

Criação de modelo artificial de avaliação postural para otimização de identificação de desníveis posturais

Creation of artificial postural assessment standards to optimize the identification of postural gaps

Creación de estándares de evaluación postural artificial para optimizar la identificación de brechas posturales

Viviane Sousa Ferreira^{1*}, Alexsandro Guimarães Reis², Ilka Kassandra Pereira Belfort¹, Pablo Lisandro Tavares dos Santos Morais¹, Marlon Lemos de Araújo¹, Nelmar de Oliveira Mendes¹, Malene Lima Gomes Sodrê¹, Alice de Sá Ferreira¹, Sally Cristina Monteiro Moutinho¹, Allan Kardec Duailibe Barros Filho¹.

RESUMO

Objetivo: Criar um padrão artificial para otimização de avaliação postural. **Métodos:** Trata de uma pesquisa aplicada, onde criou-se um modelo de simetria anatômica na visão anterior considerando para base de cálculo dos padrões de visão frontal consistentes no método Portland State University (PSU) e para efeito de cálculo de visão sagital consideramos as proporções entre as áreas definidas entre os pontos da cabeça x região cervical final e entre região torácica final x glúteos. **Resultados:** Foi elaborado por meio de padrão biomecânico pré-definido um modelo de normalidade com base nas informações inseridas, o modelo serviu de base para definir se o indivíduo está com inclinações posturais aceitáveis ou não, testes foram realizados em 40 indivíduos e o modelo foi capaz de identificar pequenos desníveis algumas vezes não notados na inspeção visual do profissional. **Conclusão:** O modelo obtido é uma ferramenta importante de implemento ao diagnóstico de desníveis posturais, contudo a ferramenta não tem o poder preditor de lesões ou dor futura, sendo necessários mais estudos para aperfeiçoá-la.

Palavras-chave: Postura, Simulação por computador, Diagnóstico clínico.

ABSTRACT

Objective: To create an artificial pattern to optimize postural assessment. **Methods:** It is an applied research, where a model of anatomical symmetry in the anterior view was created considering the basis for calculating frontal vision patterns consistent in the PSU method (Portland State University) and for the purpose of calculating sagittal vision we consider the proportions between the areas defined between the points of the head x the final cervical region and between the final thoracic region but the glutes. **Results:** A normality model was developed using a pre-defined biomechanical pattern based on the information entered, the model served as a basis for defining whether the individual has acceptable postural inclinations or not, tests were performed on 40 individuals and the model was able to identify small gaps sometimes not noticed in the visual inspection of the professional. **Conclusion:** The model obtained is an important tool to implement the diagnosis of postural unevenness, however the tool does not have the power to predict injuries or future pain, and further studies are needed to improve it.

Key words: Posture, Computer simulation, Clinical diagnosis.

¹ Universidade Federal do Maranhão, São Luís – MA. *E-mail: viviane_gnr@hotmail.com

² Faculdade Maurício de Nassau – UNINASSAU – São Luís – MA.

RESUMEN

Objetivo: crear un patrón artificial para optimizar la evaluación postural. **Métodos:** es una investigación aplicada, donde se creó un modelo de simetría anatómica en la vista anterior considerando la base para calcular patrones de visión frontal consistentes en el método PSU (Portland State University) y con el propósito de calcular la visión sagital consideramos las proporciones entre las áreas definidas entre los puntos de la cabeza x la región cervical final y entre la región torácica final pero los glúteos. **Resultados:** se desarrolló un modelo de normalidad utilizando un patrón biomecánico predefinido basado en la información ingresada, el modelo sirvió de base para definir si el individuo tiene inclinaciones posturales aceptables o no, se realizaron pruebas en 40 individuos y el modelo fue capaz de identificar brechas pequeñas que a veces no se notan en la inspección visual del profesional. **Conclusión:** El modelo obtenido es una herramienta importante para implementar el diagnóstico de desigualdad postural, sin embargo, la herramienta no tiene el poder de predecir lesiones o dolor futuro, y se necesitan más estudios para mejorarlo.

Palabra clave: Postura, Simulación por computadora, Diagnóstico clínico.

INTRODUÇÃO

Fedorak C, et al. (2003) descreve a postura humana como o posicionamento de todos os segmentos corporais em um determinado momento em que haja o mínimo possível de tensão muscular sobre a estrutura osteo-articular. O objetivo da avaliação postural é correlacionar determinada postura a um risco de lesão futura ou existente ou monitorar os resultados do tratamento e observar os desequilíbrios posturais.

Os problemas posturais têm aparecido com mais frequência desde a revolução industrial dando início às doenças ocupacionais, atualmente os problemas modernos envolvendo a postura estão muito relacionadas à utilização de smartphones e computadores, estudos realizados com adolescentes de 11 a 17 anos revelaram que dentre o grupo pesquisado em 60% do grupo havia alteração na postura, principalmente na região cervical (NOGUEIRA DA, et al., 2018). Analisar a postura requer uma medida precisa da orientação dos vários segmentos do corpo em relação ao vetor gravitacional, é necessário também conhecimento de anatomia, fisiologia, cinesiologia e biomecânica (GANGNET N, et al., 2003).

Diversas técnicas de avaliação postural têm sido testadas ao longo dos anos, técnicas bidimensionais e tridimensionais, invasivas e não-invasivas, que utilizam equipamentos especializados como: escoliômetro, eletrogoniômetro, fotogrametria e termografia, cálculo de ângulos articulares, simetria de membros, medição de ângulos posturais usando goniometria, fotografia e radiografia (SINGLA MP, et al., 2017). As técnicas mais popularmente disponíveis e utilizadas compreendem a avaliação qualitativa das curvaturas da coluna vertebral e nivelamento de estruturas buscando por assimetrias nas visões anteriores, posteriores e laterais direita e esquerda, porém, o resultado da observação vai depender de critérios subjetivos como: nível de experiência do examinador, iluminação da sala de avaliação, acuidade visual do avaliador dentre outros (KENDALL FP e MCCREARY EK e PROVANCE PE, 1995).

Althoff A, et al. (2013) elaboraram um modelo de protocolo de avaliação postural baseado em cálculos matemáticos e simetrias posturais, modelo esse que até hoje é utilizado como base para a avaliação postural não-invasiva no que se refere a simetrias posturais. O Protocolo *Portland State University* (PSU) teve como objetivo dar aos participantes envolvidos no projeto a oportunidade de conhecer as dissimetrias posturais inclui-los num programa de exercícios para melhorar essa condição e dar consciência corporal aos participantes objetivando corrigir essas assimetrias e prevenir lesões e aos avaliadores (ALTHOFF A, et al., 2013 e GANGNET N, et al., 2013). Apesar do método descrito representar uma estratégia de fácil execução existem limitações importantes que podem enviesar os resultados da análise. Um dos pontos negativos é que o procedimento não permite a noção real da dismetria entre os membros em mínimos graus, outro ponto negativo é que ele depende exclusivamente da experiência prática do avaliador, ou seja, está intrinsecamente centrado na subjetividade. Um ponto positivo é que: auxilia na detecção parcial das assimetrias (por regiões) e total, quando houver (GANGNET N, et al., 2013).

É necessária a criação de um novo método que permita aplicar medidas objetivas de mensuração para que se possa qualificar e quantificar as regiões estudadas com maior precisão, dando mais subsídios para uma boa avaliação (SANTOS JB, et al., 2005).

Como observado anteriormente, não existe um consenso acerca do melhor método não invasivo para realização de Avaliação Postural pois cada método tem seus prós e contras e depende de um item importante: experiência do examinador. Em uma revisão sistemática acerca do melhor método para realizar avaliação em posturas sagitais, os autores observaram que os métodos utilizados variam muito em relação a: tipo de instrumento utilizado, o tempo necessário para a avaliação e a especificidade da técnica para a avaliação. Dentre todos os estudos avaliados, somente dois mostraram fortes evidências científicas, representando um bom método de avaliação não-invasiva, porém não são importantes o suficiente para substituírem métodos invasivos como a radiografia (SEDREZ JA e CANDOTTI CT, 2013).

No presente estudo, escolhemos o Protocolo PSU de avaliação para a criação do modelo artificial ideal e para o treinamento do algoritmo, pois desde a sua concepção, os autores pensaram em uma ferramenta simples e que oferecesse ao paciente um diagnóstico de uma situação a fim de se estabelecer um equilíbrio e resolver o problema futuro a ser gerado.

MÉTODOS

O presente estudo é uma pesquisa aplicada onde através da inserção de métodos já validados pela prática clínica diária foi proposta a criação de um modelo artificial de avaliação postural visando auxílio no diagnóstico clínico. A pesquisa foi realizada no período de janeiro de 2019 a dezembro de 2019 e foi dividida em fases descritas a seguir:

Inserção do padrão do método PSU no algoritmo:

Para a elaboração desse modelo, foram consideradas as seguintes posturas: 1. frontal e 2. sagital. Na postura frontal, consideramos o modelo utilizado por Althoff, A. (2013), método PSU e adequamos à especificidade do algoritmo proposto, de acordo com o que é descrito na **Quadro 1** abaixo.

Quadro 1 - Padrão de correlação utilizado para a inclusão de informações para criação de um modelo para postura frontal a ser utilizada como base para avaliação do algoritmo

Simetria de ombros	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior
Simetria de cotovelos	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior
Simetria de punhos	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior
Simetria de quadris	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior
Simetria de joelhos	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior
Simetria de tornozelos	considerado normal uma linha reta paralela ao solo com 0° de inclinação para inferior ou superior

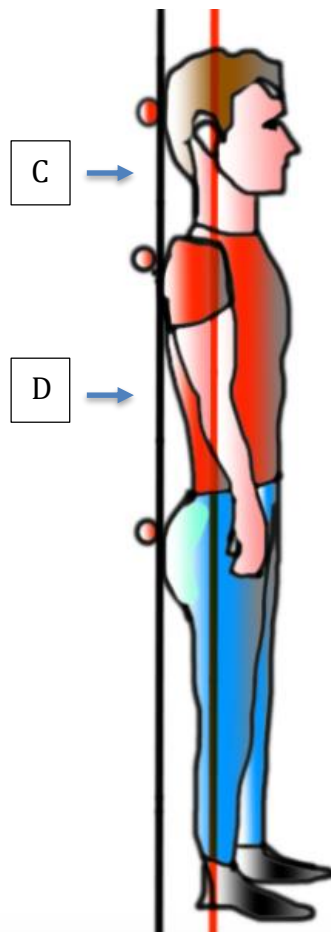
Fonte: Ferreira VS, et al., 2020

Elaboração de medida para avaliação sagital

Para a postural sagital, consideramos um modelo matemático comparativo. Foi aplicado um cálculo proporcional utilizando como base a técnica atualmente utilizada como medida padrão para avaliação de pacientes em postura sagital em que o fio de prumo passe exatamente em cima da orelha, centro da articulação do ombro, centro da articulação do quadril, centro da articulação do joelho e maléolo lateral (na figura abaixo representado em vermelho).

Essa linha traçada pelo fio de prumo, perpendicular ao solo (formando com ele 90°) foi transposta para três pontos imediatamente posteriores (representada na figura em preto), onde duas regiões de três pontos foram criadas (área C e área D), de acordo com a figura a seguir. A proporção entre as duas áreas é de 1:0,77, consideramos uma variação de -0,05 e +0,05. O cálculo foi realizado a pelo do aplicativo SketchAndCalc™

Figura 2 - Modelo ideal inserido no algoritmo em visão sagital



Fonte: Ferreira VS, et al., 2020

Linguagem de programação utilizada

A linguagem de programação utilizada foi o Python (ferramenta de desenvolvimento PyCharm Community Edition, versão 2018.2.2), utilizamos o banco de dados PostgreSQL versão 10.5 para armazenamento das informações. Também utilizamos a Biblioteca Numpy, a biblioteca Skylearn, a biblioteca Math, e a ferramenta Jupyter notebook, estas, descritas a seguir.

A biblioteca Numpy foi escolhida por ser eficiente para cálculos matemáticos em grandes matrizes. Neste trabalho ela foi utilizada para capturar a Matriz das Classes e para prover a estrutura de cálculo estatístico para a biblioteca Sklearn, auxiliando no grau de correlação entre as variáveis e alvo. A biblioteca Sklearn foi utilizada para o treinamento dos dados capturados e gerados artificialmente. Ela provê toda uma estrutura com diferentes tipos de algoritmos que podem ser utilizados para diferentes situações. A biblioteca Math, nativa da linguagem Python, foi utilizada para cálculo das inclinações entre as partes em comum do corpo avaliado e testes nos participantes da presente pesquisa.

Seleção de participantes para a fase de testes

Nessa fase realizamos a captura de imagens de participantes para avaliação do algoritmo criado. A população do estudo foi constituída por acadêmicos de ambos os sexos, sem distinção de etnia, com idade de 20 a 49 anos, devidamente matriculados em faculdades do Maranhão. Foram incluídos no estudo os participantes que atenderem aos seguintes critérios: Estar devidamente matriculados em Faculdades do Maranhão; participantes com Índice de Massa Corpórea de 18,5 a 34,9, sem histórico de doenças osteo-articulares.

Não foram incluídos na pesquisa mulheres gestantes, amamentando ou que fazem uso de anticoncepcional; Mulheres que estiverem em fase menstrual; Incapacidade física que impossibilite ou comprometa as medidas posturais; incapacidade mental que impossibilite participar das fases da pesquisa; pessoas com dores musculoesqueléticas crônicas não associadas a problemas posturais, tais como: fibromialgia, gota e doenças reumáticas; Pessoas com dores crônicas em outros sistemas; Pessoas que tenham histórico de lesões articulares, ligamentares, cirurgias ortopédicas.

Captura de imagens fotográficas

A presente fase da pesquisa, compreendeu a captura de imagens, que foi realizada através de câmera fotográfica de alta resolução, apoiada por tripé e parametrizada por medidas obtidas anteriormente à realização das fotos. O registro fotográfico foi realizado com uma máquina digital (Câmera Nikon P1000 – Zoom 125X - 4K - Wi-Fi), posicionada paralela ao chão, sobre um tripé (Tripé Ei7050 E-image). Foram realizados os registros fotográficos em posição anterior, posterior, perfil direito e perfil esquerdo, e fotografias de teste para garantir a qualidade. Todas as imagens foram obtidas por um único avaliador. As fotografias foram realizadas no mesmo horário do dia. Nas imagens obtidas objetivou-se identificar, nas seguintes visões, as estruturas a seguir:

- Vista anterior: extremidades laterais das clavículas, cabeças dos úmeros, espinhas ilíacas anteriores e superiores, joelhos, maléolos;
- Vista lateral: curvatura cervical, torácica e lombar, posicionamento de ombros, espinhas ilíacas anteriores e superiores, joelhos e tornozelos;
- Vista posterior: escápulas – ângulos superiores e inferiores, cristas ilíacas, regiões poplíteas, tornozelos.

Para o registro fotográfico os participantes permaneceram em postura ortostática, em local previamente demarcado, com uma distância padronizada de 2,40m do centro da lente da máquina fotográfica também previamente demarcada.

A obtenção dessas imagens, objetivaram a fase de testes do algoritmo, por isso, criou-se uma estrutura própria para obtê-las. Essa estrutura compreende um tablado que possui uma estimativa de altura de 1,90cm a 2,60cm, largura de 1,30 a 1,80cm que serve como base para diferenciação do algoritmo através da identificação do código RGB, o tablado é confeccionado em duas cores, branca e preta (face posterior) de acordo com a cor da pele dos participantes se mais claro, usamos o fundo preto, se mais escuros, usamos o fundo claro, para que o algoritmo tenha a capacidade de diferenciar o ser humano do ambiente. Uma linha de 2 metros, foi traçada do tablado até o tripé e próximo ao tripé e a câmera receptora, instalou-se uma torre com foco luminoso. O participante ficou posicionado a uma distância de 0,15m do tablado. Para manter esta distância fixa, foi utilizado um demarcador adesivo. A câmera fotográfica foi posicionada paralela ao chão,

sobre o tripé. Sendo este tripé posicionado de forma que sua base estava a uma altura de 1,0 m do chão para fotografar o corpo inteiro. O foco luminoso foi centralizado de forma que não causasse reflexão de luz. Foi mantida total privacidade do indivíduo durante essa fase da pesquisa. Permaneceram na sala somente duas pessoas, o pesquisador responsável por obter as imagens e um pesquisador auxiliar.

Para essa fase da pesquisa, contamos com a parceria da Universidade Maurício de Nassau (UNINASSAU) que nos forneceu sala própria, com acondicionamento térmico adequado e iluminação adequada.

Aspectos Éticos

O presente estudo obteve aprovação no Comitê de Ética em Pesquisa e Pesquisa da Universidade Federal do Maranhão, sob o número de aprovação 3.639.179. Os voluntários foram incluídos após serem informados em detalhes sobre o estudo, e preencherem corretamente o termo de Consentimento Livre e Esclarecido (TCLE). O presente estudo foi conduzido de acordo com a resolução CONSELHO NACIONAL DE SAÚDE CNS n°. 466/2012. Ficou garantida a confidencialidade dos dados e a qualquer momento o voluntário teve o direito de desistir de participar do estudo.

RESULTADOS E DISCUSSÃO

Quando pensamos no modelo ideal para comparação de dados, fornecemos ao algoritmo um parâmetro importante para a avaliação, portanto, o modelo ideal representou a normalidade absoluta, sob a qual, tudo que divergisse desse padrão foi considerado anormal. Os pontos (que a máquina transformou em linhas paralelas ao solo) são validados e utilizados na avaliação postural tradicional (ALTHOFF A, et al. 2013).

O que fizemos, foi computadorizar esses dados para a realização dos testes propostos. Sobre o modelo em postura sagital (perfil), também inserimos na máquina um modelo baseado no padrão utilizado para realizar avaliações posturais, porém, utilizando mecanismos artificiais para calcular proporções de áreas entre eles. Depois da criação e inserção do modelo padrão, buscamos identificar o indivíduo no universo e as partes do corpo, através da inserção de fotos dos participantes, foram inseridas 4 fotos de cada participante, formando um total de 160 fotos. A quantidade de dados pelos resultados obtidos foi suficiente, o algoritmo conseguiu identificar as partes com uma média de probabilidade de 60% em uma velocidade de 2 segundos. No estudo de Sharma K, et al. (2015), foi apresentado um método através de identificação de imagens, os autores usaram cerca de 244 imagens e obtiveram resultados satisfatórios, ou seja, acurácia acima de 50% do algoritmo.

Em outro estudo em que também se utilizou da avaliação de imagens para aprendizado de máquina, os autores propuseram identificar principais diferenças entre cérebros saudáveis e cérebros doentes em pacientes com doença de Alzheimer, os resultados da pesquisa mostram que as redes neurais convolucionais em 3D superam o desempenho de vários outros classificadores relatados na literatura e produzem resultados de última geração (PAYAN A e MONTANA G, 2015).

O processo de elaboração do modelo criado artificialmente foi iniciado a partir do envio do padrão das fases 1 e 2 descritas no Método do presente estudo para uma rede neural artificial a fim de separar o indivíduo do ambiente e identificação das partes do corpo. Esse método de separação do indivíduo do meio ambiente e posterior separação das partes do corpo utilizou técnicas de *deep learning* na classificação que é o processo de determinar a classe ou categoria de algo. Para isso, são usadas entradas que no caso do presente estudo são imagens, e são definidas também as saídas (classes) e, a partir daí, o modelo computacional passou pela fase de treino. O objetivo dessa etapa é: dar ao algoritmo a capacidade de identificar a probabilidade de a imagem fazer parte de uma das categorias (ZHE, et al., 2017).

Somente classificar um objeto não é suficiente, porque esse objeto está inserido em um meio ambiente então, necessitamos além de classificar essa imagem, localiza-la. Para isso, utilizando bases fundamentais de matrizes para localizar em qual ponto da imagem ela está, ou quantos pixels de imagem a compõem, a essa localização damos o nome de “caixa delimitadora ou bounding box”. Outro aspecto importante da técnica de *deep learning* é a segmentação, que é o processo de divisão em partes de uma imagem em conjuntos

chamados super-pixels. A fase de segmentação, tem como objetivo simplificar a representação de uma imagem em algo que é mais relevante e mais fácil de avaliar (DATA SCIENCE ACADEMY, 2019).

O computador avalia a imagem identificando itens como objetos, limites, linhas e outros itens nas imagens, em resumo a segmentação é o processo de rotulação a cada pixel em uma imagem, de modo que os pixels com a mesma classificação dividem as mesmas particularidades (DATA SCIENCE ACADEMY, 2019). As partes do corpo foram marcadas por suas posições em *pixels* encontrados no plano cartesiano existente na imagem e anexadas em uma matriz, chamada de Matriz das Partes que deu origem aos resultados presentes na (Tabela 1).

Utilizamos uma das imagens obtidas na fase de coleta, classificamos, localizamos e segmentamos a imagem a fim de obter informações importantes para o treinamento do algoritmo. Na tabela abaixo observamos que o algoritmo conseguiu identificar com uma probabilidade de 79% a região do pescoço, 83% a região do pulso esquerdo e 78% cotovelo esquerdo. Nas colunas “eixos” está demonstrado em que escala XY está a imagem obtida e em que escala pixel a mesma se encontra. A Tabela 1 demonstra com esse simples teste que o algoritmo foi capaz de cumprir bem as fases de classificação, localização e segmentação.

Tabela 1 - Matriz das partes – representando a probabilidade de identificação e localização no espaço de cada parte a ser identificada pelo algoritmo

Identificador da parte	Nome da parte	Probabilidade	Eixo X (Escala em pixel)	Eixo Y (Escala em Pixel)
1	Pescoço	0,79	70	15
2	Ombro Direito	0,65	31	15
3	Cotovelo Direito	0,71	31	86
4	Pulso Direito	0,83	15	157
5	Ombro Esquerdo	0,63	109	7
6	Cotovelo Esquerdo	0,78	125	78
7	Pulso Esquerdo	0,69	140	149
8	Quadril Direito	0,43	54	142
9	Joelho Direito	0,55	54	244
10	Tornozelo Direito	Não Identificado	Não Identificado	Não Identificado
11	Quadril Esquerdo	0,42	109	134
12	Joelho Esquerdo	0,47	109	236

Fonte: Ferreira VS, et al., 2020

Em todos os itens avaliados, o algoritmo obteve vantagem na identificação de desníveis posturais em relação ao avaliador humano. Os resultados de pesquisas no geral, mostram que o auxílio de ferramentas computacionais pode melhorar e muito a taxa de acerto em diagnóstico sendo essa, usada não como competidor do ser humano, mas como auxiliar.

Em outros estudos onde foram criados sistemas automatizados para a avaliação se observa uma situação semelhante, no estudo de Wang D, et al. (2016) foi revelado que a interação entre o humano e a máquina aumenta e muito a taxa de acerto, o estudo foi elaborado para identificar metástases de câncer através da avaliação de imagens, os autores explicitam que é importante ressaltar que os erros cometidos pelo algoritmo

não estavam fortemente correlacionados com os erros cometidos por um patologista humano. Portanto, embora o patologista sozinho seja atualmente superior ao sistema de aprendizado, a combinação de aprendizado profundo com o patologista produziu uma grande redução na taxa de erro do patologista, reduzindo-a de mais de 3% para menos de 1%. De maneira mais geral, esses resultados sugerem que a integração de abordagens baseadas em aprendizado profundo no fluxo de trabalho do patologista de diagnóstico pode gerar melhorias na reprodutibilidade, precisão e valor clínico dos diagnósticos patológicos (WANG D, et al., 2016).

Um dos motivadores desse estudo foi a constatação na literatura em relação à falta de objetividade na concordância das avaliações inter-examinadores, outros fatores humanos podem ser considerados quando um pesquisador opta por uma ferramenta computacional para auxiliar em diagnósticos médico, segundo Han Z, et al. (2017) há três razões principais que justifiquem o uso de ferramentas computacionais no diagnóstico na área da patologia clínica: falta de inovação na área de patologia clínica, ausência de patologistas qualificados, tarefa repetitiva e tediosa, fadiga dos patologistas poderia levar a muitos erros de diagnósticos (HAN Z, et al., 2017).

O estudo de Santos HG, et al. (2019), comprovou que a associação entre recurso humano e computador pode ser muito exitosa, o algoritmo elaborado pelos autores, identificou os tumores em 92% das vezes, os humanos em 96% das avaliações. Validando assim a hipótese da validade da associação, juntos, os dois métodos chegaram a 99,5% de taxa de acerto.

De acordo com a **Tabela 2**, os resultados obtidos na avaliação postural tradicional, demonstram a vantagem na avaliação feita de forma artificial. Pequenos desníveis não foram identificados pelo avaliador. Utilizamos uma lógica simples para demonstrar a eficiência do método artificial. A pergunta direcionada ao avaliador era: 1: há desvio, 0: não há desvio. As maiores similaridades foram observadas quando avaliamos ombro e coluna cervical, torácica e lombar. Na tabela abaixo, temos o resultado da vantagem do algoritmo em relação ao avaliador, x – representa melhor avaliação. Os resultados demonstram que na avaliação total, o algoritmo teve vantagem, principalmente quando os desníveis foram mínimos. Quando era perguntado ao avaliador e este respondia não haver desnível postural, este desnível sempre esteve entre 1º e 3º, acima disso, o avaliador humano conseguiu identificar na maioria dos casos.

Quadro 2 - Comparação entre a avaliação com base no modelo ideal inserido entre a avaliação tradicional e a avaliação artificial

Item avaliado	Avaliação artificial
Cabeça	X
Ombro	X
Cotovelos	X
Punhos	X
Coluna cervical	X
Coluna Torácica	X
Coluna Lombar	X
Joelho	X
Tornozelo	X

Fonte: Ferreira VS, et al., 2020

CONCLUSÃO

Diante do que foi apresentado, concluímos que a criação do modelo artificial apresentado neste estudo representa uma importante ferramenta auxiliar no diagnóstico e acompanhamento de pacientes. Torna-se importante salientar que o estudo não é uma ferramenta preditora de dor ou lesão osteo-articular, portanto, outros estudos devem ser empregados nessa linha de pesquisa a fim de aumentar a contribuição científica no tema que ao passar dos anos se torna motivo de preocupação e importância mundial tanto nos ambientes relacionados à esporte e lazer quanto nos setores produtivos do país, visto que, doenças ocupacionais são um grande motivador ao afastamento no trabalho.

REFERÊNCIAS

1. ALTHOFF A, et al. Back to the Basics—Whatever Happened to Posture? A report on a posture screening program at Portland State University. *Journal of Physical Education, Recreation & Dance*, 1998-2013; 43: 45-55.
2. DATA SCIENCE ACADEMY. Disponível em: <http://datascienceacademy.com.br/blog/segmentacao-de-imagens-medicas-com-deep-learning/>. Acesso em: 05 de novembro de 2019.
3. FEDORAK C, et al. Reliability of the visual assessment of cervical and lumbar lordosis: how good are we?. *Spine*. 2003; 28: 1857-1859.
4. GANGNET N, et al. Variability of the spine and pelvis location with respect to the gravity line: a three-dimensional stereoradiographic study using a force platform. *Surgery Radiology and Anatomy: SRA*. 2013; 25: 424-33, 2013.
5. HAN Z, et al. Breast Cancer Multi-classification from Histopathological Images with Structured Deep Learning Model, *Scientific Reports*, 2017; 55: 443-456.
6. KENDALL FP, MCCREARY EK, PROVANCE PE. *Músculos: provas e funções*. 5^a ed. São Paulo: Ed. Manole, 1995; 556 p.
7. NOGUEIRA, A et al. Pescoço de texto e postura em adolescentes: de 11 a 17 anos: estudo clínico, controlado, randomizado e duplo cego, REAS, *Revista Eletrônica Acervo Saúde*, 2018; 14: 1672-1683.
8. PAYAN A, MONTANA G. Predicting Alzheimer's disease: a neuroimaging study with 3D convolutional neural networks. *ArXiv*, 2015; 1-9.
9. SANTOS JB, et al. Descrição do método de avaliação postural de Portland State University. *Fisioterapia Brasil*, 2005; 6(5): 45-55.
10. SANTOS HG, et al. Machine learning para análises preditivas em saúde: exemplo de aplicação para prever óbito em idosos de São Paulo, Brasil. *Cadernos de Saúde Pública*, 2019; 35 (7): 1-16.
11. SEDREZ JA, CANDOTTI CT. Métodos não invasivos de avaliação postural da escoliose: Uma revisão sistemática. *Motricidade*, 2013; 9(4): 100-111.
12. SINGLA MP, et al. Photogrammetric Assessment of Upper Body Posture Using Postural Angles: A Literature Review. *Journal of Chiropractic Medicine*, 2017.
13. SHARMA K, et al. Predicting Alzheimer's disease: a neuroimaging study with 3D convolutional neural networks. *ArXiv*, 2015; 1-9.
14. WANG D, et al. Deep Learning for Identifying Metastatic Breast Cancer. *ArXiv*, 2016; 1-8.
15. ZHE C, SHIH-EN S e SHEIKH WY. Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields. *The Robotics Institute, Carnegie Mellon University*, 2017.