



Avaliação de gordura corporal de pacientes por visão computacional: uma revisão sistemática

Evaluation of body fat of patients by computer vision: a systematic review

Evaluación de grasa corporal de pacientes por visión computacional: una revisión sistemática

Alexandre Gonçalves Silva¹, Rangel Arthur², Franklin Cesar Flores³, Ana Paula de Campos Araújo Moreira⁴

RESUMO

Descritores: Pesos e Medidas Corporais; Antropometria; Engenharia Biomédica

Objetivo: Este trabalho apresenta uma revisão de modelos para avaliação de massa corporal e de métodos de visão computacional aplicados à antropometria. A ideia é sugerir um sistema, baseado em fotografia, para aproximação dos atributos usados nessas fórmulas (como o IMC), aplicado à monitoração permanente e automática de indicadores nutricionais em pacientes com mobilidade comprometida. **Métodos:** A metodologia consiste em ampla pesquisa em bases de dados bibliográficas na área da saúde, de tecnologia e sistemas de informação. Modelos existentes para avaliação de massa corporal são estudados; e algoritmos de processamento de imagens e aprendizagem de máquina, referentes a medições antropométricas, são exemplificados. **Resultados:** Apresentação criteriosa de um panorama sobre fórmulas e métodos computacionais para a estimação de medidas por imagens, destacando pontos positivos e negativos de cada abordagem. **Conclusão:** Uma organização sistemática sobre ferramentas existentes, evidenciando modelos com base no uso de câmeras simples para análise nutricional de pacientes.

ABSTRACT

Keywords: Body Weights and Measures; Anthropometry; Biomedical Engineering

Objective: This work presents a review of models for body mass evaluation and computational vision methods applied to anthropometry. The idea is to suggest a system, based on photography, to approximate the attributes used in these formulas (such as BMI), applied to the permanent and automatic monitoring of nutritional indicators in patients with impaired mobility. **Method:** The methodology consists of extensive research in bibliographic databases in the area of health, technology and information systems. Existing models for assessing body mass are studied; and algorithms of image processing and machine learning, referring to anthropometric measurements, are exemplified. **Results:** A detailed presentation of a panorama about formulas and computational methods for the estimation of measurements by images, highlighting the positives and negatives of each approach. **Conclusion:** A systematic organization on existing tools, evidencing models based on the use of simple cameras for nutritional analysis of patients.

RESUMEN

Descriptores: Pesos y Medidas Corporales; Antropometría; Ingeniería Biomédica

Objetivo: Este trabajo presenta una revisión de modelos para evaluación de masa corporal y de métodos de visión computacional aplicados a la antropometría. La idea es sugerir un sistema basado en fotografía para aproximar los atributos usados en esas fórmulas (como el IMC), aplicado al monitoreo permanente y automático de indicadores nutricionales en pacientes con movilidad comprometida. **Método:** La metodología consiste en una amplia investigación en bases de datos bibliográficas en el área de la salud, de tecnología y sistemas de información. Los modelos existentes para la evaluación de masa corporal se estudian; y los algoritmos de procesamiento de imágenes y aprendizaje de máquina, referentes a mediciones antropométricas, se ejemplifican. **Resultados:** Presentación cuidadosa de un panorama sobre fórmulas y métodos computacionales para la estimación de medidas por imágenes, destacando puntos positivos y negativos de cada abordaje. **Conclusión:** Una organización sistemática sobre herramientas existentes, evidenciando modelos basados en el uso de cámaras simples para análisis nutricional de pacientes.

¹ Professor Adjunto do Departamento de Informática e Estatística da Universidade Federal de Santa Catarina - UFSC, Florianópolis (SC), Brasil.

² Professor Associado da Faculdade de Tecnologia da Universidade Estadual de Campinas - UNICAMP, Campinas (SP), Brasil.

³ Professor Adjunto do Departamento de Informática da Universidade Estadual de Maringá - UEM, Maringá (PR), Brasil.

⁴ Professora Mestre em Saúde Coletiva pela Universidade de São Paulo - USP, tutora da UAB/UNIFESP, São Paulo (SP), Brasil.

INTRODUÇÃO

A mensuração de gordura corporal é uma maneira importante de avaliar dietas e treinamentos, além de servir como um parâmetro para análise de fator de risco para a saúde. A obesidade, segundo dados de 2016 da Organização Mundial da Saúde, é um dos principais fatores de morte evitáveis em todo o mundo, com taxas de prevalência cada vez maiores¹. Nas capitais brasileiras, entre os adultos, 19% estão obesos e 35% têm sobrepeso; em Florianópolis, por exemplo, 49,8% da população tem excesso de peso⁽¹⁾. Em outro espectro, distúrbios alimentares (como a anorexia), disfunções com comprometimento alimentar, condições de extrema pobreza, entre outras situações, promovem significativa perda de peso, e requerem o devido acompanhamento.

Nenhuma técnica comercial para avaliação da gordura corporal é exata e todas as abordagens são estimativas. O método *Dual-Energy X-ray Absorptiometry* (DEXA ou DXA) é o mais preciso¹¹ e amplamente aceito para a mensuração da composição corporal em ambientes clínicos⁽²⁾. Na prática, são utilizados métodos indiretos, sem custos e aproximados. O Índice de Massa Corporal (IMC) ou *Body Mass Index* (BMI) é o mais praticado na avaliação de gordura. A fórmula do IMC exige apenas uma balança e uma fita métrica, mas apresenta problemas como, por exemplo, a não consideração de diferenças de gênero. Recentemente, um novo modelo, denominado Índice de Massa Gorda Relativa (IMR) ou *Relative Fat Mass* (RFM), além de descartar o uso de balança, e necessitar apenas de uma fita métrica para a determinação de altura e de circunferência da cintura, se mostrou uma alternativa mais confiável para a avaliação corporal. A expressão do IMR é dada pela Equação⁽¹⁾, sendo o cálculo mais preciso do que outras 300 fórmulas (incluindo o IMC), e o que se revelou mais próximo da densitometria por DEXA⁽³⁾.

$$\text{IMR} = 64 - \left(20 \cdot \frac{\text{altura}}{\text{circunf_cintura}} \right) + (12 \cdot \text{sexo}), \text{ onde } \text{sexo} = \begin{cases} 0 & \text{para masculino} \\ 1 & \text{para feminino} \end{cases} \quad (1)$$

Embora não haja necessidade de balança, a determinação desses parâmetros ainda pode ser inconveniente para pacientes com pouca mobilidade. Neste sentido, diversas outras medidas e relações podem ser consideradas^(4,5). Algumas delas apresentadas na Figura 1. A massa (em kg) e altura (em cm), por exemplo, são estimadas pelas Equações (2) e (3), abaixo⁽⁵⁾:

$$\text{massa} = 0,5759 \cdot \text{circunf_braço} + 0,5263 \cdot \text{circunf_abdominal} + 1,2452 \cdot \text{circunf_panturrilha} - 4,8689 \cdot \text{sexo} - 32,9241 \quad (2)$$

$$\text{altura} = 58,6940 - 2,9740 \cdot \text{sexo} - 0,0736 \cdot \text{idade} + 0,4958 \cdot \text{comprimento_braço} + 1,1320 \cdot \text{meia_envergadura} \quad (3)$$

$$\text{onde } \text{sexo} = \begin{cases} 1 & \text{para masculino} \\ 2 & \text{para feminino} \end{cases}$$

Com os recentes avanços em métodos de aprendizagem profunda, muitas aplicações de reconhecimento de objetos se tornaram possíveis por visão computacional. No contexto deste trabalho, há especial interesse em métodos para análise de faces⁽⁶⁻⁸⁾ e poses humanas⁽⁹⁻¹¹⁾, de modo que possam ser adaptados para extração de parâmetros antropométricos, com base tão somente em uma única imagem fotográfica, de forma robusta, automática e sem contato físico com o paciente. Como objetivo principal, pretende-se efetuar um levantamento sistemático de trabalhos da literatura que possibilitem a construção de um sistema robusto baseado em visão computacional ou que tenham obtido resultados com alto nível de acurácia para implementação de métodos de avaliação de gordura corporal por imagem.

MÉTODO

Esta seção descreve o protocolo de revisão sistemática adotado, composto pelas fases de planejamento, execução, seleção e extração. O planejamento consistiu na formulação da principal questão de pesquisa: *antropometria baseada em análise imagens, obtidas por dispositivos móveis, pode ser empregada na estimativa de gordura corporal, – tais como o índice de massa corporal (IMC, ou BMI em inglês) ou o recente índice de massa gorda relativa (IMR, ou RFM em inglês) –, de modo a ser utilizado especialmente na avaliação de pacientes com pouca ou nenhuma mobilidade?* Esta pergunta contempla o termo “índice de massa gorda relativa” (IMR), proposto recentemente por Woolcott, Bergman (2018)⁽⁵⁾, no qual, associado à atuação dos autores do presente trabalho, na área de processamento de imagens, instigou o início desta revisão. E, para responder ao questionamento formulado, uma ampla pesquisa em bases de dados bibliográficas foi executada, nas áreas da saúde – Biblioteca Virtual em Saúde (BVS) – e de sistemas de informação – *ScienceDirect* (*Science,*

health and medical journals), e Google Acadêmico –, para estudo tecnológico de modelos existentes para avaliação de massa corporal e de algoritmos para processamento de imagens e aprendizagem de máquina, referentes a medições antropométricas. A seleção de artigos, especialmente de publicações consideradas qualificadas (entre outras variáveis, se inseridas em um processo

¹ <http://www.who.int/en/news-room/fact-sheets/detail/obesity-and-overweight>

¹¹ Os melhores métodos para determinar a composição corporal de um humano vivo são chamados de “modelos de quatro componentes” (4CM) que dividem o corpo em água, proteína, mineral e gordura usando isótopos radioativos para determinar a água corporal total e o potássio total do corpo, mas são impraticáveis, mesmo na maioria dos cenários clínicos (Fonte: <http://fellrn.com/wiki/DEXA>).

editorial criterioso e/ou com expressiva quantidade de citações) de estudos, preferencialmente desenvolvidos a partir de 2008, foi baseada na composição de palavras chaves e formação de três *strings* de busca:

Í% **String 1:** (“*anthropometric measurements*” AND ((*height* OR *weight*) AND *estimation*) AND *regression*

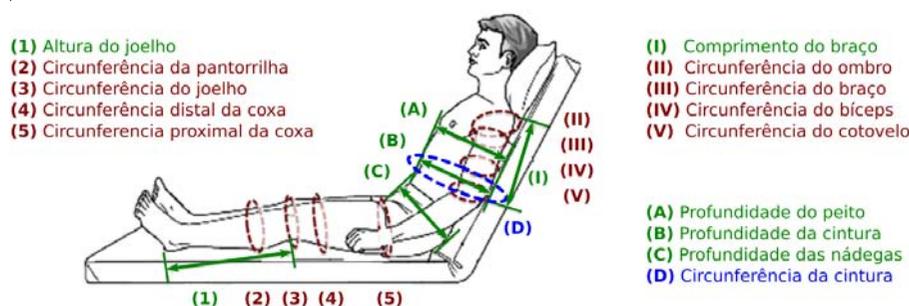


Figura 1 - Alguns parâmetros antropométricos obtidos por fita métrica (Adaptado de Rativa, Fernandes, Roque (2018)⁽⁴⁾).

Í% **String 2:** (“facial features” OR “facial landmark localization”) AND (“weight estimation” OR bmi) AND (“single image” OR “rgb image”) AND (“image processing” OR “computer vision”)

Í% **String 3:** (“body model” OR “pose model” OR “human body skeleton detection”) AND (“height estimation” OR bmi) AND (“single image” OR “rgb image”) AND (“image processing” OR “computer vision”)

No portal BVS, os *strings* 2 e 3 não retornaram nenhum resultado. O *string* 1, por ser mais genérico e historicamente relacionado com a área da saúde, resultou em uma lista com 38 trabalhos. Não havendo, nessa base, nenhum trabalho envolvendo os aspectos tecnológicos presentes nos *strings* 2 e 3, optou-se pela verificação daqueles que fizessem referência a alguma técnica computacional moderna para estimação de medidas antropométricas ou tivesse preocupação com pacientes com pouca mobilidade. Os artigos de Rativa, Fernandes, Roque (2018)⁽⁴⁾ e Rabito, et al. (2006)⁽⁵⁾ foram considerados os mais representativos. O primeiro por utilizar aprendizagem de máquina, a partir de bases antropométricas consolidadas, como NHANES III^{III} e ANSUR^{IV}, para estimação de altura e peso de pacientes com pouca mobilidade. O segundo por adequar as fórmulas à população brasileira de imobilizados. No entanto, nenhum estudo para estimação das mesmas medidas, baseado exclusivamente em fotografias (de cabeça e/ou membros inferiores e superiores), foi encontrado na BVS.

Considerando que o *string* 1 não é foco desta revisão, mas foi importante para ilustrar formas de estimativas de altura e peso (utilizados no cálculo do IMC), a partir de outras medidas antropométricas, obtidas manualmente, e que dois artigos se tornaram representantes importantes desta busca, optou-se em utilizar, para as demais bases bibliográficas, apenas os *strings* 2 e 3, de rara ocorrência, que são, de fato, o interesse maior da presente pesquisa.

Para o portal *ScienceDirect*, a busca pelo *string* 2 resultou em três trabalhos, sendo apenas um relacionado ao rastreamento de peso e gordura corporal. O uso do *string* 3, por sua vez, resultou em apenas um trabalho que, embora faça breve análise de partes do corpo, propõe aprendizagem para a classificação de ações/gestos humanos e, portanto, com objetivo distinto do esperado.

O Google Acadêmico contempla diversas outras bases

(como, por exemplo, a *IEEE Xplore Digital Library*). Com a *string* 2, em sua indexação, foram obtidos 32 artigos completos e teses. Destes, 21 foram descartados por serem repetidos ou estarem em contextos diferentes (por exemplo, estimação de peso para animais, ou de peso em funções matemáticas, ou de idade, ou mesmo BMI sendo sigla de momento invariante, além de uso de câmeras de profundidades ou termais, entre outros). Portanto, 11 trabalhos foram considerados. Com o *string* 3, inicialmente, 46 artigos completos e teses foram recuperados, desconsiderando repetições, sendo 26 fora de contexto (sistemas baseados em câmeras de profundidade ou métodos voltados à digitalização 3D foram descartados). Portanto, 20 trabalhos foram considerados.

O único artigo destacado pelo *ScienceDirect*, também surgiu no Google Acadêmico para o *string* 2. E, no Google Acadêmico, um trabalho se repetiu nas buscas usando os *strings* 2 e 3. Como a grande maioria dos 20 trabalhos resultantes (11 do *string* 1, mais 20 do *string* 2, menos 1 em comum) não envolviam medições antropométricas, optou-se por efetuar nova busca no Google Acadêmico, acrescentando a palavra “anthropometric”, por conexão lógica “AND”, aos *strings* 2 ou 3, formando um novo:

• **String 4:** (*string* 2 OR *string* 3) AND anthropometric

Foram obtidas 12 respostas no primeiro caso e 31 no segundo, havendo 4 repetições. Portanto, 39 entradas, sem qualquer filtragem por conteúdo relacionado, passaram a ser analisadas.

Para todas as filtrações de buscas efetuadas em todas as bases, desconsiderando os trabalhos fora de contexto (repetidos, foco em digitalização 3D ou gestos, estimação de idade, uso de câmera de profundidade ou termal, etc), foram extraídas as referências apresentadas na próxima seção.

RESULTADOS

Nesta seção, são descritos os resumos e resultados das técnicas propostas nos artigos selecionados pelo presente estudo, de acordo com os critérios da metodologia. No Quadro 1, os trabalhos são detalhados.

DISCUSSÃO

O exame DEXA⁽²⁾, apesar de preciso, é caro, e vem sendo aproximado quase que universalmente pelas classificações simples e de baixo custo de IMC. Porém,

^{III} <https://wwwn.cdc.gov/nchs/nhanes/nhanes3/>

^{IV} <http://www.openlab.psu.edu/ansur2/>

Quadro 1 – Artigos extraídos nas bases de dados, sobre modelos de regressão para determinação de gordura corporal, e métodos de visão computacional para estimação de medidas antropométricas.

Artigo	Objetivo	Resultados
Woolcott, Bergman (2018) ⁽³⁾	O estudo propõe uma alternativa mais confiável, simples e precisa, em relação ao IMC, denominada de Índice de Massa Gorda Relativa (IMR ou RFM). Para isto, propõe-se o uso apenas de uma fita métrica para a determinação da altura e da circunferência da cintura.	Os autores filtraram e analisaram a importante base NHANES de nutrição e estabeleceram uma nova fórmula, ilustrada pela Equação (1). Este cálculo, feito para 3456 pacientes adultos, foi mais preciso do que mais de 300 outras fórmulas (incluindo o IMC), sendo o que mais se aproximou da densitometria por DEXA de corpo inteiro, considerada “padrão ouro” ⁽²⁾ .
Rativa, Fernandes, Roque (2018) ⁽⁴⁾	Altura e peso de pacientes, especialmente sem ou com parcial mobilidade ou que estão impossibilitados de se comunicar, podem ser estimados por meios antropométricos. A ideia é avaliar 13 medidas que possam ser obtidas confortavelmente, com o paciente deitado ou sentado, usando apenas uma fita métrica. E, por meio de regressões baseadas em aprendizagem de máquina, comparar com os modelos tradicionais que utilizam regressões lineares.	O trabalho utilizou as bases NHANES III e ANSUR, combinou diversos parâmetros antropométricos, separando as amostras para treinamento e testes. Os resultados, usando aprendizagem de máquina foram melhores que os obtidos por regressões estatísticas tradicionais. O gênero foi considerado e não houve dependência de etnia para as populações analisadas. Para pacientes sem mobilidade, a predição de peso, a partir de medidas do membro inferior, tiveram melhor desempenho com Intervalo de Confidência (IC) de 94% e limites entre 3,19 e 4,20kg. No caso de ser possível medir ambos os membros (inferior e superior), o IC obtido foi de 97% com limites entre 2,94 e 3,91kg. Se parâmetros relativos à profundidade também puderem ser medidos, a predição atinge o melhor valor de precisão com um IC de 98% e limites entre 1,14 e 1,77kg, e, se a altura for conhecida, o IC passa a 99% com limites entre 0,64 e 1,13kg.
Rabito, et al. (2006) ⁽⁵⁾	Confirmar a adequação da fórmula sugerida na literatura e/ou desenvolver equações apropriadas para a população brasileira de pacientes imobilizados com base em medidas antropométricas simples.	Medidas de 368 pessoas foram avaliadas em dois centros hospitalares e cinco predições de peso e duas equações de predição de altura foram propostas a partir das medidas obtidas. Entre as novas equações, a mais simples para estimativa de massa foi ilustrada pela Equação (2); e a de estimativa de altura foi dada pela Equação (3). As estimativas assim calculadas não diferiram significativamente das medidas reais, com $p=0,94$ e $0,89$ e erro médio de $6,0$ e $2,1\%$ para peso e altura, respectivamente.
Wen, Guo (2013) ⁽⁶⁾	Faces humanas codificam muitas informações úteis. Estudos recentes em psicologia e percepção humana descobriram que características faciais têm relação com o peso humano ou IMC. Motivado por essas pesquisas, este trabalho desenvolve um método computacional para prever automaticamente o IMC das imagens faciais. A predição do IMC é formulada a partir de características faciais como um problema de visão de máquina.	Abordagem baseada em visão computacional é avaliada em um banco de dados com mais de 14500 imagens faciais. Os coeficientes de correlação e as medidas do valor p demonstram correlações entre as características faciais calculadas, por meio de técnicas de visão de máquina e aprendizagem estatística, e o IMC de maneira estatisticamente significativa. A abordagem computacional é provavelmente a primeira a prever automaticamente o IMC a partir de imagens faciais. O resultado foi promissor, demonstrando a viabilidade de um sistema computacional para a predição do IMC a partir de imagens faciais em larga escala.
Dantcheva, Bremond, Bilinski (2018) ⁽⁷⁾	Trabalhos anteriores sobre estimativas automatizadas de altura, peso e IMC concentraram-se predominantemente em imagens e vídeos de corpo inteiro 2D e 3D. Este trabalho explora a possibilidade de estimar a altura, o peso e o IMC a partir de imagens faciais, propondo um método de regressão baseado na arquitetura rede neural residual (ResNet) de 50 camadas. Além disso, apresenta-se um novo conjunto de dados que consiste em 1026 indivíduos.	Os resultados sugerem que as imagens faciais contêm informações discriminatórias relativas à altura, peso e IMC, comparáveis àquelas de imagens corporais e vídeos. Experimentos conduzidos em um novo conjunto de dados resultaram em acurácias promissoras de correlação de até $\rho=0,78$ para a estimativa do peso feminino e erros absolutos médios de $2,3$ para a estimativa do IMC feminino. Não foi observado um viés de gênero significativo na estimativa de altura, peso e IMC.
Kazemi, Sullivan (2014) ⁽⁸⁾	Este artigo aborda o problema do alinhamento de face para uma única imagem. Discute-se como um conjunto de árvores de regressão pode ser usado para estimar as posições de referência da face diretamente de um subconjunto esparsos de intensidades de pixel, alcançando um desempenho em tempo real com previsões de alta qualidade. É apresentada uma estrutura geral baseada no aumento de gradiente para aprender um conjunto de árvores de regressão que otimiza a soma da perda de erro quadrada e lida naturalmente com dados ausentes ou parcialmente rotulados.	Um novo algoritmo é apresentado para realizar o alinhamento de faces em milissegundos e atinge uma precisão superior ou comparável aos métodos de última geração (modelos de contornos ativos, STASM e CompASM) para as bases de dados HELENY e LFPW ^{VI} . Os ganhos de velocidade em relação aos métodos anteriores são uma consequência da identificação dos componentes essenciais de algoritmos existentes de alinhamento de face e incorporação deles em uma formulação simplificada em uma cascata de funções de regressão de alta capacidade aprendidas via aumento de gradiente. Os erros de detecção foram de $0,049$ para a base de dados HELEN e $0,038$ para a LFPW.
Liu, Sowmya, Khamis (2018) ⁽⁹⁾	O principal objetivo deste trabalho é de demonstrar que a altura e a circunferência do braço (MUAC), – indicadores de desnutrição –, podem ser estimadas com precisão aplicando regressão linear a medidas de distância de fotografias de participantes tiradas de cinco vistas, e determinar as combinações ideais de vistas. Um objetivo secundário é o de observar o efeito no erro de estimativa de duas abordagens que reduzem a complexidade da configuração, os requisitos computacionais e a especialização exigida do observador.	A diferença absoluta média (DAB) entre as estimativas de regressão linear e as medidas manuais foi menor em comparação com outros métodos. Para as combinações ideais de visão (menor DAB), o erro técnico de medição e o coeficiente de confiabilidade também indicam que os métodos de regressão linear são mais confiáveis. A combinação ideal de vistas foi a frontal e lateral. Ao estimar a estatura por meio de regressão linear da distância da cabeça ao solo, a DAB média foi de $10,51\text{mm} \pm 6,52\text{mm}$, e ao estimar a altura da caixa delimitadora usando o objeto de referência, a média da DAB por participante foi de $11,53\text{mm} \pm 6,43\text{mm}$. Ao estimar o MUAC a partir do raio médio do braço usando o objeto de referência, o DAB média foi de $7,24\text{mm} \pm 4,79\text{mm}$. A DAB média para todos os métodos ao usar a calibração da câmera foi 2 a 3mm menor.

^V <http://www.ifp.illinois.edu/~vuongle2/helen/>^{VI} <https://neerajkumar.org/databases/lfpw/>

Wei et al. (2016) ⁽¹⁰⁾	Abordagens de última geração para estimativa de pose humana articulada são embasadas em modelos hierárquicos com dependências que não possibilitam a captura de todas as interações entre partes do corpo. Embora modelos com interações mais complexas possam ser definidos, aprender os parâmetros desses modelos continua sendo um desafio. Neste trabalho, em vez de realizar inferências sobre um modelo gráfico aprendido, a estrutura da máquina de inferência é construída e um método para estimar a pose humana articulada é apresentado. Há a incorporação de interações espaciais ricas entre múltiplas partes e informações em partes de diferentes escalas. Além disso, a estrutura modular facilita a implementação sem necessidade de otimização especializada.	A contribuição deste trabalho é implicitamente modelar dependências de longo alcance entre variáveis em tarefas de predição estruturadas, tais como estimativa de posicionamento articulado. Uma arquitetura sequencial composta por redes convolucionais sendo capaz de aprender implicitamente modelos espaciais para pose humana, comunicando crenças cada vez mais refinadas, que preservam a incerteza entre os estágios. Problemas com dependências espaciais entre variáveis surgem em múltiplos domínios da visão computacional, como rotulagem de imagens semânticas, previsão de profundidade de imagem única e detecção de objetos. Esta abordagem alcança precisão de última geração em todos os <i>benchmarks</i> primários, incluindo as bases de dados MPII ^{VII} , LSP ^{VIII} e FLIC ^{IX} , com detecções acima de 84% em todos os casos. No entanto, são observados casos de falha principalmente quando várias pessoas estão próximas.
Jiang, Guo (2019) ⁽¹¹⁾	Implementar um sistema baseado em imagens de corpo inteiro para a estimação de peso. Avaliar a correlação entre as medidas antropométricas extraídas e os valores de IMC.	Uma base com 5900 imagens de 2950 pessoas é produzida, com a devida rotulagem quanto ao gênero, altura e peso. Cinco características antropométricas para imagens 2D frontais do corpo são propostas e medidas automaticamente por métodos computacionais (aprendizagem profunda): largura da cabeça, largura da cintura, largura do quadril, largura da coxa e área abdominal. A acurácia preditiva foi de 81% para a categoria obesa e 64% para sobrepeso (havia poucas amostras de pessoas abaixo do peso, resultando em baixo desempenho nestes casos).

sabe-se que o IMC é problemático por não fazer distinção de gênero, nem sempre refletir com exatidão a massa muscular, e resultar eventualmente em classificações distorcidas para crianças e idosos^X. Neste sentido, dentre centenas de fórmulas⁽³⁻⁴⁾, o IMR, ainda mais simples e praticamente sem custos, se apresentou mais próximo de resultados da densitometria⁽⁵⁾. Com base neste resultado, as medidas de altura e circunferência da cintura se tornam os principais parâmetros antropométricos de avaliação de gordura corporal, que poderiam ser observados por futuros sistemas de visão computacional.

Caso o interesse seja ainda o de estimar o IMC por fotografia, equações simples para massa e altura⁽⁵⁾, que dependem tão somente do uso de uma fita métrica, no caso virtualizada por relações de imagem, poderiam ser exploradas.

Outras abordagens envolvem a análise de faces humanas, partindo da premissa que são relacionadas com o peso⁽⁶⁻⁷⁾ ou mesmo com a altura⁽⁷⁾ de indivíduos, e apresentam resultados com acurácias acima de 80%. Nesta linha, o estado da arte para o problema de alinhamento de face é

destacado⁽⁸⁾, com testes sendo apresentados na Figura 2.

Outra frente de estudo requer a análise de imagens de corpo inteiro, de modo que, novamente, se possa virtualizar a ação de uma fita métrica, sem contato físico. Um método inicial seria a captura de fotos lateral e frontal para estimativa de altura e circunferência do braço⁽⁹⁾. Esta abordagem, no entanto, não é apropriada a pacientes com mobilidade comprometida. De modo a evitar fotografias em posições rígidas, buscou-se o estado da arte para detecção de poses humanas, a partir de uma única imagem sem qualquer calibração inicial⁽¹⁰⁻¹¹⁾. Acredita-se que tal ideia, associada ao alinhamento facial, se configuram como técnicas promissoras para avaliação de gordura e nutricional de cadeirantes, acamados ou pacientes com alguma impossibilidade motora. Na Figura 3, alguns testes iniciais são apresentados.

CONCLUSÃO

Medidas antropométricas são importantes para indicar o estado geral de saúde e nutrição em crianças e adultos.

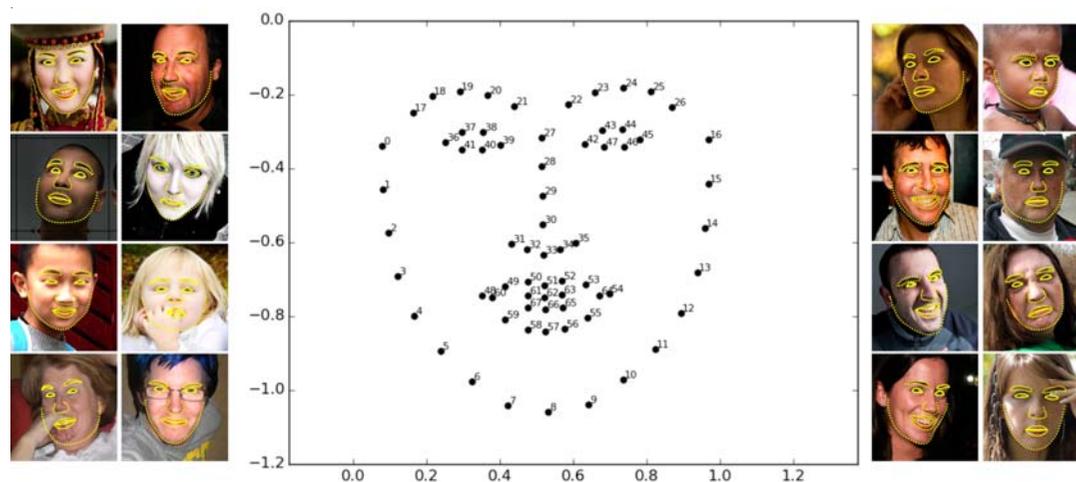


Figura 2 - Pontos de referência (*landmarks*) de faces (ao centro) e exemplos de resultados de aplicação do algoritmo de alinhamento de face, por conjunto de árvores de regressão [9], na base de dados HELEN (à esquerda e à direita) (Adaptado de <https://stackoverflow.com/> e de [9]).

^{VII} <http://human-pose.mpi-inf.mpg.de/>

^{VIII} <http://sam.johnson.io/research/lsp.html>

^{IX} <https://bensapp.github.io/flic-dataset.html>

^X <https://www.sciencelert.com/new-accurate-rfm-body-fat-measure-could-end-bmi-body-mass-index>



Figura 3 - Aplicação do método de máquinas de pose convolucional (*convolutional pose machines*)⁽¹⁰⁾ para a determinação de medidas antropométricas (Elaborada pelo autor, a partir de imagens obtidas de <https://bit.ly/2JWjsKC> , <https://bit.ly/2QHPRXK> , <https://bit.ly/2RJ9grE> , <https://bit.ly/2DgayX9>).

Métodos robustos, baratos e precisos são desejados. Inúmeros modelos efetuam a determinação indireta de massa, ou mesmo altura e IMC. Mais recentemente o IMR tende a se tornar um padrão na área por ser simples e mais próximo do exame DEXA. De modo a não exigir balança ou fita métrica, iniciativas baseadas no uso de

câmera fotográfica, sem contato físico e com possibilidade de monitoramento rápido, automático e constante, mesmo para pacientes com pouca mobilidade, começam a surgir. Resultados acurados de reconhecimento de faces e poses humanas podem ser adaptados e são promissores para a avaliação de gordura corporal de pacientes.

REFERÊNCIAS

1. Monteiro CA et al. Vigitel Brasil 2017: vigilância de fatores de risco e proteção para doenças crônicas por inquérito telefônico. Ministério da Saúde, Brasília; 2018. [Acesso 2019 Set 02]. Disponível em: <https://bit.ly/2QmT71x>
2. Kakinami L, Henderson M, Chiolerio A, Cole TJ, Paradis G. Identifying the best body mass index metric to assess adiposity change in children. *Arch Dis Child*. 2014 Nov;99(11):1020-4.
3. Woolcott OO, Bergman RN. Relative fat mass (RFM) as a new estimator of whole-body fat percentage % A cross-sectional study in American adult individuals. *Sci Rep*. 2018 Jul 20;8(1):10980.
4. Rativa D, Fernandes BJT, Roque A. Height and weight estimation from anthropometric measurements using machine learning regressions. *IEEE J Transl Eng Health Med*. 2018 Mar 29;6:4400209.
5. Rabito EI, Vannucchi GB, Suen VMM, Neto LLC, Marchini JS. Weight and height prediction of immobilized patients. *Rev Nutr., Campinas*. 2006;19(6):655-61.
6. Wen L, Guo G. A computational approach to body mass index prediction from face images. *Imag Vis Comput*. 2013; 31(5):392-400.
7. Dantcheva A, Bremond F, Bilinski P. Show me your face and I will tell you your height, weight and body mass index. *Proceedings of the 24th International Conference on Pattern Recognition ICPR*; 2018 Aug 20-24; Beijing, China. [Acesso 2019 Set 02]. Available from: <https://hal.inria.fr/hal-01799574/>
8. Kazemi V, Sullivan J. One millisecond face alignment with an ensemble of regression trees. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2018 Jun 22-28; Salt Lake City, USA. IEEE Computer Society; 2018. p.1867-74. Available from: <https://doi.org/10.1109/CVPR.2014.241>
9. Liu Y, Sowmya A, Khamis H. Single camera multi-view anthropometric measurement of human height and mid-upper arm circumference using linear regression. *PLoS ONE*. 2018; 13(4-e0195600):1-22.
10. Wei SE, Ramakrishna V, Kanade T, Sheikh Y. Convolutional pose machines. *Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2016 Jun 27-30; Las Vegas, USA. IEEE Computer Society; 2016. Available from: <http://arxiv.org/abs/1602.00134>
11. Jiang M, Guo G. Body weight analysis from human body images. *IEEE Transac Inform Forensics Security*. 2019;14(10):2676-88.