



UNIVERSIDADE ESTADUAL PAULISTA
JÚLIO DE MESQUITA FILHO
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA - SP

FABIAN RODRIGO CASTRO FORERO

Sistema Baropodométrico e Classificação de Escoliose Utilizando Técnicas de Machine Learning

Ilha Solteira

2019

FABIAN RODRIGO CASTRO FORERO

**Sistema Baropodométrico e Classificação de Escoliose
Utilizando Técnicas de Machine Learning**

Tese apresentada à Faculdade de Engenharia -
UNESP - Câmpus de Ilha Solteira, Programa
de Pós-graduação em Engenharia Elétrica,
como requisito para obtenção do título de
Doutor em Engenharia Elétrica.

Área de Conhecimento: Automação

Orientador: Prof. Dr. Aparecido Augusto de
Carvalho

Ilha Solteira
2019

FICHA CATALOGRÁFICA


Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C355s Castro Forero, Fabian Rodrigo.
Sistema baropodométrico e classificação de escoliose utilizando técnicas de machine learning / Fabian Rodrigo Castro Forero. -- Ilha Solteira: [s.n.], 2019
140 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2019

Orientador: Aparecido Augusto de Carvalho
Inclui bibliografia

1. Escoliose. 2. Baropodômetro. 3. Crosstalk. 4. Aprendizado de máquina.


Raiane da Silva Santos


CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Sistema Baropodométrico e Classificação de Escoliose Utilizando Técnicas de Machine Learning


AUTOR: FABIAN RODRIGO CASTRO FORERO


ORIENTADOR: APARECIDO AUGUSTO DE CARVALHO


Aprovado como parte das exigências para obtenção do Título de Doutor em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:



Prof. Dr. APARECIDO AUGUSTO DE CARVALHO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. JOSE ANGELO BARELA
Departamento de Educação Física / Instituto de Biociências de Rio Claro - UNESP


Profa. Dra. ERICA REGINA MARANI DARUICHI MACHADO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. VANDER TEIXEIRA PRADO
Departamento de Engenharia Elétrica / Universidade Tecnológica Federal do Paraná - UTFPR 

Prof. Dr. ADALBERTO VIEIRA CORAZZA
Curso de Medicina e Enfermagem / Universidade Federal de Mato Grosso do Sul - UFMS

Ilha Solteira, 19 de dezembro de 2019

À minha família, mas especialmente aos meus pais:

Nubia Forero e Regulo Castro

pelo exemplo, dedicação e

amor que recebi.

Definitivamente ao melhor sobrinho do mundo:

Sebastian Saavedra

E à minha irmã:

Lina Castro.

AGRADECIMENTOS

Quero agradecer primeiramente aos meus pais, pela ajuda, compreensão e amor que recebi, mesmo na distância eles nunca deixaram de me socorrer, apoiar e motivar. Não existem palavras para dizer o quanto eu amo e admiro essas pessoas maravilhosas.

A minha irmã que sempre com a maior alegria empenhou-se em me dar forças, ao meu sobrinho que sempre expressava a saudade do tio e me lembrava o valor da família. À família inteira, que nunca esqueceram de mim, sempre orando pelo meu bem-estar, sempre apoiando e sempre torcendo.

A Consuelo pela paciência e por todo incentivo que sempre demonstrou.

Ao meu orientador, Prof. Dr. Aparecido Augusto de Carvalho, pela confiança, pela orientação, por me receber e me dar a oportunidade de trabalhar junto à maravilhosa família LIEB. Um verdadeiro exemplo como pessoa e profissional.

Ao Prof. Dr. Marcelo Sanches que esteve sempre contribuindo nos diferentes trabalhos, sempre cheio de energia, ideias e vivências.

Um agradecimento especial aos Prof. Aparecido e Marcelo que me socorreram e auxiliaram nos momentos mais difíceis. Igualmente ao Jorge quem também me socorreu e com quem foi compartilhado este sono.

À família LIEB, ao Ricardo T, Andressa, Weslin, Rafael, Willian, Mariana, Caroline, e todos que já passaram pelo laboratório de pesquisa, com quem a gente trabalha e estão sempre dispostos a ajudar, compartilhando conhecimentos e experiências que garantem o crescimento pessoal e profissional.

Aos meus amigos de todas as nacionalidades e de Rep. com quem foram compartilhadas alegrias, tristezas, vitórias e derrotas, que sempre me motivaram para continuar.

À UNESP, seu corpo docente e funcionários, especialmente aos funcionários técnicos: Everaldo, Wendel, Chaves e Adilson, que sempre de bom grado e com a maior disposição providenciaram soluções para os inúmeros problemas nos diferentes projetos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A todos que compartilharam este sono de me formar como doutor e me ajudaram a ser um melhor profissional, e ainda mais importante, uma melhor pessoa.

Gracias...Totales

*“Go placidly amid the noise and haste,
and remember what peace there may be in silence.
As far as possible without surrender
be on good terms with all persons.
Speak your truth quietly and clearly;
and listen to others,
even the dull and the ignorant;
they too have their story.
Avoid loud and aggressive persons,
they are vexations to the spirit.
If you compare yourself with others,
you may become vain and bitter;
for always there will be greater and lesser persons than yourself.
Enjoy your achievements as well as your plans...”*

(Max Ehrman)

RESUMO

A postura do corpo humano é o resultado da junção de sistemas ósseo, muscular e nervoso; no entanto, o segmento mais importante e estudado em pesquisas posturais é a coluna vertebral. Uma postura errada pode gerar desordens vertebrais, que dependendo da deformidade, pode ser classificada como escoliose, sendo ela uma deformidade tridimensional da coluna vertebral. Numerosos estudos mostraram que existem diferenças na distribuição de forças na região plantar e dados de estabilometria entre população diagnosticada com e sem escoliose. O equipamento indicado para realizar este tipo de pesquisa é o baropodômetro, que devido ao seu elevado custo, é pouco acessível para a maioria das instituições de saúde brasileiras. Assim, neste trabalho é apresentado, por um lado, o desenvolvimento e caracterização do sistema baropodométrico *LiebScan System*, que utiliza uma matriz piezoresistiva com 2304 *sensels* e circuito para controle de *crosstalk*. Foram utilizadas técnicas de aprendizado de máquina para explorar a correlação entre os dados baropodométricos, biométricos e de estabilometria, com o grau de desvio lateral, possibilitando desenvolver um classificador para o diagnóstico de escoliose totalmente inovador. O LiebScan System pode realizar avaliações baropodométricas estáticas, mensurando pressões na faixa 5-300 kPa, com acurácia de 6,02 % (RMSE%). Com frequência de amostragem máxima de 40 Hz, o sistema possibilita realizar avaliações de estabilometria. O circuito de controle *crosstalk* mostrou ser efetivo, apresentando erro de leitura médio de 0,23 %. As características técnicas do sistema LiebScan mostraram ser competitivas quando comparadas com as características de equipamentos comerciais. Em relação às técnicas de aprendizado de máquina utilizadas, a rede neural artificial do tipo *multi layer perceptron* com topologia [30-44-1] e algoritmo de treinamento *trainscg* mostrou ter o melhor rendimento com uma acurácia geral de $75,40 \pm 5,56$ % de classificação. Por sua vez, a técnica de aprendizado *support vector machine* obteve uma acurácia geral de $74,89 \pm 7,19$ %. Desta forma, estabeleceu-se que existe uma correlação entre as distribuições de força na região plantar, os dados biométricos, e os dados de estabilometria, com o grau do desvio lateral da coluna vertebral. No entanto, dita correlação não representa necessariamente causalidade, podendo haver mais fatores envolvidos.

Palavras-chave – Escoliose. Baropodômetro. Crosstalk. Aprendizado de Máquina.

ABSTRACT

The posture of the human body is the result of bone, muscle and nervous systems interaction; however, the most important and studied segment in postural research is the spine. A wrong posture could cause vertebral disorders, that depending on the deformity can be classified as scoliosis, which is a three-dimensional deformity of the spine. Many researches have shown that there are differences in the forces distribution under the plantar region and data of stabilometry between population diagnosed with and without scoliosis. The equipment indicated to carry out this kind of research is the baropodometer that, due to its high cost, is not accessible for most of the Brazilian health care institutions. Thus, in this work the development and characterization of the system for baropodometry *LiebScan System* is shown. It uses a piezoresistive array with 2304 sensels and non-crosstalk circuit. Some machine learning techniques were used to determine the correlation between baropodometric, biometric and stabilometry data and the scoliosis degree, allowing the development of a completely innovative scoliosis classifier. The LiebScan system has been shown to have the ability to perform static baropodometric evaluations with pressure measurements in the range of 5-300 kPa and accuracy of 6.02% (RMSE%). With a maximum sampling frequency of 40 Hz, the system makes it possible to perform stabilometry evaluations. The non-crosstalk circuit proved to be effective, with a mean read error of 0.23%. LiebScan technical specifications have been shown to be competitive when compared to commercial equipment features. Related to the machine learning techniques used, the artificial neural network with multi layer perceptron, topology [30–44–1] and trainscg as training algorithm, obtained the best performance with a general classification accuracy of $75.40 \pm 5.56\%$. Similarly, the learning technique support vector machine achieved an overall accuracy of $74.89 \pm 7.19\%$. Thus, it is established that there is a correlation between the baropodometric, biometric, and stabilometry data, with the scoliosis; however, this correlation does not necessarily represent causality and there may be more factors involved.

Keywords – Scoliosis. Baropodometer. Crosstalk. Machine Learning.

LISTA DE FIGURAS

Figura 1 – Divisão da coluna vertebral segundo as regiões das vértebras, e curvaturas da coluna no plano sagital e coronal.	19
Figura 2 – Distorções estruturais e alterações posturais da coluna vertebral.	20
Figura 3 – Medição do ângulo de Cobb na curvatura principal. Escolise tipo C.	22
Figura 4 – Postura ortostática ideal e alinhamento corporal.	24
Figura 5 – Sistema postural. Cadeias ascendentes, descendentes e sistema de pêndulo duplo.	26
Figura 6 – Divisão do pé e abóbada plantar.	27
Figura 7 – Deformidades dos pés e solicitações anormais da cadeia ascendente.	29
Figura 8 – Técnicas tradicionais de avaliação de forças na região plantar, (a) pedigrafia e (b) podóscopio	31
Figura 9 – Baropodômetro comercial emed® da Novel GmbH.	32
Figura 10 – Participação do baropodômetro nas áreas clínicas e de pesquisa.	33
Figura 11 – Deslocamentos do centro de pressão.	35
Figura 12 – Técnicas de análise do COP, (a) Estabilograma; (b) Estatocinesigrama.	35
Figura 13 – Eletrodos para sensores piezoresistivos; (a) estrutura interdigital e, (b) estrutura superficial.	46
Figura 14 – Matriz de sensores piezoresistivos e sensel.	46
Figura 15 – Matriz de sensores resistiva; (a) representação elétrica e seleção do EBT, (b) efeito crosstalk	48
Figura 16 – Erro de leitura do EBT variando EBT e NSE na faixa 1-100 k Ω com M=N=4.	49
Figura 17 – Baropodômetro LIEB V2.0 contruído com sensores FSR.	52
Figura 18 – Matriz de sensores piezoresistivos FSR-MS9705.	53
Figura 19 – Circuito A, baseado em aterramento (ZP).	55
Figura 20 – Circuito B, com retroalimentação baseada em aterramento.	56
Figura 21 – Circuito C, com tensão de retroalimentação nos NSE.	56
Figura 22 – Circuito D, com tensão de retroalimentação nos NSE.	57
Figura 23 – Circuito E, com tensão de retroalimentação nos NSE e ZP.	58
Figura 24 – Tensões de saída, variando EBT na faixa 1-100 k Ω , M=N=4, e NSE = 100 k Ω	58

Figura 25 – Porcentagem de erros relativos, (a) com $EBT = 100\text{ k}\Omega$ e variando NSE, (b) Variando simultaneamente $EBT = NSE$. Variações de impedância na faixa de 1-100 $\text{k}\Omega$	60
Figura 26 – Erros relativos na leitura do EBT, variando NSE de 1 $\text{k}\Omega$ a 100 $\text{k}\Omega$ e $EBT = 100\text{ k}\Omega$, com $M=N=60$	61
Figura 27 – <i>Improved isolated drive feedback circuit</i> - IIDFC	62
Figura 28 – Comparação de erros relativos de leitura do EBT nos modelos do circuito IIDFC e identificação da impedância mínima	64
Figura 29 – Placa modular para leitura de matrizes piezoresistivas.	65
Figura 30 – Núcleo STM32H743-ZI.	66
Figura 31 – Baropodômetro LiebScan.	67
Figura 32 – Módulo de aquisição de dados LiebScan System	68
Figura 33 – Fluxograma da aquisição e comunicação de dados dos 2304 sensels em cada amostra da matriz	70
Figura 34 – Metodologia utilizada no aprendizado de máquina supervisionado.	72
Figura 35 – Procedimento de cross-validation.	75
Figura 36 – Matriz de confusão em classificação binária, exemplo.	78
Figura 37 – Adaptative Linear Element - ADALINE.	82
Figura 38 – Multilayer Perceptron, topologia $[n-5-2]$	83
Figura 39 – Fluxograma do procedimento utilizado para selecionar e sintonizar a RNA.	86
Figura 40 – SVM linearmente separável.	87
Figura 41 – Classificação por SVM de dados não linearmente separáveis em 2D.	88
Figura 42 – Máquina universal de ensaios MUE-LIEB.	93
Figura 43 – Calibração da matriz piezoresistiva por áreas.	94
Figura 44 – Resposta resistiva da matriz MS9705 quando submetida a 300 kPa.	95
Figura 45 – Erro relativo por efeito crosstalk no LiebScan variando os NSE na faixa 1,58-170 $\text{k}\Omega$, enquanto o $EBT=170\text{ k}\Omega$	96
Figura 46 – Curvas de caracterização na medição de pressões, (a) acurácia em uma das áreas selecionadas, (b) linearidade em 16 áreas.	100
Figura 47 – Curva de caracterização de histerese em uma das áreas selecionadas.	101
Figura 48 – Metodologia para avaliar medição do COP.	102
Figura 49 – Curva de caracterização de efeito creep em uma das áreas selecionadas.	103

Figura 50 – Distribuição de pressão na região plantar do voluntário com o LiebScan System.	107
Figura 51 – Análise de Componente Principal PCA.	110
Figura 52 – Exemplo de saída gráfica da função de otimização bayesopt com rede feedforwardnet, função de treinamento trainrp e sintonizando PCA e H, obtendo a topologia [34-26-1].	111
Figura 53 – Análise de Componente Principal PCA.	117
Figura 54 – Processamento de imagens; (a) distribuição de forças original, (b) distribuição de forças processada.	120
Figura 55 – Processamento de imagem a vetor uni-dimensional.	120
Figura 56 – Análise de Componente Principal (PCA) em imagens, dados de establiometria e dados biométricos.	121

LISTA DE TABELAS

Tabela 1 – Variáveis de Estabilometria.	36
Tabela 2 – Quadro comparativo de algoritmos de aprendizado de máquina supervisionado.	77
Tabela 3 – Dados biométricos dos voluntários avaliados.	90
Tabela 4 – Dados biométricos dos Grupos A e B.	91
Tabela 5 – Comparação funções de treinamento segundo coeficientes de determinação (R^2).	98
Tabela 6 – Comparação LiebScan System com equipamentos baropodométricos comerciais.	106
Tabela 7 – Dados de estabilometria em voluntário.	108
Tabela 8 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária.	112
Tabela 9 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com duas camadas ocultas na camada intermediária.	113
Tabela 10 – Rendimento da RNA-MLP tipo patternnet, função de treinamento <i>trainscg</i> e topologia [30–44–1].	114
Tabela 11 – Rendimento do SVM sintonizado.	116
Tabela 12 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária. Análise por segmentação de voluntários.	117
Tabela 13 – Rendimentos RNA e SVM sintonizados. Avaliação por voluntários. . .	118
Tabela 14 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária, em processamento com imagens.	121
Tabela 15 – Rendimento RNA e SVM sintonizados, processamento de imagens. . .	122

LISTA DE ABREVIATURAS E SIGLAS

ACC	Accuracy - Acurácia
bps	Bits per Second - Bits por Segundo
COP	Center of Pressure - Centro de Pressão
EBT	Element Being Tested - Elemento Sendo Testado
ESP	Especificidade
FN	False Negative - Falso Negativo
FP	False Positive - Falso Positivo
FSR	Force Sensing Resistor - Sensor Resistivo de Força
IIDFC	Improved Isolated Drive Feedback Circuit
IMR	Impedância Mínima Recomendada
ML	Machine Learning - Aprendizado de Máquina
MLP	Multi Layer Perceptron - Múltiplas Camadas de Perceptrons
MSE	Mean Square Error - Erro Quadrado Médio
MSPS	Mega Samples per Second - Milhões de amostras por segundo
MUE	Máquina Universal de Ensaio
NNToolbox	Neural Network Toolbox - Ferramenta de Rede Neural em Matlab
NSE	Non-Scanned Elements - Elementos não escaneados
OA	Olhos Abertos
OF	Olhos Fechados
OP-AMP	Operational Amplifier - Amplificador Operacional
PCA	Principal Component Analysis - Análise de Componentes Principais
PCS	Precision - Precisão

RMSE	Root Mean Square Error - Desvio da Raiz Quadrática Média
RNA	Rede Neural Artificial
Rsw	Resistência de ON do switch analógico ou multiplexador
SE	Sensibilidade
SEL	Seletividade
SML	Supervised Machine Learning - Aprendizado de Máquina Supervisionado
SVM	Support Vector Machine - Máquina de Vetor Suporte
TN	True Negative - Verdadeiro Negativo
TP	True Positive - Verdadeiro Positivo
VF	Voltage Feedback - Tensão de Realimentação
VTI	Valor Total dos Indicadores
ZP	Zero Potential - Diferença de Potencial Zero

SUMÁRIO

1	INTRODUÇÃO	17
1.1	COLUNA VERTEBRAL	18
1.1.1	<i>Coluna Vertebral Patológica</i>	19
1.1.2	<i>Escoliose</i>	21
1.2	BIOMECÂNICA - POSTUROLOGIA CLÍNICA	23
1.3	RECEPTOR PODAL E CADEIA ASCENDENTE	25
1.3.1	<i>Relação Pé – Escoliose</i>	30
1.4	SISTEMAS DE MEDIÇÃO DE PRESSÕES PLANTARES	31
1.4.1	<i>Centro de Pressão</i>	34
1.5	MACHINE LEARNING – ESTADO DA ARTE	37
1.5.1	<i>Machine Learning – Região Plantar</i>	37
1.5.2	<i>Machine Learning – Escoliose</i>	39
1.5.3	<i>Machine Learning – Escoliose – Baropodômetro</i>	41
1.6	OBJETIVOS	42
1.7	ESTRUTURA DO TRABALHO	42
2	BAROPODÔMETRO	43
2.1	TIPOS DE SENSORES	43
2.1.1	<i>Sensores Capacitivos</i>	43
2.1.2	<i>Sensores Resistivos - Piezoresistivos</i>	44
2.1.3	<i>Sensores Piezoelétricos</i>	44
2.2	MATRIZ DE SENSORES PIEZORESISTIVOS	45
2.2.1	<i>Crosstalk</i>	47
2.3	CARACTERÍSTICAS DOS BAROPODÔMETROS	49
2.4	BAROPODÔMETRO LIEBSCAN	51
2.4.1	<i>Sensor</i>	52
2.4.2	<i>Circuito de Crosstalk</i>	54
2.4.3	<i>Hardware do LiebScan System</i>	64
2.4.4	<i>Software do LiebScan System</i>	68
3	MACHINE LEARNING	71

3.1	PROCESSO DE APRENDIZADO DE MÁQUINA SUPER-	
	VISIONADO	72
3.1.1	<i>Problema</i>	73
3.1.2	<i>Coleta e Identificação de Dados</i>	73
3.1.3	<i>Pré-processamento de Dados</i>	73
3.1.4	<i>Divisão de Dados - Treinamento e Teste</i>	74
3.1.5	<i>Algoritmos de Treinamento</i>	75
3.1.6	<i>Treinamento</i>	76
3.1.7	<i>Teste</i>	77
3.1.8	<i>Sintonização do Classificador</i>	79
3.2	CLASSIFICADORES SUPERVISIONADOS UTILIZADOS .	81
3.2.1	<i>Rede Neural Artificial - RNA</i>	81
3.2.2	<i>Support Vector Machine - SVM</i>	87
3.3	BASE DE DADOS	89
3.3.1	<i>Protocolo de Avaliação e Coleta de Dados</i>	89
3.3.2	<i>Dados Biométricos</i>	90
3.3.3	<i>Grupos de Avaliação</i>	91
4	RESULTADOS	92
4.1	BAROPODÔMETRO	92
4.1.1	<i>Metodologia de Calibração da Matriz Piezoresistiva</i>	92
4.1.2	<i>Matriz Piezoresistiva MS9705</i>	95
4.1.3	<i>Calibração LiebScan – Redes Neurais Artificiais</i>	96
4.1.4	<i>Caracterização do LiebScan System</i>	99
4.1.5	<i>Comparação do LiebScan System com Sistemas Comerciais</i>	105
4.1.6	<i>Avaliação com Voluntário</i>	107
4.2	MACHINE LEARNING	109
4.2.1	<i>Pré-Processamento de Dados</i>	109
4.2.2	<i>RNA - Seleção Tipo de Rede e Função de Treinamento</i>	110
4.2.3	<i>RNA - Sintonização de Algoritmo de Treinamento</i>	113
4.2.4	<i>RNA - Rendimento</i>	114
4.2.5	<i>SVM - Configuração, Sintonização, e Rendimento</i>	115
4.2.6	<i>RNA e SVM, Segmentação e Avaliação por Voluntários</i>	116

4.2.7	<i>RNA, SVM e Processamento Digital de Imagens</i>	119
5	CONCLUSÕES	123
	REFERÊNCIAS	127

1 INTRODUÇÃO

Para manter a estabilidade tanto em condições estáticas quanto em condições dinâmicas, o corpo humano possui três receptores somatossensoriais (receptores que permitem experimentar sensações geradas por estímulos externos): visual, auditivo e tátil, este último, especialmente, através da planta dos pés (CORDEIRO *et al.*, 2014). Os pés são a única conexão com o solo durante a locomoção bípede, permitindo uma interação constante com o ambiente (BOSCH *et al.*, 2009).

O pé, como parte fundamental do corpo humano, oferece equilíbrio e estabilidade. Sendo a base de sustentação, o pé possui duas funções: transferir as forças próprias do corpo ao solo e atuar como amortecedor de impactos ao caminhar ou correr. Por este motivo, os pés junto com os membros inferiores, são considerados um sistema complexo composto por elementos dos sistemas ósseo, articular, muscular e nervoso, que permitem ao corpo desenvolver inúmeras atividades. Uma apropriada biomecânica e sincronismo neste sistema, possibilita manter a postura corporal enquanto as forças próprias e externas ao corpo são transferidas simetricamente à superfície de contato através das regiões plantares, tanto na marcha quanto na posição ortostática (ROSENBAUM; BECKER, 1997; MCKEON *et al.*, 2015).

A postura pode ser explicada como a junção e configuração dos sistemas ósseo, articular, muscular e nervoso para manter uma posição em relação a um ponto de referência. Assim, no corpo humano, qualquer parte e/ou articulação que suporte e transfira peso é considerada um segmento postural (LIPPERT, 2011). Com as configurações dos segmentos posturais é possível posicionar o corpo para realizar as mais diversas tarefas. Com efeito, inúmeras são as posições que podem ser adotadas pelo corpo humano; no entanto, a postura pode ser classificada em posturas estáticas (ficar em pé, sentar, deitar, etc.) ou posturas dinâmicas (caminhar, correr, pular, etc.) (DUARTE; FREITAS, 2010).

Como explicado, a postura é uma configuração de variados sistemas próprios do corpo humano. O segmento mais importante, e o mais estudado nas avaliações posturais, é a coluna vertebral. Lippert (2011) explica de forma metafórica que a coluna vertebral pode ser representada como uma coluna de caixas uma sobre a outra. No entanto, uma coluna de caixas embora estável, não facilita o controle postural pela sua rigidez. Assim, as caixas são deslocadas do seu eixo central, fazendo curvas através da coluna, mantendo

a rigidez e acrescentando mobilidade e flexibilidade à coluna. Na coluna vertebral, estas curvaturas, além de aumentarem a mobilidade, também reduzem os impactos e ajudam a prevenir lesões ao atuar como uma mola. Embora seja difícil estabelecer os parâmetros para uma postura correta, uma postura incorreta é definida como uma postura onde são prejudicados outros sistemas e órgãos do próprio corpo (WOJTKÓW; SZKODA-POLISZUK; SZOTEK, 2018).

Considerando a postura como a junção de diferentes segmentos dentro de uma corrente cinemática da cabeça aos pés, onde todos contribuem para a estabilidade e para o equilíbrio, é possível afirmar que a capacidade da pessoa de se manter em uma posição determinada não está associada somente ao sistema somatossensorial, mas também às características fisiológicas e biométricas próprias do corpo (FAN *et al.*, 2013; DEEPASHINI *et al.*, 2014).

Neste capítulo serão abordados os principais tópicos biomecânicos que compõem a corrente cinemática, da cabeça aos pés, a relação da base de sustentação com desvios posturais do tronco e especificamente da coluna vertebral, a fisiologia dos pés, métodos de avaliação de pressões plantares, e mecanismos que possibilitem explorar as correlações existentes entre os pés e a coluna vertebral.

1.1 COLUNA VERTEBRAL


A coluna vertebral é o eixo do corpo humano e fornece duas qualidades ao tronco humano, porém contraditórias: rigidez e flexibilidade (KAPANDJI, 2000), obtidas pelos diferentes elementos musculares e ligamentares que compõem a coluna. Ao todo, a coluna vertebral é formada por um conjunto de 33 a 34 vértebras, divididas em 4 regiões, segundo a posição no tronco da pessoa (Figura 1). A região cervical com 7 vértebras, a região torácica com 12 vértebras, a região lombar com 5 vértebras e região pélvica com 9 ou 10 vértebras (LATARJET; LIARD, 2011).

As vértebras da região cervical suportam o crânio e estão situadas diretamente abaixo dele (KAPANDJI, 2000). Estas vértebras estão fortemente protegidas pelos músculos do pescoço e são dificilmente reconhecíveis. Apenas a sétima vértebra é visível pela proeminência na parte posterior, estando conectada à região torácica (LATARJET; LIARD, 2011).

Devido aos órgãos internos como coração e pulmões, a coluna vertebral é deslocada para a parte posterior na região torácica, como mostrado na Figura 1. Para equilibrar o deslocamento da região torácica, as vértebras da região lombar recuperam a posição central, possibilitando o suporte do peso do tronco superior (KAPANDJI, 2000).

As curvaturas necessárias para realizar o deslocamento das vértebras podem ser observadas no plano sagital, sendo estas: curvatura sacral (1); lordose lombar (2); cifose dorsal (3); e lordose cervical (4), vide Figura 1. Entretanto, vista desde pelo plano coronal, parte frontal ou posterior, a coluna está normalmente em linha reta sem curvaturas laterais (KAPANDJI, 2000; LATARJET; LIARD, 2011).

Figura 1 – Divisão da coluna vertebral segundo as regiões das vértebras, e curvaturas da coluna no plano sagital e coronal.



Fonte: Adaptado de Club (2019) e Kapandji (2000).


1.1.1 Coluna Vertebral Patológica

Como descrito por Lippert (2011) e Latarjet e Liard (2011), as curvaturas da coluna vertebral não estão definidas por um ângulo fixo que determine uma postura correta

podendo haver alguns graus de desvio sem se considerar uma postura anormal; no entanto, quando as curvaturas, sejam no plano sagital, axial ou coronal, têm altos graus de desvio (Figura 2), podem ser catalogadas dentro de alguma patologia associada à região da curvatura como segue:

- Cifose: é o incremento excessivo da curvatura da região torácica de convexidade posterior. Com o decorrer dos anos, a distância entre as vértebras vai diminuindo acrescentando a curvatura da região torácica, podendo gerar esta distorção estrutural;
- Lordose: relacionada às curvaturas excessivas de convexidades anteriores, da regiões cervicais e lombares. No entanto, o ângulo formado entre a região pelviana e a região lombar é de especial interesse, sendo que uma curvatura excessiva nesta área incrementa o ângulo da lordose lombar gerando a Hiperlordose. O ângulo ideal entre as regiões pélvica e lombar é de aproximadamente 30°;
- Escoliose: é caracterizada por desvios laterais no plano coronal que, conseqüentemente, gera deformações torácicas.

Figura 2 – Distorções estruturais e alterações posturais da coluna vertebral.



Fonte: BiologyForums (2013).

1.1.2 Escoliose

A escoliose é uma desordem vertebral, definida como uma deformidade tridimensional da coluna, caracterizada por alterações geométricas na cavidade torácica (SANTIAGO *et al.*, 2013). A escoliose é caracterizada por desvios laterais no plano frontal, rotação vertebral no plano axial e curvaturas de convexidades anteriores no plano sagital (ABREU *et al.*, 2012).

De forma geral existem dois tipos de escoliose, caracterizadas pela quantidade de desvios laterais. A deformidade mais comum é a escoliose em “C”, com uma única curvatura em uma única direção, podendo estar nas regiões torácica e lombar. Entretanto, a deformidade em “S” apresenta duas curvaturas em direções opostas, localizadas nas regiões torácica e lombar (MAUDE, 2018). Desde que a deformidade mais comum é a deformidade tipo “C”, neste trabalho focaremos a análise neste tipo de escoliose.

A escoliose é normalmente diagnosticada por ortopedistas realizando uma avaliação postural e um exame específico como o raio-X da coluna vertebral. Utilizando a informação obtida do raio-X, é possível identificar a altura, lado de convexidade e angulação da curvatura na região torácica. A angulação é o dado mais importante dentre os obtidos na avaliação do raio-X, porque determina a gravidade da patologia e também define o tratamento a seguir (FANFONI, 2017).


Diagnostica-se escoliose quando o grau do desvio lateral é maior que 10° (ROLTON; NNADI; FAIRBANK, 2014).

Embora existam outros métodos para mensurar a angulação da escoliose (Rei, Lenke, King), o método de medição de Cobb é o mais utilizado e define, em graus, a intensidade da deformidade postural. Normalmente, o ângulo de Cobb é calculado diretamente sobre as radiografias, utilizando goniômetros (CUNHA; ROCHA; CUNHA, 2009).

Como descrito por Fanfoni (2017), a coluna patológica com escoliose tem duas curvaturas, mas é principalmente estudada a curva principal com maior desvio lateral. Para mensurar o ângulo de Cobb é necessário identificar as vértebras apical e caudal. Em sentido descendente, a vértebra apical é a vértebra mais rotacionada em direção à curva; enquanto a vértebra caudal é a última rotacionada também em direção à curva (Figura 3).

Uma vez identificadas, são projetadas linhas paralelas aos planos superior e inferior das vértebras apical e caudal, respectivamente. O ângulo formado pela interseção dessas duas linhas é conhecido como ângulo de Cobb. Embora possa ser feito manualmente,

Figura 3 – Medição do ângulo de Cobb na curvatura principal. Escolise tipo C.



Fonte: Adaptado de Asher (2019).

atualmente métodos computadorizados fornecem o ângulo de Cobb com maior acurácia e precisão (ROLTON; NNADI; FAIRBANK, 2014).

Existem na literatura numerosas pesquisas que utilizam técnicas alternativas para mensurar o ângulo de Cobb. De forma geral, existem três métodos alternativos para mensurar o desvio lateral: assistido por computador, medição automática, e com aplicativos para equipamentos móveis como *smartphones* (LANGENSIEPEN *et al.*, 2013). A diferença entre o método assistido por computador e a medição automática, é que no primeiro caso são necessárias algumas marcas em áreas de interesse, que atuam como referência e permitem uma correta operação do método. Estes métodos realizam avaliações em 2D utilizando diretamente as radiografias dos sujeitos avaliados; no entanto e com o avanço da tecnologia, é possível encontrar novas técnicas que utilizam dados de tomografias computadorizadas para reconstruir digitalmente a coluna vertebral do paciente, permitindo obter diagnósticos ainda mais precisos (HUO *et al.*, 2017).

1.2 BIOMECÂNICA - POSTUROLOGIA CLÍNICA

Desde o século XIX, existe um interesse constante em se responder à seguinte pergunta: como o homem consegue se manter em pé? Para se responder a esta pergunta, desenvolveu-se o conceito de postura e, com o decorrer dos anos, a Posturologia, que é a área que estuda a postura e as variáveis a ela relacionadas. Os conceitos e definições propostos nesta seção, estão baseados principalmente nos trabalhos de Bricot (2010), Lippert (2011), Fonseca, Cardoso e Guimarães (2015), Crétual (2015) e Carini *et al.* (2017).

Do ponto de vista biomecânico, a postura corporal é entendida como a interação de todas as partes do corpo que permitem a manutenção de qualquer posição que demande uma sustentação anti-gravitacional. No entanto, além das forças gravitacionais, o corpo deve manter a postura quando submetido a forças externas e quando é necessária a própria movimentação. Também se refere não só a postura, mas ao sistema postural como um todo, aquele que permite ao corpo se situar no espaço-tempo do seu ambiente.

Cada parte do corpo que transfere peso é considerado um segmento postural. Neste sentido, uma boa postura é o correto alinhamento de todos os segmentos posturais do corpo. Quando alinhado corretamente, o gasto energético do corpo diminui, uma vez que é necessário destinar menor quantidade de energia aos músculos, principais responsáveis por manter o corpo na posição desejada e, especificamente, na posição ortostática.


Na Figura 4 são apresentadas as vistas e alinhamento de um corpo masculino, sem deficiências físicas, com postura em pé ideal. A vista lateral (plano sagital) oferece uma linha de referência para entender as partes do corpo que devem estar alinhadas para diminuir o gasto energético muscular. Se o corpo estiver desalinhado para anterior ou posterior, os músculos, principalmente os anteriores e posteriores da panturrilha, precisam estar ativados constantemente para corrigir o deslocamento do centro de gravidade. Embora os músculos da panturrilha sejam os de maior gasto energético quando há desalinhamento postural em anterior-posterior, existe toda uma corrente muscular, da cabeça aos pés, que influenciam na posição ortostática, conhecida como musculatura estática.

Os movimentos constantes, realizados pelos músculos para manter uma determinada posição, são chamados de micro-movimentos. De fato, embora em uma posição ereta e aparentemente estática, o corpo humano precisa realizar micro-movimentos para manter o

controle da posição. Por esta razão, o sistema de controle postural tem sido modelado de forma similar ao controle realizado por um sistema de pêndulo invertido ou pêndulo duplo.

O sistema que comanda os micro-movimentos e ativação de segmentos posturais é conhecido como sistema tônico postural, que além de manter uma postura definida, serve para manter a relação espaço-tempo sobre o ambiente da pessoa. Este sistema é relacionado a uma caixa preta, uma vez que as entradas e saídas do sistema são conhecidas, mas o funcionamento do sistema como tal ainda é de difícil entendimento. É por isto que profissionais da área da fisioterapia, especializados em posturologia, se referem à posturologia clínica como um processo de avaliação e tratamento holístico.

Figura 4 – Postura ortostática ideal e alinhamento corporal.



Fonte: Adaptado de Lippert (2011).

O sistema tônico postural depende principalmente da informação coletada pelos seus receptores, nos quais se destacam os pés, olhos e o aparelho mastigador. O receptor mastigador é considerado porque o aparelho mastigatório está diretamente ligado às cadeias musculares posteriores e anteriores do pescoço e do tronco. No entanto, dentre os receptores, são especialmente importantes os pés e olhos, que são receptores somatossensoriais.

Para entender a biomecânica da postura estática, é prático identificar o corpo humano como um conjunto de segmentos posturais que se relacionam entre eles, podendo ser relações ascendentes ou descendentes.

A relação ascendente começa no receptor podal e indica que um segmento se equilibra sobre outro elemento. É assim como as pernas equilibram-se sobre os pés, as coxas sobre as pernas, a cintura pélvica sobre as coxas, e o tronco sobre a cintura. Esta relação ascendente é muito importante para o equilíbrio estático da pessoa.

A relação descendente começa no receptor visual que deve manter a verticalidade e horizontalidade. Na relação descendente intervêm os músculos do pescoço, que repousam sobre os ombros, membros superiores e o tronco em geral.

Embora comentadas como relações ascendentes ou descendentes, o sistema se comporta como um todo e as relações podem ser de duas vias, como apresentado na Figura 5. Assim, o tronco é o segmento comum entre as relações ascendentes e descendentes, sendo aí onde são realizadas grande parte das compensações estáticas.

Mesmo que os receptores visual e podal sejam os mais importantes para o sistema postural, os pés apresentam maior correlação com os desvios posturais da coluna vertebral.

1.3 RECEPTOR PODAL E CADEIA ASCENDENTE


Com o intuito de entender a biomecânica do receptor podal, o pé humano foi dividido em três partes, como mostrado na Figura 6a.

A região posterior, também conhecida como retropé, constituída pelo tálus e calcâneo, que ao caminhar é a primeira parte em fazer contato com o solo, normalmente suporta entre o 40% e 50% do peso corporal.

A região do mediopé, constituída pelos ossos navicular, cuboides e cuneiformes, que permitem a estabilidade e mobilidade do corpo, além de transferir a energia da parte posterior para a parte anterior do pé ao caminhar ou correr. Estima-se que o mediopé suporta peso corporal na faixa de 10-20%.

Por fim, a parte anterior do pé, também chamada antepé, que suporta peso entre 30% e 40%, está composta pelos metatarsos e as falanges de cada dedo; ao caminhar e correr é a última parte a entrar em contato com o chão. Igualmente é a parte que se adapta melhor à superfície de apoio, possibilitando maior estabilidade (KAPANDJI, 2000; LIPPERT, 2011).


Figura 5 – Sistema postural. Cadeias ascendentes, descendentes e sistema de pêndulo duplo.



Fonte: Adaptado de Bricot (2010).

O pé, como explicado anteriormente, é um complexo sistema composto por elementos ósseos, ligamentares e musculares. Particularmente o pé possui uma estrutura que assemelha uma abóbada arquitetônica, consequentemente chamada abóbada plantar. A abóbada plantar é formada por três arcos e três pontos de apoio que estão em contato com o solo, vide Figuras 6b e 6c. A abóbada plantar é encarregada de transferir as forças ao solo e, pela sua elasticidade, possibilita que o pé se adapte à superfície de contato (LIPPERT, 2011). As curvaturas da região plantar são consideradas uma resposta evolutiva à necessidade de correr e transportar cargas (MCKEON *et al.*, 2015).

Figura 6 – Divisão do pé e abóbada plantar.



Fonte: Adaptado de Kapandji (2000) e Lippert (2011).

Os pés, como base de suporte, fazem parte dos segmentos que possibilitam o controle postural. De fato, os pés são a parte final da corrente cinemática e inicial da cadeia ascendente, e uma assimetria ou desequilíbrio nesta corrente pode gerar patologias articulares, ligamentares ou musculares (BRICOT, 2010).

Algumas das patologias recorrentes no receptor podal são o pé chato e o pé cavo. O pé chato (plano) tem uma perda do arco meio do pé, que com o descarregamento do peso exige uma rotação interna dos eixos tibiais e femorais (Figura 7). Entretanto, o pé cavo, com um arco meio do pé elevado, exige a distribuição de forças na região posterior (calcanhar) e anterior (metatarsos e falanges), gerando um pisada supinada com desalinhamento tipo varo, fazendo uma rotação externa dos eixos tibiais e femorais. As rotações tibiais e femorais geram rotações na cintura pélvica no plano sagital, podendo ocasionar problemas posturais como o dorso plano, no caso dos pés com alinhamento tipo varo, ou hiperlordose com alinhamento tipo valgo (BRICOT, 2010; LIPPERT, 2011).

As rotações e desalinhamentos dos membros inferiores, assim como da cintura pélvica, geram, conseqüentemente, solicitações anormais às costas e outros segmentos posturais. No caso de dorso plano, o centro de gravidade da pessoa é deslocado anteriormente, obrigando aos músculos posteriores a atuarem constantemente para manter o balanço e equilíbrio do corpo. Desta forma, tensões na região cervical e lombar são comuns, sendo também

exigidos maiores esforços dos músculos das panturrilhas e pressões excessivas na região anterior do pé, principalmente nos dedos (BRICOT, 2010).

No caso da hiperlordose, as vértebras lombares são sobrecarregadas, gerando contraturas musculares e finalizando em lombalgia, que são dores na região lombar chegando a atingir também as nádegas e as pernas (BRICOT, 2010).

As relações entre as deformações dos pés e os desvios posturais, principalmente da região lombar e no plano sagital, têm sido amplamente estudadas na história recente.

Igualmente, numerosos estudos têm mostrado que os pés têm não só relação com desvios posturais, mas também com características próprias do corpo humano. Menz e Morris (2006) relacionaram estatisticamente picos de pressão e distribuições de força na região plantar de adultos maiores ao caminhar, identificando que o peso corporal da pessoa contribui, mas não exclusivamente, à magnitude e tipos de distribuição de forças plantares.


Por outro lado, Cordeiro *et al.* (2014) mostraram que a distribuição de forças na região plantar pode ser influenciada pela diferença entre o comprimento das pernas. Da mesma forma, os autores mostraram que através de pilates e uso de palmilhas, foi possível reeducar a postura da pessoa, balanceando assim a distribuição de forças plantares.

Similarmente, Fang (2018) encontrou diferenças nas pressões máximas que são exercidas por dois grupos de mulheres em diferentes faixas etárias. Isto em concordância com a pesquisa realizada por McKay *et al.* (2017) onde foi possível identificar que as pressões máximas exercidas pelos pés mudam com o decorrer dos anos, aumentando na parte frontal do pé.

Em uma pesquisa recente, Wojtków, Szkoda-Polizuk e Szotek (2018) mostraram que existe correlação entre a distribuição de forças na região plantar e ângulos de desvios posturais nas regiões sacro-lombares e cervo-torácicas. Neste caso foram avaliados 78 menores, na faixa 6-8 anos, sendo 53,8% do sexo feminino e 46,2% do sexo masculino. As correlações foram estatisticamente significativas no nível $\rho < 0.05$ entre os ângulos da regiões torácica (cifose) e lombar (lordose) com a distribuição de forças do pé esquerdo no caso do grupo feminino. Igualmente foram significativas no mesmo nível, entre os ângulos da regiões pelviana e lombar com a distribuição de forças do pé direito no caso do grupo masculino.

Assim sendo, é possível afirmar que existe uma correlação entre distribuições de força na região plantar e a postura da pessoa, considerando além das características do

Figura 7 – Deformidades dos pés e solicitações anormais da cadeia ascendente.



Fonte: Adaptado de Body (2010) e Bricot (2010).

sistema somatossensorial, também os dados biométricos de cada indivíduo como idade, altura, sexo e massa corporal entre outras.

1.3.1 Relação Pé – Escoliose

Embora sejam variadas as pesquisas encontradas na literatura sobre escoliose, postura, estabilidade e baropodometria, infelizmente poucos trabalhos estão focados em quantificar e avaliar a relação direta entre escoliose e distribuições de força na região plantar. Tanto o baropodômetro como o centro de pressão e as variáveis de estabilometria serão explicados em detalhe na Seção 1.4.

Uma pesquisa representativa nesta área foi a desenvolvida por Park *et al.* (2009), no qual a partir de uma análise estatística, avaliaram as correlações entre o ângulo de Cobb em pacientes com desvios laterais e pressões em áreas definidas na região plantar. Neste caso, apenas 4 sujeitos foram objeto de análise, sendo todos de sexo masculino e adultos jovens de 20 anos de idade. A média dos graus do desvio lateral dos participantes da pesquisa foi de 2,8°. Para avaliar a angulação da coluna vertebral utilizaram-se radiografias dos sujeitos avaliados; enquanto para avaliar a distribuição de forças na região plantar um baropodômetro comercial do tipo *in-shoe* foi utilizado. Os resultados mostraram uma correlação significativa na ordem $p < 0,05$, sendo que quanto maior a angulação na coluna vertebral, maiores as diferenças nas pressões plantares.

Entretanto, Park *et al.* (2015) fizeram um estudo com 118 adolescentes na faixa dos 13–17 anos, sendo 96 mulheres e 22 homens, todos diagnosticados com escoliose (ângulos de Cobb maiores que 10°). A pesquisa objetivou correlacionar desalinhamentos do tipo pé valgo com desvios torácico–lombares. Os autores encontraram correlações significativas na ordem $p < 0,05$ entre os ângulos dos pés valgos e os ângulos de rotações torácicas. Ainda comentaram a opção de utilizar os ângulos do calcanhar para diagnosticar e prever o progresso de escoliose.

Em caso de escoliose a posição natural da coluna vertebral é modificada, alterando o centro de massa, dificultando o controle postural, e gerando um incremento nas oscilações corporais, que são refletidas nas variáveis associadas ao centro de pressão (COP) como mostrado por Zabjek *et al.* (2008), Santiago *et al.* (2013), e Chern *et al.* (2014).

Neste sentido e como já mostraram diferentes pesquisas, entre elas algumas recentes como as publicadas por Pasha e Baldwin (2018) e Wilczynski *et al.* (2018), desvios laterais


na região tóraca estão relacionados diretamente com variáveis de estabilometria, sendo que quanto maior a(s) curvatura(s) na coluna vertebral maiores as magnitudes de algumas das variáveis de estabilometria como áreas e velocidades de deslocamento do COP. Embora existam problemas na padronização dos testes de estabilometria, dificultando a comparação objetiva das pesquisas na área, é possível afirmar que realmente existe uma relação (não significativamente alta) entre o comportamento do COP e a escoliose (DUFVENBERG *et al.*, 2018).

Similarmente, Paolucci *et al.* (2013) reportaram, além do incremento nas oscilações corporais mensuradas através do COP, também assimetrias nas distribuições de pressão na região plantar em 13 pacientes adolescentes com escoliose (ângulos de Cobb = $32 \pm 9^\circ$) comparados com um grupo de controle de 13 adolescentes sem escoliose.

1.4 SISTEMAS DE MEDIÇÃO DE PRESSÕES PLANTARES

Desde a pesquisa documentada por Elftman (1934) até a atualidade, inúmeras pesquisas têm sido desenvolvidas para conhecer e interpretar a interação dos pés com as superfícies de apoio. Tradicionalmente a análise de distribuição de forças na região plantar é feita através de avaliações subjetivas e com técnicas amplamente difundidas, como a pedigrafia (Figura 8a), ou com equipamentos de observação, como o podoscópio (Figura 8b).

Figura 8 – Técnicas tradicionais de avaliação de forças na região plantar, (a) pedigrafia e (b) podóscopio




Fonte: Castro (2016)

Embora sejam técnicas de baixo custo ou equipamentos de fácil aquisição por parte de instituições de saúde, este tipo de avaliação é subjetiva, porque tais técnicas não quantificam variável alguma e dependem inteiramente do julgamento do avaliador.

Para quantificar e realizar avaliações mais precisas, foi desenvolvido o baropodômetro. O baropodômetro é um sistema constituído por elementos de *software* e *hardware* (Figura 9). Na parte física, o equipamento é caracterizado por possuir numerosos sensores de pressão ou força dentro de uma área grande o suficiente para avaliar a interação do pé com a superfície de apoio. Do lado computacional, o baropodômetro tem um *software* específico que possibilita fazer aquisição de dados em tempos de execução baixos, com frequências de amostragem que permitam realizar avaliações dinâmicas e estáticas.

Figura 9 – Baropodômetro comercial emed® da Novel GmbH.




Fonte: Novel (2008a).

Como inicialmente proposto por Hughes (1993) e afirmado recentemente por Ramirez-Bautista *et al.* (2017), o baropodômetro possui três usos clínicos definidos: a) auxiliar profissionais da área da saúde no monitoramento e avaliação de tratamentos, e também no diagnóstico de patologias associadas à região plantar; b) coletar, armazenar e analisar dados para fazer comparações por grupos; c) desenvolvimento de elementos ortopédicos para membros inferiores.

Como apresentado na Figura 10, com o decorrer do anos o baropodômetro tem incrementado exponencialmente sua participação na área clínica e de pesquisa, segundo os resultados obtidos na base de dados acadêmica *Google Scholar*. Este comportamento pode ser explicado pelo avanço tecnológico das últimas décadas, possibilitando uma maior interação entre as áreas exatas e as áreas da saúde.

Mesmo havendo um número crescente de pesquisas utilizando baropodômetros, os mesmos ainda têm um custo elevado, impossibilitando sua aquisição por parte da

Figura 10 – Participação do baropodômetro nas áreas clínicas e de pesquisa.



Fonte: Elaboração do próprio autor.

maioria de instituições de saúde e de ensino. Neste sentido, instituições acadêmicas têm desenvolvido vários equipamentos de avaliação de distribuição de força na região plantar visando uma produção de baixo custo (CASTRO, 2016; RAMIREZ-BAUTISTA *et al.*, 2017).

Os equipamentos desenvolvidos para avaliar distribuições de força podem ser classificados em dois grupos: sistemas de plataforma, caracterizados por serem sistemas fixos, geralmente localizados em ambientes fechados, como laboratórios ou clínicas; e sistemas *in-shoe*, caracterizados por serem sistemas embarcados e sem fio, onde sensores ficam dentro do calçado, sendo possível realizar avaliações dinâmicas em ambientes naturais para o sujeito avaliado (RAZAK *et al.*, 2012).

Como explicado, são muitos os equipamentos desenvolvidos para coletar dados da interação do pé com o solo. O baropodômetro é o equipamento mais completo uma vez que possibilita realizar avaliações dinâmicas e estáticas. No entanto, existem outras duas técnicas bastante utilizadas. A primeira utiliza processamento digital de imagens para identificar topologias dos pés e pontos de máxima pressão, a segunda é a plataforma de força que permite identificar a posição e a magnitude da força exercida em uma área conhecida (RAZAK *et al.*, 2012).

As técnicas com processamento digital de imagens são geralmente associadas a podoscopios que possibilitam identificar formas dos pés e pontos de máxima pressão como mostrado por Laowattanatham *et al.* (2015) e Medina *et al.* (2018). Por outro lado, as plataformas de força que possuem tipicamente 4 sensores de força (células de carga),

possibilitam a medição da magnitude de força exercida sobre o equipamento, também como a posição relativa desta força nas coordenadas X e Y para identificar o COP (DUARTE; FREITAS, 2010).

A plataforma de força, por ser um equipamento relativamente simples e econômico, é o mais utilizado para avaliar padrões de marcha e para avaliar dados de estabilidade por meio do conceito de centro de pressão.

1.4.1 Centro de Pressão

No corpo humano, o centro de pressão (COP) é a localização do ponto do vetor de força de reação ao solo. Ele representa a média de todas as pressões sob os pés e em contato com o solo (WINTER, 1995). Desta forma o COP refere-se a uma posição em coordenadas médio-lateral (COP_x) e anterior-posterior (COP_y) que representa o vetor de força de reação ao solo exercido pela distribuição de forças na região plantar. Segundo Han, Paik e Im (1999) o par ordenado é calculado como segue:


$$COP(x, y) = COP_x, COP_y = \frac{\sum_{i=1}^N (P_i * X_i)}{\sum_{i=1}^N (P_i)}, \frac{\sum_{i=1}^N (P_i * Y_i)}{\sum_{i=1}^N (P_i)} \quad (1)$$

onde X_i é a ordenada de cada sensor no eixo X, Y_i a ordenada de cada sensor no eixo Y, P_i a pressão em cada sensor e N o número de sensores do sistema.

Na Figura 11 é apresentado um exemplo de deslocamento do COP para identificar e esclarecer seu conceito. Considere que as áreas mais escuras das figuras representam as regiões de maior força exercida na região plantar sobre uma área definida. No caso da Figura 11a, a pessoa exerce maior pressão com o pé esquerdo, assim, o COP identificado com o ponto verde está deslocado à esquerda sobre o eixo horizontal. Se a pessoa exerce uma pressão igual com os dois pés, o COP vai ficar na origem como apresentado na Figura 11b. Já no caso da Figura 11c, a pessoa exerce maior pressão no pé direito deslocando o COP na mesma direção. As diferenças de pressão na direção AP foram desconsideradas.

A estabilometria é o estudo do comportamento do COP. Devido às forças intrínsecas do corpo para manter a posição ereta, o COP está em constante deslocamento, as vezes imperceptível ao olho humano, mas que com ajuda de equipamentos como baropodômetros e plataformas de força, é possível quantificar as diferentes grandezas associadas a estes deslocamentos. Na Tabela 1 estão relacionadas as variáveis propostas por Duarte e

Figura 11 – Deslocamentos do centro de pressão.




Fonte: Elaboração do próprio autor.

Freitas (2010) para análise global do COP e que são utilizadas nas inúmeras análises de estabilometria.

Os dados de estabilometria RMS_{ML} e RMS_{AP} são obtidos através do *Estabilograma*, que representa graficamente os deslocamentos do COP nas direção ML e AP em função do tempo, como apresentado na Figura 12a. Os dados restantes são obtidos da técnica de *Estatocinesigrama*, que faz uma representação gráfica do deslocamento do COP no plano AP vs ML, como mostrado na Figura 12b.

Figura 12 – Técnicas de análise do COP, (a) Estabilograma; (b) Estatocinesigrama.



Fonte: Elaboração do próprio autor.

Tabela 1 – Variáveis de Estabilometria.

Variável	Expressão
Deslocamento da Oscilação Total (DOT)	$\sum_{i=0}^{M-1} \sqrt{(COPx_{i+1} - COPx_i)^2 + (COPy_{i+1} - COPy_i)^2}$
Deslocamento da Oscilação Total em ML (DOT_{ML})	$\sum_{i=0}^{M-1} COPx_{i+1} - COPx_i $
Deslocamento da Oscilação Total em AP (DOT_{AP})	$\sum_{i=0}^{M-1} COPy_{i+1} - COPy_i $
Velocidade Média Total (VMT)	$\frac{f * DOT}{M-1}$
Velocidade Média Total em ML (VMT_{ML})	$\frac{f * DOT_{ML}}{M-1}$
Velocidade Média Total em AP (VMT_{AP})	$\frac{f * DOT_{AP}}{M-1}$
Amplitude de Deslocamento em ML (AD_{ML})	$max(COPx) - min(COPx)$
Amplitude de Deslocamento em AP (AD_{AP})	$max(COPy) - min(COPy)$
Área de Deslocamento (SWA)	$[vec, val] = eig(cov(COPy, COPx)); SWA = pi * prod(2, 4478 * sqrt(svd(val)))$
Deslocamento Eficaz em ML (RMS_{ML})	$\sqrt{\frac{\sum_{i=0}^{M-1} COPx_i^2}{M}}$
Deslocamento Eficaz em AP (RMS_{AP})	$\sqrt{\frac{\sum_{i=0}^{M-1} COPy_i^2}{M}}$

M = Número total de amostras.

Fonte: Adaptado de Duarte e Freitas (2010).

1.5 MACHINE LEARNING – ESTADO DA ARTE

Utilizando dados baropodométricos e dados de estabilometria, numerosas pesquisas têm sido desenvolvidas para entender a biomecânica do corpo humano. Uma linha de pesquisa pouco explorada dentro das variadas pesquisas com dados baropodométricos é a utilização de técnicas de aprendizado de máquina ou *Machine Learning* (ML).

Analiticamente, o ML é a interação entre as estatísticas, obtidas a partir das correlações de variáveis de diferentes sistemas, e a ciência da computação; possibilitando identificar padrões em bases de dados, geradas pelas inúmeras observações do comportamento dos próprios sistemas, sempre à procura da maior eficiência (ALSHEIKH *et al.*, 2014; KOBAR; FERBER, 2018). Como descrito por Ayodele (2010), o ML faz parte da chamada inteligência artificial, sendo que um sistema inteligente é aquele com a capacidade de reagir e aprender sobre as mudanças do ambiente. O ambiente no qual está envolvido o conceito de ML é um ambiente relacionado ao reconhecimento de padrões, predição de processos e dados, classificações de dados, resolução de problemas matemáticos e estatísticos entre outros.

Em resumo, o ML é a junção de análises estatísticas com algoritmos computacionais visando a classificação de dados por padrão ou predição. Nesse sentido, o ML e as técnicas associadas a ele, constituem uma área transversal do conhecimento, permitindo sua utilização nas mais variadas aplicações como por exemplo: diagnósticos e classificações na área médica (WILLIAM *et al.*, 2018; PELLEGRINI *et al.*, 2018), sistemas de energia renovável (ALMONACID *et al.*, 2017; VOYANT *et al.*, 2017), sistemas de gerenciamento de energia e recursos em prédios (YILDIZ; BILBAO; SPROUL, 2017; AFRAM *et al.*, 2017), sistemas de produção de azeite de oliva (GONZALEZ-FERNANDEZ *et al.*, 2018), entre muitos outros.

1.5.1 *Machine Learning – Região Plantar*

Como ilustrado na Figura 10, desde a última década do século XX houve um incremento exponencial na utilização de dados baropodométricos nas áreas clínicas e de pesquisa. Igualmente, nessa mesma década, e com desenvolvimento computacional da época, iniciaram-se muitas pesquisas utilizando técnicas de aprendizado de máquina.

Para o caso particular de dados baropodométricos utilizados em conjunto com técnicas de ML, é importante fazer referência a Holzreiter e Köhle (1993) que utilizaram

Redes Neurais Artificiais (RNA) para classificar voluntários entre saudáveis e patológicos, utilizando dados coletados de análise de marcha. Neste caso, os autores utilizaram duas plataformas de força para mensurar a marcha de 225 voluntários, sendo 94 saudáveis e 131 diagnosticados com diferentes patologias na marcha e na postura. A técnica obteve uma porcentagem de classificação correta de até 95%.

Igualmente, Barton e Lees (1995) classificaram patologias nos pés segundo dados baropodométricos coletados de um baropodômetro da Novel (2008a). Ao todo foram selecionados 18 sujeitos para treinar uma RNA que possibilitasse classificar dados em 3 possíveis categorias: normal, pé cavo, ou hálux valgo. Os resultados mostraram classificações corretas na faixa de 77-92%. A variação na porcentagem de acerto na classificação é devido ao método de avaliação e teste da RNA, e ao limitado tamanho da base de dados.

Anos mais tarde, Begg e Kamruzzaman (2006) desenvolveram a primeira pesquisa que utilizou dados da marcha para diferenciar entre sujeitos de diferentes faixas etárias. No total foram utilizados dados de 24 voluntários sendo 12 adultos jovens com idade média de 28 anos e 12 adultos idosos com idade média de 68 anos. A coleta de dados foi realizada utilizando uma plataforma de força e um sistema de análise de movimento em 2D. A RNA atingiu 87% de acerto na classificação.

É importante destacar o trabalho desenvolvido pelo *Institute for Health and Sport (IHES)* da *Victoria University* em Melbourne, Australia, sob orientação do Prof. Dr. Rezaul K. Begg. Os pesquisadores deste instituto têm gerado consideráveis aportes ao conhecimento através de pesquisas que envolvem o estudo da biomecânica do pé e da marcha, utilizando técnicas de ML para encontrar correlações e realizar classificações. Destaca-se o uso de técnicas como Máquinas de Vetor Suporte (SVM) e RNA para detectar padrões de marcha em adultos jovens e idosos, bem como para detectar risco de queda segundo padrões de marcha em idosos. As pesquisas deste grupo envolvem dados baropodométricos, sistemas de análise de movimento e sensores inerciais (BEGG; PALANISWAMI; OWEN, 2005; LAI *et al.*, 2009; SANTHIRANAYAGAM *et al.*, 2015; NAGANO; BEGG, 2018).

No mesmo grupo de trabalho, Wafai *et al.* (2014) utilizaram uma RNA para classificar sujeitos segundo as características da sua marcha entre normal e patológica. 47 voluntários foram avaliados nesta pesquisa, sendo 31 deles classificados como sujeitos de controle ou normais e o restante como o grupo com alguma patologia associada à marcha.

Para a coleta dos dados utilizou-se uma metodologia de marcha e sensores do tipo *in-shoe*. A RNA mostrou uma acurácia média de 94%.

Por outro lado, Keijsers *et al.* (2013) utilizaram dados baropodométricos para classificar pacientes segundo sua condição de dor no antepé. Ao todo foram avaliados 297 voluntários na faixa etária 16-78 anos, onde 52% dos avaliados relataram algum tipo de dor no antepé. Para a coleta de dados utilizou-se um baropodômetro e uma metodologia de marcha. Além das distribuições de força na região plantar foram utilizados dados de estabilometria. A RNA atingiu 70,4% de acerto e os autores afirmam que realmente existe uma relação de causalidade entre as pressões da região plantar e as dores no antepé.

Recentemente, outro grupo de estudo tem feito importantes avanços na análise de dados de marcha e técnicas de ML. O grupo dirigido pelo Prof. Dr. Krikor B. Ozanyan, da *University of Manchester*, tem pesquisado sobre a classificação de padrões de marcha e atividades cotidianas utilizando variadas técnicas de ML, chegando a utilizar técnicas de aprendizado mais avançadas como *Deep Learning* (COSTILLA-REYES; SCULLY; OZANYAN, 2016; COSTILLA-REYES; SCULLY; OZANYAN, 2017; ZEBIN; SCULLY; OZANYAN, 2017; REYES *et al.*, 2019). De forma geral os autores encontraram que a técnica de ML por SVM apresenta os melhores resultados para avaliações e classificações de marcha. As pesquisas utilizaram um equipamento baropodométrico próprio, que usa fibras óticas de plástico suscetíveis à deformação por pressão (CANTORAL-CEBALLOS *et al.*, 2015).

1.5.2 Machine Learning – Escoliose

Da mesma forma que com os dados baropodométricos, o uso de técnicas de ML para analisar a escoliose teve um crescimento considerável com o novo século.

Nesta linha de pesquisa, destaca-se o grupo multicentro organizado pelo Prof. M.D. Hubert Labelle da *Université de Montréal*, Canada. Com quase 20 anos de experiência na área, o grupo têm contribuído ativamente com a utilização de técnicas de ML para o entendimento da escoliose. Alguns dos trabalhos mais importantes são mencionados a seguir.

Jaremko *et al.* (2000) utilizaram RNA para classificar e correlacionar graus de acometimento de escoliose com as rotações de costelas. A RNA atingiu uma eficiência média de 60%. A base de dados utilizada nesta pesquisa é constituída por informações radiográficas de 35 adolescentes. Em um trabalho contínuo, Jaremko *et al.* (2001) utilizaram

uma RNA para classificar e diagnosticar ângulos de Cobb em imagens radiográficas e imagens em 3D do torso. A eficiência relatada da RNA foi de 63%. A base de dados é formada por 65 dados obtidos de 40 pacientes.

Sendo um projeto multi-centro, foram colocados à disposição diferentes laboratórios, em diferentes cidades, que possibilitaram realizar uma coleta mais abrangente em termos de número de pacientes e graus de acometimento de desvio lateral. Mezghani *et al.* (2008) utilizaram dados de raios-X para treinar e testar uma RNA autorganizável de Kohonen e assim classificar, segundo o grau de acometimento, vários voluntários em 3 diferentes grupos classificados como: normal, moderada e severa. Após treinar e testar 174 dados, a RNA obteve uma acurácia de 97%.

Sendo uma pesquisa continuada, Mezghani *et al.* (2012) utilizaram uma RNA de Kohonen para auxiliar, na tomada de decisão, ao profissional cirúrgico em relação à escoliose e considerando a classificação de Lenke que permite identificar as áreas de fusão. A classificação de Lenke depende do ângulo de Cobb. Neste caso, foi utilizada uma base de dados com 1776 sujeitos avaliados e munidos de radiografia da coluna vertebral. A base de dados pertence ao grupo *Spinal Deformity Study Group (SDSG)* e além dos raio-X dos pacientes, eram disponíveis seus dados biométricos, classificação de Lenke, ângulo de Cobb e resumo pré e pós cirurgia. Com a mencionada RNA, obteve-se um acerto de 88%.

Adankon *et al.* (2012) utilizaram dados coletados das imagens 3D dos dorsos e radiografias da coluna vertebral, para classificar 165 pacientes, em 3 grupos, segundo o tipo de curvatura na coluna. A técnica SVM foi utilizada, obtendo-se uma acurácia média de 95%.

Similarmente, García-Cano *et al.* (2018) utilizaram uma regressão por *Random Forest* (técnica de ML). A técnica objetivou prever a variação da coluna vertebral de pacientes diagnosticados com escoliose, durante um período de ano e meio. Neste caso foram utilizados modelos em 3D da coluna vertebral. Foram utilizados para treinamento 150 pacientes, e 15 pacientes para teste, obtendo um erro em ângulos de Cobb, da predição da deformidade, de $1,01 \pm 3,37$ graus.

Realizando uma pesquisa independente do grupo anterior, Lin (2008) utilizou uma RNA para classificar, segundo modelos em 3D da coluna vertebral, o nível de fusão e o processo cirúrgico, seguindo o critério de classificação de King. A base de dados de treinamento e teste do pesquisador possuía somente 25 modelos de coluna; no entanto, as porcentagens de acerto estão na faixa de 98%.

Também, Kadoury *et al.* (2017) desenvolveram uma técnica de ML própria baseada em modelos probabilísticos e o conceito de vizinhança por meio de distâncias euclidianas. O objetivo dos autores foi inicialmente classificar entre escoliose progressiva ou não progressiva, segundo modelos em 3D de colunas vertebrais de pacientes diagnosticados com escoliose. Utilizando uma base de tempo de 3 anos, onde foram coletados dados de pacientes recorrentes, conseguiram prever, por meio de ML, deformações na coluna utilizando o ângulo de Cobb como referência. Utilizando 745 modelos 3D, obtidos de 133 sujeitos, a técnica de ML obteve acurácia máxima de 81% na classificação entre escoliose progressiva e não progressiva. Em relação à predição da angulação, a técnica de ML mostrou erros não significativos entre o ângulo de Cobb e o ângulo predito.

1.5.3 Machine Learning – Escoliose – Baropodômetro

A correlação e/ou classificação de escoliose com dados baropodométricos e de estabilometria utilizando técnicas de aprendizado de máquina não tem sido explorada e não foram encontrados trabalhos de pesquisa nesta área.

Apenas o trabalho de pesquisa desenvolvido no Laboratório de Instrumentação e Engenharia Biomédica (LIEB), do Departamento de Engenharia Elétrica da UNESP – Câmpus de Ilha Solteira, tem feito aproximações neste campo do conhecimento. Fanfoni (2017) e Fanfoni *et al.* (2017), utilizando distribuições de força na região plantar, classificaram voluntários em dois grupos segundo o grau de desvio lateral: com e sem escoliose. Por meio de uma RNA do tipo ADALINE, que é uma técnica de ML de classificação de dados linearmente separáveis, obteve-se uma acurácia geral de 91,9%.

Entretanto, Castro *et al.* (2017), através de análise estatística, conferiu que existem correlações entre a escoliose, os dados estabilométricos e os dados biométricos em voluntários de diferentes faixas etárias.

As pesquisas do LIEB supracitadas foram desenvolvidas com um baropodômetro de baixa densidade de sensores por unidade de área (URBAN, 2015), motivo pelo qual decidiu-se implementar um novo baropodômetro com número de sensores compatível com baropodômetros comerciais, que são de alto custo.

1.6 OBJETIVOS

Considerando a necessidade de desenvolvimento de um equipamento baropodométrico com características comparáveis com equipamentos comerciais e, considerando também, que é possível utilizar técnicas de machine learning para explorar as correlações pé–escoliose através do banco de dados coletados pelo LIEB, são dois os objetivos do trabalho:

- Desenvolver e caracterizar um baropodômetro utilizando uma matriz piezoresistiva e um circuito para controle de *crosstalk*.
- Avaliar o uso de técnicas de ML para classificar voluntários segundo o grau de desvio lateral da coluna vertebral, utilizando dados baropodométricos, biométricos e de estabilometria.

1.7 ESTRUTURA DO TRABALHO

Neste capítulo foram apresentados conceitos que contribuem ao desenvolvimento das pesquisas, focando principalmente no estado da arte e visando entender a relação escoliose–pé e baropodômetro–ML.

Para atingir os objetivos propostos, é necessário realizar um estudo aprofundado dos diferentes sistemas e ferramentas tanto em *hardware* como em *software*.

No Capítulo 2 é apresentada uma revisão bibliográfica sobre baropodômetros e suas principais características.

O desenvolvimento de um novo sistema baropodométrico é descrito, desde a seleção dos circuitos até a metodologia de avaliação e caracterização do sistema. São também mencionados os principais índices de desempenho do sistema que devem ser atingidos.

No Capítulo 3 descreve-se algumas ferramentas de *software* e, mais especificamente, algumas técnicas de ML. São apresentados alguns classificadores binários supervisionados e metodologias aplicadas para sua implementação.

No Capítulo 4 são apresentados os resultados e as discussões das pesquisas realizadas.

No Capítulo 5 são apresentadas as principais conclusões das pesquisas e sugestões para realização de trabalhos futuros.

2 BAROPODÔMETRO

Conforme mencionado no capítulo anterior, o baropodômetro é um equipamento desenvolvido para mensurar a distribuição de forças na região plantar de pessoas.

Os baropodômetros tradicionais são estruturas fixas com áreas delimitadas que possibilitam realizar avaliações estáticas e dinâmicas, mas sempre em um ambiente adequado estabelecido pelo avaliador. Visando realizar avaliações típicas de movimentação do paciente, como caminhar, correr ou praticar alguma atividade física e esportiva, foram desenvolvidos equipamentos baropodométricos portáteis *in-shoe*, que possuem os mesmos tipos de sensores que as plataformas fixas, mas acrescentando sistemas sem fio ou de armazenamento local. Neste trabalho é apresentado o desenvolvimento de um baropodômetro fixo.

2.1 TIPOS DE SENSORES

Vários são os tipos de sensores utilizados para mensurar as forças exercidas pelos pés ao contato com o solo. No entanto, é desejável que os sensores tenham algumas características como: resposta linear, baixa histerese, baixa sensibilidade à variação de temperatura (principalmente na faixa 20-37 °C), faixa de força adequada para suportar os esforços aos quais vão ser submetidos (geralmente na faixa 0-1 MPa), área ativa de no mínimo, 25 mm², quando o equipamento utiliza sensores individuais (podendo ter sensores ainda menores quando implementada uma matriz de sensores), frequência de amostragem adequada em função do tipo de avaliação realizada (sendo 200 Hz a frequência máxima requerida em caso de avaliações de corrida), elevada repetibilidade e baixo efeito *creep* (definido como a deformação do material sob condições estáticas) (RAZAK *et al.*, 2012).

A seguir, são apresentados os sensores mais utilizados para medição de forças na região plantar e utilizados em equipamentos baropodométricos.

2.1.1 Sensores Capacitivos

O sensor capacitivo é feito principalmente de duas placas condutivas carregadas eletricamente e separadas por um material dielétrico. Qualquer estímulo físico que modifique a distância entre as placas condutivas, ou seja, varie a espessura do material dielétrico,

pode ser mensurado relacionando-o com a mudança na capacitância do sensor. Algumas das características mais importantes deste tipo de sensores são sua elevada sensibilidade, pouca variação com a temperatura e baixo consumo de energia. Empresas com ampla trajetória no mercado de desenvolvimento de equipamentos baropodométricos, como a Novel (2008a), utilizam sensores capacitivos. No entanto, esta tecnologia requer circuitos complexos e são susceptíveis a correntes parasitas e interferências eletromagnéticas (YANG *et al.*, 2017).

2.1.2 Sensores Resistivos - Piezoresistivos

Os sensores que mudam a resistência elétrica em função de estímulos mecânicos exercidos sobre suas áreas ativas são conhecidos como sensores resistivos ou piezoresistivos. Possuem dois eletrodos ou placas condutoras, com um material piezoresistivo no meio, geralmente um polímero, como é o caso do sensor mais utilizado, o FSR - *force sensing resistor* (YANG *et al.*, 2017; RAZAK *et al.*, 2012).

Geralmente, quanto maior for a força exercida sobre o sensor, menor será sua resistência elétrica. Este efeito é obtido em função da variação geométrica do sensor, como no caso dos extensômetros (*strain gauges*), ou pela variação própria na resistividade do material. As principais características dos sensores piezoresistivos são sua sensibilidade, ampla faixa de operação, e processos de fabricação simples e de baixo custo. Entretanto, são materiais dependentes da temperatura, elevada histerese e suscetíveis ao efeito de *crosstalk*.

2.1.3 Sensores Piezoelétricos

O sensor piezoelétrico gera uma diferença de potencial quando submetido a esforços mecânicos. As principais características deste sensor são alta sensibilidade, baixo consumo de energia e elevadas impedâncias. No entanto, a saída de tensão gerada pelo sensor é influenciada pelo efeito *drift*, fazendo com que o sinal não seja constante ao longo do tempo, impossibilitando seu uso em avaliações estáticas e utilizado apenas em avaliações dinâmicas (YANG *et al.*, 2017; RAZAK *et al.*, 2012).

A estrutura física deste tipo de sensor é similar à estrutura dos sensores capacitivos, sendo que possui igualmente duas placas condutivas e um material entre elas que define a

característica do sensor; neste caso, as placas estão separadas por materiais como titanato zirconato de chumbo (PZT) ou flureto de polivinilideno (PVDF) que são os elementos mais utilizados (STASSI, 2013).

Embora existam outros tipos de sensores para mensurar forças, como sensores magnéticos, óticos e de ultrassom, não é factível sua utilização em baropodômetros devido aos custos de fabricação, custos computacionais e custos estruturais, além de características como histerese, alta sensibilidade eletromagnética e dependência da temperatura (STASSI, 2013).

2.2 MATRIZ DE SENSORES PIEZORESISTIVOS

Para o desenvolvimento de equipamentos de medição de forças em grandes áreas é inviável a utilização de sensores individuais, uma vez que elevariam o custo de produção dos equipamentos e apresentariam grandes desafios técnicos como a instalação de cada sensor, assim como a aquisição e interfaceamento dos sinais de cada um deles.


Desta forma foram introduzidas matrizes de sensores utilizando o funcionamento básico dos sensores piezoresistivos.

Existem basicamente dois tipos de distribuição de eletrodos para o desenvolvimento de matrizes de sensores.

A primeira é uma distribuição sobre uma das faces do material piezoresistivo, deixando os eletrodos próximos e em forma de pente, como mostrado na Figura 13a. Este tipo de eletrodo é conhecido como eletrodo de estrutura interdigital, sendo bastante utilizado em materiais com baixas espessuras como os polímeros de carbono, que possuem espessuras na ordem de $150\ \mu m$ (AHMAD; ANDERSSON; SIDÉN, 2017).

A segunda é uma distribuição mais tradicional, com contato superficial, na qual os eletrodos estão separados pelo material piezoresistivo (Figura 13b).


Figura 13 – Eletrodos para sensores piezoresistivos; (a) estrutura interdigital e, (b) estrutura superficial.



Fonte: Giovanelli e Farella (2016)

Em ambos os casos, os eletrodos são interconetados com outros eletrodos para formar linhas e colunas com trilhas condutivas comuns. Assim sendo, é possível distribuir e conectar os sensores matricialmente (Figura 14). São obtidas matrizes de $M \times N$ sensores, sendo M o número de linhas e N o número de colunas, reduzindo também o número de conexões de $2 \times M \times N$ para $M + N$. A resolução da matriz de sensores é limitada apenas pelo tamanho e espaçamento entre as trilhas condutivas, permitindo também atingir grandes áreas ativas (LIU *et al.*, 2010). No caso da Figura 14, com linhas e colunas condutivas assim como espaçamento entre linhas de 2,5 mm, é atingida uma densidade de 4 sensels/cm².

Figura 14 – Matriz de sensores piezoresistivos e sensel.



Fonte: Elaboração do próprio autor.

Uma vez que uma matriz de sensores é identificada comercialmente como um único sensor, então define-se cada nó individual dentro da matriz como um **Sensel** (Figura 14) (PAPAKOSTAS; LIMA; LOWE, 2002).

Tradicionalmente as matrizes de sensores piezoresistivos são feitas com folhas de carbono. No entanto, nos últimos anos numerosas pesquisas têm desenvolvido compósitos piezoresistivos, cujas características elétricas dependem dos materiais com que são feitos e do tipo de fabricação. Inicialmente, pode-se pensar em compósitos piezoresistivos como materiais poliméricos misturados com partículas condutivas como nanotubos de carbono, níquel, cobre, ouro, entre outras, que, ao serem submetidos a forças externas, modificam a distribuição das partículas condutivas dentro do polímero, permitindo uma maior ou menor resistência elétrica dependendo do caso (STASSI *et al.*, 2014; ZHAI *et al.*, 2015; DING *et al.*, 2017).

Embora estes compósitos sejam principalmente desenvolvidos em pesquisas de medição de pequenas forças em grandes áreas, como em sensores têxteis, foram encontradas na literatura algumas pesquisas que visam a utilização deste tipo de sensores na medição de forças na região plantar, como a apresentada por Tan *et al.* (2015), baseada em um material de carbono como elemento piezoresistivo e por Stassi *et al.* (2013), baseado na mistura do bi-componente polydimethylsiloxane (PDMS) e pó de cobre eletrolítico dendrítico (Cu) obtendo o material PDMS-Cu.

O compósito bi-componente PDMS Sylgard 184 da Dow Corning, junto com o pó de cobre eletrolítico dendrítico fornecido pela empresa Brutt - Indústria Metalúrgica, já foi explorado e avaliado, constatando-se que ele apresenta problemas de repetibilidade e sensibilidade na sua resposta piezoresistiva. Além disso, problemas mecânicos impossibilitam a reprodução de matrizes de grande área como as necessárias para o desenvolvimento de um baropodômetro fixo.


2.2.1 Crosstalk

Conforme mencionado, a leitura de cada sensel dentro da matriz é realizada selecionando a coordenada linha-coluna correspondente. Em termos gerais a matriz de sensores piezoresistivos pode ser representada eletricamente como mostrado na Figura 15a, na qual o sensel é representado como um resistor no meio de uma linha e uma coluna condutiva. Neste caso o sensel selecionado é o R22, sendo que foi selecionada a linha 2 junto com

a coluna 2. Geralmente são utilizados multiplexadores e demultiplexadores analógicos para selecionar e ler cada sensel, deixando as linhas e colunas não selecionadas em alta impedância.

O sensel selecionado é normalmente conhecido como elemento sendo testado ou *element being tested* (*EBT*), enquanto os elementos não escaneados ou *non-scanned elements* (*NSE*) são todos os R_{ij} diferentes de *EBT* ($R_{ij} \neq EBT$).

Figura 15 – Matriz de sensores resistiva; (a) representação elétrica e seleção do EBT, (b) efeito crosstalk




Fonte: Giovanelli e Farella (2016)

No entanto, as matrizes de sensores piezoresistivos têm um problema associado com correntes parasitas que fluem pelo circuito sem controle. Este tipo de comportamento indesejado é conhecido como ***crosstalk***. Na Figura 15b são simbolizadas as correntes parasitas do circuito ao selecionar o sensel R22, sendo que as linhas e colunas não selecionadas estão em alta impedância. As correntes parasitas fluindo pelo circuito através dos elementos não escaneados incrementam o erro de leitura do *EBT*.

Na Figura 16 mostra-se o erro relativo de leitura do EBT ao variar todos os sensels de uma matriz resistiva na faixa 1-100 kΩ, com $M=N=4$ (16 sensels) e considerando o estado de alta impedância em linhas e colunas não selecionadas. O circuito foi implementado em ambiente PSpice. Como observado, o erro de leitura atinge o valor máximo (921%) quando o EBT está em alta impedância (100 kΩ) e os NSE têm impedância baixa (1 kΩ). Uma

representação visual desta última condição seria pressionar a matriz toda com máxima pressão, enquanto um único sensel é deixado livre de pressão, gerando os elevados erros por crosstalk mencionados.

Figura 16 – Erro de leitura do EBT variando EBT e NSE na faixa 1-100 k Ω com M=N=4.



Fonte: Elaboração do próprio autor.

É importante salientar que quanto maior o número de linhas e colunas na matriz, maiores serão os efeitos de crosstalk.

2.3 CARACTERÍSTICAS DOS BAROPODÔMETROS

Atualmente existem numerosas empresas que desenvolvem e comercializam baropodômetros. Academicamente, numerosos equipamentos têm sido desenvolvidos visando a medição de pressões plantares tanto em avaliações estáticas quanto dinâmicas. Para estabelecer uma referência, Ramirez-Bautista *et al.* (2017) relataram 12 equipamentos comerciais e 58 equipamentos acadêmicos somente do tipo *in-shoe*, dos quais 41 são baseados em sensores resistivos ou piezoresistivos (66,67%).

Embora sejam muitos os equipamentos desenvolvidos nesta área, infelizmente não existe um padrão internacional que permita estabelecer os parâmetros mínimos que cada equipamento deve atingir. Giacomozzi *et al.* (2012), por meio do *Group of the International Foot and Ankle Biomechanics Community (i-FAB-PG)* promoveram uma

pesquisa visando estabelecer um consenso sobre as principais características técnicas que devem ser atingidas pelos equipamentos baropodométricos para avaliações dinâmicas e seus respectivos equipamentos de calibração. A seguir, menciona-se as características que foram mais consensuais:

- Os equipamentos baropodométricos devem ser caracterizados e testados com equipamentos que permitam exercer forças controladas e uniformes tanto em áreas locais como na área ativa completa do equipamento.
- Para equipamentos com áreas ativas $\leq 0,25 \text{ m}^2$ pelo menos 5 áreas aleatórias devem ser testadas conferindo acurácia e precisão;
- Área ativa de pelo menos 0,4 m X 0,6 m;
- Pressões máximas de 1,5 MPa;
- Resolução espacial de 5 mm;
- Frequência de amostragem de 100 Hz;
- Acurácia na medição de força e/ou pressão $< 5\%$;
- Histerese $< 5\%$;
- Efeito creep $< 5 \text{ kPa/s}$ para avaliações dinâmicas e $< 0,15 \text{ kPa/s}$ para avaliações estáticas;
- Precisão na medição do centro de pressão $< 2 \text{ mm}$ em cada eixo;
- Crosstalk $< 5\%$.

Foi consensual a necessidade da elevada frequência de amostragem (100 Hz) porque a pesquisa foi focada em equipamentos para avaliações dinâmicas. Considera-se 100 Hz uma elevada frequência de amostragem, porque em cada leitura da matriz, é necessário ler o total de sensels que a compõem, resultando em um desafio e esforço significativo em processamento e transmissão de dados.

O tamanho da área ativa foi devido principalmente à distância entre os passos dos voluntários. Em termos de área ativa os equipamentos comerciais não atingem este requerimento, sendo que a maioria oferecem áreas próximas a $0,14 \text{ m}^2$ (380 mm x 380 mm). Para avaliações estáticas os requerimentos mínimos são diferentes.

Em relação à frequência de amostragem, a maioria dos equipamentos comerciais oferecem frequências de amostragem na faixa 50-100 Hz. É importante que os equipamentos baropodométricos tenham frequências de amostragem elevadas, uma vez que mesmo não considerando a necessidade de avaliações dinâmicas, altas frequências de amostragem

são desejáveis porque possibilitam coletar dados relacionados ao COP. Contudo, Vieira, Oliveira e Nadal (2009) mostraram que para avaliações estáticas são necessárias frequências de amostragem maiores que 5 Hz, uma vez que o maior conteúdo de informação nas análises de estabilometria estão na faixa de 0-2 Hz. Igualmente Ruhe, Fejer e Walker (2010) e Scoppa *et al.* (2013) estabeleceram que as componentes principais de frequência em análise de estabilometria estão na faixa 0,01-10 Hz.

Assim, pesquisas envolvendo avaliações de estabilometria geralmente são feitas com frequências de amostragem de no mínimo 20 Hz e aplicando filtros passa-baixas com frequências de corte na faixa 5-10 Hz (FREITAS *et al.*, 2005; PINHEIRO; VILAÇA; CARVALHO, 2014; NAGYMÁTE; ORLOVITS; KISS, 2018).

Por outro lado, a característica de máxima pressão (1500 kPa), sugerida pelos autores, é questionável, uma vez que pesquisas têm mostrado que pressões máximas na região plantar estão na faixa de 100-350 kPa quando realizados testes estáticos (BRYANT; TINLEY; SINGER, 2000; LALANDE *et al.*, 2016). Equipamentos comerciais como o Go-tec da SPI (2018) e o MobilMat da TekScan (2018) suportam pressões máximas de 200 kPa e 350 kPa, respectivamente. No caso de avaliações dinâmicas, pesquisas têm mostrado que picos de pressão superiores a 700 kPa são raramente encontrados (XU *et al.*, 2017; FANG, 2018).

Assim, um baropodômetro para avaliações estáticas precisa ter uma área ativa próxima a $0,15\text{ m}^2$, frequência de amostragem mínima de 20 Hz e suportar pressões máximas de até 300 kPa.

2.4 BAROPODÔMETRO LIEBSCAN


No Laboratório de Instrumentação e Engenharia Biomédica (LIEB) têm sido desenvolvidos baropodômetros objetivando atender necessidades de clínicas e hospitais brasileiros

Freitas (2008) desenvolveu um baropodômetro com 48 células de carga e seus respectivos extensômetros. O circuito precisava de alimentação externa e possuía comunicação serial com taxa de transmissão de 38.400 bps, possibilitando uma frequência de amostragem de 2 Hz.

Posteriormente Urban (2015) implementou um baropodômetro com 120 sensores de tipo *force sensing resistive* - *FSR* (Figura 17). Neste equipamento o circuito é do tipo *plug-and-play*, sendo a alimentação fornecida diretamente do barramento USB, que

também permite comunicação serial com taxa de transmissão de 1,2 Mbps, possibilitando uma frequência de amostragem de 20 Hz. Aproveitando a frequência de amostragem de 20 Hz é possível realizar avaliações de estabilometria com este equipamento.

Figura 17 – Baropodômetro LIEB V2.0 contruído com sensores FSR.




Fonte: Urban (2015)

O Baropodômetro LIEB V2.0 mostrou ser prático, robusto e principalmente útil para os objetivos propostos nas pesquisas associadas; porém, as suas características técnicas ainda estão distanciadas das características de equipamentos comerciais, especificamente em relação à densidade de sensores por unidade de área.


2.4.1 Sensor

Visando o aprimoramento contínuo e a evolução da linha de pesquisa, foi desenvolvido um novo baropodômetro utilizando uma matriz de sensores piezoresistivos. Foi adquirida a matriz de sensores FSR MS9705 da Kitronyx (2018) (Figura 18).

Figura 18 – Matriz de sensores piezoresistivos FSR-MS9705.



(a)



(b)

Fonte: Kitronyx (2018).

A matriz dispõe de 2304 sensels interligados por 48 linhas e 48 colunas, em uma área ativa de aproximadamente $0,15 \text{ m}^2$. Segundo informações do fabricante, cada sensel suporta pressões máximas de até 400 kPa. Com um peso de 177 g e espessura de 1 mm, a matriz de sensores atinge os requerimentos básicos estabelecidos para avaliações baropodométricas estáticas, como comentado na Seção 2.3.

Cada sensel é identificado dentro da matriz pela quadricula sobre o sensor (Figura 18a). Cada sensel possui área de 64 mm^2 (8 mm x 8 mm). Os eletrodos em cada sensel são do tipo estrutura interdigital (Figura 13a) e estão localizados na parte inferior da matriz. Os conectores da matriz são do tipo flex com espaçamento de 1 mm e fabricados em materiais plásticos (Figura 18b), o qual faz com que sejam conectores extremamente frágeis, sendo necessário prestar especial atenção no manuseio deles.

Da mesma forma que os sensores individuais FSR, a matriz MS9705 precisa ser calibrada e caracterizada. Embora seja uma matriz comercial, não foram encontrados trabalhos acadêmicos onde a matriz tenha sido caracterizada e avaliada.

Conforme mencionado neste trabalho, as matrizes de sensores piezoresistivas sofrem do efeito crosstalk. Assim, é necessário selecionar e dimensionar um circuito que possibilite a leitura dos sensels, diminua as correntes parasitas, e que seja implementável segundo o projeto e rendimento.

2.4.2 Circuito de Crosstalk


Ao longo dos anos vários circuitos, com diferentes características, têm sido desenvolvidos visando reduzir o efeito crosstalk em matrizes de sensores resistivos ou piezoresistivos. No entanto, os circuitos geralmente estão divididos em duas categorias, segundo suas características, sendo uma delas por diferença de potencial zero (*zero potential-ZP*) e outra por tensão de realimentação (*voltage feedback-VF*) (WU, 2017). Em ambas é objetivado estabelecer a mesma diferença de potencial entre os terminais condutores de cada sensel não selecionado e assim eliminar as correntes parasitas.

Visando a utilização de circuitos para o controle de correntes indesejadas em matrizes piezoresistivas de grandes áreas, foram avaliados e comparados cinco circuitos referenciados por Wu (2017). Os circuitos foram simulados em ambiente PSpice.

O Circuito A, proposto por D'Alessio (1999), é do tipo ZP, baseado em aterramento. Neste circuito, é conectado um amplificador operacional (op-amp) a cada coluna do circuito e um op-amp de transresistência em cada linha (Figura 19). Assim, obriga-se uma diferença de potencial zero entre os elementos não escaneados da matriz ($ZP - NSE$), diminuindo o efeito crosstalk.

O Circuito B, proposto por Saxena, Bhan e Aggrawal (2009), é um circuito ZP com apenas um op-amp para a matriz inteira (MxN). Neste caso, o EBT é conectado

Figura 19 – Circuito A, baseado em aterramento (ZP).




Fonte: D'Alessio (1999)

entre a saída e a entrada inversora do amplificador, enquanto a entrada não inversora é aterrada. Os NSE da coluna selecionada ($N-1$) são conectados entre a entrada inversora e a referência terra. Os NSE da linha selecionada ($M-1$) são conectados entre a saída do amplificador e a referência terra. Os NSE restantes $(M-1) \times (N-1)$ têm diferença de potencial zero. Para definir o ganho do circuito foi estabelecido um resistor R_L entre a entrada de tensão e a entrada inversora do op-amp (Figura 20).

O Circuito C, proposto por Wu, Wang e Li (2014), é do tipo VF com apenas um op-amp (Figura 21). Neste circuito, os NSE das linhas e colunas não selecionadas têm a mesma diferença de potencial, que é fornecida pela tensão de realimentação imposta pela tensão de saída do sistema ($VF - NSE$). Neste caso os NSE da linha e coluna selecionada influenciam a leitura do EBT, apresentando efeito crosstalk.


Por esta razão, o Circuito D proposto por Wu, Wang e Li (2015), é considerado um sistema aprimorado do Circuito C, no qual, por meio de uma configuração especial do VF, o erro causado pelos NSE da coluna selecionada é reduzido (Figura 22). Entretanto, os NSE da linha selecionada ainda influenciam a leitura do EBT.

Figura 20 – Circuito B, com retroalimentação baseada em aterramento.




Fonte: Saxena, Bhan e Aggrawal (2009)

Figura 21 – Circuito C, com tensão de retroalimentação nos NSE.



Fonte: Wu, Wang e Li (2014)

Figura 22 – Circuito D, com tensão de retroalimentação nos NSE.




Fonte: Wu, Wang e Li (2015)

Por fim, o Circuito E proposto por Wu *et al.* (2016) é um circuito ZP que aprimora o circuito proposto por Liu *et al.* (2010). Dois op-amp são utilizados para garantir a mesma diferença de potencial zero entre todos os NSE da matriz (Figura 23).


Para garantir uma comparação objetiva, foram simulados os circuitos supracitados com as seguintes condições: matrizes de $M=N=4$; tensões de saída na faixa $\pm 5-0$ V; tensões de entrada $V_i = 5$ V; como sugerido por Kim, Kwon e Choi (2016), as impedâncias de condução em *switches*, multiplexadores e demultiplexadores foram estabelecidas em $R_{SW} = 10 \Omega$; utilizaram-se amplificadores de propósito geral LM741 com tensões de alimentação ± 12 V; e configuraram-se as impedâncias associadas a cada circuito como segue - Circuito A: $R_r = 1 \text{ k}\Omega$; Circuito B: $R_L = 120 \text{ k}\Omega$; Circuito C: $R_S = 10 \text{ k}\Omega$; Circuito D: $R_S = 10 \text{ k}\Omega$; e Circuito E: $R_{CG} = 50 \Omega$, $R_L = 1 \text{ k}\Omega$.

Na Figura 24 são mostradas as tensões de saída de cada circuito fazendo uma varredura no EBT e mantendo os NSE da matriz em alta impedância, $R_{ij} = 100 \text{ k}\Omega$. As tensões de saída dos Circuitos A e E são similares, com alta sensibilidade quando o EBT está na faixa 1-5 $\text{k}\Omega$ com 0,9500 V/ $\text{k}\Omega$ e baixa sensibilidade na faixa 20-100 $\text{k}\Omega$ com apenas 0,0023 V/ $\text{k}\Omega$. Neste sentido, os Circuitos A e E são desconsiderados para

Figura 23 – Circuito E, com tensão de retroalimentação nos NSE e ZP.

Fonte: Wu *et al.* (2016)

uma aplicação prática, uma vez que matrizes piezoresistivas têm impedâncias com faixas bastante abrangentes (Ω - $M\Omega$).

Figura 24 – Tensões de saída, variando EBT na faixa 1-100 k Ω , $M=N=4$, e $NSE = 100$ k Ω .

Fonte: Elaboração do próprio autor.

Para determinar a eficiência do circuito ao reduzir o efeito crosstalk, foi avaliada a porcentagem de erro relativo sobre a tensão de leitura, como segue:

$$e\% = \left| \frac{V_{id} - V_{out}}{V_{id}} \right| * 100 \quad (2)$$

na qual V_{id} é a tensão ideal sem interferência por correntes parasitas, enquanto V_{out} é a tensão de saída obtida no ambiente PSpice.

As porcentagens de erros relativos nas leituras do EBT nos diferentes circuitos são apresentadas na Figura 25. Na Figura 25a são mostrados os erros por crosstalk quando os NSE variam na faixa 1-100 k Ω , enquanto o EBT está fixo em alta impedância. Igualmente, na Figura 25b são mostrados os erros quando os NSE e o EBT variam simultaneamente ($EBT = NSE$). Embora cada circuito apresente um comportamento único, todos eles têm uma característica em comum, sendo que quanto menor a impedância dos NSE, maior a porcentagem do erro relativo na leitura do EBT.

Analisando os erros médios de cada circuito (Figura 25), é possível estabelecer que o Circuito D tem o menor erro médio dentre os circuitos viáveis (0,24%), seguido pelo Circuito C com 0,29% e, finalmente, o Circuito B com 0,50%. Embora o Circuito A apresente o menor erro médio (0,08%), ele e o Circuito E foram desconsiderados devido a sua sensibilidade.


Assim, para análise e utilização em matrizes de sensores de grande área, foi selecionado o Circuito D, **Improved Isolated Drive Feedback Circuit (IIDFC)**.

Inicialmente, o circuito IIDFC associado a uma matriz de $M=N=60$ foi simulado com os parâmetros anteriormente mencionados, variando os NSE na faixa 1-100 k Ω e mantendo o EBT em alta impedância (100 k Ω). Em seguida, foi utilizado o modelo matemático (3) proposto por Wu, Wang e Li (2015), considerando que os NSE têm a mesma impedância (R_{ij}) e que todas as impedâncias de condução dos *switches* são iguais entre elas (R_{SW}).


$$V_{OUT} = \frac{R_S V_i}{R_S + 2R_{SW} + EBT \left(1 + (M-1) \frac{R_{SW}}{R_{ij}} \right)} \quad (3)$$

Quando feita a comparação entre os erros relativos relacionados ao efeito crosstalk do modelo matemático e do modelo em PSpice do circuito IIDFC, estabeleceu-se que o modelo (3) não representa o comportamento real do circuito e que o efeito por crosstalk é

Figura 25 – Porcentagem de erros relativos, (a) com $EBT = 100 \text{ k}\Omega$ e variando NSE, (b) Variando simultaneamente $EBT = NSE$. Variações de impedância na faixa de 1-100 $\text{k}\Omega$.



(a)




(b)

Fonte: Elaboração do próprio autor.

muito maior do que relatado por Wu, Wang e Li (2015), vide Figura 26. Estes modelos não consideram as correntes por curto circuito no op-amp.

Figura 26 – Erros relativos na leitura do EBT, variando NSE de 1 k Ω a 100 k Ω e EBT = 100 k Ω , com M=N=60.




Fonte: Elaboração do próprio autor.

Devido à diferença entre os modelos matemático e simulado, foi feita uma análise detalhada das características do circuito IIDFC, apresentado na Figura 27. Como descrito anteriormente, o circuito é do tipo VF onde a tensão de realimentação é dada pela tensão de saída do op-amp, que é praticamente a mesma tensão de leitura do EBT. A tensão de realimentação é imposta nas linhas e colunas dos NSE da matriz.

O modelo (3) considera apenas os elementos não escaneados sobre a linha selecionada para ler o EBT. Ao invés disso, foi realizado uma análise nodal sobre o IIDFC, obtendo um modelo matemático alternativo ao proposto originalmente por Wu, Wang e Li (2015), permitindo avaliar características não relatadas sobre o circuito.

Na Figura 27 é possível identificar os nós principais: nó da coluna selecionada (CC), nó da linha selecionada (RC), nó da linha não selecionada (RNC), e nó da coluna não selecionada (NCC). Considerando que todos os NSE da matriz têm a mesma impedância R_{ij} (análise pessimista), e que os nós das colunas não selecionadas têm a mesma diferença de potencial entre eles, igual aos nós das linhas não selecionadas, é possível obter um

Figura 27 – Improved isolated drive feedback circuit - IIDFC

Fonte: Castro *et al.* (2018)

sistema linear de equações representado em (4). Neste caso utilizou-se o modelo ideal do amplificador operacional.

$$V_i = \left(1 + \frac{R_{SW}}{EBT} + (M-1)\frac{R_{SW}}{R_{ij}}\right) V_{CC} - \left(\frac{R_{SW}}{EBT}\right) V_{RC} - \left((M-1)\frac{R_{SW}}{R_{ij}}\right) V_{RNC}$$

$$0 = V_{CC} - \left(1 + \frac{EBT}{R_S + R_{SW}} + (N-1)\frac{EBT}{R_{ij}}\right) V_{RC} + \left((N-1)\frac{EBT}{R_{ij}}\right) V_{CNC}$$

$$0 = V_{CC} + \left(\frac{R_{ij}}{R_{SW}}\right) V_{RC} - \left(\frac{R_{ij}}{R_{SW}} + N\right) V_{RNC} + (N-1)V_{CNC}$$

$$0 = \left(1 + \frac{R_{ij}}{R_{SW}}\right) V_{RC} + (M-1)V_{RNC} - \left(\frac{R_{ij}}{R_{SW}} + M\right) V_{CNC}$$

(4)

Solucionando o sistema de equações (4), obtêm-se a tensão de saída V_{OUT} em função da tensão no nó da linha selecionada (RC) como segue:

$$V_{OUT} = V_{RC} \left(\frac{R_S}{R_S + R_{SW}} \right) \quad (5)$$

Para obter a porcentagem de erro relativo descrita em (2), considera-se a tensão de saída ideal como aquela que não é influenciada pelos NSE na matriz, descrita em (6). Foram adicionadas as impedâncias de condução em switches (R_{SW}).


$$V_{id} = V_i \left(\frac{R_S}{R_S + 2R_{SW} + EBT} \right) \quad (6)$$

Para conferir o modelo proposto e a efetividade do circuito de crosstalk, foi implementado um protótipo do circuito IIDFC em uma matriz resistiva de $M=N=4$ com os seguintes parâmetros: NSE na faixa 1-100 k Ω ; $V_i = 5,13$ V; impedâncias de condução em switches $R_{SW} = 10,34$ Ω ; $R_S = 9,96$ k Ω ; e $EBT = 100,32$ k Ω . Todos os valores foram obtidos com o multímetro digital Keysight 34405A de 5 1/2 Dígitos. O circuito foi implementado com o op-amp de propósito geral LM741 e tensões de alimentação ± 12 V. Igualmente, o circuito IIDFC foi simulado com os parâmetros mencionados em ambiente PSpice e comparados com a resposta do modelo aqui proposto e o modelo proposto por Wu, Wang e Li (2015) (Figura 28).

A resposta do circuito IIDFC em ambiente PSpice com o op-amp LM741 obteve um erro médio de 0,27% enquanto o modelo proposto em (3) teve um erro médio de 0,13%. O modelo aqui proposto em (4) obteve o menor erro com 0,11% sendo este modelo o de maior acurácia. Entretanto, o protótipo do circuito implementado apresentou um erro médio de 1,31%. A magnitude do erro no circuito implementado pode estar associada à qualidade dos elementos utilizados e às características próprias do amplificador. Contudo, como mostrado na Figura 28, os modelos apresentaram o mesmo comportamento exceto o modelo proposto por Wu, Wang e Li (2015) que não mostrou o ponto de inflexão perto da impedância de 1,5 k Ω .

Assim, foi determinada a existência de uma impedância mínima, que deve evitar a matriz piezoresistiva, para garantir um erro reduzido por crosstalk. A impedância mínima varia segundo as características do circuito, principalmente do tamanho da matriz (M e N), e também a faixa de resposta dela. No caso do circuito implementado, a impedância mínima mostrou-se próxima de 1300 Ω , enquanto que no modelo proposto e circuitos simulados

Figura 28 – Comparação de erros relativos de leitura do EBT nos modelos do circuito IIDFC e identificação da impedância mínima



Fonte: Elaboração do próprio autor.

está em torno de 1700 Ω (Figura 28). Caso a matriz apresente impedâncias inferiores à impedância mínima recomendada, o erro por crosstalk aumentará drasticamente.

Além da característica de impedância mínima, em Castro *et al.* (2018) podem ser encontrados dados adicionais do circuito como limitações de corrente devido ao op-amp e rendimento em função do tamanho da matriz.


2.4.3 Hardware do LiebScan System

Conforme mencionado, foi adquirida a matriz piezoresistiva MS9705 e para diminuir o problema associado ao efeito crosstalk foi selecionado o circuito IIDFC.

O circuito precisa de switches analógicos ao invés de multiplexadores e demultiplexadores para seu correto funcionamento. Utilizou-se o switch analógico TS5A623157DGSR para as conexões de linhas e colunas, com uma impedância de condução $R_{sw} = 10 \Omega$. Os switches analógicos são controlados por registros de deslocamento SN74AHC594DR. Pelas características próprias dos registros de deslocamento, foi possível implementar circuitos

em placas modulares que permitissem ampliar ou diminuir o número de sensores segundo a matriz piezoresistiva associada, vide Figura 29. Cada placa modular permite interconectar 8 linhas e 8 colunas, sendo necessárias 6 placas modulares para atingir os 2304 sensels da matriz piezoresistiva ($M=N=48$). É importante salientar que os circuitos modulares possibilitam reconfigurar os circuitos de controle (op-amp, impedâncias associadas, conversores, etc.), sendo possível realizar comparações entre diversos circuitos anti-crosstalk em matrizes de sensores com grandes áreas ativas, que como visto na literatura, não têm sido feitas.

Figura 29 – Placa modular para leitura de matrizes piezoresistivas.




Fonte: Elaboração do próprio autor.

Utilizou-se o amplificador operacional de baixa potência OPA837 ($I_s=570 \mu A$ - $V_S=3 V$), CMRR 105 dB, corrente de saída de 55 mA e largura de banda de 105 MHz. Os resistores R_s associados ao circuito possuem resistência elétrica de $3,4 k\Omega$.

Para fazer a leitura, controle e interfaceamento de dados, selecionou-se o Núcleo STM32H743-ZI da STMicroelectronics (2018) (Figura 30). O núcleo dispõe de um microcontrolador ARM Cortex-M7 de 32 bits, interfaces de comunicação Ethernet, USB, USART/UART e SPI, além de conversores ADC de 8 até 16 bits, com até 4 MSPS. O núcleo oferece todas as características necessárias para implementar um baropodômetro com 2304 sensels.

Selecionou-se uma comunicação USART para o interfaceamento de dados entre o baropodômetro e o computador. Embora o núcleo STM32H743ZI permita realizar comunicações USART de até 20 Mbps, existe uma limitação na taxa de transmissão por parte da porta USB dos computadores, limitando seu uso a apenas 2,2 Mbps. No entanto,

Figura 30 – Núcleo STM32H743-ZI.



Fonte: STMicroelectronics (2018)

com taxa de transmissão de 2,2 Mbps é possível atingir frequências de amostragem de 40 Hz, configurando o ADC em 8 bits.


Uma vez que a comunicação é feita através da porta USB, utiliza-se a mesma como fonte de energia para o circuito. O circuito precisa de 240 mA para seu funcionamento, de forma que não envolve risco para o computador. Assim sendo, o equipamento é considerado do tipo *plug and play*, uma vez que não precisa de fonte de alimentação externa. Isto também reduz ainda mais o risco de choque elétrico para os usuários do equipamento.

Utilizou-se acrílico para construir a base e obter o acabamento desejado no equipamento, tal como mostrado na Figura 31. O equipamento possui 550 mm de comprimento, 650 mm de largura, 30 mm de altura e massa total de 6,5 kg, constituindo-se em um equipamento portátil e robusto.


Desde que o equipamento desenvolvido será utilizado em condições de avaliações estáticas com pressões máximas de até 300 kPa, limita-se seu uso para usuários com massa corporal de até 120 kg. Isto considerando um descarregamento simétrico entre os pés e com 50% de descarregamento na região de cada retropé numa área de $10,24 \text{ cm}^2$.

Para um descarregamento mais homogêneo das forças sobre os sensores, e seguindo as recomendações do fabricante da matriz de sensores, utiliza-se um lençol de borracha atóxica, com espessura de 1 mm, sobre a área ativa do equipamento. A borracha foi coberta com vinil para facilitar o processo de limpeza do equipamento (Figura 31b).

Figura 31 – Baropodômetro LiebScan.



(a)



(b)

Fonte: Elaboração do próprio autor.


2.4.4 Software do LiebScan System

Para aquisição, processamento, visualização, e gerenciamento de dados do LiebScan, foi aprimorado o aplicativo desenvolvido por Castro (2016) para o Baropodômetro LIEB V2.0 em ambiente LabVIEW 2017®.

O aplicativo *LiebScan System* tem um módulo de aquisição de dados e dois modos de visualização. Para iniciar seu trabalho com o módulo de aquisição de dados, o avaliador deve preencher uma ficha de cadastro com os dados biométricos do paciente/voluntário: nome, idade (anos), sexo (masculino ou feminino), lateralidade (destro ou canhoto), massa corporal (kg), altura (cm) e observações gerais. Os dados registrados na ficha de cadastro são os dados básicos coletados pelo avaliador quando feita a anamnese do paciente/voluntário.

No módulo de aquisição são apresentadas ao avaliador as distribuições de pressões sobre o equipamento em “tempo real” por meio de gráficos em 3D e em kPa (Figura 32). Também é apresentado para o avaliador o descarregamento de forças no lado direito e esquerdo da plataforma, visando identificar possíveis desequilíbrios na postura do sujeito avaliado.

Figura 32 – Módulo de aquisição de dados LiebScan System



Fonte: Elaboração do próprio autor.

O sistema foi desenvolvido para realizar avaliações estáticas com *Olhos Abertos* (OA) e *Olhos Fechados* (OF). O avaliador controla o tipo de teste a ser realizado sempre

que não ultrapasse o tempo máximo de leitura. O sistema permite armazenar até 3600 amostras em cada teste OA e OF. Assim, caso seja selecionada a frequência máxima de amostragem do sistema de 40 Hz, o sistema permite coletar 90 s em cada teste para um total de 180 s (3 min).

Cada amostra contém os dados dos 2304 sensels; assim, no caso do teste de 180 s com frequência de 40 Hz, serão armazenados 8.294.400 dados de sensels em cada teste (OA e OF). Por esta razão é necessário um computador com alguns requerimentos mínimos de rendimento. O desenvolvimento e testes do aplicativo foram realizados em um computador com processador Intel Core i5-6200U (Sexta Geração), RAM de 8 GB, Windows 10 de 64 bits, e HD de estado sólido de 512 GB.


Como explicado, cada amostra contém os dados dos 2304 sensels. Para coletar cada amostra, o aplicativo, juntamente com o núcleo STM32H743ZI, interagem com o diagrama de fluxo mostrado na Figura 33. O diagrama de fluxo só pode ser implementado quando utilizado o ADC de 8 bits, que possibilita comunicar ao computador a leitura de cada sensel como se fosse um carácter ASCII. Os equipamentos comerciais utilizam esta mesma técnica nos processos de aquisição de dados (LUO; BERGLUND; AN, 1998; NOVEL, 2008b).

Devido à quantidade de dados e velocidade de leitura de cada sensel é normal obter diferenças relativas entre as leituras dos diferentes sensels, fazendo necessário um filtro para suavizar sua apresentação em 3D. Neste caso e como proposto por Kalamdani, Messom e Siegel (2006), foi implementado um filtro Gaussiano com um kernel de 3x3 com $\sigma = 1$ como segue:

$$G = \begin{bmatrix} 0,0625 & 0,1250 & 0,0625 \\ 0,1250 & 0,2500 & 0,1250 \\ 0,0625 & 0,1250 & 0,0625 \end{bmatrix} \quad (7)$$

Uma vez armazenados os dados nos testes de OA e OF, o sistema possibilita visualizar e, se necessário, também exportar as variáveis de estabilometria de cada teste por meio das técnicas de Estatocinesigrama e Estabilograma (Figura 12).

Figura 33 – Fluxograma da aquisição e comunicação de dados dos 2304 sensels em cada amostra da matriz



Fonte: Elaboração do próprio autor.

3 MACHINE LEARNING


Como descrito por Ayodele (2010), o *machine learning* (ML), de uma forma simples de ser entendido, é um conjunto de algoritmos desenvolvidos para otimizar um processo ou sistema por meio de dados ou experiências passadas.

O ML pode ser dividido em dois grupos, conhecidos como aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, o objetivo do algoritmo é classificar ou aprender o padrão a partir de dados de entrada conhecidos junto com suas respectivas saídas. Já o aprendizado não supervisionado possui uma base de dados de entrada sem uma saída específica conhecida; o objetivo deste tipo de aprendizado é identificar padrões e agrupar os diferentes tipos de entrada segundo suas próprias características (BISHOP, 2006; DEO, 2015).

Uma vez que o objetivo é classificar escoliose segundo o grau de acometimento através de uma base de dados baropodométricos com saídas conhecidas, utilizam-se aprendizados de máquina supervisionados.

O objetivo do aprendizado supervisionado é desenvolver um classificador que consiga generalizar e classificar novas amostras baseado em dados e experiências passadas. O desenvolvimento deste classificador precisa de um processo e metodologia de implementação à procura das melhores características que permitam o maior rendimento. Na Figura 34 apresenta-se uma metodologia amplamente utilizada e descrita por Kotsiantis, Zaharakis e Pintelas (2007).

Figura 34 – Metodologia utilizada no aprendizado de máquina supervisionado.



Fonte: Adaptado de Kotsiantis, Zaharakis e Pintelas (2007).

3.1 PROCESSO DE APRENDIZADO DE MÁQUINA SUPERVISIONADO

De forma geral, na Figura 34 estabelece-se uma metodologia que serve para estruturar de forma correta o processo de aprendizado de máquina supervisionado. No entanto, esta metodologia não é rígida permitindo assim diferentes fluxos de operação entre os diferentes procedimentos. A seguir, é apresentada uma explicação sucinta de cada procedimento da metodologia proposta, considerando as informações fornecidas por Kotsiantis, Zaharakis e Pintelas (2007).

3.1.1 Problema

No aprendizado de máquina supervisionado é necessário ter um objetivo claro final que permita avaliar quantitativamente o rendimento do processo. Por exemplo, no caso do presente estudo, objetiva-se classificar voluntários com ou sem escoliose através de dados de baropodometria e, dependendo da quantidade de acertos, pode-se estabelecer o rendimento do processo. O rendimento pode ser calculado uma vez que os dados de saída são previamente conhecidos (DEO, 2015).

3.1.2 Coleta e Identificação de Dados

A coleta é um procedimento feito com antecedência e sob uma metodologia fixa que possibilite uma uniformidade nos dados a serem processados.

Os dados coletados formam a base de dados ou *dataset*, que está constituída por observações (cada teste em um voluntário é uma observação), e características (altura, idade, pressões, etc.). A identificação de dados é necessária em todo processo de aprendizado de máquina. Geralmente são utilizados todos os dados disponíveis na base de dados. No entanto, nem sempre todas as características de cada observação são necessárias, sendo preciso filtrar e separar apenas os dados que contribuem ao processo.

3.1.3 Pré-processamento de Dados

A etapa de pré-processamento de dados é talvez a etapa mais importante no processo de aprendizado de máquina. Nesta etapa os dados são processados de forma que seja possível identificar características irrelevantes, redundantes ou altamente dependentes entre elas. Entre os métodos mais utilizados no pré-processamento de dados estão: a normalização e padronização das características, filtragem, análises de componentes principal e transformações de dados, entre outras (BISHOP, 2006; SMOLINSKA *et al.*, 2014).

3.1.4 Divisão de Dados - Treinamento e Teste


Uma vez que o objetivo da técnica de aprendizado de máquina supervisionado é classificar dados desconhecidos em grupos conhecidos e definidos, utilizam-se dois grupos para treinar e avaliar o rendimento de um classificador.

Na literatura são utilizadas duas técnicas de divisão de dados, sendo a mais conhecida a divisão por *hold out method*, onde os dados são divididos unicamente em dois grupos. O primeiro grupo, chamado de grupo de treinamento ou *training set*, está constituído por uma maior porcentagem de observações da base de dados, geralmente na proporção de $2/3$ dos dados; e o segundo grupo, chamado de grupo de teste ou *testing set*, que possui o restante da base de dados ($1/3$). É recomendável utilizar esta técnica quando a base de dados é consideravelmente grande e assim desconsiderar a alta variabilidade da eficiência por conta da divisão dos grupos de treinamento e teste. Por outro lado, esta técnica de divisão de dados pode gerar *overfitting* que é um fenômeno altamente indesejado, no qual o modelo proposto tem um rendimento aceitável com os dados de treinamento, mas consideravelmente baixos com dados desconhecidos (BISHOP, 2006).

A outra técnica de divisão de dados é conhecida como validação cruzada ou *cross-validation*. Embora haja alguns tipos de validação cruzada, a mais utilizada é a *k-Fold Cross Validation*, na qual a base de dados é dividida em k subgrupos para fazer um *training set* com $k-1$ subgrupos e o *testing set* com o subgrupo restante (KOHAVI, 1995).

O processo é feito iterativamente até atingir todas as combinações de *training set* e *testing set* com os k subgrupos. Na Figura 35 é apresentado o processo de *cross-validation*, salientando que a acurácia total do treinamento é a média das acurácias obtidas em cada iteração do *k-Fold Cross Validation* (GIOVANINI, 2017).

Figura 35 – Procedimento de cross-validation.



Fonte: Adaptado de Giovanini (2017).

3.1.5 Algoritmos de Treinamento

Os algoritmos de treinamento são o núcleo do processo de aprendizado de máquina, pois são eles que impõem as características do processo inteiro. Os algoritmos de treinamento são classificados em grupos, dependendo sua funcionalidade e característica. De forma geral existem algoritmos lógicos e simbólicos, algoritmos baseados em perceptron e algoritmos baseados em estatística. Autores como Theodoridis e Koutroumbas (2009) classificam os algoritmos como lineares, não lineares e baseados na teoria de decisão de Bayes. No entanto, trata-se dos mesmos algoritmos de aprendizado.

Os algoritmos Lógicos e Simbólicos mais utilizados são as árvores de decisão ou *decision trees*, que são modelos que classificam dados baseados nas regras “se-então”, através de associação e peso de cada característica de cada observação na base de dados. Desta forma pode-se decompor cada observação como se fosse uma árvore fazendo com que cada nó seja uma característica e cada ramo os valores que pode ter cada característica. As características mais importantes segundo seu peso são situadas na raiz da árvore e as de menor peso em um outro nível inferior, e assim por diante até atingir todas as características (SILVA, 2005).

Os algoritmos baseados em *Perceptron* são os algoritmos mais populares principalmente porque são utilizados em Redes Neurais Artificiais (RNA). Embora o perceptron permita classificar dados linearmente separáveis, não é possível utilizá-lo para problemas não lineares; no entanto, um conjunto de perceptron configurados em camadas, permite

contornar o problema da linearidade oferecendo ao algoritmo uma alta versatilidade para sua aplicação nos mais variados problemas. Este tipo de topologia é conhecida como *Multi Layer Perceptron* (MLP), bastante utilizada na literatura.

Entre os algoritmos baseados em estatística destaca-se o algoritmo do vizinho mais próximo ou *k-Nearest Neighbour* (kNN). O algoritmo é baseado no princípio que dados com características similares podem ser agrupados. Desta forma, dados novos são avaliados e localizados em uma vizinhança onde os dados são próximos entre eles.

Um outro algoritmo bastante utilizado, porém não classificado entre as categorias tradicionais, é a máquina de vetores suporte ou *Support Vector Machine* (SVM). Basicamente o SVM muda a dimensão dos dados de entrada do algoritmo para gerar uma margem que possibilita separar duas classes de dados. Quanto maior a margem, menor o risco das classes a serem classificadas se misturarem entre elas.

De forma geral Kotsiantis, Zaharakis e Pintelas (2007) fizeram uma comparação entre os algoritmos mais utilizados em aprendizado de máquina supervisionado como apresentado na Tabela 2. Mesmo que o parâmetro mais relevante seja a acurácia e apresente melhores resultados com RNA e SVM, os autores destacam que nenhum algoritmo é superior ou melhor que outro, mas sob condições específicas, um método pode apresentar um rendimento consideravelmente maior que os outros.

3.1.6 Treinamento

Nesta fase é acionado o algoritmo de treinamento previamente configurado. Na maioria dos casos é um algoritmo iterativo que adapta seus parâmetros até que seja atingido um erro mínimo desejado ou um número de iterações máximas. Em aprendizado de máquina supervisionado tradicionalmente utiliza-se o *Mean Square Error* (MSE) que representa a média dos erros entre as saídas do algoritmo em treinamento e as saídas já conhecidas. Geralmente estabelece-se um erro mínimo a ser atingido e estabelece-se o ponto de parada do treinamento. No entanto, alguns algoritmos podem ter seus próprios critérios de parada.

Tabela 2 – Quadro comparativo de algoritmos de aprendizado de máquina supervisionado.

	Decision Trees	ANN	Naïve Bayes	kNN	SVM	Rule-learners
Acurácia em geral	**	***	*	**	****	**
Velocidade de aprendizado em relação ao número de atributos e o número de instâncias	***	*	****	****	*	**
Velocidade de classificação	****	****	****	*	****	****
Tolerância a valores ausentes	***	*	****	*	**	**
Tolerância a atributos irrelevantes	***	*	**	**	****	**
Tolerância a atributos redundantes	**	**	*	**	***	**
Tolerância a atributos altamente interdependentes (por exemplo, problemas de paridade)	**	***	*	*	***	**
Lidando com atributos discretos/binários/contínuos	****	*** (ND)	*** (NC)	*** (NDD)	** (ND)	*** (NDC)
Tolerância ao ruído	**	**	***	*	**	*
Lidar com o perigo de overfitting	**	*	***	***	**	**
Tentativas de aprendizado incremental	**	***	****	****	**	*
Capacidade de explicação/transparência do conhecimento/classificações	****	*	****	**	*	****
Manipulação de parâmetros do modelo	***	*	****	***	*	***

ND = Não Discreto. *NDD* = Não Diretamente Discreto.

NC = Não Contínuo. *NDC* = Não Diretamente Contínuo.

Fonte: Kotsiantis, Zaharakis e Pintelas (2007).

3.1.7 Teste

Como mencionado, a eficiência de um processo de aprendizado de máquina é mensurada pela capacidade de classificar dados desconhecidos em função de treinamentos feitos com dados conhecidos.

Em classificações binárias supervisionadas, como é o caso do presente estudo, para mensurar a capacidade de classificação, geralmente utiliza-se a medida de acurácia, definida como o número de acertos sobre o total de elementos a serem classificados. No entanto, em classes desequilibradas esta única medida pode ser enganosa. Por exemplo: supondo que um algoritmo tem que classificar 100 dados, dos quais 80% pertencem à classe A e

20% à classe B; se o algoritmo classifica todos os 100 dados dentro da classe A, ainda teria uma acurácia geral de 80%, mesmo que o classificador estivesse realizando função nenhuma.

Em bases de dados desequilibradas devem ser utilizados outros fatores de medição como os contidos na matriz de confusão, que é uma tabela onde são apresentadas as diferenças e comportamento do algoritmo ao classificar corretamente ou incorretamente os diferentes dados (BRADLEY, 1997). Na Figura 36 é apresentada uma matriz de confusão de uma classificação binária para um *testing set* desequilibrado de 100 dados, sendo que 60% correspondem à classe A, neste caso considerada a classe negativa, e 40% dos dados correspondem à classe B, considerada a classe positiva.

Figura 36 – Matriz de confusão em classificação binária, exemplo.

		Saída Desejada		
		0	1	
Saída Classificador	0	50 TN	5 FN	0 = Classe A 1 = Classe B
	1	10 FP	35 TP	
		60	40	

Fonte: Elaboração do próprio autor.

Na matriz de confusão os dados classificados são etiquetados segundo sua validade, isto é, dados corretamente e incorretamente classificados são etiquetados como segue:

- *True Positive - TP*: dado da classe positiva corretamente classificado.
- *True Negative - TN*: dado da classe negativa corretamente classificado.
- *False Positive - FP*: dado da classe negativa incorretamente classificado.
- *False Negative - FN*: dado da classe positiva incorretamente classificado.

Com os dados da matriz de confusão é possível estabelecer os seguintes parâmetros que permitem avaliar a eficiência do processo de aprendizado de máquina.

$$\text{Sensibilidade - SE} = \frac{TP}{TP + FN} * 100\% \quad (8)$$

$$\text{Especificidade - ESP} = \frac{TN}{TN + FP} * 100\% \quad (9)$$

$$\text{Seletividade - SEL} = \frac{TP}{TP + FP} * 100\% \quad (10)$$

$$\text{Acurácia - ACC} = \frac{TP + TN}{TP + TN + FP + FN} * 100\% \quad (11)$$

A sensibilidade é a capacidade do algoritmo de classificar corretamente dados da classe positiva. A especificidade mede a capacidade do algoritmo para classificar dados dentro da classe negativa. A seletividade quantifica a capacidade do classificador para rejeitar falsas detecções da classe positiva. Por sua vez e como dito anteriormente, a acurácia mede a eficiência do algoritmo ao classificar corretamente os diferentes dados (BEGG; KAMRUZZAMAN, 2006).

De forma geral pode-se estabelecer que quanto maior o valor de cada um dos parâmetros supracitados, melhor será o rendimento do algoritmo de aprendizado de máquina. Por esta razão foi definido o termo Valor Total dos Indicadores (VTI) como segue:

$$VTI = SE + ESP + SEL + ACC. \quad (12)$$

No caso do exemplo da Figura 36, a SE=87,50%; ESP=83,33%; SEL=77,78%; e ACC=85%, obtendo um VTI= 333,61%.

3.1.8 Sintonização do Classificador

O processo de aprendizado de máquina supervisionado tem características próprias que mudam com cada problema, o que faz dele um projeto único. Por esta razão não existe uma fórmula exata que garanta o sucesso do processo, obrigando sempre ao pesquisador a procurar soluções ótimas e específicas.

A procura destas soluções ótimas faz com que sejam necessárias numerosas iterações, mudando parâmetros próprios de cada algoritmo de treinamento (sintonização), ou modifi-

cando a divisão de dados de treinamento e teste, ou acrescentando/diminuindo métodos de pré-processamento de dados, e inclusive eliminando/mudando características ou observações da base de dados.

O objetivo da sintonização dos classificadores é encontrar os melhores hiperparâmetros ($\lambda^{(*)}$) que reduzam o erro de avaliação (ε) de um dataset (χ) em um algoritmo de treinamento (Υ), variando os próprios hiperparâmetros da função (λ) (Equação 13). Os hiperparâmetros a serem sintonizados são definidos pelo usuário e devem estar dentro de um conjunto finito de possibilidades (Λ) (BERGSTRA; BENGIO, 2012).

$$\lambda^{(*)} = \operatorname{argmin} \langle \varepsilon [\Upsilon_{\lambda}(\chi)] \rangle ; \lambda \in \Lambda \quad (13)$$

Existem diferentes métodos para sintonizar os parâmetros e hiperparâmetros de cada técnica de ML utilizada. Os mais utilizados são o método por *grid search*, no qual são avaliadas sistematicamente todas as possibilidades dentro do conjunto Λ (força bruta), requerendo grandes esforços computacionais dependendo principalmente do tamanho do conjunto. Por outro lado, um método comumente utilizado é o *random search*, no qual são selecionados dados aleatórios do conjunto Λ para encontrar a solução com melhor rendimento (BERGSTRA; BENGIO, 2012).

Métodos de otimização como algoritmos genéticos e heurísticas são empregados em processos de sintonização, sendo alguns deles considerados como aprimoramentos do método *random search* (LEUNG *et al.*, 2003; WALCZAK; CERPA, 1999).

Uma vez identificado um classificador com um rendimento desejado, tanto o algoritmo quanto seus hiperparâmetros (parâmetros próprios do algoritmo e da técnica de ML) devem ser salvos para poder classificar dados desconhecidos. É importante que os novos dados sejam submetidos aos mesmos processos de identificação e pré-processamento que os dados de treinamento e teste.

3.2 CLASSIFICADORES SUPERVISIONADOS UTILIZADOS

No aprendizado de máquina supervisionado (*supervised machine learning* – SML) existem numerosos algoritmos ou técnicas que permitem classificar dados segundo suas próprias características. No caso do presente estudo é importante lembrar que se objetiva a classificação de escoliose, utilizando dados baropodométricos, fazendo basicamente uma classificação binária na qual 0 é a classe negativa com ângulo de desvio lateral inferior a 10° , e 1 representa a classe positiva com ângulos de acometimento maiores ou iguais que 10° . O problema então é direcionado como um problema de reconhecimento de padrão.

Foram selecionados os classificadores por Redes Neurais Artificiais (RNA) e Máquina de Vetor Supporte (SVM). Para realizar o processo de SML utilizou-se o *Neural Network Toolbox 11.1* do Matlab 2018®.

3.2.1 Rede Neural Artificial - RNA

O classificador por RNA é um classificador baseado em perceptron que representa o modelo matemático de um neurônio inicialmente proposto por McCulloch e Pitts em 1943, logo aprimorado por Rosenbalt em 1962 e utilizado como algoritmo de aprendizado de máquina por Widrow e Lehr (1990) com a rede neural *Adaptative Linear Element - ADALINE* (BISHOP, 2006; HUDSON; COHEN, 2000).

A saída de uma rede neural baseada em um único perceptron, é uma combinação linear das características de entrada, filtrada por uma função de ativação que pode ou não ser uma função linear, vide Figura 37.

Como explicado anteriormente, o modelo ADALINE é uma combinação resultante do produto interno dos vetores de entrada

$$X_k = [X_{0k} + X_{1k} + X_{2k} + \dots + X_{nk}]^T \quad (14)$$


e do vetor de pesos associados a cada entrada

$$W = [W_0 + W_1 + W_2 + \dots + W_n]^T \quad (15)$$

obtendo a combinação linear resultante

$$S_k = \langle X_k, W \rangle \quad (16)$$

Figura 37 – Adaptive Linear Element - ADALINE.



Fonte: Adaptado de Widrow e Lehr (1990)


que logo depois é filtrada por uma função de ativação f_s . No entanto, para que o modelo descrito seja um modelo de aprendizado supervisionado, é necessário acrescentar a medição do erro entre a saída obtida e a saída desejada, para que, através de um algoritmo de treinamento, o vetor de pesos W seja adaptado, modificando a resposta de saída e diminuindo o erro. Ao fazer numerosas iterações o erro é diminuído, sendo que o algoritmo de treinamento pode deter o processo quando o erro atinge um nível desejado, ou quando atingido o número de iterações máximas (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007).

Dentro do SML existem fatores que podem ser configurados pelo pesquisador para obter variações na resposta do processo de aprendizado, como por exemplo, no caso específico da rede ADALINE da Figura 37 temos: a forma de medição de erro, o algoritmo utilizado para ajuste dos pesos, e a função de ativação f_s entre os mais importantes. Estes fatores são chamados de parâmetros da rede, e achar os valores adequados possibilita um melhor rendimento do processo de classificação. A procura sistemática dos parâmetros que ofereçam melhor rendimento é o procedimento de sintonização, discutido na seção anterior.

Pelas características básicas em funcionamento e desenvolvimento, a rede ADALINE só permite reconhecimento de padrões quando os dados são linearmente separáveis. Infelizmente, para processamentos mais complexos as redes ADALINE não são funcionais. Por este motivo foram desenvolvidas as redes *Multi ADALINE* - *MADALINE* ou também conhecidas como redes *Multilayer Perceptron* (MLP), tipicamente referenciadas na literatura.

tura como *Redes Neurais Artificiais*. Este tipo de rede consiste em múltiplas camadas com determinado número de neurônios (perceptrons) em cada uma delas (Figura 38).

Figura 38 – Multilayer Perceptron, topologia [n–5–2].



Fonte: Elaboração do próprio autor.

A camada de entrada possui tantos neurônios quantas características tenha o vetor de entrada. A camada de saída tem tantos neurônios quanto opções de saída definidas pelo usuário (HUDSON; COHEN, 2000).

No entanto, a camada intermediária, que conecta as camadas de entrada e saída, pode ter mais de uma camada oculta, e o número de neurônios é um dos desafios na utilização desta técnica de SML. Considerar um número reduzido de neurônios nesta camada pode levar a uma aproximação de baixo rendimento, enquanto um número excessivo de neurônios pode gerar o efeito indesejado de *overfitting* (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007).

É importante esclarecer e de forma informativa, que uma rede *multilayer perceptron* tipo *feedforward*, é uma rede neural com topologia baseada em perceptrons, com múltiplas camadas e com algoritmos de atualização de pesos baseados no erro entre as saídas obtidas e as saídas desejadas. Este tipo de rede, com este tipo de algoritmos de funcionamento, é comumente referenciada na literatura como *Rede Neural Back-Propagation*, sendo esta a rede neural implementada neste trabalho para classificação de escoliose.

O NNToolbox do Matlab 2018® possui a rede padrão *feedforwardnet* com algoritmo Back-Propagation que é uma rede de propósito geral. No entanto, alguns problemas têm requerimentos especiais, motivo pelo qual têm sido desenvolvidas algumas variações desta

rede como *patternnet*, *cascadeforwardnet* e *fitnet*. A rede *fitnet* é utilizada para operações de regressões lineares, sendo assim desconsiderada neste trabalho para classificação de escliose.

Por outro lado, as redes mencionadas anteriormente podem utilizar diferentes tipos de funções de treinamento. O NNToolbox disponibiliza um total de 13 funções de treinamento para SML (DEMUTH; BEALE; HAGAN, 1992). No entanto, são recomendadas para reconhecimento de padrão as seguintes funções (MATHWORKS, 2018):

- Resilient Backpropagation: *trainrbp*;
- Scaled Conjugate Gradient: *trainscg*;
- Conjugate Gradient with Powell/Beale Restartst: *traincgb*;
- Levenberg-Marquardt: *trainlm*.

A sintonização da RNA é necessária para qualquer processo de SML, uma vez que ao selecionar adequadamente os parâmetros de rede, é possível melhorar o desempenho desta. O NNToolbox possibilita além de configurar a topologia utilizada na RNA, também modificar parâmetros e hiperparâmetros próprios da rede incluindo os algoritmos de treinamento e as funções de ativação.

Neste trabalho, é utilizada a função *bayesopt* disponível no Matlab 2018, que é um método de otimização de bayes (caso especial de uma otimização não linear) que possibilita encontrar os melhores parâmetros e hiperparâmetros dentro de um conjunto de possibilidades segundo a função objetivo utilizada (MARTINEZ-CANTIN, 2014).


O processo de SML, utilizado na identificação e avaliação da RNA, é apresentado na Figura 39. A metodologia empregada para treinar, testar, e sistematicamente encontrar os parâmetros que possibilitem o melhor desempenho da rede é explicada a seguir:

- Identificação e pré-processamento de dados: Utilizaram-se os dados baropodométricos, biométricos e de estabilometria dos voluntários disponíveis na base de dados. Cada característica foi normalizada entre as diferentes observações na faixa $[-1,1]$. Igualmente, as características foram escalonadas para obter um valor médio 0 e desvio padrão 1. Posteriormente os dados foram submetidos a um análise de componente principal (PCA) para reduzir a dimensão da base de dados.
- Seleção do tipo de rede e função de treinamento: Utiliza-se o método de otimização de bayes para definir a rede e a função de treinamento com maior rendimento, variando

o número de camadas ocultas (H) e o número de dados do PCA. Os hiperparâmetros das funções de treinamento são configurados em *default*.

- Divisão dos dados para treinamento e teste por crossvalidation: Foi utilizado o método de k-Fold com $k=5$, para realizar a divisão dos dados e assim realizar uma validação cruzada. A estabilidade do rendimento da rede é quantificada ao fazer repetidamente o mesmo procedimento 5 vezes.
- Treinamento e teste: Cada *Fold* da validação cruzada foi treinado e testado 5 vezes, enquanto que cada procedimento destes foi feito 5 vezes para quantificar a estabilidade na resposta da rede. O desempenho das redes é avaliado em função da SE, ESP, SEL, e ACC (VTI) como apresentado nas equações (8)-(11).
- Identificação hiperparâmetros: Uma vez identificada a melhor combinação considerando tipo de rede, função de treinamento, topologia, e número de PCA, sintonizam-se os hiperparâmetros da rede e do algoritmo através da função bayesopt.
- Consolidação de resultados: verifica-se através de treinamento e teste com crossvalidation o desempenho final da RNA.

Figura 39 – Fluxograma do procedimento utilizado para selecionar e sintonizar a RNA.




Fonte: Elaboração do próprio autor.

3.2.2 Support Vector Machine - SVM

A máquina de vetor suporte é uma técnica de ML utilizada principalmente para realizar classificações de dados binários, isto é, classificar dados em duas classes.

Da mesma forma que as redes ADALINE, as SVM permitem classificar dados sempre que sejam linearmente separáveis entre eles. Se os dados de entrada são linearmente separáveis, é possível encontrar uma margem, que é uma faixa entre os dois lados de um hiperplano que separa as duas classes, vide Figura 40. A margem é definida pelos pontos mais próximos ao hiperplano, desta forma quanto mais separados os pontos do hiperplano maior será a margem e melhor o rendimento do algoritmo. Os pontos mais próximos ao hiperplano determinam o limite de margem e são chamados de vetores suporte, daí o nome da técnica SVM (ELIZONDO, 2006; KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007; REN, 2012).

Figura 40 – SVM linearmente separável.




Fonte: Adaptado de Ren (2012)

Contudo, este modo de classificação não é útil para dados não separáveis linearmente como os apresentados na Figura 41a com dimensão 2D. Neste caso, a SVM faz um mapeamento não linear para projetar os dados de um espaço não linearmente separável para um espaço linearmente separável. Isto é, a SVM faz uma transformação do espaço das características de entrada, levando-as para uma dimensão maior onde sejam linearmente separáveis. Como apresentado na Figura 41b, os dados não linearmente separáveis em 2D

são levados a uma dimensão 3D, para que através de um hiperplano, seja possível fazer a classificação binária.

Figura 41 – Classificação por SVM de dados não linearmente separáveis em 2D.



Fonte: Davidson e Waas (2018)

O kernel, que é a função de transformação, é o parâmetro mais importante a ser configurado em um SML utilizando SVM. Desta forma, selecionar e sintonizar o kernel junto com seus hiperparâmetros é similar à seleção e sintonização da topologia e algoritmos de treinamento em RNA (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007). Hsu *et al.* (2003) propõem uma metodologia similar à apresentada na Sub-Seção 3.2.1, onde, sistematicamente e através de iterações, determinam-se os parâmetros e hiperparâmetros que ofereçam o melhor desempenho à técnica de SML. Igualmente, os autores dão ênfase ao pré-processamento de dados, utilizando técnicas de normalização e padronização. Por outro lado, sugerem a utilização do kernel *Radial Basis Function* (RBF) como primeira opção de teste uma vez que esta função é, em si mesma, um aprimoramento de outras funções. Além disso, este kernel possui menos hiperparâmetros que as outras funções tornando mais viável sua sintonização.

Assim, para identificação e sintonização da SVM, além dos procedimentos de pré-processamento de dados realizados para as RNA, é necessário sintonizar o algoritmo mudando os seus hiperparâmetros, de forma sistemática, até atingir o melhor rendimento. Como no caso da RNA, é possível utilizar o método de otimização por bayes, a procura dos hiperparâmetros que maximizem o rendimento da técnica de ML. O rendimento é novamente avaliado em função da sensibilidade, especificidade, seletividade e acurácia.

3.3 BASE DE DADOS

Não existindo um banco de dados de livre acesso com avaliações baropodométricas em voluntários que apresentem escoliose, foi necessário implementar um protocolo de avaliação que permitisse obter tanto os dados de distribuições de força na região plantar, quanto dados de estabilometria, juntamente com dados biométricos de cada voluntário.

3.3.1 *Protocolo de Avaliação e Coleta de Dados*

Devido ao tempo de desenvolvimento e caracterização do LiebScan System e, considerando também o tempo de coleta de dados com dito sistema, neste trabalho foram avaliados e utilizados os dados baropodométricos coletados com o Baropodômetro LIEB V2.0 (Figura 17).

A coleta de dados e avaliação de voluntários teve autorização do Comitê de Ética em Pesquisa da Faculdade de Ciências e Tecnologia da UNESP, Câmpus de Presidente Prudente sob protocolo CAAE: 59693616.9.1001.5402, de 2017.

Todos os participantes foram informados sobre aos objetivos e procedimentos executados no experimento através da leitura de um texto informativo. Todos os voluntários assinaram um Termo de Consentimento Livre e Esclarecido (TCLE), autorizando o uso de seus dados para a presente pesquisa. Os voluntários menores de idade assinaram o Termo de Assentimento enquanto seu tutor ou adulto responsável assinou o TCLE.

A avaliação de cada voluntário foi realizada sob supervisão de um profissional da área da saúde, que fez uma avaliação postural e uma avaliação do grau de desvio lateral, garantindo a segurança e a integridade do teste e do voluntário (FANFONI, 2017).

O primeiro procedimento realizado pelo profissional da área da saúde foi a anamnese de cada voluntário na qual foram coletadas informações como nome, sexo, idade, peso, altura, lateralidade e observações gerais. Posteriormente, foi feita uma avaliação postural para inspecionar pontos específicos da anatomia do voluntário que podem influenciar a postura como ombros, quadris, joelhos, posição de pernas e pés entre outras.

Em seguida foi mensurado diretamente sobre a radiografia da coluna vertebral do voluntário o grau de acometimento do desvio lateral, por meio do ângulo de Cobb e utilizando um goniômetro. Desta forma, os critérios de inclusão da pesquisa eram que os participantes estivessem munidos de radiografia da coluna vertebral com tempo inferior a

seis anos, apresentarem peso igual ou inferior a 120 kg e serem capazes de permanecer em pé, sem qualquer tipo auxílio.

Finalmente, foi solicitado que o voluntário ficasse a vontade e em posição ortostática sobre o baropodômetro.

Inicialmente o voluntário devia ficar com os braços esticados ao longo do corpo e observando um alvo fixo por 60 s. O alvo encontrava-se a uma distância de aproximadamente 1,5 m. Posteriormente foi realizada a avaliação com olhos fechados, na qual o voluntário fica por mais 60 s sobre o equipamento e com os braços esticados ao longo do corpo. Este tipo de avaliação é amplamente utilizado na literatura e permite identificar o comportamento do COP do voluntário ao mudar o seu sistema somatossensorial (DUARTE; FREITAS, 2010; SCOPPA *et al.*, 2013).

3.3.2 Dados Biométricos

Como descrito por Fanfoni (2017), um total de 61 voluntários foram avaliados. A maior parte da população avaliada foi do sexo feminino com 47 participantes, representando 77,1%, enquanto do sexo masculino foram 14 participantes (22,9%).

Como mostrado na Tabela 3, trata-se de um grupo abrangente com participantes de todas as faixas etárias. A altura do desvio lateral foi maioritariamente na região torácica (77,1%) e com convexidade lateral à direita (54,1%).

Tabela 3 – Dados biométricos dos voluntários avaliados.

Variável	Média	Desvio Padrão
Idade (anos)	38,2	19,8
Massa Corporal (kg)	64,9	16,4
Altura (cm)	161.6	9,4
Graus de Desvio Lateral	9,8	4,1

Fonte: Elaboração do próprio autor.

3.3.3 Grupos de Avaliação

Considerando que a escoliose é diagnosticada a partir de 10° , os 61 voluntários foram divididos em 2 grupos, sendo que o Grupo A está formado pelos voluntários com graus $\leq 9^\circ$, enquanto o Grupo B é constituído pelos voluntários com graus $\geq 10^\circ$.

O Grupo A teve 25 voluntários e o Grupo B, 36 voluntários. Na Tabela 4 são apresentados os dados biométricos dos voluntários segundo o grupo ao qual pertencem.

Tabela 4 – Dados biométricos dos Grupos A e B.

Variável	Grupo A	Grupo B
Número Voluntários (N)	25	36
Idade (anos)	$37,2 \pm 19,9$	$39,0 \pm 19,9$
Massa Corporal (kg)	$60,9 \pm 12,11$	$67,6 \pm 18,4$
Altura (cm)	$160,8 \pm 10,0$	$162,2 \pm 9,0$
Graus de Desvio Lateral	$6,0 \pm 2,26$	$12,3 \pm 2,9$

Fonte: Elaboração do próprio autor.

Os grupos mostraram ser homogêneos em relação à idade, altura e massa corporal, no entanto, é uma base de dados desequilibrada sendo que há maior quantidade de voluntários no Grupo B (grau de desvio lateral maior ou igual que 10°).

4 RESULTADOS

4.1 BAROPODÔMETRO

Não foi encontrado nenhum trabalho ou relatório técnico descrevendo a caracterização da matriz de sensores FSR MS9705, utilizada na implementação do baropodômetro.

Nesta seção, serão apresentados os equipamentos, métodos, procedimentos e resultados obtidos na caracterização do LiebScan System.

4.1.1 Metodologia de Calibração da Matriz Piezoresistiva

Embora cada sensel dentro da matriz possua uma resposta única e seja recomendada a sua calibração individual (LUO; BERGLUND; AN, 1998), exercer forças em cada sensel para calibração individuais é inviável, devido ao tamanho da matriz e ao número de sensels. Assim sendo, a caracterização foi feita da matriz como um todo.

Na literatura, há poucas referências sobre calibração de matrizes piezoresistivas. No entanto, utilizando dados da empresa TekScan (2018), com os equipamentos *Equilibration Device*, e os trabalhos desenvolvidos por Hurkmans *et al.* (2006), Papaioannou *et al.* (2008) e Yao *et al.* (2017), pode-se ter uma ideia do processo de calibração realizado a nível industrial e comercial.

O *Equilibration Device* possui uma câmara e uma membrana em seu interior. Utilizando um sistema pneumático, a membrana é preenchida e exerce pressões constantes e homogêneas sobre a área ativa do sensor. Desta forma, todos os sensels devem mensurar a mesma pressão, e são utilizados fatores escalares para compensar digitalmente as leituras em cada um deles para atingir a leitura de pressão desejada.


Embora o método seja recomendado, estes equipamentos de calibração têm custos elevados, de uso exclusivo para este tipo de aplicação e fornecido/utilizado apenas pelos próprios fabricantes dos baropodômetros.

Um equipamento alternativo e altamente usado para a caracterização de sensores de força e compósitos piezoresistivos é a máquina universal de ensaios (MUE), que possibilita exercer forças axiais controladas. No LIEB foi implementada uma MUE que exerce forças controladas de tração ou compressão (Figura 42).

Esta MUE possui um motor de passo NEMA 23 de 19 kgf.cm e um sistema de polias correias com relação 1:4, possibilitando um torque final no sistema de transmissão de 7,45 N.m. Considerando perdas por atrito, o equipamento consegue exercer forças controladas de até 1,3 kN.

No entanto, selecionando uma célula de carga com capacidade de 100 kgf, limitou-se a capacidade de carga máxima do equipamento a 85% da capacidade da célula para evitar danificá-la. portanto, a MUE-LIEB pode exercer forças de compressão ou tração de até 830 N.

Figura 42 – Máquina universal de ensaios MUE-LIEB.



Fonte: Elaboração do próprio autor.

A MUE-LIEB possui avanços mínimos de $0,468 \mu\text{m}$, velocidade de avanço mínima de $0,468 \mu\text{m/s}$ e máxima de 4 mm/s . O sistema é controlado remotamente através de um aplicativo desenvolvido em linguagem Python e embarcado em uma Raspberry Pi 3 B+,


que por ter WiFi integrado, possibilita conexões remotas através de uma rede LAN/WAN com qualquer equipamento, por exemplo, celular, computador ou tablet. Desta forma o sistema não precisa conexões externas nem instalações de software proprietários que limitariam seu uso.

Segundo informação do fabricante, a matriz suporta até 400 kPa; no entanto e como será apresentado a seguir, a matriz entra em região de saturação sob pressões próximas de 300 kPa.

Considerando que a área ativa da matriz é de $0,15 \text{ m}^2$, seria necessário exercer uma força distribuída de 45 kN para caracterizar o sensor como um todo. Neste sentido, a MUE desenvolvida não tem a capacidade para exercer a força necessária.

Assim, foi proposta uma caracterização por áreas menores, que garantam uma distribuição de forças homogêneas, e que possibilitem atingir os níveis de pressão requeridos. A matriz foi dividida em 144 áreas de 2304 mm^2 , com 36 sensels cada área, sendo necessária uma força máxima de 690 N para atingir 300 kPa. Para exercer pressões uniformes, utilizaram-se acessórios na ponta de prova da MUE, como mostrado na Figura 43.

Figura 43 – Calibração da matriz piezoresistiva por áreas.




Fonte: Elaboração do próprio autor.

O processo de calibração foi feito por passos de 15 kPa na faixa 0-300 kPa, na qual cada passo possui duração de 10 s. A frequência de amostragem da MUE e do LiebScan System foi configurada em 20 Hz.

4.1.2 Matriz Piezoresistiva MS9705

Ao exercer pressões na faixa 0-300 kPa, nas 144 áreas da matriz piezoresistiva, foi possível conferir que cada sensel possui uma resposta única, e como tal, precisa de uma calibração particular. Além disso, ao exercer uma pressão constante de 300 kPa, a matriz piezoresistiva não apresentou uma resposta resistiva homogênea, como mostrado na Figura 44. A impedância mínima atingida por cada sensel está na faixa 1,58 - 15,01 k Ω , enquanto a máxima é uniforme, próxima de 170 k Ω . A impedância média mínima da matriz é 7,19 k Ω .

Figura 44 – Resposta resistiva da matriz MS9705 quando submetida a 300 kPa.




Fonte: Elaboração do próprio autor.

Ao avaliar o modelo proposto em (4) com os parâmetros do LiebScan, é possível determinar que a impedância mínima recomendada (IMR) para o sistema é 8,48 k Ω e assim manter erros por crosstalk inferiores a 0,69%, como mostrado na Figura 45.

No entanto, é importante notar que a IMR é calculada quando considerados ambientes pessimistas e improváveis, sendo que para calculá-la, a matriz inteira deveria ter uma resposta resistiva uniforme na faixa 1,58 – 170 k Ω . Além disso, a matriz tem valores de impedância menores que a IMR em zonas de pouco usabilidade na área ativa, como são as zonas entre as linhas 40 e 48, que apresentaram as menores respostas piezoresistivas.

Figura 45 – Erro relativo por efeito crosstalk no LiebScan variando os NSE na faixa 1,58-170 k Ω , enquanto o EBT=170 k Ω .



Fonte: Elaboração do próprio autor.

4.1.3 Calibração LiebScan – Redes Neurais Artificiais

Quando a resposta de um sensor é não linear é necessário utilizar técnicas de modelamento e linearização.

O método tradicional de linearização da resposta do sensor é através de modelos polinomiais; no entanto, este método requer elevados esforços computacionais devido ao ponto flutuante no processamento do sinal (BENGTTSSON, 2012; ERDEM, 2010). Igualmente, determinar a ordem ideal do polinômio que melhor represente a resposta do sensor é uma tarefa complexa. Desde que é necessário caracterizar 2304 sensels no LiebScan System, o método de calibração e compensação de sensel por sensel proposto por Luo, Berglund e An (1998) e Saggin, Scaccabarozzi e Tarabini (2013) é inviável.

Considerando a particularidade de cada sensel, foi decidido realizar a linearização utilizando redes neurais artificiais (RNA). As RNA são utilizadas em numerosas e variadas aplicações tais como classificação, modelagem e controle. Sua principal vantagem é a elevada acurácia devido a sua habilidade de aprender funções contínuas (ALMASSRI *et al.*, 2018).

Devido às características não lineares de cada sensel da matriz, foi configurada uma RNA com topologia de múltiplas camadas de perceptrons (MLP).

A RNA-MLP com três camadas tem mostrado ser uma boa função de aproximação universal. De fato, a caracterização de sensores usando RNA tem mostrado melhores acurácias que outras técnicas de regressão (ENG; AL-MAI; AHMADI, 2018). No entanto, não existe uma RNA por *default* que possa ser utilizada, uma vez que cada rede tem suas próprias singularidades e configurações dependendo das exigências de cada problema. Assim, os principais parâmetros a serem considerados na configuração de uma rede são: o número de camadas, o número de neurônios por camada, o tipo de funções de ativação e algoritmos de treinamento, com seus respectivos hiperparâmetros (RIVERA *et al.*, 2007). Neste sentido será necessário configurar, treinar e testar 2304 RNAs.

O Neural Network Toolbox (NNToolbox) de Matlab 2018® foi utilizado para a linearização da matriz. Foram estabelecidas RNA-MLP com 3 camadas: a) camada de entrada, com um único neurônio (leitura de cada sensel, 8 bits); b) camada oculta com H número de neurônios; c) camada de saída com um único neurônio (pressão exercida em cada sensel em kPa).

Foi selecionado o algoritmo *backpropagation* e o aproximador universal *fitnet*, que é recomendado para aplicações de regressões.

Para identificar a melhor função de treinamento, 4 dentre as 144 áreas da matriz (36 sensels cada uma) foram selecionadas aleatoriamente.

Foram linearizados os 144 sensels com as 13 funções de treinamento disponíveis no *toolbox*: *trainlm*, *trainbr*, *trainbfg*, *traincgb*, *traincgf*, *traincgp*, *traingd*, *traingda*, *traingdm*, *traingdx*, *trainoss*, *trainrp*, e *trainscg*.

Uma camada oculta de doze neurônios ($H=12$) foi selecionada, enquanto hiperparâmetros e funções de ativação foram configuradas por *default*.

Para determinar a melhor função, a média do coeficiente de determinação (R^2) dos 144 sensels foi utilizada. Quanto mais próximo o R^2 de 1, maior a acurácia do sistema.

Como observado na Tabela 5, a função de treinamento com melhor rendimento foi a função ***trainlm*** sob a otimização Levenberg-Marquardt. Neste caso a função selecionada obteve a maior média e o menor desvio padrão dos coeficientes de determinação.

Tabela 5 – Comparação funções de treinamento segundo coeficientes de determinação (R^2).

Função	M $\pm$ DP *	Função	M $\pm$ DP *
<i>trainlm</i>	0,9440 $\pm$ 0,0437	<i>trainгда</i>	0,8908 $\pm$ 0,1257
<i>trainbr</i>	0,9436 $\pm$ 0,0438	<i>trainгdm</i>	0,3337 $\pm$ 0,2355
<i>trainbfg</i>	0,9419 $\pm$ 0,0423	<i>trainгdx</i>	0,9157 $\pm$ 0,0752
<i>traincgb</i>	0,9423 $\pm$ 0,0427	<i>trainoss</i>	0,9428 $\pm$ 0,0437
<i>traincgf</i>	0,9439 $\pm$ 0,0428	<i>trainrp</i>	0,9426 $\pm$ 0,0438
<i>traincgp</i>	0,9418 $\pm$ 0,0435	<i>trainscg</i>	0,9434 $\pm$ 0,0444
<i>trainгd</i>	0,2979 $\pm$ 0,2279		

M $\pm$ DP = Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

Uma vez identificada a função de treinamento apropriada, cada sensel da matriz é linearizado com a função selecionada. No entanto, é necessário sintonizar cada RNA de cada sensel para garantir o seu melhor desempenho.

Como comentado na Sub-Seção 3.2.1, a função *bayesopt* é utilizada para ajustar os hiperparâmetros da RNA e garantir o maior desempenho possível. Neste caso, a função objetivo (17) do otimizador *bayesopt* em cada sensel minimiza o erro médio quadrático entre a pressão exercida pela MUE-LIEB (P_{Cal}) e pressão de saída fornecida pela rede (P_{RNA}), sendo que esta última é obtida em função do H. O número de amostras é T .

$$f_{(Sensel)} = argmin \sqrt{\frac{\sum_{i=1}^T (P_{Cal} - P_{RNA})^2}{T}}; P_{Cal}, P_{RNA} \in [0, 300kPa] \quad (17)$$

Foi ajustada a camada oculta sintonizando o numero de neurônios H na faixa 3-15 neurônios. O H médio nos 2304 sensels foi de 12,45 neurônios, e o coeficiente de determinação nas linearizações foi $R^2 = 0,9307 \pm 0,0581$. O coeficiente de determinação foi baixo e menor que os apresentados na Tabela 5, devido aos sensels entre as linhas 40–48 que saturam sob pressões inferiores a 300 kPa.

Após ter identificado o número de neurónios ótimos na camada oculta, e assim que for treinada e testada cada rede neural em cada sensel, um vetor de saída para cada entrada possível da rede é gerado. Desta forma, inserindo um vetor de entrada com valores

na faixa 0–255, um vetor de saída na faixa 0–300 kPa, correspondente à resposta em cada sensel, é obtido.

Assim, é obtida uma tabela de dimensões 2304x256 com as respostas em kPa de toda a matriz. Este método é conhecido como *lookup table* e possibilita a fácil integração das RNA com outros sistemas e ainda reduz o tempo de processamento (URRY, 1999; BENGTTSSON, 2012).

4.1.4 Caracterização do LiebScan System

No processo de caracterização é necessário avaliar parâmetros tais como: acurácia na medição de pressões, histerese, acurácia e precisão na medição do COP, efeito *creep* e efeito *crosstalk*.

Foram usados alguns dos métodos propostos por Giacomozzi (2010) e Giacomozzi *et al.* (2012) para realizar uma comparação objetiva com características de equipamentos comerciais. Todos os testes foram realizados à temperatura ambiente, em torno de 23°C.

Acurácia na Medição de Pressão:


A acurácia na medição de pressões exercidas sobre a área ativa da matriz tem sido obtida através de avaliações em pequenas áreas. Enquanto Giacomozzi (2010) avaliou 5 áreas aleatórias de 7,03 cm², neste trabalho foram avaliadas 16 áreas de 10,24 cm² cada uma, que corresponde à área formada por 16 sensels.

Assim, ao todo foram feitos 48 testes de avaliação. Foram exercidas pressões por passos de 50 kPa, na faixa 0-300 kPa, com uma duração de 10 s por passo. Para análise comparativa, foram obtidos os valores RMSE absolutos (kPa) e a porcentagem de erros relativos RMSE (%), este último é obtido da relação entre o RMSE absoluto e a máxima pressão suportada pelo equipamento.


Para eliminar o piso de ruído das leituras em cada sensel, estabeleceu-se um limiar de medição de pressão de 5 kPa (*threshold*), ou seja pressões abaixo de 5 kPa são desconsideradas. Portanto, forças exercidas em cada sensel, inferiores a 0,32 N (32,62 g), não são levadas em consideração. O nível de *threshold* foi selecionado considerando a elevada sensibilidade da matriz piezoresistiva.

Na Figura 46a são apresentadas as pressões exercidas por passos de 50 kPa e a resposta de uma das áreas selecionadas. O coeficiente de correlação entre as pressões exercidas e lidas é de 0,9945, enquanto o coeficiente de determinação R^2 é 0,9890. Nesta área foi obtido um erro médio quadrático RMSE de 12,15 kPa.

Figura 46 – Curvas de caracterização na medição de pressões, (a) acurácia em uma das áreas selecionadas, (b) linearidade em 16 áreas.



(a)



(b)

Fonte: Elaboração do próprio autor.

Como mencionado, a matriz MS9705 tem sensels que saturam com pressões inferiores a 300 kPa, mais especificamente em torno de 250 kPa como mostrado na Figura 46b, onde

são apresentadas as curvas características de 16 testes correspondentes a um dos três testes feitos nas 16 áreas selecionadas.


Avaliando os 48 testes, nas 16 áreas, obteve-se um $RMSE=18,06 \pm 7,31$ kPa e $R^2 = 0,9850 \pm 0,0085$. O erro RMSE médio em relação à máxima pressão exercida (300 kPa) é 6,02%.

Histerese:

Pressões crescentes e decrescentes na faixa 0-250 kPa foram exercidas para mensurar a histerese.

A faixa de pressão foi selecionada como proposto por Giacomozzi (2010), com 83,33% da pressão máxima suportada. As pressões foram exercidas em cinco áreas de 10,24 cm² cada uma, selecionadas aleatoriamente. Três ciclos de carregamento e descarregamento de pressões foram feitos em cada área. Em cada ciclo de carregamento e descarregamento é obtida uma curva de caracterização de histerese como a mostrada na Figura 47, na qual a histerese média foi de 2,98%, com $R^2 = 0,9883$, e $RMSE=15,75$ kPa.

Figura 47 – Curva de caracterização de histerese em uma das áreas selecionadas.




Fonte: Elaboração do próprio autor.

Ao avaliar as cinco áreas com as três curvas de carregamento e descarregamento em cada área obteve-se uma histerese média total de $3,42 \pm 1,18\%$, coeficiente de determinação médio de $R^2 = 0,9837$, e raiz do erro médio quadrático $RMSE=20,03 \pm 3,89$ kPa.

Acurácia e Precisão na Medição do COP:

A medição do COP com o baropodômetro foi avaliada seguindo a metodologia proposta por Giacomozzi *et al.* (2009) e Giacomozzi (2010), na qual são exercidas três forças idênticas ($F_1=F_2=F_3$), nos três vértices de um triângulo equilátero, como apresentado na Figura 48. O COP é localizado exatamente no baricentro do triângulo e pode ser comparado com o COP mensurado pelo equipamento.

Figura 48 – Metodologia para avaliar medição do COP.



Fonte: Elaboração do próprio autor.

Foram avaliadas cinco zonas aleatórias da matriz, sendo que em cada uma foram exercidas pressões de 20 kPa nos vértices do triângulo.

As pressões foram exercidas por um período de 30 s. Após este período, a média dos COP coletados foi obtida.

Em cada zona foram obtidos seis pares de coordenadas médias do COP, nas direções ML e AP, correspondente aos seis COP, das seis possíveis posições, obtidas ao girar, as três forças, consecutivamente 20 graus (Figura 48).

A acurácia é quantificada com o valor RMSE entre as coordenadas do COP mensurado e do COP teórico nas cinco zonas, obtendo uma acurácia $ACC_{ML} = 0,40 \pm 0,07$ cm e $ACC_{AP} = 0,50 \pm 0,15$ cm nas direções ML e AP.

Entretanto, a precisão é obtida com o desvio padrão dos valores RMSE dos COP coletados nos 30 s, em cada sequência em relação ao COP teórico, obtendo uma precisão $PCS_{ML} = 0,16 \pm 0,04$ cm e $PCS_{AP} = 0,26 \pm 0,07$ cm nas direções ML e AP.


Efeito Creep:

O efeito creep é o incremento nas leituras do sensor quando submetido a estímulos externos constantes (MÜLLER; FRITZSCHE; ELKMANN, 2015).

Para avaliar o efeito creep no LiebScan System, foi exercida uma pressão constante de 150 kPa por 60 s em 5 áreas, selecionadas aleatoriamente, de 10,24 cm² cada uma. O gradiente de pressão foi obtido sobre os primeiros 40 s do período de pressão estática (GIACOMOZZI, 2010).

Na Figura 49 é mostrado o efeito creep em uma das áreas selecionadas. Neste caso a variação de tempo Δt foi de 40 s, enquanto a variação de pressão ΔP foi de 5,4 kPa, resultando em um efeito creep $\Delta P/\Delta t = 0,13$ kPa/s. Ao avaliar as áreas restantes obteve-se um efeito creep geral de $0,13 \pm 0,02$ kPa/s.

Figura 49 – Curva de caracterização de efeito creep em uma das áreas selecionadas.



Fonte: Elaboração do próprio autor.

Efeito Crosstalk:

O efeito crosstalk é o erro de leitura de um sensor causado pela influência de outros sensores, principalmente em matrizes de sensores resistivos/piezoresistivos.

Existe uma dificuldade mecânica para avaliar o erro por crosstalk de forma apropriada, porque seria necessário exercer pressões constantes na matriz inteira enquanto um único sensel é deixado livre de pressão.

Desta forma, alguns autores têm proposto algumas metodologias de avaliação como Giacomozzi *et al.* (2012) que propõem uma avaliação do erro por pressões exercidas em pequenas áreas (pouco clara); enquanto, Saggin, Scaccabarozzi e Tarabini (2013) propõem um método onde apenas um sensel é carregado e só os sensels adjacentes são analisados.

Foi proposto um método por áreas adjacentes que possibilita quantificar o efeito aqui citado. Este método de avaliação foi proposto porque diferentes experimentos executados em Castro *et al.* (2018) ao avaliar os circuitos de crosstalk, mostraram que o erro depende da impedância e do número de sensels carregados na mesma linha e na mesma coluna do sensel que está sendo testado.

Foram selecionadas 4 áreas adjacentes de 15,90 cm² cada uma, e depois foi exercida uma pressão constante de 150 kPa em três dessas áreas, deixando uma das quatro livre de pressão. O efeito por crosstalk vai corresponder ao erro de leitura nos sensels da área livre de pressão. Este procedimento foi aplicado em cinco zonas selecionadas aleatoriamente na matriz.

Os testes possibilitaram estabelecer que, nas áreas de interesse, as pressões mensuradas por crosstalk foram menores que o limiar de pressão de 5 kPa, isto é, pressões desprezíveis. No entanto, desconsiderando o limiar, os testes mostraram que houve um incremento médio nas leituras de cada sensel dentro da área livre de pressão de $0,60 \pm 0,42$ bits, representado por um erro de fundo de escala de $0,23 \pm 0,16\%$.

Quanto mais próximo o teste da zona de baixa impedância e rápida saturação entre as linhas 40 e 48, maior o erro por crosstalk, uma vez que as impedâncias nestas zonas são menores que a impedância mínima recomendada (8,48 k Ω).

O erro por crosstalk foi consideravelmente baixo e comparável com os resultados obtidos com o modelo do IIDFC proposto em (4) e com os dados apresentados na Figura 45, no qual era esperado um erro médio de 0,69% sob condições extremas.

4.1.5 Comparação do LiebScan System com Sistemas Comerciais

Uma comparação objetiva das características do baropodômetro LiebScan com equipamentos comerciais poder ser efetuada considerando os testes feitos por Giacomozzi (2010), no qual foram avaliados equipamentos das empresas Medilogic, AM Cube, TekScan e Novel, vide Tabela 6.

O LiebScan System tem características competitivas, quando comparado com equipamentos comerciais. Particularmente, a baixa histerese e o efeito creep são apenas superados pelo equipamento Emed®-X da Novel (2008a). De fato, os sistemas Emed têm melhor rendimento que qualquer outro sistema comercial (SAGGIN; SCACCABAROZZI; TARABINI, 2013; HSIAO; GUAN; WEATHERLY, 2002).

Embora com uma acurácia na medição de pressão acima do limite estabelecido (5%), o LiebScan ainda mostrou melhor rendimento que o sistema comercial Medilogic (2016). É importante notar que todos os testes para medição de pressão, realizados por Giacomozzi (2010), foram feitos na faixa 0-600 kPa, apenas dentro da faixa de operação do equipamento Medilogic. Além disso, não foi mensurada a acurácia no fundo de escala dos sistemas restantes. Nessa perspectiva, é provável que o LiebScan tenha maior acurácia de fundo de escala do que o sistema Amcube (2010).

Em relação à medição do COP, o LiebScan mostrou um rendimento similar ao apresentado pelo sistema Medilogic, embora ambos estejam fora da faixa recomendada.

O problema com a medição do COP no LiebScan esta relacionado à sensibilidade da matriz e a baixa pressão exercida nos testes de COP (20 kPa), fazendo com que a distribuição não fosse homogênea nas áreas selecionadas.

Embora o efeito crosstalk em equipamentos comerciais não tenha sido avaliado por Giacomozzi (2010), os sistemas pedar-X da Novel (2008b), mostraram erros na medição de pressão de até 14%, devido ao crosstalk, tal como mencionado por Saggin, ScaccabaroZZi e Tarabini (2013). Neste caso, apenas um sensel foi carregado, sendo avaliado o comportamento dos sensels adjacentes.

Tabela 6 – Comparação LiebScan System com equipamentos baropodométricos comerciais.

Parâmetro	Int. cons.	Medilogic	AM Cube	LiebScan	TekScan	Novel
Tecnologia do sensor	IND	Resistivo	Capacitivo	Resistivo	Resistivo	Capacitivo
Área Ativa do Sensor (mm ²)	400 x 600	480 x 240	490 x 490	384 x 384	436 x 369	475 x 320
Número de sensels	IND	2048	4096	2304	2288	6080
Resolução (sensels/cm ²)	> 1,4	1,78	1,7	1,56	1,4	4
Faixa de Pressão (kPa)	0-1500	6-640	10-1200	5-300	0-850	10-1270
Limiar de Pressão – threshold (kPa)	10	6	10	5	IND	10
Frequência de Amostragem (Hz)	100	20	IND	40	100	100
Acurácia na Medição de Pressão - RMSE (kPa)	< 75	59,20 ± 13,90	28,80 ± 8,60	18,06 ± 7,31	12,70 ± 3,40	2,00 ± 0,10
Acurácia na Medição de Pressão - RMSE (%)	< 5%	9,86 ± 2,32	4,80 ± 1,43	6,02 ± 2,44	2,12 ± 0,57	0,33 ± 0,02
Histerese (%)	< 5%	63,15	13,65	3,42	4,6	3,15
Creep - $\Delta P / \Delta t$ (kPa/s)	< 0,15	IND	0,18	0,13	0,15	0,09
COP ML (cm)	< 0,2	0,46 ± 0,11	0,33 ± 0,21	0,40 ± 0,16	0,18 ± 0,06	0,12 ± 0,04
COP AP (cm)	< 0,2	0,56 ± 0,17	0,46 ± 0,19	0,50 ± 0,26	0,32 ± 0,04	0,12 ± 0,02
Crosstalk	< 5%	IND	IND	0,23 ± 0,16	IND	IND

IND: Informação não disponível.

Int. cons.: International consensus (GIACOMOZZI *et al.*, 2012). Medilogic (MEDIOLOGIC, 2016).

AM Cube (AMCUBE, 2010). TekScan (TEKSCAN, 2019). Novel (NOVEL, 2008a)

Fonte: Elaboração do próprio autor e adaptado de Giacomozzi (2010).


4.1.6 Avaliação com Voluntário

Com o intuito de exemplificar o funcionamento do LiebScan System, foi feito um teste de baropodometria e estabilometria seguindo os protocolos recomendados por Duarte e Freitas (2010) e Scoppa *et al.* (2013), nos quais se solicita ao voluntário permanecer em pé sobre o equipamento, em posição ortostática, por 60 s, com os braços estendidos ao longo do corpo, e visualizando um alvo fixado a 1,5 m de distância do voluntário. Em seguida, é solicitado ao voluntário fechar os olhos enquanto fica na mesma posição por mais 60 s.

O teste foi realizado com um voluntário sadio de 31 anos de idade, 81 kg de massa corporal, 1,78 m de altura, masculino, e destro.

Na Figura 50 é mostrada a distribuição de pressão na região plantar do voluntário, sendo 50,18% do peso distribuído no pé esquerdo, enquanto o restante 49,82% no pé direito. A distribuição de pressão no pé esquerdo foi de 46,52% no retropé, 18,33% no mediopé e 35,15% no antepé. O descarregamento no pé direito foi de 45,06% na parte posterior do pé, 18,23% na parte média do pé, e 36,71% na parte anterior do pé.

Figura 50 – Distribuição de pressão na região plantar do voluntário com o LiebScan System.



Fonte: Elaboração do próprio autor.

A distribuição de pressões plantares é normal, segundo parâmetros estabelecidos por Kapandji (2000), nos quais a parte posterior do pé (retropé) descarrega cerca de 50% do peso, o mediopé 16% e antepé (metatarsais e falanges) 34%. Neste caso o pico de máxima pressão foi de 70,12 kPa na região do calcanhar do pé direito. O COP médio durante a avaliação está nas coordenadas (ML;AP)=(182,88 ; 175,40) mm.

Para análise de estabilometria foi utilizado um filtro passa-baixas Butterworth de quarta ordem, com frequência de corte de 10 Hz, como recomendado por Ruhe, Fejer e Walker (2010). Os parâmetros obtidos são aqueles propostos na Tabela 1 do Capítulo 1.

Os dados de estabilometria do voluntário são apresentados na Tabela 7, onde a magnitude da maioria dos dados, obtidos no teste de olhos abertos, é maior que os dados do voluntário obtidos com olhos fechados. Este é um resultado esperado em avaliações de estabilidade e posturologia, devido à mudança no sistema somatossensorial (BŁASZCZYK, 2016).

Tabela 7 – Dados de estabilometria em voluntário.

Variável	Olhos Abertos	Olhos Fechados
Deslocamento Total (mm)	556,97	576,55
Deslocamento ML (mm)	353,29	333,81
Deslocamento AP (mm)	361,24	399,25
Velocidade Média Total (mm/s)	8,54	9,39
Velocidade ML (mm/s)	5,42	5,44
Velocidade AP (mm/s)	5,54	6,50
Amplitude ML (mm)	5,62	7,32
Amplitude AP (mm)	8,33	9,26
Área de Deslocamento (mm ²)	24,87	31,41
RMS ML (mm)	0,92	1,06
RMS AP (mm)	1,44	1,70

Fonte: Elaboração do próprio autor.

4.2 MACHINE LEARNING

4.2.1 Pré-Processamento de Dados

O pré-processamento de dados é considerada a parte mais importante no processo de aprendizado de máquina supervisionado. As distribuições de força da região plantar foram inicialmente normalizadas na faixa 0-1, considerando o pico de máxima pressão. Logo depois cada característica dos dados coletados foi normalizada na faixa -1,1 e posteriormente padronizada de tal forma que os dados ficassem com valor médio 0 e desvio padrão 1, sendo este último procedimento conhecido como escalonamento.

No total, a base de dados possui 149 observações (testes com voluntários) e 147 características, sendo que 120 são dados dos sensores do equipamento, 20 são dados de estabilometria e 7 são dados biométricos de cada voluntário (idade, massa corporal, altura, sexo, lateralidade e posição do COP nas direções COP-AP e COP-ML). Desta forma consideram-se todos os dados disponíveis dos voluntários avaliados.

A base de dados possui 149 observações, uma vez que muitos dos 61 voluntários avaliados fizeram mais de um teste de baropodometria e são analisados como voluntários independentes.


Cada voluntário tem 147 características que resulta em um número elevado que impacta diretamente sobre a capacidade e tempo de processamento das técnicas de ML. Assim, utiliza-se a análise de componente principal (PCA) que é uma técnica estatística de análise multivariada que possibilita reduzir a dimensão da base de dados através da correlação entre as próprias características (MOHAMAD-SALEH; HOYLE *et al.*, 2008; JOLLIFFE; CADIMA, 2016).

O PCA define uma nova base de dados, ordenada segundo seja o impacto ou variação da característica dentro da base de dados original.

Na Figura 51 é apresentada a porcentagem da variação total que cada componente principal contribui para a base de dados. Assim, considera-se que os primeiros 70 componentes principais representam 98,15% da base de dados.

Desta forma, de agora em diante as técnicas de ML utilizadas serão treinadas e testadas utilizando apenas os 70 primeiros componentes principais de cada voluntário.

Figura 51 – Análise de Componente Principal PCA.



Fonte: Elaboração do próprio autor.

4.2.2 RNA - Seleção Tipo de Rede e Função de Treinamento

Como explicado na Sub-Seção 3.2.1, inicialmente deve ser identificado o tipo de rede que vai ser utilizada junto com a função de treinamento, segundo o rendimento de cada combinação. Os tipos de rede utilizados foram: *feedforwardnet*, *patternnet*, e *cascadeforwardnet*; enquanto as funções de treinamento foram: *trainlm*, *trainscg*, *traincgb* e *trainrp*.

Deve ser identificado o número de camadas ocultas na camada intermediária. Neste caso foram testadas redes com uma e duas camadas ocultas.

Em cada combinação (rede, função de treinamento, e topologia) foi empregado o crossvalidation com $k=5$, enquanto cada Fold foi treinado e testado 5 vezes para mensurar a estabilidade da rede.

Embora a análise de PCA tenha mostrado que 70 componentes representam 98,15% da base de dados, nem sempre esses componentes são necessários ou contribuem positivamente no processo de ML.

Utilizando o método de otimização *bayesopt* foram encontrados, para cada combinação, o número de PCA que ofereça o melhor rendimento na faixa 20-70, e também o número de neurônios H da(s) camada(s) oculta(s) na faixa 10-70.

Assim, a função objetivo para o método de otimização é dada por:

$$\lambda^{(*)} = \operatorname{argmin} \left\langle \frac{1}{VTI_{\lambda}} \right\rangle; \forall \lambda = (PCA, H) \quad (18)$$


satisfazendo:

$$\begin{aligned} SE_{\lambda} &> 50 \% ; \forall \lambda = (PCA, H); \\ ESP_{\lambda} &> 50 \% ; \forall \lambda = (PCA, H); \\ PCA &\in [20, 70]; H \in [10, 70]. \end{aligned} \quad (19)$$

A função objetivo (18) procura minimizar o erro ao maximizar os VTI, mudando os PCA e H. Foram definidas as regras 19 uma vez que não é de interesse valores de sensibilidade e especificidade menores ao 50%.

Na Figura 52 é mostrado um exemplo da saída gráfica do método de otimização bayesopt em uma rede do tipo *feedforwardnet*, com função de treinamento *trainrp* e uma camada oculta. A solução ótima neste exemplo foi $\lambda^{(*)} = (PCA, H) = (34, 26)$, deixando uma rede com topologia [34-26-1].

Figura 52 – Exemplo de saída gráfica da função de otimização bayesopt com rede feed-forwardnet, função de treinamento trainrp e sintonizando PCA e H, obtendo a topologia [34-26-1].



Fonte: Elaboração do próprio autor.

Após utilizar o método de otimização nos diferentes tipos de rede, assim como nas diferentes funções de treinamento, foram identificados o número de PCA e o número de neurônios (H) ótimos que oferecem melhor rendimento em cada combinação ($\lambda^{(*)}$).

Os valores de VTI obtidos ao realizar este procedimento com as combinações possíveis de tipo de rede, função de treinamento e número de camadas ocultas na camada intermediária são apresentados nas Tabelas 8 e 9, salientando que em cada rede foram realizados testes repetitivos para identificar a estabilidade da rede e evitar falsos desempenhos ótimos por questões fortuitas.

A Tabela 8 contém os valores VTI das redes com uma única camada oculta nas diferentes combinações, na qual a rede do tipo *patternnet* e com função de treinamento *trainscg* apresentou o melhor rendimento. Neste caso, a otimização pela função *bayesopt* possibilitou estabelecer que a quantidade necessária de PCA para obter um resultado satisfatório foi de 30, com um número H de neurônios de 44, obtendo uma topologia final [30–44–1]. Os fatores de avaliação nesta rede, após o teste geral de 5 iterações para a estabilidade, crossvalidation com k=5 e 5 testes por cada Fold (125 treinamentos e testes), foram os seguintes: SE = $79,39 \pm 8,91\%$; ESP = $62,72 \pm 13,51\%$; SEL = $81,33 \pm 5,24\%$; e ACC = $73,83 \pm 5,73\%$.

Tabela 8 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária.

Função de Treinamento	<i>feedforwardnet</i>	<i>patternnet</i>	<i>cascadeforwardnet</i>
<i>trainlm</i>	282,46 $\pm$ 6,17	296,77 $\pm$ 10,30	280,11 $\pm$ 5,32
<i>trainscg</i>	291,07 $\pm$ 7,58	297,28 $\pm$ 5,99	289,75 $\pm$ 6,81
<i>traincgb</i>	274,70 $\pm$ 10,47	291,74 $\pm$ 4,44	290,69 $\pm$ 5,05
<i>trainrp</i>	280,21 $\pm$ 8,87	294,64 $\pm$ 9,66	280,64 $\pm$ 5,36

Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

É importante perceber que o desvio padrão principalmente na especificidade (ESP) é relativamente elevado, isto porque a ESP está relacionada com a capacidade da RNA de classificar voluntários sem escoliose e, devido fundamentalmente ao tamanho da base de dados e ao número de voluntários avaliados com ângulo de Cobb inferior a 10° , os resultados pela divisão de dados para treinamento e teste são altamente variáveis.

Entretanto, entre as diferentes combinações das redes com duas camadas ocultas na camada intermediária, a rede do tipo *cascadeforwardnet* com função de treinamento *trainscg* apresentou o melhor rendimento (Tabela 9).

Tabela 9 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com duas camadas ocultas na camada intermediária.

Função de Treinamento	<i>feedforwardnet</i>	<i>patternnet</i>	<i>cascaforwardnet</i>
<i>trainlm</i>	292,55 ± 10,31	295,51 ± 9,64	287,82 ± 8,05
<i>trainscg</i>	293,12 ± 4,47	291,88 ± 7,89	293,51 ± 3,60
<i>traincgb</i>	292,68 ± 4,19	293,04 ± 8,32	288,69 ± 5,82
<i>trainrp</i>	284,65 ± 6,59	288,08 ± 5,95	283,70 ± 4,81

Média ± Desvio Padrão.

Fonte: Elaboração do próprio autor.

Neste caso foi estabelecido que o número de PCA foi de 33, com um número H de neurônios de 69, obtendo uma topologia final [33–69–69–1]. Os fatores de avaliação nesta rede após o teste geral foram: SE = 77,56 ± 7,44%; ESP = 62,68 ± 11,27%; SEL = 80,71 ± 5,19%; e ACC = 72,55 ± 6,58%.

De forma geral a rede do tipo *patternnet* junto com a função de treinamento *Scaled Conjugate Gradient - trainscg*, e com topologia de camada única na camada intermediária, obtiveram o melhor rendimento considerando 30 componentes principais e 44 neurônios na camada oculta [30–44–1].

4.2.3 RNA - Sintonização de Algoritmo de Treinamento

O algoritmo de treinamento selecionado na Sub-Seção anterior foi o *trainscg* para uma RNA do tipo MLP com topologia [30–44–1]. Embora a acurácia tenha sido de 73,83%, o algoritmo precisa ser sintonizado, encontrando os valores adequados dos hiperparâmetros que possibilitem melhorar a eficiência da rede.

No caso da função de treinamento selecionado, é possível sintonizar as funções de transferência, e dados próprios como o *sigma* e o *lambda* que modificam as aproximações matemáticas e, em consequência, a resposta da rede.

As funções de transferência com o melhor desempenho foram *tansig* na camada intermediária e *logsig* na camada de saída.

Novamente, utilizando o método de otimização de bayes com a função *bayesopt* são identificados os valores apropriados para *sigma* e *lambda* da função de treinamento *trainscg*. Neste caso a função objetivo é definida como:

$$\beta^{(*)} = \operatorname{argmin} \left\langle \frac{1}{VTI_{\beta}} \right\rangle; \forall \beta = (\sigma, \lambda)$$

$$\sigma \in [5, 0 \times 10^0, 5 \times 10^{-10}];$$

$$\lambda \in [5 \times 10^{-2}, 5 \times 10^{-12}]$$
(20)

Os valores apropriados dos hiperparâmetros para potencializar a resposta da rede foram $\sigma = 5,81 \times 10^{-10}$ e $\lambda = 6,17 \times 10^{-5}$.

4.2.4 RNA - Rendimento

Uma vez sintonizada a RNA, foram feitos os testes de estabilidade tanto em treinamentos como em testes, tal como explicado no processo de MLS implementado e mostrado na Figura 39 na Sub-Seção 3.2.1, obtendo os indicadores apresentados na Tabela 10.

Tabela 10 – Rendimento da RNA-MLP tipo patternnet, função de treinamento *trainscg* e topologia [30–44–1].

Variável	Sem Sintonizar	Sintonizada
Sensibilidade (%)	79,39 ± 8,91	80,05 ± 8,57
Especificidade (%)	62,72 ± 13,51	66,16 ± 9,57
Seletividade (%)	81,33 ± 5,24	82,65 ± 4,17
Acurácia (%)	73,83 ± 5,73	75,40 ± 5,56

Média ± Desvio Padrão.

Fonte: Elaboração do próprio autor.

De forma geral a rede mostrou um melhor rendimento, aumentando os valores médios e diminuindo os desvios padrão dos indicadores, embora os dados obtidos não apresentem uma melhoria realmente significativa.

A rede conseguiu classificar corretamente os voluntários com escoliose em 80,05%, no entanto conseguiu classificar corretamente os voluntários sem escoliose em apenas 66,16%. A porcentagem tão baixa de ESP é determinada, em grande parte, pelo desequilíbrio dos

grupos e o baixo número de voluntários. Ao sintonizar a RNA, a acurácia média aumentou 1,57%.

4.2.5 SVM - Configuração, Sintonização, e Rendimento

Como comentado na Sub-Seção 3.2.2, para a classificação de escoliose com SVM, selecionou-se o kernel *Radial Basis Function* (RBF).

Contudo, é ainda necessário determinar o número de PCA que contribuem positivamente para a classificação. É necessário treinar, testar e otimizar o SVM em função do número de PCA e dos hiperparâmetros do kernel RBF, sendo eles, *KernelScale* que determina a distribuição Gaussiana do kernel, e *BoxConstraint* que determina o custo de erros na classificação.

Para otimizar a técnica foi utilizada a função de otimização *bayesopt* com a seguinte função objetivo associada:

$$\begin{aligned} \Gamma^{(*)} &= \underset{\Gamma}{\operatorname{argmin}} \left\langle \frac{1}{VTI_{\Gamma}} \right\rangle; \forall \Gamma = (KernelScale, BoxConstraint, PCA) \\ KernelScale &\in [1, 0 \times 10^{-5}, 1, 0 \times 10^5]; \\ BoxConstraint &\in [1, 0 \times 10^{-5}, 1, 0 \times 10^{10}]; \\ PCA &\in [20, 70]. \end{aligned} \tag{21}$$

O processo de otimização permitiu identificar que o número de PCA que oferece maior rendimento à classificação é 22; enquanto o *KernelScale* = 32,51 e o *BoxConstraint* = $4,21 \times 10^{-5}$.

Da mesma forma que nas RNAs, o rendimento desta técnica de ML é avaliada em função da SE, ESP, SEL, e ACC que ao serem somados representam os VTI. Os parâmetros de rendimento após sintonizar, treinar e testar a técnica SVM são mostrados na Tabela 11.

Neste caso a acurácia da técnica de ML mostrou ser menor que a apresentada pela RNA ($75,40 \pm 5,56\%$), mas principalmente a especificidade (capacidade da técnica para classificar voluntários sem escoliose) é menor que a obtida com a RNA ($66,16 \pm 9,57\%$) e ainda com maior desvio padrão, ou seja, com resposta mais oscilatória. O comportamento oscilante na especificidade pode ser resultado do tamanho da base de dados e a quantidade

Tabela 11 – Rendimento do SVM sintonizado.

Variável	Valor ($M \pm DP$)
Sensibilidade (%)	$81,41 \pm 8,71$
Especificidade (%)	$62,00 \pm 15,11$
Seletividade (%)	$81,28 \pm 6,22$
Acurácia (%)	$74,89 \pm 7,19$

Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

de amostras de voluntários com menos de 10°. Contudo, todos os parâmetros de rendimento se mostraram mais instáveis no SVM que na RNA.


4.2.6 RNA e SVM, Segmentação e Avaliação por Voluntários

Como descrito anteriormente, a base de dados é constituída com os dados de 61 voluntários que foram, em alguns casos, avaliados mais de uma única vez, gerando um total de 149 observações. Devido à pouca quantidade de observações em cada classe (50 sem escoliose, 99 com escoliose), decidiu-se realizar treinamento e teste com o total das informações coletadas; no entanto, dita abordagem pode acrescentar o rendimento geral do sistema, uma vez que dados de treinamento e teste podem pertencer a um mesmo voluntário, havendo pouca variabilidade entre os dados.

Com o intuito de avaliar o impacto da abordagem descrita anteriormente com as 149 observações, modificou-se o processo de treinamento das técnicas de ML, considerando apenas uma única avaliação por voluntário. Neste sentido, foram selecionadas 61 observações que correspondem a uma avaliação por cada voluntário. Em caso de voluntários com múltiplas avaliações, é selecionada uma observação de forma aleatória. As 61 observações são divididas em dois grupos repetidamente com o procedimento de crossvalidation (grupos de treinamento e teste). Entretanto, as observações restantes (88), constituem o grupo re-teste. Assim, a base de dados foi dividida em 3 grupos: treinamento, teste e re-teste.

Aplicou-se a análise de PCA no grupo de dados de treinamento e teste (61 voluntários) e observou-se que as 45 primeiras componentes representam o 98,72% dos dados (Figura 53).

Figura 53 – Análise de Componente Principal PCA.



Fonte: Elaboração do próprio autor.

Para o processo de seleção de topologia e função de treinamento, foi utilizado o mesmo procedimento da Sub-Seção (4.2.2), com a função objetivo (18), sendo que neste caso o PCA está na faixa $[20,45]$ e o H na faixa $[10,45]$. Entretanto, devido às poucas observações no grupo de treinamento e teste, foi considerado um crossvalidation com $k=10$.

Como mostrado na Tabela 12, a função de treinamento com melhor rendimento foi a *trainscg* e com topologia $[27-45-1]$. Os parâmetros de rendimento foram: $SE = 75,55 \pm 4,28\%$; $ESP = 60,59 \pm 7,06\%$; $SEL = 83,49 \pm 3,12\%$; e $ACC = 68,68 \pm 3,80\%$.

Tabela 12 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária. Análise por segmentação de voluntários.

Função de Treinamento	<i>feedforwardnet</i>	<i>patternnet</i>	<i>cascadeforwardnet</i>
<i>trainlm</i>	$265,87 \pm 2,40$	$287,83 \pm 2,71$	$277,92 \pm 2,21$
<i>trainscg</i>	$261,89 \pm 1,98$	$288,33 \pm 2,40$	$283,68 \pm 1,94$
<i>traincgb</i>	$285,41 \pm 2,10$	$277,34 \pm 1,67$	$286,58 \pm 2,26$
<i>trainrp</i>	$279,01 \pm 2,71$	$272,49 \pm 3,60$	$275,61 \pm 2,99$

Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

Para o processo de sintonização é utilizado o método de otimização de bayes com a função objetivo definida em (20). Como descrito anteriormente, foi considerado um kFold

de 10 para o procedimento de crossvalidation, no entanto, devido à pouca quantidade de observações, este parâmetro tem um impacto considerável no rendimento do sistema, uma vez que quanto maior o k , maior número de observações disponíveis para treinamento e menor quantidade para teste. Assim, como mostrado na Tabela 13, as RNA com topologia [27-45-1] e função de treinamento *trainscg*, obtiveram diferentes rendimentos quando selecionados diferentes kFold nos procedimentos de crossvalidation. Neste caso, a RNA com $k=10$ obteve maior rendimento porque este modelo dispõe de maior quantidade de informação para o treinamento. É importante salientar que neste procedimento selecionou-se um kFold de 10 porque, além do grupo de teste do procedimento de crossvalidation, também existe o grupo de re-teste que possibilita avaliar o modelo da rede.

Tabela 13 – Rendimentos RNA e SVM sintonizados. Avaliação por voluntários.

Variável	RNA Sintonizada $k=5$	RNA Sintonizada $k=10$	SVM Sintonizado $k=10$
Sensibilidade (%)	$65,38 \pm 5,16$	$74,96 \pm 4,02$	$78,12 \pm 4,12$
Especificidade (%)	$51,48 \pm 7,68$	$61,52 \pm 6,82$	$51,63 \pm 7,64$
Seletividade (%)	$76,02 \pm 2,48$	$82,61 \pm 2,43$	$79,71 \pm 2,33$
Acurácia (%)	$61,22 \pm 2,97$	$71,02 \pm 2,78$	$70,37 \pm 2,79$

Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

Os valores apropriados dos hiperparâmetros para potencializar a resposta da rede com $k=10$ foram $\sigma=5,09 \times 10^{-10}$ e $\lambda=1,41 \times 10^{-5}$. Entretanto, os valores para a rede com $k=5$ foram $\sigma=5,26 \times 10^{-8}$ e $\lambda=7,77 \times 10^{-3}$.

Com a abordagem de segmentação de treinamento, teste e re-teste, também foi configurada, avaliada e sintonizada a técnica SVM, com os procedimentos descritos na Sub-Seção (4.2.5), com a função objetivo associada (21), salientando que neste caso o PCA está na faixa 20-45. Selecionou-se o $k=10$ para o processo de crossvalidation.

O processo de otimização permitiu identificar que o número de PCA que oferece maior rendimento à classificação é 28; enquanto o *KernelScale* = 5,79 e o *BoxConstraint* = 3,74. Os parâmetros de rendimento são mostrados na Tabela (13).

Neste caso a acurácia da técnica SVM mostrou ser menor que a apresentada pela RNA com $k=10$, embora a sensibilidade (capacidade da técnica para classificar voluntários com escoliose) seja maior que a obtida com a RNA.

Embora o SVM tenha amostrado uma acurácia geral similar à RNA na abordagem de avaliação e segmentação por voluntários, esta técnica ainda mostrou maior acurácia quando treinado e testado com os 149 voluntários, mesmo que as respostas fossem mais instáveis principalmente no parâmetro de especificidade (Tabela 11).

4.2.7 RNA, SVM e Processamento Digital de Imagens

Os dados baropodométricos coletados, treinados e testados, correspondem às distribuições de força da região plantar em contato com os 120 sensores do Baropodômetro V2.0 (Figura 17). Contudo, nem todos os voluntários têm o mesmo tamanho de pé, e nem todos distribuem o peso sobre os mesmos sensores.

Visando explorar diferentes opções de pré-processamento de dados, foi feito o processamento das imagens da distribuição de forças na região plantar dos voluntários avaliados.

No processamento das imagens são padronizados os tamanhos dos pés considerando apenas as pressões desde o calcanhar até a região dos metatarsos, desconsiderando descarregamentos nos dedos dos pés.


Com o intuito de eliminar a angulação entre as pisadas, em cada imagem é alinhado o primeiro metatarso e o calcanhar de cada pé. As imagens são redimensionadas para obter amostras uniformes do mesmo tamanho.

Na Figura 54a é mostrada a distribuição de forças de um voluntário com 10° de desvio lateral, com 617x462 pixels e resolução 72 pixels por polegada. Na Figura 54b é apresentada a imagem processada, com o alinhamento dos calcanhares e os primeiros metatarsos, com dimensões 96x55 pixels e 72 pixels por polegada.

As imagens são representadas digitalmente nas cores aditivas vermelho, verde e azul, conhecidas como representação RGB. Cada pixel da imagem tem uma representação digital RGB associada, ou seja, cada pixel tem uma representação tridimensional.

Para utilizar as técnicas de ML em classificação de imagens é necessário desenvolver um conjunto de entradas uni-dimensional para cada voluntário. Cada imagem é processada para obter um único vetor com as informações das cores RGB, vide Figura 55. Assim, o vetor resultante de cada imagem tem 15.840 características (96x55 pixels x 3 RGB).


Figura 54 – Processamento de imagens; (a) distribuição de forças original, (b) distribuição de forças processada.



Fonte: Elaboração do próprio autor.

É importante notar que todas as imagens estão normalizadas pelo ponto de máxima pressão identificado com cor vermelha.


Figura 55 – Processamento de imagem a vetor uni-dimensional.



Fonte: Elaboração do próprio autor.

O banco de dados é constituído por 15.840 características das imagens processadas, 20 características de estabilometria e 7 de dados biométricos, com um total de 15.867 características e 149 observações. Após passar pelo processo de padronização e escalonamento, as características são submetidas à análise de componente principal (PCA), na qual determinou-se que as primeiras 125 características representam 98,27% da base de dados (Figura 56).

Figura 56 – Análise de Componente Principal (PCA) em imagens, dados de estabilometria e dados biométricos.



Fonte: Elaboração do próprio autor.

Uma vez feito o pré-processamento de dados e seleção dos PCA, utilizaram-se os métodos propostos nas Sub-Seções 4.2.2 – 4.2.4. Assim, na Tabela 14 são apresentados os rendimentos de cada RNA em função do tipo de rede e função de treinamento utilizada. Foram avaliadas redes MLP de única camada oculta.

Os resultados obtidos mostraram que a rede tipo *patternnet* com função de treinamento *trainlm* obteve o melhor rendimento médio; porém, a função *trainscg* mostrou rendimento próximo, com desvio padrão menor, motivo pelo qual esta última foi selecionada para ser sintonizada.

A RNA selecionada teve a topologia [49–70–1] e foi sintonizada obtendo $\sigma=7,21 \times 10^{-10}$ e $\lambda=1,83 \times 10^{-8}$.

Tabela 14 – Valor total dos indicativos segundo o tipo de rede e função de treinamento com uma camada oculta na camada intermediária, em processamento com imagens.

Função de Treinamento	<i>feedforwardnet</i>	<i>patternnet</i>	<i>cascaforwardnet</i>
<i>trainlm</i>	270,23 ± 8,63	288,75 ± 8,32	270,03 ± 5,38
<i>trainscg</i>	271,36 ± 9,09	285,35 ± 6,15	272,01 ± 7,32
<i>traincgb</i>	268,89 ± 11,00	283,02 ± 8,60	277,92 ± 6,32
<i>trainrp</i>	268,17 ± 5,54	273,79 ± 10,42	273,21 ± 5,04

Média ± Desvio Padrão.

Fonte: Elaboração do próprio autor.

Da mesma forma que na Sub-Seção 4.2.5, os dados de imagens, estabilometria e biométricos foram avaliados em uma SVM logo após o pré-processamento de dados.

Utilizou-se o kernel RBF e foram sintonizados, tanto o número de PCA utilizados, como os hiperparâmetros *KernelScale* e *BoxConstraint*. Novamente, foi implementada a função de otimização de bayes considerando a função objetivo (21).

O rendimento e cada variável, tanto da RNA como da SVM sintonizadas, são mostrados na Tabela 15. O SVM com melhor rendimento utilizou 39 PCA, com *KernelScale* = 188,55 e *BoxConstraint* = 44.619.

Tabela 15 – Rendimento RNA e SVM sintonizados, processamento de imagens.

Variável	RNA Sintonizada	SVM Sintonizado
Sensibilidade (%)	79,80 $\pm$ 8,39	76,47 $\pm$ 9,44
Especificidade (%)	55,92 $\pm$ 15,10	49,80 $\pm$ 17,08
Seletividade (%)	78,61 $\pm$ 5,49	75,51 $\pm$ 6,45
Acurácia (%)	71,77 $\pm$ 6,03	67,49 $\pm$ 7,32

Média $\pm$ Desvio Padrão.

Fonte: Elaboração do próprio autor.

Na utilização de imagens como pré-processamento de dados, a RNA obteve melhores rendimentos que a técnica de SVM. No entanto, esta técnica, com este pré-processamento de dados, foi menos eficiente que a RNA com os dados de força, uma vez que esta última apresentou melhores indicadores de rendimento (Tabela 10).

5 CONCLUSÕES

Com a pesquisa bibliográfica efetuada foi possível constatar que são poucas as pesquisas que relacionam diretamente a escoliose com a distribuição de forças na região plantar de voluntários em diferentes faixas etárias.

Algumas pesquisas mostraram que existe uma correlação entre o pé e a coluna, utilizando principalmente estatística descritiva. Entretanto, nenhum trabalho havia classificado escoliose utilizando dados baropodométricos, excetuando os realizados no LIEB.

Neste trabalho, implementou-se pela primeira vez, pelo que é de nosso conhecimento, um classificador para diagnóstico de escoliose baseado em dados baropodométricos, biométricos e de estabilometria, utilizando técnicas de ML. O classificador atingiu uma acurácia geral de 75,4%.

Implementou-se também o sistema baropodométrico *LiebScan System* com uma matriz piezoresistiva de 2304 *sensels* e área ativa de $0,15 \text{ m}^2$ (380 mm $\times$ 380 mm), obtendo uma resolução de $1,56 \text{ sensels/cm}^2$. O equipamento possui 550 mm de comprimento, 650 mm de largura e 30 mm de altura, com uma massa total de 6,5 kg, tornando-o um equipamento prático, robusto e portátil. Pela frequência de amostragem do sistema (40 Hz), é possível realizar avaliações estáticas e também algumas avaliações dinâmicas, como marcha com passadas lentas sobre o equipamento. Neste sentido não é recomendável utilizar este equipamento para avaliações de atividades físicas esportivas como saltar ou correr.

Foi necessária a implementação de um circuito para reduzir correntes parasitas e o efeito *crosstalk* na matriz piezoresistiva. Dentre os diferentes circuitos de *non-crosstalk* disponibilizados na literatura, constatou-se que o circuito mais adequado para esta aplicação foi o *Improved Isolated Drive Feedback Circuit - IIDFC*.

O circuito IIDFC não havia sido implementado em matrizes de sensores com numerosos sensels, como apresentado neste trabalho. Sua análise ficava restrita a circuitos simulados e modelos matemáticos.

A análise feita neste trabalho possibilitou estabelecer a característica de impedância mínima recomendada (IMR) para matrizes piezoresistivas de grande área, sendo que esta característica não havia sido relatada em nenhum trabalho especializado no projeto e análise de circuitos de controle de crosstalk.

Embora exista uma dificuldade mecânica para realizar um teste apropriado de crosstalk, os testes realizados por áreas adjacentes da matriz mostraram que o erro de leitura médio, de 0,23%, está dentro dos limites esperados, e podem ser desconsiderados, uma vez que as leituras produzidas por estes erros são inferiores ao limiar de pressão (*threshold*) do baropodômetro, de 5 kPa.

A matriz piezoresistiva MS9705 não havia ainda sido caracterizada com o nível de detalhe aqui apresentado. Apresentou saturação quando sobre ela foi exercida pressão de 300 kPa.

Entretanto, a característica mais importante, documentada neste trabalho, é a não homogeneidade na resposta resistiva da matriz quando submetida a uma pressão constante. A matriz tem resposta piezoresistiva na faixa 1,58 - 170 k Ω (300 - 0 kPa). Contudo, nem todos os sensels da matriz atingem essa impedância mínima, sendo que quando exercida uma pressão constante de 300 kPa, as impedâncias mínimas da matriz estão na faixa 1,58 - 15,01 k Ω . Mesmo com impedâncias mínimas inferiores à IMR (8,48 k Ω), nas regiões de maior utilização para avaliações estáticas, a resposta resistiva não atingiu a IMR, resultando em um erro desprezível por crosstalk.

Considerando a resposta resistiva de cada sensel, utilizou-se o método de linearização por RNA.

A acurácia geral do sistema baropodométrico na medição de pressões foi de 6,02%. A acurácia foi maior que o limite recomendado (5%) devido às regiões de saturação sob pressões inferiores a 300 kPa. Os resultados obtidos evidenciam que o LiebScan System possui características técnicas competitivas em relação às dos baropodômetros comerciais.

Foram utilizadas as técnicas de aprendizado de máquina RNA e SVM para classificação de escoliose, utilizando dados baropodométricos, biométricos e de estabilometria.

No pré-processamento de dados a análise por PCA mostrou que 70 características representam a maior parte da base de dados. Contudo, nem todas as características contribuem no processo de classificação.

Na configuração e sintonização das técnicas de ML, foi utilizado o método de otimização de *bayes*. Foram objeto de configuração o número de PCA, o número de neurônios na camada intermediária e hiperparâmetros próprios de cada função de treinamento.

Foi possível constatar que a RNA obteve o melhor rendimento com apenas 30 PCA. A rede do tipo *patternnet*, com função de treinamento *trainscg* e topologia [30–44–1], obteve acurácia média de 75,40%, sensibilidade de 80,05% e especificidade de 66,16%.

A técnica SVM obteve acurácia média de 74,89%. Embora a sensibilidade tenha sido maior que a RNA, a especificidade foi menor e o desvio padrão maior em todas as variáveis de rendimento, sendo esta uma técnica com maior instabilidade.

A baixa especificidade no rendimento de ambas as técnicas mostra a necessidade de ampliar o número de voluntários sem escoliose.

Realizando uma segmentação da base de dados por voluntários, considerando apenas uma observação por cada um deles (61) para os grupos de treinamento e teste, obteve-se menor rendimento na técnica SVM (acurácia = 70,37%) em relação à RNA (acurácia = 71,02%). No entanto, o rendimento geral desta abordagem foi menor que o rendimento das técnicas avaliadas empregando o total de observações dos voluntários (149). A acurácia está relacionada com a quantidade de dados fornecidos à rede para treinamento e teste. Neste sentido, a diminuição do rendimento foi um resultado esperado, uma vez que com menor número de dados para treinamento, a rede não consegue desenvolver um modelo que generalize melhor a solução ao problema. No entanto, esta abordagem evita possíveis vícios na rede, uma vez que é considerada apenas uma observação por voluntário.

Igualmente, foi conferido que o número de divisões no processo de crossvalidation (kFold) tem um impacto considerável no rendimento da rede, uma vez que quanto maior o k , maior número de observações disponíveis para treinamento e menor para teste, aumentando consequentemente o rendimento do sistema. No caso da RNA segmentada por voluntários, a rede obteve uma acurácia geral de classificação de 71,02% com $k=10$, enquanto com $k=5$ obteve 61,22%.

Utilizando o processamento digital de imagens no pré-processamento de dados, foi possível implementar classificadores com as técnicas RNA e SVM. Os resultados obtidos mostraram que a RNA conseguiu maior rendimento que a SVM. No entanto, quando comparados com os resultados do pré-processamento com dados baropodométricos puros de força, a RNA com processamento de imagens obteve menor rendimento, com acurácia geral de 71,77%.

Considerando o rendimento da RNA e pré-processamento de dados de força, o classificador, utilizando dados baropodométricos, biométricos e de estabilometria, diagnosticou escoliose com uma porcentagem de acerto de 75,40%.

A baixa porcentagem pode estar relacionada à causalidade entre os segmentos coluna vertebral-pé, que embora estejam correlacionados entre si, existem fatores como

comprimento dos membros inferiores, patologias nos pés, lordose e cifose, entre outros, que podem influenciar a correlação, mudando a relação de causalidade.

Trabalhos Futuros

Com a programação e configuração das técnicas de ML, ficou evidente a necessidade de uma base de dados com maior número de voluntários com e sem escoliose.

É importante manter um protocolo de avaliação e rigor na coleta de dados, possibilitando que os algoritmos de pré-processamento de dados sejam mais efetivos, e contribuindo ativamente ao rendimento das técnicas de ML.

Com a coleta de mais dados com o LiebScan System, haverá maior quantidade de características por voluntário e aumentará o nível de detalhe na distribuição de pressão em cada pé. Assim, será necessário considerar novamente o pré-processamento de dados por imagens, além dos dados baropodométricos, de estabilometria e biométricos, com o intuito de generalizar melhor o problema de classificação.

Um banco de dados maior possibilitará a implementação de técnicas de ML mais potentes, como RNA Convolutacional ou Deep Learning, e haverá a necessidade de migrar da plataforma de análise em Matlab, para plataformas especializadas e de código aberto como *TensorFlow*, *Keras* ou *Scikit-learn*.

REFERÊNCIAS

- ABREU, D. C. C. de *et al.* What is the influence of surgical treatment of adolescent idiopathic scoliosis on postural control? **Gait & Posture**, Amsterdam, v. 36, n. 3, p. 586–590, 2012. DOI 10.1016/j.gaitpost.2012.05.019. Citado na página 21.
- ADANKON, M. M. *et al.* Non invasive classification system of scoliosis curve types using least-squares support vector machines. **Artificial Intelligence in Medicine**, Amsterdam, v. 56, n. 2, p. 99–107, 2012. DOI 10.1016/j.artmed.2012.07.002. Citado na página 40.
- AFRAM, A. *et al.* Artificial neural network (ANN) based model predictive control (MPC) and optimization of hvac systems: A state of the art review and case study of a residential hvac system. **Energy and Buildings**, Amsterdam, v. 141, p. 96–113, 2017. DOI 10.1016/j.enbuild.2017.02.012. Citado na página 37.
- AHMAD, J.; ANDERSSON, H.; SIDÉN, J. Sitting posture recognition using screen printed large area pressure sensors. *In*: 2017 IEEE SENSORS, 2017, Glasgow. **Anais[...]**. Glasgow: IEEE Conference Publications, 2017. p. 1–3. DOI 10.1109/ICSENS.2017.8233944. Citado na página 45.
- ALMASSRI, A. M. M. *et al.* Self-calibration algorithm for a pressure sensor with a real-time approach based on an artificial neural network. **Sensors**, Basel, v. 18, n. 8, 2018. ISSN 1424-8220. DOI 10.3390/s18082561. Citado na página 96.
- ALMONACID, F. *et al.* Review of techniques based on artificial neural networks for the electrical characterization of concentrator photovoltaic technology. **Renewable and Sustainable Energy Reviews**, Oxford, v. 75, p. 938–953, 2017. DOI 10.1016/j.rser.2016.11.075. Citado na página 37.
- ALSHEIKH, M. A. *et al.* Machine learning in wireless sensor networks: Algorithms, strategies, and applications. **IEEE Communications Surveys Tutorials**, Piscataway, v. 16, n. 4, p. 1996–2018, 2014. ISSN 1553-877X. DOI 10.1109/COMST.2014.2320099. Citado na página 37.
- AMCUBE. **AM3, footWork Pro**. [*S.l.: s.n.*], 2010. Disponível em: <http://www.amcube.co.uk/products/footwork-pro-pressure-plate/>. Acesso em: 12 Jun. 2019. Citado 2 vezes nas páginas 105 e 106.
- ASHER, A. **How Scoliosis Is Measured by the Cobb Angle**. [*S.l.: s.n.*], 2019. Disponível em: <https://www.verywellhealth.com/cobbs-angle-and-scoliosis-296583>. Acesso em: 27 Ago. 2019. Citado na página 22.
- AYODELE, T. O. Introduction to machine learning. *In*: ZHANG, Y. (Ed.). *New Advances in Machine Learning*. Rijeka: IntechOpen, 2010. cap. 1. DOI 10.5772/9394. Citado 2 vezes nas páginas 37 e 71.
- BARTON, J.; LEES, A. Development of a connectionist expert system to identify foot problems based on under-foot pressure patterns. **Clinical Biomechanics**, Oxford, v. 10, n. 7, p. 385–391, 1995. DOI 10.1016/0268-0033(95)00015-D. Citado na página 38.

- BEGG, R.; KAMRUZZAMAN, J. Neural networks for detection and classification of walking pattern changes due to ageing. **Australasian Physics & Engineering Sciences in Medicine**, Dordrecht, v. 29, n. 2, p. 188, 2006. DOI 10.1007/BF03178892. Citado 2 vezes nas páginas 38 e 79.
- BEGG, R. K.; PALANISWAMI, M.; OWEN, B. Support vector machines for automated gait classification. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 52, n. 5, p. 828–838, 2005. DOI 10.1109/TBME.2005.845241. Citado na página 38.
- BENGTSSON, L. E. Lookup table optimization for sensor linearization in small embedded systems. **Journal of Sensor Technology**, Irvine, v. 2, n. 4, p. 177–184, 2012. DOI 10.4236/jst.2012.24025. Citado 2 vezes nas páginas 96 e 99.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **Journal of Machine Learning Research**, Cambridge, v. 13, n. Feb, p. 281–305, 2012. Citado na página 80.
- BIOLOGYFORUMS, S. F. **Abnormal spinal curvatures: kyphosis, lordosis, and scoliosis**. [S.l.: s.n.], 2013. Disponível em: <https://biology-forums.com/index.php?action=gallery&sa=view&id=8799>. Acesso em: 27 Ago. 2019. Citado na página 20.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1st. ed. New York: Springer, 2006. ISBN 978-0387-31073-2. Citado 4 vezes nas páginas 71, 73, 74 e 81.
- BLASZCZYK, J. W. The use of force-plate posturography in the assessment of postural instability. **Gait & Posture**, Amsterdam, v. 44, p. 1–6, 2016. ISSN 0966-6362. DOI 10.1016/j.gaitpost.2015.10.014. Citado na página 108.
- BODY, S. I. **Body Scientific International**. [S.l.: s.n.], 2010. Disponível em: http://teamdoctorsblog.com/wp-content/uploads/2012/03/Safe_Range.jpg. Acesso em: 10 Sep. 2019. Citado na página 29.
- BOSCH, K. *et al.* From “first” to “last” steps in life–pressure patterns of three generations. **Clinical Biomechanics**, Oxford, v. 24, n. 8, p. 676–681, 2009. DOI 10.1016/j.clinbiomech.2009.06.001. Citado na página 17.
- BRADLEY, A. P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. **Pattern Recognition**, Amsterdam, v. 30, n. 7, p. 1145–1159, 1997. DOI 10.1016/S0031-3203(96)00142-2. Citado na página 78.
- BRICOT, B. **Posturologia clínica**. First edition. São Paulo: CIES Brasil, 2010. Citado 5 vezes nas páginas 23, 26, 27, 28 e 29.
- BRYANT, A. R.; TINLEY, P.; SINGER, K. P. Normal values of plantar pressure measurements determined using the EMED-SF system. **Journal of the American Podiatric Medical Association**, Bethesda, v. 90, n. 6, p. 295–299, 2000. DOI 10.7547/87507315-90-6-295. Citado na página 51.
- CANTORAL-CEBALLOS, J. A. *et al.* Intelligent carpet system, based on photonic guided-path tomography, for gait and balance monitoring in home environments. **IEEE Sensors Journal**, Piscataway, v. 15, n. 1, p. 279–289, 2015. DOI 10.1109/JSEN.2014.2341455. Citado na página 39.

CARINI, F. *et al.* Posture and posturology, anatomical and physiological profiles: overview and current state of art. **Acta Bio-medica: Atenei Parmensis**, Fidenza, v. 88, n. 1, p. 11, 2017. Citado na página 23.

CASTRO, F. **Aprimoramento de um baropodômetro eletrônico e análise de estabiliometria em voluntários com escoliose**. Orientador: Prof. Dr. Aparecido Augusto de Carvalho. 2016. 91 f. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista (UNESP), Ilha Solteira, São Paulo, Brasil, 2016. Disponível em: <https://repositorio.unesp.br/handle/11449/138907>. Acesso em: 21 ago. 2019. Citado 3 vezes nas páginas 31, 33 e 68.

CASTRO, F. *et al.* Stabilometry data analysis in volunteers with different ages and scoliosis degrees. **Revista Argentina de Bioingeniería**, Córdoba, v. 21, n. 2, p. 20–24, 2017. ISSN 2591-376X. Citado na página 41.

CASTRO, F. *et al.* Crosstalk error analysis in IIDFC readout circuit for use in piezoresistive composite. **IEEE Sensors Journal**, Piscataway, v. 18, n. 1, p. 382–389, 2018. ISSN 1530-437X. DOI 10.1109/JSEN.2017.2771151. Citado 3 vezes nas páginas 62, 64 e 104.

CHERN, J.-S. *et al.* Severity of spine malalignment on center of pressure progression during level walking in subjects with adolescent idiopathic scoliosis. In: 36TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 36., 2014, Chicago. **Anais[...]**. Chicago: IEEE Conference Publications, 2014. p. 5888–5891. ISSN 1094-687X. DOI 10.1109/EMBC.2014.6944968. Citado na página 30.

CLUB, D. d. E. **La Columna Vertebral ¿Cómo se encuentra conformada y cómo funciona?** [*S.l.: s.n.*], 2019. Disponível em: <https://dolordelaespalda.club/columna-vertebral/>. Acesso em: 26 Ago. 2019. Citado na página 19.

CORDEIRO, T. *et al.* Baropodometer as a clinical tool for evaluating and following treatment of postural deviations: a case report. **Journal of Spine**, Los Angeles, v. 3, n. 4, p. 1000175, 2014. DOI 10.4172/2165-7939.1000175. Citado 2 vezes nas páginas 17 e 28.

COSTILLA-REYES, O.; SCULLY, P.; OZANYAN, K. B. Temporal pattern recognition in gait activities recorded with a footprint imaging sensor system. **IEEE Sensors Journal**, Piscataway, v. 16, n. 24, p. 8815–8822, 2016. DOI 10.1109/JSEN.2016.2583260. Citado na página 39.

COSTILLA-REYES, O.; SCULLY, P.; OZANYAN, K. B. Age-sensitive differences in single and dual walking tasks from footprint floor sensor data. In: 2017 IEEE SENSORS, 2017, Glasgow. **Anais[...]**. Glasgow: IEEE Conference Publications, 2017. p. 1–3. DOI 10.1109/ICSENS.2017.8234299. Citado na página 39.

CRÉTUAL, A. Which biomechanical models are currently used in standing posture analysis? **Neurophysiologie Clinique/Clinical Neurophysiology**, Issy-les-Moulineaux, v. 45, n. 4-5, p. 285–295, 2015. Citado na página 23.

CUNHA, A. L. L. M. d.; ROCHA, L. E. M. d.; CUNHA, L. A. M. d. Método de cobb na escoliose idiopática do adolescente: avaliação dos ângulos obtidos com goniômetros

- articulados e fixos. **Coluna/Columna**, São Paulo, v. 8, n. 2, p. 161–170, 2009. DOI 10.1590/S1808-18512009000200011. Citado na página 21.
- D’ALESSIO, T. Measurement errors in the scanning of piezoresistive sensors arrays. **Sensors and Actuators A: Physical**, Amsterdam, v. 72, n. 1, p. 71–76, 1999. DOI 10.1016/S0924-4247(98)00204-0. Citado 2 vezes nas páginas 54 e 55.
- DAVIDSON, P.; WAAS, A. M. Probabilistic defect analysis of fiber reinforced composites using kriging and support vector machine based surrogates. **Composite Structures**, London, v. 195, p. 186–198, 2018. DOI 10.1016/j.compstruct.2018.03.007. Citado na página 88.
- DEEPASHINI, H. *et al.* An insight into the plantar pressure distribution of the foot in clinical practice: Narrative review. **Polish Annals of Medicine**, Warsaw, v. 21, n. 1, p. 51–56, 2014. DOI 10.1016/j.poamed.2014.03.003. Citado na página 18.
- DEMUTH, H.; BEALE, M.; HAGAN, M. Neural network toolbox. **For Use with MATLAB. The MathWorks Inc**, Natick, v. 2000, 1992. Citado na página 84.
- DEO, R. C. Machine learning in medicine. **Circulation**, Waltham, v. 132, n. 20, p. 1920–1930, 2015. DOI 10.1161/CIRCULATIONAHA.115.001593. Citado 2 vezes nas páginas 71 e 73.
- DING, S. *et al.* Pressure-sensitive behaviors, mechanisms and model of field assisted quantum tunneling composites. **Polymer**, London, v. 113, p. 105–118, 2017. DOI 10.1016/j.polymer.2017.02.058. Citado na página 47.
- DUARTE, M.; FREITAS, S. M. Revision of posturography based on force plate for balance evaluation. **Brazilian Journal of Physical Therapy**, São Carlos, v. 14, n. 3, p. 183–192, 2010. DOI 10.1590/S1413-35552010000300003. Citado 6 vezes nas páginas 17, 34, 35, 36, 90 e 107.
- DUFVENBERG, M. *et al.* Does postural stability differ between adolescents with idiopathic scoliosis and typically developed? a systematic literature review and meta-analysis. **Scoliosis and Spinal Disorders**, London, v. 13, n. 1, p. 19, 2018. DOI 10.1186/s13013-018-0163-1. Citado na página 31.
- ELFTMAN, H. A cinematic study of the distribution of pressure in the human foot. **The Anatomical Record**, Hoboken, v. 59, n. 4, p. 481–491, 1934. DOI 10.1002/ar.1090590409. Citado na página 31.
- ELIZONDO, D. The linear separability problem: Some testing methods. **IEEE Transactions on Neural Networks**, Piscataway, v. 17, n. 2, p. 330–344, 2006. DOI 10.1109/TNN.2005.860871. Citado na página 87.
- ENG, S.; AL-MAI, O.; AHMADI, M. A 6 dof, wearable, compliant shoe sensor for total ground reaction measurement. **IEEE Transactions on Instrumentation and Measurement**, Piscataway, v. 67, n. 11, p. 2714–2722, 2018. DOI 10.1109/TIM.2018.2829338. Citado na página 97.
- ERDEM, H. Implementation of software-based sensor linearization algorithms on low-cost microcontrollers. **ISA Transactions**, New York, v. 49, n. 4, p. 552–558, 2010. DOI 10.1016/j.isatra.2010.04.004. Citado na página 96.

- FAN, Y. *et al.* Standing footprint diagnostic method. **Journal of Applied Physics**, Melville, v. 114, n. 16, p. 164702, 2013. DOI 10.1063/1.4827859. Citado na página 18.
- FANFONI, C. M. **Avaliação de escoliose utilizando baropodômetro e rede neural artificial**. Orientador: Prof. Dr. Aparecido Augusto de Carvalho. 2017. 76 f. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista (UNESP), Ilha Solteira, São Paulo, Brasil, 2017. Disponível em: <https://repositorio.unesp.br/handle/11449/150994>. Acesso em: 21 ago. 2019. Citado 4 vezes nas páginas 21, 41, 89 e 90.
- FANFONI, C. M. *et al.* Evaluation of scoliosis using baropodometer and artificial neural network. **Research on Biomedical Engineering**, Uberlândia - MG, v. 33, n. 2, p. 121–129, 2017. DOI 10.1590/2446-4740.00117. Citado na página 41.
- FANG, Q. Comparisons of foot pressure between teenager girls and young female adults. **Physical Activity and Health**, London, v. 2, n. 1, p. 24–28, 2018. DOI 10.5334/paah.9. Citado 2 vezes nas páginas 28 e 51.
- FONSECA, M. P. M.; CARDOSO, F.; GUIMARÃES, A. Fundamentos biomecânicos da postura e suas implicações na performance da flauta. **PER MUSI: Revista Acadêmica de Musica**, Belo Horizonte, n. 31, 2015. Citado na página 23.
- FREITAS, R. L. B. **Plataforma de força para aplicações biomédicas**. Orientador: Prof. Dr. Aparecido Augusto de Carvalho. 2008. 136 f. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista (UNESP), Ilha Solteira, São Paulo, Brasil, 2008. Disponível em: <https://repositorio.unesp.br/handle/11449/87056>. Acesso em: 02 dez. 2019. Citado na página 51.
- FREITAS, S. M. *et al.* Age-related changes in human postural control of prolonged standing. **Gait & Posture**, Amsterdam, v. 22, n. 4, p. 322–330, 2005. DOI 10.1016/j.gaitpost.2004.11.001. Citado na página 51.
- GARCÍA-CANO, E. *et al.* Prediction of spinal curve progression in adolescent idiopathic scoliosis using random forest regression. **Computers in Biology and Medicine**, Oxford, 2018. DOI 10.1016/j.combiomed.2018.09.029. Citado na página 40.
- GIACOMOZZI, C. Appropriateness of plantar pressure measurement devices: a comparative technical assessment. **Gait & Posture**, Amsterdam, v. 32, n. 1, p. 141–144, 2010. DOI 10.1016/j.gaitpost.2010.03.014. Citado 6 vezes nas páginas 99, 101, 102, 103, 105 e 106.
- GIACOMOZZI, C. *et al.* Pneumatic test device for the accurate assessment of pressure sensors. In: WORLD CONGRESS ON MEDICAL PHYSICS AND BIOMEDICAL ENGINEERING, 2009, Munich. **Anais[...]**. Munich: Springer, 2009. p. 319–322. DOI 10.1007/978-3-642-03889-1_86. Citado na página 102.
- GIACOMOZZI, C. *et al.* International scientific consensus on medical plantar pressure measurement devices: technical requirements and performance. **Annali dell'Istituto Superiore di Sanita**, Rome, v. 48, p. 259–271, 2012. DOI 10.4415/ANN.12_03_06. Citado 4 vezes nas páginas 49, 99, 104 e 106.

- GIOVANELLI, D.; FARELLA, E. Force sensing resistor and evaluation of technology for wearable body pressure sensing. **Journal of Sensors**, London, v. 2016, 2016. DOI 10.1155/2016/9391850. Citado 2 vezes nas páginas 46 e 48.
- GIOVANINI, R. d. M. **SSVEP-EEG Signal Pattern Recognition System for Real-Time Brain-Computer Interfaces Applications**. Orientador: Prof. Dr. Aparecido Augusto de Carvalho. 2017. 89 f. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista (UNESP), Ilha Solteira, São Paulo, Brasil, 2017. Disponível em: <https://repositorio.unesp.br/handle/11449/151710>. Acesso em: 21 ago. 2019. Citado 2 vezes nas páginas 74 e 75.
- GONZALEZ-FERNANDEZ, I. *et al.* A critical review on the use of artificial neural networks in olive oil production, characterization and authentication. **Critical Reviews in Food Science and Nutrition**, New York, v. 0, n. 0, p. 1–14, 2018. DOI 10.1080/10408398.2018.1433628. Citado na página 37.
- HAN, T. R.; PAIK, N. J.; IM, M. S. Quantification of the path of center of pressure (COP) using an F-scan in-shoe transducer. **Gait & Posture**, Amsterdam, v. 10, n. 3, p. 248–254, 1999. DOI 10.1016/S0966-6362(99)00040-5. Citado na página 34.
- HOLZREITER, S. H.; KÖHLE, M. E. Assessment of gait patterns using neural networks. **Journal of Biomechanics**, Oxford, v. 26, n. 6, p. 645–651, 1993. DOI 10.1016/0021-9290(93)90028-D. Citado na página 37.
- HSIAO, H.; GUAN, J.; WEATHERLY, M. Accuracy and precision of two in-shoe pressure measurement systems. **Ergonomics**, Abingdon, v. 45, n. 8, p. 537–555, 2002. DOI 10.1080/00140130210136963. Citado na página 105.
- HSU, C.-W. *et al.* A practical guide to support vector classification. **National Taiwan University**, Taipei, 2003. Citado na página 88.
- HUDSON, D. L.; COHEN, M. E. **Neural networks and artificial intelligence for biomedical engineering**. New York: IEEE, 2000. Citado 2 vezes nas páginas 81 e 83.
- HUGHES, J. The clinical use of pedobarography. **Acta Orthop Belg**, Brussels, v. 59, n. 1, p. 10–16, 1993. Citado na página 32.
- HUO, X. *et al.* An integrative framework for 3d cobb angle measurement on ct images. **Computers in Biology and Medicine**, Oxford, v. 82, p. 111–118, 2017. DOI 10.1016/j.compbiomed.2017.01.007. Citado na página 22.
- HURKMANS, H. *et al.* Accuracy and repeatability of the pedar mobile system in long-term vertical force measurements. **Gait & Posture**, Amsterdam, v. 23, n. 1, p. 118–125, 2006. DOI 10.1016/j.gaitpost.2005.05.008. Citado na página 92.
- JAREMKO, J. *et al.* Use of neural networks to correlate spine and rib deformity in scoliosis. **Computer Methods in Biomechanics and Biomedical Engineering**, Abingdon, v. 3, n. 3, p. 203–213, 2000. DOI 10.1080/10255840008915265. Citado na página 39.
- JAREMKO, J. L. *et al.* Estimation of spinal deformity in scoliosis from torso surface cross sections. **Spine**, Philadelphia, v. 26, n. 14, p. 1583–1591, 2001. DOI 10.1097/00007632-200107150-00017. Citado na página 39.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, London, v. 374, n. 2065, p. 20150202, 2016. DOI 10.1098/rsta.2015.0202. Citado na página 109.

KADOORY, S. *et al.* 3d morphology prediction of progressive spinal deformities from probabilistic modeling of discriminant manifolds. **IEEE transactions on medical imaging**, Piscataway, v. 36, n. 5, p. 1194–1204, 2017. DOI 10.1109/TMI.2017.2657225. Citado na página 41.

KALAMDANI, A.; MESSOM, C.; SIEGEL, M. Tactile sensing by the sole of the foot: part i: apparatus and initial experiments toward obtaining dynamic pressure maps useful for stabilizing standing, walking, and running of humanoid robots. *In*: IEEE INTERNATIONAL WORKSHOP ON HAPTIC AUDIO VISUAL ENVIRONMENTS AND THEIR APPLICATIONS (HAVE), 2006, Ottawa. **Anais[...]**. Ottawa: IEEE Conference Publications, 2006. p. 147–151. DOI 10.1109/HAVE.2006.283783. Citado na página 69.

KAPANDJI, A. **Fisiologia Articular: Membro inferior**. 5ª edição. ed. Rio de Janeiro: Guanabara Koogan S.A., 2000. II. 236 p. Citado 5 vezes nas páginas 18, 19, 25, 27 e 108.

KEIJERS, N. *et al.* Classification of forefoot pain based on plantar pressure measurements. **Clinical Biomechanics**, Oxford, v. 28, n. 3, p. 350–356, 2013. DOI 10.1016/j.clinbiomech.2013.01.012. Citado na página 39.

KIM, J.-S.; KWON, D.-Y.; CHOI, B.-D. High-accuracy, compact scanning method and circuit for resistive sensor arrays. **Sensors**, Basel, v. 16, n. 2, 2016. ISSN 1424-8220. DOI 10.3390/s16020155. Disponível em: <https://www.mdpi.com/1424-8220/16/2/155>. Acesso em: 16 Fev. 2020. Citado na página 57.

KITRONYX. **Kitronyx™, MS9705 Large Area FSR Matrix**. [*S.l.: s.n.*], 2018. Disponível em: <https://www.kitronyx.com/store/c3/Sensors.html>. Acesso em: 12 Jun. 2019. Citado 2 vezes nas páginas 52 e 53.

KOBSAR, D.; FERBER, R. Wearable sensor data to track subject-specific movement patterns related to clinical outcomes using a machine learning approach. **Sensors**, Basel, v. 18, n. 9, p. 2828, 2018. DOI 10.3390/s18092828. Citado na página 37.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *In*: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE (IJCAI), 1995, Montreal. **Anais[...]**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. p. 1137–1143. Citado na página 74.

KOTSIANTIS, S. B.; ZAHARAKIS, I.; PINTELAS, P. Supervised machine learning: A review of classification techniques. **Emerging Artificial Intelligence Applications in Computer Engineering**, Oxford, v. 160, p. 3–24, 2007. Citado 8 vezes nas páginas 71, 72, 76, 77, 82, 83, 87 e 88.

LAI, D. T. *et al.* Automatic recognition of gait patterns exhibiting patellofemoral pain syndrome using a support vector machine approach. **IEEE Transactions on Information Technology in Biomedicine**, Piscataway, v. 13, n. 5, p. 810–817, 2009. DOI 10.1109/TITB.2009.2022927. Citado na página 38.

- LALANDE, X. *et al.* Normal values of pressures and foot areas measured in the static condition. **Journal of the American Podiatric Medical Association**, Bethesda, v. 106, n. 4, p. 265–272, 2016. DOI 10.7547/14-008. Citado na página 51.
- LANGENSIEPEN, S. *et al.* Measuring procedures to determine the cobb angle in idiopathic scoliosis: a systematic review. **European Spine Journal**, Heidelberg, v. 22, n. 11, p. 2360–2371, 2013. DOI 10.1007/s00586-013-2693-9. Citado na página 22.
- LAOWATTANATHAM, N. *et al.* Smart digital podoscope for foot deformity assessment. *In*: BIOMEDICAL ENGINEERING INTERNATIONAL CONFERENCE (BMEICON), 7th., 2014, Fukuoka. **Anais[...]**. Fukuoka: IEEE Conference Publications, 2015. p. 1–5. DOI 10.1109/BMEiCON.2014.7017410. Citado na página 33.
- LATARJET, M.; LIARD, A. R. **Anatomía Humana. Tomo 1.** 4ª edição. ed. Buenos Aires: Médica Panamericana, 2011. II. Citado 2 vezes nas páginas 18 e 19.
- LEUNG, F. H.-F. *et al.* Tuning of the structure and parameters of a neural network using an improved genetic algorithm. **IEEE Transactions on Neural Networks**, Piscataway, v. 14, n. 1, p. 79–88, 2003. DOI 10.1109/TNN.2002.804317. Citado na página 80.
- LIN, H. Identification of spinal deformity classification with total curvature analysis and artificial neural network. **IEEE Transactions on Biomedical Engineering**, Piscataway, v. 55, n. 1, p. 376–382, 2008. DOI 10.1109/IEMBS.2005.1615903. Citado na página 40.
- LIPPERT, L. **Clinical Kinesiology and Anatomy**. Fifth edition. Philadelphia: FA Davis Company, 2011. Citado 7 vezes nas páginas 17, 19, 23, 24, 25, 26 e 27.
- LIU, H. *et al.* Measurement errors in the scanning of resistive sensor arrays. **Sensors and Actuators A: Physical**, Amsterdam, v. 163, n. 1, p. 198–204, 2010. DOI 10.1016/j.sna.2010.08.004. Citado 2 vezes nas páginas 46 e 57.
- LUO, Z.-P.; BERGLUND, L. J.; AN, K.-N. Validation of F-Scan pressure sensor system: a technical note. **Journal of Rehabilitation Research and Development**, Baltimore, v. 35, n. 2, p. 186–191, 1998. Citado 3 vezes nas páginas 69, 92 e 96.
- MARTINEZ-CANTIN, R. Bayesopt: A bayesian optimization library for nonlinear optimization, experimental design and bandits. **The Journal of Machine Learning Research**, Cambridge, v. 15, n. 1, p. 3735–3739, 2014. Citado na página 84.
- MATHWORKS, I. **Pattern Recognition**. [*S.l.: s.n.*], 2018. Disponível em: <https://es.mathworks.com/help/deeplearning/pattern-recognition-and-classification.html>. Acesso em: 15 Out. 2018. Citado na página 84.
- MAUDE, E. **Scoliosis SOS Clinic. S-Curve vs C-Curve Scoliosis Treatment**. [*S.l.: s.n.*], 2018. Disponível em: <https://www.scoliosissos.com/news/post/s-curve-vs-c-curve-scoliosis-treatment>. Acesso em: 20 jan. 2020. Citado na página 21.
- MCKAY, M. J. *et al.* Spatiotemporal and plantar pressure patterns of 1000 healthy individuals aged 3–101 years. **Gait & Posture**, Amsterdam, v. 58, p. 78–87, 2017. DOI 10.1016/j.gaitpost.2017.07.004. Citado na página 28.

- MCKEON, P. O. *et al.* The foot core system: a new paradigm for understanding intrinsic foot muscle function. **Br J Sports Med**, London, v. 49, n. 5, p. 290–290, 2015. DOI 10.1136/bjsports-2013-092690. Citado 2 vezes nas páginas 17 e 26.
- MEDILOGIC. **Medilogic - Pressure Measuring Platform Basic**. [S.l.: s.n.], 2016. Disponível em: <https://medilogic.com/en/platform-basic/>. Acesso em: 12 Jun. 2019. Citado 2 vezes nas páginas 105 e 106.
- MEDINA, R. *et al.* Footprint analysis using a low cost photo-podoscope. *In*: SECOND ECUADOR TECHNICAL CHAPTERS MEETING (ETCM), 2nd., 2017, Salinas. **Anais[...]**. Salinas: IEEE Conference Publications, 2018. p. 1–6. DOI 10.1109/ETCM.2017.8247497. Citado na página 33.
- MENZ, H. B.; MORRIS, M. E. Clinical determinants of plantar forces and pressures during walking in older people. **Gait & Posture**, Amsterdam, v. 24, n. 2, p. 229–236, 2006. DOI 10.1016/j.gaitpost.2005.09.002. Citado na página 28.
- MEZGHANI, N. *et al.* A computer-based classifier of three-dimensional spinal scoliosis severity. **International Journal of Computer Assisted Radiology and Surgery**, Heidelberg, v. 3, n. 1-2, p. 55–60, 2008. DOI 10.1007/s11548-008-0163-3. Citado na página 40.
- MEZGHANI, N. *et al.* A kohonen neural network description of scoliosis fused regions and their corresponding lenke classification. **International Journal of Computer Assisted Radiology and Surgery**, Heidelberg, v. 7, n. 2, p. 257–264, 2012. DOI 10.1007/s11548-011-0667-0. Citado na página 40.
- MOHAMAD-SALEH, J.; HOYLE, B. S. *et al.* Improved neural network performance using principal component analysis on matlab. **International Journal of the Computer, the Internet and Management**, New Delhi, v. 16, n. 2, p. 1–8, 2008. Citado na página 109.
- MÜLLER, V.; FRITZSCHE, M.; ELKMANN, N. Sensor design and calibration of piezoresistive composite material. *In*: 2015 IEEE SENSORS, 2015, Busan. **Anais[...]**. Busan: IEEE Conference Publications, 2015. p. 1–4. DOI 10.1109/ICSENS.2015.7370488. Citado na página 103.
- NAGANO, H.; BEGG, R. Shoe-insole technology for injury prevention in walking. **Sensors**, Basel, v. 18, n. 5, p. 1468, 2018. DOI 10.3390/s18051468. Citado na página 38.
- NAGYMÁTÉ, G.; ORLOVITS, Z.; KISS, R. M. Reliability analysis of a sensitive and independent stabilometry parameter set. **PloS one**, San Francisco, v. 13, n. 4, p. 1–14, 2018. DOI 10.1371/journal.pone.0195995. Citado na página 51.
- NOVEL. **Novel GmbH, emed®-X highlights**. [S.l.: s.n.], 2008. Disponível em: <http://novel.de/novelcontent/emed>. Acesso em: 12 Set. 2019. Citado 5 vezes nas páginas 32, 38, 44, 105 e 106.
- NOVEL. **Novel GmbH, pedar® system**. [S.l.: s.n.], 2008. Disponível em: <https://www.novel.de/products/pedar/>. Acesso em: 03 Sep. 2019. Citado 2 vezes nas páginas 69 e 105.

PAOLUCCI, T. *et al.* Effect of chèneau brace on postural balance in adolescent idiopathic scoliosis: a pilot study. **Europ. J. Phys. Rehab. Med**, Turin, v. 49, n. 5, p. 649–657, 2013. Citado na página 31.

PAPAIIOANNOU, G. *et al.* A new method for pressure sensor equilibration and conditioning. **Brazilian Journal of Biomotricity**, Itaperuna - RJ, v. 2, n. 3, 2008. Citado na página 92.

PAPAKOSTAS, T. V.; LIMA, J.; LOWE, M. A large area force sensor for smart skin applications. *In*: 2002 IEEE SENSORS, 2., 2002, Orlando. **Anais[...]**. Orlando: IEEE Conference Publications, 2002. p. 1620–1624. DOI 10.1109/ICSENS.2002.1037366. Citado na página 47.

PARK, J. *et al.* The correlation between calcaneal valgus angle and asymmetrical thoracic-lumbar rotation angles in patients with adolescent scoliosis. **Journal of Physical Therapy Science**, Tokyo, v. 27, n. 12, p. 3895–3899, 2015. DOI 10.1589/jpts.27.3895. Citado na página 30.

PARK, J.-H. *et al.* The study of correlation between foot-pressure distribution and scoliosis. *In*: INTERNATIONAL CONFERENCE ON BIOMEDICAL ENGINEERING, 13th., 2008, Singapore. **Anais[...]**. Berlin: Springer, 2009. p. 974–978. ISSN 1680-0737. DOI 10.1007/978-3-540-92841-6_241. Citado na página 30.

PASHA, S.; BALDWIN, K. Are we simplifying balance evaluation in adolescent idiopathic scoliosis? **Clinical Biomechanics**, Oxford, v. 51, p. 91–98, 2018. DOI 10.1016/j.clinbiomech.2017.11.011. Citado na página 30.

PELLEGRINI, E. *et al.* Machine learning of neuroimaging for assisted diagnosis of cognitive impairment and dementia: A systematic review. **Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring**, New York, 2018. DOI 10.1016/j.dadm.2018.07.004. Citado na página 37.

PINHEIRO, H. A.; VILAÇA, K. H. C.; CARVALHO, G. de A. Estabilidade postural, risco de quedas e medo de cair em idosos com neuropatia diabética que realizam exercícios terapêuticos. **Fisioterapia e Pesquisa**, São Paulo, v. 21, n. 2, p. 127–132, 2014. DOI 10.1590/1809-2950/41121022014. Citado na página 51.

RAMIREZ-BAUTISTA, J. A. *et al.* A review in detection and monitoring gait disorders using in-shoe plantar measurement systems. **IEEE Reviews in Biomedical Engineering**, Piscataway, v. 10, p. 299–309, 2017. DOI 10.1109/RBME.2017.2747402. Citado 3 vezes nas páginas 32, 33 e 49.

RAZAK, A. H. A. *et al.* Foot plantar pressure measurement system: A review. **Sensors**, Basel, v. 12, n. 7, p. 9884–9912, 2012. ISSN 1424-8220. DOI 10.3390/s120709884. Disponível em: <http://www.mdpi.com/1424-8220/12/7/9884>. Acesso em: 16 Fev. 2020. Citado 3 vezes nas páginas 33, 43 e 44.

REN, J. ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. **Knowledge-Based Systems**, Amsterdam, v. 26, p. 144–153, 2012. DOI 10.1016/j.knosys.2011.07.016. Citado na página 87.

- REYES, O. C. *et al.* Analysis of spatio-temporal representations for robust footstep recognition with deep residual neural networks. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Piscataway, v. 41, n. 2, p. 285–296, 2019. DOI 10.1109/TPAMI.2018.2799847. Citado na página 39.
- RIVERA, J. *et al.* Self-calibration and optimal response in intelligent sensors design based on artificial neural networks. **Sensors**, Basel, v. 7, n. 8, p. 1509–1529, 2007. ISSN 1424-8220. DOI 10.3390/s7081509. Disponível em: <https://www.mdpi.com/1424-8220/7/8/1509>. Acesso em: 16 Fev. 2020. Citado na página 97.
- ROLTON, D.; NNADI, C.; FAIRBANK, J. Scoliosis: a review. **Paediatrics and Child Health**, Oxford, v. 24, n. 5, p. 197–203, 2014. DOI 10.1016/j.paed.2013.09.014. Citado 2 vezes nas páginas 21 e 22.
- ROSENBAUM, D.; BECKER, H.-P. Plantar pressure distribution measurements. technical background and clinical applications. **Foot and Ankle Surgery**, London, v. 3, n. 1, p. 1–14, 1997. DOI 10.1046/j.1460-9584.1997.00043.x. Citado na página 17.
- RUHE, A.; FEJER, R.; WALKER, B. The test-retest reliability of centre of pressure measures in bipedal static task conditions—a systematic review of the literature. **Gait & Posture**, Amsterdam, v. 32, n. 4, p. 436–445, 2010. DOI 10.1016/j.gaitpost.2010.09.012. Citado 2 vezes nas páginas 51 e 108.
- SAGGIN, B.; SCACCABAROZZI, D.; TARABINI, M. Metrological performances of a plantar pressure measurement system. **IEEE Transactions on Instrumentation and Measurement**, Piscataway, v. 62, n. 4, p. 766–776, 2013. DOI 10.1109/TIM.2013.2245185. Citado 3 vezes nas páginas 96, 104 e 105.
- SANTHIRANAYAGAM, B. K. *et al.* A machine learning approach to estimate minimum toe clearance using inertial measurement units. **Journal of Biomechanics**, Oxford, v. 48, n. 16, p. 4309–4316, 2015. DOI 10.1016/j.jbiomech.2015.10.040. Citado na página 38.
- SANTIAGO, H. A. de *et al.* The influence of vision and support base on balance during quiet standing in patients with adolescent idiopathic scoliosis before and after posterior spinal fusion. **The Spine Journal**, Amsterdam, v. 13, n. 11, p. 1470–1476, 2013. DOI 10.1016/j.spinee.2013.03.027. Citado 2 vezes nas páginas 21 e 30.
- SAXENA, R.; BHAN, R.; AGGRAWAL, A. A new discrete circuit for readout of resistive sensor arrays. **Sensors and Actuators A: Physical**, Amsterdam, v. 149, n. 1, p. 93–99, 2009. DOI 10.1016/j.sna.2008.10.013. Citado 2 vezes nas páginas 54 e 56.
- SCOPPA, F. *et al.* Clinical stabilometry standardization: basic definitions—acquisition interval—sampling frequency. **Gait & Posture**, Amsterdam, v. 37, n. 2, p. 290–292, 2013. DOI 10.1016/j.gaitpost.2012.07.009. Citado 3 vezes nas páginas 51, 90 e 107.
- SILVA, L. M. O. **Uma Aplicação de Árvores de Decisão, Redes Neurais e KNN para a Identificação de Modelos ARMA Não-Sazonais e Sazonais**. Orientador: Prof. Dr. Reinaldo Castro Souza. 2005. 145 f. Tese (Doutorado em Ciências em Engenharia Elétrica) — Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Rio de Janeiro, Brasil, 2005. Disponível em: <https://www.maxwell.vrac.puc-rio.br/colecao.php?strSecao=resultado&nrSeq=7587@1>. Acesso em: 21 ago. 2019. Citado na página 75.

SMOLINSKA, A. *et al.* Current breathomics—a review on data pre-processing techniques and machine learning in metabolomics breath analysis. **Journal of Breath Research**, Bristol, v. 8, n. 2, p. 027105, 2014. DOI 10.1088/1752-7155/8/2/027105. Citado na página 73.

SPI, S. P. I. **Go-tec, Foot Mapping Sensor System**. [S.l.: s.n.], 2018. Disponível em: <https://www.sensorprod.com/pdf/go-tec-foot-plate.pdf>. Acesso em: 23 set. 2018. Citado na página 51.

STASSI, S. **Tactile sensor devices exploiting the tunnelling conduction in piezoresistive composites**. Orientador: Prof. PhD. Candido Fabrizio Pirri. 2013. 144 f. Tese (Doutorado em Física) — Politecnico di Torino, Turim, Itália, 2013. DOI 10.6092/polito/porto/2506202. Disponível em: <https://iris.polito.it/handle/11583/2506202#.XV2qzm5FyUk>. Acesso em: 21 ago. 2019. Citado na página 45.

STASSI, S. *et al.* Wearable and flexible pedobarographic insole for continuous pressure monitoring. *In*: 2013 IEEE SENSORS, 2013, Baltimore. **Anais[...]**. Baltimore: IEEE Conference Publications, 2013. p. 1–4. ISSN 1930-0395. DOI 10.1109/ICSENS.2013.6688460. Citado na página 47.

STASSI, S. *et al.* Flexible tactile sensing based on piezoresistive composites: A review. **Sensors**, Basel, v. 14, n. 3, p. 5296–5332, 2014. DOI 10.3390/s140305296. Citado na página 47.

STMICROELECTRONICS. **NUCLEO-H743ZI**. [S.l.: s.n.], 2018. Disponível em: <https://www.st.com/en/evaluation-tools/nucleo-h743zi.html>. Acesso em: 02 out. 2018. Citado 2 vezes nas páginas 65 e 66.

TAN, A. M. *et al.* Design of low cost smart insole for real time measurement of plantar pressure. **Procedia Technology**, Amsterdam, v. 20, p. 117–122, 2015. DOI 10.1016/j.protcy.2015.07.020. Citado na página 47.

TEKSCAN. **TekScan, ClassicMat Platforms MatScan™ 3150**. [S.l.: s.n.], 2019. Disponível em: <https://www.tekscan.com/products-solutions/systems/matscan>. Acesso em: 12 Jun. 2019. Citado na página 106.

TEKSCAN, I. **MobileMat**. [S.l.: s.n.], 2018. Disponível em: https://www.tekscan.com/sites/default/files/resources/mdl_mobilemat_datasheet_0.pdf. Acesso em: 23 set. 2018. Citado 2 vezes nas páginas 51 e 92.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. Fourth edition. San Diego: Elsevier Inc, 2009. Citado na página 75.

URBAN, M. F. R. **Implementação de um sistema eletrônico para avaliar a distribuição da força na região plantar de pacientes**. Orientador: Prof. Dr. Aparecido Augusto de Carvalho. 2015. 100 f. Tese (Doutorado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista (UNESP), Ilha Solteira, São Paulo, Brasil, 2015. Disponível em: <https://repositorio.unesp.br/handle/11449/134100>. Acesso em: 21 ago. 2019. Citado 3 vezes nas páginas 41, 51 e 52.

URRY, S. Plantar pressure-measurement sensors. **Measurement Science and Technology**, Bristol, v. 10, n. 1, p. R16, 1999. Citado na página 99.

VIEIRA, T.; OLIVEIRA, L.; NADAL, J. Estimation procedures affect the center of pressure frequency analysis. **Brazilian Journal of Medical and Biological Research**, Ribeirão Preto, v. 42, n. 7, p. 665–673, 2009. DOI 10.1590/s0100-879x2009000700012. Citado na página 51.

VOYANT, C. *et al.* Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, Oxford, v. 105, p. 569–582, 2017. DOI 10.1016/j.renene.2016.12.095. Citado na página 37.

WAFAI, L. *et al.* Automated classification of plantar pressure asymmetry during pathological gait using artificial neural network. *In: MIDDLE EAST CONFERENCE ON BIOMEDICAL ENGINEERING*, 2nd., 2014, Doha. **Anais[...]**. Doha: IEEE Conference Publications, 2014. p. 220–223. ISSN 1558-2531. DOI 10.1109/MECBME.2014.6783244. Citado na página 38.

WALCZAK, S.; CERPA, N. Heuristic principles for the design of artificial neural networks. **Information and Software Technology**, Amsterdam, v. 41, n. 2, p. 107–117, 1999. DOI 10.1016/S0950-5849(98)00116-5. Citado na página 80.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415–1442, 1990. DOI 10.1109/5.58323. Citado 2 vezes nas páginas 81 e 82.

WILCZYNSKI, J. *et al.* Body posture and balance reactions in girls and boys aged 12-15 years. **Modern Applied Science**, Toronto, v. 12, n. 4, p. 89, 2018. DOI 10.5539/mas.v12n4p89. Citado na página 30.

WILLIAM, W. *et al.* A review of applications of image analysis and machine learning techniques in automated diagnosis and classification of cervical cancer from pap-smear images. *In: 2018 IST-AFRICA WEEK CONFERENCE (IST-AFRICA)*, Gaborone. **Anais[...]**. Gaborone: IEEE Conference Publications, 2018. p. 1–11. ISSN 2576-8581. Citado na página 37.

WINTER, D. A. Human balance and posture control during standing and walking. **Gait & Posture**, Amsterdam, v. 3, n. 4, p. 193–214, 1995. DOI 10.1016/0966-6362(96)82849-9. Citado na página 34.

WOJTKÓW, M.; SZKODA-POLISZUK, K.; SZOTEK, S. Influence of body posture on foot load distribution in young school-age children. **Acta of Bioengineering and Biomechanics**, Wroclaw, v. 20, n. 2, 2018. DOI 10.5277/ABB-01079-2018-01. Citado 2 vezes nas páginas 18 e 28.

WU, J. Scanning approaches of 2-D resistive sensor arrays: A review. **IEEE Sensors Journal**, Piscataway, v. 17, n. 4, p. 914–925, Feb 2017. ISSN 1530-437X. DOI 10.1109/JSEN.2016.2641001. Citado na página 54.

WU, J.; WANG, L.; LI, J. VF-NSE method measurement error analysis of networked resistive sensor array. **Sensors and Actuators A: Physical**, Amsterdam, v. 211, p. 45–50, 2014. DOI 10.1016/j.sna.2014.02.033. Citado 2 vezes nas páginas 55 e 56.

WU, J.; WANG, L.; LI, J. Design and crosstalk error analysis of the circuit for the 2-D networked resistive sensor array. **IEEE Sensors Journal**, Piscataway, v. 15, n. 2, p. 1020–1026, 2015. DOI 10.1109/JSEN.2014.2359967. Citado 5 vezes nas páginas 55, 57, 59, 61 e 63.

WU, J.-F. *et al.* An improved zero potential circuit for readout of a two-dimensional resistive sensor array. **Sensors**, Basel, v. 16, n. 12, p. 2070, 2016. DOI 10.3390/s16122070. Citado 2 vezes nas páginas 57 e 58.

XU, C. *et al.* Reliability of the footscan® platform system in healthy subjects: A comparison of without top-layer and with top-layer protocols. **BioMed Research International**, London, v. 2017, 2017. DOI 10.1155/2017/2708712. Citado na página 51.

YANG, T. *et al.* Recent advances in wearable tactile sensors: Materials, sensing mechanisms, and device performance. **Materials Science and Engineering: R: Reports**, Amsterdam, v. 115, p. 1–37, 2017. ISSN 0927-796X. DOI 10.1016/j.mser.2017.02.001. Citado na página 44.

YAO, Y. *et al.* Calibration and verification of a thin flexible film hand sensor. *In: INTERNATIONAL CONFERENCE ON ADVANCED MECHATRONIC SYSTEMS (ICAMECHS)*, 2017, Xiamen. **Anais[...]**. Xiamen: IEEE Conference Publications, 2017. p. 501–505. ISSN 2325-0690. DOI 10.1109/ICAMechS.2017.8316525. Citado na página 92.

YILDIZ, B.; BILBAO, J. I.; SPROUL, A. B. A review and analysis of regression and machine learning models on commercial building electricity load forecasting. **Renewable and Sustainable Energy Reviews**, Oxford, v. 73, p. 1104–1122, 2017. DOI 10.1016/j.rser.2017.02.023. Citado na página 37.

ZABJEK, K. F. *et al.* Estimation of the centre of mass for the study of postural control in idiopathic scoliosis patients: a comparison of two techniques. **European Spine Journal**, Heidelberg, v. 17, n. 3, p. 355–360, 2008. DOI 10.1007/s00586-007-0568-7. Citado na página 30.

ZEBIN, T.; SCULLY, P. J.; OZANYAN, K. B. Evaluation of supervised classification algorithms for human activity recognition with inertial sensors. *In: IEEE SENSORS*, 2017, Glasgow. **Anais[...]**. Glasgow: IEEE Conference Publications, 2017. p. 1–3. DOI 10.1109/ICSENS.2017.8234222. Citado na página 39.

ZHAI, T. *et al.* Piezoresistive and compression resistance relaxation behavior of water blown carbon nanotube/polyurethane composite foam. **Composites Part A: Applied Science and Manufacturing**, Oxford, v. 72, p. 108–114, 2015. DOI j.compositesa.2015.02.003. Citado na página 47.