



UNIVERSIDADE FEDERAL DO PARÁ

MÁRCIO GABRIEL DOS SANTOS DE ARAUJO

**Visão Computacional e IA para Medidas Corporais - Uma
Análise Comparativa entre MNASNet e
SnapMeasurementAI**

TUCURUÍ – PA

2026

MÁRCIO GABRIEL DOS SANTOS DE ARAUJO

**Visão Computacional e IA para Medidas Corporais - Uma Análise Comparativa
entre MNASNet e SnapMeasurementAI**

Trabalho final de graduação apresentado à banca
examinadora da Universidade Federal do Pará
como requisito na obtenção do título de bacharel
em Engenharia Elétrica.

Orientador: DANIEL DA CONCEIÇÃO PINHEIRO

TUCURUÍ – PA

2026

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a)
autor(a)

D722v dos Santos de Araújo, Márcio Gabriel.
Visão Computacional e IA para Medidas Corporais - Uma
Análise Comparativa entre MNASNet e SnapMeasurementAI
/ Márcio Gabriel dos Santos de Araújo. — 2026.
65 f. : il. color.

Orientador(a): Prof. Dr. Daniel da Conceição Pinheiro
Coorientador(a): Prof. Dr. Raphael Barros Teixeira
Trabalho de Curso (Graduação) - Universidade Federal
do Pará, Campus Universitário de Tucuruí, Faculdade de
Engenharia Elétrica, Tucuruí, 2026.

1. inteligência artificial. 2. visão computacional. 3.
medidas corporais. 4. estimativa antropométrica. 5.
recomendação de tamanhos. I. Título.

CDD 006.3



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUI
FACULDADE DE ENGENHARIA ELÉTRICA

FICHA DE AVALIAÇÃO DO TRABALHO DE CONCLUSÃO DE CURSO

Aluno	MÁRCIO GABRIEL DOS SANTOS DE ARAUJO
Título do TCC	Visão Computacional e IA para Medidas Corporais – Uma Análise Comparativa entre MNASNet e SnapMeasurementAI

ORIENTAÇÃO

Orientador:	Faculdade
Daniel da Conceição Pinheiro	FECOMP/UFPA
Co-orientador:	Faculdade/Instituição
Raphael Barros Teixeira	FEE/UFPA

BANCA EXAMINADORA

A. Presidente (Orientador)	Faculdade
Daniel da Conceição Pinheiro	FECOMP/UFPA
B. Membro	Interno
Raphael Barros Teixeira	FEE/UFPA
C. Membro	Externo
Erick Vinicius Damasceno da Silva	Engenheiro Egresso da UFPA

AVALIAÇÃO

Critérios	Pontuação Máxima	Banca Examinadora			Total	Média
Apresentação Escrita	1,0	0,8	0,7	0,9	2,4	0,8
Metodologia	1,0	0,8	0,8	0,9	2,5	0,83
Desenvolvimento	2,0	1,8	1,8	2,0	5,6	1,87
Conclusão	2,0	1,8	1,7	2,0	5,5	1,83
Relevância do trabalho	2,0	2,0	2,0	1,8	5,8	1,93
Apresentação Oral	2,0	2,0	2,0	1,8	5,8	1,93
Total de Pontos						9,2
Conceito						EXE

Tucuruí, 10/07/2026

Documento assinado digitalmente
gov.br DANIEL DA CONCEICAO PINHEIRO
Data: 10/07/2026 15:34:08-0300
Verifique em <https://validar.iti.gov.br>

Orientador

Documento assinado digitalmente
gov.br RAPHAEL BARROS TEIXEIRA
Data: 10/07/2026 19:24:34-0300
Verifique em <https://validar.iti.gov.br>

Co-orientador

Documento assinado digitalmente
gov.br ERICK VINICIUS DAMASCENO DA SILVA
Data: 10/07/2026 19:04:50-0300
Verifique em <https://validar.iti.gov.br>

Examinador Externo

Examinador (a)

MÁRCIO GABRIEL DOS SANTOS DE ARAUJO

Visão Computacional e IA para Medidas Corporais - Uma Análise Comparativa entre
MNASNet e SnapMeasurementAI

Trabalho final de graduação apresentado à banca
examinadora da Universidade Federal do Pará
como requisito na obtenção do título de bacharel
em Engenharia Elétrica.

DATA DA APROVAÇÃO

BANCA EXAMINADORA

Orientador (a):

Prof. Dr. Daniel da Conceição Pinheiro

Membro:

Prof. Dr. Raphael Barros Teixeira

Membro:

Eng. Erick Vinicius Damasceno da Silva

RESUMO

O presente trabalho investiga a aplicação de técnicas de inteligência artificial e visão computacional na estimativa das medidas corporais do tórax, cintura e quadril a partir de imagens, com foco em sua utilização em sistemas de recomendação de tamanhos para o comércio eletrônico de vestuário. O crescimento acelerado do e-commerce de moda tem evidenciado desafios relevantes relacionados à escolha inadequada de tamanhos, impactando diretamente a experiência do consumidor e os custos operacionais das empresas. Nesse contexto, foi realizada uma análise comparativa entre duas abordagens: o modelo MNASNet, treinado com dados reais, e a solução SnapMeasurementAI. A metodologia envolveu a utilização de datasets compostos por imagens frontais e laterais associadas a informações antropométricas, bem como a avaliação por meio da métrica erro absoluto médio (MAE) e da conversão das medidas estimadas em categorias de tamanho comerciais. Os resultados demonstraram diferenças significativas entre os modelos. O MNASNet apresentou MAE de 3,7 cm para o grupo feminino e 6,9 cm para o grupo masculino, indicando melhor desempenho para mulheres e evidenciando a presença de viés. Na avaliação prática utilizando tabelas comerciais, o modelo atingiu 50% de acerto para classificação de tamanhos baseada em tórax e cintura da marca Insider, porém apenas 17% de acerto para medidas de quadril, associadas a erros médios de até 10,1 cm. Em contrapartida, o SnapMeasurementAI apresentou desempenho mais equilibrado entre os gêneros e menor variabilidade global, demonstrando maior robustez e capacidade de generalização. Os resultados também evidenciaram que a conversão das medidas estimadas em tamanhos de vestuário constitui um dos principais desafios práticos da aplicação, uma vez que diferenças de poucos centímetros podem alterar significativamente a classificação final de tamanho. Conclui-se que, embora ambas as abordagens apresentem potencial para sistemas de recomendação de vestuário, ainda existem limitações relacionadas à precisão, robustez e generalização, reforçando a necessidade de aprimoramento dos modelos e de estratégias mais eficazes para conversão de medidas em categorias comerciais.

Palavras-chave: inteligência artificial; visão computacional; medidas corporais; estimativa antropométrica; recomendação de tamanhos.

ABSTRACT

This study investigates the application of artificial intelligence and computer vision techniques for estimating human body measurements from images, focusing on their use in clothing size recommendation systems for e-commerce. The rapid growth of online fashion retail has highlighted significant challenges related to incorrect size selection, which directly impacts customer experience and operational costs. In this context, a comparative analysis was conducted between two approaches: MNASNet, a model trained on real-world data, and SnapMeasurementAI, a commercially available solution. The methodology involved the use of datasets containing frontal and lateral images combined with anthropometric information, as well as model evaluation using the Mean Absolute Error (MAE) metric and clothing size classification based on commercial sizing charts. The results revealed significant differences between the evaluated approaches. MNASNet achieved an MAE of 3.7 cm for female subjects and 6.9 cm for male subjects, indicating better performance for women and evidencing the presence of bias in the model. In practical evaluations based on commercial sizing charts, the model achieved a 50% accuracy rate for chest and waist size classification using Insider® clothing tables, but only 17% accuracy for hip measurements, with average errors reaching 10.1 cm. In contrast, SnapMeasurementAI demonstrated more balanced performance across genders and lower overall variability, indicating greater robustness and generalization capability. The results also showed that converting estimated body measurements into clothing size categories remains one of the main practical challenges, since variations of only a few centimeters can lead to different size recommendations. It is concluded that, although both approaches demonstrate potential for size recommendation systems, limitations related to accuracy, robustness, and generalization still affect their practical applicability. The findings highlight the need for further improvements in data balancing, bias reduction, and the development of more reliable strategies for converting body measurements into commercial clothing sizes.

Keywords: artificial intelligence; computer vision; body measurements; anthropometric estimation; size recommendation systems.

LISTA DE ILUSTRAÇÕES

Figura 1 - Relação entre inteligência artificial, aprendizado de máquina, aprendizado profundo e visão computacional.....	12
Figura 2 - Representação de uma imagem digital como matriz de pixels.	13
Figura 3 - Comparação entre abordagens paramétricas e não paramétricas para estimativa de medidas corporais.....	15
Figura 4 - Exemplo de ambiguidade de escala em imagens bidimensionais capturadas a diferentes distâncias.....	21
Figura 5 - Pipeline de implementação da solução MNASNet na estimativa de medidas corporais.....	26
Figura 6 - Processo de segmentação da imagem original para obtenção da silhueta corporal.	29
Figura 7 - Silhuetas do dataset desenvolvido, na sequência, 3 homens e 3 mulheres.	30
Figura 8 - Distribuição percentual dos dados nas estratégias MNASNet V1 e MNASNet V2.....	31
Figura 9 - Silhueta homem 3, pior estimativa do modelo SnapMeasurementAI.	37
Figura 10 - Silhueta homem 2, pior estimativa do modelo MNASNet.....	37
Figura 9 – MAE (Mean Absolute Error) dataset desenvolvido V2, MNASNet V2	40
Figura 10 - MAE por indivíduo durante treinamento.....	41
Figura 11 - MAE por gênero com desvio padrão modelo MNASNet	42
Figura 12 - MAE por medida corporal durante treinamento.	43
Figura 13 - MAE por gênero com desvio padrão modelo SnapMeasurementAI.....	49
Figura 16 – Boxplot do MAE por gênero para MNASNet	55
Figura 17 – Boxplot do MAE por gênero para SnapMeasurementAI.....	56
Figura 18 - MAE por indivíduo para cada modelo	57

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Objetivo geral.....	10
1.2	Objetivos específicos	10
2	REFERENCIAL TEÓRICO E TRABALHOS RELACIONADOS	12
2.1	INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL	12
2.1.1	Definição de IA e visão computacional.	12
2.1.2	Principais técnicas e algoritmos utilizados na análise de imagens corporais.	14
2.1.3	Redes Neurais Convolucionais.....	16
2.1.4	Evolução das aplicações em e-commerce de moda.....	17
2.2	ESTIMATIVA DE MEDIDAS CORPORAIS POR IA	18
2.2.1	Métodos tradicionais versus métodos baseados em IA.....	18
2.2.2	Importância da precisão métrica e dos dados de entrada (imagens, altura, peso).	18
2.3	DESAFIOS E LIMITAÇÕES.....	19
2.3.1	Variabilidade dos corpos humanos e representatividade dos dados.	19
2.3.2	Ambiguidade de escala e limitações técnicas dos modelos.	20
2.3.3	Barreiras éticas e de privacidade no uso de imagens corporais.....	22
2.4	DESCRIÇÃO DAS ARQUITETURAS	23
2.4.1	Detalhamento da MNASNet: estrutura, funcionamento e vantagens.....	23
2.4.2	Características do SnapMeasurementAI: abordagem de mercado e diferenciais.	23
2.5	MÉTRICAS DE AVALIAÇÃO.....	24
3	METODOLOGIA	25
3.1	ESTRUTURA GERAL DO PIPELINE DE PROCESSAMENTO	26
3.2	CONJUNTO DE DADOS	28
3.2.1	Apresentação do dataset BodyM e outros utilizados.	28
3.2.2	Processamento das imagens (segmentação, vistas frontal e lateral).	29

3.2.3	Critérios de seleção, preparação e balanceamento dos dados.	30
3.3	ESTRATÉGIAS DE TREINAMENTO	31
3.3.1	Divisão do dataset	31
3.3.2	Quantidade de treinamento	32
3.4	IMPLEMENTAÇÃO DAS SOLUÇÕES.....	32
3.4.1	Detalhes da implementação da MNASNet.....	32
3.4.2	Configuração e uso do SnapMeasurementAI.	34
3.5	MÉTODO DE AVALIAÇÃO QUANTITATIVA	35
4	RESULTADOS E DISCUSSÕES	36
4.1	AVALIAÇÃO QUALITATIVA.....	36
4.2	AVALIAÇÃO QUANTITATIVA.....	39
4.2.1	Resultados obtidos nos primeiros treinamentos	39
4.2.2	Resultados obtidos do dataset desenvolvido V2 e MNasNet V2	40
4.2.3	Resultados obtidos do SnapMeasurementAI	49
4.3	ANÁLISE COMPARATIVA	55
4.3.1	Boxplot do Erro (MAE).....	55
4.3.2	Pontos fortes e fracos de cada abordagem.	57
4.3.3	Diferenças nos resultados e implicações práticas para o e-commerce.	58
4.3.4	Barreiras técnicas e científicas ainda presentes.....	59
5	CONCLUSÃO E TRABALHOS FUTUROS	60
	REFERÊNCIAS.....	63

1 INTRODUÇÃO

A crescente digitalização das relações de consumo tem impulsionado significativamente o desenvolvimento do comércio eletrônico, especialmente no setor de moda, um dos segmentos mais relevantes do mercado global. Nos últimos anos, o e-commerce de vestuário apresentou expansão acelerada, favorecida pela ampliação do acesso à internet, pela consolidação de plataformas digitais e pela mudança no comportamento dos consumidores, que passaram a valorizar cada vez mais conveniência, agilidade e personalização nas compras. Esse cenário evidencia a importância econômica do setor e reforça a necessidade de soluções tecnológicas capazes de aprimorar a experiência de compra no ambiente online.

Apesar desse crescimento expressivo, o setor ainda enfrenta desafios estruturais que impactam diretamente a experiência do usuário e os custos operacionais das empresas. Entre esses desafios, destaca-se a escolha inadequada de tamanho nas compras online de roupas, frequentemente associada às devoluções de produtos. Esse problema afeta consumidores e varejistas, pois gera insatisfação, custos logísticos adicionais com transporte reverso e perdas financeiras decorrentes de trocas ou reembolsos. Em muitos casos, a dificuldade decorre da impossibilidade de experimentar fisicamente as peças antes da compra e da limitação do usuário em estimar corretamente suas próprias medidas corporais.

Nesse contexto, embora existam soluções voltadas à recomendação de tamanhos no ambiente digital, muitas ainda apresentam limitações relacionadas à precisão das estimativas, à generalização para diferentes perfis corporais e à dependência de informações inseridas manualmente pelo usuário. Métodos tradicionais, baseados em tabelas padronizadas ou modelos simplificados, tendem a não representar adequadamente a variabilidade antropométrica humana, o que pode resultar em recomendações pouco assertivas.

Diante desse cenário, a aplicação de inteligência artificial (IA) e visão computacional surge como uma abordagem promissora para automatizar a estimativa de medidas corporais a partir de imagens. O uso de redes neurais profundas possibilita a extração de características visuais relevantes do corpo humano e a realização de estimativas diretamente a partir de dados visuais, reduzindo a dependência de medições físicas manuais. Além disso, a integração de informações

complementares, como altura e peso, pode contribuir para reduzir ambiguidades de escala e melhorar a precisão das previsões.

Entretanto, apesar dos avanços recentes, a estimativa de medidas corporais por meio de IA ainda apresenta desafios importantes, como a escassez de bases de dados reais e representativas, a diversidade de biotipos, a presença de vieses nos modelos e a dificuldade de alcançar precisão métrica compatível com aplicações práticas. Essas limitações tornam necessária a realização de estudos comparativos que avaliem diferentes abordagens, identifique seus pontos fortes e fracos e discutam sua aplicabilidade em cenários reais de recomendação de tamanhos.

Assim, este trabalho propõe investigar a aplicação de técnicas de inteligência artificial e visão computacional na estimativa de medidas corporais, por meio de uma análise comparativa entre a arquitetura MNASNet, treinada com dados reais, e a solução comercial SnapMeasurementAI. A escolha dessas abordagens justifica-se por representarem perspectivas distintas: de um lado, um modelo de caráter acadêmico e customizável; de outro, uma solução aplicada ao mercado. Essa comparação permite avaliar não apenas a precisão numérica das estimativas, mas também sua robustez, a ocorrência de possíveis vieses e sua viabilidade prática em sistemas de recomendação de tamanhos para o e-commerce de moda.

Com base nesse contexto, o presente trabalho é orientado pelos objetivos apresentados a seguir, os quais delimitam o foco da pesquisa e organizam as etapas necessárias para avaliar o desempenho das abordagens analisadas.

1.1 Objetivo geral

Analisar comparativamente o desempenho da arquitetura MNASNet e da solução SnapMeasurementAI na estimativa de medidas corporais a partir de imagens, considerando precisão, robustez, possíveis vieses e aplicabilidade em sistemas de recomendação de tamanhos para o comércio eletrônico de vestuário.

1.2 Objetivos específicos

- Contextualizar a aplicação de inteligência artificial e visão computacional na estimativa de medidas corporais e na recomendação de tamanhos no e-commerce de moda.

- Analisar comparativamente as abordagens MNASNet e SnapMeasurementAI na estimativa antropométrica por imagens, considerando suas características, limitações, desempenho, robustez, variabilidade e possíveis vieses entre os grupos masculino e feminino, bem como sua aplicabilidade em sistemas de recomendação de tamanhos.
- Preparar e utilizar conjuntos de dados compostos por imagens corporais, silhuetas e medidas antropométricas reais para avaliação dos modelos analisados.
- Avaliar quantitativamente o desempenho dos modelos por meio do erro absoluto médio (MAE), considerando regiões corporais relevantes para o vestuário, como tórax, cintura e quadril.
- Analisar a conversão das medidas estimadas em categorias comerciais de tamanho, utilizando tabelas de vestuário de marcas como Insider e Renner.

2 REFERENCIAL TEÓRICO E TRABALHOS RELACIONADOS


Neste capítulo, serão abordados os conceitos teóricos fundamentais relacionados a este projeto, além da apresentação de trabalhos correlatos que contribuem para a compreensão do tema.

2.1 INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL

2.1.1 Definição de IA e visão computacional.

A inteligência artificial (IA) consiste em um campo interdisciplinar da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que, tradicionalmente, requerem inteligência humana, como reconhecimento de padrões, tomada de decisão e aprendizado a partir de dados (RUIZ et al., 2022). Inserida nesse contexto, a visão computacional surge como uma subárea responsável pela interpretação e compreensão de informações visuais por meio de imagens e vídeos, permitindo que sistemas automatizados extraiam características relevantes do ambiente (CHEN et al., 2018).

Figura 1 - Relação entre inteligência artificial, aprendizado de máquina, aprendizado profundo e visão computacional.




Fonte: imagem gerada por inteligência artificial (DALL·E 3) a partir de descrição do autor, para fins ilustrativos (OpenAI, 2026).

A Figura 1 apresenta a relação hierárquica entre os principais conceitos envolvidos neste trabalho. A inteligência artificial constitui o campo mais amplo,

voltado ao desenvolvimento de sistemas capazes de executar tarefas associadas à inteligência humana. Dentro desse campo, o aprendizado de máquina permite que modelos aprendam padrões a partir de dados, enquanto o aprendizado profundo utiliza redes neurais com múltiplas camadas para extrair representações mais complexas. A visão computacional, por sua vez, aplica essas técnicas à interpretação de imagens e vídeos, sendo fundamental para a estimativa de medidas corporais a partir de informações visuais.

Do ponto de vista computacional, imagens são representadas como estruturas matriciais compostas por elementos denominados pixels, nos quais cada elemento armazena valores numéricos correspondentes à intensidade ou à cor. Esse processo decorre da discretização de um fenômeno contínuo do mundo real, permitindo sua representação em formato digital manipulável por algoritmos (SCURI, 2002). Essa transformação é fundamental, pois possibilita que operações matemáticas sejam aplicadas às imagens, viabilizando sua análise, modificação e interpretação por sistemas computacionais.

Figura 2 - Representação de uma imagem digital como matriz de pixels.



Fonte: imagem gerada por inteligência artificial (DALL·E 3) a partir de descrição do autor, para fins ilustrativos (OpenAI, 2026).

A Figura 2 ilustra o processo pelo qual uma imagem do mundo real é convertida em uma matriz de pixels, na qual cada elemento armazena valores numéricos associados à intensidade luminosa ou à cor. Essa representação permite que a imagem seja processada computacionalmente por meio de operações matemáticas, filtros e algoritmos de aprendizado de máquina. No contexto deste trabalho, essa

transformação é essencial, pois possibilita que as redes neurais interpretem características visuais do corpo humano, como contornos, proporções e regiões de interesse, convertendo informações visuais em estimativas numéricas de medidas corporais.

Com o avanço das técnicas de aprendizado de máquina e, principalmente, das redes neurais profundas, a visão computacional alcançou níveis elevados de desempenho em tarefas como detecção de objetos, segmentação semântica e reconstrução tridimensional (LOPER et al., 2015). Esses avanços têm ampliado significativamente o escopo de aplicações da área, incluindo reconhecimento facial, direção autônoma e análise biométrica, além de aplicações voltadas ao comércio eletrônico, como estimativa de medidas corporais e recomendação de vestuário.

Dessa forma, a integração entre IA e visão computacional permite não apenas automatizar processos complexos de análise visual, mas também viabilizar aplicações escaláveis e adaptativas, capazes de operar em ambientes dinâmicos e com grande variabilidade de dados.

2.1.2 Principais técnicas e algoritmos utilizados na análise de imagens corporais.


A análise de imagens corporais por meio de inteligência artificial envolve diferentes abordagens, que podem ser classificadas, de forma geral, em métodos paramétricos e não paramétricos. Métodos paramétricos utilizam modelos matemáticos explícitos do corpo humano, como o SMPL (Skinned Multi-Person Linear Model), que representa a geometria corporal por meio de parâmetros de forma e pose, possibilitando a reconstrução tridimensional a partir de imagens bidimensionais (LOPER et al., 2015).

Apesar de proporcionarem alto nível de detalhamento anatômico, esses métodos apresentam limitações relacionadas à necessidade de múltiplas vistas, dependência de parâmetros intrínsecos de câmera e elevado custo computacional. Além disso, a obtenção de dados reais para treinamento e validação pode ser onerosa, levando frequentemente ao uso de bases sintéticas (DIBRA et al., 2016).

Em contraste, os métodos não paramétricos são baseados principalmente em aprendizado de máquina e, mais recentemente, em aprendizado profundo, não assumindo um modelo geométrico explícito do corpo humano. Nessas abordagens,

redes neurais são treinadas para aprender diretamente a relação entre os dados de entrada (imagens) e as saídas desejadas (medidas corporais), sem depender de uma representação intermediária tridimensional. Esse processo ocorre por meio da extração automática de características relevantes, permitindo que o modelo capture padrões complexos presentes nos dados visuais, mesmo em condições de alta variabilidade antropométrica.

Figura 3 - Comparação entre abordagens paramétricas e não paramétricas para estimativa de medidas corporais.



Fonte: imagem gerada por inteligência artificial (DALL·E 3) a partir de descrição do autor, para fins ilustrativos (OpenAI, 2026).

A Figura 3 sintetiza a diferença entre as abordagens paramétricas e não paramétricas aplicadas à estimativa de medidas corporais. Nos métodos paramétricos, o corpo humano é representado por modelos geométricos explícitos, geralmente tridimensionais, nos quais parâmetros de forma e pose são ajustados para reconstruir a estrutura corporal. Já os métodos não paramétricos, como os baseados em redes neurais convolucionais, não dependem de uma reconstrução 3D explícita, mas aprendem diretamente a relação entre imagens e medidas corporais a partir dos dados. Essa distinção é relevante para este trabalho, pois a abordagem baseada em MNASNet se enquadra no grupo dos métodos não paramétricos, priorizando a extração automática de características visuais e a regressão direta das medidas.

Entre as técnicas não paramétricas, destacam-se as redes neurais convolucionais (CNNs), que realizam a extração hierárquica de características visuais, identificando desde padrões básicos, como bordas e contornos, até estruturas mais complexas relacionadas à forma do corpo humano. Essas redes permitem a regressão direta de medidas corporais a partir de imagens, reduzindo a necessidade de etapas intermediárias, como reconstrução 3D, e aumentando a escalabilidade da solução.

Nesse contexto, arquiteturas como a MNASNet destacam-se por sua eficiência computacional e capacidade de extração de características relevantes, sendo especialmente adequadas para aplicações em dispositivos com restrições de processamento (TAN et al., 2019). Além disso, modelos modernos incorporam estratégias adicionais, como o uso de múltiplas vistas (frontal e lateral) e a integração de metadados, como altura e peso, para reduzir ambiguidades de escala e melhorar a acurácia das estimativas (YAN et al., 2020).

Outra abordagem relevante envolve o uso de técnicas adversariais, como o treinamento com exemplos sintéticos desafiadores, que permitem aumentar a robustez do modelo ao expô-lo a cenários com baixa representatividade nos dados reais (RUIZ et al., 2022). Essas estratégias contribuem significativamente para a generalização dos modelos, especialmente em contextos com elevada variabilidade antropométrica, tornando os métodos não paramétricos particularmente vantajosos em aplicações reais, como sistemas de recomendação de tamanhos no e-commerce.

2.1.3 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (Convolutional Neural Networks – CNN) constituem uma arquitetura amplamente utilizada em tarefas de visão computacional devido à sua capacidade de extrair e aprender características espaciais presentes em imagens. Diferentemente de técnicas tradicionais de processamento de imagens, as CNNs realizam a aprendizagem automática de atributos relevantes por meio de múltiplas camadas de processamento, permitindo identificar padrões visuais complexos de forma eficiente. Essa característica torna as CNNs particularmente adequadas para aplicações como classificação de imagens, detecção de objetos, segmentação semântica e reconhecimento de padrões visuais.

O funcionamento de uma CNN baseia-se principalmente na operação de convolução, na qual pequenos filtros percorrem a imagem de entrada para extrair

características locais, como bordas, texturas e formas. Essa abordagem reduz significativamente a quantidade de parâmetros necessários para o treinamento da rede em comparação com redes neurais totalmente conectadas, aumentando a eficiência computacional sem comprometer a capacidade de aprendizado. De acordo com Lecun et al. (2015), a utilização de filtros convolucionais permite que a rede identifique padrões visuais relevantes independentemente de sua posição na imagem, favorecendo a robustez do modelo em diferentes cenários.

Durante o processamento, as primeiras camadas da CNN são responsáveis pela extração de características mais simples, enquanto as camadas mais profundas aprendem representações cada vez mais abstratas e complexas dos objetos presentes na imagem. Ao final desse processo, os mapas de características gerados pelas sucessivas camadas são utilizados para classificar ou detectar objetos de interesse. Segundo Ghosh et al. (2020), essa estrutura hierárquica de aprendizado permite que as CNNs alcancem elevados níveis de desempenho em aplicações de visão computacional, consolidando-se como uma das principais abordagens empregadas em sistemas modernos de inteligência artificial voltados à análise de imagens.

2.1.4 Evolução das aplicações em e-commerce de moda.

A aplicação de inteligência artificial no setor de e-commerce de moda tem evoluído de forma significativa nas últimas décadas, acompanhando o crescimento do comércio digital e a demanda por experiências de compra mais personalizadas. Inicialmente, os sistemas eram baseados em regras estáticas e tabelas de medidas padronizadas, que ofereciam recomendações pouco adaptadas às características individuais dos usuários.

Com o avanço da IA, surgiram soluções mais sofisticadas, como sistemas de recomendação baseados em aprendizado de máquina, ferramentas de busca visual e provadores virtuais. Essas tecnologias possibilitam não apenas a personalização da experiência de compra, mas também a análise do comportamento do consumidor e a otimização de processos logísticos (COSTA, 2024; COUTO, 2025).

A visão computacional, em particular, tem desempenhado papel central nessa evolução, permitindo o desenvolvimento de sistemas capazes de estimar medidas corporais diretamente a partir de imagens. Essas soluções têm como objetivo reduzir

a incerteza associada à escolha de tamanhos e, conseqüentemente, diminuir a taxa de devoluções, um dos principais desafios do setor (ROTHSTEIN, 2025).

Apesar desses avanços, ainda existem limitações significativas, especialmente relacionadas à precisão das estimativas e à capacidade dos sistemas de generalizar para diferentes perfis corporais, evidenciando a necessidade de estudos adicionais e aprimoramentos tecnológicos.

2.2 ESTIMATIVA DE MEDIDAS CORPORAIS POR IA

2.2.1 Métodos tradicionais versus métodos baseados em IA

A estimativa de medidas corporais evoluiu de abordagens tradicionais baseadas em reconstrução tridimensional e análise manual para métodos automatizados baseados em inteligência artificial. Os métodos tradicionais geralmente envolvem a reconstrução de modelos 3D a partir de imagens capturadas em múltiplas vistas, com posterior cálculo de distâncias geodésicas entre pontos de interesse (LOPER et al., 2015).

Embora esses métodos apresentem alto nível de detalhamento, sua aplicação prática é limitada pela necessidade de equipamentos específicos e pela dificuldade de obtenção de dados em larga escala. Além disso, esses métodos são sensíveis a fatores como iluminação, pose e parâmetros de captura, o que pode comprometer a precisão das estimativas.

Em contraste, métodos baseados em IA permitem a regressão direta de medidas corporais a partir de imagens, utilizando redes neurais profundas capazes de aprender padrões complexos presentes nos dados. Essa abordagem reduz significativamente a complexidade do processo e permite maior escalabilidade, tornando-se mais adequada para aplicações em larga escala, como o e-commerce (RUIZ et al., 2022).

2.2.2 Importância da precisão métrica e dos dados de entrada (imagens, altura, peso).

A precisão métrica é um fator crítico na estimativa de medidas corporais, especialmente em aplicações práticas como recomendação de vestuário, nas quais pequenas variações podem resultar em mudanças significativas na classificação de tamanho.

A qualidade dos dados de entrada exerce impacto direto sobre o desempenho dos modelos, sendo essencial que as imagens apresentem resolução adequada, iluminação controlada e representação completa do corpo. Além disso, a utilização de múltiplas vistas e a incorporação de metadados, como altura e peso, são estratégias fundamentais para reduzir ambiguidades de escala e melhorar a acurácia das estimativas (YAN et al., 2020).

Estudos demonstram que a ausência de dados representativos ou a utilização de imagens de baixa qualidade pode comprometer significativamente a capacidade de generalização dos modelos, resultando em erros sistemáticos (SMITH et al., 2019). Dessa forma, a qualidade e diversidade dos dados constituem elementos fundamentais para o desenvolvimento de soluções confiáveis e aplicáveis em contextos reais.

2.3 DESAFIOS E LIMITAÇÕES

2.3.1 Variabilidade dos corpos humanos e representatividade dos dados.

A variabilidade dos corpos humanos representa um dos maiores desafios para a estimativa de medidas corporais por inteligência artificial, pois envolve uma ampla gama de biotipos, proporções, gêneros, idades e condições físicas que precisam ser corretamente representados nos conjuntos de dados utilizados para treinamento dos modelos. A falta de diversidade e representatividade nos dados pode levar a vieses e limitações nos algoritmos, resultando em erros sistemáticos para grupos sub-representados, como pessoas com altos índices de massa corporal, diferentes etnias ou características morfológicas menos comuns (RUIZ et al., 2022). Estudos mostram que muitos datasets tradicionais, como o CAESAR, embora volumosos, não contemplam toda a complexidade da população global, o que compromete a capacidade dos modelos de generalizar e oferecer estimativas precisas para todos os usuários (LOPER et al., 2015).


Para mitigar esses problemas, abordagens modernas têm investido na criação de bases de dados mais inclusivas, como o BodyM, e na utilização de técnicas de aumento adversarial, que expõem os modelos a exemplos desafiadores e pouco representados, promovendo maior robustez e equidade nas previsões (YAN et al., 2020). Ainda assim, garantir a representatividade adequada permanece um desafio contínuo, exigindo esforços colaborativos entre pesquisadores, empresas e

comunidades para ampliar a coleta de dados e desenvolver soluções que atendam às necessidades de diferentes perfis corporais, contribuindo para sistemas mais justos e precisos em aplicações como e-commerce, saúde e ergonomia.

2.3.2 Ambiguidade de escala e limitações técnicas dos modelos.

A ambiguidade de escala é um dos principais obstáculos técnicos enfrentados por modelos de inteligência artificial na estimativa de medidas corporais, especialmente quando se trabalha com imagens bidimensionais sem informações explícitas sobre distância da câmera, resolução ou altura real do indivíduo. Essa falta de referência métrica pode levar a estimativas imprecisas, comprometendo a confiabilidade dos sistemas em aplicações como recomendação de tamanhos no e-commerce ou avaliação clínica em saúde (LOPER et al., 2015). Para mitigar esse problema, muitos modelos modernos passaram a incorporar metadados como altura e peso, que ajudam a calibrar as previsões e reduzir a variabilidade causada por diferentes condições de captura (RUIZ et al., 2022). No entanto, mesmo com esses avanços, persistem limitações técnicas relacionadas à capacidade dos modelos de generalizar para corpos com proporções incomuns, poses variadas ou roupas que ocultam contornos corporais. Além disso, redes neurais profundas exigem grandes volumes de dados representativos e bem anotados para alcançar desempenho satisfatório, o que nem sempre é viável em contextos reais.

Figura 4 - Exemplo de ambiguidade de escala em imagens bidimensionais capturadas a diferentes distâncias.



Fonte: imagem gerada por inteligência artificial (DALL·E 3) a partir de descrição do autor, para fins ilustrativos (OpenAI, 2026).

A Figura 4 exemplifica a ambiguidade de escala presente em imagens bidimensionais. Embora o indivíduo possua as mesmas medidas corporais reais, a alteração da distância em relação à câmera modifica a proporção ocupada pelo corpo na imagem, influenciando a quantidade de pixels associada à silhueta e a percepção visual de largura, altura e contorno. Esse fenômeno pode dificultar a estimativa métrica realizada por modelos de visão computacional, uma vez que imagens visualmente semelhantes podem representar corpos com dimensões reais distintas, ou, inversamente, o mesmo corpo pode assumir representações diferentes em função da distância de captura. Por esse motivo, metadados como altura e peso, bem como estratégias de padronização da aquisição das imagens, tornam-se elementos importantes para reduzir incertezas e melhorar a robustez dos modelos.

Modelos como o BMnet, por exemplo, demonstram melhorias significativas quando treinados com dados sintéticos e adversariais, mas ainda enfrentam dificuldades em ambientes não controlados, como imagens capturadas em condições de iluminação adversa ou com ruído visual (SMITH et al., 2019). Portanto, superar a ambiguidade de escala e as limitações técnicas dos modelos requer não apenas

avanços arquiteturais, mas também estratégias robustas de coleta e enriquecimento de dados, além de validações rigorosas em cenários diversos.

2.3.3 Barreiras éticas e de privacidade no uso de imagens corporais.

O uso de imagens corporais em sistemas de inteligência artificial levanta sérias barreiras éticas e preocupações com a privacidade, especialmente em aplicações que envolvem reconhecimento corporal, estimativa de medidas e geração de conteúdo visual. A coleta, armazenamento e processamento de imagens pessoais por algoritmos de IA podem expor indivíduos a riscos de identificação indevida e uso não autorizado de sua imagem, o que fere direitos fundamentais como o direito à privacidade e à dignidade (FAMA, 2025).

Casos envolvendo *deepfakes* (vídeos falsos gerados por IA) e recriação de imagens sem consentimento têm se tornado cada vez mais comuns, evidenciando a necessidade de regulamentações mais rígidas e práticas transparentes por parte das empresas e desenvolvedores (FERREIRA, 2024). A Lei Geral de Proteção de Dados (LGPD), no Brasil, estabelece diretrizes para o tratamento de dados pessoais, incluindo imagens, exigindo consentimento explícito e finalidades legítimas para seu uso. No entanto, mesmo com legislações em vigor, o avanço acelerado da IA desafia a capacidade de fiscalização e controle, tornando essencial o desenvolvimento de modelos éticos e responsáveis que respeitem os direitos de personalidade e evitem a exploração indevida da identidade visual dos indivíduos (NEVES, 2023). A adoção de princípios como transparência, explicabilidade e consentimento informado deve ser central na construção de sistemas que utilizam imagens corporais, garantindo que a inovação tecnológica não se sobreponha à proteção dos direitos humanos.

2.4 DESCRIÇÃO DAS ARQUITETURAS

2.4.1 Detalhamento da MNASNet: estrutura, funcionamento e vantagens.

A MNASNet é uma arquitetura de rede neural convolucional desenvolvida para otimizar a relação entre precisão e eficiência computacional, sendo especialmente adequada para aplicações em dispositivos móveis e sistemas que exigem baixo consumo de recursos. Baseada no conceito de neural architecture search (NAS), a MNASNet utiliza algoritmos de busca automática para definir a melhor combinação de blocos convolucionais, profundidade e largura da rede, equilibrando desempenho e custo computacional (TAN et al., 2019).

Sua estrutura é composta por blocos *depthwise separable convolutions*, que reduzem significativamente o número de parâmetros e operações, mantendo alta capacidade de extração de características visuais. Essa abordagem permite que a MNASNet seja mais eficiente que arquiteturas tradicionais, como MobileNet e ResNet, apresentando menor latência e consumo energético sem comprometer a acurácia (HOWARD et al., 2017). Além disso, a arquitetura incorpora mecanismos de escalonamento adaptativo, ajustando automaticamente a complexidade da rede conforme as restrições do dispositivo ou aplicação, o que a torna ideal para tarefas como estimativa de medidas corporais em ambientes de e-commerce, onde é necessário processar imagens com rapidez e precisão.

Estudos recentes demonstram que a MNASNet, quando combinada com estratégias de treinamento robustas e dados diversificados, alcança resultados competitivos em métricas de erro absoluto médio (MAE) e robustez frente a variações de pose e iluminação, consolidando-se como uma solução eficiente para aplicações práticas em visão computacional (TAN et al., 2019; HOWARD et al., 2017; RUIZ et al., 2022).

2.4.2 Características do SnapMeasurementAI: abordagem de mercado e diferenciais.

O SnapMeasurementAI é uma solução comercial desenvolvida para atender às demandas do e-commerce, oferecendo estimativa automatizada de medidas corporais a partir de imagens capturadas pelo usuário em dispositivos móveis. Diferentemente de arquiteturas acadêmicas como MNASNet, que priorizam otimização de desempenho e eficiência computacional, o SnapMeasurementAI adota

uma abordagem orientada à experiência do consumidor, integrando algoritmos proprietários de visão computacional com técnicas de aprendizado profundo para gerar previsões rápidas e intuitivas.

Seu funcionamento baseia-se na captura de imagens frontais e laterais, complementadas por metadados como altura e peso, permitindo calibrar as estimativas e reduzir ambiguidades de escala, um dos principais desafios na análise antropométrica. Entre os diferenciais da plataforma, destacam-se a interface amigável e a capacidade de operar em tempo real, sem necessidade de hardware especializado, tornando-a altamente escalável para grandes varejistas. Embora os detalhes técnicos da arquitetura sejam restritos por questões de propriedade intelectual, estudos e análises de mercado indicam que soluções como SnapMeasurementAI representam um avanço significativo na aplicação prática da IA, oferecendo precisão competitiva e experiência otimizada para consumidores. (COUTO, 2025; ROTHSTEIN, 2025; FAMA, 2025).

2.5 MÉTRICAS DE AVALIAÇÃO

O MAE (*Mean Absolute Error*) representa o erro em cada previsão e é amplamente empregado na avaliação de modelos de visão computacional voltados à estimativa de medidas corporais, por fornecer uma métrica direta e interpretável da precisão das predições realizadas a partir de imagens. Essa métrica calcula a média das diferenças absolutas entre as medidas estimadas pelo modelo e os valores reais de referência, permitindo quantificar, de forma objetiva, o desvio médio das estimativas em relação às dimensões corporais reais (DATACAMP, 2025). Sua utilização é particularmente relevante nesse contexto, pois os resultados mantêm a mesma unidade das medidas físicas (como centímetros), facilitando a interpretação prática dos erros e sua aplicação em áreas como e-commerce de vestuário, ergonomia e saúde (GEEKSFORGEEKS, 2026). Além disso, o MAE trata todos os erros de maneira uniforme, sem diferenciar superestimções ou subestimções, o que contribui para uma avaliação consistente do desempenho global do modelo (DATACAMP, 2025). Outra vantagem importante é sua menor sensibilidade a valores extremos, característica que aumenta a robustez da métrica em cenários onde há variações nos dados de entrada, como diferenças de iluminação, pose ou qualidade das imagens. Dessa forma, o MAE se destaca como uma métrica adequada para

validar modelos de inteligência artificial aplicados à estimativa de medidas corporais, permitindo avaliar com clareza o erro médio das previsões em aplicações práticas.

Formalmente, o erro absoluto médio pode ser expresso pela equação a seguir.

$$MAE = \left(\frac{1}{n}\right) \cdot \sum |y_i - \hat{y}_i|$$

Equação 1 – Fórmula do erro absoluto médio (MAE)

Nessa expressão, n representa o número total de amostras avaliadas, y_i corresponde ao valor real da medida para a amostra i e $\hat{y}_i$ representa o valor estimado pelo modelo. Essa formulação evidencia que o MAE corresponde à média das diferenças absolutas entre os valores reais e previstos, sem considerar a direção do erro.


3 METODOLOGIA

O sistema proposto foi desenvolvido com o objetivo de estimar medidas corporais a partir de imagens, utilizando técnicas de visão computacional e aprendizado profundo. De forma geral, o fluxo do sistema segue uma abordagem baseada em processamento de imagens, extração de características e inferência por meio de redes neurais convolucionais.

Assim como abordagens consolidadas na literatura, o sistema parte da aquisição de imagens digitais, que são representadas como matrizes de pixels e processadas computacionalmente para extração de informações relevantes. A partir dessas imagens, é aplicada uma pipeline estruturada que envolve pré-processamento, normalização, inferência pelo modelo MNASNet e pós-processamento dos resultados.

3.1 ESTRUTURA GERAL DO PIPELINE DE PROCESSAMENTO

Figura 5 - Pipeline de implementação da solução MNASNet na estimativa de medidas corporais.



Fonte: imagem gerada por inteligência artificial (DALL·E 3) a partir de descrição do autor, para fins ilustrativos (OpenAI, 2026).

O pipeline desenvolvido, observado na Figura 5, pode ser descrito em quatro blocos principais:

1. Aquisição e preparação dos dados;
2. Pré-processamento das imagens;
3. Inferência com modelo MNASNet;
4. Pós-processamento e geração das medidas.

A etapa inicial do sistema consiste na aquisição e preparação das imagens utilizadas como entrada do modelo. Essas imagens representam indivíduos em condições controladas para análise corporal e são organizadas em um conjunto de dados estruturado, contendo tanto as imagens quanto suas respectivas medidas reais associadas. Esse conjunto é fundamental para o treinamento supervisionado do modelo, permitindo o aprendizado da relação entre padrões visuais e medidas corporais estimadas.

Após a aquisição, é realizada a etapa de pré-processamento das imagens, com o objetivo de padronizar os dados de entrada e garantir consistência durante o treinamento. Essa etapa envolve o redimensionamento das imagens para o formato esperado pela arquitetura da rede, normalização dos valores de pixels e ajuste das

proporções. Considerando que as imagens digitais são representadas como matrizes de valores numéricos, essa padronização é essencial para assegurar que o modelo receba entradas uniformes e comparáveis ao longo de todo o processo de treinamento, reduzindo interferências decorrentes de variações de escala, resolução e iluminação.

O modelo adotado neste trabalho baseia-se na arquitetura MNASNet, uma Rede Neural Convolucional (CNN) projetada para oferecer bom desempenho aliado à eficiência computacional. Essa arquitetura é composta por múltiplas camadas convolucionais responsáveis pela extração hierárquica de características, permitindo que padrões simples, como bordas e contornos, evoluam para representações mais complexas relacionadas à estrutura corporal. Durante o processo de treinamento, cada imagem de entrada é propagada pela rede por meio do chamado *forward pass*, etapa na qual os dados percorrem sequencialmente as camadas convolucionais, de ativação e de redução dimensional, gerando ao final uma saída correspondente às estimativas das medidas analisadas.

A partir dessa saída, é calculado o erro em relação aos valores reais, sendo então aplicada a etapa de *backpropagation*, responsável por ajustar os pesos da rede de forma iterativa. Nesse processo, o erro é propagado de volta através das camadas, permitindo a atualização dos parâmetros internos por meio de algoritmos de otimização, com o objetivo de minimizar a função de perda. Esse ciclo contínuo de propagação direta e retropropagação permite que o modelo refine progressivamente suas previsões, culminando em uma camada final capaz de produzir estimativas numéricas contínuas das medidas corporais com maior precisão.

Por fim, após o processo de inferência do modelo, é aplicada uma etapa de pós-processamento, responsável por converter as saídas em valores interpretáveis no contexto da aplicação. Nessa etapa, os valores previstos pela rede são ajustados conforme fatores de escala e transformados para unidades reais, como centímetros, possibilitando sua utilização em aplicações práticas, como recomendação de tamanhos de vestuário. Esse processo garante que as estimativas geradas pelo modelo sejam consistentes com o domínio real e adequadas para uso em sistemas de apoio à decisão.

3.2 CONJUNTO DE DADOS

3.2.1 Apresentação do dataset BodyM e outros utilizados.

O conjunto de dados BodyM foi utilizado como base principal para o treinamento e avaliação do modelo MNASNet. BodyM é o primeiro dataset público de larga escala voltado à estimativa de medidas corporais, contendo 8.324 imagens de silhuetas frontais e laterais, associadas à altura, peso e 14 medidas antropométricas de 2.779 indivíduos reais, o que permite calibrar os modelos e reduzir ambiguidades de escala (RUIZ et al., 2022). Além disso, o dataset apresenta diversidade étnica, incluindo indivíduos autodeclarados brancos (40%), asiáticos (30%), negros ou afro-americanos (14%), indígenas ou nativos do Alasca (1%) e outras categorias (15%), sendo que aproximadamente 15% dos participantes também se declararam hispânicos. Essa diversidade contribui para uma representação mais abrangente das diferentes características corporais presentes na população e favorece a capacidade de generalização dos modelos treinados.


Além disso, o BodyM inclui dados sintéticos gerados a partir de modelos paramétricos, como o SMPL, que possibilitam ampliar a variabilidade das poses e proporções corporais sem os altos custos associados à coleta de dados reais (LOPER et al., 2015). Essa integração entre dados reais e sintéticos é essencial para garantir robustez e generalização, especialmente em cenários onde a representatividade é um desafio, como corpos com altos índices de massa corporal ou características morfológicas menos comuns.

A qualidade e diversidade desses conjuntos de dados são determinantes para o desempenho dos modelos, influenciando diretamente métricas como erro absoluto médio (MAE), e constituem um dos pilares metodológicos para o desenvolvimento de sistemas confiáveis e escaláveis em aplicações práticas de visão computacional.

Além do dataset BodyM, foi utilizado um conjunto de imagens de 6 indivíduos, em duas distâncias diferentes, 2 metros e 3 metros, para validar o modelo treinado, onde chamamos de Dataset desenvolvidoV1, separando as distâncias simulando indivíduos diferentes, e Dataset desenvolvidoV2, onde consideramos as duas imagens no mesmo indivíduo.

3.2.2 Processamento das imagens (segmentação, vistas frontal e lateral).

Figura 6 - Processo de segmentação da imagem original para obtenção da silhueta corporal.




Fonte: Autoria Própria.

A Figura 6 apresenta, de forma simplificada, o processo de segmentação aplicado às imagens corporais. Inicialmente, as imagens capturadas são submetidas à segmentação para separar o corpo do fundo, utilizando técnicas baseadas em CNNs e modelos de segmentação semântica, que permitem identificar com precisão os contornos corporais mesmo em cenários com ruído visual ou iluminação variável (CHEN et al., 2018). Essa etapa é fundamental para reduzir interferências do ambiente, como fundo, iluminação e objetos externos, permitindo que os modelos concentrem sua análise nas características corporais relevantes para a estimativa das medidas.

O processamento das imagens é uma etapa crucial para garantir a qualidade dos dados utilizados na estimativa de medidas corporais, envolvendo procedimentos como segmentação, normalização e padronização das vistas frontal e lateral.

Figura 7 - Silhuetas do dataset desenvolvido, na sequência, 3 homens e 3 mulheres.



Fonte: Autoria Própria.

Após a segmentação, aplica-se a normalização das imagens para padronizar escala, orientação e proporções, garantindo que as vistas frontal e lateral estejam alinhadas e compatíveis com os requisitos do modelo de aprendizado (YAN et al., 2020) conforme pode-se observar na Figura 7. Essa padronização é essencial para reduzir ambiguidades de escala e melhorar a consistência das estimativas, especialmente quando os dados são coletados em condições não controladas, como dispositivos móveis.

O processamento adequado das imagens, portanto, não apenas assegura a qualidade dos dados, mas também contribui para a generalização e precisão das redes neurais, sendo um componente indispensável na metodologia de sistemas baseados em visão computacional para estimativa antropométrica.

3.2.3 Critérios de seleção, preparação e balanceamento dos dados.

A definição de critérios rigorosos para seleção, preparação e balanceamento dos dados é essencial para garantir a qualidade e a representatividade do conjunto


utilizado no treinamento de modelos de estimativa de medidas corporais. Inicialmente, a seleção das imagens deve considerar parâmetros como resolução mínima, iluminação adequada e ausência de obstruções visuais, assegurando que as vistas frontal e lateral apresentem contornos corporais nítidos e completos (YAN et al., 2020).

A preparação envolve etapas de normalização, padronização de escala e alinhamento das imagens, além da validação dos metadados antropométricos (altura, peso e medidas físicas), que são fundamentais para reduzir ambiguidades e calibrar as previsões (RUIZ et al., 2022). Além disso, a divisão do dataset em subconjuntos de treino, validação e teste deve seguir protocolos de estratificação para preservar a representatividade das categorias em todas as fases do processo. Esses cuidados metodológicos garantem não apenas maior precisão métrica, mas também robustez e equidade nos resultados, tornando o balanceamento e a preparação dos dados pilares fundamentais para o sucesso das soluções baseadas em IA.

3.3 ESTRATÉGIAS DE TREINAMENTO

3.3.1 Divisão do dataset

Figura 8 - Distribuição percentual dos dados nas estratégias MNASNet V1 e MNASNet V2.



Fonte: Autoria Própria.

A Figura 8 apresenta a distribuição percentual dos dados nas duas estratégias de treinamento avaliadas neste trabalho. Na configuração MNASNet V1, os dados foram divididos em 70% para treinamento, 15% para validação e 15% para teste, seguindo uma abordagem mais convencional de separação entre as etapas. Já na

configuração MNASNet V2, foi adotada uma divisão com aproximadamente 84,9% dos dados destinados ao treinamento, 15% à validação e 0,1% ao teste.

A adoção dessas duas abordagens teve como objetivo analisar o impacto do aumento do número de indivíduos disponíveis para o treinamento do modelo, mantendo uma base consistente de validação para monitoramento do desempenho. Dessa forma, buscou-se avaliar como a ampliação do conjunto de treino influencia a capacidade de aprendizado da rede, bem como seus efeitos na generalização dos resultados observados.

3.3.2 Quantidade de treinamento

No contexto de redes neurais e aprendizado de máquina, uma *epoch* corresponde a uma passagem completa de todo o conjunto de dados de treinamento pelo modelo, durante a qual cada amostra é processada e utilizada para o ajuste dos parâmetros internos da rede. Esse conceito está diretamente relacionado ao processo iterativo de aprendizado, no qual o modelo refina suas previsões ao longo de múltiplas épocas, reduzindo progressivamente o erro. Neste trabalho, a definição do número adequado de *epochs*¹ foi realizada por meio de uma estratégia de treinamento incremental, na qual sucessivos experimentos com diferentes quantidades de épocas foram conduzidos. A análise dos resultados obtidos permitiu observar o comportamento do erro ao longo do treinamento, identificando o ponto em que o modelo apresentava convergência — caracterizado pela estabilização ou redução consistente do erro — e, posteriormente, os momentos em que ocorria divergência ou degradação do desempenho, indicativos de possíveis efeitos de *overfitting*². Dessa forma, a escolha da quantidade final de treinamento foi baseada na melhor relação entre aprendizado do modelo e capacidade de generalização, buscando maximizar a precisão sem comprometer a robustez dos resultados.

3.4 IMPLEMENTAÇÃO DAS SOLUÇÕES

3.4.1 Detalhes da implementação da MNASNet.

Para a avaliação do modelo MNASNet, foram utilizados dois conjuntos de dados compostos por imagens de seis indivíduos distintos, denominados Dataset

¹ Uma passagem completa do conjunto de treinamento pelo modelo durante o processo de aprendizagem.

² Ocorre quando o modelo se ajusta excessivamente aos dados de treinamento e perde capacidade de generalização para dados não observados.

Desenvolvido V1 e Dataset Desenvolvido V2. A principal diferença entre esses conjuntos está relacionada à forma de tratamento das imagens de entrada e à estratégia de cálculo das estimativas. A utilização de seis indivíduos no experimento decorreu das condições necessárias para a coleta das imagens, especialmente a necessidade de uso de vestimentas ajustadas ao corpo, de modo a permitir melhor definição dos contornos corporais e maior qualidade na segmentação das silhuetas. Dessa forma, optou-se por participantes próximos ao pesquisador, garantindo maior viabilidade na coleta e padronização das condições experimentais.

No Dataset Desenvolvido V1, foram consideradas imagens capturadas em duas diferentes condições de distância em relação à câmera, especificamente a aproximadamente 2 metros e 3 metros. Nessa configuração, as imagens de uma mesma pessoa obtidas em distâncias distintas foram tratadas como se correspondessem a indivíduos diferentes. Essa estratégia foi adotada de forma deliberada como um procedimento experimental para ampliar a variação aparente do conjunto de avaliação e investigar a sensibilidade do modelo à mudança de escala, perspectiva e proporção projetada na imagem. Embora as medidas reais do indivíduo permaneçam constantes, a alteração da distância em relação à câmera modifica a representação visual da silhueta, influenciando o número de pixels ocupados pelo corpo, a definição dos contornos e a relação entre as dimensões corporais observadas na imagem. Assim, ao tratar cada condição de captura como uma amostra independente, buscou-se simular cenários práticos em que usuários diferentes podem enviar imagens com enquadramentos e distâncias variadas, permitindo avaliar se o modelo é capaz de manter estimativas consistentes mesmo diante dessas variações de aquisição.

Já no Dataset Desenvolvido V2, adotou-se uma estratégia distinta, na qual, para cada indivíduo, foram utilizadas duas imagens e realizada a média das estimativas obtidas pelo modelo. Essa abordagem buscou reduzir a variabilidade associada a fatores como posicionamento, iluminação e ruído na aquisição das imagens, proporcionando uma estimativa mais estável e representativa das medidas corporais.

3.4.2 Configuração e uso do SnapMeasurementAI.

A solução SnapMeasurementAI foi utilizada como referência comparativa, sendo implementada por meio de sua plataforma web. Diferentemente do modelo MNASNet, essa abordagem não requer configuração de parâmetros internos por parte do usuário, apresentando um fluxo de utilização simplificado e orientado à usabilidade.

O processo de utilização da ferramenta consiste, essencialmente, no carregamento (upload) das imagens do indivíduo e na inserção manual de informações complementares, como a altura. A partir desses dados, a plataforma realiza automaticamente o processamento e fornece como saída as estimativas das medidas corporais, sem a necessidade de intervenção adicional ou ajustes técnicos por parte do usuário.

3.5 MÉTODO DE AVALIAÇÃO QUANTITATIVA

Para a avaliação da melhor alternativa, realizamos comparações com as duas primeiras versões do treinamento, com 50 e 100 *epochs*. Após isto, iremos comparar os resultados com as tabelas de medidas e tamanhos de dois fabricantes, com medidas masculinas da Insider® e medidas femininas da Renner®, conforme tabelas a seguir:

Tabela 1 - Medidas camisa Insider

Tamanho	TORAX			CINTURA		
	MIN	MAX	Diferença	MIN	MAX	Diferença
PP	85	90	5	74	84	10
P	91	96	5	85	88	3
M	97	104	7	89	93	4
G	105	108	3	94	98	4
GG	109	112	3	99	105	6
	média		4,6	média		5,4

Fonte: Adaptado do site do fabricante.

Tabela 2 - Medidas short Insider

Tamanho	CINTURA			QUADRIL		
	MIN	MAX	Diferença	MIN	MAX	Diferença
P	79	82	3	90	98	8
M	83	90	7	99	108	9
G	91	96	5	109	112	3
GG	97	102	5	112	118	6
XGG	103	110	7	119	124	5
	média		5,4	média		6,2

Fonte: Adaptado do site do fabricante.

Vale ressaltar que a Renner utiliza uma única tabela tanto para short como para camisa, como pode-se notar a seguir.

Tabela 3 - Medidas Camisas/Short Renner

BUSTO				CINTURA			QUADRIL		
Tamanho	MIN	MAX	Diferença.	MIN	MAX	Diferença	MIN	MAX	Diferença
PP	78	82	4	60	64	4	88	92	4
P1	82	86	4	64	68	4	92	96	4
P2	86	90	4	68	72	4	96	100	4
M1	90	94	4	72	76	4	100	104	4
M2	94	98	4	76	80	4	104	108	4
G1	98	102	4	80	84	4	108	112	4
G2	102	107	5	84	89	5	112	117	5
GG1	107	112	5	89	94	5	117	122	5
GG2	112	117	5	94	99	5	122	127	5
GL1	117	122	5	99	104	5	127	132	5
GL2	122	127	5	104	109	5	132	137	5
média			4,5	média		4,5	média		4,5

Fonte: Adaptado do site do fabricante.

A Tabela 1, Tabela 2 e Tabela 3 mostram as medidas dos dois fabricantes que iremos tomar como referência, Insider e Renner. As tabelas demonstram que o tamanho das peças de roupas varia em média de 4 em 4 centímetros, sendo este um parâmetro para avaliar se o modelo está atendendo ou não o requisito mínimo para ser assertivo em suas previsões.

4 RESULTADOS E DISCUSSÕES

Esta seção aborda a análise de desempenho dos modelos MNASNet treinado com a base de dados BodyM e comparação com o modelo gratuito SnapMeasurementAI.

4.1 AVALIAÇÃO QUALITATIVA

A análise qualitativa foi conduzida a partir da observação das silhuetas utilizadas no processo de estimativa, conforme ilustrado na Figura 7 e Figura 9.


Figura 9 - Silhueta homem 3, pior estimativa do modelo SnapMeasurementAI.



Fonte: Autoria Própria.

A partir da análise das silhuetas, observa-se que a qualidade da definição dos contornos corporais exerce influência direta na precisão das estimativas realizadas pelos modelos. No caso do indivíduo representado na Figura 9 (homem 3), nota-se que a silhueta apresenta maior variação em relação ao contorno real do corpo, possivelmente decorrente do uso de vestimentas mais folgadas, o que dificulta a delimitação precisa da geometria corporal. Esse fator compromete a extração de características relevantes pelo modelo, resultando em maiores erros de estimativa. Em contraste, nas demais silhuetas masculinas com melhores resultados, observa-se maior separação entre os membros e contornos mais bem definidos, favorecendo a interpretação das proporções corporais.

Figura 10 - Silhueta homem 2, pior estimativa do modelo MNASNet.



Fonte: Autoria Própria.

Na Figura 16, correspondente ao homem 2, observa-se que a pior estimativa do modelo MNASNet está associada a uma silhueta que, embora apresente contorno corporal relativamente definido, pode ter gerado dificuldades para a rede em razão da distribuição das proporções corporais e da forma como a estrutura visual foi representada após a segmentação. Diferentemente do SnapMeasurementAI, que utiliza uma solução proprietária possivelmente calibrada para lidar com maior variação de entrada, o MNASNet depende diretamente dos padrões aprendidos no conjunto de treinamento. Assim, pequenas alterações na largura aparente do tronco, na relação entre tórax, cintura e quadril podem ser interpretadas de forma inadequada pelo modelo, resultando em superestimções ou subestimções relevantes nas medidas corporais. Esse comportamento está coerente com os resultados quantitativos apresentados anteriormente, nos quais o grupo masculino apresentou maior MAE e maior instabilidade, indicando que o modelo teve menor capacidade de generalização para esse perfil corporal.

No conjunto de indivíduos do grupo feminino, observa-se maior uniformidade nas características visuais das silhuetas, uma vez que todas utilizam vestimentas mais ajustadas ao corpo, o que contribui para uma representação mais fiel da geometria corporal. No entanto, mesmo com contornos aparentemente semelhantes, como pode-se observar nas 3 imagens inferiores da Figura 7, foram identificadas diferenças significativas no desempenho dos modelos entre os casos de melhor e pior estimativa, indicando que fatores adicionais, não diretamente visíveis na silhueta, também influenciam os resultados. Entre esses fatores, destacam-se a variação antropométrica, possíveis limitações do conjunto de treinamento e a sensibilidade do modelo a pequenas variações nas proporções corporais.

De forma geral, os resultados qualitativos corroboram as análises quantitativas apresentadas anteriormente, evidenciando que a precisão dos modelos depende não apenas da arquitetura utilizada, mas também da qualidade da representação visual das silhuetas e das condições de captura das imagens. Adicionalmente, observa-se que características como ajuste da vestimenta, definição dos contornos e separação dos membros influenciam diretamente o desempenho do modelo. Dessa forma, torna-se evidente a necessidade de estratégias de aprimoramento, incluindo a diversificação do conjunto de dados, a otimização de hiperparâmetros e a melhoria do processo de

segmentação das silhuetas, visando aumentar a robustez do sistema e reduzir erros em cenários mais desafiadores.

4.2 AVALIAÇÃO QUANTITATIVA


4.2.1 Resultados obtidos nos primeiros treinamentos

Nos experimentos iniciais, foram avaliadas quatro combinações entre duas versões do conjunto de teste e duas configurações do modelo MNASNet, com treinamentos de 50 e 100 *epochs*. Para facilitar a interpretação, a primeira sigla de cada combinação refere-se ao dataset utilizado na avaliação e a segunda sigla refere-se à versão do modelo treinado. Assim, a notação V1 V1 indica a avaliação do Dataset desenvolvidoV1 com o MNASNet V1; V1 V2 indica o Dataset desenvolvidoV1 com o MNASNet V2; V2 V1 indica o Dataset desenvolvidoV2 com o MNASNet V1; e V2 V2 indica o Dataset desenvolvidoV2 com o MNASNet V2.

Os testes preliminares mostraram que diferentes combinações de dataset e modelo produziram comportamentos distintos em termos de erro médio absoluto. Em valores estritamente numéricos, a combinação V1 V1 com 100 *epochs* apresentou o menor MAE entre os cenários iniciais. No entanto, a decisão de continuidade do estudo não foi baseada apenas no menor erro pontual, mas principalmente na representatividade do procedimento de avaliação. Nesse contexto, optou-se por seguir com a configuração V2 V2, pois ela associa o MNASNet V2 ao Dataset desenvolvidoV2, versão em que as duas imagens de cada indivíduo, capturadas em distâncias diferentes, são tratadas de forma integrada para compor uma estimativa média mais estável. Essa escolha reduz o efeito de variações ocasionadas apenas pela distância da captura e torna a avaliação mais coerente com a proposta do trabalho, que busca estimativas mais robustas por indivíduo, e não apenas o melhor resultado isolado em uma configuração específica.

4.2.2 Resultados obtidos do dataset desenvolvido V2 e MNasNet V2

Figura 11 – MAE (Mean Absolute Error) dataset desenvolvido V2, MNASNet V2




Fonte: Autoria Própria.

A análise da Figura 11 indica que o desempenho do modelo não melhora de forma linear com o aumento do número de *epochs*. Observa-se que a configuração com 700 *epochs* apresentou o menor MAE dentre os cenários avaliados, evidenciando que, a partir desse ponto, o acréscimo no tempo de treinamento não resultou em ganhos adicionais de precisão. Pelo contrário, o comportamento posterior sugere início de degradação da capacidade de generalização do modelo, fenômeno compatível com *overfitting*, no qual a rede passa a se ajustar excessivamente às particularidades do conjunto de treinamento, reduzindo seu desempenho sobre dados de avaliação.

Dessa forma, a adoção do modelo treinado com 700 *epochs* para as análises subsequentes mostra-se metodologicamente adequada, por representar o melhor equilíbrio entre aprendizado e generalização. Essa escolha é particularmente relevante no contexto deste trabalho, uma vez que o objetivo não consiste apenas em minimizar o erro no conjunto de treinamento, mas em obter estimativas mais robustas e confiáveis para aplicação prática na inferência de medidas corporais e, posteriormente, na recomendação de tamanhos de vestuário.

Figura 12 - MAE por indivíduo durante treinamento




Fonte: Autoria Própria.

A partir da análise da Figura 12, observa-se que o modelo MNASNet apresenta comportamento distinto ao longo do treinamento para os diferentes grupos avaliados. As curvas associadas aos indivíduos do grupo feminino iniciam com valores MAE inferiores e mantêm-se relativamente estáveis ao longo das épocas, indicando maior consistência no processo de aprendizado. Em contrapartida, as curvas associadas aos indivíduos do grupo masculino apresentam valores iniciais de erro mais elevados, maior oscilação durante o treinamento e, de modo geral, permanecem acima das curvas femininas em praticamente todas as épocas analisadas.

Esse padrão evidencia que o modelo não apenas apresenta menor desempenho para o grupo masculino, como também demonstra maior instabilidade durante o processo de treinamento, o que indica maior dificuldade de convergência para esse conjunto de dados. Tal comportamento pode estar relacionado a fatores como possível desbalanceamento do conjunto de treinamento, com maior representatividade de dados femininos, bem como à maior variabilidade antropométrica associada aos indivíduos masculinos, o que torna o problema de generalização mais complexo para o modelo.

Adicionalmente, observa-se que, embora todas as curvas apresentem redução inicial do erro, característica típica do aprendizado do modelo, o grupo masculino tende a convergir para patamares de erro mais elevados e menos estáveis. Esse resultado sugere a presença de viés no processo de aprendizado, indicando que o modelo assimila mais rapidamente e de forma mais consistente os padrões associados ao grupo feminino. Dessa forma, torna-se evidente a necessidade de estratégias de mitigação, como balanceamento do dataset e aprimoramento do treinamento, visando melhorar a capacidade de generalização e reduzir a disparidade de desempenho entre os grupos.

Figura 13 - MAE por gênero com desvio padrão modelo MNASNet



Fonte: Autoria Própria.


Ao analisar a Figura 13, observa-se que o modelo MNASNet apresenta MAE significativamente distinto entre os gêneros, com valor de 6,901 para indivíduos do grupo masculino e 3,722 para o grupo feminino. Esse resultado indica maior precisão do modelo na estimativa das medidas corporais femininas, evidenciando maior capacidade de generalização para esse grupo. Além disso, o desvio padrão também se mostra mais elevado para o grupo masculino (1,706) em comparação ao feminino (1,198), indicando maior variabilidade e menor consistência nas previsões realizadas para indivíduos masculinos.

A combinação de maior erro médio e maior dispersão dos resultados para o grupo masculino demonstra que o modelo não apenas apresenta menor precisão, mas também menor estabilidade nesse grupo, o que reforça a necessidade de aprimoramento do treinamento com maior representatividade de características

corporais masculinas. Em termos práticos, essa diferença implica maior risco de erro sistemático na aplicação do modelo para indivíduos masculinos, especialmente em cenários que envolvem conversão das medidas em categorias discretas, como recomendação de vestuário.

Dessa forma, os resultados evidenciam a presença de viés no modelo MNASNet, tanto em termos de precisão quanto de estabilidade, favorecendo indivíduos do grupo feminino. Adicionalmente, observa-se que a maior variabilidade nos resultados masculinos pode indicar maior diversidade não capturada adequadamente pelo modelo, sugerindo a necessidade de balanceamento do conjunto de dados e de estratégias específicas de treinamento para reduzir esse viés e melhorar a robustez geral do sistema.

Figura 14 - MAE por medida corporal durante treinamento.



Fonte: Autoria Própria.

A análise da Figura 14 demonstra que MAE (*Mean Absolute Error*) do modelo MNASNet apresenta comportamento diretamente relacionado à complexidade da medida corporal estimada. Observa-se que medidas de menor dimensão e menor variabilidade geométrica, como pulso, tornozelo e antebraço, apresentam valores de erro consistentemente mais baixos ao longo do treinamento, além de menor oscilação entre as épocas, indicando maior facilidade de aprendizado e maior estabilidade nas previsões. Em contrapartida, medidas de maior dimensão, como peito, quadril e

largura de ombros, apresentam maiores valores de erro e maior variabilidade ao longo do treinamento, evidenciando maior dificuldade do modelo em capturar corretamente essas características.

Esse comportamento pode ser explicado pela maior complexidade espacial associada às regiões corporais de maior volume, que sofrem maior influência de fatores como variação antropométrica, postura, perspectiva da imagem e tipo de vestimenta. Como consequência, o modelo apresenta maior dificuldade de generalização para essas medidas, resultando em curvas de erro mais instáveis e com picos expressivos ao longo das épocas. Adicionalmente, observa-se que, embora todas as medidas apresentem tendência de redução inicial do erro, as medidas mais complexas tendem a convergir para patamares mais elevados, o que reforça a limitação do modelo nessas regiões.

Para fins deste trabalho, optou-se pela utilização das medidas de torax, quadril e cintura como referência para estimativa de tamanho de vestuário, apesar de apresentarem maior erro, por serem diretamente relacionadas às tabelas comerciais das peças. No entanto, os resultados indicam que essas medidas representam um desafio relevante para o modelo, influenciando diretamente a precisão final do sistema. Dessa forma, conclui-se que o desempenho do modelo não é uniforme entre as diferentes partes do corpo, sendo dependente da complexidade da medida estimada, o que reforça a necessidade de estratégias específicas de aprimoramento para regiões corporais mais críticas.

Tabela 4 - Resultados obtidos do MNASNet V2 para torax da camisa Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	92	102	P	M	0	-10
homem 2	92	109	P	GG	0	-17
homem 3	96	107	P	G	0	-11
mulher 1	88	90	PP	PP	1	-2
mulher 2	85	86	PP	PP	1	-1
mulher 3	88	82	PP	PP	1	6

Taxa de acerto: 50%
 MAE geral: 7,8
 MAE masculino: 12,7
 MAE feminino: 2,9

Tabela 5 - Resultados obtidos do MNASNet V2 para cintura da camisa Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	74	PP	PP	1	5
homem 2	86	101	P	GG	0	-15
homem 3	88	79	P	PP	0	9
mulher 1	72	80	out	out	-	-8
mulher 2	72	73	out	out	-	-1
mulher 3	77	69	PP	PP	1	8

Taxa de acerto: 50%

MAE geral: 7,7

MAE masculino: 9,7

MAE feminino: 5,7

Out: Termo escolhido para identificar as medidas que ficaram abaixo da tabela mínima do fabricante.

Ao avaliar a assertividade do modelo MNASNet V2 para camisas da marca Insider, conforme apresentado na Tabela 4 e Tabela 5, observa-se desempenho limitado tanto na estimativa das medidas quanto na conversão para as categorias de tamanho. A métrica de MAE geral, MAE para o grupo masculino e MAE para o grupo feminino foi calculado de acordo com a equação 1 da sessão 3.3.2. Para a medida de tórax (Tabela 4), o modelo apresentou taxa de acerto de 50%, com desempenho significativamente distinto entre os grupos analisados: enquanto todos os três indivíduos femininos foram corretamente classificados, nenhum dos indivíduos masculinos foi classificado corretamente. Essa discrepância também se reflete nos erros médios, com MAE aproximado de 3 cm para o grupo feminino e 12 cm para o grupo masculino, evidenciando forte viés do modelo e menor capacidade de generalização para indivíduos do sexo masculino. Além disso, os erros observados nos indivíduos masculinos são de grande magnitude, alcançando diferenças de até 17 cm, o que resulta em mudanças significativas de categoria de tamanho, como transições de “P” para “GG”.

Para a medida da cintura (Tabela 5), o modelo manteve desempenho semelhante em termos de taxa de acerto (50% entre os casos válidos), porém com erro médio elevado (MAE de 7,7 cm). Destaca-se que dois dos três indivíduos femininos apresentaram valores reais abaixo do intervalo mínimo da tabela da marca, sendo classificadas como “out”, o que não configura falha do modelo, mas limitação da cobertura da tabela de tamanhos da fabricante. Considerando apenas os quatro casos classificáveis, o modelo obteve dois acertos, distribuídos entre um indivíduo masculino e um feminino, indicando ausência de viés evidente nessa medida

específica. Entretanto, os erros nas demais indivíduos permanecem elevados, com diferenças que chegam a 15 cm, impactando diretamente a confiabilidade da recomendação.

Em conjunto, os resultados demonstram que o modelo MNASNet V2 apresenta desempenho heterogêneo tanto em função da medida corporal quanto do perfil dos indivíduos, com destaque para o elevado erro e baixa robustez na estimativa de medidas para indivíduos masculinos na região do tórax. Além disso, observa-se que a limitação da tabela de tamanhos da marca influencia diretamente a aplicabilidade prática dos resultados, especialmente nos casos em que os indivíduos se encontram fora dos intervalos definidos. Esses achados reforçam a necessidade de aprimoramento do modelo, tanto por meio de balanceamento do conjunto de dados quanto pela adoção de estratégias específicas para reduzir erros em medidas críticas e melhorar a generalização entre diferentes perfis corporais.

Tabela 6 - Resultados obtidos do MNASNet V2 para cintura do short Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	74	P	P	1	5
homem 2	86	101	M	GG	0	-15
homem 3	88	79	M	P	0	9
mulher 1	72	80	P	P	1	-8
mulher 2	72	73	out	out	-	-1
mulher 3	77	69	out	out	-	8

Taxa de acerto: 50%
 MAE geral: 7,7
 MAE masculino: 9,7
 MAE feminino: 5,7

Tabela 7 - Resultados obtidos do MNASNet V2 para quadril do short Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	95	106	P	M	0	-11
homem 2	98	111	P	G	0	-13
homem 3	94	107	P	M	0	-13
mulher 1	94	96	P	P	1	-2
mulher 2	94	104	P	M	0	-10
mulher 3	92	103	P	M	0	-11

Taxa de
 acerto: 17%
 MAE geral: 10,1
 MAE masculino: 12,4
 MAE feminino: 7,7

A análise dos resultados apresentados na Tabela 6 e Tabela 7 evidencia limitações relevantes no desempenho do modelo MNASNet V2 para recomendação de shorts da marca Insider, especialmente quando consideradas diferentes regiões corporais. Para a medida de cintura (Tabela 6), o modelo apresentou MAE elevado (7,7 cm) e taxa de acerto de 50% entre os casos classificáveis. Observa-se, ainda, que duas instâncias femininas apresentaram valores abaixo do intervalo mínimo da tabela da marca, sendo classificadas como “out”, o que representa uma limitação da cobertura da tabela e não necessariamente da estimativa do modelo. Nos casos restantes, o modelo obteve desempenho moderado, acertando um indivíduo masculino e um feminino; no entanto, os erros observados atingem magnitudes significativas, de até 15 cm, resultando em alterações relevantes na categoria de tamanho.

Em contraste, para a medida de quadril (Tabela 7), o modelo apresentou desempenho substancialmente inferior, com MAE elevado (10,1 cm) e taxa de acerto de apenas 17%. Nesse cenário, o modelo foi capaz de classificar corretamente apenas um indivíduo, enquanto nos demais casos foram observados erros expressivos, frequentemente superiores a 10 cm, levando a classificações incorretas de tamanho. Esses resultados indicam maior dificuldade do modelo em estimar medidas relacionadas ao quadril, região que, conforme observado anteriormente, apresenta maior complexidade geométrica e variabilidade.

De forma geral, os resultados evidenciam que o desempenho do modelo MNASNet V2 é heterogêneo e dependente da medida corporal analisada, com desempenho apenas moderado para a cintura e significativamente reduzido para o quadril. Esse comportamento sugere limitação na capacidade de generalização do modelo para regiões corporais mais complexas, impactando diretamente sua aplicabilidade prática na recomendação de vestuário. Assim, conclui-se que, para o contexto analisado, a estimativa do quadril constitui um fator crítico de erro, exigindo estratégias específicas de aprimoramento do modelo, tais como enriquecimento do conjunto de dados e ajustes no processo de treinamento para melhor capturar variações dessa região corporal.

Tabela 8 - Resultados obtidos do MNASNet V2 para torax das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	92	102	M1	G1	0	-10
homem 2	92	109	M1	GG1	0	-17
homem 3	96	107	M2	G2	0	-11
mulher 1	88	90	P2	P2	1	-2
mulher 2	85	86	P1	P1	1	-1
mulher 3	88	82	P2	PP	0	6

Taxa de acerto: 33%

MAE geral: 7,8

MAE masculino: 12,7

MAE feminino: 2,9

Tabela 9 - Resultados obtidos do MNASNet V2 para cintura das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	74	M2	M1	0	5
homem 2	86	101	G2	GL1	0	-15
homem 3	88	79	G2	M2	0	9
mulher 1	72	80	P2	M2	0	-8
mulher 2	72	73	P2	P2	1	-1
mulher 3	77	69	M2	P2	0	8

Taxa de acerto: 17%

MAE geral: 7,7

MAE masculino: 9,7

MAE feminino: 5,7

Tabela 10 - Resultados obtidos do MNASNet V2 para quadril das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	95	106	P1	M2	0	-11
homem 2	98	111	P2	G1	0	-13
homem 3	94	107	P1	M2	0	-13
mulher 1	94	96	P1	P1	1	-2
mulher 2	94	104	P1	M1	0	-10
mulher 3	92	103	PP	M1	0	-11

Taxa de acerto: 17%

MAE geral: 10,1

MAE masculino: 12,4


MAE feminino: 7,7

A análise dos resultados obtidos para as roupas da marca Renner, apresentados na Tabela 8, Tabela 9 e Tabela 10, demonstra comportamento consistente com o observado anteriormente para as peças da marca Insider, embora com algumas diferenças relevantes na taxa de acerto.

No entanto, ao analisar a conversão dessas medidas em categorias de tamanho, observa-se redução na taxa de acerto para as roupas da Renner em comparação com as da Insider. Para a medida de tórax (Tabela 8), o modelo obteve taxa de acerto de 33%, acertando apenas duas instâncias femininas, enquanto para a Insider haviam sido observados três acertos no mesmo grupo. Para a medida da cintura (Tabela 9), a taxa de acerto foi ainda mais reduzida (17%), com apenas um acerto, inferior ao desempenho obtido para a Insider, que já apresentava resultados limitados, porém ligeiramente superiores. De forma semelhante, na medida de quadril (Tabela 10), o modelo manteve baixo desempenho, com taxa de acerto de 17%, acertando apenas uma instância feminina, comportamento equivalente ao observado para a Insider, porém ainda indicando limitação significativa do modelo nessa região corporal.

4.2.3 Resultados obtidos do SnapMeasurementAI

Figura 15 - MAE por gênero com desvio padrão modelo SnapMeasurementAI.



Fonte: Autoria Própria.

A análise dos dados do modelo SnapMeasurementAI observados na Figura 15 demonstra que o MAE (*Mean Absolute Error*) apresenta valores próximos entre os gêneros, com aproximadamente 4,24 cm para indivíduos do sexo masculino e 4,49 cm para indivíduos do sexo feminino. Essa diferença reduzida indica ausência de viés significativo no desempenho do modelo em relação ao gênero. Além disso, os valores de desvio padrão são semelhantes entre os grupos (1,066 para masculino e 0,950 para feminino), evidenciando um comportamento consistente e estável. Observa-se também que a variabilidade do erro ocorre mais em nível individual do que entre

grupos, indicando que o modelo apresenta boa capacidade de generalização. Em comparação com outros modelos analisados, o SnapMeasurementAI demonstra maior equilíbrio e robustez, embora ainda apresente limitações inerentes ao erro médio observado.

Tabela 11 - Resultados obtidos do SnapMeasurementAI para torax e camisa Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	92	93	P	P	1	-1
homem 2	92	94	P	P	1	-2
homem 3	96	102	P	M	0	-6
mulher 1	88	94	PP	P	0	-6
mulher 2	85	89	PP	PP	1	-4
mulher 3	88	89	PP	PP	1	-1

Taxa de acerto: 67%
 MAE geral: 3,5
 MAE masculino: 3,1
 MAE feminino: 4,0

Os resultados apresentados na Tabela 11 demonstram que o modelo SnapMeasurementAI apresentou MAE de 3,5 cm e taxa de acerto de 67% na classificação de tamanhos. A análise por gênero indica desempenho equivalente, com taxa de acerto de 66,7% tanto para indivíduos do sexo masculino quanto para o sexo feminino, evidenciando ausência de viés na classificação. Observa-se que os erros ocorreram em casos específicos, principalmente quando a diferença entre o valor real e o previsto atingiu aproximadamente 6 cm, resultando em mudança de categoria de tamanho. Além disso, nota-se uma tendência do modelo em superestimar as medidas corporais, evidenciada pela predominância de diferenças negativas. Esses resultados indicam que, embora o modelo apresente boa precisão na estimativa numérica, a conversão das medidas em categorias de tamanho constitui o principal fator limitante para sua aplicação prática.

Tabela 12 - Resultados obtidos do SnapMeasurementAI para cintura e camisa Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	85	PP	P	0	-6
homem 2	86	84	P	PP	0	2
homem 3	88	96	P	G	0	-8
mulher 1	72	87	out	out	-	-15
mulher 2	72	85	out	out	-	-13
mulher 3	77	83	PP	PP	1	-6

Taxa de acerto: 25%

MAE geral: 8,4

MAE masculino: 5,4

MAE feminino: 11,3

Complementando a análise dos resultados obtidos para a medida de tórax, a Tabela 12 apresenta o desempenho do modelo SnapMeasurementAI na estimativa da circunferência da cintura e sua conversão para tamanhos de camisetas da marca Insider. Observa-se uma queda significativa de desempenho, com MAE de 8,4 cm e taxa de acerto de apenas 25% entre os casos válidos.

Destaca-se que dois dos seis casos foram classificados como “out”, não devido a falhas do modelo, mas em razão de os valores reais de medida estarem abaixo do intervalo mínimo contemplado pela tabela de tamanhos da fabricante. Esse fato evidencia uma limitação do sistema de classificação adotado, e não necessariamente da estimação numérica realizada pelo modelo.

Verifica-se também a ocorrência de erros de grande magnitude, superiores a 10 cm, indicando limitações na modelagem da região da cintura. Assim como observado na análise anterior, o modelo apresenta tendência de superestimar as medidas corporais, comportamento que se mostra ainda mais acentuado para essa região anatômica.

Adicionalmente, observa-se baixa confiabilidade na conversão das medidas em categorias de tamanho, com apenas um acerto entre os casos válidos, indicando alta sensibilidade da classificação a variações nas medidas estimadas.

Em conjunto, os resultados demonstram que o desempenho do modelo depende da região corporal analisada, apresentando comportamento mais consistente para o tórax e significativamente inferior para a cintura. Esses achados evidenciam que a aplicabilidade prática do modelo para recomendação de vestuário

está condicionada tanto à precisão da estimativa quanto à compatibilidade entre as medidas dos indivíduos e os intervalos definidos pelas tabelas comerciais, como as adotadas pela marca Insider.

Tabela 13 - Resultados obtidos do SnapMeasurementAI para cintura e short Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	85	P	P	1	-6
homem 2	86	84	M	M	1	2
homem 3	88	96	M	G	0	-8
mulher 1	72	87	P	M	0	-15
mulher 2	72	85	out	out	-	-13
mulher 3	77	83	out	out	-	-6

Taxa de acerto: 50%
 MAE geral: 8,4
 MAE masculino: 5,4
 MAE feminino: 11,3

Tabela 14 - Resultados obtidos do SnapMeasurementAI para quadil e short Insider

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	95	92	P	P	1	3
homem 2	98	91	P	P	1	7
homem 3	94	100	P	M	0	-6
mulher 1	94	97	P	P	1	-3
mulher 2	94	93	P	P	1	0
mulher 3	92	89	P	P	1	3

Taxa de acerto: 83%
 MAE geral: 3,7
 MAE masculino: 5,5
 MAE feminino: 1,9

A análise dos resultados apresentados na Tabela 13 e Tabela 14 evidencia diferenças significativas no desempenho do modelo SnapMeasurementAI ao estimar medidas corporais para recomendação de shorts da marca Insider, em função da região anatômica avaliada. Para a medida de cintura, observa-se um MAE elevado (8,4 cm) e taxa de acerto de 50% entre os casos válidos, além da ocorrência de indivíduos fora do intervalo mínimo da tabela da fabricante, o que limita sua classificação. Mesmo entre os casos classificáveis, verificam-se erros relevantes, com diferenças que chegam a 15 cm, resultando em mudanças incorretas de categoria, como na transição de tamanhos médios para grandes. Em contraste, para a medida de quadril, o modelo apresenta desempenho significativamente superior, com MAE

reduzido (3,7 cm) e alta taxa de acerto (83%), demonstrando maior consistência e confiabilidade nas previsões. Nota-se ainda que, enquanto a medida de cintura apresenta alta sensibilidade a variações e maior impacto na classificação final, a medida de quadril mostra-se mais estável e menos suscetível a erros críticos. Dessa forma, os resultados indicam que o modelo apresenta comportamento heterogêneo conforme a região corporal, sendo mais adequado para aplicação prática quando a recomendação de tamanho é baseada no quadril, ao passo que a utilização da cintura constitui um fator limitante relevante no contexto de recomendação de shorts da marca Insider.

Tabela 15 - Resultados obtidos do SnapMeasurementAI para torax das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	92	93	M1	M1	1	-1
homem 2	92	94	M1	M2	0	-2
homem 3	96	102	M2	G1	0	-6
mulher 1	88	94	P2	M2	0	-6
mulher 2	85	89	P1	P2	0	-4
mulher 3	88	89	P2	P2	1	-1

Taxa de acerto: 33%

MAE geral: 3,5

MAE masculino: 3,1

MAE feminino: 4,0

Tabela 16 - Resultados obtidos do SnapMeasurementAI para cintura das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	79	85	M2	G2	0	-6
homem 2	86	84	G2	G1	0	2
homem 3	88	96	G2	GG2	0	-8
mulher 1	72	87	P2	G2	0	-15
mulher 2	72	85	P2	P2	1	-13
mulher 3	77	83	M2	G1	0	-6

Taxa de acerto: 17%

MAE geral: 8,4

MAE masculino: 5,4

MAE feminino: 11,3

Tabela 17 - Resultados obtidos do SnapMeasurementAI para quadil das camisas/short Renner

Indivíduo	Real	Previsto	Medida Real	Medida Prevista	acerto	Diferença
homem 1	95	92	P1	PP	0	3
homem 2	98	91	P2	PP	0	7
homem 3	94	100	P1	M1	0	-6
mulher 1	94	97	P1	P2	0	-3
mulher 2	94	93	P1	P1	1	0
mulher 3	92	89	PP	PP	1	3

Taxa de acerto: 33%

MAE geral: 3,7

MAE masculino: 5,5

MAE feminino: 1,9

A análise dos resultados obtidos para as roupas da marca Renner (Tabela 15, Tabela 16 e Tabela 17) evidencia desempenho inferior do modelo SnapMeasurementAI em comparação com os resultados observados para as peças da marca Insider. Para a medida de tórax, o modelo apresentou MAE de 3,5 cm, valor semelhante ao obtido anteriormente com camisas Insider; no entanto, a taxa de acerto foi significativamente menor (33%), indicando que, embora a precisão numérica da estimativa tenha se mantido, a conversão para os tamanhos comerciais da Renner foi menos eficaz. Esse comportamento sugere maior sensibilidade do sistema de classificação da marca, no qual pequenas diferenças nas medidas resultam em mudanças de categoria mais frequentes.

Para a medida de cintura, o desempenho do modelo apresentou queda acentuada, com MAE elevado (8,4 cm) e taxa de acerto de apenas 17%, inferior ao já limitado desempenho observado para as roupas Insider. Observa-se que erros de maior magnitude, como diferenças superiores a 10 cm, impactam diretamente na classificação, resultando em mudanças significativas de tamanho (por exemplo, P2 para G2). Esses resultados indicam que a tabela de medidas da Renner, assim como observado parcialmente na Insider, apresenta elevada sensibilidade a variações dimensionais na região da cintura, agravando o impacto dos erros do modelo.


Em relação à medida de quadril, embora o modelo tenha apresentado MAE reduzido (3,7 cm), similar ao desempenho obtido com shorts da Insider, a taxa de acerto permaneceu limitada (33%), consideravelmente inferior aos 83% observados anteriormente. Esse comportamento reforça que o desempenho do sistema não

depende exclusivamente da precisão numérica da estimativa, mas também da forma como cada marca estrutura suas faixas de tamanho. Assim, conclui-se que, enquanto o modelo SnapMeasurementAI apresenta desempenho relativamente consistente na estimativa de medidas, sua aplicação prática na recomendação de vestuário é fortemente influenciada pela tabela de tamanhos adotada, sendo mais eficaz para as peças da marca Insider do que para as da Renner.

4.3 ANÁLISE COMPARATIVA

4.3.1 Boxplot do Erro (MAE)

Figura 16 – Boxplot do MAE por gênero para MNASNet



Fonte: Autoria Própria.


O boxplot apresentado na Figura 16 permite uma análise mais completa do MAE, evidenciando não apenas os valores centrais, mas também a dispersão e a variabilidade dos dados para cada grupo. Observa-se que o grupo feminino apresenta valores de erro mais concentrados, com menor amplitude interquartil e ausência de pontos extremos significativos, indicando maior consistência nas estimativas realizadas pelo modelo.

Em contraste, o grupo masculino apresenta maior dispersão dos dados, com distribuição mais ampla e presença de valores mais elevados de erro, o que demonstra maior variabilidade nas previsões. Essa característica indica que, além de apresentar erro médio superior, o modelo também se comporta de forma menos

estável para o grupo masculino, produzindo resultados menos previsíveis e mais dependentes das condições específicas de cada amostra.

Esses resultados reforçam as análises anteriores, evidenciando a presença de viés no modelo MNASNet, tanto em termos de precisão quanto de estabilidade. Do ponto de vista prático, essa maior variabilidade implica maior risco de erros críticos na estimativa para indivíduos do grupo masculino, especialmente em aplicações que envolvem a conversão das medidas em categorias discretas, como recomendação de vestuário, nas quais pequenas variações podem resultar em classificações incorretas.

Figura 17 – Boxplot do MAE por gênero para SnapMeasurementAI



Fonte: Autoria Própria.

O boxplot apresentado na Figura 17, diferentemente do observado no MNASNet, nota-se que, as distribuições de erro entre os dois grupos apresentam forte sobreposição: as medianas são próximas e as caixas (intervalos interquartis) ocupam faixas semelhantes do eixo vertical, sugerindo que o desempenho do modelo é mais equilibrado entre os gêneros no conjunto avaliado.

Além disso, a amplitude interquartil e o alcance dos “bigodes” (variabilidade) também se mostram comparáveis entre masculino e feminino, indicando que o SnapMeasurementAI tende a manter estabilidade semelhante nos dois grupos. Embora haja variação individual (pontos dentro de cada grupo), não se observa o mesmo padrão de “separação” visto no MNASNet, onde o masculino concentrava erros mais altos e maior dispersão. Em termos práticos, esse comportamento sugere


menor evidência de viés por gênero no SnapMeasurementAI, reduzindo a probabilidade de que um grupo seja sistematicamente mais penalizado em aplicações de recomendação de vestuário.

Por fim, é importante registrar que a amostra por grupo é pequena (poucos indivíduos por gênero), o que limita inferências estatísticas mais fortes. Ainda assim, como evidência visual qualitativa, a Figura 13 reforça a conclusão de que o SnapMeasurementAI apresenta distribuição de erros mais homogênea entre os gêneros quando comparado ao MNASNet, o que é desejável quando se busca maior equidade e previsibilidade do sistema no uso prático.

4.3.2 Pontos fortes e fracos de cada abordagem.

A seguir, a Figura 18 comparativa das métricas de MAE dentre os seis indivíduos e ambos os modelos.

Figura 18 - MAE por indivíduo para cada modelo



Fonte: Autoria Própria.

A partir dos resultados apresentados na seção 4.14.1 e 4.1, observa-se que o modelo MNasNet demonstrou desempenho superior na estimativa para o público feminino, com um MAE de 3,72 cm, vencendo em 67% dos indivíduos femininos, enquanto o SnapMeasurementAI obteve MAE de 4,49 cm nesse mesmo grupo. Isso sugere que o MNasNet pode ser mais sensível às características morfológicas das mulheres, possivelmente devido à maior capacidade de extração de detalhes do modelo. Em contrapartida, o SnapMeasurementAI apresentou melhor desempenho no

grupo masculino, com MAE de 4,24 cm contra 6,90 cm do MNasNet, indicando que sua arquitetura pode ser mais eficiente para padrões encontrados nesse segmento.

No resultado geral, o SnapMeasurementAI ainda mantém vantagem, com uma diferença de 0,94 cm em relação ao MNasNet, mostrando maior consistência e robustez, vencendo em 67% dos casos, quando se considera a amostra total. Entre os pontos fortes do MNasNet, destaca-se sua precisão para mulheres, o que pode ser explorado em contextos em que esse público é predominante. Já o SnapMeasurementAI apresenta como principal vantagem sua estabilidade e desempenho superior para homens e no resultado geral, sendo mais indicado para aplicações abrangentes.

Em relação aos pontos fracos, o MNasNet apresenta limitação significativa ao lidar com dados masculinos, sugerindo necessidade de ajustes ou customizações para esse perfil, como é possível observar por exemplo na medida do tórax da Tabela 4, onde as mulheres apresentam erro médio de 3 cm enquanto entre os homens existe erro de até 17 cm. O SnapMeasurementAI, por sua vez, tem desempenho inferior para mulheres, o que pode impactar negativamente experiências em nichos específicos.

4.3.3 Diferenças nos resultados e implicações práticas para o e-commerce.

A análise comparativa entre os modelos MNasNet e SnapMeasurementAI revela diferenças substanciais de desempenho que impactam diretamente as estratégias e operações do e-commerce, especialmente em soluções de recomendação de tamanhos e personalização de produtos.

O MNasNet se destaca pela precisão na estimativa de medidas para o público feminino. Essa capacidade pode ser explorada em lojas virtuais que atendem predominantemente a este público, favorecendo a redução de trocas e devoluções relacionadas ao ajuste de roupas. Por outro lado, o SnapMeasurementAI apresenta robustez e estabilidade superiores ao lidar com dados masculinos e na amostra geral, tornando-se uma alternativa mais indicada para plataformas de e-commerce com diversidade de público ou onde a padronização do desempenho é prioritária.

As implicações práticas dessas diferenças são significativas: a escolha do modelo deve considerar não apenas o perfil demográfico dos clientes, mas também a experiência desejada, uma vez que a precisão nas recomendações pode aumentar a satisfação, fidelização e eficiência logística. No entanto, ambos os modelos

apresentam limitações; o MNasNet requer ajustes para melhorar seu desempenho no segmento masculino, enquanto o SnapMeasurementAI pode comprometer a experiência de nichos específicos, como o feminino, se utilizado de forma genérica. A adoção em ambientes reais demanda avaliação criteriosa dos datasets utilizados, integração com sistemas de gestão e atenção à escalabilidade, para garantir que as vantagens técnicas se traduzam em benefícios práticos. Além disso, a aplicação de modelos de IA na visão gráfica do e-commerce abre caminho para novas funcionalidades, como sugestões personalizadas e experiências de compra mais intuitivas, reforçando o potencial de inovação, mas também exigindo um compromisso com a equidade e a precisão nas recomendações para públicos diversos.

4.3.4 Barreiras técnicas e científicas ainda presentes.

Ao analisar os dados apresentados, observa-se que o desempenho dos modelos MNasNet e SnapMeasurementAI revela barreiras técnicas e científicas importantes para aplicação no e-commerce. O MAE do MNasNet para mulheres (3,72) indica alta precisão nesse nicho, porém sua performance inferior para homens (MAE de 6,90) evidencia limitações na generalização do modelo. Por outro lado, o SnapMeasurementAI, apesar de apresentar maior estabilidade nos resultados gerais (MAE de 4,24 para homens e 4,49 para mulheres), ainda não atinge o mesmo nível de precisão para o público feminino, sugerindo dificuldades no ajuste fino para diferentes perfis morfológicos.

Essas métricas reforçam desafios persistentes, como a necessidade de modelos que sejam igualmente eficientes para ambos os gêneros, evitando vieses e inconsistências nas recomendações. Além disso, a diferença de desempenho entre os grupos evidencia a importância de datasets diversificados e representativos, bem como o desenvolvimento de técnicas de adaptação e personalização. O equilíbrio entre precisão, estabilidade e equidade permanece como uma barreira científica, impactando diretamente a experiência do usuário e a eficácia operacional no e-commerce.

5 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho investigou a aplicação de técnicas de visão computacional e inteligência artificial para a estimativa de medidas corporais, com foco na recomendação de tamanhos de vestuário. Foi realizada uma análise comparativa entre o modelo MNASNet, treinado com dados reais, e a solução SnapMeasurementAI, disponível gratuitamente. A partir dos experimentos conduzidos, envolvendo diferentes medidas corporais, peças de roupa e tabelas de tamanhos de distintas marcas, foi possível avaliar não apenas a precisão dos modelos, medida por meio do MAE, mas também sua efetividade prática na conversão dessas estimativas em categorias de tamanho.

Os resultados demonstraram diferenças no desempenho dos modelos em função da medida corporal analisada e do grupo avaliado. Considerando o desempenho por gênero, o MNASNet apresentou menor erro médio para o grupo feminino, com MAE de 3,72 cm, enquanto o grupo masculino apresentou MAE de 6,90 cm. Já o SnapMeasurementAI apresentou valores mais próximos entre os gêneros, com MAE de 4,49 cm para o grupo feminino e 4,24 cm para o grupo masculino, indicando maior equilíbrio entre os grupos avaliados. Em relação à recomendação de tamanhos, o MNASNet alcançou taxas de acerto de 50% para tórax em camisas, 50% para cintura em camisas e 50% para cintura em shorts, porém apresentou apenas 17% de acerto para quadril em shorts. Por sua vez, o SnapMeasurementAI obteve 67% de acerto para tórax em camisas, 25% para cintura em camisas, 50% para cintura em shorts e 83% para quadril em shorts. Esses resultados evidenciam que o SnapMeasurementAI apresentou melhor desempenho global e maior estabilidade entre os grupos avaliados, enquanto o MNASNet apresentou resultados competitivos em cenários específicos, principalmente para o grupo feminino, mas com maior sensibilidade às variações presentes na amostra analisada.

Apesar dos avanços observados, os resultados indicam que a aplicação direta dos modelos em cenários reais de recomendação de vestuário ainda apresenta limitações significativas. Verificou-se que erros relativamente pequenos nas medidas estimadas podem resultar em classificações incorretas de tamanho, principalmente devido à sensibilidade das tabelas de medida adotadas pelas diferentes marcas. Além disso, constatou-se que o desempenho varia não apenas entre modelos, mas também em função da região do corpo analisada, sendo observados erros mais elevados em

medidas como cintura e quadril, que são críticas para a escolha de peças como shorts. Outro fator relevante é a influência das próprias tabelas comerciais, que podem não cobrir adequadamente todos os perfis corporais, impactando diretamente a taxa de acerto. Dessa forma, conclui-se que, embora os modelos apresentem potencial, sua utilização em aplicações reais deve ser acompanhada de ajustes adicionais, tanto na modelagem quanto na definição das estratégias de conversão para tamanho.

Como continuidade deste estudo, recomenda-se o aprimoramento do modelo MNASNet a partir de estratégias voltadas ao aumento de sua robustez, à redução dos vieses observados e à ampliação de sua capacidade de generalização. Nesse sentido, uma primeira medida consiste no balanceamento do conjunto de dados e na ampliação da representatividade de diferentes perfis corporais, especialmente do grupo masculino, uma vez que os resultados evidenciaram maior dificuldade do modelo em estimar medidas para esse segmento. Além disso, torna-se pertinente explorar arquiteturas mais robustas e estratégias de treinamento mais avançadas, incluindo técnicas de aumento de dados, ajuste de hiperparâmetros e validação cruzada estratificada, de modo a identificar e corrigir possíveis vieses associados a gênero, faixa etária ou biotipo.

Entre as alternativas mais promissoras para a melhoria dos resultados, destacam-se: a realização de testes de abrangência morfológica com bases de dados ampliadas, contemplando diferentes corpos, idades e perfis antropométricos; a implementação de validação cruzada estratificada, permitindo avaliar separadamente o desempenho do modelo em grupos distintos; o ajuste sistemático de hiperparâmetros, como camadas, funções de ativação e algoritmos de otimização; e o fine-tuning com um conjunto de dados masculinos mais robusto, com o objetivo de reduzir o erro médio absoluto nesse segmento. Também se mostra relevante a personalização baseada em clusters morfológicos, por meio do treinamento de versões customizadas do modelo para diferentes grupos de usuários, bem como o uso de data augmentation direcionado, simulando variações corporais específicas para ampliar a diversidade do treinamento. Paralelamente, outra frente importante de evolução consiste na melhoria da etapa de conversão das medidas estimadas em tamanhos de vestuário, incorporando abordagens probabilísticas ou sistemas capazes de considerar incertezas e intervalos de confiança nas previsões.

Por fim, recomenda-se a ampliação do conjunto de testes, com maior número de indivíduos e maior diversidade de cenários, a fim de validar de maneira mais robusta a aplicabilidade dos modelos em contextos reais de e-commerce. Em conjunto, essas estratégias podem contribuir para superar barreiras científicas e técnicas ainda presentes, promovendo maior equidade nas recomendações, melhor desempenho preditivo e maior aderência das soluções às demandas de públicos diversos.

REFERÊNCIAS

- CHEN, Liang-Chieh et al. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: European Conference on Computer Vision (ECCV), 2018.
- COSTA, Luíza. Como a Inteligência Artificial Transforma o E-commerce: 6 Aplicações e Exemplos para Otimizar Vendas e Operações. Cleverence, 2024. Disponível em: <<https://www.cleverence.com/articles/blogs-de-negocios/artificial-intelligence-in-ecommerce-6-use-cases-examples-4839201/>>. Acesso em: 26 out. 2025.
- COUTO, Marcela. Inteligência artificial no e-commerce: 16 aplicações úteis. Nuvemshop, 2025. Disponível em: <<https://www.nuvemshop.com.br/blog/inteligencia-artificial-ecommerce/>>. Acesso em: 26 out. 2025.
- DATACAMP. *Erro absoluto médio explicado: medindo a precisão do modelo*. Disponível em: <<https://www.datacamp.com/pt/tutorial/mean-absolute-error>>. Acesso em: 13 maio 2026.
- DIBRA, Endri et al. Hs-nets: Estimating human body shape from silhouettes with convolutional neural networks. In: International Conference on 3D Vision (3DV), 2016.
- FAMA, Josué Sá. Inteligência artificial e privacidade: implicações legais e éticas na era digital. Revista Científica Multidisciplinar Núcleo do Conhecimento, 2025. Disponível em: <<https://www.nucleodoconhecimento.com.br/wp-content/uploads/2025/01/implicacoes-legais.pdf>>. Acesso em: 27 out. 2025.
- FERREIRA, Diego Ribeiro de Meneses. Proteção do indivíduo: o embate entre privacidade e direito de imagem na era digital. Revista Tópicos, 2024. Disponível em: <<https://revistatopicos.com.br/artigos/protecao-do-individuo-o-embate-entre-privacidade-e-direito-de-imagem-na-era-digital>>. Acesso em: 27 out. 2025.
- GEEKSFORGEES. *Regression metrics*. Disponível em: <<https://www.geeksforgeeks.org/machine-learning/regression-metrics/>>. Acesso em: 13 maio 2026.
- GHOSH, Anirudha et al. Fundamental concepts of convolutional neural network. In: RECENT TRENDS AND ADVANCES IN ARTIFICIAL INTELLIGENCE AND INTERNET OF THINGS. 2020.
- HOWARD, Andrew G. et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. In: arXiv preprint arXiv:1704.04861, 2017. Disponível em: <<https://arxiv.org/abs/1704.04861>>. Acesso em: 27 nov. 2025.
- LECUN, Yann et al. Deep learning. Nature, v. 521, n. 7553, p. 436–444, 2015.
- LOPER, Matthew et al. SMPL: A skinned multiperson linear model. Transactions on Graphics (Proc. SIGGRAPH Asia), v. 34, n. 6, p. 248:1–248:16, 2015.
- NEVES, Paula. A ética da inteligência artificial: a recriação de imagens póstumas e os desafios do direito digital e direitos da personalidade. Junqueira de Carvalho e Murgel, 2023. Disponível em: <<https://jcm.adv.br/artigo/a-etica-da-inteligencia-artificial-a-recriacao-de-imagens-postumas-e-os-desafios-do-direito-digital-e-direitos-da-personalidade/>>. Acesso em: 27 out. 2025.
- OPENAI. DALL·E 3: modelo de geração de imagens por inteligência artificial. Disponível em: <https://openai.com/pt-BR/index/dall-e-3/>. Acesso em: 29 jun. 2026.
- ROTHSTEIN, Thiago Rodrigo. Visão computacional no varejo: 4 Aplicações que estão transformando o setor. Revista Varejo Brasil, 2025. Disponível em: <<https://www.revistavarejobrasil.com.br/visao-computacional-no-varejo-4-aplicacoes-que-estao-transformando-o-setor/>>. Acesso em: 26 out. 2025.

- RUIZ, Nataniel et al. Human Body Measurement Estimation with Adversarial Augmentation. In: Proceedings of the Conference on Computer Vision and Pattern Recognition, 2022. Disponível em: <<https://adversarialbodysim.github.io>>. Acesso em: 27 nov. 2025.
- SCURI, Antonio, Fundamentos da Imagem Digital. PUC-Rio - Setembro de 2002. Disponível em: <<https://web.tecgraf.puc-rio.br/~scuri/download/fid.pdf>>. Acesso em 06 de novembro de 2026.
- SMITH, Brandon M. et al. Towards accurate 3D human body reconstruction from silhouettes. In: International Conference on 3D Vision (3DV), 2019.
- TAN, Mingxing et al. MnasNet: Platform-Aware Neural Architecture Search for Mobile. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019. Disponível em: <<https://arxiv.org/abs/1807.11626>>. Acesso em: 27 nov. 2025.
- YAN, S.; WIRTA, J.; KÄMÄRÄINEN, J.-K. Silhouette body measurement benchmarks. In: International Conference on Pattern Recognition (ICPR), Milano, Italy (online), 2020.