



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
MESTRADO ACADÊMICO EM ENGENHARIA DE TELEINFORMÁTICA

JOÃO WELLINGTON MENDES DE SOUZA

**UMA ABORDAGEM PARA A ESTIMATIVA DE MEDIDAS ANTROPOMÉTRICAS A
PARTIR DE IMAGENS 2D UTILIZANDO *MACHINE LEARNING***

FORTALEZA

2023

JOÃO WELLINGTON MENDES DE SOUZA

UMA ABORDAGEM PARA A ESTIMATIVA DE MEDIDAS ANTROPOMÉTRICAS A
PARTIR DE IMAGENS 2D UTILIZANDO *MACHINE LEARNING*

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S238a Souza, João Wellington Mendes de.
Uma abordagem para a estimativa de medidas antropométricas a partir de imagens 2D utilizando Machine Learning / João Wellington Mendes de Souza. – 2023.
52 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2023.
Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
1. Medidas Antropométricas. 2. Machine Learning. 3. Redes Neurais Convolucionais. I. Título.
CDD 621.38
-

JOÃO WELLINGTON MENDES DE SOUZA

UMA ABORDAGEM PARA A ESTIMATIVA DE MEDIDAS ANTROPOMÉTRICAS A
PARTIR DE IMAGENS 2D UTILIZANDO *MACHINE LEARNING*

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Pedro Pedrosa Rebouças Filho (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Guilherme de Alencar Barreto
Universidade Federal do Ceará (UFC)

Prof. Dr. José Daniel de Alencar Santos
Instituto Federal de Educação, Ciência e Tecnologia
do Ceará (IFCE)

AGRADECIMENTOS

À minha família, pelo amor incondicional e por todo suporte prestado durante toda minha vida.

À minha companheira, Kallyne, por seu amor e carinho durante esta caminhada.

Ao meu orientador, Prof. Dr. Pedro Pedrosa, por sua orientação, ensinamentos e suporte durante todo desenvolvimento acadêmico.

Aos professores e colegas do Programa de Pós-Graduação em Engenharia de Teleinformática da Universidade Federal do Ceará (PPGETI/UFC), especialmente para os colaboradores do Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (LAPISCO), que sempre apoiaram e ajudaram de alguma forma.

A todos que não foram citados mas contribuíram direta ou indiretamente na minha jornada.

RESUMO

Medidas antropométricas são utilizadas em diversas áreas de estudo, podendo ser aplicadas na saúde pública como um indicador de risco cardiovascular; também podem ser empregadas como um parâmetro para confecção de roupas sob medida ou mesmo para reconstrução corporal em um acompanhamento nutricional. Assim, a estimativa automática dessas medidas pode proporcionar uma melhoria nos processos antropométricos, ainda mais se for baseada em imagens 2D, pois representa um ganho devido ao baixo custo de implantação dessa tecnologia. Este trabalho apresenta uma abordagem para estimar essas medidas antropométricas por meio de imagens usando *Machine Learning* e CNNs. Além disso, durante esta pesquisa, foi proposto um conjunto de dados de medidas antropométricas, contendo 913 amostras (500 mulheres e 413 homens) com imagens e medidas (bíceps, panturrilha, antebraço, quadril, coxa e cintura), bem como informações adicionais dos pacientes, como idade, altura e peso. Por fim, foram realizados experimentos para analisar a influência das informações do paciente na estimativa das medidas, bem como uma análise de gênero para obter *insights* sobre o conjunto de dados. Na abordagem proposta, em experimentos utilizando dados do sexo feminino na predição da medida antropométrica do antebraço, foram obtidos um MAE de $0,778 \pm 0,083cm$, RMSE de $1,096 \pm 0,292cm$, utilizando o regressor *Elastic-Net*. Chegamos a uma marca de aproximadamente 2% com o MAPE utilizando o regressor SVR com dados do gênero masculino para a predição da medida do quadril. Por fim, este trabalho apresenta resultados satisfatórios, já que dispõe de uma margem pequena de erro, assim como uma superioridade perante resultados de uma abordagem semelhante presente na literatura.

Palavras-chave: medidas antropométricas; *machine learning*; redes neurais convolucionais.

ABSTRACT

Anthropometric measurements are used in several areas of study and can be applied in public health as an indicator of cardiovascular risk; it can also be used as a parameter for making tailored clothes or even for body reconstruction in a nutritional follow-up. Thus, the automatic estimation of these measurements can provide an improvement in anthropometric processes, even more so if it is based on 2D images, as it represents a gain due to the low cost of implementing this technology. This work presents an approach to estimate these anthropometric measurements through images using Machine Learning and CNNs. Furthermore, during this research, an anthropometric measurements dataset was proposed containing 913 samples (500 women and 413 men) with images of human body and measurements (biceps, calf, forearm, hip, thigh and waist) and the patients' additional information, like age, height and weight. Finally, experiments were performed to analyze the influence of patient information on the estimation of measures, as well as a gender analysis to obtain insights into the dataset. In the proposed approach, experiments using female data in predicting the forearm anthropometric measurement yielded a (MAE) of $0.778 \pm 0.083cm$ and (RMSE) of $1.096 \pm 0.292cm$ using the Elastic-Net regressor. We achieved an approximate 2% error with (MAPE) using SVR regressor with male gender data for predicting hip measurement. Lastly, this work presents satisfactory results since it has a small margin of error and superiority compared to the results of a similar approach in the literature.

Keywords: anthropometric measurements; machine learning; convolutional neural networks.

LISTA DE FIGURAS

Figura 1 – Estrutura básica de uma rede neural MLP.	19
Figura 2 – Exemplo de arquitetura de CNN com a divisão de camadas.	22
Figura 3 – Exemplo de operações e estruturas básicas de uma arquitetura de CNN.	23
Figura 4 – Exemplo da qualidade das segmentações da YOLACT++ em comparação com outros modelos: Mask R-CNN (HE <i>et al.</i> , 2017) e FCIS (LI <i>et al.</i> , 2017)	26
Figura 5 – Fluxograma da abordagem proposta.	28
Figura 6 – Amostras do conjunto de dados proposto.	29
Figura 7 – Amostras de imagens segmentadas e com estimação de pose.	30
Figura 8 – Localização das Distâncias Antropométricas Planas (DAPs).	31
Figura 9 – Comparação entre métodos de transformação de dados, onde a normalização utiliza o mínimo e o máximo; e a padronização utiliza a média e o desvio padrão.	36
Figura 10 – Resultados médios para cada medida antropométrica agrupados por experimento, índice de desempenho e sexo.	38
Figura 11 – Melhores resultados (regressor e gênero) para cada medida antropométrica separada por experimento.	39

LISTA DE TABELAS

Tabela 1 – Configuração dos regressores.	35
Tabela 2 – Comparação entre os resultados do trabalho proposto por Souza <i>et al.</i> (2020) e pela abordagem proposta nesse trabalho usando ambos dados de sexo masculino e feminino.	41
Tabela 3 – Resultados de ambos os experimentos para o bíceps.	43
Tabela 4 – Resultados de ambos os experimentos para a panturrilha.	44
Tabela 5 – Resultados de ambos os experimentos para o antebraço.	45
Tabela 6 – Resultados de ambos os experimentos para o quadril.	46
Tabela 7 – Resultados de ambos os experimentos para a coxa.	47
Tabela 8 – Resultados de ambos os experimentos para a cintura.	48

LISTA DE ABREVIATURAS E SIGLAS

MAE	<i>Mean Absolute Error</i>
RMSE	<i>Root Mean Square Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
DAP	Distância Antropométrica Plana
DXA	<i>Dual-energy X-ray absorptiometry</i>
MQO	Mínimos Quadrados Ordinários
SVR	<i>Support Vectors Regression</i>
MLP	<i>MultiLayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
CNN	<i>Convolutional Neural Network</i>
YOLACT	<i>You Only Look At CoefficientTs</i>
IoU	<i>Intersection over Union</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Estado da arte	14
1.2	Objetivos	14
1.2.1	<i>Objetivos específicos</i>	15
1.3	Produção científica	15
1.3.1	<i>Artigos publicados</i>	15
1.3.2	<i>Artigos submetidos</i>	16
1.4	Organização do trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Aprendizado de Máquina	17
2.1.1	<i>Método dos Mínimos Quadrados Ordinários</i>	17
2.1.2	<i>Regressão de Vetores de Suporte</i>	18
2.1.3	<i>Perceptron de Múltiplas Camadas</i>	19
2.1.4	<i>Árvores de Decisão</i>	20
2.1.5	<i>Floresta Aleatória</i>	20
2.1.6	<i>Elastic-Net</i>	21
2.2	Redes Neurais Convolucionais	22
2.2.1	<i>Estrutura básica de Redes Neurais Convolucionais (CNN)</i>	22
2.2.1.1	<i>Operações e estruturas</i>	22
2.2.1.2	<i>Tipos de camada</i>	24
2.2.1.3	<i>Funções de ativação</i>	24
2.2.2	<i>Yolact Plus (YOLACT++)</i>	25
2.2.3	<i>OpenPose</i>	26
3	METODOLOGIA	28
3.1	Conjunto de dados	29
3.2	Segmentação e estimativa de Pose	30
3.3	Engenharia de atributos	31
3.4	Estimativa de medidas antropométricas	32
3.5	Índices de desempenho	33
3.6	Transformação dos dados	34

4	RESULTADOS	35
4.1	Configuração experimental	35
4.2	Avaliação dos experimentos	37
4.3	Impacto do gênero sobre os resultados	40
4.4	Comparação com trabalhos da literatura	41
5	CONCLUSÕES E TRABALHOS FUTUROS	49
	REFERÊNCIAS	50

1 INTRODUÇÃO

A obesidade é um lado do duplo fardo da desnutrição, e hoje mais pessoas são obesas do que abaixo do peso em quase todas as regiões do mundo. A grande maioria das crianças com sobrepeso ou obesidade vive em países em desenvolvimento; em 2016, 1,9 bilhão de adultos estavam acima do peso e 650 milhões eram obesos em todo o mundo (WORLD HEALTH ORGANIZATION, 2021).

De acordo com a Consulta de Especialistas em Obesidade da Organização Mundial da Saúde (OMS), a razão cintura-quadril (ou seja, a circunferência da cintura dividida pela circunferência do quadril) foi sugerida como uma medida adicional da distribuição de gordura corporal devido à necessidade de outros indicadores para identificar indivíduos com risco aumentado de morbidade relacionada à obesidade (WORLD HEALTH ORGANIZATION EXPERT CONSULTATION ON OBESITY, 2008).

Sendo assim, no âmbito da antropometria¹, muitos estudos indicam que medidas antropométricas, como circunferências de cintura e quadril, oferecem aos profissionais uma oportunidade vital para melhorar o manejo e a saúde dos pacientes (ROSS *et al.*, 2020). Muitos aplicativos de celular utilizam essa medida para identificar a obesidade visceral (GADEKAR *et al.*, 2020; ROSS *et al.*, 2020), prever o risco cardiometabólico (NEVILL *et al.*, 2022; KE *et al.*, 2022), estimar o percentual de gordura do corpo humano (ALVES *et al.*, 2021), ou até mesmo definir a atratividade do corpo feminino (PAZHOOHI *et al.*, 2020).

Para ser mais claro, as medidas antropométricas são medidas físicas do corpo humano, usadas para avaliar a composição corporal, tamanho, proporções e outras características físicas dos indivíduos. Essas medidas podem ser obtidas por meio de técnicas de medição direta, como com o uso de fitas métricas e escalas, ou por meio de técnicas de imagem, como a tomografia computadorizada e a ressonância magnética. As medidas antropométricas são amplamente utilizadas em áreas como a saúde, a educação física e o esporte para avaliar o estado nutricional, a aptidão física, a composição corporal e outras características relacionadas ao corpo humano.

A relevância das medidas antropométricas não se limita a questões de saúde, impactando outras áreas como a indústria de moda e vestuário, onde a medição sem contato está revolucionando alguns negócios (MOHAMMADI; KALHOR, 2021; GHODHBANI *et al.*, 2022).

¹ Antropometria é a ciência que define as medidas físicas de tamanho, forma e capacidades funcionais de uma pessoa (KOMLOS; BATEN, 2004).

Dada a importância das medidas antropométricas em diversas áreas, a sua obtenção pode ser realizada através de uma fita métrica, necessitando de um contato humano. Essa forma é péssima para avaliações antropométricas em um cenário de isolamento social, como aconteceu na pandemia do Covid-19, pois o distanciamento social foi crítico e necessário (BAGNI *et al.*, 2021; KRZRNARIĆ *et al.*, 2020).

Especificamente, estimar com precisão as medidas antropométricas em uma abordagem sem contato é um problema desafiador. A solução facilitaria muitas áreas, como mencionado anteriormente, incluindo vendas de roupas *online*, ergonomia, atendimentos nutricionais, entre outros (JAVAID *et al.*, 2021).

Com isso, algumas aplicações surgiram, como varreduras corporais em 3D com multisensores que podem ser usados para adquirir medidas antropométricas por meio da reconstrução do corpo humano usando regressão não linear para fornecer estimativas de medidas antropométricas (LI *et al.*, 2022; XIE; ZHONG, 2020; YAN *et al.*, 2020).

Todavia, esses aplicativos exigem *hardware* sofisticado e não são tão triviais de usar. Alguns aplicativos usam apenas imagens para fornecer uma estimativa dessas medidas antropométricas que possuem alta aplicabilidade (ŠKORVÁNKOVÁ *et al.*, 2021; YAN; KÄMÄRÄINEN, 2021; SOUZA *et al.*, 2020).

Este trabalho apresenta uma abordagem para estimar medidas antropométricas por meio de imagens 2D utilizando Aprendizado de Máquinas (do inglês, *Machine Learning*) com análise baseada em gênero. Nesse contexto, houve a aplicação de métodos de regressão em aprendizado de máquina e houve uma exploração técnicas de pré-processamento e transformação usando alguns recursos para estimar medidas antropométricas com algumas análises baseadas em gênero.

Além disso, houve uma contribuição com um conjunto de dados, BodyFat-912 (BF-912), contendo diversas medidas antropométricas e exames por DXA² coletados por um especialista. O conjunto de dados consiste em 913 indivíduos (413 homens e 500 mulheres). É essencial ressaltar que este conjunto de dados é uma melhoria de trabalhos anteriores (ALVES *et al.*, 2021; SOUZA *et al.*, 2020).

² *Dual-energy X-ray absorptiometry* (DXA) é um meio que utiliza imagens espectrais para medir a densidade mineral óssea.

1.1 Estado da arte

Existem alguns trabalhos na literatura que propuseram abordagens para estimar medidas antropométricas. Esta seção apresentará algumas metodologias que seguem o mesmo objetivo de estimativa de medidas antropométricas.

Škorvánková *et al.* (2021) formularam pesquisas para estimativa de medidas corporais usando aprendizado profundo e redes neurais a partir de vários tipos de dados de entrada visual, como imagens 2D e 3D (nuvens de pontos). Eles também lidam com a falta de dados supervisionados, gerando um conjunto de dados sintéticos de várias formas do corpo humano e realizando uma anotação orientada por esqueleto.

Yan e Kämäräinen (2021) forneceram uma metodologia para um modelo de forma baseado em peças e uma rede neural profunda para estimar medidas antropométricas de imagens 2D. Eles também renderizaram os resultados em objetos 3D para simular medidas corporais virtuais personalizadas.

Nana *et al.* (2022) propuseram uma avaliação da composição corporal e antropométrica a partir de imagens bidimensionais por um *smartphone*. Além disso, os autores propuseram uma concordância da avaliação proposta em comparação com a análise tradicional de impedância bioelétrica³.

Por fim, apresentando uma continuação do desenvolvimento de uma pesquisa, foi referenciado um trabalho proposto por Souza *et al.* (2020) que teve como objetivo encontrar medidas antropométricas baseadas em aproximações geométricas após segmentação e pós-processamento dos contornos do corpo humano. Nesta abordagem, os autores coletaram pontos-chave por meio de correlações entre pontos de contorno e, com esses pontos-chave, localizaram-se as partes do corpo que foram então utilizadas para as aproximações geométricas.

1.2 Objetivos

Este trabalho tem como objetivo principal o desenvolvimento de uma abordagem para a estimativa de medidas antropométricas (i.e., quadril, cintura, *etc*) a partir de imagens bidimensionais utilizando *Machine Learning* como regressão.

³ Impedância bioelétrica é uma medida da resistência elétrica do corpo, frequentemente usada para estimar a composição corporal, obtida através de um equipamento chamado bioimpedância.

1.2.1 *Objetivos específicos*

Como objetivos específicos deste trabalho, temos:

- Ajudar na coleta, organização e distribuição de um conjunto de dados de medidas e avaliações antropométricas;
- Desenvolvimento de abordagem para a estimativa de medidas antropométricas, desde estratégias para a extração de características de imagens até a predição das medidas através de regressão;
- Analisar diversos métodos de regressão conceituados na literatura para a predição de medidas antropométricas;
- Avaliar os efeitos da separação por gênero do paciente na estimativa das medidas antropométricas;
- Comparar os resultados obtidos com os resultados de uma abordagem similar encontrada no estado da arte (SOUZA *et al.*, 2020).

1.3 **Produção científica**

1.3.1 *Artigos publicados*

1. **DE SOUZA, JOAO W. M.**; HOLANDA, GABRIEL B.; IVO, ROBERTO F.; ALVES, SHARA S. A.; DA SILVA, SUANE P. P.; NUNES, VIRGINIA X.; LOUREIRO, LUIZ LANNES; DIAS-SILVA, C. H.; REBOUCAS FILHO, PEDRO P. *Predicting body measures from 2D images using Convolutional Neural Networks*. International Joint Conference on Neural Networks (IJCNN), Glasgow, pp. 1-6, 2020.
2. ALVES, SHARA S. A.; OHATA, ELENE F.; NASCIMENTO, NAVAR M.M.; **DE SOUZA, JOAO W. M.**; HOLANDA, GABRIEL B.; LOUREIRO, LUIZ LANNES; REBOUCAS FILHO, PEDRO PEDROSA. *Gender-based approach to estimate the human body fat percentage using Machine Learning*. International Joint Conference on Neural Networks (IJCNN), Shenzhen, pp. 1-8, 2021.
3. SILVA, FRANCISCO H. DOS S.; BEZERRA, GABRIEL M.; HOLANDA, GABRIEL B.; **DE SOUZA, JOAO W. M.**; REGO, PAULO A. L.; LIRA NETO, ALOÍSIO V.; DE ALBUQUERQUE, VICTOR HUGO C.; REBOUÇAS FILHO, PEDRO P. *A novel feature extractor for human action recognition in visual question answering*. Pattern Recognition

Letters, v. 147, p. 41-47, 2021.

4. **DE SOUZA, JOAO W. M.**; MEDEIROS, A. G.; BANDEIRA HOLANDA, GABRIEL; REGO, PAULO A. L.; REBOUCAS FILHO, P. P. *Fingerprint Classification Based on the Henry System via ResNet*. International Conference on Systems, Signals and Image Processing (IWSSIP), Bratislava, ed. 1, v. 1527, p. 15-28, 2022.

1.3.2 Artigos submetidos

1. **DE SOUZA, JOAO W. M.**; NASCIMENTO, NAVAR M. M.; OHATA, ELENE F.; ALVES, SHARA S. A.; LOUREIRO, LUIZ L.; BITTENCOURT, VICTOR Z.; CAPISTRANO JUNIOR, VALDEN L. M.; REBOUCAS FILHO, PEDRO P. *Estimating anthropometric measurements through 2D images using Machine Learning with gender-based analysis*. International Joint Conference on Neural Networks (IJCNN), Queensland, 2023.

1.4 Organização do trabalho

Esta dissertação está organizada da seguinte forma: Inicialmente, o Capítulo 1 introduz este trabalho, contextualizando e apresentando os objetivos. No Capítulo 2, é apresentada a fundamentação teórica para o embasamento científico. Em seguida, a metodologia proposta é descrita no Capítulo 3, onde todos os processos realizados são descritos. No Capítulo 4, apresento os resultados e discussões com diversas análises sobre os experimentos realizados. Por fim, as conclusões e trabalhos futuros são apresentados no Capítulo 5.

2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo é disposto um arcabouço teórico que fundamenta os métodos e ferramentas utilizados neste trabalho. Com isso, são apresentados os métodos utilizados para segmentação, estimativa de pose e regressão. Para isso, esta fundamentação teórica é dividida em métodos de aprendizado de máquina (Seção 2.1) e ferramentas baseadas em arquiteturas redes neurais convolucionais (Seção 2.2).

2.1 Aprendizado de Máquina

Nesta seção são apresentados os métodos de aprendizado de máquina utilizados para regressão de dados.

2.1.1 Método dos Mínimos Quadrados Ordinários

O método dos Mínimos Quadrados Ordinários (MQO) é uma das abordagens mais conhecidas para regressão linear. Este método tem como objetivo minimizar a soma dos quadrados dos resíduos em um conjunto de dados, buscando o melhor ajuste linearmente possível (FREEDMAN, 2005).

Supondo que tenhamos N observações, cada observação i inclui uma resposta y_i e um vetor coluna \mathbf{x}_i de entrada referente à p parâmetros. Em um modelo de regressão linear, a variável de resposta y_i é uma função linear dos p parâmetros apresentada na Equação 2.1, onde β são os parâmetros desconhecidos, \mathbf{x}_i é o vetor coluna anteriormente mencionado e ε_i representa o erro ou resíduo da regressão.

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i = \mathbf{x}_i^T \beta + \varepsilon_i \quad (2.1)$$

Suponha que \mathbf{b} seja um valor candidato para o parâmetro β . O resíduo, representado por $y_i - \mathbf{x}_i^T \mathbf{b}$, para a i -ésima observação, avalia o grau de ajuste entre o dados reais e o modelo. A soma dos resíduos quadrados é uma medida do ajuste geral do modelo, apresentada na Equação 2.2 (HAYASHI, 2000).

$$S(\mathbf{b}) = \sum_{i=1}^N (y_i - \mathbf{x}_i^T \mathbf{b})^2 \quad (2.2)$$

O valor de \mathbf{b} que minimiza essa soma é chamado de estimativa MQO para β . A função $S(\mathbf{b})$ é quadrática em \mathbf{b} , possuindo um único mínimo global. Após a estimativa de β , os valores ajustados da regressão serão expressos por $\hat{y} = \mathbf{x}^T \mathbf{b}$ (HAYASHI, 2000).

2.1.2 Regressão de Vetores de Suporte

Esta técnica de regressão é baseada no conceito de máquina de vetores de suporte proposto por Vapnik (CORTES; VAPNIK, 1995). A Regressão de Vetores de Suporte (SVR, do inglês *Support Vectors Regression*) constrói um conjunto de hiperplanos interpoladores em um espaço vetorial de alta dimensão, que pode ser usado para problemas de regressão (BISHOP, 2006).

O objetivo da SVR é encontrar a função que melhor estima o valor de y para um dado conjunto de variáveis independentes \mathbf{x} . Essa técnica busca encontrar um hiperplano de regressão que minimize a soma dos erros de regressão e , ao mesmo tempo, mantenha uma margem de separação máxima entre os pontos de treinamento e o hiperplano interpolador. Essa margem é definida por um parâmetro C , que controla a penalidade por pontos estimados incorretamente (DRUCKER *et al.*, 1996; SMOLA; SCHÖLKOPF, 2004).

O processo de treinamento da SVR envolve a identificação dos vetores de suporte, que são os pontos de treinamento mais próximos do hiperplano interpolador. Esses pontos influenciam a posição e a inclinação desse hiperplano, e são usados para estimar os coeficientes da função. Essa técnica pode ser resolvida utilizando a técnica de multiplicadores de Lagrange, onde o modelo dual é dado pela Equação 2.3.

$$L(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \hat{\mathbf{x}}_i^T \mathbf{x}_j + \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i^* - \alpha_i) \quad (2.3)$$

sujeito à $\sum_{n=0}^N (\alpha_n - \alpha_n^*) = 0, \quad \forall n \in 0 \leq \alpha_n \leq C \quad \text{e} \quad \forall n \in 0 \leq \alpha_n^* \leq C.$

Já a função usada para prever novos valores depende apenas dos vetores de suporte, sendo apresentada na Equação 2.4.

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) (\hat{\mathbf{x}}_i^T \mathbf{x}) + b \quad (2.4)$$

onde α e α^* são os coeficientes de Lagrange e b é um termo constante independente.

2.1.3 Perceptron de Múltiplas Camadas

Para falar da rede neural artificial Perceptron de Múltiplas Camadas (MLP, do inglês *MultiLayer Perceptron*), é preciso introduzir o conceito de neurônio. Um neurônio artificial é a unidade básica de processamento de uma rede neural artificial, havendo três elementos essenciais: um conjunto de sinapses, um combinador linear e uma função de ativação. A função básica do neurônio artificial é realizar o somatório ponderado pelos pesos sinápticos e aplicar este resultado como entrada de uma função de ativação (HAYKIN, 1998).

A MLP é um rede neural que deriva do Perceptron Simples (MINSKY; PAPERT, 1969), algoritmo de aprendizado utilizado para resolver problemas linearmente separáveis. A MLP consiste em pelo menos três camadas de nós: uma camada de entrada, uma camada oculta e uma camada de saída, o que pode ser visto na Figura 1. Com exceção dos nós de entrada, cada nó é um neurônio artificial que usa uma função de ativação não linear. O MLP utiliza uma técnica de aprendizagem por retropropagação do erro para treinamento (RUMELHART *et al.*, 1986). Suas múltiplas camadas e ativação não linear diferenciam o MLP de um perceptron simples, podendo assim, processar dados que são não lineares.

Figura 1 – Estrutura básica de uma rede neural MLP.



Fonte: Elaborado pelo autor.

O seu uso pode ser destinado tanto a problemas de classificação quanto a problemas de regressão, necessitando de alguns ajustes na rede neural para cada caso, podendo assim empregar funções de ativação arbitrárias.

2.1.4 Árvores de Decisão

As Árvores de Decisão (do inglês, *Decision Trees*) são um método de aprendizado supervisionado que pode ser usado para problemas de regressão. O objetivo é criar um modelo que preveja o valor de uma variável de destino aprendendo regras de decisão simples inferidas dos recursos de dados. Uma árvore pode ser vista como uma aproximação constante por partes (BREIMAN *et al.*, 1984; QUINLAN, 1986).

Dados os vetores de treinamento $x_i \in \mathbb{R}^n; i = 1, \dots, l$ e um vetor de rótulo $y \in \mathbb{R}^l$, uma árvore de decisão particiona recursivamente o espaço de recursos de modo que as amostras com os mesmos rótulos ou valores de destino semelhantes sejam agrupadas.

Assumindo que os dados no nó m são representados por Q_m com n_m amostras, para cada divisão candidata $\theta = (j, t_m)$ consistindo em um recurso j e limite t_m , o algoritmo sugere particionar os dados em subconjuntos $Q_m^{esquerda}(\theta)$ e $Q_m^{direita}(\theta)$, como apresentado na Equação 2.5.

$$\begin{aligned} Q_m^{esquerda}(\theta) &= \{(x, y) \mid x_j < t_m\} \\ Q_m^{direita}(\theta) &= Q_m \setminus Q_m^{esquerda}(\theta) \end{aligned} \tag{2.5}$$

Se o alvo for um valor contínuo (regressão), então, para o nó m , os critérios comuns a serem minimizados para determinar os locais para futuras divisões são o erro quadrático médio (MSE), o desvio de Poisson, bem como o erro absoluto médio (MAE). O MSE e o desvio de Poisson definem o valor previsto dos nós terminais para o valor médio aprendido \bar{y}_m do nó, enquanto o MAE define o valor previsto dos nós terminais para a mediana.

2.1.5 Floresta Aleatória

O algoritmo da Floresta Aleatória (do inglês, *Random Forest*) faz parte de um conjunto de métodos *ensemble*, que tem como objetivo combinar as previsões de vários estimadores construídos com um determinado algoritmo de aprendizado, a fim de melhorar a generalização/robustez em um único estimador. Nesse caso, esse algoritmo utiliza uma abordagem de reamostragem e combinação de forma adaptativa com o conjunto de dados original (BREIMAN, 1998).

Nesse algoritmo, por padrão, cada árvore do conjunto é construída a partir de uma amostra extraída com reposição do conjunto de treinamento, sendo uma alternativa à utilização

de todo o conjunto de dados para construir cada árvore. Além disso, ao dividir cada nó durante a construção de uma árvore, a melhor divisão é encontrada em todos os recursos de entrada ou em um subconjunto aleatório de tamanho máximo de recursos (BREIMAN, 2001).

O objetivo dessas duas fontes de aleatoriedade é diminuir a variância do estimador florestal. De fato, as árvores de decisão individuais geralmente exibem alta variância e tendem a se sobreajustar. A aleatoriedade injetada nas florestas produz árvores de decisão com erros de previsão desacoplados. Tirando uma média dessas previsões, alguns erros podem ser anulados. As Florestas Aleatórias obtêm uma variância reduzida combinando diversas árvores, às vezes ao custo de um ligeiro aumento no viés. Na prática, a redução da variância geralmente é significativa, resultando em um modelo geral melhor.

No seu uso para regressão, o algoritmo ajusta uma série de árvores de decisão em várias sub-amostras do conjunto de dados e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo.

2.1.6 *Elastic-Net*

A *Elastic-Net* é um modelo de regressão linear que combina linearmente as penalidades (coeficientes de regularização) ℓ_1 e ℓ_2 dos métodos *Lasso* e *Ridge* (TIBSHIRANI, 1996; HILT; SEEGRIST, 1977) para regularizar os modelos de regressão. Essa combinação permite obter um modelo esparsos onde poucos dos pesos são diferentes de zero, mantendo as propriedades de regularização. Pode-se controlar a combinação convexa dos coeficientes ℓ_1 e ℓ_2 usando um parâmetro de razão entre os coeficientes ρ , penalizando proporcionalmente um ou o outro (ZOU; HASTIE, 2005).

O processo de busca do estimador da *Elastic-Net* consiste em duas etapas, que envolvem os métodos *Lasso* e *Ridge*. Ele primeiro encontra os coeficientes de regressão *Ridge* e, em seguida, conduz a segunda etapa usando uma espécie de encolhimento dos coeficientes do *Lasso*.

A minimização da função objetivo, neste caso, é apresentada na Equação 2.6, onde N é o número de amostras, φ e ρ são constantes, que podem ser estimadas por validação cruzada, β são os coeficientes do modelo, \mathbf{x} e y são as variáveis do conjunto de dados utilizado.

$$\min_{\beta} \frac{1}{2n} \sum_{i=1}^N \|y_i - \mathbf{x}_i^T \beta\|_2^2 + \varphi \rho \|\beta\|_1 + \frac{\varphi(1-\rho)}{2} \|\beta\|_2^2 \quad (2.6)$$

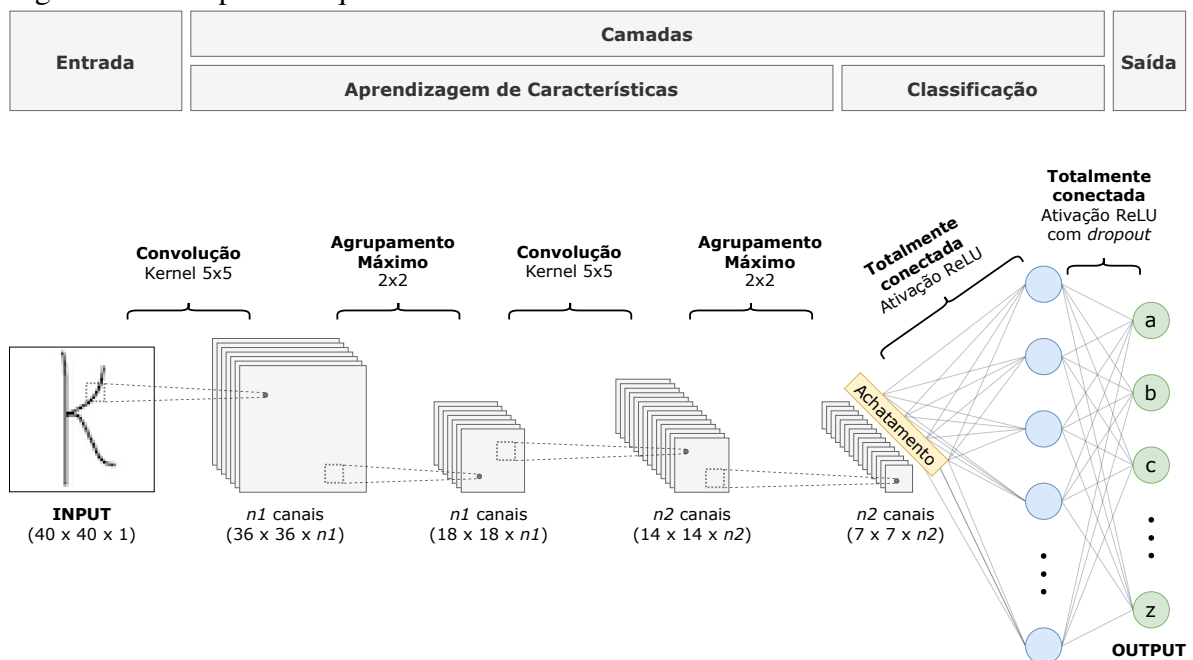
2.2 Redes Neurais Convolucionais

Nesta seção são apresentados as ferramentas baseadas em redes neurais convolucionais, além de introduzir seus fundamentos básicos.

2.2.1 Estrutura básica de Redes Neurais Convolucionais (CNN)

Uma Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*) é uma arquitetura de rede para aprendizado profundo que aprende diretamente dos dados. CNNs são particularmente úteis para encontrar padrões em imagens para reconhecer objetos. Eles também podem ser bastante eficazes para classificar dados que não sejam de imagem, tais como: áudio, séries temporais e sinais no geral (GOODFELLOW *et al.*, 2016). A Figura 2 apresenta um exemplo de arquitetura de CNN com a divisão de suas camadas, visando resolver um problema de classificação de caracteres.

Figura 2 – Exemplo de arquitetura de CNN com a divisão de camadas.

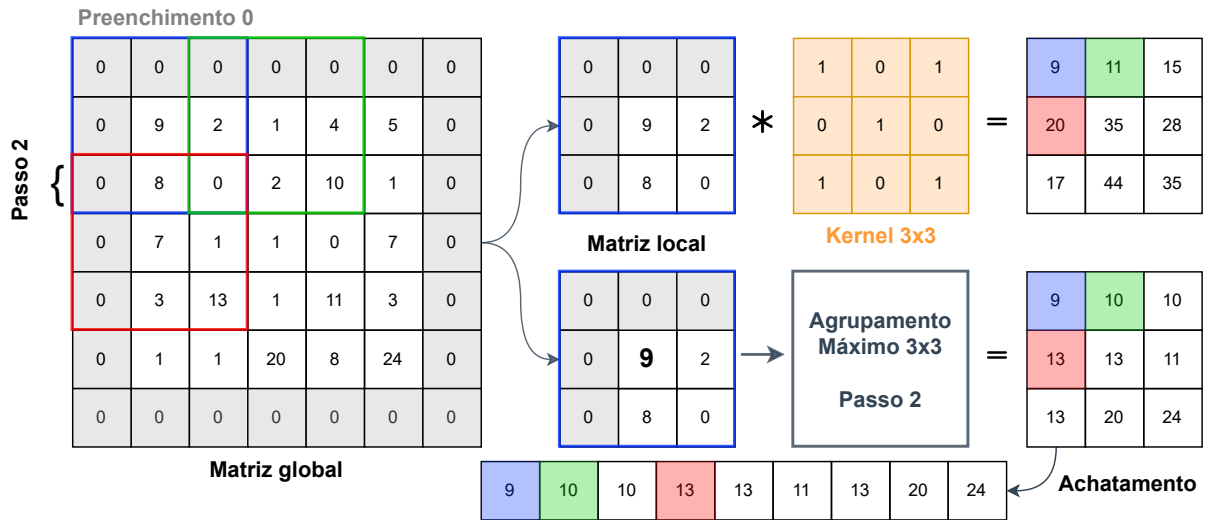


Fonte: Elaborado pelo autor.

2.2.1.1 Operações e estruturas

As operações em CNNs baseiam-se em operações de filtragem digital, no qual são aplicadas no processo de convolução. Algumas das operações e estruturas mais utilizadas são: *kernel*, passo (*stride*), preenchimento (*padding*), agrupamento (*pooling*) e achatamento (*flatten*).

Figura 3 – Exemplo de operações e estruturas básicas de uma arquitetura de CNN.



Fonte: Elaborado pelo autor.

A Figura 3 apresenta um exemplo prático das operações e estruturas aplicadas em uma arquitetura da CNN. O Kernel nada mais é do que uma estrutura usada na filtragem, que serve para extrair as características das matrizes locais.

Já o passo é um parâmetro do filtro da rede neural que modifica a quantidade de movimento sobre a matriz de entrada. No exemplo da Figura 3 temos o passo 2, então a varredura irá se deslocar de 2 em 2 pixels, coletando as matrizes locais a partir do pixel central.

Outro parâmetro utilizado é o preenchimento, pois se refere ao valor dos pixels adicionados ao redor da matriz quando ela está sendo processada por um kernel de uma CNN. No exemplo da Figura 3, utilizamos um preenchimento com valores 0, ou seja, cada valor de pixel adicionado terá o valor zero.

O agrupamento é uma técnica para generalizar recursos extraídos por filtros convolucionais e ajudar a rede a reconhecer recursos independentemente de sua localização na imagem. No exemplo da Figura 3, utilizamos um agrupamento máximo de 3x3 com o passo 2. Com isso, generalizamos a matriz global em uma matriz bem reduzida.

Por fim, o achatamento é usado para converter todas as matrizes bidimensionais resultantes de operações convolucionais em um único vetor linear contínuo. A matriz achatada é alimentada como entrada para a camada totalmente conectada, como veremos a seguir.

2.2.1.2 Tipos de camada

As CNNs se distinguem de outras redes neurais por seu desempenho superior com entradas de sinais n -dimensionais. Elas têm três tipos principais de camadas, que são: convolucionais, agrupamento (*pooling*) e totalmente conectadas (*fully-connected*).

A camada convolucional é usada para extrair os vários recursos das imagens de entrada através do processo de convolução. Nesta camada, usamos a estrutura de *kernel* para extrair recursos da imagem de entrada.

Já a camada de agrupamento tem como principal objetivo, diminuir o tamanho da matriz de características¹ para reduzir os custos computacionais. Isso é realizado diminuindo as conexões entre as camadas e operando independentemente em cada matriz de características. Dependendo do método usado, existem vários tipos de operações de agrupamento, como o agrupamento máximo e o agrupamento médio.

Por fim, a camada totalmente conectada consiste nos neurônios, sendo usada para conectar os neurônios entre duas camadas diferentes. Essas camadas geralmente são colocadas antes da camada de saída, formando as últimas camadas de uma arquitetura de CNN.

Outra característica típica das CNNs é a camada *dropout*. Essa camada é basicamente uma máscara que anula alguns neurônios, inibindo o fluxo para a próxima camada, deixando o fluxo normal no restante dos neurônios.

2.2.1.3 Funções de ativação

Uma função de ativação determina se um neurônio deve ser ativado ou não. Isso significa que ela decidirá se a entrada do neurônio na rede é importante ou não no processo de predição. Existem várias funções de ativação comumente usadas, cada uma para um propósito específico, tais como: Sigmóide, Tanh, Softmax e ReLU (DUBEY *et al.*, 2021; NWANKPA *et al.*, 2018).

A função Sigmóide é apresentada na Equação 2.7. Sendo uma função não-linear, ela é utilizada principalmente quando desejamos uma classificação binária, por empurrar seus valores para os extremos, sendo muito desejável quando lidamos com uma classe específica.

¹ Matriz resultante após o processo de convolução.

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.7)$$

A função Tanh funciona de forma semelhante à função sigmóide, com a diferença de ser simétrica em relação à origem, variando de -1 a 1 . Ela é apresentada na Equação 2.8.

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.8)$$

A função Softmax é usada frequentemente como a última função de ativação de uma rede neural para normalizar a saída de uma rede para uma distribuição de probabilidade sobre as classes de saída previstas. A Equação 2.9 descreve essa função.

$$\text{Softmax}(\mathbf{x})_j = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}}; j = 1, \dots, K \text{ e } \mathbf{x} = (x_1, x_2, \dots, x_K) \in \mathbb{R}^K \quad (2.9)$$

onde a entrada é um vetor \mathbf{x} de K números reais, normalizado por uma distribuição de probabilidade que consiste em K probabilidades proporcionais aos exponenciais dos números de entrada.

Por fim, apresentada na Equação 2.10, a principal vantagem de usar a função ReLU sobre outras funções de ativação é que ela não ativa todos os neurônios ao mesmo tempo.

$$\text{ReLU}(x) = \max(0, x) \quad (2.10)$$

2.2.2 Yolact Plus (YOLACT++)


O *YOLACT++*, ou simplesmente *Yolact Plus*, é um modelo simples e totalmente convolucional para segmentação de instância em tempo real², que alcança resultados competitivos no MS COCO³ (LIN *et al.*, 2014) avaliado em um única placa gráfica Titan XP (BOLYA *et al.*, 2020).

Herdando as estruturas do YOLACT (BOLYA *et al.*, 2019), o *YOLACT++* incorpora convoluções deformáveis no núcleo da rede, com melhores escalas das caixas de ancoragem e com uma nova abordagem para repontuação das máscaras, podendo assim otimizar a frente de predição.

² Apresenta uma performance maior que 30 *frames/segundo*.

³ Microsoft COCO é um conjunto de dados de detecção, segmentação e legendagem de objetos em larga escala.

Figura 4 – Exemplo da qualidade das segmentações da YOLACT++ em comparação com outros modelos: Mask R-CNN (HE *et al.*, 2017) e FCIS (LI *et al.*, 2017)



Fonte: Retirado e adaptado de Bolya *et al.* (2020).

A Figura 4 apresenta uma comparação gráfica da segmentação da YOLACT++ em relação a outros modelos de referência da literatura. A escolha desse modelo para este trabalho se dá principalmente porque ele se destaca em relação a outros modelos presentes na literatura, proporcionando um ótimo custo-benefício, com a melhor segmentação e um dos melhores custos.

A abordagem de repontuação das máscaras foi inspirada no *Mask R-CNN* (HE *et al.*, 2017), introduzindo uma rede de rápida repontuação da máscara, que reavalia as máscaras preditas com base em sua máscara IoU com o padrão-ouro.

A rede de rápida repontuação da máscara, é uma rede totalmente convolucional de 6 camadas com não linearidade garantida pela função de ativação ReLU por camada de convolução e uma camada de agrupamento no final.

Assim, o modelo da YOLACT++ concatena a rede de repontuação das máscaras com a YOLACT, além de substituir algumas camadas com blocos de redes residuais por camadas de convolução deformável.

2.2.3 *OpenPose*

O método de Estimativa de Pose 2D de Várias Pessoas em Tempo Real, também conhecido como *OpenPose*, é uma abordagem que usa uma representação não paramétrica para aprender a associar partes do corpo com indivíduos na imagem (CAO *et al.*, 2019).

A arquitetura codifica o contexto global, permitindo uma etapa de análise de afunilamento que mantém alta precisão enquanto alcança desempenho em tempo real, independentemente do número de pessoas na imagem. A arquitetura é projetada para aprender conjuntamente

as localizações das peças (pontos-chave no corpo humano) e sua associação por meio de duas ramificações do mesmo processo de previsão sequencial.

Essa abordagem já é uma melhoria de sua versão anterior, que sofria com problemas de desempenho porque o tempo de execução era diretamente proporcional ao número de pessoas na imagem, devido a uma estratégia que estima a pose de cada pessoa em cada uma das regiões detectadas (CAO *et al.*, 2017).

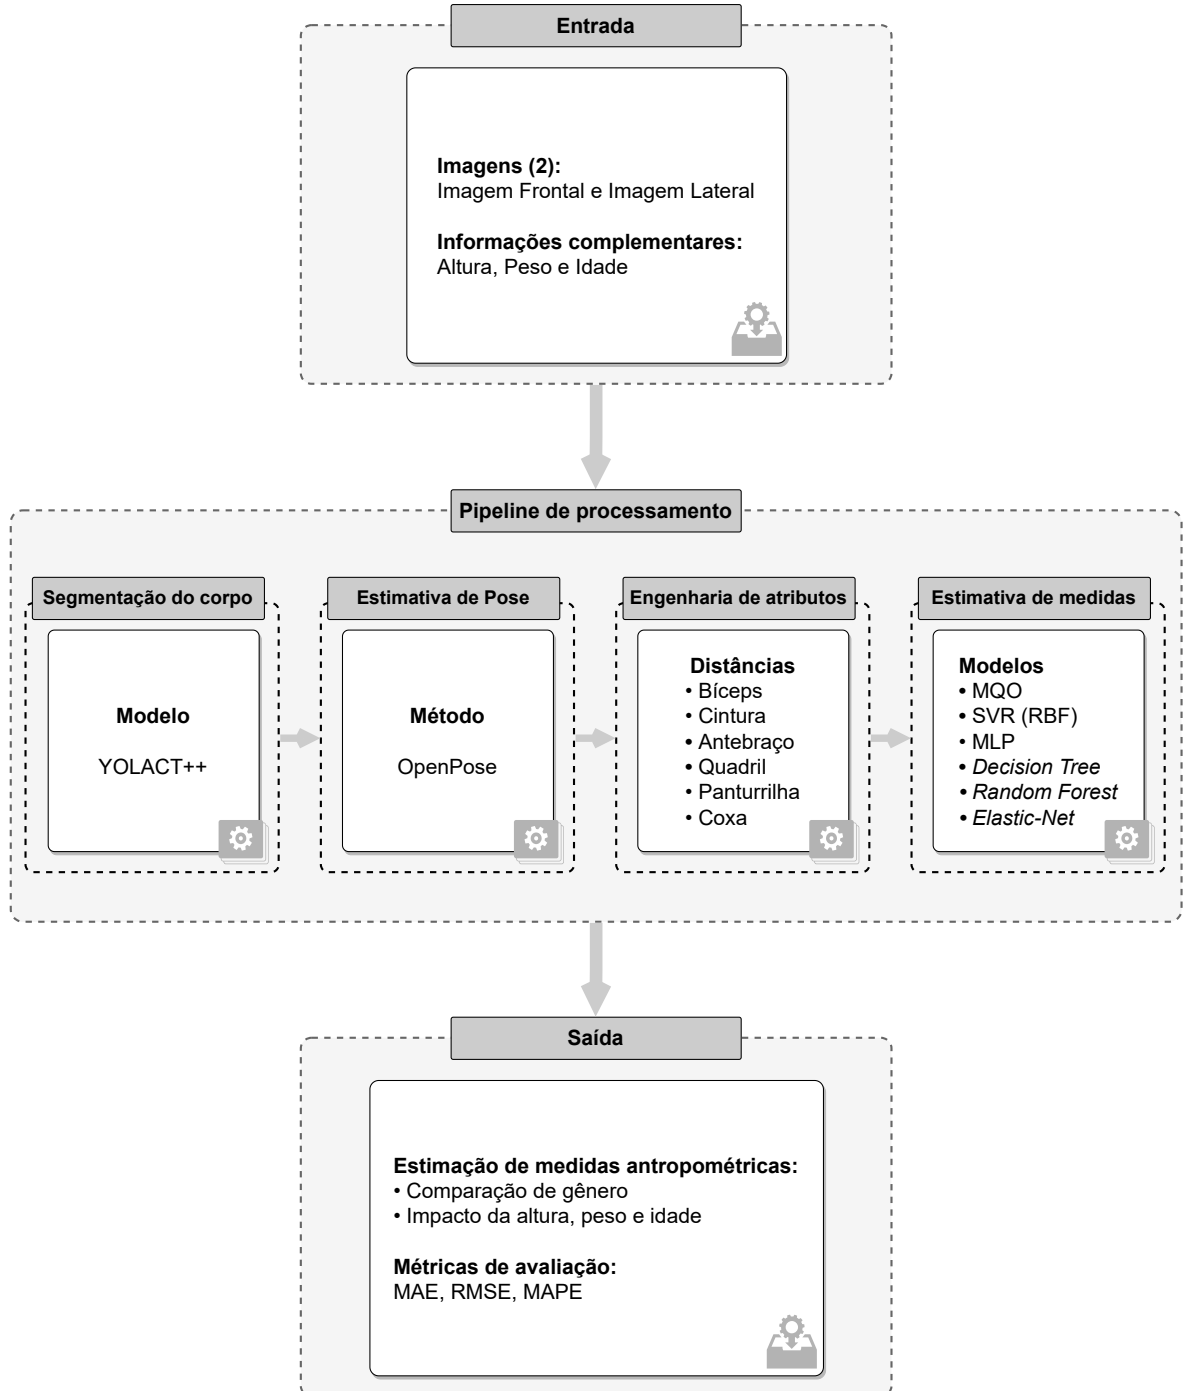
Apesar desse método ser projetado e avaliado utilizando GPUs, há trabalhos que adaptaram sua arquitetura para funcionar com um custo mais equilibrado, funcionando em CPUs, ampliando a aplicabilidade em diferentes contextos (OSOKIN, 2018).

Os métodos de CNN apresentados nesta seção, assim como os métodos clássicos de Aprendizado de Máquinas expostos na Seção 2.1, formam o embasamento teórico que será utilizado para construir a metodologia deste trabalho, exposta no Capítulo 3.

3 METODOLOGIA

Neste capítulo, há o detalhamento da abordagem proposta, desde o conjunto de dados analisado até os métodos e ferramentas utilizados neste trabalho. A Figura 5 apresenta o fluxograma da abordagem proposta que inclui todos os procedimentos utilizados neste trabalho.

Figura 5 – Fluxograma da abordagem proposta.



Fonte: Elaborado pelo autor.

3.1 Conjunto de dados

O conjunto de dados utilizado é composto por 913 amostras: 413 homens e 500 mulheres, e contém as seguintes informações: 4 imagens, idade, altura, peso, resultado do exame DXA, circunferências do bíceps, antebraço, cintura, quadril, coxa e panturrilha. Todas as medidas foram utilizadas na unidade de centímetros. Uma câmera de *smartphone* obteve imagens de todas as perspectivas do corpo com resolução de 1920×1080 pixels na profundidade de 8 bits. A Figura 6 apresenta algumas amostras do conjunto de dados utilizado.

Quatro imagens do corpo humano foram adquiridas para cada pessoa, contendo perspectivas frontal, traseira, lateral direita e lateral esquerda. O conjunto de dados inclui pessoas de 18 a 65 anos e DXA em 9,30 – 57,60. As imagens e medidas foram coletadas por profissionais da área de nutrição da Universidade Federal do Rio de Janeiro (UFRJ).

O conjunto de dados e aquisição foram analisados e aprovados pelo Comitê de Ética em Pesquisa do IFCE (Protocolo nº 3.593.367), dentro dos parâmetros exigidos. Assim, todos os indivíduos concordaram que os dados coletados poderiam ser utilizados para fins de pesquisa e que estão dentro dos parâmetros exigidos. Esse conjunto de dados foi proposto em um artigo submetido proveniente desta dissertação, expresso na Seção 1.3.2 (ALVES *et al.*, 2021; SOUZA *et al.*, 2020).

Figura 6 – Amostras do conjunto de dados proposto.

(a) Imagem Frontal



(b) Imagem Lateral (Esquerda)



Fonte: Conjunto de dados apresentado na Seção 3.1.

3.2 Segmentação e estimativa de Pose

Dadas as imagens do conjunto de dados, foram utilizadas apenas as imagens da frente e do lado esquerdo, buscando diminuir o custo de processamento e carga de trabalho para estimação, uma vez que para cada estimativa teríamos que coletar somente 2 imagens ao invés de 4, conforme apresentado para cada amostra do conjunto de dados.

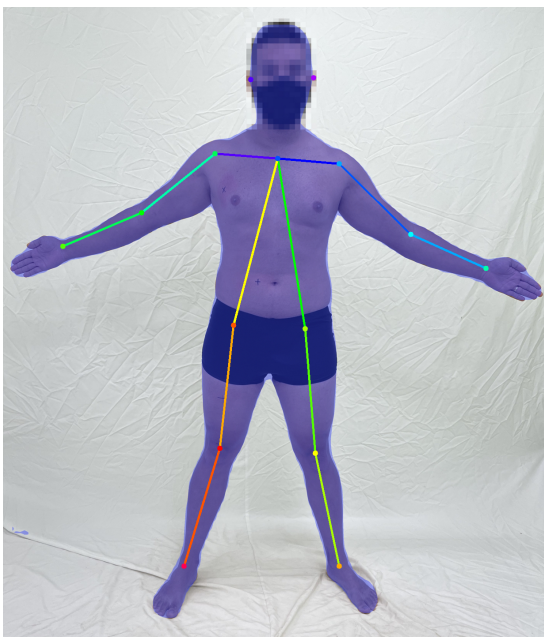
Primeiramente, a YOLACT++ (BOLYA *et al.*, 2020) foi aplicada para ambas as imagens, em busca de obter imagens segmentadas. Após a segmentação, foi extraído o contorno corporal com o método *Find Contours* da biblioteca OpenCV (BRADSKI, 2000). Isso garante que o corpo humano seja localizado na imagem; caso a imagem não contenha uma pessoa, um erro é retornado no algoritmo, através de uma tentativa de exceção.

Também foi utilizada uma abordagem de classificação de pixels com Marcadores Morfológicos (SOUZA *et al.*, 2020), tendo entrada a segmentação extraída pela YOLACT++. Essa abordagem proporciona um refinamento na segmentação e foi proposta em publicações anteriores, como apresentada na Seção 1.3.1 (SOUZA *et al.*, 2020).


Em seguida, usando o OpenPose (CAO *et al.*, 2019), foi realizada uma estimativa de pose, extraindo os pontos-chave do corpo humano na imagem, permitindo identificar regiões importantes para a abordagem proposta, como ombro, cotovelo, punho, joelho, entre outras.

Figura 7 – Amostras de imagens segmentadas e com estimativa de pose.

(a) Imagem Frontal

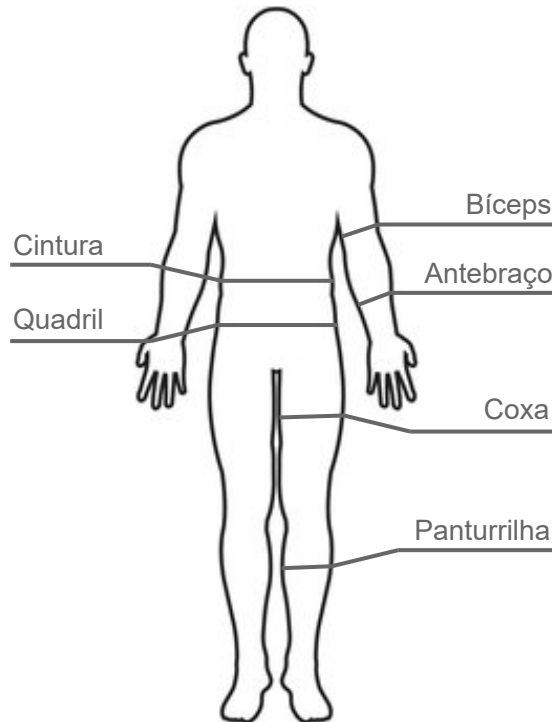


(b) Imagem Lateral (Esquerda)



Fonte: Processado a partir do conjunto de dados apresentado na Seção 3.1.

Figura 8 – Localização das Distâncias Antropométricas Planas (DAPs).



Fonte: Elaborado pelo autor.

Na Figura 7 são apresentadas amostras de imagens do conjunto de dados proposto após o processamento da segmentação com YOLACT++ e OpenPose. A máscara azul é o resultado da segmentação do corpo humano e os pontos e traços coloridos são resultado da estimativa de pose.

3.3 Engenharia de atributos

O processo de engenharia de atributos inicia após encontrar os pontos-chave e o contorno corporal, visando identificar os locais de medição na imagem, conforme mostrado na Figura 8. Esses locais foram deduzidos a partir dos pontos médios entre os pontos-chave encontrados pelo OpenPose (por exemplo, o bíceps é o ponto médio entre o ombro e o cotovelo). Essa regra vale para todos os locais de medição, exceto para o quadril e a cintura.

O quadril é encontrado automaticamente pelo OpenPose, enquanto a cintura é encontrada a partir de uma heurística, considerada como um terço da distância do quadril ao meio do ombro.

Assim, foram encontrados os dois pontos de contorno mais próximos a esses locais de medição e foram traçadas linhas representadas por uma Distância Antropométrica Plana (DAP) ou simplesmente uma distância euclidiana da parte do corpo, conforme ilustra a Figura 8.

Os regressores usaram essas distâncias como atributos para modelar um processo de medição de circunferência que será explicado mais adiante.

Foram utilizados 3 atributos para as medidas do bíceps, antebraço, coxa e panturrilha, pois consideramos 2 distâncias da imagem frontal e 1 distância da imagem lateral. Para o quadril e cintura, usamos apenas 2 atributos, com 1 distância para cada perspectiva de imagem, devido a oclusão por conta da perspectiva.

Após encontrar as DAPs, essas distâncias foram utilizadas como atributos para a próxima etapa, juntamente com as informações de altura, idade e peso. Portanto, para cada medida antropométrica foram utilizadas as informações de altura, idade, peso e de duas à três DAPs como atributos para cada modelo, sendo que haverá um modelo específico para cada medida.

3.4 Estimativa de medidas antropométricas

Após reunir os atributos para a regressão, procede-se à estimativa de algumas medidas antropométricas. Essas medidas são o bíceps, panturrilha, antebraço, quadril, coxa e cintura. O leitor pode encontrar a localização dessas medidas na Figura 8, sendo que a saída da predição é uma medida antropométrica, ou seja, a circunferência de um membro do corpo humano.

Dada a simetria do corpo humano, temos duas medidas semelhantes para bíceps, panturrilha, antebraço e coxa, que consideramos que são aproximadamente iguais, então pre- vemos apenas um valor para cada uma dessas medidas antropométricas. Por outro lado, temos apenas uma circunferência para quadril e cintura, e estimamos apenas um valor para cada uma.

Esta etapa consiste em treinar os seguintes modelos de regressão: Mínimos Quadra- dos Ordinários (MQO) (FREEDMAN, 2005), *Support Vectors Regressors* (SVR) com configura- ção RBF (DRUCKER *et al.*, 1996), *Multi-layer Perceptron* (MLP) com duas camadas ocultas (HAYKIN, 1998), *Decision Trees* (QUINLAN, 1986), *Random Forest* (BREIMAN, 2001) e *Elastic-Net* (ZOU; HASTIE, 2005).

Foram propostos dois experimentos para investigar o impacto da altura, peso e idade na regressão. Portanto, no primeiro experimento, foram usados esses atributos adicionais e os atributos gerados a partir da imagens (DAPs). No segundo experimento, usamos apenas os atributos gerados (DAPs).

Os detalhes dos experimentos para encontrar o modelo adequado para cada experi- mento são descritos no Capítulo 4.

3.5 Índices de desempenho

Na avaliação de modelos, são comumente utilizados índices de desempenho que verificam a precisão das previsões. Para modelos de regressão, a precisão é medida pela diferença entre o valor real e o previsto, uma vez que o resultado da predição não é discreto.

Diante disso, durante a avaliação de modelos de regressão, essas medidas têm um papel principal, sendo muitas vezes necessário utilizar mais do que uma medida, pois cada uma tem suas particularidades para cada caso específico (HARRISON, 2019).

O erro absoluto médio (MAE — do inglês *Mean Absolute Error*), como mostrado na Equação 3.1, mede a média da diferença entre o valor real com o predito. Uma particularidade dessa medida é que ela dá menos peso aos *outliers*¹, ou seja, essa medida é menos afetada por valores discrepantes.

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.1)$$

O erro quadrático médio (MSE — do inglês *Mean Squared Error*), além de calcular a média da diferença entre o valor real com o predito, penaliza *outliers*, devido a elevação ao quadrado na diferença. Além dessa medida ser sensível a valores discrepantes, ela apresenta um problema de interpretabilidade, onde a unidade do erro é o quadrado da unidade do resultado da predição. Essa medida é descrita na Equação 3.2.

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.2)$$

A raiz do erro quadrático médio (RMSE — do inglês *Root Mean Square Error*), descrita na Equação 3.3, é basicamente a raiz da medida MSE. Com isso, além de apresentar a mesma ideia de penalização de *outliers*, essa medida resolve um problema comum da medida MSE, que é a mudança de unidade, uma vez que a índice MSE apresenta os erros ao quadrado. Portanto, essa é uma medida bem mais criteriosa, já que a sua sensibilidade a valores discrepantes pode levar a uma divergência no resultado se comparada com a medida MAE.

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.3)$$

¹ Grosso modo, *outlier* significa um valor atípico ou resultado que foge da média.

O erro percentual absoluto médio (MAPE — do inglês *Mean Absolute Percentage Error*), é semelhante a MAE, mas normalizado por um valor real, mostrando a porcentagem de erro em relação aos valores reais. A Equação 3.4 descreve essa medida, onde podemos observar que é preciso cautela pelo risco de divisão por zero em casos onde $y_i = 0$.

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(e, |y_i|)} \quad (3.4)$$

Neste trabalho iremos utilizar os índices de desempenho MAE, RMSE e MAPE. A medida RMSE será utilizada no lugar da medida MSE, pois a primeira, além de herdar características de penalização, normaliza os erros para suas unidades padrões.

3.6 Transformação dos dados

A normalização e a padronização são técnicas comuns de transformação de dados usadas em aprendizado de máquina para transformar os dados de entrada em uma escala comum, permitindo que os algoritmos de aprendizado de máquina possam ser executados de maneira mais eficiente e precisa.

A normalização é o processo de transformar os dados para que cada valor esteja na mesma escala, geralmente de 0 a 1. A formulação da normalização é apresentada na Equação 3.5, sendo usada principalmente para dados que estão em diferentes escalas e variam amplamente em valores.

$$x_{normalizado} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.5)$$

A padronização, por outro lado, transforma os dados de modo que a média seja 0 e o desvio padrão seja 1. A Equação 3.6 apresenta sua formulação, sendo usada principalmente para dados que seguem uma distribuição normal ou aproximadamente normal. Essa técnica é particularmente útil para algoritmos que utilizam medidas de distância.

$$x_{padronizado} = \frac{x_i - \mu(x)}{\sigma(x)} \quad (3.6)$$

4 RESULTADOS

Neste capítulo, apresentar-se-á a configuração experimental deste trabalho, bem como a avaliação de experimentos, o impacto do gênero sobre os resultados e a comparação com trabalhos da literatura. Além disso, houve uma discussão dos resultados sobre a estimativa de medidas antropométricas no decorrer de todo o capítulo.

4.1 Configuração experimental

Os experimentos foram conduzidos em uma computador com Intel Core i5 (7ª Geração) 2,50 GHz, 16 GB de RAM, NVIDIA GeForce 940MX no Ubuntu 16.04. A linguagem Python 3.9 foi usada com a biblioteca scikit-learn e OpenCV. Por fim, foi utilizado o código-fonte aberto dos algoritmos Yolact Plus e OpenPose, bem como DCNv2 com PyTorch para realizar operações convolucionais.


Foram realizados dois experimentos diferentes neste trabalho, (1) usando as DAPs, descritos na Seção 3.3, juntamente com informações de altura, peso e idade e (2) usando apenas as DAPs. Para cada experimento os dados foram divididos entre masculino, feminino e ambos. Na estimativa das medidas antropométricas do bíceps, panturrilha, antebraço, quadril, coxa e cintura (em centímetros), foram utilizados os métodos de regressão MQO, SVR (RBF), MLP (2 *Camadas Ocultas*), *Decision Trees*, *Random Forest* e *Elastic-Net*.

Tabela 1 – Configuração dos regressores.

Modelos de regressão	Parâmetros
SVR (RBF)	$C = 2^x \forall x \subseteq [-5, -3, \dots, 16]$ (<i>passo de 2</i>) $\gamma = 2^x \forall x \subseteq [-15, -13, \dots, 4]$ (<i>passo de 2</i>)
MLP (2 <i>Camadas Ocultas</i>)	Tamanhos de cada camada oculta contidos em $[(x_1, y_1), \dots, (x_2, y_2)]$ Com 200 pares para x_1, y_1, x_2, y_2 escolhidos aleatoriamente do intervalo $[2, 500]$ (<i>passo de 25</i>) 200 neurônios em cada uma das camadas ocultas 1000 para a quantidade máxima de iterações
<i>Decision Trees</i>	Profundidade máxima $\subseteq [2, 3, 5, 10, 20]$ Mínimo de folhas de amostras $\subseteq [5, 10, 20, 50, 100]$
<i>Random Forest</i>	Número de estimadores (árvores) $\subseteq [25, 75, \dots, 2001]$ (<i>passo de 50</i>)
<i>Elastic-Net</i>	$\alpha = 10^x \forall x \subseteq [-5, 3]$ (<i>passo de 1</i>) Relação L1 $\subseteq [0, 1]$ (<i>passo de 0,01</i>)

Fonte: Elaborado pelo autor.

Figura 9 – Comparação entre métodos de transformação de dados, onde a normalização utiliza o mínimo e o máximo; e a padronização utiliza a média e o desvio padrão.



Fonte: Elaborado pelo autor.

Para cada experimento foram realizadas 10 rodadas de treinamento, com otimização de hiperparâmetros utilizando busca aleatória em 15 iterações e validação cruzada de 5 *folds*. As configurações utilizadas nos modelos de regressão são apresentadas na Tabela 1.

Em termos de avaliação dos regressores, foi utilizado o índice MAE em centímetros, para avaliar o desempenho dos regressores sem dar tanta importância aos *outliers*; ademais foi utilizado o RMSE, também em centímetros, como índice de desempenho que penaliza o regressor de acordo com os *outliers*; e, por fim, foi adotado o MAPE, em porcentagem numérica, com o objetivo de apresentar os erros em termos percentuais, para equalizar os erros das medidas antropométricas de escalas diferentes, como por exemplo, o quadril é uma medida antropométrica que no geral é aproximadamente 2 vezes maior que o bíceps.

Antes da iniciação dos experimentos, houve uma etapa de preparação dos dados. Como indicado nas Seções 3.2 e 3.3, a fim de realizar a estimação das medidas antropométricas, as etapas de segmentação, estimativa de poses e cálculo das DAPs foram executadas. Deste modo, foi obtido um conjunto de dados contendo DAPs e informações adicionais (idade, altura e peso), que foi utilizado como entrada para os modelos de regressão.

Buscando decidir qual transformação utilizar sobre o conjunto de dados, ao agrupar todos os resultados em torno da média, para cada índice de desempenho, a padronização de dados apresentou uma leve melhoria nos resultados, o que pode ser visto na Figura 9. Portanto, os resultados apresentados neste trabalho foram obtidos através do conjunto de dados padronizado, que refere-se a todos os atributos passados aos regressores.

4.2 Avaliação dos experimentos

Após a execução de ambos os experimentos, foram obtidos diversos resultados para cada uma das medidas antropométricas. Esses resultados estão dispostos nas Tabelas 3, 4, 5, 6, 7 e 8, onde cada tabela detém os resultados para cada medida antropométrica específica dentre os dois experimentos.

Nessas tabelas, os resultados apresentados em negrito representam os erros menores para cada índice de desempenho, gênero e classificador de uma medida antropométrica. Os valores destacados em verde representam os melhores resultados para cada índice de desempenho de uma medida antropométrica e experimento. Já os valores destacados em vermelho representam os piores resultados para cada índice de desempenho de uma medida antropométrica e experimento.

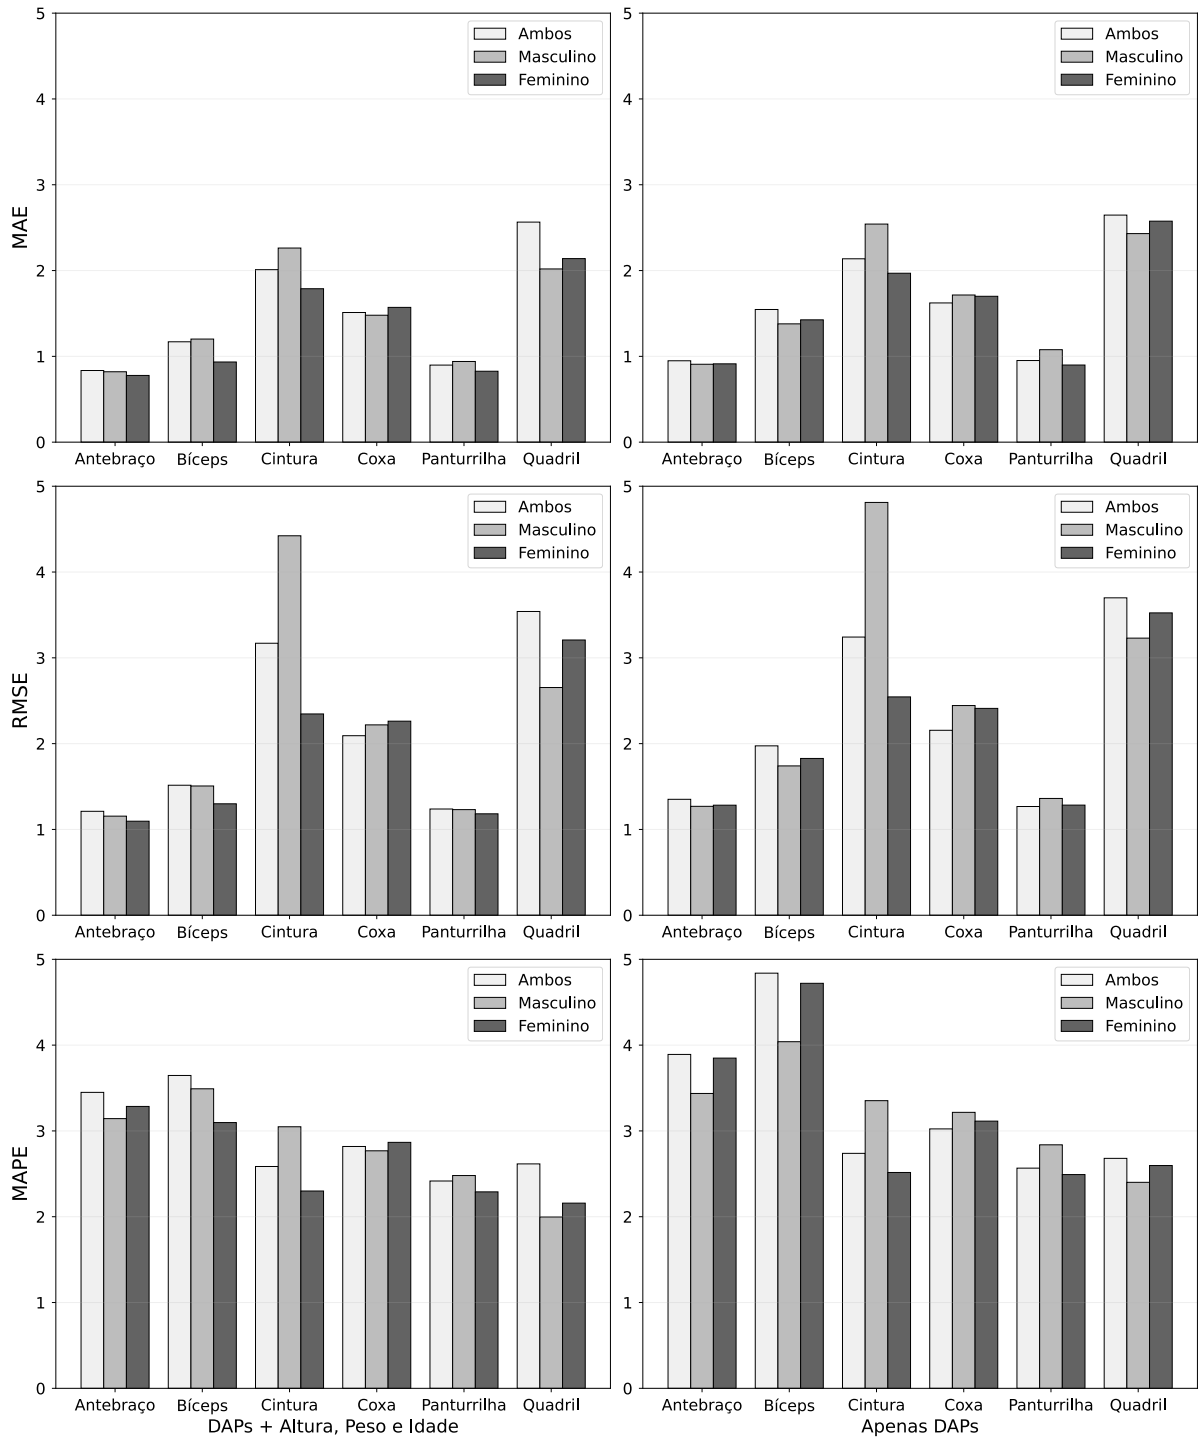
A partir desse conjunto de tabelas, já é possível inferir algumas conclusões, como por exemplo, na maioria dos casos os resultados utilizando dados do sexo feminino apresentam os menores erros de predição das medidas antropométricas. Outra conclusão é observada nos resultados destacados em verde, onde é possível inferir que os erros do experimento 1, utilizando DAPs e informações adicionais, são ligeiramente menores que os erros do experimento 2, que utilizam somente as DAPs.

Além disso, esse conjunto de tabelas é essencial na análise dos regressores para cada caso específico de gênero, experimento e medida antropométrica. É possível notar diversos padrões, como por exemplo a frequência em que os piores resultados aparecem para o conjunto de dados do sexo masculino. Além do mais, é possível comparar regressores, onde percebemos que o classificador MQO apresenta resultados competitivos se comparado a métodos mais sofisticados.

Buscando agrupar os dados e facilitar na interpretação dessas informações, a Figura 10 traz os resultados médios para cada regressor, agrupando os índices de desempenho por medida antropométrica, gênero e experimento. Esse gráfico foi obtido através do agrupamento dos resultados em torno da média, visando entender como os regressores se saíram no geral. Portanto, visualmente, é possível reafirmar o que foi concluído no parágrafo anterior, que os resultados do experimento 1 (utilizando atributos adicionais) se sobressaem aos resultados do experimento 2 (utilizando apenas DAPs).


Outro padrão que é possível visualizar através da Figura 10, é que as medidas antropométricas em maior escala (*i.e.* membros maiores) tendem a apresentar erros mais significativos, como no caso de quadril e cintura, seguidos de coxa e bíceps. Ou seja, quanto maior a circunferência das medidas antropométricas, maiores os erros de predição.

Figura 10 – Resultados médios para cada medida antropométrica agrupados por experimento, índice de desempenho e sexo.



Fonte: Elaborado pelo autor.

Figura 11 – Melhores resultados (regressor e gênero) para cada medida antropométrica separada por experimento.



Fonte: Elaborado pelo autor.

Entretanto, como o MAPE mostra o erro percentual, é possível constatar outra perspectiva em seu gráfico, pois as medidas do bíceps e antebraço passaram a ter os erros mais proeminentes, como visto na Figura 10. No entanto, considerando a natureza do processo de medição, um erro de 1 centímetro para o bíceps ou cintura será equivalente. Assim, a análise MAPE serve apenas para comparar uma mesma medida antropométrica.

Ademais, é possível atentar-se a presença de discrepância nos resultados, uma vez que o RMSE apresentou um aumento para o MAE, principalmente para as medidas de quadril e cintura. Essa discrepância pode significar a presença de outliers ou talvez a não uniformidade das previsões, sugerindo uma variação particular entre os regressores.

A fim de afunilar esta avaliação e buscar casos onde regressores específicos sobressaíram para um certo gênero e experimento, a Figura 11 apresenta os melhores resultados para

cada medida antropométrica separada por experimento.

Visto por outra ótica, é possível ratificar que o experimento utilizando DAPs e informações adicionais destacam-se, comprovando assim a eficácia dessas informações extras para a estimativa de medidas antropométricas. Continuando a análise da Figura 11, chega-se à conclusão de que o antebraço e a panturrilha apresentam os menores erros para MAE e RMSE. Já o quadril, a panturrilha e a cintura, exibem os menores erros percentuais com o MAPE. Além do mais, os regressores SVR (RBF), *Elastic-net* e *Random Forest* mostraram-se superiores ao manifestarem-se com mais frequência nos melhores resultados.

Para cada uma dos índices de desempenho, o antebraço e o quadril apresentaram os melhores resultados. No antebraço, usando dados do sexo feminino com regressor *Elastic-Net*, foi obtido $0,778 \pm 0,083$ para o MAE e $1,096 \pm 0,292$ para o RMSE. Quanto ao quadril, usando dados do sexo masculino com o regressor SVR (RBF), foi obtido $0,020 \pm 0,002$ para o MAPE, que é aproximadamente 2%. Os membros inferiores da coxa e panturrilha apresentaram os piores resultados.

Vale destacar que o regressor MQO apresenta resultados impressionantes, muitas vezes se sobressaindo aos regressores mais sofisticados, o que sugere uma possível adoção para casos em que busca-se um maior custo-benefício.

Por fim, acredita-se que os resultados são satisfatórios, já que em média, nos piores casos, a margem de erro gira em torno de 4 centímetros. Em outros casos, desconsiderando os *outliers*, os erros se contêm em torno de 2 centímetros para mais ou para menos.

4.3 Impacto do gênero sobre os resultados

Na seção anterior, ao analisar brevemente as tabelas com todos os resultados, os melhores resultados encontrados utilizaram dados do sexo feminino. No entanto, através da Figura 11, é possível ver que a divisão dos melhores resultados divide-se quase que igualmente entre os sexos masculino e feminino, apesar da superioridade dos resultados com dados do sexo feminino. Destarte, é possível concluir que é benéfico criar modelos distintos para cada gênero, visto que um modelo genérico não performou tão bem quanto modelos para gêneros específicos.

Entretanto, apesar dos melhores resultados estarem concentrados em gêneros distintos, os resultados que utilizaram dados do sexo masculino apresentaram-se com mais frequência dentre os valores destacados em vermelho (piores resultados para cada medida antropométrica e experimento).

Contudo, por muitas vezes os resultados destacados em vermelho não apresentam um intervalo tão grande, e além disso, essa situação pode ser contornada pela utilização de um regressor mais adequado.

Ademais, algumas medidas antropométricas destacam-se para cada gênero. O quadril apresenta melhores resultados se for treinado com amostras do gênero masculino. Já a cintura e a panturrilha se sobressaem com amostras do gênero feminino. A coxa e o antebraço tem resultados semelhantes para todos os conjuntos de gênero. Um caso particular é o bíceps, que no experimento 1 apresentou resultados melhores com amostras do gênero feminino e no experimento 2 apresentou resultados superiores com amostras do gênero masculino.

Por fim, pode-se afirmar que o gênero tem influência sobre os resultados, por vezes sendo necessário a criação de modelos distintos ou até mesmo a utilização de mais de um modelo para o aumento da robustez de predições.

4.4 Comparação com trabalhos da literatura

Visando reforçar a contribuição deste trabalho, a abordagem proposta aqui foi comparada com a abordagem proposta por Souza *et al.* (2020). Ademais, a comparação ocorreu nas mesmas condições apresentadas neste trabalho e sendo possível devido ao acesso do código-fonte, já que o trabalho de Souza *et al.* (2020) é de nossa autoria, como pode ser visto na Seção 1.3.1.

Tabela 2 – Comparação entre os resultados do trabalho proposto por Souza *et al.* (2020) e pela abordagem proposta nesse trabalho usando ambos dados de sexo masculino e feminino.

Medida Antropométrica	Abordagem	MAE (cm)	RMSE (cm)	MAPE (%)
Bíceps	Souza <i>et al.</i> (2020)	6,548	11,274	22,70
	Abordagem Proposta	1,170	1,515	3,60
Panturrilha	Souza <i>et al.</i> (2020)	6,897	11,633	18,68
	Abordagem Proposta	0,898	1,238	2,40
Antebraço	Souza <i>et al.</i> (2020)	3,084	5,902	12,15
	Abordagem Proposta	0,835	1,211	3,40
Quadril	Souza <i>et al.</i> (2020)	4,295	6,328	4,35
	Abordagem Proposta	2,565	3,540	2,60
Coxa	Souza <i>et al.</i> (2020)	4,819	7,235	8,96
	Abordagem Proposta	1,511	2,092	2,80
Cintura	Souza <i>et al.</i> (2020)	11,362	15,454	14,86
	Abordagem Proposta	2,010	3,170	2,60

Fonte: Elaborado pelo autor.

Visto que a abordagem proposta nessa dissertação é uma continuação da abordagem apresentada na literatura, sendo entendida como uma melhoria direta, é importante ressaltar que a principal diferença entre esses trabalhos é a utilização de regressores para a modelagem do processo de estimativa de medidas, já que no artigo presente na literatura (SOUZA *et al.*, 2020) foram utilizadas aproximações geométricas para determinar essas medidas antropométricas.

A Tabela 2 apresenta uma comparação dos melhores resultados das abordagens através dos três índice de desempenho apresentadas neste trabalho. Vale ressaltar que os resultados obtidos com a abordagem apresentada na literatura foram computados novamente utilizando o conjunto de imagens apresentado nesta dissertação.

Inicialmente, é possível notar que os resultados da abordagem de Souza *et al.* (2020) estão piores do que as apresentadas no artigo original. Isso pode ser explicado pelo conjunto de dados utilizado, pois aqui contamos com 913 amostras e no artigo original os autores utilizaram somente 38 amostras. Além do mais, o conjunto de dados atual conta com uma maior variedade nas amostras, apresentando atletas, obesos e pessoas com físico convencional.

Analisando a Tabela 2, podemos concluir que a abordagem proposta neste trabalho é superior para todos os casos quando utilizado o conjunto de dados com mais amostras. Por fim, a abordagem deste trabalho mostrou-se mais robusta em comparação a abordagem da literatura, devido à adoção de regressores para modelagem do problema.

Tabela 3 – Resultados de ambos os experimentos para o bíceps.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	1,17±0,092	1,515±0,116	0,036±0,003
	MLP (2 Camadas Ocultas)	1,218±0,068	1,73±0,263	0,038±0,002
	Random Forest	1,188±0,081	1,516±0,107	0,037±0,003
	MQO	1,223±0,063	1,691±0,19	0,038±0,002
	Elastic-Net	1,231±0,068	1,693±0,187	0,038±0,002
	Decision Trees	1,391±0,088	1,795±0,119	0,044±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	0,934±0,08	1,299±0,213	0,031±0,002
	MLP (2 Camadas Ocultas)	1,068±0,115	1,587±0,336	0,035±0,004
	Random Forest	0,99±0,061	1,328±0,119	0,033±0,002
	MQO	0,973±0,083	1,376±0,272	0,032±0,002
	Elastic-Net	1,005±0,072	1,398±0,25	0,033±0,002
	Decision Trees	1,288±0,125	1,683±0,216	0,043±0,004
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	1,202±0,083	1,525±0,13	0,035±0,002
	MLP (2 Camadas Ocultas)	1,582±0,316	2,565±0,827	0,046±0,009
	Random Forest	1,211±0,087	1,506±0,086	0,036±0,002
	MQO	1,293±0,073	1,849±0,278	0,037±0,002
	Elastic-Net	1,306±0,071	1,836±0,275	0,038±0,002
	Decision Trees	1,443±0,092	1,76±0,138	0,042±0,003

Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	1,546±0,126	1,986±0,165	0,048±0,004
	MLP (2 Camadas Ocultas)	1,57±0,153	2,131±0,465	0,049±0,004
	Random Forest	1,558±0,097	1,974±0,12	0,049±0,003
	MQO	1,596±0,099	2,12±0,188	0,05±0,003
	Elastic-Net	1,613±0,098	2,119±0,185	0,05±0,003
	Decision Trees	1,592±0,111	2,012±0,139	0,05±0,004
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	1,433±0,076	1,827±0,172	0,048±0,002
	MLP (2 Camadas Ocultas)	1,628±0,245	2,412±0,846	0,054±0,008
	Random Forest	1,483±0,106	1,925±0,151	0,049±0,004
	MQO	1,426±0,054	1,844±0,154	0,047±0,001
	Elastic-Net	1,438±0,048	1,857±0,141	0,048±0,001
	Decision Trees	1,507±0,142	1,998±0,179	0,05±0,005
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	1,406±0,149	1,827±0,25	0,041±0,004
	MLP (2 Camadas Ocultas)	1,752±0,179	3,259±1,191	0,05±0,005
	Random Forest	1,379±0,09	1,74±0,108	0,04±0,003
	MQO	1,493±0,124	2,145±0,386	0,043±0,004
	Elastic-Net	1,5±0,124	2,129±0,38	0,043±0,004
	Decision Trees	1,471±0,127	1,808±0,144	0,043±0,004

Fonte: Elaborado pelo autor.

Tabela 4 – Resultados de ambos os experimentos para a panturrilha.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	0,941±0,125	1,267±0,203	0,025±0,004
	MLP (2 Camadas Ocultas)	0,999±0,113	1,47±0,389	0,027±0,003
	<i>Random Forest</i>	0,898±0,051	1,238±0,12	0,024±0,001
	MQO	1,109±0,101	1,63±0,265	0,03±0,003
	<i>Elastic-Net</i>	1,108±0,098	1,635±0,258	0,03±0,003
	<i>Decision Trees</i>	1,109±0,061	1,473±0,112	0,03±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	0,863±0,09	1,281±0,253	0,024±0,003
	MLP (2 Camadas Ocultas)	1,038±0,181	1,678±0,462	0,029±0,005
	<i>Random Forest</i>	0,827±0,078	1,182±0,281	0,023±0,003
	MQO	0,928±0,094	1,379±0,289	0,026±0,003
	<i>Elastic-Net</i>	0,92±0,096	1,387±0,292	0,025±0,003
	<i>Decision Trees</i>	1,023±0,073	1,407±0,251	0,028±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	0,94±0,063	1,231±0,117	0,025±0,002
	MLP (2 Camadas Ocultas)	3,325±4,513	6,318±5,842	0,087±0,118
	<i>Random Forest</i>	0,944±0,082	1,233±0,106	0,025±0,002
	MQO	1,131±0,122	1,904±0,636	0,03±0,003
	<i>Elastic-Net</i>	1,187±0,153	1,959±0,619	0,031±0,004
	<i>Decision Trees</i>	1,14±0,088	1,469±0,156	0,03±0,002

Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	0,951±0,061	1,267±0,14	0,026±0,002
	MLP (2 Camadas Ocultas)	1,014±0,129	1,596±0,643	0,027±0,004
	<i>Random Forest</i>	0,999±0,049	1,341±0,109	0,027±0,001
	MQO	1,278±0,058	2,147±0,334	0,034±0,002
	<i>Elastic-Net</i>	1,343±0,142	2,11±0,244	0,036±0,004
	<i>Decision Trees</i>	1,099±0,075	1,454±0,135	0,03±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	0,899±0,07	1,284±0,239	0,025±0,003
	MLP (2 Camadas Ocultas)	1,126±0,167	1,668±0,363	0,031±0,005
	<i>Random Forest</i>	0,937±0,067	1,313±0,238	0,026±0,003
	MQO	1,033±0,068	1,531±0,274	0,028±0,003
	<i>Elastic-Net</i>	1,038±0,072	1,553±0,284	0,029±0,003
	<i>Decision Trees</i>	1,032±0,099	1,404±0,232	0,029±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	1,078±0,046	1,385±0,131	0,028±0,001
	MLP (2 Camadas Ocultas)	1,486±0,491	3,751±3,549	0,039±0,013
	<i>Random Forest</i>	1,078±0,059	1,361±0,064	0,029±0,002
	MQO	1,515±0,168	3,067±1,18	0,04±0,005
	<i>Elastic-Net</i>	1,778±0,239	3,059±0,953	0,047±0,006
	<i>Decision Trees</i>	1,246±0,113	1,613±0,162	0,033±0,003

Fonte: Elaborado pelo autor.

Tabela 5 – Resultados de ambos os experimentos para o antebraço.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	0,835±0,079	1,211±0,42	0,034±0,008
	MLP (2 Camadas Ocultas)	0,874±0,1	1,26±0,406	0,036±0,008
	Random Forest	0,874±0,074	1,286±0,411	0,036±0,007
	MQO	0,848±0,083	1,222±0,417	0,035±0,008
	Elastic-Net	0,848±0,083	1,222±0,417	0,035±0,008
	Decision Trees	0,989±0,09	1,425±0,394	0,04±0,008
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	0,797±0,085	1,138±0,294	0,034±0,004
	MLP (2 Camadas Ocultas)	0,836±0,078	1,179±0,249	0,035±0,004
	Random Forest	0,836±0,093	1,192±0,282	0,035±0,005
	MQO	0,781±0,088	1,104±0,293	0,033±0,005
	Elastic-Net	0,778±0,083	1,096±0,292	0,033±0,004
	Decision Trees	0,937±0,088	1,319±0,256	0,039±0,004
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	0,827±0,094	1,165±0,532	0,032±0,011
	MLP (2 Camadas Ocultas)	1,055±0,245	1,459±0,536	0,04±0,012
	Random Forest	0,883±0,076	1,242±0,523	0,034±0,011
	MQO	0,82±0,098	1,155±0,535	0,031±0,011
	Elastic-Net	0,825±0,098	1,159±0,534	0,032±0,011
	Decision Trees	1,013±0,055	1,419±0,464	0,038±0,009
Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	0,954±0,12	1,353±0,392	0,039±0,009
	MLP (2 Camadas Ocultas)	0,974±0,118	1,378±0,384	0,04±0,008
	Random Forest	1,058±0,099	1,489±0,368	0,043±0,008
	MQO	0,949±0,122	1,351±0,393	0,039±0,009
	Elastic-Net	0,949±0,122	1,351±0,393	0,039±0,009
	Decision Trees	1,069±0,088	1,496±0,344	0,043±0,007
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	0,913±0,08	1,283±0,254	0,038±0,004
	MLP (2 Camadas Ocultas)	0,971±0,075	1,342±0,238	0,041±0,004
	Random Forest	1,019±0,09	1,405±0,251	0,043±0,005
	MQO	0,914±0,08	1,287±0,253	0,039±0,005
	Elastic-Net	0,917±0,081	1,287±0,25	0,039±0,005
	Decision Trees	1,08±0,102	1,48±0,251	0,045±0,005
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	0,911±0,085	1,274±0,479	0,034±0,01
	MLP (2 Camadas Ocultas)	0,999±0,087	1,368±0,456	0,038±0,01
	Random Forest	1,018±0,092	1,437±0,474	0,038±0,011
	MQO	0,908±0,094	1,269±0,485	0,034±0,011
	Elastic-Net	0,908±0,093	1,27±0,484	0,034±0,011
	Decision Trees	1,082±0,083	1,466±0,435	0,04±0,01

Fonte: Elaborado pelo autor.

Tabela 6 – Resultados de ambos os experimentos para o quadril.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	2,587±0,231	3,641±0,707	0,026±0,003
	MLP (2 Camadas Ocultas)	2,565±0,254	3,54±0,714	0,026±0,003
	Random Forest	2,642±0,216	3,713±0,693	0,027±0,003
	MQO	2,877±0,236	4,144±0,691	0,029±0,003
	Elastic-Net	2,884±0,225	4,136±0,689	0,029±0,003
	Decision Trees	2,938±0,249	4,028±0,61	0,03±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	2,228±0,138	3,38±0,85	0,022±0,003
	MLP (2 Camadas Ocultas)	2,359±0,186	3,385±0,845	0,024±0,003
	Random Forest	2,484±0,174	3,67±0,858	0,025±0,003
	MQO	2,15±0,231	3,218±0,945	0,022±0,004
	Elastic-Net	2,139±0,23	3,208±0,948	0,022±0,004
	Decision Trees	2,898±0,279	4,105±0,719	0,029±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	2,019±0,259	2,851±0,976	0,02±0,002
	MLP (2 Camadas Ocultas)	2,733±0,958	4,754±4,01	0,027±0,01
	Random Forest	2,033±0,178	2,654±0,309	0,02±0,002
	MQO	2,161±0,232	3,097±1,018	0,021±0,002
	Elastic-Net	2,181±0,233	3,127±1,024	0,022±0,002
	Decision Trees	2,368±0,213	3,05±0,294	0,023±0,002

Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	2,646±0,244	3,699±0,74	0,027±0,003
	MLP (2 Camadas Ocultas)	2,656±0,216	3,716±0,693	0,027±0,003
	Random Forest	2,878±0,22	3,925±0,668	0,029±0,003
	MQO	3,018±0,203	4,321±0,645	0,031±0,003
	Elastic-Net	3,027±0,206	4,326±0,659	0,031±0,003
	Decision Trees	2,888±0,241	4,007±0,674	0,029±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	2,609±0,198	3,578±0,876	0,026±0,004
	MLP (2 Camadas Ocultas)	5,869±9,366	7,414±10,671	0,057±0,088
	Random Forest	2,939±0,144	4,092±0,784	0,03±0,004
	MQO	2,583±0,198	3,524±0,903	0,026±0,004
	Elastic-Net	2,576±0,199	3,524±0,902	0,026±0,004
	Decision Trees	3,083±0,18	4,229±0,802	0,031±0,004
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	2,507±0,502	3,875±2,092	0,025±0,005
	MLP (2 Camadas Ocultas)	2,959±1,034	5,628±5,162	0,029±0,011
	Random Forest	2,431±0,171	3,23±0,226	0,024±0,002
	MQO	2,986±0,371	4,423±1,906	0,03±0,004
	Elastic-Net	3,022±0,36	4,466±1,903	0,03±0,003
	Decision Trees	2,544±0,265	3,387±0,339	0,025±0,003

Fonte: Elaborado pelo autor.

Tabela 7 – Resultados de ambos os experimentos para a coxa.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	1,515±0,188	2,093±0,303	0,028±0,004
	MLP (2 Camadas Ocultas)	1,511±0,117	2,092±0,266	0,028±0,003
	Random Forest	1,619±0,141	2,229±0,308	0,03±0,003
	MQO	1,602±0,119	2,298±0,3	0,03±0,003
	Elastic-Net	1,601±0,119	2,301±0,303	0,03±0,003
	Decision Trees	1,862±0,133	2,45±0,245	0,035±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	1,571±0,173	2,267±0,972	0,029±0,002
	MLP (2 Camadas Ocultas)	1,963±0,177	2,809±0,755	0,036±0,003
	Random Forest	1,736±0,156	2,503±0,868	0,032±0,002
	MQO	1,571±0,138	2,262±0,94	0,029±0,002
	Elastic-Net	1,585±0,136	2,27±0,935	0,029±0,002
	Decision Trees	2,064±0,211	2,955±0,826	0,038±0,003
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	1,479±0,263	2,219±0,702	0,028±0,007
	MLP (2 Camadas Ocultas)	4,048±6,872	5,654±7,718	0,074±0,124
	Random Forest	1,616±0,211	2,271±0,555	0,03±0,006
	MQO	1,647±0,219	2,672±0,68	0,031±0,006
	Elastic-Net	1,647±0,22	2,666±0,682	0,031±0,006
	Decision Trees	1,911±0,239	2,575±0,526	0,036±0,006

Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	1,623±0,093	2,181±0,255	0,03±0,002
	MLP (2 Camadas Ocultas)	1,63±0,091	2,156±0,238	0,031±0,003
	Random Forest	1,798±0,119	2,471±0,309	0,034±0,003
	MQO	1,765±0,12	2,567±0,414	0,033±0,003
	Elastic-Net	1,787±0,123	2,607±0,411	0,034±0,003
	Decision Trees	1,858±0,096	2,455±0,203	0,035±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	1,7±0,177	2,433±0,914	0,031±0,002
	MLP (2 Camadas Ocultas)	1,796±0,178	2,562±0,888	0,033±0,002
	Random Forest	1,91±0,153	2,729±0,871	0,035±0,002
	MQO	1,703±0,143	2,411±0,898	0,031±0,002
	Elastic-Net	1,709±0,138	2,416±0,896	0,031±0,002
	Decision Trees	2,06±0,146	2,947±0,788	0,038±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	1,715±0,281	2,444±0,707	0,032±0,007
	MLP (2 Camadas Ocultas)	2,108±0,513	3,513±1,847	0,039±0,01
	Random Forest	1,761±0,242	2,444±0,553	0,033±0,006
	MQO	2,01±0,374	3,473±1,273	0,038±0,009
	Elastic-Net	2,135±0,338	3,539±1,207	0,04±0,008
	Decision Trees	1,919±0,25	2,581±0,551	0,036±0,006

Fonte: Elaborado pelo autor.

Tabela 8 – Resultados de ambos os experimentos para a cintura.

Experimento utilizando DAPs + Altura, Peso e Idade				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	2,078±0,416	3,273±1,25	0,026±0,007
	MLP (2 Camadas Ocultas)	2,01±0,236	3,17±1,031	0,026±0,005
	Random Forest	2,166±0,189	3,447±0,902	0,027±0,004
	MQO	2,108±0,206	3,272±0,938	0,027±0,005
	Elastic-Net	2,107±0,206	3,271±0,939	0,027±0,005
	Decision Trees	2,586±0,209	3,973±0,791	0,032±0,004
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	1,842±0,125	2,495±0,228	0,024±0,002
	MLP (2 Camadas Ocultas)	1,942±0,202	2,662±0,229	0,025±0,003
	Random Forest	1,931±0,18	2,587±0,282	0,024±0,002
	MQO	1,793±0,129	2,354±0,208	0,023±0,001
	Elastic-Net	1,788±0,128	2,346±0,212	0,023±0,001
	Decision Trees	2,27±0,177	3,015±0,258	0,029±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	2,479±0,527	4,659±1,773	0,033±0,009
	MLP (2 Camadas Ocultas)	2,769±0,887	4,778±2,005	0,037±0,014
	Random Forest	2,627±0,23	4,952±1,398	0,035±0,007
	MQO	2,262±0,323	4,423±1,816	0,03±0,008
	Elastic-Net	2,264±0,319	4,432±1,809	0,031±0,008
	Decision Trees	3,264±0,285	5,47±1,277	0,042±0,007
Experimento utilizando apenas DAPs				
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Ambos sexos	SVR (RBF)	2,177±0,196	3,318±0,996	0,028±0,004
	MLP (2 Camadas Ocultas)	2,137±0,202	3,242±1,013	0,027±0,004
	Random Forest	2,356±0,234	3,617±0,908	0,03±0,005
	MQO	2,534±0,258	3,824±0,845	0,032±0,005
	Elastic-Net	2,535±0,259	3,824±0,845	0,032±0,005
	Decision Trees	2,56±0,274	3,871±1,01	0,032±0,005
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Feminino	SVR (RBF)	1,969±0,148	2,598±0,198	0,025±0,001
	MLP (2 Camadas Ocultas)	1,972±0,12	2,545±0,164	0,025±0,001
	Random Forest	2,133±0,17	2,847±0,23	0,027±0,002
	MQO	1,986±0,123	2,579±0,169	0,026±0,001
	Elastic-Net	1,982±0,131	2,575±0,183	0,026±0,001
	Decision Trees	2,28±0,173	3,017±0,271	0,029±0,002
Gênero	Modelo de Regressão	MAE	RMSE	MAPE
Masculino	SVR (RBF)	2,542±0,349	4,811±1,674	0,034±0,008
	MLP (2 Camadas Ocultas)	2,893±0,416	5,012±1,428	0,038±0,006
	Random Forest	2,905±0,371	5,246±1,469	0,038±0,009
	MQO	2,835±0,386	5,014±1,8	0,037±0,009
	Elastic-Net	2,835±0,386	5,015±1,8	0,037±0,009
	Decision Trees	3,134±0,352	5,377±1,415	0,04±0,008

Fonte: Elaborado pelo autor.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho propõe uma abordagem para estimar medidas antropométricas a partir de imagens bidimensionais. Os atributos são extraídos a partir das imagens, por meio de CNNs e, em seguida, as DAPs (Distâncias Antropométricas Planas) são obtidas para serem usadas como entrada dos regressores, objetivando estimar as circunferências de partes do corpo.

Além de fornecer essa metodologia, as contribuições deste trabalho se concentram em alguns experimentos e discussões em torno da análise do impacto da altura, peso e idade no processo de estimativa de medidas antropométricas. Além do mais, também examinou-se o efeito do gênero, onde os dados foram separados entre sexo feminino, masculino e ambos os sexos para cada experimento, onde chegou-se a conclusão de que as amostras do sexo feminino apresentaram os melhores resultados.

Na abordagem proposta para estimar as medidas antropométricas, foram obtidos resultados aceitáveis, com as melhores estimativas sendo realizadas no antebraço para o sexo feminino com $0,778 \pm 0,083$ para MAE e $1,096 \pm 0,292$ para RMSE. A coxa e panturrilha (membros inferiores) para o sexo masculino apresentaram os piores resultados com $4,048 \pm 6,872$ para o MAE e $6,318 \pm 5,842$ para o RMSE, respectivamente. Além disso, a abordagem proposta destacou-se em relação a trabalhos publicados anteriormente em eficiência e desempenho.

Essa abordagem é considerada criativa e desafiadora, pois aborda as variações de regressores para predição e análise de gênero no processo de estimativa de medidas antropométricas. A proposta desse trabalho pode até mesmo ser implantada na nuvem, sendo acessada por meio de aplicativos *mobile*, auxiliando os especialistas no acompanhamento dos pacientes.

Ademais, um conjunto de dados foi proposto durante essa pesquisa, sendo apresentado em artigos apresentados nas Seções 1.3.1 e 1.3.2. Esse conjunto de dados foi utilizado para realização dos experimentos deste trabalho e também para reavaliar resultados de trabalhos existentes na literatura.

Para trabalhos futuros, há uma ampla margem em direção à continuidade da pesquisa, através do aprimoramento dos resultados obtidos e realização de novos experimentos, como a estimativa de novas medidas antropométricas, de gordura corporal e até mesmo da densidade óssea, diretamente de CNNs. Por fim, há um comprometimento para continuar fornecendo novas amostras para o conjunto de dados proposto neste trabalho, contribuindo assim para a construção de melhores modelos.

REFERÊNCIAS

- ALVES, S. S.; OHATA, E. F.; NASCIMENTO, N. M.; SOUZA, J. W. M. D.; HOLANDA, G. B.; LOUREIRO, L. L.; FILHO, P. P. R. Gender-based approach to estimate the human body fat percentage using machine learning. *In: 2021 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2021, Shenzhen. Proceedings [...]* Shenzhen: IEEE, 2021. p. 1–8.
- BAGNI, U. V.; RIBEIRO, K. D. da S.; BEZERRA, D. S.; BARROS, D. C. de; FITTIPALDI, A. L. de M.; ARAÚJO, R. G. P. da S.; FERREIRA, A. A. Anthropometric assessment in ambulatory nutrition amid the covid-19 pandemic: Possibilities for the remote and in-person care. **Clinical Nutrition ESPEN**, California, v. 41, p. 186–192, 2021.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1st. ed. New York, NY: Springer New York, 2006. ISBN 978-0387-31073-2.
- BOLYA, D.; ZHOU, C.; XIAO, F.; LEE, Y. J. Yolact: Real-time instance segmentation. *In: 2019 IEEE/CVF INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2019, Seoul. Proceedings [...]* Seoul: IEEE, 2019. p. 9156–9165.
- BOLYA, D.; ZHOU, C.; XIAO, F.; LEE, Y. J. Yolact++: Better real-time instance segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, 2020.
- BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, USA, v. 120, p. 122–125, 2000.
- BREIMAN, L. Arcing classifiers. **Annals of Statistics**, Beachwood, v. 26, n. 801–849, 1998.
- BREIMAN, L. Random forests. **Machine Learning**, London, v. 45, n. 1, p. 5–32, 2001.
- BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. 1. ed. New York, NY: Routledge, 1984. ISBN 9781315139470.
- CAO, Z.; HIDALGO, G.; SIMON, T.; WEI, S.-E.; SHEIKH, Y. Openpose: Realtime multi-person 2d pose estimation using part affinity fields. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, v. 43, n. 1, p. 172–186, 2019.
- CAO, Z.; SIMON, T.; WEI, S.-E.; SHEIKH, Y. Realtime multi-person 2d pose estimation using part affinity fields. *In: 2017 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2017, Honolulu. Proceedings [...]* Honolulu: IEEE, 2017. p. 1302–1310.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, Kluwer Academic Publishers, USA, v. 20, n. 3, p. 273–297, sep 1995.
- DRUCKER, H.; BURGESS, C. J. C.; KAUFMAN, L.; SMOLA, A.; VAPNIK, V. Support vector regression machines. *In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 9., 1996, Denver. Proceedings [...]* Denver: MIT Press, 1996.
- DUBEY, S. R.; SINGH, S. K.; CHAUDHURI, B. B. Activation functions in deep learning: A comprehensive survey and benchmark. **Computing Research Repository (CoRR)**, arXiv, Ithaca, 2021.

FREEDMAN, D. **Statistical Models: Theory and Practice**. New York, NY: Statistical Models: Theory and Practice, 2005. ISBN 9781139165495.

GADEKAR, T.; DUDEJA, P.; BASU, I.; VASHISHT, S.; MUKHERJI, S. Correlation of visceral body fat with waist–hip ratio, waist circumference and body mass index in healthy adults: A cross sectional study. **Medical Journal Armed Forces India**, Pune, v. 76, n. 1, p. 41–46, 2020. ISSN 0377-1237.

GHODHBANI, H.; NEJI, M.; RAZZAK, I.; ALIMI, A. M. You can try without visiting: a comprehensive survey on virtually try-on outfits. **Multimedia Tools and Applications**, Basel, v. 81, p. 19967–19998, 2022.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. 326-366 p. ISBN 9780262035613. Disponível em: <http://www.deeplearningbook.org>. Acesso em: 10 jan. 2023.

HARRISON, M. **Machine Learning – Guia de Referência Rápida: Trabalhando com dados estruturados em Python**. São Paulo, SP: Novatec Editora, 2019. ISBN 9788575228173.

HAYASHI, F. **Econometrics**. Princeton, NJ: Princeton University Press, 2000. 15-18 p. ISBN 978-0691010182.

HAYKIN, S. O. **Neural Networks: A comprehensive foundation**. 2. ed. Upper Saddle River, NJ: Pearson Prentice Hall, 1998. ISBN 978-0-13-273350-2.

HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask r-cnn. *In*: 2017 IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2017, Venice. **Proceedings** [...] Venice: IEEE, 2017. p. 2980–2988.

HILT, D. E.; SEEGRIST, D. W. Ridge: a computer program for calculating ridge regression estimates. *In*: RESEARCH NOTE NE-236, 1977, Upper Darby. Upper Darby: UNITED STATES OF AMERICA. Department of Agriculture. Forest Service. Northeastern Forest Experiment Station., 1977. p. 1–7.

JAVAIID, M.; HALEEM, A.; SINGH, R. P.; SUMAN, R. Industrial perspectives of 3d scanning: Features, roles and it’s analytical applications. **Sensors International**, Amsterdam, v. 2, p. 100114, 2021. ISSN 2666-3511.

KE, J.-F.; WANG, J.-W.; LU, J.-X.; ZHANG, Z.-H.; LIU, Y.; LI, L.-X. Waist-to-height ratio has a stronger association with cardiovascular risks than waist circumference, waist-hip ratio and body mass index in type 2 diabetes. **Diabetes Research and Clinical Practice**, Amsterdam, v. 183, p. 109–151, 2022. ISSN 0168-8227.

KOMLOS, J.; BATEN, J. Looking backward and looking forward: Anthropometric research and the development of social science history. **Social Science History**, Cambridge University Press, Cambridge, v. 28, n. 2, p. 191–210, 2004.

KRZNARIĆ, Z.; BENDER, D.; CUERDA, C.; LAVIANO, A.; LANDI, F.; BARAZZONI, R.; MONTEIRO, R.; PIRLICH, M. A simple remote nutritional screening tool and practical guidance for nutritional care in primary practice during the covid-19 pandemic. **Clinical Nutrition**, Amsterdam, v. 39, p. 1983–1987, 08 2020.

- LI, X.; LI, G.; LI, T.; JIANPIN, L.; MITROUCHEV, P. Design of a multi-sensor information acquisition system for mannequin reconstruction and human body size measurement under clothes. **Textile Research Journal**, Los Angeles, v. 92, p. 3750–3765, 2022.
- LI, Y.; QI, H.; DAI, J.; JI, X.; WEI, Y. Fully convolutional instance-aware semantic segmentation. *In: 2017 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2017, Honolulu. Proceedings [...]* Honolulu: IEEE, 2017. p. 4438–4446.
- LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft coco: Common objects in context. *In: 2014 EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2014, Cham. Proceedings [...]* Cham: Springer International Publishing, 2014. p. 740–755.
- MINSKY, M.; PAPERT, S. **Perceptrons**. Boston, MA: MIT Press, 1969. ISBN 9780262630221.
- MOHAMMADI, S. O.; KALHOR, A. Smart fashion: a review of ai applications in the fashion & apparel industry. **Computing Research Repository (CoRR)**, Ithaca, v. 2111, p. 1–99, 2021.
- NANA, A.; STAYNOR, J.; ARLAI, S.; EL-SALLAM, A.; DHUNGEL, N.; SMITH, M. Agreement of anthropometric and body composition measures predicted from 2d smartphone images and body impedance scales with criterion methods. **Obesity Research Clinical Practice**, Amsterdam, v. 16, n. 1, p. 37–43, 2022. ISSN 1871-403X.
- NEVILL, A.; DUNCAN, M.; MYERS, T. Bmi is dead; long live waist-circumference indices: But which index should we choose to predict cardio-metabolic risk? **Nutrition, Metabolism and Cardiovascular Diseases**, Amsterdam, v. 32, n. 7, p. 1642–1650, 2022. ISSN 0939-4753.
- NWANKPA, C.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. Activation functions: Comparison of trends in practice and research for deep learning. **Computing Research Repository (CoRR)**, arXiv, Ithaca, v. 1811, p. 1–20, 2018.
- OSOKIN, D. Real-time 2d multi-person pose estimation on cpu: Lightweight openpose. **Computing Research Repository (CoRR)**, arXiv, Ithaca, v. 1811, p. 1–5, 2018.
- PAZHOOHI, F.; ARANTES, J.; KINGSTONE, A.; PINAL, D. Waist to hip ratio and breast size modulate the processing of female body silhouettes: An eeg study. **Evolution and Human Behavior**, Amsterdam, v. 41, n. 2, p. 150–169, 2020. ISSN 1090-5138.
- QUINLAN, J. R. Induction of decision trees. **Machine Learning**, London, v. 1, n. 1, p. 81–106, 1986.
- ROSS, R.; NEELAND, I. J.; YAMASHITA, S.; SHAI, I. Waist circumference as a vital sign in clinical practice: a consensus statement from the ias and iccr working group on visceral obesity. **Nature Reviews Endocrinology**, London, v. 16, p. 177–189, 2020.
- RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning representations by back-propagating errors. **Nature**, London, v. 323, p. 533–536, 1986.
- ŠKORVÁNKOVÁ, D.; RIEČICKÝ, A.; MADARAS, M. Automatic estimation of anthropometric human body measurements. **Computing Research Repository (CoRR)**, arXiv, Ithaca, v. 2112, p. 1–8, 2021.
- SMOLA, A.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, Basel, v. 14, p. 199–222, 2004.

SOUZA, J. W. M. de; HOLANDA, G. B.; IVO, R. F.; ALVES, S. S. A.; SILVA, S. P. P. da; NUNES, V. X.; LOUREIRO, L. L.; DIAS-SILVA, C. H.; FILHO, P. P. R. Predicting body measures from 2d images using convolutional neural networks. *In: 2020 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2020, Glasgow. Proceedings [...]* Glasgow: IEEE, 2020. p. 1–6.

TIBSHIRANI, R. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society. Series B (Methodological)**, [Royal Statistical Society, Wiley], v. 58, n. 1, p. 267–288, 1996. ISSN 00359246.

WORLD HEALTH ORGANIZATION. **Obesity and overweight**. [S. l.], 2021. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight>. Acesso em: 17 jul. 2022.

WORLD HEALTH ORGANIZATION EXPERT CONSULTATION ON OBESITY. **Waist Circumference and Waist-Hip Ratio**. [S. l.], 2008. Disponível em: <https://www.who.int/publications/i/item/9789241501491>. Acesso em: 03 ago. 2022.

XIE, H.; ZHONG, Y. Structure-consistent customized virtual mannequin reconstruction from 3d scans based on optimization. **Textile Research Journal**, Los Angeles, v. 90, n. 7–8, p. 937–950, 2020.

YAN, S.; KÄMÄRÄINEN, J.-K. Learning anthropometry from rendered humans. **Computing Research Repository (CoRR)**, arXiv, Ithaca, v. 2101, p. 1–10, 2021.

YAN, S.; WIRTA, J.; KÄMÄRÄINEN, J.-K. Anthropometric clothing measurements from 3d body scans. **Machine Vision and Applications**, Springer, Basel, v. 31, n. 1, p. 1–11, 2020.

ZOU, H.; HASTIE, T. Regularization and variable selection via the elastic net. **Statistical Methodology**, Amsterdam, v. 67, n. 2, p. 301–320, 2005.