

UNIVERSIDADE ABERTA



DEPARTAMENTO DE CIÊNCIAS E TECNOLOGIA

Mestrado em Bioestatística e Biometria

**Relação entre a fadiga na musculatura do tronco e
prevalência de lombalgia em tenistas utilizando
técnicas de aprendizagem supervisionada**

Avelino Domingos Rolha Pereira Barroso

Lisboa, 2017

UNIVERSIDADE ABERTA



DEPARTAMENTO DE CIÊNCIAS E TECNOLOGIA

Mestrado em Bioestatística e Biometria

**Relação entre a fadiga na musculatura do tronco e
prevalência de lombalgia em tenistas utilizando
técnicas de aprendizagem supervisionada**

Dissertação apresentada para obtenção do grau de Mestre em Bioestatística
e Biometria

Avelino Domingos Rolha Pereira Barroso

Orientador: Professor Doutor Pedro Miguel Picado de Carvalho Serranho

Co-orientador: Professor Doutor Luís Miguel Domingues Ferreira Silva

Lisboa, 2017

Resumo

Este trabalho tem como objetivo determinar quais as covariáveis que têm maior importância na classificação da fadiga na musculatura do tronco e a prevalência de lombalgia em tenistas. Foi recolhido sinal de eletromiografia (EMG) em 35 tenistas durante a realização de quatro exercícios tendo sido extraídas medidas no domínio do tempo (valor médio da amplitude do EMG) e no domínio da frequência (mediana de frequência). Os atributos derivados dos eletromiogramas foram usados na construção de modelos de classificação usando Máquinas de Vetores Suporte (SVM – *Support Vector Machines*). A classificação foi baseada em 3 grupos, de acordo com a última manifestação temporal de lombalgia. O primeiro grupo era constituído por tenistas que não sentiram dor lombar no último ano (15), o segundo pelos que a sentiram nesse mesmo período (12) e o terceiro pelos que a sentiram nos últimos 7 dias (8).

Dos atributos extraídos no domínio do tempo (avrEMG) e da frequência (MF) identificaram-se os mais diferenciadores em relação às 3 classes por representação gráfica em diagrama de caixa (*boxplot*) sendo depois utilizados subconjuntos na construção de 4 modelos de classificação SVM.

Obtiveram-se resultados promissores na utilização do algoritmo SVM para a classificação dos EMGs, conseguindo-se uma precisão de 7 em 9 (78%) sobre o conjunto de teste para o modelo com menor número de atributos (6) originados apenas por uma prancha (exercício).

Palavras-chave: EMG, SVM, aprendizagem supervisionada, classificação, atributos, dor lombar

Abstract

The objective of this work is to identify the most important co-variables for classification of trunk muscle fatigue and low back pain in tennis players. Surface electromyography (EMG) has been collected from 35 tennis players while performing 4 isometric exercises. Two sets of attributes have been extracted from EMGs, one in time domain, EMG amplitude average (avrEMG) and the second in frequency domain, median frequency, (MF). Those attributes have been used to build classification models using Support Vector Machines (SVM) algorithm. The classification has been based in 3 groups of subjects according to their low back pain history. First group has no low back pain history (15), the second for the ones that experienced low back pain in last year (12) and the third group for the ones that experienced low back pain in last week (8).

From boxplot visualization of both type of attributes, time (avrEMG) and frequency domain (MF), those with more differentiation power among the 3 groups of subjects have been selected and used to build 4 SVM classification models.

Promising results for using SVM algorithm to classify EMGs have been found, attained a precision of 7 in 9 (78%) over the test set in the model with lower number of attributes (6) selected from a single test.

Keywords: EMG, SVM, supervised learning, classification, features, low back pain

Agradecimentos

À minha família que sempre me apoiou, mesmo nas decisões mais absurdas.

Ao Professor Doutor Pedro Serranho pela excelência letiva e pelos sábios conselhos com que foi orientando este trabalho.

Ao Professor Doutor Luís Silva pela disponibilidade demonstrada, apoio numa área que me era quase desconhecida e incentivos que me foi transmitindo ao longo desta caminhada.

À Professora Doutora Teresa Oliveira que desde o primeiro momento me estimulou à candidatura ao MBB e apoiou ao longo do percurso.

Aos restantes professores do MBB pela forma dedicada com que nos motivaram a chegar ao fim de cada unidade curricular.

À colega Carla Noronha, fonte inspiradora de energia para vencer os momentos mais difíceis.

Aos restantes colegas do MBB que foram cúmplices neste percurso e ampliaram a minha lista de amigos.

Aos meus colegas de trabalho de agora e do passado pela forma com que sempre me animaram a progredir até ao fim.

Ao Laboratório de Comportamento Motor da Faculdade de Motricidade Humana pela cedência dos dados, assim como ao Dr. Pedro Correia, responsável por essa recolha.

Índice

| | |
|---|-----|
| Resumo..... | iii |
| Abstract..... | iv |
| Agradecimentos..... | v |
| Índice..... | vi |
| Índice de Figuras..... | ix |
| Índice de Tabelas..... | x |
| 1. Introdução..... | 1 |
| 2. Revisão de Literatura..... | 4 |
| 2.1 A Eletromiografia..... | 5 |
| 2.2 Aplicações da Eletromiografia..... | 7 |
| 2.3 Estudo da Fadiga através da Eletromiografia..... | 8 |
| 2.4 Sintomatologia da Lombalgia em Tenistas..... | 8 |
| 2.5 Aprendizagem supervisionada e sua aplicação na diferenciação clínica..... | 9 |
| 2.5.1 Aprendizagem supervisionada..... | 9 |
| 2.5.2 Diferenciação Clínica de EMG's através de SVM..... | 10 |
| 3. Método..... | 12 |
| 3.1 Apresentação do Problema..... | 13 |
| 3.2 Objetivos do Estudo..... | 13 |
| 3.3 Máquinas de Vetores Suporte..... | 13 |
| 3.3.1 SVM para dados linearmente separáveis..... | 13 |
| 3.3.2 SVM linear para dados não separáveis..... | 19 |
| 3.3.3 SVM não linear..... | 20 |
| 3.3.4 SVM multiclasse..... | 21 |
| 3.4 Conjeturas sobre o Problema..... | 21 |
| 3.5 Sujeitos..... | 22 |
| 3.6 Instrumentação..... | 23 |

| | | |
|---------|---|----|
| 3.6.1 | Aquisição dos Eletromiogramas..... | 23 |
| 3.6.2 | Pré-processamento..... | 24 |
| 3.7 | Extração de Atributos | 24 |
| 3.8 | Processamento via algoritmo SVM - Máquinas de Vetores Suporte | 25 |
| 3.9 | Limitações do Estudo..... | 26 |
| 4. | Resultados..... | 27 |
| 4.1 | Análise gráfica dos atributos | 28 |
| 4.2 | Resultados Modelo 1 | 29 |
| 4.3 | Resultados Modelo 2 | 30 |
| 4.4 | Resultados Modelo 3 | 31 |
| 4.5 | Resultados Modelo 4 | 31 |
| 5. | Discussão..... | 33 |
| 5.1 | Discussão..... | 34 |
| 6. | Referências | 36 |
| 7. | Apêndices | 40 |
| 7.1 | Código (“ <i>Script</i> ”) e <i>Output</i> Análise Gráfica..... | 41 |
| 7.1.1 | Conteúdo | 41 |
| 7.1.2 | Importação dos Dados | 41 |
| 7.1.3 | Formato dos dados..... | 41 |
| 7.1.4 | Cálculo dos declives | 41 |
| 7.1.5 | Análise dos Declives por prancha | 43 |
| 7.1.5.1 | Prancha 1 - Declive Mediana da Amplitude | 43 |
| 7.1.5.2 | Prancha 2 - Declive Mediana da Amplitude | 49 |
| 7.1.5.3 | Prancha 3 - Declive Mediana da Amplitude | 53 |
| 7.1.5.4 | Prancha 4 - Declive Mediana da Amplitude | 57 |
| 7.1.6 | Declive Mediana da Frequência..... | 61 |
| 7.1.6.1 | Prancha 1 - Declive Mediana da Frequência..... | 61 |

| | | |
|---------|--|----|
| 7.1.6.2 | Prancha 2 - Declive Mediana da Frequência..... | 65 |
| 7.1.6.3 | Prancha 3 - Declive Mediana da Frequência..... | 69 |
| 7.1.6.4 | Prancha 4 - Declive Mediana da Frequência..... | 73 |
| 7.2 | Código (“ <i>Script</i> ”) para o Algoritmo SVM..... | 77 |

Índice de Figuras

| | |
|--|----|
| Figura 2.1 Eletromiograma pré-processado – contração e relaxamento do músculo | 6 |
| Figura 3.1 – Exemplos de retas que separam os dados das classes A e B | 14 |
| Figura 3.2 Melhor separação entre as classes A e B, no sentido da reta de máxima margem..... | 14 |
| Figura 3.3 Maximização da Margem de Separação..... | 15 |
| Figura 4.1 – Diferenciação dúbia e clara das classes..... | 28 |

Índice de Tabelas

| | |
|--|----|
| Tabela 4-1 Atributos diferenciados por análise gráfica | 29 |
| Tabela 4-2 - Matriz de confusão – treino – Modelo 1 | 30 |
| Tabela 4-3 - Matriz de confusão – teste – Modelo 1 | 30 |
| Tabela 4-4 – Matriz de confusão – treino – Modelo 2..... | 30 |
| Tabela 4-5 – Matriz de confusão – teste – Modelo 2..... | 30 |
| Tabela 4-6 – Matriz de confusão – treino – Modelo 3..... | 31 |
| Tabela 4-7 – Matriz de confusão – teste – Modelo 3..... | 31 |
| Tabela 4-8 – Matriz de confusão – treino – Modelo 4..... | 31 |
| Tabela 4-9 – Matriz de confusão – teste – Modelo 4..... | 32 |

1. Introdução

O trabalho apresentado tem por base métodos de aprendizagem estatística, através dos quais se pretende avaliar a existência de uma relação entre a fadiga na musculatura do tronco e a prevalência de lombalgia em tenistas.

A aprendizagem estatística consiste num conjunto de métodos ou algoritmos que servem de base para a construção de modelos matemáticos de um conjunto de dados. Estes modelos têm a capacidade de prever resultados para novos elementos não pertencentes ao conjunto a partir do qual o modelo foi criado. Podem distinguir-se duas vertentes: aprendizagem supervisionada e não supervisionada.

Os métodos de aprendizagem supervisionada, também designados por aprendizagem com professor, devem o seu nome à forma como extraem a informação para construir o modelo de decisão. O conceito de professor é uma abstração e deve-se ao facto do método usar os pares entrada/saída do conjunto de treino para a aprendizagem e construção do modelo, adaptando-o para uma resposta de erro mínimo (Haykin, 2009). A classificação é uma aplicação deste método (Luxburg & Schoelkopf, 2009). A partir de atributos recolhidos e da classificação de cada elemento do conjunto de treino, obtém-se um modelo com a capacidade de prever a que grupo pertence um novo elemento cuja classificação é desconhecida. Estes novos elementos são classificados mediante o modelo que foi anteriormente construído com dados de “treino”. Na construção deste modelo obtém-se informação quanto à precisão do processo de classificação e sobre quais os atributos com maior relevância. A importância destes modelos de classificação manifesta-se em duas vertentes. Por um lado, fornece um modelo de classificação para novos elementos. Por outro, o modelo criado pode indicar quais os atributos (ou conjunto deles) com maior capacidade discriminatória entre grupos, permitindo assim estabelecer a sua importância nessa diferenciação.

Por oposição, nos métodos de aprendizagem não supervisionada, não existe professor, ou seja, não existem pares entrada/saída como conjunto de treino, não sendo conhecidas saídas para as entradas. A Análise de Clusters e a Análise de Componentes Principais são exemplos deste tipo de aprendizagem (Haykin, 2009).

Foram extraídos atributos de amplitude e de frequência do sinal eletromiográfico para construção de modelos de Máquinas de Vetores Suporte (SVM – Support Vector Machines, com a finalidade de classificar os eletromiogramas de acordo com o historial de dor lombar dos sujeitos.

Este estudo tem como objetivo avaliar a existência de diferentes estratégias neuromusculares face à sintomatologia de lombalgia. Para tal, foram recolhidos eletromiogramas (EMG) de vários músculos em posições diferentes tendo sido analisado o poder discriminatório através de SVM.

A base de dados corresponde às respostas e medições obtidas sobre 35 tenistas que completaram um protocolo de avaliação do tronco constituído por quatro testes isométricos, nomeadamente a flexão do tronco, o teste Biering-Sørensen (extensor) e a posição de decúbito lateral para o lado direito e para o lado esquerdo.

2. Revisão de Literatura

2.1 A Eletromiografia

Um eletromiograma consiste no registo da atividade elétrica muscular medida à superfície ou em profundidade (Konrad, 2005). Estes sinais são produzidos pela variação do estado de polarização das membranas das fibras musculares, como se ilustra de seguida. Em repouso, existe uma diferença de potencial de -80 a -90 mV entre o interior e o exterior da célula muscular. Esta diferença de potencial tende a ser mantida por bombas iónicas que mantêm o interior da célula mais negativo que o exterior, existindo maior concentração de Na⁺ (Sódio) no exterior comparativamente com o interior e a situação contrária em relação ao K⁺ (Potássio), o ião que apresenta maior permeabilidade na membrana celular. O estímulo de contração da fibra muscular, originado no sistema nervoso central, é transmitido à fibra através da libertação de acetilcolina na interface entre o motoneurónio e a fibra muscular. A acetilcolina liga-se aos recetores fechados de Na⁺ no sarcolema (membrana da fibra muscular). Esta ligação leva à abertura destes canais possibilitando o influxo de Na⁺ para o interior da fibra muscular, o que conduz à despolarização da membrana. A ação contínua da bomba iónica e o encerramento dos canais de Na⁺ e abertura dos canais de K⁺ rapidamente repõe as concentrações iónicas originais dando-se como consequência a repolarização da membrana (Konrad, 2005).

A despolarização obedece à lei do tudo ou nada ocorrendo ao longo da membrana celular, propagando-se em todas as direções desta (Guyton & Hall, 2006) a uma velocidade que varia entre 2 a 6 ms⁻¹ (Konrad, 2005). Estas alterações que resultam na propagação da alteração de polaridade designam-se por potencial de ação.

Existem dois métodos para captação da atividade elétrica dos músculos: através de elétrodos de profundidade e de superfície. A utilização de elétrodos de superfície tem como principais vantagens ser um método não-invasivo e permitir captar a atividade representativa da ativação muscular. O sinal captado através de eletromiografia de superfície (sEMG) é a resultante da atividade recolhida nos tecidos da zona subcutânea sobre a qual estão colocados os elétrodos. O método de profundidade é invasivo e consiste na introdução de elétrodos em forma de agulha no interior do músculo, ficando em contacto direto com as fibras musculares. O sinal captado resulta da atividade de um conjunto de fibras musculares na sua proximidade. Devido à distribuição irregular no músculo das fibras correspondentes a uma unidade motora (várias fibras musculares

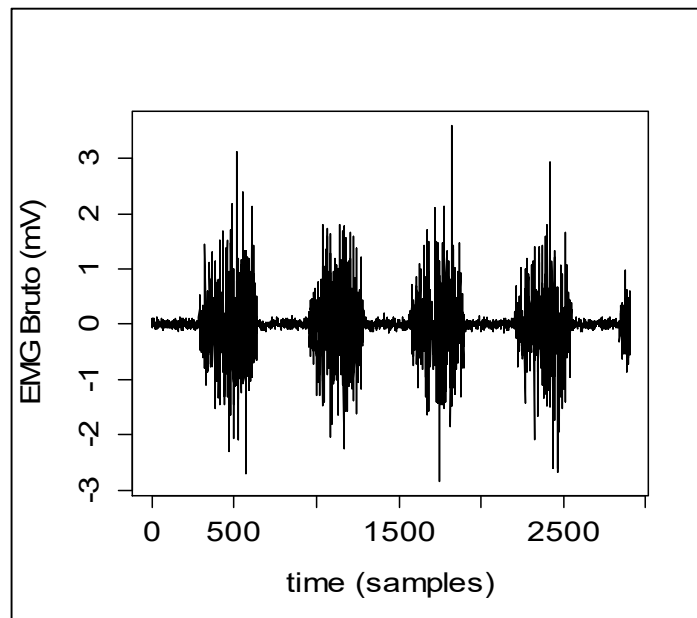
inervadas por um motoneurónio), o EMG de profundidade recolhido não reflete a totalidade do potencial de ação de uma unidade motora histológica mas antes uma mistura de potenciais gerados nas fibras mais próximas, pertencentes a mais de uma unidade motora (Pezarat-Correia & Mil-Homens, 2004).

O sinal eletromiográfico é influenciado por fatores como as características dos tecidos, interferência cruzada entre músculos próximos ao que se pretende estudar (*crosstalk*), variação da geometria dos pontos de fixação dos elétrodos e do músculo em estudo, ruído de origem externa e qualidade e tipo dos elétrodos e pelos amplificadores de sinal (Konrad, 2005).

A atividade eletromiográfica é de natureza aleatória devido à variabilidade das fibras musculares recrutadas conduzindo a registos não reprodutíveis ponto-a-ponto mas incorporando informação sobre o estado de contração muscular (Konrad, 2005).

A Figura 2.1 apresenta um sinal de eletromiografia em bruto com remoção da componente contínua (colocação da linha de base a zero). As zonas de maior amplitude correspondem à contração do músculo e os intervalos entre estas a períodos de relaxamento muscular.

Figura 2.1 Eletromiograma pré-processado – contração e relaxamento do músculo



O sinal em bruto original é constituído por impulsos positivos e negativos de amplitude aproximadamente igual e de média nula, sobrepostos a uma componente contínua

(Pezarat-Correia, 2012). A sua amplitude pode alcançar +/- 5 mV e contém um espectro de frequências entre 6 e 500 Hz, com componentes mais intensas na banda de 20 a 150Hz (Konrad, 2005).

2.2 Aplicações da Eletromiografia

A Eletromiografia tem tido nas últimas décadas uma função importante nas áreas de investigação sobre a atividade muscular compreendendo aplicações na pesquisa médica, reabilitação, ergonomia e na ciência do desporto. Nesta última, assume relevância a biomecânica, a sub-área que recorre a essa técnica de análise para estudo nas vertentes cinemática e cinética (Konrad, 2005).

De Luca (1997) detalha três grupos de aplicações no campo da biomecânica, nomeadamente ativação muscular, relação entre a força e o sinal EMG e a utilização do sinal EMG como índice de fadiga.

Visando melhorar a estabilidade dos interfaces homem-máquina baseados em sinais eletromiográficos, Tkach, Huang, e Kuiken, (2010) estudaram o impacto de perturbações como a variação da localização dos elétrodos, variação na contração muscular e fadiga na precisão da classificação obtida. Como classificador, estes autores usaram a Análise Discriminante Linear. Observaram que a utilização conjunta de mais de um atributo, de entre os 10 extraídos, aumentava a precisão de classificação. No entanto, esta não melhorava a partir da combinação de mais de 4 atributos. Para cada perturbação identificaram os 4 atributos mais estáveis, sendo que *waveLen* (Waveform Length), *AR* (Autoregression Coefficient) e *Ceps* (Cepstrum coefficients) constavam em cada uma das 3 combinações. Estas obtiveram precisão de classificação semelhante, variando entre 70 e 87%.

Num âmbito afim a este trabalho – eletromiografia de superfície aplicada ao estudo da dor lombar e fadiga muscular – em artigo de revisão de literatura entre 2000 e 2012 (Bandpei et al., 2014) conclui-se ser a eletromiografia de superfície uma ferramenta útil para a avaliação da fadiga dos músculos paraespinais em sujeitos com dor lombar. O parâmetro mais utilizado para a avaliação foi a mediana da frequência.

A análise das diferenças no tempo de resistência, fadiga e ativação muscular do tronco em tenistas com e sem lombalgia foi realizada recorrendo igualmente à eletromiografia (J. P. Correia, Oliveira, Vaz, Silva e Pezarat-Correia, 2015).

2.3 Estudo da Fadiga através da Eletromiografia

A fadiga pode ser quantificada pela modificação das propriedades espectrais do eletromiograma durante a contração muscular (de Luca, 1997). Adicionalmente, mostrou-se que o sinal eletromiográfico exibe modificações prévias à alteração da força muscular, sendo assim potencialmente útil na previsão do início da fadiga (de Luca, 1997). Entre os vários atributos possíveis de calcular a partir do EMG, a Mediana da Frequência (MF) do sinal pode ser utilizada como indicador de fadiga, incorporando as vantagens de ser menos sensível ao ruído, menos sensível à distorção (*aliasing*) e geralmente mais sensível aos processos bioquímicos e fisiológicos que ocorrem no músculo em contrações isométricas. Este tipo de contração muscular permite excluir perturbações causadas pela movimentação dos elétrodos relativamente às fibras musculares e alterações do padrão de ativação das unidades motoras. Em contrações isométricas verifica-se uma diminuição da MF em função do tempo, estando correlacionada com o estado de fadiga muscular (de Luca, 1997).

Outro atributo correlacionado com a fadiga é a Amplitude do Sinal. Verifica-se um aumento da Amplitude à medida que o músculo vai apresentando fadiga (de Luca, 1984; Troiano et al., 2008).

A Velocidade de Condução das fibras musculares e Dimensão Fractal são outros atributos que Troiano (2008) mostrou estarem relacionados com a fadiga, diminuindo ambos com o aumento desta.

2.4 Sintomatologia da Lombalgia em Tenistas

O Ténis é um desporto de elevada sollicitação dos músculos do tronco, de forma repetida e assimétrica. As forças envolvidas podem ultrapassar a resistência dos tecidos causando danos na estrutura vertebral e consequente lombalgia (Campbell, Straker, O'Sullivan, Elliott, & Reid, 2013), podendo eventualmente causar espondilose no tenista (Ellenbecker, Pluim, Vivier, & Sniteman, 2009).

Ellenbecker et al. (2009) mencionam igualmente a possibilidade dos tenistas sofrerem de alterações discais lombares, ciática e síndrome da faceta articular, também resultantes da repetitiva carga em excesso.

A dor lombar constitui um grave problema associado a esta modalidade desportiva devido a poder conduzir à interrupção forçada da sua prática (Renkawitz, Boluki, & Grifka, 2006).

A quantificação da atividade muscular do tenista através da EMG tem sido abordada em múltiplos estudos, constituindo uma via de identificar a eficácia dos gestos e dos riscos de lesão (Chow, Park, Tillman, & Grover, 2009; Creveaux et al., 2013; Girard, Micallef, & Millet, 2005; Kibler, Chandler, Shapiro, & Conuel, 2007; Pezarat-Correia et al., 2008).

Atletas com lombalgia manifestam desequilíbrio na ativação muscular da Massa Comum durante a extensão do tronco, sendo que em sujeitos assintomáticos isso não é significativo (Renkawitz et al., 2006).

2.5 Aprendizagem supervisionada e sua aplicação na diferenciação clínica

2.5.1 Aprendizagem supervisionada

A aprendizagem supervisionada consiste na criação de um modelo a partir de exemplos “entrada-saída”, motivada pela forma de aprendizagem do ser humano. O conjunto dos exemplos entrada-saída designa-se por conjunto de treino. A solução é encontrada pelo algoritmo de aprendizagem escolhendo, de entre uma família de funções candidatas, a que consegue melhor desempenho. Conforme os valores possíveis para a saída, o problema será de classificação binária se apenas forem possíveis dois valores, de classificação multiclasse para um número finito de possibilidades e de regressão se a solução for um conjunto de valores reais (Cristianini & Shawe-Taylor, 2000).

As Máquinas de Vetores Suporte (SVM – *Support Vector Machines*) constituem um algoritmo de classificação baseado em aprendizagem supervisionada que foi apresentado no início da década de 90 do século XX (Boser, Guyon, & Vapnik, 1992) e desenvolvido posteriormente por (Vapnik, 1999) e seus colaboradores (Cristianini & Shawe-Taylor, 2000).

2.5.2 Diferenciação Clínica de EMG's através de SVM

A extração de atributos do sinal eletromiográfico é essencial para introdução num classificador. De acordo com a literatura, os atributos podem agrupar-se nos domínios do tempo, da frequência ou do tempo-frequência (Phinyomark et al., 2013).

Da multiplicidade de atributos extraíveis, muitos poderão ser redundantes especialmente os no domínio do tempo pelo que a sua escolha deve ter este aspeto em consideração reduzindo o número dos atributos utilizados no classificador (Phinyomark, Phukpattaranont, & Limsakul, 2012).

Dos classificadores conhecidos, as SVM são dos mais recentes e têm por base uma forte base teórica. Num estudo comparativo com LDA (*Linear Discriminant Analysis*) e MLP (*Multi Layer Perceptron*) as SVM obtiveram uma precisão de 95%, semelhante à LDA e ao MLP com duas camadas internas. Já o MLP com uma única camada interna apenas alcançou os 89% (Oskoei & Hu, 2007). O estudo incidiu sobre a utilização de sEMG para classificação de movimentos do membro superior para efeitos de utilização em Sistemas de Controlo Mioelétrico de motores elétricos e atuadores. Tomados os devidos cuidados na captação do sinal para evitar ao máximo as interferências, é possível dele extrair atributos válidos para classificação em vários contextos. Oskoei & Hu (2007) descrevem uma sequência de procedimentos para reconhecimento de padrões nos atributos derivados de sEMG para efeitos de aplicação a uma interface Homem-Máquina de controlo mioelétrico:

1. Aquisição do sinal eletromiográfico através de elétrodos de superfície com pré-amplificador incorporado, filtro passa-banda 10-450Hz e filtro de rejeição da frequência da rede elétrica (50/60Hz). Digitalização a 1000Hz /12 bit.
2. Extração dos atributos relevantes em cada canal a partir de segmentos de 200ms. Os atributos extraídos para este estudo foram um grupo constituído por MAV (*Mean Absolute Value*), WL (*Waveform Length*), ZC (*Zero Crossing*) e SSC (*Slope Sign Changes*), e outro grupo constituído por RMS (Root Mean Square) e AR6 (*Autoregressive Coefficients of Order 6*).
3. Classificação dos atributos: No caso de SVM o algoritmo é treinado antecipadamente com padrões conhecidos e otimizado por busca em grelha para os parâmetros do modelo e *5-fold cross-validation*.
4. Avaliação: Verificação do desempenho do classificador.

Também para efeito do controlo de 4 movimentos de próteses a partir de sEMG, as SVM obtiveram uma precisão de 99% em cada um dos movimentos, superando a precisão da LDA que se situou entre 96 e 98% (Alkan & Günay, 2012).

3. Método

3.1 Apresentação do Problema

A dor lombar é muito comum nos tenistas. Pode ter como causas a postura, a disfunção muscular, excesso de exercício, instabilidade ou disfunção articular da zona lombar. No entanto, em 95% dos casos não se encontram anomalias físicas específicas que a possam explicar (IFT, 2017).

A fadiga muscular está correlacionada com a atividade eletrofisiológica do músculo, permitindo a sua avaliação a partir do eletromiograma (de Luca, 1984).

Este trabalho foca-se na investigação de eventuais relações entre a fadiga muscular e a prevalência de lombalgia, a partir do registo eletromiográfico de jogadores de ténis com e sem manifestação de dor lombar.

3.2 Objetivos do Estudo

Recorrendo a técnicas de aprendizagem supervisionada, nomeadamente Máquinas de Vetores Suporte – SVM (*support vector machines*), pretende-se encontrar um classificador capaz de diferenciar os sinais EMG provenientes de sujeitos com e sem lombalgia.

A partir do sinal EMG digitalizado podem extrair-se atributos (Phinyomark et al., 2012), de que são exemplos a Amplitude e a Mediana da Frequência, utilizados neste estudo. Com estes atributos treina-se um algoritmo de SVM com vista à obtenção de um modelo de classificação para os EMGs.

Estabelecido o classificador será possível identificar quais as propriedades dos sinal EMG mais importantes para a classificação e assim identificar quais as propriedades do sinal que estão relacionadas com a prevalência de dor lombar.

3.3 Máquinas de Vetores Suporte

3.3.1 SVM para dados linearmente separáveis

O caso SVM mais simples é aquele cujos dados pertencem a uma de duas classes e são linearmente separáveis, isto é, existe um hiperplano que passa entre os dois conjuntos de pontos de cada classe, separando um do outro. A regra de decisão para identificar a que classe pertence um dado ponto pode ser definida assim pelo hiperplano. A Figura 3.1

em 2D representa dois conjuntos de pontos (com dados bidimensionais) e três possíveis opções para a reta de separação, de entre uma infinidade de possibilidades.

Figura 3.1 – Exemplos de retas que separam os dados das classes A e B

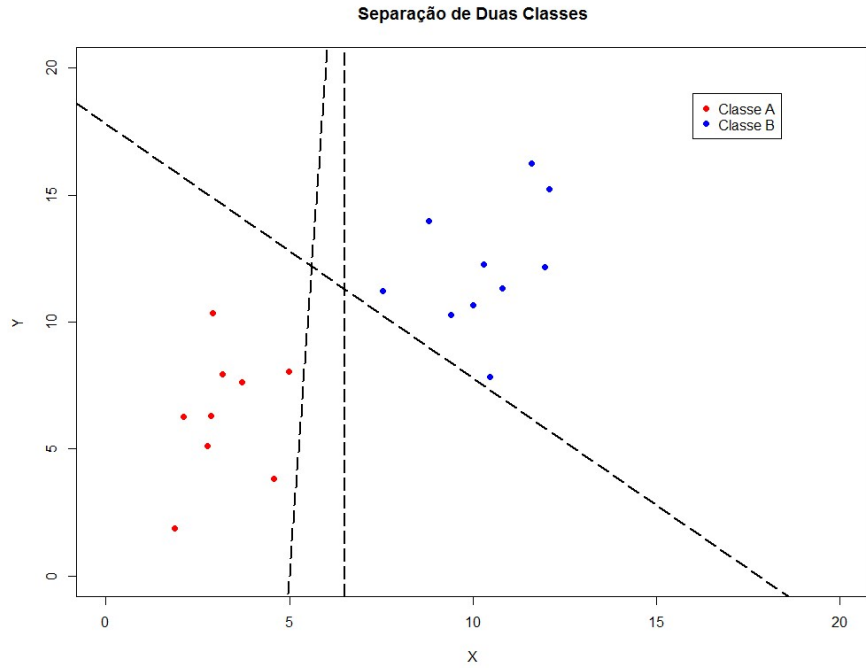
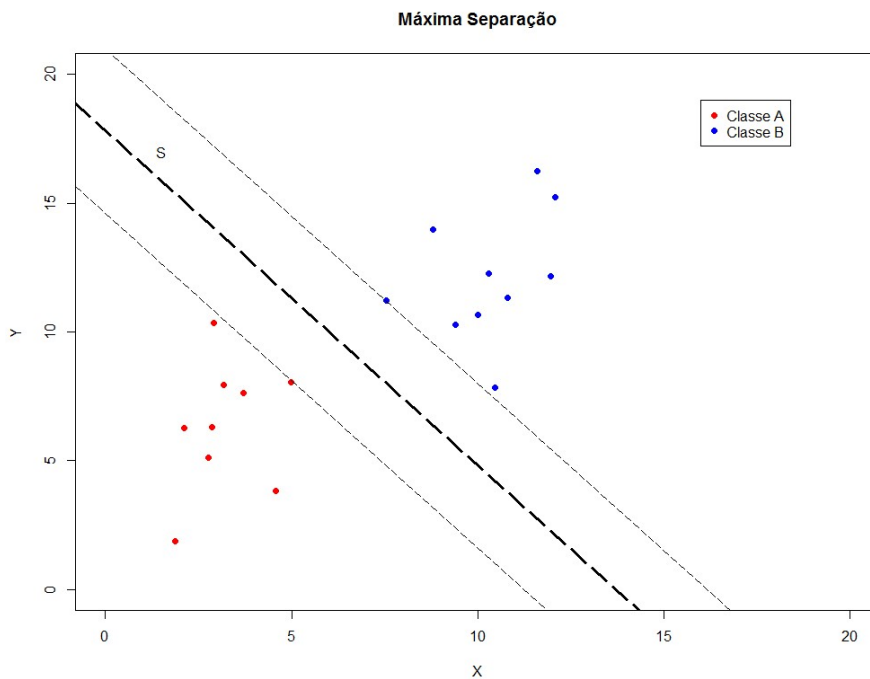


Figura 3.2 Melhor separação entre as classes A e B, no sentido da reta de máxima margem



Ainda que qualquer uma das retas consideradas separe os pontos conhecidos de ambas as classes, a reta s da Figura 3.2 é a que o faz da melhor forma no sentido seguinte. Esta reta pode definir-se como aquela cuja distância relativamente aos pontos mais próximos de cada classe é a maior possível, designando-se por reta de margem máxima.

No caso tridimensional de dados linearmente separáveis em duas classes, a separação ótima entre as duas classes seria um plano.

Numa abordagem mais formal, seja um conjunto de treino com p elementos \mathbf{x}_i , pontos de dimensão n , cada um pertencente a y_i , ou seja,


$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_p, y_p) \quad (1)$$

$$\text{onde } \begin{cases} y_i = 1 & \text{se } \mathbf{x}_i \text{ pertence à classe A,} \\ y_i = -1 & \text{se } \mathbf{x}_i \text{ pertence à classe B} \end{cases}$$

O objetivo é que o algoritmo, após o treino, encontre os parâmetros da função de decisão $D(\mathbf{x})$ para que se possam classificar elementos desconhecidos de acordo com a seguinte regra (Boser et al., 1992):

$$\begin{aligned} \mathbf{x} \in A & \text{ se } D(\mathbf{x}) > 0 \\ \mathbf{x} \in B & \text{ se } D(\mathbf{x}) \leq 0 \end{aligned} \quad (2)$$

Figura 3.3 Maximização da Margem de Separação



Como exemplo, vamos considerar o caso bidimensional e dados separáveis, ilustrado na Figura 3.3.

Os pontos de um hiperplano podem representar-se pela expressão (3), onde \mathbf{w} é um vetor normal ao hiperplano e \mathbf{u} outro vetor cujas coordenadas correspondem às de um ponto genérico desse hiperplano. O parâmetro b define a distância do hiperplano à origem.

$$\mathbf{w} \cdot \mathbf{u} + b = 0 \quad (3)$$

Voltando ao exemplo, o objetivo é calcular o hiperplano que melhor separa os pontos das duas classes, designado por hiperplano de margem máxima (Cortes & Vapnik, 1995), aqui identificado pela reta s , pelo procedimento abaixo descrito.

Uma vez que as classes são separáveis, existirá uma banda onde não existem pontos, correspondente à margem de separação entre as classes cuja amplitude, M , queremos maximizar e cuja linha média é a reta s . Estabeleça-se que se verificam as seguintes relações para todos os pontos \mathbf{x} de cada uma das classes A e B :

$$\begin{aligned} \mathbf{w} \cdot \mathbf{x}_i + b &\geq 1, \text{ se } y_i = 1 \\ \mathbf{w} \cdot \mathbf{x}_i + b &\leq -1, \text{ se } y_i = -1 \end{aligned} \quad (4)$$

Atendendo ao valor da variável de classificação y_i tal que

$$\begin{aligned} y_i &= 1 \quad \text{se } \mathbf{x} \in A \\ y_i &= -1 \quad \text{se } \mathbf{x} \in B \end{aligned} \quad (5)$$

Multiplicando as expressões (4) pelo valor correspondente de y_i , obtém-se

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq 0 \quad (6)$$

para qualquer $i=1,2,\dots,p$ e para os pontos que estejam sobre os limites da margem (retas s_1 e s_2 , paralelas e equidistantes a s limitando a zona livre de pontos):

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 = 0 \quad (7)$$

para alguns valores de i .

Sejam \mathbf{x}_A e \mathbf{x}_B vetores correspondentes a pontos das classes A e B que se situem sobre as margens (podem não ser únicos para cada classe), conforme ilustrado na Figura 3.3.

A largura da margem, M , será a projeção de $\mathbf{x}_A - \mathbf{x}_B$ segundo a normal a s_1 e s_2 , quaisquer que sejam os pontos escolhidos, desde que estejam sobre as margens e em margens opostas. O vetor \mathbf{w} é normal a s_1 e s_2 , logo

$$M = (\mathbf{x}_A - \mathbf{x}_B) \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} \quad (8)$$

Combinando (8) com (7) e (5), obtém-se:

$$M = \frac{2}{\|\mathbf{w}\|} \quad (9)$$

Maximizar M dado por (9) é equivalente em termos de argumento a minimizar $\|\mathbf{w}\|$ ou por conveniência matemática a minimizar $1/2 \times \|\mathbf{w}\|^2$. Em qualquer dos casos os constrangimentos de (7) terão de ser satisfeitos.

A minimização pode fazer-se recorrendo ao método dos multiplicadores de Lagrange e existem duas razões que o justificam. A primeira é que as restrições são substituídas por restrições nos multiplicadores de Lagrange, logo a formulação é menos complexa. A segunda é que os dados usados para treino do algoritmo apenas aparecem na forma de produto interno de vetores (Burges, 1998). Este último facto facilita a extensão a dados não separáveis linearmente, como veremos adiante.

A função Lagrangeana é dada por:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^p \alpha_i [y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1] \quad (10)$$

O mínimo em \mathbf{w} encontra-se no ponto em que as derivadas parciais de L

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^p \alpha_i y_i \mathbf{x}_i \quad \frac{\partial L}{\partial b} = \sum_{i=1}^p \alpha_i y_i \quad (11)$$

se anulam, ou seja,

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^p \alpha_i y_i \mathbf{x}_i \quad (12)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^p \alpha_i y_i = 0 \quad (13)$$

A expressão (12) mostra que o hiperplano ótimo se escreve como combinação linear dos vetores de treino e que apenas aqueles em que $\alpha_i > 0$ contribuem para a solução, sendo estes designados por vetores suporte (Lorena & de Carvalho, 2007).

Substituindo (12) em (10), obtemos

$$L_D = \frac{1}{2} \left(\sum_{i=1}^p \alpha_i y_i \mathbf{x}_i \right) \cdot \left(\sum_{j=1}^p \alpha_j y_j \mathbf{x}_j \right) - \left(\sum_{i=1}^p \alpha_i y_i \mathbf{x}_i \cdot \left(\sum_{j=1}^p \alpha_j y_j \mathbf{x}_j \right) \right) - \sum_{i=1}^p \alpha_i y_i b + \sum_{i=1}^p \alpha_i \quad (14)$$

Simplificando e atendendo a (13) tem-se:

$$L_D = \sum_{i=1}^p \alpha_i - \frac{1}{2} \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (15)$$

A solução do problema de otimização consiste no ponto sela do Lagrangeano (10), minimizando relativamente ao parâmetro \mathbf{w} e maximizando (15) relativamente aos multiplicadores de Lagrange, $\alpha_i \geq 0$ (Cortes & Vapnik, 1995; Lorena & de Carvalho, 2007), com as restrições:

$$\begin{cases} \alpha_i \geq 0, & \forall i = 1, \dots, p \\ \sum_{i=1}^p \alpha_i y_i = 0 \end{cases} \quad (16)$$

Designando por α^* a solução da maximização de (15), a solução associada \mathbf{w}^* pode calcular-se por (12). Para calcular a solução b^* é necessário recorrer às condições de Karush-Kuhn-Tucker que no espaço dual se traduzem por (Lorena & de Carvalho, 2007; Vapnik, 1999):

$$\alpha_i^* (y_i (\mathbf{w}^* \cdot \mathbf{x}_i + b^*) - 1) = 0, \quad \forall i = 1, \dots, p \quad (17)$$

Por (17) e atendendo a (7), verifica-se que α_i^* só pode ser não nulo para os pontos que se encontram sobre as margens, designados por vetores suporte.

O valor de b^* é dado por:

$$b^* = \frac{1}{n_{SV}} \sum_{\mathbf{x}_j \in SV} \frac{1}{y_j} - \mathbf{w}^* \cdot \mathbf{x}_j \quad (18)$$

onde n_{SV} é o número de vetores suporte e SV é o conjunto dos vetores suporte (Lorena & de Carvalho, 2007).

Finalmente, o resultado final da função de classificação para duas classes é dada por (Lorena & de Carvalho, 2007):

$$D(\mathbf{x}) = \sum_{\mathbf{x}_i \in SV} y_i \alpha_i^* \mathbf{x}_i \cdot \mathbf{x} + b^* \quad (19)$$

3.3.2 SVM linear para dados não separáveis

Nos problemas reais é comum os dados não serem linearmente separáveis. O algoritmo encontrado anteriormente, designado por SVM de margens rígidas, pode ser expandido pela introdução de variáveis de folga nos constrangimentos, $\xi \geq 0$, designando-se agora por SVM de margens suaves (Burges, 1998; Cristianini & Shawe-Taylor, 2000):

$$\begin{aligned} \mathbf{w} \cdot \mathbf{x}_i + b &\geq +1 - \xi_i \text{ para } y_i = +1 \\ \mathbf{w} \cdot \mathbf{x}_i + b &\leq -1 + \xi_i \text{ para } y_i = -1 \end{aligned} \quad (20)$$

ou, de forma simplificada:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq -\xi_i \quad (21)$$

O classificador permite agora a existência de dados entre os hiperplanos marginais (onde se situam os vetores suporte) e quando $\xi_i > 1$, existe um erro de treino, ou seja, o elemento i será mal classificado (Lorena & de Carvalho, 2007). Numa interpretação geométrica, admite-se que os elementos possam estar no interior da margem de separação; $\xi_i > 1$ faz com que o elemento i esteja para lá do hiperplano de separação relativamente à classe a que pertence.

Como $\sum_i \xi_i$ constitui o limite superior dos erros de treino, uma forma natural de atribuir um custo extra para os erros é em vez de minimizar $\frac{1}{2} \|\mathbf{w}\|^2$, minimizar $\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i$ onde C é um parâmetro escolhido quantificador da penalidade para os erros, com a restrição $0 \leq \alpha_i \leq C$ (Burges, 1998).

O algoritmo SVM de margens suaves, conforme apresentado até aqui, possibilita a sua aplicação a maior variedade de problemas de classificação mas ainda com a limitação de ser um classificador linear, isto é, é utilizado um hiperplano na dimensão considerada como superfície de separação, sendo admitido algum erro de classificação na aprendizagem.

Outra possibilidade é considerar separação não linear, o que é usualmente feito através de uma transformação não linear dos dados para um espaço de dimensão superior onde

se aplica um classificador linear (Burges, 1998; Cristianini & Shawe-Taylor, 2000). Embora este procedimento pareça mais complicado, na realidade não o é, pois não é preciso explicitar a transformação não linear a considerar, como veremos de seguida.

3.3.3 SVM não linear

A generalização do algoritmo SVM para separadores não lineares tem por base um truque, conhecido por “Kernel trick”, (Aizerman, Braverman, & Rozonoer, 1964) cuja utilização foi proposta por (Boser et al., 1992). Atendendo a que os dados de treino apenas aparecem na solução sob a forma de produto interno de vetores (15), pode previamente aplicar-se-lhes uma transformação para um espaço Euclidiano \mathcal{H} , de maior dimensão através de um mapeamento designado por Φ (Burges, 1998; Müller, Mika, Rätsch, Tsuda, & Schölkopf, 2001) :

$$\begin{aligned} \Phi: \mathbb{R}^d &\rightarrow \mathcal{H} \\ \mathbf{x} &\rightarrow \Phi(\mathbf{x}) \end{aligned} \quad (22)$$

O espaço Euclidiano \mathcal{H} poderá ter dimensão infinita, não sendo fácil determinar Φ de forma explícita. No entanto, a substituição de $\mathbf{x}_i \cdot \mathbf{x}_j$ por $K(\mathbf{x}_i, \mathbf{x}_j)$ em (15) onde K é uma função Kernel tal que $K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ permite a realização do treino num espaço de tempo semelhante ao necessário para o treino com os dados originais e sem necessitar de explicitar a função Φ . A função de decisão é agora dada pelo sinal de $f(\mathbf{x})$ (Burges, 1998):

$$f(\mathbf{x}) = \sum_{i=1}^{NS} \alpha_i y_i \Phi(\mathbf{s}_i) \cdot \Phi(\mathbf{x}) + b = \sum_{i=1}^{NS} \alpha_i y_i K(\mathbf{s}_i, \mathbf{x}) + b \quad (23)$$

onde \mathbf{s}_i são os vetores suporte e NS é o seu número.

Nem todas as funções podem ser utilizadas como Kernel K , por forma a corresponder a uma função Φ de interesse. Para que uma função possa ser Kernel deve satisfazer o Teorema de Mercer que de forma simplificada implica que dê origem a matrizes semi-definidas positivas quando aplicada aos vetores suporte e seja simétrico (Lorena & de Carvalho, 2007).

O truque da transformação para uma dimensão superior através da função Kernel permite em teoria que a aplicação de um classificador SVM linear de margens suaves obtenha um erro menor (ou igual) do que se aplicado no espaço original (Lorena & de Carvalho, 2007), uma vez que aumenta a flexibilidade do separador.

As funções Kernel mais referidas na literatura e que usualmente se encontram implementadas nos diversos *softwares* de processamento de dados são (Hsu, Chang, & Lin, 2010):

- Linear: $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$
- Polinomial: $K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^d$, $\gamma > 0$
- Gaussiano RBF (*Radial Basis Function*):

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \quad \gamma > 0$$

- Sigmoidal: $K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + r)$

Como é fácil observar, a desvantagem destes métodos é que são introduzidos mais parâmetros, nomeadamente para a função Kernel. Estes parâmetros são geralmente estimados por validação cruzada, por forma a otimizar a percentagem de precisão do classificador na fase de treino.

3.3.4 SVM multiclasse

O classificador SVM nas suas variantes descritas anteriormente é um classificador binário, isto é, classifica um novo elemento entre duas classes. Existem, porém, muitas situações em que as classes são mais de duas. A expansão do SVM para k classes pode fazer-se, entre outras, por duas abordagens. A primeira consiste em treinar k classificadores binários independentes em que cada um distingue uma classe do conjunto das restantes. Um elemento desconhecido é classificado por todos os classificadores e aquele cujo resultado da função de decisão for mais elevado indica a classe do novo elemento. Este procedimento designa-se por “Um contra Todos”. A segunda abordagem é designada por “Um contra Um”. Nesta, $k(k-1)/2$ classificadores binários são treinados para separar cada par de duas classes. Para classificar um novo elemento, a classe que receber mais votos dos classificadores binários é-lhe atribuída. O método “Um contra Um” tem a vantagem de calcular a probabilidade de cada elemento pertencer a cada uma das classes (Oskoei & Hu, 2007).

3.4 Conjeturas sobre o Problema

As conjeturas que irão ser testadas para encontrar uma solução para o problema colocado são:

C1: Os perfis de fadiga diferem entre sujeitos com e sem manifestação de lombalgia.

C2: A diferenciação dos perfis de fadiga pode fazer-se através de um pequeno número de atributos utilizados no modelo.

Em vez de testarmos estas conjeturas de forma clássica, procurando diferenças de médias entre grupos, vamos tentar ir mais longe e obter um classificador que nos indique se um sujeito tem ou não lombalgia, dado o seu perfil de fadiga (leia-se o sinal EMG de alguns exercícios longos, por forma a provocar fadiga, ver secção 3.6.1., adiante). O classificador, além de permitir verificar se essa diferença existe (consoante a sua precisão for mais ou menos elevada), permite também identificar que perfis de fadiga são mais importantes para a classificação e assim para a distinção entre os grupos.

Para a primeira conjetura tentaremos uma classificação binária com um modelo treinado a partir dos atributos dos sujeitos com e sem manifestação de lombalgia.

Para a segunda, iremos reduzindo o número de atributos utilizados no treino do modelo e para a classificação. Esperamos conseguir uma precisão de classificação elevada com um reduzido número de atributos.

3.5 Sujeitos

O estudo partiu de 37 tenistas voluntários, dos quais 35 (28 do sexo masculino, 7 do sexo feminino, idade 18.54 ± 3.00 anos) cumpriam os critérios para inclusão. Um dos tenistas foi excluído por ter sido submetido anteriormente a cirurgia do tronco e outro por não conseguir executar as posições das pranchas (Exercícios em que foram recolhidos os sinais de EMG) devido a entorse no tornozelo.

Os critérios de inclusão foram:

- Mínimo de 3 anos de prática de ténis.
- Mínimo de 6 horas/semana de prática de ténis no último ano.
- Presentemente integrados em competições nacionais ou de nível superior.

Os critérios de exclusão foram:

- Historial de cirurgia tronco/coluna.
- Historial de patologia músculo-esquelética severa (cirurgia do tronco, tumor, infeção, escoliose estrutural, fratura da coluna).
- Prática de outra atividade desportiva por 3 ou mais vezes por semana (excluindo treino físico).
- Ser incapaz de assumir as posições dos testes.

O recrutamento foi alheio ao estado atual de sintomatologia de lombalgia.

3.6 Instrumentação

3.6.1 Aquisição dos Eletromiogramas

Os sujeitos executaram um protocolo de resistência da musculatura do tronco (Mcgill et al., 1999) constituído por 4 pranchas isométricas (posição em que é executado um exercício. Duas em decúbito lateral esquerdo/direito e as outras duas em decúbito dorsal flexão/extensão. Foram dadas instruções de encorajamento a manter a posição tanto tempo quanto possível. A sequência das pranchas foi aleatória e houve 5 min de intervalo de recuperação entre cada uma delas. O início e o fim da aquisição dos eletromiogramas foram determinados através do acionamento do teclado. A fadiga foi a razão indicada por todos os sujeitos para o fim do exercício.

Na zona de aplicação dos elétrodos a pele foi depilada e limpa com álcool. Foram utilizados elétrodos bipolares (Ag-AgCl, 10 mm de diâmetro) AMBU® Bluesensor N (AMBU, Ballerup, Dinamarca) com gel condutor, alinhados com a orientação das fibras musculares e com uma distância centro-a-centro de 20mm. O sinal eletromiográfico foi adquirido por um sistema de aquisição bioPLUX 2010 (PLUX, Lisboa, Portugal) com uma rejeição em modo comum de 110 dB, impedância de entrada superior a 100 MΩ e um ganho diferencial de 10^3 . A frequência de amostragem foi de 10^3 Hz. Nos sujeitos canhotos os músculos direitos foram processados como esquerdos e vice-versa para garantir a consistência dos dados.

Foram recolhidos eletromiogramas bilateralmente dos músculos *rectus abdominis*, *external obliques*, *iliocostalis lumborum* e *longissimus thoracis*.

3.6.2 Pré-processamento

O eletromiograma bruto foi recolhido e processado em MATLAB (*The Mathworks Inc.*, Natick, Massachusetts). Foi-lhe aplicado um filtro banda passante (10-490 Hz), retificado em onda completa e suavizado por um filtro Butterworth de 4ª ordem, 12 Hz. O resultado foi depois normalizado em amplitude pela média do intervalo entre os 3º e 6º segundos de cada teste. Os primeiros 3s foram ignorados para assegurar a estabilidade do sinal e maior consistência na normalização. A duração do teste foi normalizada para 100% da duração de cada teste para permitir a comparação entre exercícios.

3.7 Extração de Atributos

A partir do sinal eletromiográfico filtrado e normalizado extraíram-se o valor médio da amplitude e a mediana da frequência (Phinyomark, Limsakul, & Phukpattaranont, 2009).

Os valores médios da amplitude (avrEMG) foram obtidos pela fórmula:

$$avrEMG = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (24)$$

onde N é o número de amostras¹ consideradas e x_i o valor de cada uma delas.

Os valores da mediana da frequência (MF) foram obtidos a partir dos dados filtrados digitalmente (10-490 Hz) pela equação:

$$\int_0^{MF} S_m(f) df = \int_{MF}^{\infty} S_m(f) df \quad (25)$$

onde $S_m(f)$ é o espectro de frequência do sinal, MF é a mediana da frequência do sinal e f é a frequência em Hz. Os valores de MF foram determinados pelo algoritmo *Fast Fourier Transform* (FFT) em janelas temporais de 1000ms.

Os valores médios de avrEMG e MF foram calculados em janelas de 2000ms para cada um dos percentis decimais, o que juntamente com o valor inicial produziu 11 valores para cada eletromiograma.

¹ O sinal eletromiográfico foi digitalizado com uma frequência de 10³Hz, ou seja, em cada segundo existem 1000 amostras do sinal.

3.8 Processamento via algoritmo SVM - Máquinas de Vetores Suporte

Para o processamento foi utilizado o software R, versão 3.2.2 integrado no ambiente de desenvolvimento RStudio, versão 1.0.136.

Foram usadas as bibliotecas **e1071** versão 1.6.7 (funções svm) e **ggplot2** versão 1.0.1 (criação de gráficos).

Foi seguido o procedimento indicado na literatura da especialidade (Hsu et al., 2010).

Os atributos extraídos diretamente dos EMGs eram em número excessivamente grande, tornando-se redundantes e pela variabilidade inerente à aquisição do sinal tornou-se necessária a sua redução (Phinyomark et al., 2012). Optou-se pela regressão linear dos 11 momentos (percentis) relativos a cada músculo e prancha, para a avrEMG e para a MF. Os declives correspondentes a cada reta de regressão constituem os novos atributos. Através da sua representação gráfica por classe, “Box-plot” ou diagrama de caixa, foi feita uma seleção visual dos relativos ao músculo e prancha que mais se diferenciavam entre classes, atendendo às informações diretamente identificáveis (mediana, quartis e eventual presença de *outliers*). Finalmente os atributos selecionados usaram-se para treinar o modelo svm.

Foram consideradas 3 classes de sujeitos (A, n=15, sem manifestação de dor lombar; B, n=12, com manifestação de dor lombar no último ano e C, n=8, com manifestação de dor lombar na última semana.

Os 35 sujeitos foram repartidos em dois grupos, treino e teste (75% / 25%), tendo o cuidado de garantir proporções semelhantes de todas as classes para ambos os grupos.

Para a construção do modelo SVM recorreu-se a um *Kernel* não-linear do tipo Gaussiano (*RBF – Radial Basis Function*).

Após uma afinação inicial do modelo através da função “*tune.svm*”, onde eram identificados os melhores valores dos parâmetros “ γ ” e “C”, encontrou-se o modelo final sendo a sua precisão avaliada por validação cruzada² (3 vezes), “*3-fold cross validation*”. O número 3 foi selecionado em função do baixo número de sujeitos no grupo de treino.

² Os dados são internamente divididos aleatoriamente em 3 grupos. Guarda-se um grupo para testar o modelo que se obtém com os restantes, procedendo assim com cada um dos 3 grupos. A performance do modelo é a média das performances obtidas em cada um dos 3 modelos.

3.9 Limitações do Estudo

Embora o algoritmo SVM se adeque a amostras pequenas, dada também a assimetria do número de elementos por classe, a generalização do modelo fica limitada.

4. Resultados

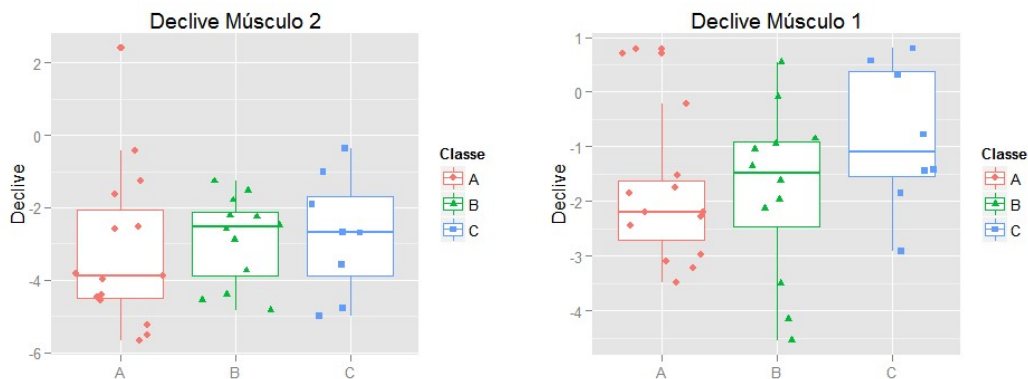
4.1 Análise gráfica dos atributos

O elevado número de atributos originais, 352 para avrEMG e outros 352 para MF, originados por 11 percentis para cada um dos 8 músculos e cada uma das 4 pranchas, quando usado em simultâneo na construção do modelo SVM conduziu a modelos com capacidade de classificação inferior a 50%, logo sem a utilidade pretendida. Atribui-se este resultado à elevada dimensionalidade e redundância dos atributos.

Após a primeira redução do número de atributos através da obtenção do declive da reta de regressão para cada conjunto dos 11 momentos (percentis) e usando todos os declives, o resultado não melhorou de forma significativa, continuando a ser insuficiente.

A análise gráfica dos declives e subsequente seleção dos que mais diferiam entre classes, permitiu a redução dos atributos para 13, sendo cada um o declive da reta de regressão correspondente a uma prancha, um músculo e um tipo de atributo (avrEMG ou MF), conforme se mostra na Tabela 4.1. Os gráficos da figura 4.1 são exemplo de diferenciação dúbia e diferenciação clara das classes em função dos declives.

Figura 4.1 – Diferenciação dúbia e clara das classes



Da análise da Tabela 4-1, verifica-se que a prancha 1 não conduz a diferenciação visual para nenhum dos músculos, que as pranchas 2 e 4 são as mais diferenciadoras e que a Mediana da Frequência é mais diferenciadora que a Amplitude Média.

Tabela 4-1 Atributos diferenciados por análise gráfica

| Prancha ----- Músculo | Amplitude Média, avrEMG | | | | Mediana da Frequência, MF | | | |
|-----------------------------|-------------------------|---|---|---|---------------------------|---|---|---|
| | 1 | 2 | 3 | 4 | 1 | 2 | 3 | 4 |
| 1 | | X | | | | X | | |
| 2 | | | | X | | | | X |
| 3 | | | | | | X | X | |
| 4 | | | | | | | | X |
| 5 | | X | | | | | | X |
| 6 | | X | | | | | | |
| 7 | | | | | | | X | |
| 8 | | | X | | | X | | |

Construíram-se os seguintes modelos SVM, diferenciando-se pelo número de atributos utilizados na sua construção:

Modelo 1: Totalidade dos declives calculados (32 + 32)

Modelo 2: Totalidade dos declives identificados graficamente (5 avrEMG + 8 MF)

Modelo 3: Os declives relativos aos músculos identificados graficamente para as duas pranchas mais diferenciadoras, 2 e 4 (4 avrEMG + 6 MF)

Modelo 4: Os declives relativos à prancha mais diferenciadora, prancha 2, (3 avrEMG + 3 MF)

Para cada um dos modelos apresentam-se as matrizes de confusão para os dados de treino e de teste (estes não entraram no modelo):

4.2 Resultados Modelo 1

Após aplicação do modelo, usando os parâmetros resultantes da sua afinação, $C = 2$ e $\gamma = 0.015625$, obtiveram-se os resultados constantes nas tabelas 4.2 e 4.3 para o modelo RBF.

Tabela 4-2 - Matriz de confusão – treino – Modelo 1

| | | Real | | |
|----------|---|-----------|----------|----------|
| | | A | B | C |
| Previsto | A | 11 | 0 | 0 |
| | B | 0 | 9 | 0 |
| | C | 0 | 0 | 6 |

Tabela 4-3 - Matriz de confusão – teste – Modelo 1

| | | Real | | |
|----------|---|----------|----------|----------|
| | | A | B | C |
| Previsto | A | 3 | 2 | 1 |
| | B | 1 | 1 | 0 |
| | C | 0 | 0 | 1 |

Classificação de 100% correta para os sujeitos usados na construção do modelo mas apenas classificação correta de 5 em 9 (56%) para o conjunto de teste.

4.3 Resultados Modelo 2

Após aplicação do modelo, usando os parâmetros resultantes da sua afinação, $C = 8$ e $\gamma = 0.0625$, obtiveram-se os resultados constantes nas tabelas 4.4 e 4.5 para o modelo RBF.

Tabela 4-4 – Matriz de confusão – treino – Modelo 2

| | | Real | | |
|----------|---|-----------|----------|----------|
| | | A | B | C |
| Previsto | A | 11 | 0 | 0 |
| | B | 0 | 9 | 0 |
| | C | 0 | 0 | 6 |

Tabela 4-5 – Matriz de confusão – teste – Modelo 2

| | | Real | | |
|----------|---|----------|----------|----------|
| | | A | B | C |
| Previsto | A | 1 | 1 | 0 |
| | B | 3 | 2 | 2 |
| | C | 0 | 0 | 0 |

Classificação pobre sobre o conjunto de teste, apenas 3 em 9 (33%), não identificando nenhum elemento da classe C.

4.4 Resultados Modelo 3

Após aplicação do modelo, usando os parâmetros resultantes da sua afinação, $C = 32$ e $\gamma = 0.03125$, obtiveram-se os resultados constantes nas tabelas 4.6 e 4.7 para o modelo RBF.

Tabela 4-6 – Matriz de confusão – treino – Modelo 3

| | | Real | | |
|----------|---|-----------|----------|----------|
| | | A | B | C |
| Previsto | A | 11 | 0 | 0 |
| | B | 0 | 9 | 0 |
| | C | 0 | 0 | 6 |

Tabela 4-7 – Matriz de confusão – teste – Modelo 3

| | | Real | | |
|----------|---|----------|----------|----------|
| | | A | B | C |
| Previsto | A | 1 | 1 | 0 |
| | B | 3 | 2 | 0 |
| | C | 0 | 0 | 2 |

Classificação razoável, 5 em 9 (56%), do conjunto de teste.

4.5 Resultados Modelo 4

Após aplicação do modelo, usando os parâmetros resultantes da sua afinação, $C = 2$ e $\gamma = 0.0625$, obtiveram-se os resultados constantes nas tabelas 4.8 e 4.9 para o modelo RBF.

Tabela 4-8 – Matriz de confusão – treino – Modelo 4

| | | Real | | |
|----------|---|----------|----------|----------|
| | | A | B | C |
| Previsto | A | 8 | 4 | 3 |
| | B | 3 | 5 | 1 |
| | C | 0 | 0 | 2 |

Resultados

Tabela 4-9 – Matriz de confusão – teste – Modelo 4

| | | Real | | |
|----------|---|------|---|---|
| | | A | B | C |
| Previsto | A | 4 | 2 | 0 |
| | B | 0 | 1 | 0 |
| | C | 0 | 0 | 2 |

Classificação razoável quer no conjunto de treino quer no de teste, neste último 7 em 9 (78%).

Este resultado, obtido a partir de apenas uma prancha e seis atributos, constitui evidência de se verificarem as nossas conjeturas, nomeadamente:

- Existe diferenciação entre os perfis de fadiga nos sujeitos com e sem manifestação de lombalgia;

e

- A diferenciação dos perfis de fadiga pode fazer-se através de um pequeno número de atributos utilizados no modelo.

5. Discussão

5.1 Discussão

Este trabalho teve como objetivo avaliar a possibilidade de construir um modelo com base no algoritmo SVM capaz de classificar eletromiogramas adquiridos em sujeitos com e sem historial de dor lombar. Os sujeitos distribuíram-se por 3 classes, sem historial de dor lombar, com manifestação de episódios de dor lombar no último ano e com episódios de dor lombar na última semana.

Extraíram-se atributos no domínio do tempo (avrEMG) e da frequência (MF) em 11 momentos (percentis) de testes isométricos (quatro), bilateralmente para 4 músculos do tronco. O total de atributos iniciais foi de 704.

A criação de um modelo com todos os atributos iniciais não resultou devido ao seu elevado número, sua redundância e baixo número de elementos na amostra.

Implementou-se uma redução do número de atributos pela regressão linear de cada conjunto de 11 percentis correspondentes a um músculo e uma prancha quer para o domínio do tempo quer da frequência, retendo-se o declive da reta de regressão como o novo atributo.

Foi feita uma seleção dos declives (músculo e prancha em ambos os domínios) através de visualização gráfica em diagrama de caixa (*boxplot*).

Construíram-se 4 modelos, um com todos os declives calculados, um segundo com todos os que visualmente apresentavam diferenciação, um terceiro com as duas pranchas identificadas como mais diferenciadoras e um quarto modelo apenas com a prancha mais diferenciadora.

Verificou-se ser crítica a escolha dos atributos para a classificação dos eletromiogramas de acordo com o perfil de fadiga e sua associação com o historial de dor lombar.

A existência ou não de manifestação de dor lombar traduz-se numa alteração do perfil de fadiga ao realizar os testes (pranchas) que por sua vez conduz a alterações do sinal eletromiográfico. Os atributos extraídos dos EMGs permitem assim a classificação de acordo com os padrões de fadiga de cada classe considerada.

Dos 6 atributos incluídos no Modelo 4, 2 deles pertencem a 1 músculo, estando assim identificadas as covariáveis mais importantes na classificação da fadiga na musculatura do tronco.

Os resultados, não podendo ser considerados muito bons, são, no entanto, promissores e justificam futuras abordagens com o algoritmo SVM. Como variações possíveis estão o método de redução do número de atributos, sua seleção e o aumento do número de sujeitos da amostra.

6. Referências

- Aizerman, M. A., Braverman, E. M., & Rozonoer, L. I. (1964). Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control*, (25), 821–837.
- Alkan, A., & Günay, M. (2012). Identification of EMG signals using discriminant analysis and SVM classifier. *Expert Systems with Applications*, 39(1), 44–47. <http://doi.org/10.1016/j.eswa.2011.06.043>
- Bandpei, M. A. M., Rahmani, N., Majdoleslam, B., Abdollahi, I., Ali, S. S., & Ahmad, A. (2014). Reliability of surface electromyography in the assessment of paraspinal muscle fatigue: an updated systematic review. *Journal of Manipulative and Physiological Therapeutics*, 37(7), 510–21. <http://doi.org/10.1016/j.jmpt.2014.05.006>
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A Training Algorithm for Optimal Margin Classifiers.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition, 167, 121–167.
- Campbell, A., Straker, L., O’Sullivan, P., Elliott, B., & Reid, M. (2013). Lumbar loading in the elite adolescent tennis Serve: Link to low back pain. *Medicine and Science in Sports and Exercise*, 45(8), 1562–1568. <http://doi.org/10.1249/MSS.0b013e31828bea5e>
- Chow, J. W., Park, S., Tillman, M. D., & Grover, G. B. (2009). Lower Trunk Kinematics and Muscle Activity During Different Types of Tennis Serves.pdf. *Sports Medicine, Arthroscopy, Rehabilitation, Therapy & Technology: SMARTT*, 1(24), 1–14.
- Correia, J. P., Oliveira, R., Vaz, J. R., Silva, L., & Pezarat-Correia, P. (2015). Trunk muscle activation, fatigue and low back pain in tennis players. *Journal of Science and Medicine in Sport*, 2–7. <http://doi.org/10.1016/j.jsams.2015.04.002>
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Chemical Biology & Drug Design*, 297(1995), 273–297. <http://doi.org/10.1111/j.1747-0285.2009.00840.x>
- Creveaux, T., Dumas, R., Hautier, C., Macé, P., Chèze, L., & Rogowski, I. (2013). Joint kinetics to assess the influence of the racket on a tennis player’s shoulder. *Journal of Sports Science and Medicine*, 12(2), 259–266.
- Cristianini, N., & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and Other Kernel-based Methods*. (C. U. Press, Ed.) (16th ed.). Cambridge: CPI Group Ltd.
- de Luca, C. J. (1984). Myoelectrical Manifestations of Localized Muscular Fatigue in Humans. *CRC Critical Reviews in Biomedical Engineering*, 11(4), 251–279. <http://doi.org/10.1017/CBO9781107415324.004>
- de Luca, C. J. (1997). The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, 13, 135–163. <http://doi.org/citeulike-article-id:2515246>
- Ellenbecker, T. S., Pluim, B., Vivier, S., & Snitman, C. (2009). Common Injuries in Tennis Players: Exercises to Address Muscular Imbalances and Reduce Injury

- Risk. *Strength and Conditioning Journal*, 31(4), 50–58. <http://doi.org/10.1519/SSC.0b013e3181af71cb>
- Girard, O., Micallef, J. P., & Millet, G. P. (2005). Lower-limb activity during the power serve in tennis: Effects of performance level. *Medicine and Science in Sports and Exercise*, 37(6), 1021–1029. <http://doi.org/10.1249/01.mss.0000171619.99391.bb>
- Guyton, A. C., & Hall, J. E. (2006). *Textbook of Medical Physiology*. (E. SAUNDERS, Ed.) *Textbook of Medical Physiology* (11th ed.). <http://doi.org/10.1016/j.semnephrol.2006.07.001>
- Haykin, S. (2009). *Neural networks and learning machines*. (M. Horton & A. Dworkin, Eds.) (3rd ed.). New Jersey: Pearson.
- Hsu, C., Chang, C., & Lin, C. (2010). A Practical Guide to Support Vector Classification, 1(1), 1–16.
- IFT, I. T. F. (2017). Lower Back Pain. Retrieved March 5, 2017, from <http://www.itftennis.com/scienceandmedicine/injury-clinic/tennis-injuries/lower-back.aspx>
- Kibler, W. B., Chandler, T. J., Shapiro, R., & Conuel, M. (2007). Muscle activation in coupled scapulohumeral motions in the high performance tennis serve. *British Journal of Sports Medicine*, 41(11), 745–749. <http://doi.org/10.1136/bjism.2007.037333>
- Konrad, P. (2005). *The ABC of EMG: A Practical Introduction to Kinesiological Electromyography*. Scottsdale, USA: Noraxon INC.
- Lorena, a. C., & de Carvalho, a. C. P. L. F. (2007). Uma Introdução às Support Vector Machines. *Revista de Informática Teórica E Aplicada*, 14(2), 43–67. Retrieved from http://seer.ufrgs.br/index.php/rita/article/viewArticle/rita_v14_n2_p43-67
- Luxburg, U. von, & Schoelkopf, B. (2009). *Statistical Learning Theory: Models, Concepts, and Results*. (D. M. Gabbey, S. Hartmann, & J. Woods, Eds.) *Handbook of the History of Logic* (Vol. 10). Elsevier BV. <http://doi.org/10.1016/B978-0-444-52936-7.50016-1>
- Mcgill, S. M., Childs, A., Liebenson, C., Sm, A. M., Childs, A., & Endur-, L. C. (1999). Endurance Times for Low Back Stabilization Exercises: Clinical Targets for Testing and Training From a Normal Database, 80(August), 0–3.
- Müller, K. R., Mika, S., Rätsch, G., Tsuda, K., & Schölkopf, B. (2001). An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, 12(2), 181–201. <http://doi.org/10.1109/72.914517>
- Oskoei, M. A., & Hu, H. (2007). Application of support vector machines in upper limb motion classification using myoelectric signals. ... *and Biomimetics, 2007. ROBIO 2007. IEEE ...*, 33, 388–393. <http://doi.org/10.1109/ROBIO.2007.4522193>
- Pezarat-Correia, P. (2012). Aparelho Locomotor: Função Neuromuscular e Adaptações à Atividade Física - Volume 2. *FMH Edições*, 2, 270.
- Pezarat-Correia, P., Coutinho, C., Portero, R. G., Fernández-Fernández, J., Zierof, P., Sanz, D., & Porta, J. (2008). *Investigação e Ténis II*. (P. P. Correia & C. Coutinho, Eds.). Cruz Quebrada: Edições FMH.
- Pezarat-Correia, P., & Mil-Homens, P. (2004). *A Electromiografia no Estudo do*

- Movimento Humano*. (E. FMH, Ed.). Cruz Quebrada.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). A Novel Feature Extraction for Robust EMG Pattern Recognition. *Journal of Computing*, 1(1), 71–80. <http://doi.org/10.3109/03091902.2016.1153739>
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420–7431. <http://doi.org/10.1016/j.eswa.2012.01.102>
- Phinyomark, A., Quaine, F., Charbonnier, S., Serviere, C., Tarpin-Bernard, F., & Laurillau, Y. (2013). EMG feature evaluation for improving myoelectric pattern recognition robustness. *Expert Systems with Applications*, 40(12), 4832–4840. <http://doi.org/10.1016/j.eswa.2013.02.023>
- Renkawitz, T., Boluki, D., & Grifka, J. (2006). The association of low back pain, neuromuscular imbalance, and trunk extension strength in athletes. *Spine Journal*, 6(6), 673–683. <http://doi.org/10.1016/j.spinee.2006.03.012>
- Tkach, D., Huang, H., & Kuiken, T. a. (2010). Study of stability of time-domain features for electromyographic pattern recognition. *Journal of Neuroengineering and Rehabilitation*, 7, 21. <http://doi.org/10.1186/1743-0003-7-21>
- Troiano, A., Naddeo, F., Sosso, E., Camarota, G., Merletti, R., & Mesin, L. (2008). Assessment of force and fatigue in isometric contractions of the upper trapezius muscle by surface EMG signal and perceived exertion scale. *Gait and Posture*, 28(2), 179–186. <http://doi.org/10.1016/j.gaitpost.2008.04.002>
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks / a Publication of the IEEE Neural Networks Council*, 10(5), 988–999. <http://doi.org/10.1109/72.788640>

7. Apêndices

7.1 Código (“*Script*”) e *Output* Análise Gráfica

Nota: o texto foi escrito em RMarkdown e constitui um output do R com notas explicativas, inclusão do código utilizado e respetivo resultado.

7.1.1 Conteúdo

Texto escrito em R_Markdown. O objetivo é proceder à análise gráfica dos atributos com recurso ao *package* **ggplot2**. Abaixo descreve-se o procedimento incluindo toda a programação em R necessária para o efeito. ###Carregamento de Bibliotecas do R

```
library(e1071)
library(ggplot2)
```

7.1.2 Importação dos Dados

```
load(file = "dadosc.svm.rda")
load(file = "classe.svm.rda")
```

7.1.3 Formato dos dados

- **dadosc.svm** contém uma linha por sujeito; 35 linhas.
- Cada coluna corresponde a 1 de 12 momentos por músculo e por prancha. Existem 768 colunas (24 momentos x 8 músculos x 4 pranchas). Os momentos 12 e 24 correspondem ao valor médio do teste, relativos a avrEMG e MF respetivamente, e não serão utilizados.
- As linhas estão ordenadas pelo grupo,
 - Primeiro os sujeitos sem manifestação de dor lombar (n=15),
 - seguindo-se os que manifestaram dor lombar nos últimos 12 meses (n=12) e
 - finalmente os que a manifestaram na última semana (n=8).
- O vetor **classe.svm** é um factor representando os 3 níveis acima.

7.1.4 Cálculo dos declives

O código abaixo calcula os *declives* a partir da regressão linear dos 11 momentos. O 12º não se inclui nos cálculos uma vez que representa o valor calculado sobre o teste completo.

```
##### Declives por Músculo e Prancha - Med Amplitude
#####
# Colunas 1 a 8 (Prancha 1); 9 a 16 (Prancha 2); ...
slopes.amp.svm = matrix(0, 35, 32)
x = c(1:11)      # Valores de x para a Regressão Linear
for (l in 1:35)  # Sujeito
{
  k = 1          # Índice 1 a 32 para os Declive 4x8 (prancha x músculo)
```

```

for (i in 1:4)
{
  prancha = c(i)                                # Seleccção da Prancha
  myvarsT = paste("T", prancha, sep="")
  for (j in 1:8)
  {
    musculo = c(j)                               # Seleccção do músculo
    myvarsM = paste("M", musculo, sep="")

    feature = c(1:11)                             # Seleccção dos 11 moment
os Mediana Amplitude
    myvarsF = paste("F", feature, sep="")

    z = expand.grid(myvarsT, myvarsM, myvarsF)     # Expansão das com
binações T, M e F
    myvars = paste(z[,1], z[,2], z[,3], sep="")  # Merging das comb
inações

    d_svm = subset(dadosc.svm, select=myvars)     # Seleccção das col
unas relativas aos 11 momentos

    y = t(d_svm[1,])                             # Extração dos 11 momentos do Su
jeito l e sua transposição
    mod = lm(y ~ x)                               # Cálculo do Slope: Sujeito l, P
rancha i, Músculo m
    slopes.amp.svm[1,k] = mod$coef[2]            # Extracção do Slope do mode
lo linear
    k = k+1                                       # Incrementa o índice do Slope
  }
}

##### Declives por Músculo e Prancha - Med Frequência
#####
# Colunas 1 a 8 (Prancha 1); 9 a 16 (Prancha 2); ...
slopes.frq.svm = matrix(0, 35, 32)
x = c(1:11)                                       # Valores de x para a Regressão Linear
for (l in 1:35)  # Sujeito
{
  k = 1                                           # Índice 1 a 32 para os Declive 4x8 (prancha x mús
culo)
  for (i in 1:4)
  {
    prancha = c(i)                                # Seleccção da Prancha
    myvarsT = paste("T", prancha, sep="")
    for (j in 1:8)
    {
      musculo = c(j)                               # Seleccção do músculo
      myvarsM = paste("M", musculo, sep="")

      feature = c(13:23)                           # Seleccção dos 11 momen
tos Mediana Frequência
      myvarsF = paste("F", feature, sep="")

```

```

z = expand.grid(myvarsT, myvarsM, myvarsF) # Expansão das com
binacões T, M e F
myvars = paste(z[,1], z[,2], z[,3], sep="") # Merging das comb
inacões

d_svm = subset(dadosc.svm, select=myvars) # Seleccão das col
unas relativas aos 11 momentos

y = t(d_svm[1,]) # Extracção dos 11 momentos do S
ujeito L e sua transposição
mod = lm(y ~ x) # Cálculo do Slope: Sujeito L, P
rancha i, Músculo m
slopes.frq.svm[1,k] = mod$coef[2] # Extracção do Slope do mode
Lo linear
k = k+1 # Incrementa o índice do Slope
}
}
}

```

7.1.5 Análise dos Declives por prancha

O código seguinte seleciona 8 colunas consecutivas, contendo os **declives** de cada um dos 8 músculos, obtidos por regressão linear dos valores dos 11 momentos da Mediana da Amplitude.

Optou-se por uma visualização de Boxplots, uma por cada Classe, sobrepondo graficamente os pontos de cada uma, desfasados segundo o eixo dos XX face à opção do **ggplot2** `geom=c("boxplot", "jitter")`.

```

prancha = 1 # Seleccão da Prancha
i = 1+(prancha-1)*8
j = prancha*8
slp.svm = subset(slopes.amp.svm, select=i:j) # Mediana da Amplitude
slp.svm = as.data.frame(slp.svm)
slp.svm = cbind(slp.svm, classe.svm) # Junta a coluna referente à
Classe
names(slp.svm) = c("Músc_1", "Músc_2", "Músc_3", "Músc_4", "Músc_5", "
Músc_6", "Músc_7", "Músc_8", "Classe")


```

7.1.5.1 Prancha 1 - Declive Mediana da Amplitude



```



qplot(Classe, Músc_1, data=slp.svm, geom=c("boxplot", "jitter"),
shape=Classe, colour=Classe, main="Declive Músculo 1",
xlab="", ylab="Declive")



```




O código para os músculos 2 a 8 é semelhante, fazendo variar nome “Músc_1” com o sufixo correspondente ao número do músculo em causa.


















7.1.5.2 Prancha 2 - Declive Mediana da Amplitude














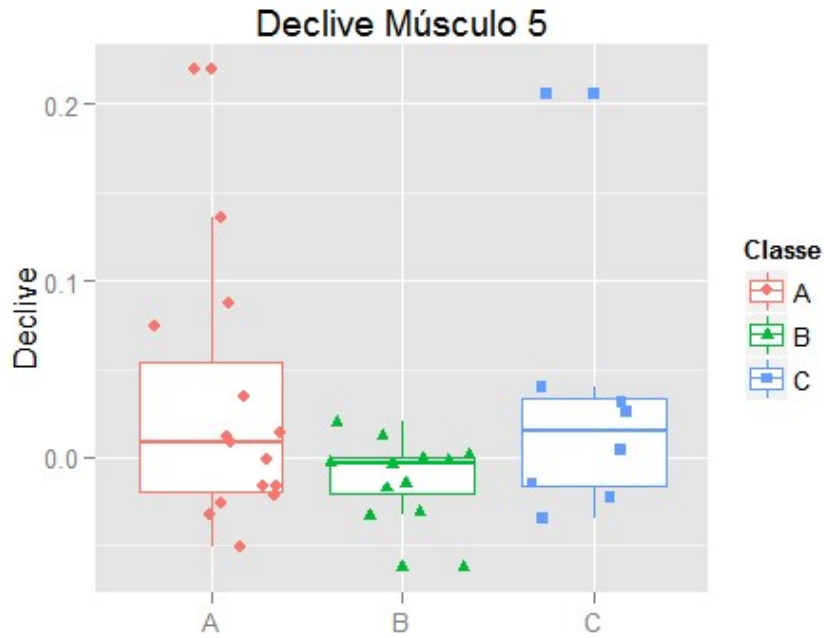


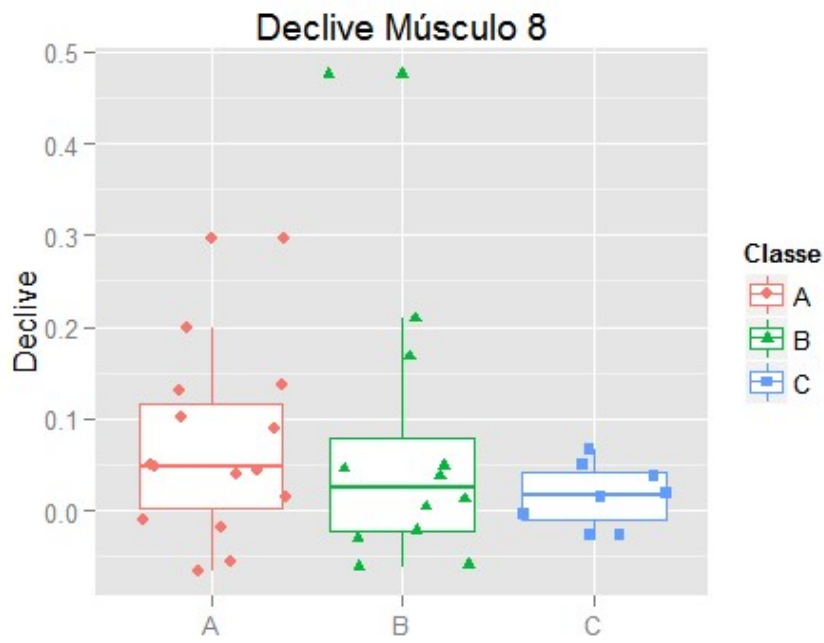





















7.1.6 Declive Mediana da Frequência

7.1.6.1 Prancha 1 - Declive Mediana da Frequência

















7.1.6.2 Prancha 2 - Declive Mediana da Frequência













7.1.6.3 Prancha 3 - Declive Mediana da Frequência

















7.1.6.4 Prancha 4 - Declive Mediana da Frequência









7.2 Código (“Script”) para o Algoritmo SVM

Inclui-se o cálculo dos declives e do modelo correspondente aos atributos (declives) identificados graficamente, 5 para avrEMG e 8 para MF.

Output de R_Markdown

```
rm(list = ls())
set.seed(50)

library(e1071)

load(file = "dadosc.svm.rda")
##### Slopes por Músculo e Prancha - Med Amplitude ##
#####
# Colunas 1 a 8 (Prancha 1); 9 a 16 (Prancha 2); ...
slopes.amp.svm = matrix(0, 35, 32)
x = c(1:11)      # Valores de x para a Regressão Linear
for (l in 1:35)  # Sujeito
{
  k = 1          # Índice 1 a 32 para os Slopes 4x8 (prancha x músculo)
  for (i in 1:4)
  {
    prancha = c(i)                                # Seleção da Prancha
    myvarsT = paste("T", prancha, sep="")
    for (j in 1:8)
    {
      musculo = c(j)                               # Seleção do músculo
      myvarsM = paste("M", musculo, sep="")

      feature = c(1:11)                            # Seleção dos 11 momentos
      myvarsF = paste("F", feature, sep="")

      z = expand.grid(myvarsT, myvarsM, myvarsF)    # Expansão das combinações T, M e F
      myvars = paste(z[,1], z[,2], z[,3], sep="")  # Merging das combinações

      d_svm = subset(dadosc.svm, select=myvars)    # Seleção das colunas relativas aos 11 momentos

      y = t(d_svm[l,])                             # Extração dos 11 momentos do Sujeito l e sua transposição
      mod = lm(y ~ x)                               # Cálculo do Slope: Sujeito l, Prancha i, Músculo m
      slopes.amp.svm[l,k] = mod$coef[2]            # Extração do Slope do modelo Linear
      k = k+1                                       # Incrementa o índice do Slope
    }
  }
}
```

```
##### Slopes por Músculo e Prancha - Med Frequência #
#####
# Colunas 1 a 8 (Prancha 1); 9 a 16 (Prancha 2); ...
slopes.frq.svm = matrix(0, 35, 32)
x = c(1:11)      # Valores de x para a Regressão Linear
for (l in 1:35)  # Sujeito
{
  k = 1          # Índice 1 a 32 para os Slopes 4x8 (prancha x músculo)
  for (i in 1:4)
  {
    prancha = c(i)          # Seleccção da Prancha
    myvarsT = paste("T", prancha, sep="")
    for (j in 1:8)
    {
      musculo = c(j)        # Seleccção do músculo
      myvarsM = paste("M", musculo, sep="")

      feature = c(13:23)    # Seleccção dos 11 momentos Mediana Frequência
      myvarsF = paste("F", feature, sep="")

      z = expand.grid(myvarsT, myvarsM, myvarsF) # Expansão das combinações T, M e F
      myvars = paste(z[,1], z[,2], z[,3], sep="") # Merging das combinações

      d_svm = subset(dadosc.svm, select=myvars) # Seleccção das colunas relativas aos 11 momentos

      y = t(d_svm[1,])      # Extracção dos 11 momentos do Sujeito l e sua transposição
      mod = lm(y ~ x)       # Cálculo do Slope: Sujeito l, Prancha i, Músculo m
      slopes.frq.svm[l,k] = mod$coef[2] # Extracção do Slope do modelo Linear
      k = k+1              # Incrementa o índice do Slope
    }
  }
}

# Construção do vector Classes
classe.svm = c(rep('A', 15), rep('B', 12), rep('C', 8))
classe.svm = factor(classe.svm)
# *****
# Criar grupos Treino e Teste 75%/25%
samp_idx = c(sample(1:15, size=11), sample(16:27, size=9), sample(28:35, size=6))
classe.svm.total = c(rep('A', 15), rep('B', 12), rep('C', 8))
classe.svm = classe.svm.total[samp_idx]
classe.svm = factor(classe.svm) # Vector Classe treino
classe.svm.teste = classe.svm.total[-samp_idx]
classe.svm.teste = factor(classe.svm.teste) # Vector Classe Teste
```

```

# Slopes para a Amplitude
slopes.amp.svm.total = slopes.amp.svm
slopes.amp.svm = slopes.amp.svm.total[samp_idx,] # Slopes Amp para tre
ino
slopes.amp.svm.teste = slopes.amp.svm.total[-samp_idx,] # Slopes Amp p
ara teste
slopes.amp.svm = as.data.frame(slopes.amp.svm) # formato dataframe
slopes.amp.svm.teste = as.data.frame(slopes.amp.svm.teste) #formato da
taframe
# Slopes para a frequência
slopes.frq.svm.total = slopes.frq.svm
slopes.frq.svm = slopes.frq.svm.total[samp_idx,] # Slopes Freq para tr
eino
slopes.frq.svm.teste = slopes.frq.svm.total[-samp_idx,] # Slopes Freq
para teste
slopes.frq.svm = as.data.frame(slopes.frq.svm) # formato dataframe
slopes.frq.svm.teste = as.data.frame(slopes.frq.svm.teste) # formato d
ataframe

# *****
# Seleção das colunas (prancha/músculo)
col_amp = c(9, 13, 14, 24, 26)
col_frq = c(9, 11, 16, 19, 23, 26, 28, 29)
slpa.svm = subset(slopes.amp.svm, select=col_amp) # Média da Amplitud
e
slpf.svm = subset(slopes.frq.svm, select=col_frq) # Mediana da Frequê
ncia
slpa.svm = as.data.frame(slpa.svm)
slpf.svm = as.data.frame(slpf.svm)
slp.svm = cbind(slpa.svm, slpf.svm) # Junta Slopes Amp com Freq

mod.tuned = tune.svm(slp.svm, classe.svm, gamma=2^(-10:5), cost=2^(-10
:5))
custo = mod.tuned$best.parameters$cost
gama = mod.tuned$best.parameters$gamma
paste("custo", custo, "; gama", gama)

## [1] "custo 8 ; gama 0.0625"

mod.svm = svm(slp.svm, classe.svm, type='C', kernel="radial", cost=cus
to, gamma=gama, cross=3)
mod.svm$accuracies

## [1] 25.00000 44.44444 22.22222

pred = predict(mod.svm, slp.svm)
table(pred, classe.svm)

##      classe.svm
## pred  A  B  C
##    A 11  0  0
##    B  0  9  0
##    C  0  0  6

```

```
# Avaliação com o conjunto de teste
slpa.svm.teste = subset(slopes.amp.svm.teste, select=col_amp) # Coluna
s Amp
slpf.svm.teste = subset(slopes.frq.svm.teste, select=col_frq) # Coluna
s Freq
slp.svm.teste = cbind(slpa.svm.teste, slpf.svm.teste)
slp.svm.teste = as.data.frame(slp.svm.teste)

pred = predict(mod.svm, slp.svm.teste)
table(pred, classe.svm.teste)

##      classe.svm.teste
## pred A B C
##    A 1 1 0
##    B 3 2 2
##    C 0 0 0
```