

Estimando calorias em alimentos usando aprendizado de máquina

Cleanio Talmo de Queiroz Paiva
Engenharia de Software, Ufersa
Martins, Brasil
cleanio.paiva@alunos.ufersa.edu.br

Silvio Martins Santos
Engenharia de Software, Ufersa
Pereiro, Brasil
silvio.santos@alunos.ufersa.edu.br

Rosana Cibely B. Rego
Departamento de Engenharias e
Tecnologia, Ufersa
Pau dos Ferros, Brasil
rosana.rego@ufersa.edu.br

Abstract – This work explores the integration of technology and nutrition through the prediction of calories in foods based on their nutrients. To achieve this, machine learning models were developed, including recursive feature elimination and multilayer perceptron neural networks, aimed at predicting the caloric content from the nutrient values present in food. The neural network model stood out, demonstrating performance with a Mean Squared Error (MSE) of 142.94, a Mean Absolute Error (MAE) of 5.88, and an R^2 of approximately 99.5%. Furthermore, the application of Explainable Artificial Intelligence techniques allowed for a better understanding of the impact of each nutrient on the caloric predictions, contributing to greater transparency and trust in the models.

Keywords – neural networks, machine learning, calorie prediction, multilayer perceptron

Resumo – Este trabalho explora a integração entre tecnologia e nutrição por meio da predição de calorias em alimentos com base em seus nutrientes. Para isso, foram desenvolvidos modelos de aprendizado de máquina, incluindo eliminação recursiva de atributos e redes neurais perceptron multicamadas, com o objetivo de prever a quantidade de calorias a partir dos valores dos nutrientes presentes no alimento. O modelo de rede neural destacou-se, demonstrando um desempenho com um MSE de 142,94, um MAE de 5,88 e um R^2 de aproximadamente 99,5%. Além disso, a aplicação de técnicas de Inteligência Artificial Explicável permitiu compreender o impacto de cada nutriente na predição das calorias, contribuindo para uma maior transparência e confiança nos modelos.

Palavras chaves – redes neurais, aprendizado de máquina, predição de calorias, perceptron multicamadas

I. INTRODUÇÃO

A nutrição desempenha um papel fundamental na promoção da saúde e na prevenção de doenças, sendo um dos principais pilares para a manutenção do bem-estar ao longo da vida. Uma alimentação equilibrada está diretamente associada à redução do risco de doenças crônicas, como obesidade, diabetes, doenças cardiovasculares e câncer, que estão entre as principais preocupações de saúde global [1].

Embora os estudos indiquem consequências graves para a saúde associadas à obesidade, sua ocorrência continua a crescer. Esse aumento pode ser atribuído, em parte, às mudanças na dieta, como a maior disponibilidade de alimentos ultra processados e baratos, mais saborosos e ricos em energia. Esses alimentos, por serem mais palatáveis, tendem a ser consumidos em porções maiores, o que contribui para o ganho de peso e, conseqüentemente, eleva os riscos à saúde [2]. Por isso, conhecer o valor nutricional dos alimentos, como proteínas, lipídios e carboidratos, e estimar o valor calórico associado, é essencial tanto para consumidores que desejam manter uma dieta saudável quanto para profissionais da saúde que buscam otimizar dietas e intervenções nutricionais.

Em alguns casos, a quantidade exata de calorias de um alimento pode ser difícil de determinar com base apenas em informações superficiais, como o teor de água, proteínas ou lipídios. Desenvolver modelos que possam preencher essas lacunas é essencial para auxiliar tanto consumidores quanto profissionais de saúde. O processo de rastreamento de calorias nos alimentos pode ser trabalhoso. Ele exige que o usuário faça um controle diário dos alimentos e realize cálculos complicados para estimar a quantidade de calorias consumidas em cada item de sua refeição [3].

Neste trabalho, propomos um modelo de *machine learning* para estimar a quantidade de calorias de alimentos com base em suas informações nutricionais tomando como base uma extensa base de dados. Utilizando técnicas como eliminação recursiva de atributos e redes neurais, nosso objetivo é facilitar a compreensão do valor calórico dos alimentos, ajudando tanto consumidores que busquem avaliar melhor sua própria dieta, quanto profissionais de saúde a fazerem escolhas mais informadas. Este modelo analisa nutrientes como água, proteínas e gorduras para realizar suas previsões, oferecendo uma ferramenta poderosa e acessível para o controle da dieta.

II. TRABALHOS RELACIONADOS

A busca por métodos eficientes para classificar alimentos utilizando modelos de redes neurais tem incentivado a produção de diversos estudos. Nesse contexto, é relevante analisar os resultados e métodos obtidos em

pesquisas anteriores para compará-los com o presente trabalho.

Um dos estudos encontrados utiliza imagens para estimar o conteúdo calórico dos alimentos, uma abordagem particularmente promissora para avaliações dietéticas. A pesquisa realizada por Miyazaki, De Silva e Aizawa (2011) apresenta um sistema de gestão dietética baseado na web que usa imagens capturadas por usuários para estimar a quantidade de calorias em suas refeições. Nesse estudo, foi construído um conjunto de dados denominado *FoodLog*, composto por 6.512 imagens, nas quais o conteúdo calórico foi estimado por especialistas em nutrição. A comparação entre a imagem de entrada e os dados de referência foi realizada utilizando várias características de imagem, como histogramas de cores, correlogramas de cores e recursos SURF, sendo a estimativa calórica final obtida por um modelo de regressão linear baseado nas similaridades identificadas. A Figura 1, mostra um dos experimentos onde há um resultado de amostra para dois sanduíches diferentes.

Apesar da inovação, os resultados obtidos pelo sistema de Miyazaki, De Silva, e Aizawa (2011) mostram uma precisão limitada, pois apenas 35% das estimativas de calorias estavam corretas dentro de uma margem de erro de mais ou menos 20%, e 79% dentro de mais ou menos 40%.

A correlação entre o valor estimado e o valor verdadeiro foi relativamente baixa (0.32), sugerindo que melhorias, como segmentação de imagem para identificar diferentes pratos em uma mesma fotografia, são necessárias para aumentar a acurácia e a estimativa calórica.



		
	<i>turkey breast</i>	<i>roast beef</i>
Actual	310 grams 450 calories	310 grams 530 calories
Predicted	309.966 grams 450.219 calories	310.08 grams 528.5218 calories

Figura 1. Amostra experimental. (Miyazaki, De Silva, & Aizawa, 2011)

Em contraste, o modelo proposto neste trabalho utiliza técnicas que visam aumentar a precisão na predição de calorias, baseando-se em parte dos dados nutricionais detalhados e da composição de cada elemento, oferecendo assim uma solução mais robusta e eficaz para o controle dietético.

O presente estudo utiliza um *dataset* disponibilizado pelo site *Kaggle*¹, que contém um arquivo chamado *ABBREV.csv*, uma base de dados abrangente compilada pelo *United States Department of Agriculture (USDA)*. Essa base de dados contém informações detalhadas sobre os valores nutricionais de milhares de alimentos, incluindo calorias, vitaminas, minerais e outros nutrientes essenciais [5]. Podemos ver tal base de dados como ferramenta de grande utilidade para a análise nutricional, e, neste trabalho, será utilizada como base para o desenvolvimento de um modelo de predição de calorias. A importância, quantidade e diversidade dos dados disponíveis possibilitam uma análise aprofundada do conteúdo nutricional dos alimentos, contribuindo para a construção de modelos precisos e aplicáveis a diferentes necessidades dietéticas. Conforme observado em pesquisas que destacam o crescente volume e diversidade dos dados na área de saúde, técnicas modernas de *machine learning* têm sido essenciais para extrair informações valiosas de grandes bases de dados, especialmente em modelos preditivos [6].

A base de dados utilizada neste projeto consiste em um arquivo com 54 colunas que fornecem informações nutricionais detalhadas sobre mais de 8.700 alimentos. Em um primeiro momento, todos os nomes das colunas foram renomeados para padronizar e tornar os nomes mais intuitivos, facilitando o manuseio dos dados. Em seguida, foram removidas colunas irrelevantes como por exemplo, a coluna que representa o índice, a coluna que referencia o estudo dos alimentos pela USDA e registros com valores ausentes.

Embora a base de dados *ABBREV*, do *USDA*, forneça um conjunto robusto de informações nutricionais sobre alimentos consumidos nos Estados Unidos, é importante destacar que a composição dos alimentos pode variar significativamente entre diferentes países. No Brasil, muitos alimentos possuem variações regionais nos métodos de preparo, ingredientes e processamento, o que pode influenciar diretamente os valores nutricionais, incluindo o teor de calorias, gorduras, proteínas, entre outros. Essas variações precisam ser consideradas ao aplicar modelos de aprendizado de máquina treinados com bases de dados internacionais. Por isso, os resultados apresentados neste estudo refletem a realidade dos alimentos consumidos nos Estados Unidos e podem não ser diretamente aplicáveis à realidade brasileira sem ajustes. Um passo futuro essencial seria a adaptação do modelo a bases de dados brasileiras, para aumentar a confiabilidade dos resultados no contexto local.

Para a construção de um modelo de predição de calorias eficiente, foi necessário selecionar as características mais relevantes entre as diversas informações nutricionais e descritivas presentes no *dataset*. Para essa tarefa, optou-se pelo uso da Eliminação Recursiva de Atributos (*Recursive*

III. MÉTODO

¹ <https://www.kaggle.com/>

Feature Elimination - RFE) que é baseado no algoritmo *Random Forest*.

O *Random Forest* possui uma capacidade de lidar com conjuntos de dados de alta dimensionalidade e por ser um método robusto contra *overfitting*, por conta da utilização de múltiplas árvores de decisão construídas a partir de diferentes subconjuntos de dados. Além disso, o *Random Forest* também tem a vantagem de fornecer estimativa da importância de cada característica, o que torna especialmente adequado para o processo de seleção de atributos [7][8]. Por esse motivo, a técnica RFE foi implementada baseada no algoritmo do *Random Forest*.

A RFE utiliza o modelo *Random Forest* para avaliar a importância das características e, iterativamente, elimina as menos importantes até alcançar o número desejado de variáveis. No caso deste estudo, o RFE foi aplicado com o modelo de *Random Forest* para selecionar as 10 variáveis mais significativas para a previsão de calorias [9].

Após a seleção das 10 características mais relevantes utilizando RFE, os dados selecionados foram normalizados para garantir que para garantir que estivessem na mesma escala. Essa etapa é crucial para o desempenho dos modelos de *machine learning* baseados em redes neurais, que são sensíveis à quantidade e variabilidade das variáveis de entrada.

Com os dados devidamente separados e normalizados, foi desenvolvido um modelo de rede neural *Multilayer Perceptron* (MLP) utilizando o *TensorFlow*. Vários modelos foram testados, sendo que o modelo com o melhor desempenho possui uma arquitetura sequencial composta por múltiplas camadas densas. A primeira camada densa foi configurada com 128 neurônios utilizando a função de ativação *Rectified Linear Unit* (ReLU), seguida por camadas subsequentes com 64 e 32 neurônios, respectivamente. A função de ativação ReLU foi escolhida por sua eficiência em redes *feedforward* e por ter apresentado o melhor desempenho nos testes, enquanto a camada final foi configurada com uma única unidade de saída linear, adequada para o problema de regressão [10].

Um dos métodos para evitar o *overfitting* no modelo foi a adição de uma pequena taxa de *dropout* que foi aplicada após as duas primeiras camadas, o que ajuda a regularizar o modelo durante o treinamento [7]. Além disso, o otimizador Adam (Estimativa de Momento Adaptativo) foi utilizado com uma taxa de aprendizado para 0.001 [12].

O treinamento do modelo foi monitorado utilizando a técnica de *early stopping*, com base na perda de validação. Este procedimento garante que o modelo seja aquele que apresenta o melhor desempenho de dados não vistos, evitando o treinamento excessivo do modelo.

Ao final do treinamento, as métricas de desempenho, como o erro médio quadrático (*mean squared error*, MSE) e o valor de perda ao longo das épocas, foram salvas para uma análise posterior juntamente com o modelo final [7]. A Figura 2 mostra uma forma de abstração do modelo MLP implementado e descrito anteriormente.




Figura 2 .Modelo. Fonte: autoria própria.

A. Treinamento do modelo

Tendo como objetivo realizar o treinamento do modelo descrito na seção anterior, o dataset foi dividido em outros arquivos contendo dados de treino e de teste, onde 80% dos dados foram destinados para treinamento do modelo, e 20% dos dados foram para teste.

O processo de treinamento de uma rede neural consiste em iterar através de múltiplas épocas, ajustando os pesos para minimizar os erros. Não há um número ideal de épocas universalmente aceito para o treinamento de redes neurais. Uma quantidade insuficiente de épocas pode resultar em *underfitting*, enquanto um número excessivo pode causar *overfitting* [13].

Para mitigar esses problemas, foi adotada a estratégia de *Early Stopping*. Isso envolve a avaliação da precisão da classificação nos dados de validação ao final de cada época, utilizando a entropia cruzada como métrica. Quando a métrica para de melhorar, o treinamento é interrompido para evitar o *overfitting* [13].

No modelo, a decisão foi interromper o treinamento após 35 épocas consecutivas sem melhoria na métrica de desempenho, garantindo que o modelo com o melhor desempenho durante o treinamento fosse salvo. Essa abordagem minimiza o risco de encerrar o processo prematuramente, permitindo que o treinamento continue até que melhorias adicionais não sejam mais possíveis.

B. Métricas de desempenho

O Mean Squared Error (MSE) é uma das métricas utilizadas para avaliar o modelo presente neste trabalho, que mede a média dos quadrados dos erros, ou seja, a diferença entre os valores reais e os valores previstos ao quadrado [13]. Quanto menor o MSE, melhor o modelo está ajustado aos dados. A equação do MSE é dada por (1).

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

Outra métrica utilizada para medir a precisão do modelo foi o Mean Absolute Error (MAE), essa métrica calcula a média das diferenças absolutas entre os valores reais e os valores previstos. Diferente do MSE, o MAE não dá mais peso a erros maiores, o que o torna uma métrica mais intuitiva para interpretação. Sua equação é dada por (2).

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

A terceira métrica utilizada para a avaliação do modelo foi o Coeficiente de Determinação (R^2) é uma métrica que indica o quão bem os valores previstos se ajustam aos valores reais. O R^2 foi calculado para avaliar o poder explicativo do modelo, demonstrando a proporção da variabilidade dos dados que é capturada pelo modelo [13]. Ele varia de 0 a 1, onde 1 indica um modelo perfeito. A equação do R^2 é dada por (3):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

IV. RESULTADOS

A construção do modelo de classificação envolve diversas fases. Inicialmente, realizou-se a seleção de atributos na Seção IV-A. Subsequentemente, a avaliação do modelo, descrita na Seção IV-B, foi efetuada para verificar o desempenho do modelo treinado. E por fim IV-C, é possível ver algumas interpretações sobre os resultados do modelo criado.

A. Seleção de atributos

Abaixo segue o nome da coluna (*atributo*) selecionado com algoritmo RFE e sua descrição em relação ao alimento.

1. água_g: Quantidade de água (g);
2. lipídios_g: Quantidade total de lipídios (g);
3. ash_g: Quantidade de cinzas no alimento (g), aqui se refere a resquícios de minerais inorgânicos após o aquecimento do alimento;
4. carboidratos_g: Quantidade de carboidratos (g);
5. fibra_g: Quantidade de fibras dietéticas totais (g).
6. cálcio_mg: Quantidade de cálcio (mg).
7. potássio_mg: Quantidade de potássio (mg).
8. sódio_mg: Quantidade de sódio (mg).
9. gordura_saturada_g: Quantidade de gordura saturada (g).
10. gordura_monoinsaturada_g: Quantidade de gordura monoinsaturada (g).

B. Avaliação do modelo

A convergência do modelo durante o treinamento pode ser observada no Gráfico 1, onde a perda (loss) do modelo diminui progressivamente ao longo das épocas. Essa diminuição indica que o modelo foi capaz de aprender de forma eficaz, minimizando os erros quadráticos ao longo do tempo, o que contribuiu para a obtenção de um MSE relativamente baixo no conjunto de testes [13].




Gráfico 1. Evolução da perda durante o treinamento. Fonte: autoria própria.

Além disso, o Gráfico 2 oferece uma visualização clara da precisão das previsões do modelo ao comparar os valores reais com os valores previstos, utilizando os dados de teste. Neste gráfico de dispersão, os pontos estão majoritariamente alinhados à linha vermelha pontilhada, que representa a situação ideal onde os valores previstos são iguais aos valores reais. A proximidade dos pontos a essa linha sugere que o modelo possui uma boa capacidade preditiva, reforçando a eficácia do ajuste observado através do MSE. Essa visualização é fundamental para compreender a qualidade das previsões do modelo em termos de acurácia e consistência.

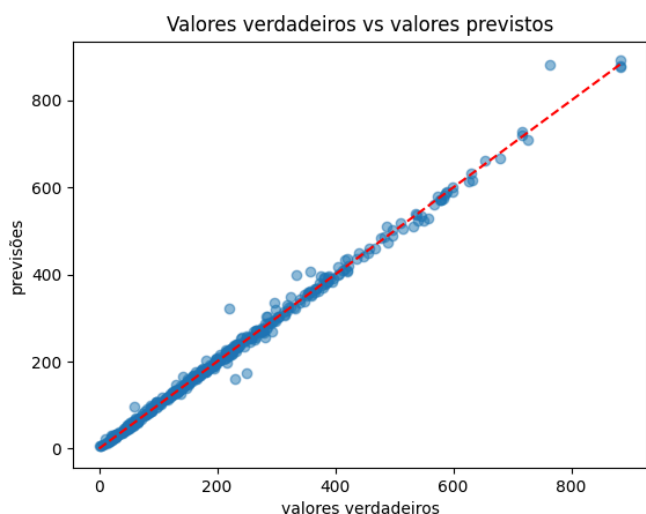


Gráfico 2. Comparação entre valores reais e valores previstos. Fonte: autoria própria.

Os valores obtidos de cada equação de cada métrica mencionada que avaliam o modelo podem ser visualizados logo abaixo, na Tabela 1.

MSE	MAE	R ²
142.9362	5.8846	0.9947

Tabela 1. Métricas: Fonte: autoria própria

O valor do MSE indica que, em média, o quadrado das diferenças entre os valores reais e os previstos é relativamente baixo, sugerindo um bom desempenho do modelo. Um MSE desse valor implica que o modelo consegue realizar previsões bastante próximas dos valores reais na maioria dos casos, ainda que alguns erros possam ter maior impacto devido ao fato de o erro ser elevado ao quadrado [13].

O valor obtido pelo MAE indica que a média dos erros absolutos entre as previsões e os valores reais é inferior a 6 calorias. Isso sugere que o modelo faz previsões com uma precisão média muito boa, e os erros nas previsões são pequenos em magnitude, o que é desejável em problemas de predição de calorias [13].

O valor da métrica R² atingiu um valor próximo à 0.995, o que significa que o modelo é capaz de explicar aproximadamente 99,5% da variabilidade presente nos dados de teste. Esse valor muito próximo de 1 sugere que o modelo possui um excelente ajuste aos dados e tem uma boa confiabilidade para realizar previsões de calorias com base nas características nutricionais fornecidas [13].

C. Interpretação dos Resultados

Para entender melhor a importância das características no modelo, foram gerados três gráficos usando a biblioteca SHAP. Estes gráficos ajudam a visualizar como cada característica influencia as previsões e fornecem uma compreensão detalhada da explicabilidade do modelo.

O Gráfico 3 exibe a importância média das características na predição das calorias, representada por um gráfico de barras. Neste gráfico, cada barra representa a média dos valores SHAP para uma característica específica, indicando a influência geral de cada característica nas previsões do modelo [14]. As características com barras maiores, como a *água* têm um impacto mais significativo nas previsões, proporcionando uma visão clara de quais atributos são mais relevantes para o modelo.

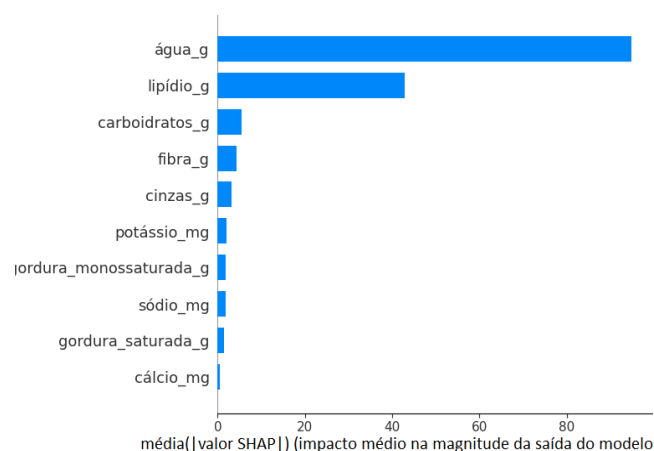


Gráfico 3. Importância das características. Fonte: dados do modelo.

O Gráfico 4 mostra a distribuição dos valores SHAP em um formato de dispersão. Cada ponto no gráfico representa o valor SHAP de uma observação para uma característica específica. Este gráfico ilustra como as características influenciam as previsões do modelo em diferentes magnitudes e direções. A dispersão dos pontos ao redor da linha central pode ajudar a identificar padrões e outliers na influência das características [14].

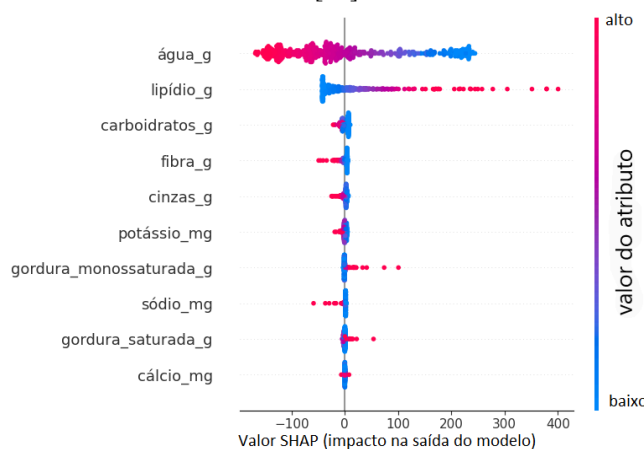


Gráfico 4. Distribuição dos valores. Fonte: Dados do modelo.

O Gráfico 5 exibe a dependência dos valores SHAP da característica *água* e como ela interage com a característica *lipídios*. Esse gráfico ajuda a entender como as mudanças na característica *água* afetam a previsão, levando em consideração a interação com outra característica. A visualização das interações entre características pode revelar como diferentes atributos combinam suas influências nas previsões do modelo [14], [15]. Neste caso específico, pode-se inferir que o gráfico sugere que a água tem uma influência menor ou até pode contribuir para a redução dos níveis de lipídios, dentro deste contexto particular.




Gráfico 5. Impacto água vs lipídio. Fonte: Dados do modelo.

V. CONCLUSÃO

Neste trabalho, foi desenvolvido um modelo de rede neural para a predição de calorias em alimentos, abordando um problema de regressão. Inicialmente, foram realizados os ajustes necessários no *dataset* utilizado. Em seguida, aplicou-se o algoritmo *RFE* para selecionar as características mais relevantes dos dados, baseando o modelo nessas características selecionadas. Diversos modelos foram analisados e testados até que se encontrasse o que apresentou o melhor desempenho conforme as métricas estabelecidas. O gráfico da função de perda demonstra que as curvas de treinamento e validação convergem para valores próximos após um certo ponto, resultando em um MSE de aproximadamente 142,93 para o modelo escolhido. Além disso, as outras métricas confirmam a eficiência do modelo. Foi possível também entender a interação entre as variáveis e sua influência nas previsões de calorias utilizando a ferramenta SHAP.

Para trabalhos futuros, recomenda-se a adaptação do modelo para incluir um maior número de variáveis de entrada, ou até mesmo todos os componentes nutricionais disponíveis na base de dados. Além disso, deve-se buscar aprimorar as métricas de avaliação, focando na melhoria do MSE, MAE e R^2 . Isso pode ser alcançado por meio de técnicas como ajuste de hiperparâmetros, validação cruzada para otimização do modelo, experimentação com diferentes

algoritmos de aprendizado de máquina, ou a inclusão de técnicas de regularização para evitar o sobreajuste.

VI. REFERÊNCIAS

- [1] World Health Organization(WHO). Healthy diet. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/healthy-diet>. Acesso em: 12 ago. 2024.
- [2] BRUNSTROM, Jeffrey M.; ROGERS, Peter J. How many calories are on our plate? Expected fullness, not liking, determines meal-size selection. *Obesity*, v. 17, n. 10, p. 1884-1890, 2009.
- [3] ELBEL, Brian. Consumer estimation of recommended and actual calories at fast food restaurants. *Obesity*, v. 19, n. 10, p. 1971-1978, 2011. Acesso em: 15 ago. 2024.
- [4] MIYAZAKI, Tatsuya; DE SILVA, Gamhewage C.; AIZAWA, Kiyoharu. Image-based calorie content estimation for dietary assessment. In: IEEE International Symposium on Multimedia, 2011, Dana Point IEEE, 2011. p. 363-368.
- [5] The Nutritional Content of Food - A Comprehensive [recurso eletrônico]. Disponível em: <https://www.kaggle.com/datasets/thedevastator/the-nutritional-content-of-food-a-comprehensive>. Acesso em: 15 ago. 2024.
- [6] LUO, Wei et al. Guidelines for developing and reporting machine learning predictive models in biomedical research: a multidisciplinary view. *Journal of Medical Internet Research*, v. 18, n. 12, p. e323, 2016.
- [7] Data Science Academy. Deep Learning Book, 2022. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 17 ago. 2023.
- [8] JAVEED, Arshad; ZHOU, Shuang; YONGJIAN, Liu; QASIM, Irfan; NOOR, Ahmad; NOUR, Rehan. An intelligent learning system based on random search algorithm and optimized random forest model for improved heart disease detection. *IEEE Access*, v. 7, p. 180235-180243, 2019.
- [9] SCIKIT-LEARN. `sklearn.feature_selection.RFE`. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.RFE.html. Acesso em: 17 ago. 2024.
- [10] TensorFlow. An end-to-end open source machine learning platform. Disponível em: <https://www.tensorflow.org/?hl=pt-br>. Acesso em: 15 ago. 2024.
- [11] CARVALHO, André Ponce de Leon F. de. Redes Neurais Artificiais, 2009. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 17 de ago. 2024.
- [12] HARRISON, Matt. Machine Learning – Guia de Referência Rápida: Trabalhando com dados estruturados em Python. (2019). Brasil: Novatec Editora. Brasil: Novatec Editora, 2019.

[13] PEREIRA, Daiane M.; COUTO, Rodrigo S. Predição de métricas em grafos temporais utilizando redes neurais. In: Anais do XX Workshop em Desempenho de Sistemas Computacionais e de Comunicação. SBC, 2021. p. 84-95.

[14] SHAP. SHAP Documentation. Disponível em: <https://shap.readthedocs.io/en/latest/>. Acesso em: 18 ago. 2024.

[15] DA ROCHA FERNANDES, Anita Maria; PINHEIRO, Marcel Borges; NAZÁRIO, Abraão Gualberto. Aplicação de Algoritmos de Aprendizado de Máquina no Apoio a Elaboração de Planos Nutricionais. Brazilian Journal of Development, v. 6, n. 8, p. 60935-60944, 2020.