

# Predição do Somatotipo Usando Antropometria Craniofacial

Antonio R. A. Brasil<sup>1</sup>, Patrick M. Ciarelli<sup>2</sup>, Josinaldo O. Dias<sup>3</sup>

<sup>1</sup>Pós-Graduação Lato Sensu Especialização em Inteligência Artificial - UFES  
Av. Fernando Ferrari, 514 - Goiabeiras, Vitória - ES, 29075-910

<sup>2</sup>Departamento de Engenharia Elétrica - UFES  
Av. Fernando Ferrari, 514 - Goiabeiras, Vitória - ES, 29075-910

<sup>3</sup>Departamento de Ciências Florestais e da Madeira - UFES  
Alto Universitário, S/N - Guararema, Alegre - ES, 29500-000

anribrasil@gmail.com, patrick.ciarelli@ufes.br, josinaldo.dias@ufes.br

**Abstract.** *Somatotype is a theory that states that the human body is composed of three main components: endomorph, mesomorph, and ectomorph. It is relevant in the fields of medicine and physical education and is traditionally estimated using measuring equipment applied directly on the body by specialists. This study explored the estimation of somatotype based on craniofacial features extracted from 2D facial images. Eight regression models were evaluated, and the best results were obtained with the SVR model for the endomorph component, kNN for the ectomorph component, and Linear Regression for the mesomorph component. The results can help further studies of facial features as approximate predictors of somatotype.*

**Resumo.** *O somatotipo é uma teoria que afirma que o corpo humano é composto por três componentes principais: endomorfo, mesomorfo e ectomorfo. Ela é relevante nas áreas da medicina e educação física e é tradicionalmente estimada por meio de equipamentos de medição aplicados diretamente sobre o corpo por especialistas. Este trabalho investigou a estimativa do somatotipo a partir de características craniofaciais extraídas de imagens 2D de rostos. Oito modelos de regressão foram avaliados e os melhores resultados foram obtidos com o modelo SVR para o componente endomorfo, kNN para o componente ectomorfo e Regressão Linear para o mesomorfo. Os resultados podem ajudar em estudos futuros de características faciais como preditores aproximados do somatotipo.*

## 1. Introdução

A antropometria é o estudo das propriedades físicas do corpo humano, com ênfase na mensuração de variáveis corporais como tamanho, forma e composição corporal [Pheasant and Haslegrave 2018]. Trata-se de uma ferramenta essencial na avaliação das características morfológicas dos indivíduos [Seçgin et al. 2023], e fornece subsídios valiosos para a análise do estado nutricional em crianças, adultos e gestantes [Fryar et al. 2021, Santos et al. 2014, Ververs et al. 2013].

As principais variáveis antropométricas incluem peso, altura, circunferência da cabeça, índice de massa corporal (IMC), perímetros corporais (como cintura, quadril e

membros), além da espessura das dobras cutâneas [Casadei and Kiel 2019]. A análise dessas medidas é fundamental tanto para o monitoramento da composição corporal e da adiposidade quanto para a avaliação de condições clínicas específicas, como obesidade e risco cardiovascular [Taylor Jr et al. 2010].

As características anatômicas dos seres humanos, bem como as medidas antropométricas, podem variar de acordo com a idade, sexo, altura, peso, raça e fatores fisiológicos e patológicos [Perissinotto et al. 2002]. Diante disso, uma das formas antropométricas que vem sendo utilizada atualmente é a determinação do somatotipo, que é crucial para interpretar as medidas anatômicas do corpo humano, dividindo-o em três componentes: endomorfo, mesomorfo e ectomorfo, referindo-se respectivamente à gordura relativa do corpo, à robustez músculo-esquelética e linearidade corporal [Carter and Heath 1990]. A partir das medidas corporais, os valores de cada componente são calculados. Uma vertente da antropometria é a antropometria craniofacial, que tem como objetivo estudar as medidas e proporções da cabeça e da face humana [Dmitrienko et al. 2019].

A antropometria craniofacial tem papel relevante em diferentes aspectos, como análise clínica de pacientes com síndrome de Down, desvio de septo nasal, assimetria facial, distúrbios dentofaciais e cirurgias ortofaciais [Dmitrienko et al. 2019, Farkas et al. 2001, Gulsen et al. 2006, Mommaerts and Moerenhout 2011]. Recentemente, a associação entre o somatotipo de indivíduos e suas medidas craniofaciais antropométricas foi estudada, sendo encontradas relações entre grupos de somatotipos e os parâmetros craniofaciais [Seçgin et al. 2023].

Em um estudo recente, Seçgin e colaboradores [Seçgin et al. 2023] realizaram a coleta das medidas antropométricas de 191 voluntários, seguindo o protocolo de Heath-Carter, e calcularam as componentes para cada participante em conjunto com as medidas faciais (feitas manualmente em imagens usando o programa Image J [Abràmoff et al. 2004], que incluíam: (a) comprimento nasal total, (b) largura do nariz (distância entre as asas nasais), (c) distância pupilar, (d) altura facial inferior, (e) altura total da face, (f) altura mandibular e (g) largura da face. Em sua análise, os autores concluíram que existe uma relação estatisticamente significativa entre o somatotipo e os parâmetros craniofaciais ( $P < 0,05$ ), especificamente nos indivíduos do tipo endomorfo, que apresentaram maiores valores nas medidas de largura do nariz, distância pupilar, largura facial e altura mandibular, concluindo que o somatotipo pode influenciar diretamente as características morfológicas faciais, devendo ser considerado em avaliações clínicas e estudos na área da saúde. A Figura 1 apresenta os parâmetros craniofaciais propostos pelos autores.

Diante disso, o objetivo deste trabalho é aplicar técnicas de aprendizado de máquina juntamente com visão computacional para extrair automaticamente medidas craniofaciais a partir de imagens 2D de corpos humanos, visando estimar as componentes do somatotipo dos indivíduos, objetivando permitir a estimativa dos valores do somatotipo apenas por meio de imagens, reduzindo o tempo necessário para o cálculo dessas componentes.



**Figura 1. Parâmetros craniofaciais propostos por [Seçgin et al. 2023], onde tem-se: (a) comprimento nasal total, (b) largura do nariz (distância entre as asas nasais), (c) distância pupilar, (d) altura facial inferior, (e) altura total da face, (f) altura mandibular, e (g) largura da face. Fonte: [Seçgin et al. 2023].**

## 2. Revisão da Literatura

A busca por estimar ou classificar componentes do somatotipo a partir de imagens digitais é uma área relativamente nova. Um dos primeiros trabalhos desenvolvidos foi o de Gonçalves et al. [Goncalves 2017] e Brasil e colaboradores [Brasil et al. 2021], em que os autores buscaram prever os valores das componentes do somatotipo a partir de imagens 2D, coletadas em visões frontal e lateral de participantes de uma competição de fisiculturismo. Foram coletados dados de 46 indivíduos (15 do sexo masculino e 31 do sexo feminino). Por meio de técnicas de processamento digital de imagens, como *Statistical Region Merging* (SRM) e método de Otsu, foi realizada a estimativa das medidas antropométricas de diferentes partes do corpo. Uma rede neural junto a um algoritmo genético foi usada para estimar as componentes endomorfo, ectomorfo e mesomorfo. O melhor erro absoluto médio (MAE) foi de 0,12. Além disso, a classificação do somatotipo obteve uma acurácia de até 92,86%. No entanto, os autores concluíram que uma possível limitação foi a baixa variedade do conjunto de dados, os quais continham apenas pessoas do campeonato de fisiculturismo, enviesando os resultados e o modelo, e comprometendo a capacidade de generalização.

Posteriormente, Brasil e colaboradores [Brasil et al. 2022] buscaram aprimorar os estudos anteriores, explorando soluções em conjuntos maiores, mas utilizando técnicas automatizadas de extração de características e aprendizado de máquina, como o aprendizado profundo. Em seu trabalho, os autores obtiveram um conjunto de dados contendo 456 modelos 3D de indivíduos, denominado NOMO 3D. Cada modelo de indivíduo da base de dados foi classificado manualmente por especialistas em uma componente (endomorfo, ectomorfo e mesomorfo). Duas imagens 2D extraídas do modelo em posição frontal e lateral foram usadas para treinar um modelo de aprendizado profundo com transferência de conhecimento, a VGG-16 e a InceptionResNet, sendo que a VGG-16 obteve uma acurácia de 65,70% na classificação, concluindo em seu estudo que são necessárias pesquisas adicionais e bases de dados aprimorados para melhorar os resultados.

Chiu e colaboradores [Chiu et al. 2022] buscaram estimar o somatotipo a partir de modelos 3D obtidos por escaneamento corporal. Usando medidas extraídas dos modelos 3D e usando o modelo SVM, os autores conseguiram obter resultados com um erro médio

inferior a 0,5. No entanto, enfatizaram a necessidade de mais estudos em conjuntos de dados diversos. Outrora, Yoon e colaboradores [Yoon et al. 2024] aplicaram aprendizado profundo para classificar o corpo humano nas componentes do somatotipo usando dados antropométricos 3D. Os autores coletaram escaneamentos 3D de 217 participantes e obtiveram a melhor acurácia de 72% com o uso da rede MobileNetV2. Por fim, Brasil e colaboradores [Brasil et al. 2025] exploraram o uso de modelos multimodais e linguagem generativa para classificação do somatotipo em classes predominantes (endomorfo, ectomorfo e mesomorfo) a partir de imagens de corpo em uma base contendo 50 indivíduos e, como resultado, obtiveram a acurácia de até 97% usando apenas imagens frontais.

### 3. Materiais e Métodos

#### 3.1. Base de Dados

O conjunto de dados utilizado neste trabalho foi coletado entre agosto e dezembro de 2023, sendo aprovado pelo Comitê de Ética em Pesquisa da Universidade Federal do Espírito Santo (CAAE 54408121.0.0000.5542). O conjunto é formado por dados de 80 participantes (36 do sexo masculino e 44 do sexo feminino) com idades entre 18 e 65 anos e com idade média de 27,9 anos ( $\pm 8,9$  anos). Os participantes foram orientados a evitar atividades físicas ou ingestão de bebidas diuréticas antes dos experimentos, a fim de preservar a confiabilidade das medições. Foi seguido o protocolo de coleta de medidas antropométricas de Heath e Carter [Carter and Heath 1990] para estimar com precisão cada componente do somatotipo (valores variando entre 0 e 7), sendo coletadas dez medidas antropométricas por três especialistas para cada participante: estatura, peso, dobras cutâneas do tríceps, supra-ilíaca, subescapular e panturrilha medial, diâmetro bi-epicondilar do úmero, diâmetro bi-epicondilar do fêmur, circunferência do braço em contração máxima e circunferência da panturrilha. Todas as coletas foram feitas com instrumentos calibrados: paquímetro, balança, fita métrica e estadiômetro. Importante destacar que algumas imagens tiveram uma distância fixada, entretanto outras não seguiram este mesmo protocolo.

Além disso, todos os participantes tiveram as imagens dos corpos frontais capturadas em condições padronizadas, com iluminação uniforme, posicionados em postura neutra, olhando diretamente para a câmera. A partir dessas imagens, medidas craniofaciais foram extraídas dos participantes utilizando técnicas de visão computacional. Para efetuar o cálculo das medidas antropométricas faciais foi utilizada a biblioteca dlib [King 2009] com o modelo pré-treinado de 68 pontos de referência facial [Kazemi and Sullivan 2014]. Para a detecção e extração das faces a partir das imagens, foi aplicado o algoritmo de Histograma de Gradiente Orientado (HOG), seguido pela predição dos pontos de referência com o preditor baseado em *Ensemble of Regression Trees* pré-treinado na base iBUG 300-W [Kazemi and Sullivan 2014, Sagonas et al. 2016]. Isso foi necessário para que pudesse ser aplicado a biblioteca dlib. As sete medidas faciais (comprimento nasal total, largura do nariz, distância pupilar, altura facial inferior, altura total da face, altura mandibular e largura da face) foram calculadas através das distâncias euclidianas entre pontos de referência específicos, seguindo a referência do trabalho de Seçgin e colaboradores [Seçgin et al. 2023] e foram introduzidas outras medidas (índice nasal, proporção facial inferior, índice facial, proporção ocular, proporção mandibular, proporção nasal vertical, proporção nasal horizontal, área facial relativa e razão altura-largura facial), sendo os pontos para calcular os valores das medidas obtidos pela biblioteca dlib

[Kazemi and Sullivan 2014], resultando em um total de 16 características usadas no modelo.

Para conversão das unidades das medidas das imagens, foi utilizada a informação de DPI (*dots per inch*) dos metadados das imagens (informações incorporadas pelo dispositivo que capturou a imagem), aplicando-se a conversão padrão de 25,4 mm (polegada) dividido pelo DPI [Akand et al. 2019]. A Tabela 1 apresenta as características descritivas completas da base de dados, incluindo as medidas antropométricas tradicionais e as medidas faciais extraídas automaticamente.

**Tabela 1. Características do conjunto de dados (valores médios  $\pm$  desvio padrão).**

Medidas Corporais Gerais			
Variável	Média	Variável	Média
Idade (anos)	27,9 $\pm$ 8,9	Supra-iliaca (mm)	16,0 $\pm$ 8,0
Altura (cm)	170,3 $\pm$ 8,8	Subescapular (mm)	17,0 $\pm$ 15,0
Peso (kg)	69,4 $\pm$ 13,8	Panturrilha medial (mm)	16,0 $\pm$ 8,5
Masculino / Feminino	36 / 44	Úmero (mm)	6,3 $\pm$ 0,6
Endomorfia	4,65 $\pm$ 1,97	Fêmur (mm)	9,0 $\pm$ 0,7
Ectomorfia	2,15 $\pm$ 1,29	Braço flexionado (cm)	30,7 $\pm$ 4,1
Mesomorfia	4,15 $\pm$ 1,53	Panturrilha (cm)	36,8 $\pm$ 4,2
Tríceps (mm)	15,7 $\pm$ 9,7		
Medidas Faciais (Imagem 2D)			
Variável	Média	Variável	Média
Comprimento nasal (mm)	3,84 $\pm$ 0,48	Altura facial total (mm)	11,43 $\pm$ 1,26
Largura nasal (mm)	2,03 $\pm$ 0,29	Altura mandibular (mm)	3,85 $\pm$ 0,57
Distância interpupilar (mm)	6,87 $\pm$ 0,78	Largura bizigomática (mm)	10,64 $\pm$ 1,24
Altura facial inferior (mm)	5,77 $\pm$ 0,79		

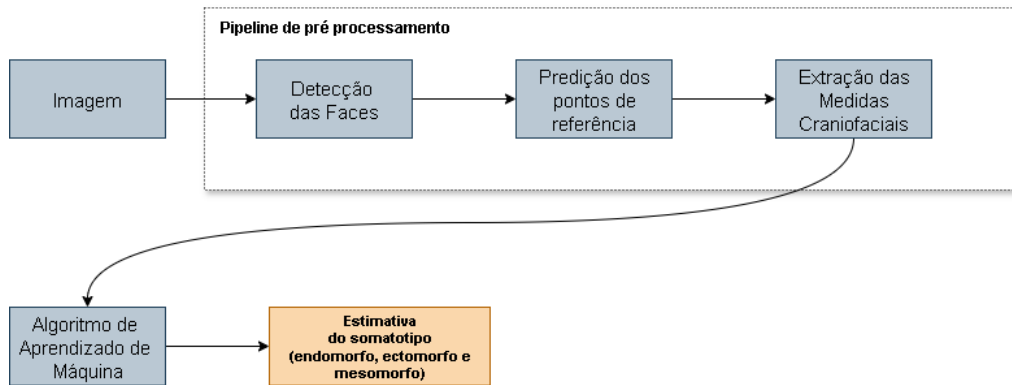
A coleta de dados foi feita em três ambientes diferentes, cada uma realizada por um especialista. Algumas imagens, especificamente em duas sessões de coleta, foram capturadas usando um Apple iPad 10ª geração (modelo A2696), com uma câmera de 10,9 megapixels. Na terceira sessão, as imagens foram feitas com um iPhone 12, possuindo uma câmera de 12 megapixels. Diante disso, as imagens apresentaram variações de resolução, com larguras entre 945 e 1469 pixels e alturas entre 709 e 1102 pixels, além de diferentes fundos e condições de iluminação.

### 3.2. Metodologia

A Figura 2 apresenta a metodologia do presente trabalho. Ela se inicia com a detecção da face do participante, extração das landmarks usando predição dos pontos de referência e, com base nesses pontos, são extraídas as medidas antropométricas craniofaciais em escala relativa. Na sequência, as variáveis extraídas alimentam os algoritmos para predição das componentes do somatotipo. Foram utilizados os seguintes algoritmos de regressão: Regressão Linear, Regressão Ridge (alfa = 1), Regressão Lasso (alfa = 0,1), ElasticNet (alfa = 0,1, razão L1 de 0,5), Floresta Aleatória (n = 100), *Gradient Boosting* (n = 100), Suporte a Vetores de Regressão (SVR) com kernel RBF (c = 1,0) e kNN (regressor) com k = 5.

Todos os experimentos foram executados usando Python com a biblioteca Sklearn<sup>1</sup>. Todos os parâmetros foram definidos após a otimização de hiperparâmetro utilizando Grid Search com validação cruzada estratificada (3-fold). Para a Regressão Logística, foram testados valores do parâmetro de regularização C variando de 0,01 a

<sup>1</sup>scikit-learn.org



**Figura 2. Metodologia do trabalho.**

100, combinados com os solvers *liblinear* e *saga*, configurações de iterações máximas (1000 e 2000) e balanceamento de classes (balanceado ou não). A Floresta Aleatória foi otimizada com número de estimadores (50 a 300), profundidade máxima (5, 10, 15 e ilimitada), critérios de divisão mínima (2, 5, 10 amostras) e folhas mínimas (1, 2, 4 amostras). Para Suporte a Vetores de Regressão, foram explorados valores de C (0,01 a 100), três tipos de kernel (RBF, linear e polinomial), parâmetros gamma (scale, auto e valores específicos de 0,001 a 0,1) e balanceamento de classes. O kNN teve variação dos números de vizinhos (3 a 15), esquemas de ponderação (*uniform* e *distance*), métricas de distância (euclidiana, Manhattan e Minkowski) e parâmetros de potência. Por fim, o *Gradient Boosting* foi ajustado variando o número de estimadores (50 a 200), taxa de aprendizado (0,01 a 0,2), profundidade máxima (3 a 7) e fração de subamostragem (0,8 e 1,0). Cada modelo foi treinado para prever uma componente, sendo apenas uma saída, e não as três componentes. Esta abordagem foi escolhida para que fosse possível maximizar os resultados do modelo e identificar as nuances e padrões de cada componente individualmente.

Os algoritmos foram aplicados usando LOOCV (*Leave One Out Cross Validation*) devido à baixa quantidade de amostras na base de dados. Todos os experimentos foram conduzidos em um computador Intel Core i7-77900HQ CPU 2.80GHz com 16 GB de memória e uma placa de vídeo GeForce GTX 1050 Ti (4GB de memória). A Figura 2 encapsula a aplicação do LOOCV.

### 3.3. Métricas de avaliação

Para avaliar o desempenho dos regressores, foram usadas quatro métricas padrão de regressão: erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE) e coeficiente de determinação ( $R^2$ ).

O MSE (Equação 1) calcula a média das diferenças quadráticas entre os valores reais  $y_i$  e os valores estimados  $\hat{y}_i$ , sendo  $n$  o número de indivíduos avaliados.

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

A RMSE (Equação 2) é simplesmente a raiz quadrada do MSE, trazendo o erro de

volta às unidades originais de medida.

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

O MAE (Equação 3) calcula a magnitude média dos erros, sem elevar ao quadrado.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (3)$$

O  $R^2$  (Equação 4) mede a proporção da variância da variável dependente que é explicada pelo modelo, onde  $y_i$  representa o valor real,  $\hat{y}_i$  o valor estimado pelo modelo,  $\bar{y}$  a média dos valores reais e  $n$  o número total de observações.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (4)$$

#### 4. Resultados e Discussão

A Tabela 2 apresenta o desempenho dos melhores modelos de regressão para cada um dos componentes do somatotipo, considerando apenas características faciais. O modelo SVR apresentou o melhor desempenho para o componente endomorfo, enquanto o modelo kNN se destacou na predição de ectomorfos. Para mesomorfos, a Regressão Linear obteve os melhores resultados. Em média, os modelos alcançaram um RMSE de 1,46, MAE de 1,13 e  $R^2$  médio de 0,16, indicando uma predição razoável dos componentes de somatotipo a partir de traços craniofaciais.

**Tabela 2. Resumo dos resultados dos modelos de regressão para predição dos componentes do somatotipo com base em características faciais.**

Componente	Métricas do Melhor Modelo				Melhor Predição		Pior Predição		
	Modelo	RMSE	MAE	$R^2$	MSE	Real / Pred.	Erro	Real / Pred.	Erro
Endomorfo	SVR	1,922	1,438	0,037	3,693	4,781 / 5,094	0,313	11,687 / 3,558	8,128
Ectomorfo	KNN	1,163	0,955	0,181	1,353	2,279 / 1,709	0,570	5,232 / 1,940	3,292
Mesomorfo	Linear Reg.	1,308	1,019	0,263	1,711	3,529 / 3,515	0,015	3,178 / 7,167	3,989
<b>Média Geral</b>	-	<b>1,464</b>	<b>1,137</b>	<b>0,160</b>	<b>2,252</b>	-			

Para o componente endomorfo, os modelos apresentaram desempenho semelhante, com destaque para o SVR que obteve os melhores resultados (RMSE = 1,9217). Outros modelos como a Floresta Aleatória (RMSE = 1,9850) e ElasticNet (RMSE = 1,9849) também apresentaram erros próximos, mas com menor capacidade explicativa ( $R^2$  negativos). O kNN teve o pior desempenho (RMSE = 2,0638), seguido por *Gradient Boosting* (RMSE = 2,0553).

Para o componente ectomorfo, o modelo kNN foi o mais eficaz, apresentando RMSE = 1,1633, superando ligeiramente o SVR (RMSE = 1,1976) e ElasticNet (RMSE = 1,1982). Os modelos baseados em regressão linear (Ridge, Lasso e Regressão Linear) obtiveram desempenhos consistentes, com  $R^2$  variando entre 0,08 e 0,12. Já o *Gradient Boosting* teve o pior resultado (RMSE = 1,3250).

Para o componente mesomorfo, a Regressão Linear apresentou os melhores resultados (RMSE = 1,3082), seguida de perto por Ridge e Floresta Aleatória, ambos com desempenho semelhante. Lasso e ElasticNet também obtiveram bons resultados, com erros pouco maiores e valores de  $R^2$  entre 0,21 e 0,23. Quando se analisa o kNN, ele teve o maior erro entre todos os modelos (RMSE = 1,3883).

De modo geral, os modelos apresentaram desempenho razoável na predição dos valores das componentes, com  $R^2$  modestos. Esse resultado pode estar relacionado à própria natureza das componentes do somatotipo, que não são totalmente representadas por traços faciais: parte delas depende diretamente de medidas obtidas por dobras cutâneas. Como a abordagem proposta utiliza apenas características craniofaciais extraídas de imagens 2D, essas informações não são capturadas, o que impacta negativamente no desempenho dos classificadores.

É importante destacar algumas observações. O desempenho dos modelos em termos de  $R^2$ , especialmente para o endomorfo, cujo valor mais alto foi apenas 0,037, pode indicar que as feições faciais não são suficientes para explicar as componentes do somatotipo, embora contenham alguma informação a respeito. Isto acontece especialmente em relação à gordura corporal, dado que suas medidas são capturadas usando equipamentos que obtêm dobras cutâneas do corpo dos participantes.

Todavia, quando analisou-se o ectomorfo, que está relacionado à linearidade e magreza do corpo, os modelos tiveram desempenho levemente superior, com o kNN obtendo  $R^2 = 0,1807$ . Esse resultado pode sugerir que participantes com traços faciais mais alongados ou angulosos podem apresentar padrões que refletem melhor a componente do ectomorfo, e que pode ser uma explicação para a melhor capacidade estimativa dos algoritmos para este caso em específico.

Quando se analisa a componente mesomorfo, que é uma componente associada à robustez e desenvolvimento muscular, a Regressão Linear superou os modelos mais complexos. Isso pode ser um indicativo de que a relação entre os traços faciais e a componente pode seguir uma tendência mais linear e menos dependente de interações não lineares ou estruturas complexas, o que possibilita modelos mais tradicionais serem mais eficazes. Ainda assim, o  $R^2$  máximo alcançado foi de 0,263, o que reforça o caráter limitado dos dados faciais usados para predição desta componente.

## 5. Conclusão

O objetivo desse trabalho foi realizar a estimativa do somatotipo de indivíduos usando apenas informações craniofaciais de rostos 2D. Para isso, foi aplicado diversos algoritmos de regressão que foram avaliados com validação cruzada (LOOCV) com o objetivo de maximizar os resultados e lidar com a limitação de tamanho reduzido das amostras. Os resultados demonstraram que, embora tenham sido observadas correlações modestas entre traços faciais e os componentes do somatotipo, a predição baseada apenas em informações faciais possui limitações importantes. O melhor desempenho foi observado no componente mesomorfo, com  $R^2$  de 0,263 usando regressão linear, enquanto os modelos para os demais componentes apresentaram resultados de  $R^2$  inferiores a 0,2, refletindo na baixa capacidade de estimativa.

Apesar das limitações inerentes à estimativa dos componentes do somatotipo a partir de imagens 2D, especialmente pela impossibilidade de mensurar dobras cutâneas,



este estudo contribui para suportar o potencial do uso das características faciais como fonte de informação complementar para a estimativa do somatotipo, especialmente em cenários onde a coleta de medidas antropométricas tradicionais não é viável.

Como trabalho futuro, propõe-se a ampliação da base de dados, fusão das informações corpóreas e das informações faciais, e a aplicação de modelos baseados em aprendizado profundo, como redes neurais convolucionais, com o intuito de aprimorar a predição das componentes a partir de informações visuais não invasivas.

## Referências

- Abràmoff, M. D., Magalhães, P. J., and Ram, S. J. (2004). Image processing with imagej. *Biophotonics international*, 11(7):36–42.
- Akand, M., Civcik, L., Buyukaslan, A., Altintas, E., Kocer, E., Koplay, M., and Erdogru, T. (2019). Feasibility of a novel technique using 3-dimensional modeling and augmented reality for access during percutaneous nephrolithotomy in two different ex-vivo models. *International Urology and Nephrology*, 51(1):17–25.
- Brasil, A. R. A., Amaral, F. T., Oliveira, L. C. S. L., Brasil, G. A., Côco, K. F., and Ciarelli, P. M. (2025). A somatotype classification approach based on generative ai and frontal images of individuals. *IEEE Access*, pages 1–1.
- Brasil, A. R. A., Castro, J. W. B., Gonçalves, E. C., Brasil, G. A., Coco, K. F., and Ciarelli, P. M. (2022). Convolutional neural networks for somatotype classification of images from 3d human bodies. In *IX Congresso Latino-Americano de Engenharia Biomédica*.
- Brasil, A. R. A., de Oliveira Gonçalves, T., Castro, J. W. B., Gonçalves, E. C., Côco, K. F., and Ciarelli, P. M. (2021). Automatic identification of somatotype by digital images. In *Simpósio Brasileiro de Automação Inteligente-SBAI*, volume 1.
- Carter, J. L. and Heath, B. H. (1990). *Somatotyping: development and applications*, volume 5. Cambridge University Press.
- Casadei, K. and Kiel, J. (2019). Anthropometric measurement.
- Chiu, C.-Y., Ciems, R., Thelwell, M., Bullas, A., and Choppin, S. (2022). Estimating somatotype from a single-camera 3d body scanning system. *European Journal of Sport Science*, 22(8):1204–1210.
- Dmitrienko, S., Domenyuk, D., Melekhov, S., Domenyuk, S., and Weisheim, L. (2019). Analytical approach within cephalometric studies assessment in people with various somatotypes. *Archiv EuroMedica*, 9(3):103.
- Farkas, L. G., Katic, M. J., Forrest, C. R., and Litsas, L. (2001). Surface anatomy of the face in down’s syndrome: linear and angular measurements in the craniofacial regions. *Journal of Craniofacial Surgery*, 12(4):373–379.
- Fryar, C. D., Carroll, M. D., Gu, Q., Afful, J., and Ogden, C. L. (2021). Anthropometric reference data for children and adults: United states, 2015-2018.
- Goncalves, T. d. O. (2017). Identificação do somatotipo de fisiculturistas através de imagens digitais. Master’s thesis, Universidade Federal do Espírito Santo.

- Gulsen, A., Okay, C., Aslan, B. I., Uner, O., and Yavuzer, R. (2006). The relationship between craniofacial structures and the nose in anatolian turkish adults: a cephalometric evaluation. *American Journal of Orthodontics and Dentofacial Orthopedics*, 130(2):131–e15.
- Kazemi, V. and Sullivan, J. (2014). One millisecond face alignment with an ensemble of regression trees. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1867–1874.
- King, D. E. (2009). Dlib-ml: A machine learning toolkit. *The Journal of Machine Learning Research*, 10:1755–1758.
- Mommaerts, M. and Moerenhout, B. (2011). Ideal proportions in full face front view, contemporary versus antique. *Journal of Cranio-Maxillofacial Surgery*, 39(2):107–110.
- Perissinotto, E., Pisent, C., Sergi, G., Grigoletto, F., Enzi, G., Group, I. W., et al. (2002). Anthropometric measurements in the elderly: age and gender differences. *British Journal of nutrition*, 87(2):177–186.
- Pheasant, S. and Haslegrave, C. M. (2018). *Bodyspace: Anthropometry, ergonomics and the design of work*. CRC press.
- Sagonas, C., Antonakos, E., Tzimiropoulos, G., Zafeiriou, S., and Pantic, M. (2016). 300 faces in-the-wild challenge: Database and results. *Image and vision computing*, 47:3–18.
- Santos, D. A., Dawson, J. A., Matias, C. N., Rocha, P. M., Minderico, C. S., Allison, D. B., Sardinha, L. B., and Silva, A. M. (2014). Reference values for body composition and anthropometric measurements in athletes. *PloS one*, 9(5):e97846.
- Seçgin, Y., Toy, Ş., Şenol, D., and Öner, Z. (2023). Associating craniofacial morphometry determined by photo analysis with somatotype in healthy young individuals. *The European Research Journal*, 9(4):717–724.
- Taylor Jr, H. A., Coady, S. A., Levy, D., Walker, E. R., Vasan, R. S., Liu, J., Akyzbekova, E. L., Garrison, R. J., and Fox, C. (2010). Relationships of bmi to cardiovascular risk factors differ by ethnicity. *Obesity*, 18(8):1638–1645.
- Ververs, M.-t., Antierens, A., Sackl, A., Staderini, N., and Captier, V. (2013). Which anthropometric indicators identify a pregnant woman as acutely malnourished and predict adverse birth outcomes in the humanitarian context? *PLoS currents*, 5:ecurrents-dis.
- Yoon, J., Lee, S.-Y., and Lee, J.-Y. (2024). Ai somatotype system using 3d body images: Based on deep-learning and transfer learning. *Applied Sciences*, 14(6):2608.