



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA

ANDRESSA HELENA MELO COSTA

USO DE BAROPODÔMETROS E INTELIGÊNCIA ARTIFICIAL PARA
SEPARAÇÃO DE GRAU DE ESCOLIOSE

Ilha Solteira

2023



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA

ANDRESSA HELENA MELO COSTA

**USO DE BAROPODÔMETROS E INTELIGÊNCIA ARTIFICIAL PARA
SEPARAÇÃO DE GRAU DE ESCOLIOSE**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia do Campus de Ilha Solteira – UNESP como requisito para a obtenção do grau de Doutorado.

Orientador: Prof. Dr. Marcelo Augusto
Assunção Sanches

Ilha Solteira

2023

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C837u Costa, Andressa Helena Melo .
Uso de baropodômetros e inteligência artificial para separação de grau de escoliose / Andressa Helena Melo Costa. -- Ilha Solteira: [s.n.], 2023
51 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2023

Orientador: Marcelo Augusto Assunção Sanches

Inclui bibliografia

1. Escoliose idiopática. 2. Diagnóstico. 3. Baropodômetro. 4. Inteligência artificial. 5. Deep learning.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: USO DE BAROPODÊMTROS E INTELIGÊNCIA ARTIFICIAL PARA SEPARAÇÃO DE GRAU DE ESCOLIOSE

AUTORA: ANDRESSA HELENA MELO COSTA

ORIENTADOR: MARCELO AUGUSTO ASSUNÇÃO SANCHES

Aprovada como parte das exigências para obtenção do Título de Doutora em Engenharia Elétrica, área: Automação pela Comissão Examinadora:

Prof. Dr. MARCELO AUGUSTO ASSUNÇÃO SANCHES (Participação Presencial)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. APARECIDO AUGUSTO DE CARVALHO (Participação Presencial)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. ADALBERTO VIEIRA CORAZZA (Participação Presencial)
Faculdade de Medicina / Anatomia Humana / Universidade Federal de Mato Grosso do Sul - UFMS

Dr. JORGE ESTEBAN BLANCO RODRIGUEZ (Participação Virtual)
Instituto Federal de Mato Grosso do Sul - IFMS

Prof. Dr. FABIAN RODRIGO CASTRO FORERO (Participação Virtual)
Programa Ingenieria Electrónica / Universidad Pedagógica y Tecnológica de Colombia

Ilha Solteira, 18 de maio de 2023

RESUMO

O presente trabalho tem como objetivo principal desenvolver um método de diagnóstico e classificação de escoliose idiopática (EI) para diferentes graus, utilizando dados baropodométricos e *Deep Learning*. A Escoliose Idiopática é uma deformação tridimensional da coluna vertebral, cuja deformidade é classificada através do grau de curvatura da coluna e considera-se o diagnóstico de escoliose, quando o desvio lateral é maior que 10°. O diagnóstico é concluído após o exame de Raio-X da coluna e análise de um profissional. Como alternativa ao Raio-X, recentes estudos utilizaram dados de pressão plantar, dados estabilométricos e algoritmos de Inteligência Artificial (AI) para diagnosticar e classificar a EI. Para alcançar o objetivo principal, inicialmente realizou-se a comparação entre dois baropodômetros, o BaroScan, que é um equipamento comercial e o LiebScan. Para o primeiro teste, utilizou-se massas conhecidas. O teste mostrou que os dois equipamentos fornecem as principais variáveis necessárias à avaliação da postura corporal, apesar de existir discrepâncias entre os valores de variáveis e sub-variáveis relacionadas ao deslocamento médio-lateral e anteroposterior. O BaroScan apresentou resultados muito próximos do esperado no teste com massas fixas, ao contrário do LiebScan, que apresentou diferença entre o resultado esperado e o resultado dos testes. Além disso, implementou-se dois modelos utilizando *Convolutional Neural Network* (CNN). O primeiro modelo classificou os sujeitos entre “com escoliose” e “sem escoliose” (CNN-Escoliose) e segundo modelo classificou o grau de escoliose em duas faixas diferentes (CNN-Grau). O modelo CNN-Escoliose alcançou acurácia de 68,67% e o modelo CNN-Grau obteve acurácia de 87,5%. Pela primeira vez, que se tem conhecimento, pode-se classificar o grau da escoliose e classificar a escoliose utilizando o baropodômetro e técnicas de *Deep Learning*.

Palavras-chave: escoliose idiopática; diagnóstico; baropodômetro; inteligência artificial; *deep learning*.

ABSTRACT

The present work has as main objective to develop a method of diagnosis and classification of Idiopathic Scoliosis (IE) for different degrees of deformity, using baropodometric and Deep Learning. The idiopathic Scoliosis is a three-dimensional deformation of the spine, whose deformity is classified by the degree of curvature and is considered the diagnosis of scoliosis when the lateral deviation is bigger than 10° . Your diagnosis is completed after X-ray exam and analysis by professional. As an alternative to X-ray, recent studies have used plantar pressure data, stabilometric data and Artificial Intelligence (AI) algorithms to diagnose and classify IE. To achieve the main goal, initially, a comparison was made between two baropodometers, the BaroScan, which is a commercial equipment and the LiebScan. For the first trial, known masses were used. The trial showed, that the two devices provide the main variables necessary for the evaluation of body posture, despite the existence of discrepancies between the values of variables and sub-variables related to Middle-Lateral and Anteroposterior displacement. O BaroScan tem resultados muito semelhantes ao esperado no teste com massas fixas, ao contrário do LiebScan. In addition, two models were implemented with CNN, one for classification (diagnosis) of scoliosis (CNN-Scoliosis) and another for classification of the degree of scoliosis (CNN-Grade) in two different ranges. The first resulted in an accuracy of 68.67% and the second an accuracy of 87.5%. For the first time, to our knowledge, we can classify the degree of scoliosis and classify scoliosis using Deep Learning techniques.

Keywords: idiopathic scoliosis; diagnosis; baropodometer; artificial intelligence; deep learning.

*Aos voluntários, parte fundamental
desse estudo!*

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais por todo o amor, compreensão e incentivo em todas as etapas de minha vida. Sem o apoio incondicional deles, nada seria possível. Amo-os infinitamente.

Às minhas queridas irmãs, que me acompanharam, mesmo de longe, em todos os momentos desse caminho. Aos meus lindos e amados sobrinhos, Ana Livia e Vinicius, que me enchem de alegria e orgulho.

À minha amada avó, Perpétua, que me ensinou o valor do estudo, da determinação e a força que tem uma mulher. A todos os meus familiares, que estiveram presente nos momentos de angústias e alegrias desse trajeto.

Ao meu amado esposo, Luciano, por toda a compreensão, incentivo e carinho durante este período. Obrigada por todo o apoio e amor.

À Naína, minha amiga de mais longa data, que sempre esteve ao meu lado, apoiando cada passo, me transmitindo confiança e força. À Bruna, pela amizade e apoio.

As minhas amigas queridas, Andréia, Enielma, Izabeli, Camila e Roberta, que a UNESP me deu e que compartilharam das mesmas angústias e alegrias.

À Família LIEB, pelo apoio companheirismo e aprendizado. Vocês me ajudaram a ser uma pessoa e uma profissional melhor.

Ao meu orientador, Professor Marcelo, agradeço pela confiança, apoio e por compartilhar seu conhecimento. Ao professor Aparecido, obrigada por me confiar esse projeto e por todo o auxílio. Aos dois, expresso minha admiração pelos profissionais e pessoas que são.

Agradeço especialmente o professor Adalberto, que tornou possível uma das etapas principais desse estudo.

Aos demais membros da banca, Dr. Fabian Castro, Dr. Jorge Blanco e Dr. Matheus Urban, pela disponibilidade em contribuir com esse trabalho.

À empresa HsTechnology, que nos emprestou o BaroScan, utilizado no estudo.

Ao Hospital Regional da Costa Leste Magid Thomé, pelo apoio e doação dos exames de raio-x.

Por fim, agradeço a confiança que os voluntários depositaram em mim e na pesquisa. Sem eles, não nada seria possível.

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

SUMÁRIO

1 INTRODUÇÃO	8
1.1 DIAGNÓSTICO DA ESCOLIOSE IDIOPÁTICA: MÉTODO OURO	9
1.3 INTELIGÊNCIA ARTIFICIAL E DIAGNÓSTICO DE ESCOLIOSE: MÉTODO ALTERNATIVO	11
1.4 OBJETIVOS	12
1.4.1 <i>Objetivo Geral</i>	12
1.4.2 <i>Objetivos Específicos</i>	12
1.5 ESTRUTURA DO TEXTO	12
2 REFERENCIAL TEÓRICO	13
2.1 POSTUROLOGIA	13
2.1.1 <i>Postura Humana</i>	13
2.1.2 <i>O pé</i>	14
2.1.3 <i>Relação Pressão Plantar X Escoliose</i>	17
2.2 INTELIGÊNCIA ARTIFICIAL	17
2.1 LÓGICA FUZZY	18
2.2 APRENDIZAGEM DE MÁQUINA (MACHINE LEARNING)	19
2.3 APRENDIZADO PROFUNDO (DEEP LEARNING)	20
3 MATERIAIS E MÉTODOS	22
3.1 EQUIPAMENTOS PARA DADOS POSTUROLÓGICOS E ESTABILIMÉTRICOS	22
3.1.1 <i>LiebScan System</i>	22
3.1.2 <i>BaroScan</i>	23
3.2 TESTE DE COMPARAÇÃO DOS EQUIPAMENTOS	23
3.2.1 <i>Teste com Massa Conhecidas</i>	23
3.2.2 <i>Teste com Voluntários</i>	24
3.3 PROTOCOLO PARA COLETA DE DADOS DOS VOLUNTÁRIOS	24
3.3.1 <i>Amostra</i>	25
3.3.2 <i>Análise Radiográfica</i>	26
3.3.3 <i>Baropodometria e Análise de Distribuição de Força</i>	26
3.3.4 <i>Base de dados</i>	28
3.4 MÉTODO DE CLASSIFICAÇÃO	29
3.4.1 <i>Convolutional Neural Network</i>	29
3.4.2 <i>Ferramentas para Programação</i>	32
4 RESULTADOS	33

4.1 COMPARAÇÃO ENTRE OS DOIS BAROPODÔMETROS	33
4.1.1 Testes com Massas Estáticas Conhecidas	36
4.1.2 Imagem da Pressão Plantar	37
4.3 MODELOS DE CLASSIFICAÇÃO	39
4.3.1 Classificação com/sem Escoliose com dados LiebScan e BaroScan	39
4.3.2 Classificação do Grau de Escoliose com Dados do LiebScan e do BaroScan	40
5 CONCLUSÃO.....	42
REFERÊNCIAS	43
ANEXO A - Parecer Consubstancial do CEP.....	477

1 INTRODUÇÃO


A escoliose, conforme mostra-se na Figura 1, é uma alteração tridimensional da coluna vertebral, cuja deformidade é classificada através do grau de curvatura e considera-se o diagnóstico de escoliose, quando o desvio lateral é maior que 10° (SHAKIL; IQBAL; AL-GHADIR, 2014; TROBISCH; SUESS; SCHWAB, 2010).

Sua origem tem diversas causas, podendo ser secundária a outras doenças, como escoliose congênita, escoliose neuromuscular, neurofibrose tipo 1, escoliose síndrômica ou pode ser classificada como idiopática (Escoliose Idiopática), quando não apresenta uma única causa definida (NNADI; FAIRBANK, 2010).

Outra forma de classificar a escoliose é quanto à fase da vida do indivíduo que o diagnóstico é realizado, podendo ser infantil (0 a 3 anos), juvenil (3 a 10 anos) ou adolescente (10 a 18 anos). Na fase adulta, sujeitos com mais de 18 anos, a escoliose idiopática é a continuação da escoliose na adolescência. Na primeira infância e na infância a ocorrência é rara, porém aumenta-se a incidência na fase escolar (SHAKIL; IQBAL; AL-GHADIR, 2014; TROBISCH; SUESS; SCHWAB, 2010).

Igualmente importante, a escoliose pode ser classificada quanto ao ponto de rotação de suas vértebras e isso determina o tipo de curva, que pode ser Cervical (C1-C6), Cervicotorácica (C7-T1), Torácica (T2-T12), Toracolumbar (T12-L1), Lombar (L2-L4) e Lombossacral (L5-S1) (NNADI; FAIRBANK, 2010).

Figura 1 – À esquerda, coluna vertebral normal e à direita, coluna vertebral com escoliose.



Coluna Vertebral Normal


Escoliose

Fonte: Adaptada de BIOLOGY FORUMS (2022).

Comumente, a Escoliose Idiopática (EI) não apresenta sintomas aparentes e graves. Entretanto, aproximadamente $\frac{1}{4}$ dos pacientes apresentam dor. Outro sintoma indicativo de EI é a assimetria, geralmente, apresentada no peito, ombros e quadril (Figura2) (FERREIRA, 2015).

Entretanto, os sintomas físicos não são os únicos a afetarem a qualidade de vida dos indivíduos com EI. A assimetria citada provoca alterações estéticas e, conseqüentemente, pode provocar distúrbios psicossociais como perda de confiança e depressão (COSTA, 2012; FERREIRA, 2015).

Figura 2 - Postura e assimetria do ombro e quadril. À esquerda uma coluna com escoliose e à direita uma coluna normal.



Fonte: Adaptada de HOSPITAL (2022).

Portanto, o diagnóstico deve ser realizado precocemente já que, além de afetar a qualidade de vida, pode agravar a progressão da doença. Na Escoliose Idiopática Infantil (EII), por exemplo, a deformação da coluna pode afetar o desenvolvimento pulmonar da criança (NNADI; FAIRBANK, 2010).

1.1 DIAGNÓSTICO DA ESCOLIOSE IDIOPÁTICA: MÉTODO OURO


Dado que a EI não apresenta uma causa definida, em seu diagnóstico observa-se, primeiramente, a exclusão de doenças primárias que causam escoliose. Nessa etapa, exames neurológicos podem ser solicitados (FERREIRA, 2015). Nesse processo, um questionário inicial avalia o histórico familiar de escoliose, para verificar pré-disposição. Ainda, outros dados são considerados, como ocorrência da menarca em meninas e crescimento rápido na infância e adolescência (TROBISCH; SUESS; SCHWAB, 2010).

Como mencionado, a assimetria é uma característica aparente da escoliose e, portanto, é um aspecto avaliado no processo de diagnóstico. Outro teste clínico aplicado é o Teste de

Adam - *Forward Bending* (Figura 3), que consiste na inclinação do tronco para frente para avaliar a gibosidade, uma proeminência torácica e lombar, que pode surgir como consequência da EI (ALBUQUERQUE et al., 2009; FAIRBANK, 2004; NNADI; FAIRBANK, 2010).

Figura 3 – Teste de Adams para sujeito com escoliose.

Avaliação de flexão para frente



Fonte: Adaptado de CHICK (2022).

Apesar dos testes clínicos mencionados, o diagnóstico de EI é concluído após o exame com Raio-X e análise de um profissional. Esse exame é o parâmetro para a avaliação inicial e a determinação da severidade da deformação (FORERO, 2019; NNADI; FAIRBANK, 2010; TROBISCH; SUESS; SCHWAB, 2010).


Para determinar a gravidade da EI, o método mais utilizado é o cálculo do ângulo de Cobb, como mostrado na Figura 4. (LANGENSIEPEN et al., 2013).

Na definição do ângulo, primeiramente identifica-se as vértebras que delimitam a curva (Apical e Caudal). Em seguida, são traçadas retas paralelas aos planos superiores e inferiores às vértebras limitantes da curva. O ângulo formado pela intersecção das retas é o ângulo de Cobb, que está indicado na Figura 4, é medido manualmente utilizando um goniômetro ou transferidor na radiografia. Além da avaliação quantitativa da escoliose, pode-se avaliá-la quanto à lateralidade da curvatura. Quando a escoliose tem sua convexidade para a direita, diz-se que a escoliose é à direita, quando a convexidade é à esquerda, diz-se que a escoliose é à esquerda. Como exemplo, a escoliose ilustrada na Figura 4 é uma escoliose à direita com ângulo de 89° (CUNHA; ROCHA; CUNHA, 2009; FORERO, 2019; LANGENSIEPEN et al., 2013).

Segundo LANGENSIEPEN et al. (2013) o cálculo do ângulo de Cobb, feito manualmente, é considerado o método padrão ouro. Entretanto, as técnicas de medição estão

avanzando e o método vem se renovando. Em sua revisão, os autores identificam os novos processos, que podem ser divididos em procedimentos assistidos por computador, procedimentos automáticos e procedimentos utilizando aplicativos de *smarthphone*.

Figura 4 – Ângulo de Cobb.



Fonte: Adaptado de ASHER, 2020.

1.3 INTELIGÊNCIA ARTIFICIAL E DIAGNÓSTICO DE ESCOLIOSE: MÉTODO ALTERNATIVO

Como mencionado anteriormente, o diagnóstico da EI é composto por uma série de fases, que é concluído com a análise do exame de Raio-X por um profissional qualificado. Já a severidade da deformidade vertebral é classificada de acordo com o grau de Cobb.

Entretanto, o acompanhamento da evolução e regressão da escoliose requer a realização periódica de exames de Raio-X. Em contrapartida a esse fato, está a necessidade de se minimizar a exposição à radiação (NNADI; FAIRBANK, 2010).

Como alternativa ao Raio-X, recentes estudos utilizaram dados de pressão plantar, establiométricos e algoritmos de Inteligência Artificial (AI) para diagnosticar e classificar a EI. A utilização da pressão plantar é possível pois existe uma relação de causa e consequência com alterações posturais. Essa relação é abordada no Capítulo 2.

Fanfoni (2017) e Fanfoni et al. (2017) classificaram os sujeitos em com e sem EI, utilizando dados de distribuição de força na região plantar e algoritmo de classificação de Rede Neural Artificial (RNA) do tipo ADALINE. Os resultados apresentaram uma acurácia de 91,9%.

Mais recentemente, Castro (2019) utilizou dados baropodométricos e biométricos para classificar sujeitos como acometidos ou não por EI. Como algoritmos de classificação empregou-se uma RNA tipo *multi layer perceptron* e algoritmo de treinamento *trainscg*, que apresentaram acurácia de $75,40 \pm 5,56\%$. O algoritmo *Support Vector Machine* (SVM) também foi utilizado e apresentou acurácia de $74,89 \pm 7,19\%$.

1.4 OBJETIVOS

Diante das considerações apresentadas, este estudo tem os seguintes objetivos geral e específicos.

1.4.1 Objetivo Geral

Desenvolver um método complementar de diagnóstico e classificação de EI para diferentes graus de deformidade, utilizando dados baropodométricos e algoritmo de *Deep Learning*.

1.4.2 Objetivos Específicos

- Realizar análise mecânica comparativa da estabilometria e distribuição de forças entre os baropodômetros BaroScan e LiebScan;
- Coletar dados baropodométricos e biométricos de, aproximadamente, 100 voluntários, utilizando o BaroScan e o LiebScan para contribuir com a criação de um banco de dados de livre acesso;
- Empregar algoritmos de *deep learning* para a classificação do grau de escoliose de voluntários com os dados obtidos pelos dois baropodômetros;
- Comparar os resultados alcançados, tanto com relação aos modelos de IA empregados, quanto com relação aos dados obtidos com os dois baropodômetros.

1.5 ESTRUTURA DO TEXTO

Na sequência, apresenta-se o referencial teórico sobre Inteligência Artificial e conceitos sobre a Postura Humana. Seguindo, os Materiais e Métodos utilizados estão descritos no Capítulo 3. No Capítulo 4, apresenta-se os resultados obtidos e a discussão. Por fim, o Capítulo 5, aborda a conclusão e possível continuação para a pesquisa.

2 REFERENCIAL TEÓRICO

Essa seção se destina a trazer os conceitos que associam a escoliose à distribuição de força plantar e como essa relação possibilita o diagnóstico da escoliose utilizando dados baropodométricos. Para isso, a postura humana e a Inteligência Artificial terão seus conceitos, aqui, abordados.

2.1 POSTUROLOGIA

As definições trazidas aqui serão baseadas nas seguintes literaturas: (BARELA, 2000; BRICOT, 2010; CARINI et al., 2017; CRÉTUAL, 2015; FORERO, 2019; FREITAS JÚNIOR; BARELA, 2004; IVANENKO; GURFINKEL, 2018; LIPPERT, 2013; WINTER, 1995; ZABJEK et al., 2008)

2.1.1 Postura Humana

Os humanos são animais bípedes, que se locomovem sobre o solo com apenas um pé em contato com o chão enquanto caminham. Ou, enquanto parados, se sustentam com os dois pés apoiados ao chão. Em ambas as situações, há um grande desafio do sistema de controle de balanço, para manter o equilíbrio corporal.

Devido a esse desafio, é grande o interesse em estudar como o corpo humano se mantém em pé, já que 2/3 de sua massa corporal está localizada à 2/3 da sua altura do chão, gerando assim, uma constante necessidade de atuação do sistema de controle postural.

A postura é definida como uma posição que mantém o balanço do corpo com o máximo de estabilidade, mínimo de consumo energético e o mínimo de demanda das estruturas anatômicas. Uma outra definição é a manutenção do equilíbrio na posição estática e durante os movimentos.

A estabilidade postural precisa ser mantida mesmo sob a ação da gravidade, forças externas e forças resultantes do próprio movimento. Para isso, é necessária uma interação constante entre informações sensoriais e motoras, mesmo durante a posição ereta. Essas informações ocorrem tanto entre os segmentos corporais, quanto com relação aos segmentos e ao ambiente.

As principais informações sensoriais são geradas pelos sistemas visual, vestibular e somatossensorial. Esta última, relaciona informações tanto entre a posição de um segmento corporal com outro, quanto entre os seguimentos corporais e o ambiente. Sendo o segmento corporal ou segmento postural qualquer parte do corpo que transfira carga.

Portanto, a comunicação entre os sistemas citados e os segmentos corporais ocorrem com a finalidade de estimar as forças agindo no corpo, para que a atividade muscular ocorra de maneira apropriada e se mantenha a postura corporal. Essa interação ocorre mesmo quando o corpo está, aparentemente, parado, pois os micromovimentos atuam constantemente para manter a posição e o equilíbrio.

Dessa forma, um corpo com a postura correta tem seus segmentos corporais alinhados. Para que isso ocorra, os micromovimentos são controlados pelo Sistema Tônico Postural (STP), que é um sistema complexo e atua constantemente nos movimentos como levantar-se, sentar-se e manter-se em pé. O STP é composto por computador central, efetores e captadores.

O computador central recebe as informações dos captadores e ajusta o equilíbrio através dos efetores. O computador central é composto por núcleos vestibulares, gânglios da base com os núcleos cinzentos e o corpo estriado, cerebelo, sistema reticulatório com os núcleos mesencefálicos e núcleos rubros e colículo (BRICOT, 2010).

No sistema de execução o efector final é o músculo estriado. De todos os músculos, os músculos posturais, além de serem efetores, são também captadores. Os principais captadores são:

- Pés: informações variadas podem vir do pé, já que é um elemento proprioceptivo e exteroceptivo;
- Olho: A visão possui função fundamental equilíbrio postural (CARVALHO; ALMEIDA, 2019);
- Aparelho manducatório: envolve uma série de estruturas como os ossos do pescoço, face, crânio e dentes.


Como mostrado, o sistema tônico postural é uma complexa interação entre múltiplas funções. Sua atividade começa antes mesmo do início do movimento e segue atuante durante e após.

2.1.2 O pé

Os pés, compostos por ossos, ligamentos e músculos, são elementos fundamentais na marcha humana. Além disso, em conjunto com o olho é parte importante na manutenção da postura, devido a grande quantidade de informações advindas de seus receptores. Sua estrutura é dividida em 3 grandes partes. O retropé, constituído pelo tálus e calcâneo é a primeira parte que toca o chão durante a fase de apoio da marcha. O mediopé é formado pelos ossos navicular, cuboide e os três ossos cuneiformes. Sua estrutura garante estabilidade e mobilidade ao transferir a carga do retropé para o antepé. Esse, por sua vez, é composto pelos ossos metatarsais

e pelas falanges e é a última parte a tocar o solo na fase de apoio da marcha. Essa estrutura está ilustrada na Figura 6.

Figura 6 – Partes funcionais do pé.



Fonte: LIPPERT (2013)


Na marcha, o pé é responsável pelo contato com o solo e sua função não se resume em absorver o impacto. O pé se adapta às variações do chão e impulsiona o corpo para realizar o próximo passo. Para ocorrer a sustentação do peso, os pés são organizados em três arcos, como mostrado na Figura 7.

A “chave de abóboda” é parte essencial do arco e, geralmente, está em seu topo. Durante a sustentação de peso, o arco pode sofrer um leve abaixamento que retorna ao seu estado padrão ao se retirar o peso. A chave possui três arcos, dois longitudinais e um transversal.

As alterações referentes ao arco podem causar anormalidades nos pés. Essas anormalidades são divididas em dois grandes contextos, os pés planos e os pés cavos. O primeiro é causado pelo desabamento do arco medial do pé e está associado às alterações posturais, que ocorrem de baixo para cima. Essas perturbações rotacionam os eixos tibiais e femorais para dentro e, conseqüentemente, rotaciona a cintura pélvica anteriormente no plano sagital. Por outro lado, o pé cavo, que tem arco medial elevado, causa rotação externas dos eixos tibiais e femorais e rotação da pelve.


Dessa forma, tanto os pés planos quanto os pés cavos podem causar alterações posturais. No caso do pé plano, é possível que surja uma hiperlordose. Já o pé cavo, pode deixar o dorso plano. A Figura 8 resume as alterações descritas.

Figura 7 – Arcos plantares, vista superior e lateral do pé direito.



Fonte: Kapanji (2000).

Figura 8 - Deformidades dos pés e consequentes alterações posturais.



Fonte: Adaptado de Castro (2019) e Bricot (2010).

2.1.3 Relação Pressão Plantar X Escoliose

Como descrito anteriormente, as deformidades dos pés podem causar alterações posturais. Portanto, a avaliação dessa estrutura pode levar a um indicativo de deformidades na coluna vertebral, como a escoliose.

Baseado nesse fato, diversos estudos determinaram a relação da escoliose e da distribuição da força plantar. Em 1997, um estudo (DANGERFIELD et al., 1997) mostrou a diferença de pressão plantar entre o pé direito e pé esquerdo em indivíduos com escoliose.

Também referente à distribuição de força plantar, em 2009, um estudo relacionou a escoliose, em adultos, com o desequilíbrio corporal identificado através da diferença de pressão entre os pés (PARK et al., 2009). Além disso, os resultados mostraram tendência de aumento da diferença da pressão entre os pés, à medida que o grau de escoliose também aumenta.

A mesma relação pôde ser observada na Escoliose Idiopática Adolescente (EIA). No estudo de Lee, Kim e Kim (2014), a região de pressão plantar dos pés dos pacientes com EIA aumentou significativamente em relação à adolescentes saudáveis, mostrando como a EIA afeta os parâmetros de pressão plantar dos pés (LEE; KIM; KIM, 2014).

Essa correlação, entre os dados estabiliométricos e biométricos com a escoliose, foi apresentada por Castro et al. (2017).

2.2 INTELIGÊNCIA ARTIFICIAL


Desde o surgimento da informática, algoritmos e modelos matemáticos vem sendo empregados na solução de diversos dilemas, que são passíveis de modelagem. Entretanto, problemas biomédicos são de difícil modelagem, por serem complexos, em sua maioria. Como efeito, novas técnicas foram desenvolvidas para lidar com esse tipo de questão. Uma das primeiras aplicações em biomédica, foram os métodos de reconhecimento de padrão e classificação de padrão. Na década de 1970, surgiu o interesse na aplicação de Inteligência Artificial na medicina (HUDSON; COHEN, 1999).

A Inteligência Artificial (IA) é uma das ciências mais recentes, que pode sintetizar e automatizar diversas atividades e tarefas dependentes do intelecto. Portanto, tem grande capacidade em diversas áreas, cuja racionalidade humana é essencial.

As definições de IA são diversas, mas segue quatro linhas, divididas entre raciocínio e comportamento humano. De forma geral, são sistemas que pensam e/ou atuam como seres humanos (HONÓRIO, 2010).

Dentre as diversas áreas de emprego dessa ferramenta, a medicina reúne diversos estudos em distintos campos, utilizando técnicas para o diagnóstico de doenças ou condições

clínicas possíveis em um paciente (KAUR et al., 2020). O diagnóstico (Figura 9) é o método para identificar uma doença a partir de seus sintomas e sinais. Sendo esse, um processo complexo por depender de vários parâmetros que devem ser avaliados por um profissional. Portanto, o diagnóstico empregando técnicas de IA pode apoiar o profissional de saúde nessa fase do tratamento de um paciente (KAUR et al., 2020).




Fonte: Adaptado de Kaur et al. (2020)

No estudo de Kaur et al. (2020) há uma revisão da literatura referente à utilização de técnicas de IA para diagnóstico de doenças. Como resultado, apresentou as principais técnicas utilizadas no diagnóstico, que foram divididas entre lógica nebulosa (*fuzzy logic*), aprendizagem de máquina (*machine learning*) e aprendizagem profunda (*deep learning*).

A Figura 10 mostra como se relaciona o Machine Learning (ML) e o Deep Learning (DL) com a Inteligência Artificial.

Figura 10 – Localização do ML e do DL dentro da IA.



Fonte: Adaptado de Chollet (2018).

2.1 LÓGICA FUZZY

A lógica nebulosa foi apresentada pela primeira vez em 1965 por Lotfi A. Zadeh (GOGUEN, 1973). Sua teoria combina o conhecimento e experiência do profissional, o processo de decisão humana e um conjunto de regras simples (NOGUEIRA, 2013).

Diferentemente do conjunto *crisp*, no processo da lógica *fuzzy*, os elementos de entradas são divididos em conjuntos *fuzzy*, no qual cada elemento pode pertencer parcialmente a mais de um conjunto. (ROUVRAY, 1996; ZADEH, 1988).

Um processo de lógica *fuzzy* pode ser resumido das seguintes etapas (KAUR et al., 2020; ROUVRAY, 1996; ZADEH, 1988):

1. Fuzzificação: nessa etapa as entradas *crisp* são transformadas em entradas *fuzzy*. Ou seja, as entradas são codificadas em graus de pertinência, de acordo com o conhecimento e experiência do especialista.
2. Sistema de inferência: ou regras *fuzzy* fornecem a descrição qualitativa do sistema na forma de regras compostas por termos antecedente (**se**) e consequente (**então**) e por operações básicas como como União e Interseção.
3. Aplicação das regras: conhecidos como controladores *fuzzy*, esses são os responsáveis por aplicar as regras baseadas nos bancos de dados. Os controladores mais utilizados são o MANDANI e o controlador SUGENO.
4. Defuzzificação: nessa etapa o conjunto *fuzzy* resultante é transformado para um valor escalar.

Essa é uma técnica que pode ser aplicada, quando o conhecimento humano pode ser traduzido em classes e regras difusas. Entretanto, em alguns sistemas as informações não estão disponíveis para ser apresentadas em forma de conjuntos *fuzzy*, mas podem ser representadas utilizando-se algoritmos de aprendizagem de máquina.

2.2 APRENDIZAGEM DE MÁQUINA (MACHINE LEARNING)

Na aprendizagem de máquina, o algoritmo possibilita que a máquina “aprenda” a realizar tarefas por meio de treinamento, que pode ser supervisionado ou não supervisionado (KAUR et al., 2020; KUBAT, 2017). Diferentemente da lógica *fuzzy*, em que as regras precisam ser definidas por um especialista, os algoritmos de *Machine Learning* (ML) podem aprender essas regras por si. Esse processo é chamado de treinamento (ESTEBAN, 2020).

O desenvolvimento do algoritmo segue a seguinte metodologia (KAUR et al., 2020; KUBAT, 2017):

1. Aquisição de dados: a primeira etapa do processo é uma das mais importantes, já que os dados são elementos cruciais para a tomada de decisão (KUBAT, 2017).
2. Condicionamento de dados: nesta etapa os dados brutos são processados para que informações relevantes sejam extraídas.
3. Escolha do modelo: escolha de um algoritmo para representar os dados pré-processados.

4. Treinamento: o algoritmo precisa ser treinado para que ele “aprenda” como tomar as decisões.
5. Avaliação do modelo: os resultados apresentados pelo modelo são comparados com os objetivos definidos inicialmente.
6. Ajuste de parâmetros: altera-se, alguns parâmetros do modelo como a taxa de aprendizagem e os valores de inicialização, dependendo da avaliação dos resultados.
7. Teste real: o modelo é testado com dados reais e sua saída é comparada a resultados apontados por especialistas.

Como visto, nas técnicas de ML os dados precisam ser, anteriormente, pré-processados por meio de algoritmos e suas características precisam ser extraídas com o auxílio de um especialista.


2.3 APRENDIZADO PROFUNDO (DEEP LEARNING)

O aprendizado profundo, ou *Deep Learning*, diferentemente do ML, possibilita a extração dos dados úteis sem a intervenção humana. Esse método atua como o funcionamento do cérebro humano, pois cria padrões que serão usados na tomada de decisão (ESTEBAN, 2020; KAUR et al., 2020). A Figura 11 ilustra a diferença básica de ML e DL.

O *Deep Learning* é um subcampo do ML. Sua estrutura é composta por vários níveis de representação, resultante da composição de módulos simples não lineares. Cada seguimento transforma sua entrada para aumentar a seletividade e a invariância da representação (LECUN; BENGIO; HINTON, 2015). Portanto, o termo *deep* (profundo) está associado a quantidade de camadas que um modelo possui, ou seja, quanto mais camadas, mais profundo esse será. Sendo que, o número de camadas pode variar de dezenas até centenas (CHOLLET, 2018).

Os modelos de camadas mais utilizados são do tipo Redes Neurais (RN), estruturas matemáticas que aprendem representações a partir de dados. Devido à quantidade de camadas, um modelo pode ter milhões de parâmetros (pesos), que são ajustados por algoritmo de retro-propagação até que as saídas tenham valores desejados. Na Figura 12 representa-se um diagrama geral de DL e o processo de ajuste de parâmetros da RN (CHOLLET, 2018; ESTEBAN, 2020).


Figura 11 – Diagrama da diferença básica entre ML e DL.



Fonte: Adaptado de Kaur et al. (2020)

O DL tem sua utilização estimulada em diversos campos, mas em especial no diagnóstico por imagem. Apesar de existirem muitas ferramentas disponíveis para diagnóstico, há sempre um grau de incerteza devido à grande variedade de atributos disponíveis para a análise dos profissionais e, ao contrário do diagnóstico comum, a utilização de DP possibilita selecionar os atributos mais relevantes para o diagnóstico (KAUR et al., 2020). Entretanto, deve-se salientar que a DL não elimina completamente a incerteza e a possibilidade de erros de diagnóstico, esta é uma ferramenta utilizada no diagnóstico médico, que é um processo complexo envolvendo diversos fatores.

Figura 12 – Diagrama de fluxo de algoritmo de DL e atualização de pesos.



Fonte: Adaptado de Esteban (2020) e Chollet (2018)

3 MATERIAIS E MÉTODOS

Esta seção serão apresenta os métodos e materiais utilizados neste estudo.

3.1 EQUIPAMENTOS PARA DADOS POSTUROLÓGICOS E ESTABILIOMÉTRICOS


Nesta pesquisa, foram utilizados dois equipamentos para a coleta das informações, o baropodômetro LIEBScan *System* e o baropodômetro comercial BaroScan da HS *Technology*.

O baropodômetro pode medir a distribuição de força plantar de indivíduos, sendo utilizado para realizar avaliações de movimento, postural e estabiliométricas sobre o equipamento. Além disso, o equipamento também possui *software* para realizar avaliações estáticas e dinâmicas.

3.1.1 LiebScan *System*

É um baropodômetro composto por *hardware* e *software* desenvolvido por Castro (2019) no Laboratório de Instrumentação e Engenharia Biomédica da Faculdade de Engenharia de Ilha Solteira e já foi utilizado anteriormente com 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. O LiebScan (Figura 13) possui uma matriz com 2034 sensores de força e seu *software* possibilita a visualização das avaliações estáticas e dinâmicas.

Figura 13: LiebScan.



Fonte: Castro (2019).

3.1.2 BaroScan

O baropodômetro BaroScan da empresa HS *Technology* é uma plataforma composta por 4096 sensores e possibilita a realização de exames baropodométricos estáticos, dinâmicos e com vídeo. A Figura 14 mostra o BaroScan.

Figura 14: BaroScan.



Fonte: BaroScan (2021).

3.2 TESTE DE COMPARAÇÃO DOS EQUIPAMENTOS

Para inteirar-se do comportamento dois equipamentos em avaliações estáticas, foram realizados testes com massas conhecidas (anilhas) de 2,34 kg, 4,23 kg, 6,25 kg e 8,34 kg, pois indivíduos, mesmo em posição estática, apresentam micromovimentos e isso invalidaria as respostas. Posteriormente realizou-se teste com 3 voluntários.

3.2.1 Teste com Massa Conhecidas

Para a aplicação da carga, inicialmente, determinou-se a área útil de cada equipamento. Posteriormente, a carga foi aplicada no centro da área útil de cada equipamento e no ponto médio dos quatro quadrantes. O teste foi realizado 3 vezes em cada área. A duração de cada coleta foi de 10 s. Na Figura 15 está ilustrado um exemplo de carga no centro do primeiro

quadrante. Os testes estáticos tinham o objetivo de avaliar as características de cada equipamento.

Figura 15 – Exemplo de posicionamento da carga fixa.



Fonte: Da autora.

3.2.2 Teste com Voluntários

Na execução desse teste, participaram 3 voluntários, 2 do sexo masculino e 1 do sexo feminino, com idades entre 24 e 36 anos.

Durante o teste os voluntários permaneceram em posição ortostática, olhando um alvo fixo a aproximadamente 1,5m da parede, durante 40s.

Nesta etapa, as informações dos voluntários foram utilizadas para identificar as características dos equipamentos e informações por eles fornecidas, sob condições reais de utilização.

3.3 PROTOCOLO PARA COLETA DE DADOS DOS VOLUNTÁRIOS

Protocolo para coleta de informações dos voluntários para o banco de dados e implementação de IA.

Os dados baropodométricos e biométricos foram autorizados pelo comitê de ética em pesquisa da Faculdade de Ciência e Tecnologia do Campus de Presidente Prudente. O parecer número 5.349.447 está anexado ao final da tese (Anexo A – Parecer Consubstancial do CEP).

Para o desenvolvimento deste estudo foi utilizada uma amostra de 79 voluntários, sendo 56 do sexo feminino e 23 do sexo masculino. A idade média é de 39,17 anos (12 – 87 anos). Entretanto, a baropododometria com LiebScan não foi realizada com todos os voluntários

devido à indisponibilidade do equipamento em todas as coletas. Sendo assim, há um total de 67 amostras com dados dos dois equipamentos.

3.3.1 Amostra

Participaram da pesquisa, 79 indivíduos, de ambos os sexos, em diferentes faixas etárias. Os voluntários podiam ou não possuir patologia que envolva problemas de estabilidade ou de controle corporal como Hemiplegia e Parkinson. Além disso, os voluntários podiam apresentar problemas posturais, como escoliose nos diferentes graus, ou patologias associadas com membros inferiores, principalmente, relacionados aos pés como pé plano, cavo, etc. Os voluntários serão divididos em 4 grupos e 8 subgrupos:

- G1: voluntários com desvio (ângulo de Cobb) menor que 10 (sem escoliose);
 - G1c: com escoliose em “C”;
 - G1s: com escoliose em “S”.
- G2: voluntários com $10^{\circ} \leq \text{Coob} \leq 18^{\circ}$;
 - G2c: com escoliose em “C”;
 - G2s: com escoliose em “S”.
- G3: voluntários com $19^{\circ} \leq \text{Coob} \leq 28^{\circ}$;
 - G3c: com escoliose em “C”;
 - G3s: com escoliose em “S”.
- G4: voluntários com $29^{\circ} \leq \text{Coob} \leq 38^{\circ}$;
 - G4c: com escoliose em “C”;
 - G4s: com escoliose em “S”.

Embora o projeto seja abrangente em termos de inclusão de voluntários, foram empregados os seguintes critérios para participar da pesquisa.

Critérios de Inclusão

- Os participantes devem apresentar peso igual ou inferior a 120 kg;
- Ter disponibilidade de comparecer aos testes, que serão previamente agendados;
- Os participantes devem ser capazes de permanecer em pé sobre o baropodômetro e na área ativa do equipamento;

- Ter 14 anos ou mais;
- Assinar o Termo de Consentimento Livre e Esclarecido (TCLE);
- Voluntários com idade inferior a 18 anos com TCLE assinado pelos responsáveis.

Critérios de Exclusão

- Desistência do voluntário em qualquer fase da pesquisa;
- Caso o voluntário passe a apresentar doença crônica ou aguda, que o impeça de permanecer em pé sobre o baropodômetro e na área ativa do equipamento.

3.3.2 Análise Radiográfica

Em caso de voluntários com escoliose, a análise de radiografia da coluna vertebral, permitiu conhecer seu grau, através da medição do ângulo de Coob. Portanto, aquele voluntário que não possuía uma radiografia recente, foi submetido a um exame radiográfico da região toraco-lombar.

Todos os voluntários realizaram exames radiográficos, como descrito anteriormente. Foram realizadas 5 radiografias, para analisar a coluna vertebral (cervical, torácica e lombar), nas vistas médio-lateral e anteroposterior. Entretanto, apenas a vista médio-lateral foi utilizada para o diagnóstico da escoliose, como mostra a Figura 16. O ângulo de Cobb foi mensurado nas radiografias dos voluntários por um fisioterapeuta, que também classificou a escoliose quanto ao tipo de curvatura (S ou C), direção (esquerda ou direita) e localização (cervical, torácica ou lombar).


3.3.3 Baropodometria e Análise de Distribuição de Força

Foi avaliado o mapeamento da distribuição de pressão nos pés (Figura 18) e o centro de pressão dos voluntários, utilizando o BaroScan e o LiebScan.

Para realizar a avaliação, foram efetuadas coletas utilizando os dois equipamentos, seguindo uma sequência que envolve, primeiramente, obter os dados com Olhos Abertos (OA) durante o período de 30 segundos. Para isso, o voluntário permaneceu em posição ortostática, observando um alvo fixo posicionado a uma distância de aproximadamente 1,5 metro.

Ainda sobre o equipamento, avaliação foi realizada novamente com o voluntário posicionado, agora com os Olhos Fechados (OF), permanecendo novamente durante 30 segundos na posição ortostática.


Figura 16 – Imagens radiográficas de um voluntário com escoliose e o ângulo de Cobb correspondente. a) Escoliose toracolumbar em C à esquerda com 29,68°. b) Escoliose cervicotorácica em C à direita com 22,6°.



Fonte: Da autora.

Após gerar as imagens, elas foram salvas em pastas como mostra a Figura 17. A divisão de arquivos em diretórios (pastas) é a maneira de informar ao algoritmo a qual classe pertence cada imagem a ser utilizada, para treinamento ou validação. O endereço de cada pasta é informado para o modelo nas linhas do código.

Figura 17 – Esquema de classificação das imagens por pastas, para fornecer as entradas dos modelos de classificação.




Fonte: Da autora.

Como mencionado anteriormente, este estudo utilizou as imagens baropodométricas para a classificação da escoliose utilizando CNN. Para isso, portanto, foi necessário salvar os

dados de pressão plantar em arquivos de imagem. O próprio *software* LiebScan possibilita, gerar suas imagens, mas o BaroSys não tem essa funcionalidade. Os dados de imagem baropodométricas são salvos em arquivos do tipo PDF, portanto, foi necessário de convertê-los em imagens utilizando um aplicativo de conversão de documentos para imagens do tipo JPG.

Figura 18 - Mapeamento da distribuição de pressão nos pés.



Fonte: Da autora.

3.3.4 Base de dados

Os dados baropodométricos e biométricos foram adquiridos através dos testes descritos anteriormente,

Para o desenvolvimento deste estudo foi requerida uma amostra de 79 voluntários. Sendo 56 do sexo feminino e 23 do sexo masculino. A idade média é de 39,17 anos (12 – 87 anos). Entretanto, a baropododometria com LiebScan não foi realizada com todos os voluntários, sendo assim, há um total de 67 amostras. Na Tabela 1, resume-se os dados antropométricos dos voluntários, bem como o resultado da análise radiográfica.

Tabela 1 – Dados antropométricos dos voluntários.

Idade dos Voluntários	$\bar{X} = 39,87; \delta = 26,52$
Sexo dos Voluntários	F = 72,6%, M = 27,4%
Voluntários com escoliose	69,6 (%)
Voluntários no grupo G2c	35,13 (%)
Voluntários no grupo G2s	21,62(%)
Voluntários no grupo G3c	4,05 (%)
Voluntários no grupo G3s	5,4 (%)
Voluntários no grupo G4c	0 (%)
Voluntários no grupo G4s	1,35 (%)

Obs.: A idade de 3 voluntários não foi especificada.

Fonte: Da autora.

3.4 MÉTODO DE CLASSIFICAÇÃO

Como mencionado, foram utilizados 2 baropodômetros diferentes para coleta de dados dos voluntários. Entretanto, o BaroScan só disponibiliza a pressão plantar completa, ou seja, em toda a áreas dos pés, em forma de imagem com escalas de cores, para diferenciar as diferentes pressões. Esse fato foi decisivo para a escolha do classificador, pois o algoritmo escolhido deveria ser capaz de classificar os dados a partir da imagem plantar dos voluntários.

Portanto, visando alcançar o objetivo desse estudo, optou-se por utilizar o algoritmo de *Deep Learning Convolutional Neural Network* (CNN) para a classificação da EI e de seu grau.

3.4.1 Convolutional Neural Network

A CNN é um algoritmo de classificação de dados, que apesar de ser usada há décadas, só passou a ser considerada como *Deep Learning* recentemente (RODRIGUES, 2021). Sua arquitetura é inspirada na visão biológica (LI et al., 2022) e é usada, principalmente, para processar dados do tipo matriz de pixels 1-D e 2-D (imagens) (MEHLIG, 2021).

É um dos algoritmos mais representativos do DL devido a algumas vantagens em relação aos modelos *fully connected* como: 1) convergência mais rápida, pois possui conexão local e portanto, parâmetros reduzidos; 2) parâmetros reduzidos devido ao compartilhamento de pesos; 3) A camada de *pooling* permite a otimização dos dados ao selecionar apenas os úteis. A principal diferença da CNN é extrair as características de interesse usando estruturas de convolução (LI et al., 2022). Portanto, seu nome origina-se de uma operação matemática linear descrita em (1), geralmente, empregada para eliminar ruídos em dados de interesse.


$$s(t) = (x * w)(t) \quad (1)$$

Na qual, x é a entrada, w é o *kernel* (filtros) e a saída $s(t)$ é o mapa de características de interesse para a classificação (MEHLIG, 2021; RAWAT; WANG, 2017). A Figura 19 ilustra a topologia de uma CNN, que é composta, de maneira geral, por estágio de convolução e por estágio *fully connected layers* (camadas totalmente conectadas) (RAWAT; WANG, 2017). A seguir apresenta-se a descrição das etapas de classificação usando CNN:

- a) Camada de Convolução: Esta é a primeira fase do estágio de convolução. Sendo essa camada fundamental para a extração das características essenciais à classificação. Nessa etapa, a matriz de *kernel* é aplicada à matriz de tensor (entrada), como ilustra a Figura 20, para se obter o mapa de características. Diversos *kernels* são aplicados para se obter diferentes características do tensor de entrada. Tais filtros são definidos por dois parâmetros,


o primeiro determina seu tamanho e o segundo a quantidade de características que devem ser extraídas (MEHLIG, 2021; YAMASHITA et al., 2018);

Figura 19 – Topologia completa de uma CNN.



Fonte: Adaptado (RAWAT; WANG, 2017).


Figura 20 – Aplicação do *kernel* ao tensor.



Fonte: Adaptado (YAMASHITA et al., 2018).


- b) Camada de *Pooling*: Esta é a segunda fase do estágio de convolução e sua função é reduzir a dimensão do mapa de características, seja generalizando, ou consolidando suas características. As operações de *pooling* mais comuns são a *Max Pooling*, que extrai valores máximos em cada *patch* (pacote) do mapa de entrada e a *Global Average Pooling*, que extrai a média em cada *patch* do mapa de características. A Figura 21 mostra a diferença entre as duas funções (ESTEBAN, 2020; MEHLIG, 2021);
- c) *Fully Connected Layers*: Após a saída da etapa de convolução, os dados são submetidos ao *flattening*, que os transforma em uma matriz de uma dimensão (1D), ou seja, um vetor, para que possam ser conectados às *fully connected layers*, também conhecidas como camadas densas. Nessa topologia, todas as saídas de uma camada estão conectadas a todas as entradas da próxima camada por pesos de aprendizagem (Figura 22) e são seguidas por funções de ativação. As camadas densas são responsáveis por calcular a probabilidade que cada entrada tem de pertencer à determinada classe (YAMASHITA et al., 2018), ou seja, interpretam as características extraídas no estágio anterior (RAWAT; WANG, 2017). Sua saída possui tantos nós quanto a quantidade de classes possíveis (YAMASHITA et al., 2018).

Figura 21 – Diferença entre as funções *Max Pooling* e *Global Average Pooling*,



Fonte: Adaptado (RAWAT; WANG, 2017).

Figura 22 – Ilustração esquemática do estágio de convolução e do estágio de camadas densas.



Fonte: Adaptado (LI et al., 2022).

3.4.2 Ferramentas para Programação

Para o desenvolvimento do modelo, utilizou-se o ambiente de programação (IDE) *Spyder*. Esse IDE foi desenvolvido para a linguagem *Python* (IDE, 2023), que foi a linguagem de programação utilizada neste trabalho, principalmente, pela grande quantidade de bibliotecas disponíveis para a análise de dados.

Grande parte das funções utilizadas no desenvolvimento dos modelos de classificação desse estudo, são da *TensorFlow*, que é uma biblioteca de código aberto, disponível em diversas linguagens de programação, para o desenvolvimento de códigos de computação numérica (TENSORFLOW, 2023).

Além do *TensorFlow*, utilizou-se a *Application Programming Interface* (API) Keras. Essa é uma API de alto nível, e de fácil aplicação, criada para treinar modelos de *Deep Learning* através de uma prototipagem rápida (KERAS, 2023).

4 RESULTADOS


Como mencionado, foram realizados testes com a finalidade de conhecer as características dos equipamentos que serão utilizados. Os resultados mostram como são exibidas as informações produzidas por cada um dos equipamentos através de seus *softwares*. Posteriormente, é apresentada uma comparação entre os principais parâmetros de informações establiométricas fornecidas.

4.1 COMPARAÇÃO ENTRE OS DOIS BAROPODÔMETROS

As imagens a seguir mostram as principais informações disponibilizadas pelo *software* de cada equipamento. Primeiramente, exibe-se as informações referentes ao BaroSys, *Software* do BaroScan. Posteriormente, as informações obtidas pelo LiebScan serão apresentadas.

Na Figura 23 é possível observar a tela inicial de um exame do BaroSys. Nela, identifica-se os parâmetros de pressão média e máxima, distribuição de pressão dos pés, além de visualizar a imagem bidimensional da distribuição de pressão nos pés com escala de cores, sendo que, quanto mais próximo da cor vermelha, maior é a pressão naquele local.


Figura 23 – Tela inicial do BaroSys.



Fonte: Da autora.

A Figura 24 exibe dados referentes às informações temporais de amplitude de deslocamento, velocidade e área de deslocamento do centro de pressão. E a Figura 25 é a tela do *software* com os parâmetros de amplitude de oscilações médio-lateral (latero-lateral/ML) e antero-posterior (AP) ocorridas ao longo do teste realizado.

Figura 24 – Tela de centro de pressão.



Fonte: Da autora.

Figura 25 – Tela de Oscilações temporais.



Fonte: Da autora.

As Figuras de 26 a 28 foram obtidas por meio de capturas de tela obtidas do *software* LiebScan. A Figura 26 refere-se à tela inicial do software em que é possível visualizar o resultado de um exame, podendo-se observar dados de anamnese, distribuição de peso entre os dois pés, peso em quilograma exercido na plataforma, força total em Newtons e imagem bidimensional da distribuição de pressão nos pés com escala de cores, sendo que, quanto mais próximo da cor vermelha, maior é a pressão naquele local.

Figura 26 – Tela inicial do LiebScan.

The screenshot shows the initial interface of the LiebScan software. On the left, there is a heatmap representing the pressure distribution on a foot, with axes labeled from 0 to 384. A color scale on the right indicates pressure values from -98,52 to -49,26. The top right corner displays the patient's name, 'Andressa H M Costa', and the test date, '19/07/2021'. Below this, fields for age (30), weight (60), height (1,68), laterality (Destro), and sex (F) are visible. A section for observations is present, along with buttons for 'Exportar Distribuição', 'Exportar Pressões', 'Estabilimetria', and 'VOLTAR'. The bottom right corner features the 'unesp' logo.

Fonte: Da autora.

A Figura 27 é a tela com dados estabiliométricos, no qual são disponibilizadas informações como amplitude e deslocamento (médio-lateral e anteroposterior), velocidade (médio-lateral e anteroposterior), amplitude (médio-lateral e anteroposterior), centro de pressão e dados de anamnese.


Figura 27 – Tela de estabilimetria do LiebScan.

The screenshot displays the stabilometry screen of the LiebScan software. It shows a comprehensive set of data for the patient 'Andressa H M Costa' on '19/07/2021'. The interface is divided into several sections: patient data (age, weight, height, laterality, sex), observations, center of pressure (ML: 197,431 mm, AP: 143,205 mm), and frequency settings (40 Hz sampling, 12 Hz cutoff). The main section is titled 'OLHOS' and contains two columns of data. The left column lists various displacement and velocity measurements for the 'OA' (Open Air) condition, while the right column lists similar measurements for the 'OF' (Open Foot) condition. At the bottom, there are buttons for 'Estatocinesigrama', 'Estabilograma', 'Exportar EXCEL', and 'Voltar'. The 'unesp' logo is visible in the bottom right corner.

Fonte: Da autora.

Por fim, a Figura 28 é a tela com a imagem do deslocamento do centro de pressão no plano médio-lateral x anteroposterior.

Figura 28 – Tela de establiograma do LiebScan.



Fonte: Da autora.

4.1.1 Testes com Massas Estáticas Conhecidas

Os testes com massas conhecida tiveram a finalidade de avaliar as informações estáticas disponibilizadas pelos baropodômetros utilizados e comparar o dispositivo desenvolvido por Castro (2019) com o equipamento comercial. A Tabela 2 compara os resultados encontrados nos testes para a coordenada na origem dos dois baropodômetros. Observando os resultados, verifica-se que há diferenças entre os dois equipamentos em todos os parâmetros descritos. Cada valor na tabela refere-se a média aritmética de três ensaios realizados.

Tabela 2 – Teste com massas estáticas para os dois baropodômetros na coordenada [0,0].

Coordenada [x,y]	[0,0]							
Massa	2 kg		4 kg		6 kg		8 kg	
Equipamento	BaroScan	LiebScan	BaroScan	LiebScan	BaroScan	LiebScan	BaroScan	LiebScan
Amp. oscilação AP (mm)	0,05	19,31	0,023	7,12	0,04	3,6	0,013	1,87
Amp. oscilação ML (mm)	0,05	22,1	0,02	6,9	0,02	3,16	0,02	1,85
Centro de pressão ML (mm)	0,59	-3,28	0,59	-7,41	0,59	-3,04	0,59	-3,91
Centro de pressão AP (mm)	0,65	-4,68	0,6	0,99	0,62	-4,4	0,55	-6,7
Velocidade média (mm/s)	0,42	70,51	0,24	22,34	0,32	13,73	0,14	7,87
Área (mm²)	0	149,1	0	9,23	0	2,93	0	1,21

Fonte: Da autora.

Em específico, a amplitude de oscilação ML e AP são a base para o cálculo do centro de pressão, da velocidade e da área. Portanto, analisar esse parâmetro pode ajudar a compreender e comparar o comportamento dos dois baropodômetros.

Como é possível observar na Tabela 2, existem oscilações ML e AP para os dois equipamentos. Entretanto, enquanto a oscilação do BaroScan é próxima a zero, como esperado por se tratar de massa estática, a oscilação do LiebScan diverge desse valor.

Outra observação refere-se à relação entre aumento de massa e diminuição da amplitude de oscilação. Essas duas grandezas estão inversamente proporcionais, pois na medida que se dobra a massa, a oscilação diminui para aproximadamente a metade e se aproxima do valor esperado, que é zero. Portanto, o erro tende a diminuir quando se trabalha próximo da capacidade nominal do equipamento.


Como mencionado, as medições foram realizadas em 5 pontos distintos dos equipamentos. Entretanto, a nível de comparação, apenas o ponto central (origem) dos dois baropodômetros foi considerado, uma vez que o BaroScan sempre translada a origem dos eixos (x-y) de acordo com o posicionamento do Centro de pressão (Center of Pressure - CoP) instantâneo. Portanto, não foi possível fazer uma comparação direta nas posições $[x,y]$, $[x,-y]$, $[-x,y]$ e $[-x,-y]$.

4.1.2 Imagem da Pressão Plantar

Comparando a imagem de um voluntário, nota-se que a forma dos pés desenhadas pelos *softwares* é semelhante nos 2 equipamentos, assim como, os pontos de maior e menor pressão indicados. Nas Figuras 29 a 31 foram disponibilizadas as imagens obtidas pelos softwares dos equipamentos de três voluntários para visualização das distribuições plantares apresentadas.

A Tabela 2 mostra os resultados obtidos com os voluntários no LiebScan e no BaroScan com os olhos abertos. Algumas informações não são disponibilizadas nos dois baropodômetros, entretanto as principais informações para analisar a posturologia são apresentadas pelos equipamentos, com exceção do Centro de Pressão do corpo, que não é fornecido pelo BaroScan.

Figura 29 – Imagem da distribuição de pressão plantar do voluntário 1. À esquerda BaroScan e à direita LiebScan.




Fonte: Da autora.

Dentre as variáveis de possível comparação entre os dois baropodômetros, observa-se o comportamento similar da amplitude de oscilação, verificado no teste estático, ou seja, a amplitude de oscilação é maior no LiebScan.

Uma variável importante para indicar a presença de escoliose é a distribuição de pressão entre os dois pés. Nesse parâmetro, apenas os dados do voluntário 3 apresentou divergência na comparação entre BaroScan e LiebScan.


Como a velocidade do deslocamento é dependente do deslocamento, a discrepância entre os dois equipamentos está presente para os 3 voluntários.

Figura 30 - Imagem da distribuição de pressão plantar do voluntário 2. À esquerda BaroScan e à direita LiebScan.



Fonte: Da autora.

Figura 31 - Imagem da distribuição de pressão plantar do voluntário 3. À esquerda BaroScan e à direita LiebScan.



Fonte: Da autora.

Tabela 2- Dados obtidos com o LiebScan e o BaroScan com 3 voluntários (Teste de olhos abertos).

Voluntário	1		2		3	
Equipamento	BaroScan	LiebScan	BaroScan	LiebScan	BaroScan	LiebScan
Massa real kg	62		86,3		108	
Massa baro kg	NI	63,4	NI	74,3	NI	101
Distribuição Peso pé direito (%)	53,96	52,84	49,44	48,05	53,66	47,52
Distribuição Peso pé esquerdo (%)	46,04	47,16	50,56	51,95	46,34	52,47
Força total (N)	NI	622	NI	729	NI	991
Amp. Deslocamento ML (mm)	5,71	13,71	6,33	18,04	7,24	18,04
Amp. Deslocamento AP (mm)	14,85	21,65	10,59	17,69	12,23	17,69
Pressão média pé esquerdo (kgf/cm²)	0,45	NI	0,67	NI	0,34	NI
Pressão média pé direito (kgf/cm²)	0,51	NI	0,52	NI	0,4	NI
Área total da superfície de contato (cm²)	150,75	NI	186,16	NI	317,99	NI
Centro de pressão ML (mm)	NI	6,17	NI	32,23	NI	12,3
Centro de pressão AP (mm)	NI	-51,57	NI	-69,16	NI	-69,16
Velocidade oscilação ML (mm/s)	2,08	32,5	1,52	32,51	1,98	32,51
Velocidade oscilação AP (mm/s)	2,26	30,52	1,47	30,52	2,56	30,52

Fonte: Da autora.

4.3 MODELOS DE CLASSIFICAÇÃO

Foram projetados modelos de classificação com 2 objetivos diferentes. O primeiro objetivo era classificar os dados entre 2 grupos, com e sem escoliose. O segundo objetivo era classificar aqueles com escoliose em outros 2 grupos, grau 1 ($10^\circ \leq \alpha \leq 18,9^\circ$) ou grau 2 ($\alpha \geq 19^\circ$) de escoliose. Apesar do diagnóstico ter considerado o tipo de curvatura da escoliose, ela não foi considerada para o teste com os modelos que serão apresentados a seguir.

Para atingir os objetivos, foram desenvolvidos 2 modelos utilizando CNN. A base de dados foi dividida em 2 partes, sendo 80% dos dados foram usados para treinamento e validação e o restante, 20%, para testar o modelo.

4.3.1 Classificação com/sem Escoliose com dados LiebScan e BaroScan

O objetivo deste modelo é classificar os dados de entrada como “com escoliose” e “sem escoliose”, usando dados baropodométricos do LiebScan e do BaroScan. Esse teste busca comparar a acurácia do mesmo modelo entre os dados de cada um dos baropodômetros.

Para obter-se o melhor modelo, diversos parâmetros foram testados. Ao fim, selecionou-se aqueles que apresentaram melhor acurácia.

O modelo CNN-Escoliose possui 3 etapas. A primeira possui 3 camadas convolucionais com uma camada *BatchNormalization* após cada uma. Tendo as seguintes características: 64 filtros com tamanho 3x3 cada e função de ativação “ReLU”. A segunda etapa é composta por uma camada de *Flattening*. Por fim, a última etapa é composta por uma rede *Multilayer Perceptron* com 1 cama de entrada, 1 camada escondida e 1 camada de saída com 180, 68 e 1 neurônios respectivamente em cada camada. Utilizou-se a função de ativação *Relu* nas camadas

de entrada e escondida, para a camada de saída utilizou-se a função de ativação *Sigmoid*. Além disso, como otimizador de treinamento, o SGD.

Inicialmente, utilizou-se um total de 55 dados (imagens) para esse modelo. A quantidade de dados nesse teste foi limitada pelo número de dados que o LiebScan possuía, já que um dos objetivos era comparar o modelo de IA usando os mesmos parâmetros, porém entre as imagens dos dois equipamentos. Como resultado final do treinamento, este modelo alcançou uma acurácia de 66,67% com os dados dos dois baropodômetros.

Posteriormente, para o modelo descrito, foi realizado um segundo treinamento com um número maior de dados do BaroScan. O objetivo era avaliar a influência do aumento de dados, ainda que a quantidade não fosse muito maior. Nessa etapa foram utilizados os dados de 73 voluntários, que foram divididos entre treinamento e validação, sendo 80% dos dados para treinamento e validação e o restante, 20%, para testar o modelo. Como resultado, obteve-se uma acurácia de 68,67%. O aumento do resultado obtido em relação ao *dataset* inicial se deve ao fato de que algoritmos de *Deep Learning* apresentarem desempenho melhor ao acessar um maior volume de dados.

4.3.2 Classificação do Grau de Escoliose com Dados do LiebScan e do BaroScan

O objetivo deste modelo é classificar os dados de entrada em dois grupos diferentes de grau de escoliose, usando dados baropodométricos do LiebScan e do BaroScan e comparar seus resultados.

O modelo CNN-Grau possui 3 etapas. A primeira possui 3 camadas convolucionais com uma camada *BatchNormalization* após cada uma. Tendo as seguintes características: 64 filtros com tamanho 3x3 cada e função de ativação “ReLU”. A segunda etapa é composta por uma camada de *Flattening*. Por fim, a última etapa é composta por uma rede *Multilayer Perceptron* com 1 camada de entrada, 1 camada escondida e 1 camada de saída com 180, 68 e 1 neurônios respectivamente em cada camada. Utilizou-se a função de ativação *Relu* nas camadas de entrada e escondida, já para a camada de saída utilizou-se a função de ativação *Sigmoid*. E como otimizador de treinamento, o RMSprop.

Utilizou-se um total de 44 dados do LiebScan e 53 dados do BaroScan para a classificação. Como resultado final do treinamento, este modelo alcançou uma acurácia de 87,5% para o LiebScan e 81,82% com os dados do BaroScan.

Apesar de haver maior quantidade de dados do BaroScan, os testes com o LiebScan apresentaram maior acurácia. Uma explicação para esse resultado, pode estar na separação do banco de dados para treinamento e validação. Já que, utilizou-se dados de voluntários diferentes

para o treinamento com cada um dos equipamentos. Na Tabela 3, está o resumo dos resultados obtidos.

Tabela 3 – Resumos dos resultados dos modelos de classificação.

Modelo	Acurácia BaroScan (%)	Acurácia LiebScan (%)
CNN-escoliose com 55 voluntários	66,67	66,67
CNN-escoliose com 73 voluntários	68,67	-
CNN-grau com 44 voluntários	-	87,5
CNN-grau com 53 voluntários	81,82	-

Fonte: Da autora.

5 CONCLUSÃO

Através dos testes realizados pôde-se comparar dois baropodômetros, o LiebScan, que foi desenvolvido no LIEB, e o Baroscan, que é um equipamento comercial. Ambos fornecem as principais variáveis necessárias à avaliação da postura corporal como a amplitude de deslocamento ML e AP, velocidade do deslocamento ML e AP e distribuição de pressão plantar. Entretanto, existem discrepâncias entre os valores de variáveis e sub-variáveis relacionadas ao deslocamento. O BaroScan apresenta resultados muito próximos do esperado no teste com massas fixas, ao contrário do LiebScan. Sendo assim, conclui-se que a diferença entre os dois equipamentos pode ser causada por ruídos que o LiebScan apresenta. Para concluir sobre a causa desse problema, mais testes devem ser realizados, com o intuito verificar se a fonte do problema é *hardware* ou *software* e qual a possível solução.

Além disso, implementou-se dois modelos com CNN, um para classificação (diagnóstico) da escoliose (CNN-Escoliose) e outro para classificação do grau de escoliose (CNN-Grau). O primeiro alcançou acurácia de 68,67% e o segundo acurácia de 87,5%. Pela primeira vez, que se tem conhecimento, pode-se classificar o grau da escoliose e classificar a escoliose utilizando técnicas de *Deep Learning*.

Com os testes realizados, foi possível avaliar a resposta de cada modelo com dados dos dois equipamentos e verificar a acurácia com um banco de dados ligeiramente maior. Sugerindo que com um banco de dados maior pode fornecer maiores valores de acurácia. Portanto, como trabalhos futuros, sugere-se:

- Primeiramente, que se obtenha um maior banco de dados para alcançar uma melhor acurácia;
- Separar os dados de diagnóstico com relação ao tipo de curvatura da escoliose;
- Incluir dados biométricos dos voluntários para a classificação;
- Implementar outros algoritmos de *Deep Learning*;
- Classificar o grau de escoliose com faixas menores.

REFERÊNCIAS

- ALBUQUERQUE, D. M. et al. School screening for scoliosis: action for early diagnosis. **Journal of Human Growth and Development**, São Paulo, v. 19, n. 3, p. 357–368, 2009.
- ASHER, A. **How scoliosis is measured by the Cobb angle**. Disponível em: <https://www.verywellhealth.com/cobbs-angle-and-scoliosis-296583>. Acesso em: 6 jan. 2022.
- BARELA, J. A. Estratégias de controle em movimentos complexos: ciclo percepção-ação no controle postural. **Revista Paulista de Educação Física**, São Paulo, v. supl.3, n. 1996, p. 79-88, 2000.
- BIOLOGY FORUMS. **The two most common deformities of the spinal column are scoliosis and kyphosis**. Disponível em: <https://biology-forums.com/index.php?action=gallery;sa=view;id=30715>. Acesso em: 6 jan. 2022.
- BRICOT, B. **Posturologia Clínica**. 1 ed. São Paulo: CIES Brasil, 2010.
- CARINI, F. et al. Posture and posturology, anatomical and physiological profiles: overview and current state of art. **Acta Biomedica**, Santo Antônio de Pádua, 2017.
- CARVALHO, R. L.; ALMEIDA, G. L. Aspectos sensoriais e cognitivos do controle postural. **Revista Neurociências**, São Paulo, v. 17, n. 2, p. 156–160, 2019.
- CHICK, D. **World spine day: a look at scoliosis**. Disponível em: <https://domesticchick.home.blog/2019/10/16/world-spine-day-a-look-at-scoliosis/>. Acesso em: 6 jan. 2022.
- CHOLLET, F. **Deep Learning with Python**. Shelter Island: Manning Publications Co., 2018.
- COSTA, M. A. S. DA. Tratamento da escoliose idiopática do adolescente. **Revista Portuguesa de Ortopedia e Traumatologia**, Porto, p. 1–23, 2012.
- CRÉTUAL, A. Which biomechanical models are currently used in standing posture analysis? **Neurophysiologie Clinique/Clinical Neurophysiology**, Amsterdam, v. 45, n. 4-5, p. 285-295, nov. 2015.
- CUNHA, A. L. L. M. DA.; ROCHA, L. E. M. DA.; CUNHA, L. A. M. DA. 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.
- DANGERFIELD, P. H. et al. Foot pressure measurements in children with adolescent scoliosis. **Studies in Health Technology and Informatics**, New York, v. 37, p. 201–203, 1997.
- ESTEBAN, J. B. R. **Classificação de sinais de EEG para potenciais visuais evocados utilizando deep learning ao de sinais de EEG para potenciais**. 2020. 103 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista "Julio de Mesquita Filho", Ilha Solteira, 2020.
- FAIRBANK, J. C. T. William Adams and the spine of Gideon Algernon Mantell. **Annals of**

the **Royal College of Surgeons of England**, v. 86, n. 5, p. 349–352, London, 2004.

FERREIRA, D. G. **Escoliose idiopática do adolescente**. 2015. 56 f. Dissertação (Mestrado em Medicina) – Universidade da Beira Interior, Covilhã, 2015.

FORERO, F. R. C. **Sistema baropodométrico e classificação de escoliose utilizando técnicas de machine learning**. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista "Julio de Mesquita Filho", Ilha Solteira, 2019.

FREITAS JÚNIOR, P. B.; BARELA, J. A. Postural control as a function of self- and object-motion perception. **Neuroscience Letters**, New York, v. 369, n. 1, p. 64–68, 2004.

GOGUEN, J. A. L. A. Zadeh. Fuzzy sets. Information and control, vol. 8, pp. 338–353. L. A. Zadeh. Similarity relations and fuzzy orderings. Information sciences, vol. 3 (1971), pp. 177–200. **Journal of Symbolic Logic**, Shaftesbury Road, v. 38, n. 4, p. 656–657, 12 dez. 1973. Doi:10.2307/2272014

HONÓRIO, L. F. Inteligência Artificial: Conceitos e Aplicações. **Revista Olhar Científico**, Município de Talatona, v. 01, p. 107–113, 30 jun. 2010.

HOSPITAL, U. OF I. S. F. C. **What is scoliosis?** Disponível em: <https://uichildrens.org/treating-scoliosis>. Acesso em: 6 jan. 2022.

HUDSON, D. L.; COHEN, M. E. **Neural networks and artificial intelligence for biomedical engineering**. San Francisco: Wiley-IEEE Press, 1999.

IDE, S. **Spyder is a free and open source scientific**. Disponível em: <https://www.spyder-ide.org/>. Acesso em: 2 maio 2023.

IVANENKO, Y.; GURFINKEL, V. S. Human postural control. **Frontiers in neuroscience**, Switzerland, v. 12, n. Mar, p. 1–9, 2018.

KAPANJI, A. I.; **Filosofia Articular**. São Paulo: Panamericana, 2000.

KAUR, S. et al. Medical Diagnostic Systems Using Artificial Intelligence (AI) Algorithms: Principles and Perspectives. **IEEE Access**, New York, v. 8, p. 228049-228069, 2020.

KERAS, A. **About Keras First contact with Keras**. Disponível em: <https://keras.io/about/>. Acesso em: 2 maio 2023.

KUBAT, M. **An Introduction to Machine Learning**. 2. ed. Coral Gables: Springer, 2017.

LANGENSIEPEN, S. et al. Measuring procedures to determine the Cobb angle in idiopathic scoliosis: a systematic review. **European Spine Journal**, London, v. 22, n. 11, p. 2360–2371, 27 nov. 2013.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, London, v. 521, n. 7553, p. 436–444, 2015.

LEE, J. U.; KIM, M. Y.; KIM, J. Comparison of static plantar foot pressure between healthy

subjects and patients with adolescent idiopathic scoliosis. **Toxicology and Environmental Health Sciences**, Reston, v. 6, n. 2, p. 127–132, 2014.

LI, Z. et al. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. **IEEE Transactions on Neural Networks and Learning Systems**, New York, v. 33, n. 12, p. 6999–7019, 2022.

LIPPERT, L. S. **Cinesiologia Clínico e Anatomia**. 5. ed. Rio de Janeiro: Editora Guanabara Koogan LTDA, Rio de Janeiro, 2013.

MEHLIG, B. Convolutional Networks. In: MEHLIG, B. **Machine Learning with Neural Networks**. Cambridge University Press, 2021. p. 141–156.

NNADI, C.; FAIRBANK, J. Scoliosis: a review. **Pediatrics and Child Health**, Cambridge, v. 20, n. 5, p. 215–220, maio 2010.

NOGUEIRA, M. **Aplicando lógica fuzzy no controle de robôs móveis usando dispositivos lógicos programáveis e a linguagem VHDL**. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista "Julio de Mesquita Filho", Ilha Solteira, 2013.

PARK, J. H. et al. The study of correlation between foot-pressure distribution and scoliosis. **IFMBE Proceedings**, New York, v. 23, p. 974–978, 2009.

RAWAT, W.; WANG, Z. Deep convolutional neural networks for image classification: a comprehensive review. **Neural Computation**, Massachusetts, v. 29, n. 9, p. 2352–2449, set. 2017.

RODRIGUES, V. **Como Máquinas Aprendem**. 2. ed. França: Publicação Independente, 2021.

ROUVRAY, D. H. **Fuzzy sets and fuzzy logic: theory and applications**. New Jersey: Prentice Hall PTR, 1996. v. 20.

SHAKIL, H.; IQBAL, Z. A.; AL-GHADIR, A. H. Scoliosis: Review of types of curves, etiological theories and conservative treatment. **Journal of Back and Musculoskeletal Rehabilitation**, Amsterdam, v. 27, n. 2, p. 111–115, 1 abr. 2014.

TENSORFLOW. **Criar modelos de machine learning no nível de produção com o TensorFlow**. Disponível em: <https://keras.io/about/br>. Acesso em: 2 maio 2023.

TROBISCH, P.; SUESS, O.; SCHWAB, F. Idiopathic Scoliosis. **Deutsches Ärzteblatt international**, v. 107, n. 49, 10 dez. 2010.

WINTER, D. Human balance and posture control during standing and walking. **Gait & Posture**, Oxford, v. 3, n. 4, p. 193–214, dez. 1995.

YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. **Insights into Imaging**, London, v. 9, n. 4, p. 611–629, 22 ago. 2018.

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**, Antwerp, v. 17, n. 3, p. 355–360, 2008.

ZADEH, L. A. Fuzzy logic. **Computer**, Oxford, v. 21, n. 4, p. 83–93, abr. 1988.

ANEXO A – Parecer Consubstancial do CEP

UNESP - FACULDADE DE
CIÊNCIAS E TECNOLOGIA DO
CAMPUS DE PRESIDENTE
PRUDENTE



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: AVALIAÇÃO POSTURAL DE INDIVÍDUOS EM DIFERENTES FAIXAS ETÁRIAS UTILIZANDO O BAROPODÔMETROS ELETRÔNICOS E PLATAFORMA DE FORÇA

Pesquisador: Andressa Helena Melo Costa

Área Temática:

Versão: 1

CAAE: 57681022.4.1001.5402

Instituição Proponente: UNESP Campus de Ilha Solteira

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.349.447

Apresentação do Projeto:

O estudo da distribuição de força na região plantar é realizado com o baropodômetro, um equipamento composto por sistemas de hardware e software, ou por uma plataforma de força. Então, através da coleta desses dados, essa pesquisa tem como principal objetivo desenvolver procedimentos para classificar o acometimento postural de pacientes com escoliose idiopática, utilizando técnicas de Deep Learning (DP) na distribuição de pressão plantar e considerando dados estabilométricos e biométricos de voluntários. Dessa forma, será requerida uma amostra com 300 voluntários, homens e mulheres com idade a partir de 14 anos, que se enquadrarem nos critérios de inclusão e exclusão. Os voluntários incluídos farão uma sequência de testes que envolve, principalmente, 2 baropodômetros e 1 plataforma de força, para realizarem os protocolos de Avaliação da Postura Corpórea, Análise Radiográfica, Baropodometria e Análise de Distribuição de Força e Mensuração da Flexibilidade. Portanto, espera-se, principalmente, desenvolver métodos com Inteligência Artificial e dados de distribuição de força plantar para diagnosticar diferentes patologias relacionadas à postura.

Objetivo da Pesquisa:

Como objetivo primário pretende-se: Desenvolver procedimentos para classificar o acometimento postural de pacientes com escoliose idiopática, utilizando técnicas de ML na distribuição de pressão plantar e considerando dados estabilométricos e biométricos de voluntários.

Endereço: Rua Roberto Simonsen, 305 - Faculdade de Ciência e Tecnologia da Unesp - Prédio da Administração - SI 04
Bairro: Centro Educacional **CEP:** 19.060-900
UF: SP **Município:** PRESIDENTE PRUDENTE
Telefone: (18)3229-5315 **Fax:** (18)3229-5300 **E-mail:** cep.fct@unesp.br

**UNESP - FACULDADE DE
CIÊNCIAS E TECNOLOGIA DO
CAMPUS DE PRESIDENTE
PRUDENTE**



Continuação do Parecer: 5.349.447

Como objetivos secundários pretende-se:

- 1) Construir uma base de dados de livre acesso, única a nível mundial, com dados baropodométricos, de estabilometria e biométricos, com pelo menos 300 voluntários;
- 2) Comparar o baropodômetro com uma plataforma de força e avaliar o uso do baropodômetro como ferramenta na coleta de dados de iniciação da marcha;
- 3) Processar os dados baropodométricos, biométricos e de estabilometria para a implementação de técnicas de ML, considerando a padronização e a normalização de dados;
- 4) Processar os dados de distribuições de pressão na região plantar por meio de processamento digital de imagens que possibilite normalizar tanto os tamanhos dos pés, como a posição sobre o baropodômetro, para obter não apenas uma normalização nas características, mas também a normalização das distribuições de pressão dos pés dos voluntários;
- 5) Configurar e implementar bibliotecas de código aberto para aprendizado de máquina como Tensor Flow, Keras, ou Scikit-learn, que são ferramentas mais potentes que as utilizadas nas pesquisas anteriores;
- 6) Implementar técnicas de ML comuns (RNA e SVM) e também técnicas mais avançadas como Redes Neurais Convolucionais e/ou Deep Learning, utilizando bibliotecas e ferramentas de código aberto e linguagem Python;
- 7) Comparar as técnicas de ML utilizadas visando determinar a técnica de melhor rendimento e concluir se há viabilidade ou não se de utilizar o baropodômetro para o diagnóstico e classificação de escoliose.

Avaliação dos Riscos e Benefícios:

Segundo os autores, a participação nesta pesquisa não infringe as normas legais e éticas (pode envolver um risco relacionado à desorientação ou sensação de instabilidade, quando feita a avaliação com olhos fechados). Os procedimentos adotados nesta pesquisa obedecem aos Critérios da Ética em Pesquisa com Seres Humanos conforme Resolução no. 466/2012 do Conselho Nacional de Saúde. Nenhum dos procedimentos usados oferece riscos à dignidade dos participantes.

Ao participar desta pesquisa o voluntário não terá nenhum benefício direto. Entretanto, esperamos que este estudo traga informações importantes sobre um método para diagnóstico de escoliose, transtornos da marcha e avaliação postural utilizando Inteligência Artificial, de forma que o conhecimento que será construído a partir desta pesquisa possa oferecer uma nova via de diagnóstico sem a utilização de exames de raio-X para as demandas mencionadas, onde

Endereço: Rua Roberto Simonsen, 305 º Faculdade de Ciência e Tecnologia da Unesp º Prédio da Administração º SI 04
Bairro: Centro Educacional **CEP:** 19.060-900
UF: SP **Município:** PRESIDENTE PRUDENTE
Telefone: (18)3229-5315 **Fax:** (18)3229-5300 **E-mail:** cep.fct@unesp.br

**UNESP - FACULDADE DE
CIÊNCIAS E TECNOLOGIA DO
CAMPUS DE PRESIDENTE
PRUDENTE**



Continuação do Parecer: 5.349.447

pesquisador se compromete a divulgar os resultados obtidos, respeitando-se o sigilo das informações coletadas, conforme previsto no item anterior.

Comentários e Considerações sobre a Pesquisa:

A pesquisa envolve duas universidades, a Universidade Federal do Mato Grosso do Sul, através do Campus de Três Lagoas e a UNESP, através do Faculdade de Engenharia Elétrica do Campos de Ilha Solteira. Os pesquisadores almejam desenvolver procedimentos para classificar o acometimento postural de pacientes com escoliose idiopática, utilizando técnicas de ML na distribuição de pressão plantar e considerando dados estabíliométricos e biométricos de voluntários. Uma das razões do estudo é a dependência do Raio-X para o diagnóstico da escoliose, limitando devido aos custos, exposição à radiação e disponibilidade do exame. Portanto, essa pesquisa pode oferecer uma nova via de diagnóstico.

Considerações sobre os Termos de apresentação obrigatória:

Todos os termos apresentados estão adequados, são eles: folha de rosto; TCLE, Termos de Assentimento, Declaração de Anuência de Instituição Proponente, Termos de Compromisso dos Pesquisadores, Termo de responsabilidade e compromisso para uso, guarda e divulgação de dados e arquivos de pesquisa, Declaração da Coordenadora Regional de Educação do Mato Grosso do Sul (ciência e autorização para o desenvolvimento da pesquisa), Autorização para o desenvolvimento da pesquisa na Faculdade de Engenharia de Ilha Solteira.

Recomendações:

Apenas recomento a pesquisadora para adequar o nome do vice-coordenador do Comitê de Ética, tendo em vista que os documentos apresentados estão com o nome da gestão anterior.

Conclusões ou Pendências e Lista de Inadequações:

O projeto pode ser aprovado e não apresenta pendências.

Considerações Finais a critério do CEP:

Em reunião realizada no dia 12.04.2022, o Comitê de Ética em Pesquisa da Faculdade de Ciências e Tecnologia - Unesp - Presidente Prudente, em concordância com o parecerista, considerou o projeto APROVADO.

Obs: Lembramos que pesquisas que se enquadram na resolução 466/12 devem apresentar relatório parcial e final, e pesquisas que se enquadram na resolução 510/16 devem apresentar relatório final.

Endereço: Rua Roberto Simonsen, 305 º Faculdade de Ciência e Tecnologia da Unesp º Prédio da Administração º SI 04
Bairro: Centro Educacional **CEP:** 19.060-900
UF: SP **Município:** PRESIDENTE PRUDENTE
Telefone: (18)3229-5315 **Fax:** (18)3229-5300 **E-mail:** cep.fct@unesp.br

**UNESP - FACULDADE DE
CIÊNCIAS E TECNOLOGIA DO
CAMPUS DE PRESIDENTE
PRUDENTE**



Continuação do Parecer: 5.349.447

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1829124.pdf	08/04/2022 15:48:18		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEresponsaveis.pdf	08/04/2022 15:45:02	Andressa Helena Melo Costa	Aceito
Outros	SEI_UFMS_Declaracao.pdf	15/03/2022 16:51:28	Andressa Helena Melo Costa	Aceito
Outros	termoderesponsabilidadadedadosearquivos.pdf	15/03/2022 16:43:47	Andressa Helena Melo Costa	Aceito
Outros	DeclaracaoCoord_Regional_Educacao.pdf	15/03/2022 16:41:40	Andressa Helena Melo Costa	Aceito
Outros	DeclaracaoFEIS.pdf	15/03/2022 16:40:38	Andressa Helena Melo Costa	Aceito
Outros	CRONOGRAMA.pdf	15/03/2022 16:36:43	Andressa Helena Melo Costa	Aceito
Solicitação Assinada pelo Pesquisador Responsável	cepdeclaracaoautorizacao.pdf	15/03/2022 16:35:23	Andressa Helena Melo Costa	Aceito
Declaração de Pesquisadores	TermodeCompromissoPesquisadores.pdf	15/03/2022 16:34:16	Andressa Helena Melo Costa	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE.pdf	15/03/2022 16:33:03	Andressa Helena Melo Costa	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TermoDeAssentimento.pdf	15/03/2022 16:32:54	Andressa Helena Melo Costa	Aceito
Projeto Detalhado / Brochura Investigador	ProjetoFinal.pdf	15/03/2022 16:32:17	Andressa Helena Melo Costa	Aceito
Folha de Rosto	FolhadeRosto.pdf	15/03/2022 16:15:06	Andressa Helena Melo Costa	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Rua Roberto Simonsen, 305 - Faculdade de Ciência e Tecnologia da Unesp - Prédio da Administração - SI 04
Bairro: Centro Educacional **CEP:** 19.060-900
UF: SP **Município:** PRESIDENTE PRUDENTE
Telefone: (18)3229-5315 **Fax:** (18)3229-5300 **E-mail:** cep.fct@unesp.br

UNESP - FACULDADE DE
CIÊNCIAS E TECNOLOGIA DO
CAMPUS DE PRESIDENTE
PRUDENTE



Continuação do Parecer: 5.349.447

PRESIDENTE PRUDENTE, 13 de Abril de 2022

Assinado por:
Edna Maria do Carmo
(Coordenador(a))

Endereço: Rua Roberto Simonsen, 305 º Faculdade de Ciência e Tecnologia da Unesp º Prédio da Administração º SI 04
Bairro: Centro Educacional **CEP:** 19.060-900
UF: SP **Município:** PRESIDENTE PRUDENTE
Telefone: (18)3229-5315 **Fax:** (18)3229-5300 **E-mail:** cep.fct@unesp.br