

Estimação de Percentual de Gordura Corporal por Visão Computacional e Aprendizado de Máquina

L. de S. Tiné¹, B. A. S. Ávila¹, G. M. Araújo², A. A. de Lima², L. L. Loureiro³, S. L. Netto¹ e E. A. B. da Silva¹

Resumo— Este trabalho descreve uma solução de visão computacional para a estimação do índice de gordura corporal. Duas redes neurais são usadas na análise dos dados: DensePose para segmentação semântica de partes do corpo; PyTorch Keypoints RCNN para detectar pontos-chave. Um processamento visual permite o cálculo de medidas do corpo do indivíduo analisado. Um regressor usa as medidas para estimar o percentual de gordura. O método foi aplicado numa base de dados com 220 voluntários e os resultados indicam um erro absoluto médio de $4,25 \pm 1,66$ e $3,71 \pm 1,00$ para homens e mulheres, respectivamente.

Palavras-Chave— Visão computacional, Percentual de gordura corporal, Medidas antropométricas, Aprendizado de máquina.

Abstract— This work describes a computer vision solution for estimating the body fat index. We use two neural networks to analyze the data: DensePose for semantic segmentation of body parts; PyTorch Keypoints RCNN for detecting key points. We also use visual processing to calculate the body measurements of the subjects. A regressor uses them to estimate body fat percentage. The method was applied to a database with two images of 220 volunteers, and the results indicate an average absolute error of 4.25 ± 1.66 and 3.71 ± 1.00 for men and women, respectively.

Keywords— Computer vision, Body fat percentage, anthropometric measurements, Machine learning.

I. INTRODUÇÃO

A obesidade é um problema sério de saúde em escala mundial e pode estar associada a doenças como diabetes, hipertensão, entre outras [1]. O índice de massa corporal (*body mass index*, BMI) é uma medida de razão entre peso e altura, e costuma ser utilizado para definir obesidade, porém não é tão correlacionado aos riscos de doenças associadas a ela [2]. Desta forma, métricas mais complexas e específicas como percentual de gordura corporal (*body fat percentage*, BFP) costuma explicar melhor a relação da obesidade com o risco de doenças associadas. No entanto, a medição do BFP requer a utilização de equipamentos de custo elevado manuseados por especialista. Portanto, é importante a estimação por meio de outros atributos não tão diretamente relacionados, porém de mais fácil aquisição.

Neste trabalho, o problema de estimar o percentual de gordura corporal foi dividido em outros dois sub-problemas de estimação, conforme indicado na Fig. 1. O primeiro consiste em estimar medidas antropométricas dos indivíduos analisados, a partir de fotos e outros dados fornecidos. Já o segundo consiste em utilizar as estimativas de medidas antropométricas para então estimar o percentual de gordura corporal, que é o objetivo final. Ambos os problemas se utilizam da entrada de dados fornecida pelo usuário, a qual consiste em dados

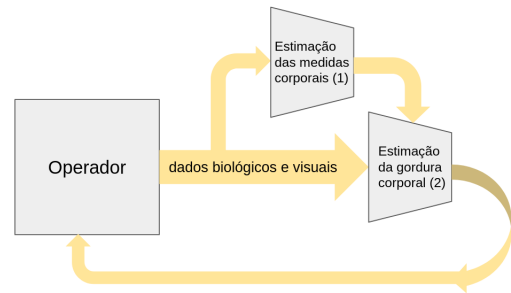


Fig. 1

FLUXO DE DADOS QUE REPRESENTA A ABORDAGEM PROPOSTA

relativos ao corpo do indivíduo do qual se deseja estimar o percentual de gordura.

Para apresentar a metodologia aqui proposta, este artigo é organizado da seguinte forma: A Seção II contém a descrição de trabalhos recentes associados tanto à estimação de medidas antropométricas quanto à estimação de percentual de gordura. A Seção III descreve a base de dados utilizada neste trabalho; A Seção IV detalha o procedimento de extrair informação quantitativa das imagens fornecidas pelos usuários do sistema e os resultados alcançados nessa etapa. Já a Seção V descreve a metodologia para usar essas informações para gerar a estimativa final do percentual de gordura corporal e os resultados obtidos nesse processo. A Seção VI conclui o trabalho enfatizando seus principais resultados.

II. TRABALHOS RELACIONADOS

As referências pertinentes à estimação de medidas antropométricas a partir de imagens podem ser separadas devido ao sistema de aquisição de dados: os artigos [3], [4], [5], [6], [7] são associados à digitalização 3D de corpo inteiro; já os artigos [8], [9] utilizam imagens 2D, sendo que o primeiro utiliza também câmeras infravermelho (IR) com marcações e vestimentas auxiliares.

Os trabalhos que tratam da estimativa de medidas antropométricas em modelos 3D geralmente empregam equipamento especializado, tais como digitalizadores 3D ou dispositivos do tipo Kinect. Com efeito, sistemas baseados em modelos 3D geralmente são mais caros ou menos portáteis que os sistemas baseados em imagens estáticas. Quanto à utilização de imagens 2D, o artigo [8] utiliza câmeras RGB e IR, dispositivo para os pés, um colete com marcadores para estimação de circunferências e marcadores no plano de fundo para estimação da altura. Testes foram realizados com dados

¹ Universidade Federal do Rio de Janeiro; ² Centro Federal de Educação Tecnológica; ³ Universidade Federal do Ceará.

de 10 clientes. Já Souza et al. [9] propõem a utilização de redes neurais convolucionais (*convolutional neural networks*, CNN). O conjunto de dados é composto por 38 exames com 4 imagens (frente, costas, direita e esquerda) de cada voluntário.

Os trabalhos referentes à estimação do BFP [10], [11], [12], [13], [14] são todos baseados em medidas antropométricas obtidas manualmente. Shao [10] desenvolveu abordagens híbridas inteligentes para a predição. O melhor desempenho foi obtido com MR-MARS (*multiple regression-multivariate adaptive regression splines*). Swainson et al. [11] desenvolveram um sistema de predição tanto de BFP, quanto de tecido adiposo visceral (*visceral adipose tissue*, VAT) por meio de 5 medidas antropométricas. Os atributos antropométricos BMI, circunferência da cintura (*waist circumference*, WC), razão cintura-quadril (*waist-to-hip ratio*, WHR), razão cintura-altura (*waist-to-height ratio*, WHtR) e $\text{cintura/altura}^{0.5}$ (*waist/height*^{0.5}, WHt.5R) foram medidos e calculados para 81 adultos. Os resultados concluíram que a melhor medida antropométrica para estimar as massas BFP e VAT é WHtR. Chiong et al. [12] utilizaram com sucesso a técnica *improved relative error support vector machine* (IRE-SVM) para estimação de gordura corporal. Alves et al. [13] propuseram um sistema baseado no gênero do usuário para estimar o BFP. O regressor LS-SVR (*least square-support vector regression*) alcançou o melhor desempenho para a abordagem baseada em gênero; neste caso, o regressor para homens utilizou 13 medidas antropométricas como atributos, enquanto o regressor para mulheres utilizou as medidas de cintura, altura, quadril e peso, que foram transformadas em BMI, WHtR, WHR e WHt.5R. A estimação usando algoritmos híbridos de aprendizado de máquinas proposta por [14] objetiva alta acurácia e quantidade mínima de parâmetros. Os modelos híbridos DT+SVR e MLP+DT+SVR juntamente com a seleção dos mais importantes atributos por correlação de Spearman, variando em número de 4 a 9, atingiram os melhores resultados.

No que diz respeito à estimação de medidas antropométricas, nenhuma das referências utiliza o mesmo conjunto de dados. Já na estimação de percentual de gordura corporal, 2 artigos utilizam dados diferentes de todos os outros, porém 3 referências [10], [12], [14] utilizam o mesmo conjunto de dados de forma integral, ou ainda parcialmente. Desta forma, eles são os únicos com possibilidade da realização de uma justa comparação de modelos por meio de resultados numéricos.

III. BASE DE DADOS

Para estimarmos o BFP, utilizamos uma base de dados composta de dois sub-conjuntos de informações complementares:

- Dados visuais: um par de fotos de cada voluntário, com pouca roupa cobrindo o corpo, de modo a permitir a análise de seu corpo;
- Dados biológicos: idade, altura, sexo, e peso do indivíduo.

Um par de imagens do corpo do indivíduo forma o conjunto de dados visuais. Cada uma das fotos deve ser tomada de acordo com a descrição a seguir, conforme ilustrado na Fig. 2:

- 1) Tirada de frente, com pés levemente afastados e abertos, e braços abertos na lateral do corpo, levemente erguidos;
- 2) Tomada pelo lado direito, com o voluntário tendo os pés juntos, o braço direito erguido de forma perpendicular

ao corpo, e o esquerdo relaxado junto ao corpo de modo a não aparecer na foto.




Fig. 2

EXEMPLO DE DADOS VISUAIS A SEREM FORNECIDOS COMO ENTRADA AO SISTEMA.

Vale destacar que, apesar do esforço empenhado para que todos os candidatos estivessem na mesma pose, as fotos de diferentes registros foram tomadas em diferentes condições de iluminação, com planos de fundo e distâncias para o indivíduo distintos, e também com câmeras diferentes. A pose dos indivíduos também não está sempre perfeitamente ajustada, de modo que alguns apresentam leves desvios, como braços em inclinações distintas do desejado, ou membros do lado esquerdo do corpo parcialmente visíveis na foto do lado direito. No entanto, a altura da câmera no momento da foto foi aproximadamente a mesma para todos os registros, graças ao uso de um tripé padronizado, cuja altura exata, no entanto, não foi mensurada.

Os dados dispostos na Tabela I exemplificam o conjunto de dados biológicos e antropométricos de um voluntário. O conjunto de dados antropométricos foi medido em laboratório para cada indivíduo e as medições anotadas são as circunferências (em cm) de (i) braço, (ii) antebraço, (iii) cintura, (iv) quadril, (v) coxa e (vi) panturrilha.

TABELA I

DADOS BIOLÓGICOS E ANTROPOMÉTRICOS CARACTERÍSTICOS DE UM REGISTRO DE DADOS DA BASE.

identificador	A1	sexo	masculino
idade [anos]	18	coxa [cm]	57,4
altura [cm]	174	panturrilha [cm]	40,4
peso [kg]	69,1	antebraço [cm]	26,4
braço [cm]	28,5	BMI [kg/m²]	22,82
cintura [cm]	74,6	% gordura	13,7
quadril [cm]	92,5		

A base de dados aqui utilizada é composta por 339 registros, sendo 216 de indivíduos do sexo feminino e 123 do sexo masculino. O percentual de gordura corporal foi medido para um subgrupo menor da base, composto por apenas 220 voluntários. Entre estes indivíduos, dois tipos de métodos de medição de gordura corporal foram utilizados: avaliação de composição corporal por DXA (*Dual-energy X-ray Absorptiometry*, ou absorciometria de raios-X de dupla energia) e por ultrassom.

A coleta desses dados e a construção da base aqui descrita foi, no contexto do projeto, avaliada e aprovada pelo Comitê

de Ética em Pesquisa (CEP) do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, segundo o parecer de número 3.593.367.

IV. PROCESSAMENTO DE IMAGENS

No primeiro estágio do sistema, objetivamos estimar 6 medidas antropométricas de circunferência corporal, com máxima precisão possível. Posteriormente, essas medidas estimadas serão usadas num segundo estágio para estimar o percentual de gordura corporal a partir de um processo de regressão.

Uma vez que dados visuais tenham sido disponibilizados, cada um dos membros do corpo visível nas fotos pode ser segmentado, usando uma rede neural DensePose [15], como ilustrado na Fig. 3. Além disso, a detecção de pontos-chave utilizando a rede neural PyTorch Keypoints RCNN [16] permite que um esqueleto seja parametrizado a partir desses pontos, definindo as regiões centrais da segmentação da figura humana obtidas utilizando o DensePose, como visto na Fig. 4.



Fig. 3

REPRESENTAÇÃO VISUAL DA SEGMENTAÇÃO SEMÂNTICA DAS PARTES DO CORPO, À DIREITA, APLICADA EM UMA IMAGEM TÍPICA, À ESQUERDA.

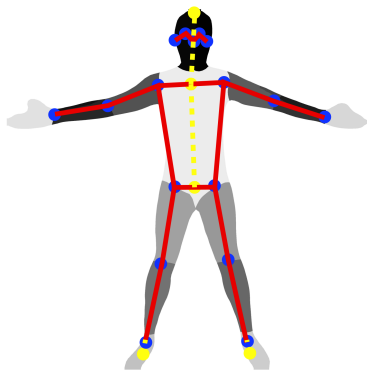


Fig. 4

DEMONSTRAÇÃO VISUAL DA COMBINAÇÃO DAS DUAS ANÁLISES: SEGMENTAÇÃO SEMÂNTICA E ESTIMAÇÃO DE POSE HUMANA.

Para cada medida a ser tomada, existe um ponto de interesse, que é o lugar do corpo que, numa hipotética medida de




Fig. 5

ILUSTRAÇÃO SIMPLIFICADA DO PROCESSO DE BUSCA PARA PONTO DE INTERESSE DA MEDIDA DO ANTEBRAÇO, E DA MEDIÇÃO DE SUA LARGURA ORTOGONAL

laboratório, um profissional envolveria com uma fita métrica para tomar a circunferência. Para fins didáticos, tome-se como exemplo a medida de circunferência do antebraço, em que o ponto de interesse é o ponto de maior circunferência. O processo de estimação dessa medida é ilustrado na Fig. 5 e descrito por:

- 1) A região do membro do corpo de interesse é destacada do restante da imagem, que é ignorado neste processo, e os pontos do esqueleto que delimitam a área de busca do ponto de interesse são definidos. No caso do antebraço, o ponto de interesse sempre está entre o cotovelo e o pulso;
- 2) A região de busca é dividida em 100 pontos equidistantes que são testados de acordo com o critério do ponto de interesse. No caso do antebraço, como buscamos o ponto de maior circunferência, entre os pontos testados será selecionado aquele cuja largura ortogonal do membro tiver maior comprimento. A largura ortogonal de cada ponto é testada utilizando a direção perpendicular à do esqueleto naquele ponto. Uma variação de ± 10 graus é feita para cada sentido, horário e anti-horário, para compensar leves erros de localização que os pontos-chave possam ter;
- 3) Dentre os pontos equidistantes, aquele em que a medida de largura ortogonal do membro for mais adequada será selecionado como o ponto de interesse da medida. No caso da medida do antebraço, este será o ponto onde se puder fazer a maior medida de comprimento perpendicular do membro. Observe que, no caso de outras medidas, o ponto de interesse poderia ser o de menor largura ortogonal, ou até mesmo um ponto fixo definido como uma interpolação linear de pontos-chave;
- 4) A medida da largura ortogonal do ponto de interesse encontrado é quantificada e armazenada. Uma vez que esta medida é um comprimento em pixels, a informação da altura é utilizada para fazer uma estimativa do comprimento real, em centímetros.

Com a largura ortogonal das segmentações semânticas nos pontos de interesse de cada medida armazenadas, uma para cada foto, duas abordagens podem ser utilizadas para estimar a circunferência real: a partir de aproximações geométricas, que considerariam a seção transversal do corpo como uma figura geométrica conhecida (uma circunferência ou elipse);

ou a partir de um modelo de aprendizado de máquina que estimaria a circunferência real após ser treinado em uma base de dados.

A. Resultados Experimentais do Processamento de Imagem

Para a avaliação das estimações obtidas no experimento, consideramos as seguintes métricas de erro: erro absoluto médio (MAE), o erro absoluto percentual médio (MAPE) e o erro médio quadrático (MSE). As Tabelas II e III apresentam os indicadores de erro para as estimações feitas por meio de aproximações geométricas e de modelos de aprendizado de máquina (no caso, de regressão linear), respectivamente.

Observe que a Tabela II mostra, para o braço e para o antebraço, cada métrica de erro duas vezes: cada uma relacionada a uma única foto. Isto é consequência de o braço e o antebraço terem, nas duas fotos, quase a mesma direção de vista, em sentidos opostos (e portanto, redundantes, em tese).

TABELA II

MÉTRICAS DE ERROS DA ESTIMAÇÃO POR APROXIMAÇÕES GEOMÉTRICAS.

medida	MAE [cm]	MAPE [%]	MSE [cm ²]
braço (frente)	3,79	12,92	18,70
braço (direita)	10,70	35,58	130,18
antebraço (frente)	1,96	7,63	5,80
antebraço (direita)	7,13	27,85	59,29
cintura	6,16	8,29	46,28
quadril	3,30	3,36	18,25
coxa	3,87	7,45	20,73
panturrilha	1,40	3,90	3,69

TABELA III

MÉTRICAS DE ERROS OBTIDAS NA ESTIMAÇÃO POR REGRESSÃO LINEAR.

medida	MAE [cm]	MAPE [%]	MSE [cm ²]
braço	1,91 ± 0,24	6,40 ± 0,84	5,53 ± 1,06
antebraço	1,19 ± 0,17	4,70 ± 0,73	2,27 ± 0,71
cintura	2,53 ± 0,39	3,38 ± 0,53	10,80 ± 3,11
quadril	2,62 ± 0,34	2,67 ± 0,35	11,10 ± 2,79
coxa	2,64 ± 0,51	5,01 ± 0,88	10,82 ± 3,82
panturrilha	1,45 ± 0,24	4,03 ± 0,77	3,50 ± 1,35

No caso do modelo de aprendizado de máquina, usou-se a técnica de validação cruzada em k -folds: os dados da sub-base de medidas corporais foram embaralhados em $k = 15$ lotes com aproximadamente o mesmo número de registros; dessa forma, por meio da agregação dos resultados de cada fold como conjunto de teste, é possibilitado o cálculo de valor esperado e desvio padrão para cada métrica de erro.

Comparando os resultados dos dois métodos, é possível perceber uma ampla vantagem do método de aprendizado de máquina em todas as métricas utilizadas, salvo poucos casos estatisticamente empatados (e.g., MAE e MAPE de panturrilha). Por isso, esta técnica foi utilizada na estimativa final de BFP.

V. ESTIMAÇÃO DE PERCENTUAL DE GORDURA CORPORAL

Nesta seção, descrevemos o experimento de estimativa do BFP utilizando estimativas de medidas corporais e outros

TABELA IV

COMPARAÇÃO ENTRE RESULTADOS DA ABORDAGEM DO PRESENTE TRABALHO E OS RESULTADOS DE [3].

Todos		
Autoria	MAE	MSE
Proposta (e1)	3,71 ± 0,71	21,74 ± 9,14
Proposta (e2)	4,14 ± 0,62	26,12 ± 8,56
Ref. [13]	3,57 ± 0,29	19,92 ± 3,49
Homens		
Autoria	MAE	MSE
Proposta (e1)	3,56 ± 1,77	19,37 ± 20,57
Proposta (e2)	4,25 ± 1,66	27,03 ± 24,37
Ref. [13]	2,76 ± 0,15	12,41 ± 1,64
Mulheres		
Autoria	MAE	MSE
Proposta (e1)	3,71 ± 0,60	21,30 ± 7,49
Proposta (e2)	3,71 ± 1,00	22,08 ± 10,36
Ref. [13]	4,00 ± 0,82	27,49 ± 13,12

dados, extraídos de imagens ou fornecidos a priori. O experimento é dividido em duas etapas.

Na primeira etapa, são utilizados os dados de medidas corporais anotados em laboratório, em conjunto com os dados biológicos (definidos na Seção III) e com cortes de segmentação extraídos das imagens. Esses dados são usados para treinar um regressor para estimar o BFP da forma mais confiável possível. Desta forma, os resultados obtidos na primeira etapa não sofrem influência dos erros de estimativa de medidas do primeiro estágio do sistema e funcionam como uma espécie de limite teórico de desempenho do sistema. Os resultados desta etapa são apresentados na Fig. 6. Foram avaliadas para a tarefa de regressão várias técnicas de aprendizado de máquina. Dentre os diversos tipos de modelos testados, se destacaram os seguintes: regressor ridge Bayesiano (BR), regressor ridge (RR) e *orthogonal matching pursuit* (OMP), sendo BR a que obteve melhor desempenho para os modelos separados por sexo.

Na segunda etapa, será utilizado o conjunto de estimativas mais confiável obtido no experimento de estimativa de medidas, apresentado na Subseção IV-A, e, desta forma, tem-se o sistema prático que depende apenas das imagens fornecidas inicialmente. As estimativas obtidas nesta etapa são apresentadas na Fig. 7. Nesta etapa, o BR também gerou o melhor resultado para os modelos baseados em sexo.

Podemos observar que os resultados do processo completo de estimativa, mostrados na Tabela IV, são, em média, bem próximos dos resultados ideais. O desempenho de modelos treinados especificamente para um determinado sexo frequentemente apresentam métricas melhores, em média, do que modelos generalistas, ao custo de um ligeiro aumento da variância de estimativa causada, muito provavelmente, pela diminuição da quantidade de dados em cada caso. É importante notar que a referência [13] estima o BFP a partir de medidas obtidas manualmente, sendo então a comparação mais adequada com a proposta (e1). Já a proposta (e2) possui dois níveis de estimativa sujeitos a mais erros acumulados, tornando o sistema mais desafiador. Ainda assim a proposta (e2) obteve resultado superior ao da referência [13] para o caso do sexo feminino.

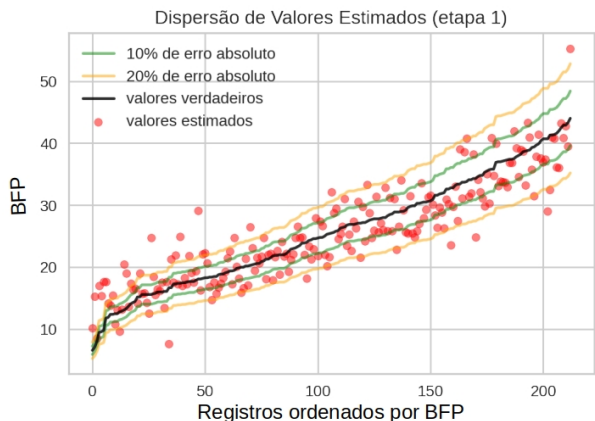


Fig. 6

RESULTADOS ESTIMADOS NA ETAPA 1 A PARTIR DAS MEDIDAS FORNECIDAS NA BASE DE DADOS.

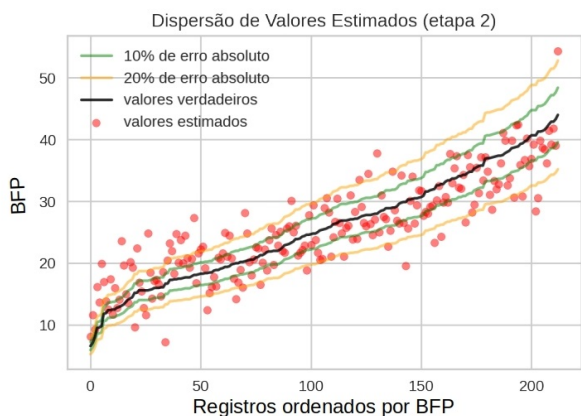


Fig. 7

RESULTADOS ESTIMADOS NA ETAPA 2 A PARTIR DAS IMAGENS FORNECIDAS NA BASE DE DADOS.

VI. CONCLUSÃO

As doenças associadas à obesidade possuem maior correlação com a medida do BFP, do que com o tradicional BMI, porém a medição do BFP requer a intervenção de mão-de-obra especializada e equipamentos caros. Desta forma, a estimação precisa do BFP por meio de medidas antropométricas obtidas sem o contato do especialista é muito importante.

O sistema proposto estima as medidas antropométricas dos usuários por meio de pares de imagens 2D nas posições frontal e lateral direita, bastando que o usuário utilize vestimenta apropriada e se coloque na posição pré-estabelecida. A segmentação da imagem corporal em instâncias foi realizada pela DensePose CNN+Keypoints RCNN e a estimação das medidas foi realizada por regressão linear. Uma vez que as medidas antropométricas foram estimadas, os dados alimentaram um regressor ridge Bayesiano para os modelos baseado no sexo do usuário. O MAE do sistema completo foi $4,24 \pm 1,66$ e $3,71 \pm 1,00$ para homens e mulheres, respectivamente.

A investigação de novas técnicas de aprendizado de

máquinas para melhor estimar as medidas antropométricas, a seleção/redução de atributos e até a diferenciação de atributos dependentes do modelo para estimação de gordura corporal são caminhos promissores para a redução do erro de estimação do sistema.

AGRADECIMENTO

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

REFERÊNCIAS

- [1] S. A. Patel, M. Ali, D. Alam, L. L. Yan, N. S. Levitt, A. Bernabe-Ortiz, W. Checkley, Y. Wu, V. Irazola, L. Gutierrez, A. Rubinstein, R. Shivashankar, X. Li, J. J. Miranda, M. A. Chowdhury, A. T. Siddiquee, T. A. Gaziano, M. M. Kadir, and D. Prabhakaran, "Obesity and its relation with diabetes and hypertension: A cross-sectional study across 4 geographical regions." *Global heart*, vol. 11, no. 1, pp. 71–79, 2016.
- [2] J. Escobedo-de la Peña, J. Ramírez-Hernández, M. Fernández-Ramos, E. González-Figueroa, and B. Champagne, "Body fat percentage rather than body mass index related to the high occurrence of type 2 diabetes." *Archives of medical research*, vol. 51, no. 6, pp. 564–571, 2020.
- [3] J.-M. Lu and M.-J. J. Wang, "The evaluation of scan-derived anthropometric measurements," *IEEE Transactions on Instrumentation and Measurement*, vol. 59, no. 8, pp. 2048–2054, 2010.
- [4] A. Tsoli, M. Loper, and M. J. Black, "Model-based anthropometry: Predicting measurements from 3d human scans in multiple poses," in *2014 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Los Alamitos, USA, MAR 2014, pp. 83–90.
- [5] T. Xiaohui, P. Xiaoyu, L. Liwen, and X. Qing, "Automatic human body feature extraction and personal size measurement," *Journal of Visual Languages & Computing*, vol. 47, no. 1, pp. 9–18, 2018.
- [6] S. Yan, J. Wirta, and J.-K. Kämäräinen, "Anthropometric clothing measurements from 3d body scans," *Machine Vision and Applications*, vol. 31, no. 7, 2020.
- [7] N. N. Kaashki, P. Hu, and A. Munteanu, "Deep learning-based automated extraction of anthropometric measurements from a single 3-d scan," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, no. 1, pp. 1–14, 2021.
- [8] T. Uhm, H. Park, and J.-I. Park, "Fully vision-based automatic human body measurement system for apparel application," *Measurement*, vol. 61, no. 1, pp. 169–179, 2015.
- [9] J. W. M. de Souza, G. B. Holanda, R. F. Ivo, S. S. A. Alves, S. P. P. da Silva, V. X. Nunes, L. L. Loureiro, C. H. Dias-Silva, and P. P. Rebouças Filho, "Predicting body measures from 2d images using convolutional neural networks," in *2020 International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, SEP 2020, pp. 1–6.
- [10] Y. Shao, "Body fat percentage prediction using intelligent hybrid approaches," *The Scientific World Journal*, vol. 2014, no. 1, p. 383910, 2014.
- [11] M. G. Swainson, A. M. Batterham, C. Tsakirides, Z. H. Rutherford, and K. Hind, "Prediction of whole-body fat percentage and visceral adipose tissue mass from five anthropometric variables," *PLOS ONE*, no. 5, pp. 1–12, 2017.
- [12] R. Chiong, Z. Fan, Z. Hu, and F. Chiong, "Using an improved relative error support vector machine for body fat prediction," *Computer Methods and Programs in Biomedicine*, vol. 198, no. 1, p. 105749, 2021.
- [13] S. S. Alves, E. F. Ohata, N. M. Nascimento, J. W. M. De Souza, G. B. Holanda, L. L. Loureiro, and P. P. Rebouças Filho, "Gender-based approach to estimate the human body fat percentage using machine learning," in *2021 International Joint Conference on Neural Networks (IJCNN)*, ShenZen, China, JUL 2021, pp. 1–8.
- [14] M. K. Uçar, Z. Uçar, F. Köksal, and N. Daldal, "Estimation of body fat percentage using hybrid machine learning algorithms," *Measurement*, vol. 167, no. 1, p. 108173, 2021.
- [15] R. A. Güler, N. Neverova, and I. Kokkinos, "Densepose: Dense human pose estimation in the wild," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake, USA, JUN 2018, pp. 7297–7306.
- [16] Pytorch, "Keypoint r-cnn," https://pytorch.org/vision/main/models/keypoint_rcnn.html, 2023, (Acesso em 02 Abril 2023).