



CLASSIFICAÇÃO DA FORÇA DE REAÇÃO DO SOLO DURANTE A MARCHA
DE SUJEITOS COM FRATURA DE MEMBRO INFERIOR.

Carlos Alirio Lozano Ortiz

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Biomédica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Biomédica.

Orientadores: Jurandir Nadal

Adriane Mara de Souza Muniz

RIO DE JANEIRO, RJ – BRASIL

NOVEMBRO DE 2010

CLASSIFICAÇÃO DA FORÇA DE REAÇÃO DO SOLO DURANTE A MARCHA
DE SUJEITOS COM FRATURA DE MEMBRO INFERIOR.

Carlos Alirio Lozano Ortiz

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO
ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE
ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO
GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA BIOMÉDICA.

Examinada por:

Prof. Jurandir Nadal, D.Sc.

Profa. Adriane Mara de Souza Muniz, D.Sc.

Prof. Flavio Fonseca Nobre, Ph.D

Prof. Carlos Eduardo Pedreira, Ph.D

RIO DE JANEIRO, RJ – BRASIL

NOVEMBRO DE 2010

Ortiz, Carlos Alirio Lozano

Classificação da força de reação do solo durante a marcha de sujeitos com fratura de membro inferior / Carlos Alirio Lozano Ortiz. – Rio de Janeiro: UFRJ/COPPE, 2010.

XV, 63 p.: il.; 29,7 cm.

Orientadores: Jurandir Nadal

Adriane Mara de Souza Muniz

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Biomédica, 2010.

Referências Bibliográficas: p. 54-60.

1. Componente Vertical da Força de Reação do Solo 2. Análise de Componentes Principais. 3. Redes Neurais Artificiais. 4. Máquinas de Vetores de Suporte. I. Nadal, Jurandir *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Biomédica. III. Título

“A diferença entre um homem de sucesso e outro orientado para o fracasso é que um está aprendendo a errar, enquanto o outro está procurando aprender com os seus próprios erros (Confúcio)”.

Agradecimentos

À vida, porque tem me permitido crescer e alcançar coisas que não imaginava, mostrando-me novos caminhos, novas trilhas, e novos amigos de viagem com os quais posso partilhar sonhos e glórias.

Ao professor Jurandir, por me acolher sem me conhecer, e me apoiar em todo o desenvolvimento desse trabalho.

Aos meus pais, Francisco Alirio e Nhora Cecília, por terem confiado em mim e ensinar-me, desde criança, a necessidade do estudo para ser alguém na vida. Pelos dias que passaram junto a mim, perto ou apenas na lembrança, imprescindíveis para minha formação. Por esses momentos de dificuldades econômicas que, por maiores que foram nunca abalaram o amor de família e a dedicação à mesma.

Ao meu irmão Richard Lozano, amigo, lutador da vida, e incansável trabalhador dos ideais. Nos momentos que precisei de ajuda e conselho sempre se mostrou disponível, e nos momentos que foi necessário partilhar uma tristeza soube como me ajudar a superar. Sempre um exemplo de vida, mostrando que o crescimento não está apenas na academia, mas é construído no esforço e perseverança de cada dia.

À minha mulher, amiga, confidente, companheira de caminhada, Kátia Kelvis. Obrigado por ser essa pessoa especial que sempre você foi e é para mim, por me acompanhar nos momentos difíceis da minha estadia aqui, e por ser um exemplo de superação e de força em todos os momentos. Não agradeço a Deus por me dar a mulher mais linda do mundo, mas por ter me mostrado que é você. Obrigado por me ensinar que esperar não é deixar de fazer, mas é parar para pensar na melhor forma de fazer as coisas.

Aos meus sogros e demais familiares da Kátia, sempre torcendo por minha felicidade e meus êxitos, pelo sucesso e pela história que estou criando junto com a Kátia. Obrigado por me acolherem como filho e abrirem as portas para o intercâmbio cultural.

À turma colombiana, professor Ricardo, César Valencia, Ivanovich, David, Leonardo e muitos mais, que sempre estiveram aqui para escutar as tristezas, melancolias, mas também compartilhar as felicidades, êxitos, avanços e demais coisas que fazem parte do processo de crescimento de uma pessoa fora do país.

Ao professor Flavio Nobre pelos oportunos conselhos e indicações respeito ao trabalho realizado.

À Adriane Muniz, pela co-orientação do trabalho e as informações oportunas referentes ao desenvolvimento desse projeto.

Aos funcionários do PEB, pelo pronto atendimento e ajuda com toda a papelada associada ao fato de ser estudante estrangeiro.

Ao CNPq pelo incentivo à pesquisa e pela bolsa de estudos a mim concedida.

E a todos aqueles que indireta ou diretamente, contribuíram para o crescimento da minha pessoa, tornando-me melhor pessoa e melhor ser humano.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

CLASSIFICAÇÃO DA FORÇA DE REAÇÃO DO SOLO DURANTE A MARCHA
DE SUJEITOS COM FRATURA DE MEMBRO INFERIOR.

Carlos Alirio Lozano Ortiz

Novembro/2010

Orientador: Jurandir Nadal

Adriane Mara de Souza Muniz

Programa: Engenharia Biomédica

O objetivo desse trabalho é avaliar o desempenho de diferentes ferramentas computacionais de reconhecimento de padrões de dados no desenvolvimento de classificadores do padrão de marcha humana e ao avaliar o efeito do tratamento fisioterapêutico em sujeitos com fratura no membro inferior. A base de dados é formada por 38 sujeitos saudáveis (GC) e 13 sujeitos com fratura em um dos membros inferiores (GF), sendo cinco sujeitos deste grupo submetidos a tratamento fisioterapêutico (GFT). Foi utilizada análise de componentes principais (ACP) para reduzir a dimensionalidade dos dados, extrair as características relevantes e eliminar as redundâncias. Redes neurais artificiais (RNA) e máquina de vetores de suporte (MVS) foram utilizadas como ferramentas de classificação. Técnicas estatísticas como acurácia (ACC), área sob a curva ROC (AUC), *bootstrap* e *leave-one-out* foram utilizadas na validação de desempenho dos classificadores. Os melhores resultados foram obtidos com o classificador baseado em rede neural probabilística (RNP), com desempenhos de 96,79% de AUC e 90,19% de ACC, e o classificador SVM com núcleo linear, com 95,12% de AUC e 95,39 de ACC. Na validação do tratamento fisioterapêutico, o classificador RFF foi o mais restritivo. Estes resultados mostram a viabilidade e a potencialidade da aplicação de técnicas de inteligência computacional na classificação de padrão de marcha humana.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

CLASSIFICATION OF GROUND REACTION FORCES DURING GAIT IN
HUMANS WITH LOWER LIMB FRACTURE.

Carlos Alirio Lozano Ortiz

November/2010

Advisor: Jurandir Nadal

Adriane Mara de Souza Muniz

Department: Biomedical Engineering

The aim of this work was applying methods of computational for pattern recognition in the classification of human gait and evaluation of physiotherapeutic treatment. The database contains data of 38 healthy subjects (CG) and 13 subjects with lower limb fracture (FG), being five of them evaluated also after a physiotherapeutic treatment (FGT). Principal component analysis (PCA) was used to retain the main features in database while decreasing the data redundancy. Artificial neural networks (ANN) and support vector machines (SVM) were used as classifiers and clustering data tools. The statistical approaches bootstrap, accuracy (ACC), area under receiver operating characteristic curve (AUC), and leave-one-out theory were employed in the validation of each classifier performance. Better results was obtained with classifiers based on probabilistic neural network (PNN) with 96,79% AUC and 90,19% ACC, and on SVM classifier with linear kernel function, with 95,12% AUC and 95,39% ACC. In treatment validation, RFF was the most restrictive method. These results show the viability and the potentiality of the application of these computational intelligence techniques for pattern recognition in human gait.

SUMÁRIO

	página
CAPÍTULO 1.....	1
Introdução	1
1.1 Objetivos	4
1.2 Organização do trabalho	4
CAPÍTULO 2.....	6
A Marcha Humana	6
2.1 Marcha Humana	6
2.1.1 O ciclo da marcha	7
2.1.2 Força de reação do solo.....	8
2.1.3 Marcha Patológica	10
CAPÍTULO 3.....	12
Fundamentos Teóricos	12
3.1 Análise de Componentes Principais.....	12
3.1.1 Teste <i>Broken Stick</i>	14
3.1.2 Bootstrap	15
3.2 Redes Neurais Artificiais	16
3.2.1 Rede <i>FeedForward</i>	18
3.2.2 Rede Neural Probabilística	21
3.2.3 Máquinas de Vetores de Suporte	24
3.2.4 Topologias de SVM	25
3.2.4.1 SVM Linear	25
3.2.4.2 SVM Polinomial	25
3.2.4.3 SVM com função Gaussiana de base radial (FBR)	26
CAPÍTULO 4.....	27

Materiais e Métodos.....	27
4.1 Amostra.....	27
4.1.1 Aquisição dos dados	28
4.2 Processamento dos Sinais	29
4.2.1 <i>Bootstrap</i>	30
4.3 Classificadores utilizados na identificação do padrão de marcha humana	31
4.3.1 Classificador baseado em <i>rede feed forward</i>	32
4.3.2 Classificador baseado em rede neural probabilística.....	32
4.3.3 Classificador baseado em maquina de vetores de suporte de função núcleo linear	32
4.3.4 Classificador baseado em maquina de vetores de suporte de função núcleo polinomial	32
4.3.5 Treinamento e teste dos classificadores.....	33
4.4 Avaliação do desempenho dos classificadores	33
4.4.1 Acurácia	34
4.4.2 Sensibilidade	34
4.4.3 Especificidade	34
4.4.4 Área abaixo da Curva ROC (AUC)	34
4.5 Validação do tratamento fisioterapêutico	36
4.6 Análise Estatística.....	36
CAPÍTULO 5.....	37
Resultados.....	37
5.1 Análise de Componentes Principais.....	37
5.2 Desempenho dos Classificadores.....	38
5.1.1 Rede <i>feedforward</i>	38
5.2.1 Rede Neural Probabilística	39

5.2.2	Máquina de vetor de suporte linear.....	41
5.2.3	Máquina de vetor de suporte polinomial	42
5.2.4	Classificador SVM FBR	43
5.3	Modelos obtidos para os classificadores baseados em maquinas de vetores de suporte	44
5.4	Análise estatística do desempenho dos classificadores	47
5.5	Validação do tratamento fisioterapêutico com base na classificação ..	48
CAPÍTULO 6.....		49
Discussão		49
CAPÍTULO 7.....		53
Conclusão.....		53
Referências Bibliográficas		54
ANEXO I		61
ANEXO II.....		62
ANEXO III.....		63

LISTA DE FIGURAS

Figura 1. Sete componentes que formam a base da marcha, modelo de causa e efeito. (adaptado VAUGHAN <i>et al.</i> , 1992).	6
Figura 2. Diagrama Esquemático da Marcha Humana. (adaptado de ABERNETHY <i>et al.</i> , 2005)	8
Figura 3. FRSv média de 30 sujeitos normais, normalizada pelo peso corporal. No eixo x, o trecho entre 0 e 100 representa o membro inferior direito e entre 201 e 200 o membro inferior esquerdo. (Base de Dados MUNIZ, 2008).	9
Figura 4. Ciclos de marcha para sujeitos que apresentam padrão de FRSv normal, padrão de FRSv com necrose vascular e padrão de FRSv com osteoartrite (adaptado VAUGHAN <i>et al.</i> , 1992).	10
Figura 5. Representação Geométrica da CP. X1 e X2 definem o espaço de dados; Y1 e Y2 representam as direções sobre as quais se tem a maior variância dos dados e correspondem aos dois componentes principais.	14
Figura 6. Estrutura Geral de uma Rede Neural Artificial	17
Figura 7. Topologia RFF MLP (adaptado de HAYKIN, 1999).....	19
Figura 8. Algoritmo <i>backpropagation</i> : Propagação e Retropropagação	20
Figura 9. Topologia RP (adaptada de DAFENG <i>et al.</i> , 2009).	21
Figura 10. Curva ROC.	35
Figura 11. Teste <i>Broken Stick</i>	37
Figura 12. Diagrama de espalhamento do primeiro e segundo CP. A linha vertical (sólida) que divide os sujeitos normais e lesados é arbitrária.	38
Figura 13. Desempenho do classificador RFF	38
Figura 14. Intervalo de confiança de 95% para o desempenho do classificador RFF quanto ao número de camadas escondidas.....	39
Figura 15 – Desempenho do classificador RNP	40
Figura 16 - Intervalo de confiança de 95% para o desempenho do classificador RNP40	
Figura 17 - Desempenho do classificador SVM linear	41

Figura 18 - Intervalo de confiança de 95% para o desempenho do classificador SVM linear	41
Figura 19 - Desempenho do classificador SVM polinomial.....	42
Figura 20 - Intervalo de confiança de 95% para o desempenho do classificador SVM polinomial	43
Figura 21 - Desempenho do classificador SVM FBR	43
Figura 22 - Intervalo de confiança de 95% para o desempenho do classificador SVM FBR.....	44
Figura 23. Boxplot da distribuição de ACC em cada classificador. O teste de Kruskal-Wallis evidenciou diferença significativa entre os classificadores ($p < 0,001$)....	47
Figura 24. Boxplot para da distribuição de AUC dos classificadores.	48

LISTA DE TABELAS

Tabela 1. Características do grupo com fratura	28
Tabela 2 – Grupos de combinações gerados para 3 CPs	29
Tabela 3. Formação dos dados <i>Bootstrap</i>	30
Tabela 4. Parâmetros dos classificadores.....	31
Tabela 5. ACC segundo parâmetros de cada classificador SVM	45
Tabela 6. AUC segundo parâmetros de cada classificador SVM	45
Tabela 7. Desempenho Geral dos Classificadores	46
Tabela 8. Classificação de sujeitos lesados.....	48

LISTA DE SIGLAS

Sigla	Significado
ACC	Acurácia
PCA	Do inglês <i>principal component analysis</i>
ART-MAP	<i>Adaptative resonance theory map</i>
AUC	<i>Area under the ROC curve</i>
BS	<i>Bootstrap</i>
CPs	Componentes principais
ECG	Electrocardiograma
EEG	Electroencefalograma
FRS	Força de reação do solo
FRSv	Componente vertical da força de reação do solo
GC	Grupo de controle
GF	Grupo de fratura
GFT	Grupo de fratura depois do tratamento (5 sujeitos)
MLP	Do inglês <i>multi layer perceptron</i>
SVM	Do inglês <i>support vector machines</i>
SVM RBF	Do inglês <i>support vector machine – radial basis function</i>
RFF	<i>Rede feed forward</i>
RNA	Rede neural artificial
RNP	Rede neural probabilística
ROC	Do inglês <i>receiver operating characteristic</i>

CAPÍTULO 1

Introdução

René Descartes, no século XVII, definiu o corpo humano como uma máquina movimentada pelo espírito. Os mecanismos dessa máquina começaram a ser esclarecidos nos trabalhos dos renascentistas: Leonardo Da Vinci, que desenhou ossos e músculos diferenciados pela primeira vez em 1504; Giovanni Alfonso Borelli, que apresentou a organização dos músculos e ossos em níveis e demonstrou que durante uma atividade física o quadril e os joelhos podem transmitir forças maiores que o peso do próprio corpo; Galvani, no final do século XVIII, que verificou que os músculos produzem corrente elétrica detectável quando se contraem. Nos anos 1880, Eadweard Muybridge, na América e Etienne-Jules Marey, na França, registraram o mecanismo do movimento com base em sequências fotográficas de atletas e de cavalos (TOZEREN, 2000). No início do século XX, Scherb definiu o padrão da seqüência da ação muscular dos membros inferiores. Também nesta época, Schwartz iniciou estudos sobre as pressões e forças envolvidas com a marcha humana. Em 1940, Nikolai Bernstein apresentou um estudo da coordenação e regulação do movimento humano e a biomecânica foi estabelecida como ciência.

A marcha é a forma natural de locomoção humana, que possibilita deslocamento na posição vertical com pouco dispêndio energético. É uma das mais importantes atividades realizadas pelo homem, envolvendo distintos padrões de movimentos. Cada pessoa executa a marcha de uma maneira característica e única, com pouca variabilidade no dia-a-dia. O padrão característico do movimento humano é estabelecido por estruturas neurológicas complexas e sincronizadas.

A biomecânica estuda o movimento humano sob aspectos mecânicos e anatomo-fisiológicos (PAOLUCCI, 2006). Sob um caráter multidisciplinar e com o objetivo de facilitar o entendimento dos processos envolvidos, utiliza analogias com a teoria das máquinas (sistema de barras, polias, juntas) na representação de elementos da anatomia (HUSTON, 2009).

A identificação das características funcionais da marcha é de grande interesse no campo da biomecânica clínica (SCHÖLLHORN, 2004). A análise da marcha provê a quantificação dos fatores que governam a funcionalidade das extremidades

inferiores, sendo esta informação importante para a detecção de alterações nos padrões, identificação de fatores de equilíbrio e análise dos resultados obtidos por intervenções clínicas, programas de reabilitação e tratamento fisioterapêuticos (LAI *et al.*, 2008). O conhecimento das características das fases da marcha permite analisar qualitativamente o padrão de marcha apresentado por um indivíduo.

A análise da marcha fornece dados que auxiliam médicos e fisioterapeutas na compreensão do mecanismo fisiopatológico inicial, no direcionamento do tratamento e no planejamento cirúrgico e terapêutico em pacientes com distúrbios de locomoção (SIMON, 2004). Enquanto pesquisa clínica, a análise atua na compreensão dos mecanismos envolvidos na marcha normal e na marcha em condições patológicas, na tomada de decisão terapêutica e na avaliação pós-tratamento.

A força de reação do solo (FRS) é uma variável que contém informações quantitativas das características da marcha, as quais refletem os efeitos das forças internas e externas durante a locomoção (ROMEI *et al.*, 2004) e possibilita a identificação de alterações no padrão de movimento.

Diversas técnicas de reconhecimento de padrões têm sido exploradas na análise da marcha humana: redes neurais artificiais (RNA), máquinas de vetores de suporte (SVM), regressão logística, análise de componentes principais, agrupamento de dados por similaridade (LEE *et al.*, 2000; OZA e TUMER, 2008; YOO *et al.*, 2008).

É importante realizar estudos que utilizem diferentes técnicas de processamento e de representação dos padrões de entrada como forma de avaliar o desempenho dos diferentes métodos de classificação de padrão de dados. A decisão quanto ao uso de determinada técnica deve considerar o desempenho da mesma e índices devem ser adotados para mensurá-lo (KOHLE e MERKL, 1997). LEVINGER *et al.* (2009) utilizaram SVM para separar o padrão de marcha de indivíduos com osteoartrite e indivíduos saudáveis, baseados em parâmetros espaço-temporais, com acurácia de 100% para o grupo de treinamento e 88,89% para o grupo de teste. No mesmo estudo, essa ferramenta computacional foi utilizada para prever o padrão de marcha após cirurgia de joelho.

CHEN *et al.*, (2008), apresentaram resultados experimentais eficientes e robustos na identificação de padrão de marcha normal e anormal utilizando SVM.

Resultados de 91% de sucesso na classificação de eventos de marcha foram obtidos com aplicação de SVM (HUANG *et al.*, 2007).

BEGG e KAMRUZZAMAN (2005) apresentaram resultados que indicam a SVM como melhor classificador de padrões de marcha entre pessoas idosas e pessoas jovens, com menor tempo de processamento comparado com os classificadores baseados em RNA. SVM permitiu detecção de características espaço-temporais e mostrou-se suficientemente sensível para distinguir entre sujeitos com osteoartrite e normais (LEVINGER *et al.*, 2009).

A utilização de SVM apresentou acurácia de 89% no reconhecimento de padrões afetados pela síndrome patelofemoral de dor (LAI *et al.*, 2008).

As RNA têm sido aplicadas em pesquisas das áreas de engenharia aeroespacial, automobilística, eletrônica, manufatura, petróleo e gás, robótica, telecomunicações e em outras áreas do saber. Na medicina, viabilizam a análise de sinais eletroencefalograma (EEG) e eletrocardiograma (ECG), o desenvolvimento de próteses (HAGAN *et al.*, 1996) e a classificação de padrões de marcha humana (MUNIZ *et al.*, 2008, DHANALAKSHMI *et al.*, 2009, CHAU, 2001).

Em estudos anteriores realizados no Programa de Engenharia Biomédica da COPPE/UFRJ, MUNIZ e NADAL (2009) utilizaram análise de componentes principais e o componente vertical da FRS para classificar sujeitos normais e sujeitos com fratura do membro inferior, com base no padrão de marcha, propondo um índice baseado na distância de Mahalanobis para avaliação do efeito de tratamentos de fisioterapia nos sujeitos que sofreram lesões. Métodos de inteligência computacional, incluindo modelos de RNA e SVM foram aplicados com sucesso na classificação de padrões de sujeitos normais e com doença de Parkinson, com e sem tratamento (MUNIZ *et al.*, 2010). Técnicas estatísticas de *bootstrap* foram empregadas para a escolha do melhor modelo com base na área sob a curva (AUC) característica do receptor (ROC) e na máxima verossimilhança.

O presente trabalho tem como base o estudo de algoritmos de classificação e técnicas de processamento digital de sinais para o desenvolvimento de ferramentas computacionais de reconhecimento e classificação de padrões de marcha humana. A importância do estudo está associada à capacidade de desenvolver uma sistemática de avaliação dos tratamentos fisioterapêuticos e identificação de anormalidades.

1.1 Objetivos

O objetivo geral deste estudo é avaliar o desempenho de redes neurais artificiais e máquinas de vetores de suporte na classificação do padrão de marcha humana e na validação do tratamento fisioterapêutico de sujeitos com fratura no membro inferior.

Para cumprir o objetivo geral, foram definidos os seguintes objetivos específicos:

- Utilizar redes neurais artificiais e máquinas de vetores de suporte como ferramentas de classificação de padrões de FRS.
- Estudar e aplicar a técnica *bootstrap* no processo de validação das ferramentas de classificação.
- Comparar os resultados obtidos nos classificadores, por meio dos indicadores de desempenho - acurácia e área abaixo da curva ROC.
- Validar um modelo de classificação, de desempenho ótimo, com base na combinação de técnicas de inteligência computacional e estatísticas.
- Verificar os efeitos do tratamento fisioterapêutico com base na classificação final do padrão de marcha apresentado por sujeitos com fratura do membro inferior submetidos à fisioterapia.

1.2 Organização do trabalho

O Capítulo 2 contempla uma breve descrição de conceitos sobre a marcha humana.

O Capítulo 3 apresenta as ferramentas computacionais utilizados no presente trabalho (redes neurais artificiais e máquinas de vetores de suporte) e as técnicas de manipulação dos dados de entrada nos classificadores (análise de componentes principais, e *bootstrap*);

O Capítulo 4 descreve a base de dados, apresentando as características dos sujeitos que a compõe, o protocolo de aquisição dos dados, os métodos utilizados na implementação e os indicadores de desempenho utilizados na validação dos classificadores.

O Capítulo 5 apresenta os resultados obtidos pelos classificadores.

O Capítulo 6 apresenta a discussão dos resultados, e por fim, tem-se as conclusões do trabalho realizado no Capítulo 7.

CAPÍTULO 2

A Marcha Humana

Nesse capítulo é apresentada a revisão bibliográfica sobre a marcha humana e as variáveis fisiológicas associadas.

2.1 Marcha Humana

Uma característica marcante dos animais é sua capacidade de locomoção, que lhe permite percorrer um espaço geográfico, usufruindo o exercício da liberdade e da autonomia. A locomoção bípede é uma das principais características que distinguem o ser humano dos outros animais.

A marcha humana pode ser definida como um processo de locomoção, no qual o corpo se desloca de uma posição para outra pelo movimento rítmico e alternado do tronco e das extremidades (VAUGHAN *et al.*, 1992).

Os mecanismos de locomoção ocorrem nos centros supra-espinhais e envolvem a conversão de uma intenção de movimento em um padrão de atividade muscular necessária para a realização da marcha. A interação entre o sistema nervoso central, o sistema nervoso periférico e o sistema músculo-esquelético efetor é apresentada na Figura 1 (VAUGHAN *et al.*, 1992).

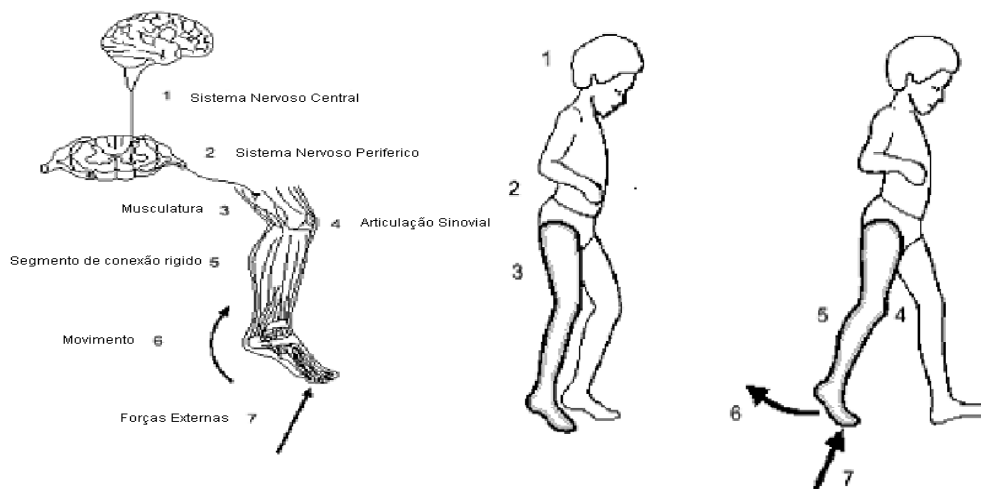


Figura 1. Sete componentes que formam a base da marcha, modelo de causa e efeito. (adaptado VAUGHAN *et al.*, 1992).

O ato de andar depende, basicamente, de dois processos principais: movimentos periódicos de cada pé, de uma posição inicial de apoio até a próxima posição de apoio do mesmo pé e das forças de reação do solo.

Sete eventos são necessários para a ocorrência da marcha humana: (1) registro e ativação do comando de marcha no sistema nervoso central, (2) transmissão dos sinais de marcha ao sistema nervoso periférico, (3) contração dos músculos que produzem tensão, (4) geração de forças e momentos nas articulações sinoviais, (5) regularização das forças e momentos aplicados nas articulações pela antropometria dos segmentos rígidos, (6) deslocamento dos segmentos de tal forma que são reconhecidos como marcha funcional, (7) geração de forças de reação do solo.

O modelo de causa e efeito considera a marcha como um processo de coordenação neural e colaboração dos sistemas nervoso e músculo-esquelético para alcançar uma dinâmica correta, com manutenção do equilíbrio corporal em uma pequena base de suporte (LAI *et al.*, 2008).

Esse modelo de locomoção pode ser empregado para identificar patologias e determinar métodos de tratamento, auxiliando no processo de tomada de decisão, quando do estudo da marcha humana (VAUGHAN *et al.*, 1992).

2.1.1 O ciclo da marcha

O ciclo normal de marcha é dividido em duas fases: apoio e balanço (Figura 2). A fase de apoio inicia-se no instante em que uma extremidade entra em contato com o solo e termina quando o pé deixa o solo. Esta fase corresponde a aproximadamente 60% do ciclo de locomoção. A fase de balanço inicia quando o membro inferior descola do solo e termina antes de o mesmo ter contato novamente com o solo. Esta fase constitui cerca de 40% do ciclo de marcha. A fase de apoio pode ainda se subdividir em três fases: primeiro duplo apoio, apoio simples, e segundo duplo apoio. A fase de balanço também se divide em três: balanço inicial, balanço médio e balanço terminal (ABERNETHY *et al.*, 2005).




Figura 2. Diagrama Esquemático da Marcha Humana. (adaptado de ABERNETHY *et al.*, 2005)

2.1.2 Força de reação do solo

Durante a fase de apoio, o peso corporal atua sobre o pé de suporte, gerando forças verticais, horizontais e rotatórias de reação do solo. A força de reação do solo (FRS) é uma força que atua do solo para o corpo que está em contato, representando uma resposta às ações musculares e ao peso corporal transmitido por meio dos pés (MUNIZ, 2010; VAUGHAN *et al.*, 1992). A FRS tem a mesma magnitude e direção, mas sentido oposto à força que o corpo exerce na superfície do solo, obedecendo, portanto, à terceira lei de Newton (MUNIZ, 2008).

O componente vertical da força de reação do solo (FRS_v) é decorrente do peso corporal e de qualquer aceleração ou desaceleração que atuam no corpo. Essa componente é necessária para se contrapor à ação da gravidade, para manter a altura do centro de massa acima da superfície de contato (MUNIZ, 2008).

A curva característica do componente vertical da força de reação do solo (Figura 3) em função do tempo possui dois picos e um vale. O primeiro pico, observado durante a primeira metade do período de apoio e caracteriza parte do apoio quando a perna está recebendo o peso corporal, logo após o contato do pé com o solo. O segundo pico é observado no final do período de apoio e representa a propulsão do

antepé à frente, para iniciar o próximo passo. Esse pico é ativo, envolvendo a participação de ações voluntárias. O vale entre os dois picos corresponde à etapa de balanço do pé contralateral, sendo que o valor mínimo ocorre quando o pé se encontra na posição plana em relação ao solo, (RAZUL K. BEGG e SYED M RAHMAN, 2000; FEI WANG *et al.*, 2007; MUNIZ e NADAL, 2010), no período de apoio simples (WINTER, 1991). O vale indica a capacidade do sistema motor em responder ao impacto no início do apoio através da ação muscular da perna de apoio e da influência da dinâmica da perna de balanço




Figura 3. FRSv média de 30 sujeitos normais, normalizada pelo peso corporal. No eixo x, o trecho entre 0 e 100 representa o membro inferior direito e entre 201 e 200 o membro inferior esquerdo. (Base de Dados MUNIZ, 2008).

Em um ciclo de marcha normal tem-se uma simetria natural entre os lados direito e esquerdo, enquanto em marchas patológicas tem-se a presença de padrões assimétricos (Figura 4).




Figura 4. Ciclos de marcha para sujeitos que apresentam padrão de FRSv normal, padrão de FRSv com necrose vascular e padrão de FRSv com osteoartrite (adaptado VAUGHAN *et al.*, 1992).

2.1.3 Marcha Patológica

O padrão de marcha humana consolida-se com o tempo, a aprendizagem e a maturidade dos sistemas compensatórios da estabilidade. Por volta dos cinco anos de idade, período no qual o sistema sensorio-motor torna-se capaz de gerar um conjunto repetitivo de comandos sem esforço consciente, a marcha humana assume um padrão característico (ESTRÁZULAS *et al.*, 2005, VAUGHAN *et al.*, 1992).

Nos adultos, o padrão de marcha é bem definido, embora possa se alterar por problemas neurológicos ou lesões musculares e ósseas. A fratura óssea pode ser causada por sobrecarga, trauma, degeneração, fadiga ou alguma doença. A fratura devida a sobrecarga ocorre quando o osso é submetido a cargas superiores à força máxima que o mesmo suporta. As fraturas causadas por fadiga ocorrem quando forças com frequências e amplitudes maiores das que o osso pode suportar, são repetidamente aplicadas (HUSTON, 2009). Outros tipos de fratura, causadas por osteoporose, ocorrem quando o conteúdo mineral dos ossos decresce, alterando a geometria e a capacidade elástica do osso (HUSTON, 2009).

Pelo menos 20% dos idosos apresentam dificuldades para caminhar, necessitando de ajuda de outra pessoa ou de equipamentos específicos (HAUSDORFF

e ALEXANDER, 2005). De modo geral, uma das maiores limitações é a queda ou o medo desta, implicando na diminuição de atividades com perda da função muscular, do tecido articular e do processamento da informação (ESTRÁZULAS *et al.*, 2005). Essas alterações são percebidas nas mudanças de velocidade da marcha, no tamanho dos passos e no tempo entre os eventos necessários para a ocorrência da marcha (BEGG e KAMRUZZAMAN, 2005a, WINTER, 1991).

Em virtude dos diversos fatores que governam a marcha patológica, faz-se necessário o uso de ferramentas de alto desempenho para caracterizar o padrão apresentado por determinado indivíduo.

CAPÍTULO 3

Fundamentos Teóricos

Nesse capítulo serão apresentadas as ferramentas estatísticas utilizados na preparação dos dados de entrada - Análise de Componentes Principais e *Bootstrap* e as ferramentas computacionais utilizadas para reconhecimento do padrão de marcha humana - Redes Neurais Artificiais e Máquinas de Vetores de Suporte.

3.1 Análise de Componentes Principais

Análise de componentes principais (PCA) é uma técnica de análise multivariada, introduzida por Pearson em 1901 e desenvolvida formalmente por Hotelling em 1933 (JOLLIFFE, 2002). Essa técnica é utilizada para reduzir a dimensionalidade de um conjunto de dados, composto por variáveis fortemente correlacionadas, e maximizar a representação da variabilidade deste (JOLLIFFE, 2002).

Os componentes principais (CPs) não são correlacionados entre si e, portanto essa técnica tem como ganho adicional eliminar a redundância existente nos dados originais, conservando grande parte da variância total (JOLLIFFE, 2002). É possível selecionar os CPs que retenham o máximo possível da informação contida nas variáveis originais, restringindo o foco de análise e tornando o processo de classificação mais eficiente (CHEN *et al.*, 2008). A importância de um componente principal é avaliada por meio de sua contribuição, isto é, pela proporção de variância total explicada por ele. Alguns CPs variam muito pouco relativamente a outras, e, nestes casos, pode-se descartar as dimensões de menor variância, sem comprometer substancialmente a qualidade dos dados. Geralmente, grande parte da variância dos dados é explicada por um número reduzido de componentes.

Na forma algébrica, a PCA pode ser expressa pela combinação linear das variáveis originais (Equação 1).

$$\begin{aligned}
y_1 &= a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \\
y_2 &= a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n
\end{aligned}
\tag{1}$$

$$y_n = a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n$$

onde: a_{nn} é o vetor de autovalores (expressam a variância dos n componentes principais) e x_n são os dados de entrada. Neste novo conjunto y_1 , ou primeiro componente principal (CP), é orientado na direção de maior variância dos dados originais. O segundo CP (y_2) é ortogonal ao primeiro, e maximiza a representação da variância residual. Portanto, pode-se reter k CPs que permitam explicar quase toda a variância dos dados, sendo $k \ll n$ (JOLLIFFE, 2002). O valor de k é obtido por meio de testes, destacando-se o Teste *Broken Stick* (JOLLIFFE, 2002).

A proporção da variância total de X , representada pela k – ésima CP é dada por:

$$V(Y_k) = \sum_{k=1}^K \lambda_k \tag{2}$$

onde: $i = 1, 2, \dots, k$; e λ_k são as variâncias parciais tomadas em ordem decrescente.

Geometricamente, os componentes principais são representados por um sistema de coordenadas, obtido por meio da rotação do sistema de coordenadas originais, sendo que os novos eixos são ortogonais entre si e representam as direções com variabilidade máxima (DELUZIO *et al.*, 1997). A projeção ortogonal minimiza o erro de aproximação.

Na Figura 5 tem-se a representação geométrica da PCA em um plano bidimensional.




Figura 5. Representação Geométrica da CP. X1 e X2 definem o espaço de dados; Y1 e Y2 representam as direções sobre as quais se tem a maior variância dos dados e correspondem aos dois componentes principais.

3.1.1 Teste *Broken Stick*

Trata-se de um teste estatístico que observa as variâncias individuais de cada componente, baseado em autovalores de uma variável aleatória (JACKSON, 2003). Se a variância total (soma de todos os autovalores) de um conjunto de dados multivariados é dividida aleatoriamente entre os vários componentes, a distribuição esperada dos autovalores seguirá a distribuição *broken stick*.

A proporção de variância associada ao k -ésimo componente principal, no modelo *broken stick*, é dado por:

$$b_k = \frac{1}{p} \sum_{i=k}^p \frac{1}{i} \quad (3)$$

onde: p é o número de variáveis

Uma forma de decidir a proporção de variância a ser retida é comparar a proporção de b_k com a variância do componente principal y_k (λ_k Componentes principais que apresentam λ_k maior que b_k são retidos na análise e os demais eliminados (JACKSON, 2003).

3.1.2 Bootstrap

A técnica de *bootstrap* (BS) foi introduzida em 1979 como uma técnica computacional que estima o erro padrão $\hat{\theta}$ (EFRON E TIBISHARINI, 1997) de um conjunto amostral de variância. É uma técnica estatística não paramétrica, que utiliza a inferência sem considerar modelos paramétricos para uma distribuição populacional (CHERNIK e FRISS, 2003) e é uma ferramenta de re-amostragem como *validação cruzada* e o *Jackknifing* (HAMAMOTO *et al.*, 1997).

A técnica de *bootstrap* tenta realizar o que seria desejável realizar na prática, se tal fosse possível: repetir a experiência. As observações são escolhidas de forma aleatória e as estimativas recalculadas. Uma vez que não se dispõe de toda população (observações), a técnica BS faz o melhor com o que está disponível – as amostras.

O algoritmo proposto por EFRON e TIBISHARINI (1997) estima o erro padrão ($\hat{\theta} = s(x)$) de um conjunto x de tamanho amostral n :

1. Seleciona-se B amostras (BS) independentes $x^{*1}, x^{*2}, \dots, x^{*B}$, cada uma constituída de n valores gerados com base na escolha aleatória de x .
2. Valida-se as réplicas BS correspondentes às amostras BS.

$$\hat{\theta} = s(x^b) \quad b = 1, 2, \dots, B; \quad (4)$$

onde B são as amostras BS independentes.

3. Estima-se o erro padrão $se_F(\hat{\theta})$ pelo desvio padrão amostral das réplicas

$$se_B = \left\{ \sum_{b=1}^B \frac{[\hat{\theta}(b) - \hat{\theta}(\cdot)]^2}{B-1} \right\}^{1/2} \quad (5)$$

onde:

$$\hat{\theta}(\cdot) = \sum_{b=1}^B \frac{\hat{\theta}(b)}{B}$$

A estimativa ideal do BS (se_∞) indica um $B = \infty$; no entanto, o tempo de computação para validar as réplicas BS cresce linearmente com B.

A equação 6 apresenta o cálculo de estimativa do erro para o estimador .632+ (EFRON E TIBISHARINI, 1997).

$$\hat{Err}^{(.632+)} = \hat{Err}^{(.632)} + (\hat{Err}^{(1)} - \overline{err}) * \frac{.368 * .632 * \hat{R}}{1 - \hat{R}} \quad (6)$$

onde $\hat{Err}^{(1)}$ é a estimativa do erro para a amostra *bootstrap* que não contém o elemento da amostra retida pela técnica *leave-one-out*; \overline{err} é o erro esperado; \hat{R} é a taxa relativa de *overfitting*, medindo o grau de especialização da técnica *bootstrap*; e os coeficientes .368 ($e^{-1} = .368$) e .632 foram sugeridos empiricamente, dado que as amostras *BS* são baseadas em aproximadamente 63,2% dos dados originais.

$\hat{Err}^{(.632)}$ foi proposto para corrigir o erro de tendências das estimativas de variância do conjunto amostral. A regra .632+ deu maior importância ao $\hat{Err}^{(1)}$ em situações nas quais a diferença entre $\hat{Err}^{(1)}$ e \overline{err} é grande (EFRON E TIBISHARINI, 1997).

O sucesso do BS depende da técnica de reamostragem utilizada e essa decisão deve se basear na análise qualitativa dos dados disponíveis e no conhecimento do problema que se quer tratar (ZOUBIR e ISKANDER, 2007).

3.2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são modelos computacionais com capacidade de aprendizado e adaptação, podendo ser utilizadas para reconhecimento, classificação e organização de dados complexos, multivariados e não lineares (HAYKIN, 1999).

As redes neurais mimetizam o comportamento do sistema nervoso, tanto que a unidade de processamento da rede é denominada neurônio (KOHOLE *et al.*, 1997, HAYKIN, 1999).

Assim como no cérebro, os neurônios são agrupados em redes e cada neurônio recebe entradas que correspondem à excitação ou inibição de outros neurônios. Quando a rede excitada alcança um nível programado, o neurônio “dispara” (disparar, neste contexto significa propagar estímulos). O neurônio é binário no modo de funcionamento; portanto, ou ele dispara ou não dispara (HAYKIN, 1999).

A estrutura geral de uma RNA é apresentada na Figura 6.

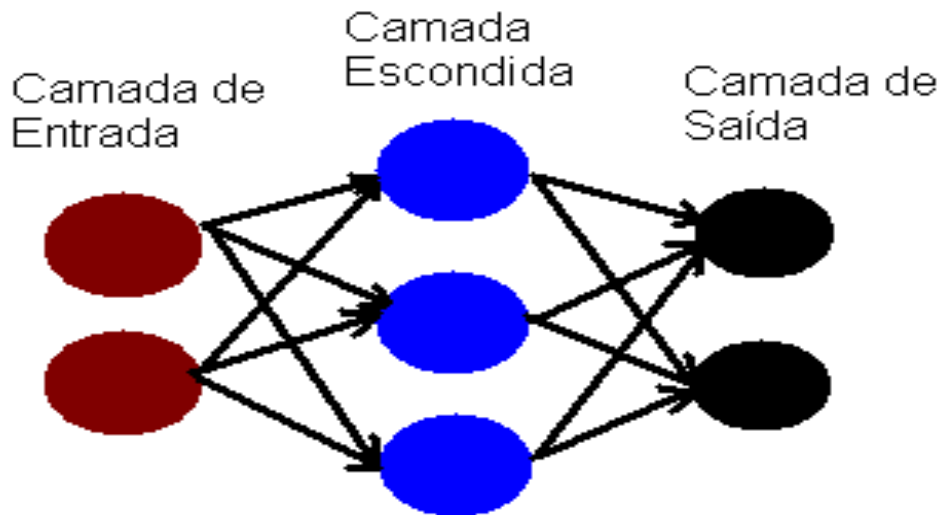


Figura 6. Estrutura Geral de uma Rede Neural Artificial

O conjunto de dados é apresentado à camada de entrada. A camada escondida é responsável pelo processamento e captura das características principais dos dados de entrada. O resultado do processamento dos dados pela rede é apresentado na camada de saída.

As funções neurais, tais como memória, são salvas nos neurônios e nas regiões de conexão entre eles (sinapses). O aprendizado é visto como a existência de novas conexões entre os neurônios ou modificações das conexões existentes (HAGAN *et al.*, 1996).

Nos anos 40, Warren McCulloch e Walter Pitts apresentaram as redes neurais, mostrando a sua capacidade de executar funções lógicas e aritméticas. No entanto, a primeira aplicação de RNA ocorreu nos anos 50, quando Frank Rosenblatt e seu grupo demonstraram a capacidade destas no reconhecimento de padrões, com base em uma genuína rede de múltiplos neurônios do tipo discriminadores lineares, denominada perceptron (HAGAN *et al.*, 1996).

Apesar do crescente uso dessa ferramenta computacional, ainda há muitos desafios e, portanto, a justificativa da utilização de RNA e outros métodos de classificação devem considerar a capacidade de aprendizado, a generalização e o desempenho em relação a métodos tradicionais para resolver problemas do mundo real (CLOETE e ZURADA, 2000). Alguns critérios devem ser observados:

- A definição da topologia de rede (*feed forward*, *Self Organized Maps* (SOM), *Adaptive Resonance Theory* (ART-MAP), logística), a qual altera o desempenho do classificador e pode influenciar na resposta da rede.
- O processamento é dependente da quantidade de neurônios que compõem a rede. Muitos neurônios podem gerar superespecialização da rede ao padrão de dados de entrada, enquanto poucos neurônios acarretam sobrecarga de processamento.
- O padrão de dados de entrada deve ser escolhido de forma que seja altamente representativo dos dados originais. Para redes de treinamento supervisionado, o processo de treinamento deve impedir a super especialização da rede (perde-se a capacidade de generalizar um padrão). Deve-se garantir que o processo de treinamento possibilite à rede reconhecer as características do padrão de dados de entrada e não os dados propriamente ditos.
- O processo de treinamento deve convergir ao aprendizado, respondendo eficientemente ao padrão de dados de entrada. Logo, algoritmos de minimização do erro de aprendizado devem ser utilizados.
- No treinamento supervisionado, critérios devem ser estabelecidos para escolha dos grupos (treinamento, validação e testes da rede), definição da quantidade de ciclos de treinamento e para a análise de desempenho.

3.2.1 Rede *FeedForward*

Uma RNA do tipo *feed forward* (RFF) consiste em um grupo de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. O sinal de entrada é propagado da camada de entrada até a camada de saída. Essa topologia de rede é comumente nomeada *multi layer perceptrons* (MLP), uma generalização da *single layer perceptrons* (HAYKIN, 1999) (Figura 7).




Figura 7. Topologia RFF MLP (adaptado de HAYKIN, 1999)

A rede MLP tem uma ou mais camadas de neurônios escondidas, que não são parte nem da entrada nem da saída da rede. Esses neurônios escondidos permitem à rede aprender tarefas complexas extraíndo, em cada iteração do processo de aprendizado, a informação mais relevante dos padrões de entrada.

A escolha aleatória dos dados para treinamento preconiza que a rede possa aprender com as características dos dados de entrada e não com os dados em si, ou seja, garante-se menor especialização ao padrão de entrada (HAYKIN, 1999).

A consequência direta da utilização de várias camadas escondidas na rede é o aumento do espaço de padrões que a rede pode representar. Por isto compreende-se que a rede MLP apresenta um processamento dinâmico (TORRES, 2008).

A MLP é utilizada com sucesso para a solução de diversos problemas matemáticos e aritméticos, sendo o treinamento realizado com o algoritmo com retropropagação de erro, conhecido como *backpropagation* (HAYKIN, 1999), cujo princípio é utilizar o gradiente descendente e estimar o erro das camadas intermediárias pela estimativa do resultado encontrado no erro da camada de saída

O *backpropagation* é um tipo de algoritmo supervisionado que utiliza pares de entrada e saída da rede para, por meio de um mecanismo de correção de erros, ajustarem os pesos da rede. Este algoritmo apresenta duas partes:

1. Propagação: depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde é obtida a resposta da rede e o erro é calculado;
2. Retro propagação do erro: desde a camada de saída até a camada de entrada, são feitas alterações nos pesos sinápticos.

A Figura 8 apresenta a estrutura do algoritmo *backpropagation*.

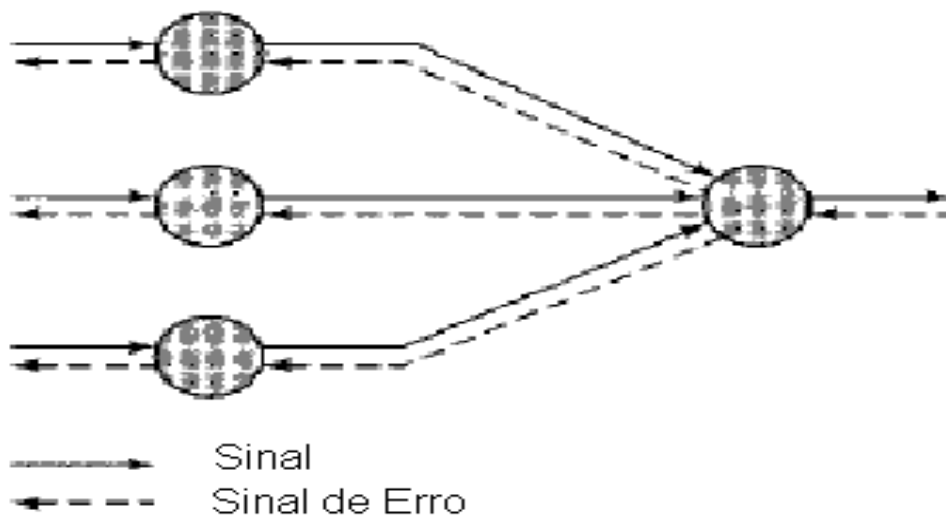


Figura 8. Algoritmo *backpropagation*: Propagação e Retropropagação

Durante a fase treinamento da rede, é apresentado um par de dados: valor de entrada para a rede e valor desejado para resposta a entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retropropagação. Apesar de não haver garantias de que a rede forneça uma solução ótima para o problema, este processo é muito utilizado por apresentar uma boa solução para o treinamento de MLPs.

O erro da saída da rede é calculado, sendo retroalimentado para as camadas intermediárias, possibilitando o ajuste desses pesos. O erro utilizado para computar os valores dos erros das camadas anteriores e fazer as correções necessárias nos pesos sinápticos.é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (7)$$

onde: $d_j(n)$ é a saída desejada e $y_j(n)$ é a resposta obtida, na iteração n e neurônio j

O algoritmo *backpropagation* é consideravelmente simples, uma vez que os pesos são atualizados com base no padrão existente até um número de épocas (quantidade de iterações) que for necessário para alcançar um nível requerido, (por exemplo, erro máximo, erro mínimo, tempo de treinamento) e os ajustes são realizados em concordância com os erros computados para cada padrão apresentados à rede.

As redes MLP têm um potencial computacional maior que os *perceptrons* de uma camada, por permitirem tratar dados não linearmente separáveis. A quantidade de camadas da rede define a potencialidade de processamento da rede

3.2.2 Rede Neural Probabilística

É uma RNA com topologia *feed forward*, de aprendizado supervisionado, que utiliza na camada escondida função de base radial (DAFENG *et al.*, 2009) (Figura 9).

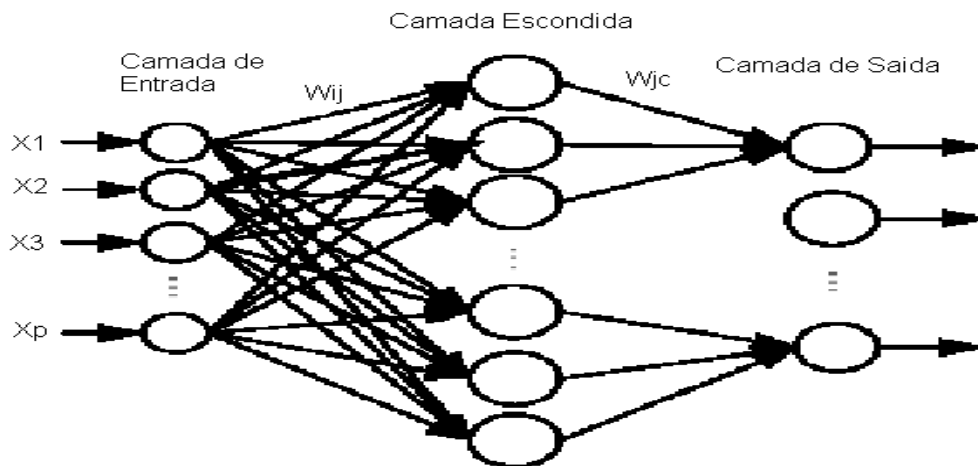


Figura 9. Topologia RP (adaptada de DAFENG *et al.*, 2009).

A vantagem desse tipo de rede é o tempo de treinamento reduzido em relação à rede feedforward. A quantidade de elementos na camada de entrada é igual ao número de parâmetros ou variáveis utilizados para descrever os objetos a serem

classificados. Na camada de saída, a quantidade de neurônios é a mesma do número das classes a serem reconhecidas.

A primeira camada contém os nós de entrada, que correspondem às variáveis explicativas. Cada nó apresenta um componente do vetor X do padrão de treinamento por vez. Esta camada tem como papel simplesmente prover os dados de entrada aos neurônios da camada seguinte, ou camada padrão.

Cada unidade da camada padrão armazena um vetor do conjunto de treinamento, assim como a sua verdadeira classe. As conexões que comunicam os nós na camada de entrada com os neurônios de padrões na camada imediatamente seguinte são ponderadas por pesos sinápticos, de tal forma que, a cada neurônio i da camada de unidades de padrão existe um vetor de pesos W a ele associado.

Uma característica importante dessa rede é que o vetor de pesos não sofre alteração ao longo do processo de treinamento. De uma forma geral, no treinamento de uma RNP, para cada entrada apresentada à rede, calculam-se as distâncias entre o padrão apresentado e o padrão esperado. Cada unidade da camada padrão aplica essa distância à função de ativação. A função de ativação de cada neurônio da camada padrão substitui a função sigmoideal clássica por uma exponencial (SPECH, 1992):

$$g(Z_i) = \exp\left[-\frac{(x_i - y)'(x_i - y)}{2\sigma^2}\right] \quad (8)$$

onde σ é o desvio padrão da variável de entrada, x_i é o valor apresentado e y é o valor.

Os resultados $g(Z_i)$ são somados e enviados às unidades de saída, que irá comparar os resultados recebidos e decidir por alocar x em uma das classes possíveis.

Logo, assume-se que as variáveis de entrada têm distribuição Gaussiana e utiliza-se a regra de Bayes para a determinação de funções não lineares de separação usando probabilidades à priori, estimadas a partir da frequência relativa dos eventos de entrada (SPECH, 1992).

A unidade de soma simplesmente soma as entradas da unidade padrão, a qual corresponde à categoria em que o padrão de treinamento foi selecionado.

As saídas relativas a cada padrão de entrada são somadas, de modo a estimar a função densidade não-normalizada $g_l(y)$, para cada classe l (normal/lesado). Assim, a probabilidade de um vetor de entrada y pertencer à classe l é dada por:

$$P(y \in l) = \frac{g_l(y)}{\sum_{i=1}^L g_i(y)} \quad (9)$$

onde L é o número de classes (L = 2).

As unidades de saída da RNP adotam o modelo do algoritmo competitivo “*winner takes all*”: dados r unidades de saída, apenas aquela de maior probabilidade é ativada com o valor unitário, e r-1 unidades de saída terão valor zero (DAFENG *et al.*, 2009).

Portanto, as unidades de saída são neurônios binários ativados segundo um critério de decisão baseado na equação:

$$\text{Probabilidade } P_c = \frac{U_L}{\sum W_{jL}} = \frac{1}{\sum W_{jL}} * \sum W_{jL} \quad (10)$$

tendo como resultado $Y = \text{Max}(P_c)$, $L = 1, 2, 3, \dots, r$. Quando a probabilidade é igual a 1 tem-se a ativação do neurônio (DAFENG *et al.*, 2009).

A característica principal das RNPs é a habilidade de explorar a estrutura da rede e reduzir o cálculo (da probabilidade condicional de um evento, dada a evidência disponível) a uma série de cálculos locais, usando somente variáveis obtidas de um nó e seus vizinhos em uma estrutura de rede, evitando calcular a função de distribuição de probabilidades conjunta global.

O processo de aprendizado de uma RNP é mais rápido que uma *feed forward* convencional em problemas onde a adaptação incremental do tempo de retropropagação é uma fração significativa do tempo total de computação (SPECH, 1990). A RNP apresenta grande habilidade de generalização, porém requer neurônios para cada padrão de treinamento (SPECH, 1992) e isso pode significar maior exigência de armazenamento no treinamento de parâmetros desconhecidos (SPECH, 1990).

3.2.3 Máquinas de Vetores de Suporte

Máquina de vetores de suporte (SVM) é um método de grande interesse para a modelagem de sistemas complexos (WANG, 2005), apresentando boa generalização em problemas de classificação de padrões (HAYKIN, 1999).

No processo de classificação, são utilizadas funções de decisão (núcleo Kernel), as quais mapeiam dados de entrada de um espaço \mathbf{x} m -dimensional em um espaço de características \mathbf{z} l -dimensional, classificando os dados com base em um hiperplano de separação ótimo (WANG, 2005).

Para um vetor \mathbf{x} , representado no espaço de entradas de dimensão m_0 , o termo m_l é a dimensão do espaço de características $\varphi_j(\mathbf{x})$, que representa um grupo de transformações não lineares as quais definem um hiperplano de separação conforme a expressão:

$$f(x) = (w^T \cdot (x)) + b \quad (11)$$

onde b é o bias do SVM, w^T é um vetor multidimensional que representa um grupo de pesos que conecta os espaços de características e a saída do SVM e (x) representa a imagem induzida do vetor de entrada no espaço de características.

Assume-se que $\varphi_j(\mathbf{x})$ é definido *a priori* para todos os termos j . Portanto, o hiperplano de separação pode ser definido, de maneira simplificada, conforme a relação:

$$\sum_{j=0}^{m_l} (w_j \cdot \varphi_j(\mathbf{x})) + b = 0 \quad (12)$$

onde $\varphi_j(\mathbf{x})$ é definido na forma vetorial:

$$\varphi(\mathbf{x}) = [\varphi_0(\mathbf{x}), \varphi_1(\mathbf{x}), \dots, \varphi_{m_l}(\mathbf{x})]^T \quad (13)$$

e, por definição, tem-se para todo \mathbf{x} :

$$\varphi(\mathbf{x}) = 1 \quad (14)$$

Deve ser introduzida então a forma estendida do produto inercial, dada por:

$$\begin{aligned}
K(x, x_i) &= \varphi^T(x) \varphi(\mathbf{x}) \\
&= \sum_{j=0}^{m_1} \varphi^T(\mathbf{x}) \varphi(\mathbf{x}) \text{ para todo } j
\end{aligned}
\tag{15}$$

Dessa forma, a SVM pode ser expressa como um mapeamento não linear do vetor de entrada em um espaço multidimensional de características que é oculto tanto para entrada como para a saída, e representado por um hiperplano ótimo na separação de características (HAYKIN, 1999).

3.2.4 Topologias de SVM

Diversas máquinas de aprendizado, podem ser implementadas com base em diferentes funções do núcleo (HAYKIN, 1999). Nesse trabalho foram implementadas três funções núcleo: linear, polinomial e Gaussiano de base radial.

3.2.4.1 SVM Linear

A função linear é utilizada quando o problema de classificação pode ser separado linearmente no espaço de entrada, não sendo necessário criar um mapa multidimensional de classificação. Funções de decisão lineares consistem de um limite de decisão dado por um hiperplano (uma linha, um plano em 2D ou um hiperplano em 3 ou mais dimensões) separando duas regiões diferentes no espaço. Uma função linear é definida por:

$$H(x_i, x_j) = x_i x_j \tag{16}$$

onde x_i e x_j são valores do vetor de dados representado no espaço de entradas.

3.2.4.2 SVM Polinomial

A função núcleo polinomial é dada por:

$$H(x_i, x_j) = (x_i x_j + 1)^d \tag{17}$$

onde d é a ordem do polinômio, especificada *a priori*.

3.2.4.3 SVM com função Gaussiana de base radial (FBR)

A função de base radial núcleo Gaussiano corresponde a um espaço de características de dimensão infinita; a utilização desse núcleo permite que uma SVM apresente características de uma rede neural artificial de função de base radial – FBR.

Esta função é definida por:

$$H(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (18)$$

onde σ é um parâmetro de ajuste da função e determina a obtenção do hiperplano ótimo de separação.

CAPÍTULO 4

Materiais e Métodos

Neste capítulo serão apresentados a base de dados utilizada no desenvolvimento dos classificadores, e o método de aquisição dos sinais, o processamento dos sinais, os classificadores de marcha humana e os indicadores de desempenho utilizados na implementação e validação dos classificadores.

4.1 Amostra

A base de dados compõe-se de 51 sujeitos, divididos em dois grupos: grupo controle (GC) formado por 38 sujeitos normais (18 homens e 20 mulheres), com idade média de $23,09 \pm 3,77$ anos (média \pm desvio padrão), massa corporal média $67,04 \pm 13,66$ kg e altura média de $171,75 \pm 7,99$ cm sem lesões neurológicas ou músculo-esqueléticas. Além de um grupo com fratura (GF) composto por 13 sujeitos com fratura unilateral do membro inferior (Tabela 1) que apresentaram consolidação da fratura no controle radiográfico, foram liberados pela equipe médica para realização de apoio total no membro lesado e não realizaram nenhum tipo de tratamento fisioterapêutico até o momento da avaliação. Cinco sujeitos deste grupo foram depois submetidos a tratamento fisioterapêutico três vezes por semana, por aproximadamente quatro meses e foram, então, reavaliados (GFT).

Tabela 1. Características do grupo com fratura

Sujeito	Idade (anos)	Massa Corporal (kg)	Altura (m)	Gênero	Localização da Fratura
1	24	102	180	Masculino	Tíbia e Fíbula
2	29	69	171	Masculino	Calcâneo
3	28	61,5	176	Masculino	Tíbia e Fíbula
4	16	99,5	194	Masculino	Tíbia e Fíbula
5	40	110	177	Feminino	Calcâneo
6	34	89	183	Masculino	Calcâneo
7	32	65,6	165	Feminino	Fêmur
8	21	61,8	168	Masculino	Fêmur
9	33	77,2	171	Masculino	Calcâneo
10	28	81,8	180	Masculino	Tíbia
11	58	76,5	159	Feminino	Fêmur
12	43	91,9	170	Masculino	Calcâneo
13	28	89,2	172	Masculino	Tíbia
Média	31,85	92,50	174,31		
(desvio padrão)	(10,66)	(17,9)	(8,87)		

4.1.1 Aquisição dos dados

O protocolo de aquisição de dados foi previamente aprovado pelo comitê de ética local do Centro de Educação Física, Fisioterapia e Desportos da Universidade do Estado de Santa Catarina e está descrito por MUNIZ (2008).

O componente vertical da força de reação do solo (FRSv) foi coletado em uma esteira instrumentalizada Gaitway (Kistler, Suíça) com frequência de amostragem de 300 Hz durante 10 s. Este período correspondeu a aproximadamente 10 ciclos da marcha em cada tentativa, os quais foram usados para obtenção da curva média da FRSv em cada membro inferior. O uso da média é recomendado para reduzir o ruído mecânico da esteira. A FRSv foi normalizada pelo peso corporal de cada sujeito (MUNIZ, 2008), para possibilitar a comparação entre sujeitos diferentes.

4.2 Processamento dos Sinais

Para minimizar os efeitos do ruído aleatório, o sinal da FRSv foi submetido a filtro *Butterworth* passa-baixas de segunda ordem, com frequência de corte em 30 Hz (MUNIZ, 2008). O filtro foi aplicado nos sentidos direto e reverso para evitar desvios de fase.

Os sinais foram interpolados e re-amostrados com 100 pontos de acordo com a fase de apoio de cada pé. Assim, cada sujeito da base de dados foi representado por 200 amostras da FRSv para uma passada completa (pés direito e esquerdo). Teve-se, portanto, uma matriz 51 x 200 (51 linhas representaram 38 sujeitos do GC e 13 GF e 200 colunas as amostras de FRSv).

Para reduzir a dimensionalidade e eliminar redundâncias na representação dos dados, utilizou-se a PCA descrita na seção 3.1. O teste *Broken Stick* e o gráfico scree foram utilizados como critério de seleção do número de CPs a serem retidos na análise.

Os CPs retidos na análise pelo teste *Broken Stick* foram combinados como possível sem repetição, como no exemplo da Tabela 2, na tentativa de explorar a capacidade da representação de todo o conjunto de dados e obter o melhor desempenho de cada classificador empregado.

Tabela 2 – Grupos de combinações gerados para 3 CPs

	Grupo 1*	Grupo 2*	Grupo 3*
	1	1 e 2	1, 2 e 3
CPs utilizados	2	1 e 3	
	3	2 e 3	

*Exemplo das possíveis combinações que podem ser obtidas a partir de 3 CPs, gerando 3 novos conjunto de dados.

4.2.1 *Bootstrap*

Uma base de dados foi gerada utilizando-se a técnica *bootstrap*, apresentada na seção 3.2, e os grupos de combinações dos CPs. Essa associação de técnicas tem por objetivo corrigir a tendenciosidade dos classificadores, uma vez que a base de dados original é pequena (tamanho amostral igual a 51).

Então, obteve-se 500 amostras (B) *bootstrap* independentes, cada uma composta por 51 sujeitos aleatoriamente escolhidos podendo ter repetição no processo. Cada sujeito da amostra B tem diferentes representações, como se fosse um dado novo, conforme a combinação de CPs utilizada. Por fim, a base de dados foi composta por 500 amostras de 51 sujeitos.

Com exemplo, a partir de uma base original com 10 sujeitos distintos, foi obtida uma amostra *bootstrap* com nove sujeitos. Nota-se que um determinado sujeito pode aparecer mais de uma vez (sujeitos 2 e 4), ao mesmo tempo em que pode não aparecer (sujeitos 3, 5, 6 e 10). A base de dados de teste é então composta pelos sujeitos que não estão contemplados na amostra *bootstrap* de treinamento. . Deste modo, garante-se que o classificador seja testado com dados desconhecidos (Tabela 3).

Tabela 3. Formação dos dados *Bootstrap*

Sujeitos na base de dados originais	Sujeitos em uma amostra <i>bootstrap</i>	Sujeitos na amostra de teste do classificador
1	7	3
2	9	5
3	2	6
4	8	10
5	2	
6	4	
7	1	
8	4	
9	2	
10		

4.3 Classificadores utilizados na identificação do padrão de marcha humana

Redes neurais artificiais e máquinas de vetores de suporte foram utilizadas para implementar cinco classificadores.

No processo de aprendizado, independente do classificador, as 500 amostras *bootstrap B* da base de dados de treinamento foram apresentadas uma a uma, para cada uma das combinações possíveis de CPs. Em cada iteração do algoritmo, uma amostra *bootstrap B* com 51 sujeitos aleatoriamente escolhidos e representados por uma combinação *kk1*, de um grupo *kk* de combinações ($kk=1,2,3,\dots,11$), foi apresentada ao classificador.

Cada classificador foi testado com diferentes modelos, definidos com base nos parâmetros de configuração da ferramenta computacional (RNA ou SVM) utilizada (Tabela 4).

Tabela 4. Parâmetros dos classificadores

Classificador	Parâmetro de configuração	
RFF	# neurônios	2, 4, 6
	# épocas	100
RNP	erro	0,001
	spread	0,1: 0,1:1
SVM linear	C ^{*+}	0,1, 1, 10, 100, 1000
SVM polinomial	C ^{*+}	0,1, 1, 10, 100, 1000
	d ^{**}	2, 3, 4
SVM FBR	C ^{*+}	0,1, 1, 10, 100, 1000
	spread	0,1, 1, 10

* BEGG *et al.* (2005); ** BEGG *et al.* (2005b); + MUNIZ e NADAL (2010)

Para os testes variou-se estes parâmetros, com o objetivo de verificar o efeito no desempenho do classificador. O classificador foi testado em diferentes configurações e o resultado final foi o modelo que apresentou o melhor desempenho.

A base de dados de teste foi composta pelos sujeitos não contemplados nas 500 amostras de treinamento *B*.

4.3.1 Classificador baseado em *rede feed forward*

Três modelos de RFF foram implementados, conforme a quantidade de neurônios na camada escondida (2, 4 ou 6). A base de dados de 500 amostras *bootstrap* foi dividida, sendo 20% utilizada para validação e 80% para treinamento da rede. O treinamento foi realizado com os seguintes parâmetros de parada: 100 épocas ou 0,001 de erro esperado.

4.3.2 Classificador baseado em rede neural probabilística

Dez modelos de RNP foram implementados, de acordo com o raio da função (spread) de ativação da camada escondida que variou de 0,1 a 1 com incrementos de 0,1. Cada modelo de RNP foi treinado com a apresentação das 500 amostras *bootstrap B* e testado com as amostras da base de teste e os pesos das camadas escondidas obtidos no processo de treinamento.

4.3.3 Classificador baseado em maquina de vetores de suporte de função núcleo linear

Neste classificador variou-se o parâmetro *C* da função núcleo linear, responsável por minimizar o erro empírico do processo de treinamento e a complexidade da máquina. Obteve-se cinco modelos deste classificador, conforme o valor de *C* (0,1, 1, 10, 100 e 1000). Os valores de *C* foram escolhidos empiricamente, baseados nos resultados obtidos por BEGG *et al.* (2005) e MUNIZ e NADAL (2010).

4.3.4 Classificador baseado em maquina de vetores de suporte de função núcleo polinomial

Este classificador foi implementado em cinco configurações nas quais foi variado o valor de *C*, com os mesmos valores utilizados na função núcleo linear, e o grau do polinômio da função núcleo (2, 3, e 4). BEGG *et al.* (2005b) utilizaram polinômios de graus 2 e 3 e apresentaram bons resultados. A utilização da função

polinomial de quarto grau teve por objetivo determinar se o desempenho dos classificadores segundo estes parâmetros aumentava com uma função mais complexa.

Classificador baseado em maquina de vetores de suporte de função núcleo base radial. Este classificador foi implementado também com cinco configurações variando o parâmetro C , com os mesmos valores das funções anteriores, e ainda o parâmetro *spread* (δ) da função de base radial, que define a sensibilidade da função kernel RBF. Obteve-se cinco modelos para cada valor de C e o δ assumiu os valores 0,1, 1, e 10.

4.3.5 Treinamento e teste dos classificadores

No processo de treinamento, independente do classificador e de sua configuração ou modelo, as 500 amostras de teste, compostas pelos sujeitos não contemplados nas amostras *bootstrap* B de treinamento, são apresentadas.

Para um modelo JL e uma combinação de CPs $kk1$ para representação dos 51 sujeitos de uma determinada amostra de teste k , obteve-se o desempenho do classificador mensurado com base nos índices apresentados na seção 4.4. Portanto, para cada modelo de classificador foi gerado 500 valores de AUC e 500 valores de ACC. Ao final, k valores para o modelo JL , para uma combinação $kk1$. Para cada grupo kk de combinações, o resultado da classificação é representado em matrizes de dimensão ($kk1 \times JL$), sendo cada elemento desta o valor médio de cada índice de desempenho.

Selecionou-se, por grupo kk , o maior valor médio e então o desempenho do classificador foi apresentado em relação à quantidade de CPs utilizados e os parâmetros de configuração do classificador.

4.4 Avaliação do desempenho dos classificadores

No processo de validação dos classificadores, as 500 amostras de teste foram apresentadas. Para cada amostra, obteve-se o desempenho com base nos índices acurácia e área abaixo da curva ROC, descritos a seguir.

O valor médio de cada um desses índices foi utilizado para escolher o modelo do classificador com maior desempenho. O modelo envolveu a configuração do

classificador (parâmetros), atendendo uma relação de compromisso entre AUC e ACC, e a quantidade de CPs utilizada na representação dos dados, correspondente ao maior valor de AUC. Este modelo foi utilizado na validação do tratamento fisioterapêutico dos indivíduos do GFT.

4.4.1 Acurácia

A acurácia (ACC) é definida por:

$$Acuracia = \left(\frac{VP + VN}{VP + VN + FP + FN} \right) * 100 \quad (19)$$

onde VP são os verdadeiros positivos; VN os verdadeiros negativos; FP os falsos positivos e FN falsos negativos.

4.4.2 Sensibilidade

É o percentual de classificação correta que ocorreu entre os sujeitos lesados (verdadeiros positivos).

$$Sensibilidade = \left(\frac{VP}{VP + FN} \right) * 100 \quad (20)$$

4.4.3 Especificidade

É a percentagem de classificação correta que ocorreu entre os sujeitos normais (verdadeiros negativos). Esse parâmetro é calculado pela divisão do número de indivíduos do grupo de controle classificado corretamente (VN) pelo total de indivíduos que pertencem ao grupo (VN+FP).

$$Especificidade = \left(\frac{VN}{VN + FP} \right) * 100 \quad (21)$$

4.4.4 Área abaixo da Curva ROC (AUC)

A curva ROC é uma representação bidimensional do desempenho de um classificador, com base na relação entre a sensibilidade e o complemento da

especificidade (1-especificidade) (Figura 10).




Figura 10. Curva ROC.

A reta representa a relação entre a sensibilidade e o complemento da especificidade obtida na análise de classificadores discretos, ou seja, que geram como saída apenas uma classe e, portanto, são representados por apenas um ponto no espaço ROC. Merecem destaque os seguintes pontos: (a) ponto (0,1), relacionado a uma classificação perfeita; (b) ponto (0,0), quando o modelo nunca gera uma classificação positiva – não comete falsos positivos, tampouco gera verdadeiros positivos; (c) ponto (1,1) apresentado pelo classificador que gera, incondicionalmente, verdadeiros positivos.

Para comparar classificadores é necessário reduzir a curva ROC a um valor escalar. Um método comum é calcular a área abaixo da curva ROC (AUC). A AUC está relacionada ao poder discriminante dos métodos utilizados para classificação. Corresponde à probabilidade de identificar corretamente dois grupos experimentais (HANLEY e McNEIL, 1982), sendo neste trabalho identificados por lesados e não lesados.

Analiticamente, a AUC pode ser determinada por meio de métodos de resolução numérica (por exemplo, regra do trapézio) e métodos estatísticos, tais como

a estatística de Wilcoxon-Mann-Witney e estimativa de máxima verossimilhança (BRAGA, 2000).

Neste trabalho, cada amostra apresentada ao classificador produziu um ponto da curva ROC que foi utilizado na integração trapezoidal e se obteve então AUC para cada modelo de classificador.

4.5 Validação do tratamento fisioterapêutico

Uma vez encontrado o modelo do classificador que possibilita maior desempenho em relação à ACC e AUC, os sujeitos que sofreram lesão no membro inferior e foram submetidos a tratamento fisioterapêutico foram apresentados a cada um dos classificadores. A resposta, correspondente à classificação destes sujeitos, é uma medida do efeito do tratamento. Espera-se que os cinco sujeitos alcancem o padrão de normalidade da FRSv.

4.6 Análise Estatística

Para investigar a normalidade da distribuição dos índices de desempenho, foi realizado o teste de Kolmogorov-Smirnov.

Uma vez que o teste rejeitou a hipótese nula, ou seja, os índices de desempenho não apresentam distribuição normal, utilizou-se o teste de Kruskal-Wallis para comparar os classificadores com base nos índices ACC e AUC, tendo como hipótese nula a igualdade entre as médias desses índices. O teste Tukey foi utilizado na análise *post-hoc* uma vez que a hipótese nula de igualdade entre as médias dos índices foi rejeitada. O nível de significância estabelecido foi $\alpha = 0.05$. Os testes foram realizados no programa SPSS versão 13.0 (*Statistical Package for the Social Science*, EUA). As análises restantes, a implementação dos classificadores e o processamento dos sinais foram realizados em rotinas desenvolvidas no programa Matlab 7.1 (The Mathworks, EUA).

CAPÍTULO 5

Resultados

Este capítulo apresenta os resultados obtidos no presente trabalho, segundo as técnicas utilizadas e descritas no Capítulo 4.

5.1 Análise de Componentes Principais

Neste trabalho foram utilizadas para a implementação dos classificadores 11 CPs, indicados pelo teste *Broken stick*, explicando a maior variância dos dados (Figura 11).

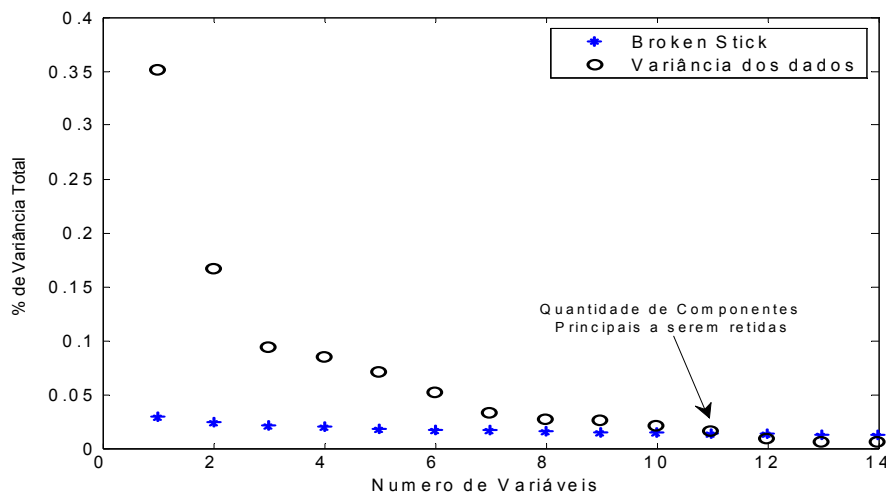


Figura 11. Teste *Broken Stick*

O diagrama de espalhamento do primeiro CP com o segundo (Figura 12) evidenciou que o primeiro CP apresentou maior contribuição na separação dos dados.

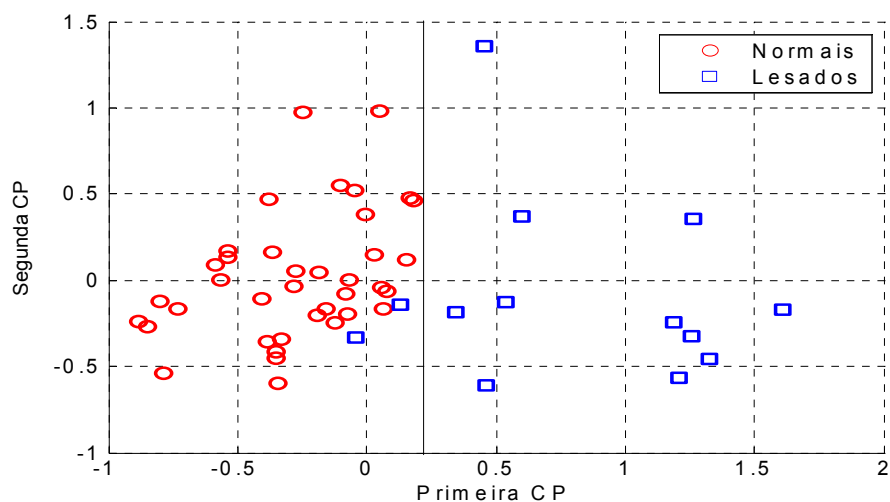


Figura 12. Diagrama de espalhamento do primeiro e segundo CP. A linha vertical (sólida) que divide os sujeitos normais e lesados é arbitrária.

5.2 Desempenho dos Classificadores

5.1.1 Rede *feedforward*

A RFF apresentou melhor desempenho com cinco variáveis segundo o índice ACC (0,8406), (1°, 2°, 3°, 7° e 8° CPs) e com três variáveis (1°, 3° e 4° CPs) segundo o índice AUC (0,7278) (Figura 13), sendo que os índices de desempenho indicam resultados piores à medida que se aumenta o número de CPs.




Figura 13. Desempenho do classificador RFF

O melhor desempenho (maior valor médio) do classificador RFF foi obtido para dois neurônios na camada escondida considerando o critério AUC e para quatro no ACC (Figura 14). Para estabelecer um compromisso entre ACC e AUC, foi escolhido dois neurônios na camada escondida no modelo final, com valores de AUC de $0,7278 \pm 0,2377$ (Média \pm Desvio Padrão) e ACC de $0,7792 \pm 0,2194$.




Figura 14. Intervalo de confiança de 95% para o desempenho do classificador RFF quanto ao número de camadas escondidas

5.2.1 Rede Neural Probabilística

O melhor desempenho para a RNP foi obtido com quatro variáveis para o critério AUC (0,9866) (1°, 3°, 5° e 6° CPs) e com uma variável segundo o índice ACC (0,9019) (1° CP) (Figura 15). Neste classificador, a adição de variáveis tem maior efeito negativo no desempenho da ACC, quando comparado à AUC.

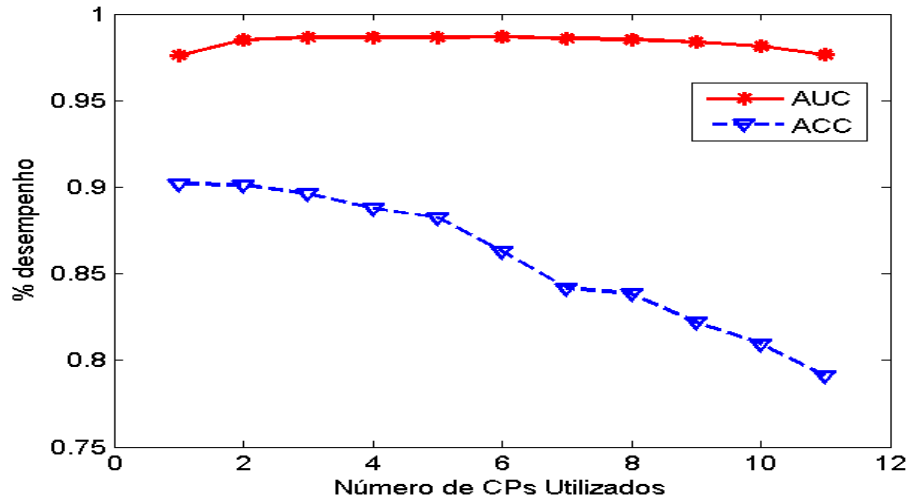


Figura 15 – Desempenho do classificador RNP

Em relação ao parâmetro *spread* (δ) da função de ativação da camada escondida, o melhor desempenho segundo o índice ACC foi obtido para $\delta = 0,1$ ($0,9019 \pm 0,0567$) e para o índice AUC $\delta = 1,0$ ($0,9866 \pm 0,0129$) (Figura 16).

O modelo final do classificador RNP foi escolhido para atender o compromisso entre os índices de desempenho ACC e AUC. Portanto neste caso tem-se o classificador com $\delta = 0,1$, com AUC $0,9679 \pm 0,0285$ e ACC $0,9019 \pm 0,0567$.




Figura 16 - Intervalo de confiança de 95% para o desempenho do classificador RNP

5.2.2 Máquina de vetor de suporte linear

O melhor desempenho da SVM linear foi obtido com três variáveis de entrada (1°, 2° e 6° CPs) para ACC (0,9539 ± 0,0558) (Figura 17) e com quatro (1°, 2°, 5° e 6° CPs) segundo a AUC (0,9512 ± 0,0535), sendo que os índices indicaram o parâmetro C igual a 100 (Figura 18).

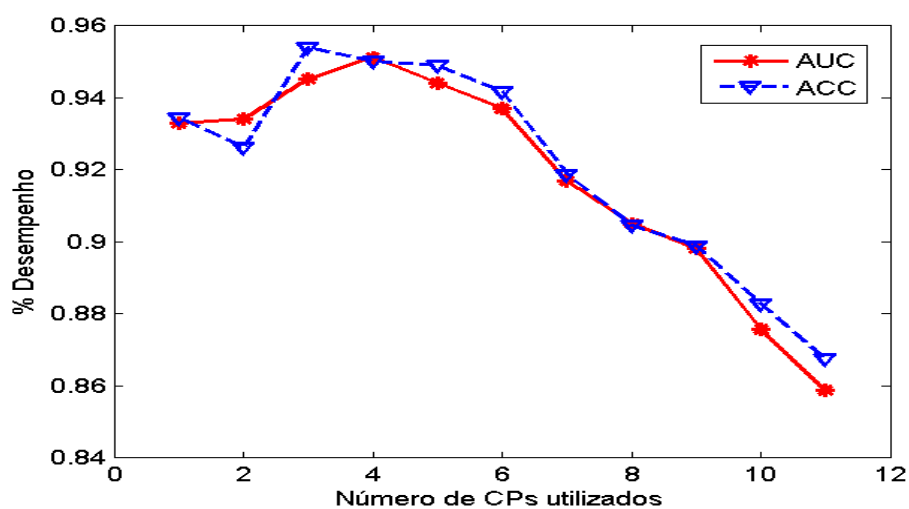


Figura 17 - Desempenho do classificador SVM linear




Figura 18 - Intervalo de confiança de 95% para o desempenho do classificador SVM linear

5.2.3 Máquina de vetor de suporte polinomial

O melhor desempenho para a SVM polinomial foi obtido com uma variável (1º CP) segundo os índices ACC ($0,9442 \pm 0,0525$) com C igual a 0,1 e AUC ($0,9359 \pm 0,0573$) (Figura 19) com C igual a 1. Neste classificador pode-se observar que a adição de variáveis causa uma queda nos dois índices de desempenho. Estes valores de desempenho correspondem ao modelo de SVM com polinômio de ordem 3 (Tabela 4).

No modelo final o parâmetro C igual a 0,1 foi selecionado para manter uma relação de compromisso entre AUC ($0,9222 \pm 0,0920$) e ACC ($0,9442 \pm 0,0573$) (Figura 20).




Figura 19 - Desempenho do classificador SVM polinomial




Figura 20 - Intervalo de confiança de 95% para o desempenho do classificador SVM polinomial

5.2.4 Classificador SVM FBR

O melhor desempenho para a SVM FBR foi obtido com uma variável (1° CP) segundo o índice ACC ($0,9527 \pm 0,0405$) com C igual a 0.1 e três variáveis (1°, 2° e 6° CPs) segundo o índice AUC ($0,9459 \pm 0,0673$) com C igual a 1000 (Figura 21). Estes valores correspondem ao modelo de SVM FBR com *spread* (δ) igual a 10. Neste classificador pode-se observar que a adição de variáveis tem maior efeito negativo no desempenho representado pelo índice AUC.

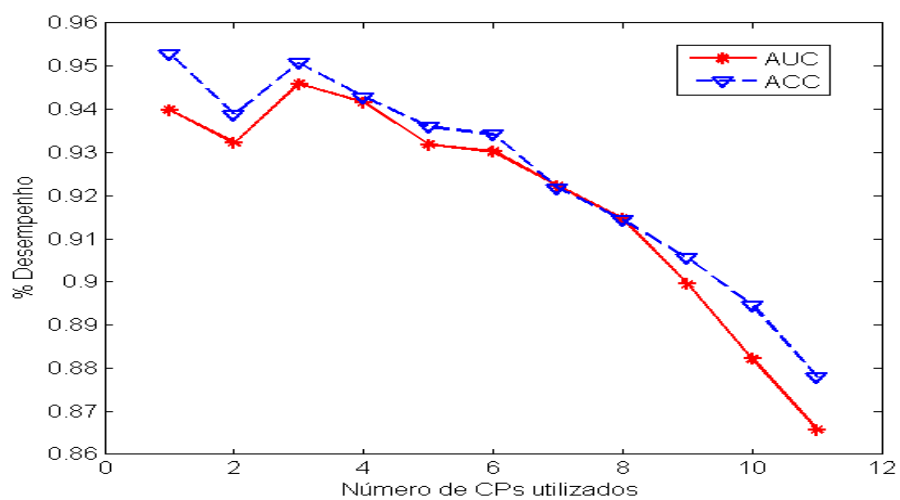


Figura 21 - Desempenho do classificador SVM FBR

O modelo final deste classificador atende a relação de compromisso entre os índices de desempenho e, portanto, apresenta C igual a 0,1. Para este modelo, tem-se AUC igual a $0,9187 \pm 0,0475$ e ACC igual a $0,9527 \pm 0,0405$, (Figura 22).




Figura 22 - Intervalo de confiança de 95% para o desempenho do classificador SVM FBR

5.3 Modelos obtidos para os classificadores baseados em máquinas de vetores de suporte

Os resultados de ACC e AUC obtidos com todas as SVM são sumarizados nas Tabelas 5 e 6 respectivamente, onde os melhores desempenhos são apresentados em negrito.

Tabela 5. ACC segundo parâmetros de cada classificador SVM

Núcleo	C					
	0,1	1	10	100	1000	
Linear	0,9076	0,9245	0,9408	0,9539	0,9478	
Polinomial	d = 2	0,9416	0,9313	0,9223	0,9119	0,9049
	d = 3	0,9442	0,9380	0,9271	0,9129	0,8971
	d = 4	0,9462	0,9398	0,9239	0,9088	0,8897
FBR	$\delta = 0,1$	0,8728	0,8614	0,8547	0,8450	0,8233
	$\delta = 1$	0,9437	0,9375	0,9269	0,8978	0,8737
	$\delta = 10$	0,9527	0,9516	0,9352	0,9231	0,9187

Valores em negrito representam maior desempenho. d representa o grau do polinômio e δ o spread

Tabela 6. AUC segundo parâmetros de cada classificador SVM

Kernel	C					
	0,1	1	10	100	1000	
Linear	0,9184	0,9483	0,9488	0,9512	0,9491	
Polinomial	d = 2	0,9262	0,9340	0,9302	0,9199	0,9105
	d = 3	0,9222	0,9359	0,9312	0,9176	0,9084
	d = 4	0,9243	0,9357	0,9228	0,9130	0,8984
FBR	$\delta = 0,1$	0,8490	0,8432	0,8369	0,8248	0,7839
	$\delta = 1$	0,9340	0,9343	0,9273	0,8845	0,8404
	$\delta = 10$	0,8874	0,8868	0,8942	0,9209	0,9459

Valores em negrito representam maior desempenho. d representa o grau do polinômio e δ o spread.

Modelos de melhor desempenho A Tabela 7 apresenta os modelos finais dos classificadores, sendo estes utilizados para validação do tratamento fisioterapêutico. Os parâmetros referentes a cada modelo foram escolhidos em observância à relação de compromisso entre ACC e AUC. No caso do SVM, com os maiores valores

médios de ACC e AUC ocorrem para valores diferentes de C, tomou-se os parâmetros referentes ao menor valor de C entre os dois e em relação à RNP e RFF foi realizada a relação de compromisso com base no valor do *spread* e da quantidade de neurônios na camada escondida, respectivamente.

Quanto ao número de variáveis, entendendo-se que o índice AUC é mais robusto, para o modelo final foi utilizado os CPs correspondentes ao maior valor desse parâmetro

Tabela 7. Desempenho Geral dos Classificadores

Classificador	Parâmetro *	Variáveis de entrada (CPs)	AUC	ACC
RFF	$n = 2$	1°, 3° e 4°	0,7278 (±0,2377)	0,7792 (±0,2194)
RNP	$\delta = 0,1$	1°, 3°, 5° e 6°	0,9679 (±0,0335)	0,9019 (±0,0567)
SVM Linear	$C = 100$	1°, 2°, 5° e 6°	0,9512 (±0,0558)	0,9539 (±0,0535)
SVM Polinomial	$d = 3$ $C = 0,1$	1°	0,9222 (±0,0920)	0,9442 (±0,0573)
SVM FBR	$\delta = 10$ $C = 0,1$	1°, 2°, e 6°	0,9459 (±0,0673)	0,9527 (±0,0405)

* Parâmetro de configuração do classificador. Para RFF n é a quantidade de neurônios na camada escondida, para RNP δ é o raio da função de ativação, para SVM C é o parâmetro de regularização, d é a ordem do polinômio da função núcleo polinomial e δ é o raio da função de ativação.

Nos modelos estudados, o classificador que apresentou o melhor desempenho segundo o critério AUC foi o RNP (Tabela 7) e segundo o critério ACC foi a SVM linear Em todos os classificadores verificou-se a redução do número de variáveis de entrada no modelo final.

5.4 Análise estatística do desempenho dos classificadores

O teste de Kruskal-Wallis evidenciou diferença estatística no desempenho dos classificadores testados quanto ao critério ACC ($p < 0,001$) (Figura 23) e AUC ($p < 0,001$) (Figura 24).

No critério ACC, a RFF apresentou maior dispersão dos resultados (Figura 23). O classificador com melhor desempenho foi o SVM de função núcleo linear, seguido pelo polinomial e núcleo probabilístico. Na análise *post hoc*, concluiu-se que os classificadores RFF e RNP são significativamente diferentes dos demais; contudo, entre os classificadores SVM não há diferença significativa.




Figura 23. Boxplot da distribuição de ACC em cada classificador. O teste de Kruskal-Wallis evidenciou diferença significativa entre os classificadores ($p < 0,001$).

Com relação à AUC, a RNP apresentou maior desempenho (em relação ao valor médio) comparado aos outros classificadores (Figura 24). No entanto, o teste de *post-hoc* de Tukey para AUC mostrou que apenas o classificador RFF é significativamente diferente dos demais.

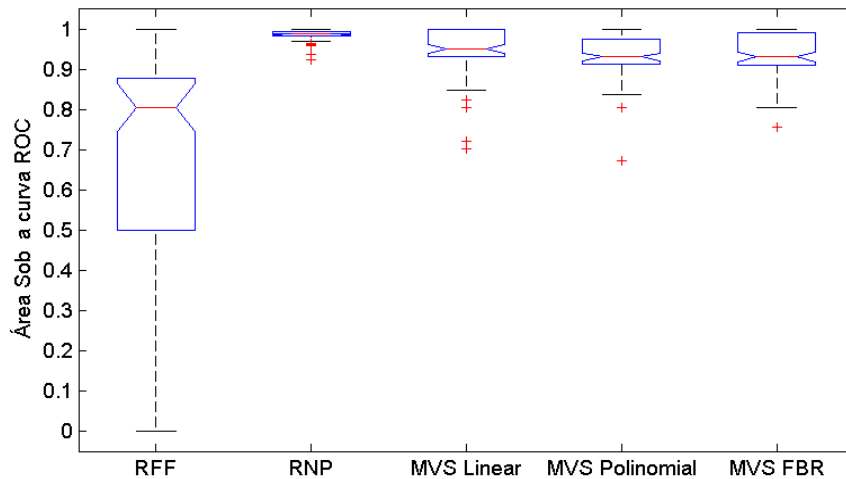


Figura 24. Boxplot para da distribuição de AUC dos classificadores.

5.5 Validação do tratamento fisioterapêutico com base na classificação

A Tabela 8 apresenta os resultados obtidos na classificação de cinco sujeitos da base de dados que sofreram lesão em membro inferior e foram submetidos a tratamento fisioterapêutico

Tabela 8. Classificação de sujeitos lesados

Classificador	Normal	Lesado
RFF	3	2
RNP	4	1
SVM Linear	4	1
SVM Polinomial	4	1
SVM FBR	4	1

O classificador RFF foi o mais restritivo, classificando dois sujeitos como lesados. Nos demais, pelo menos um sujeito não alcançou a normalidade após tratamento.

CAPÍTULO 6

Discussão

Este trabalho se propôs a desenvolver classificadores do padrão de marcha humana, com relação ao componente vertical da força de reação do solo, com base em ferramentas de inteligência computacional: máquinas de vetores de suporte e redes neurais artificiais.

A aplicação da técnica multivariada de PCA sobre os sinais de FRSv possibilitou a redução da dimensionalidade e a eliminação das redundâncias na representação da FRSv. Decidiu-se pela quantidade de CPs indicada no teste *broken stick*, também utilizado por MUNIZ *et al.* (2010), devido à maior representatividade da variância total dos dados (94,16%). A seguir, todas as combinações possíveis de um a onze CPs foram consideradas para o desenvolvimento e teste dos classificadores. O CP que mais contribuiu na classificação foi o primeiro (35,48% da variância total) (Figura 12), sendo que esse componente foi selecionado como variável de entrada no modelo de melhor desempenho dos classificadores utilizados no estudo (Tabela 7).

Verificou-se que o desempenho dos classificadores, em geral, foi melhor com um número reduzido de CPs na entrada de cada classificador (Figuras 13, 15, 17, 19 e 21). Esse comportamento foi reportado em outras investigações. BEGG *et al.* (2005) observaram melhoria no desempenho de classificadores baseados em SVM com a utilização de um número reduzido de variáveis (3 a 5), selecionadas por meio do algoritmo de seleção de características Hill-Climbing. YOM-TOV e INBAR (2002) obtiveram melhores resultados com um menor número de variáveis (10-20), selecionadas a partir de 1000 variáveis originais, na classificação do movimento com base no sinal de eletro-encefalograma. LAI *et al.* (2009) obtiveram AUC de 70,37% utilizando 30 variáveis e 88,89% com um grupo de seis variáveis de melhor representatividade, no reconhecimento de síndrome patelo-femoral. Além da evidente melhoria no desempenho, deve-se considerar ainda o fato de que o processamento de um menor número de variáveis produz menor carga computacional, viabilizando aplicações em tempo-real. O presente trabalho confirma os achados da literatura, com modelos de classificadores, de maior desempenho, com no máximo quatro variáveis (Tabela 7) para representação dos dados.

A comparação entre os valores de AUC e ACC permitiu a seleção dos valores ideais dos parâmetros de configuração (quantidade de neurônios na camada escondida, para RFF, *spread* para RNP e C para SVM), para compor os classificadores (MUNIZ *et al.*, 2010, HERNANDEZ-CARBALLO *et al.*, 2005). O modelo final de cada classificador foi, portanto, o resultado da relação de compromisso entre os dois índices. AUC tem sido recomendada como melhor índice de desempenho, uma vez que apresenta maior convergência em relação à ACC e representa a sensibilidade média do classificador sobre todas as possíveis especificidades. A variância associada ao índice AUC é consideravelmente menor que a variância da ACC, tornando-o mais robusto na avaliação de desempenho (BRANDLEY, 1997; GLAS *et al.*, 2003).

A literatura discute o desempenho dos classificadores SVM em relação ao parâmetro de regularização C. LAI *et al.* (2009) concluíram que, em geral, classificadores SVM comportaram-se melhor com valores menores de C (AUC igual a 88,89% para C igual a 1 e função núcleo polinomial). Os autores também enfatizam que SVM de função polinomial foi menos sensível às variações de C enquanto SVM FBR foi mais sensível às mesmas variações. BEEG *et al.* (2005a) apresentaram resultado de AUC de 95% com C igual a 10 em SVM função de base radia no reconhecimento do padrão de marcha de pessoas jovens e idosas e em outro trabalho (BEGG e KAMMURAZZAN, 2005b) sugerem o intervalo de 0,2 a 0,45 como valores ideais de C (AUC de 91,7%). LEVINGER *et al.* (2007) apresentaram AUC de 94,2% com C igual a 10 em SVM FBR, na avaliação do efeito de cirurgia no joelho com base em medidas quantitativas da marcha. KAMURAZZAN e BEGG (2006) mostraram que em classificadores SVM de funções núcleo polinomial e FBR os melhores desempenhos são obtidos com valores menores de C e não há alterações significativas para $C > 10$. O valor desse parâmetro pode implicar em maior custo computacional e este pode ser um critério de escolha. As estratégias propostas para seleção do valor ótimo de C dependem muito do problema. Segundo KAMURAZZAN e BEGG (2006), se o problema a ser resolvido não é linearmente separável, a seleção de um valor muito alto para C pode penalizar o erro de treinamento, comprometendo a margem de separação. O melhor resultado dos classificadores SVM é o de função núcleo linear com AUC de 95,12% e ACC de 95,39% para C igual a 100. Os modelos de melhor desempenho dos classificadores são apresentados na Tabela 7, segundo os índices e a configuração correspondente.

Em geral, verifica-se a superioridade de SVM linear (AUC de 95,12%) em relação à RFF (AUC de 72,78%). Essa situação também foi discutida em outros trabalhos. BEGG *et al.*, (2005) na classificação do padrão de marcha de pessoas idosas e jovens apresentaram AUC de 93% para SVM contra 75% para RFF. CHAN *et al.*, (2002) avaliaram o desempenho de SVM e RFF na classificação de glaucoma e obtiveram AUC de 90,4% para SVM contra 89,8% para RFF. Esses resultados podem ser justificados pelo fato de SVM eliminar muitas das dificuldades apresentadas na implementação de RFF, tais como o processamento de mínimo local e *overfitting*.

Os classificadores SVM não diferem significativamente para ACC (Figura 23), tampouco para AUC (Figura 24). Resultados observados em outros trabalhos (BEGG *et al.*, 2005a, CHAN *et al.*, 2002, LAI *et al.*, 2009, KAMRUZZAN e BEGG, 2006, LEVINGER *et al.*, 2007) também confirmam esse comportamento. Diante de tais discussões e observando o desempenho geral dos classificadores (Tabela 7, Figura 23 e Figura 24), conclui-se que, dentre as RNAs o melhor classificador quanto ao critério AUC é o RNP (98,66%) e dentre os SVM o melhor é o linear (95,12%) e quanto ao critério ACC é o RNP (90,19) e dentre os SVM o melhor é o linear (95,39). A técnica *bootstrap*, utilizada por ser uma ferramenta robusta de estimativa do desempenho de classificadores quando há poucos dados disponíveis, permite reduzir a tendenciosidade do classificador (SAHINER *et al.*, 2008).

Na validação do tratamento fisioterapêutico, os sujeitos do grupo de tratamento foram apresentados aos modelos finais dos classificadores. Verificou-se que para todos os classificadores pelo menos um sujeito foi reconhecido como lesado. Uma análise *a posterior* da base de dados indicou que esse sujeito tinha sofrido acidente automobilístico, com múltiplas fraturas expostas e perda de massa muscular, justificando assim a dificuldade de recuperação do padrão normal de marcha. Esse sujeito também não foi classificado como normal no classificador usado pela distância padrão com o mesmo banco de dados (MUNIZ e NADAL, 2009).

Como limitação desse trabalho, deve-se considerar que as redes neurais multicamadas, que apresentaram os piores resultados, não foram exaustivamente exploradas com vistas ao melhor desempenho. Como o estudo explorou todas as combinações possíveis de uma a onze entradas, com 500 amostras de *bootstrap* para cada caso, optou-se por limitar o treinamento da RFF por meio de três critérios: erro inferior a 0,001, 100 épocas ou através do grupo de validação. Mesmo assim, o

desenvolvimento de todas as redes testadas demandou uma semana de processamento em um microcomputador *Intel Core Quad Core*, processador de 2.33GHz e 3GHz de RAM.

CAPÍTULO 7

Conclusão

Neste trabalho, propôs-se o desenvolvimento de seis classificadores baseados nas ferramentas computacionais redes neurais artificiais e máquinas de vetores de suporte. As características relevantes dos dados disponíveis foram extraídas por meio da técnica de análise de componentes principais e uma nova base de dados, representada pelos componentes que possibilitam melhor separação dos dados em classes, foi utilizada.

Os classificadores com melhor desempenho baseado em RNA foi a RNP, com 90,19% de ACC e 98,66% de AUC. Utilizando-se SVM, o classificador com melhor desempenho foi o de núcleo linear com 95,39% de ACC e 95,12% de AUC.

A RFF apresentou desempenhos estatisticamente menores para os critérios ACC e AUC e na validação do tratamento fisioterapêutico esse classificador foi o mais restritivo em relação aos indivíduos que sofreram fraturas em membro inferior.

A análise da marcha humana então constitui uma importante ferramenta clínica para validar o efeito de tratamentos e explorar causas de disfunções. Os resultados apresentados neste trabalho sugerem a utilização dos classificadores RNP e SVM em aplicações de reconhecimento do padrão de dados de marcha humana, viabilizando procedimentos de monitoração e avaliação do efeito de tratamentos de reabilitação.

Referências Bibliográficas

- ABERNETHY, B., HANRAHAN, S. J., KIPPERS, V., MACKINNON, L. T., PANDY, M. G., 2005, *The Biophysical Foundations of Human Movement*, 2 ed. USA, Human Kinetics.
- BARBOSA, L., KLEISINGER, G. H., VALDEZ, A.D., MONZÓN, J.E., 2001, “Utilización del Modelo de Kohonen y del Perceptron Multicapa para Detectar Arritmias Cardiacas”. In: *Memorias del II congreso Latinoamericano de Ingenieria Biomédica*, Habana.
- Barton, G., Lees, A., Lisboa, P., Attfield, S., 2006, “Visualisation of gait data with Kohonen self-organising neural maps”, *Gait & Posture*, v. 24, pp. 46–53.
- BEGG R., KAMRUZZAMAN, J., 2005, “A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data”, *Journal of Biomechanics*, v. 38, pp. 401-408.
- BEGG R., KAMRUZZAMAN, J., 2005b, “Support Vector Machine for Automated Gait Classification”, In: *IEEE Transactions on Biomedical Engineering*, v. 52, n. 5, pp. 828-838.
- BEGG, R., RAHMAN, S.M., 2000, “A Method for the reconstruction of Ground Reaction Force-Time Characteristics During Gait from Force Platform Recordings of Simultaneous Foot Falls”, In: *IEEE transactions on Biomedical Engineering*, v. 47, n. 4, pp. 547- 551.
- BEGG, R., PALANISWAMI, M.; OWEN, B., 2005, “Support Vector Machines for Automated Gait Classification”, In: *IEEE Transactions on Biomedical Engineering*, v. 52, n. 5, pp. 828-838.
- BRAGA ACS. *Curvas ROC: Aspectos funcionais e aplicações*. Tese de Doutorado, Universidade do Minho, dezembro de 2000, Portugal.
- BRANDLEY, A.P., 1997. “The use of the area under the roc curve in the evaluation of machine learning algorithms” *Pattern Recognition*, v. 30, n. 7, pp. 1145–1159.
- CANG S., YU, H., 2005, “Novel Probability neural Netwrok”, In: *IEEE Preoceedings*

- Vision, Image and Signal Processing*, v. 152, n. 5, pp. 535-544.
- CHAN K., LEE, T-W., SAMPLE, P. A., GOLDBAUM, M. H., 2002, “Comparison of Machine Learning and Traditional Classifier in Glaucoma Diagnosis”, In: *IEEE Transactions on Biomedical Engineering*, v. 49, n. 9, pp. 963-974.
- CHAU, T., 2001, “A review of analytical techniques for gait data. Part 2: neural network and wavelet methods”, *Gait & Posture*, v. 13, n. 2, pp. 102–120.
- CHEN, M., HUANG, B., XU, Y., 2008, “Intelligent Shoes for Abnormal Gait Detection”. In: *IEEE International Conference on Robotics and Automation*, pp. 2019-2024.
- CHERNICK, M.R., FRIIS, R.H., 2003, *Introductory Biostatistics for the Health Sciences, Modern Applications Including Bootstrap*, New Jersey, Wiley-Interscience.
- CLOETE, I., ZURADA, J. M., 2000, *Knowledge Based Neurocomputing*. Massachusetts: Massachusetts Institute of Technology.
- DAFENG, D., YANG, M., XIURONG, G., 2009 “Application of PNN to Fault Diagnosis of IC Engine”. In: *Second International Conference on Intelligent Computation Technology and Automation*, pp. 495-498.
- DELUZIO, K. J., WYSS, U. P., ZEE, B., COSTIGAN, P. A., SERBIE, C., 1997, “Principal component models of knee kinematics and kinetics: normal vs. pathological gait patterns”. *Human Movement Science*, v. 16, n. 2-3, pp. 201–217.
- DHANALAKSHMI, P., PALANIVEL, S., RAMALINGAM, V., 2009, “Classification of audio signals using SVM and RBFNN”. *Expert Systems With Applications*, v. 36, n. 3P2, pp. 6069–6075.
- EFRON, B., TIBSHIRANI, R., 1997, “Improvements on Cross-Validation: The .632+ Bootstrap Method”, *Journal of the American Statistical Association*, v. 92, n. 938, pp. 548-560.

- ESTRÁZULAS, J. A., PIRES, R., SANTOS, D. M., STOLT, L. R. O. G, MELO, S. I. L, 2005. “Características biomecânicas da marcha em crianças, adultos e idosos”, In: <http://www.efdeportes.com/> *Revista Digital*, n. 88, ano 10, Buenos Aires.
- GLAS, A.S., LIJMER, J.G., PRINS, M.H., BONSEL, G.J., BOSSUYT, P.M.M., 2003, “The diagnostic odds ratio: a single indicator of test performance”, *Journal of Clinical Epidemiology*, v. 56, pp. 1129–1135.
- GRIM, J., SOMOL, P., PUDIL, P., 2003, “Probabilistic Neural Network Paying a Simple Game, In: *Artificial Neural Networks in Pattern Recognition (S. Marinai and M. Gori, eds.)*, University of Florence, Florence, pp. 132–138.
- HAGAN, M. T., DEMUTH, H. B., BEALE, M., 1996, *Neural Network Design*. USA, PWS Publishing Company.
- HAMAMOTO, Y., UCHIMURA, S., TOMITA, S., 1997, “A Bootstrap Technique for Nearest Neighbor Classifier Design”. *IEEE Transaction on Pattern Analysis and Machine Inteligence*, v. 19, n. 1, pp. 73-79.
- HANLEY, J.A., McNEIL, B.J., 1982, “The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve”, *Journal of Radiology*, v. 143, n. 1, pp. 29-36.
- HAUSDORFF, J.M., ALEXANDER, N.B., 2005, *Gait Disorders, Evaluation and Management*, 1 ed. Boca Raton, FL, Taylor & Francis Group.
- HAYKIN, S., *Neural Networks A Comprehensive Foundation*. New Jersey, Prentice Hall International, 1999.
- HERNÁNDEZ-CARABALLO, E.A., RIVAS, F., PÉREZ, A.G., MARCÓ-PARRA, M., 2005, “Evaluation of chemometric techniques and artificial neural networks for cancer screening using Cu, Fe, Se and Zn concentrations in blood serum”, *Analytica Chimica Acta*, 533, pp. 161–168.
- HUNG-REN KO, A., SABOURIN, R., 2009, “Leave-One-Out-Training and Leave-One-Out-Testing Hidden Markov Models for Handwritten Numeral Recognizer: The Implication of a Single Classifier and Multiple Classification”, In: *IEEE transaction on pattern analysis and machine intelligence*, v. 31, n. 12, pp. 2168-2178.

- HUSTON, R. L., 2009, *Principles of Biomechanics*. 1 ed. Boca Raton, FL, Taylor & Francis Group.
- JACKSON, D.A., 2003, "Stopping Rules in Principal Components Analysis: A Comparison of Heuristical and Statistical Approaches" *The Ecological Society of America*, v. 74, n. 8, p.2204-2214.
- JOLLIFFE, I.T., 2002, *Principal Component Analysis*. 2 ed. New York, Springer-Verlag.
- KAMRUZZAMAN, J., BEGG R., 2006, "Support Vector Machines and Other Pattern Recognition Approaches to the Diagnosis of Cerebral Palsy Gait", In: *IEEE Transactions on Biomedical Engineering*, v. 53, n. 12, pp. 2479-2490.
- KOHOLE, M., MERKL, D., KASTNER, J., 1997, "Clinical Gait Analysis by Neural Networks: Issues and Experiences", In: *10th IEEE Symposium on Computer-Based Medical Systems*, pp. 138-143.
- LAI, D. T., BEGG, R. K., TAYLOR, S., PALANISWAMI, M., 2008, "Detection of tripping gait patterns in the elderly using autoregressive features and support vector machines", *Journal of Biomechanics*, v. 41, n. 8, pp. 1762–1772.
- LAI, D.T., LEVINGER, P., BEGG, R.K., GILLEARD, W.L., PALANISWAMI, M., 2009. "Automatic recognition of gait patterns exhibiting patellofemoral pain syndrome using a support vector machine approach", In: *IEEE Transactions on Information Technology in Biomedicine*, v. 13, n. 4, pp. 810–817.
- LEE, H., GUAN, L., BURNE, J.A., 2000, "Human gait and posture analysis for diagnosing neurological disorders", In: *proceedings of international conference on image processing*, v. 2, pp. 435-438.
- LEE L. e GRIMSON W. E. L., 2002, "Gait analysis for recognition and classification," In: *Proceedings of 5th International Conference in Automatic Face Gesture Recognition (FGR'02)*, pp. 1–8.
- LEVINGER, P., LAI, D. T., WEBSTER, K., BEGG, R. K. E., FELLER, J. A., 2007, "Support Vector Machines for detecting recovery from kneeplacement surgery using quantitative gait measures." In: *Proceedings of the 29th Annual International Conference of the IEEE EMBS*, pp. 4875-4878.
- LEVINGER, P., LAI, D. T., BEGG, R. K., WEBSTER, K. E., FELLER, J. A., 2009,

“The application of support vector machines for detecting recovery from knee replacement surgery using spatio-temporal gait parameters”, *Gait & Posture*, v. 29, n. 1, pp. 91–96.

MUNIZ, A.M.S., 2008, *Quantificação da marcha humana utilizando análise de componentes principais para avaliação de procedimentos terapêuticos*. Tese D.Sc., Programa de Engenharia Biomédica /COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

MUNIZ, A.M.S., LIU, H., LYONS, K., Pahwa, R., liu, W., Nadal, J., 2010, “Comparison among probabilistic neural network, support vector machine and logistic regression for evaluating the effect of subthalamic stimulation in Parkinson disease on ground reaction force during gait”. *Journal of Biomechanics*. V.43, pp. 720-726.

MUNIZ, A.M.S., MANFIO, E.F., ANDRADE, M.C., NADAL, J., 2006, “Principal Component Analysis of Vertical Ground Reaction Force: A Powerful Method to Discriminate Normal and Abnormal Gait and Assess Treatment”, In: *Proceedings of the 28th IEEE EMBS Annual International Conference*, pp. 2683-2686, New York.

MUNIZ, A.M.S., NADAL, J., 2009, “Application of principal component analysis in vertical ground reaction force to discriminate normal and abnormal gait”. *Gait & Posture*, v. 29, n. 1, pp. 31-35.

NETO, P.R.P., JACKSON, D.A., SOMERS, K.M., 2004, “How many principal components?, Stopping rules for determining the number of non-trivial axes revisited”, *Computational statistics & data analysis*, Elsevier, v.49, pp. 974-997.

O’HALLORAN, J., ANDERSON, R., 2008 , “The use of kohonen feature maps in the kinematic analysis of rowing performance”, In: *ISBS Conference 2008*, pp. 165-168.

OJA, E., KASKI, S., 1999, *Kohonen Maps*. Amsterdam: Elsevier Science.

OZA N.C., TUMER K., 2008, “Classifier ensembles: Select real-world applications”,

- In: *Information Fusion In Special Issue on Applications of Ensemble Methods*, v. 9, n. 1, pp. 4-20.
- PAOLUCCI, L.A., 2006, *Comparação de dois métodos para representação da força de reação do solo no desempenho de classificação de padrões de marcha*. Tese M.Sc., Programa de Pós-graduação em Educação Física, Universidade Federal de Minas Gerais, Belo Horizonte.
- ROMEI, M., GALLI, M., MOTTA, F., SCHWARTZ, M., CRIVELLINI, M., 2004, “Use of the normalcy index for the evaluation of gait pathology,” *Gait and Posture*, v. 19, pp. 85-90.
- SADEGHI, H., ALLARDAD, P., BARBIER, F., SADEGHI, S., HINSEH, S., PERRAULT, R., LABELLE, H., 2002, “Main functional roles of knee flexors/extensors in able-bodied gait using principal component analysis”, *The Knee*, v. 9, pp. 47-53.
- SAHINER, B., CHAN, H.P., HADJIISKI, L., 2008, “Classifier performance prediction for computer-aided diagnosis using a limited dataset”, *Journal of Medic and Physics*. v.35, n. 4, pp. 1559-1570.
- SCHMIDT, H., HESSE, S., WERNER, C., BARDELEBEN, A., 2004, “Upper and lower extremity robotic devices to promote motor recovery after stroke-recent developments”, In: *Proceedings of the 26th Annual International Conference of the IEEE EMBS*, San Francisco, CA.
- SCHÖLLHORN, W., 2004, “Applications of artificial neural nets in clinical biomechanics”, *Clinical Biomechanics*, v. 19, pp. 876-898.
- SIMON, S. R., 2004, “Quantification of human motion: gait analysis – benefits and limitations to its application to clinical problems”. *Journal of Biomechanics*, v. 37, pp. 1869-1880.
- SPECH, D. F., 1992, “Enhancements of Probabilistic Neural Network”. In: *International Joint Conference on Neural Networks*, 1992, v. 1, pp. 761-768.
- SPECH, D.F., 1990 “Probabilistic Neural Networks and the Polynomial Adaline as Complementary Techniques for Classification”. *IEEE Transaction on Neural Networks*, v. 1, n. 1, pp. 111-121.
- TORRES, J.A.C., 2008, *Um Método de Classificação em Grupos de Informatica*

- Visando sua Segurança*. Dissertação de Mestrado, Universidad Presbiteriana Mackenzie, São Paulo.
- TOZEREN, A., 2000, *Human Body Dynamics: Classical Mechanics and Human Movement*. 1 ed. New York, Springer-Verlag.
- VAUGHAN, C. L., DAVIS, B. L., O'CONNOR, J. C., 1992, *Dynamics of Human Gait*. 2 ed. Cape Town: Kiboho.
- WANG, F., WEN, S., WU, C., 2008, "Gait Pattern Estimation for Intelligent Bionic Leg", In: *Chinese Control and Decision Conference*, pp. 2215-2221. Yantai, Shandong.
- WANG, L.P., 2005, *Support Vector Machines: Theory and Applications*. v. 177. Netherlands, Springer-Verlag, 2005.
- WINTER, D. A., 1991, *The Biomechanics and Motor Control of Human Gait: Normal, Elderly and Pathological*, 2 ed. Waterloo: University of Waterloo.
- YOM-TOV E. e INBAR G. F., 2002, "Feature selection for the classification of movements from single movement-related potentials," *IEEE Trans Neural System Rehabilitation Engineering*, vol. 10, n. 3, pp. 170–177.
- YOO, J.H., HWANG, D., MOON, K.Y., NIXON, M.S., 2008, "Automated human recognition by gait using neural network", In: *First Workshops on Image Processing theory, tools and applications*, pp. 1-6.
- ZOUBIR, A. M., ISKANDER, D. R., 2007, "Bootstrap Methods and Applications: A Tutorial for the Signal Processing Practitioner". In: *IEEE Signal processing Magazine*, pp. 10-19.

ANEXO I

ABSTRACT DO ARTIGO APRESENTADO

XIII Congresso Brasileiro de Biomecânica 2009

CLASSIFICAÇÃO DA MARCHA HUMANA APÓS LESÃO DE MEMBRO INFERIOR UTILIZANDO REDES NEURAIS ARTIFICIAIS

Carlos Alirio Lozano Ortiz¹, Kátia Kelvis Cassiano¹, Jurandir Nadal¹

¹ Programa de Engenharia Biomédica – COPPE/UFRJ, Rio de Janeiro, Brasil

e-mail de contato: krloslozano@peb.ufrj.br, katia@peb.ufrj.br, jn@peb.ufrj.br,

Abstract - The vertical component of ground reaction force (vGRF) is used in human gait analysis, allowing the study of mechanical overloads into the motor system. Injuries in lower limbs modify the normal gait parameters in both injured and non-injured limbs. This work aims at applying two different artificial neural networks – a Kohonen's self organized map and a feedforward network (FF) to recognize and classify the gait pattern of subjects after treatment, trying to verify if the gait pattern reaches normality after treatment. The vGRF was employed as descriptive variable of gait pattern of 51 subjects, being 38 from normal subjects and 13 recorded from subjects after an unilateral fracture of lower limb. Data from five of such subjects, recorded after a physiotherapeutic treatment were analyzed a posteriori, with the resulting classifiers. The FF network was trained using three different configuration of training, testing and validating groups. The higher global performance was obtained with the FF network where 50% of data was used for training and 30% for validating, giving 96.1% accuracy. In the assessment of treatment, the four classifiers show different results, where only three subjects presented normal pattern of vGRF among all cases. This study showed the capability of employing artificial neural networks for the classification of GRF patterns, taking into account the whole data of this variable.

Key words: Pattern recognition, human gait analysis, artificial neural networks.

ANEXO II

ABSTRACT DO ARTIGO APRESENTADO

32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society “Merging Medical Humanism and Technology”

Human Gait Classification after Lower Limb Fracture using Artificial Neural Networks and Principal Component Analysis

Carlos A. Lozano-Ortiz, Adriane M. S. Muniz, *Member, EMBS*, and Jurandir Nadal, *Member, IEEE*

Abstract—Vertical ground reaction force (vGRF) has been commonly used in human gait analysis making possible the study of mechanical overloads in the locomotor system. This study aimed at applying the principal component (PC) analysis and two Artificial Neural Networks (ANN), multi-layer feed forward (FF) and self organized maps (SOM), for classifying and clustering gait patterns from normal subjects (CG) and patients with lower limb fractures (FG). The vGRF from a group of 51 subjects, including 38 in CG and 13 in FG were used for PC analysis and classification. It was also tested the classification of vGRF from five subjects in a treatment group (TG) that were submitted to a physiotherapeutic treatment. Better results were obtained using four PC as inputs of the ANN, with 96% accuracy, 100% specificity and 85% sensitivity using SOM, against 92% accuracy, 100% specificity and 69% sensitivity for FF classification. After treatment, three of five subjects were classified as presenting normal vGRF.

Key words: Neural Networks in Bio-signal Processing and Classification, Principal Component Analysis.

Manuscript received April 23, 2010. This work was supported in part by The Brazilian Agency CNPq.

C. A. Lozano-Ortiz and J. Nadal are with the Biomedical Engineering Program, Federal University of Rio de Janeiro, P. O. Box 68510, ZIP 21941-972, Rio de Janeiro, Brazil (e-mails: krloslozano@peb.ufrj.br, jn@peb.ufrj.br).

A. M. S. Muniz is with Post-graduation Department, Army Physical Education School, Rio de Janeiro, RJ – BRAZIL, (email: adriane_muniz@yahoo.com.br)

ANEXO III

ABSTRACT DO ARTIGO APRESENTADO

XXII Congresso Brasileiro de Engenharia Biomédica

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS *FEED FORWARD* OU PROBABILÍSTICA PARA CLASSIFICAÇÃO DE MARCHA HUMANA EM PACIENTES COM FRATURA DE MEMBRO INFERIOR

C.A. LOZANO*, A.M.S. MUNIZ **, F.F NOBRE* e J. NADAL*

*PEB/UFRJ, Rio de Janeiro, Brasil

**Escola de Educação Física do Exército, Rio de Janeiro, Brasil

e-mail: krloslozano@peb.ufrj.br

Abstract: The aim of this work was to apply two artificial neural network topologies: feed forward (FFN) and probabilistic neural network (PNN) to classify a group of 13 subjects with lower limb fracture (FG) and 38 normal subjects (CG). Principal component analysis (PCA) was first applied to the subject's vertical ground reaction force data, and 11 principal components (PC) were retained, representing 94.16% of the total variance. Bootstrap approach was employed to compare the classifiers by accuracy (ACC) and area under ROC curve. The FFN allowed obtaining 100% ACC and ROC area, using just one PC. After treatment, four of five subjects were classified as normal by both Neural Networks topologies.

Palavras-chave: Principal Component Analysis, Bootstrap, Artificial Neural Networks, Gait Analysis.