



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS, TECNOLOGIA E SAÚDE - CAMPUS ARARANGUÁ
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

Gabriel Gobbo Araújo Valera

Extração de Medidas Corporais com Visão Computacional

Araranguá
2024

Gabriel Gobbo Araújo Valera

Extração de Medidas Corporais com Visão Computacional

Trabalho de Conclusão de Curso do Curso de Graduação em Engenharia de Computação do Centro de Ciências, Tecnologia e Saúde - Campus Araranguá da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Alison R. Panisson, Dr.

Araranguá
2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Valera, Gabriel Gobbo Araújo
Extração de Medidas Corporais com Visão Computacional /
Gabriel Gobbo Araújo Valera ; orientador, Alison R.
Panisson, 2024.
36 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Campus Araranguá,
Graduação em Engenharia de Computação, Araranguá, 2024.

Inclui referências.

1. Engenharia de Computação. 2. Engenharia de Computação.
3. Visão Computacional . 4. Processamento Digital de
Imagens . 5. Medidas Corporais . I. Panisson, Alison R..
II. Universidade Federal de Santa Catarina. Graduação em
Engenharia de Computação. III. Título.

Gabriel Gobbo Araújo Valera

Extração de Medidas Corporais com Visão Computacional

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia de Computação” e aprovado em sua forma final pelo Curso de Graduação em Engenharia de Computação.

Araranguá, 28 de Junho de 2024.

Prof. Jim Lau, Dr.
Coordenador do Curso

Banca Examinadora:

Prof. Alison R. Panisson, Dr.
Orientador

Prof. Alexandre Leopoldo Gonçalves, Dr.
Avaliador
Universidade Federal de Santa Catarina

Prof. Jim Lau, Dr.
Avaliador
Universidade Federal de Santa Catarina

Extração de Medidas Corporais com Visão Computacional

Gabriel Gobbo Araújo Valera*

Alison R. Panisson†

2024, July

Resumo

As medidas corporais são uma ferramenta valiosa para quem deseja monitorar a saúde, comprar roupas online, melhorar o desempenho esportivo, entre outras aplicações. Porém, a extração dessas medidas costuma ser feita manualmente, tornando o processo demorado, difícil e, muitas vezes, inviável na ausência de materiais apropriados. Neste contexto, o presente trabalho tem como objetivo criar um sistema para extrair medidas corporais de forma rápida e precisa, além de utilizar essas medidas em futuras aplicações, como a busca pelo vestuário ideal. Utilizando visão computacional, o sistema desenvolvido calcula as medidas corporais a partir de uma foto enviada pelo usuário, juntamente com a altura da pessoa da imagem. Com o auxílio de bibliotecas essenciais e processamento digital de imagens, detalhados neste trabalho, foi possível realizar os cálculos para determinar as medidas corporais. Os resultados dos testes realizados demonstram que o método apresentou uma precisão com erro absoluto médio variando de 0% a 7.51%. Esses resultados destacam a eficiência do método proposto, oferecendo uma alternativa rápida para a obtenção de medidas corporais, especialmente para aqueles que não possuem os equipamentos adequados para medições manuais ou para aqueles que desejam utilizar o método proposto em aplicações diversas.

Palavras-chaves: Visão Computacional. Processamento Digital de Imagens. Medidas Corporais.

*gabrielgavalera@gmail.com

†alison.panisson@ufsc.br

Extraction of Body Measurements Using Computer Vision

Gabriel Gobbo Araújo Valera*

Alison R. Panisson†

2024, July

Abstract

Body measurements are a valuable tool for those who want to monitor their health, buy clothes online, improve athletic performance, among other applications. However, extracting these measurements is usually done manually, making the process time-consuming, difficult, and often unfeasible in the absence of appropriate materials. In this context, the present work aims to create a system to extract body measurements quickly and accurately, as well as to use these measurements in future applications, such as the search for the ideal clothing. Using computer vision, the developed system calculates body measurements from a photo sent by the user, along with the person's height in the image. With the help of essential libraries and digital image processing, detailed in this work, it was possible to perform the calculations to determine body measurements. The results of the tests carried out show that the method presented an accuracy with an average absolute error ranging from 0% to 7.51%. These results highlight the efficiency of the proposed method, offering a quick alternative for obtaining body measurements, especially for those who do not have the proper equipment for manual measurements or for those who wish to use the proposed method in various applications.

Key-words: Computer Vision. Digital Image Processing. Body Measurements.

*gabrielgavalera@gmail.com

†alison.panisson@ufsc.br

1 Introdução

Quando uma pessoa está ciente de suas medidas corporais, ela obtém informações valiosas e essenciais para uma variedade de propósitos, incluindo o monitoramento da saúde e do condicionamento físico, análise e rastreamento de resultados esportivos, e até mesmo para a escolha adequada de vestuário. No entanto, obter essas medidas manualmente pode se revelar uma tarefa complexa, e em alguns casos, impossível, especialmente na ausência de uma fita métrica ou algum outro equipamento que é essencial para uma medição.

No contexto da saúde e do condicionamento físico, as medidas corporais são frequentemente utilizadas para avaliar o progresso de um indivíduo em relação a metas específicas. Parâmetros como peso, altura, circunferência da cintura, percentual de gordura corporal e Índice de Massa Corporal (IMC) são comumente monitorados para determinar a eficácia de programas de exercícios e planos alimentares. Essas medidas oferecem uma visão abrangente da composição corporal e ajudam a identificar áreas que precisam de melhoria, contribuindo assim para a prevenção de doenças relacionadas ao estilo de vida (AHERN et al., 2012).

Além disso, no campo esportivo, as medidas corporais desempenham um papel fundamental na análise e rastreamento de resultados. Atletas e treinadores utilizam dados como peso, altura, proporção de massa muscular e composição corporal para avaliar o desempenho, identificar áreas de fraqueza e desenvolver estratégias de treinamento personalizadas. Essas medidas não apenas ajudam a maximizar o potencial atlético, mas também auxiliam na prevenção de lesões, na recuperação eficiente e até para saber se o atleta possui as medidas corporais ideais de acordo com o esporte, como é citado em Santos et al. (2014).

A escolha do vestuário também é influenciada pelas medidas corporais. A indústria da moda reconhece a importância de roupas que se ajustam adequadamente ao corpo, não apenas em termos de estética, mas também de conforto e desempenho. Medidas precisas garantem que as roupas se adaptem de maneira adequada, proporcionando liberdade de movimento e sustentação ao corpo onde necessário. Além disso, para atletas e praticantes de atividade física, o vestuário esportivo adequado pode melhorar o desempenho, facilitando a regulação da temperatura corporal e reduzindo o atrito durante a atividade física. Alguns estudos, como exemplo Zunker et al. (2014), descrevem objetivamente como a roupa impacta na performance das atividades físicas.

Nesse contexto, torna-se evidente a vantagem de ter acesso fácil às suas medidas corporais. Este trabalho propõe-se uma solução tecnológica e acessível para a extração de medidas corporais por meio de técnicas de visão computacional. O sistema desenvolvido é capaz de extrair medidas do corpo humano a partir de uma única foto e da altura informada pelo usuário, oferecendo assim uma alternativa eficiente e conveniente para a medição manual.

Esse documento está organizado da seguinte forma. Primeiramente, na Seção 2, é descrito a fundamentação teórica do trabalho, incluindo conceitos e tecnologias utilizadas para o seu desenvolvimento. Na Seção 3 é descrito o método proposto para extração de medidas corporais utilizando visão computacional, incluindo a abstração de serviço proposta e uma aplicação na área de vestuário. Na Seção 4 são apresentados os resultados obtidos, onde os mesmos são discutidos. Finalmente, na Seção 5 apresentamos os trabalhos relacionados, e por fim, na Seção 6, são descritas as conclusões e trabalhos futuros.

2 Background

Nessa seção é descrito o *background* que fundamenta o trabalho desenvolvido, introduzindo os conceitos, técnicas e algoritmos utilizados. Também, contextualizamos as áreas de aplicação da abordagem desenvolvida.

2.1 Visão Computacional

Inicialmente é importante diferenciarmos visão e imagem. O conceito de visão geralmente se refere à percepção ou à capacidade de observar algo diretamente, enquanto uma imagem é uma representação visual estática, seja através de uma fotografia, pintura, gráfico ou qualquer outra forma de representação visual.

A visão computacional, um campo interdisciplinar que combina técnicas de computação e processamento de imagens, encontra suas raízes nessa distinção fundamental entre visão e imagem. Enquanto a visão humana envolve a interpretação de informações visuais para compreender o mundo ao nosso redor, a visão computacional busca capacitar os sistemas computacionais a realizar tarefas semelhantes. Isso é alcançado através da análise e interpretação de imagens digitais, permitindo que os computadores entendam o conteúdo visual e tomem decisões baseadas nessa compreensão.

Assim como a visão humana é uma experiência visual direta, a visão computacional capacita os computadores a processar e interpretar informações visuais de maneira semelhante, por meio de algoritmos e técnicas computacionais. Isso os habilita a executar uma ampla gama de tarefas, desde o reconhecimento de objetos até a navegação autônoma.

No final da década de 1960, a visão computacional tornou-se uma área acadêmica e começou a ser investigada nas universidades. Foi desenvolvida para imitar o sistema visual humano, como um trampolim para dotar robôs de comportamento inteligente (SZELISKI, 2010). Nesse contexto, surgiram os primeiros sinais do interesse de pesquisadores em desenvolver algoritmos capazes de identificar objetos em imagens, visando aplicativos estratégicos. No entanto, as limitações tecnológicas da época restringiram as aplicações práticas.

Ao longo do tempo, com o avanço tecnológico, destacou-se o trabalho pioneiro de Roberts (1963), desenvolvendo um sistema chamado “*Blockworld*” na Bolt, Beranek, and Newman (BBN) Corporation. Esse trabalho influenciou as pesquisas posteriores em visão computacional e teve um impacto significativo no desenvolvimento de tecnologias de processamento de imagem e visão computacional. Posteriormente, Dana e Christopher (1982) definiram a visão computacional como a habilidade de construir descrições explícitas de objetos físicos a partir de imagens, buscando emular a capacidade visual humana. Este campo interdisciplinar da inteligência artificial concentra-se na aquisição de informações visuais por meio de câmeras e no processamento de imagens para identificar objetos, reconhecer padrões e compreender a profundidade e o movimento em cena.

Atualmente, a visão computacional alcançou um alto nível de desenvolvimento, com uma ampla variedade de bibliotecas, algoritmos, e frameworks dedicados ao seu uso. Isso reflete o notável crescimento e sofisticação da área, proporcionando aos profissionais e pesquisadores as ferramentas para explorar e aplicar os conceitos da visão computacional em diversos campos, incluindo sistemas de diagnóstico médico (SABA, 2021), realidade aumentada (SOUSA, 2015), detecção de medidas corporais (STANCIC; SUPUK; CECIC, 2009), entre outros.

2.1.1 Visão Computacional Aplicada para Extração de Medidas Corporais

A visão computacional oferece um amplo leque de aplicações, e uma delas é a leitura de medidas corporais a partir de imagens 2D ou 3D, o que se revela extremamente versátil. Além disso, de similar importância, aplicação da visão computacional na extração de medidas diversas tem ganhado crescente relevância e impacto em diversas áreas, como por exemplo: (i) na medicina, onde, por exemplo, (TEK; DEMPSTER; KALE, 2009) utiliza visão computacional para diagnóstico de malária; (ii) na segurança, onde, por exemplo, (CHEN; SURETTE; SHAH, 2021) utiliza da visão computacional para fazer monitoramento com câmeras fornecendo análise automatizada de vídeo em tempo real; (iii) na agricultura, onde, por exemplo, (MOGILI; DEEPAK, 2018) utiliza drones e técnicas de visão computacional para aumentar a produtividade da área de plantio; e (iv) esportes, onde, por exemplo, (NAIK; HASHMI; BOKDE, 2022) destaca a utilização da visão computacional em vários esportes.

O processo de extração de medidas corporais por meio da visão computacional envolve o uso de câmeras 2D (como a câmera do celular), câmeras 3D (*LIDAR*) ou sensores de profundidade (*Kinect*). Esses dispositivos, em conjunto com algoritmos de processamento de imagem, permitem identificar e quantificar características do corpo humano, tais como altura, largura do quadril, comprimento dos membros, entre outros parâmetros. A quantidade e a precisão dos parâmetros extraídos muitas vezes dependem da qualidade e do método de captura das imagens utilizadas e bem como do algoritmo utilizado ou desenvolvido.

Essas medidas podem ser utilizadas em uma variedade de aplicações, desde a avaliação do estado de saúde de um paciente (analisar a quantidade de massa corporal) até a personalização de roupas ou equipamentos esportivos (estimar medidas corporais e comparar com medidas indicadas por fabricantes de roupas e equipamentos esportivos), demonstrando o vasto potencial dessa tecnologia.

2.1.2 Visão Computacional no Contexto de Treinamento Físico

Nas seções anteriores, discutimos a abrangência das aplicações da visão computacional, que se estende a diversas áreas. No contexto do treinamento físico, essa tecnologia também desempenha papéis essenciais, incluindo análise e rastreamento de movimentos, avaliação de desempenho, prevenção de lesões e Realidade Aumentada. Sua contribuição é considerada notável para a melhoria da performance e qualidade da prática física.

A aplicação de câmeras em conjunto com algoritmos especializados possibilitam a captura precisa dos movimentos durante atividades físicas. Através dessas imagens, é viável realizar uma análise e o rastreamento dos movimentos. Essa tecnologia oferece aos atletas uma avaliação detalhada de seu desempenho (HOST; IVAŠIĆ-KOS, 2022). Um exemplo do uso dessa tecnologia pode ser observado no aplicativo Nike Training Club¹, que utiliza visão computacional para monitorar movimentos e fornecer feedback personalizado (WANG et al., 2019).

A captação de movimentos vai além do simples aprimoramento da execução de atividades como musculação, *yoga* e pilates; ela também proporciona uma análise aprofundada do desempenho atlético. Um exemplo é o aplicativo *Runtastic Results*², que utiliza visão computacional para avaliar a precisão dos movimentos durante os exercícios. Esse

¹ <<https://www.nike.com.br/sc/corrida-app-nike-run-club>>

² <<https://www.runtastic.com>>

aplicativo oferece instruções detalhadas e feedback em tempo real, elevando ainda mais a experiência do usuário e contribuindo para um treinamento mais eficaz.

Além de contribuir para a avaliação do desempenho, essa abordagem desempenha um papel preventivo essencial. Ao monitorar os movimentos é possível identificar padrões que podem levar a lesões (KHANAL et al., 2022). Isso não apenas melhora a execução das atividades, mas também contribui significativamente para evitar potenciais lesões, promovendo a saúde e a segurança dos praticantes de exercícios físicos.

Também, ao incorporar visão computacional na realidade aumentada abre-se um vasto leque de possibilidades, destacando-se sua contribuição fundamental para a melhoria do treinamento físico personalizado. Como exemplo é a criação de um “*fisiogame*” voltado para a reabilitação de pacientes, conforme detalhado em Fernandes et al. (2014).

Em síntese, a visão computacional no contexto do treinamento físico se destaca como uma aliada crucial, desempenhando um papel significativo no aprimoramento da qualidade do treinamento. Desde análises precisas e rastreamento de movimentos até avaliações personalizadas de desempenho, prevenção de lesões e integração com a Realidade Aumentada. A visão computacional emerge como um catalisador que impulsiona o cenário do treinamento físico, permitindo que indivíduos pratiquem de forma autônoma e sem a necessidade de suporte profissional. Além disso, para aqueles que já possuem conhecimento, torna-se um aliado poderoso para alcançar novos marcos e superar desafios.

2.2 Processamento de Imagens

Primeiramente, é fundamental compreender o papel dos pixels no contexto de processamento de imagem. Os pixels, abreviação de “elementos de imagem” em inglês (*picture elements*), são os blocos fundamentais que compõem uma imagem digital. Cada pixel representa um minúsculo ponto em uma grade, e a meticulosa combinação de milhões desses pontos culmina na imagem que visualizamos em nossos dispositivos eletrônicos (KAEHLER; BRADSKI, 2016).

Esses pontos individuais transportam informações de cor e intensidade luminosa, sendo eles os blocos de construção essenciais para qualquer imagem digital. O processamento de imagens, por sua vez, engloba um conjunto de técnicas e algoritmos utilizados para manipular esses pixels. Isso pode incluir aprimoramento da qualidade da imagem, extração de informações úteis e execução de tarefas específicas, como reconhecimento de padrões ou detecção de objetos (SZELISKI, 2022).

Compreender os fundamentos dos pixels e das técnicas de processamento de imagens nos leva a explorar um vasto leque de aplicações. Desde o refinamento de fotografias até a concepção de sistemas avançados, como os de visão computacional. Também, oferecendo diversas possibilidades de aplicação, como em algoritmos de reconhecimento facial (PASSOS; QUINTANILHA; ARAUJO, 2018).

Nesse contexto, é crucial destacar a importância do processamento de imagem para o desenvolvimento de algoritmos de visão computacional. Existem uma série de bibliotecas que auxiliam as diferentes tarefas de processamento de imagens, como veremos na próxima seção.

2.3 Biblioteca Úteis para Visão Computacional

A visão computacional, como mencionado anteriormente, é uma área de pesquisa e desenvolvimento que se baseia em técnicas e algoritmos para interpretar e compreender o conteúdo visual de imagens e vídeos. Ao longo dos anos, essa área tem sido alvo de diversos estudos e avanços significativos, resultando em uma vasta gama de técnicas e ferramentas disponíveis para os desenvolvedores.

Nesse sentido, a utilização de bibliotecas especializadas em visão computacional desempenha um papel fundamental no desenvolvimento de algoritmos e aplicações nesse campo. Estas bibliotecas fornecem uma base sólida e eficiente para a implementação de diversas tarefas, desde processamento básico de imagens até tarefas mais avançadas, como detecção de objetos e reconhecimento facial.

Ao aproveitar o poder dessas bibliotecas, os desenvolvedores podem economizar tempo e esforço na implementação de algoritmos do zero, além de se beneficiarem do conhecimento e das melhores práticas incorporadas nessas ferramentas. No contexto deste trabalho, serão abordadas algumas das bibliotecas mais amplamente utilizadas e relevantes para a visão computacional, destacando suas principais características e funcionalidades. As bibliotecas utilizadas são: *Open Source Computer Vision Library* (OpenCV) para processamento de imagem e aplicação do algoritmo de detecção de bordas, MediaPipe para segmentação de imagem e aplicação do algoritmo de pose, e NumPy para os cálculos das medidas corporais. Cada uma delas será descrita em maiores detalhes nas seções seguintes.

2.3.1 Biblioteca Open Source Computer Vision Library (OpenCV)

A Biblioteca de Visão Computacional de Código Aberto (OpenCV)³ é uma ferramenta amplamente reconhecida e respeitada no campo do processamento de imagens e visão computacional. Desenvolvida em 1999 por Gary Bradski, na época pesquisador na Intel, a OpenCV foi criada com o objetivo principal de fornecer um conjunto abrangente de ferramentas para tarefas de visão computacional.

Uma das características distintivas da OpenCV é sua natureza de código aberto, o que oferece aos desenvolvedores acesso ao código-fonte para modificações e personalizações de acordo com as necessidades específicas do projeto. Além disso, a presença de uma comunidade ativa de desenvolvedores contribui para a constante melhoria da biblioteca, garantindo a correção de *bugs* e a introdução de novos recursos de forma colaborativa.

Outro ponto relevante é a compatibilidade multiplataforma da OpenCV. Com suporte para uma ampla gama de sistemas operacionais, incluindo Windows, Linux, macOS, Android e iOS, os desenvolvedores têm a flexibilidade de criar aplicativos de visão computacional que funcionam em diversos dispositivos, garantindo a escalabilidade e a acessibilidade do algoritmo desenvolvido.

A OpenCV também se destaca por sua integração facilitada com outras bibliotecas e *frameworks* populares, como NumPy, SciPy, TensorFlow e MediaPipe, ampliando ainda mais suas capacidades e possibilitando o desenvolvimento de soluções poderosas e flexíveis para o projeto em questão.

Vale destacar, OpenCV possui abundante documentação, recursos e vários livros de aprendizado online como o livro (MINICHINO; HOWSE, 2015) que é um dos pilares para quem quer aprender a OpenCV utilizando Python. A existência de material abrangente

³ <<https://opencv.org>>

torna o processo de aprendizagem e desenvolvimento acessível para desenvolvedores de todos os níveis de habilidade, facilitando a implementação e o aprimoramento do algoritmo de determinação de medidas corporais.

Além disso, a OpenCV oferece várias funções prontas para uso, destacando-se a detecção de bordas. O algoritmo *Canny*⁴, disponível na OpenCV como `cv2.Canny`, é amplamente utilizado para detecção precisa de bordas em imagens, desempenhando um papel fundamental em muitos projetos de visão computacional.

Em suma, a combinação de acessibilidade, funcionalidade abrangente, eficiência, compatibilidade multiplataforma e recursos de aprendizado fazem da OpenCV uma escolha sólida para quem busca uma biblioteca robusta e flexível para o desenvolvimento de aplicações de processamento de imagem e visão computacional.

2.3.2 Biblioteca MediaPipe

A MediaPipe é uma biblioteca de código aberto desenvolvida pelo Google⁵. Ela oferece uma série de componentes pré-construídos para diversas tarefas de processamento de imagem e vídeo, permitindo aos desenvolvedores criar aplicações envolvendo detecção de objetos, reconhecimento facial, rastreamento de mãos, estimativa de pose, entre outras funcionalidades de visão computacional e aprendizado de máquina.

A MediaPipe implementa a *MediaPipe Pose Detection*⁶, uma solução para a detecção de pose corporal. O algoritmo de detecção de pose é baseado na arquitetura de Rede Neural Convolutiva (do inglês *Convolutional Neural Network* - CNN) e é projetada para extrair *landmarks* específicos do corpo humano e traçar seu esqueleto. O algoritmo é capaz de extrair 33 *landmarks*, como pode ser observado na Figura 1, que podem ser utilizados para uma variedade de aplicações. A escolha desta biblioteca se deu principalmente pela quantidade de *landmarks* oferecidos e pela eficiência com que é capaz de estimar a pose humana em imagens.

Através da detecção de poses com a *MediaPipe Pose Detection*, é possível extrair com precisão as posições dos *landmarks* do corpo humano. Esses *landmarks* servem como referências valiosas, fornecendo informações cruciais sobre a posição do corpo humano na imagem. Essas informações podem ser utilizadas para uma variedade de aplicações. Por exemplo, é viável calcular os ângulos formados pelo joelho conforme a pessoa se agacha. Tal funcionalidade pode ser aplicada em um auxiliar de agachamento, como demonstrado no artigo (TSAI; HUANG,). Além disso, essas informações são fundamentais em aplicações que envolvem análise de movimento corporal ou interação humano-computador.

Outra funcionalidade da biblioteca MediaPipe é a segmentação de imagem⁷, que permite dividir imagens em regiões com base em categorias predefinidas. Com essa funcionalidade, é possível identificar objetos ou texturas específicas e aplicar efeitos visuais, como desfoque de fundo. Existem vários modelos disponíveis na biblioteca para segmentação de pessoas e suas características nas imagens, os quais foram fundamentais nesse trabalho.

Um dos modelos utilizados para segmentar o corpo de uma pessoa e colocá-lo em um fundo branco é o SelfieMulticlass (256 x 256) (model card)⁸. Este modelo de

⁴ <https://docs.opencv.org/4.x/da/d22/tutorial_py_canny.html>

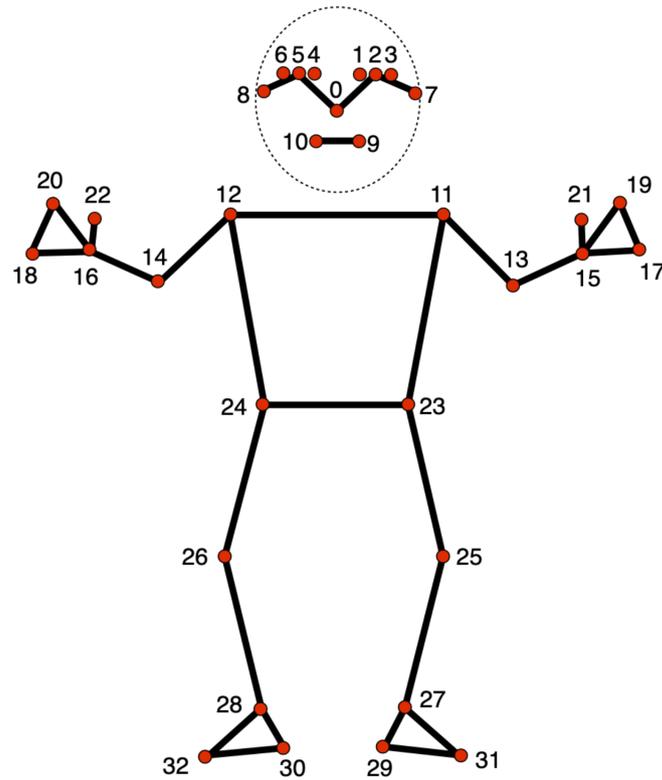
⁵ <<https://developers.google.com/mediapipe>>

⁶ <https://developers.google.com/mediapipe/solutions/vision/pose_landmarker>

⁷ <https://ai.google.dev/edge/mediapipe/solutions/vision/image_segmenter>

⁸ <<https://storage.googleapis.com/mediapipe-assets/Model%20Card%20Multiclass%20Segmentation>>

Figura 1 – Landmarks retornados pela MediaPipe Pose Detection.



Fonte: Google (2023).

segmentação multi-classe classifica cada pixel como fundo, cabelo, corpo, rosto, roupas ou outros. Ele suporta imagens contendo uma ou mais pessoas, *selfies* e imagens de corpo inteiro⁹.

2.3.3 Biblioteca NumPY

A NumPy¹⁰ é uma biblioteca essencial para processamento numérico em Python, especialmente quando se trata de realizar operações matemáticas em imagens. Ela fornece uma ampla gama de recursos poderosos para lidar com *arrays* multidimensionais, incluindo operações matriciais e indexação avançada.

Uma das principais vantagens do NumPy é sua extensa coleção de funções para manipulação de *arrays*, incluindo operações aritméticas básicas, funções matemáticas avançadas, ajuste de forma e tamanho de *arrays*, entre outras. Sua sintaxe simples e eficiente permite a realização de operações complexas de forma concisa.

No contexto específico do processamento de imagem, a NumPy é frequentemente empregada em uma variedade de tarefas, como filtragem, transformações geométricas, manipulação de histogramas e cálculo de gradientes¹¹. Sua capacidade de lidar facilmente

pdf>

⁹ Um exemplo prático da biblioteca foi disponibilizado em: <<https://github.com/valeragabriel/BodySegmentation-MediaPipe/blob/main/main.py>>

¹⁰ <<https://numpy.org/>>

¹¹ <<https://numpy.org/doc/stable/user/c-info.html>>

com *arrays* multidimensionais facilita a representação e manipulação de imagens como matrizes, o que é crucial para a implementação eficiente de algoritmos de processamento de imagem.

2.4 Lógica Fuzzy

A lógica fuzzy, também conhecida como lógica difusa, foi introduzida pelo artigo “*Fuzzy Sets*” publicado por Zadeh (1965). Este trabalho propôs a lógica fuzzy como uma extensão da lógica clássica, projetada para lidar com imprecisões e incertezas frequentes em problemas do mundo real. Enquanto a lógica clássica opera com valores binários, a lógica fuzzy permite a inclusão de valores intermediários, representando graus variados de verdade.

A lógica fuzzy se baseia na teoria dos conjuntos fuzzy, onde um elemento pode pertencer a um conjunto com o grau de pertinência que varia entre 0 e 1. Em vez de inferir que uma proposição é completamente verdadeira ou falsa, a lógica fuzzy permite expressar que uma proposição é “parcialmente verdadeira”. Isso é particularmente útil em situações onde a rigidez da lógica clássica não se aplica, como definir o tamanho de vestuário de uma pessoa com base em suas medidas ou controlar a temperatura de uma estufa.

Do ponto de vista prático, ela pode ser aplicada com Python através da biblioteca “*scikit-fuzzy*”¹². Com essa biblioteca é possível criar sistemas de inferência fuzzy, definir conjuntos fuzzy e aplicar funções de pertinência para modelar variáveis linguísticas. A biblioteca oferece uma ampla gama de funções para operações fuzzy, incluindo lógica fuzzy clássica e operações de conjuntos. Além disso, a integração com outras bibliotecas do ecossistema Python, como NumPy e Matplotlib, permite realizar análises complexas e visualizações de dados.

A utilização da lógica fuzzy permite lidar com valores intermediários, sendo ideal para diversas aplicações que necessitam de resultados imprecisos e adaptáveis. Com a biblioteca scikit-fuzzy, a aplicação prática da lógica fuzzy torna-se mais acessível em várias áreas, como controle de sistemas, tomada de decisão e processamento de imagem, proporcionando uma maneira eficiente e intuitiva de incorporar raciocínio impreciso em diferentes contextos, como encontrando o tamanho ideal de vestuário da pessoa com base em suas medidas corporais.

2.5 Equações Utilizadas

Para validação do método de extração de medidas corporais foram feitas análises estatísticas, e nelas foram usadas as seguintes equações: Erro Médio, Erro Absoluto Médio, Raiz Do Erro Quadrático Médio

2.5.1 Erro Médio

O Erro Médio (ME - *Mean Error*) é uma métrica usada para avaliar como varia a média do erro do modelo de previsão no qual o sinal importa, comparando os valores previstos pelos modelos com os valores reais. A Equação 1 representa o cálculo do Erro Médio (ME), onde y_i é o valor observado e \hat{y}_i é o valor predito.

$$\text{Erro Médio} = \bar{y} - \bar{\hat{y}} \quad (1)$$

¹² <<https://pypi.org/project/scikit-fuzzy/>>

onde:

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

e

$$\bar{\hat{y}} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i$$

Descrição dos termos:

- \bar{y} : É a média dos valores observados (reais).
- $\bar{\hat{y}}$: É a média dos valores previstos (preditos).
- y_i : É o valor observado (real) na i -ésima observação.
- \hat{y}_i : É o valor previsto na i -ésima observação.
- n : É o número total de observações.

2.5.2 Erro Absoluto Médio

Erro Absoluto Médio (MAE - *Mean Absolute Error*) é uma medida estatística que calcula a média dos valores absolutos dos erros entre as previsões e os valores reais, sendo amplamente utilizado para avaliar a precisão de modelos de previsão ou estimativa. A Equação 2 representa o cálculo do Erro Absoluto Médio, onde y_i é o valor observado e \hat{y}_i é o valor previsto.

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

2.5.3 Raiz Do Erro Quadrático Médio

A Raiz do Erro Quadrático Médio (RMSE - *Root Mean Square Error*) é uma métrica robusta que penaliza mais fortemente grandes erros de previsão, refletindo melhor a magnitude dos erros em comparação com a média simples. É comumente utilizado para comparar a performance de diferentes modelos e para ajustar parâmetros visando a minimização dos erros quadráticos. A RMSE é calculada pela Equação 3, onde y_i é o valor observado e \hat{y}_i é o valor previsto.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

3 Extração de Medidas Corporais usando Visão Computacional

Esse trabalho propõe uma abordagem de extração de medidas corporais utilizando visão computacional, a qual pode ser utilizada em uma variedade de aplicações. É evidente os benefícios de algoritmos de extração de medidas corporais que sejam de fácil acesso e com respostas rápidas. Tal técnica pode viabilizar soluções pragmáticas para a obtenção precisa e conveniente de dados antropométricos, abrangendo uma variedade de áreas de aplicação, desde saúde até moda.

Nesse trabalho, é proposto uma abordagem em que a extração de medidas é realizada à partir de uma fotografia simples do usuário, acompanhada da medida de sua altura. A partir do envio de uma fotografia, a abordagem proposta realiza a segmentação da imagem, removendo o fundo original e substituindo-o por um fundo branco, deixando apenas o corpo da pessoa visível. Em seguida, a imagem modificada é enviada para o algoritmo de extração de medidas corporais, onde a imagem é processada através da aplicação de técnicas de detecção de bordas e pose, posteriormente extraíndo um conjunto de medidas pré-definidos.

A abordagem proposta foi desenvolvida para processar fotografias bem iluminadas em 2D, com posicionamento frontal do corpo, com proporção correta. A Figura 2 demonstra o padrão de fotografia esperado. Essas características garantem que as medidas corporais extraídas sejam as mais precisas possíveis. As medidas extraídas pela abordagem proposta nesse trabalho estão ilustradas na Figura 3, e as descrições das mesmas estão listadas na Tabela 1.

Figura 2 – Imagem referência

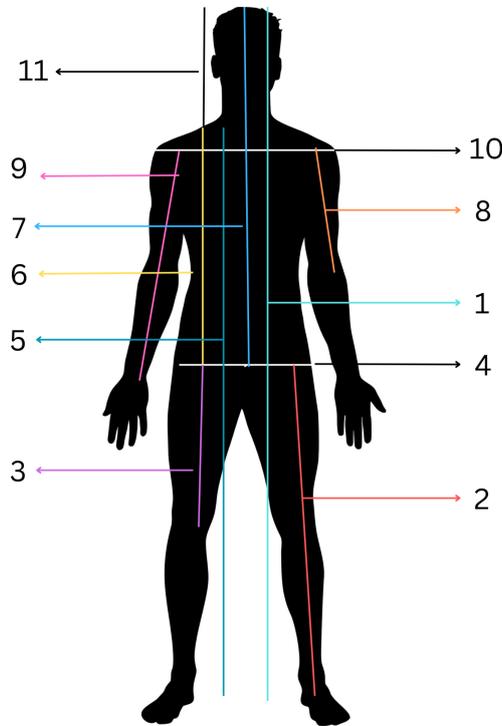


Fonte: O autor.

Como descrito, além da foto, é necessário que a altura também seja informada. Esta informação é crucial para estabelecer a relação entre os pixels e centímetros na imagem. Utilizamos a posição da altura do usuário, conforme indicada pela linha azul clara (1) na Figura 3. A escolha de utilizar a altura como referência se justifica pela ampla familiaridade das pessoas com sua própria estatura, bem como pelo fato de que pequenas variações nessa medida têm um impacto reduzido nos resultados finais, devido à sua escala maior

em relação às outras medidas.

Figura 3 – Medidas Extraídas



Fonte: O Autor.

Na abordagem desenvolvida, após receber a fotografia e a altura da pessoa, a imagem é segmentada para isolar o corpo, removendo o fundo original e substituindo-o por um fundo branco. Em seguida, a imagem processada é salva e passa pelo algoritmo desenvolvido que realiza a extração das medidas corporais. Primeiramente, a foto é processada utilizando OpenCV. A imagem é lida e convertida para escala de cinza para melhorar o desempenho. Converter uma imagem para escala de cinza diminui significativamente a quantidade de dados a serem processados, acelerando algoritmos que não dependem de informações de cor, como a detecção de bordas (Canny) e detecção de pose (MediaPipe). Em seguida, a detecção de bordas é realizada utilizando o OpenCV, por meio da função `cv2.Canny`. Após essa etapa, a biblioteca MediaPipe é empregada para detectar a pose. Com isso, obtêm-se as informações necessárias para extrair as medidas corporais pretendidas nesse estudo. A Figura 4 mostra o resultado após a aplicação de segmentação, detecção de bordas e pose sob a fotografia da Figura 2.

Para obter as medidas corporais é necessário identificar qual a parte do corpo deve ser medida, direcionando a técnica a ser aplicada. Por exemplo, considerando a extração da medida 7 da Tabela 1, a qual necessita tanto de pontos de pose como borda para ser extraída, conforme passos abaixo:

1. Obtém-se os *landmarks* do quadril esquerdo, quadril direito e nariz. Os *landmarks*

Tabela 1 – Medidas corporais extraídas

Nº	Medida (comprimento)	Descrição
1	Altura	Distância do topo da cabeça até o final dos pés
2	Comprimento da Perna	Distância do quadril até o pé
3	Comprimento do Joelho	Distância do quadril até o joelho
4	Largura do Quadril	Distância de um quadril até outro
5	Perna + Tronco	Distância do pé até o fim do ombro
6	Tronco	Distância do quadril até o fim do ombro
7	Tronco + Cabeça	Distância do quadril até o topo da cabeça
8	Manga	Distância do fim do ombro até o cotovelo
9	Comprimento do Braço	Distância do fim do ombro até o pulso
10	Largura dos Ombro	Distância entre os ombros
11	Pescoço até Cabeça	Distância do início do pescoço (fim do tronco) até o topo da cabeça

Fonte: O autor.

Figura 4 – Imagem segmentada, com detecção de bordas e pose.



Fonte: O autor.

são pontos de referências obtidos através da aplicação da detecção de pose, como demonstrado na Figura 1, correspondendo as *landmarks* 23, 24 e 0, respectivamente.

2. Calcula-se o ponto médio do quadril (a média das coordenadas x e y dos *landmarks* do quadril esquerdo e direito). Basicamente, identifica-se a coordenada do quadril direito e do quadril esquerdo, dividindo as mesmas por 2, encontrando assim o centro do quadril. Isso possibilita extrair uma linha reta do quadril até o nariz (primeiro

segmento da medida a ser extraída).

3. Converte-se as coordenadas do ponto médio do quadril e do nariz da imagem em pixels. Os *landmarks* estão representados como coordenadas normalizadas, ou seja, valores entre 0 e 1, onde (0, 0) representa o canto superior esquerdo da imagem e (1, 1) representa o canto inferior direito. Portanto, antes de serem normalizadas em pixels, as coordenadas são obtidas como coordenadas normalizadas, e então são multiplicadas pelas dimensões da imagem (largura e altura) para serem convertidas em coordenadas de pixel na imagem original. Após, para realizar os cálculos de medidas, essas coordenadas são transformadas em posições de pixels.
4. Calcula-se a distância vertical entre o ponto médio do quadril e o nariz em pixels. Essa medida corresponde o primeiro segmento da medida (7) a ser extraída.
5. Calcula-se a distância vertical do nariz até a borda mais distante acima do *landmark* (representando a borda superior da cabeça), obtendo-se assim o segmento final para extração da medida. Note que não há nenhum *landmark* no topo da cabeça, dessa forma existe a necessidade de combinar medidas entre *landmarks* (ou linhas estabelecidas por eles) e bordas. Bordas podem ser facilmente verificadas na imagem processada através da biblioteca numpy, função np.zeros, onde a matriz formada pela detecção de bordas é utilizada como parâmetro, e a implementação encontra o elemento borda mais distante ao *landmark* do nariz, indicado pelo topo da cabeça.
6. Com essa distância obtida, tem-se agora a o valor em píxeis do comprimento quadril até nariz e nariz até topo da cabeça. O resultado da distância em centímetros é então calculado utilizando a distância entre esses pontos extremos. Para isso, utiliza-se a função foundPixels, que realiza o cálculo de quantos pixels/cm a imagem possui, através da altura fornecida pelo usuário e a altura em píxeis extraída a partir do método proposta, ou seja, medida 1 da Figura 3. O cálculo de píxeis por centímetro é realizado da seguinte forma:

$$Pixel/cm = \frac{Altura\ em\ cm}{Altura\ em\ pixels} \quad (4)$$

Com a proporção de píxeis por cm, as distâncias obtidas em pixels podem ser calculadas.

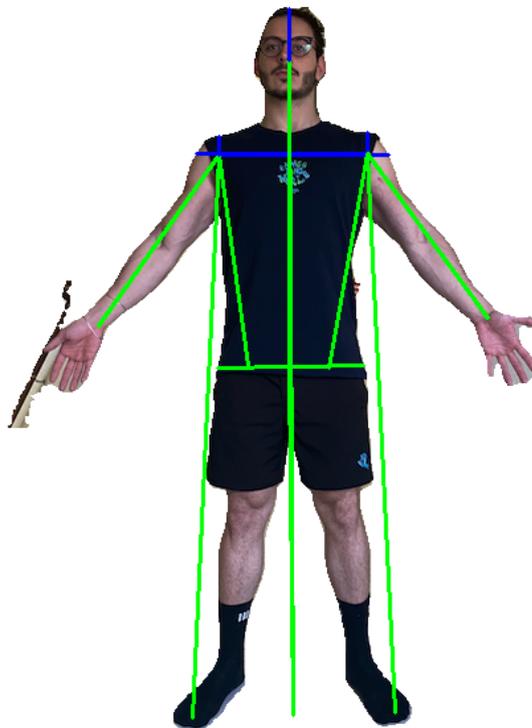
7. Com as distâncias obtidas, tem-se o valor em pixels do comprimento do quadril até o nariz e do nariz até o topo da cabeça. Para converter essa distância em centímetros, multiplica-se o resultado da distancia obtido em pixel pelo resultado retornado pela função foundPixels.
8. Finalmente, retorna-se a soma das duas distâncias calculadas anteriormente, que representa a distância total entre o quadril e a cabeça em centímetros. Sendo esse o resultado final da medida extraída.

Vale ressaltar que para cada medida de interesse extraída é realizado uma abordagem diferente, entretanto a extração da medida (7) faz uso de todas as técnicas necessárias. Por exemplo, para calcular a medida de quadril, medida (4) da Tabela 1, são utilizados os *landmarks* do quadril, esquerdo e direito, procurando-se a borda mais próxima na horizontal esquerda e horizontal direita, respectivamente.

Algumas medidas dependem de outras previamente já calculadas, por exemplo, a medida (11) da Tabela 1, que é calculada pela diferença de 2 outras medidas. Além disso, também é aplicada uma validação da altura. Por exemplo, para a extração da medida (11), o resultado da medida do quadril até a cabeça é confrontado com a medida do quadril tronco, e a diferença entre essas duas medidas é o resultado da medida pescoço até cabeça. Também, para a validação da altura, os resultados das medidas do quadril até a cabeça e comprimento da perna são somados. A soma dessas medidas necessariamente deve ser igual a fornecida pelo o usuário.

A imagem da Figura 5 mostra as linhas das medidas extraídas do usuário após a aplicação do algoritmo. Essas linhas representam as medidas de ponto a ponto, servindo como referência para verificar se as medidas foram extraídas das posições corretas.

Figura 5 – Linhas das Medidas Extraídas



Fonte: O Autor.

Ao final do processo de extração, obtêm-se as medidas corporais indicadas na Tabela 1. A abordagem proposta se destaca pela simplicidade de *inputs*, requerendo apenas uma fotografia e medida de referência (altura), e pode ser incorporada em inúmeras aplicações, sem necessidade de grande recurso computacional, ou mesma transformada em serviços de extração de medidas, como descreveremos posteriormente nesse documento. Em todos essas instâncias, a abordagem se mostra promissora na coleta de dados antropométricos, de maneira prática e precisa. Também se destaca pela eficiência e acessibilidade, características que serão evidenciadas nos resultados apresentados posteriormente.

3.1 Implementação

Para implementar o algoritmo de extração de medidas corporais, foram utilizadas três bibliotecas principais: OpenCV, MediaPipe e NumPy.

A biblioteca OpenCV desempenha um papel fundamental no processamento da imagem. Ela é responsável por carregar a imagem em um formato compatível para ser processada pela biblioteca NumPy, como também proporciona o algoritmo de detecção de bordas (algoritmo Canny) utilizado, e assim permite manipular a imagem como matrizes numéricas, facilitando as operações de processamento. Além disso, a OpenCV é empregada na padronização da imagem para aplicar o modelo de pose utilizado pelo MediaPipe. Adicionalmente, são aplicados métodos como o `cv2.canny` para detecção de bordas na imagem, essenciais para a identificação precisa das características corporais, como descrito na seção anterior. A utilização do algoritmo *Canny* simplifica significativamente o processo de detecção de bordas, fornecendo uma implementação robusta e eficiente que pode ser integrada facilmente ao fluxo de trabalho do projeto.

O NumPy é utilizado para realizar operações matemáticas, especialmente de distância entre um ponto até a borda. Ao aplicar o modelo de pose, o MediaPipe fornece *landmarks* que representam o esqueleto da pessoa na imagem. Com um total de 33 pontos, cada um com sua posição indexada, é possível obter as coordenadas normalizadas de cada landmark. Utilizando essas coordenadas, o NumPy viabiliza operações matemáticas entre landmarks, permitindo calcular distâncias e, caso necessário, estimar medidas ausentes. Por exemplo, ao calcular o comprimento do quadril, onde os landmarks não cobrem toda a região, é possível determinar as bordas mais próximas na horizontal para obter a medida correta. Também é relevante destacar outra funcionalidade oferecida pela MediaPipe: a segmentação de imagem. Antes que a imagem seja submetida ao algoritmo de extração de medidas, ela passa por um processo de segmentação. Esse processo resulta em uma imagem com o corpo da pessoa segmentado, com um fundo branco.

3.2 Abstração de Serviço

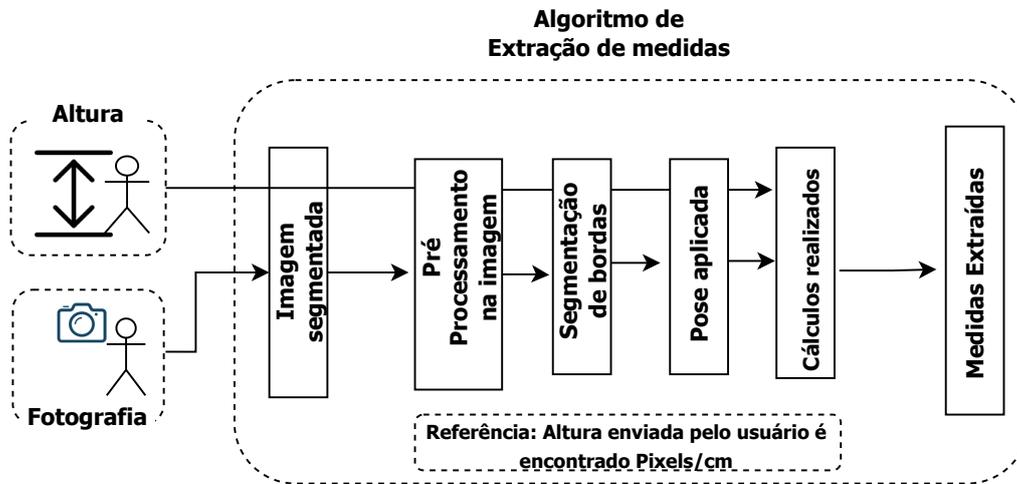
Para viabilizar uma diversidade de usos da abordagem desenvolvida, enfatizando sua abrangência, bem como avaliar a abordagem desenvolvida tanto da perspectiva geral, como também da perspectiva de aplicações, ela foi transformada em um serviço. Dessa forma, para a utilização da abordagem de extração de medidas corporais desenvolvida, basta que a mesma seja configurada como uma API do lado da aplicação. O diagrama da Figura 6 ilustra o funcionamento da abordagem proposta.

Com a abstração de serviço, a abordagem pode ser integrada, por exemplo, em uma aplicação web. Para demonstrar sua funcionalidade, foi criado uma página web local (localhost) utilizando o Framework Django¹³ e a linguagem de programação Python¹⁴. Na página, após fazer login, o usuário tem acesso a opção “extração de medidas corporais”. Ao clicar nessa opção, o usuário é redirecionado a uma página que solicita a altura e uma fotografia corporal, com algumas instruções para garantir os melhores resultados possíveis. Após fornecer esses dados, eles são enviados para o serviço (abordagem desenvolvida de extração de medidas corporais), o qual retornará as medidas corporais extraídas e elas são apresentadas ao usuário.

¹³ <https://www.djangoproject.com>

¹⁴ <https://www.python.org>

Figura 6 – Diagrama Aplicação do Algoritmo de medidas.



Fonte: O Autor.

As medidas extraídas podem ser utilizadas em diversos contextos. Além da aplicação simples para extração de medidas corporais, também realizou-se a implementação inicial de uma aplicação na área de vestuário, focada na sugestão do vestuário ideal para um usuário, usando como referência configurações de tamanhos informado no lado da aplicação. Na próxima seção essa aplicação será apresentada em detalhes. Para a aplicação do vestuário basta selecionar opção “Vestuário ideal”. Ela funciona de maneira semelhante ao “extração de medidas corporais”. O usuário envia uma fotografia e fornece sua altura, além de ter a opção de escolher o modelagem da roupa desejada (justa, normal, larga). Após fornecer esses dados, eles são enviados para o serviço, que retorna uma página descrevendo o tamanho ideal de vestuário com base nas medidas corporais extraídas.

Como se pode observar, o serviço desenvolvido pode ser utilizado em várias outras aplicações além de vestuário. Por exemplo, poderia ser utilizado em aplicações para analisar o desenvolvimento de medidas corporais de uma pessoa, seja no processo de emagrecimento, ganho de massa ou até mesmo para analisar o quanto uma criança vai crescendo ao longo do tempo.

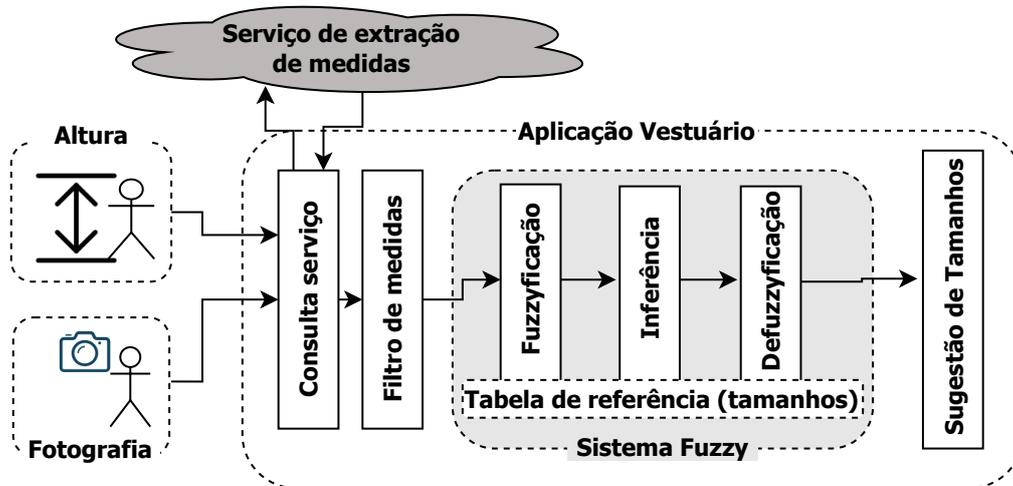
3.3 Aplicação em Vestuário

A indústria da moda desempenha um papel significativo no cenário mundial, especialmente com o crescimento das lojas virtuais. Segundo um estudo recente conduzido pela Octadesk em parceria com a Opinion Box (G1 Globo, 2022), 61% dos consumidores preferem comprar pela internet em comparação com lojas físicas. Além disso, a maioria (78%) realiza compras online uma ou mais vezes por mês (G1 Globo, 2022).

Com essa mudança no comportamento do consumidor, torna-se crucial ter conhecimento das medidas corporais ao fazer compras de vestuário e artigos esportivos. Isso se deve à impossibilidade de experimentar os produtos antes da compra. Nesse contexto, é importante ressaltar uma legislação específica: o Artigo 49 do Código de Defesa do Consumidor¹⁵ estabelece o direito do consumidor de desistir do contrato no prazo de 7

¹⁵ <<https://www.tjdft.jus.br/institucional/imprensa/campanhas-e-produtos/direito-facil/educacao-semanal/direito-ao-arrependimento-de-compra>>

Figura 7 – Diagrama Aplicação de Vestuário.



Fonte: O Autor.

dias após a assinatura ou recebimento do produto ou serviço, especialmente em casos de compras realizadas fora do estabelecimento comercial.

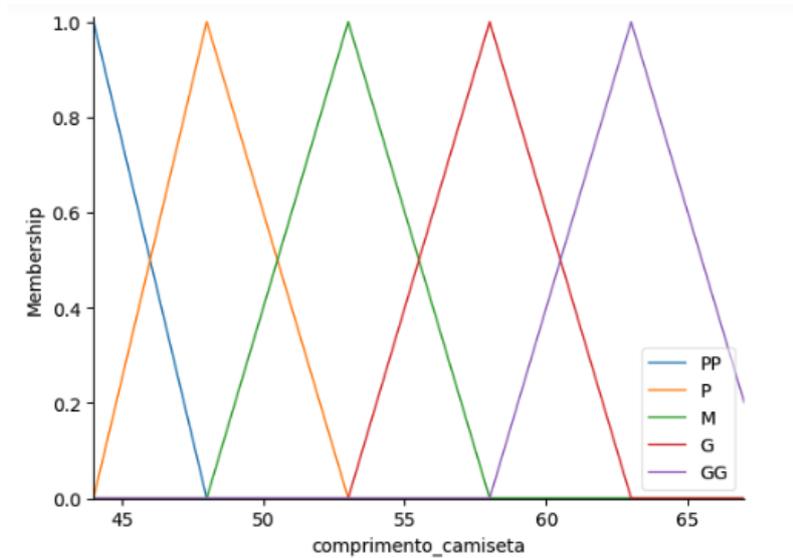
Nesse contexto, conhecer suas medidas corporais ao fazer compras online oferece vantagens tanto para os consumidores quanto para as empresas. Para o consumidor, isso significa maior precisão na escolha do tamanho adequado, resultando em menos frustrações e necessidade de devoluções. Para as lojas, isso pode significar uma redução significativa no número de devoluções, cortando despesas logísticas e melhorando a satisfação do cliente.

Sob estas circunstâncias, considerando que a aplicação do serviço de extração de medidas corporais desenvolvido é relevante no contexto de vestuário, uma aplicação de vestuário foi desenvolvida, utilizando a abordagem proposta. Na aplicação de vestuário desenvolvida, o usuário envia sua fotografia e altura, e a aplicação calcula as medidas corporais do usuário, comparando as mesmas com as tabelas de medidas de roupas oferecidas pela loja virtual correspondente à consulta, sugerindo o tamanho de roupa mais adequado.

Na Figura 7, pode-se observar o fluxo da aplicação. Primeiramente, como descrito, o usuário envia a fotografia e sua altura, o que serve como dados de entrada para a aplicação. Com essas informações, a aplicação consulta o serviço de extração de medidas corporais, que retorna as medidas extraídas, apresentadas previamente na Tabela 1. Após, a aplicação realiza um filtro sobre as medidas retornadas, utilizando apenas aquelas que são relevantes no contexto da aplicação. As medidas relevantes são então fornecidas a um sistemas fuzzy que realiza a inferência da melhor medida de vestuário para aquele usuário, baseado nas medidas de referência fornecidas pela marca/empresa na configuração da aplicação. A Figura 8 apresenta um exemplo do processo de modelagem dos conjuntos Fuzzy para tamanho de camiseta. Ao final do processo, a aplicação sugere o tamanho ideal de vestuário, permitindo ainda uma personalização de preferência, solicitando se o usuário tem preferência por roupas mais justas ou largas, adequando a sugestão a essa preferência, quando infere-se pertinência similares para classes próximas.

Por exemplo, quando o usuário interage com o sistema, enviando seus dados e selecionando uma camiseta específica, o sistema utiliza essas informações para inferir a

Figura 8 – Conjuntos Fuzzy para Tamanho de Camiseta.



Fonte: O Autor.

relevância para classes de tamanho como P e M, atribuindo pertinências de, por exemplo, 0.7 e 0.65 respectivamente. Se o usuário expressar preferência por roupas mais largas, o sistema pode sugerir o tamanho M, devido à pequena diferença entre as pertinências calculadas para essas classes pelo sistema de inferência. Caso contrário, o tamanho P seria recomendado.

Essa tecnologia pode ser integrada em aplicativos de lojas virtuais, permitindo uma experiência de compra mais personalizada e conveniente. Os consumidores podem escolher como preferem a modelagem do vestuário, e ter uma indicação personalizada da aplicação. Ao aplicar a abordagem de extração de medidas corporais em uma aplicação no ramo de vestuário, foi possível sugerir tamanhos de vestuários de maneira precisa, considerando ainda as preferências individuais de modelagem. Considera-se que isso proporciona uma experiência de compra mais satisfatória e personalizada.

4 Resultados e Discussão

Nesta seção, apresentamos os resultados obtidos durante a avaliação do algoritmo de extração de medidas corporais. Para realizar o teste de desempenho do algoritmo, foram obtidas manualmente 15 medidas corporais, conforme descrito na Tabela 1, de 15 pessoas voluntárias, utilizando suas fotografias como entrada para o algoritmo, em posição adequada, conforme exemplificado pela Figura 2. As fotografias e as alturas das pessoas foram fornecidas como inputs para o algoritmo, permitindo a comparação entre as medidas extraídas pelo algoritmo e as medidas reais dos participantes. Na Tabela 2, são apresentados os resultados dessa análise, indicando o intervalo de erro entre as medidas extraídas e reais, para cada medida considerada.

Destacam-se as seguintes observações:

- Para a extração da medida de comprimento da perna, a pequena discrepância observada pode ser atribuída à posição do quadril, uma vez que o algoritmo, ocasionalmente,

Tabela 2 – Relação de Erro entre as medidas extraídas e reais.

Medida	Erro em cm
Altura	0
Comprimento da Perna	1-3
Comprimento do Joelho	1-3
Largura do Quadril	1-3
Perna + Tronco	1-3
Tronco	1-3
Tronco + Cabeça	1-3
Manga	1-3
Comprimento do Braço	1-2
Largura dos Ombro	1-3
Pescoço até Cabeça	1-3

Fonte: O autor.

identifica o quadril um pouco mais acima ou abaixo da posição real. O mesmo problema influenciou a extração das medidas que necessitam dessa identificação, como tronco, tronco + cabeça, perna + tronco, etc. Contudo, essa variação resultou em uma diferença pouco significativa, indicando que o algoritmo possui uma boa precisão no cálculo dessas medidas.

- Para a extração da medida de comprimento do joelho, a variação entre 1 e 3 centímetros, pode ser atribuída, em parte, à posição do quadril (assim como ocorre para o comprimento da perna), bem como à identificação do ponto inicial do joelho. O algoritmo, ocasionalmente, localiza o joelho um pouco mais abaixo da posição real, especialmente para participantes que estavam vestindo calças.
- Para a extração da medida da manga, a variação de 1 à 3 centímetros está relacionada à identificação da posição do cotovelo, ocasionalmente, o algoritmo reconhece a posição do cotovelo antes da posição real, resultando em um comprimento menor do que o verdadeiro
- No algoritmo, medidas como o comprimento do pescoço até a cabeça são derivada de outras medidas. A precisão dessa medida depende da precisão das anteriores.

Os resultados indicam uma alta correlação entre as medidas extraídas pelo algoritmo e as medidas reais das pessoas, demonstrando a eficácia do algoritmo na tarefa de extração de medidas corporais. A proximidade das medidas calculadas pelo algoritmo em relação às medidas reais evidenciam a precisão e a confiabilidade do método proposto. Entretanto existem alguns pontos a serem discutidos. Durante o desenvolvimento deste trabalho, compreendemos o processo de extração das medidas corporais, especialmente a relação entre pixels e centímetros derivada da altura da imagem. É essencial destacar que essa relação exerce uma influência significativa nos resultados. Caso haja um erro considerável na altura da pessoa cuja extração de medidas será realizada, resultará em medidas imprecisas. No entanto, ao fornecer uma altura precisa, os resultados tendem a ser mais acurados.

Outro destaque relevante a comentar é qual a maneira de tirar a fotografia. Esta precisa ser tirada em posicionamento semelhante a representada pela Figura 2, com a câmera reta (sem estar inclinada). Caso a imagem esteja inclinada, resultara numa foto sem proporção. Quando a câmera estiver para cima do tronco e a foto ter sido tirado de cima

para baixo, o tronco terá valores maiores que os reais, e as pernas terão uma representação menor que a realidade. Quando a fotografia for tirada ao contrario, o resultado se inverte. Logo, é notável que a maneira com que o posicionamento da câmera influencia direto nos resultados.

Além disso, é importante abordar como o posicionamento do corpo pode influenciar na precisão da extração de medidas corporais. A posição correta do indivíduo, em pé e com os braços abertos, é crucial para essa aplicação. Caso não esteja posicionado conforme mostrado na Figura 2, podem ocorrer erros na aplicação da biblioteca de pose, levando à detecção de *landmarks* em posições inadequadas e, conseqüentemente, à obtenção de medidas imprecisas. Outro ponto também relacionado à fotografia é o ambiente e a roupa que a pessoa está utilizando, caso ela esteja em um lugar escuro, com pouca iluminação, há chances das medidas não serem extraídas com precisão, devido a qualidade da foto. Contudo, ao seguir corretamente os passos para obter as medidas corporais, os resultados das medidas extraídas são precisos.

Para uma análise mais minuciosa, foram calculadas as médias das medidas reais e das medidas extraídas, com base nos dados dos 15 participantes da avaliação. Essa análise foi realizada para obter uma noção do tamanho médio das medidas dos participantes e, assim, comparar o erro com essas medidas. Se o erro for de poucos centímetros e a medida em análise for grande, isso indica que o erro foi pequeno, e vice-versa. Para obter esses valores médios, calculou-se separadamente a média das medidas reais e a média das medidas extraídas. A Tabela 3 mostra os resultados médios das medidas:

Tabela 3 – Resultados médios das medidas obtidas em centímetros.

Medida	Média reais	Média extraídas
Altura	173.12	173.12
Comprimento da Perna	87.93	86.05
Comprimento do Joelho	37.26	37.71
Largura do Quadril	36.00	36.19
Perna + Tronco	143.60	141.49
Tronco	55.87	55.49
Tronco + Cabeça	85.23	87.23
Manga	24.47	22.74
Comprimento do Braço	49.40	49.09
Largura dos Ombros	42.20	43.22
Pescoço até Cabeça	29.67	31.72

Fonte: O autor.

A comparação entre as médias das medidas reais e as medidas extraídas revela que, em geral, os valores são bastante similares, com diferenças mínimas entre eles. Nesta seção, discutiremos outras métricas utilizadas para calcular a precisão do algoritmo. A Tabela 3 será utilizada como referência para as medidas. Por exemplo, um Erro Absoluto Médio de 2 cm no comprimento da perna seria considerado um erro pequeno. Dado que o comprimento médio de uma perna é aproximadamente 87 cm. Um erro absoluto médio de 2 cm indica que o sistema é capaz de calcular essa medida com precisão.

O erro médio (ME - *Mean Error*), conforme equação (1), foi uma das métricas utilizadas para ter uma dimensão como o modelo avalia as medidas corporais, se estes valores estão acima ou abaixo dos valores esperados, para cada medida. Um resultado negativo indica que a medida corporal detectada é maior que o valor esperado, enquanto

um resultado positivo indica que é menor.

Tabela 4 – Erro médio entre as medidas extraídas e reais.

Medida	Erro em cm
Altura	0
Comprimento da Perna	1.88
Comprimento do Joelho	-0.44
Largura do Quadril	-0.19
Perna + Tronco	2.10
Tronco	0.37
Tronco + Cabeça	-2.10
Manga	1.72
Comprimento do Braço	0.30
Largura dos Ombro	-1.02
Pescoço até Cabeça	-2.06

Fonte: O autor.

Como pode ser observado na Tabela 4, há uma variação entre -2.10 e 2.10. Em geral, os erros médios são relativamente pequenos. Esta análise sugere que tanto para valores positivos quanto negativos, as discrepâncias são geralmente mínimas. Outro ponto a ser observado é que o comprimento da perna tende a ser subestimado, enquanto o quadril e a cabeça apresentam valores superiores ao esperado. Esta diferença pode estar relacionada à posição do quadril, onde o erro em uma medida pode compensar o erro na outra.

Outra métrica utilizada para avaliar o desempenho do modelo é o Erro Absoluto Médio (MAE - *Mean Absolute Error*), conforme equação (2), é especialmente útil porque fornece uma ideia clara da magnitude média dos erros cometidos pelo modelo, independentemente da direção (subestimação ou superestimação) desses erros. Em contextos como previsão de medidas corporais, por exemplo, o MAE permite entender o quão próximas ou distantes as medidas extraídas do modelo estão dos valores reais, sem considerar se o modelo tende a errar para mais ou para menos.

Tabela 5 – Erro Absoluto Médio entre as medidas extraídas e reais.

Medida	Erro em cm
Altura	0
Comprimento da Perna	2.05
Comprimento do Joelho	1.66
Largura do Quadril	1.89
Perna + Tronco	2.2
Tronco	1.65
Tronco + Cabeça	2.27
Manga	1.75
Comprimento do Braço	0.98
Largura dos Ombro	1.97
Pescoço até Cabeça	2.30

Fonte: O autor.

Os resultados da Tabela 5 indicam que há uma variação de 0 a 2.30 cm nas medidas. Ao analisar com base o comprimento médio das medidas, apresentados na Tabela 3, observamos que o modelo geralmente é preciso na avaliação das medidas corporais,

apresentando pequenas variações. No entanto, é importante notar que para medidas menores, como o comprimento da manga e a distância do pescoço até a cabeça, o algoritmo mostra menos precisão em comparação às outras medidas. Por exemplo, a manga possui uma diferença de 1.75 cm, o que representa aproximadamente 7% de erro em relação à medida média (24.47 cm). Similarmente, a distância do pescoço até a cabeça apresenta cerca de 7.51% de erro em relação à sua média. No entanto, todas as outras medidas têm valores de erro abaixo desses percentuais, o que indica uma boa precisão do modelo na extração das medidas corporais. Um exemplo é a medida de “tronco + cabeça”, que apresenta a segunda maior discrepância em centímetros. Apesar de um erro absoluto de 2.27 cm, isso representa apenas 2.66% de diferença em relação à medida média. A Tabela 6 demonstra a porcentagem do MAE em relação a média das medidas.

Tabela 6 – MAE em relação a média das medidas reais.

Medida	Erro em porcentagem
Altura	0%
Comprimento da Perna	2.33%
Comprimento do Joelho	4.45%
Largura do Quadril	5.25%
Perna + Tronco	1.53%
Tronco	2.95%
Tronco + Cabeça	2.66%
Manga	7%
Comprimento do Braço	1.98%
Largura dos Ombro	4.66%
Pescoço até Cabeça	7.51%

Fonte: O autor.

A Raiz do Erro Quadrático Médio (RMSE - *Root Mean Square Error*), conforme equação (3), é uma medida estatística amplamente utilizado para avaliar a precisão que um modelo tem em relação aos valores reais. Ela foi utilizada pois fornece uma interpretação direta em unidades de medida, tornando-se útil em contextos onde a escala das previsões e dos valores reais é significativa, como na detecção de medidas corporais.

Tabela 7 – Raiz do Erro Quadrático Médio entre as medidas extraídas e reais.

Medida	Erro em cm
Altura	0
Comprimento da Perna	2.50
Comprimento do Joelho	1.93
Largura do Quadril	2.21
Perna + Tronco	2.90
Tronco	1.96
Tronco + Cabeça	2.83
Manga	2.02
Comprimento do Braço	1.09
Largura dos Ombro	2.42
Pescoço até Cabeça	2.71

Fonte: O autor.

Conforme observado os resultados demonstrados na Tabela 7, alguns valores apre-

sentam pequenas variações em relação ao MAE. No entanto, essas diferenças não são significativas, já que nenhuma medida varia mais do que 1 cm em relação ao MAE. A proximidade entre MAE e RMSE indica que o modelo possui uma precisão geral boa, destacando a capacidade do método de fornecer medidas corporais consistentes e confiáveis.

A sensibilidade do RMSE a grandes erros, em comparação à simplicidade interpretativa do MAE, proporciona uma visão complementar sobre o desempenho do modelo, demonstrando que ele evita grandes desvios e mantém uma precisão constante. Esse nível de precisão e consistência é crucial em cenários onde pequenas variações podem impactar significativamente o desempenho, como em medições precisas.

Para realizar uma análise mais detalhada da precisão do algoritmo, os dados foram divididos em dois grupos de altura: altura menor ou igual a 170 cm e altura maior que 170 cm. O grupo de menor altura consistiu em 6 pessoas, enquanto o outro grupo 9 pessoas. Foram calculadas a média das medidas corporais reais e extraídas de cada grupo, seguido pela aplicação do MAE como métrica para avaliar o impacto da altura no resultados. A Tabela 8 apresenta a relação entre as médias extraídas e as médias reais para as medidas consideradas. A Tabela ?? apresenta o MAE para cada uma das faixas de altura.

Tabela 8 – Tabela de Comparação das Medidas Corporais por Altura

Medida	Altura ≤ 170		Altura > 170	
	Méd. Real	Méd. Extraída	Méd. Real	Méd. Extraída
Altura	166.00	166.00	178.00	178.00
Perna	84.50	82.65	90.22	88.32
Joelho	36.50	36.25	37.78	38.68
Quadril	35.50	35.60	36.33	36.59
Perna+Tronco	136.17	134.71	148.56	146.01
Tronco	52.00	52.39	58.44	57.57
Quadril+Cabeça	81.33	83.36	87.67	89.81
Manga	23.67	21.36	25.00	23.66
Braço	48.17	47.87	50.22	49.91
Ombro	40.17	40.74	43.56	44.88
Pescoço+Cabeça	29.33	30.97	29.89	32.23

Fonte: O autor.

Conforme apresentado na Tabela 8, a média das medidas extraídas de ambas as faixas de alturas apresentaram resultados semelhantes às suas médias reais, o que demonstra a precisão dos resultados mesmo em faixas de alturas diferentes. Além disso, ao realizar a diferença das médias das medidas extraídas e a diferença das médias das medidas reais de ambas as faixas de alturas, é possível notar que os resultados se assemelham.

Na Tabela 9, são apresentados os valores de MAE para ambas as faixas de altura. Observa-se uma leve diferença entre os resultados, indicando que, conforme diminui a altura da pessoa, o MAE tende a ser menor, com exceção da medida Manga. Este resultado está de acordo com o esperado, pois medidas maiores geralmente apresentam maiores erros absolutos, devido à maior variação nos valores.

Tabela 9 – Tabela de MAE por Altura

Medida	MAE (≤ 170 cm)	MAE (> 170 cm)
Altura	0.00	0.00
Comprimento da Perna	1.92	2.15
Comprimento da Joelho	1.69	1.64
Largura do Quadril	1.41	2.22
Perna + Tronco	1.55	2.63
Tronco	1.90	1.48
Tronco + Cabeça	2.10	2.39
Manga	2.31	1.38
Comprimento Braço	1.22	0.82
Largura dos Ombro	1.70	2.16
Pescoço até Cabeça	1.64	2.75

Fonte: O autor.

5 Trabalhos Relacionados

Para selecionar os trabalhos relacionados, foram escolhidos aqueles que forneceram ideias centrais e contribuíram significativamente para diferentes etapas do método proposto para extração de medidas corporais automatizadas. O primeiro trabalho destacou a aplicação de medidas automáticas no contexto do vestuário. Os demais estudos foram fundamentais ao fornecerem *insights* sobre técnicas de captura de imagens, processamento prévio e métodos de análise de dados.

No artigo de [Zhao, He e Kemao \(2019\)](#), os autores descrevem uma abordagem de medição automatizada de medidas corporais utilizando *3D body scanner* e apresentam modelos de redes neurais para prever tamanhos corporais e as medições são usadas para personalizar roupas. Em resumo é explorado o uso de redes neurais e *scanners* corporais 3D para melhorar a previsão de tamanhos e a personalização de vestuários. É comparado diferentes tipos de dados de entrada (nuvens de pontos 3D, locais-chave do corpo e medições estimadas) e utiliza rede neural para prever medições corporais e rótulos de tamanho.

[Pantanowitz et al. \(2021\)](#) publicaram um artigo que realiza estimativas de medidas corporais através da análise de fotografias, utilizando CNN. A partir de imagens fotográficas 2D (semelhantes a [imagem2](#)), o trabalho proposto realiza a estimativa do IMC através de CNN. Nele foram coletados dados antropométricos e fotografias de 161 participantes de Camarões e Senegal. As imagens foram pré-processadas para gerar silhuetas simplificadas (uma segmentação de imagem, transformando o fundo em branco e o corpo da pessoa todo em preto) para facilitar o treinamento do modelo de aprendizado de máquina (reduzindo o custo computacional para o treinamento da rede neural). O trabalho conclui que o uso de CNN em imagens fotográficas pode ser uma abordagem viável e eficiente para estimar o IMC em grandes populações.

[Ruiz et al. \(2022\)](#), utiliza uma CNN chamada *Body Measurement network* (BMnet), a qual foi desenvolvida especificamente para estimar as medidas antropomórficas tridimensionais do corpo humano a partir de imagens de silhuetas em 2D. A BMnet é treinada com dados de indivíduos reais e aprimorada com o uso de um simulador adversarial de corpos, permitindo lidar com uma variedade de formas corporais. Vale destacar que a BMnet recebe como entrada duas imagens de silhuetas de uma pessoa (uma imagem frontal e a outra lateral), que são combinadas para formar uma única imagem de entrada. Além

disso, informações de altura e peso do indivíduo são incluídas como metadados. Após essa etapa de entrada de dados, é feita a extração das características, regressão de medidas e treinamento aprimorado, respectivamente, a qual tem resultados promissores na estimativa de medidas corporais em cenários reais.

No artigo de [Liu et al. \(2013\)](#), é abordada a medição das dimensões corporais de suínos. Para isso, os autores utilizaram uma câmera CCD SSC-E473P da SONY e uma lente H051-MP da CBC do Japão, com uma distância focal de 5 mm e uma resolução do chip CCD de 4,8 mm x 3,6 mm. Com esses equipamentos, conseguiram obter imagens com tamanho de 704 pixels x 576 pixels, o que permitiu calcular os pixels por cm. Em seguida, procederam com o processamento das imagens para remover o fundo e reduzir o ruído, convertendo-as para escala de cinza e aplicando filtros para melhorar o processamento. Posteriormente, realizaram o processamento dos dados para destacar os contornos dos suínos, removendo a cabeça e a cauda. Nesse processo, desenvolveram um método para identificar os pontos-chave, possibilitando a extração precisa das medidas corporais. Para validar a precisão do algoritmo, foram realizados experimentos utilizando imagens de suínos e medições manuais. Os resultados mostraram que o algoritmo teve uma precisão elevada na extração das medidas corporais, com um baixo erro relativo em relação às medições manuais.

Os trabalhos relacionados exploram métodos como *scanners* 3D, CNNs ou câmeras específicas para medição animal. Em contrapartida, o método proposto nesse documento adota uma abordagem acessível, permitindo que qualquer pessoa possa utilizá-lo com apenas uma foto e a altura correspondente. Além de ser transformado em um serviço, o método oferece aplicações práticas diversificadas, como determinação do tamanho ideal de vestuário e outras necessidades que envolvam medidas corporais precisas. Destaca-se sua eficiência e precisão, representando uma alternativa viável.

6 Conclusão

Nesse documento foi apresentado um método de extração de medidas corporais a partir de fotografia 2D de pessoas, usando sua altura como medida de referência. Para avaliar o método proposto, tanto de maneira geral como sua utilização em aplicações diversas, a mesma foi transformada em um serviço, demonstrando sua viabilidade em aplicações práticas, por exemplo, em uma aplicação para encontrar o tamanho ideal de vestuário.

Além da aplicação apresentada, a abordagem desenvolvida poderia ser utilizada nas áreas de: (i) *Fitness* e Esporte, onde a obtenção rápida e precisa das medidas corporais representa uma ferramenta poderosa nesse mundo. Ela pode ser aplicada em diversas áreas, desde o planejamento de treinos físicos até o monitoramento do progresso físico. No planejamento de treinos, conhecer as medidas corporais permite a adaptação do treinamento de forma adequada ao tipo de corpo específico, bem como identificar estratégias para otimizar a evolução física. No monitoramento físico, a capacidade de extrair medidas corporais de maneira eficiente possibilita um rastreamento preciso ao longo do tempo, utilizando comparações das medidas extraídas. Além disso vale destacar o tempo economizado em relação a necessidade de medições manuais; (ii) Saúde e Nutrição: A obtenção rápida e precisa das medidas corporais pode ser uma grande aliada nessas áreas, proporcionando benefícios que vão desde o diagnóstico de condições médicas até o suporte à nutrição. No diagnóstico médico, as medidas corporais, juntamente com uma avaliação médica, podem

indicar o estado de saúde do paciente. Como auxiliar na nutrição, onde o nutricionista pode monitorar se a dieta está sendo eficaz através do rastreamento das medidas corporais ao longo do tempo.

Através da avaliação realizada, observou-se que a técnica utilizada nesse trabalho é eficaz e acessível, possibilitando a obtenção de dados antropométricos de forma rápida e precisa. Como evidenciado na Tabela 6 verifica-se uma variação na porcentagem de erro em relação às medidas corporais reais, variando de 0% a 7.51%. Entretanto para esses resultados serem os melhores possíveis a fotografia enviada deve seguir o padrão ilustrado na Figura 2 e a altura informada corresponda à da pessoa na foto.

Conclui-se que, este trabalho se destaca pela simplicidade dos inputs necessários, pela precisão dos resultados e a rapidez ao obter suas medidas. Além de ser uma ferramenta promissora para aplicações que necessitam de medidas corporais confiáveis e rápidas, como na área da moda, saúde e esporte.

6.1 Trabalhos Futuros

Um dos grandes potenciais do trabalho desenvolvido está na sua utilização em diversas aplicações, como por exemplo de vestuário ideal, rastreamento de medidas para o esporte físico e análise de medidas para quadros médicos, entre outras.

Em primeiro plano, destaca-se a aplicação do algoritmo na experiência de compra online de vestuário. Muitas vezes, os consumidores enfrentam a dificuldade de determinar o tamanho ideal das roupas, considerando as variações entre os padrões de tamanho de cada loja e os diferentes cortes e formas das peças. Ao aplicar o algoritmo de extração de medidas, é possível obter as dimensões corporais do usuário e relacioná-las aos tamanhos de roupas disponíveis, fornecendo assim uma indicação mais precisa do tamanho adequado para o cliente.

Na área do esporte físico, com base nas medidas corporais extraídas, seria possível fazer um rastreio físico do usuário, para notar sua evolução no esporte, por exemplo. Sempre que o usuário utilizar a aplicação, ela poderia extrair as medidas e armazená-las, realizando uma comparação temporal, mostrando, por exemplo, o quanto uma pessoa ganhou de medidas corporais ao praticar musculação, ou até o quanto uma pessoa perdeu de medidas corporais ao começar a correr e fazer um processo de emagrecimento. Aplicações desse tipo seriam bastante versáteis, onde o usuário poderia, com apenas uma foto, ter um rastreamento da sua evolução.

Na área da saúde, medidas corporais podem ser utilizadas para analisar pacientes em recuperação físicas, pessoas com problemas na lombar, discos, rastrear o seu desenvolvimento clínico de uma maneira simples e não invasiva. Também, ao conhecer as medidas precisas do corpo de uma pessoa, é possível estabelecer uma relação com o percentual de gordura corporal e a massa magra. Essa análise pode oferecer informações cruciais sobre a saúde metabólica do indivíduo e o potencial risco de desenvolvimento de doenças associadas à obesidade.

O algoritmo de extração de medidas corporais demonstra claramente suas aplicações benéficas para a sociedade. As áreas discutidas são apenas uma amostra das muitas possibilidades de utilização dessa tecnologia. Portanto, ressalta-se a importância contínua do desenvolvimento e aprimoramento desta tecnologia, acreditando-se que ela possa ter um impacto positivo significativo em diversas áreas, nesse contexto muitos trabalhos futuros podem estar por vir.

Uma direção promissora é a integração de técnicas de *machine learning* para aprimorar a precisão dos resultados. O uso de modelos de aprendizado de máquina pode trazer melhorias significativas em várias etapas do processo, desde a proporção da imagem até a estimativa das medidas corporais. Modelos de *machine learning* podem ser treinados para detectar a inclinação da câmera com base em características visuais da imagem. Redes Neurais Convolucionais (do inglês, *Convolutional Neural Networks* - CNNs) podem ser utilizadas para identificar padrões de distorção e determinar o ângulo de inclinação. Uma vez identificado, pode-se aplicar uma correção geométrica para normalizar a imagem, ajustando a perspectiva para que as proporções fiquem mais próximas da realidade. Outra maneira de corrigir a proporção da imagem é utilizando a técnica de aprendizado supervisionado com dados rotulados. Essa abordagem envolve aumentar o conjunto de dados com fotografias capturadas de vários ângulos e indicar qual é o ângulo correto para a extração das medidas. O aprendizado supervisionado permitirá que o modelo aprenda as relações entre imagens distorcidas e imagens corrigidas, aplicando essas correções de forma automatizada em novos dados.

Incorporar *machine learning* supervisionado no cálculo das medidas pode aumentar a precisão dos resultados. Algoritmos de regressão, treinados com dados de medidas reais e suas correspondentes em pixels, podem aprender as relações não lineares entre as características da imagem e as medidas corporais reais. Isso pode compensar pequenas variações na posição dos pontos de referência e fornecer estimativas mais precisas das medidas corporais.

Uma aplicação adicional do *machine learning* é na realização de previsões. Ao aumentar o volume de dados de medidas corporais, pode alimentar uma rede neural com essas informações para prever as medidas de uma pessoa. Isso pode ser feito com base na altura informada pelo usuário ou até mesmo utilizando uma foto. No caso do uso de imagens, pode-se empregar uma combinação de CNN e redes neurais recorrentes (RNN) para obter previsões mais precisas das medidas corporais do usuário. Neste contexto, comparar os resultados das medidas corporais obtidas por este modelo com os deste trabalho seria uma fonte valiosa de informação para avaliar a eficácia e a precisão dos métodos propostos.

A integração de técnicas de *machine learning* ao algoritmo de extração de medidas corporais pode trazer avanços significativos na precisão e robustez dos resultados. Com a capacidade de aprender e se adaptar a partir de grandes conjuntos de dados, esses modelos podem superar limitações atuais e aprimorar significativamente o desempenho e a confiabilidade do algoritmo. Continuar investindo em pesquisas e desenvolvimentos nessa direção não apenas trará avanços tecnológicos, mas também proporcionará benefícios substanciais para a sociedade como um todo, devido a vasta gama de aplicações possíveis.

Referências

- AHERN, T. et al. Body mass index estimation and measurement by healthcare professionals. *Open Journal of Preventive Medicine*, v. 2, n. 03, p. 265–271, 2012. Citado na página [7].
- CHEN, C.; SURETTE, R.; SHAH, M. Automated monitoring for security camera networks: promise from computer vision labs. *Security Journal*, Springer, v. 34, p. 389–409, 2021. Citado na página [9].
- DANA, H. B.; CHRISTOPHER, M. B. Computer vision. *Prentice, Hall, Inc.# Englewood Cliffs, New Jersey*, v. 7632, p. 76–77, 1982. Citado na página [8].
- FERNANDES, F. G. et al. Realidade virtual e aumentada aplicada em reabilitação fisioterapêutica utilizando o sensor kinect e dispositivos móveis. *Universidade Federal de Uberaba-UNIUBE, Minas Gerais*, 2014. Citado na página [10].
- G1 Globo. *61% dos brasileiros compram mais pela internet do que em lojas físicas, aponta estudo*. 2022. <<https://g1.globo.com/economia/noticia/2022/12/14/61percent-dos-brasileiros-compram-mais-pela-internet-do-que-em-lojas-fisicas-aponta-estudo.html>>. Acessado em: 22 de abril de 2024. Citado na página [22].
- Google. *MediaPipe Pose*. 2023. <https://ai.google.dev/edge/mediapipe/solutions/vision/pose_landmarker>. Citado na página [13].
- HOST, K.; IVAŠIĆ-KOS, M. An overview of human action recognition in sports based on computer vision. *Heliyon*, Elsevier, 2022. Citado na página [9].
- KAEHLER, A.; BRADSKI, G. *Learning OpenCV 3: computer vision in C++ with the OpenCV library*. [S.l.]: "O'Reilly Media, Inc.", 2016. Citado na página [10].
- KHANAL, S. R. et al. A review on computer vision technology for physical exercise monitoring. *Algorithms*, MDPI, v. 15, n. 12, p. 444, 2022. Citado na página [10].
- LIU, T. et al. Extraction algorithms and applications of pig body size measurement points based on computer vision. *Transactions of the Chinese Society of Agricultural Engineering*, Editorial Office of Transactions of the Chinese Society of Agricultural . . . , v. 29, n. 2, p. 161–168, 2013. Citado na página [31].
- MINICHINO, J.; HOWSE, J. *Learning OpenCV 3 Computer Vision with Python*. [S.l.]: Packt Publishing Ltd, 2015. Citado na página [11].
- MOGILI, U. R.; DEEPAK, B. B. V. L. Review on application of drone systems in precision agriculture. *Procedia Computer Science*, v. 133, p. 502–509, 2018. ISSN 1877-0509. International Conference on Robotics and Smart Manufacturing (RoSMa2018). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050918310081>>. Citado na página [9].
- NAIK, B. T.; HASHMI, M. F.; BOKDE, N. D. A comprehensive review of computer vision in sports: Open issues, future trends and research directions. *Applied Sciences*, MDPI, v. 12, n. 9, p. 4429, 2022. Citado na página [9].

- PANTANOWITZ, A. et al. Estimation of body mass index from photographs using deep convolutional neural networks. *Informatics in Medicine Unlocked*, v. 26, p. 100727, 2021. Citado na página [30].
- PASSOS, W. L.; QUINTANILHA, I. M.; ARAUJO, G. M. Real-time deep-learning-based system for facial recognition. *Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT)*, v. 37, p. 895–899, 2018. Citado na página [10].
- ROBERTS, L. G. *Machine perception of three-dimensional solids*. Tese (Doutorado) — Massachusetts Institute of Technology, 1963. Citado na página [8].
- RUIZ, N. et al. Human body measurement estimation with adversarial augmentation. In: *IEEE. 2022 International Conference on 3D Vision (3DV)*. [S.l.], 2022. p. 219–230. Citado na página [30].
- SABA, T. Computer vision for microscopic skin cancer diagnosis using handcrafted and non-handcrafted features. *Microscopy Research and Technique*, Wiley Online Library, v. 84, n. 6, p. 1272–1283, 2021. Citado na página [8].
- SANTOS, D. A. et al. Reference values for body composition and anthropometric measurements in athletes. *PloS one*, Public Library of Science San Francisco, USA, v. 9, n. 5, p. e97846, 2014. Citado na página [7].
- SOUSA, P. H. A. Q. d. Interação com um personagem fisicamente simulado usando visão computacional e realidade aumentada. 2015. Citado na página [8].
- STANCIC, I.; SUPUK, T.; CECIC, M. Computer vision system for human anthropometric parameters estimation. *WSEAS Transactions on Systems*, World Scientific and Engineering Academy and Society (WSEAS) Stevens Point . . . , v. 8, n. 3, p. 430–439, 2009. Citado na página [8].
- SZELISKI, R. *Computer Vision: Algorithms and Applications*. Springer London, 2010. (Texts in Computer Science). ISBN 9781848829350. Disponível em: <<https://books.google.com.br/books?id=bXzAlkODwa8C>>. Citado na página [8].
- SZELISKI, R. *Computer Vision: Algorithms and Applications*. [S.l.]: Springer, 2022. Citado na página [10].
- TEK, F. B.; DEMPSTER, A. G.; KALE, I. Computer vision for microscopy diagnosis of malaria. *Malaria journal*, Springer, v. 8, p. 1–14, 2009. Citado na página [9].
- TSAI, C.-H.; HUANG, K.-N. Squat training assistance system based on mediapipe. Citado na página [12].
- WANG, J. et al. Ai coach: Deep human pose estimation and analysis for personalized athletic training assistance. In: *Proceedings of the 27th ACM international conference on multimedia*. [S.l.: s.n.], 2019. p. 374–382. Citado na página [9].
- ZADEH, L. Fuzzy sets. *Information and Control*, v. 8, n. 3, p. 338–353, 1965. ISSN 0019-9958. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001999586590241X>>. Citado na página [14].
- ZHAO, J.; HE, X.; KEMAO, Q. Automatic body measurement by neural networks. In: *Proceedings of the 2019 2nd International Conference on Robot Systems and Applications*. [S.l.: s.n.], 2019. p. 9–14. Citado na página [30].

ZUNKER, C. et al. Perceptions of running performance: the role of clothing fit. *The Sport Journal*, 2014. Citado na página [7].