

Nome do Aluno: Fernando Fincatti

Nome do Orientador: Fabio de Miranda

Título: Mensuração de macronutrientes através de inteligência artificial.

Palavras-chave: diabetes, macronutrientes ,inteligência artificial, machine learning, deep learning, mobile

1. Descrição do Problema e Revisão de Literatura

O diabetes mellitus é uma doença crônica causada pelos altos níveis de glicose no sangue. Estudos realizados pela Organização Mundial da Saúde (OMS) apontam que 1 em cada 11 pessoas possui diabetes (LABOISSIÈRE, 2016), além disso, mais da metade da população brasileira, cerca de 55.7% (NEVES, 2015), possui excesso de peso, sendo assim predispostas a desenvolverem diabetes tipo 2.

O número de diabéticos vem crescendo nos últimos anos, em geral isso ocorre por uma má alimentação e dietas desregradadas, com abuso de gordura saturada e carboidratos. Existem inúmeras complicações causadas por esta doença em diversas partes do corpo, uma vez que a longo prazo a hiperglicemia afeta nervos e vasos sanguíneos, podendo levar ao óbito (“Complicações do diabetes”). Pode-se controlar a glicemia com alimentos de baixo impacto glicêmico e a obesidade com alimentos saciantes e de baixo conteúdo energético.

Nos últimos anos, diversas tecnologias, serviços e produtos surgiram para auxiliar os pacientes que sofrem com a doença. As soluções propostas variam desde produtos como medidores de glicemia contínuos, por exemplo o Abbot Libre (ABBOTT, 2020) (“Sistema Flash de Monitorização de Glicose FreeStyle Libre”), lentes de contato inteligentes para medição da glicemia via fluido lacrimal, desenvolvidas pelo Google (Santino), ou até mesmo serviços de acompanhamento para controle comportamental, como é o caso da startup Virta Health (VIRTA, 2020). Entretanto o mercado carece de soluções que auxiliem o paciente na tomada de decisão e que tornem visível o impacto imediato e a longo prazo das consequências do comportamento alimentar. Isso pode ser feito por exemplo estimando o impacto glicêmico e calórico das refeições.

Neste contexto, foram encontradas algumas tecnologias para suprir tal necessidade, em geral, softwares que utilizam *machine* e *deep learning*, sistemas que podem, através dos sensores de câmera, estimar macronutrientes em uma refeição, além de projetar o efeito esperado do comportamento alimentar atual, sendo possível auxiliar os usuários no emagrecimento, ganho de massa muscular etc.

Alguns exemplos de soluções existentes são: Snap-n-Eat (ZHANG, Weiyu et al.; 2015) e Im2Calories (MEYERS, Austin et al.; 2015). Ambos os modelos são sistemas que surgem com a proposta de uma aplicação mobile, ou seja, foram desenvolvidos para serem aplicativos de celular que utilizam técnicas de inteligência artificial para atingir seus objetivos. O Snap-n-Eat utiliza a câmera do celular para fazer estimativas de quantidade de nutrientes sem a necessidade de qualquer intervenção do usuário. O Im2Calories possui o mesmo princípio, entretanto é limitado a um cardápio específico.

Ambos os exemplos supracitados adotaram simplificações durante seu desenvolvimento e poderiam ser aperfeiçoados ou continuados. No software Snap-n-Eat, por exemplo, foi limitado o desempenho do mesmo devido a razões computacionais, além disso, para que o app se torne realista, seria necessário uma maior quantidade de categorias de alimentos, uma vez que atualmente possui apenas 15, como por exemplo sanduíches, carnes, frutas e vegetais. O Im2Calories, como dito acima, possui uma simplificação que faz com que o software seja aplicado a cardápios de restaurantes pré-definidos (nutritionix), facilitando o desempenho do algoritmo.

2. Objetivo

Nesse projeto o objetivo é desenvolver um software para ajudar pacientes que sofrem com diabetes. Isso será feito focando no problema de estimar parte dos macronutrientes das refeições. Portanto a pesquisa consiste em desenvolver um sistema que reconhece tipos de alimentos e estima a quantidade de carboidratos, gorduras e calorias através de uma imagem capturada pela câmera do smartphone.

A pesquisa será baseada no estudo de *machine learning* e visão computacional, área responsável pela interpretação e processamento de imagens e vídeos.

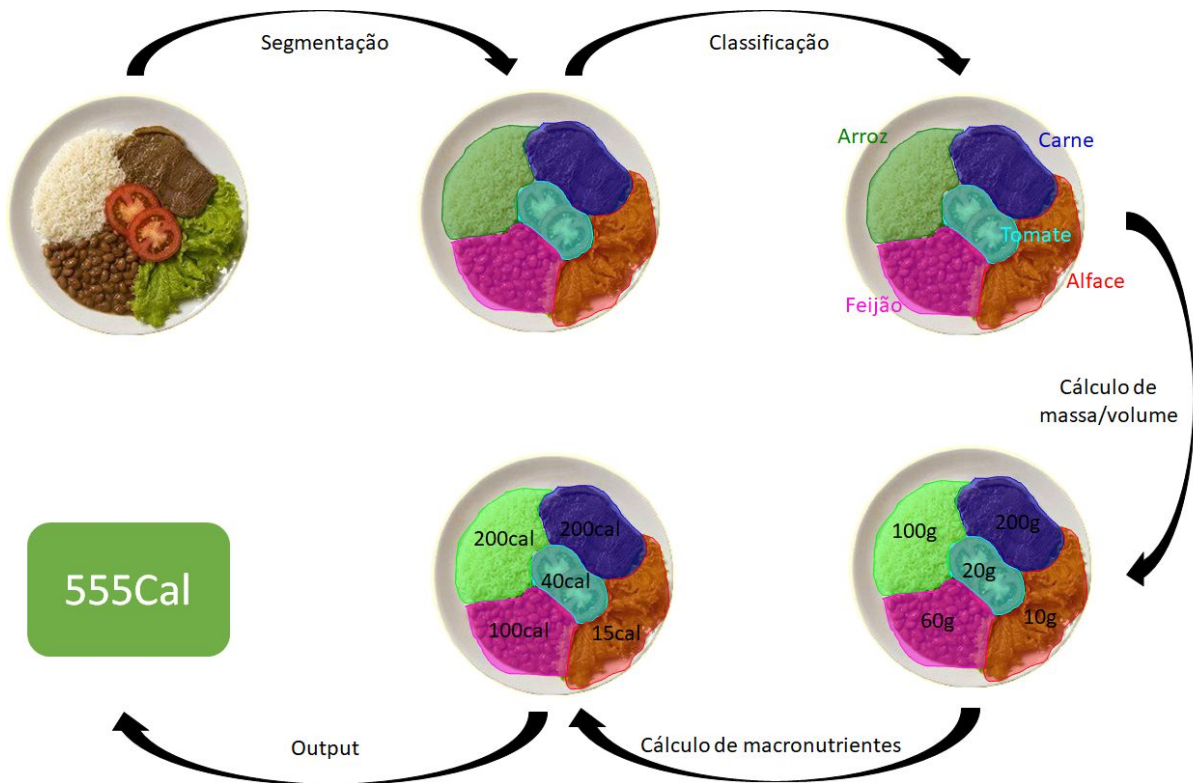
3. Metodologia

Para estimar os nutrientes presentes na refeição, será necessário dividir a pesquisa em 3 partes:

1. **Segmentação da imagem:** nesta etapa serão utilizadas técnicas para separar os alimentos na imagem capturada. Para uma aplicação baseada em *machine learning* Isso pode ser feito utilizando características similares dos alimentos, como cor, textura e tamanho (DOULAH, Abul; SAZONOV, Edward. 2015) ou podem ser utilizados algoritmos de clusterização, como por exemplo o K-means. Para uma aplicação em *deep learning* essa etapa será feita automaticamente pela técnica.
2. **Classificação dos alimentos:** uma vez segmentados, através de modelos de *deep learning* ou *machine learning*, os alimentos da imagem serão identificados para que, após um cálculo de seu volume, seja possível estimar os macronutrientes;
3. **Cálculo do volume:** o cálculo do volume será feito para enfim estimar os macronutrientes. Isso pode ser feito contando o número de pixels correspondente a cada um dos alimentos, como feito no aplicativo Snap-n-eat.

Para disponibilizar e desenvolver o software, será utilizado a plataforma Jupyter Notebook. Dessa forma será desenvolvido um arquivo que fará os cálculos com base em uma imagem escolhida pelo usuário. A Figura1 ilustra um esquema de como funcionará o processo.

Figura1 - Esquemático do processo de estimação de macronutrientes



fonte: desenvolvido pelo autor

Para desenvolver o sistema proposto, será necessário estudo preliminar em redes neurais, mais especificamente *deep learning* e técnicas de *machine learning*, com os objetivos de aprendizado e seleção de técnica para construção do protótipo.

Inicialmente, serão construídos modelos de ambas as técnicas (*machine learning* e *deep learning*), isso pois cada um possui suas vantagens e desvantagens, dessa forma será avaliado o desempenho de cada um. A tabela1 a seguir apresenta algumas das vantagens e desvantagens de cada modelo:

Tabela1 - Comparação entre Deep Learning e Machine Learning

	Vantagens	Desvantagens
Deep Learning	<ol style="list-style-type: none"> 1. Em geral, possui um desempenho superior comparado aos algoritmos de <i>machine learning</i>; 2. A seleção de características necessárias para resumir a imagem já é feita automaticamente 	<ol style="list-style-type: none"> 1. Exige uma quantidade muito maior de dados para funcionar com desempenho razoável; 2. Exige maior capacidade de processamento computacional
Machine Learning	<ol style="list-style-type: none"> 1. Exige uma menor quantidade de dados 	<ol style="list-style-type: none"> 1. Em geral, possui menor desempenho comparado aos algoritmos de <i>deep learning</i>; 2. É necessário resumir a imagem de alguma forma, seja por histogramas ou features extractors (bordas, quinas, gradientes, etc); 3. Tipicamente precisam de uma técnica de reduzir dimensionalidade

A programação para avaliação da alternativa *deep learning* será baseada em Python e serão avaliadas alternativas implementadas com as seguintes bibliotecas:

- **Tensorflow:** biblioteca criada pelo Google para computação numérica, contém algoritmos que facilitam a criação de um modelo de redes neurais.
- **Pytorch:** biblioteca desenvolvida pelo Facebook, têm como principal função o uso de modelos de aprendizado de máquina, utilizada principalmente em apps de visão computacional.

Para treinar um modelo de inteligência artificial como o proposto acima, é necessário uma quantidade grande de dados, portanto algumas bases de dados com imagens de alimentos serão necessárias no decorrer do processo. Nesse projeto, serão utilizadas as imagens fornecidas pela ImageNet, que possui 14 milhões de imagens com 200 categorias distintas, e FoodB.

4. Resultados Esperados

Como resultado da pesquisa, esperamos construir um arquivo baseado em Python, o qual será capaz de estimar parte dos macronutrientes de algumas categorias de alimentos, através de uma imagem 2D capturada por um usuário.

O resultado será publicado no GitHub de modo *Open Source*. Esperamos divulgar nosso trabalho em simpósios de de iniciação científica, além de Meetups.

5. Referências bibliográficas

BD and CO. Complicações do diabetes. *Beckton Dickinson & Company*. Disponível em <https://www.bd.com/pt-br/our-products/diabetes-care/diabetes-learning-center/diabetes-education/complications>. Acesso em: 25 de out. de 2020.

ZHANG, Weiyu et al. “snap-n-eat” food recognition and nutrition estimation on a smartphone. *Journal of diabetes science and technology*, v. 9, n. 3, p. 525-533, 2015.

MEYERS, Austin et al. Im2Calories: towards an automated mobile vision food diary. In: *Proceedings of the IEEE International Conference on Computer Vision*. 2015. p. 1233-1241.

DOULAH, Abul; SAZONOV, Edward. Clustering of food intake images into food and non-food categories. In: *International Conference on Bioinformatics and Biomedical Engineering*. Springer, Cham, 2017. p. 454-463.

VIRTA. Diabetes affects your health every day. Your medical care should do the same. *Virta Health*. Disponível em <https://www.virtahealth.com/howitworks>. Acesso em 25 de out. de 2020.

LABOISSIÈRE, Paula. “Uma em cada 11 pessoas no mundo tem diabetes, alerta OMS.” *Agência Brasil*. 14 de nov de 2016. Disponível em <https://agenciabrasil.ebc.com.br/geral/noticia/2016-11/uma-em-cada-11-pessoas-no-mundo-tem-diabetes-alerta-oms#:~:text=Uma%20em%20cada%2011%20pessoas,diabetes%2C%20alerta%20OMS%20%7C%20Ag%C3%A2ncia%20Brasil>. Acesso em 25 out 2020.

Neves, Úrsula. “Mais da metade dos brasileiros está acima do peso e 20% obesos, alerta Ministério da Saúde.” *pebmed*, 15 03 2015,
<https://pebmed.com.br/mais-da-metade-dos-brasileiros-esta-acima-do-peso-e-20-obesos-alerta-ministerio-da-saude/>. Acesso em 25 out 2020.

Santino, Renato. “Tecnologia no seu olho: saiba o que lentes de contato inteligente podem fazer.” *olhardigital*, 01 08 2019,
<https://olhardigital.com.br/noticia/tecnologia-no-seu-olho-saiba-o-que-lentes-de-contato-inteligente-podem-fazer/88634>. Acesso em 25 out 2020.

ABBOTT Pharmaceutical. “Sistema Flash de Monitorização de Glicose FreeStyle Libre.” *freestylediabetes*,
<https://www.freestylediabetes.pt/nossos-produtos/gama-de-produtos/freestyle-libre?jjj=1603636736814>. Acesso em 25 out 2020.

nutritionix. “We offer a customized meal-building experience for the following restaurant chains.” *Nutritionix Calculators*,
<https://www.nutritionix.com/consumer/nutrition-calculator>. Acesso em 31 out 2020.

Cronograma de atividades

	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
Estruturação e estudo das bases de dados	■										
Estudo de técnicas de aprendizado de máquina e treinamentos de modelos.		■	■	■	■	■	■	■	■	■	
Avaliação de desempenho e aplicação de possíveis melhorias				■	■				■	■	
Atividade de escrita de relatório					■					■	■