



Universidade do Distrito Federal Professor Jorge Amaury
Escola Superior de Ciências da Saúde
Mestrado Acadêmico em Ciências da Saúde

APRIMORAMENTO DE MODELO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DE PESO CORPORAL EM PACIENTES ACAMADOS POR MEIO DE IMAGENS DE SMARTPHONES

Autor: Michel Ramos de Faria

Orientador: Prof. Dra. Ana Lúcia Ribeiro Salomon
Coorientador: Prof. Dr. Guilherme Duprat Ceniccola

Brasília – DF

2026

APRIMORAMENTO DE MODELO DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DE PESO CORPORAL EM PACIENTES ACAMADOS POR MEIO DE IMAGENS DE SMARTPHONES

Dissertação apresentada ao Programa de Pós- Graduação *Stricto Sensu* em Ciências da Saúde da Escola Superior em Ciências da Saúde, como requisito parcial para obtenção do Título de Mestre em Ciências da Saúde.

Área de Concentração:

Atenção à Saúde

Linha de Pesquisa: Ciclos da Vida e Saúde de Grupos Populacionais e Vulnerabilidades específicas

Autor: Michel Ramos de Faria

Orientador: Prof. Dra. Ana Lúcia Ribeiro Salomon
Coorientador: Prof. Dr. Guilherme Duprat Ceniccola

Brasília

2026

Ficha catalográfica

Ficha catalográfica gerada automaticamente com os dados
fornecidos pelo(a) autor(a)

F224a

FARIA, MICHEL RAMOS DE

Aprimoramento de modelo de Inteligência Artificial para
estimativa de peso corporal de pacientes acamados por meio de
imagens de smartphone / MICHEL RAMOS DE FARIA; orientadora
Ana Lúcia Ribeiro Salomon; coorientador Guilherme Duprat
Ceniccola. - Brasília, 2026.

111 p.

Dissertação (Mestrado - Programa de Pós-Graduação em
Mestrado Acadêmico em Ciências da Saúde) -- Escola
Superior de Ciências da Saúde, Universidade do Distrito
Federal.

1. Inteligência artificial. 2. Avaliação Nutricional. 3.
Antropometria. 4. Peso corporal. 5. Aprendizado de Máquina.
I. Salomon, Ana Lúcia Ribeiro, orient. II. Ceniccola,

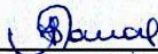
TERMO DE APROVAÇÃO

MICHEL RAMOS DE FARIA

Aprimoramento de modelo de inteligência artificial para estimativa do peso corporal em pacientes acamados por meio de imagens de smartphones

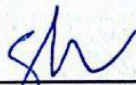
Dissertação aprovada como requisito parcial para obtenção do título de **Mestre em Ciências da Saúde**, pelo programa de Pós-Graduação *Stricto Sensu* em Ciências da Saúde – Mestrado Acadêmico - da Escola Superior de Ciências da Saúde (ESCS/UnDF).

Aprovada em: 26/05/2026.



Prof.ª Dr.ª Ana Lúcia Ribeiro Salomon
Mestrado Acadêmico em Ciências da Saúde
Escola Superior de Ciências da Saúde (ESCS/UnDF)
Orientadora

Prof. Dr. Guilherme Duprat Ceniccola
Hospital de Base do Distrito Federal
Secretaria de Saúde do Distrito Federal
Coorientador



Prof.ª Dr.ª Shila Minari Hargreaves
Mestrado Acadêmico em Ciências da Saúde
Escola Superior de Ciências da Saúde (ESCS/UnDF)
Examinadora Interna



Prof.ª Dr.ª Renata Costa Fortes
Mestrado Profissional em Ciências para a Saúde (MPCS)
Escola de Saúde Pública do Distrito Federal (ESP/DF/Fepecs)
Examinadora Externa

Dedicatória

À Fernanda, companheira de vida e de sonhos, pelo incentivo constante. Ao Martin, meu filho, por quem busco ser um profissional e uma pessoa melhor todos os dias. À minha mãe Marenilza, cujos sacrifícios e ensinamentos foram os pilares que me permitiram chegar até aqui.

Agradecimentos

A minha equipe de pesquisa, cujo trabalho foi o alicerce deste projeto. Ao especialista em IA, Dyonnatan Ferreira Maia, responsável por todo o desenvolvimento tecnológico deste projeto. Expresso minha profunda gratidão pelo apoio, empenho e parceria desde 2021, sua expertise foi o pilar fundamental para transformar esta ideia em realidade e conduzir os avanços da inteligência artificial até aqui.

Às pesquisadoras Rhaylane Gomes e Thiersy Millian, pelo empenho excepcional e por permanecerem comigo até o final na coleta de dados. A dedicação e o rigor demonstrados por ambas foram fundamentais para a viabilidade desta pesquisa e para as etapas de desenvolvimento da IA.

À FAP-DF (Fundação de Apoio à Pesquisa do Distrito Federal) e ao programa StartBSB, pelo fomento para o desenvolvimento tecnológico e a execução deste estudo.

Aos orientadores Ana Lúcia Salomon e Guilherme Duprat, pelas contribuições ao longo deste trabalho.

A todos os pacientes que aceitaram participar deste estudo, permitindo que a coleta de dados fosse realizada para o treinamento e para o constante processo de evolução da inteligência artificial.

À Escola Pública de Saúde do DF, pelo suporte institucional para a realização desta pesquisa.

As ideias não surgem totalmente formadas. Tornam-se claras à medida que se trabalham nelas. Só é preciso começar.

Mark Zuckerberg

RESUMO

Referência: Aprimoramento de modelo de inteligência artificial para estimativa de peso corporal de pacientes acamados por meio de imagens de smartphones

Introdução: A estimativa do peso corporal em pacientes acamados representa um desafio frequente na prática hospitalar quando a aferição direta não é possível. Métodos indiretos convencionais apresentam limitações operacionais e variabilidade na precisão das estimativas, enquanto abordagens baseadas em inteligência artificial têm emergido como alternativas promissoras. **Objetivos:** Desenvolver e aprimorar um modelo de inteligência artificial para estimativa do peso corporal a partir de registros fotográficos obtidos por smartphones em ambiente hospitalar real, visando atingir proporção de estimativas com erro inferior a 10% do peso aferido (P10) superior a 70%. **Método:** Estudo transversal analítico conduzido em cinco hospitais públicos do Distrito Federal, incluindo 300 pacientes adultos hospitalizados e aproximadamente 1.300 imagens corporais. Após a aferição direta do peso corporal e da estatura, os participantes foram fotografados no leito para simular o cenário de aplicação da tecnologia. O modelo utilizou técnicas de segmentação corporal, reconstrução tridimensional, extração de atributos antropométricos e regressão para estimativa do peso corporal. O desempenho foi avaliado pela proporção de estimativas com erro inferior a 10% do peso aferido (P10), erro absoluto médio (Mean Absolute Error – MAE), coeficiente de determinação (R^2) e coeficiente de correlação intraclassa (CCI). Os resultados foram comparados ao modelo piloto previamente desenvolvido pelo grupo de pesquisa. **Resultados:** O modelo atingiu P10 de 78,7%, indicando que 78,7% das estimativas apresentaram erro inferior a 10% em relação ao peso aferido. Em comparação ao modelo piloto, observou-se redução do erro absoluto médio de 13,16 kg para 5,24 kg, com melhora média pareada de 7,93 kg. Houve ainda aumento do coeficiente de determinação de 0,388 para 0,873 e elevada concordância entre os valores estimados e aferidos (CCI = 0,93). **Conclusões:** O modelo de inteligência artificial demonstrou potencial para estimativa do peso corporal em ambiente hospitalar real utilizando smartphones. Os resultados evidenciam avanço substancial em relação ao modelo piloto e desempenho compatível com critérios contemporâneos de aceitabilidade clínica, reforçando seu potencial como ferramenta de apoio à prática multiprofissional em situações nas

quais a aferição direta do peso não é viável.

Palavras-chave: Antropometria, Avaliação Nutricional, Inteligência Artificial, Aprendizado de Máquina.

ABSTRACT

Reference: Enhancement of an artificial intelligence model for body weight estimation in bedridden patients using smartphone images

Introduction: Estimating body weight in bedridden patients remains a frequent challenge in hospital practice when direct measurement is not feasible. Conventional indirect methods present operational limitations and substantial variability in accuracy, whereas artificial intelligence–based approaches have emerged as promising alternatives. **Objectives:** To develop and improve an artificial intelligence model for body weight estimation from smartphone-acquired images obtained in a real-world hospital environment, aiming to achieve a proportion of estimates within 10% of measured body weight (P10) greater than 70%. **Methods:** This cross-sectional analytical study was conducted in five public hospitals in the Federal District of Brazil and included 300 hospitalized adults and approximately 1,300 body images. After direct measurement of body weight and height, participants were photographed in a hospital bed to simulate the intended application scenario of the technology. The model employed body segmentation, three-dimensional reconstruction, extraction of anthropometric attributes, and regression techniques to estimate body weight. Performance was evaluated using the proportion of estimates within 10% of measured body weight (P10), Mean Absolute Error (MAE), coefficient of determination (R^2), and Intraclass Correlation Coefficient (ICC). Results were compared with those of a previously developed pilot model. **Results:** The model achieved a P10 of 78.7%, indicating that 78.7% of weight estimates were within 10% of the measured body weight. Compared with the pilot model, the Mean Absolute Error decreased from 13.16 kg to 5.24 kg, corresponding to a mean paired improvement of 7.93 kg. The coefficient of determination increased from 0.388 to 0.873, and agreement between estimated and measured values was high (ICC = 0.93). **Conclusions:** The artificial intelligence model demonstrated potential for body weight estimation in a real-world hospital setting using smartphone images. The findings indicate substantial improvement compared with the pilot model and performance consistent with contemporary criteria for clinical acceptability, supporting its potential use as a tool to assist multidisciplinary clinical practice when direct body weight measurement is unavailable.

Keywords: Anthropometry; Nutritional Assessment; Artificial Intelligence; Machine Learning.

Lista de figuras

Figura 1. Precisão dos sistemas de estimativa de peso por meio de câmeras 3D utilizando a métrica P10.	14
Figura 2. Arquitetura da versão inicial desenvolvida no estudo piloto.	17
Figura 3. Controle das principais variáveis do ambiente para realização dos registros fotográficos e gravação de vídeos dos pacientes deitados na cama hospitalar (Faria et al., 2023).	25
Figura 4. Posições corporais nos cinco registros fotográficos para cada paciente (Faria et al., 2023).	26
Figura 5. Arquitetura aprimorada para estimativa do peso corporal em pacientes acamados utilizando imagens de smartphones.	30
Figura 6. Fluxograma de inclusão dos participantes e processamento das imagens corporais do estudo.	38
Figura 7. Distribuição dos participantes por sexo segundo as faixas de IMC estabelecidas no estudo.	39
Figura 8. Distribuição da idade pelas faixas de IMC estabelecidas no estudo.	40
Figura 9. Distribuição das imagens processadas segundo a posição corporal do participante.	42
Figura 10. Avaliação do modelo final: (A) valores estimados vs. aferidos; (B) análise de Bland-Altman; (C) distribuição dos erros; (D) erro vs. valor real.	47
Figura 11. Avaliação do modelo anterior: (A) valores estimados vs. aferidos; (B) análise de Bland-Altman; (C) distribuição dos erros; (D) erro vs. valor real.	48
Figura 12. Desempenho do modelo (P10) por faixa etária.	49
Figura 13. Desempenho do modelo (P10) por sexo.	49
Figura 14. Desempenho do modelo (P10) por faixas de IMC.	50
Figura 15. Desempenho do modelo (P10) segundo a posição corporal da imagem.	50
Figura 16. Matriz de confusão das classificações de IMC segundo os pontos de corte da OMS (2000) para o modelo final.	52
Figura 17A. Curvas ROC para identificação de baixo peso ($IMC < 18,5 \text{ kg/m}^2$) e de sobrepeso ($IMC \geq 25 \text{ kg/m}^2$) segundo critérios da OMS (2000).	53
Figura 17B. Curvas ROC para identificação de obesidade classe I ($IMC \geq 30 \text{ kg/m}^2$) e de obesidade classe II ($IMC \geq 35 \text{ kg/m}^2$) segundo critérios da OMS (2000).	54
Figura 17C. Curva ROC para identificação de obesidade classe III ($IMC \geq 40 \text{ kg/m}^2$) segundo critérios da OMS (2000).	55

Lista de tabelas

Tabela 1. Fórmulas preditivas para estimativa de peso corporal desenvolvidas por Chumlea et al. (1988).	7
Tabela 2. Fórmulas preditivas para estimativa de peso corporal desenvolvidas por Rabito et al. (2006).	7
Tabela 3. Caracterização comparativa da amostra entre o conjunto atual e o conjunto anterior.	41
Tabela 4. Distribuição das faixas de IMC nos conjuntos atual e anterior.	42
Tabela 5. Comparação pareada do desempenho entre o modelo final e o modelo anterior na estimativa do peso corporal.	43
Tabela 6. Desempenho do modelo final para estimativa de peso corporal segundo critérios clínicos pré-especificados.	44
Tabela 7. Métricas secundárias de desempenho, associação e concordância do modelo final para estimativa de peso corporal.	45
Tabela 8. Comparação da frequência de erros absolutos acima de limiares clínicos entre o método anterior e o modelo final.	46
Tabela 9. Resultados complementares do modelo final para estimativa do IMC.	51

Lista de abreviaturas e siglas

AJ - Altura do joelho

CA - Circunferência abdominal

CB - Circunferência do Braço

CCI - Coeficiente de Correlação Intraclasse

IMC - Índice de Massa Corporal

IA - Inteligência Artificial

MAE - Média Absoluta do Erro

MAPE - Média Percentual Absoluta do Erro

OMS - Organização Mundial da Saúde

P10 – Proporção de estimativas com erro $\leq 10\%$ do valor real.

P20 – Proporção de estimativas com erro $\leq 20\%$ do valor real.

RMSE - Raiz do Erro Quadrático Médio

R² - Coeficiente de determinação

UTI - Unidade de Terapia Intensiva

TCLE - Termo de Consentimento Livre e Esclarecido

SUMÁRIO

1.0 INTRODUÇÃO	1
2.0 REFERENCIAL TEÓRICO	5
2.1 Avaliação antropométrica de pacientes hospitalizados e acamados	5
2.2 A importância clínica da estimativa de peso de pacientes acamados	5
2.3 Limitações dos métodos tradicionais indiretos em pacientes acamados	6
2.4 Limitações econômicas e operacionais das camas hospitalares com balança integrada	9
2.5 Abordagens computacionais para estimativa antropométrica	10
2.5.1 Sensores e métodos de aquisição aplicados à estimativa antropométrica	10
2.5.2 Visão computacional e inteligência artificial na estimativa antropométrica	11
2.6 Trabalhos relacionados	13
2.7 Estudo piloto e desenvolvimento inicial da tecnologia	16
2.8 Diretrizes para desenvolvimento, validação e relato de modelos de inteligência artificial em saúde	18
3.0 JUSTIFICATIVA	19
4.0 MÉTODOS	20
4.1 Delineamento do estudo	20
4.2 Aspectos éticos	21
4.3 Cálculo amostral	21
4.4 Recrutamento e seleção da amostra	22
4.5 Logística de segurança para avaliações antropométricas	24
4.6 Avaliação antropométrica dos pacientes	24
4.7 Captura dos registros fotográficos dos pacientes e gravação dos vídeos	25
4.8 Anonimização das características faciais dos pacientes nos registros fotográficos e nos vídeos	27
4.9 Armazenamento e segurança dos registros fotográficos e dos vídeos	28
4.10 Treinamento da arquitetura de aprendizado de máquina e avaliação do desempenho do modelo computacional.	28
4.10.1 Arquitetura proposta	28
4.10.2 Pré-processamento e aumento de dados	30
4.10.3 Extração e organização dos atributos	31
4.10.4 Treinamento dos modelos regressores	31
4.10.5 Validação interna e avaliação de desempenho	32
4.11.1 Análise estatística	33
4.11.2 Interpretação das métricas utilizadas na avaliação do modelo	35
4.11.2.1 Média absoluta do erro (MAE)	35
4.11.2.2 Erro percentual absoluto médio (MAPE)	35
4.11.2.3 Raiz do erro quadrático médio (RMSE)	36
4.11.2.4 Métricas P10 e P20	36

4.11.5 Coeficiente de determinação (R^2)	36
4.11.2.6 Correlação de Pearson	37
4.11.2.7 Coeficiente de correlação intraclasse (CCI)	37
4.11.2.8 Análise de Bland-Altman	37
5.0 RESULTADOS	37
5.1 Amostra analisada e fluxo dos dados	38
5.2 Comparação com o método anterior	43
5.3 Desempenho do modelo final e avaliação da aceitabilidade clínica na estimativa de peso	43
5.4 Análises complementares	48
5.4.1 Análise por sexo, idade, faixa de IMC e posição corporal da imagem	48
5.4.2 Análise do IMC	50
6.0 DISCUSSÃO	55
6.1 Síntese dos principais achados	55
6.2 Características, heterogeneidade e representatividade do conjunto de dados em ambiente clínico real	57
6.3 Comparação com abordagens baseadas em inteligência artificial para estimativa do peso corporal: implicações para aplicabilidade clínica	58
6.4 Relevância clínica e implicações dos métodos de estimativa de peso corporal na prática multiprofissional	59
6.5 Interpretação do ganho em relação ao modelo anterior	62
6.6 Concordância e aceitabilidade clínica	62
6.7 Resultados complementares de IMC	63
6.8 Relação com Frameworks de relato	63
7.0 CONCLUSÃO	64
7.1 Conclusão	64
7.2 Limitações	64
7.3 Trabalhos futuros	65
7.4 Financiamento	67
7.5 Conflitos de interesses	67
7.6 Disponibilidade de dados	67
8.0 REFERÊNCIAS	68
APÊNDICE A - Ficha de coleta de dados	76
APÊNDICE B - Resultados individuais utilizados nas análises de desempenho do modelo anterior	77
APÊNDICE C - Resultados individuais utilizados nas análises de desempenho do modelo final	86
ANEXO I - Checklist TRIPOD+AI (2024) preenchido	95

1.0 INTRODUÇÃO

A obtenção precisa do peso corporal de pacientes acamados representa um grande desafio no ambiente hospitalar. O peso corporal é um parâmetro fundamental para os nutricionistas, pois orienta o diagnóstico nutricional, a estimativa das necessidades energéticas e proteicas, a prescrição dietética e a avaliação da eficácia da terapia nutricional (Rezende et al., 2009). No entanto, erros na estimativa dessa medida podem resultar em iatrogenias, como a subestimação do peso real do paciente. Isso pode levar a uma prescrição insuficiente de calorias e proteínas, comprometendo a recuperação nutricional e aumentando o risco de desnutrição ou a piora de um quadro já existente. Por outro lado, a superestimação do peso corporal pode resultar em uma oferta excessiva de calorias e proteínas, elevando o risco de hiperglicemia, sobrecarga metabólica, síndrome da realimentação e, em casos graves, até mesmo óbito (Da Silva et al., 2020; Monsees et al., 2025).

Para a prescrição medicamentosa pelos médicos e farmacêuticos, erros na estimativa do peso corporal também podem ter consequências graves. A subestimação pode resultar em doses insuficientes de medicamentos, reduzindo a eficácia do tratamento. Por outro lado, a superestimação pode levar à administração de doses excessivas, aumentando o risco de toxicidade e eventos adversos potencialmente fatais (Herath et al., 2023; Monsees et al., 2025; Sonar et al., 2025).

No ambiente hospitalar, a aferição direta do peso corporal pode ser inviabilizada em pacientes acamados devido a sua condição clínica ou limitações físicas. Entre os principais perfis de pacientes que não podem ser pesados diretamente estão aqueles internados em unidades de terapia intensiva sob ventilação mecânica, pacientes desnutridos com incapacidade de ficar em pé e idosos com sarcopenia. Nesses casos, métodos tradicionais como balanças tornam-se inviáveis, uma vez que exigem que o paciente permaneça em posição ortostática (Rezende et al., 2009).

Uma alternativa para a aferição direta do peso corporal é o uso de camas com balança integrada, que permitem medir o peso do paciente enquanto ele permanece deitado. No entanto, esses equipamentos apresentam limitações, como alto custo, necessidade de calibração frequente, algo muitas vezes negligenciado e baixa disponibilidade em grande parte dos hospitais brasileiros, tornando sua implementação pouco viável na realidade clínica do país (Manoj et al., 2019).

Adicionalmente, García-Pastor et al. (2015) demonstraram que, no ambiente hospitalar, entre 70% e 85% dos pacientes que estão conscientes e orientados não sabem relatar o peso corporal atual, seja por desconhecimento ou por omissão do valor real. Nesse contexto, diversos métodos indiretos são empregados para estimar o peso corporal, a altura e o IMC, auxiliando na tomada de decisões clínicas e nutricionais (Saueressig et al., 2023).

No Brasil, os métodos indiretos mais utilizados para estimar o peso corporal são as fórmulas preditivas de Chumlea (1988), desenvolvidas com base em uma população adulta norte-americana. Para estimar o peso corporal, essas fórmulas utilizam a circunferência do braço (CB) e a altura do joelho (AJ) (Saueressig et al., 2022). No entanto, estudos realizados com adultos brasileiros mostram que essas equações apresentam resultados divergentes e diferenças estatisticamente significativas em relação às medidas reais aferidas, o que dificulta sua aplicação com precisão na prática clínica (Rezende et al., 2009; Melo et al., 2014; Saueressig et al., 2023).

O método indireto denominado de “IMC visual” também tem sido amplamente utilizado nos hospitais do Brasil. Esse método é baseado na escala de silhuetas adaptada e validada por Kakeshita (2008) para estimar o peso corporal de pacientes acamados. A escala é composta por 15 cartões com figuras de silhuetas, separadas por sexo, com início no IMC 12,5 kg/m² e final no IMC de 47,5 kg/m² e com a variação de 2,5 kg/m² pontos de IMC entre cada uma delas. O nutricionista faz a inspeção visual à beira leito das proporções físicas do paciente, identifica a figura na escala que mais se aproxima, determina o IMC correspondente à figura e estima o peso corporal por meio da fórmula: $\text{Peso corporal} = \text{IMC visual} \times \text{Estatura}^2$ (Beserra, Rodrigues, Lisboa, 2011).

No estudo conduzido por Beserra, Rodrigues e Lisboa (2011), com objetivo de estimar o IMC de pacientes acamados por meio do uso de escala de silhuetas e a inspeção visual de duas nutricionistas, foram obtidas correlações de grau forte com o IMC calculado dos pacientes ($r=0,83$ e $r=0,79$; $r=0,86$ e $r=0,81$, respectivamente, todos com $p < 0,001$). Contudo, esse método depende, em grande parte, da experiência clínica do nutricionista que faz a inspeção visual, sendo que aqueles que não possuem experiência clínica suficiente estão sujeitos a cometerem erros na estimativa do peso corporal (Beserra, Rodrigues, Lisboa, 2011).

A dependência da subjetividade clínica na estimativa do peso corporal é evidenciada pelo estudo de Monsees et al. (2025). Os autores observaram que as estimativas de peso realizadas por nutricionistas e enfermeiros em unidades de terapia intensiva (UTI) apresentaram erro superior a 10% do peso real em 36% dos casos. Embora a maioria das estimativas tenha permanecido dentro dessa margem de erro, os resultados demonstram a variabilidade inerente à avaliação visual realizada por profissionais de saúde. O estudo concluiu que o peso referido pelo paciente, quando disponível, apresentou maior precisão do que a estimativa visual realizada pela equipe assistencial.

Não há consenso quanto ao melhor método para estimativa do peso corporal de pacientes acamados, pois cada método possui limitações que devem ser consideradas para o uso, como praticidade, custo, acurácia, reprodutibilidade de acordo com sexo, faixa etária, etnia e nacionalidade da população. Por se tratarem de métodos indiretos, muitas variáveis podem interferir nessas estimativas e gerarem erros de subestimação ou superestimação com consequências iatrogênicas potencialmente graves para esses pacientes, especialmente em UTI (Rezende et al., 2009; Beserra, Rodrigues, Lisboa 2011; Melo et al., 2014, Saueressig et al., 2022).

Nesse contexto, o uso da Inteligência Artificial (IA), por meio de técnicas de aprendizado de máquina, tem se destacado como uma abordagem promissora para viabilizar estimativas mais confiáveis e precisas dessas medidas antropométricas. O aprendizado de máquina consiste em treinar um modelo computacional para realizar uma tarefa específica com base em um banco de dados disponível. Durante o processo de treinamento, o modelo aprende padrões e refina suas previsões até se tornar altamente especializado na tarefa proposta. Dessa forma, a aplicação do aprendizado de máquina pode contribuir para aprimorar a estimativa do peso corporal, altura e IMC de pacientes acamados, tornando-a mais precisa e acessível na prática clínica (Habebeh, Gohel, 2021).

Nos últimos anos, com o crescente desenvolvimento de ferramentas de IA para auxiliar na resolução de problemas complexos na saúde, diversos estudos têm sido realizados com o objetivo de desenvolver alternativas tecnológicas para estimativas precisas de medidas antropométricas. As principais técnicas empregadas incluem o uso de sistemas de câmeras 3D e aprendizado profundo. Os estudos que adotaram essas abordagens demonstram resultados promissores, com todos os sistemas disponíveis superando o padrão mínimo de precisão de P10 >

70%, métrica que representa a proporção de estimativas situadas dentro de 10% do valor real. Esse critério, originalmente estabelecido para sistemas de estimativa de peso pediátrico, passou a ser adotado também em estudos de estimativa de peso em adultos, por representar um nível de precisão considerado clinicamente aceitável para minimizar erros em intervenções dependentes do peso corporal, especialmente prescrições medicamentosas. Segundo Wells et al. (2024), esse limiar foi definido para garantir que o erro na dose prescrita permaneça inferior a 5%, evidenciando o potencial clínico dessa tecnologia.

Entretanto, a aplicação dessas tecnologias em ambientes hospitalares ainda enfrenta limitações relacionadas ao custo dos equipamentos, à necessidade de infraestrutura específica, à disponibilidade de dispositivos dedicados e à integração com a rotina assistencial (Wells et al., 2024). Em contraste, smartphones estão amplamente disponíveis nos serviços de saúde e representam uma alternativa de baixo custo, portátil e passível de ampla implementação em diferentes contextos assistenciais. Dessa forma, o desenvolvimento de modelos capazes de estimar o peso corporal utilizando apenas imagens 2D obtidas por smartphones convencionais pode ampliar significativamente a viabilidade operacional e a acessibilidade dessa tecnologia em cenários reais de assistência.

Nesse contexto, o presente estudo teve como objetivo aprimorar um modelo de inteligência artificial previamente desenvolvido para estimativa do peso corporal a partir de imagens obtidas por smartphones em ambiente hospitalar, avaliando seu desempenho em relação à versão inicial do modelo e ao peso corporal aferido em balança calibrada, utilizado como método de referência, com o propósito de atingir o critério de aceitabilidade clínica definido como proporção de estimativas dentro de 10% do peso aferido (P10) superior a 70%.

Como objetivos específicos, buscou-se: (i) otimizar a arquitetura do modelo desenvolvido no estudo piloto; (ii) avaliar a precisão e a concordância das estimativas de peso corporal em relação ao peso aferido em balança calibrada; (iii) comparar o desempenho do modelo aprimorado com a versão inicial; (iv) analisar o desempenho do modelo em subgrupos definidos por faixa de índice de massa corporal, idade, sexo e posição corporal durante a aquisição das imagens; e (v) investigar seu potencial de aplicabilidade clínica em cenários nos quais a aferição direta do peso corporal não seja viável.

2.0 REFERENCIAL TEÓRICO

2.1 Avaliação antropométrica de pacientes hospitalizados e acamados

A avaliação nutricional de pacientes hospitalizados, especialmente daqueles acamados, constitui um processo dinâmico e contínuo, que se inicia no momento da admissão e se estende ao longo de toda a internação. Dessa forma, o monitoramento periódico do estado nutricional é fundamental para identificar mudanças clínicas e nutricionais que possam impactar o prognóstico e a conduta terapêutica. Após a triagem inicial, recomenda-se a reavaliação periódica do estado nutricional durante a internação, geralmente em intervalos de 7 a 10 dias ou sempre que ocorrerem alterações clínicas relevantes (Castro et al., 2023).

Trata-se de um processo abrangente que envolve múltiplos componentes, incluindo a avaliação do consumo alimentar, a análise antropométrica, a interpretação de exames laboratoriais e a investigação da história clínica do paciente. A integração dessas informações permite ao nutricionista estabelecer um diagnóstico nutricional mais preciso, subsidiando a prescrição adequada da terapia nutricional (Duarte, 2007).

No contexto da avaliação antropométrica, as medidas de peso corporal e estatura são amplamente utilizadas como parâmetros fundamentais. A antropometria convencional, entretanto, baseia-se no pressuposto de que tais medidas podem ser obtidas diretamente, por meio do uso de balança e estadiômetro. Em pacientes acamados, esse pressuposto frequentemente não se sustenta, o que exige a adoção de métodos indiretos para a estimativa dessas variáveis (Rezende et al., 2009; Melo et al., 2014).

2.2 A importância clínica da estimativa de peso de pacientes acamados

Nesse cenário, a estimativa precisa do peso corporal torna-se fundamental, uma vez que esse parâmetro constitui a base para a prescrição clínica realizada por nutricionistas, médicos e farmacêuticos. Dessa forma, a medida do peso corporal não se restringe ao suporte da conduta terapêutica nutricional, mas configura variável crítica para a segurança do paciente e para a eficácia das intervenções farmacológicas (Wells, Henry, Goldstein, 2023; Sonar et al., 2025).

O peso corporal constitui uma variável determinante para o cálculo da

dosagem de diversos medicamentos, incluindo antibióticos potencialmente nefrotóxicos, agentes quimioterápicos, anticoagulantes e sedativos. Em pacientes com Acidente Vascular Cerebral Isquêmico (AVCi) elegíveis para trombólise, a dose do agente trombolítico é rigorosamente calculada com base no peso do paciente. Nesse contexto, erros na estimativa do peso corporal podem resultar em consequências graves, como hemorragia intracraniana em casos de superdosagem ou falha terapêutica por subdosagem, comprometendo a reperfusão adequada (Melo et al., 2014; Sonar et al., 2025)

As evidências da literatura reforçam essa problemática. Em seu estudo de acompanhamento de pacientes no ambiente hospitalar, Darnis et al. (2012) demonstraram que aproximadamente metade dos pacientes utilizava ao menos um medicamento cuja posologia dependia do peso corporal. Além disso, entre os pacientes em uso de enoxaparina, mais de um quarto encontrava-se fora da faixa de dose considerada adequada, evidenciando o impacto clínico da imprecisão na estimativa do peso.

2.3 Limitações dos métodos tradicionais indiretos em pacientes acamados

Quando o paciente não pode ser posicionado em uma balança para a aferição do peso corporal, devido a limitações como fraqueza muscular, paralisia ou rebaixamento do nível de consciência, torna-se necessária a utilização de métodos indiretos para a estimativa dessa medida. Esses métodos baseiam-se na obtenção de medidas de segmentos corporais que apresentam correlação estatística com o peso corporal, permitindo sua inferência por meio de equações preditivas (Rezende et al., 2009; Melo et al., 2014).

As equações preditivas desenvolvidas por Chumlea com base na população norte-americana em 1988 permanecem, após mais de 30 anos, entre as mais utilizadas mundialmente para a estimativa do peso corporal em pacientes acamados. Esses métodos baseiam-se em medidas antropométricas de segmentos corporais, como a altura do joelho (AJ) e a circunferência do braço (CB), a partir das quais o peso corporal é estimado por meio de equações específicas. As fórmulas propostas por Chumlea et al. (1988) apresentam variações de acordo com sexo e etnia, refletindo a tentativa de contemplar a variabilidade biológica entre diferentes populações. Essa estratificação visa aumentar a precisão das estimativas, conforme descrito na tabela 1.

Tabela 1. Fórmulas preditivas para estimativa de peso corporal desenvolvidas por Chumlea et al. (1988).

Mulheres
19-59 anos (Negra) Peso = (AJ X 1,24) + (CB x 2,97) – 82,48
19-59 anos (Branca) Peso = (AJ X 1,01) + (CB X 2,81) – 66,04
Homens
19-59 anos (Negro) Peso = (AJ X 1,09)+ (CB X 3,14) – 83,72
19-59 anos (Branco) Peso = (AJ X 1,19) + (CB X 3,21) – 86,82

Nota: AJ= Altura do joelho (cm) e CB= Circunferência do braço (cm)

Em virtude da elevada miscigenação e das características antropométricas específicas da população brasileira, Rabito et al. (2006) desenvolveram equações preditivas adaptadas a esse contexto. A principal inovação deste método foi a inclusão da circunferência abdominal (CA) como variável para a estimativa do peso corporal, com o objetivo de capturar de forma mais adequada a adiposidade central, frequentemente negligenciada por outras abordagens. Essa estratégia busca aumentar a precisão das estimativas ao incorporar uma medida diretamente relacionada à distribuição de gordura corporal. As fórmulas propostas encontram-se descritas na tabela 2.

Tabela 2. Fórmulas preditivas para estimativa de peso corporal desenvolvidas por Rabito et al. (2006).

Ambos sexos
Peso corporal= [0,5759 x CB (cm)] + [0,5263 x CA (cm)] + [1,2452 x CP (cm)] – [4,8689 x (sexo)*] - 32,9241

Nota: CP = circunferência da panturrilha, CB = circunferência do braço, CA = circunferência abdominal. * Fator de multiplicação de acordo com o sexo: 1 para o sexo masculino e 2 para o sexo feminino.

As equações preditivas para estimativa do peso corporal contribuem para mitigar a limitação da mensuração direta em pacientes acamados; entretanto, introduzem uma nova restrição relacionada à dependência do contexto populacional em que foram desenvolvidas. A equação de Chumlea, amplamente utilizada para a

estimativa de peso em pacientes acamados no Brasil, foi derivada a partir de uma população norte-americana. Nesse sentido, a aplicação dessas fórmulas em populações com características antropométricas distintas, como a brasileira, marcada por elevada miscigenação, pode comprometer a precisão das estimativas.

Em adultos brasileiros, Rezende et al. (2009) e Melo et al. (2014) identificaram diferenças entre o peso estimado por equações preditivas e o peso aferido. Rezende et al. (2009), em 98 homens adultos saudáveis, observaram superestimação média de 5,46 kg, correspondente a 7,4% do peso aferido médio ($p < 0,001$). Melo et al. (2014), em 142 adultos hospitalizados, relataram diferenças médias que chegaram a +7,12 kg em mulheres, cerca de 10,3% do peso real médio, com IC 95% de 5,90 a 8,34 kg e $p < 0,001$. Esses resultados sugerem viés de aplicação das equações preditivas quando utilizadas em populações diferentes daquelas de origem ou validação.

No que se refere às equações preditivas propostas por Rabito et al. (2006), a principal limitação para sua aplicabilidade reside na obtenção adequada das medidas antropométricas necessárias ao cálculo, especialmente da circunferência abdominal. Essa medida deve ser realizada no ponto anatômico correspondente à cicatriz umbilical, exigindo padronização técnica para garantir sua reprodutibilidade. Em pacientes acamados, frequentemente portadores de múltiplos dispositivos médicos, a mensuração da circunferência abdominal por meio de fita métrica ao redor do abdome pode ser tecnicamente difícil, pouco prática e, em muitos casos, inviável na rotina hospitalar. Além disso, tanto a circunferência abdominal quanto a circunferência da panturrilha correspondem a importantes sítios de acúmulo de líquidos corporais, podendo ser significativamente influenciadas por condições como ascite, edema periférico e retenção hídrica, o que pode comprometer a precisão das estimativas obtidas por essas equações.

Como consequência, apesar das limitações relacionadas à validade externa, a equação de Chumlea (1988) permanece como o método mais utilizado na prática clínica no Brasil, em razão de sua maior viabilidade operacional. Entretanto, mesmo sendo considerada mais factível para uso à beira-leito, sua aplicação ainda depende da obtenção de medidas antropométricas específicas, o que pode representar um desafio em diversos contextos assistenciais (Santos, Camargo, Paulo, 2012).

Esses desafios decorrem, em grande parte, das exigências inerentes ao processo de aferição antropométrica. A obtenção das medidas de segmentos

corporais utilizados como variáveis nessas equações requer tempo, treinamento específico e acesso a múltiplos marcos anatômicos, que nem sempre estão disponíveis na prática clínica. Em pacientes acamados, especialmente aqueles com múltiplos dispositivos médicos, curativos extensos, dor, deformidades, obesidade mórbida ou fraturas, a realização dessas aferições por meio de fita métrica pode ser tecnicamente limitada ou até inviável, comprometendo a padronização das medidas. Esse aspecto é particularmente relevante, uma vez que o objetivo não se restringe à obtenção de um valor numérico isolado, mas sim à geração de uma informação confiável que subsidie decisões clínicas seguras (Santos, Camargo, Paulo, 2012; Lima et al., 2023).

2.4 Limitações econômicas e operacionais das camas hospitalares com balança integrada

A principal alternativa para situações em que não é possível realizar a aferição direta do peso corporal em pacientes acamados consiste no uso de camas hospitalares com balança integrada. Esses equipamentos permitem a mensuração do peso do paciente diretamente no leito, sem a necessidade de mobilização para uma balança convencional. No entanto, devido ao elevado grau de sofisticação tecnológica, apresentam alto custo de aquisição (Manoj et al., 2019; Skoll et al., 2024).

Essa realidade é evidenciada por processos licitatórios no contexto brasileiro, como o da Prefeitura de Princesa Isabel (2023), cujo Termo de Referência registrou valor unitário médio de R\$ 27.083,68 para camas hospitalares com balança integrada. Em contraste, camas hospitalares convencionais, sem sistema de pesagem, apresentam custos significativamente inferiores, como demonstrado em ata de registro de preços da Secretaria de Estado de Saúde do Distrito Federal (2022), na qual modelos do tipo Fowler foram registrados por aproximadamente R\$ 3.000,00 por unidade, evidenciando uma diferença de custo de cerca de nove vezes em relação aos modelos com balança integrada. Nesse contexto, a implementação em larga escala desses equipamentos tecnológicos torna-se economicamente inviável para muitas instituições de saúde, especialmente em sistemas públicos com recursos financeiros limitados, como o Sistema Único de Saúde (SUS), nos quais o investimento em tecnologias de alto custo compete diretamente com a aquisição de insumos essenciais e medicamentos (Pereira, 2025).

Além disso, a utilização desses dispositivos exige treinamento da equipe assistencial e, frequentemente, a atuação coordenada de múltiplos profissionais para a mobilização segura do paciente. Para a correta aferição do peso corporal, é necessário que todas as etapas do processo estejam rigorosamente sincronizadas. A balança deve ser previamente tarada com a cama em uma configuração idêntica àquela em que o paciente será pesado, idealmente antes da admissão, com o enxoval padrão já posicionado. Entretanto, a dinâmica da prática hospitalar impõe desafios adicionais. A variação no enxoval, decorrente de trocas frequentes para higiene ou conforto, pode alterar significativamente a carga sobre a balança. Caso não haja tara a cada modificação, o acúmulo de tecidos pode induzir a erros (Skoll et al., 2024).

Em ambientes como Unidades de Terapia Intensiva (UTI), nos quais o paciente pode estar conectado a múltiplos dispositivos simultaneamente, esse processo torna-se altamente complexo, demandando tempo, coordenação e aumentando o risco de eventos adversos, como desconexões acidentais de dispositivos essenciais. Soma-se a isso a necessidade de calibração periódica e manutenção técnica, fatores que ampliam ainda mais a complexidade operacional e os custos associados. Diante dessas limitações, evidencia-se a persistência de uma lacuna significativa na prática clínica para a obtenção de medidas confiáveis de peso corporal em pacientes acamados no ambiente hospitalar (Skoll et al., 2024).

2.5 Abordagens computacionais para estimativa antropométrica

2.5.1 Sensores e métodos de aquisição aplicados à estimativa antropométrica

Na computação, diferentes abordagens têm sido investigadas para estimativa de medidas antropométricas, que vão desde sensores não ópticos a representações óticas do mundo físico. Uma das linhas de investigação envolve sensores não ópticos, como radares de radiofrequência, que permitem medições antropométricas sem contato físico e com maior preservação de privacidade.

Kim et al. (2022) avaliaram o uso de radares IR-UWB estrategicamente posicionados em uma amostra de 45 adultos saudáveis e obtiveram erro quadrático médio da raiz (Root Mean Squared Error – RMSE) de 5,31 kg para peso corporal e de 2,25 kg/m² para IMC. Soares et al. (2024), por sua vez, utilizaram radar CW de 5,8 GHz em 92 voluntários, com idade entre 18 e 50 anos e IMC entre 17,5 e 40

kg/m², alcançando aproximadamente 72,5% de acurácia na classificação de categorias de IMC. De modo semelhante, sensores inerciais de smartphones, como unidades de medição inercial (Inertial Measurement Units – IMUs), também são explorados para inferência de IMC a partir de características de marcha e movimento, mas dependem da capacidade de locomoção do indivíduo (Yao, Song, Ye, 2020).

Outra linha utiliza sensores ópticos de profundidade, como sensores RGB-D, Microsoft Kinect®, câmeras 3D e LiDAR. Esses dispositivos permitem a captura direta da geometria tridimensional, favorecendo a reconstrução volumétrica e, por conseguinte, a estimativa de medidas antropométricas. Contudo, costumam exigir ambientes controlados e apresentam limitações para aplicação clínica rotineira, como elevado custo de aquisição e manutenção, necessidade de calibração frequente, infraestrutura específica e baixa disponibilidade em hospitais com recursos limitados (Pfitzner et al., 2018; Wells et al., 2024).

Por fim, há abordagens baseadas em sensores ópticos bidimensionais, especialmente imagens fotográficas obtidas por câmeras convencionais ou smartphones. Essa estratégia é operacionalmente mais acessível, mas configura um problema complexo de inferência antropométrica em visão computacional. Diferentemente da mensuração direta ou da captura tridimensional, imagens 2D exigem a estimativa indireta de grandezas tridimensionais, como volume corporal, distribuição de massa e escala real, a partir de projeções ambíguas. Essas imagens estão sujeitas à perda de informação de profundidade, ausência de escala absoluta, variações de pose, oclusões e diferenças de enquadramento, o que torna a estimativa antropométrica uma tarefa computacionalmente desafiadora, embora promissora pela ampla disponibilidade de câmeras e smartphones (Gunel, Rhodin e Fua, 2019; Mohammedkhan et al., 2025).

2.5.2 Visão computacional e inteligência artificial na estimativa antropométrica

A visão computacional e a inteligência artificial têm sido progressivamente aplicadas à análise de imagens corporais para estimativa de medidas antropométricas. Nesse contexto, a inteligência artificial compreende um conjunto de métodos computacionais capazes de identificar padrões em dados complexos, enquanto o aprendizado de máquina permite que modelos sejam treinados a partir de exemplos previamente rotulados para realizar tarefas de classificação ou

regressão. Em aplicações supervisionadas na saúde, esses modelos são geralmente treinados com dados de entrada associados a medidas de referência, como peso, altura, IMC ou outras variáveis clínicas, permitindo a aprendizagem de relações entre características observáveis e desfechos mensuráveis (Bajwa et al., 2021; Habehh, Gohel, 2021).

Na estimativa antropométrica por imagens, o aprendizado supervisionado é particularmente relevante porque permite associar atributos visuais do corpo humano a medidas obtidas por métodos de referência. Para dados estruturados ou tabulares, algoritmos como Ridge Regression (Rajan, 2022), Random Forest (Breiman, 2001) e LightGBM (Ke et al., 2017) podem ser empregados na modelagem de relações entre variáveis clínicas, demográficas e antropométricas. Para dados visuais, por sua vez, redes neurais profundas têm maior destaque, pois permitem a extração automática de características complexas diretamente das imagens, reduzindo a dependência de atributos definidos manualmente (Lindroth et al., 2024; Kabir et al., 2025).

A visão computacional corresponde ao campo voltado ao processamento e interpretação de imagens e vídeos por métodos computacionais. Em saúde, essa área tem sido amplamente utilizada para apoiar a análise de imagens médicas, como radiografias, tomografias, ressonâncias magnéticas e vídeos endoscópicos, por meio da identificação automática de padrões morfológicos relevantes (Lindroth et al., 2024; Kabir et al., 2025). No caso da antropometria, entretanto, o foco não é a detecção de lesões ou doenças em exames diagnósticos, mas a extração de informações corporais relacionadas à forma, proporção, postura, volume e composição visual do indivíduo (Wells et al., 2024).

Com o avanço do aprendizado profundo, diferentes tarefas de visão computacional passaram a contribuir para a estimativa antropométrica baseada em imagens. Entre elas, destacam-se a detecção de pessoas, a segmentação corporal, a estimativa de pose, a reconstrução tridimensional aproximada, a estimativa de profundidade monocular e a regressão direta ou indireta de medidas corporais. Essas técnicas permitem transformar imagens bidimensionais em representações mais informativas do corpo humano, ainda que persistam desafios relacionados à ausência de escala absoluta, variações de postura, oclusões, vestimentas, iluminação, distância da câmera e diversidade antropométrica (Mohammedkhan et al., 2025).

Sob essa perspectiva, a nutrição clínica hospitalar apresenta um campo relevante para aplicação de visão computacional e inteligência artificial. Pacientes acamados ou com mobilidade reduzida frequentemente apresentam dificuldades para aferição direta de peso e altura, e equipamentos específicos, como balanças-leito ou sistemas tridimensionais, nem sempre estão disponíveis na rotina assistencial. Assim, métodos baseados em imagens de câmeras convencionais ou smartphones podem representar uma alternativa operacionalmente viável para estimativa antropométrica, desde que treinados com dados representativos, comparados a métodos de referência e validados com métricas clinicamente interpretáveis (Wells et al., 2024).

2.6 Trabalhos relacionados

Os trabalhos relacionados à estimativa antropométrica por métodos computacionais podem ser organizados em diferentes linhas de investigação, de acordo com o tipo de dado utilizado, o método de aquisição e o contexto de aplicação. De modo geral, a literatura inclui estudos baseados em sensores de profundidade e câmeras 3D, abordagens utilizando imagens 2D de indivíduos em posição ortostática, aplicações em pacientes deitados ou hospitalizados e métodos que exploram imagens médicas, como radiografias de tórax. Essa organização permite compreender a evolução das abordagens propostas, desde sistemas dependentes de hardware especializado até métodos baseados em dispositivos amplamente disponíveis, como smartphones (Pfitzner, May, Nüchter, 2018; Jiang, Guo, 2020; Wells et al., 2024; Sonar et al, 2025).


A primeira linha de investigação utiliza sensores de profundidade e câmeras tridimensionais para estimar medidas antropométricas a partir da geometria corporal. Jiang, Shang e Guo (2020) exploraram imagens 3D capturadas por sensor Kinect em ambiente controlado, estimando separadamente estatura e volume corporal, com posterior correção do volume em função da vestimenta e cálculo do IMC. O estudo, realizado com 163 indivíduos, obteve a média absoluta de erro (Mean Absolute Error – MAE) de 5,15 kg para peso corporal e 2,54 kg/m² para IMC.

Na mesma direção, a revisão de Wells et al. (2024) sintetizou as evidências disponíveis e demonstrou que sistemas baseados em câmeras 3D podem atingir desempenho clinicamente promissor, utilizando a métrica P10, que representa a

proporção de estimativas situadas dentro de 10% do peso real (Figura 1). Foram identificados 11 sistemas de estimativa de peso corporal com dados de P10 disponíveis. O menor índice registrado foi ligeiramente inferior a 80%, enquanto quatro sistemas superaram 95%. Em conjunto, esses resultados sugerem elevado potencial para aplicação clínica dessa tecnologia.

Além disso, uma metanálise conduzida pelo mesmo grupo demonstrou que, entre os métodos tradicionais de estimativa de peso em adultos, apenas o peso autorreferido apresentou grau de precisão semelhante aos sistemas baseados em câmeras. Entretanto, a utilização dessa estratégia apresenta limitações importantes, uma vez que pacientes graves frequentemente são incapazes de informar o próprio peso, situação observada em aproximadamente 75% a 80% dos casos. Esses achados reforçam a necessidade de métodos de estimativa independentes do relato do paciente, indicando que sistemas baseados em câmeras 3D podem representar uma alternativa eficaz para aplicação no ambiente hospitalar (Wells et al., 2024).

Figura 1. Precisão dos sistemas de estimativa de peso por meio de câmeras 3D utilizando a métrica P10.



Fonte: Wells et al. (2024).

Embora os sistemas baseados em sensores de profundidade e câmeras tridimensionais apresentem resultados promissores, sua aplicação depende de hardware dedicado e de condições específicas de aquisição. Em paralelo, outra linha de investigação tem explorado o uso de imagens bidimensionais convencionais, obtidas por câmeras 2D, buscando soluções potencialmente mais acessíveis e aplicáveis em cenários reais de assistência.

Jiang e Guo (2019) buscaram estimar o IMC de indivíduos a partir de imagens frontais 2D obtidas em ambientes não controlados, além de identificar diferenças de peso corporal entre pares de imagens representando o antes e depois de um mesmo indivíduo. O banco de dados foi composto por 5.900 imagens de 2.950 indivíduos coletadas na plataforma Reddit. A estimativa do IMC foi realizada por meio da extração de proporções corporais derivadas da detecção de articulações esqueléticas e do contorno corporal, obtendo MAE de 3,76 kg/m² para IMC.

Altinigne, Thanou e Achanta (2020), utilizando uma arquitetura derivada da U-Net, estimaram peso corporal, estatura, silhueta e pontos articulares em imagens 2D não controladas, alcançando MAE de 9,80 kg para peso corporal. De forma semelhante, Pantanowitz et al. (2021) avaliaram a predição do IMC a partir da silhueta corporal em captura frontal padronizada, obtendo MAE de 1,2 kg/m² no melhor modelo. Esses estudos demonstram a viabilidade da extração de sinais antropométricos a partir de imagens 2D; contudo, foram conduzidos predominantemente com indivíduos em posição ortostática, o que limita sua transferência direta para pacientes acamados ou com mobilidade reduzida.

Uma linha de investigação mais próxima do contexto clínico do presente estudo envolve pacientes deitados ou hospitalizados. Huaijing et al. (2023) propuseram o uso de redes neurais convolucionais para estimar estatura e peso corporal de recém-nascidos deitados em berço, a partir de vídeos capturados por smartphone em centro obstétrico. O estudo incluiu 200 recém-nascidos e obteve MAE inferior a 0,28 kg para peso corporal.

Em adultos hospitalizados, Pfitzner, May e Nüchter (2018) investigaram a estimativa de peso corporal em pacientes deitados em cama hospitalar utilizando uma câmera de profundidade Kinect e uma câmera térmica Optris PI400 posicionadas sobre o leito. Com amostra de 69 pacientes, os autores relataram acurácia próxima a 90% para o peso corporal real e erro relativo inferior a 10%. Embora esses estudos se aproximem mais do cenário assistencial, ainda

apresentam limitações relevantes: o primeiro foi conduzido em recém-nascidos, população antropometricamente distinta dos adultos, enquanto o segundo dependeu de sensores dedicados e de posicionamento controlado no ambiente hospitalar.

Além das abordagens baseadas em imagens fotográficas convencionais, estudos recentes têm explorado o uso de imagens médicas adquiridas rotineiramente na prática clínica. Ichikawa, Itadani e Sugimori (2023) investigaram a estimativa de peso corporal utilizando 85.849 radiografias de tórax, obtendo MAE de 2,63 kg em pacientes do sexo feminino e 3,35 kg em pacientes do sexo masculino. De forma complementar, Nakao et al. (2023) utilizaram 14.322 radiografias de tórax e observaram correlação significativa entre peso estimado e peso aferido, com coeficientes de $R = 0,793$ para o sexo masculino e $R = 0,86$ para o sexo feminino. Esses achados sugerem que imagens bidimensionais podem conter informações antropométricas úteis para regressão do peso corporal; contudo, sua aplicação depende da disponibilidade de exames radiológicos e não substitui a necessidade de métodos acessíveis, não ionizantes e aplicáveis diretamente à beira do leito.

Em conjunto, os estudos disponíveis indicam que a estimativa antropométrica por métodos computacionais é tecnicamente viável, especialmente quando há controle das condições de aquisição, uso de sensores de profundidade, disponibilidade de grandes bases de dados ou emprego de exames de imagem. Contudo, a maior parte das evidências ainda se concentra em indivíduos em posição ortostática, em populações não hospitalares, em recém-nascidos ou em métodos dependentes de hardware dedicado e infraestrutura específica. Permanece, portanto, uma lacuna relevante quanto à estimativa de peso corporal em pacientes adultos acamados utilizando apenas imagens 2D capturadas por smartphones em ambiente clínico real.

2.7 Estudo piloto e desenvolvimento inicial da tecnologia

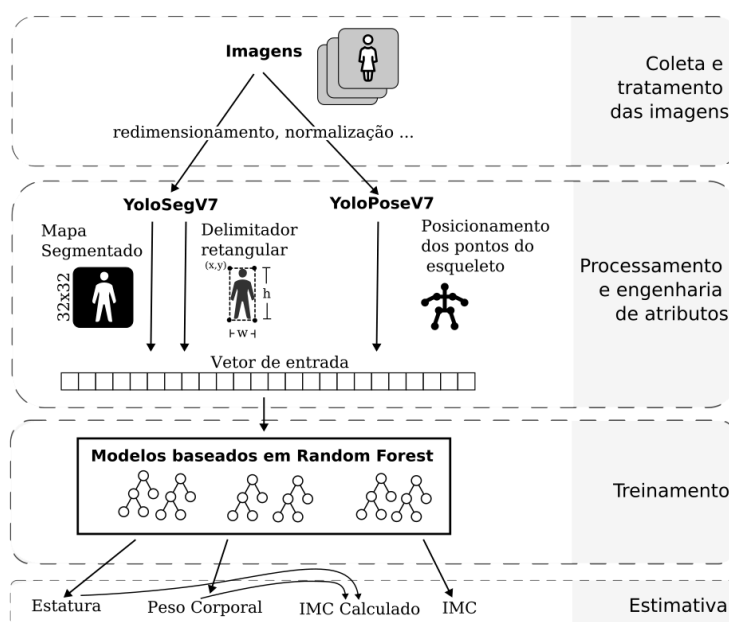
Como antecedente direto da presente dissertação, nosso grupo de pesquisa conduziu um estudo piloto pioneiro com o objetivo de desenvolver uma abordagem baseada em inteligência artificial para estimativa de estatura, peso corporal e índice de massa corporal (IMC) a partir de registros fotográficos de pacientes adultos posicionados em leito hospitalar (Faria et al., 2023). O estudo foi realizado entre dezembro de 2021 e setembro de 2022 em cinco hospitais públicos do Distrito Federal e constituiu a primeira etapa do desenvolvimento tecnológico da solução

proposta nesta linha de pesquisa.

Participaram do estudo 150 pacientes adultos hospitalizados, provenientes de clínicas médicas e cirúrgicas, totalizando 708 registros fotográficos obtidos em diferentes posições corporais padronizadas no leito hospitalar. Após a aferição direta da estatura e do peso corporal por métodos convencionais, os participantes eram posicionados na cama hospitalar para a realização dos registros fotográficos, permitindo a criação de um banco de dados voltado especificamente para pacientes em posição supina.

A arquitetura desenvolvida é apresentada na Figura 2. O modelo combinava técnicas de segmentação semântica, delimitação da silhueta corporal, identificação de pontos-chave anatômicos por meio dos modelos YOLOv7 e regressão baseada em Random Forest para estimativa da estatura, peso corporal e IMC. A hipótese central era que atributos geométricos extraídos das imagens seriam capazes de representar características antropométricas suficientes para inferir essas medidas, mesmo em pacientes deitados em leito hospitalar.

Figura 2. Arquitetura da versão inicial desenvolvida no estudo piloto.



Fonte: Faria et al. (2023).

Os resultados demonstraram a viabilidade técnica da abordagem

proposta. O modelo alcançou erro absoluto médio (MAE) de 4,32 cm para estatura, 7,94 kg para peso corporal e 1,59 kg/m² para IMC, além de correlação moderada para estatura ($r = 0,51$), forte para peso corporal ($r = 0,82$) e muito forte para IMC ($r = 0,90$). Esses resultados forneceram a primeira evidência de que registros fotográficos obtidos por smartphones poderiam ser utilizados para estimativa antropométrica de pacientes em leito hospitalar.

Apesar dos resultados promissores, o estudo piloto apresentou limitações importantes relacionadas ao tamanho amostral, à utilização de atributos predominantemente bidimensionais e à arquitetura empregada. Essas limitações motivaram o desenvolvimento da presente dissertação, que buscou aprimorar substancialmente a abordagem inicial por meio da ampliação da amostra, reconstrução 3D do corpo humano, extração de atributos geométricos mais complexos e utilização de uma estratégia de validação mais robusta.

2.8 Diretrizes para desenvolvimento, validação e relato de modelos de inteligência artificial em saúde

O rápido crescimento das aplicações de inteligência artificial na área da saúde evidenciou a necessidade de diretrizes específicas para melhorar a transparência, a reprodutibilidade e a qualidade metodológica dos estudos. Em resposta a esse cenário, diferentes frameworks internacionais foram desenvolvidos para orientar o planejamento, a condução e o relato de pesquisas envolvendo modelos baseados em inteligência artificial (Collins et al., 2024; Sounderajah et al., 2025).

Entre essas iniciativas, destaca-se o TRIPOD-AI (Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis – Artificial Intelligence), uma extensão das diretrizes TRIPOD voltada especificamente para estudos de desenvolvimento, validação e atualização de modelos preditivos baseados em inteligência artificial. O framework estabelece recomendações para descrição detalhada dos participantes, dados utilizados, pré-processamento, desenvolvimento dos modelos, estratégias de validação, métricas de desempenho e interpretação dos resultados, buscando aumentar a transparência e a reprodutibilidade das pesquisas (Collins et al., 2024).

De forma complementar, o STARD-AI (Standards for Reporting Diagnostic Accuracy Studies – Artificial Intelligence) consiste em uma extensão das diretrizes STARD destinada a estudos que avaliam o desempenho de sistemas de inteligência artificial na área da saúde. Suas recomendações enfatizam a descrição clara da população estudada, dos métodos de referência utilizados, das métricas de desempenho e das potenciais fontes de viés, contribuindo para uma avaliação mais robusta da qualidade metodológica dos estudos (Sounderajah et al., 2025).

Embora o presente estudo seja caracterizado principalmente como uma pesquisa de desenvolvimento e validação interna de modelo preditivo, diversos elementos recomendados pelo STARD-AI foram incorporados ao planejamento e ao relato dos resultados, especialmente aqueles relacionados à descrição da população, dos métodos de referência, das métricas de desempenho e das estratégias de validação. Dessa forma, o TRIPOD-AI constituiu o principal framework metodológico adotado, enquanto o STARD-AI foi utilizado como diretriz complementar para fortalecer a transparência e a qualidade do relato científico.

3.0 JUSTIFICATIVA

A estimativa precisa do peso corporal de pacientes acamados é fundamental para diferentes profissionais da saúde. Para o nutricionista, essas medidas são essenciais para a prescrição dietética adequada e para o ajuste das intervenções nutricionais. Para médicos e farmacêuticos, a estimativa do peso corporal é indispensável para a dosagem correta de medicamentos. Os métodos indiretos atualmente utilizados para estimar essas medidas, como as equações preditivas de Chumlea e a estimativa visual, frequentemente apresentam limitações de precisão, acurácia e reprodutibilidade, podendo comprometer a adequação nutricional e os desfechos clínicos dos pacientes.

Diante desse cenário, a inteligência artificial surge como uma alternativa promissora. Ferramentas tecnológicas baseadas em IA têm o potencial de reduzir erros na estimativa do peso corporal, proporcionando maior confiabilidade para a prescrição de dietas e demais terapias dependentes do peso corporal. No entanto, para que um modelo de IA possa ser incorporado à prática clínica, é fundamental demonstrar sua concordância com métodos de referência por meio de estudos de validação adequadamente conduzidos.

Além da relevância para a prática clínica dos profissionais de saúde, a

proposta apresenta potencial impacto na saúde pública. A indisponibilidade de equipamentos específicos para aferição do peso corporal, como camas com balança integrada e outros sistemas tecnológicos dedicados, é uma realidade em grande parte dos serviços de saúde, especialmente em hospitais públicos e instituições com recursos limitados. Nesse contexto, uma tecnologia baseada apenas em smartphones, amplamente disponíveis nos serviços assistenciais, pode ampliar o acesso a estimativas de peso corporal mais padronizadas e reproduzíveis. A longo prazo, a utilização de ferramentas dessa natureza pode contribuir para a redução de erros relacionados à prescrição nutricional e medicamentosa, promovendo maior segurança assistencial e potencialmente reduzindo custos decorrentes de complicações evitáveis associadas a estimativas inadequadas do peso corporal.

Portanto, este estudo propõe otimizar o modelo de IA desenvolvido no estudo piloto, determinando sua precisão na estimativa do peso corporal em comparação com o método de referência baseado na aferição direta do peso corporal em balança calibrada. Esta etapa é fundamental para consolidar a robustez do algoritmo, permitindo que futuras iterações do projeto avancem para a integração em uma interface de aplicativo móvel. Com a evolução e validação contínua da tecnologia, espera-se que, a longo prazo, o sistema possa contribuir como ferramenta de apoio à prática assistencial hospitalar, auxiliando nutricionistas e equipes multiprofissionais na estimativa do peso corporal de pacientes acamados em situações nas quais a aferição direta não seja viável.

4.0 MÉTODOS

4.1 Delineamento do estudo

Trata-se de um estudo transversal, de caráter analítico e com abordagem tecnológica, conduzido em cinco hospitais públicos do Distrito Federal: Hospital Regional da Asa Norte (HRAN), Hospital Regional de Ceilândia (HRC), Hospital da Região Leste (HRL), Hospital Regional de Taguatinga (HRT) e Hospital de Base, vinculado ao IGES-DF. A coleta de dados foi realizada entre abril de 2024 e setembro de 2025.

O estudo foi conduzido e relatado de acordo com as recomendações do *framework* TRIPOD-AI (Collins et al., 2024), voltadas ao desenvolvimento e à validação de modelos preditivos baseados em inteligência artificial. De forma

complementar, foram consideradas as diretrizes do STARD-AI (Sounderajah et al., 2025) para apoio à avaliação do modelo.

A descrição da arquitetura computacional foi organizada em nível funcional, contemplando as etapas de segmentação corporal, estimativa de pose, reconstrução tridimensional, extração de atributos e regressão para estimativa do peso corporal. Esse nível de detalhamento buscou permitir a avaliação metodológica do estudo, especialmente quanto à origem dos dados, à organização dos atributos, à prevenção de vazamento entre treino e validação e às métricas de desempenho.

O estudo foi organizado em duas fases: Fase I – constituição do banco de imagens para o modelo computacional; e Fase II – treinamento da arquitetura de aprendizado de máquina e avaliação do desempenho do modelo computacional. O presente estudo dá continuidade ao desenvolvimento do modelo computacional iniciado em estudo piloto prévio (Faria et al., 2023), realizado durante o programa de Residência Multiprofissional em Urgência e Trauma (2021–2023), nos cenários assistenciais da Secretaria de Estado de Saúde do Distrito Federal.

4.2 Aspectos éticos

O projeto de pesquisa foi submetido à apreciação ética e aprovado pelos Comitês de Ética em Pesquisa do IGES-DF (Parecer nº 7.309.650) e da FEPECS (Parecer nº 6.694.958). A coleta de dados foi iniciada somente após a obtenção das aprovações éticas, sendo conduzida em conformidade com os princípios estabelecidos pelas Resoluções CNS nº 466/2012 e nº 510/2016.

4.3 Cálculo amostral

Para estimativa do tamanho amostral, foi utilizado o pacote *pwr* (Cohen, 1988), versão 1.3-0, no software R versão 4.1.1 (R Core Team, 2024). A estimativa foi baseada em teste unilateral para proporções, com o objetivo de determinar o número mínimo de pacientes necessário para validar a precisão do modelo. Considerou-se clinicamente aceitável que pelo menos 70% das estimativas apresentassem erro absoluto $\leq 10\%$ do peso corporal aferido. Para o cálculo amostral, assumiu-se como hipótese alternativa uma proporção esperada de 80% de estimativas com erro $\leq 10\%$ ($p = 0,80$), em comparação a uma proporção mínima aceitável de 70% ($p_0 = 0,70$). Adotou-se nível de significância de 5% ($\alpha = 0,05$) e

poder estatístico de 80% ($1 - \beta = 0,80$). Com base nesses parâmetros, foi estimado tamanho amostral mínimo de 114 pacientes.

4.4 Recrutamento e seleção da amostra

Foram realizadas busca ativa por meio do prontuário eletrônico nos sistemas Trakcare® (Hospitais HRAN, HRC, HRT e HRL) e MVSoul (Hospital de Base). Foram abertos os prontuários individuais com objetivo de rastrear os possíveis pacientes que atendessem aos critérios de inclusão e exclusão.

No prontuário individual foram consultadas informações utilizadas para a triagem inicial e verificação dos critérios de elegibilidade dos participantes. Na evolução da nutrição, foram verificadas as informações mais recentes referentes ao peso corporal (kg), estatura (m), índice de massa corporal (IMC) e exame físico do paciente. Na evolução da enfermagem, foi consultado o escore da Escala de Morse, utilizado para identificação de pacientes com alto risco de queda, conforme previsto nos critérios de exclusão do estudo.

Na evolução médica, foram verificados os diagnósticos atuais e pregressos do paciente com o objetivo de identificar condições clínicas que atendessem aos critérios de exclusão, tais como doenças associadas à presença de edema, ascite, alterações cognitivas, dependência de oxigenoterapia ou outras condições potencialmente capazes de interferir na participação do paciente ou na qualidade das medidas obtidas.

Os critérios de inclusão foram: pacientes adultos de ambos os sexos internados nas Clínicas Médicas e Cirúrgicas do Hospital Regional da Asa Norte (HRAN), Hospital Regional de Ceilândia (HRC), Hospital da Região Leste (HRL), Hospital Regional de Taguatinga (HRT), nos Pronto-socorros do HRAN e HRC e na Oncologia (10º andar) do Hospital de Base - (IGES-DF).

Os critérios de exclusão foram: pacientes que estavam com precaução de contato ou por gotículas ou por aerossóis, aqueles que não conseguiam ficar em pé sem auxílio de qualquer dispositivo (muletas, bengalas, andadores etc.) e/ou deambular, com alto risco de queda na escala de Morse, em monitoramento cardíaco, dependentes de oxigenoterapia, capacidade decisória reduzida (déficit cognitivo, confusão mental, delirium etc.), mulheres gestantes ou puérperas, portadores de doença renal crônica em tratamento dialítico, doença hepática crônica ou qualquer outra patologia que cursasse com ascite, edema de membros

superiores e/ou inferiores, portadores de cânceres com metástase óssea, que possuíam histórico de hipoglicemias frequentes e próteses metálicas no corpo. A presença de déficit cognitivo, confusão mental, delirium ou outras condições associadas à redução da capacidade decisória foi identificada por meio das informações registradas no prontuário eletrônico pela equipe assistencial.

Embora a tecnologia proposta tenha como público-alvo pacientes acamados, nesta etapa do desenvolvimento do modelo foram incluídos apenas participantes capazes de permanecer em posição ortostática para a aferição direta do peso corporal e da estatura, utilizados como padrão de referência para o treinamento e validação do modelo. Após a avaliação antropométrica, os participantes eram posicionados deitados em leito hospitalar e fotografados de acordo com o protocolo do estudo, simulando o cenário real de utilização da tecnologia em pacientes acamados, para os quais a obtenção direta do peso corporal frequentemente não é possível.

Após as buscas nos prontuários, aplicação dos critérios de inclusão e exclusão, os pacientes elegíveis para participarem da pesquisa foram registrados no formulário 01 com um número sequencial que foi atribuído, clínica de internação e leito (APÊNDICE A). Estes pacientes foram visitados individualmente no leito pelos pesquisadores membros da equipe de pesquisa. Foi realizado o convite, com apresentação detalhada do projeto e dos procedimentos metodológicos a serem realizados, e caso optasse por participar, foram apresentados o termo de consentimento livre e esclarecido (TCLE) e o termo de autorização para utilização de imagem para leitura e compreensão destes, e posteriormente as assinaturas.

Para os participantes não alfabetizados que aceitaram participar da pesquisa, o Termo de Consentimento Livre e Esclarecido (TCLE) e o Termo de Autorização para Utilização de Imagem foram lidos integralmente em linguagem clara e acessível, com esclarecimento de todos os procedimentos, riscos, benefícios e eventuais dúvidas. Após a concordância do participante, foi coletada sua impressão digital nos documentos.

Quando o participante estava acompanhado por representante legal ou acompanhante alfabetizado, a leitura e os esclarecimentos foram realizados na presença desse acompanhante, que também assinou os documentos quando aplicável. Nos casos em que o representante legal ou acompanhante também não era alfabetizado, ou quando o participante estava desacompanhado, foi convidada

uma testemunha instrumentária, imparcial e sem vínculo direto com a equipe de pesquisa, para acompanhar todo o processo de leitura, esclarecimento e manifestação de consentimento. Ao final, foram coletadas a impressão digital do participante e a assinatura da testemunha instrumentária nos documentos correspondentes.

4.5 Logística de segurança para avaliações antropométricas

Para a realização da avaliação antropométrica e dos registros fotográficos, foram adotados procedimentos de biossegurança em conformidade com as normas institucionais vigentes. Inicialmente, o pesquisador realizou a higienização das mãos com álcool em gel e utilizou máscara cirúrgica e luvas de procedimento não estéreis. Após a aferição do peso corporal na balança e da estatura no estadiômetro, os equipamentos utilizados foram submetidos à desinfecção com álcool etílico 70% e papel toalha descartável. Em seguida, as luvas de procedimento foram removidas e descartadas adequadamente, permanecendo apenas o uso da máscara cirúrgica. Antes do atendimento ao participante seguinte, o pesquisador repetia os procedimentos de biossegurança descritos anteriormente.

4.6 Avaliação antropométrica dos pacientes

Os dados antropométricos de peso corporal e estatura foram coletados por duas pesquisadoras nutricionistas voluntárias com experiência em avaliação antropométrica e pelo pesquisador principal. Todos os membros da equipe de pesquisa receberam treinamento específico para padronização na coleta de dados pelo pesquisador principal. Para aferição do peso corporal (kg) foi utilizada a balança digital portátil da marca Avanutri®, modelo Premium, cor preta, com capacidade máxima de 200kg. A balança foi instalada em um local da enfermaria com piso nivelado, de forma a garantir sua estabilidade durante o procedimento. O paciente foi orientado a retirar objetos pesados do corpo, tais como chaves, cintos, óculos, telefones celulares e quaisquer outros itens que pudessem interferir na medida. A aferição foi realizada com o participante utilizando vestimenta hospitalar habitual, sem calçados e sem objetos adicionais. Posteriormente, o equipamento foi ligado e o paciente posicionado no centro da balança, em posição ereta, com os pés juntos e os braços estendidos ao longo do corpo, sendo então realizada a aferição do peso corporal (Brasil, 2011).


Para aferição da estatura (m), foi utilizado o estadiômetro portátil da marca Sanny® Personal Caprice, modelo ES2060, cor prata, com capacidade de aferição de 115 cm a 210 cm. O paciente foi posicionado no centro do equipamento, descalço, em posição ereta, com os calcanhares unidos e encostados à haste vertical do estadiômetro, os braços estendidos ao longo do corpo, a cabeça livre de adereços e orientada conforme o plano horizontal de Frankfurt. Foi deslocada a parte móvel do equipamento até o vértex da cabeça, aplicando pressão suficiente para comprimir os cabelos, sendo realizada a leitura da estatura sem deslocamento da haste móvel (Brasil, 2011). Os dados aferidos de peso corporal (kg) e estatura (m) foram registrados no Formulário 01 (APÊNDICE A).

4.7 Captura dos registros fotográficos dos pacientes e gravação dos vídeos

Após a avaliação antropométrica, o paciente foi orientado a retornar ao leito hospitalar. Em seguida, foi solicitado que permanecesse deitado no leito, utilizando vestimenta hospitalar ajustada rente ao corpo e sem cobertura por lençóis. Os registros fotográficos e os vídeos foram obtidos pelos pesquisadores utilizando a câmera de um smartphone, conforme ilustrado na Figura 3.

A câmera foi posicionada frontalmente em relação ao leito hospitalar, a aproximadamente 1 m da cama e entre 1,3 e 1,4 m de altura em relação ao solo, mantendo-se a cabeceira elevada a 30°. A posição da câmera permaneceu constante durante toda a aquisição, enquanto os participantes foram orientados a assumir diferentes posições corporais.

Figura 3. Controle das principais variáveis do ambiente para realização dos registros fotográficos e gravação de vídeos dos pacientes deitados na cama hospitalar (Faria et al., 2023).



Foram obtidos cinco registros fotográficos de corpo inteiro e, posteriormente, um vídeo com duração aproximada de 20 segundos. Inicialmente, os pacientes foram fotografados nas cinco posições corporais previstas no protocolo. Após a obtenção dos registros fotográficos, foi realizada a gravação do vídeo. Durante a filmagem, a câmera percorreu o corpo do paciente dos pés à cabeça e da esquerda para a direita, mantendo o enquadramento de corpo inteiro sempre que possível. Ao longo da gravação, o participante foi orientado a assumir, de forma sequencial, as mesmas posições corporais utilizadas nos registros fotográficos. Foram obtidos cinco registros fotográficos em diferentes posições corporais padronizadas (Figura 4):

Posição 1 – Decúbito dorsal, com travesseiro sob a cabeça, braços e pernas estendidos e ligeiramente afastados do corpo.


Posição 2 – Decúbito dorsal, com travesseiro sob a cabeça, braços e pernas estendidos e rentes ao corpo.

Posição 3 – Decúbito dorsal, com travesseiro sob a cabeça, braços estendidos e rentes ao corpo e pernas estendidas e afastadas.

Posição 4 – Decúbito dorsal, com travesseiro sob a cabeça, braços estendidos e afastados do corpo e pernas estendidas e rentes ao corpo.

Posição 5 – Decúbito lateral, com um dos braços em abdução, pernas estendidas ao longo do corpo e o outro braço apoiado sobre a face lateral da coxa.

Figura 4. Posições corporais nos cinco registros fotográficos para cada paciente (Faria et al., 2023).



Os participantes foram identificados nos registros fotográficos e nos vídeos por meio de um número sequencial atribuído na ficha de coleta de dados (APÊNDICE A). Esse número foi escrito com pincel atômico em um bloco de notas autoadesivas (Post-it®) e fixado na parte inferior do leito hospitalar, permitindo a vinculação dos registros ao respectivo participante durante o processamento dos dados.

4.8 Anonimização das características faciais dos pacientes nos registros fotográficos e nos vídeos

A Lei Geral de Proteção de Dados Pessoais (LGPD) (Lei nº 13.709/2018) dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade, privacidade e o livre desenvolvimento da personalidade da pessoa natural. No contexto de pesquisas científicas e acadêmicas, a LGPD prevê hipóteses específicas para o tratamento de dados pessoais e dados sensíveis, desde que observados princípios como finalidade, necessidade, segurança e, sempre que possível, anonimização dos dados. Neste estudo, a utilização das imagens ocorreu mediante consentimento do participante e adoção de medidas voltadas à proteção da privacidade e confidencialidade das informações.

Ao término da captura dos registros fotográficos e da gravação dos vídeos, os arquivos foram transferidos via conexão USB para uma pasta no notebook do pesquisador. Após a transferência para a pasta do notebook, todos os registros fotográficos foram excluídos da memória do smartphone. Em seguida, foi realizado o tratamento das fotografias por meio do software Adobe Photoshop CC®, foi utilizada a ferramenta Laço Poligonal para seleção do rosto do paciente, posteriormente, foi utilizada a ferramenta de Pincel História da Arte para o borramento de toda a área do rosto selecionada. Com relação aos vídeos, também foi realizado o tratamento no software Sony Vegas Pro®, foi utilizada a ferramenta Over Circle Mask Creation Tool para selecionar o rosto do paciente, posteriormente, foi aplicado o efeito Sony Gaussian Blur para borramento de toda área do rosto selecionada. Portanto, toda a extensão do rosto do paciente foi borrada nas imagens e nos vídeos, mantendo assim a anonimização das características faciais do paciente.

4.9 Armazenamento e segurança dos registros fotográficos e dos vídeos

Após a realização do borramento das características faciais dos pacientes, os arquivos foram transferidos e armazenados no servidor local RedCap (Harris et al., 2019) da FEPECS, somente os pesquisadores tiveram posse da senha de acesso a esta conta. No servidor local RedCap da FEPECS foi criada uma ID para cada paciente de acordo com o número de identificação na pesquisa. Em seguida, os arquivos foram excluídos da pasta do notebook, ficando somente armazenados no servidor local RedCap® durante o período de coleta de dados. As imagens e os vídeos foram salvos em um mesmo diretório em formato padronizado, o nome da imagem e do vídeo foi composto pela identificação numérica gerada para o paciente, identificação da pose e data e a hora do registro fotográfico. A identificação numérica foi utilizada para relacionar as imagens e os vídeos com as respectivas aferições antropométricas.

4.10 Treinamento da arquitetura de aprendizado de máquina e avaliação do desempenho do modelo computacional.

4.10.1 Arquitetura proposta

O modelo computacional proposto foi estruturado como uma pipeline de extração de atributos visuais e tridimensionais seguida por modelos regressores para estimativa do peso corporal. A arquitetura combina informações provenientes da segmentação corporal, da estimativa de pose bidimensional e da reconstrução tridimensional do paciente, buscando representar características morfológicas relevantes para a predição antropométrica conforme exposto na figura 5.

Na primeira etapa, as imagens foram submetidas à segmentação da pessoa, com atualização do modelo utilizado no estudo piloto, trocando o YOLOv7-seg, para o modelo YOLO26-seg, que possui maior precisão e robustez de acordo com Jocher et al (2026). O objetivo dessa etapa foi isolar a região corporal do paciente, reduzir a interferência do fundo da imagem e gerar máscaras, recortes e imagens segmentadas para as etapas subsequentes. Quando havia mais de uma detecção de pessoa na imagem, foi selecionada a região de maior relevância com base na combinação entre centralidade e área ocupada no quadro. O pipeline gerou, para

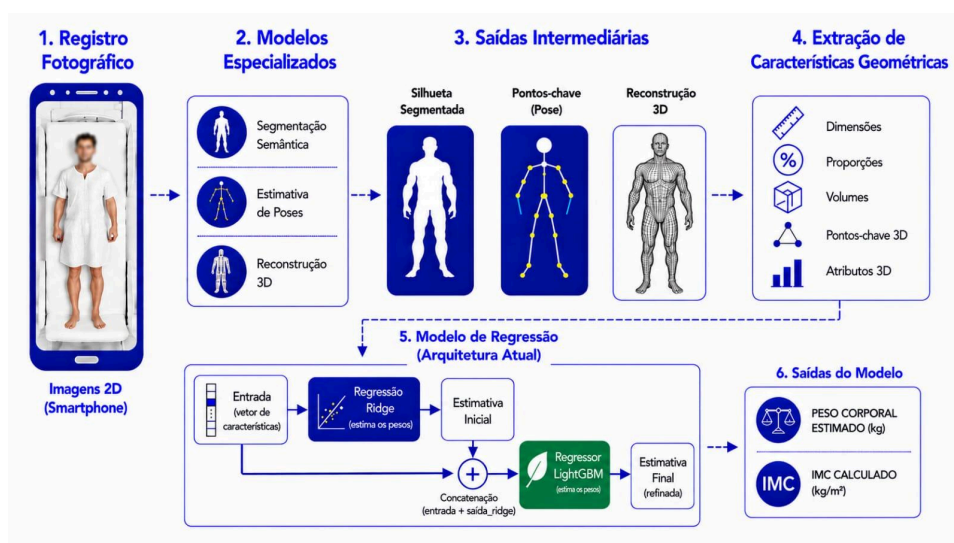
cada imagem processada, a máscara corporal, a caixa delimitadora e a imagem da pessoa isolada.

Em seguida, foi aplicada a estimativa de pose do estudo piloto com a atualização para YOLO26-pose, utilizando como entrada as imagens previamente segmentadas. Essa estratégia simplifica a tarefa do estimador de pose, uma vez que a imagem já destaca a pessoa de interesse. Foram extraídos 17 pontos anatômicos no padrão COCO, incluindo cabeça, ombros, cotovelos, punhos, quadris, joelhos e tornozelos, além das respectivas coordenadas e escores de visibilidade. Esses atributos permitiram representar a posição corporal do paciente na projeção da foto e fornecer descritores complementares à segmentação.

Paralelamente, foram extraídos atributos tridimensionais por modelos de reconstrução baseado no Momentum Human Rig. Esse componente reconstrói a pessoa em malha tridimensional e gera descritores relacionados à forma corporal, parâmetros do modelo, esqueleto, proporções, volumes e medidas geométricas derivadas. As features tridimensionais foram armazenadas por imagem em arquivo tabular, mantendo identificadores de rastreabilidade entre imagem, pessoa, malha gerada e atributos extraídos.

Os atributos tridimensionais compreenderam descritores morfológicos derivados da malha corporal reconstruída, incluindo parâmetros de forma global, proporções corporais, medidas geométricas aproximadas, volumes segmentares, áreas, larguras, comprimentos anatômicos e relações antropométricas. Esses atributos foram organizados em formato tabular e utilizados como variáveis de entrada dos modelos regressores.

Figura 5. Arquitetura aprimorada para estimativa do peso corporal em pacientes acamados utilizando imagens de smartphones.



Nota: IMC = Índice de Massa Corporal; LightGBM = Light Gradient Boosting Machine. A arquitetura integra segmentação semântica, estimativa de pose, reconstrução tridimensional e regressão para estimativa do peso corporal.

4.10.2 Pré-processamento e aumento de dados

Antes do treinamento dos modelos regressores, o banco de imagens foi submetido a uma etapa de pré-processamento e aumento de dados. O conjunto original continha 1.335 imagens referentes a 300 indivíduos, distribuídas de forma desigual entre as faixas de IMC. Para reduzir o desbalanceamento entre as classes, foi realizado oversampling com data augmentation e frames dos vídeos, com alvo de 600 imagens por faixa de IMC, resultando em 4.200 imagens planejadas.

As transformações aplicadas foram leves e compatíveis com variações esperadas na captura por smartphone, incluindo rotação limitada, translação horizontal e vertical, variação discreta de escala, espelhamento horizontal e ajustes de brilho e contraste. Essas transformações foram definidas de modo a aumentar a diversidade visual do conjunto sem distorcer significativamente as proporções corporais, aspecto crítico para a estimativa de peso e IMC.

Em razão do número reduzido de participantes na primeira faixa de IMC, essa faixa foi agrupada à faixa imediatamente subsequente para fins de estratificação e validação, evitando a formação de subconjuntos estatisticamente frágeis durante a divisão dos dados.

4.10.3 Extração e organização dos atributos

Após o pré-processamento, foram organizados três grupos principais de atributos: atributos derivados da segmentação corporal, atributos de pose e atributos tridimensionais. Os atributos de segmentação incluíram medidas da caixa delimitadora, área da máscara, proporção de preenchimento, centralidade e dimensões relativas da região corporal. Os atributos de pose incluíram as coordenadas dos pontos anatômicos e seus respectivos indicadores de visibilidade. Os atributos tridimensionais incluíram parâmetros de forma corporal, medidas geométricas da malha, proporções segmentares, volumes aproximados e descritores derivados da reconstrução 3D.

Todos os dados foram integrados por meio de identificadores únicos de imagem e de participantes. Essa organização permitiu que múltiplas imagens pertencentes ao mesmo indivíduo permanecessem vinculadas ao mesmo identificador, garantindo que todas fossem alocadas conjuntamente nos conjuntos de treinamento ou de validação. Essa estratégia foi adotada para evitar o vazamento de informação, situação em que imagens de um mesmo participante são distribuídas simultaneamente entre os conjuntos de treinamento e validação. Nesses casos, o modelo pode aprender características específicas daquele indivíduo durante o treinamento e apresentar desempenho artificialmente elevado na validação, comprometendo a avaliação da sua capacidade de generalização para novos pacientes.

4.10.4 Treinamento dos modelos regressores

O treinamento foi realizado na plataforma Google Colab®, com uso de GPU NVIDIA A100. Foram avaliadas diferentes configurações experimentais com modelos de regressão aplicados às features extraídas. As arquiteturas testadas incluíram regressão Ridge, Random Forest Regressor e LightGBM, além de uma configuração com empilhamento de modelos, na qual a predição *do fold* correspondente de um modelo Ridge foi utilizada como atributo adicional para o LightGBM. Da bateria de testes preliminares foi selecionado como modelo principal por apresentar o melhor MAE e R^2 , o empilhamento de Ridge com LightGBM usando um subconjunto selecionado de features tridimensionais (feature importance 95% corte). A seleção de atributos foi realizada dentro de cada partição de treinamento,

sem utilizar os dados de validação externa do respectivo fold, reduzindo o risco de viés por vazamento.

Tanto a nova arquitetura quanto a arquitetura atualizada do estudo piloto utilizaram o novo método de avaliação. Diferentemente da análise apresentada em Faria et al. (2023), baseada em uma divisão simples entre treino e teste, a avaliação atual incorporou validação cruzada repetida e estimativas de incerteza por *bootstrap*, técnica estatística baseada em reamostragens sucessivas dos dados que permite avaliar a estabilidade dos resultados e calcular intervalos de confiança para as métricas de desempenho. Essas estratégias proporcionam uma avaliação mais robusta e menos dependente de uma única divisão da amostra, permitindo comparação pareada entre os métodos no mesmo conjunto de participantes. Portanto, a comparação com a arquitetura anterior foi conduzida após a sua reexecução no conjunto de dados atual, sob os novos critérios analíticos descritos a seguir com mais detalhes.

4.10.5 Validação interna e avaliação de desempenho

A validação interna foi realizada por validação cruzada repetida 5×2, método no qual a amostra é repetidamente dividida em dois subconjuntos complementares para treinamento e validação do modelo, permitindo uma avaliação mais robusta e menos dependente de uma única divisão dos dados (Dietterich, 1998). A estratificação foi realizada por faixa de IMC e o agrupamento por indivíduo. Em cada repetição, os participantes foram divididos em duas metades complementares, preservando a separação pelo identificador único do participante. Dessa forma, imagens de um mesmo indivíduo não foram distribuídas simultaneamente entre os conjuntos de treinamento e validação.

Durante o treinamento, foram utilizadas imagens originais e imagens aumentadas pertencentes aos participantes alocados no conjunto de treinamento. A unidade de particionamento utilizada foi o participante e não a imagem. Dessa forma, todas as imagens associadas a um mesmo indivíduo permaneceram integralmente no conjunto de treinamento ou no conjunto de validação. Na etapa de validação, foram consideradas exclusivamente as imagens originais dos participantes alocados no conjunto de validação, evitando que imagens sintéticas derivadas influenciassem artificialmente as métricas de desempenho.

O desempenho dos modelos foi avaliado para estimativa de peso corporal e IMC. As predições obtidas em cada partição da validação cruzada foram armazenadas em diferentes níveis de agregação, incluindo predições por amostra e por indivíduo. Para as análises principais, adotou-se o indivíduo como unidade primária de inferência, e não cada imagem isoladamente, com o objetivo de reduzir o risco de pseudoreplicação decorrente da existência de múltiplas imagens por participante.

As métricas de desempenho incluíram medidas contínuas de erro, associação e concordância, além de métricas de aceitabilidade clínica baseadas na proporção de estimativas dentro de limites percentuais de erro em relação ao peso aferido. O detalhamento estatístico dessas métricas é apresentado na seção seguinte.

4.11.1 Análise estatística

Os dados sociodemográficos e antropométricos foram analisados por estatística descritiva. As variáveis categóricas, como sexo, raça/cor e faixa de IMC, foram descritas por frequências absolutas e percentuais. As variáveis contínuas, como idade e medidas antropométricas, foram apresentadas por média, desvio-padrão, mediana, mínimo e máximo, conforme aplicável.

A análise estatística do desempenho dos modelos foi realizada a partir das predições obtidas no protocolo de validação interna cruzada repetida 5×2. As análises principais foram conduzidas no nível do indivíduo.

As métricas contínuas utilizadas para avaliar o desempenho preditivo incluíram erro absoluto médio (MAE, *Mean Absolute Error*), erro quadrático médio (MSE, *Mean Squared Error*), raiz do erro quadrático médio (RMSE, *Root Mean Squared Error*), erro percentual absoluto médio (MAPE, *Mean Absolute Percentage Error*), erro absoluto mediano, coeficiente de determinação (R^2), viés médio e correlação de Pearson entre os valores estimados e aferidos. Para essas métricas, foram calculados intervalos de confiança de 95% por bootstrap com reamostragem.

A concordância entre os valores estimados e aferidos foi analisada por gráficos de Bland-Altman, com estimativa do viés médio e dos limites de concordância de 95%. Também foram avaliados indicadores de calibração, incluindo intercepto e inclinação da relação entre valores preditos e observados.

A validade clínica das estimativas de peso corporal foi avaliada pela proporção de predições dentro de limites percentuais de erro em relação ao peso

aferido. O endpoint primário do estudo foi definido como a proporção de estimativas de peso com erro absoluto percentual menor ou igual a 10% do peso aferido, denominada P10.

A hipótese principal considerou que o modelo final alcançaria P10 superior a 70%. Formalmente, a hipótese nula foi definida como:

$$H_0: p \leq 0,70$$

e a hipótese alternativa como:

$$H_1: p > 0,70$$

em que p representa a proporção verdadeira de estimativas de peso com erro absoluto percentual menor ou igual a 10%.

A análise do endpoint primário foi realizada por meio do teste binomial exato unilateral, com nível de significância de 5%, acompanhado de intervalo de confiança exato de 95% pelo método de Clopper-Pearson. Para essa inferência principal, foi considerado o modelo final previamente definido no protocolo analítico, correspondente à arquitetura baseada em atributos tridimensionais selecionados, predição *out-of-fold* por Ridge e regressão final por LightGBM.

Como análises secundárias, foram avaliadas as proporções de estimativas com erro absoluto percentual menor ou igual a 5% e 20%, denominadas P5 e P20, respectivamente. Para P5, o limiar de referência foi de 70%. Para P20, foi adotado limiar de referência de 95%. Essas proporções foram analisadas por teste binomial exato unilateral e acompanhadas por intervalos de confiança exatos de Clopper-Pearson.

A comparação entre o método final e o método anterior foi realizada como análise secundária, considerando apenas os participantes para os quais foram obtidas predições por ambos os modelos. Para cada participante, a estimativa gerada pelo modelo final foi comparada diretamente à estimativa gerada pela arquitetura anterior, permitindo uma comparação pareada utilizando o mesmo indivíduo como unidade de análise. Essa comparação foi conduzida com estimativa das diferenças de desempenho por *bootstrap*, incluindo métricas de erro, viés e proporções dentro dos limiares clínicos. Foram calculadas frequências de erros absolutos acima de limiares pré-definidos (>5 kg, >10 kg, >15 kg e >20 kg), com respectivas proporções e intervalos de confiança de 95% (IC 95%).

As análises relacionadas ao IMC foram tratadas como complementares, uma vez que o endpoint primário do estudo foi a estimativa do peso corporal. Para o IMC, foram avaliadas métricas contínuas de erro, concordância e desempenho por faixas de classificação, incluindo matriz de confusão, acurácia, precisão, sensibilidade/recall e F1-score, quando aplicável.

Análises por sexo, idade, faixa de IMC e posição da imagem foram conduzidas como exploratórias, com o objetivo de investigar padrões de erro, viés sistemático e possíveis limitações de generalização do modelo. Nos testes exploratórios com múltiplas comparações, foi aplicada correção pelo método de Benjamini e Hochberg (1995).

4.11.2 Interpretação das métricas utilizadas na avaliação do modelo

O desempenho do modelo de inteligência artificial foi avaliado por meio de métricas contínuas, relativas e de concordância, permitindo caracterizar tanto a magnitude média dos erros quanto a estabilidade e a capacidade preditiva das estimativas produzidas. A seguir, são apresentados os principais parâmetros utilizados e a forma de interpretação de cada métrica no contexto deste estudo.

4.11.2.1 Média absoluta do erro (MAE)

A média absoluta do erro (mean absolute error – MAE) representa a média das diferenças absolutas entre os valores estimados pelo modelo e os valores aferidos. Essa métrica expressa o erro médio esperado na mesma unidade da variável analisada. Valores menores indicam melhor desempenho do modelo, sendo uma das métricas mais utilizadas na avaliação de modelos preditivos devido à sua interpretação clínica direta (Chicco, Warrens, Jurman, 2021). Por exemplo, um MAE de 2 kg indica que, em média, as estimativas produzidas pelo modelo diferem aproximadamente 2 kg do valor aferido.

4.11.2.2 Erro percentual absoluto médio (MAPE)

O erro percentual absoluto médio (mean absolute percentage error – MAPE) representa o erro percentual médio entre os valores estimados e aferidos. Essa métrica permite interpretação relativa do erro independentemente da unidade de medida, facilitando comparações entre indivíduos com diferentes valores. Os valores menores indicam maior precisão relativa das estimativas (Chicco, Warrens, Jurman,

2021). Por exemplo, um MAPE de 5% indica que, em média, as estimativas apresentaram erro correspondente a aproximadamente 5% do valor real.

4.11.2.3 Raiz do erro quadrático médio (RMSE)

A raiz do erro quadrático médio (root mean squared error – RMSE) representa a raiz quadrada da média dos erros elevados ao quadrado. Diferentemente do MAE, essa métrica penaliza de forma mais intensa erros de maior magnitude. Os valores menores indicam melhor desempenho global do modelo. O RMSE é particularmente útil para identificar a presença de erros extremos ou maior dispersão residual (Chicco, Warrens, Jurman, 2021). Por exemplo, um RMSE de 3 kg sugere baixa influência de erros extremos sobre o desempenho global do modelo.

4.11.2.4 Métricas P10 e P20

As métricas P10 e P20 representam a proporção de estimativas realizadas dentro de limites percentuais pré-definidos em relação ao valor aferido. O P10 corresponde à proporção de estimativas com erro absoluto inferior a 10% do valor real, enquanto o P20 representa estimativas dentro de 20% do valor aferido. Valores mais elevados indicam maior proporção de estimativas clinicamente aceitáveis. Essas métricas são amplamente utilizadas em estudos de estimativa de peso corporal por refletirem diretamente a aplicabilidade clínica das estimativas produzidas pelo modelo (Wells, Henry e Goldstein, 2023). Por exemplo, um P10 de 75% indica que 75% das estimativas apresentaram erro inferior a 10% em relação ao valor real.

4.11.5 Coeficiente de determinação (R^2)

O coeficiente de determinação (R^2) representa a proporção da variabilidade dos valores aferidos que pode ser explicada pelo modelo. Os valores próximos de 1 indicam maior capacidade preditiva e melhor ajuste global entre os valores estimados e reais. Entretanto, o R^2 não representa diretamente concordância clínica ou magnitude absoluta do erro (Chicco, Warrens, Jurman, 2021). Por exemplo, um R^2 de 0,80 indica que aproximadamente 80% da variabilidade observada nos valores aferidos pode ser explicada pelas estimativas produzidas pelo modelo.

4.11.2.6 Correlação de Pearson

A correlação de Pearson avalia a intensidade da associação linear entre os valores estimados e aferidos. Valores próximos de 1 indicam forte associação linear positiva entre as medidas. Entretanto, métricas de correlação avaliam associação e não necessariamente concordância clínica entre métodos (Plevris et al., 2022). Por exemplo, uma correlação de Pearson de 0,90 indica forte associação linear entre os valores estimados e aferidos

4.11.2.7 Coeficiente de correlação intraclasse (CCI)

O coeficiente de correlação intraclasse (CCI) avalia o grau de concordância absoluta entre os valores estimados e aferidos. Os valores próximos de 1 indicam elevada concordância entre as medidas, refletindo maior reprodutibilidade e confiabilidade das estimativas produzidas pelo modelo (Koo, Li, 2016). Por exemplo, um CCI de 0,92 indica elevada concordância absoluta entre os valores estimados e aferidos.

4.11.2.8 Análise de Bland-Altman

A análise de Bland–Altman avalia a concordância entre os valores estimados e aferidos por meio da distribuição das diferenças individuais entre os métodos. Essa abordagem permite identificar o viés médio das estimativas e os limites de concordância. O viés médio corresponde à média das diferenças entre os valores estimados e reais, sendo valores positivos indicativos de tendência à superestimação e valores negativos indicativos de subestimação. Os limites de concordância representam o intervalo no qual aproximadamente 95% das diferenças individuais estão distribuídas (Bland, Altman, 1986). Por exemplo, um viés médio de +1 kg indica tendência média à superestimação de aproximadamente 1 kg em relação ao valor aferido, enquanto limites de concordância entre -10 kg e +10 kg indicam que aproximadamente 95% das diferenças individuais entre os métodos encontram-se dentro desse intervalo.

5.0 RESULTADOS

Os resultados são apresentados em alinhamento com os itens aplicáveis dos Frameworks TRIPOD+AI e STARD-AI, contemplando o fluxo dos dados, a unidade

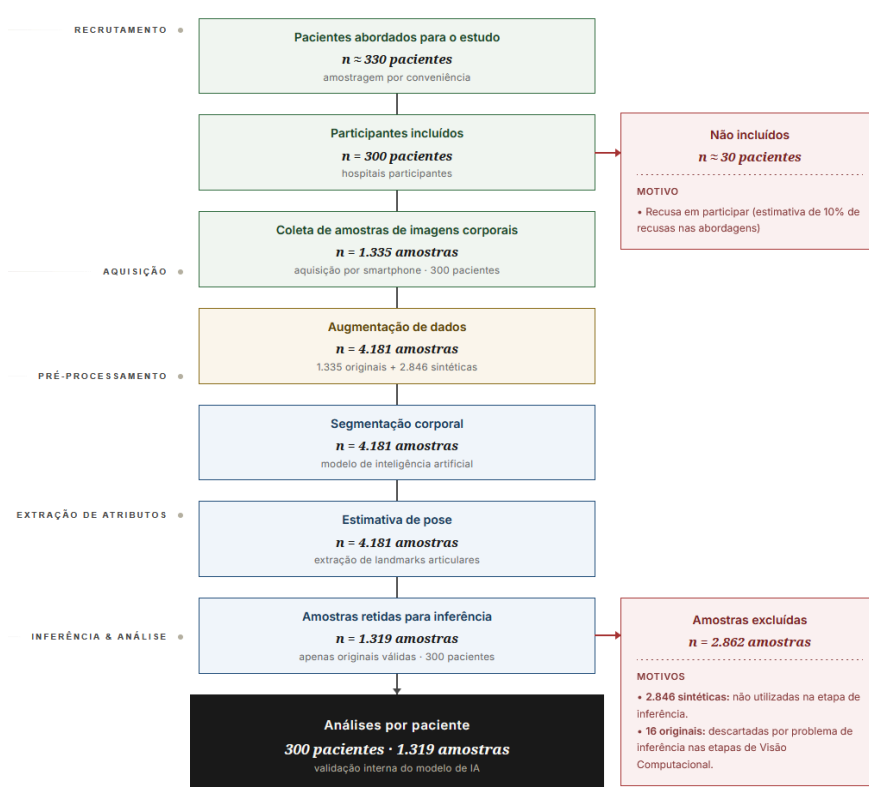
de análise, o modelo avaliado, o padrão de referência, as estimativas de desempenho, a incerteza associada e as análises exploratórias. A lista de verificação detalhada de aderência aos Frameworks é apresentada no Anexo I.

5.1 Amostra analisada e fluxo dos dados

Foram cadastrados 300 pacientes na base original. A análise final por pessoa incluiu cada um dos 300 participantes. A unidade primária de inferência foi o paciente, e não a imagem, com agregação por indivíduo dentro de cada partição da validação cruzada repetida descrita nos métodos. O tamanho amostral disponível ($n = 300$) excedeu o número mínimo estimado para obtenção de potência estatística de 80% ($n = 114$), sendo considerado suficiente para as análises propostas.

A base original continha 1.335 registros fotográficos de 300 pacientes. O Pipeline de segmentação e estimativa de pose gerou representações por imagem em múltiplas posições de captura, totalizando 4.181 amostras processadas. Para a análise final, foram considerados 1.319 registros únicos elegíveis, correspondentes a imagens originais com extração completa de atributos e ausência de falhas de qualidade na segmentação (Figura 6).

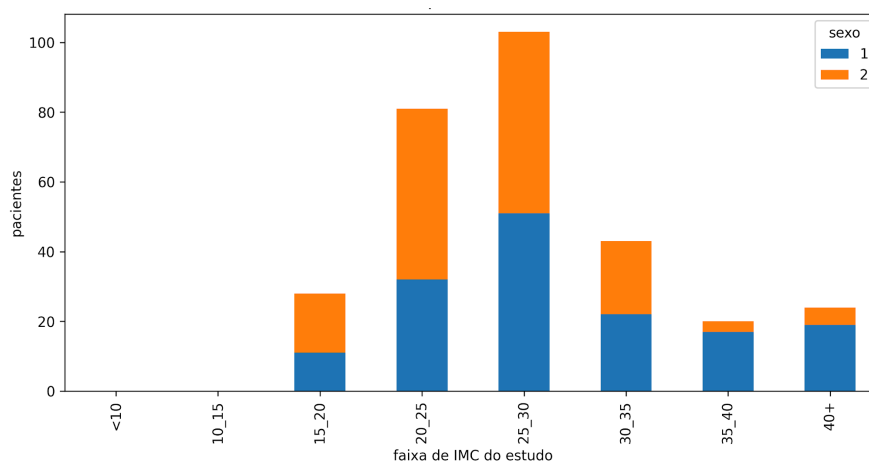
Figura 6. Fluxograma de inclusão dos participantes e processamento das imagens corporais do estudo.



A amostra analisada apresentou de idade média de $45,88 \pm 14,01$ anos, com distribuição equilibrada entre os sexos (51% feminino; 49% masculino). Em relação à faixa etária, 32 participantes (10,6%) tinham 65 anos ou mais. Foi realizada a distribuição da amostra em sete faixas de IMC, com intervalos de cinco em cinco kg/m^2 , iniciando em $\text{IMC} \geq 10 \text{ kg/m}^2$ e finalizando em $\text{IMC} \geq 40 \text{ kg/m}^2$, conforme apresentado na Tabela 4. Essa estratificação teve como objetivo avaliar a distribuição e o balanceamento da amostra entre diferentes categorias antropométricas, permitindo identificar a representatividade dos indivíduos ao longo das faixas de IMC, especialmente nos extremos da distribuição.


A distribuição dos participantes por sexo ao longo das diferentes faixas de IMC (Figura 7) demonstrou maior concentração nas categorias intermediárias, especialmente entre IMC de $20,0\text{--}24,9 \text{ kg/m}^2$ e $25,0\text{--}29,9 \text{ kg/m}^2$, com presença de ambos os sexos em todas as faixas e sem predominância marcante de um sexo específico. A distribuição da idade segundo as faixas de IMC (Figura 8) apresentou medianas semelhantes entre os grupos, concentradas principalmente entre 40 e 50 anos, com ampla sobreposição das distribuições e menor número de pacientes nas extremidades etárias (<20 e >70 anos). Não foi observada diferença estatisticamente significativa entre as faixas de IMC em relação à idade (Kruskal-Wallis, $p = 0,8266$).

Figura 7. Distribuição dos participantes por sexo segundo as faixas de IMC estabelecidas no estudo.



Nota: As barras representam o número de participantes em cada faixa de índice de massa corporal (IMC). A cor azul representa o sexo masculino e a cor laranja representa o sexo feminino. Faixas de IMC estabelecidas para o estudo: $<15,0 \text{ kg/m}^2$; $15,0\text{--}19,9 \text{ kg/m}^2$; $20,0\text{--}24,9 \text{ kg/m}^2$; $25,0\text{--}29,9 \text{ kg/m}^2$; $30,0\text{--}34,9 \text{ kg/m}^2$; $35,0\text{--}39,9 \text{ kg/m}^2$; e $\geq 40,0 \text{ kg/m}^2$.

Figura 8. Distribuição da idade pelas faixas de IMC estabelecidas no estudo.



Nota: Faixas de IMC estabelecidas no estudo: Faixas 1_2 (<20,0 kg/m²), Faixa 3 (20,0–24,9 kg/m²), Faixa 4 (25,0–29,9 kg/m²), Faixa 5 (30,0–34,9 kg/m²), Faixa 6 (35,0–39,9 kg/m²) e Faixa 7 (≥40,0 kg/m²).

Conforme a Tabela 3, o conjunto atual representa uma ampliação relevante do dataset anterior do estudo piloto, com aproximadamente o dobro de participantes incluídos na análise final e maior número de registros fotográficos. No total, foram obtidos mais de 1.300 registros entre fotografias e vídeos. Para cada participante, foram planejados cinco registros fotográficos, correspondentes às posições corporais previamente definidas no protocolo de coleta. Nos casos em que o paciente relatou impossibilidade de permanecer em decúbito lateral, por cirurgia recente, dor, desconforto ou limitação clínica, foram realizados quatro registros fotográficos em posição supina.

Em relação à caracterização da amostra, observa-se distribuição equilibrada entre os sexos no conjunto atual, em contraste com o conjunto anterior, que apresentava maior proporção de indivíduos do sexo masculino. As medidas antropométricas apresentaram valores médios semelhantes entre os conjuntos, incluindo peso corporal, estatura e IMC, indicando comparabilidade geral entre as amostras. De modo geral, o conjunto atual mantém características demográficas e antropométricas consistentes com o conjunto anterior, com ampliação do tamanho amostral e maior diversidade de registros.

Tabela 3. Caracterização comparativa da amostra entre o conjunto atual e o conjunto anterior.

Variável	Conjunto atual	Conjunto anterior
Pacientes incluídos na análise final (n)	300	150
Quantidade de registros (n)	1319	708
Sexo feminino, n (%)	153 (51%)	67 (45%)
Sexo masculino, n (%)	147 (49%)	83 (55%)
Idade (anos)	45,88 ± 14,01; md 47; 18–75	46 ± 14.51
Peso corporal aferido (kg)	76,65 ± 21,27; md 74,25; 34,80–172,35	71 ± 18.96
Estatura (m)	1,65 ± 0,09; md 1,65; 1,42–1,92	1.65 ± 0.09
IMC (kg/m ²)	28,22 ± 7,37; md 27,31; 15,53–64,99	27 ± 6.14

Nota: Valores contínuos expressos como média ± desvio padrão e mediana (mínimo – máximo). Valores categóricos expressos como número absoluto e porcentagem. IMC: índice de massa corporal. Dados de mediana e intervalo (mínimo–máximo) não estavam disponíveis para o conjunto anterior.

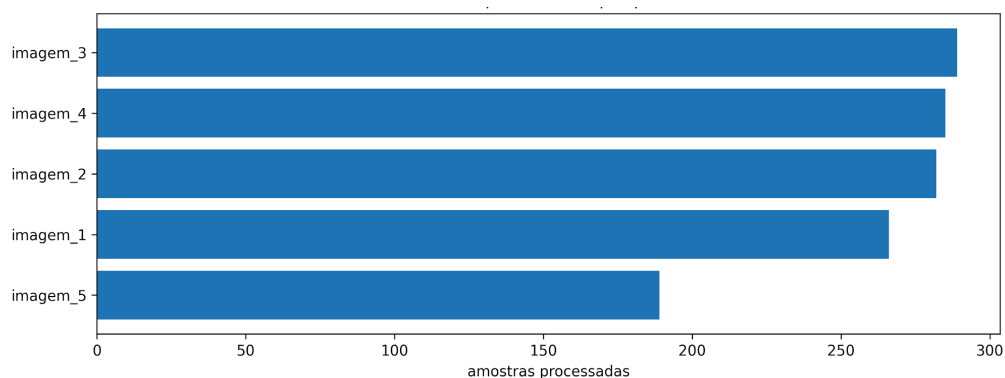
Conforme disposto na Tabela 4, observa-se maior concentração de pacientes nas faixas intermediárias de IMC, especialmente entre 25,00 e 29,99 kg/m² e entre 20,00 e 24,99 kg/m². As faixas inferiores e a categoria de IMC ≥ 40,00 kg/m² apresentaram menor representatividade. Em comparação ao conjunto anterior, nota-se padrão de distribuição semelhante, com predominância nas categorias intermediárias e menor frequência nas extremidades.

Tabela 4. Distribuição das faixas de IMC nos conjuntos atual e anterior.

Faixas de IMC (kg/m ²)	Conjunto atual (n=300), n (%)	Conjunto anterior (n= 150) n (%)
10,00–14,99	1 (0,3 %)	0 (0 %)
15,00–19,99	28 (9,3%)	12 (8,0%)
20,00–24,99	81 (27%)	52 (34,7%)
25,00–29,99	103 (34,3%)	52 (34,7%)
30,00–34,99	43 (14,3%)	18 (12,0%)
35,00–39,99	20 (6,7%)	7 (4,6%)
≥ 40,00	24 (8,0%)	9 (6,0%)

Nota: Valores apresentados como número absoluto e porcentagem [n (%)]. Percentuais calculados em relação ao total de cada conjunto.

A distribuição das amostras processadas segundo a posição de captura do registro fotográfico está apresentada na Figura 9. Observa-se participação de todas as posições avaliadas, com maior frequência nas posições correspondentes às imagens 2, 3 e 4, que apresentaram números semelhantes de registros. A posição referente à imagem 1 apresentou frequência ligeiramente inferior, enquanto a imagem 5 concentrou o menor número de amostras processadas.

Figura 9. Distribuição das imagens processadas segundo a posição corporal do participante.

Nota: imagem_1 = posição supina com braços e pernas estendidos e ligeiramente afastados do corpo; imagem_2 = posição supina com braços e pernas estendidos e rentes ao corpo; imagem_3 = posição supina com braços estendidos rentes ao corpo e pernas estendidas e afastadas; imagem_4 = posição supina com braços estendidos e afastados do corpo e pernas estendidas e rentes ao corpo; imagem_5 = posição em decúbito lateral com um dos braços em abdução e pernas estendidas ao longo do corpo.

5.2 Comparação com o método anterior

A comparação com o método anterior do estudo piloto, foi conduzida após a reexecução da arquitetura computacional anterior no conjunto de dados atual, sob os mesmos critérios analíticos descritos neste presente trabalho. Na comparação por indivíduo, o método final apresentou menor erro na estimativa de peso corporal em relação ao método anterior baseado em atributos bidimensionais e regressão por florestas aleatórias. O MAE foi reduzido de 13,16 kg para 5,24 kg, com melhora média pareada de 7,93 kg (IC 95%: 6,69–9,08). A proporção de estimativas dentro de 10% do peso aferido aumentou de 35% para 78,7%, correspondendo a ganho de 43,7 pontos percentuais (IC 95%: 34,4–48,8). Os resultados completos das métricas de erro, associação e desempenho clínico estão apresentados na Tabela 5.

Tabela 5. Comparação pareada do desempenho entre o modelo final e o modelo anterior na estimativa do peso corporal.

Métrica	Modelo final (IC 95%)	Modelo anterior (IC 95%)	Melhora do método final (IC 95%)
MAE (kg)	5,24 (4,62–5,88)	13,16 (12,01–14,34)	7,93 (6,69–9,08)
RMSE (kg)	7,60 (6,32–8,96)	16,92 (15,32–18,55)	9,32 (7,86–10,84)
MAPE (%)	6,90 (6,17–7,62)	19,06 (17,13–21,05)	12,16 (10,35–14,04)
R ²	0,873 (0,837–0,905)	0,372 (0,285–0,437)	0,501 (0,424–0,592)

Notas: Valores apresentados como estimativa pontual com intervalo de confiança de 95% (IC 95%) entre parênteses, quando disponível. MAE: erro absoluto médio (mean absolute error); RMSE: raiz do erro quadrático médio (root mean squared error); MAPE: erro percentual absoluto médio (mean absolute percentage error); R²: coeficiente de determinação; P10: proporção de estimativas dentro de $\pm 10\%$ do peso real. A diferença representa o ganho absoluto do modelo final em relação ao modelo anterior.

5.3 Desempenho do modelo final e avaliação da aceitabilidade clínica na estimativa de peso

O critério primário pré-especificado do estudo foi a proporção de estimativas de peso com erro absoluto percentual menor ou igual a 10% do peso aferido (P10).

O modelo final, definido a priori para essa inferência, baseia-se em atributos tridimensionais selecionados de forma aninhada, empilhamento por regressão regularizada e regressão final por *gradient boosting*.

O critério clínico primário P10 > 70% foi atingido, com IC 95% de 73,6%–83,2% e $p < 0,005$ no teste binomial exato unilateral. Para P20, apesar de o valor observado ser 95,7%, possui IC 95% de 93,2–97,7% e o p-valor foi 0,358, portanto, possui desempenho descritivo compatível com o limiar, mas sem confirmação estatística de superioridade (Tabela 6).

Tabela 6. Desempenho do modelo final para estimativa de peso corporal segundo critérios clínicos pré-especificados.

Critério clínico	Modelo final (%)	Limite inferior (IC 95%)	Modelo anterior (%)	Limite inferior (IC 95%)	Referência clínica
P5	46,3	41,5	18,3	14,7	≥ 70%
P10	78,7	73,6	35,0	30,4	> 70%
P20	95,7	93,2	64,7	59,9	≥ 95%

Notas: P5, P10 e P20 = proporção de estimativas de peso corporal que se encontram dentro de $\pm 5\%$, $\pm 10\%$ e $\pm 20\%$ do peso real mensurado, respectivamente. IC 95% = Limite inferior unilateral de 95%. Em negrito: critério atingido.

As métricas secundárias de desempenho, associação e concordância do modelo final estão apresentadas na Tabela 7. Observou-se elevado coeficiente de determinação ($R^2 = 0,873$; IC 95% 0,837–0,905), indicando forte capacidade explicativa do modelo. A correlação de Pearson foi de 0,935 (IC 95% 0,916–0,952), enquanto a correlação de Spearman foi de 0,947 (IC 95% 0,929–0,960), evidenciando forte associação linear e monotônica entre os valores estimados e aferidos.

O coeficiente de correlação intraclassa (CCI) foi de 0,931 (IC 95% 0,911–0,950), indicando alta concordância entre as medidas. O viés médio foi de 0,44 kg (IC 95% -0,41 a 1,31), próximo de zero e com intervalo de confiança que inclui o zero, sugerindo ausência de tendência sistemática consistente de superestimação ou subestimação. Os limites de concordância variaram de -14,46 kg

a +15,34 kg, indicando a amplitude das diferenças individuais entre os valores estimados e aferidos.

Tabela 7. Métricas secundárias de desempenho, associação e concordância do modelo final para estimativa de peso corporal.

Métrica	Resultado	IC 95%
R ²	0,873	0,837–0,905
Correlação de Pearson (r)	0,935	0,916–0,952
Correlação de Spearman (ρ)	0,947	0,929–0,960
CCI — concordância absoluta	0,931	0,911–0,950
Viés médio (kg)	0,44	–0,41–1,31
Limites de concordância (kg)	–14,46 a 15,34	Limite inferior: –17,58 a –11,64; Limite superior: 12,81 a 17,85

Nota: IC 95%: intervalo de confiança de 95%; R²: coeficiente de determinação; r: coeficiente de correlação de Pearson; ρ: coeficiente de correlação de Spearman; CCI: coeficiente de correlação intraclassa. O viés médio e os limites de concordância foram calculados pelo método de Bland-Altman. Os limites de concordância representam o intervalo entre a diferença média \pm 1,96 desvios-padrão. Para os limites de concordância, o IC 95% é apresentado separadamente para o limite inferior e para o limite superior.

Na Tabela 8, foi avaliada a frequência de erros absolutos acima de limiares pré-definidos em quilogramas, definidos como o módulo da diferença entre o peso estimado e o peso aferido. Foram analisados os limiares >5 kg, >10 kg, >15 kg e >20 kg, com o objetivo de caracterizar a distribuição da cauda de erro e identificar a ocorrência de estimativas potencialmente relevantes do ponto de vista clínico. Observou-se redução substancial da proporção de pacientes com erros elevados em todos os limiares avaliados. Para erros superiores a 5 kg, a frequência foi reduzida de 76,7% para 39,0%, correspondendo a redução relativa de 49,1%. Os resultados ainda mais expressivos foram observados nos limiares superiores, com redução de 53,3% para 13,0% nos erros >10 kg, de 35,3% para 3,7% nos erros >15 kg e de 22,7% para 2,7% nos erros >20 kg. As maiores reduções relativas ocorreram nos erros de maior magnitude, alcançando 89,6% para erros >15 kg e 88,2% para erros >20 kg, indicando importante diminuição da ocorrência de estimativas potencialmente críticas do ponto de vista clínico.

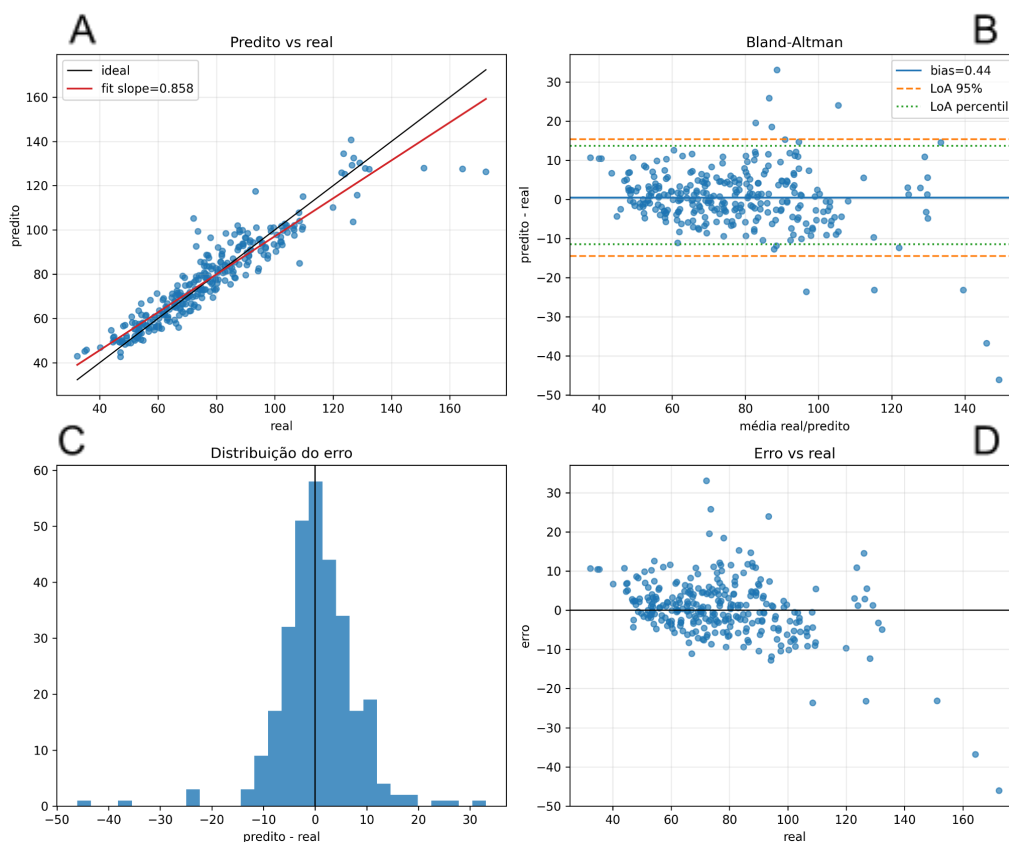
Tabela 8. Comparação da frequência de erros absolutos acima de limiares clínicos entre o método anterior e o modelo final.

Limiar de erro absoluto	Modelo anterior n/N (%) [IC 95%]	Modelo final n/N (%) [IC 95%]	Redução absoluta	Redução relativa
> 5 kg	230/300 (76,7%) [71,5–81,3]	117/300 (39,0%) [33,4–44,8]	37,7 p.p.	49,1%
> 10 kg	160/300 (53,3%) [47,5–59,1]	39/300 (13,0%) [9,4–17,3]	40,3 p.p.	75,6%
> 15 kg	106/300 (35,3%) [29,9–41,0]	11/300 (3,7%) [1,8–6,5]	31,7 p.p.	89,6%
> 20 kg	68/300 (22,7%) [18,1–27,8]	8/300 (2,7%) [1,2–5,2]	20,0 p.p.	88,2%

Nota: n/N (%) representa o número e a proporção de pacientes com erro absoluto superior ao limiar especificado. IC 95%: intervalo de confiança de 95% para a proporção; p.p.: pontos percentuais. Os limiares são apresentados de forma acumulada, portanto um paciente com erro > 20 kg também está incluído nos limiares > 15 kg, > 10 kg e > 5 kg.

A Figura 10 apresenta a avaliação do desempenho do modelo final por diferentes abordagens gráficas. No painel (A), observa-se forte relação linear entre os valores estimados e aferidos de peso corporal, com inclinação da reta de calibração de aproximadamente 1,018, indicando boa correspondência entre as medidas ao longo da faixa analisada. A correlação de calibração foi $r = 0,935$, reforçando a forte associação entre peso estimado e peso aferido. No painel (B), a análise de Bland–Altman demonstrou viés médio de 0,44 kg, indicando pequena tendência média à superestimação, sem diferença sistemática relevante. Os limites de concordância situaram-se entre $-14,46$ kg e $+15,34$ kg, refletindo a variabilidade das diferenças individuais. No painel (C), a distribuição dos erros apresentou comportamento aproximadamente centrado em torno de zero, indicando ausência de viés direcional expressivo nas estimativas. No painel (D), a relação entre erro e valor real evidenciou distribuição dos resíduos ao redor de zero ao longo da faixa analisada, com indício de aumento da dispersão nos valores mais elevados.

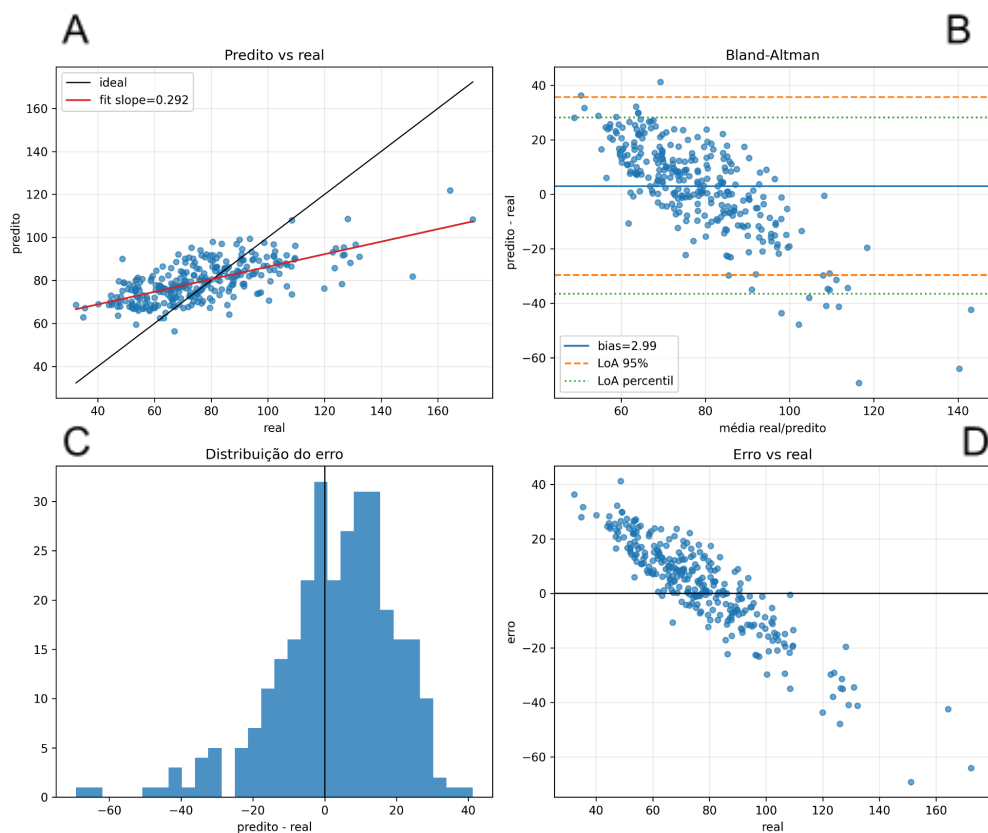
Figura 10. Avaliação do modelo final: (A) valores estimados vs. aferidos; (B) análise de Bland-Altman; (C) distribuição dos erros; (D) erro vs. valor real.



Quando comparado ao método anterior (Figura 11), o modelo final apresentou melhora substancial nas análises gráficas e quantitativas de desempenho. Na relação entre valores estimados e aferidos, observou-se aumento expressivo da associação entre as medidas, com correlação de Pearson passando de 0,666 no método anterior para 0,935 no modelo final, e R^2 passando de 0,372 para 0,873, indicando maior fidelidade das estimativas ao comportamento real do peso corporal.

Na análise de Bland–Altman, o modelo final apresentou viés médio de 0,44 kg, inferior ao observado no método anterior (2,99 kg), sugerindo menor tendência sistemática de erro. Além disso, houve redução importante da dispersão residual, refletida pela queda do RMSE de 16,92 kg para 7,60 kg e do MAE de 13,16 kg para 5,24 kg. A distribuição dos erros tornou-se mais concentrada em torno de zero, com menor frequência de erros extremos. Embora ainda haja variabilidade individual e indício de maior dispersão em valores mais elevados de peso, o padrão geral indica melhora consistente da acurácia, da associação e da concordância em relação ao método anterior.

Figura 11. Avaliação do modelo anterior: (A) valores estimados vs. aferidos; (B) análise de Bland-Altman; (C) distribuição dos erros; (D) erro vs. valor real.



5.4 Análises complementares

As análises complementares foram conduzidas em apoio ao objetivo principal do estudo, que consistiu na estimativa contínua do peso corporal. Em seguida, foi avaliado o desempenho do modelo segundo o critério P10, com os resultados apresentados de forma estratificada por sexo, idade, faixas etárias, posição do registro fotográfico e categorias de IMC.

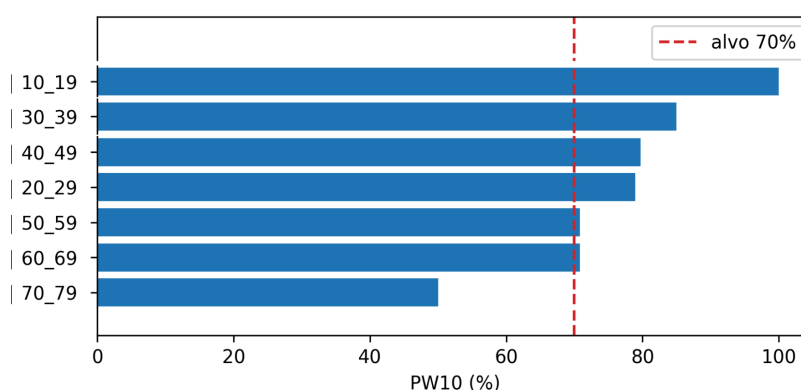
5.4.1 Análise por sexo, idade, faixa de IMC e posição corporal da imagem

As análises por sexo, idade, faixa de IMC e posição da imagem foram mantidas como exploratórias. Embora alguns estratos tenham apresentado P10 superior a 70%, não se adotou interpretação confirmatória para subgrupos sem atendimento simultâneo aos critérios de tamanho mínimo, limiar clínico e correção para múltiplas comparações.

O desempenho do modelo segundo o critério P10 variou entre os estratos

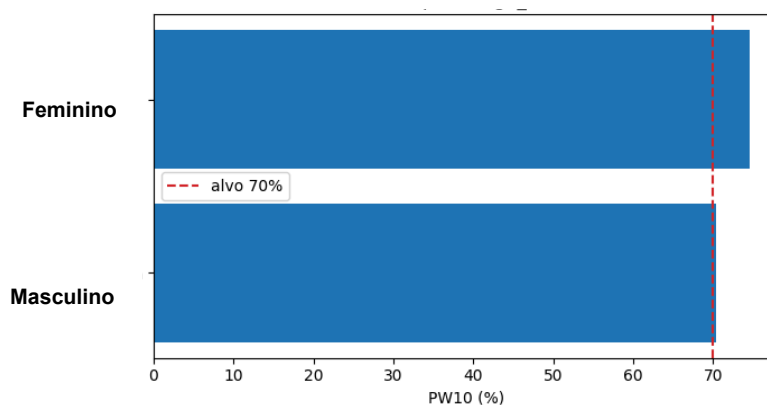
analisados (Figuras 12, 13, 14 e 15). Por faixa etária, a maioria dos grupos atingiu o limiar de 70%, com destaque para as faixas de 10–19 anos ($\approx 95\%$) e 30–39 anos ($\approx 85\%$), enquanto apenas a faixa de 70–79 anos apresentou desempenho inferior ao alvo estabelecido ($\approx 55\%$). Segundo o sexo, ambos os grupos apresentaram desempenho próximo ou superior ao alvo de 70%, sem diferenças expressivas entre eles. Em relação às faixas de IMC, as categorias intermediárias apresentaram melhor desempenho ($> 80\%$), ao passo que as faixas 1–2 ($\approx 45\%$) e 7 ($\approx 60\%$) permaneceram abaixo do limiar de 70%, enquanto as faixas adjacentes (3 e 6) apresentaram os maiores valores de P10. Por fim, considerando a posição do registro fotográfico, as cinco posições avaliadas apresentaram valores de P10 próximos ou superiores a 70%, sem variações relevantes entre os diferentes posicionamentos.

Figura 12. Desempenho do modelo (P10) por faixa etária.



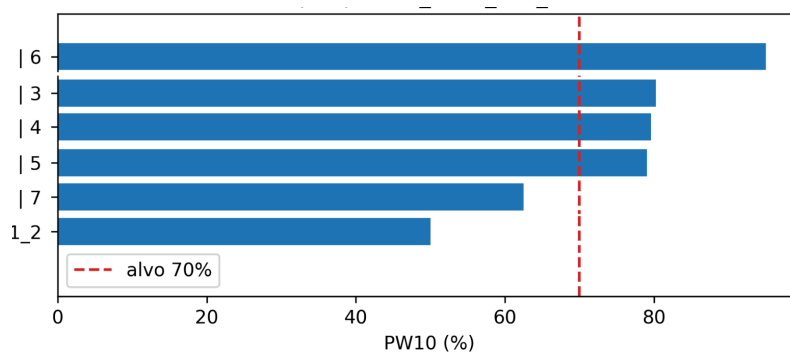
Notas: Nota: P10: proporção de estimativas com erro relativo inferior ou igual a 10% em relação ao peso aferido. A linha tracejada vermelha representa o critério de aceitabilidade clínica pré-especificado ($P10 \geq 70\%$).

Figura 13. Desempenho do modelo (P10) por sexo.




Notas: Nota: P10: proporção de estimativas com erro relativo inferior ou igual a 10% em relação ao peso aferido. A linha tracejada vermelha representa o critério de aceitabilidade clínica pré-especificado ($P10 \geq 70\%$).

Figura 14. Desempenho do modelo (P10) por faixas de IMC.



Notas: Nota: P10: proporção de estimativas com erro relativo inferior ou igual a 10% em relação ao peso aferido. A linha tracejada vermelha representa o critério de aceitabilidade clínica pré-especificado ($P10 \geq 70\%$).

Figura 15. Desempenho do modelo (P10) segundo a posição corporal da imagem.



Notas: Nota: P10: proporção de estimativas com erro relativo inferior ou igual a 10% em relação ao peso aferido. A linha tracejada vermelha representa o critério de aceitabilidade clínica pré-especificado ($P10 \geq 70\%$).

5.4.2 Análise do IMC

De forma consistente com os resultados observados para o peso corporal, a estimativa do IMC também apresentou melhora substancial de desempenho em relação ao método anterior, com redução do MAE de 4,61 para 1,905 kg/m² e aumento do R² de 0,358 para 0,866. O modelo final apresentou elevado desempenho preditivo e forte concordância com os valores aferidos (Tabela 9). O MAE foi de 1,905 kg/m², enquanto o RMSE foi de 2,697 kg/m², indicando baixo erro

médio das estimativas. O MAPE foi de 6,864%, sugerindo reduzido erro percentual relativo.

As métricas de associação e concordância também demonstraram desempenho robusto do modelo. O R^2 foi de 0,866, indicando elevada capacidade explicativa das estimativas em relação aos valores reais de IMC. A correlação de Pearson foi de 0,932, evidenciando forte associação linear entre os valores estimados e aferidos. De forma semelhante, o CCI foi de 0,926, indicando elevada concordância absoluta.

Na análise categórica, a acurácia global para classificação das categorias clínicas de IMC foi de 72,667%, enquanto a acurácia balanceada foi de 59,640%. A diferença entre essas métricas sugere influência do desbalanceamento entre as categorias de IMC avaliadas, com menor representatividade das classes extremas na amostra.


Tabela 9. Resultados complementares do modelo final para estimativa do IMC.

Métrica	Resultado IC 95%
MAE (kg/m ²)	1,905 (1,701–2,132)
RMSE (kg/m ²)	2,697 (2,262–3,190)
MAPE (%)	6,864 (6,186–7,578)
R^2	0,866 (0,822–0,8996)
Correlação de Pearson (r)	0,932 (0,909–0,951)
CCI (Concordância absoluta)	0,926 (0,902–0,943)
Acurácia (%)	72,667 (67,667–77,667)
Acurácia balanceada (%)	59,640 (53,929–64,694)

Nota: Valores apresentados como estimativa pontual com intervalo de confiança de 95% (IC 95%) entre parênteses, quando disponível. MAE: erro absoluto médio (mean absolute error); RMSE: raiz do erro quadrático médio (root mean squared error); MAPE: erro percentual absoluto médio (mean absolute percentage error); R^2 : coeficiente de determinação; CCI: coeficiente de correlação intraclass. A acurácia por faixas clínicas de IMC representa a proporção de classificações corretas nas categorias clínicas. A acurácia balanceada considera o desempenho médio entre as classes, mitigando o efeito de desbalanceamento.

A matriz de confusão (Figura 15) baseada nos pontos de corte clínicos da OMS (2000) demonstrou predominância de classificações corretas na diagonal principal, indicando adequada discriminação entre as categorias de IMC. Os erros ocorreram predominantemente entre classes adjacentes, especialmente entre eutrofia, sobrepeso e obesidade classe I, refletindo a proximidade dos limites de classificação. Os erros entre categorias clinicamente distantes foram raros, sugerindo preservação da coerência ordinal das predições do modelo. As categorias extremas, particularmente baixo peso e obesidade classe III, apresentaram menor número de observações e maior dispersão relativa das classificações.

Figura 16. Matriz de confusão das classificações de IMC segundo os pontos de corte da OMS (2000) para o modelo final.



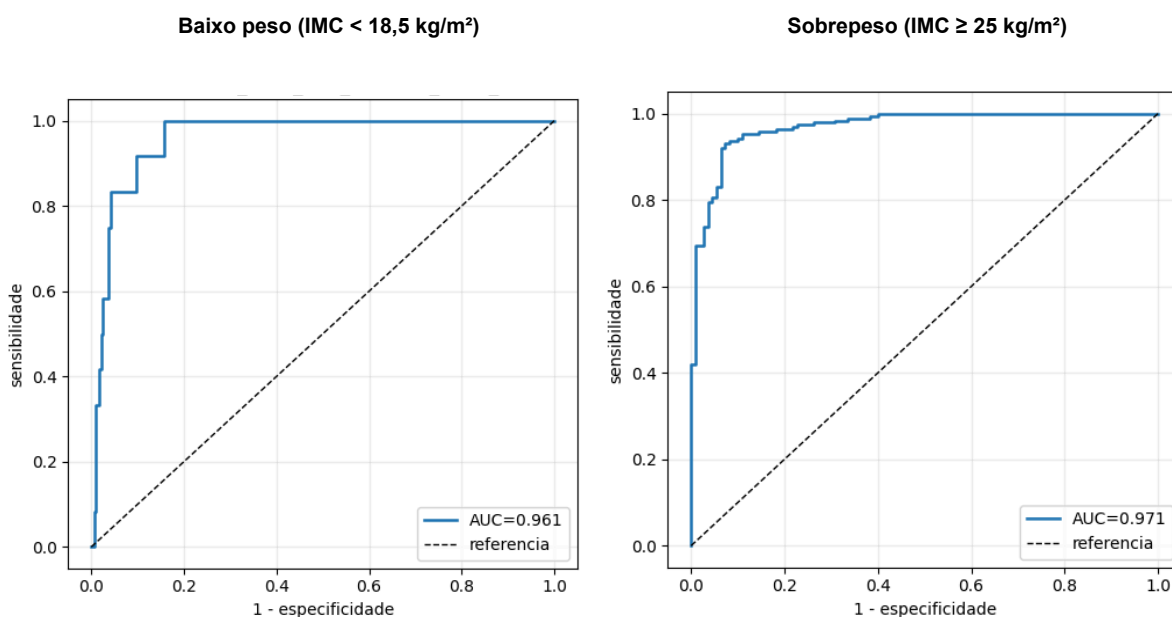
Nota: As linhas representam as classes reais e as colunas as classes preditas. Os valores indicam o número de observações em cada combinação. A diagonal principal representa as classificações corretas.

As curvas ROC para a classificação das categorias de IMC estão apresentadas nas Figuras 17A, 17B e 17C. Embora a curva ROC seja originalmente definida para desfechos binários, sua aplicação em problemas multiclasse foi realizada por meio da estratégia *one-vs-rest*, na qual cada classe é considerada individualmente como positiva em relação às demais. Dessa forma, foram estimadas, para cada categoria, a sensibilidade, a taxa de falso positivo (1 - especificidade) e a respectiva área sob a curva.

A classificação de indivíduos com baixo peso (IMC < 18,5 kg/m²) e sobrepeso

($\text{IMC} \geq 25 \text{ kg/m}^2$) apresentou excelente desempenho discriminativo pelo modelo final (Figura 17A). A área sob a curva (AUC) foi de 0,961 para baixo peso e 0,971 para sobrepeso, indicando elevada sensibilidade e especificidade para ambas as classificações. Observa-se que as curvas permaneceram substancialmente afastadas da linha diagonal de referência, evidenciando desempenho significativamente superior ao acaso. O desempenho discretamente superior na identificação de indivíduos com sobrepeso pode estar relacionado à maior representatividade dessa categoria na amostra e à menor sobreposição com as categorias de baixo IMC.

Figura 17A. Curvas ROC para identificação de baixo peso ($\text{IMC} < 18,5 \text{ kg/m}^2$) e de sobrepeso ($\text{IMC} \geq 25 \text{ kg/m}^2$) segundo critérios da OMS (2000).

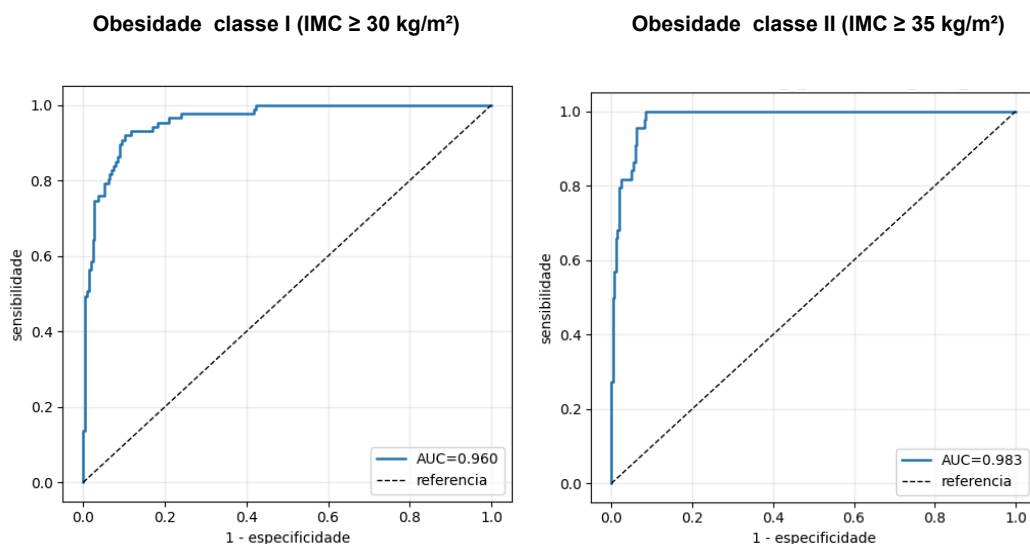


Notas: AUC: área sob a curva ROC. O gráfico à esquerda corresponde à identificação de baixo peso ($\text{IMC} < 18,5 \text{ kg/m}^2$) e o gráfico à direita à identificação de sobrepeso ($\text{IMC} \geq 25 \text{ kg/m}^2$), conforme critérios da OMS (2000).

A identificação de indivíduos com obesidade classe I ($\text{IMC} \geq 30 \text{ kg/m}^2$) e obesidade classe II ($\text{IMC} \geq 35 \text{ kg/m}^2$) também apresentou elevado desempenho discriminativo pelo modelo final (Figura 17B). A área sob a curva (AUC) foi de 0,960 para obesidade classe I e 0,983 para obesidade classe II, indicando excelente capacidade de distinção entre indivíduos pertencentes e não pertencentes a essas categorias clínicas. As curvas mantiveram-se distantes da linha diagonal de referência e próximas ao canto superior esquerdo do gráfico, sugerindo combinação

favorável entre sensibilidade e especificidade. O melhor desempenho observado para obesidade classe II pode refletir maior separação entre os padrões corporais dessa categoria e das demais faixas de IMC.

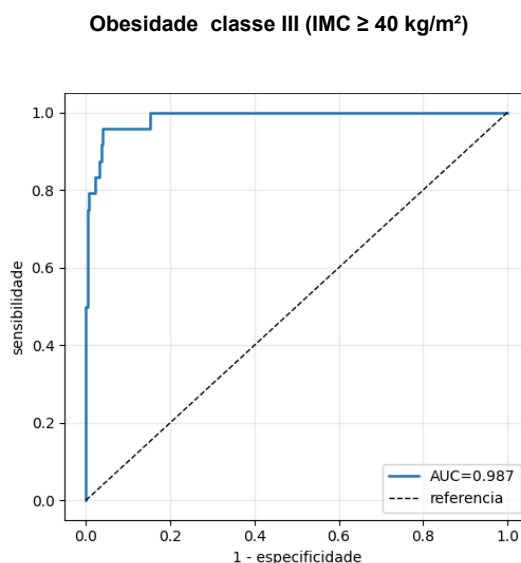
Figura 17B. Curvas ROC para identificação de obesidade classe I (IMC ≥ 30 kg/m²) e de obesidade classe II (IMC ≥ 35 kg/m²) segundo critérios da OMS (2000).



Nota: AUC: área sob a curva ROC. O gráfico à esquerda corresponde à identificação de obesidade (IMC ≥ 30 kg/m²) e o gráfico à direita à identificação de obesidade grau II (IMC ≥ 35 kg/m²), conforme critérios da OMS (2000).

A identificação de indivíduos com obesidade classe III (IMC ≥ 40 kg/m²) apresentou desempenho discriminativo quase perfeito pelo modelo final (Figura 17C). A área sob a curva (AUC) foi de 0,987, indicando excelente capacidade de distinção entre indivíduos pertencentes e não pertencentes a essa categoria clínica. Observa-se que a curva permaneceu substancialmente afastada da linha diagonal de referência e próxima ao canto superior esquerdo do gráfico, sugerindo elevada sensibilidade associada a baixa taxa de falso-positivos. Este resultado sugere elevada consistência do modelo na identificação de indivíduos com valores extremos de IMC.

Figura 17C. Curva ROC para identificação de obesidade classe III (IMC ≥ 40 kg/m²) segundo critérios da OMS (2000).



Nota: AUC: área sob a curva ROC. A curva ROC apresentada corresponde à identificação de obesidade classe III (IMC ≥ 40 kg/m²), conforme critérios da OMS (2000).

6.0 DISCUSSÃO

6.1 Síntese dos principais achados

Este estudo avaliou o aprimoramento de um modelo de inteligência artificial para estimativa de peso corporal a partir de imagens obtidas por smartphone em ambiente hospitalar. Em comparação com o método anterior, o modelo final apresentou redução do erro absoluto médio de 13,16 kg para 5,24 kg e elevou a proporção de estimativas dentro de 10% do peso aferido de 35,0% para 78,7%, atingindo o critério primário pré-especificado de P10 superior a 70% na validação interna cruzada.

Adicionalmente, o modelo apresentou P20 de 95,7%, indicando que a maioria das estimativas permaneceu dentro de 20% do peso corporal real. Esse achado sugere desempenho favorável como parâmetro complementar de segurança, pois indica menor ocorrência de erros de grande magnitude. Entretanto, esse resultado deve ser interpretado de forma descritiva, uma vez que a superioridade estatística em relação ao limiar de 95% não foi confirmada pelo teste binomial unilateral. Assim, enquanto o P10 representa o principal critério de precisão clínica adotado neste estudo, o P20 fornece uma medida complementar da capacidade do modelo em

evitar erros potencialmente relevantes para decisões clínicas e prescrições baseadas no peso corporal (Wells, Henry e Goldstein, 2023).

A análise dos erros absolutos acima de limiares pré-definidos em quilogramas reforçou essa interpretação. Em comparação ao modelo anterior, o modelo final reduziu a frequência de erros superiores a 5 kg de 76,7% para 39,0%, erros superiores a 10 kg de 53,3% para 13,0%, erros superiores a 15 kg de 35,3% para 3,7% e erros superiores a 20 kg de 22,7% para 2,7%. Essa análise complementa métricas globais, como MAE, RMSE, R^2 e coeficientes de correlação, pois permite avaliar diretamente a cauda da distribuição dos erros. Em contexto clínico, essa informação é relevante porque poucos erros de grande magnitude podem ter impacto desproporcional sobre decisões assistenciais, especialmente quando o peso estimado é utilizado para cálculo de necessidades nutricionais, planejamento terapêutico ou ajuste de condutas dependentes do peso corporal.

O modelo final também apresentou desempenho agregado favorável, com correlações elevadas, coeficiente de correlação intraclassa de concordância absoluta superior a 0,93 e calibração linear próxima da reta ideal. Esses resultados indicam boa capacidade de ordenação dos indivíduos segundo o peso corporal e adequada concordância geral entre valores estimados e aferidos. O coeficiente de determinação sugere que uma proporção substancial da variabilidade do peso corporal foi explicada pelo modelo, embora ainda exista variação residual não capturada pelas variáveis extraídas das imagens e pelos atributos utilizados na modelagem.

Apesar desses resultados, a variabilidade individual observada nos limites de concordância de Bland–Altman ($-14,46$ a $+15,34$ kg) indica que o modelo ainda não deve ser interpretado como substituto direto da aferição do peso em situações nas quais a precisão individual em quilogramas seja crítica, como em doses medicamentosas de estreita margem terapêutica ou intervenções nutricionais altamente dependentes de estimativas exatas. Essa limitação é particularmente importante porque métricas agregadas elevadas podem coexistir com erros individuais relevantes.

Dessa forma, o conjunto de evidências sustenta a continuidade do desenvolvimento da solução em cenário clínico, especialmente como ferramenta auxiliar para estimativa de peso corporal em pacientes acamados quando a aferição direta não for viável. No entanto, antes de sua adoção assistencial ampla, são

necessárias etapas adicionais de validação externa, avaliação prospectiva em campo e análise do desempenho em subgrupos clínicos, faixas de IMC, posições corporais e condições reais de uso por operadores.

6.2 Características, heterogeneidade e representatividade do conjunto de dados em ambiente clínico real

A coleta de dados foi realizada em ambiente hospitalar público real no Distrito Federal, abrangendo cinco hospitais públicos, sendo dois localizados em regiões centrais e três em cidades satélites, o que amplia a representatividade da amostra em diferentes contextos socioeconômicos e estruturais. O Distrito Federal é marcado por significativa diversidade regional, decorrente de intensos fluxos migratórios internos. Segundo a Pesquisa Distrital por Amostra de Domicílios Ampliada (PDAD-A, 2024), uma parcela expressiva da população residente não é natural da região; em áreas centrais, como o Plano Piloto, aproximadamente 57,6% dos habitantes nasceram em outros estados. Além disso, observa-se composição heterogênea quanto à origem regional, com predominância de migrantes do Sudeste em áreas centrais e do Nordeste em regiões periféricas e rurais, onde estes podem representar mais de 60% dos migrantes.

Essa característica confere ao conjunto de dados elevada heterogeneidade, incorporando variações antropométricas, culturais, étnicas e contextuais relevantes. Estudos de ancestralidade genética na população do Distrito Federal também demonstram ampla variabilidade interindividual, com média aproximada de 69,9% de contribuição europeia, 19,8% africana e 8,6% nativa americana, além de elevados desvios padrão entre indivíduos, reforçando a diversidade biológica da amostra (Sousa, 2023).

Adicionalmente, os dados foram coletados em condições reais de prática clínica, sem controle estrito de variáveis ambientais e estruturais, refletindo a realidade de muitos cenários de saúde pública no Brasil. Os aspectos como iluminação não padronizada, variações na altura dos leitos, limitações estruturais, incluindo camas com falhas de regulagem de altura e cabeceiras inoperantes, bem como diferentes condições de posicionamento dos pacientes, estiveram presentes durante a aquisição das imagens.

Outro aspecto relevante foi a inclusão de múltiplas posições corporais de

captura das fotos. Embora o protocolo previsse registros em posições padronizadas, parte dos participantes apresentava limitações clínicas, desconforto, dor e restrições pós-operatórias. Dessa forma, o conjunto de dados incorporou condições frequentemente observadas na prática hospitalar, especialmente em pacientes acamados. Essa estratégia amplia a robustez operacional do modelo, permitindo potencial aplicabilidade mesmo em cenários nos quais a padronização completa da captura não seja viável.

Além disso, o conjunto de dados também incorporou variabilidade inerente ao ambiente hospitalar, incluindo diferenças de iluminação, enquadramento, dispositivos de captura, presença de dispositivos médicos, organização do leito e variações relacionadas às vestimentas hospitalares dos pacientes. Em muitos casos, as roupas hospitalares dos pacientes apresentavam ajustes distintos ao corpo, podendo estar mais folgadas ou mais justas, condição que potencialmente interfere na percepção visual do contorno corporal e acrescenta complexidade à análise computacional. Embora esses fatores aumentem o ruído do conjunto de dados e tornem a tarefa preditiva mais desafiadora, sua inclusão tende a favorecer maior validade externa do modelo, reduzindo a discrepância entre o desempenho experimental e a aplicação clínica real.

Essa ausência de padronização reflete a complexidade do ambiente hospitalar público e reproduz com maior fidelidade o contexto de aplicação do modelo de inteligência artificial. Diferentemente de estudos conduzidos em cenários controlados, como os de Pfitzner, May e Nüchter (2018), Sonar et al. (2025) e aqueles sintetizados na revisão de Wells et al. (2024), nos quais as condições são rigidamente ajustadas para otimizar o desempenho dos modelos, o presente conjunto de dados incorpora o “ruído” inerente ao mundo real. Nesse sentido, modelos que não são treinados para lidar com essa variabilidade tendem a apresentar desempenho inferior quando aplicados em contextos clínicos reais (El Arab et al., 2025).

6.3 Comparação com abordagens baseadas em inteligência artificial para estimativa do peso corporal: implicações para aplicabilidade clínica

A revisão conduzida por Wells et al. (2024) destaca o potencial de tecnologias baseadas em sistemas de captura tridimensional para a estimativa do peso corporal,

com resultados frequentemente elevados, atingindo valores de P10 próximos a 90% e, em todos os estudos analisados, superiores a 78%. Esses achados demonstram que abordagens baseadas em inteligência artificial e sensores de profundidade podem alcançar elevados níveis de acurácia em cenários experimentais.

Entretanto, aspectos metodológicos relevantes devem ser considerados na interpretação desses resultados. Conforme destacado pelos próprios autores Wells et al. (2024), a maioria dos estudos foi conduzida em ambientes controlados, com limitações relacionadas ao tamanho amostral, diversidade populacional e ausência de validação em cenários clínicos reais. Nesse contexto, ao considerar o critério de aceitabilidade clínica baseado na proporção de estimativas dentro de 10% do valor real ($P10 \geq 70\%$), observa-se que o modelo desenvolvido no presente estudo também atingiu esse limiar, mesmo sendo treinado e avaliado em um ambiente caracterizado por elevada variabilidade e ausência de controle rigoroso das condições de aquisição. Esse aspecto é particularmente relevante, pois sugere que níveis clinicamente aceitáveis de precisão podem ser alcançados mesmo em cenários mais próximos da prática assistencial real.

Dessa forma, enquanto as tecnologias baseadas em captura tridimensional demonstram elevado desempenho em condições experimentais, a abordagem proposta neste estudo se diferencia ao priorizar não apenas o desempenho preditivo, mas também a viabilidade operacional e a aplicabilidade clínica. Ao utilizar dispositivos amplamente disponíveis e de fácil acesso, como smartphones convencionais, e conduzir o desenvolvimento do modelo em condições próximas à prática assistencial real, o estudo contribui para aproximar soluções baseadas em inteligência artificial da realidade clínica, favorecendo potencial aplicabilidade em diferentes cenários hospitalares sem necessidade de infraestrutura tecnológica especializada.

6.4 Relevância clínica e implicações dos métodos de estimativa de peso corporal na prática multiprofissional

A estimativa de peso em pacientes acamados permanece um problema frequente na prática hospitalar e impacta diretamente a atuação da equipe multiprofissional. O peso corporal é uma variável central para o cálculo de necessidades energéticas e proteicas, ajuste de terapias nutricionais, definição de

doses farmacológicas e tomada de decisões clínicas por médicos, nutricionistas e farmacêuticos, que dependem de uma referência antropométrica confiável.

Na prática clínica, profissionais como médicos e farmacêuticos lidam frequentemente com medicamentos que requerem ajuste de dose com base no peso corporal, incluindo trombolíticos, anticoagulantes, antibióticos potencialmente nefrotóxicos, drogas vasoativas, quimioterápicos, sedativos e anestésicos. Em situações de urgência, como no AVCi, a necessidade de tratamento em janela terapêutica limitada faz com que o peso corporal seja estimado em até 85% dos casos. No entanto, evidências indicam que discrepâncias superiores a 10% entre o peso estimado e o peso real podem estar associadas a um aumento de até 250% em desfechos clínicos desfavoráveis (Wells, Goldstein, Cattermole, 2022).

Diante desse cenário, a precisão da estimativa do peso corporal torna-se um fator crítico, uma vez que impacta diretamente na adequação da dose administrada, podendo resultar em subdosagem (ineficácia terapêutica) ou sobredosagem (toxicidade), com potenciais consequências graves, incluindo aumento de morbimortalidade. Assim, a estimativa precisa do peso corporal é fundamental para a segurança e efetividade das intervenções clínicas, sendo particularmente relevante em diferentes cenários assistenciais, como no atendimento pré-hospitalar, emergência, pronto-socorro, UTI, centros cirúrgicos e enfermarias em geral (Wells, Goldstein, Cattermole, 2022).

De forma complementar, na prática clínica do nutricionista, a estimativa do peso corporal em pacientes acamados também desempenha papel fundamental. A superestimação do peso pode levar à prescrição de aportes calóricos e proteicos superiores às necessidades reais do paciente. Em indivíduos em terapia nutricional enteral ou parenteral, esse erro assume maior relevância clínica, pois pode contribuir para o desenvolvimento da síndrome da realimentação, especialmente quando a oferta nutricional é iniciada de forma inadequadamente agressiva. A ocorrência dessa síndrome está associada a piores desfechos clínicos, incluindo aumento do tempo de internação e maior risco de mortalidade (Da Silva et al., 2020).

Por outro lado, a subestimação do peso corporal pode resultar na prescrição de aporte energético e proteico insuficiente, favorecendo o desenvolvimento ou agravamento da desnutrição. Esse cenário compromete a recuperação clínica, prolonga o tempo de hospitalização e está associado a maior incidência de complicações infecciosas e pior prognóstico geral (Da Silva et al., 2020).

A relevância clínica dos erros na estimativa do peso corporal depende diretamente da decisão terapêutica que será tomada a partir dessa informação. Na prescrição nutricional, por exemplo, um erro de ± 5 kg em um paciente de 80 kg resultaria em uma diferença aproximada de ± 125 a 150 kcal/dia, considerando recomendações usuais de 25 a 30 kcal/kg/dia. Em muitos casos, essa variação pode ser corrigida por meio do monitoramento clínico e dos ajustes rotineiros da terapia nutricional. Entretanto, erros mais expressivos podem comprometer a estratificação do risco de síndrome da realimentação e influenciar decisões clínicas dependentes do peso corporal, incluindo a prescrição de anticoagulantes, aminoglicosídeos e agentes trombolíticos (Da Silva et al., 2020).

Sob essa perspectiva, o presente estudo adotou como critério de aceitabilidade clínica o atingimento de $P10 > 70\%$, conforme proposto na literatura, uma vez que esse limiar foi estabelecido como condição para que o erro na estimativa do peso corporal resulta em variações inferiores a 5% em prescrições baseadas no peso corporal, especialmente medicamentosas (Wells et al., 2024). Assim, ao atingir esse critério, o modelo demonstra potencial para utilização como ferramenta de apoio à prescrição em cenários nos quais a aferição direta do peso não é viável ou disponível, condicionado à próxima etapa de validação externa e à avaliação de segurança e desempenho em ambiente assistencial real.

Além disso, os métodos indiretos convencionais frequentemente utilizados na prática clínica para estimativa do peso corporal, como as fórmulas de Chumlea (1988) e Rabito (2006), dependem da mensuração de múltiplos segmentos corporais como CB, CP, AJ e CA, seguida da aplicação de equações preditivas para obtenção da estimativa do peso corporal. Esse processo demanda tempo, treinamento da equipe e maior manipulação do paciente, além de estar sujeito à variabilidade interobservador e a dificuldades operacionais relacionadas ao posicionamento adequado do paciente e à obtenção precisa das medidas antropométricas nos marcos anatômicos (Santos, Camargo e Paulo, 2012; Saueressig et al., 2023).

Embora estudos brasileiros tenham demonstrado concordância variável entre essas fórmulas e o peso aferido, a maior parte das investigações nacionais concentra-se em métricas como correlação, concordância e erro médio, sem reportar critérios contemporâneos de aceitabilidade clínica, como $P10$ e $P20$ (Rezende et al., 2009; Melo et al., 2014; Saueressig et al., 2023). Nesse contexto, a utilização de métricas padronizadas de aceitabilidade clínica, como $P10 > 70\%$ e

P20 > 95%, conforme proposto por Wells et al (2024), contribui para avaliação mais objetiva da aplicabilidade clínica dos métodos de estimativa do peso corporal, especialmente em cenários nos quais decisões terapêuticas e prescrições são diretamente dependentes da estimativa do peso corporal.

Em contraste, a abordagem baseada em inteligência artificial proposta neste estudo pode possibilitar a obtenção de estimativas confiáveis em poucos segundos, a partir de registros fotográficos obtidos por smartphones, reduzindo a complexidade operacional do processo e contribuindo para maior produtividade assistencial e integração ao fluxo clínico hospitalar. Adicionalmente, a interpretação dos resultados por estratos requer cautela, especialmente nos extremos antropométricos, conforme discutido na seção de limitações.

6.5 Interpretação do ganho em relação ao modelo anterior

A diferença observada em relação ao modelo anterior pode ser atribuída à combinação de três mudanças metodológicas: incorporação de atributos tridimensionais derivados da reconstrução de forma corporal, seleção aninhada de variáveis dentro das partições de treino e empilhamento de predições por regressão regularizada com regressão final por gradient boosting. Essa arquitetura desloca o modelo de uma representação predominantemente bidimensional para uma descrição mais completa da geometria corporal. A comparação com o modelo anterior foi conduzida pareada por indivíduos, circunscrita à validação interna cruzada compartilhada por ambos os métodos.

6.6 Concordância e aceitabilidade clínica

O P10 superior a 70% e o coeficiente de correlação intraclasses de concordância absoluta superior a 0,93 são consistentes com nível de concordância considerado aceitável para uma ferramenta de apoio à estimativa de peso (Wells et al., 2024). O P5 permaneceu abaixo do limiar de 70%, indicando que o modelo, na configuração atual, não atende ao critério de precisão fina (5%) em todos os pacientes; seu uso, portanto, deve ser interpretado como apoio à estimativa aproximada, e não como substituto da medida aferida quando esta é viável.

A análise de Bland-Altman corrobora essa interpretação inicial ao demonstrar viés médio próximo de zero e calibração linear adequada no agregado. Contudo, as inclinações proporcionais e dos resíduos absolutos, embora pequenas, são

estatisticamente detectáveis. Esse comportamento reflete a regressão à média esperada em modelos calibrados com amostras sub-representadas nos extremos, o que gera um efeito de alavancagem nas inclinações. Tal efeito é evidente no gráfico de erro *versus* valor real, em que as inferências de alto erro se restringem a poucas ocorrências pontuais no extremo superior. Além disso, os limites de concordância não paramétricos (-12,18 a 13,08 kg) denotam considerável variabilidade individual, exigindo cautela nesses casos.

6.7 Resultados complementares de IMC

O desempenho contínuo do IMC foi consistente com os resultados observados para o peso corporal, com erro absoluto médio de 1,91 kg/m². Na classificação por categorias clínicas, a acurácia global foi mais elevada nas faixas intermediárias e inferior nas categorias extremas, especialmente baixo peso e obesidade classe III. Esse padrão é compatível com a distribuição da amostra, na qual essas categorias compreenderam apenas 11 e 24 indivíduos, respectivamente, além da própria estratégia de otimização contínua do modelo, que não incorporou ponderação específica para os pontos de corte clínicos do IMC. A ampliação amostral planejada para os extremos antropométricos, descrita nos trabalhos futuros, apresenta potencial para reduzir essa limitação. Dessa forma, os resultados categóricos do IMC devem ser interpretados como complementares, contribuindo para caracterização do comportamento do modelo sem alterar o foco principal do estudo, centrado na estimativa contínua do peso corporal.

6.8 Relação com Frameworks de relato

A organização dos resultados seguiu a lógica de relato do TRIPOD+AI para modelos preditivos e incorporou elementos do STARD-AI para explicitação do teste algorítmico, padrão de referência, unidade de análise e incerteza das estimativas. Essa opção favorece a transparência sem transformar o texto principal em uma lista de verificação. A lista de verificação detalhada de aderência aos Frameworks é apresentada no Anexo I, e o corpo do capítulo mantém a leitura centrada nos achados.

7.0 CONCLUSÃO

7.1 Conclusão

O estudo avaliou o aprimoramento de um modelo de inteligência artificial destinado à estimativa de peso corporal em pacientes acamados, a partir de imagens obtidas por smartphone em ambiente hospitalar. O modelo final, baseado em atributos tridimensionais de forma corporal, seleção aninhada de variáveis e empilhamento preditivo, atingiu o critério primário pré-especificado de P10 superior a 70% na validação interna cruzada por participante, com P10 de 78,7% (IC95% 73,6–83,2) e erro absoluto médio de 5,24 kg para estimativa do peso corporal.

Em comparação pareada com o modelo anterior, observou-se redução do erro absoluto médio de 7,93 kg (IC 95%: 6,69–9,08) e aumento de 43,7 pontos percentuais na proporção de estimativas dentro de 10% do peso aferido. Resultados consistentes foram observados para o IMC com o erro absoluto médio de 1,91 kg/m². A calibração linear apresentou-se próxima da reta ideal e o coeficiente de correlação intraclasse de concordância absoluta foi superior a 0,92.

Considerando o conjunto de evidências apresentadas, o modelo proposto apresenta desempenho compatível com aplicação como ferramenta de apoio à estimativa antropométrica em situações nas quais a aferição direta de peso não é factível. Os resultados sustentam o avanço metodológico em relação ao modelo anterior, sem substituir a necessidade de validação externa independente, prevista nas etapas seguintes do projeto.

7.2 Limitações

A principal limitação do estudo é o caráter interno da validação. Embora o protocolo tenha preservado a separação de indivíduos entre treino e validação por meio de validação cruzada repetida e a unidade primária de inferência tenha sido o paciente, o desempenho em população externa, com captura por equipes assistenciais distintas e em contextos hospitalares heterogêneos, ainda precisa ser demonstrado. Dessa forma, o modelo ainda não deve ser utilizado na prática clínica sem validação externa independente.

A amostra foi proveniente de hospitais públicos do Distrito Federal, o que pode limitar a generalização imediata para outros contextos assistenciais, perfis populacionais e protocolos de captura. A composição etária concentra-se em adultos

de meia-idade (média de 45,9 anos), com 32 participantes (10,7%) com 65 anos ou mais. Como a aplicação clínica de maior interesse para a estimativa antropométrica indireta inclui idosos hospitalizados, a aplicabilidade ao subgrupo geriátrico requer ampliação amostral.

Outra limitação decorre do próprio padrão de referência. A inclusão exigiu peso aferido em balança, o que pressupõe algum grau de viabilidade para a medida direta. A extrapolação para pacientes completamente incapazes de mobilização, em estado crítico ou com dispositivos que impeçam a captura padronizada da imagem deve ser conduzida com cautela.

No comportamento do modelo, observou-se variabilidade individual relevante nos extremos de peso e de IMC, refletida nos limites de concordância da análise de Bland-Altman e na sensibilidade mais baixa das categorias dos extremos. Foram também detectadas inclinação proporcional discreta e heteroscedasticidade dos resíduos, padrões coerentes com regressão à média em modelos calibrados sobre amostras com menor representatividade nos extremos. Esses pontos não invalidam a leitura agregada do modelo, mas delimitam a interpretação por estrato.

Por fim, esta etapa não incluiu comparação direta entre o modelo proposto e as equações antropométricas tradicionais de uso clínico estabelecido como Chumlea (1988) e Rabito (2006). Essas comparações estão previstas nas etapas seguintes do projeto.

7.3 Trabalhos futuros

As próximas etapas do projeto contemplam ampliação amostral estruturada, refinamento metodológico e validação externa prospectiva, articuladas em torno das limitações identificadas neste estudo.

A primeira frente é a construção de um novo conjunto de dados tridimensional, com seleção estratégica de participantes orientada por estratos clínicos prioritários. O conjunto incluirá mais de mil novas imagens, com cobertura específica dos extremos antropométricos (baixo peso, obesidade classe II e classe III), faixas etárias sub-representadas (em particular idosos com 65 anos ou mais) e diversidade racial mais ampla. Essa expansão tem por objetivo direto mitigar a regressão à média observada nos extremos, melhorar a sensibilidade da classificação por faixas clínicas e aumentar a estabilidade do desempenho por subgrupo.

A segunda frente consiste na coleta paralela de medidas antropométricas aferidas adicionais, entre as quais circunferência da panturrilha, circunferência do braço, altura do joelho e demais variáveis exigidas pelas equações de uso clínico, viabilizando a comparação direta entre o modelo proposto e fórmulas estabelecidas na literatura. O conjunto de dados ampliado incluirá também avaliação por bioimpedância elétrica, agregando informações sobre composição corporal, como massa magra, massa gorda e água corporal total. Esses dados poderão ser utilizados para investigar a influência da composição corporal sobre o desempenho do algoritmo, identificar potenciais fontes de erro das estimativas e subsidiar o desenvolvimento de futuras versões da ferramenta capazes de incorporar informações relacionadas ao estado nutricional e à composição corporal dos pacientes.

A terceira frente é o refinamento da reconstrução tridimensional. A representação atual será aprimorada com o objetivo de aumentar a fidelidade da malha à forma corporal real, reduzindo a perda de informação geométrica nas regiões com maior variabilidade morfológica. Essa melhoria incide diretamente sobre os atributos derivados utilizados pelo modelo preditivo e tem potencial de reduzir o erro proporcional observado na análise de Bland-Altman.

A quarta frente é o desenvolvimento da camada de qualidade da captura no aplicativo de uso clínico. O aplicativo incorporará um guia visual em tempo real que oferece feedback objetivo ao usuário sobre a qualidade da detecção da pose e da segmentação corporal antes da aquisição final. Essa camada visa padronizar o ângulo de captura, a distância e a oclusão, reduzindo a variabilidade operacional e aumentando a consistência dos atributos extraídos. A expectativa é que essa padronização contribua para a estabilidade do desempenho em uso real.

A quinta frente é a validação externa prospectiva, em pacientes hospitalizados sob captura padronizada por profissionais da rotina assistencial, com avaliação de aceitabilidade operacional e análise de aplicabilidade em diferentes contextos hospitalares. Adicionalmente, será incorporada a estimativa de incerteza por predição, permitindo que o sistema indique quando uma estimativa individual deve ser considerada confiável e quando deve ser descartada ou repetida, recurso particularmente relevante para aplicações assistenciais, nas quais um erro individual expressivo pode ter impacto sobre a conduta clínica de nutricionistas, médicos e farmacêutico.

7.4 Financiamento

O desenvolvimento tecnológico relacionado à pesquisa recebeu apoio financeiro do programa StartBSB, vinculado à Fundação de Apoio à Pesquisa do Distrito Federal (FAPDF).

7.5 Conflitos de interesses

Os autores declaram potencial conflito de interesses acadêmico e tecnológico relacionado ao desenvolvimento de uma solução baseada em inteligência artificial para estimativa antropométrica, objeto de pesquisa e inovação conduzida pelos próprios pesquisadores. A tecnologia desenvolvida poderá futuramente ser objeto de proteção intelectual, transferência tecnológica ou exploração comercial. Entretanto, não houve participação de empresas, patrocinadores ou financiadores externos no planejamento, condução, análise ou interpretação dos resultados deste estudo, os quais foram desenvolvidos exclusivamente no contexto acadêmico.

7.6 Disponibilidade de dados

As planilhas em formato CSV contendo os resultados utilizados nas análises estatísticas poderão ser disponibilizadas para fins de verificação e reprodutibilidade dos resultados. Adicionalmente, os dados individuais utilizados nas análises de desempenho encontram-se apresentados no APÊNDICE B (modelo anterior) e no APÊNDICE C (modelo final) deste trabalho. Entretanto, os registros fotográficos e o código-fonte do modelo não estão disponíveis publicamente por envolverem dados sensíveis protegidos pela LGPD (2018) e integrarem tecnologia proprietária sob responsabilidade dos pesquisadores.

8.0 REFERÊNCIAS

1. ALTINIGNE, Can Yilmaz; THANOU, Dorina; ACHANTA, Radhakrishna. Height and weight estimation from unconstrained images. In: **IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING (ICASSP)**, 2020, Barcelona, Spain. Anais [...]. Piscataway: IEEE, 2020. p. 2298–2302. DOI: 10.1109/ICASSP40776.2020.9053363.
2. BAJWA, Junaid et al. Artificial intelligence in healthcare: transforming the practice of medicine. **Future Healthcare Journal**, v. 8, n. 2, p. e188-e194, jul. 2021. DOI: 10.7861/fhj.2021-0095.
3. BESERRA, Eliane Albuquerque; RODRIGUES, Patrícia; LISBOA, Adriana. Validação de métodos subjetivos para estimativa do índice de massa corporal em pacientes acamados. **Comunicação em Ciências da Saúde**, Brasília, v. 22, n. 1, p. 19–26, 2011. Disponível em: https://bvsmis.saude.gov.br/bvs/periodicos/revista_ESCS_v22_n1_a03_validacao_metodos.pdf. Acesso em: 19 jun. 2026.
4. BENJAMINI, Yoav; HOCHBERG, Yosef. Controlling the false discovery rate: a practical and powerful approach to multiple testing. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 57, n. 1, p. 289–300, 1995. DOI: 10.1111/j.2517-6161.1995.tb02031.x.
5. BLAND, J. M.; ALTMAN, D. G. Statistical methods for assessing agreement between two methods of clinical measurement. **The Lancet**, v. 1, n. 8476, p. 307–310, 1986. DOI: 10.1016/S0140-6736(86)90837-8.
6. BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). **Diário Oficial da União**: seção 1, Brasília, DF, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/ato2015-2018/2018/lei/l13709.htm. Acesso em: 19 jun. 2026.
7. BRASIL. Ministério da Saúde. Secretaria de Atenção à Saúde. Departamento de Atenção Básica. Orientações para a coleta e análise de dados antropométricos em serviços de saúde: norma técnica do Sistema de Vigilância Alimentar e Nutricional – SISVAN. Brasília, DF: Ministério da Saúde, 2011. Disponível em: <https://www.gov.br/saude/pt-br/composicao/saps/vigilancia-alimentar-e-nutricao>

- [nal/arquivos/orientacoes-para-a-coleta-e-analise-de-dados-antropometricos-e-m-servicos-de-saude/view](#). Acesso em: 19 jun. 2026.
8. BREIMAN, Leo. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324.
 9. CASTRO, Melina Gouveia et al. Diretriz BRASPEN de terapia nutricional no paciente grave. *BRASPEN Journal*, v. 38, n. 2, supl. 2, 2023. Disponível em: <https://braspenjournal.org/article/10.37111/braspenj.diretrizDOENTEGRAVE/pdf/braspen-38-2%2C+Supl+2-6537d6b0a953950ad57860b3.pdf> . Acesso em: 19 jun. 2026.
 10. CHUMLEA, W. C.; ROCHE, A. F.; MUKHERJEE, D. Anthropometric estimates of body size and components for self-care and hospitalized elderly. **Journal of Gerontology**, v. 43, n. 6, p. M190–M195, 1988. DOI: 10.1093/geronj/43.6.M190.
 11. CHICCO, Davide; WARRENS, Matthijs J.; JURMAN, Giuseppe. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, v. 7, p. e623, 2021. DOI: 10.7717/peerj-cs.623.
 12. COLLINS, Gary S. et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. **BMJ**, v. 385, p. e078378, 2024. DOI: 10.1136/bmj-2023-078378.
 13. DA SILVA, Joshua S. V. et al. ASPEN consensus recommendations for refeeding syndrome. **Nutrition in Clinical Practice**, v. 35, n. 2, p. 178–195, 2020. DOI: 10.1002/ncp.10474.
 14. DARNIS, S. et al. Estimation of body weight in hospitalized patients. **QJM: An International Journal of Medicine**, v. 105, n. 8, p. 769–774, 2012. DOI: 10.1093/qjmed/hcs072.
 15. DIETTERICH, T. G. Approximate statistical tests for comparing supervised classification learning algorithms. **Neural Computation**, v. 10, n. 7, p. 1895–1923, 1998. DOI: 10.1162/089976698300017197.
 16. DISTRITO FEDERAL (Brasil). Instituto de Pesquisa e Estatística do Distrito Federal (IPEDF). Pesquisa Distrital por Amostra de Domicílios Ampliada (PDAD-A): relatório de resultados. Brasília, DF: **IPEDF**, 2024. Disponível em: https://pdad.ipe.df.gov.br/files/reports/Relatorio_DF_WVongqRN.pdf. Acesso em: 19 jun. 2026.

17. DUARTE, Antônio Cláudio. **Avaliação nutricional**: aspectos clínicos e laboratoriais. São Paulo: Atheneu, 2007.
18. DISTRITO FEDERAL. Secretaria de Estado de Saúde. Ata de registro de preços nº 160887741: aquisição de camas hospitalares. Brasília, DF: Secretaria de Estado de Saúde do Distrito Federal, 2022. Disponível em: https://www.saude.df.gov.br/documents/37101/0/Ata_de_Registro_de_Precos_160887741J.pdf/ee6b059e-6c71-b947-98f7-1f68c5013cfc?t=1754310177752. Acesso em: 4 maio 2026.
19. EL ARAB, R. A. et al. Bridging the gap: from AI success in clinical trials to real-world healthcare implementation—a narrative review. **Healthcare**, v. 13, n. 7, art. 701, 2025. DOI: 10.3390/healthcare13070701.
20. FARIA, Michel R. et al. Estimativa de peso, altura e IMC de pacientes acamados por meio do aprendizado de máquina. **BRASPEN Journal**, São Paulo, v. 38, n. 1, supl. 1, p. 108–109, 2023. Trabalho apresentado no Ganepão 2023. Disponível em: <https://braspenjournal.org/article/655e29b3a953957fde7e9337/pdf/braspen-38-1-%2C+Supl+1-655e29b3a953957fde7e9337.pdf>. Acesso em: 19 jun. 2026.
21. GARCÍA-PASTOR, Andrés et al. Tissue plasminogen activator for acute ischemic stroke: calculation of dose based on estimated patient weight can increase the risk of cerebral bleeding. **Journal of Thrombosis and Thrombolysis**, v. 40, n. 3, p. 347–352, 2015. DOI: 10.1007/s11239-015-1232-4.
22. GUNEL, Semih; RHODIN, Helge; FUA, Pascal. What face and body shapes can tell us about height. In: IEEE/CVF INTERNATIONAL CONFERENCE ON COMPUTER VISION WORKSHOPS (ICCVW), 2019, Seoul, South Korea. Proceedings [...]. Piscataway: IEEE, 2019. p. 1819–1828. Disponível em: https://openaccess.thecvf.com/content_ICCVW_2019/papers/WIDER/Gunel_What_Face_and_Body_Shapes_Can_Tell_Us_About_Height_ICCVW_2019_paper.pdf. Acesso em: 19 jun. 2026.
23. HABEHH, Hafsa; GOHEL, Suril. Machine learning in healthcare. **Current Genomics**, v. 22, n. 4, p. 291–300, 2021. DOI: 10.2174/1389202922666210705124359.

24. HERATH, H. M. M. T. B. et al. Estimation of body weight using anthropometric parameters in Sri Lankan hospitalized adult patients. **PLoS ONE**, v. 18, n. 9, e0290895, 2023. DOI: 10.1371/journal.pone.0290895.
25. SHU, Huaijing et al. Single image based infant body height and weight estimation. In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION WORKSHOPS (CVPRW), 2023, Vancouver, BC, Canada. Proceedings [...]. Piscataway: IEEE, 2023. p. 6052–6059. Disponível em: https://openaccess.thecvf.com/content/CVPR2023W/CVPM/papers/Shu_Single_Image_Based_Infant_Body_Height_and_Weight_Estimation_CVPRW_2023_paper.pdf . Acesso em: 19 jun. 2026.
26. ICHIKAWA, S.; ITADANI, H.; SUGIMORI, H. Prediction of body weight from chest radiographs using deep learning with a convolutional neural network. **Radiological Physics and Technology**, v. 16, n. 1, p. 127–134, 2023. DOI: 10.1007/s12194-023-00697-3.
27. JIANG, Min; GUO, Guodong. Body weight analysis from human body images. **IEEE Transactions on Information Forensics and Security**, v. 14, n. 10, p. 2676–2688, 2019. DOI: 10.1109/TIFS.2019.2904840
28. JIANG, Min; SHANG, Yuanyuan; GUO, Guodong. Computational approach to body mass index estimation from dressed people in 3D space. **IET Image Processing**, v. 14, n. 7, p. 1248–1256, 2020. DOI: 10.1049/iet-ipr.2019.1170.
29. JOCHER, Glenn et al. Ultralytics YOLO26: Unified Real-Time End-to-End Vision Models. **arXiv**, 2026. DOI: 10.48550/arXiv.2606.03748.
30. KABIR, Md Mohsin et al. Computer vision algorithms in healthcare: recent advancements and future challenges. **Computers in Biology and Medicine**, v. 185, art. 109531, 2025. DOI: 10.1016/j.compbiomed.2024.109531.
31. KAKESHITA, Idalina Shiraishi. Adaptação e validação de escalas de silhuetas para crianças e adultos brasileiros. 2008. **Tese (Doutorado em Psicobiologia) – Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2008.** Disponível em: <https://teses.usp.br/teses/disponiveis/59/59134/tde-25052008-170240/publico/TESE.pdf> . Acesso em: 19 jun. 2026.
32. KE, Guolin et al. LightGBM: a highly efficient gradient boosting decision tree. In: **GUYON, Isabelle et al. (ed.)**. Advances in Neural Information Processing Systems 30. Red Hook, NY: Curran Associates, Inc., 2017. p. 3146–3154.

Disponível em:
https://papers.nips.cc/paper_files/paper/2017/hash/6449f44a102fde848669bd9eb6b76fa-Abstract.html . Acesso em: 19 jun. 2026.

33. KIM, J. et al. Preclinical trial of noncontact anthropometric measurement using IR-UWB radar. **Scientific Reports**, v. 12, art. 8174, 2022. DOI: 10.1038/s41598-022-12209-1
34. KOO, Terry K.; LI, Mae Y. A guideline of selecting and reporting intraclass correlation coefficients for reliability research. **Journal of Chiropractic Medicine**, v. 15, n. 2, p. 155–163, 2016. DOI: 10.1016/j.jcm.2016.02.012.
35. LIMA, M. F. S. et al. Development and validation of predictive workable weight equations for Brazilian older adult residents in long-term care institutions. **PLoS ONE**, v. 18, n. 1, e0280541, 2023. DOI: 10.1371/journal.pone.0280541.
36. LINDROTH, Heidi et al. Applied artificial intelligence in healthcare: a review of computer vision technology application in hospital settings. **Journal of Imaging**, v. 10, n. 4, art. 81, 2024. DOI: 10.3390/jimaging10040081.
37. MANOJ, Rahul et al. Continuous weight monitoring system for ICU beds using air-filled mattresses/pads: a proof of concept. In: **IEEE INTERNATIONAL SYMPOSIUM ON MEDICAL MEASUREMENTS AND APPLICATIONS (MEMEA)**, 2019, Istanbul, Turkey. Proceedings [...]. Piscataway, NJ: IEEE, 2019. p. 1–6. DOI: 10.1109/MEMEA.2019.8802148.
38. MELO, Ana Paula F. et al. Methods for estimating body weight and height in hospitalized adults: a comparative analysis. **Revista Brasileira de Cineantropometria & Desempenho Humano**, v. 16, n. 4, p. 475–484, 2014. DOI: 10.5007/1980-0037.2014v16n4p475.
39. MONSEES, Jonas et al. Difference between estimated and actual body weight in an intensive care unit—A service evaluation. **Nursing in Critical Care**, v. 30, n. 2, e13271, 2025. DOI: 10.1111/nicc.13271.
40. MOHAMMEDKHAN, H. et al. Inferring body measurements from 2D images: a comprehensive review. **Journal of Imaging**, v. 11, n. 6, art. 205, 2025. DOI: 10.3390/jimaging11060205.
41. NAKAO, Yasuhiko et al. Development of deep-learning tool to predict appropriate height and weight from chest radiographs in bedridden patients. **Clinical Nutrition Open Science**, v. 51, p. 109–117, 2023. DOI: 10.1016/j.nutos.2023.08.005.

42. PANTONOWITZ, Adam et al. Estimation of body mass index from photographs using deep convolutional neural networks. **Informatics in Medicine Unlocked**, v. 26, art. 100727, 2021. DOI: 10.1016/j.imu.2021.100727.
43. PEREIRA, Blenda Leite Saturnino. Gestão orçamentária e financeira do SUS: uma análise do gasto e da eficiência orçamentária nos municípios brasileiros (2018-2023). 2025. **Tese (Doutorado em Saúde Pública) – Faculdade de Saúde Pública**, Universidade de São Paulo, São Paulo, 2025. Disponível em: https://teses.usp.br/teses/disponiveis/6/6143/tde-12092025-145207/publico/PeiraBLS_DR.pdf . Acesso em: 19 jun. 2026.
44. PFITZNER, Christian; MAY, Stefan; NÜCHTER, Andreas. Neural network-based visual body weight estimation for drug dosage finding. In: **MEDICAL IMAGING 2016: IMAGING INFORMATICS FOR HEALTHCARE, RESEARCH, AND APPLICATIONS**, 2016, San Diego, CA, USA. Proceedings [...]. Bellingham, WA: SPIE, 2016. Art. 97841Z. DOI: 10.1117/12.2216042.
45. PFITZNER, Christian; MAY, Stefan; NÜCHTER, Andreas. Body weight estimation for dose-finding and health monitoring of lying, standing and walking patients based on RGB-D data. **Sensors**, v. 18, n. 5, art. 1311, 2018. DOI: 10.3390/s18051311.
46. PLEVRIS, V. et al. Investigation of performance metrics in regression analysis and machine learning-based prediction models. In: **EUROPEAN CONGRESS ON COMPUTATIONAL METHODS IN APPLIED SCIENCES AND ENGINEERING (ECCOMAS)**, 8., 2022, Oslo, Norway. Proceedings [...]. Oslo: Scipedia, 2022. Disponível em: https://www.scipedia.com/public/Plevris_et_al_2022a. Acesso em: 10 maio 2026.
47. PRINCESA ISABEL (PB). Prefeitura Municipal. Termo de referência para aquisição de equipamentos hospitalares. Princesa Isabel: Prefeitura Municipal, 2023. Disponível em: <https://www.princesa.pb.gov.br/storage/licitacao/820/arquivos/696e48054e413jq0ox.pdf> . Acesso em: 04 maio 2026.
48. RABITO, Estela Iraci et al. Weight and height prediction of immobilized patients. **Revista de Nutrição**, v. 19, n. 6, p. 655–661, 2006. DOI: 10.1590/S1415-52732006000600002.

49. REZENDE, Fabiane AC. et al. Avaliação da aplicabilidade de fórmulas preditivas de peso e estatura em homens adultos. **Revista de Nutrição**, v. 22, n. 4, p. 443–451, 2009. DOI: 10.1590/S1415-52732009000400001.
50. RAJAN, M. P. An efficient ridge regression algorithm with parameter estimation for data analysis in machine learning. **SN Computer Science**, v. 3, art. 171, 2022. DOI: 10.1007/s42979-022-01051-x.
51. SANTOS, Elizabete Alexandre dos; CAMARGO, Roberta Nemer; PAULO, Andreza Zumbini. Análise comparativa de fórmulas de estimativa de peso e altura para pacientes hospitalizados. **Revista Brasileira de Nutrição Clínica**, v. 27, n. 4, p. 218–225, 2012. Disponível em: <http://www.braspen.com.br/home/wp-content/uploads/2016/12/Artigo-2-4-2014.pdf>. Acesso em: 04 maio 2026.
52. SOARES, Beatriz et al. Impact and classification of body stature and physiological variability in the acquisition of vital signs using continuous wave radar. **Applied Sciences**, v. 14, n. 2, art. 921, 2024. DOI: 10.3390/app14020921.
53. SAUERESSIG, Camila et al. Utilização de métodos indiretos para estimativa de peso corporal e estatura e sua correlação com os valores aferidos em pacientes hospitalizados. **BRASPEN Journal**, v. 37, n. 4, p. 340–345, 2023. DOI: 10.37111/braspenj.2022.37.4.03.
54. SKOLL, D. et al. Accuracy and correlation of bed and standing scale weights in monitoring volume status in heart failure patients. **Future Cardiology**, v. 20, n. 7–8, p. 389–393, 2024. DOI: 10.1080/14796678.2024.2340919.
55. SONAR, V. G. et al. 3D camera-based body weight estimation using artificial intelligence in emergency care settings. **Emergency Care and Medicine**, v. 2, n. 4, art. 55, 2025. DOI: 10.3390/ecm2040055.
56. SOUNDERAJAH, V. et al. The STARD-AI reporting guideline for diagnostic accuracy studies using artificial intelligence. **Nature Medicine**, 2025. DOI: 10.1038/s41591-025-03953-8.
57. SOUSA, Luciana Maia Escher dos Santos. Ancestralidade genética em populações miscigenadas: desafios, aplicações e um olhar sobre a história da formação do Distrito Federal. 2023. 154 f. **Tese (Doutorado em Biologia Animal)** – Universidade de Brasília, Brasília, 2023. Disponível em:

- http://repositorio2.unb.br/bitstream/10482/49090/1/2023_LucianaMaiaEscherDosSantosSousa_TESE.pdf . Acesso em: 19 jun. 2026.
58. WELLS, M.; GOLDSTEIN, L. N.; CATTERMOLE, G. Development and validation of a length- and habitus-based method of ideal and lean body weight estimation for adults requiring urgent weight-based medical intervention. **European Journal of Drug Metabolism and Pharmacokinetics**, v. 47, n. 6, p. 841–853, 2022. DOI: 10.1007/s13318-022-00791-9.
59. WELLS, M.; HENRY, B.; GOLDSTEIN, L. Weight estimation for drug dose calculations in the prehospital setting: a systematic review. **Prehospital and Disaster Medicine**, v. 38, n. 4, p. 471–484, 2023. DOI: 10.1017/S1049023X23006027.
60. WELLS, Mike et al. Total body weight estimation by 3D camera systems: potential high-tech solutions for emergency medicine applications? A scoping review. **JACEP Open**, v. 5, n. 5, e13320, 2024. DOI: 10.1002/emp2.13320.
61. WORLD HEALTH ORGANIZATION. Obesity: preventing and managing the global epidemic: report of a WHO consultation. Geneva: World Health Organization, 2000. (WHO Technical Report Series, 894). Disponível em: <https://iris.who.int/items/933e09aa-64f9-46e9-8dbb-78d8cddf1a3d> . Acesso em: 19 jun. 2026.
62. YAO, Yumin; SONG, Ling; YE, Jin. Motion-To-BMI: using motion sensors to predict the body mass index of smartphone users. **Sensors**, v. 20, n. 4, art. 1134, 2020. DOI: 10.3390/s20041134.

APÊNDICE A - Ficha de coleta de dados

Número de de identificação na pesquisa: _____

Clínica: _____ Leito: _____

Sexo: _____ Data de Nascimento: _____ Idade: _____

Diagnósticos médicos atuais e progressos: _____

Diagnóstico nutricional (GLIM, 2018): _____

Distância da cama hospitalar: _____

Critérios de exclusão:

- 1) Está em precaução de contato, gotículas ou aerossóis? () Sim () Não
- 2) Alto risco de queda segundo escala de Morse ? () Sim () Não
- 3) Consegue ficar de pé sem auxílio de dispositivos? () Sim () Não
- 4) Se mulher, está gestante ou puérpera ? () Sim () Não
- 5) Possui hepatopatia crônica ou doença renal crônica ? () Sim () Não
- 6) Possui câncer com metástase óssea? () Sim () Não
- 7) Está com edema em qualquer parte do corpo? () Sim () Não
- 8) Possui capacidade decisória reduzida? () Sim () Não
- 9) Está em monitoramento cardíaco ou dependente de oxigenoterapia?
() Sim () Não
- 10) Possui históricos de hipoglicemias frequentes? () Sim () Não
- 11) Possui próteses metálicas no corpo? () Sim () Não

Avaliação antropométrica:

Antropometria	Data: / /	Data: / /
	Prontuário	Pesquisador
Peso (kg)		
Estatuta (m)		
IMC (kg/m²)		

APÊNDICE B - Resultados individuais utilizados nas análises de desempenho do modelo anterior

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
1	2	45	3	78.000	81.191	3.191 [3.685, 14.283]	4.09 [4.72, 18.31]	23.81	29.26	74.315	92.283	65.895	92.271	
2	1	35	3	53.700	67.617	13.917 [10.029, 16.884]	25.92 [18.68, 31.44]	22.07	23.67	69.888	70.584	63.729	66.267	
3	1	27	4	65.400	68.310	2.910 [0.507, 8.494]	4.45 [0.78, 12.99]	28.31	27.60	73.894	67.936	64.893	66.518	
4	1	25	7	151.100	81.852	69.248 [64.840, 72.985]	45.83 [42.91, 48.30]	55.50	29.78	82.751	80.282	78.115	86.260	
5	1	24	3	56.800	67.913	11.113 [3.862, 16.483]	19.56 [6.80, 29.02]	23.34	25.16	73.283	71.863	60.662	65.843	
6	2	46	3	59.300	67.300	8.000 [1.813, 20.744]	13.49 [3.06, 34.98]	21.52	25.23	62.417	65.218	61.113	67.710	80.044
7	2	48	3	77.350	80.100	2.750 [0.392, 6.835]	3.56 [0.51, 8.84]	24.41	28.06	82.622	84.185	73.963	77.742	81.989
8	1	68	6	104.000	88.936	15.064 [12.218, 18.283]	14.48 [11.75, 17.58]	39.14	32.71	89.376	88.867	91.782	85.717	
9	1	34	5	89.200	84.512	4.688 [1.274, 8.158]	5.26 [1.43, 9.15]	30.51	31.23	87.926	87.056	83.602	82.934	81.042
10	2	70	4	76.600	69.314	7.286 [3.508, 13.292]	9.51 [4.58, 17.35]	25.01	26.95	72.032	68.764	63.308	69.372	73.092
11	2	58	3	66.200	71.286	5.086 [0.893, 8.198]	7.68 [1.35, 12.38]	24.92	25.80	74.330	74.398	67.093	69.321	
12	2	52	7	119.900	76.254	43.646 [38.215, 49.506]	36.40 [31.87, 41.29]	44.04	27.63	81.685	77.368	75.783	76.040	70.394
13	2	53	4	81.200	75.167	6.033 [1.459, 9.954]	7.43 [1.80, 12.26]	27.13	28.82	72.654	77.114	72.162	71.246	82.659
14	1	44	7	100.650	84.868	15.782 [11.024, 23.225]	15.68 [10.95, 23.07]	40.32	31.35	87.140	85.280	89.626	77.425	
15	1	42	4	75.800	80.370	4.570 [0.203, 9.358]	6.03 [0.27, 12.35]	27.84	28.70	82.491	85.158	78.233	75.597	
16	1	36	4	84.800	84.294	0.506 [0.211, 3.521]	0.60 [0.25, 4.15]	29.00	28.99	84.589	85.734	83.896	81.279	85.974
17	1	43	4	76.700	75.762	0.938 [0.184, 8.333]	1.22 [0.24, 12.17]	29.23	29.20	75.931	73.825	67.367	76.884	84.804
18	2	30	1_2	53.400	76.359	22.959 [19.483, 27.696]	42.99 [36.48, 51.86]	17.44	27.25	81.096	75.099	72.883		
19	2	65	3	72.600	74.505	1.905 [1.912, 7.979]	2.62 [2.63, 10.99]	24.54	27.07	78.537	74.512	69.907	80.579	68.990
20	1	21	4	86.200	74.877	11.323 [6.082, 14.169]	13.14 [7.06, 16.44]	29.83	28.96	74.317	73.531	74.390	72.031	80.118
21	2	61	6	109.500	90.362	19.138 [13.315, 22.928]	17.48 [12.16, 20.94]	36.59	31.94	86.572	88.007	91.798	96.185	89.249
22	2	28	4	93.400	81.966	11.434 [1.546, 28.245]	12.24 [1.66, 30.24]	27.89	31.05	91.854	91.113	76.887	84.820	65.155
23	1	44	4	62.300	76.735	14.435 [5.767, 23.279]	23.17 [9.26, 37.37]	25.27	29.60	85.504	85.579	68.067	70.050	74.474
24	2	69	4	89.100	82.536	6.564 [2.862, 9.731]	7.37 [3.21, 10.92]	29.09	29.21	79.369	86.238	82.000		
25	1	40	6	95.600	91.981	3.619 [1.475, 6.294]	3.79 [1.54, 6.58]	35.54	34.94	93.603	91.839	94.125	91.030	89.306
26	1	51	7	123.600	85.664	37.936 [35.991, 40.913]	30.69 [29.12, 33.10]	43.79	31.57	87.029	87.609	82.687	85.329	
27	2	64	4	79.100	79.636	0.536 [0.820, 9.371]	0.68 [1.04, 11.85]	28.36	28.15	85.929	79.920	69.729	81.937	80.663
28	2	54	4	77.150	77.077	0.073 [0.389, 6.989]	0.09 [0.50, 9.06]	25.19	28.32	77.539	73.119	70.161	81.378	83.188
29	2	33	3	71.250	83.803	12.553 [11.561, 14.287]	17.62 [16.23, 20.05]	22.49	29.30	82.811	84.048	82.819	85.537	
30	2	30	4	86.500	76.468	10.032 [1.167, 22.328]	11.60 [1.35, 25.81]	29.24	27.86	85.333	78.381	64.172	72.224	82.227
31	1	26	3	63.100	74.487	11.387 [3.166, 19.171]	18.05 [5.02, 30.38]	22.90	29.07	77.069	82.271	72.340	66.266	
32	1	61	6	101.900	91.455	10.445 [9.069, 12.124]	10.25 [8.90, 11.90]	38.83	34.58	90.922	92.175	89.776	92.831	91.570
33	2	61	3	65.800	85.748	19.948 [17.345, 26.094]	30.32 [26.36, 39.66]	24.77	32.15	85.014	91.894	84.667	83.145	84.019
34	1	45	6	94.500	89.505	4.995 [2.494, 10.255]	5.29 [2.64, 10.85]	37.38	33.98	90.662	96.994	86.120	84.245	

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
35	2	32	4	75.800	74.747	1.053 [0.121, 4.625]	1.39 [0.16, 6.10]	25.04	27.49	75.921	77.926	71.175	73.968	
36	2	27	5	126.100	78.257	47.843 [45.598, 49.767]	37.94 [36.16, 39.47]	34.21	27.37		80.502	76.332	77.937	
37	1	49	5	78.650	78.163	0.487 [0.087, 3.820]	0.62 [0.11, 4.86]	32.74	30.01	80.255	79.004	74.830	78.563	
38	1	47	3	56.100	66.867	10.767 [6.787, 14.220]	19.19 [12.10, 25.35]	22.76	25.89	69.846	67.836	63.447	62.887	70.320
39	1	45	4	66.600	76.137	9.537 [8.937, 10.137]	14.32 [13.42, 15.22]	25.38	28.81	76.737				75.537
40	1	60	5	82.900	73.193	9.707 [6.789, 14.972]	11.71 [8.19, 18.06]	33.21	27.09	71.678	68.539	68.132	67.928	89.689
41	1	41	6	94.200	93.219	0.981 [0.040, 3.221]	1.04 [0.04, 3.42]	39.21	32.85	96.420	91.318	90.979	94.160	
42	1	42	6	90.100	87.847	2.253 [0.608, 7.254]	2.50 [0.68, 8.05]	36.09	31.62	90.708	82.846	83.814	88.898	92.966
43	2	63	5	94.850	89.822	5.028 [0.629, 12.635]	5.30 [0.66, 13.32]	34.84	32.41	94.221	94.217	88.373	90.082	82.215
44	2	61	4	68.400	92.134	23.734 [17.538, 29.452]	34.70 [25.64, 43.06]	27.40	33.50	85.938	93.116	97.852	91.631	
45	1	20	3	61.550	77.707	16.157 [8.883, 22.052]	26.25 [14.43, 35.83]	22.61	28.17	83.602	83.316	73.476	70.433	
46	1	46	4	51.900	70.158	18.258 [13.233, 22.542]	35.18 [25.50, 43.43]	25.03	26.58	71.164	69.642	65.133	70.408	74.442
47	2	36	3	70.600	79.531	8.931 [0.955, 17.665]	12.65 [1.35, 25.02]	23.59	28.24	88.265	72.062	71.555	85.319	80.457
48	1	50	4	76.600	81.590	4.990 [2.874, 7.650]	6.51 [3.75, 9.99]	25.89	28.06	81.102	79.474	81.533	84.250	
49	1	68	3	53.500	66.690	13.190 [11.458, 14.855]	24.65 [21.42, 27.77]	23.78	25.85	68.355	66.244	64.958	67.205	
50	1	45	1_2	40.150	68.926	28.776 [24.428, 34.499]	71.67 [60.84, 85.92]	17.15	25.75	69.287	67.190	64.578	74.649	
51	2	52	4	74.800	74.210	0.590 [0.146, 4.355]	0.79 [0.19, 5.82]	26.50	26.80	74.946	79.155	71.587	74.349	71.012
52	2	53	4	83.200	83.646	0.446 [1.486, 7.605]	0.54 [1.79, 9.38]	25.97	30.11	81.543	86.418	81.714	91.005	77.551
53	2	21	4	85.700	68.562	17.138 [11.264, 27.102]	20.00 [13.14, 31.62]	28.97	25.53	73.781	74.218	58.598	61.779	74.436
54	2	56	5	94.400	82.865	11.535 [6.528, 14.300]	12.22 [6.92, 15.15]	30.13	29.46	82.242	81.552	82.556	80.100	87.672
55	2	74	4	74.800	76.248	1.448 [1.149, 9.896]	1.94 [1.54, 13.23]	28.50	28.43	84.696	77.468	65.668	75.949	77.458
56	1	63	5	84.800	85.808	1.008 [1.810, 6.497]	1.19 [2.13, 7.66]	34.85	31.04	86.610	86.665	78.662	91.297	
57	1	58	5	78.800	80.010	1.210 [0.015, 6.527]	1.53 [0.02, 8.28]	30.78	30.59	85.327	83.755	78.785	79.193	72.987
58	1	41	4	61.600	75.536	13.936 [5.293, 26.904]	22.62 [8.59, 43.68]	25.97	28.33	74.517	77.658	66.893	70.105	88.504
59	2	26	5	99.700	86.788	12.912 [1.494, 21.386]	12.95 [1.50, 21.45]	30.10	30.70	96.104	78.934	78.314	82.383	98.206
60	1	68	4	64.600	73.521	8.921 [4.422, 16.422]	13.81 [6.85, 25.42]	26.89	27.22	81.022	74.831	69.022	72.848	69.883
61	1	33	7	131.000	96.586	34.414 [31.971, 37.584]	26.27 [24.41, 28.69]	48.71	37.55	93.416		99.029	97.313	
62	1	20	4	69.400	77.836	8.436 [3.027, 20.602]	12.16 [4.36, 29.69]	25.49	27.92	79.810	90.002	66.373	74.693	78.303
63	1	49	7	108.500	107.991	0.509 [1.075, 4.208]	0.47 [0.99, 3.88]	49.53	41.28	110.255	107.425	104.292	109.993	
64	1	34	3	49.100	79.037	29.937 [26.030, 32.783]	60.97 [53.01, 66.77]	22.72	30.32	75.130	81.883	79.820	79.315	
65	1	45	5	76.600	91.752	15.152 [5.113, 20.753]	19.78 [6.67, 27.09]	33.15	36.07	90.130	97.353	93.257	96.309	81.713
66	2	50	4	70.300	77.592	7.292 [4.099, 9.983]	10.37 [5.83, 14.20]	27.12	29.09	80.283	78.801	76.885	74.399	
67	1	21	7	109.600	96.138	13.462 [8.535, 18.385]	12.28 [7.79, 16.77]	45.04	35.29	97.815	91.215	101.065	93.422	97.174
68	2	51	4	83.700	97.044	13.344 [0.873, 27.940]	15.94 [1.04, 33.38]	29.66	33.84	111.640	89.018	90.104	109.885	84.573

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
69	1	37	5	80.500	89.048	8.548 [0.985, 15.018]	10.62 [1.22, 18.66]	31.45	34.45	94.483	89.194	79.515	95.518	86.529
70	2	22	1_2	57.200	72.160	14.960 [7.346, 31.419]	26.15 [12.84, 54.93]	19.11	25.88	70.363	72.699	64.546	64.574	88.619
71	1	56	7	128.150	108.546	19.604 [16.044, 21.782]	15.30 [12.52, 17.00]	48.83	41.30	107.486	106.368	112.106	108.224	
72	1	52	1_2	53.700	80.419	26.719 [18.873, 32.517]	49.76 [35.15, 60.55]	19.25	30.54	72.573	86.217	77.746	84.575	80.983
73	2	55	5	90.900	94.611	3.711 [0.206, 10.473]	4.08 [0.23, 11.52]	31.45	33.33	101.373	92.849	90.694	90.607	97.531
74	2	34	1_2	58.700	79.716	21.016 [14.357, 29.221]	35.80 [24.46, 49.78]	19.61	28.83	87.921	78.021	79.356	73.057	80.225
75	2	55	4	74.900	85.601	10.701 [0.516, 17.233]	14.29 [0.69, 23.01]	26.54	30.69	85.764	88.470	86.224	92.133	75.416
76	2	47	4	91.600	78.411	13.189 [4.489, 20.257]	14.40 [4.90, 22.11]	28.59	28.82	76.830	81.823	71.343	74.950	87.111
77	1	54	7	164.300	121.879	42.421 [35.991, 49.204]	25.82 [21.91, 29.95]	64.99	43.62	115.096	119.703	128.309	124.408	
78	1	35	4	65.500	72.223	6.723 [4.370, 10.215]	10.26 [6.67, 15.59]	27.98	27.02	69.870	70.063	73.708	71.762	75.715
79	1	54	4	63.350	69.501	6.151 [3.768, 8.576]	9.71 [5.95, 13.54]	28.92	27.20	71.926	69.585	70.098	68.777	67.118
80	2	63	4	81.400	85.869	4.469 [1.875, 8.714]	5.49 [2.30, 10.71]	29.54	31.75	90.114	89.359	83.275	87.948	78.649
81	2	35	5	77.800	78.734	0.934 [0.454, 8.104]	1.20 [0.58, 10.42]	30.77	28.58	74.334	85.904	75.873	77.346	80.215
82	1	22	3	66.600	77.814	11.213 [5.444, 15.883]	16.84 [8.17, 23.85]	22.00	29.72	78.914		72.044		82.483
83	1	58	4	57.300	70.977	13.677 [10.717, 15.881]	23.87 [18.70, 27.72]	25.13	27.70		71.766	70.946	73.181	68.017
84	1	24	3	50.900	78.323	27.423 [23.790, 29.757]	53.88 [46.74, 58.46]	22.62	31.15		80.657	74.690	78.142	79.804
85	2	38	3	60.100	67.221	7.121 [1.603, 19.158]	11.85 [2.67, 31.88]	20.32	26.19		64.592	63.331	61.703	79.258
86	2	33	4	82.850	92.029	9.179 [1.688, 21.577]	11.08 [2.04, 26.04]	25.57	31.42		84.538	104.427	87.369	91.782
87	1	56	4	73.600	90.080	16.480 [14.530, 18.056]	22.39 [19.74, 24.53]	25.77	31.84		88.130	91.429	89.104	91.656
88	1	66	4	73.000	68.558	4.442 [2.614, 12.099]	6.09 [3.58, 16.57]	29.62	27.80		60.901	75.614	67.693	70.022
89	1	33	3	58.250	65.813	7.563 [4.380, 12.271]	12.98 [7.52, 21.07]	22.20	26.43		63.129	66.973	62.630	70.521
90	1	68	3	47.050	63.581	16.531 [14.630, 19.808]	35.14 [31.09, 42.10]	22.38	24.90		61.680	62.977	62.810	66.858
91	1	42	4	82.850	82.598	0.252 [0.168, 4.388]	0.30 [0.20, 5.30]	29.71	32.58		86.651	78.462	82.682	
92	2	75	4	66.400	70.167	3.767 [1.948, 17.184]	5.67 [2.93, 25.88]	25.94	26.68		72.192	60.438	64.452	83.584
93	2	58	4	85.800	81.889	3.911 [1.679, 5.357]	4.56 [1.96, 6.24]	28.34	31.71		80.796	84.121	80.443	82.196
94	2	42	4	90.350	82.561	7.789 [1.575, 22.295]	8.62 [1.74, 24.68]	28.52	31.51	88.775	93.597	68.055	80.388	81.990
95	1	54	4	72.400	73.001	0.601 [1.671, 8.440]	0.83 [2.31, 11.66]	29.00	27.27		74.071	63.960	74.974	78.999
96	1	34	4	74.250	72.697	1.553 [1.032, 3.830]	2.09 [1.39, 5.16]	29.37	26.43	76.155	73.218		70.996	70.420
97	2	35	4	96.800	73.998	22.802 [16.964, 27.263]	23.56 [17.52, 28.16]	29.55	27.80	73.773	74.805	69.537	72.038	79.836
98	1	65	4	60.000	71.979	11.979 [4.749, 22.575]	19.96 [7.91, 37.62]	27.39	29.35	77.492	67.853	67.226	64.749	82.575
99	1	51	4	67.300	72.016	4.716 [0.954, 10.780]	7.01 [1.42, 16.02]	25.02	27.08	72.389	71.685	68.254	69.670	78.080
100	2	42	5	80.600	91.689	11.089 [8.472, 13.415]	13.76 [10.51, 16.64]	34.89	34.09	93.995	89.675	94.015	89.072	
101	1	50	5	88.950	82.125	6.825 [0.079, 27.571]	7.67 [0.09, 31.00]	34.75	32.59	87.801	82.206	88.871	90.366	61.379
102	2	49	3	49.750	70.353	20.603 [14.293, 30.092]	41.41 [28.73, 60.49]	20.71	25.97		66.256	64.043	71.271	79.842

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
103	1	37	3	55.900	66.828	10.928 [3.000, 16.542]	19.55 [5.37, 29.59]	23.57	25.99	70.250	69.076	58.900	63.471	72.442
104	1	51	4	68.100	76.186	8.086 [4.199, 19.856]	11.87 [6.17, 29.16]	26.94	28.78	72.299	72.747	74.512	73.415	87.956
105	2	58	3	54.900	71.340	16.440 [7.003, 24.869]	29.95 [12.76, 45.30]	21.99	25.94	77.097	73.264	61.903	64.668	79.769
106	2	31	4	80.300	70.566	9.734 [3.310, 15.509]	12.12 [4.12, 19.31]	26.22	26.31		72.166	68.316	64.791	76.990
107	1	27	4	69.250	77.413	8.163 [4.078, 11.112]	11.79 [5.89, 16.05]	25.75	27.91	80.362	73.328	75.661	79.659	78.056
108	1	43	4	63.300	76.417	13.117 [11.261, 15.816]	20.72 [17.79, 24.99]	25.68	28.30	77.324	76.378	74.707	74.561	79.116
109	2	63	3	66.100	71.210	5.110 [0.555, 12.799]	7.73 [0.84, 19.36]	21.83	26.34		72.581	67.814	65.545	78.899
110	1	43	1_2	48.050	72.506	24.456 [16.481, 33.670]	50.90 [34.30, 70.07]	18.54	27.45	73.997	72.545	64.531	69.735	81.720
111	1	22	3	67.600	72.015	4.415 [1.929, 7.034]	6.53 [2.85, 10.40]	23.12	27.89	73.030	74.633	65.671	72.614	74.127
112	2	63	3	66.650	67.968	1.318 [0.271, 3.419]	1.98 [0.41, 5.13]	23.34	26.43	68.102	70.069	66.379		67.323
113	2	59	3	67.600	77.183	9.583 [4.447, 11.744]	14.18 [6.58, 17.37]	24.83	27.73	79.344	78.946	78.396	72.047	
114	1	34	3	60.000	67.547	7.547 [4.548, 11.831]	12.58 [7.58, 19.72]	23.44	26.21	67.923	65.884		64.548	71.831
115	1	62	3	54.200	71.886	17.686 [12.529, 21.377]	32.63 [23.12, 39.44]	22.85	26.70	75.577	73.451	66.729	72.379	71.294
116	1	62	7	109.300	89.764	19.536 [12.587, 29.313]	17.87 [11.52, 26.82]	40.64	32.01			96.713	92.591	79.987
117	2	42	4	90.650	92.072	1.422 [1.348, 9.414]	1.57 [1.49, 10.39]	27.67	33.35	100.064	91.998	88.056	88.171	
118	1	26	3	71.000	80.011	9.011 [0.299, 15.724]	12.69 [0.42, 22.15]	24.28	29.80	86.724	82.405	75.750	83.878	71.299
119	2	51	5	91.100	78.301	12.799 [10.583, 15.451]	14.05 [11.62, 16.96]	33.46	27.92	77.731	79.085	80.517	78.524	75.649
120	2	57	5	91.100	89.482	1.618 [1.756, 7.001]	1.78 [1.93, 7.68]	31.90	32.30	92.856	96.181	88.164	86.108	84.099
121	2	47	4	76.200	94.060	17.860 [11.595, 22.748]	23.44 [15.22, 29.85]	27.65	33.66	98.948		95.436		87.795
122	1	51	4	65.600	75.579	9.979 [7.745, 13.005]	15.21 [11.81, 19.83]	27.66	27.11	78.605	73.345	73.663		76.700
123	2	59	3	65.600	75.821	10.221 [2.192, 15.238]	15.58 [3.34, 23.23]	24.10	28.72	80.838		76.426	78.227	67.792
124	2	35	5	97.650	82.428	15.222 [12.740, 18.036]	15.59 [13.05, 18.47]	31.89	28.98	79.614	84.910	83.250	83.185	81.183
125	2	53	4	73.500	86.969	13.469 [7.282, 20.309]	18.33 [9.91, 27.63]	28.01	31.19	90.617	93.809	82.373	87.264	80.782
126	1	47	4	71.800	67.622	4.178 [8.790, 16.180]	5.82 [12.24, 22.54]	29.50	27.30	62.717	63.010	62.913	61.490	87.980
127	2	25	3	70.100	76.882	6.782 [4.366, 15.345]	9.67 [6.23, 21.89]	22.63	27.18	82.663	85.445	81.548	74.466	60.286
128	1	46	6	87.200	78.092	9.108 [5.827, 11.625]	10.44 [6.68, 13.33]	37.25	29.37	81.373		78.392	77.030	75.575
129	1	39	4	76.200	80.049	3.849 [2.654, 10.591]	5.05 [3.48, 13.90]	28.68	29.10	79.297	80.562	73.546		86.791
130	1	67	7	102.850	88.379	14.471 [11.864, 17.864]	14.07 [11.54, 17.37]	41.73	32.90	90.986		87.822	89.721	84.986
131	2	30	3	68.400	77.191	8.791 [3.990, 15.090]	12.85 [5.83, 22.06]	23.39	27.28	74.986	76.749	72.390	78.341	83.490
132	2	34	5	103.400	87.634	15.766 [7.510, 33.079]	15.25 [7.26, 31.99]	34.15	31.46	93.817		95.890	90.509	70.321
133	2	43	4	85.300	88.850	3.550 [0.178, 14.050]	4.16 [0.21, 16.47]	28.17	32.04	87.036	83.893	85.121	99.350	
134	2	66	1_2	44.500	70.251	25.751 [19.819, 36.007]	57.87 [44.54, 80.91]	16.96	26.70	73.384	66.216	64.319	66.828	80.507
135	1	42	3	53.150	74.968	21.818 [18.047, 24.880]	41.05 [33.95, 46.81]	21.29	29.45	78.030	72.954	71.197	77.690	
136	1	59	3	58.700	68.605	9.905 [6.455, 15.051]	16.87 [11.00, 25.64]	22.93	25.74	68.837	69.836	65.155	65.447	73.751

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
137	1	47	7	124.000	94.918	29.082 [26.469, 33.282]	23.45 [21.35, 26.84]	41.43	35.94		97.531	96.506		90.718
138	1	49	7	97.500	74.387	23.113 [18.103, 27.539]	23.71 [18.57, 28.25]	42.76	28.58	74.439	76.356	71.782	69.961	79.397
139	1	65	3	63.150	76.301	13.151 [8.902, 16.233]	20.82 [14.10, 25.71]	23.77	27.88		79.383	72.052	74.929	78.838
140	1	33	5	74.050	82.288	8.238 [0.842, 13.087]	11.13 [1.14, 17.67]	32.05	31.24	87.137	82.154	74.892	81.177	86.082
141	1	33	4	80.200	80.556	0.356 [0.052, 3.996]	0.44 [0.06, 4.98]	29.10	29.00	82.202	81.398	80.148	82.826	76.204
142	2	27	4	91.400	89.443	1.957 [0.683, 5.742]	2.14 [0.75, 6.28]	28.53	30.70	92.083	85.658	89.987	90.046	
143	2	34	5	91.600	77.296	14.304 [9.612, 16.672]	15.62 [10.49, 18.20]	30.25	27.57	78.858	74.928	75.354	75.351	81.988
144	2	39	1_2	49.150	78.882	29.732 [21.499, 36.305]	60.49 [43.74, 73.87]	17.01	28.48	85.455	75.782	70.649	83.228	79.296
145	2	28	3	60.400	77.853	17.453 [14.279, 24.425]	28.90 [23.64, 40.44]	23.01	28.46	78.099	74.781	74.679	76.883	84.825
146	2	21	3	64.800	82.365	17.565 [9.033, 32.515]	27.11 [13.94, 50.18]	20.45	28.62	79.894	73.833	75.824	97.315	84.961
147	2	69	3	72.950	72.619	0.331 [0.791, 7.952]	0.45 [1.08, 10.90]	24.09	27.15	72.159	71.753	77.459	64.998	76.726
148	2	51	5	99.600	90.948	8.652 [4.190, 11.158]	8.69 [4.21, 11.20]	32.90	30.98	91.251	88.442	88.687	95.410	
149	2	23	4	95.100	83.041	12.059 [5.190, 22.300]	12.68 [5.46, 23.45]	29.35	28.99	89.910	82.949	83.407	86.138	72.800
150	2	20	3	53.000	75.145	22.145 [11.350, 27.735]	41.78 [21.42, 52.33]	21.23	27.60	76.692	77.557	64.350	76.390	80.736
151	1	59	5	82.000	86.380	4.380 [4.346, 7.912]	5.34 [5.30, 9.65]	34.58	32.15	89.912	87.643	87.904	88.785	77.654
152	2	50	3	62.200	77.135	14.935 [7.785, 24.690]	24.01 [12.52, 39.69]	24.60	27.31	79.759	86.890	72.404	76.639	69.985
153	1	61	3	47.400	79.597	32.197 [16.757, 42.816]	67.93 [35.35, 90.33]	22.86	30.54	90.216	89.846	83.397	64.157	70.370
154	2	41	6	104.000	83.070	20.930 [11.940, 28.650]	20.12 [11.48, 27.55]	36.41	31.75	84.873	92.060	80.810	82.258	75.350
155	2	52	4	79.500	71.660	7.840 [0.204, 15.607]	9.86 [0.26, 19.63]	28.85	28.80		71.792	63.892	79.296	
156	1	40	4	55.700	80.590	24.890 [11.694, 31.102]	44.69 [20.99, 55.84]	25.09	30.52	85.779	84.097	67.394	78.879	86.802
157	1	49	6	96.250	73.754	22.496 [16.544, 30.744]	23.37 [17.19, 31.94]	37.13	29.56	79.443	70.937	65.506	79.706	73.177
158	2	29	5	108.300	86.534	21.766 [16.483, 28.841]	20.10 [15.22, 26.63]	34.96	31.91	91.817	87.491	79.459	90.169	83.732
159	1	23	4	79.700	89.478	9.778 [4.834, 15.888]	12.27 [6.07, 19.93]	25.73	33.26		85.362	92.428	95.588	84.534
160	1	59	3	58.000	66.409	8.409 [4.103, 12.242]	14.50 [7.07, 21.11]	21.05	27.84	65.338	66.972	62.103	67.393	70.242
161	1	62	1_2	35.400	67.107	31.707 [29.188, 33.925]	89.57 [82.45, 95.83]	15.53	25.98	66.297	64.588		69.325	68.218
162	2	18	1_2	56.000	73.066	17.066 [7.451, 27.173]	30.48 [13.31, 48.52]	18.29	26.76	74.359	73.326	63.451	71.022	83.173
163	2	66	4	82.200	80.428	1.772 [0.264, 7.342]	2.16 [0.32, 8.93]	28.78	30.45	82.464	81.085	79.087	84.647	74.858
164	2	21	1_2	52.700	77.596	24.896 [9.968, 32.233]	47.24 [18.91, 61.16]	18.90	28.14	84.933	82.080	62.668	80.704	
165	1	34	5	96.800	89.241	7.559 [3.783, 10.379]	7.81 [3.91, 10.72]	33.49	30.32	86.421	87.949	93.017	89.575	
166	1	65	1_2	46.950	67.740	20.791 [14.908, 29.935]	44.28 [31.75, 63.76]	19.54	24.96	65.800	71.637	61.858	62.522	76.885
167	1	23	5	86.200	86.263	0.063 [0.103, 7.371]	0.07 [0.12, 8.55]	33.25	31.97	91.800	92.497	86.303	81.886	78.829
168	2	65	4	75.750	85.299	9.549 [4.688, 16.060]	12.61 [6.19, 21.20]	28.51	29.66	91.810		80.438	87.853	81.097
169	2	23	1_2	52.050	67.340	15.290 [10.694, 20.332]	29.38 [20.54, 39.06]	18.66	25.08		72.382	62.744	66.893	
170	2	60	3	61.800	74.680	12.880 [7.473, 19.027]	20.84 [12.09, 30.79]	22.16	27.38	78.660	69.961		69.273	80.827

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
171	2	53	4	73.800	82.494	8.694 [1.715, 14.957]	11.78 [2.32, 20.27]	27.11	28.70	88.757	84.514	72.085	83.708	83.406
172	2	66	4	79.700	91.643	11.943 [12.692, 22.190]	14.98 [15.93, 27.84]	28.58	32.99	101.890	97.058	92.392	99.946	66.927
173	2	48	4	90.400	89.997	0.403 [0.597, 2.835]	0.45 [0.66, 3.14]	27.59	32.25	87.565	91.366	89.192	92.060	89.803
174	1	35	3	53.550	72.592	19.042 [15.502, 24.482]	35.56 [28.95, 45.72]	21.45	26.83			69.052	70.691	78.032
175	1	44	3	61.900	62.496	0.596 [0.268, 2.722]	0.96 [0.43, 4.40]	24.18	25.15		64.622	62.168		60.697
176	1	56	1_2	34.800	62.871	28.071 [24.783, 32.423]	80.66 [71.22, 93.17]	15.89	23.98	65.317	67.223	59.583	60.977	61.257
177	1	19	3	52.050	68.314	16.264 [8.842, 23.307]	31.25 [16.99, 44.78]	22.24	25.81	70.915	66.750	67.657	60.892	75.357
178	2	71	7	126.800	95.404	31.396 [24.525, 34.829]	24.76 [19.34, 27.47]	43.36	34.22		94.399	102.275	92.972	91.971
179	2	50	4	92.600	86.334	6.266 [1.223, 16.359]	6.77 [1.32, 17.67]	29.89	31.74		89.516	91.377	88.204	76.241
180	2	49	3	65.700	74.588	8.888 [0.334, 20.164]	13.53 [0.51, 30.69]	22.47	28.63	66.034	85.864	73.062	73.394	
181	1	48	5	75.000	73.799	1.201 [0.881, 2.698]	1.60 [1.17, 3.60]	32.46	26.50	73.770		72.302	73.245	75.881
182	1	35	1_2	47.900	67.960	20.060 [12.551, 26.660]	41.88 [26.20, 55.66]	18.71	26.19		72.152	60.451	64.677	74.560
183	2	21	3	76.100	75.646	0.454 [1.361, 3.135]	0.60 [1.79, 4.12]	23.23	26.70	74.261	77.461	77.898	72.965	
184	2	57	1_2	43.950	68.571	24.621 [17.881, 34.045]	56.02 [40.68, 77.46]	15.57	27.17		67.588	66.869	77.995	61.831
185	2	65	3	54.250	68.655	14.405 [12.881, 15.913]	26.55 [23.74, 29.33]	20.17	25.88	69.097	67.131	69.371	67.514	70.163
186	2	33	4	73.750	70.228	3.522 [0.971, 7.437]	4.78 [1.32, 10.08]	25.22	26.49	75.200	69.536	67.313	66.313	72.779
187	1	41	4	83.700	75.838	7.862 [5.958, 10.960]	9.39 [7.12, 13.09]	28.62	27.54	76.193	77.742	72.740	76.676	
188	2	51	3	52.450	66.872	14.422 [11.257, 17.142]	27.50 [21.46, 32.68]	21.83	25.79	65.047	69.592	63.707	66.630	69.384
189	2	42	3	74.250	88.292	14.042 [12.418, 16.158]	18.91 [16.72, 21.76]	24.24	31.98		86.668	87.800	90.408	
190	1	33	4	69.300	71.637	2.337 [3.662, 7.291]	3.37 [5.28, 10.52]	29.60	27.15	74.010	72.962	62.984		76.591
191	2	52	5	86.400	64.137	22.263 [20.261, 26.100]	25.77 [23.45, 30.21]	31.35	25.14	64.970	66.139	65.139	60.300	
192	1	62	3	51.700	75.626	23.926 [15.957, 32.951]	46.28 [30.86, 63.74]	22.38	28.01		79.095	71.100	67.657	84.651
193	2	74	7	126.400	91.692	34.708 [29.444, 43.396]	27.46 [23.29, 34.33]	45.32	34.32	96.956	92.833	92.363	93.302	83.004
194	2	33	5	100.900	79.648	21.252 [18.263, 25.338]	21.06 [18.10, 25.11]	30.46	27.94		81.655	78.739	75.562	82.637
195	2	48	4	78.400	79.433	1.033 [1.779, 13.780]	1.32 [2.27, 17.58]	28.11	28.58	92.180	80.179	76.350	69.021	
196	2	48	4	104.300	87.056	17.244 [10.278, 19.701]	16.53 [9.85, 18.89]	29.83	30.61	84.599	84.749	94.022	84.854	
197	2	56	3	68.550	74.659	6.109 [5.921, 6.480]	8.91 [8.64, 9.45]	24.00	26.91	74.471	75.030			74.478
198	1	55	4	71.150	76.310	5.160 [1.038, 15.322]	7.25 [1.46, 21.53]	28.87	26.77	74.323	72.258	72.188	86.472	
199	1	54	6	82.950	79.734	3.216 [2.787, 6.530]	3.88 [3.36, 7.87]	35.90	29.52	78.012	76.420	80.163	77.805	86.270
200	2	58	4	75.760	71.821	3.939 [1.199, 5.900]	5.20 [1.58, 7.79]	27.83	27.33	70.034	71.852	70.399	69.860	76.959
201	1	60	4	65.900	78.516	12.616 [0.243, 19.204]	19.14 [0.37, 29.14]	28.90	30.23	75.773	85.104	84.728	66.143	80.833
202	2	59	3	70.400	82.790	12.390 [7.283, 15.172]	17.60 [10.34, 21.55]	24.36	30.14		85.572	82.644	77.683	85.262
203	2	65	5	90.000	98.975	8.975 [2.266, 15.962]	9.97 [2.52, 17.74]	34.72	34.79	105.962	92.268	92.656	105.014	
204	1	57	4	61.150	68.366	7.216 [2.807, 15.899]	11.80 [4.59, 26.00]	25.13	26.10	66.649	67.265	66.913	63.957	77.049

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
205	2	33	7	132.300	91.040	41.260 [37.312, 44.254]	31.19 [28.20, 33.45]	40.83	32.23	91.219	94.988		89.905	88.046
206	2	68	4	87.500	83.064	4.436 [0.993, 8.908]	5.07 [1.14, 10.18]	27.31	29.53	84.247	78.593	83.534	80.453	88.493
207	1	42	7	106.300	87.908	18.392 [13.345, 26.542]	17.30 [12.55, 24.97]	42.58	33.94	84.026	92.955	91.794	91.007	79.758
208	1	50	4	50.600	75.969	25.369 [16.992, 34.278]	50.14 [33.58, 67.74]	25.09	29.19	77.306	84.878	67.592	71.519	78.551
209	1	35	3	56.700	69.463	12.763 [8.140, 18.812]	22.51 [14.36, 33.18]	23.30	26.13	75.512	70.175	64.840	66.600	70.190
210	1	56	5	91.800	84.611	7.189 [1.830, 14.550]	7.83 [1.99, 15.85]	33.72	31.08	89.970	88.477	83.955	77.250	83.400
211	1	49	7	108.500	73.556	34.944 [31.810, 36.446]	32.21 [29.32, 33.59]	42.92	29.07	72.054	76.690	72.877	72.603	
212	1	58	4	72.100	90.642	18.542 [16.268, 21.918]	25.72 [22.56, 30.40]	28.16	36.20	89.677	94.018	90.504	88.368	
213	1	39	3	60.600	84.495	23.895 [19.874, 25.611]	39.43 [32.79, 42.26]	23.97	30.43	86.211	84.304	80.474	85.572	85.914
214	2	35	5	85.600	85.489	0.111 [0.170, 8.469]	0.13 [0.20, 9.89]	30.33	30.84	85.430	89.182	89.673	86.027	77.131
215	2	60	3	67.600	88.614	21.014 [11.955, 28.475]	31.09 [17.69, 42.12]	24.24	32.28	94.227	89.448	83.763	96.075	79.555
216	1	35	4	77.050	70.432	6.618 [2.060, 11.321]	8.59 [2.67, 14.69]	25.74	26.68	72.207	65.810	65.729	74.990	73.422
217	2	56	3	75.200	69.950	5.250 [1.823, 8.123]	6.98 [2.42, 10.80]	24.56	25.50	67.798	73.236	68.262	67.077	73.377
218	1	40	6	106.660	77.263	29.397 [26.312, 34.106]	27.56 [24.67, 31.98]	38.24	28.28	77.235	72.554	78.509	77.670	80.347
219	2	25	3	70.950	79.076	8.126 [0.363, 15.829]	11.45 [0.51, 22.31]	22.65	28.82	86.779	74.109	79.924	83.254	71.313
220	2	19	3	54.300	66.024	11.724 [6.229, 18.909]	21.59 [11.47, 34.82]	20.19	25.27	73.209	64.931	60.529	61.046	70.403
221	2	35	3	63.250	62.499	0.751 [0.249, 4.554]	1.19 [0.39, 7.20]	21.38	23.14	66.736	63.499	58.696	61.063	
222	2	69	3	61.900	77.656	15.756 [11.390, 18.429]	25.45 [18.40, 29.77]	23.59	28.69	80.329	78.061	73.290	78.104	78.498
223	1	62	5	79.900	76.415	3.485 [2.320, 9.928]	4.36 [2.90, 12.43]	33.26	29.11	82.220	77.149	76.318	69.972	
224	2	54	3	59.300	82.086	22.786 [21.496, 24.784]	38.43 [36.25, 41.79]	24.68	30.88	81.870	81.594	80.796	84.084	
225	2	24	1,2	51.100	67.825	16.725 [13.842, 19.684]	32.73 [27.09, 38.52]	18.11	27.18	68.206	70.784	64.942	68.819	66.374
226	2	71	4	67.050	56.366	10.684 [7.472, 13.279]	15.93 [11.14, 19.81]	28.27	20.18	55.642	59.578	56.573	53.771	56.266
227	2	61	4	70.200	67.156	3.044 [0.819, 4.946]	4.34 [1.17, 7.05]	25.48	24.55	65.254	66.820	66.118	68.210	69.381
228	2	39	4	67.250	67.598	0.348 [0.286, 2.914]	0.52 [0.43, 4.33]	25.31	26.32	66.594	70.165	66.964	66.667	
229	2	53	3	63.850	64.981	1.131 [0.587, 3.213]	1.77 [0.92, 5.03]	20.85	24.54	65.762	64.437	63.129	67.063	64.514
230	2	51	3	63.950	75.921	11.971 [7.137, 14.591]	18.72 [11.16, 22.82]	24.98	28.12	78.134		71.087	78.541	
231	2	31	4	79.550	67.215	12.335 [1.925, 17.169]	15.51 [2.42, 21.58]	27.85	25.47	66.011	67.014	63.042	62.381	77.625
232	1	56	4	81.450	84.415	2.965 [1.347, 5.871]	3.64 [1.65, 7.21]	29.21	31.97	85.860	86.405	82.797	79.691	87.321
233	1	27	1,2	32.300	68.613	36.313 [25.447, 46.241]	112.43 [78.78, 143.16]	14.95	26.80	72.863	76.855	63.046	61.690	
234	2	39	4	87.950	80.913	7.037 [4.077, 9.337]	8.00 [4.64, 10.62]	25.42	28.75	80.484	78.613	83.873	80.683	
235	1	68	4	60.250	68.784	8.534 [2.620, 14.618]	14.17 [4.35, 24.26]	27.14	27.13	74.868	70.410	62.870	66.990	
236	1	35	3	47.100	70.273	23.173 [18.566, 31.361]	49.20 [39.42, 66.58]	20.93	26.93	74.481	78.462	65.666	66.874	65.881
237	2	47	5	106.600	91.749	14.851 [7.565, 20.901]	13.93 [7.10, 19.61]	34.81	32.17	99.035	91.855	90.407	85.699	
238	2	38	1,2	52.100	68.894	16.794 [9.678, 25.812]	32.23 [18.58, 49.54]	17.41	25.09	65.460	70.144	69.178	61.778	77.912

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
239	1	36	1_2	47.700	70.105	22.405 [15.566, 31.784]	46.97 [32.63, 66.63]	19.85	26.63	68.521	79.484	63.266	69.149	
240	2	49	1_2	48.700	89.950	41.250 [31.260, 46.014]	84.70 [64.19, 94.48]	18.33	31.86	90.632	94.497	79.960	94.714	
241	1	37	7	100.350	70.613	29.737 [24.272, 35.514]	29.63 [24.19, 35.39]	41.77	25.74	76.078	72.858	64.836	68.681	
242	1	40	6	89.850	83.861	5.989 [1.249, 11.546]	6.67 [1.39, 12.85]	35.54	30.89	78.304		88.601	84.677	
243	1	35	6	87.850	72.299	15.551 [13.053, 18.807]	17.70 [14.86, 21.41]	36.10	28.32	73.756	74.797	71.600	69.043	
244	1	57	5	88.950	96.957	8.007 [2.185, 11.191]	9.00 [2.46, 12.58]	34.32	36.43	100.141	99.340	91.135	97.213	
245	2	72	1_2	53.250	79.945	26.695 [24.525, 29.545]	50.13 [46.06, 55.48]	19.56	29.60	81.425	82.795	77.775	77.785	
246	2	61	3	59.600	67.149	7.549 [1.057, 19.583]	12.67 [1.77, 32.86]	20.87	25.31	62.251	79.183	66.504	60.657	
247	2	69	3	73.050	95.198	22.148 [15.887, 27.462]	30.32 [21.75, 37.59]	24.69	33.98	100.512	95.806	88.937	95.536	
248	2	47	1_2	60.400	75.600	15.200 [13.495, 19.807]	25.17 [22.34, 32.79]	19.50	28.36	80.207		73.895	73.895	74.402
249	2	35	3	66.950	73.424	6.474 [2.269, 11.635]	9.67 [3.39, 17.38]	22.11	26.25	74.058	78.585	69.302	69.219	75.954
250	1	38	6	102.050	96.715	5.335 [1.936, 7.623]	5.23 [1.90, 7.47]	36.59	32.49	95.603	100.114	94.427		
251	1	72	4	69.250	84.314	15.064 [12.535, 16.850]	21.75 [18.10, 24.33]	27.74	30.79	81.785	85.165	84.206	86.100	
252	1	40	4	72.200	77.411	5.211 [0.936, 12.968]	7.22 [1.30, 17.96]	27.85	29.96	85.168	78.035	71.264	73.790	78.801
253	1	35	7	106.700	87.275	19.425 [17.672, 20.831]	18.20 [16.56, 19.52]	44.41	32.58	89.028	86.426	87.778	85.869	
254	1	23	5	77.500	83.259	5.759 [6.039, 16.439]	7.43 [7.79, 21.21]	31.04	30.65	83.598	93.939	84.036	71.461	
255	2	63	1_2	46.600	72.188	25.588 [22.352, 27.785]	54.91 [47.97, 59.62]	18.67	26.92	73.227	68.952	74.385		
256	1	49	4	74.550	74.095	0.455 [0.258, 2.843]	0.61 [0.35, 3.81]	27.05	28.05	74.292	74.913	75.470	71.707	
257	1	58	1_2	44.650	72.999	28.349 [26.696, 30.647]	63.49 [59.79, 68.64]	18.58	29.32	72.749	72.604	75.297	71.346	
258	1	68	1_2	45.000	69.515	24.515 [19.696, 27.126]	54.48 [43.77, 60.28]	18.73	25.81	69.524	71.715	72.126	64.696	
259	1	52	4	68.600	68.836	0.236 [2.739, 8.286]	0.34 [3.99, 12.08]	25.20	26.33	71.339	60.314		74.855	
260	1	58	6	93.650	99.325	5.675 [0.541, 11.126]	6.06 [0.58, 11.88]	36.13	39.51	94.191	96.714	101.618	104.776	
261	1	51	4	87.250	81.198	6.052 [3.955, 12.869]	6.94 [4.53, 14.75]	29.15	29.96	91.205	74.381	80.480	78.724	
262	2	49	5	102.250	84.900	17.350 [13.281, 21.603]	16.97 [12.99, 21.13]	34.56	30.19	88.969		80.647	85.084	
263	1	58	6	84.700	85.573	0.873 [0.562, 5.833]	1.03 [0.66, 6.89]	35.25	33.47	89.367	87.279	78.867	85.262	87.090
264	1	35	7	127.000	91.923	35.077 [29.309, 40.335]	27.62 [23.08, 31.76]	47.22	35.54	97.691	92.893	90.444	86.665	
265	1	30	6	102.250	91.079	11.171 [7.415, 17.651]	10.93 [7.25, 17.26]	35.38	33.64	93.200	94.835	84.600	91.681	
266	2	31	4	81.800	86.132	4.332 [1.551, 8.261]	5.30 [1.90, 10.10]	26.11	29.46	85.121	90.061	83.351	85.993	
267	1	59	3	54.700	75.327	20.627 [11.592, 30.975]	37.71 [21.19, 56.63]	24.31	28.76	85.675	73.116	66.292	76.226	
268	1	33	5	78.600	79.088	0.488 [0.267, 3.659]	0.62 [0.34, 4.66]	34.02	30.95	74.941	80.367	80.868	78.867	80.397
269	1	24	3	53.200	75.318	22.118 [18.705, 23.434]	41.58 [35.16, 44.05]	20.27	30.91	76.634	76.324	71.905	76.411	
270	1	51	4	87.800	79.450	8.350 [0.754, 15.529]	9.51 [0.86, 17.69]	29.34	27.90	87.046	82.121	72.271	76.361	
271	2	40	3	58.800	80.767	21.967 [15.439, 27.591]	37.36 [26.26, 46.62]	21.08	30.48	77.488	84.952	74.239	86.391	
272	1	43	7	98.650	97.515	1.135 [2.579, 5.650]	1.15 [2.61, 5.73]	41.06	37.79	101.269	93.000	94.561	101.230	

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
273	1	30	7	129.100	88.202	40.898 [34.088, 51.967]	31.68 [26.40, 40.25]	45.20	32.89	95.012	88.921	77.133	91.743	
274	2	26	3	62.600	80.730	18.130 [16.115, 21.539]	28.96 [25.74, 34.41]	22.45	28.96	84.139	78.715	78.836	80.770	81.190
275	2	29	3	72.200	72.583	0.383 [0.308, 3.233]	0.53 [0.43, 4.48]	22.04	25.77		75.433	69.807	72.508	
276	2	47	3	70.800	90.114	19.314 [16.891, 21.663]	27.28 [23.86, 30.60]	24.79	29.92	92.463	90.189		87.691	
277	2	49	1_2	53.500	59.500	6.000 [4.680, 7.612]	11.21 [8.75, 14.23]	18.73	23.10	61.112	58.511	58.180	60.195	
278	1	51	4	62.900	86.511	23.611 [19.516, 28.137]	37.54 [31.03, 44.73]	27.22	33.31	82.416	91.037	87.278	85.314	
279	1	47	3	48.650	75.185	26.535 [23.824, 28.519]	54.54 [48.97, 58.62]	21.91	27.17	75.206	75.889	72.474	77.169	
280	2	23	4	87.750	78.061	9.689 [0.044, 14.831]	11.04 [0.05, 16.90]	28.01	29.06	79.931	87.706	72.919	76.008	73.740
281	2	67	3	69.100	81.043	11.943 [7.224, 15.391]	17.28 [10.45, 22.27]	22.06	28.89	82.314	76.324		84.491	
282	1	50	3	54.900	79.188	24.288 [21.044, 27.628]	44.24 [38.33, 50.32]	21.72	28.75	82.528	76.081	82.199	75.944	
283	2	40	1_2	54.200	76.786	22.586 [14.566, 30.635]	41.67 [26.87, 56.52]	19.20	28.86	84.450	84.835	69.093	68.766	
284	1	52	4	72.800	79.500	6.700 [5.146, 15.940]	9.20 [7.07, 21.90]	28.80	31.88	87.667	77.946	63.647	88.740	
285	1	57	5	78.300	92.106	13.806 [10.388, 16.256]	17.63 [13.27, 20.76]	33.89	33.08	92.562	88.688	92.618	94.556	
286	2	53	3	54.050	81.241	27.191 [20.495, 33.922]	50.31 [37.92, 62.76]	23.39	28.96	87.759	78.880	74.545	77.051	87.972
287	2	49	4	77.800	90.821	13.021 [9.282, 16.679]	16.74 [11.93, 21.44]	25.70	33.79	87.082	88.396	93.326	94.479	
288	2	49	6	122.840	93.121	29.719 [26.059, 35.710]	24.19 [21.21, 29.07]	36.28	35.16	94.313	96.345	87.130	96.781	91.036
289	1	40	5	98.500	86.759	11.741 [7.420, 14.473]	11.92 [7.53, 14.69]	33.69	30.78	87.101	84.027	84.825	91.080	
290	2	37	5	95.750	84.264	11.486 [3.659, 16.546]	12.00 [3.82, 17.28]	30.56	30.48	82.268	86.923	80.836	92.091	79.204
291	1	47	4	70.000	83.762	13.762 [11.870, 15.577]	19.66 [16.96, 22.25]	28.40	29.06	81.870	82.382	85.218	85.577	
292	1	42	5	80.500	97.966	17.466 [1.626, 26.036]	21.70 [2.02, 32.34]	33.51	36.18	101.644	99.546	106.536	99.976	82.126
293	1	51	6	89.700	83.750	5.950 [4.057, 8.983]	6.63 [4.52, 10.01]	37.34	31.43	82.255	85.643	85.643	84.492	80.717
294	1	27	4	80.400	86.409	6.009 [1.345, 11.047]	7.47 [1.67, 13.74]	29.53	31.25	87.034	91.447	79.055	88.101	
295	2	49	4	70.900	88.359	17.459 [14.392, 21.245]	24.62 [20.30, 29.96]	28.04	32.31	85.292	87.582	92.145	88.849	87.927
296	1	18	5	102.550	93.474	9.076 [4.441, 13.289]	8.85 [4.33, 12.96]	33.49	33.26	97.426	98.109	89.261	92.308	90.266
297	2	62	3	67.600	79.866	12.266 [4.261, 19.515]	18.14 [6.30, 28.87]	22.59	27.37	87.115	79.353	81.134	71.861	
298	1	46	1_2	44.900	68.744	23.844 [19.593, 32.528]	53.11 [43.64, 72.44]	18.69	27.19	77.428	67.875	64.493	65.181	
299	2	34	7	172.350	108.282	64.068 [61.692, 65.775]	37.17 [35.79, 38.16]	53.79	40.81	107.614		110.658	106.575	
300	2	49	4	81.850	90.228	8.378 [3.581, 11.911]	10.24 [4.38, 14.55]	27.35	31.04	91.670	85.431	90.050	93.761	

APÊNDICE C - Resultados individuais utilizados nas análises de desempenho do modelo final

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
1	2	45	3	78.000	96.483	18.483 [15.123, 21.860]	23.70 [19.39, 28.03]	23.81	28.14	93.123	94.249	99.860	98.699	
2	1	35	3	53.700	54.583	0.883 [1.571, 4.508]	1.64 [2.93, 8.39]	22.07	22.21	56.117	58.208	52.129	51.877	
3	1	27	4	65.400	66.575	1.175 [0.547, 3.574]	1.80 [0.84, 5.47]	28.31	28.73	64.853	68.510	68.974	63.962	
4	1	25	7	151.100	127.966	23.134 [18.344, 30.973]	15.31 [12.14, 20.50]	55.50	48.13	120.127	128.681	132.756	130.299	
5	1	24	3	56.800	55.504	1.296 [1.988, 2.930]	2.28 [3.50, 5.16]	23.34	22.94	53.870	53.964	59.369	54.812	
6	2	46	3	59.300	56.292	3.008 [0.537, 7.545]	5.07 [0.91, 12.72]	21.52	20.69	51.755	54.437	58.310	59.837	57.123
7	2	48	3	77.350	87.421	10.071 [4.573, 13.023]	13.02 [5.91, 16.84]	24.41	27.75	89.378	81.923	86.990	88.442	90.373
8	1	68	6	104.000	101.124	2.876 [1.674, 4.001]	2.77 [1.61, 3.85]	39.14	38.62	102.326	100.574	101.595	99.999	
9	1	34	5	89.200	93.692	4.492 [1.054, 7.842]	5.04 [1.18, 8.79]	30.51	32.40	97.042	95.614	92.842	92.708	90.254
10	2	70	4	76.600	88.710	12.110 [0.985, 20.348]	15.81 [1.29, 26.56]	25.01	29.02	95.333	86.640	87.041	77.585	96.948
11	2	58	3	66.200	64.902	1.298 [1.421, 5.562]	1.96 [2.15, 8.40]	24.92	24.61	68.144	63.206	60.638	67.621	
12	2	52	7	119.900	110.225	9.675 [2.548, 19.087]	8.07 [2.13, 15.92]	44.04	40.87	117.352	116.247	114.693	102.018	100.813
13	2	53	4	81.200	82.567	1.367 [0.912, 5.552]	1.68 [1.12, 6.84]	27.13	27.90	77.709	79.701	86.752	82.112	86.559
14	1	44	7	100.650	97.862	2.788 [0.455, 5.924]	2.77 [0.45, 5.89]	40.32	37.93	94.726	100.195	98.290	98.236	
15	1	42	4	75.800	80.812	5.012 [1.231, 12.614]	6.61 [1.62, 16.64]	27.84	29.20	79.102	81.162	88.414	74.569	
16	1	36	4	84.800	94.335	9.535 [6.432, 13.268]	11.24 [7.58, 15.65]	29.00	32.27	97.557	98.068	92.294	92.525	91.232
17	1	43	4	76.700	78.526	1.826 [1.085, 6.751]	2.38 [1.41, 8.80]	29.23	29.49	77.931	78.921	74.544	77.785	83.451
18	2	30	1_2	53.400	57.464	4.064 [3.281, 5.243]	7.61 [6.14, 9.82]	17.44	19.24	58.643	57.069	56.681		
19	2	65	3	72.600	73.346	0.746 [0.459, 4.410]	1.03 [0.63, 6.07]	24.54	24.93	76.779	77.010	69.979	70.819	72.141
20	1	21	4	86.200	97.986	11.786 [10.012, 14.343]	13.67 [11.61, 16.64]	29.83	34.39	96.212	96.871	98.496	97.809	100.543
21	2	61	6	109.500	101.279	8.221 [1.479, 13.752]	7.51 [1.35, 12.56]	36.59	34.37	108.021	102.333	100.258	100.036	95.748
22	2	28	4	93.400	117.383	23.983 [13.524, 32.915]	25.68 [14.48, 35.24]	27.89	35.11	115.398	119.486	118.791	106.924	126.315
23	1	44	4	62.300	62.333	0.033 [0.734, 5.043]	0.05 [1.18, 8.09]	25.27	25.04	67.343	63.742	61.566	60.486	58.529
24	2	69	4	89.100	92.898	3.798 [2.385, 7.443]	4.26 [2.68, 8.35]	29.09	29.46	86.715	95.437	96.543		
25	1	40	6	95.600	93.357	2.243 [0.534, 5.820]	2.35 [0.56, 6.09]	35.54	34.46	90.296	94.440	95.066	89.780	97.205
26	1	51	7	123.600	134.467	10.867 [7.629, 13.034]	8.79 [6.17, 10.55]	43.79	49.28	136.520	131.229	133.485	136.634	
27	2	64	4	79.100	73.541	5.559 [6.707, 11.870]	7.03 [8.48, 15.01]	28.36	26.21	72.393	70.769	70.939	67.230	86.375
28	2	54	4	77.150	79.548	2.398 [0.716, 15.607]	3.11 [0.93, 20.23]	25.19	26.19	77.866	75.283	78.591	73.245	92.757
29	2	33	3	71.250	66.723	4.527 [0.019, 10.007]	6.35 [0.03, 14.04]	22.49	20.38	71.231	68.586	65.834	61.243	
30	2	30	4	86.500	78.361	8.139 [0.638, 18.160]	9.41 [0.74, 20.99]	29.24	26.88	74.624	78.873	85.862	68.340	84.107
31	1	26	3	63.100	59.170	3.930 [1.924, 7.425]	6.23 [3.05, 11.77]	22.90	21.89	57.720	58.260	65.024	55.675	
32	1	61	6	101.900	94.652	7.248 [2.271, 10.403]	7.11 [2.23, 10.21]	38.83	36.39	91.863	91.497	91.901	93.826	104.171
33	2	61	3	65.800	67.531	1.731 [1.194, 4.400]	2.63 [1.82, 6.69]	24.77	25.39	69.341	64.606	70.200	69.055	64.454
34	1	45	6	94.500	95.671	1.171 [0.594, 2.376]	1.24 [0.63, 2.51]	37.38	37.94	96.876	95.577	96.326	93.906	

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
35	2	32	4	75.800	83.742	7.942 [2.468, 14.940]	10.48 [3.26, 19.71]	25.04	27.51	88.101	90.740	82.794	73.332	
36	2	27	5	126.100	140.665	14.565 [13.380, 15.563]	11.55 [10.61, 12.34]	34.21	36.72		140.853	141.663	139.480	
37	1	49	5	78.650	83.778	5.128 [4.054, 6.007]	6.52 [5.15, 7.64]	32.74	34.90	82.704	84.657	84.528	83.222	
38	1	47	3	56.100	56.869	0.769 [0.454, 3.890]	1.37 [0.81, 6.93]	22.76	23.06	56.554	57.288	56.787	53.725	59.990
39	1	45	4	66.600	70.823	4.223 [4.121, 4.325]	6.34 [6.19, 6.49]	25.38	26.82	70.925				70.721
40	1	60	5	82.900	77.109	5.791 [1.101, 10.860]	6.99 [1.33, 13.10]	33.21	30.86	81.799	79.907	76.046	75.755	72.040
41	1	41	6	94.200	81.445	12.755 [12.014, 13.794]	13.54 [12.75, 14.64]	39.21	34.49	81.508	80.406	81.681	82.186	
42	1	42	6	90.100	96.444	6.344 [3.903, 11.801]	7.04 [4.33, 13.10]	36.09	38.57	101.901	98.417	100.312	95.394	86.197
43	2	63	5	94.850	95.814	0.964 [3.563, 11.562]	1.02 [3.76, 12.19]	34.84	35.00	101.158	105.767	98.413	90.445	83.288
44	2	61	4	68.400	79.231	10.831 [0.301, 19.660]	15.84 [0.44, 28.74]	27.40	30.58	68.099	75.949	84.818	88.060	
45	1	20	3	61.550	68.434	6.884 [0.335, 15.543]	11.18 [0.54, 25.25]	22.61	25.00	66.277	77.093	69.149	61.215	
46	1	46	4	51.900	55.177	3.277 [0.277, 4.942]	6.31 [0.53, 9.52]	25.03	27.24	52.177	54.456	56.842	56.049	56.358
47	2	36	3	70.600	75.119	4.519 [1.598, 7.234]	6.40 [2.26, 10.25]	23.59	25.27	69.002	76.375	76.736	77.834	75.647
48	1	50	4	76.600	83.592	6.992 [4.384, 9.762]	9.13 [5.72, 12.74]	25.89	27.95	80.984	82.852	84.168	86.362	
49	1	68	3	53.500	53.280	0.220 [0.205, 2.758]	0.41 [0.38, 5.16]	23.78	24.03	53.967	54.708	53.705	50.742	
50	1	45	1_2	40.150	46.845	6.695 [5.226, 7.577]	16.68 [13.02, 18.87]	17.15	19.85	46.561	47.718	47.727	45.376	
51	2	52	4	74.800	73.846	0.954 [0.839, 3.993]	1.28 [1.12, 5.34]	26.50	26.24	77.670	75.639	73.042	72.070	70.807
52	2	53	4	83.200	98.478	15.278 [12.627, 16.800]	18.36 [15.18, 20.19]	25.97	30.87	98.808	98.257	100.000	99.498	95.827
53	2	21	4	85.700	87.052	1.352 [1.179, 5.071]	1.58 [1.38, 5.92]	28.97	29.22	90.771	82.120	84.521	88.127	89.719
54	2	56	5	94.400	82.565	11.835 [6.386, 15.542]	12.54 [6.76, 16.46]	30.13	26.24	82.556	78.858	82.588	80.806	88.014
55	2	74	4	74.800	71.126	3.674 [2.261, 11.271]	4.91 [3.02, 15.07]	28.50	26.49	77.085	77.061	63.529	68.136	69.818
56	1	63	5	84.800	75.442	9.358 [4.091, 15.852]	11.04 [4.82, 18.69]	34.85	30.66	80.709	76.310	75.800	68.948	
57	1	58	5	78.800	69.415	9.385 [7.459, 12.378]	11.91 [9.47, 15.71]	30.78	26.33	68.590	71.253	69.472	66.422	71.341
58	1	41	4	61.600	63.102	1.502 [0.304, 6.335]	2.44 [0.49, 10.28]	25.97	26.81	61.296	58.600	62.303	65.378	67.935
59	2	26	5	99.700	93.506	6.194 [0.223, 16.062]	6.21 [0.22, 16.11]	30.10	28.43	95.855	99.477	97.546	91.013	83.638
60	1	68	4	64.600	69.460	4.860 [2.123, 7.326]	7.52 [3.29, 11.34]	26.89	29.04	70.476	71.926	68.475	66.723	69.702
61	1	33	7	131.000	127.785	3.215 [0.257, 5.881]	2.45 [0.20, 4.49]	48.71	46.22	127.493		130.743	125.119	
62	1	20	4	69.400	66.435	2.965 [0.801, 5.622]	4.27 [1.15, 8.10]	25.49	24.72	68.599	67.888	63.778	64.743	67.169
63	1	49	7	108.500	104.105	4.395 [1.363, 8.206]	4.05 [1.26, 7.56]	49.53	45.40	109.863	101.215	100.294	105.047	
64	1	34	3	49.100	51.241	2.141 [1.747, 2.355]	4.36 [3.56, 4.80]	22.72	23.44	50.847	51.422	51.240	51.455	
65	1	45	5	76.600	77.727	1.127 [0.345, 3.985]	1.47 [0.45, 5.20]	33.15	33.81	76.255	78.847	80.585	78.086	74.861
66	2	50	4	70.300	70.802	0.502 [0.957, 3.631]	0.71 [1.36, 5.16]	27.12	27.55	72.612	73.931	69.343	67.321	
67	1	21	7	109.600	115.086	5.486 [2.578, 18.320]	5.01 [2.35, 16.72]	45.04	44.21	112.178	101.931	115.703	117.698	127.920
68	2	51	4	83.700	81.388	2.312 [0.546, 8.515]	2.76 [0.65, 10.17]	29.66	28.58	82.622	75.185	81.710	83.154	84.269

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
69	1	37	5	80.500	82.040	1.540 [0.171, 4.575]	1.91 [0.21, 5.68]	31.45	31.90	83.923	85.075	80.671	81.913	78.619
70	2	22	1_2	57.200	58.433	1.233 [0.637, 4.256]	2.16 [1.11, 7.44]	19.11	19.81	58.509	59.326	56.315	56.563	61.456
71	1	56	7	128.150	115.805	12.345 [3.793, 22.510]	9.63 [2.96, 17.57]	48.83	44.09	105.640	113.899	124.357	119.323	
72	1	52	1_2	53.700	56.925	3.225 [1.693, 4.022]	6.01 [3.15, 7.49]	19.25	20.61	57.070	56.957	57.483	57.722	55.393
73	2	55	5	90.900	85.581	5.319 [3.362, 7.925]	5.85 [3.70, 8.72]	31.45	29.42	87.538	85.849	82.975	86.308	85.232
74	2	34	1_2	58.700	60.803	2.103 [0.102, 3.687]	3.58 [0.17, 6.28]	19.61	20.57	61.890	58.802	60.374	62.387	60.563
75	2	55	4	74.900	79.450	4.550 [1.497, 11.117]	6.07 [2.00, 14.84]	26.54	29.06	76.397	86.017	82.231	82.256	70.346
76	2	47	4	91.600	95.182	3.582 [3.471, 16.086]	3.91 [3.79, 17.56]	28.59	29.12	102.132	103.229	99.966	95.071	75.514
77	1	54	7	164.300	127.546	36.754 [27.874, 43.972]	22.37 [16.97, 26.76]	64.99	48.15	129.198	136.426	124.231	120.328	
78	1	35	4	65.500	65.195	0.305 [0.532, 6.562]	0.47 [0.81, 10.02]	27.98	27.76	64.205	66.032	69.579	67.221	58.938
79	1	54	4	63.350	60.836	2.514 [0.569, 5.553]	3.97 [0.90, 8.77]	28.92	27.21	61.516	62.781	61.530	60.557	57.797
80	2	63	4	81.400	85.477	4.077 [2.021, 9.421]	5.01 [2.48, 11.57]	29.54	30.53	84.903	88.713	90.821	79.379	83.571
81	2	35	5	77.800	76.613	1.187 [0.510, 2.840]	1.53 [0.66, 3.65]	30.77	29.89	74.960	78.363	77.290	75.321	77.128
82	1	22	3	66.600	71.576	4.976 [0.730, 9.469]	7.47 [1.10, 14.22]	22.00	24.79	76.069		71.331		67.330
83	1	58	4	57.300	68.354	11.054 [6.996, 15.661]	19.29 [12.21, 27.33]	25.13	29.51		72.961	69.641	64.296	66.516
84	1	24	3	50.900	60.734	9.835 [4.668, 16.517]	19.32 [9.17, 32.45]	22.62	27.21		56.344	67.417	63.609	55.568
85	2	38	3	60.100	57.363	2.737 [3.518, 5.319]	4.55 [5.85, 8.85]	20.32	19.90		56.079	54.781	54.976	63.618
86	2	33	4	82.850	84.188	1.338 [3.623, 10.745]	1.61 [4.37, 12.97]	25.57	26.04		88.815	89.359	86.473	72.105
87	1	56	4	73.600	99.416	25.816 [21.189, 34.840]	35.08 [28.79, 47.34]	25.77	35.63		108.440	95.554	94.789	98.880
88	1	66	4	73.000	78.980	5.980 [0.367, 11.205]	8.19 [0.50, 15.35]	29.62	32.44		83.424	84.205	74.922	73.367
89	1	33	3	58.250	59.288	1.038 [0.018, 3.019]	1.78 [0.03, 5.18]	22.20	22.91		58.865	61.269	58.751	58.268
90	1	68	3	47.050	42.740	4.310 [0.710, 6.833]	9.16 [1.51, 14.52]	22.38	19.22		42.974	40.217	41.430	46.340
91	1	42	4	82.850	81.032	1.818 [2.401, 4.053]	2.19 [2.90, 4.89]	29.71	27.66		85.251	78.797	79.047	
92	2	75	4	66.400	72.500	6.100 [1.603, 12.744]	9.19 [2.41, 19.19]	25.94	28.43		71.860	70.992	68.003	79.144
93	2	58	4	85.800	81.159	4.641 [4.082, 16.192]	5.41 [4.76, 18.87]	28.34	26.97		81.340	81.718	69.608	91.971
94	2	42	4	90.350	89.754	0.596 [1.106, 2.592]	0.66 [1.22, 2.87]	28.52	27.35	89.244	91.572	87.796	87.758	92.399
95	1	54	4	72.400	66.207	6.193 [5.324, 8.011]	8.55 [7.35, 11.06]	29.00	26.64		67.076	66.358	64.389	67.006
96	1	34	4	74.250	73.659	0.591 [0.908, 6.411]	0.80 [1.22, 8.63]	29.37	28.30	69.798	73.342		70.835	80.661
97	2	35	4	96.800	91.655	5.145 [1.734, 13.018]	5.31 [1.79, 13.45]	29.55	28.01	90.065	89.841	99.522	95.066	83.782
98	1	65	4	60.000	56.594	3.406 [1.274, 4.997]	5.68 [2.12, 8.33]	27.39	26.00	55.003	57.470	58.726	55.928	55.843
99	1	51	4	67.300	70.678	3.378 [0.473, 9.721]	5.02 [0.70, 14.44]	25.02	26.46	69.423	66.827	70.848	69.272	77.021
100	2	42	5	80.600	77.593	3.007 [1.493, 5.646]	3.73 [1.85, 7.01]	34.89	33.84	82.093	77.862	74.954	75.462	
101	1	50	5	88.950	93.730	4.780 [7.223, 8.017]	5.37 [8.12, 9.01]	34.75	36.37	96.459	96.967	96.910	96.585	81.727
102	2	49	3	49.750	48.975	0.775 [1.558, 2.800]	1.56 [3.13, 5.63]	20.71	19.65		47.278	47.878	48.192	52.550

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
103	1	37	3	55.900	61.569	5.669[2.605, 10.339]	10.14 [4.66, 18.50]	23.57	25.98	58.505	61.719	62.052	66.239	59.332
104	1	51	4	68.100	66.572	1.528[0.885, 4.072]	2.24 [1.30, 5.98]	26.94	26.61	64.028	66.972	66.322	66.553	68.985
105	2	58	3	54.900	50.130	4.770[0.055, 6.807]	8.69 [0.10, 12.40]	21.99	19.38	48.093	49.514	48.887	49.203	54.955
106	2	31	4	80.300	81.044	0.744[1.915, 4.563]	0.93 [2.38, 5.68]	26.22	26.62		84.447	84.863	76.482	78.385
107	1	27	4	69.250	62.169	7.081[5.423, 9.576]	10.23 [7.83, 13.83]	25.75	23.38	62.396	59.674	62.860	62.086	63.827
108	1	43	4	63.300	60.169	3.131[1.043, 4.915]	4.95 [1.65, 7.76]	25.68	25.08	61.043	62.257	59.897	58.385	59.261
109	2	63	3	66.100	57.780	8.320[6.244, 9.318]	12.59 [9.45, 14.10]	21.83	19.25		57.307	57.176	59.856	56.782
110	1	43	1_2	48.050	56.640	8.590[5.885, 11.263]	17.88 [12.25, 23.44]	18.54	22.21	55.582	57.796	56.577	53.935	59.313
111	1	22	3	67.600	71.647	4.047[0.148, 8.612]	5.99 [0.22, 12.74]	23.12	24.76	68.587	72.665	76.212	67.748	73.023
112	2	63	3	66.650	74.921	8.271[2.366, 13.180]	12.41 [3.55, 19.78]	23.34	26.68	75.599	75.239	79.830		69.016
113	2	59	3	67.600	69.382	1.782[0.136, 5.076]	2.64 [0.20, 7.51]	24.83	24.66	69.382	67.736	67.736	72.676	
114	1	34	3	60.000	56.309	3.691[1.380, 7.635]	6.15 [2.30, 12.73]	23.44	21.78	52.365	57.309		56.941	58.620
115	1	62	3	54.200	66.784	12.584 [6.507, 17.813]	23.22 [12.00, 32.87]	22.85	28.16	66.515	72.013	69.206	65.479	60.707
116	1	62	7	109.300	100.311	8.989[6.863, 11.721]	8.22 [6.28, 10.72]	40.64	38.64			102.437	97.579	100.916
117	2	42	4	90.650	98.506	7.856[2.234, 12.728]	8.67 [2.46, 14.04]	27.67	29.85	92.884	102.248	103.378	95.514	
118	1	26	3	71.000	75.642	4.642[1.857, 9.794]	6.54 [2.62, 13.79]	24.28	25.45	75.861	76.379	76.034	80.794	69.143
119	2	51	5	91.100	88.223	2.877[1.479, 4.193]	3.16 [1.62, 4.60]	33.46	32.85	89.621	87.123	88.181	89.283	86.907
120	2	57	5	91.100	88.524	2.576[0.877, 9.115]	2.83 [0.96, 10.01]	31.90	30.51	90.223	87.293	81.985	83.214	99.906
121	2	47	4	76.200	80.227	4.027[3.586, 9.017]	5.28 [4.71, 11.83]	27.65	28.51	82.849		72.614		85.217
122	1	51	4	65.600	59.359	6.241[0.936, 10.503]	9.51 [1.43, 16.01]	27.66	25.27	55.097	57.338	58.464		66.536
123	2	59	3	65.600	67.799	2.199[3.179, 4.227]	3.35 [4.85, 6.44]	24.10	24.61	69.189		69.827	69.759	62.421
124	2	35	5	97.650	88.630	9.020[4.556, 16.258]	9.24 [4.67, 16.65]	31.89	28.80	89.487	87.442	93.094	91.735	81.392
125	2	53	4	73.500	71.069	2.431[0.141, 4.223]	3.31 [0.19, 5.75]	28.01	26.73	73.359	71.657	69.977	71.076	69.277
126	1	47	4	71.800	69.671	2.129[1.465, 4.931]	2.97 [2.04, 6.87]	29.50	28.72	66.869	70.219	70.335	66.994	73.939
127	2	25	3	70.100	70.037	0.063[2.660, 6.440]	0.09 [3.79, 9.19]	22.63	22.27	67.440	73.772	76.540	65.438	66.994
128	1	46	6	87.200	90.884	3.684[0.920, 7.961]	4.23 [1.06, 9.13]	37.25	37.83	88.120		95.161	88.262	91.993
129	1	39	4	76.200	73.081	3.119[0.488, 6.563]	4.09 [0.64, 8.61]	28.68	27.78	69.637	73.409	75.712		73.568
130	1	67	7	102.850	99.703	3.147[0.078, 5.639]	3.06 [0.08, 5.48]	41.73	40.20	102.772		99.782	99.048	97.211
131	2	30	3	68.400	62.968	5.432[0.345, 11.861]	7.94 [0.50, 17.34]	23.39	22.12	68.055	57.964	64.799	67.482	56.539
132	2	34	5	103.400	102.775	0.625[0.618, 3.759]	0.60 [0.60, 3.64]	34.15	34.19	104.018		105.679	99.641	101.763
133	2	43	4	85.300	82.814	2.486[0.137, 3.472]	2.91 [0.16, 4.07]	28.17	27.26	85.163	82.423	81.828	81.843	
134	2	66	1_2	44.500	49.288	4.788[3.146, 6.525]	10.76 [7.07, 14.66]	16.96	18.96	49.634	48.916	47.646	49.220	51.025
135	1	42	3	53.150	54.162	1.012[0.808, 2.557]	1.90 [1.52, 4.81]	21.29	21.47	54.468	55.707	54.130	52.342	
136	1	59	3	58.700	54.729	3.971[3.132, 6.428]	6.76 [5.34, 10.95]	22.93	21.02	54.335	52.452	52.272	52.754	61.832

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
137	1	47	7	124.000	125.217	1.217 [0.126, 2.869]	0.98 [0.10, 2.31]	41.43	40.21		123.874	124.909		126.869
138	1	49	7	97.500	87.092	10.408 [7.922, 14.641]	10.68 [8.13, 15.02]	42.76	36.99	82.859	87.434	86.553	89.578	89.033
139	1	65	3	63.150	66.769	3.619 [1.129, 5.990]	5.73 [1.79, 9.49]	23.77	25.00		68.107	69.140	67.807	62.021
140	1	33	5	74.050	79.461	5.411 [0.087, 7.219]	7.31 [0.12, 9.75]	32.05	33.31	80.875	80.682	81.269	80.343	74.137
141	1	33	4	80.200	76.002	4.198 [1.285, 9.147]	5.23 [1.60, 11.41]	29.10	27.56	76.854	71.053	78.482	78.915	74.707
142	2	27	4	91.400	94.478	3.078 [0.818, 4.983]	3.37 [0.89, 5.45]	28.53	29.16	93.037	92.218	96.273	96.383	
143	2	34	5	91.600	91.136	0.464 [1.681, 7.637]	0.51 [1.84, 8.34]	30.25	29.59	88.622	93.281	89.507	85.034	99.237
144	2	39	1_2	49.150	52.142	2.992 [1.483, 8.116]	6.09 [3.02, 16.51]	17.01	18.95	50.966	50.979	50.633	50.866	57.266
145	2	28	3	60.400	55.695	4.705 [1.543, 6.847]	7.79 [2.56, 11.34]	23.01	21.10	54.655	53.553	54.397	57.016	58.857
146	2	21	3	64.800	71.229	6.429 [3.962, 8.930]	9.92 [6.11, 13.78]	20.45	22.73	70.853	69.594	68.762	73.730	73.204
147	2	69	3	72.950	70.154	2.796 [0.088, 6.667]	3.83 [0.12, 9.14]	24.09	23.26	71.092	73.038	73.378	66.978	66.283
148	2	51	5	99.600	101.024	1.424 [1.209, 5.911]	1.43 [1.21, 5.93]	32.90	33.07	100.809	95.945	101.830	105.511	
149	2	23	4	95.100	90.599	4.501 [1.210, 8.642]	4.73 [1.27, 9.09]	29.35	27.51	93.890	90.122	91.069	91.458	86.458
150	2	20	3	53.000	51.121	1.879 [0.204, 3.583]	3.54 [0.38, 6.76]	21.23	20.25	50.512	49.417	50.863	51.612	53.204
151	1	59	5	82.000	90.554	8.554 [5.082, 10.516]	10.43 [6.20, 12.82]	34.58	36.99	90.431	92.516	91.721	91.018	87.082
152	2	50	3	62.200	62.046	0.154 [1.018, 8.104]	0.25 [1.64, 13.03]	24.60	24.60	66.769	67.061	63.218	59.084	54.096
153	1	61	3	47.400	49.766	2.366 [1.156, 11.777]	4.99 [2.44, 24.85]	22.86	23.76	46.121	48.556	45.193	49.783	59.177
154	2	41	6	104.000	102.054	1.946 [0.974, 2.663]	1.87 [0.94, 2.56]	36.41	36.60	101.447	101.683	102.778	101.337	103.026
155	2	52	4	79.500	72.808	6.692 [4.712, 9.876]	8.42 [5.93, 12.42]	28.85	26.35		69.624	74.011	74.788	
156	1	40	4	55.700	61.001	5.301 [1.567, 13.187]	9.52 [2.81, 23.68]	25.09	27.88	57.267	57.893	57.269	63.689	68.887
157	1	49	6	96.250	88.844	7.406 [4.898, 12.276]	7.69 [5.09, 12.75]	37.13	34.22	90.280	89.016	91.352	83.974	89.596
158	2	29	5	108.300	107.827	0.473 [0.183, 10.573]	0.44 [0.17, 9.76]	34.96	35.78	117.998	109.270	108.117	97.727	106.023
159	1	23	4	79.700	77.482	2.218 [0.468, 3.970]	2.78 [0.59, 4.98]	25.73	24.56		77.581	77.387	79.232	75.730
160	1	59	3	58.000	56.106	1.894 [0.440, 5.508]	3.26 [0.76, 9.50]	21.05	20.48	56.548	57.560	59.111	54.822	52.492
161	1	62	1_2	35.400	45.849	10.449 [8.800, 13.131]	29.52 [24.86, 37.09]	15.53	19.02	46.293	44.372		44.200	48.531
162	2	18	1_2	56.000	56.505	0.505 [0.053, 1.849]	0.90 [0.09, 3.30]	18.29	19.82	55.947	54.188	57.128	57.849	57.413
163	2	66	4	82.200	80.669	1.531 [2.910, 10.775]	1.86 [3.54, 13.11]	28.78	27.98	71.425	86.373	85.957	74.481	85.110
164	2	21	1_2	52.700	51.412	1.288 [0.300, 2.034]	2.44 [0.57, 3.86]	18.90	18.56	50.666	51.017	51.564	52.400	
165	1	34	5	96.800	92.172	4.628 [2.375, 6.931]	4.78 [2.45, 7.16]	33.49	32.70	90.814	89.869	94.425	93.578	
166	1	65	1_2	46.950	49.239	2.289 [0.466, 6.463]	4.88 [0.99, 13.76]	19.54	19.44	47.416	49.125	48.109	48.131	53.413
167	1	23	5	86.200	78.585	7.615 [0.797, 16.132]	8.83 [0.92, 18.71]	33.25	30.05	72.877	70.068	80.253	82.730	86.997
168	2	65	4	75.750	85.330	9.580 [7.976, 13.264]	12.65 [10.53, 17.51]	28.51	32.26	84.799		89.014	83.726	83.783
169	2	23	1_2	52.050	52.061	0.011 [0.885, 3.178]	0.02 [1.70, 6.11]	18.66	18.73		49.790	51.165	55.228	
170	2	60	3	61.800	62.074	0.274 [0.917, 6.273]	0.44 [1.48, 10.15]	22.16	22.64	62.717	64.649		65.402	55.527

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
171	2	53	4	73.800	77.720	3.920 [2.068, 4.973]	5.31 [2.80, 6.74]	27.11	28.40	77.574	78.099	78.284	75.868	78.773
172	2	66	4	79.700	82.769	3.069 [0.896, 4.951]	3.85 [1.12, 6.21]	28.58	32.54	82.746	80.596	84.651	83.633	82.222
173	2	48	4	90.400	84.138	6.262 [3.067, 7.943]	6.93 [3.39, 8.79]	27.59	25.82	82.460	83.469	87.333	84.970	82.457
174	1	35	3	53.550	53.244	0.306 [1.093, 1.702]	0.57 [2.04, 3.18]	21.45	21.84			52.457	52.023	55.252
175	1	44	3	61.900	69.116	7.216 [2.527, 12.894]	11.66 [4.08, 20.83]	24.18	27.10		64.427	68.128		74.794
176	1	56	1_2	34.800	45.215	10.415 [8.421, 11.715]	29.93 [24.20, 33.66]	15.89	19.34	45.288	45.471	45.581	46.515	43.221
177	1	19	3	52.050	50.083	1.967 [1.908, 4.035]	3.78 [3.67, 7.55]	22.24	20.51	48.897	50.142	48.830	48.015	54.533
178	2	71	7	126.800	103.625	23.175 [15.716, 30.298]	18.28 [12.39, 23.89]	43.36	37.30		96.502	103.226	103.687	111.084
179	2	50	4	92.600	94.248	1.648 [1.916, 7.256]	1.78 [2.07, 7.84]	29.89	30.23		99.856	99.181	87.271	90.684
180	2	49	3	65.700	65.609	0.091 [0.569, 2.758]	0.14 [0.87, 4.20]	22.47	22.65	66.269	68.458	64.684	63.024	
181	1	48	5	75.000	69.288	5.712 [9.681, 13.700]	7.62 [12.91, 18.27]	32.46	30.19	63.003		61.300	65.319	87.530
182	1	35	1_2	47.900	49.281	1.381 [0.348, 4.515]	2.88 [0.73, 9.42]	18.71	19.22		49.212	47.248	48.248	52.415
183	2	21	3	76.100	78.565	2.465 [0.944, 3.756]	3.24 [1.24, 4.94]	23.23	23.22	77.044	79.856	79.425	77.936	
184	2	57	1_2	43.950	54.681	10.731 [10.176, 11.053]	24.42 [23.15, 25.15]	15.57	19.39		54.879	54.717	55.003	54.126
185	2	65	3	54.250	61.693	7.443 [1.063, 13.403]	13.72 [1.96, 24.71]	20.17	23.37	62.109	64.173	67.653	59.218	55.313
186	2	33	4	73.750	65.117	8.633 [7.319, 11.294]	11.71 [9.92, 15.31]	25.22	22.79	65.834	66.431	62.456	66.187	64.675
187	1	41	4	83.700	85.061	1.361 [0.270, 3.731]	1.63 [0.32, 4.46]	28.62	28.99	83.970	81.487	87.357	87.431	
188	2	51	3	52.450	54.987	2.537 [0.563, 4.418]	4.84 [1.07, 8.42]	21.83	22.64	56.868	54.335	56.416	54.301	53.013
189	2	42	3	74.250	72.981	1.269 [0.488, 2.196]	1.71 [0.66, 2.96]	24.24	24.75		74.738	72.054	72.149	
190	1	33	4	69.300	74.878	5.578 [4.350, 7.463]	8.05 [6.28, 10.77]	29.60	32.07	74.686	76.763	74.414		73.650
191	2	52	5	86.400	85.462	0.938 [0.978, 12.543]	1.09 [1.13, 14.52]	31.35	31.02	90.157	92.413	85.422	73.857	
192	1	62	3	51.700	50.632	1.068 [0.173, 2.323]	2.07 [0.33, 4.49]	22.38	21.75		51.002	50.624	49.377	51.527
193	2	74	7	126.400	129.305	2.905 [1.767, 5.923]	2.30 [1.40, 4.69]	45.32	45.61	131.277	129.406	132.323	128.884	124.633
194	2	33	5	100.900	92.896	8.004 [5.933, 10.068]	7.93 [5.88, 9.98]	30.46	28.03		94.967	91.645	94.139	90.832
195	2	48	4	78.400	75.702	2.698 [0.412, 4.451]	3.44 [0.53, 5.68]	28.11	27.19	74.995	73.949	75.051	78.812	
196	2	48	4	104.300	98.833	5.467 [3.370, 10.025]	5.24 [3.23, 9.61]	29.83	28.82	94.275	100.369	100.930	99.757	
197	2	56	3	68.550	66.611	1.939 [1.078, 8.881]	2.83 [1.57, 12.96]	24.00	23.21	70.535	69.628			59.669
198	1	55	4	71.150	63.533	7.617 [5.053, 10.716]	10.71 [7.10, 15.06]	28.87	26.18	66.097	64.122	63.480	60.434	
199	1	54	6	82.950	83.558	0.608 [0.837, 2.448]	0.73 [1.01, 2.95]	35.90	36.48	81.731	84.684	83.864	85.398	82.113
200	2	58	4	75.760	72.933	2.827 [0.101, 6.770]	3.73 [0.13, 8.94]	27.83	26.33	74.296	70.734	68.990	74.785	75.861
201	1	60	4	65.900	70.446	4.546 [0.141, 7.928]	6.90 [0.21, 12.03]	28.90	30.70	72.709	73.828	72.294	66.041	67.356
202	2	59	3	70.400	70.055	0.345 [0.391, 7.334]	0.49 [0.56, 10.42]	24.36	23.98		67.743	70.009	77.734	64.734
203	2	65	5	90.000	79.569	10.431 [9.290, 11.449]	11.59 [10.32, 12.72]	34.72	31.54	80.710	79.539	78.551	79.474	
204	1	57	4	61.150	55.417	5.733 [2.163, 8.927]	9.37 [3.54, 14.60]	25.13	22.95	52.223	52.952	53.387	55.211	63.313

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
205	2	33	7	132.300	127.427	4.873 [1.404, 10.226]	3.68 [1.06, 7.73]	40.83	39.07	128.291	128.445		130.896	122.074
206	2	68	4	87.500	92.281	4.781 [2.756, 9.248]	5.46 [3.15, 10.57]	27.31	28.50	90.427	93.363	96.748	90.613	90.256
207	1	42	7	106.300	100.759	5.541 [6.117, 9.912]	5.21 [5.75, 9.32]	42.58	40.16	98.762	96.976	96.388	99.252	112.417
208	1	50	4	50.600	48.971	1.629 [1.271, 5.119]	3.22 [2.51, 10.12]	25.09	24.84	47.733	49.329	45.481	47.550	54.761
209	1	35	3	56.700	54.134	2.566 [1.245, 3.946]	4.53 [2.20, 6.96]	23.30	21.87	55.205	52.754	55.455	53.679	53.577
210	1	56	5	91.800	91.056	0.744 [0.704, 6.930]	0.81 [0.77, 7.55]	33.72	32.91	91.006	96.363	90.537	92.504	84.870
211	1	49	7	108.500	84.880	23.620 [22.666, 24.537]	21.77 [20.89, 22.62]	42.92	33.48	85.834	83.963	85.456	84.268	
212	1	58	4	72.100	105.176	33.076 [30.318, 35.647]	45.88 [42.05, 49.44]	28.16	41.54	107.747	102.418	106.863	103.676	
213	1	39	3	60.600	62.290	1.690 [0.122, 6.447]	2.79 [0.20, 10.64]	23.97	24.74	61.968	67.047	60.478	60.069	61.889
214	2	35	5	85.600	80.147	5.453 [4.141, 6.320]	6.37 [4.84, 7.38]	30.33	28.67	79.280	81.320	79.327	79.349	81.459
215	2	60	3	67.600	64.741	2.859 [1.008, 3.608]	4.23 [1.49, 5.34]	24.24	23.73	63.992	64.100	66.592	64.225	64.796
216	1	35	4	77.050	88.580	11.530 [3.318, 18.296]	14.96 [4.31, 23.75]	25.74	28.76	80.368	88.228	95.346	85.852	93.107
217	2	56	3	75.200	72.899	2.301 [1.416, 5.852]	3.06 [1.88, 7.78]	24.56	23.72	71.386	76.616	77.310	69.834	69.348
218	1	40	6	106.660	102.086	4.574 [1.555, 12.072]	4.29 [1.46, 11.32]	38.24	37.09	95.116	108.215	100.980	94.588	111.530
219	2	25	3	70.950	70.211	0.739 [0.653, 5.863]	1.04 [0.92, 8.26]	22.65	21.92	70.297	72.632	70.251	65.087	72.789
220	2	19	3	54.300	53.346	0.954 [0.141, 1.313]	1.76 [0.26, 2.42]	20.19	19.84	53.454	53.116	53.016	54.159	52.987
221	2	35	3	63.250	60.086	3.164 [1.833, 4.935]	5.00 [2.90, 7.80]	21.38	21.06	59.552	58.315	61.061	61.417	
222	2	69	3	61.900	61.490	0.410 [0.148, 4.819]	0.66 [0.24, 7.79]	23.59	23.85	57.081	61.752	62.213	61.343	65.059
223	1	62	5	79.900	73.422	6.478 [0.390, 10.700]	8.11 [0.49, 13.39]	33.26	30.54	69.200	70.687	79.510	74.289	
224	2	54	3	59.300	56.361	2.939 [0.968, 10.002]	4.96 [1.63, 16.87]	24.68	23.93	61.210	58.332	56.602	49.298	
225	2	24	1_2	51.100	58.122	7.022 [5.049, 8.738]	13.74 [9.88, 17.10]	18.11	20.80	56.149	59.838	58.436	57.699	58.489
226	2	71	4	67.050	55.937	11.113 [6.912, 15.877]	16.57 [10.31, 23.68]	28.27	23.88	51.173	55.900	60.138	55.063	57.412
227	2	61	4	70.200	69.296	0.904 [3.155, 10.789]	1.29 [4.49, 15.37]	25.48	25.44	66.366	66.782	65.297	67.045	80.989
228	2	39	4	67.250	61.364	5.886 [1.507, 12.535]	8.75 [2.24, 18.64]	25.31	23.53	62.334	65.743	62.662	54.715	
229	2	53	3	63.850	64.209	0.359 [1.405, 3.837]	0.56 [2.20, 6.01]	20.85	21.71	65.255	67.592	67.178	61.007	60.013
230	2	51	3	63.950	58.676	5.274 [1.218, 9.250]	8.25 [1.91, 14.46]	24.98	23.39	54.700		62.732	58.596	
231	2	31	4	79.550	78.122	1.428 [1.993, 7.294]	1.80 [2.51, 9.17]	27.85	27.23	77.557	75.603	82.198	72.256	82.996
232	1	56	4	81.450	85.623	4.173 [3.171, 12.858]	5.12 [3.89, 15.79]	29.21	31.26	76.823	84.621	94.308	78.171	94.193
233	1	27	1_2	32.300	42.960	10.660 [9.741, 11.228]	33.00 [30.16, 34.76]	14.95	18.68	43.116	42.582	43.363	42.780	
234	2	39	4	87.950	99.127	11.177 [5.579, 17.013]	12.71 [6.34, 19.34]	25.42	28.54	98.862	104.963	99.153	93.529	
235	1	68	4	60.250	60.172	0.078 [0.136, 0.910]	0.13 [0.23, 1.51]	27.14	26.55	61.160	59.670	59.473	60.386	
236	1	35	3	47.100	44.622	2.478 [1.380, 4.489]	5.26 [2.93, 9.53]	20.93	18.54	44.913	45.720	44.865	45.002	42.611
237	2	47	5	106.600	100.073	6.527 [5.090, 8.302]	6.12 [4.78, 7.79]	34.81	31.83	99.536	101.510	100.948	98.298	
238	2	38	1_2	52.100	57.885	5.785 [2.824, 7.149]	11.10 [5.42, 13.72]	17.41	19.83	57.838	58.960	59.249	58.453	54.924

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
239	1	36	1_2	47.700	50.074	2.374 [1.169, 3.482]	4.98 [2.45, 7.30]	19.85	20.30	50.749	49.497	48.869	51.182	
240	2	49	1_2	48.700	56.955	8.255 [4.768, 12.080]	16.95 [9.79, 24.81]	18.33	22.00	53.952	53.468	59.620	60.780	
241	1	37	7	100.350	90.263	10.087 [9.405, 10.937]	10.05 [9.37, 10.90]	41.77	36.91	89.413	90.602	90.092	90.945	
242	1	40	6	89.850	96.521	6.671 [5.891, 7.250]	7.42 [6.56, 8.07]	35.54	37.33	97.100		95.741	96.721	
243	1	35	6	87.850	92.447	4.597 [3.381, 5.954]	5.23 [3.85, 6.78]	36.10	36.65	93.804	91.940	91.231	92.813	
244	1	57	5	88.950	99.864	10.914 [7.662, 13.329]	12.27 [8.61, 14.99]	34.32	37.73	102.279	98.878	96.612	101.688	
245	2	72	1_2	53.250	63.512	10.262 [8.009, 11.347]	19.27 [15.04, 21.31]	19.56	24.04	61.259	64.597	64.043	64.151	
246	2	61	3	59.600	71.231	11.631 [10.133, 13.564]	19.51 [17.00, 22.76]	20.87	24.90	70.830	69.733	71.196	73.164	
247	2	69	3	73.050	92.598	19.548 [13.852, 22.380]	26.76 [18.96, 30.64]	24.69	31.42	95.430	94.457	93.604	86.902	
248	2	47	1_2	60.400	63.666	3.266 [1.089, 4.358]	5.41 [1.80, 7.21]	19.50	20.52	64.758		64.209	64.209	61.489
249	2	35	3	66.950	67.007	0.057 [1.980, 6.518]	0.08 [2.96, 9.74]	22.11	22.47	60.432	72.487	64.518	64.970	72.627
250	1	38	6	102.050	96.762	5.288 [4.053, 6.064]	5.18 [3.97, 5.94]	36.59	36.45	95.986	96.302	97.997		
251	1	72	4	69.250	68.940	0.310 [6.293, 9.829]	0.45 [9.09, 14.19]	27.74	27.38	59.421	62.957	77.783	75.599	
252	1	40	4	72.200	76.400	4.200 [1.345, 6.660]	5.82 [1.86, 11.99]	27.85	28.52	80.860	74.670	73.545	73.801	79.121
253	1	35	7	106.700	97.565	9.135 [5.720, 11.174]	8.56 [5.36, 10.47]	44.41	41.18	95.748	95.526	98.004	100.980	
254	1	23	5	77.500	83.572	6.072 [2.798, 8.643]	7.83 [3.61, 11.15]	31.04	33.95	80.298	82.876	84.968	86.143	
255	2	63	1_2	46.600	49.441	2.841 [2.665, 3.047]	6.10 [5.72, 6.54]	18.67	19.66	49.265	49.647	49.411		
256	1	49	4	74.550	85.642	11.092 [1.275, 18.247]	14.88 [1.71, 24.48]	27.05	30.99	75.825	92.797	84.101	89.844	
257	1	58	1_2	44.650	51.393	6.743 [6.522, 7.233]	15.10 [14.61, 16.20]	18.58	20.03	51.321	51.194	51.172	51.883	
258	1	68	1_2	45.000	50.069	5.069 [4.365, 6.292]	11.27 [9.70, 13.98]	18.73	20.05	49.766	51.292	49.854	49.365	
259	1	52	4	68.600	70.112	1.512 [0.075, 6.088]	2.20 [0.11, 8.87]	25.20	25.47	68.675	66.972		74.688	
260	1	58	6	93.650	101.012	7.362 [5.684, 9.923]	7.86 [6.07, 10.60]	36.13	38.92	99.809	103.573	101.334	99.334	
261	1	51	4	87.250	101.949	14.699 [12.060, 17.241]	16.85 [13.82, 19.76]	29.15	34.61	104.491	100.900	99.310	103.094	
262	2	49	5	102.250	101.745	0.505 [0.372, 1.389]	0.49 [0.36, 1.36]	34.56	35.82	101.753		102.622	100.861	
263	1	58	6	84.700	83.661	1.039 [0.145, 4.640]	1.23 [0.17, 5.48]	35.25	34.82	87.528	80.789	84.845	85.083	80.060
264	1	35	7	127.000	132.560	5.560 [1.343, 9.201]	4.38 [1.06, 7.25]	47.22	47.75	135.184	136.201	128.343	130.513	
265	1	30	6	102.250	94.595	7.655 [6.452, 9.984]	7.49 [6.31, 9.76]	35.38	33.62	95.798	92.266	94.926	95.389	
266	2	31	4	81.800	89.130	7.330 [5.828, 9.850]	8.96 [7.12, 12.04]	26.11	28.21	89.239	87.628	91.650	88.004	
267	1	59	3	54.700	58.093	3.393 [2.873, 6.635]	6.20 [5.25, 12.13]	24.31	24.24	51.827	61.335	57.886	61.324	
268	1	33	5	78.600	76.275	2.325 [2.134, 7.032]	2.96 [2.71, 8.95]	34.02	33.54	76.466	72.259	71.568	76.185	84.896
269	1	24	3	53.200	52.146	1.054 [0.292, 2.353]	1.98 [0.55, 4.42]	20.27	20.07	51.401	53.492	52.844	50.847	
270	1	51	4	87.800	99.902	12.102 [10.032, 14.311]	13.78 [11.43, 16.30]	29.34	33.84	102.111	101.280	98.385	97.832	
271	2	40	3	58.800	60.794	1.994 [0.359, 7.088]	3.39 [0.61, 12.05]	21.08	21.83	61.004	65.888	57.842	58.441	
272	1	43	7	98.650	99.387	0.737 [0.820, 2.987]	0.75 [0.83, 3.03]	41.06	42.60	101.637	100.439	97.641	97.830	

ID	Sexo	Idade	Faixa IMC	Peso aferido	Peso predito	Erro absoluto	Erro em %	IMC real	IMC predito	Peso predito por posição				
										1	2	3	4	5
273	1	30	7	129.100	130.345	1.245 [2.091, 10.239]	0.96 [1.62, 7.93]	45.20	42.67	133.899	118.861	131.191	137.429	
274	2	26	3	62.600	65.323	2.723 [0.554, 5.846]	4.35 [0.88, 9.34]	22.45	23.74	64.516	66.702	68.446	63.154	63.799
275	2	29	3	72.200	65.440	6.760 [2.007, 9.834]	9.36 [2.78, 13.62]	22.04	20.58		70.193	62.366	63.761	
276	2	47	3	70.800	63.416	7.384 [5.506, 9.445]	10.43 [7.78, 13.34]	24.79	21.70	63.600	65.294		61.355	
277	2	49	1_2	53.500	55.149	1.649 [0.865, 2.440]	3.08 [1.62, 4.56]	18.73	20.49	55.606	55.940	54.365	54.687	
278	1	51	4	62.900	64.846	1.946 [0.212, 3.376]	3.09 [0.34, 5.37]	27.22	27.51	65.374	64.622	66.276	63.112	
279	1	47	3	48.650	48.330	0.320 [0.277, 1.394]	0.66 [0.57, 2.87]	21.91	20.85	48.927	48.184	47.256	48.952	
280	2	23	4	87.750	84.427	3.323 [3.153, 8.604]	3.79 [3.59, 9.81]	28.01	26.49	79.321	81.143	84.597	80.722	96.354
281	2	67	3	69.100	78.383	9.283 [5.918, 14.136]	13.43 [8.56, 20.46]	22.06	25.22	76.895	75.018		83.236	
282	1	50	3	54.900	57.783	2.883 [1.188, 4.539]	5.25 [2.16, 8.27]	21.72	23.43	57.407	56.088	58.200	59.439	
283	2	40	1_2	54.200	56.679	2.479 [0.089, 9.454]	4.57 [0.16, 17.44]	19.20	20.21	54.111	63.654	55.360	53.592	
284	1	52	4	72.800	77.298	4.498 [2.069, 6.379]	6.18 [2.84, 8.76]	28.80	29.73	78.134	77.008	79.179	74.869	
285	1	57	5	78.300	82.293	3.993 [1.021, 7.745]	5.10 [1.30, 9.89]	33.89	35.17	82.968	79.321	86.045	80.837	
286	2	53	3	54.050	50.541	3.509 [0.625, 6.480]	6.49 [1.16, 11.99]	23.39	21.90	53.425	51.943	47.570	48.740	51.027
287	2	49	4	77.800	72.160	5.640 [2.940, 6.878]	7.25 [3.78, 8.84]	25.70	24.15	70.922	71.281	74.860	71.577	
288	2	49	6	122.840	125.833	2.993 [3.848, 13.253]	2.44 [3.13, 10.79]	36.28	34.86	128.678	133.193	126.688	131.021	109.587
289	1	40	5	98.500	100.880	2.380 [1.481, 2.864]	2.42 [1.50, 2.91]	33.69	34.85	101.027	101.364	99.981	101.148	
290	2	37	5	95.750	94.228	1.522 [0.000, 4.049]	1.59 [0.00, 4.23]	30.56	30.18	91.701	93.469	94.397	95.750	95.824
291	1	47	4	70.000	69.639	0.361 [0.522, 2.427]	0.52 [0.75, 3.47]	28.40	28.84	72.193	69.314	67.573	69.478	
292	1	42	5	80.500	92.056	11.556 [8.933, 14.249]	14.35 [11.10, 17.70]	33.51	38.08	93.655	94.749	89.845	92.596	89.433
293	1	51	6	89.700	87.019	2.681 [2.806, 5.229]	2.99 [3.13, 5.83]	37.34	36.06	86.414	84.471	84.471	86.894	92.845
294	1	27	4	80.400	80.748	0.348 [0.201, 3.089]	0.43 [0.25, 3.84]	29.53	30.00	80.601	80.182	83.489	78.720	
295	2	49	4	70.900	71.768	0.868 [1.358, 8.634]	1.22 [1.92, 12.18]	28.04	28.27	72.258	73.167	74.500	76.648	62.266
296	1	18	5	102.550	93.320	9.230 [4.395, 15.328]	9.00 [4.29, 14.95]	33.49	30.92	98.155	96.629	91.472	93.124	87.222
297	2	62	3	67.600	64.207	3.393 [1.676, 5.566]	5.02 [2.48, 8.23]	22.59	21.93	65.924	63.749	65.119	62.034	
298	1	46	1_2	44.900	51.832	6.932 [5.468, 8.574]	15.44 [12.18, 19.10]	18.69	21.08	50.368	51.758	51.730	53.474	
299	2	34	7	172.350	126.282	46.068 [45.859, 46.376]	26.73 [26.61, 26.91]	53.79	47.00	126.491		126.382	125.974	
300	2	49	4	81.850	88.335	6.485 [5.006, 7.986]	7.92 [6.12, 9.76]	27.35	28.80	88.557	86.856	88.091	89.836	

ANEXO I - Checklist TRIPOD+AI (2024) preenchido



Version: 11-January-2024

Section/Topic	Item	Development / evaluation ¹	Checklist item	Reported on page
TITLE				
<i>Title</i>	1	D,E	Identify the study as developing or evaluating the performance of a multivariable prediction model, the target population, and the outcome to be predicted	1–2
ABSTRACT				
<i>Abstract</i>	2	D,E	See TRIPOD+AI for Abstracts checklist	9–10
INTRODUCTION				
<i>Background</i>	3a	D,E	Explain the healthcare context (including whether diagnostic or prognostic) and rationale for developing or evaluating the prediction model, including references to existing models	16–30
	3b	D,E	Describe the target population and the intended purpose of the prediction model in the context of the care pathway, including its intended users (e.g., healthcare professionals, patients, public)	16–19
	3c	D,E	Describe any known health inequalities between sociodemographic groups	16–30
<i>Objectives</i>	4	D,E	Specify the study objectives, including whether the study describes the development or validation of a prediction model (or both)	19–30
METHODS				
<i>Data</i>	5a	D,E	Describe the sources of data separately for the development and evaluation datasets (e.g., randomised trial, cohort, routine care or registry data), the rationale for using these data, and representativeness of the data	30–35
	5b	D,E	Specify the dates of the collected participant data, including start and end of participant accrual; and, if applicable, end of follow-up	31–32
<i>Participants</i>	6a	D,E	Specify key elements of the study setting (e.g., primary care, secondary care, general population) including the number and location of centres	31–33
	6b	D,E	Describe the eligibility criteria for study participants	32–33
	6c	D,E	Give details of any treatments received, and how they were handled during model development or evaluation, if relevant	NA
<i>Data preparation</i>	7	D,E	Describe any data pre-processing and quality checking, including whether this was similar across relevant sociodemographic groups	33–35
<i>Outcome</i>	8a	D,E	Clearly define the outcome that is being predicted and the time horizon, including how and when assessed, the rationale for choosing this outcome, and whether the method of outcome assessment is consistent across sociodemographic groups	35–43
	8b	D,E	If outcome assessment requires subjective interpretation, describe the qualifications and demographic characteristics of the outcome assessors	NA
	8c	D,E	Report any actions to blind assessment of the outcome to be predicted	NA
<i>Predictors</i>	9a	D	Describe the choice of initial predictors (e.g., literature, previous models, all available predictors) and any pre-selection of predictors before model building	35–43
	9b	D,E	Clearly define all predictors, including how and when they were measured (and any actions to blind assessment of predictors for the outcome and other predictors)	35–43
	9c	D,E	If predictor measurement requires subjective interpretation, describe the qualifications and demographic characteristics of the predictor assessors	NA
<i>Sample size</i>	10	D,E	Explain how the study size was arrived at (separately for development and evaluation), and justify that the study size was sufficient to answer the research question. Include details of any sample size calculation	47
<i>Missing data</i>	11	D,E	Describe how missing data were handled. Provide reasons for omitting any data	35–43
<i>Analytical methods</i>	12a	D	Describe how the data were used (e.g., for development and evaluation of model performance) in the analysis, including whether the data were partitioned, considering any sample size requirements	35–43
	12b	D	Depending on the type of model, describe how predictors were handled in the analyses (functional form, rescaling, transformation, or any standardisation)	35–43
	12c	D	Specify the type of model, rationale ² , all model-building steps, including any hyperparameter tuning, and method for internal validation	51–63
	12d	D,E	Describe if and how any heterogeneity in estimates of model parameter values and model performance was handled and quantified across clusters (e.g., hospitals, countries). See TRIPOD-Cluster for additional considerations ³	51–63
	12e	D,E	Specify all measures and plots used (and their rationale) to evaluate model performance (e.g., discrimination, calibration, clinical utility) and, if relevant, to compare multiple models	36–43; 35–52
	12f	E	Describe any model updating (e.g., recalibration) arising from the model evaluation, either overall or for particular sociodemographic groups or settings	38–42
	12g	E	For model evaluation, describe how the model predictions were calculated (e.g., formula, code, object, application programming interface)	35–43
<i>Class imbalance</i>	13	D,E	If class imbalance methods were used, state why and how this was done, and any subsequent methods to recalibrate the model or the model predictions	NA
<i>Fairness</i>	14	D,E	Describe any approaches that were used to address model fairness and their rationale	50–67
<i>Model output</i>	15	D	Specify the output of the prediction model (e.g., probabilities, classification). Provide details and rationale for any classification and how the thresholds were identified	50–67

¹ D=items relevant only to the development of a prediction model, E=items relating solely to the evaluation of a prediction model, D,E=items applicable to both the development and evaluation of a prediction model

² Separately for all model building approaches.

³ TRIPOD-Cluster is a checklist of reporting recommendations for studies developing or validating models that explicitly account for clustering or explore heterogeneity in model performance (eg, at different hospitals or centres). Debray et al, *BMJ* 2023; 380: e071018 [DOI: 10.1136/bmj-2022-071018]

<i>Training versus evaluation</i>	16	D,E	Identify any differences between the development and evaluation data in healthcare setting, eligibility criteria, outcome, and predictors	NA
<i>Ethical approval</i>	17	D,E	Name the institutional research board or ethics committee that approved the study and describe the participant-informed consent or the ethics committee waiver of informed consent	32
OPEN SCIENCE				
<i>Funding</i>	18a	D,E	Give the source of funding and the role of the funders for the present study	75
<i>Conflicts of interest</i>	18b	D,E	Declare any conflicts of interest and financial disclosures for all authors	75
<i>Protocol</i>	18c	D,E	Indicate where the study protocol can be accessed or state that a protocol was not prepared	32
<i>Registration</i>	18d	D,E	Provide registration information for the study, including register name and registration number, or state that the study was not registered	32
<i>Data sharing</i>	18e	D,E	Provide details of the availability of the study data	75
<i>Code sharing</i>	18f	D,E	Provide details of the availability of the analytical code ⁴	75
PATIENT & PUBLIC INVOLVEMENT				
<i>Patient & Public Involvement</i>	19	D,E	Provide details of any patient and public involvement during the design, conduct, reporting, interpretation, or dissemination of the study or state no involvement	NA
RESULTS				
<i>Participants</i>	20a	D,E	Describe the flow of participants through the study, including the number of participants with and without the outcome and, if applicable, a summary of the follow-up time. A diagram may be helpful.	47
	20b	D,E	Report the characteristics overall and, where applicable, for each data source or setting, including the key dates, key predictors (including demographics), treatments received, sample size, number of outcome events, follow-up time, and amount of missing data. A table may be helpful. Report any differences across key demographic groups.	47–63
	20c	E	For model evaluation, show a comparison with the development data of the distribution of important predictors (demographics, predictors, and outcome).	NA
<i>Model development</i>	21	D,E	Specify the number of participants and outcome events in each analysis (e.g., for model development, hyperparameter tuning, model evaluation)	47
<i>Model specification</i>	22	D	Provide details of the full prediction model (e.g., formula, code, object, application programming interface) to allow predictions in new individuals and to enable third-party evaluation and implementation, including any restrictions to access or re-use (e.g., freely available, proprietary) ⁵	75
<i>Model performance</i>	23a	D,E	Report model performance estimates with confidence intervals, including for any key subgroups (e.g., sociodemographic). Consider plots to aid presentation.	47–67
	23b	D,E	If examined, report results of any heterogeneity in model performance across clusters. See TRIPOD Cluster for additional details ⁵ .	47–63
<i>Model updating</i>	24	E	Report the results from any model updating, including the updated model and subsequent performance	47–63
DISCUSSION				
<i>Interpretation</i>	25	D,E	Give an overall interpretation of the main results, including issues of fairness in the context of the objectives and previous studies	64–72
<i>Limitations</i>	26	D,E	Discuss any limitations of the study (such as a non-representative sample, sample size, overfitting, missing data) and their effects on any biases, statistical uncertainty, and generalizability	73
<i>Usability of the model in the context of current care</i>	27a	D	Describe how poor quality or unavailable input data (e.g., predictor values) should be assessed and handled when implementing the prediction model	75
	27b	D	Specify whether users will be required to interact in the handling of the input data or use of the model, and what level of expertise is required of users	67–70; 74–75
	27c	D,E	Discuss any next steps for future research, with a specific view to applicability and generalizability of the model	74–75

From: Collins GS, Moons KGM, Dhiman P, et al. *BMJ* 2024;385:e078378. doi:10.1136/bmj-2023-078378

⁴ This relates to the analysis code, for example, any data cleaning, feature engineering, model building, evaluation.

⁵ This relates to the code to implement the model to get estimates of risk for a new individual.