainrp* e o *trainscg*. Estes dois não requerem muita memória e são mais rápidos que o algoritmo de gradiente descendente, que possui algumas desvantagens inerentes [37].

O *trainscg*, é feito com base no método dos gradientes conjugados (*Scaled Conjugate Gradient*). Assim como no método do gradiente descendente procura a direcção que minimiza o

erro através de um melhor ajuste dos pesos, sendo que este método usa informação da derivada de segunda ordem e informação das iterações anteriores, na medida em que utiliza o conjugado da direcção usada na iteração anterior [48, 49].

Se o gradiente tiver uma magnitude muito baixa a alteração que provoca no ajuste dos pesos e das *biases* será muito reduzida podendo não melhorar o treino como era pretendido.

Para colmatar estas desvantagens, o treino *Resilient Backpropagation* tem como função eliminar os efeitos da magnitude das derivadas parciais [50]. Apenas o sinal da derivada pode determinar a direcção de actualização do peso, a magnitude da derivada não tem qualquer efeito nessa actualização. Após as actualizações dos pesos serem adaptadas é seguida uma regra simples, isto é, se a derivada for positiva (caso que corresponde ao aumento do erro), o peso diminui através da sua actualização, se a derivada for negativa, a actualização do peso consiste em aumentar o mesmo. Se a derivada for zero o valor da actualização do peso permanece o mesmo [51–53].

O desempenho da rede é determinado em função do erro quadrático médio (*mse*) entre as saídas a e os objectivos da rede t e é dado pela Eq.5 [37]:

$$F = mse = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad \text{Eq. 5}$$

As saídas da rede são comparadas com os objectivos e o erro é calculado como sendo a diferença entre o objectivo e a saída da rede. A função destes algoritmos é minimizar a média da soma destes erros através do ajuste dos pesos e das *biases* [37, 53].

Na Figura 4.9 é possível observar, também, a evolução da rede através das barras de desempenho, do número de iterações, da magnitude do gradiente e do número de verificações de validação. Estes parâmetros determinam a paragem do treino da rede na medida em que, se o número de iterações for igual a 1250, ou a magnitude do gradiente for igual a $1 \times e^{-5}$ ou ainda, se o número de verificações de validação for igual a 10 a rede pára.

O gráfico da evolução do desempenho permite observar as curvas respeitantes aos três subconjuntos. Se a curva de teste aumentar significativamente em relação à curva de validação significa que pode ter ocorrido *overfitting*.

Através da Figura 4.10 é possível observar o gráfico do desempenho da rede que permite analisar o valor da função do desempenho em função do número de iterações.




Figura 4.10 - Gráfico do desempenho da rede neuronal.

O gráfico do estado do treino permite visualizar a evolução das outras variáveis de treino como a magnitude do gradiente e o número de verificações de validação.

A Figura 4.11 representa o histograma da distribuição dos erros da rede neuronal.




Figura 4.11 - Histograma dos erros da rede neuronal.

O gráfico da regressão, representado na Figura 4.12, exibe a regressão entre as saídas e os objectivos da rede. Se o treino tiver sido perfeito então as saídas e os objectivos da rede são idênticos, no entanto, na prática esta relação não se verifica. Esta opção gera três gráficos correspondentes ao desempenho do treino, da validação e do teste. A linha a tracejado representa o resultado perfeito, ou seja, os resultados são os mesmos dos objectivos. A linha a cor representa a melhor regressão linear entre as saídas e os objectivos e o valor R indica a relação entre estes. Logo, se R for próximo de zero significa que não há relação linear entre eles.

Os círculos permitem observar que alguns pontos possuem um pior ajuste, uma vez que para haver um ajuste quase perfeito os círculos do eixo das saídas deveriam estar todos próximos do zero e no eixo do objectivo próximo do 1. Não se verificando, significa que houve saídas diferentes do objectivo.

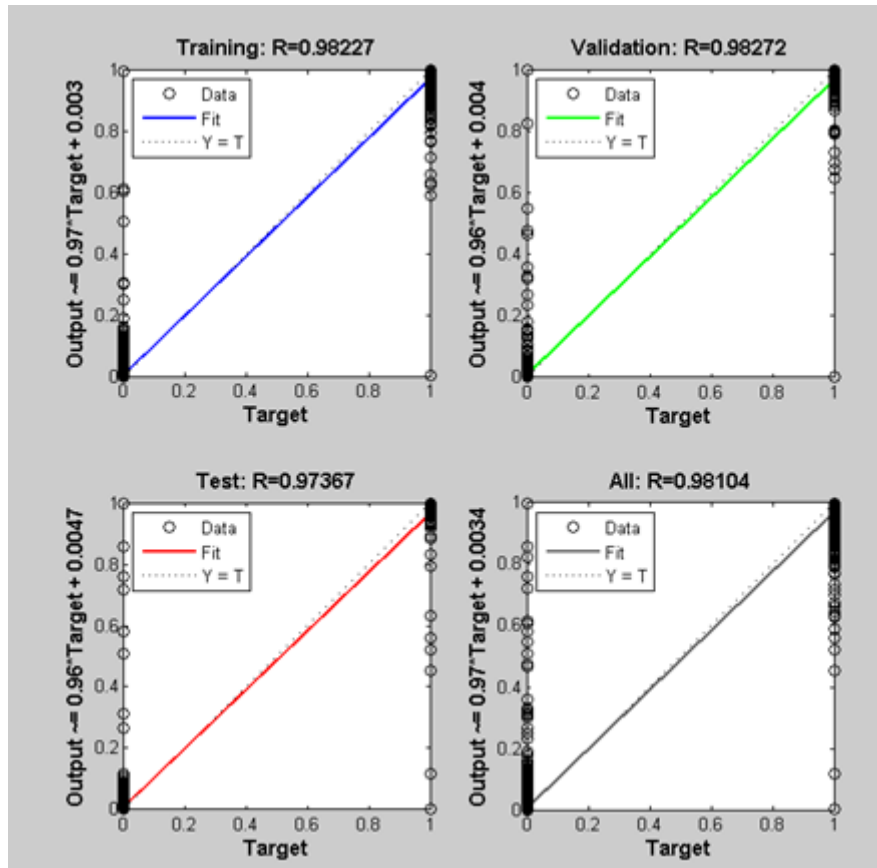


Figura 4.12 - Gráfico da regressão linear da rede neuronal.

Estes dados permitiram observar a evolução dos diferentes treinos realizados e ter uma maior sensibilidade acerca dos resultados obtidos.

4.2.1.2. *NaiveBayes.fit*

Como se trata de um classificador supervisionado, tal como no caso da rede neuronal, foi necessário atribuir classes às posições escolhidas. Para tal criou-se um vector, de 1 a 11, por forma a identificar as classes e a postura com o respectivo número. Feito isto, foi possível recorrer à função *NaiveBayes.fit* que permitiu obter um conjunto de treino (*nb*) com as respectivas classes associadas. Esta função permite escolher o tipo de distribuição que se pretende, isto é, a probabilidade que cada atributo tem de pertencer a uma determinada classe.

Geralmente o *Naive Bayes* assume que os atributos possuem uma distribuição normal ou discreta, que nem sempre se verifica ser a melhor aproximação. Ao usar uma distribuição normal, ou Gaussiana, o *Naive Bayes* estima uma distribuição normal para cada classe através do cálculo da média e da variância do conjunto de treino dessa classe. Esta distribuição é simétrica e possui uma forma semelhante à de um sino [43].

Foi usado outro tipo de distribuição, a distribuição *kernel*, uma vez que é mais adequada para atributos com uma distribuição contínua e permite reduzir a percentagem de erro em relação à distribuição normal. Este tipo de distribuição não possui uma forma estruturada, dependendo de todos os pontos do conjunto de dados para estimar a probabilidade [44].

Ao utilizar uma distribuição deste tipo para cada atributo, o algoritmo *Naive Bayes* permite estimar a densidade *kernel* para cada classe com base no conjunto de treino dessa classe. Este tipo de distribuição requer mais tempo de computação e mais memória em relação à distribuição normal [39, 43].

Depois de obtido o conjunto de treino (*nb*), é necessário testar o classificador através da função *posterior* que permite obter a classe mais provável de um determinado vector de teste. Como outputs, o *post* fornece a probabilidade que cada atributo tem de pertencer a cada classe e o *cpre* atribui a classe mais provável. Através destas funções é possível determinar o erro do classificador.

4.2.2. Experiência B

A experiência **B** consistiu em exibir uma apresentação aos sujeitos onde se fazia variar entre 8 posturas com uma ordem específica (1 - 3 - 4 - 1 - 6 - 7 - 1 - 8 - 10 - 1 - 5 - 1), cuja duração foi de 15 segundos para cada posição. Esta experiência foi realizada em conjunto com Martins [47], responsável pela decisão das posturas usadas nesta experiência, com a finalidade de evitar problemas ao nível da classificação. Antes de dar início à classificação, foram recolhidos os mapas de pressão referentes à posição “Direito” durante 12 segundos por forma a obter uma referência para cada sujeito. De seguida as posturas foram classificadas a cada 2 segundos, usando a média de todos os valores adquiridos durante esse tempo.

A classificação foi feita com base numa adaptação das redes desenvolvidas ao longo deste trabalho. Esta adaptação foi realizada por Belo (2012) [3] e por Martins [47].

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

Tal como referido no capítulo anterior, o primeiro passo realizado foi a recolha dos dados, seguida do seu tratamento para posteriormente treinar os classificadores e por fim, variar diversos parâmetros por forma a obter a melhor classificação possível. O esquema da Figura 5.1 representa de uma forma geral os procedimentos efectuados.

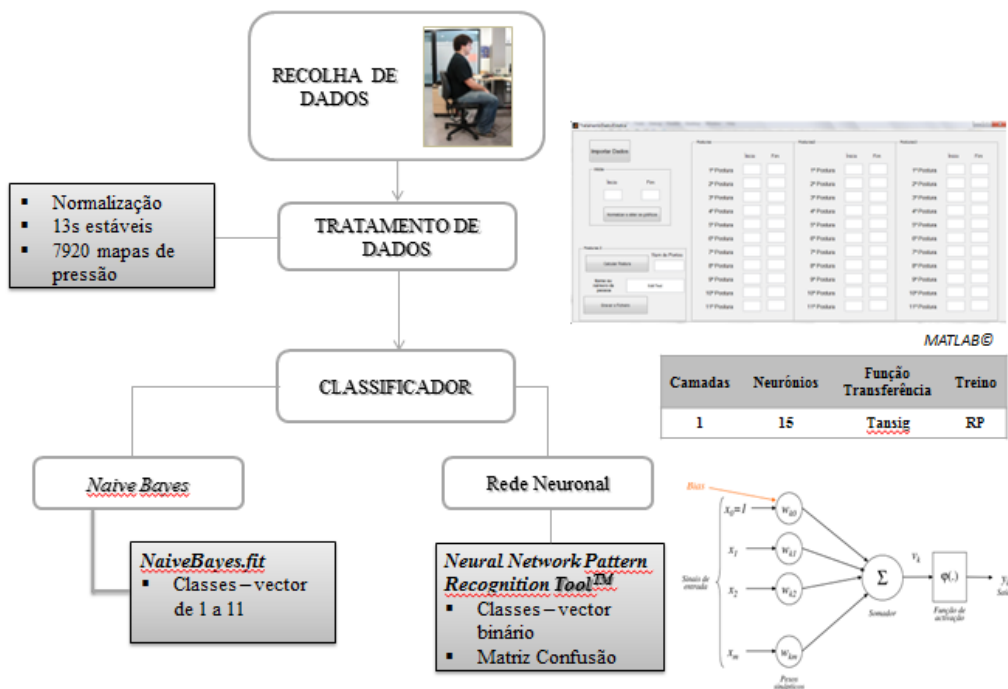


Figura 5.1 - Esquema representativo dos procedimentos efectuados para obtenção da classificação postural.

De seguida irão ser apresentados e discutidos os resultados obtidos com os diferentes testes realizados para ambos os classificadores. Por fim, será feita uma análise comparativa dos dois por forma a perceber qual apresenta melhores resultados.

5.1. EXPERIÊNCIA A

5.1.1. Rede Neuronal

5.1.1.1. Testes Iniciais

Tal como explicado no capítulo anterior, depois de recolhidos e tratados é necessário introduzir os dados na rede para poder treiná-la.

Inicialmente a divisão dos conjuntos para construir a rede neuronal foi feita através dos parâmetros intrínsecos da própria *toolbox* onde é possível escolher a percentagem de treino, validação e teste, cujos valores foram 70%, 15% e 15%, respectivamente.

Depois foi necessário utilizar diferentes treinos, utilizar várias camadas e vários neurónios por forma a compreender como se comportaria a rede com diferentes parâmetros. Para tal, foram utilizados três treinos diferentes e foram construídas redes até três camadas internas e até 35 neurónios. Como foi referido anteriormente, ao aumentar muito o número de neurónios pode resultar em *overfitting*, desta forma não foram testados mais de 35.

Foram desenvolvidas redes para o teste da postura estática e para o teste da postura dinâmica em separado, tendo obtido os resultados que se encontram na Tabela 5.1 e na Tabela 5.2, respectivamente. Para cada rede foram realizados 10 treinos.

Tabela 5.1 - Classificação do erro do teste da postura estática com diferentes camadas e diferentes neurónios para os treinos *trainlm*, *trainscg* e *trainrp*.

Teste Postura Estática						
NºCamadas- NºNeurónios	Treino					
	<i>trainlm</i> (%)	Média (%)	<i>trainscg</i> (%)	Média (%)	<i>trainrp</i> (%)	Média (%)
1-15	12,3	25,9	17,2	29,2	17,1	18,3
1-20	10,2	17,3	11,7	19,0	14,3	16,4
1-30	6,4	14,4	11,5	19,1	11,0	12,0
2-20	2,8	15,3	7,7	28,4	8,8	11,4
2-25	2,9	15,7	6,2	28,1	11,8	15,8
2-30	2,1	8,1	6,0	19,6	6,6	8,0
3-20	2,7	19,6	5,0	13,0	7,9	9,4
3-25	1,0	12,2	7,1	8,8	4,9	6,2

Tabela 5.2 - Classificação do erro do teste da postura dinâmica com diferentes camadas e diferentes neurónios para os treinos *trainlm*, *trainscg* e *trainrp*.

Teste Postura Dinâmica						
NºCamadas- NºNeurónios	Treino					
	<i>trainlm</i> (%)	Média (%)	<i>trainscg</i> (%)	Média (%)	<i>trainrp</i> (%)	Média (%)
2-25	0,5	14,9	24,3	5,9	1,5	2,3
2-30	0,8	15,1	12,6	3,1	1,3	1,8
3-20	0,5	25,8	18,4	4,5	1,8	3,6
3-25	0,5	38,6	7,1	1,7	2,1	2,9

Foi escolhida a matriz de confusão com a menor percentagem de erro, tendo sido este calculado dividindo o número de casos mal classificados pelo valor total de dados, correspondendo este valor a 2442 para o caso do teste da postura dinâmica e 7326 para a estática. A média fornece o valor médio de casos mal classificados para os 10 testes.

Apesar de, por vezes os resultados dos treinos *Levenberg-Marquardt* e *Scaled Conjugate Gradient* apresentarem erros inferiores aos do *Resilient Backpropagation* (valores sombreados a vermelho), este apresenta na maioria dos casos uma média significativamente inferior aos outros dois. Tendo em conta que o que se pretende é obter o menor erro possível, é preferível uma rede cujo desempenho seja constante ao invés de oscilar muito como é o caso dos outros dois treinos.

Verifica-se que para o teste da postura dinâmica, os valores de erro são muito inferiores aos da postura estática. Isto deve-se ao facto de na postura estática o sujeito levantar-se entre cada repetição. Facto que se confirmou com o decorrer dos testes e com o tratamento dos dados que demonstraram que os valores dos mapas de pressão variavam consideravelmente sempre que o sujeito se voltava a sentar na cadeira. O mínimo desvio faz variar significativamente os valores de pressão das bolsas.

O passo seguinte consistiu em utilizar o método *leave-one-out*, descrito no Capítulo 3, com a finalidade de testar cada um dos sujeitos individualmente. Para tal, treinaram-se redes com várias camadas e vários neurónios para o treino *Resilient Backpropagation*, que se considerou ser o melhor. A Tabela 5.3 apresenta os resultados obtidos em função das percentagens de erro das médias de teste e de treino para o teste da postura dinâmica e para o teste da postura estática.

Tabela 5.3 - Classificação do teste da postura dinâmica e estática com diferentes camadas e diferentes neurónios para o treino *trainrp* com o método *leave-one-out*.

Testes iniciais				
<i>trainrp</i>	Dinâmica		Estática	
NºCamadas- NºNeurónios	Média Teste (% erro)	Média Treino (% erro)	Média Teste (% erro)	Média Treino (% erro)
1-10	9,5	5,0	25,6	20,4
1-15	9,5	2,9	25,5	17,7
1-20	10,4	2,1	25,8	15,2
1-30	11,3	1,4	25,9	11,1
2-15	11,3	2,3	25,1	11,7
2-20	10,4	1,7	25,7	8,6
2-25	10,7	1,4	25,6	6,6
2-30	10,5	1,2	25,7	5,1
2-35	10,6	1,0	25,9	4,4
3-15	9,8	2,5	26,5	9,7
3-25	11,6	1,6	26,2	5,3
3-30	10,0	1,4	26,4	4,4
3-35	10,7	1,3	25,5	4,0

Tal como nas tabelas anteriores, verifica-se que os erros correspondentes ao teste da postura dinâmica são muito inferiores ao da postura estática, como era esperado. Verifica-se, também, que à medida que se aumenta o número de camadas e de neurónios o valor da média do treino tende a diminuir. No entanto, o valor da média do teste mantém-se praticamente constante independentemente do número de camadas e do número de neurónios, variando cerca de 1% para algumas redes.

Ao aumentar o número de camadas e o número de neurónios a aprendizagem da rede é muito lenta e requer mais memória. Assim sendo, e tendo em conta que os valores de teste não variam muito (cerca de 1%), considerou-se que uma rede com uma ou duas camadas até 35 neurónios são boas opções para implementar em tempo real, uma vez que são mais rápidas e produzem bons resultados, quando comparadas com as redes com 3 camadas cujo tempo de aprendizagem é muito superior e apresentam resultados semelhantes.

5.1.1.2. Testes Finais

Tendo em conta os resultados obtidos nos testes iniciais e com base nas limitações identificadas no Capítulo 4, realizou-se uma nova recolha de dados. Desta vez com uma calibração automática, o que permitiu reduzir o erro associado a uma calibração manual.

Com os novos dados recolhidos e efectuado o seu tratamento para introdução na rede, foram criadas redes neuronais cujo treino utilizado foi o *Resilient Backpropagation*, uma vez que

demonstrou ser o treino que permite obter melhores resultados com o menor tempo de aprendizagem. Para cada rede demonstrada nas Tabelas 5.4 e 5.5 foram realizados 5 treinos e foi escolhido o que apresentou melhores resultados. Os resultados obtidos correspondem ao erro de cada posição, para o teste da postura estática e para o teste da postura dinâmica, respectivamente.

Tabela 5.4 - Classificação do erro do teste da postura estática com o método *leave-one-out*.

		Posição*										
NºCamadas- NºNeurónios	1	2	3	4	5	6	7	8	9	10	11	Média
1-15	19,8	57,4	51,4	37,4	20,0	19,0	24,2	16,6	27,0	21,8	27,7	29,3
1-20	25,3	66,4	59,2	39,2	22,7	19,0	22,7	8,52	29,6	15,9	27,5	30,6
2-15	19,6	58,5	44,6	35,3	19,4	16,3	21,6	15,1	25,0	21,4	28,7	27,8
2-20	24,8	60,0	52,2	44,0	14,6	24,4	24,4	14,8	33,5	22,9	22,5	30,7

* - Os valores dizem respeito à percentagem de erro obtida.

Tabela 5.5 - Classificação do erro do teste da postura dinâmica com o método *leave-one-out*.

		Posição*										
NºCamadas- NºNeurónios	1	2	3	4	5	6	7	8	9	10	11	Média
1-15	0	20,6	26,7	16,7	6,1	3,9	12,8	7,2	8,3	3,3	6,7	10,2
1-20	0	19,4	17,8	10,0	6,7	4,4	11,7	14,4	12,2	7,2	13,3	10,7
2-15	0	17,2	12,2	10,0	10,6	12,8	12,8	6,7	13,9	3,3	17,8	10,7
2-20	0	18,3	18,3	17,8	8,9	10,6	15,6	8,9	14,4	1,7	11,7	11,5
2-30	0	20,0	18,9	11,1	6,7	6,7	10,0	8,9	12,2	1,7	12,8	9,9

* - Os valores dizem respeito à percentagem de erro obtida.

Como se pode observar através das médias obtidas para o erro do classificador, os valores variam entre 27,8% e 30,7%, para o caso do teste da postura estática. Isto demonstra mais uma vez que é preferível utilizar menos camadas e menos neurónios, diminuindo-se, assim, o tempo de aprendizagem da rede.

No que diz respeito ao erro obtido para cada posição, observa-se a cinzento que os valores das posições 2 e 3 para ambos os casos apresentam valores superiores aos das restantes posições. Isto pode explicar-se devido ao facto de serem duas posições muito semelhantes (inclinadas para a frente), onde o centro de massa do sujeito é quase idêntico e apenas os sensores do assento da cadeira são usados. Também em trabalhos anteriores estas posições foram as que obtiveram piores classificações quando comparadas com as outras [54].

A posição 4 (posição inclinada para trás) do teste da postura estática também apresenta valores superiores, o que veio confirmar as limitações identificadas ao nível do protótipo, visto que as costas da cadeira possuem uma área reduzida e as bolsas da zona superior nem sempre

apresentavam valores consideráveis pois os pontos de activação dos sensores não são os mesmos.

Estudados os dois testes em separado e encontrados os parâmetros que permitem obter os melhores resultados, procedeu-se à junção de todos os dados de forma a aumentar o conjunto de treino. Treinaram-se duas redes distintas, ambas com o treino *Resilient Backpropagation*, uma com uma camada e 15 neurónios e outra com duas camadas e 15 neurónios, tendo sido realizados 5 treinos por cada rede e escolhido o que apresentou melhores resultados. A Tabela 5.6 fornece os resultados da classificação das duas redes.

Tabela 5.6 - Classificação resultante da junção do teste da postura dinâmica e da estática, com o método *leave-one-out*.

NºCamadas- NºNeurónios	Posição*											Média
	1	2	3	4	5	6	7	8	9	10	11	
1-15	16,1	49,6	41,4	30,6	19,4	14,9	25,4	14,7	23,2	19,0	23,9	25,3
2-15	19,9	54,4	40,6	33,1	20,6	14,4	20,7	11,4	25,6	17,8	27,1	25,9

* - Os valores dizem respeito à percentagem de erro obtida.

Tal como para os casos anteriores, verifica-se que as posições 2, 3 e 4 possuem erros superiores às restantes posições, como seria de esperar. Relativamente às médias obtidas, ambas são muito semelhantes e apresentam uma melhoria, ainda que pouco significativa, em relação ao teste da estática. Não faz sentido fazer uma comparação com o teste da dinâmica, devido à explicação dada anteriormente.

Os valores de erro para cada posição foram obtidos somando todos os erros de cada uma das posições e dividindo por 720 (mapas de pressão para cada posição para os 30 sujeitos).

A média foi obtida através do valor médio das 30 classificações atribuídas a cada matriz de confusão, sendo que o erro de cada matriz é feito através da razão entre o total de erros das 11 posições e os 264 mapas de pressão correspondentes.

A Figura 5.2 representa a matriz de confusão cuja classificação foi a melhor de entre os 30 sujeitos, com uma percentagem de erro de 8,7%, para o treino *Resilient Backpropagation* com uma camada e 15 neurónios. Este valor foi determinado através da razão entre o total de erros das 11 posições e os 264 mapas de pressão correspondentes.

Matriz de confusão (1Camada-15Neurónios) <i>trainrp</i>											
Classe Real (1-11) (1-11)	Classe Prevista (1-11) (1-11)										
	24	0	0	0	0	0	0	0	0	0	0
	0	24	0	0	0	0	0	0	0	0	
	0	0	24	0	0	0	0	0	0	0	
	0	0	6	18	0	0	0	0	0	0	
	0	0	0	12	11	0	1	0	0	0	
	0	0	0	0	0	24	0	0	0	0	
	0	0	0	0	0	0	24	0	0	0	
	0	0	0	0	0	0	0	20	0	4	
	0	0	0	0	0	0	0	0	24	0	
	0	0	0	0	0	0	0	0	0	24	
	0	0	0	0	0	0	0	0	0	24	

Figura 5.2 - Matriz de confusão da rede neuronal com treino *trainrp* com uma camada e 15 neurónios.

5.1.2. Naive Bayes

Para construir o classificador *Naive Bayes* usaram-se duas distribuições, a normal e a *kernel*. Estes dois tipos de distribuições são utilizados em estudos de reconhecimento de padrões.

A Tabela 5.7 contém as classificações obtidas para o teste da postura dinâmica, da postura estática e da junção dos dois testes, para os dois tipos de distribuição usados. Estes valores dizem respeito aos testes iniciais e aos finais com o método *leave-one-out*, com o intuito de demonstrar que, mesmo com calibrações diferentes os valores não variam mais que 7,4%, sendo esta a maior variação encontrada, para a junção dos dois testes com distribuição normal.

Tabela 5.7 - Classificação obtida com o método *leave-one-out* para o classificador *Naive Bayes*, com a distribuição normal e *kernel* para o teste da postura dinâmica, estática e a junção dos dois.

<i>NaiveBayes*</i>						
	Dinâmica		Estática		Din_Est	
	<i>Kernel</i>	Normal	<i>Kernel</i>	Normal	<i>Kernel</i>	Normal
Testes finais	84,8	86,1	64,0	66,5	68,5	70,0
Testes iniciais	84,0	83,8	64,0	65,7	63,5	62,6

* - Os valores dizem respeito à percentagem média da classificação obtida para os 30 sujeitos.

É possível verificar que os valores para ambas as distribuições são bastante semelhantes, com uma variação máxima de cerca de 2%. Sendo a distribuição normal a que apresenta os melhores resultados, para a maioria dos casos.

Os valores correspondem à média das classificações obtidas para os 30 sujeitos, sendo que a melhor classificação obtida para a distribuição *kernel* foi de 88,26% e para a distribuição normal de 92,42%, ambas para os testes finais.

5.2.EXPERIÊNCIA B

A experiência **B** foi realizada em conjunto com o trabalho desenvolvido no âmbito de uma bolsa de investigação inserida no projecto, tendo como objectivo identificar limitações e avaliar o classificador em tempo real fazendo testes a 30 sujeitos como explicado no Capítulo 4 [47].

Foram escolhidas apenas oito posturas, excluindo posturas que foram consideradas muito semelhantes em relação a outras e que iriam dificultar o processo de avaliação do classificador.

No decorrer dos testes verificou-se que as transições para a posição de referência resultavam em classificações inferiores em comparação com outras posições, algo que foi constatado também por Zheng e Morrell (2010) [54]. Assim sendo, recorreu-se ao diagrama de caixa de bigodes de forma a tentar identificar o porquê disto acontecer. Estes diagramas permitem observar a distribuição de um conjunto de dados com base nos valores da mediana e dos quartis. As caixas contêm 50% dos valores, a linha dentro da caixa corresponde à mediana e os pontos a vermelho são valores atípicos, que se encontram fora dos limites máximo e mínimo, muito afastados dos restantes valores.

As Figura 5.3, 5.4 e 5.5 representam os diagramas de caixas de bigodes para cada postura em estudo. Estes diagramas permitem observar as distribuições de pressões para cada sensor e para cada posição.

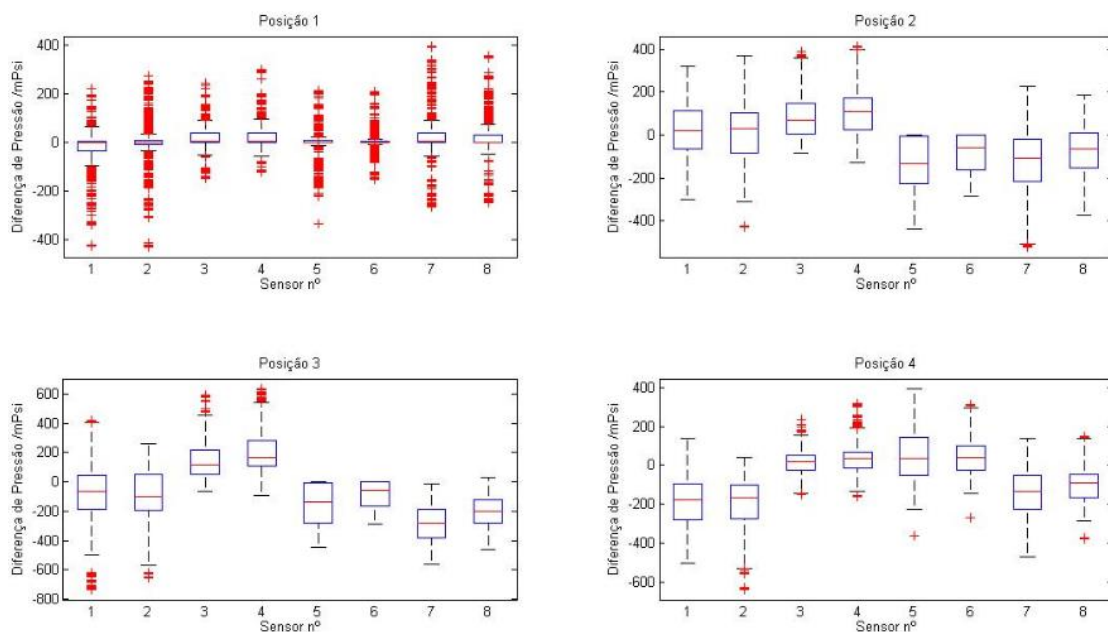


Figura 5.3 - Diagrama de caixa de bigodes das posições 1, 2, 3 e 4.

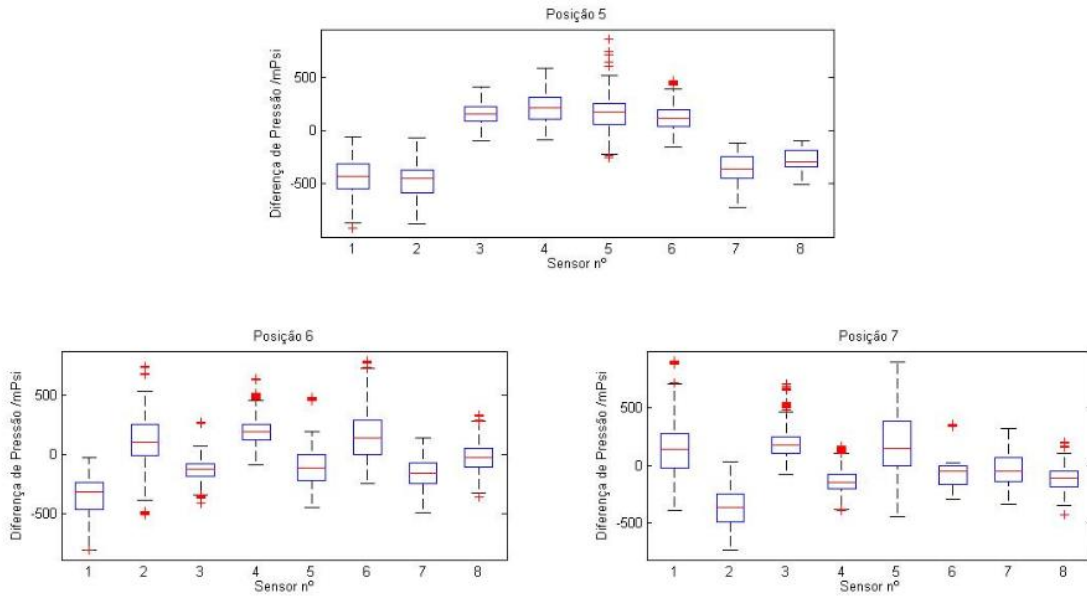


Figura 5.4 - Diagrama de caixa de bigodes das posições 5, 6 e 7.

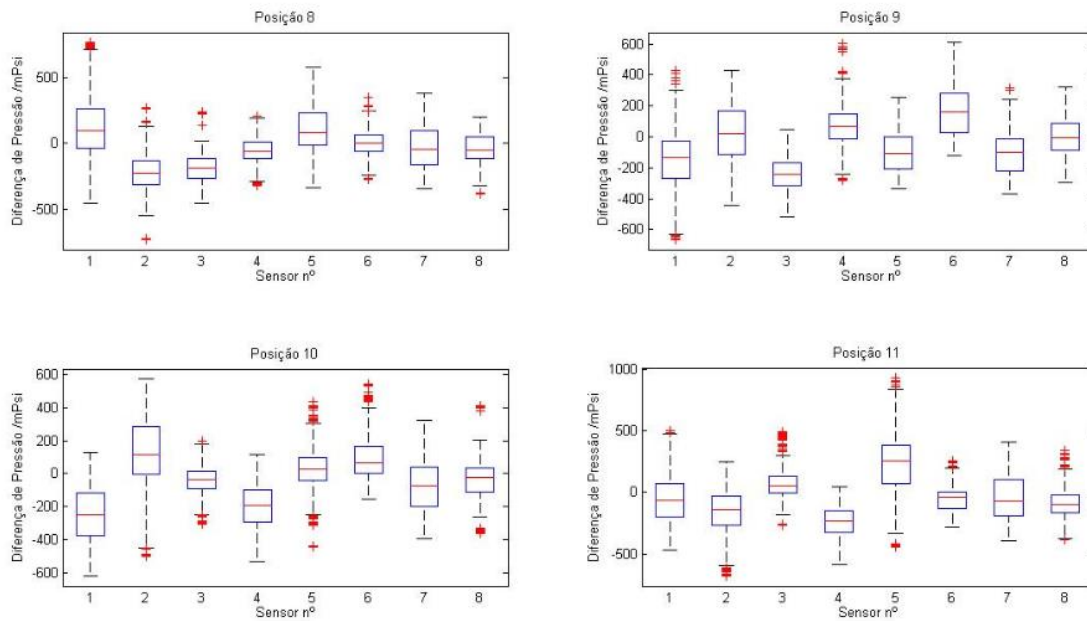


Figura 5.5 - Diagrama de caixa de bigodes das posições 8, 9, 10 e 11.

Através dos diagramas das Figuras 5.3, 5.4 e 5.5, é possível perceber a dificuldade em identificar a posição 1. Nesta posição, os valores das distribuições de pressão estão contidos num intervalo muito restrito quando comparadas com as restantes posições. Devido a esta concentração de valores num intervalo tão reduzido, à volta dos 0 mPsi, qualquer desvio faz com que esta posição seja classificada incorrectamente.

Para além disto, a forma como os sujeitos se sentam é de extrema importância, pois nem sempre utilizam as costas da cadeira da mesma forma. Sendo esta posição muito semelhante às posições 2 e 3 em termos de mapas de pressão obtidos, a classificação desta posição torna-se mais complicada.

Devido ao trabalho desenvolvido na presente dissertação e com o auxílio da aplicação móvel realizada por Belo (2012) [3], foi possível identificar, como se pode observar pelos diagramas anteriores, limitações ao nível da classificação da posição de referência. Desta forma, foi desenvolvido num trabalho em paralelo, um novo classificador para a posição de referência, onde são usados limiares de decisão (*thresholds*) para os valores de cada sensor baseados em árvores de decisão para conseguir identificar esta posição de forma mais precisa. Resolvido o problema da classificação da posição de referência, testou-se o classificador final em tempo real obtendo os resultados fornecidos pela Tabela 5.8.

Tabela 5.8 - Classificação em tempo real para cada posição. Adaptada de [47].

Postura	Classificação com <i>threshold 1</i>	Classificação com <i>threshold 2</i>
1	74.0%	62.0%
3	93.3%	91.7%
4	88.3%	91.7%
5	100.0%	100.0%
6	98.3%	98.3%
7	98.3%	98.3%
8	95.0%	98.3%
10	100.0%	100.0%

Os valores de *threshold* são os valores definidos no trabalho realizado em paralelo a este para classificar a posição 1, apresentando uma classificação de cerca de 90% [47]. Como se pode observar, a posição 1 continua a apresentar resultados inferiores às restantes, no entanto muito superiores aos resultados obtidos no início dos testes em tempo real, abaixo dos 25%.

5.3. ANÁLISE COMPARATIVA DOS CLASSIFICADORES

Analisando os resultados obtidos em ambos os classificadores, verifica-se que as redes neuronais apresentam melhores resultados, tendo obtido uma classificação média de 75% para uma rede com uma camada e 15 neurónios, com o método *leave-one-out*, e cujo algoritmo de treino utilizado foi o *Resilient Backpropagation*.

O *Naive Bayes* apresentou uma classificação média de 70% com o método *leave-one-out*, usando uma distribuição normal. Contudo, o valor do erro das redes neuronais a cada treino que

se realiza varia, enquanto que o classificador *Naive Bayes* apresenta sempre o mesmo resultado para todos os sujeitos, desde que se mantenham os mesmos parâmetros.

As redes neuronais foram mais exploradas, devido ao facto de ser possível variar mais parâmetros. O *Naive Bayes* pode-se considerar um pouco limitado uma vez que não é possível alterar muitos parâmetros à excepção do tipo de distribuição, tendo sido útil para comparar resultados com as redes neuronais. O processo de treino usando o método do *Naive Bayes* é consideravelmente mais rápido e requer menos memória que as redes neuronais, no entanto a informação que se obtém das redes é mais completa. Desta forma, com o novo protótipo e com as devidas melhorias efectuadas na cadeira é possível melhorar a classificação obtida pelos dois classificadores.

Considera-se que as redes neuronais, apesar de mais complexas, são a melhor opção, uma vez que apresentam uma menor variação de valores na classificação dos sujeitos e se consegue variar diversos parâmetros. Com o novo protótipo será possível conseguir um conjunto de treino melhor, o que permitirá obter melhores resultados usando os parâmetros explorados neste trabalho, visto que os algoritmos de treino aprendem através dos exemplos fornecidos.

CAPÍTULO 6

CONCLUSÕES E TRABALHO FUTURO

Concluído mais um trabalho no âmbito do projecto SYPEC, pode-se afirmar que os objectivos propostos foram cumpridos tendo conseguido desenvolver classificadores que permitem a identificação automática da postura de sentado, objectivo principal desta dissertação.

Foram definidas 11 posturas para estudo, escolhidas com base em trabalhos anteriores que permitem concluir serem as posturas mais adoptadas em cadeiras de escritório no desempenho das funções em ambiente de trabalho. Foi elaborado um protocolo de aquisição de dados para futura introdução nos classificadores e determinou-se, com base em testes efectuados, a calibração necessária a fazer aos sensores e à cadeira antes de dar início à recolha de dados.

Foram desenvolvidos dois classificadores, um com base em redes neuronais e outro baseado no Teorema de *Bayes*, o *Naive Bayes*, tendo apresentado uma classificação média de 75% e 70%, respectivamente, para as 11 posturas em estudo. Ambos apresentaram bons resultados tendo em conta algumas limitações do protótipo, identificadas ao longo desta dissertação. No entanto, as redes neuronais permitem obter uma informação mais completa em relação ao *Naive Bayes*, permitindo alterar diversos parâmetros, como o tipo de treino, número de camadas e número de neurónios. Como tal, as redes neuronais foram mais exploradas e conclui-se que se trata da melhor opção para este estudo, quando comparada com o *Naive Bayes*.

Dos treinos usados nas redes neuronais, o *Resilient Backpropagation* foi o que demonstrou um melhor desempenho em relação ao *Levenberg-Marquardt* e ao *Scaled Conjugate Gradient*.

Também se verificou que ao usar menos camadas e 15 a 35 neurónios se consegue obter boas classificações, com maior rapidez e sem utilizar demasiada memória. Desta forma, identificou-se o treino com uma camada e 15 neurónios como a melhor opção, visto ter apresentado os melhores resultados face às questões mencionadas. Para o *Naive Bayes*, é indiferente usar a distribuição normal ou *kernel* uma vez que apresentam resultados semelhantes.

Através dos classificadores desenvolvidos e com recurso à aplicação móvel desenvolvida e à adaptação das redes neuronais feita por Belo (2012) [3], para introdução no dispositivo móvel, é possível identificar em tempo real a posição em que o utilizador se encontra. A posição de referência foi a posição onde surgiram mais problemas ao nível da sua classificação, seguida das posições 2, 3 e 4. Posto isto, foi desenvolvido por Martins [47] um classificador que permite identificar de forma mais precisa a posição 1, tendo obtido para 8 posturas uma classificação de cerca de 90%.

Como trabalho futuro, propõe-se a continuação deste estudo com o objectivo de melhorar a classificação, usando os algoritmos desenvolvidos e explorar parâmetros que não foram analisados. Sugere-se uma nova recolha de dados com o segundo protótipo, de forma a eliminar as limitações que se encontraram no primeiro e que influenciaram a recolha de dados. Assim, pode-se melhorar o conjunto de treino obtendo melhores classificações. Com o novo protótipo, seria uma boa opção fazer a correlação dos dados obtidos, através do método desenvolvido nesta dissertação, com outros métodos existentes e comparar resultados.

Está já a ser estudado, com base no estudo desenvolvido ao longo desta dissertação, a correcção da postura que constitui o principal objectivo deste projecto.

Seria ainda interessante fazer uma análise estatística e perceber se existem padrões para indivíduos do sexo masculino/feminino ou para diferentes alturas/pesos.

Não foi possível realizar qualquer disseminação de resultados, até que o processo de patenteamento do sistema SYPEC seja iniciado, estando previsto a realização de um artigo na conferência *Engineering Applications of Neural Networks (14th EANN Conference)* em Setembro, no âmbito dos resultados obtidos para a classificação da postura.

BIBLIOGRAFIA

- [1] E. N. Corlett, “Background to sitting at work: research-based requirements for the design of work seats,” *Ergonomics*, vol. 49, no. 14, pp. 1538–1546, Nov. 2006.
- [2] R. Lucena, “SYPEC: Construção de um Protótipo,” Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2012.
- [3] J. Belo, “SYPEC: Desenvolvimento de uma aplicação Android para controlo e avaliação postural,” Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2012.
- [4] M. A. Adams and W. C. Hutton, “The effect of posture on the lumbar spine,” *J Bone Joint Surg Br*, vol. 67, no. 4, pp. 625–629, Aug. 1985.
- [5] Ying Zheng and J. B. Morrell, “A vibrotactile feedback approach to posture guidance,” 2010, pp. 351–358.
- [6] L. A. Slivovsky, “A real-time sitting posture tracking system,” *ETD Collection for Purdue University*.
- [7] H. Z. Tan, L. A. Slivovsky, and A. Pentland, “A sensing chair using pressure distribution sensors,” *Mechatronics, IEEE/ASME Transactions on*, vol. 6, no. 3, pp. 261 –268, Sep. 2001.
- [8] M. Zhu, A. M. Martínez, and H. Z. Tan, “Template-based recognition of static sitting postures,” presented at the In Workshop on Computer Vision & Pattern Recognition for Human-Computer Interaction.
- [9] S. Mota and R. W. Picard, “Automated Posture Analysis for Detecting Learner’s Interest Level,” in *Computer Vision and Pattern Recognition Workshop, 2003. CVPRW ’03. Conference on*, 2003, vol. 5, p. 49.
- [10] B. Mutlu, A. Krause, J. Forlizzi, C. Guestrin, and J. Hodgins, *Robust, Low-cost, Non-intrusive Sensing and Recognition of Seated Postures*. .
- [11] W. Y. Wong and M. S. Wong, “Detecting spinal posture change in sitting positions with tri-axial accelerometers,” *Gait & Posture*, vol. 27, no. 1, pp. 168–171, Jan. 2008.
- [12] D. B. Chaffin, G. B. J. Andersson, and B. J. Martin, *Occupational Biomechanics*, 4th ed. Wiley-Interscience, 2006.
- [13] C. Rosse and P. Gaddum-Rosse, *Hollinshead’s Textbook of Anatomy*, Fifth. Lippincott Williams & Wilkins, 1997.
- [14] G. Andersson, *On myoelectric back muscle activity and lumbar disc pressure in sitting postures*. s.n, 1974.
- [15] H. Miller, *se The Benefit of Pelvic Stabilization pdf free ebook download*. .
- [16] “<http://marcoshanry.blogspot.pt/2011/09/coluna-vertebral-e-os-movimentos.html>.” de Fevereiro de-2013.
- [17] P. van Wely, “Design and disease,” *Applied Ergonomics*, vol. 1, no. 5, pp. 262–269, Dec. 1970.
- [18] J. H. van Dieën and B. Visser, “Estimating net lumbar sagittal plane moments from EMG data. The validity of calibration procedures,” *J Electromyogr Kinesiol*, vol. 9, no. 5, pp. 309–315, Oct. 1999.
- [19] R. S. Bridger, C. Von Eisenhart-Rothe, and M. Henneberg, “Effects of seat slope and hip flexion on spinal angles in sitting,” *Hum Factors*, vol. 31, no. 6, pp. 679–688, Dec. 1989.
- [20] R. Lueder, “Anatomical, physiological and health.” Humanics ErgoSystems, Inc., 2002.

- [21] M. Graf, U. Guggenbühl, and H. Krueger, “An assessment of seated activity and postures at five workplaces,” *International Journal of Industrial Ergonomics*, vol. 15, no. 2, pp. 81–90, Feb. 1995.
- [22] W. Hüüting, E. Grandjean, and K. Maeda, “Constrained postures in accounting machine operators,” *Applied Ergonomics*, vol. 11, no. 3, pp. 145–149, Sep. 1980.
- [23] R. Lueder, “Ergonomics of sitting and seating.” Humanics ErgoSystems, Inc., 2004.
- [24] M. I. Bullock and N. (Eddington, “Ergonomics in the tourist, agricultural and mining industries, general ergonomics; proceedings,” presented at the Ergonomics Society of Australia and New Zealand, Annual Conference, 22nd, 1985, Toowoomba, Queensland, 1985.
- [25] P. H. Wood and C. L. McLeish, “Digest of data on the rheumatic diseases. 5. Morbidity in industry, and rheumatism in general practice.,” *Ann Rheum Dis*, vol. 33, no. 1, pp. 93–105, Jan. 1974.
- [26] M. A. Adams and W. C. Hutton, “The effect of posture on the fluid content of lumbar intervertebral discs,” *Spine*, vol. 8, no. 6, pp. 665–671, Sep. 1983.
- [27] E. Grandjean, *Ergonomics In Computerized Offices*, 1st ed. CRC Press, 1986.
- [28] A. Maroudas, R. A. Stockwell, A. Nachemson, and J. Urban, “Factors involved in the nutrition of the human lumbar intervertebral disc: cellularity and diffusion of glucose in vitro.,” *J Anat*, vol. 120, no. Pt 1, pp. 113–130, Sep. 1975.
- [29] A. R. Webb, *Statistical Pattern Recognition, 2nd Edition*, 2nd ed. Wiley, 2002.
- [30] R. M. Haralick and L. G. Shapiro, *Computer and robot vision*. Addison-Wesley Pub. Co., 1993.
- [31] Y.-H. Pao, *Adaptive pattern recognition and neural networks*. Addison-Wesley, 1989.
- [32] J. Fonseca, “Indução de Árvores de Decisão,” Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, Lisboa, 1994.
- [33] D. Trigueiros, *Robustez como critério de decisão em modelos financeiros sequenciais*. Lisboa: D. Trigueiros, 1991.
- [34] I. Rish, “An empirical study of the naive Bayes classifier,” presented at the IJCAI-01 workshop on “Empirical Methods in AI.”
- [35] M. Aly, *Survey on Multiclass Classification Methods*. 2005.
- [36] J. R. Quinlan, “Induction of Decision Trees,” in *Machine Learning*, 1986, pp. 81–106.
- [37] M. H. Beale, M. T. Hagan, and H. B. Demuth, *Neural Network Toolbox™ - User’s Guide*, R2012a ed. MathWorks, 2012.
- [38] M. Riedmiller and H. Braun, “A direct adaptive method for faster backpropagation learning: the RPROP algorithm,” in , *IEEE International Conference on Neural Networks, 1993*, 1993, pp. 586–591 vol.1.
- [39] T. Hastie, R. Tibshirani, and J. H. Friedman, *The Elements of Statistical Learning*, Corrected. Springer, 2003.
- [40] D. Michie and D. J. Spiegelhalter, *Machine Learning, Neural and Statistical Classification*. Prentice Hall, 1994.
- [41] “MathWorks-Confusion-Matrix <http://www.mathworks.com/help/stats/confusionmat.html>,” *Confusion Matrix*. .
- [42] A. Smola and S. V. N. Vishwanathan, *Introduction to Machine Learning*. Cambridge: Cambridge University Press, 2008.

- [43]“MathWorks-Naive Bayes Classification - <http://www.mathworks.com/help/stats/naive-bayes-classification.html>,” *Naive Bayes Classification*. .
- [44]G. John and P. Langley, “Estimating Continuous Distributions in Bayesian Classifiers,” in *In Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence*, 1995, pp. 338–345.
- [45]L. A. Slivovsky and H. Z. Tan, “A Real-Time Static Posture Classification System.”
- [46]M. Vergara and Á. Page, “System to measure the use of the backrest in sitting-posture office tasks,” *Applied Ergonomics*, vol. 31, no. 3, pp. 247–254, Jun. 2000.
- [47]L. Martins, “Relatório de Bolsa de Investigação no âmbito do projecto QREN 13330 – SYPEC.,” FCT-UNL.
- [48]M. F. Møller, “A scaled conjugate gradient algorithm for fast supervised learning,” *Neural Networks*, vol. 6, no. 4, pp. 525–533, 1993.
- [49]W.-F. Chang and M.-W. Mak, *A Conjugate Gradient Learning Algorithm for Recurrent Neural Networks*. 1998.
- [50]“MathWorks-ResilientBackpropagation <http://www.mathworks.com/help/nnet/ref/trainrp.html>,”*MathWorks-Resilient Backpropagation*. .
- [51]M. Riedmiller, *Advanced Supervised Learning in Multi-layer Perceptrons - From Backpropagation to Adaptive Learning Algorithms*. 1994.
- [52]M. Riedmiller and I. Rprop, *Rprop - Description and Implementation Details*. 1994.
- [53]C. Igel and M. Hüsken, *Improving the Rprop Learning Algorithm*. 2000.
- [54]Y. Visell, J. R. Cooperstock, B. L. Giordano, K. Franinovic, A. Law, S. Mcadams, K. Jathal, and F. Fontana, *A Vibrotactile Device for Display of Virtual Ground Materials in Walking*. .

ANEXO I

Tabela referente às características dos 30 sujeitos que realizaram os testes da Experiência A.

Nº actividade experimental	Idade	Sexo	Peso (kg)	Altura (cm)	Profissão	Posição adoptada ao longo do dia
1	23	F	50	162	Estudante	Maioritariamente sentado
2	23	M	81	181	Estudante	Maioritariamente sentado
3	24	M	94	171	Bolseiro	Maioritariamente sentado
4	26	M	70	174	Estudante	Maioritariamente sentado
5	20	F	67	176	Estudante	Maioritariamente sentado
6	24	M	78	174	Estudante	Maioritariamente sentado
7	18	F	60	164	Estudante	Ambas
8	19	F	60	165	Estudante	Ambas
9	18	F	58	163	Estudante	Maioritariamente sentado
10	20	F	53	169	Estudante	Ambas
11	19	M	75	193	Estudante	Maioritariamente sentado
12	19	M	63	177	Estudante	Maioritariamente sentado
13	19	M	65	172	Estudante	Maioritariamente em pé
14	23	M	77	183	Estudante	Maioritariamente sentado
15	23	F	45	155	Estudante	Maioritariamente sentado
16	19	F	62	170	Estudante	Ambas
17	19	F	55	163	Estudante	Ambas
18	20	F	64	170	Estudante	Maioritariamente sentado
19	20	F	70	175	Estudante	Maioritariamente sentado
20	19	M	62	178	Estudante	Maioritariamente sentado
21	19	M	72	182	Estudante	Maioritariamente sentado
22	23	M	73	188	Consultor	Maioritariamente sentado
23	20	M	80	170	Estudante	Maioritariamente sentado
24	20	M	62	170	Estudante	Maioritariamente sentado
25	23	M	97	175	Estudante	Maioritariamente sentado
26	20	F	53	166	Estudante	Maioritariamente sentado
27	19	F	68	168	Estudante	Maioritariamente sentado
28	18	F	54	160	Estudante	Ambas
29	20	M	85	177	Estudante	Ambas
30	26	F	53	168	Bolseira	Maioritariamente sentado

ANEXO II

Tabela referente às características dos 30 sujeitos que realizaram os testes da Experiência B.

Nº actividade experimental	Idade	Sexo	Peso (kg)	Altura (cm)	Profissão	Posição adoptada ao longo do dia
1	20	M	85	170	Estudante	Maioritariamente sentado
2	19	F	60	162	Estudante	Maioritariamente sentado
3	20	F	58	167	Estudante	Maioritariamente sentado
4	19	F	59	163	Estudante	Ambos
5	20	F	68	164	Estudante	Ambos
6	19	F	63	170	Estudante	Maioritariamente sentado
7	19	M	75	182	Estudante	Maioritariamente sentado
8	21	M	71	187	Estudante	Ambos
9	24	M	98	175	Estudante	Maioritariamente sentado
10	19	F	60	165	Estudante	Maioritariamente sentado
11	24	M	94	171	Bolseiro	Maioritariamente sentado
12	26	M	74	174	Estudante	Maioritariamente sentado
13	19	M	74	191	Estudante	Maioritariamente sentado
14	20	M	75	194	Estudante	Maioritariamente sentado
15	19	F	60	165	Estudante	Ambos
16	26	M	76	172	Estudante	Maioritariamente sentado
17	19	F	52	161	Estudante	Ambos
18	20	M	78	180	Estudante	Ambos
19	19	F	67	170	Estudante	Maioritariamente sentado
20	19	F	58	158	Estudante	Ambos
21	21	F	50	162	Estudante	Maioritariamente sentado
22	22	M	75	175	Estudante	Ambos
23	20	M	64	178	Estudante	Maioritariamente sentado
24	19	F	64	172	Estudante	Maioritariamente sentado
25	20	F	54	173	Estudante	Ambos
26	20	F	52	164	Estudante	Maioritariamente sentado
27	20	F	55	169	Estudante	Maioritariamente sentado
28	20	M	85	177	Estudante	Ambos
29	20	M	85	180	Estudante	Ambos
30	22	M	77	177	Estudante	Maioritariamente sentado

ANEXO III

Matrizes confusão dos testes iniciais cujos resultados se encontram nas Tabela 5.1 e 5.2, do Capítulo 5. As linhas sombreadas a vermelho correspondem às posturas que obtiveram piores classificações. Teste da Postura Dinâmica:

Matriz de confusão (2Camadas-25Neurónios) <i>trainlm</i>										
Classe Prevista (1-11) (1-11)										
Classe Real (1-11)	221	1	0	0	0	0	0	0	0	0
	0	220	2	0	0	0	0	0	0	0
	0	0	222	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0
	0	0	0	0	222	0	0	0	0	0
	0	1	0	0	0	221	0	0	0	0
	0	0	0	0	0	0	222	0	0	0
	0	0	0	0	0	0	0	216	0	1
	0	0	0	0	0	3	0	0	216	0
	0	0	0	0	0	0	0	0	222	0
	0	0	0	0	0	0	0	1	0	221
0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (2Camadas-30Neurónios) <i>trainlm</i>										
Classe Prevista (1-11)										
Classe Real (1-11)	221	1	0	0	0	0	0	0	0	0
	0	219	3	0	0	0	0	0	0	0
	0	0	222	0	0	0	0	0	0	0
	1	8	2	210	0	1	0	0	0	0
	0	0	1	0	221	0	0	0	0	0
	0	1	1	0	0	220	0	0	0	0
	0	0	0	0	0	0	222	0	0	0
	0	0	0	0	0	0	0	222	0	0
	0	0	0	0	0	0	0	0	222	0
	0	1	0	0	0	0	0	0	0	221
	0	0	0	0	0	0	0	0	0	0

Matriz de confusão (3Camadas-20Neurónios) <i>trainlm</i>										
Classe Prevista (1-11)										
Classe Real (1-11)	221	1	0	0	0	0	0	0	0	0
	0	222	0	0	0	0	0	0	0	0
	0	0	222	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0
	0	0	0	0	222	0	0	0	0	0
	0	2	0	0	0	220	0	0	0	0
	0	0	0	0	0	0	222	0	0	0
	0	0	0	0	0	0	0	216	0	0
	0	0	0	0	0	0	0	0	221	0
	0	1	0	0	0	0	0	0	0	221
	0	0	0	0	0	0	0	0	0	0

Matriz de confusão (3Camadas-25Neurónios) *trainlm*

		Classe Prevista (1-11)										
		222	0	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	0	222	0	0	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0	0	0
	0	0	0	0	222	0	0	0	0	0	0	0
	0	0	0	0	0	222	0	0	0	0	0	0
	0	0	0	0	0	0	222	0	0	0	0	0
	0	1	1	0	0	0	219	0	0	0	0	1
	2	0	0	0	0	0	0	216	4	0	0	0
	0	0	0	0	0	0	0	0	222	0	0	0
	0	0	0	0	0	0	0	0	0	222	0	0
	0	1	0	0	0	0	1	0	0	0	220	0
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (2Camadas-25Neurónios) *trainrp*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	0	214	2	6	0	0	0	0	0	0	0
	0	0	2	220	0	0	0	0	0	0	0	0
	0	0	0	0	216	0	4	0	0	0	2	0
	0	0	0	0	0	222	0	0	0	0	0	0
	0	2	1	1	0	0	211	0	0	0	0	7
	0	0	0	0	0	0	0	222	0	0	0	0
	0	0	0	0	0	0	0	0	216	0	6	0
	0	0	0	0	0	0	0	1	0	221	0	0
	0	0	0	0	0	0	0	0	0	1	220	1
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (2Camadas-30Neurónios) *trainrp*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	1	1	219	2	0	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0	0	0
	0	12	0	0	210	0	0	0	0	0	0	0
	0	0	0	0	0	222	0	0	0	0	0	0
	1	0	1	0	0	0	220	0	0	0	0	0
	5	0	0	0	0	0	0	216	1	0	0	0
	0	0	0	0	0	0	6	0	216	0	0	0
	0	0	0	0	0	0	0	0	0	222	0	0
	0	0	0	0	0	0	0	0	1	0	221	0
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (3Camadas-20Neurónios) *trainrp*

		Classe Prevista (1-11)										
		222	0	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	222	0	0	0	0	0	0	0	0	0	0
	0	0	222	0	0	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0	0	0
	0	0	0	0	218	4	0	0	0	0	0	0
	0	0	0	0	0	222	0	0	0	0	0	0
	0	1	1	0	0	0	220	0	0	0	0	0
	0	0	0	0	0	0	0	222	0	0	0	0
	0	0	0	0	0	0	4	0	216	0	1	1
	0	0	0	0	2	0	0	1	10	209	0	0
	0	0	0	0	0	0	0	0	1	0	213	8
	0	0	0	0	0	0	6	0	0	0	5	211

Matriz de confusão (3Camadas-25Neurónios) *trainrp*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	221	1	0	0	0	0	0	0	0	0	0
	0	0	216	2	4	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0	0	0
	0	0	0	0	222	0	0	0	0	0	0	0
	0	0	1	1	0	220	0	0	0	0	0	0
	0	0	1	1	0	0	220	0	0	0	0	0
	3	0	0	0	0	0	0	216	0	0	3	0
	0	0	0	0	0	0	6	0	216	0	0	0
	0	0	0	0	0	0	0	1	0	215	6	0
	0	0	0	0	0	0	0	0	0	1	214	7
	0	0	0	0	0	0	6	0	0	0	0	216

Matriz de confusão (2Camadas-25Neurónios) *trainscg*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	1	1	221	0	0	0	0	0	0	0	0	0
	0	0	1	221	0	0	0	0	0	0	0	0
	0	12	1	209	0	0	0	0	0	0	0	0
	0	0	0	0	1	221	0	0	0	0	0	0
	0	0	1	0	0	0	220	0	1	0	0	0
	0	0	0	0	0	0	0	222	0	0	0	0
	0	0	0	0	0	0	0	0	216	0	1	5
	0	0	0	0	0	0	0	0	0	222	0	0
	0	0	0	0	0	0	0	6	1	0	214	1
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (2Camadas-30Neurónios) *trainscg*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	0	220	2	0	0	0	0	0	0	0	0
	0	0	0	222	0	0	0	0	0	0	0	0
	4	4	12	0	204	0	2	0	0	0	0	0
	0	0	0	0	1	220	1	0	0	0	0	0
	0	0	0	1	0	0	220	0	1	0	0	0
	6	6	0	0	0	0	0	216	0	0	0	0
	0	0	0	0	0	6	0	0	216	0	0	0
	0	0	0	0	0	0	0	0	0	222	0	0
	0	0	0	0	0	0	0	0	1	0	221	0
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (3Camadas-25Neurónios) *trainscg*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	0	222	0	0	0	0	0	0	0	0	0
	0	0	1	221	0	0	0	0	0	0	0	0
	0	0	0	1	217	4	0	0	0	0	0	0
	0	0	0	0	0	221	1	0	0	0	0	0
	1	1	2	1	0	0	212	0	0	0	5	1
	0	0	0	0	0	0	0	222	0	0	0	0
	0	0	0	0	0	5	0	0	216	0	1	0
	0	0	0	0	0	0	0	1	0	221	0	0
	0	0	0	3	0	0	0	0	1	0	215	3
	0	0	0	0	0	0	0	0	0	0	0	222

Matriz de confusão (3Camadas-30Neurónios) *trainscg*

		Classe Prevista (1-11)										
		221	1	0	0	0	0	0	0	0	0	0
Classe Real (1-11)	0	0	0	222	0	0	0	0	0	0	0	0
	6	6 <td>0</td> <td>0</td> <td>216</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td>	0	0	216	0	0	0	0	0	0	0
	0	0	0	0	0	221	1	0	0	0	0	0
	0	0	1	1	1	0	219	0	0	0	0	0
	0	0	0	0	0	0	0	222	0	0	0	0
	0	0	0	0	0	0	0	0	222	0	0	0
	0	0	0	0	0	0	0	0	6	216	0	0
	0	0	0	0	0	0	0	6	1	0	215	0
	0	0	0	0	0	0	0	0	0	0	0	222

Teste Postura Estática:

		Matriz de confusão (1Camada-15Neurónios) <i>trainlm</i>									
		Classe Prevista (1-11)									
Classe Real (1-11)	587	39	7	18	2	0	1	0	0	12	0
	40	538	76	6	0	0	0	0	0	6	0
	10	31	594	12	7	2	0	10	0	0	0
	61	6	19	479	33	6	0	18	8	36	0
	8	0	0	38	615	1	0	0	0	4	0
	6	3	0	2	4	618	0	0	27	6	0
	6	3	0	0	0	2	601	3	10	3	38
	24	0	3	18	19	0	0	584	13	2	3
	0	0	0	1	0	11	0	14	640	0	0
	27	0	2	27	0	0	9	6	0	551	44
	0	7	0	0	0	0	24	0	0	20	615

		Matriz de confusão (1Camada-20Neurónios) <i>trainlm</i>									
		Classe Prevista (1-11)									
Classe Real (1-11)	569	52	4	0	2	0	2	6	0	25	6
	21	564	68	0	0	6	0	0	0	2	5
	0	65	583	6	6	0	0	0	0	6	0
	19	13	22	520	19	4	0	0	6	63	0
	0	1	6	22	623	5	0	0	0	9	0
	12	0	2	2	0	630	0	0	14	6	0
	0	0	0	0	0	12	613	6	0	0	35
	4	0	1	2	7	0	1	622	0	29	0
	0	0	1	0	0	20	0	13	630	2	0
	18	0	4	13	0	0	0	0	0	616	15
	0	0	0	1	0	0	30	0	0	31	604

		Matriz de confusão (1Camada-30Neurónios) <i>trainlm</i>									
		Classe Prevista (1-11)									
Classe Real (1-11)	593	11	0	33	0	2	0	12	0	14	1
	32	600	26	8	0	0	0	0	0	0	0
	18	32	595	6	0	0	0	0	0	9	6
	41	13	6	553	10	2	0	21	6	14	0
	12	0	0	10	644	0	0	0	0	0	0
	12	0	0	0	0	640	0	3	11	0	0
	0	0	0	0	0	12	645	1	0	0	8
	18	1	2	2	13	0	2	626	2	0	0
	0	0	0	0	0	0	0	8	658	0	0
	1	0	0	7	6	0	0	0	0	650	2
	0	0	0	8	0	0	7	0	0	4	647

Matriz de confusão (2Camadas-20Neurónios) <i>trainlm</i>											
Classe Prevista (1-11)											
Classe Real (1-11)	645	14	1	1	0	0	2	0	0	3	0
	9	633	15	1	1	0	5	0	0	1	1
	0	7	653	6	0	0	0	0	0	0	0
	22	4	0	620	2	2	0	3	0	12	1
	0	0	1	13	652	0	0	0	0	0	0
	0	0	10	0	2	653	0	0	1	0	0
	0	0	0	0	0	4	654	0	8	0	0
	10	9	3	0	0	1	8	627	2	6	0
	0	0	0	0	0	1	0	6	659	0	0
	1	0	0	6	2	3	0	0	0	653	1
	0	0	0	0	0	0	1	0	0	0	665

Matriz de confusão (2Camadas-25Neurónios) <i>trainlm</i>											
Classe Prevista (1-11)											
Classe Real (1-11)	643	9	1	2	6	0	0	0	0	5	0
	13	639	12	2	0	0	0	0	0	0	0
	0	12	636	6	0	0	0	12	0	0	0
	17	6	1	609	17	14	0	0	1	1	0
	0	0	1	5	659	0	1	0	0	0	0
	0	0	0	6	6	652	0	0	2	0	0
	0	0	0	0	0	10	649	0	2	0	5
	0	0	1	0	9	0	0	653	0	3	0
	0	0	0	0	0	1	0	2	663	0	0
	0	1	0	2	0	3	0	0	3	655	2
	0	0	0	8	0	0	1	0	0	4	653

Matriz de confusão (2Camadas-30Neurónios) <i>trainlm</i>											
Classe Prevista (1-11)											
Classe Real (1-11)	658	4	0	0	0	0	0	2	0	2	0
	0	659	0	0	0	0	0	0	0	7	0
	0	6	648	6	1	0	0	0	0	2	3
	6	0	0	651	4	1	1	0	0	3	0
	0	1	0	15	650	0	0	0	0	0	0
	0	3	0	0	0	659	0	1	3	0	0
	0	0	0	0	0	12	654	0	0	0	0
	9	1	8	3	12	2	1	609	15	6	0
	0	0	0	1	0	0	0	1	664	0	0
	2	0	0	4	0	0	1	0	0	658	1
	0	0	0	0	0	0	1	0	0	3	662

Matriz de confusão (3Camadas-20Neurónios) *trainlm*

		Classe Prevista (1-11)									
		627	14	1	4	0	4	1	4	0	11
Classe Real (1-11)	31	598	23	7	0	0	5	0	0	2	0
	0	16	632	12	6	0	0	0	0	0	0
	14	0	1	623	21	1	0	3	0	3	0
	0	0	0	26	636	3	0	1	0	0	0
	1	1	6	5	12	615	0	0	26	0	0
	0	0	0	0	0	8	642	0	4	1	11
	20	5	1	11	11	3	2	607	0	6	0
	0	0	1	0	0	3	0	11	651	0	0
	1	3	4	6	0	0	0	2	0	644	6
	0	4	0	1	0	0	6	1	0	10	644

Matriz de confusão (3Camadas-25Neurónios) *trainlm*

		Classe Prevista (1-11)									
		656	3	0	1	0	0	1	3	0	2
Classe Real (1-11)	0	650	10	6	0	0	0	0	0	0	0
	0	0	660	0	0	0	0	0	0	6	0
	3	0	0	659	2	0	0	0	0	1	1
	0	0	0	14	651	0	0	0	0	1	0
	0	0	1	0	0	664	1	0	0	0	0
	0	0	0	0	0	0	665	0	0	0	1
	3	0	1	1	0	2	0	651	0	8	0
	0	0	3	0	0	0	0	0	663	0	0
	1	0	0	0	0	0	0	0	0	664	1
	0	0	0	0	0	0	0	0	0	0	666

Matriz de confusão (2Camadas-20Neurónios) *trainrp*

		Classe Prevista (1-11)									
		600	23	1	16	0	5	2	8	0	11
Classe Real (1-11)	23	554	76	0	0	0	1	0	0	6	6
	0	74	563	6	6	6	1	0	0	10	0
	43	13	2	571	26	5	0	0	6	0	0
	0	1	0	15	650	0	0	0	0	0	0
	0	2	1	0	0	652	0	0	11	0	0
	0	0	0	0	0	12	602	7	0	3	42
	27	0	3	5	14	0	1	592	13	11	0
	1	0	0	0	0	4	0	23	638	0	0
	5	2	0	22	3	5	0	0	1	620	8
	0	0	0	0	0	0	7	0	0	19	640

Matriz de confusão (2Camadas-25Neurónios) *trainrp*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	552	60	0	18	0	1	0	18	0	17	0
	2	22	568	75	0	0	0	0	0	0	1	0
	3	11	130	511	6	6	0	0	0	0	2	0
	4	47	17	14	515	24	7	0	1	10	31	0
	5	4	0	1	24	637	0	0	0	0	0	0
	6	2	0	1	2	0	643	0	0	18	0	0
	7	0	0	0	0	0	12	608	0	0	0	46
	8	30	0	4	6	6	1	0	599	8	12	0
	9	0	0	0	0	0	32	0	12	622	0	0
	10	13	10	5	10	0	1	0	0	1	616	10
	11	6	0	0	0	0	0	30	0	0	37	593

Matriz de confusão (2Camadas-30Neurónios) *trainrp*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	606	22	0	13	5	4	4	6	0	6	0
	2	23	608	34	0	0	0	0	0	0	1	0
	3	3	59	582	9	0	0	4	0	0	9	0
	4	45	22	1	525	2	3	6	7	18	37	0
	5	10	0	0	5	649	0	0	0	0	2	0
	6	0	1	4	0	0	659	0	0	2	0	0
	7	0	0	0	0	0	4	646	0	8	0	8
	8	16	1	5	0	1	2	4	635	0	2	0
	9	0	0	0	0	0	5	0	3	658	0	0
	10	5	0	0	6	0	0	3	0	0	635	17
	11	3	0	0	0	0	0	6	0	0	18	639

Matriz de confusão (3Camadas-20Neurónios) *trainrp*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	605	22	1	7	0	6	0	13	0	12	0
	2	36	570	47	8	0	0	0	0	0	5	0
	3	2	53	583	6	0	13	0	0	0	9	0
	4	64	14	2	524	22	17	0	0	6	11	6
	5	12	0	13	25	616	0	0	0	0	0	0
	6	10	0	0	2	0	647	0	0	7	0	0
	7	0	0	0	0	0	8	646	6	4	0	2
	8	18	0	1	8	13	7	4	606	3	6	0
	9	0	0	0	0	0	0	0	4	661	1	0
	10	3	1	0	21	0	0	0	0	0	640	1
	11	0	0	0	0	0	0	15	0	0	2	649

Matriz de confusão (3Camadas-25Neurónios) *trainrp*

		Classe Prevista (1-11)										
		652	7	0	4	0	1	0	0	0	2	0
Classe Real (1-11)	15	617	34	0	0	0	0	0	0	0	0	0
	0	50	596	6	6	0	0	1	0	7	0	
	30	12	0	608	3	3	0	7	0	3	0	
	0	0	1	29	633	0	3	0	0	0	0	
	2	0	0	0	0	658	0	1	5	0	0	
	0	0	0	0	0	12	645	0	0	0	9	
	21	0	4	9	18	0	2	612	0	0	0	
	0	0	0	0	0	0	0	2	664	0	0	
	8	1	0	0	0	0	4	18	0	627	8	
	0	0	0	0	0	0	0	0	0	12	654	

Matriz de confusão (1Camada-15Neurónios) *trainscg*

		Classe Prevista (1-11)									
		534	64	7	11	1	16	6	9	3	15
Classe Real (1-11)	29	472	159	0	0	0	0	0	0	6	0
	0	76	565	6	6	0	0	1	0	12	0
	47	50	39	396	70	3	1	8	6	46	0
	0	12	1	24	625	4	0	0	0	0	0
	6	7	6	0	12	604	0	0	31	0	0
	1	0	0	0	0	12	592	10	0	2	49
	26	6	4	7	12	3	6	527	51	24	0
	0	0	0	0	0	52	0	17	597	0	0
	4	12	0	21	0	6	22	5	0	556	40
	0	0	0	0	0	0	42	0	0	32	592

Matriz de confusão (1Camada-20 Neurónios) *trainscg*

		Classe Prevista (1-11)									
		553	33	4	9	0	5	8	32	0	21
Classe Real (1-11)	30	556	71	1	0	1	5	0	0	2	0
	1	81	556	9	6	6	0	7	0	0	0
	38	13	14	484	28	14	0	12	2	61	0
	0	0	0	19	628	7	0	0	0	12	0
	11	0	0	0	13	627	0	1	14	0	0
	2	0	0	0	0	10	614	6	2	0	32
	15	1	2	0	2	0	1	610	21	14	0
	0	0	0	0	0	13	0	8	645	0	0
	6	4	2	20	0	0	2	8	0	599	25
	0	9	0	0	0	0	33	0	0	32	592

Matriz de confusão (1Camada-30Neurónios) *trainscg*

		Classe Prevista (1-11)										
		611	32	0	66	10	13	0	30	0	13	0
Classe Real (1-11)	611	24	12	5	0	0	6	2	0	6	0	
	32	545	73	1	0	0	3	0	0	6	6	
	0	65	594	6	0	1	0	0	0	0	0	
	66	22	8	479	18	11	8	32	14	8	0	
	10	0	2	32	620	0	0	0	0	2	0	
	13	1	0	5	3	613	0	0	25	6	0	
	0	0	0	0	0	12	622	0	0	0	32	
	30	2	4	7	18	2	1	574	26	2	0	
	0	0	1	0	0	39	0	21	593	12	0	
	13	1	4	14	2	3	0	0	0	589	40	
	0	0	0	0	0	0	5	0	0	24	637	

Matriz de confusão (2Camadas-20 Neurónios) *trainscg*

		Classe Prevista (1-11)										
		614	16	11	46	16	6	0	27	0	0	13
Classe Real (1-11)	614	23	3	20	0	3	0	3	0	0	0	
	16	584	50	5	2	0	2	0	6	1	0	
	11	30	582	6	6	4	7	12	2	6	0	
	46	19	6	531	14	2	1	8	21	18	0	
	16	0	1	22	627	0	0	0	0	0	0	
	6	0	0	0	0	636	0	0	18	6	0	
	0	0	0	0	0	6	638	0	6	0	16	
	27	1	1	7	0	5	0	618	1	6	0	
	0	0	0	0	0	7	0	2	657	0	0	
	0	0	0	5	0	5	1	0	0	647	8	
	13	0	0	8	0	0	7	0	0	17	621	

Matriz de confusão (2Camadas-25 Neurónios) *trainscg*

		Classe Prevista (1-11)										
		622	16	6	42	2	0	0	13	0	6	0
Classe Real (1-11)	622	9	4	12	0	6	3	0	0	10	0	
	16	595	38	15	0	1	0	0	0	1	0	
	6	52	606	1	0	0	0	0	0	1	0	
	42	8	11	498	40	6	0	14	8	33	6	
	2	6	0	1	653	0	0	0	0	4	0	
	0	0	0	0	0	665	0	0	1	0	0	
	0	0	0	0	0	8	641	0	4	0	13	
	13	0	2	0	4	1	2	628	8	8	0	
	0	0	0	0	0	0	0	7	659	0	0	
	6	1	0	2	0	0	0	0	0	650	7	
	0	0	0	0	0	0	5	0	8	4	649	

Matriz de confusão (2Camadas-30 Neurónios) *trainscg*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	617	7	7	12	0	0	5	4	0	14	0
	2	13	630	22	0	0	0	0	0	0	1	0
	3	0	21	623	12	6	0	0	0	0	4	0
	4	48	8	8	515	8	16	0	6	19	38	0
	5	10	0	0	6	648	2	0	0	0	0	0
	6	16	0	0	0	0	650	0	0	0	0	0
	7	0	0	0	0	0	4	648	0	8	0	6
	8	16	2	1	0	4	4	2	629	8	0	0
	9	0	0	0	0	0	6	0	18	642	0	0
	10	0	12	0	6	0	0	4	8	0	636	0
	11	0	0	0	0	0	0	0	4	0	14	648

Matriz de confusão (3Camadas-20 Neurónios) *trainscg*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	610	18	11	12	1	1	3	0	0	8	2
	2	17	626	11	8	0	0	2	0	0	0	2
	3	0	17	620	9	6	0	0	0	0	8	6
	4	23	4	0	585	10	13	6	8	1	13	3
	5	0	0	0	18	644	0	0	0	0	4	0
	6	0	0	0	0	0	666	0	0	0	0	0
	7	0	0	0	0	0	4	634	0	8	0	20
	8	11	2	1	8	6	3	3	612	2	18	0
	9	0	0	0	0	0	1	0	13	652	0	0
	10	8	1	1	4	0	1	2	5	0	639	5
	11	0	0	0	0	0	0	1	0	0	0	665

Matriz de confusão (3Camadas-25 Neurónios) *trainscg*

		Classe Prevista (1-11)										
		1	2	3	4	5	6	7	8	9	10	11
Classe Real (1-11)	1	597	14	1	22	0	0	5	5	0	20	2
	2	12	642	4	1	0	0	0	0	0	3	4
	3	0	26	624	9	0	0	0	0	0	4	3
	4	5	3	1	647	2	2	0	0	0	6	0
	5	1	0	0	21	639	5	0	0	0	0	0
	6	0	0	0	0	0	659	0	0	7	0	0
	7	0	0	0	0	0	6	636	6	6	0	12
	8	7	0	1	4	0	0	0	654	0	0	0
	9	0	0	0	0	0	6	0	4	656	0	0
	10	0	0	8	2	0	0	1	4	0	647	4
	11	0	0	0	10	0	0	7	0	0	8	641