

**Aplicação de Algoritmos de Aprendizado de Máquina no Apoio a Elaboração de Planos Nutricionais****Application of Machine Learning Algorithms to Support the Development of Nutritional Plans**

DOI:10.34117/bjdv6n8-492

Recebimento dos originais: 08/07/2020

Aceitação para publicação: 24/08/2020

**Anita Maria da Rocha Fernandes**

Dra. em Engenharia de Produção

Instituição: UNIVALI – Universidade do Vale do Itajaí – Campus Kbrasol/São José

Endereço: Rod. BR-101, km. 207, São José, SC, 88106-115

E-mail: anita.fernandes@univali.br

**Marcel Borges Pinheiro**

Especialista – MBA em Big Data

Instituição: Fatec – Serviço Nacional de Aprendizagem Industrial (SENAI)

Endereço: Av. XV de Novembro, 303, Porto - Cuiabá – MT - 78020-300

E-mail: marcelpinheiro@gmail.com

**Abraão Gualberto Nazário**

Mestre em Computação Aplicada

Instituição: Fatec – Serviço Nacional de Aprendizagem Industrial (SENAI)

Endereço: Av. XV de Novembro, 303, Porto - Cuiabá – MT - 78020-300

E-mail: abraao.nazario@fatecsenaimt.ind.br

**RESUMO**

A elaboração de dietas é a principal tarefa desenvolvida pelos profissionais de Nutrição. Uma das atividades de tais profissionais é ajudar a estabelecer hábitos que possam prevenir doenças metabólicas, como diabetes e obesidade, ou distúrbios causados pela alimentação irregular. Já existem diversos sistemas de apoio a elaboração de planos nutricionais, porém a maioria apresenta uma dieta pouco efetiva quando se considera a individualidade biológica. Já os sistemas que se baseiam em Machine Learning tem conseguido bons resultados nesta área. Neste contexto, este trabalho apresenta a aplicação de algoritmos de Machine Learning, com foco em predição, para apoiar a elaboração de planos nutricionais, em uma população adulta.

**Palavras-chave:** Machine Learning, Predição, Planos Nutricionais.

**ABSTRACT**

The elaboration of diets is the main task developed by Nutrition professionals. One of the activities of such professionals is to help establish habits that can prevent metabolic diseases, such as diabetes and obesity, or disorders caused by irregular eating. There are already several support systems for the preparation of nutritional plans, but most have an ineffective diet when considering biological individuality. Systems that are based on Machine Learning have achieved good results in this area.

In this context, this paper presents the application of Machine Learning algorithms, with a focus on prediction, to support the development of nutritional plans, in an adult population.

**Keywords:** Machine Learning, Prediction, Nutritional Plans.

## 1 INTRODUÇÃO

De acordo com Moratoya et al (2013), a mudança no padrão de consumo de alimentos vem ocorrendo desde o início da humanidade. As mudanças no consumo alimentar no mundo e seus efeitos nas populações e nos países, passaram a ser um tema de importância, visto que a alimentação é um indicador de qualidade de vida.

Conforme França et al (2017), nas últimas décadas, tem se observado inúmeras mudanças no padrão de saúde e consumo alimentar da população brasileira, que resultaram na diminuição do número de casos de desnutrição e aumento significativo do número de brasileiros com excesso de peso. Tais mudanças apontam para um cenário de problemas de saúde relacionados a alimentação e nutrição.

Com o aumento da busca das pessoas por melhora na qualidade de vida, saúde ou performance no esporte, o profissional da nutrição tornou-se peça chave para atender este tipo de demanda e, com isto, softwares vem sendo desenvolvidos para auxiliar tais profissionais na melhoria de seus processos, porém muitos deles são desenvolvidos em considerar individualidade biológica, o que causa um viés na prescrição da dieta. O princípio da individualidade biológica baseia-se no fato de que cada indivíduo é um ser único, por isso, seu organismo apresenta respostas únicas a cada estímulo dado (PEREIRA, 2011). É possível detectar semelhanças de respostas, mas não uma igualdade de resposta.

Considerando esta questão, sistemas que busquem prever a tendência do padrão de resposta de um indivíduo, com base em indivíduos semelhantes e a partir daí o profissional de Nutrição pudesse fazer as adaptações individuais de cada paciente, são de extrema relevância. Com base neste contexto, este trabalho apresenta a aplicação de algoritmos de *Machine Learning* (OLIVERIA et al 2020) para análise preditiva de dietas, a fim de auxiliar na prescrição das mesmas. Para isto, foi utilizada uma base de dados contendo dados biológicos e rotinas de alimentação de vários indivíduos, e aplicados três algoritmos de *Machine Learning*, a saber: Regressão Linear, Regressão Bayesiana, e *K-nearest neighbors*, sendo que este último foi o que obteve um melhor desempenho.

A seguir serão apresentados os trabalhos correlatos pesquisados para dar suporte a esta pesquisa, bem como as etapas da pesquisa desenvolvida e os resultados obtidos.

## 2 TRABALHOS CORRELATOS

Antes de iniciar o trabalho de coleta, tratamento e análise dos dados, foi necessário um estudo sobre trabalhos correlatos, a fim de verificar, como *Machine Learning* (LOPES & PEREIRA, 2020) vem sendo aplicado na área de prescrição de dietas. Foram utilizadas as bases da IEEE, PubMed e BMJ. Os critérios de seleção dos trabalhos foram:

- Artigo completo;
- Apresentar resultados;
- Ser escrito em inglês; e
- Ter sido publicado nos últimos cinco anos.

A partir desta análise foram selecionados quatro artigos, descritos a seguir.

Babajide et al (2020), apresentam que o gerenciamento de peso e obesidade é um dos desafios emergentes no gerenciamento atual da saúde da população. As interações nutriente-gene na obesidade humana buscam encontrar várias soluções para os desafios impostos pela obesidade e pelo excesso de peso. Neste contexto, os autores propuseram a utilização de um método de intervenção alimentar como forma de abordar o problema de controle da obesidade e sobrepeso. O programa de intervenção alimentar foi realizado por um período de dez semanas. Técnicas estatísticas tradicionais têm sido utilizadas na análise dos ganhos potenciais nos programas de intervenção em peso e dieta, porém os autores investigaram a aplicabilidade do aprendizado de máquina para melhorar a previsão de peso corporal em um programa de intervenção dietética. Os modelos utilizados incluem modelo dinâmico, modelos de *Machine Learning* (Regressão Linear, SVM – *Support Vector Machine*, *Random Forest* e Redes Neurais Artificiais). O desempenho desses modelos de estimativa foi comparado com base em métricas de avaliação como RMSE, MAE e R<sup>2</sup>. Os resultados indicam que os modelos de *Machine Learning* apresentam desempenho melhor que os outros modelos na previsão do peso corporal ao final do programa de intervenção alimentar.

Oster (2018), apresenta que indivíduos com obesidade e condições relacionadas geralmente relutam em mudar sua dieta. A avaliação dos detalhes dessa relutância é dificultada por dados limitados. Neste contexto, a autora apresenta a utilização de dados provenientes de scanner doméstico para estimar a resposta da compra de alimentos a um diagnóstico de diabetes. Ela fez uso de uma abordagem de *Machine Learning* para inferir o diagnóstico de compras de produtos relacionados ao diabetes. Em média, os agregados familiares apresentam reduções calóricas significativas, mas relativamente pequenas. Essas reduções estão concentradas em alimentos não saudáveis, sugerindo que eles refletem esforços reais para melhorar a dieta. Há alguma heterogeneidade nas mudanças de calorias entre os domicílios, embora essa heterogeneidade não

seja bem prevista pela demografia ou dieta basal, apesar das grandes correlações entre esses fatores e o diagnóstico.

Wickramasinghe, Perera e Kahandawaarachchi (2017), apresentam um estudo no qual são aplicados apresentam um estudo no qual são aplicados algoritmos de *Machine Learning* para identificar o plano de dietas mais adequado para um paciente com doença renal crônica, a fim de controlar a enfermidade. Foram aplicados os algoritmos de classificação *Multiclass Decision Jungle*, *Muticlass Decision Forest*, Rede Neural Multiclasse e Regressão Logística Multiclasse. Os experimentos demonstraram que o algoritmo *Multiclass Decision Forest* foi o que apresentou o melhor desempenho, com uma precisão de 99,17% na classificação das dietas.

Weber e Achananuparp (2016), apresentam que para apoiar as pessoas que tentam perder peso e se manter saudáveis, mais e mais aplicativos de *fitness* surgiram, para diversas finalidades, como por exemplo, rastrear a ingestão e o gasto de calorias. Os usuários desses aplicativos fazem parte de um movimento mais amplo do chamado "*eu quantificado*" (CASTIEL, MORAES & PAULA, 2016) e muitos optam por compartilhar publicamente seus dados registrados. Neste contexto, os autores fizeram uso de diários alimentares públicos de mais de 4.000 usuários ativos de longo prazo do aplicativo MyFitnessPal para estudar as características de uma dieta (não) bem-sucedida. Foi treinado um modelo de aprendizado de máquina para prever se a pessoa esta acima ou abaixo das metas diárias de calorias definidas pelo usuário e também verificar quais variáveis contribuem para a previsão do modelo. Para isto foi utilizado o algoritmo SVM (*Support Vector Machine*).

Além destes artigos, também foram encontrados dois aplicativos que aplicam *Machine Learning* para auxiliar na análise e/ou prescrição da dieta. A seguir os dois trabalhos são apresentados.

Machiori, Stelute e Okamoto (2020) apresentam o ClickPrato, um aplicativo desenvolvido por pesquisadores da USP, que é baseado em conceitos de Nutrição e *Machine Learning* para avaliar a qualidade da refeição de uma pessoa a partir das fotos que a pessoa tira de seu prato, a partir de um celular. Os autores desenvolveram um índice para verificar a qualidade nutricional de refeição pela sua imagem. Ao obter as fotos do prato, a refeição é qualificada através da aplicação de *Deep Learning* (AGGARWAL, 2018).

Freeletics, uma *startup* criada na Alemanha, desenvolveu o Nutrition, um aplicativo baseado em *Machine Learning* para criar dietas personalizadas. Ao começar a acessar o aplicativo, o usuário informa o peso, a altura e se realiza exercícios físicos, além de sua intenção com a dieta. As dietas

são baseadas na quantidade de carboidratos, proteína e gorduras que a pessoa pode ingerir por dia, e o aplicativo traz receitas simples e que atendem as expectativas do usuário (FREITAS, 2017).

### 3 METODOLOGIA

Para realizar o este trabalho, foram necessárias as seguintes etapas: (i) estabelecimento dos dados a serem coletados, bem como o mecanismo de coleta; (ii) coleta e tratamento dos dados; e (iii) análise dos dados. A seguir, cada uma destas etapas será detalhada.

#### 3.1 COLETA DOS DADOS

A estratégia utilizada para a coleta de dados dividiu-se em duas frentes. A primeira referiu-se ao uso de um formulário no Google Forms, o qual foi repondido por 159 pessoas. A segunda referiu-se a dados disponibilizados por um consultório de nutrição, limitando o período de 01/10/2019 à 30/11/2019 para o recebimento de todo este apanhado de dados.

De forma a manter a privacidade dos entrevistados, todo o questionário continha perguntas contendo apenas informações acerca de características físicas, alimentos e quantidades ingeridas diariamente. Dados pessoais como por exemplo nome, endereço e local de trabalho não foram realizadas. O mesmo referiu-se aos dados disponibilizados pelo consultório, pois os dados fornecidos já vieram anonimizados, constando somente as informações necessárias.

Os dados coletados do Google Forms e os dados fornecidos pelo consultório tinham formatos diferentes e foi necessário organizá-los de modo que ficassem homogêneos. Foram realizados processos de ETL (*extract, transform and load*) (GONÇALVES, 2012), e os dados foram carregados utilizando *dataframes* da biblioteca Pandas (Figura 1). Pandas é uma biblioteca de software criada para a linguagem Python com foco na manipulação e análise de dados (CHEN, 2018). Pandas permite a importação de diferentes formatos de arquivo, como csv e xls, para a leitura em *dataframes*. Também permite diversas operações de álgebra relacional, como projeção, junção e concatenação (CHEN, 2018).

Figura 1. Dados tratados no *dataframe* da biblioteca Pandas.

Carimbo de data/hora	Sexo	Data de nascimento	Você considera sua cor de pele como:	Escolaridade	Cidade	Estado Civil	Profissão	Refeição 1	Refeição 2	F
2019/11/25 1:15:19 PM GMT-4	Masculino	1984-02-09	Branca	Ensino superior	Cuiabá	Casado	Servidor Público	4 ovos\n100g abacate	3 ovos\n1 dose de whey	300 frango\n1 doce
2019/11/25 1:17:21 PM GMT-4	Masculino	1985-06-10	Parda	Ensino superior	Cuiabá	Solteiro	Administrador	1 salgado\	150g proteína\n250g legumes\n100g verduras	100g c
2019/11/25 1:19:25 PM GMT-4	Feminino	1976-10-30	Branca	Ensino superior	Cuiaba	Solteiro	Administradora	1 fatia pão integral\ 300ml suco verde\ 200ml ...	100 ml iogurte grego	1! vermelha, branc
2019/11/25 1:19:46 PM GMT-4	Masculino	1983-01-24	Parda	Ensino superior	São Sebastião	Divorciado	advogado	1/2 pão siriol\n1 fatia de queijo\n2 fatias de ...	5 colheres arroz\n2 colheres feijão\n100g frango	01 >
2019/11/25 1:20:20 PM GMT-4	Feminino	1988-01-23	Branca	Ensino superior	Cuiabá	Solteiro	Advogada	Café\ovo	Banana	Batata dc
2019/11/25 1:24:57 PM GMT-4	Masculino	1985-03-11	Branca	Ensino superior	Rondonopolis	Divorciado	Analista de Sistemas	1 Bauru c/ mussarela\presunto	150g Arroz\n150g Feijão\n200g Carne Vermelha	mussareli

Após a junção dos dados, os mesmos foram armazenados em um banco de dados Postgre, e passaram pelo processo de *data cleaning* a fim de melhorar a qualidade dos mesmos (ILYAS & CHU, 2019). *Data Cleaning*, também chamado de *data cleansing* ou *scrubbing*, refere-se a limpeza dos dados. Seu objetivo, segundo Ilyas e Chu (2019), é detectar e remover anomalias em bases de dados.

Para Vasco (2013), as anomalias existentes em bancos de dados são divididas em três categorias:

- Anomalias de sintaxe: se referem ao formato e valores adotados para representar o dado, pois podem haver erros lexicais, erros de formatos e irregularidades.
- Anomalias de semântica: dizem respeito ao não entendimento do dado registrado, pois podem haver restrições de integridade, contradições, duplicidade de registros e registros inválidos.
- Anomalias de cobertura: estão relacionadas a ausência de informação, quando esta for uma premissa do dado.

Ainda segundo Vasco (2013), algumas técnicas utilizadas no processo de *data cleaning* para detecção de anomalias são as técnicas estatísticas, a clusterização, as regras associativas, a análise sintática, a eliminação de duplicatas, a transformação de dados, e a análise sintática. A Tabela 1 apresenta as variáveis consideradas após o processo de *data cleaning*.

Tabela 1. Variáveis Consideradas para o estudo

Atributo	Descartado
Sexo	Não
Data de nascimento	Foi utilizado para calcular o atributo idade
Idade	Não
Altura	Não
Peso	Não
Você considera sua cor de pele como	Não
Escolaridade	Não
Cidade	Sim
Estado Civil	Não
Profissão	Não
Refeição 1	Não
Refeição 2	Não
Refeição 3	Não
Refeição 4	Não
Refeição 5	Não
Refeição 6	Não

Os dados que não foram informados foram posteriormente preenchidos utilizando métodos para imputar estas informações utilizando a solução do módulo Scikit-Learn KNN Imputer. Este tipo de trabalho permite uma menor ocorrência de problemas provenientes de *overfitting*.

*Overfitting* é um termo usado na área da estatística para descrever quando um modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados (FROCKMAN, 2019). Pode-se dizer que *overfitting* ocorre quando o modelo utilizado se adaptou muito bem aos dados com os quais está sendo treinado, porém não generaliza bem para novos dados. Ou seja, o modelo “decorou” o conjunto de dados de treino, mas não aprendeu de fato o que diferencia aqueles para quando precisar enfrentar novos testes (CODINGS, 2019).

### 3.2 ANÁLISE DE DADOS

Após toda a preparação dos dados, os mesmos foram submetidos a análise através de algoritmos de *Machine Learning*. Foram aplicados três algoritmos: kNN (*K nearest neighbors*) Regressão Linear e Regressão Bayesiana.

kNN é um algoritmo muito utilizado em problemas de classificação e pode ser utilizado em problemas de classificação. Ele se baseia no quão similar é um dado (vetor), de outro. No caso das predições, as mesmas são feitas utilizando o conjunto de dados de treinamento. As predições para uma nova instância ( $\mathbf{x}$ ) são feitas pesquisando o conjunto de treinamento para as  $\mathbf{k}$  instâncias mais semelhantes (ou vizinhos) e resumindo a variável de saída para essas instâncias  $\mathbf{k}$ . Para a regressão, essa pode ser a variável de saída média (SHALEV-SHWARTZ & BEN DAVID, 2014).

A Regressão Linear é utilizada para estimar valores reais (peso, idade, quantidade de um dado alimento) baseado em variáveis contínuas. Para isto é estabelecida uma relação entre variáveis dependentes e independentes, ajustando a melhor linha (regressão). O resultado da regressão linear é sempre um número. É utilizada adequadamente quando o dataset apresenta algum tipo de tendência de crescimento/decrécimo (CONWAY & WHITE, 2012).

A Regressão Bayesiana baseia-se em realizar o mapeamento dos dados de treinamento, considerando as distribuições de probabilidade ao invés de estimativas pontuais como na abordagem clássica (CONWAY & WHITE, 2012).

Para a aplicação dos algoritmos, o conjunto de dados foi dividido em conjunto de treinamento (70% dos dados) e conjunto de testes (30% dos dados). Os algoritmos foram implementados e aplicados através da linguagem de programação Python juntamente com o seu módulo de aprendizado de máquina de código aberto, o Scikit-Learn.

Para avaliar os resultados utilizou-se a métrica RMSE (*Root Mean Squared Error*), que se refere a medida de erro mais comumente usada para aferir a qualidade do ajuste de um modelo. Ela é a raiz do erro médio quadrático da diferença entre a predição e o valor real. Pode-se pensar nela como sendo uma medida análoga ao desvio padrão. RMSE é uma boa medida, porque geralmente ela representa explicitamente o que vários métodos tendem a minimizar (CONWAY & WHITE, 2012).

Através da métrica RMSE, verificou-se que o algoritmo k-NN apresentou o melhor desempenho (RMSE = 0,5), enquanto a Regressão Logística apresentou um RMSE de 1,99 e a Regressão Bayesiana obteve RMSE de 2,03.

#### **4 CONCLUSÕES**

Os resultados apresentados pelos três algoritmos também passaram pela análise de um profissional da área de nutrição, o qual validou as prescrições apresentadas. Apesar do resultado pelo algoritmo k-NN, alguns pontos devem ser considerados. A amostra trabalhada foi uma amostra pequena, e isto faz com que o resultado possa ter sofrido um viés, portanto, é importante que uma amostra com um volume de dados bem maior seja considerada.

Também percebeu-se que, mais variáveis devem ser coletada a fim de proporcionar uma análise mais detalhada das dietas a serem classificadas e prescritas.

Apesar destes dois pontos a serem considerados, percebe-se que a aplicação de Machine Learning na prescrição de dietas é algo muito promissor e pode auxiliar de maneira efetiva o profissional de nutrição.



**REFERÊNCIAS**

AGGARWAL, C.C. Neural Network and Deep Learning: a text book. Springer, 25 de ago. de 2018. ISBN: 3319944630, 9783319944630

BABAJIDE, O., HISSAM, T., PALCZEWSKA, A., ANATOLIY, G., ASTRUP, A., MARTINEZ, J.F., OPPERT, J.F., SØRENSEN, T. I.A. A Machine Learning Approach to Short-Term Body Weight Prediction in a Dietary Intervention Program. In: Krzhizhanovskaya V. et al. (eds) Computational Science – ICCS 2020. ICCS 2020. Lecture Notes in Computer Science, vol 12140. Springer, Cham, 2020. DOI: [https://doi.org/10.1007/978-3-030-50423-6\\_33](https://doi.org/10.1007/978-3-030-50423-6_33)

CASTIEL, L.D., MORAES, D.R., PAULA, I.J. Terapeuticalização e os dilemas preemptivistas na esfera da saúde pública individualizada. Saúde Soc. São Paulo, v.25, n.1, p.96-107, 2016. DOI: 10.1590/S0104-12902016142788.

CHEN, D.Y. Análise de Dados com Python e Pandas. Novatec Editora; Edição: 1ª edição, 2018.

CODINGS, Z. Python Machine Learning: A Beginner's Guide to Python Programming for Machine Learning and Deep Learning, Data Analysis, Algorithms and Data Science With Scikit Learn, TensorFlow, PyTorch and Keras. Independently published, 2019.

CONWAY, D.; WHITE, J.M. Machine Learning for Hackers, O'Reilly Media, Inc., 2012

FRANÇA, A.K.T., CHAGAS, D.C., PESSOA, F.S., PINHO, J.R.O., CABRAL, N.A.L. Alimentação e nutrição na atenção básica em saúde. Cadernos de Saúde da Família, EDUFMA, Universidade Federal do Maranhão, 2017.

FREITAS, T. Startup usa inteligência artificial em aplicativos de treinos e dietas. Disponível em: <https://www.startse.com/noticia/startups/startup-usa-inteligencia-artificial-em-aplicativos-de-treinos-e-dietas>. Acessado em 03 de julho de 2017.

FROCKMANN, J.M. Machine Learning For beginners: Easy guide of ML, deep learning, data analytics and cyber security in practice. Modern approach of Neural Networks, Predictive Modeling and Data Mining with 50 Key Terms, Independently published, 2019.

GONÇALVES, R.R. Integração de dados na prática: Técnicas de ETL para Business Intelligence com Microsoft Integration Services 2012. Editora Érica; Edição: 1, 2012.

ILYAS, F.I.; CHU, X. Data Cleaning. ACM Books, 2019.

LOPES, A.S.B.; PEREIRA, M.M. Using machine learning to perform design space exploration of heterogeneous multicore architectures: a state of art review. Brazilian Journal of Development. Curitiba, v. 6, n. 5, p.26730-26749, may. 2020. ISSN 2525-8761. DOI:10.34117/bjdv6n5-215

MARCHIORI, D., STELUTI, J., OKAMOTO, J. Projeto ClicPrato vai avaliar a qualidade da refeição dos brasileiros a partir de fotos de pratos feitas pelo celular, unindo nutrição e Inteligência Artificial. Jornal da USP, 2020. Disponível em: <https://jornal.usp.br/universidade/sua-refeicao-e-saudavel-pesquisa-da-usp-precisa-de-fotos-do-seu-prato-para-avaliar/>. Acessado em 25 de julho de 2020.

MORATOYA, E.E; CARVALHES, G.C.; WANDER, A.E.; ALMEIDA, L.M.M.C. Mudanças no padrão de consumo alimentar no Brasil e no mundo. Revista de Política Agrícola. Ano XXII, no. 1, jan/fev/mar. 2013.

OLIVEIRA, Y.M.; BAHIA, G.A.D.; AQUINO, F.R.; GUIMARÃES, M.V.A.F.; GONÇALVES, A.L.U.; OLIVEIRA, P.S. Machine Learning applied to estimate pile coefficient with validation by static load tests. Brazilian Journal of Development. Curitiba, v. 6, n. 1, p. 1806-1820, jan. 2020. ISSN 2525-8761. DOI:10.34117/bjdv6n1-126

OSTER, E. Diabetes and Diet: Purchasing Behavior Change in Response to Health Information. American Economic Journal: Applied Economics, 10 (4): 308-48, 2018. DOI: 10.1257/app.20160232

PEREIRA, C.S.M. Síndrome do Overtraining. Monografia (Especialização). Curso de Pós Graduação "Lato Sensu" em Treinamento Personalizado e Musculação. Centro Universitário Católico Salesiano Auxilium. UNISALESIANO, Lins, São Paulo, 2011.

SHALEV-SHWARTZ, S., BEN-DAVID, S. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press, 2014.

VASCO, D.O.B.S. Identificação de Anomalias Contextuais. Dissertação (Mestrado). Universidade do Porto, Portugal, 2013. Acessado em 01 de junho de 2020. Disponível em: <https://repositorio-aberto.up.pt/bitstream/10216/70366/2/25050.pdf>

WEBER, I., ACHANANUPARP, P. Insights from Machine-Learned Diet Success Prediction. Pacific Symposium on Biocomputing 2016, Proceedings of... Fairmont Orchid, Big Island of Hawaii. Disponível em <http://psb.stanford.edu/psb-online/proceedings/psb16/weber.pdf>. Acessado em 03 de junho de 2020.

WICKRAMASINGHE, M. P. N. M., PERERA, D. M., KAHANDAWAARACHCHI, K. A. D. C. P Dietary prediction for patients with Chronic Kidney Disease (CKD) by considering blood potassium level using machine learning algorithms, 2017 IEEE Life Sciences Conference (LSC), Proceedings of... Sydney, NSW, 2017, pp. 300-303, doi: 10.1109/LSC.2017.8268202.