

Aplicação de *Machine learning* em contextos de previsão de *Churn* – Uma revisão de literatura

Pedro Miguel da Silva Fernandes

Doutorando de Geografia na Faculdade de Letras da Universidade de Coimbra e Investigador colaborador do CEGOT - Centro de Estudos de Geografia e Ordenamento do Território

RESUMO

A fidelização de clientes constitui um aspecto fundamental na vida de qualquer empresa. Nos tempos atuais, em que o marketing se assume cada vez mais personalizado e relacional, é fulcral garantir que os consumidores permaneçam interessados nos produtos e serviços disponibilizados pela empresa. Perante o abandono de produtos ou serviços, cenário habitualmente apelidado de *churn*, torna-se crucial compreender quais os motivos que se encontram na base desse fenómeno. Para esse efeito, as empresas recorrem aos mais variados sistemas de previsão, sistemas esses cada vez dotados de maiores níveis de complexidade. Tendo em conta que as ferramentas de Inteligência Artificial (IA) evoluem rapidamente, o presente artigo tem como objetivo compreender quais são os sectores de atividade que se evidenciam mais propícios para a aplicação do *machine learning* no contexto da previsão de *churn* de clientes. Para responder a este objetivo foi adotada uma revisão sistemática de literatura tendo em conta o período 2020-2024. Conclui-se que o *machine learning*, aplicado em modelos de previsão *churn*, é amplamente proposto por vários autores ao longo do período analisado. A maioria dos estudos resultante desta investigação incide sobre aplicações no sector das telecomunicações, seguindo-se o sector da banca. Conclui-se ainda que são utilizados variados métodos neste contexto, mas com especial incidência em *Random Forest (RF)*.

Palavras-chave: Churn, Machine Learning, Artificial Intelligence.

1 INTRODUÇÃO

As empresas atuais, perante as rápidas mudanças e incertezas do meio envolvente, e também para fazer face à forte concorrência, multiplicam-se em esforços para garantir a permanência dos seus clientes. Investem valores avultados em sofisticados sistemas tecnológicos (CRM, Data-Base Marketing, Geomarketing, etc.) que lhes permitam conhecer de forma mais aprofundada os hábitos de consumo dos seus clientes, para que possam satisfazer as suas necessidades e garantir assim a sua fidelização.

Quando se aborda a questão da retenção de clientes, é importante tomar em conta a opinião de KOTLER & KELLER (2019). Sugerem que é mais dispendioso procurar novos clientes do que reter os atuais (KOTLER & KELLER, 2019, p. 150).

Sendo a fidelização um aspeto essencial em contexto empresarial, torna-se também importante determinar a respetiva taxa de *churn*.



2 CHURN

O termo *churn* é utilizado para definir o abandono ou desistência dos clientes. Mais concretamente, uma taxa de *churn* “Corresponde à percentagem de clientes perdidos num período de tempo específico, sem contar com os novos clientes angariados nesse período.” (SAIAS *et al.*, 2018, p. 1). Uma taxa de *churn* elevada deve levar a empresa a equacionar medidas que permitam compreender as razões desse abandono.

Em termos de classificação, LAZAROV & CAPOTA (2007, p. 2), sugerem a existência de três tipos de *churn*: activo/deliberado, rotacional/incidental e passivo/não voluntário (tradução nossa).

No primeiro conjunto incluem-se desistências deliberadas e conscientes por parte dos clientes. Abandonam o serviço por motivos relacionados, por exemplo, com a insatisfação dos produtos/serviços, mau serviço de atendimento, reclamações tratadas de forma incorreta, aumento injustificado de preços, etc.

No segundo conjunto, os autores exemplificam com a incapacidade financeira e ainda com a mudança de local de residência.

Por fim, temos a desistência por iniciativa da empresa, talvez por sentir que aquele cliente já não se tornar lucrativo. Muitas vezes, os valores investidos na retenção de determinados clientes, podem ser superiores ao valor das compras realizadas por esses mesmo clientes, pelo que se traduzem em prejuízo.

3 MACHINE LEARNING

Entrando agora na componente tecnológica, e antes de abordar o *machine learning* propriamente dito, é importante começar por compreender o conceito de IA - Inteligência Artificial, cujas origens remontam a Alain Turing, em 1950. De acordo com MAIA (2018, pp. 128-129), “(...) o texto *Computing machinery and intelligence*, é atualmente considerado um marco importante da teoria da computação, (...)”.

Segundo GOMES (2010, p. 234), a IA “(...) abrange uma enorme variedade de subcampos, desde áreas de uso geral, como aprendizado e percepção, até tarefas específicas como jogos de xadrez, demonstração de teoremas matemáticos, criação de poesia e diagnóstico de doenças”.

Em contexto empresarial as aplicações da IA começam a ser vastas. De acordo com GONÇALVES *et al.* (2023, p. 2), “Nas empresas, a inteligência artificial é usada para potencializar os resultados, aumentar a produtividade e economizar o tempo.”

Um termo cada vez mais usual em ambiente de IA, é o *machine learning*, aprendizado de máquina, que é entendido como “(...) uma área de IA cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática.” (MONARD & BARANAUSKAS, 2003, p. 39).

Na literatura, podemos encontrar vários estudos que nos elucidam em relação a essa diversidade de contextos: na previsão da inflação (FREITAS, 2019), na previsão da procura (DOS SANTOS, 2021), na previsão da evolução de fundos de investimento (LINS, 2020), na previsão de processos industriais



(SOUSA, 2023), na previsão climática (AGUIAR, 2022), na previsão da erosão interna dos solos (ALBUQUERQUE & CAVALCANTE, 2022), entre muitas outras.

De acordo com WANG *et al.* (2022, pp. 57-58), os tipos de modelos/técnicas mais comuns em previsão *churn* com recurso ao *machine learning* são os seguintes: *Decision Trees (DT's)*, *Random Forest (RF)*, *Logistic Regression (LR)*, *Stochastic Gradient Descent (SGD)*, *Support Vector Machine (SVM)*, *Naive Bayes (NB)*, *Multi-Layer Perceptron (MLP)*, *K-Nearest Neighbors (KNN)*, *Gradient Boosting Model (GBM)*. Note-se que todos estes modelos apresentam diferentes graus de complexidade e podem ser aplicados de forma individual ou através de integração com vários outros modelos.

Nas Árvores de Decisão (*Decision Trees (DT's)*) “O algoritmo inicia escolhendo a árvore de decisão mais geral, contendo apenas o nó inicial, chamado de nó-raiz. Com base neste nó, o algoritmo trabalha recursivamente em cada nó filho, refinando a árvore até que cada subconjunto pertença a uma única classe.” (CARVALHO, 2014, p. 48).

Quanto às Florestas Aleatórias (*Random Forest (RF)*), pode-se dizer que são “(...) um método de aprendizado conjunto para classificação e regressão que opera construindo várias árvores de decisão no momento do treinamento e produzindo a classe, que é o modo das saídas geradas por árvores individuais.” (SANTOS, 2020, p. 29).

A Regressão Logística (*Logistic Regression (LR)*), que “(...) é uma técnica estatística que tem como objetivo modelar, a partir de um conjunto de observações, a relação “logística” entre uma variável resposta dicotômica e uma serie de variáveis explicativas numéricas (contínuas, discretas) e/ou categóricas.” (CABRAL, 2013, p. 15).

O Gradiente Estocástico Descendente (*Stochastic Gradient Descent (SGD)*), é utilizado em situações que tenham como objetivo minimizar perdas. Para DA SILVA MELO (2022, p. 11) “(...) é um método iterativo que tem como objetivo, otimizar uma função objetivo escolhendo uma instância aleatória do conjunto de treinamento em cada etapa e calculando o gradiente baseado nessa única instância”.

As Máquinas de Suporte de Vetores (*Support Vector Machine (SVM)*), são “(...) um classificador formalmente definido por um hiperplano de separação. O objetivo do SVM é encontrar dentre todos os hiperplanos o que minimiza o risco empírico, isto é, procura maximizar a margem do classificador linear.” (PEREIRA, 2018, p. 38).

O classificador Naive Bayes é entendido “(...) um modelo probabilístico, sendo um caso particular de rede bayesiana com inferência, onde o número de pais na rede corresponde a um nó (...)” (SIVIERO & JÚNIOR, 2011, p. 3).

No Perceptron Multicamadas (*Multi-Layer Perceptron (MLP)*), os nós fonte formam três camadas: camada de entrada, camada oculta e camada de saída (SOUZA, 2012, p. 21).



Quanto aos Vizinhos Mais Próximos (*K-Nearest Neighbors (KNN)*), como a própria designação sugere, são um algoritmo que procura identificar os vizinhos que se encontram mais perto de um determinado ponto. Neste âmbito, são usados de forma frequente a distância Euclidiana e a de Manhattan (DOS REIS, 2012, p. 4).

Por fim, o Aumento do Gradiente, *Gradient Boosting Model (GBM)*, “(...) consiste em, iterativamente, utilizar estimadores fracos para realizar estimações e em seguida adicionar esta estimativa de forma ponderada a uma estimação gerada por um estimador forte.” (SPOLADOR, 2021, p. 24). Neste contexto, WANG *et al.* (2022, p. 58) falam em *XGBoost* e *LightGBM*.

Tendo em conta estas considerações, neste estudo vamos procurar entender em que sectores se aplica o *machine learning* no âmbito da previsão de *churn*.

4 OBJETIVO

O objetivo principal deste estudo é o de compreender quais são os sectores de atividade que se evidenciam mais propícios para a aplicação do *machine learning* no contexto da previsão de *churn* de clientes. Posteriormente, para os estudos selecionados, tentou-se perceber a frequência com que se utilizam os métodos evidenciados por WANG *et al.* (2022, pp. 57-58).

5 METODOLOGIA

Para atingir o objetivo principal deste estudo, seguiu-se uma metodologia de revisão sistemática de literatura (RSL) utilizando a conhecida base de dados Scopus. Tendo em conta o elevado número de estudos que hoje são disponibilizados, a revisão sistemática de literatura constitui um método apropriado a esta investigação.

No âmbito deste artigo foram tidas em consideração as etapas definidas por TRANFIELD *et al.* (2003) em estudos desta natureza: o planeamento, a revisão e a divulgação/disseminação dos resultados obtidos.

A 04 de fevereiro de 2024, deu-se início ao processo de pesquisa propriamente dito. A primeira pesquisa, utilizando a expressão *churn prediction machine learning sector* e sem recorrer à utilização de qualquer refinamento, conduziu a 128 resultados. Em seguida, procedeu-se ao apuramento de resultados com base num primeiro refinamento, ou seja, tendo em conta um período temporal de 2020 a 2024, e obtiveram-se 106 documentos. Num segundo refinamento, limitou-se a pesquisa tendo em conta as palavras-chave “Machine learning” e “Customer Churn Prediction”, o que conduziu a 73 resultados, que foram exportados para a plataforma Zotero.

Em seguida, avançou-se a para a leitura dos títulos e dos resumos dos 73 estudos, tendo sido selecionados 43. Nalguns casos, foi também necessário proceder à leitura dos resultados e das conclusões de determinados estudos para compreender que métodos foram utilizados/sugeridos pelos autores.

Foram descartados 30 estudos que analisavam o tema de forma genérica, não incidindo sobre nenhum sector em particular, que analisavam métodos de *machine learning* de forma geral, estados da arte, revisões sistemáticas de literatura, estudos baseados em questionários, estudos com incidência em mais do que um sector em simultâneo, estudos aplicados em perspectivas diferentes de clientes/consumidores (ex: alunos, colaboradores), estudos específicos de *deep learning* e estudos com acesso pago.


6 RESULTADOS

Do ponto de vista da produção científica em termos anuais, Figura 1, verifica-se uma tendência de crescimento. Em 2021 encontrámos apenas 7 estudos. Os anos seguintes, 2022 (15) e 2023 (15), foram de franco crescimento no número de publicações, essencialmente na Banca e nas Telecomunicações.

Deve-se também referir que foi em 2022 que foi publicado o único estudo deste período relacionado com o Factoring, (artigo em conferência de BOZKAN (2022, May)), e em 2023 o único estudo relacionado com o Renting (artigo de SUH (2023)), o que leva a concluir que só recentemente se olhou para esta ferramenta no âmbito destes dois sectores de atividade.


Quando se analisa o ano atual de 2024, até ao momento, verifica-se que já foram publicados dois estudos desta natureza, ambos dizem respeito ao sector das telecomunicações. Trata-se do único sector que já obteve publicações neste ano, e tendo em conta que se destacou no período em análise, pode-se afirmar que a tendência é a de continuidade.

Figura 1 – Distribuição anual dos estudos publicados no período 2020-2024



No período recente, 2020-2024, a *machine learning* é aplicado em variados sectores de atividade. Fica bem visível que as Telecomunicações são o sector que reúne o maior número de estudos, um total de 23. Segue-se a Banca com 13 estudos. Em terceiro lugar temos o Comércio eletrónico, com 2 estudos. Finalmente, com apenas um estudo cada, temos os restantes sectores: Energia, Factoring, Renting, Retalho e Seguros (Figura 2).

Figura 2 – Distribuição de estudos por sector de atividade



Veja-se a síntese de estudos, por cada um dos oito sectores identificados, no Quadro 2.

Quadro 2 – Lista de estudos sobre *machine learning* em diversos sectores

Sector	Estudos
Banca	Soni & Nelson (2023); Dönmez (2023, September); Murindanyi <i>et al.</i> (2023, April); Soundarya <i>et al.</i> (2023, April); Tran <i>et al.</i> (2023); de Lima Lemos, <i>et al.</i> (2022); NV <i>et al.</i> (2022, November); Agarwal <i>et al.</i> (2022, October); Haddadi (2022, May); Elyusufi & M'hamed (2022); Bhujbal & Bavdane (2021, November); Sagala & Permai (2021, October); Rahman & Kumar (2020, November)
Comércio electrónico	Nagaraj <i>et al.</i> (2023, January); Gopal & MohdNawi (2021, December)
Energia	Vezzoli <i>et al.</i> (2020)
Factoring	Bozkan (2022, May)
Renting	Suh (2023)
Retalho	Abbas (2022, December)
Seguros	Das & Gondkar (2021)
Telecomunicações	Wagh <i>et al.</i> (2024); Moradi <i>et al.</i> (2024); Imani & Arabnia (2023); Pustokhina <i>et al.</i> (2023); Shahid <i>et al.</i> (2023, February); Navienkumar & Lalithamani (2023, July); Lim <i>et al.</i> (2023, August); Mohajon & Arif (2023, September); Raj & Vetrithangam (2023, April); Srinivasan <i>et al.</i> (2023, January); Al-Shourbaji (2022); Zdanavičiūtė <i>et al.</i> (2022); Shrestha & Shakya (2022); Salian (2022, December); Prakash <i>et al.</i> (2022, December); Faritha Banu (2022); Mirza <i>et al.</i> (2022); Vakeel <i>et al.</i> (2022, January); Liu <i>et al.</i> (2022); Karamollaoglu <i>et al.</i> (2021, September); Saheed & Hambali (2021, October); Shumaly <i>et al.</i> (2020, October); Abou el Kassem <i>et al.</i> (2020)

Fonte: Elaboração própria a partir de pesquisa na base de dados Scopus a 04 fev. 2024

Tecendo agora algumas considerações em relação à frequência de utilização de diferentes métodos no contexto das telecomunicações e da banca, os sectores que se destacaram claramente com maior número de estudos, constatou-se a aplicação de inúmeros métodos, utilizados de forma individual ou de forma integrada.

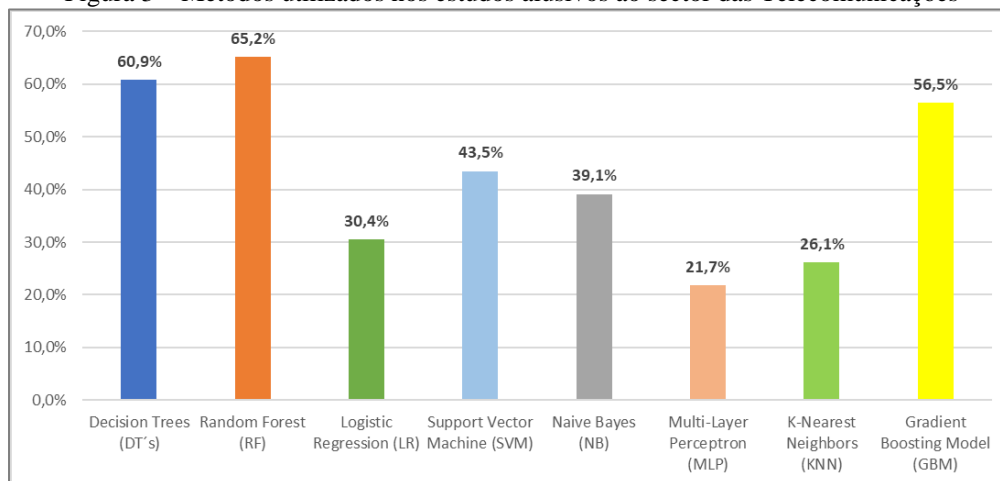
É importante realçar que, para além dos métodos que são referenciados atrás, por vezes, são utilizados outros e até propostos alguns inovadores. No entanto, neste artigo, apenas nos cingimos aos métodos considerados por WANG *et al.* (2022, pp. 57-58), que vimos atrás. É habitual, no âmbito dos estudos encontrados, proceder-se à comparação da performance em relação a vários algoritmos.

É de salientar que não se encontrou nenhum estudo que abordasse o *Stochastic Gradient Descent* (SGD). Por outro lado, algoritmos como *XGBoost*, *CatBoost*, entre outros foram considerados derivações de GBM.

No contexto das Telecomunicações, com maior número de estudos, 23, as *Random Forest* (65,2%) e as *Decisions Trees* (60,9%) são as que se destacam. Seguem-se os *Gradient Boosting Models* (56,5%), as *Suport Vector Machine* (43,5%), as *Naive Bayes* (39,1%) e a *Logistic Regression* (30,4%).

No conjunto dos *Gradient Boosting Models* encontrámos referências a *XGBoost*, *LightGBM*, *AdaBoost* e também *CatBoost*.


Figura 3 – Métodos utilizados nos estudos alusivos ao sector das Telecomunicações



Por sua vez, os métodos mais utilizados no âmbito dos 13 estudos relativos ao sector bancário, Figura 4, são as *Random Forest* (61,5%) e a *Logistic Regression* (53,8%). Com o mesmo valor, 46,2%, temos as *Decision Trees*, as *Suport Vector Machine* e os *K-Nearest Neighbors*.

Nos *Gradient Boosting Models* (38,5%) também foram visíveis referências a ferramentas *XGBoost*, *LightGBM*, *AdaBoost* e *CatBoost*.

Figura 4 – Métodos utilizados nos estudos alusivos ao sector da Banca



7 CONSIDERAÇÕES FINAIS

Este artigo teve como objetivo avaliar a utilização do *machine learning* na previsão de *churn*, a taxa de abandono de clientes. Concluiu-se que, no período 2020-2024, se encontram muitas propostas de modelos em variados sectores. Destaca-se o sector das telecomunicações, com 23 estudos. A banca obteve o segundo lugar do ranking com 13 estudos.

Também foi possível perceber que os métodos utilizados nestes estudos são bastante variados: *Decision Trees (DT's)*, *Random Forest (RF)*, *Logistic Regression (LR)*, *Support Vector Machine (SVM)*, *Naive Bayes (NB)*, *Multi-Layer Perceptron (MLP)*, *K-Nearest Neighbors (KNN)*, *Gradient Boosting Model (GBM)*.

Random Forest (RF) foi o método que obteve valores mais significativos quer no contexto das telecomunicações, quer no contexto bancário.



REFERÊNCIAS

ABBAS, W., USMAN, M., & QAMAR, U. Churn Prediction of Customers in a Retail Business using Exploratory Data Analysis. (2022, December). In 2022 International Conference on Frontiers of Information Technology (FIT) (pp. 130-135). IEEE. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/10043051>>. Acesso em: 07 de Fev. 2024.

ABOU EL KASSEM, E., HUSSEIN, S. A., ABDELRAHMAN, A. M., & ALSHEREF, F. K. Customer churn prediction model and identifying features to increase customer retention based on user generated content. (2020). International Journal of Advanced Computer Science and Applications, 11(5). Disponível em: <https://www.researchgate.net/profile/Alaa-Mostafa-15/publication/341872965_Customer_Churn_Prediction_Model_and_Identifying_Features_to_Increase_Customer_Retention_based_on_User_Generated_Content/links/5f2c35eaa6fdcccc43b01626/Customer-Churn-Prediction-Model-and-Identifying-Features-to-Increase-Customer-Retention-based-on-User-Generated-Content.pdf>. Acesso em: 12 de Fev. 2024.

AGARWAL, V., TAWARE, S., YADAV, S. A., GANGODKAR, D., RAO, A. L. N., & SRIVASTAV, V. K. Customer-Churn Prediction Using Machine learning. (2022, October). In 2022 2nd International Conference on Technological Advancements in Computational Sciences (ICTACS) (pp. 893-899). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9988187?casa_token=fjZNS7Rcv3IAAAAA:3r6AeLyjAoO9m0zVdMrxFfKlpbYhgLgBuQDgO0s3vMzRluTR9Y8AhQ_ZDFu16mDCDZP_OcZPAg>. Acesso em: 11 de Fev. 2024.

AGUIAR, Guilherme de Oliveira & SILVA, Victor Rodrigues. Sistema de previsão climática baseado em machine learning. (2022). Disponível em: <https://bdm.unb.br/bitstream/10483/34525/1/2022_GuilhermeAguiar_VictorSilva_tcc.pdf>. Acesso em: 22 de Jan. 2024.

AL-SHOURBAJI, I., HELIAN, N., SUN, Y., ALSHATHRI, S., & ABD ELAZIZ, M. Boosting ant colony optimization with reptile search algorithm for churn prediction. Mathematics, 10(7), 1031, 2022. Disponível em: <<https://www.mdpi.com/2227-7390/10/7/1031>>. Acesso em: 07 de Fev. 2024.

ALBUQUERQUE, E. A. C., & CAVALCANTE, A. L. B. Previsão de Erosão Interna em Solos com o Uso de Machine learning. (2022). Disponível em: <https://www.researchgate.net/profile/Andre-Cavalcante/publication/358724055_Previsao_de_Erosao_Interna_em_Solos_com_o_Uso_de_Machine_Learning/links/64086d39b1704f343fb477ab/Previsao-de-Erosao-Interna-em-Solos-com-o-Uso-de-Machine-Learning.pdf>. Acesso em: 22 de Jan. 2024.

BHUJBAL, N. S., & BAVDANE, G. P. Leveraging the efficiency of Ensembles for Customer Retention. (2021, November). In 2021 Fifth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC) (pp. 1675-1679). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9640757?casa_token=ax6ZFdhPqQ8AAAAA:Uo3CVtli9eWjlTMd9pNFMBcq_fNfq9DneboCvrGIRjnKX05krdK04rW_m_-Z4D7TBOnNuWeXEA>. Acesso em: 13 de Fev. 2024.

BOZKAN, T., ÇAKAR, T., SAYAR, A., & ERTUĞRUL, S. Customer Segmentation and Churn Prediction via Customer Metrics. (2022, May). In 2022 30th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.



Disponível em:<
https://ieeexplore.ieee.org/abstract/document/9864781?casa_token=6jPLctuX4BkAAAAA:x6K76RDsxdly6tQ8YnkDW3sstAQBiIFnbPPySi8OXXx1r2OwvQ0sYAPKMX0fef9gh1X6S9HDJQ>. Acesso em: 07 de Fev. 2024.

CARVALHO, H. M. Aprendizado de máquina voltado para mineração de dados: árvores de decisão. (2014). Disponível em:<https://bdm.unb.br/bitstream/10483/9487/1/2014_HialoMunizCarvalho.pdf>. Acesso em: 22 de Jan. 2024.

CABRAL, C. I. S. Aplicação do modelo de regressão logística num estudo de mercado (Doctoral dissertation). (2013). Disponível em:<https://repositorio.ul.pt/bitstream/10451/10671/1/ulfc106455_tm_Cleidy_Cabral.pdf>. Acesso em: 24 de Jan. 2024.

DA SILVA MELO, R. L. Uma abordagem para extração de relações entre entidades nomeadas utilizando autoencoder e gradient boosting (Doctoral dissertation, Universidade Federal do Rio de Janeiro). (2022). Disponível em:< <https://www.cos.ufrj.br/uploadfile/publicacao/3067.pdf>>. Acesso em: 24 de Jan. 2024.

DAS, D., & GONDKAR, R. R. Machine learning Models for Customer Churn Prediction in Insurance Sector. (2021). Grenze International Journal of Engineering & Technology (GIJET), 7(1). Disponível em:<<https://openurl.ebsco.com/EPDB%3Aagd%3A11%3A10760987/detailv2?sid=ebsco%3Aplink%3Ascholar&id=ebsco%3Aagd%3A151423765&crl=c>>. Acesso em: 07 de Fev. 2024.

DE LIMA LEMOS, R. A., SILVA, T. C., & TABAK, B. M. Propension to customer churn in a financial institution: A machine learning approach. Neural Computing and Applications, 34(14), 11751-11768, 2022. Disponível em:< <https://link.springer.com/article/10.1007/s00521-022-07067-x>>. Acesso em: 10 de Fev. 2024.

DÖNMEZ, Ş. Machine learning-Based Merchant Churn Prediction in Banking. (2023, September). In 2023 8th International Conference on Computer Science and Engineering (UBMK) (pp. 503-508). IEEE. Disponível em:<
https://ieeexplore.ieee.org/abstract/document/10286753?casa_token=dGQQiXySCKAAAAA:z9zXKFJYjiG1_ikBE3KBGqFIQqsnjlsRkV3fFbLYmIjLM1qUYNvejO4ofw7EZhRkprTBiCuYUw>. Acesso em: 06 de Fev. 2024.

DOS REIS, D. M., CHERMAN, E. A., SPOLAÔR, N., & MONARD, M. C. Extensões do algoritmo de aprendizado de máquina multirrotulo BRkNN. (2012). Encontro Nacional de Inteligência Artificial, 1-12. Disponível em:< <https://sites.labic.icmc.usp.br/pub/mcmonard/ReisENIA2012.pdf>>. Acesso em: 26 de Jan. 2024.

DOS SANTOS, F. A. B. Algoritmos de Machine learning para previsão da procura (Doctoral dissertation, Universidade do Minho (Portugal)). (2021) Disponível em:<
https://repositorium.sdum.uminho.pt/bitstream/1822/78332/1/Dissertacao_MES_Fabio_Santos_pg41825.pdf>. Acesso em: 22 de Jan. 2024.

ELYUSUFI, Y., & M'HAMED, A. I. T. Churn prediction analysis by combining machine learning algorithms and best features exploration. International Journal of Advanced Computer Science and Applications, 13(7), 2022. Disponível em:< <https://www.proquest.com/docview/2707473342?pq-origsite=gscholar&fromopenview=true>>. Acesso em: 13 de Fev. 2024.



FARITHA BANU, J., NEELAKANDAN, S., GEETHA, B. T., SELVALAKSHMI, V., UMADEVI, A., & MARTINSON, E. O. Artificial intelligence based customer churn prediction model for business markets. *Computational Intelligence and Neuroscience*, (2022). Disponível em: <<https://www.hindawi.com/journals/cin/2022/1703696/>>. Acesso em: 10 de Fev. 2024.

FREITAS, G. B. O uso de machine learning na modelagem da previsão de inflação: revisão bibliográfica. (2019). Disponível em: <https://bdm.unb.br/bitstream/10483/25328/1/2019_GabrielBelminoFreitas_tcc.pdf>. Acesso em: 22 de Jan. 2024.

GOMES, D. D. S. Inteligência Artificial: conceitos e aplicações. *Revista Olhar Científico*, v.1, n. 2, p. 234-246, 2010. Disponível em: <https://www.professores.uff.br/screspo/wp-content/uploads/sites/127/2017/09/ia_intro.pdf>. Acesso em: 20 de Jan. 2024.

GONÇALVES, L. S., FANTAZIA, G. S., DE OLIVEIRA, D. S., & COSTA, D. H. Inteligência artificial na indústria 4.0. *E-Acadêmica*, 4(2), e2642485-e2642485, 2023. Disponível em: <<https://www.eacademica.org/eacademica/article/view/485/354>>. Acesso em: 21 de Jan. 2024.

GOPAL, P., & MOHDNAWI, N. B. A Survey on Customer Churn Prediction using Machine learning and data mining Techniques in E-commerce. (2021, December). In *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)* (pp. 1-8). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9718460?casa_token=dZaQv8icNUkAAAAA:CIJG_od3gGixY3wLO_6QPI9Eo9Wcg9JNZJqHpKByla9tQb7v22hVSvs7DhJbxaDBhO27Y880IA>. Acesso em: 07 de Fev. 2024.

HADDADI, S. J., MOHAMMADI, M. O., BAHRAMI, M., KHOEINI, E., BEYGI, M., & KHOSHKAR, M. H. Customer churn prediction in the iranian banking sector. (2022, May). In *2022 International Conference on Applied Artificial Intelligence (ICAPAI)* (pp. 1-6). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9801574?casa_token=9dSTxvAEy20AAAAA:qJq_hUmrCwqiMmYKArNcfdx0NH_yuOQpCBzN9boR6i0Cnr8NadYtkTbzab50Kd0ExEBqWkmu5A>. Acesso em: 12 de Fev. 2024.

KARAMOLLAOĞLU, H., YÜCEDAĞ, İ., & DOĞRU, İ. A. Customer Churn Prediction Using Machine learning Methods: A Comparative Analysis. (2021, September). In *2021 6th International Conference on Computer Science and Engineering (UBMK)* (pp. 139-144). IEEE. Disponível em: <https://www.researchgate.net/publication/355226544_Customer_Churn_Prediction_Using_Machine_Learning_Methods_A_Comparative_Analysis>. Acesso em: 11 de Fev. 2024.

KOTLER, Philip & KELLER, Kevin Lane. *Administração de Marketing*. (2019). (15nd ed.). Prentice Hall

IMANI, M., & ARABNIA, H. R. Hyperparameter Optimization and Combined Data Sampling Techniques in Machine learning for Customer Churn Prediction: A Comparative Analysis. *Technologies*, 11(6), 167, 2023. Disponível em: <<https://www.mdpi.com/2227-7080/11/6/167>>. Acesso em: 08 de Fev. 2024.

LAZAROV, V., & CAPOTA, M. Churn prediction. (2007). *Bus. Anal. Course. TUM Comput. Sci*, 33, 34. Disponível em: <<https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=dbf15b7c5f766ef9f84ba83127c626d79b2087b2>>. Acesso em: 19 de Jan. 2024.



LIM, Z. Y., PANG, Y. H., OOI, S. Y., & KHOH, W. H. Analysis of an Optimized LightGBM Based on Different Objective Functions for Customer Churn Prediction in Telecom. (2023, August). In 2023 7th International Conference on Automation, Control and Robots (ICACR) (pp. 102-107). IEEE. Disponível em:<

https://ieeexplore.ieee.org/abstract/document/10314612?casa_token=G8Z78FFzBYcAAAAA:NJxIOjZIn3fyDndJY01OIfUoP95ob_sxFH-lS7x7y201OH78r54cEPjHqgpquVtlws42I3vHwA>. Acesso em: 09 de Fev. 2024.

LINS, R. N. F. Previsão de fundos de investimentos com o uso de machine learning (Bachelor's thesis, Universidade Tecnológica Federal do Paraná). (2020). Disponível em:<

<https://repositorio.utfpr.edu.br/jspui/bitstream/1/24679/1/fundosinvestimentosmachinelearning.pdf>>. Acesso em: 22 de Jan. 2024.

LIU, R., ALI, S., BILAL, S. F., SAKHAWAT, Z., IMRAN, A., ALMUHAIMED, A., ... & SUN, G. An intelligent hybrid scheme for customer churn prediction integrating clustering and classification algorithms. *Applied Sciences*, 12(18), 9355, 2022. Disponível em:<<https://www.mdpi.com/2076-3417/12/18/9355>>. Acesso em: 08 de Fev. 2024.

MAIA, M. Pode uma máquina desejar? TECCOGS: Revista Digital de Tecnologias Cognitivas, (17), 2018. Disponível em:< <https://revistas.pucsp.br/index.php/teccogs/article/view/48594/32074>>. Acesso em: 20 de Jan. 2024.

MIRZA, O. M., MOSES, G. J., RAJENDER, R., LYDIA, E. L., KADRY, S., ME-EAD, C., & THINNUKOOL, O. Optimal Deep Canonically Correlated Autoencoder-Enabled Prediction Model for Customer Churn Prediction. *Computers, Materials & Continua*, 73(2), 2022. Disponível em:< <https://www.scopus.com/record/display.uri?eid=2-s2.0-85132329266&origin=inward&txGid=3e4313f33b6652af1de050256afa95f8>>.

Acesso em: 07 de Fev. 2024.

MOHAJON, J., & ARIF, A. S. M. Churn Prediction With Explainability for the Customers of Telecom Industry. (2023, September). In 2023 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD) (pp. 179-183). IEEE. Disponível em:< https://ieeexplore.ieee.org/abstract/document/10303395?casa_token=yHNo9ua0sNYAAAAA:2OYgLNr6Ys3uabLsSzkRXEm8dlDsktAjpGTMUyl2AHRkJ1PmZyKcmPfhxpVrsj7dIHcxaTpKA>. Acesso em: 07 de Fev. 2024.

MONARD, M. C., & BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, 1(1), 32, 2003 Disponível em:< <https://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>>. Acesso em: 21 de Jan. 2024.

MORADI, B., KHALAJ, M., HERAT, A. T., DARIGH, A., & YAMCHOLO, A. T. A swarm intelligence-based ensemble learning model for optimizing customer churn prediction in the telecommunications sector. *AIMS Mathematics*, 9(2), 2781-2807, 2024. Disponível em:< <https://www.aimspress.com/aimspress-data/math/2024/2/PDF/math-09-02-138.pdf>>. Acesso em: 08 de Fev. 2024.

MURINDANYI, S., MUGALU, B. W., NAKATUMBA-NABENDE, J., & MARVIN, G. Interpretable Machine learning for Predicting Customer Churn in Retail Banking. (2023, April). In 2023 7th International Conference on Trends in Electronics and Informatics (ICOEI) (pp. 967-974). IEEE. Disponível em:<



https://ieeexplore.ieee.org/abstract/document/10125859?casa_token=moaWe7KWiH0AAAAA:SgmGrfICdxrIej8ZnZD4rsNwIDmjXQ3MF3r-vrsiYo7lh-qKi4Q3CuOijI8NbWC1sTvIKKmyIw>. Acesso em: 07 de Fev. 2024.

NAGARAJ, P., MUNEESSWARAN, V., DHARANIDHARAN, A., AAKASH, M., BALANANTHANAN, K., & RAJKUMAR, C. E-Commerce Customer Churn Prediction Scheme Based on Customer Behaviour Using Machine learning. (2023, January). In 2023 International Conference on Computer Communication and Informatics (ICCCI) (pp. 1-6). IEEE. Disponível em:< https://ieeexplore.ieee.org/abstract/document/10128498?casa_token=PGps1sSAc2MAAAAA:mqIVbKB5OzMio9iNGSEndC2VkzSGTfosB2IHliDjQ9CBfxI3IK1uFEiDHxI8CnUGcHLisFUm0g>. Acesso em: 07 de Fev. 2024.

NAVIENKUMAR, R., & LALITHAMANI, N. Machine learning Methods for Predictive Customer Churn Analysis in the Telecom Industry. (2023, July). In 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT) (pp. 1-7). IEEE. Disponível em:< https://ieeexplore.ieee.org/abstract/document/10306395?casa_token=UuejBdvu6agAAAAA:cCqFbl6IMUgn8rEDIBD-f5eSMwQN2u7LTa4ykRqVQpjX7ldFvCgw0iSYnK1H584EAAWDx-8znw>. Acesso em: 08 de Fev. 2024.

NV, M. K., KK, B. K., & MUDHOL, A. C. Machine learning based Prediction of Customer *Churning* in Banking Sector. (2022, November). In 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAIS) (pp. 474-481). IEEE. Disponível em:< https://ieeexplore.ieee.org/abstract/document/10011126?casa_token=1PaITG-cWosAAAAA:W_ERF_Dy_rPrfoQbS2Qx8QzHHCyTjkCNgsZzuj6iunVaNKrx7FNjgLtcadk-qzPz_UcAezM5JQ>. Acesso em: 10 de Fev. 2024.

PEREIRA, D. C. B. Aprendizado de máquina e aplicação do método de aprendizado supervisionado support vector machine. (2018). Disponível em:< https://app.uff.br/riuff/bitstream/handle/1/13609/tcc_20182_DeborahCholodovskyBarbedoPereira_113054013.pdf?sequence=1&isAllowed=y>. Acesso em: 25 de Jan. 2024.

PRAKASH, U., ANILA, A., SWETHA, C., VIGNESHWARAN, K., & KAVINAYAA, N. A Survey on Artificial Intelligence in Telecommunication for Churn Prediction. (2022, December). In 2022 6th International Conference on Electronics, Communication and Aerospace Technology (pp. 1261-1265). IEEE. Disponível em:< <https://jowua.com/wp-content/uploads/2023/04/2023.II.012.pdf>>. Acesso em: 08 de Fev. 2024.

PUSTOKHINA, I. V., PUSTOKHIN, D. A., NGUYEN, P. T., ELHOSENY, M., & SHANKAR, K. Multi-objective rain optimization algorithm with WELM model for customer churn prediction in telecommunication sector. *Complex Intell. Syst.*, 2021. Disponível em:< <https://link.springer.com/article/10.1007/s40747-021-00353-6>>. Acesso em: 09 de Fev. 2024.

RAHMAN, M., & KUMAR, V. Machine learning based customer *churn* prediction in banking. (2020, November). In 2020 4th international conference on electronics, communication and aerospace technology (ICECA) (pp. 1196-1201). IEEE. Disponível em:< https://ieeexplore.ieee.org/abstract/document/9297529?casa_token=SREtAejlIZcAAAAA:cIKJKGGVhDBr6p6FDbXA7wEcaLk8MTOA23ppRv5P_e3Jkby5BMrrL3kC1O8fhxd2fVCv7p6kNQ>. Acesso em: 07 de Fev. 2024.



RAJ, A., & VETRITHANGAM, D. Prediction of customer churn using resampling and ensemble classification algorithms on telecom dataset. (2023, April). In 2023 11th International Conference on Emerging Trends in Engineering & Technology-Signal and Information Processing (ICETET-SIP) (pp. 1-7). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10151659?casa_token=cKKd311xdgYAAAAA:q4qSTchnsejZbljSxmKfgDwbLRJvOx4csi0n6BCrBj-a1een6hzI6wfEE-GwE_EuU8Va9kVgQg>. Acesso em: 08 de Fev. 2024.

SAGALA, N. T. M., & PERMAI, S. D. Enhanced Churn Prediction Model with Boosted Trees Algorithms in The Banking Sector. (2021, October). In 2021 International Conference on Data Science and Its Applications (ICoDSA) (pp. 240-245). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9617503?casa_token=mIVNPzJI6DUAAAAA:INQnYsSI4KtMvfZ5OaKs70vg-I1wzEuvQ1rm1vtkL9arLm4Q_Ta7hsc2m-C1St2K0Gjx06AUxQ>. Acesso em: 13 de Fev. 2024.

SAHEED, Y. K., & HAMBALI, M. A. Customer churn prediction in telecom sector with machine learning and information gain filter feature selection algorithms. (2021, October). In 2021 International Conference on Data Analytics for Business and Industry (ICDABI) (pp. 208-213). IEEE. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9655792>>. Acesso em: 07 de Fev. 2024.

SAIAS, J., Rato, L., & Gonçalves, T. Estudo sobre a Predição de Churn. (2018). Disponível em: <https://dspace.uevora.pt/rdpc/bitstream/10174/30175/1/apra_techReport_paper02_2018-12_v02.pdf>. Acesso em: 19 de Jan. 2024.

SALIAN, P., MURTHY, A., & SALIAN, S. Analysis of Telecom Churn using *Machine learning* Techniques. (2022, December). In 2022 International Conference on Artificial Intelligence and Data Engineering (AIDE) (pp. 58-63). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10060222?casa_token=42dPUVw2WgYAAAAA:6pcWXCrbq3fFMdiNnyj-BkmLepFXZww1BBmtdCc40EwqboySV9LsciEoDSDybwXeZveCXKOaaA>. Acesso em: 10 de Fev. 2024.

SANTOS, G. C. Algoritmos de *machine learning* para previsão de ações da B3. (2020). Disponível em: <<https://repositorio.ufu.br/bitstream/123456789/29897/7/AlgoritmosMachineLearning.pdf>>. Acesso em: 23 de Jan. 2024.

SHAHID, A., HUSSAIN, M., & IQBAL, A. Machine learning Based Improved Customer Churn Prediction Model for Telecommunications Industry. (2023, November). In 2023 18th International Conference on Emerging Technologies (ICET) (pp. 147-153). IEEE. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10375037?casa_token=u5zuNbFkmDMAAAAA:oG7TT9seTKeQ3kKARVS0KLv6U50eud46DkOQaba0ouin70NyaqZKUrvh2kU9dc8SDSHIDb5htA>. Acesso em: 08 de Fev. 2024.

SHRESTHA, S. M., & SHAKYA, A. A Customer *Churn* Prediction Model using XGBoost for the Telecommunication Industry in Nepal. *Procedia Computer Science*, 215, 652-661, 2022. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187705092202138X>>. Acesso em: 08 de Fev. 2024.

SHUMALY, S., NEYSARYAN, P., & GUO, Y. Handling class imbalance in customer churn prediction in telecom sector using sampling techniques, bagging and boosting trees. (2020, October). In 2020 10th International Conference on Computer and Knowledge Engineering (ICCCKE) (pp. 082-087). IEEE. Disponível em: <



https://ieeexplore.ieee.org/abstract/document/9303698?casa_token=L7ibJqjsw_QAAAAA:v7o2DTWCc218aY_uJYXZWhiNZxTQpsACpDtKk_MEH7kswpriUNSH33-bwgGnmTeBztFchNhq0g>. Acesso em: 14 de Fev. 2024.

SIVIERO, M. R. L., & JÚNIOR, E. R. H. Algoritmos de Aprendizado de Máquina Aplicados à Parâmetros Mensurados no Rio Atibaia/SP. (2011). XIX Simpósio Brasileiro de Recursos Hídricos. Maceió–AL. Disponível em:<https://files.abrhidro.org.br/Eventos/Trabalhos/153/2ba206a8bc6975a0053bc7af628fca4a_01d02f5e68aec9c3e85baf3edc61acad.pdf>. Acesso em: 25 de Jan. 2024.

SONI, P. K., & NELSON, L. PCP: Profit-Driven Churn Prediction using Machine learning Techniques in Banking Sector. *International Journal of Performability Engineering*, 19(5), 2023. Disponível em:<<https://www.ijpe-online.com/EN/Y2023/V19/I5/303>>. Acesso em: 05 de Fev. 2024.

SOUNDARYA, B. C., GURURAJ, H. L., CHAITHRA, K. N., MANU, M. N., SHRIKANTH, N. G., & ANUPAMA, K. Minimization of Churn Rate Through Analysis of Machine learning. (2023, April). In 2023 International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE) (pp. 1-5). IEEE. Disponível em:<https://ieeexplore.ieee.org/abstract/document/10150441?casa_token=cennEmQ2dHYAAAAA:oKgIRqEw4okZ56VJJoy351AfGG2_XZX9hiXy7uoVeD2tJ25tLLJMLymWkQVC7zY8KfnWGiVfcfg>. Acesso em: 0 de Fev. 2024.

SOUSA, A. J. T. D. S. Aplicação de técnicas de Machine learning para a previsão de processos industriais (Doctoral dissertation). (2023). Disponível em:<<https://repositorium.sdum.uminho.pt/bitstream/1822/83739/1/Afonso%20Jose%20Torres%20da%20Silva%20e%20Sousa.pdf>>. Acesso em: 08 de Fev. 2024.

SOUZA, F. A. A. D. Análise de desempenho da rede neural artificial do tipo multilayer perceptron na era multicore (Master's thesis, Universidade Federal do Rio Grande do Norte). (2012). Disponível em:<https://repositorio.ufrn.br/bitstream/123456789/15447/1/FranciscoAAS_DISSERT.pdf>. Acesso em: 21 de Jan. 2024.

SPOLADOR, R. H. Aplicação do método de Gradient Boosting. (2021). Disponível em:<https://app.uff.br/riuff/bitstream/handle/1/25319/tcc_20202_RodolfoHauret_117054008.pdf?sequence=1&isAllowed=y>. Acesso em: 26 de Jan. 2024.

SRINIVASAN, R., RAJESWARI, D., & ELANGO VAN, G. Customer Churn Prediction Using Machine learning Approaches. (2023, January). In 2023 International Conference on Artificial Intelligence and Knowledge Discovery in Concurrent Engineering (ICECONF) (pp. 1-6). IEEE. Disponível em:<https://ieeexplore.ieee.org/abstract/document/10083813?casa_token=fe265jkAxosAAAAA:wlgNi5hgOGTQfePe1271M_aixKhxUhzPxsM2Mp5XdzWjHbg98PU-c2XWkr-3B5OXLIRITp2FRw>. Acesso em: 13 de Fev. 2024.

SUH, Y. Machine learning based customer churn prediction in home appliance rental business. *Journal of big Data*, 10(1), 41, 2023. Disponível em:< <https://link.springer.com/article/10.1186/s40537-023-00721-8>>. Acesso em: 07 de Fev. 2024.

TRAN, H., LE, N., & NGUYEN, V. H. Customer *churn* prediction in the banking sector using machine learning-based classification models. *Interdisciplinary Journal of Information, Knowledge &*



Management, 18, 2023. Disponível em:< <https://www.proquest.com/docview/2793437267?pq-origsite=gscholar&fromopenview=true&sourcetype=Scholarly%20Journals>>. Acesso em: 09 de Fev. 2024.

TRANFIELD, D., DENYER, D., & SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British journal of management*, 14(3), 207-222, 2003. Disponível em:< [https://josephmahoney.web.illinois.edu/BADM504_Fall%202019/6_Tranfield,%20Denyer%20and%20Smart%20\(2003\).pdf](https://josephmahoney.web.illinois.edu/BADM504_Fall%202019/6_Tranfield,%20Denyer%20and%20Smart%20(2003).pdf)>. Acesso em: 28 de Jan. 2024.

VAKEEL, A., VANTARI, N. R., REDDY, S. N., MUTHYAPU, R., & CHAVAN, A. Machine learning models for predicting and clustering customer churn based on boosting algorithms and gaussian mixture model. (2022, January). In *2022 International Conference for Advancement in Technology (ICONAT)* (pp. 1-5). IEEE. Disponível em:<<https://ieeexplore.ieee.org/abstract/document/9725957>>. Acesso em: 12 de Fev. 2024.

VEZZOLI, M., ZOGMAISTER, C., & VAN DEN POEL, D. Will they stay or will they go? predicting customer churn in the energy sector. *Applied Marketing Analytics*, 6(2), 136-150, 2020. Disponível em:< <https://www.ingentaconnect.com/content/hsp/ama/2020/00000006/00000002/art00006>>. Acesso em: 07 de Fev. 2024.

WAGH, S. K., ANDHALE, A. A., WAGH, K. S., PANSARE, J. R., AMBADEKAR, S. P., & GAWANDE, S. H. Customer *churn* prediction in telecom sector using machine learning techniques. (2024). *Results in Control and Optimization*, 14, 100342. Disponível em:< <https://www.sciencedirect.com/science/article/pii/S2666720723001443>>. Acesso em: 08 de Fev. 2024.

WANG, X., NGUYEN, K., & NGUYEN, B. P. *Churn* prediction using ensemble learning. (2020, January). In *Proceedings of the 4th international conference on machine learning and soft computing* (pp. 56-60). Disponível em:<https://www.researchgate.net/profile/Xing-Wang-66/publication/339778112_Churn_Prediction_using_Ensemble_Learning/links/60f9b0a61e95fe241a80e6e6/Churn-Prediction-using-Ensemble-Learning.pdf>. Acesso em: 23 de Jan. 2024.

ZDANAVIČIŪTĖ, M., JUOZAITIENĖ, R., & KRILAVIČIUS, T. Telecommunication customer *churn* prediction using machine learning methods. (2022). Disponível em:<<https://eur-ws.org/Vol-3611/paper15.pdf>>. Acesso em: 12 de Fev. 2024.