

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

PEDRO HENRIQUE TERRA DA SILVA

**APLICAÇÃO DE MACHINE LEARNING PARA CLASSIFICAÇÃO DO GRAU DE
CONFIANÇA DE SERVIDORES PÚBLICOS FEDERAIS EM GESTORES E
DEMAIS AGENTES PÚBLICOS**

**LONDRINA
2023**

PEDRO HENRIQUE TERRA DA SILVA

**APLICAÇÃO DE MACHINE LEARNING PARA CLASSIFICAÇÃO DO GRAU DE
CONFIANÇA DE SERVIDORES PÚBLICOS FEDERAIS EM GESTORES E
DEMAIS AGENTES PÚBLICOS**

**Application of machine learning for classifying the level of trust of federal
public servants on managers and other public agents**

Trabalho de Conclusão de Curso apresentado como requisito para obtenção do título de Bacharel em Engenharia de Produção, do Departamento Acadêmico de Engenharia de Produção da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Bruno Samways dos Santos.

LONDRINA

2023



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

PEDRO HENRIQUE TERRA DA SILVA

**APLICAÇÃO DE MACHINE LEARNING PARA CLASSIFICAÇÃO DO GRAU DE
CONFIANÇA DE SERVIDORES PÚBLICOS FEDERAIS EM GESTORES E
DEMAIS AGENTES PÚBLICOS**

Trabalho de Conclusão de Curso apresentado como requisito parcial ao título de Bacharel em Engenharia de Produção, do Departamento Acadêmico de Engenharia de Produção da Universidade Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 12/junho/2023

Bruno Samways dos Santos
Doutorado
Universidade Tecnológica Federal do Paraná

Rafael Henrique Palma Lima
Doutorado
Universidade Tecnológica Federal do Paraná

Rogério Tondato
Doutorado
Universidade Tecnológica Federal do Paraná

LONDRINA

2023

AGRADECIMENTOS

Agradeço aos meus pais e meus avós por me apoiarem e prestarem o suporte necessário para enfrentar todos os desafios durante essa jornada.

A Débora, minha namorada, por todo amor, carinho e incentivo.

Aos meus amigos Arthur, Ana e Ariane pela nossa parceria e amizade.

Ao meu orientador Prof. Dr. Bruno Samways dos Santos por toda ajuda e contribuição durante esse processo.

Agradeço por fim a experiência vivida na Aprimora, empresa júnior que tive a oportunidade de participar da fundação, e a todos que contribuíram e contribuem para dar continuidade a esse projeto tão especial.

RESUMO

A mineração de dados e o aprendizado de máquina são ferramentas cada vez mais utilizadas na atualidade para a análise de dados nos mais diversos setores da sociedade. A corrupção no serviço público é tema de diversos estudos que buscam entender esse fenômeno, no entanto, ainda há uma carência de pesquisas que analisam os impactos desse tipo de conduta no âmbito organizacional a partir da aplicação de aprendizado de máquina. Por esse motivo técnicas de aprendizado de máquina se apresentam como uma ferramenta para estudar esse cenário. Nesse sentido, o objetivo desta pesquisa foi o de aplicar algoritmos de mineração de dados para a classificação do nível de confiança de servidores públicos federais brasileiros com relação aos dirigentes e demais agentes públicos de sua organização. Para tanto, foi utilizada uma base de dados pública com respostas de um questionário sobre ética e corrupção no serviço público federal. Os resultados indicaram que a melhor acurácia obtida foi de 87% para predição da confiança nos gestores e 85% para os colegas de trabalho. Além disso, o estudo apontou que os principais fatores considerados pelos algoritmos para classificação da confiança foram a observação de casos de corrupção, conduta antiética, favorecimento indevido e transparência dentro da organização. Dessa maneira, foi possível concluir que o modelo preditivo elucidou aspectos relevantes na percepção da confiança dentro das organizações públicas.

Palavras-chave: corrupção; aprendizado de máquina; mineração de dados; confiança; gestão pública.

ABSTRACT

Data mining and machine learning are tools that are increasingly used nowadays for data analysis in the most diverse sectors of society. Corruption in the public service is the subject of several studies that seek to understand this phenomenon, however, there is still a lack of research that analyzes the impacts of this type of conduct at the organizational level from the application of machine learning. For this reason, machine learning techniques are presented as a tool to study this scenario. In this way, the goal of this research was to apply data mining algorithms to classify the level of confidence of Brazilian federal public servants in the leaders and other public agents of their organization. For that, a public database was used with answers to a questionnaire on ethics and corruption in the federal public service. The results indicated that the best accuracy obtained was 87% for predicting confidence in managers and 85% for coworkers. In addition, the study identified that the main factors considered by the algorithms for ranking trust were the observation of cases of corruption, unethical conduct, undue favoritism, and transparency inside the organization. In conclusion, the predictive model clarified relevant aspects in the perception of trust within public organizations.

Keywords: corruption; machine learning; data mining; trust; public management.

SUMÁRIO

1. INTRODUÇÃO.....	7
1.1 Objetivo Geral.....	8
1.2 Objetivos Específicos.....	8
1.3 Justificativa.....	9
1.4 Estrutura do Trabalho.....	9
2. REFERENCIAL TEÓRICO.....	11
2.1 Mineração de Dados e KDD (<i>Knowledge Discovery in Database</i>).....	11
2.2 Tipos de Aprendizado e Tarefas de Mineração de Dados.....	13
2.3 Técnicas de Classificação.....	14
2.3.1 <i>K-Nearest Neighbors</i> (KNN).....	15
2.3.2 Naïve Bayes.....	16
2.3.3 Árvore de Decisão.....	16
2.3.4 Floresta Aleatória.....	17
2.3.5 Redes Neurais.....	18
2.4 Métricas de Desempenho.....	20
2.5 Corrupção, Ética e Confiança.....	21
2.6 Trabalhos Correlatos.....	23
3. METODOLOGIA.....	27
3.1 Descrição do Conjunto de Dados.....	27
3.2 Recursos Utilizados.....	28
3.3 Etapas da Pesquisa.....	29
4. RESULTADOS E DISCUSSÕES.....	35
4.1 Análise de Classes.....	35
4.2 Mineração de Dados.....	36
4.3 Análise de Variáveis.....	41
4.4 Classificação de instâncias regulares.....	47
5. CONCLUSÃO.....	49
REFERÊNCIAS.....	51
APÊNDICE A - Quadro com variáveis de entrada.....	58

1. INTRODUÇÃO

Atualmente tem sido discutido sobre a aplicação e importância da mineração de dados e do *machine learning* (aprendizado de máquina), que abrangem as mais diversas áreas do conhecimento.

A mineração de dados segundo Fayyad, Shapiro e Smyth (1996) é uma etapa no processo KDD (*Knowledge Discovery in Databases*) que consiste em aplicar a análise de dados e algoritmos de descoberta com o objetivo de extrair padrões dos dados. Para AL-Nabi e Ahmed (2013), a mineração de dados é uma tecnologia com grande potencial para ajudar negócios e empresas a focar nas informações mais relevantes extraídas dos dados por elas coletados. Outra aplicação é na administração pública, pois de acordo com Figueiredo e Cabral (2020) o *machine learning* é capaz de efetuar a intersecção de dados e informações de forma eficaz, possibilitando, por exemplo, o enfrentamento à corrupção.

Dentro da mineração de dados existem diferentes tipos de algoritmos que podem ser aplicados com o intuito de encontrar padrões e modelos, como classificação, clusterização, associação, regressão, entre outros. Este trabalho estará centrado na aplicação de algoritmos apenas de classificação, sendo esses os algoritmos *K-Nearest Neighbors* (KNN), *Naïve Bayes*, Árvore de Decisão, Floresta Aleatória e Redes Neurais. A tarefa de classificação de acordo com Kumar e Verma (2012) tem como entrada uma coleção de casos, cada um pertencente a determinadas classes e descritos por seus valores em um conjunto fixo de atributos e, como saída, geram um classificador que pode prever com precisão a classe à qual um novo caso pertence.

Uma das fontes de dados disponíveis para a aplicação da mineração de dados são os dados públicos, os quais segundo Dutra e Lopes (2013) proporcionam que sejam geradas novas informações e conhecimentos que resultem em inovações na prestação de serviços públicos. Também de acordo com Dutra e Lopes (2013), os dados abertos podem contribuir ainda com a melhoria de processos dentro da gestão interna do governo, visto que trazem espaço para contribuições da sociedade.

No cenário brasileiro é comum a falta de confiança nos agentes públicos, devido entre outros fatores aos casos de corrupção, o que é negativo para a população. O levantamento feito por Ramos *et al.* (2021) no relatório ICJBrasil 2021,

da Escola de Direito de São Paulo da Fundação Getúlio Vargas, apontou que o grau de confiança no Governo Federal, por exemplo, caiu de 38% em 2011 para 6% em 2017. Para Fockink (2019), a corrupção prejudica a eficiência de gestão e afeta a confiança da população nas instituições brasileiras, elemento esse com importância fundamental para o funcionamento efetivo das instituições públicas. Além disso, de acordo com Neiva (2018) existe uma complexidade em investigar, reconhecer e medir a corrupção como algo tangível e suscetível a análises.

Nesse sentido, a pesquisa de Nieto (2021), intitulada “Ética e Corrupção no Serviço Público Federal: A Perspectiva dos Servidores”, realizada pelo Banco Mundial em parceria com a Controladoria Geral da União (CGU), disponibiliza dados sobre as respostas de servidores públicos federais sobre suas percepções e enfrentamento a questões de ética e corrupção no dia a dia de trabalho. No presente trabalho, a classificação foi realizada com o intuito de prever a confiança de funcionários do serviço público federal em relação aos seus colegas de trabalho e gestores.

1.1 Objetivo Geral

O objetivo deste trabalho é aplicar algoritmos de mineração de dados para a classificação do nível de confiança nos gestores e colegas de trabalho, a partir da percepção dos funcionários dos órgãos do serviço público federal brasileiro utilizando uma base de dados pública.

1.2 Objetivos Específicos

- Realizar o pré-processamento da base de dados para a aplicação algoritmos de classificação.
- Aplicar diferentes técnicas de classificação na análise da base de dados.
- Realizar diferentes experimentos para estudo do conjunto de dados.
- Avaliar o desempenho dos algoritmos a partir dos resultados das métricas de desempenho.
- Discutir sobre os principais atributos que influenciam a classificação dos respondentes.

1.3 Justificativa

Debates sobre ética e corrupção no serviço público estão presentes no cotidiano da população brasileira. Filgueiras (2009) afirma que há uma insatisfação coletiva com a corrupção, a qual gera um senso comum de que o brasileiro é tipicamente desonesto.

Essa é uma questão relevante, pois de acordo com Lima Junior (2010), a ética do agente público deve ser compatível com os valores associados ao bem comum almejado pela sociedade. Dessa maneira, é de interesse comum obter informações confiáveis sobre ética e confiança dentro de órgãos públicos.

Para Lima e Delen (2020), como a corrupção está presente na sociedade ao longo do tempo, sua relevância em todo o mundo faz dela um desafio digno para a aplicação de técnicas de aprendizado de máquina. De acordo com Neiva (2018) há uma dificuldade dos órgãos de controle em lidar com um expressivo volume de informações, o que propicia a aplicação de algoritmos de aprendizado de máquina, pois a quantidade de informações disponíveis está diretamente relacionada com a eficácia desses métodos.

Lima e Delen (2020) afirmam que a corrupção é um fenômeno social universal, desafiador e instigante, nesse sentido, esta pesquisa se justifica por gerar insumos para auxiliar a sociedade e órgãos públicos federais a conhecer o cenário do nível de confiança entre agentes públicos, a partir de uma ferramenta computacional para a análise, a mineração de dados.

1.4 Estrutura do Trabalho

Após o primeiro Capítulo de introdução, o presente trabalho está dividido em mais quatro capítulos. O Capítulo 2 é composta pelo referencial teórico que aborda os principais conceitos utilizados na aplicação da pesquisa como mineração de dados, tipos de aprendizado de máquina, diferentes técnicas de classificação, corrupção, ética e confiança, e trabalhos correlatos.

O Capítulo 3 descreve o conjunto de dados e a metodologia utilizada no trabalho, a partir da explicação dos passos feitos desde o pré-processamento até a aplicação dos algoritmos de classificação. O Capítulo 4 apresenta os principais resultados obtidos, compara os experimentos realizados e discute os principais

atributos de entrada considerados pelo modelo. A quinto e último Capítulo do trabalho aborda as conclusões levantadas após a aplicação da pesquisa.

2. REFERENCIAL TEÓRICO

Este capítulo aborda os conceitos sobre mineração de dados e o processo de KDD, bem como as técnicas de aprendizado de máquina e métricas utilizadas neste trabalho. Além disso, também trata sobre a ética e corrupção nos órgãos públicos e apresenta trabalhos correlatos a presente pesquisa.

2.1 Mineração de Dados e KDD (*Knowledge Discovery in Database*)

A mineração de dados, do inglês *Data Mining*, é uma tecnologia muito promissora, segundo Camilo e Silva (2009). Isso pode ser justificado, de acordo com Mahesh (2020), devido à enorme quantidade de bases de dados atualmente disponíveis.

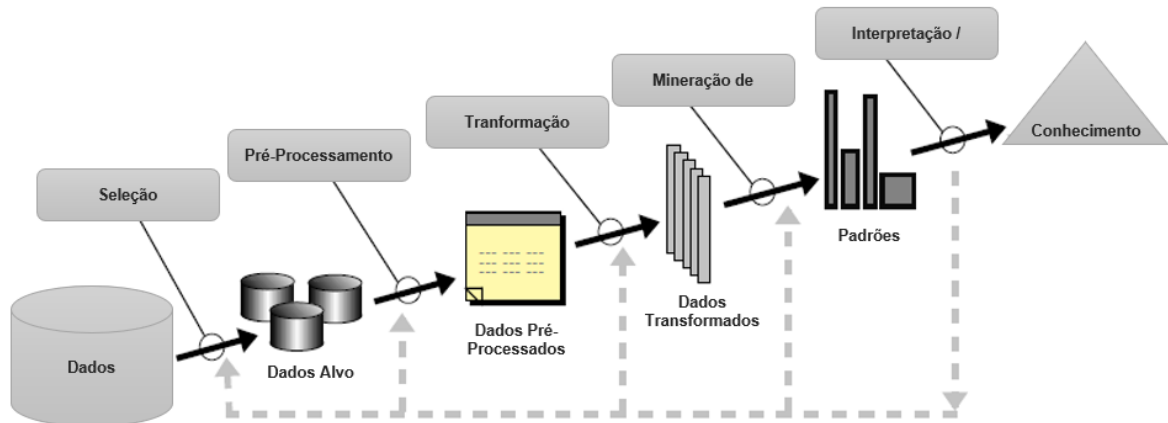
Segundo Luo (2008), mineração de dados é o processo de analisar dados por diferentes perspectivas e resumi-los em informações relevantes. Essa definição pode ser completada por Liu *et al.* (2019), que explica a mineração de dados como o meio para coletar, gerir, processar, analisar e visualizar um grande volume de dados.

A mineração de dados também pode ser considerada uma ferramenta para resolver problemas desafiadores, os quais para Shapiro, Djeraba e Getoor (2006), devem atender seis critérios:

- Ser difícil de resolver, dado ao atual nível de conhecimento sobre o tema;
- A mineração de dados deve ter um papel importante na resolução do problema;
- Ser baseado em uma base de dados ampla e publicamente disponível;
- Deve haver um objetivo claro;
- O problema é interessante aos pesquisadores e compreensível para a sociedade;
- Promove um benefício significativo a população quando resolvido.

Além disso, Fayyad, Shapiro e Smyth (1996) defendem que a mineração de dados é uma das etapas dentro do KDD (*Knowledge Discovery in Databases*), processo de descoberta de conhecimento extraído de bases de dados e ainda o define como o processo não trivial de identificar em dados padrões válidos, novos, potencialmente úteis e compreensíveis, o qual pode ser representado pela Figura 1.

Figura 1 – Processo KDD



Fonte: Adaptado de Fayyad, Shapiro e Smyth (1996, p. 41).

O processo do KDD é composto, de acordo com Luo (2008), por algumas etapas, sendo elas a seleção de dados, pré-processamento, transformação dos dados, mineração de dados e por fim a interpretação, avaliação e apresentação dos resultados obtidos. Segundo Fayyad, Shapiro e Smyth (1996), a aplicação isolada de métodos da mineração de dados pode levar a padrões inválidos e sem sentido, portanto, ressalta que os demais passos do processo de KDD são essenciais para obter-se conhecimentos relevantes a partir dos dados.

Na etapa de seleção de acordo com Fayyad, Shapiro e Smyth (1996) é necessário em primeiro lugar definir um objetivo claro para a aplicação do processo de KDD e depois obter um conjunto de dados para que o processo possa ser executado.

As etapas de pré-processamento e transformação são consideradas por Castro e Ferrari (2016) como etapas que buscam preparar os dados para uma análise eficiente a partir da mineração de dados. O pré-processamento, segundo Castro e Ferrari (2016) é composto pela limpeza de dados inconsistentes, integração dados obtidos de diversas fontes, a seleção dos dados pertinentes ao estudo e a transformação dos dados em formatos adequados para a aplicação das técnicas de mineração.

Após a aplicação na mineração de dados, o próximo passo proposto por Fayyad, Shapiro e Smyth (1996) é a interpretação dos padrões minerados, etapa que também pode envolver a construção da visualização dos padrões e modelos extraídos.

2.2 Tipos de Aprendizado e Tarefas de Mineração de Dados

A mineração de dados também está diretamente relacionada com o *machine learning*, em português, aprendizado de máquina. Para Kumar e Verma (2012), dentre as diversas aplicações para o *machine learning*, a mais importante delas é a mineração de dados. Segundo Mahesh (2020), o *machine learning* é utilizado para ensinar máquinas a trabalhar de maneira mais eficiente com dados e tem como objetivo aprender com eles.

Os algoritmos de *machine learning* podem ser classificados em algumas categorias, as principais delas, de acordo com Soofi e Awan (2017), são o aprendizado supervisionado e o não supervisionado. Segundo Nasteski (2017) algoritmos supervisionados possuem classes pré-determinadas, enquanto para algoritmos não supervisionados a principal tarefa é desenvolver os rótulos de classificação. No mesmo sentido, para Camilo e Silva (2009), a diferença entre os dois tipos de aprendizado é que, ao contrário dos supervisionados, os métodos não supervisionados não precisam ter rótulos associados, ou seja, não necessitam de um atributo alvo.

Além disso, para cada tipo de aprendizado algumas tarefas podem ser aplicadas, segundo AL-Nabi e Ahmed (2013) tarefas como classificação, regressão, clusterização, associação, entre outras, possuem próprios e diferentes algoritmos para encontrar um modelo para os dados.

Essas tarefas são explicadas e exemplificadas por Larose e Larose (2014) da seguinte maneira:

- **Classificação:** Na classificação, existe uma variável alvo categórica, como por exemplo, a faixa de renda: alta renda e baixa renda. O modelo de mineração de dados, poderia classificar a faixa de renda, com base nas outras características associadas a esse indivíduo, como idade, sexo e ocupação;
- **Regressão:** Na regressão, o valor de uma variável alvo numérica é estimada a partir de um conjunto de variáveis preditoras, sejam numéricas e/ou categóricas. Por exemplo, é possível construir um modelo para estimar a pressão arterial de um paciente, com base na idade, sexo, índice de massa corporal, entre outras variáveis;

- **Clusterização:** A clusterização refere-se ao agrupamento de registros, observações ou casos em classes de objetos semelhantes. A tarefa de clusterização não tenta classificar, estimar ou prever o valor de uma variável de destino, ao invés disso, procura segmentar todo o conjunto de dados em subgrupos ou *clusters* relativamente homogêneos, onde a similaridade dos registros dentro do cluster é maximizada, e a similaridade para registros fora desse cluster é minimizado. Por exemplo, aplicar a tarefa em uma auditoria contábil, a fim de segmentar o comportamento financeiro em categorias suspeitas ou não;
- **Associação:** A tarefa de associação busca descobrir regras para quantificar a relação entre dois ou mais atributos, no sentido de que se determinado atributo A acontece então conseqüentemente o atributo B também acontece. Uma aplicação é descobrir quais itens em um supermercado são comprados juntos e quais os itens nunca são comprados juntos.

2.3 Técnicas de Classificação

A tarefa de classificação é umas das principais técnicas que utilizam o aprendizado supervisionado. De acordo com AL-Nabi e Ahmed (2013) técnicas de classificação na mineração de dados podem processar um grande volume de dados e prever a categoria em que os dados podem ser classificados a partir do conjunto de treinamento e classes pré-definidas.

Segundo Kumar e Verma (2012) essa técnica tem como entrada uma coleção de casos, cada um pertencente a determinadas classes e descritos por seus valores em um conjunto fixo de atributos. Como saída, geram um classificador que pode prever com precisão a classe à qual um novo caso pertence. É possível caracterizar o conjunto de entrada como X e o conjunto de saída como y . Nesse sentido, Souza, Tomazi e Santos (2022) indicam que y deve ser categórico, mas o conjunto de atributos preditores X pode assumir qualquer tipo de valor.

Dentre as diversas técnicas de classificação, podem ser citadas algumas das técnicas existentes, como *K-Nearest Neighbors* (KNN), *Naïve Bayes*, *Árvore de*

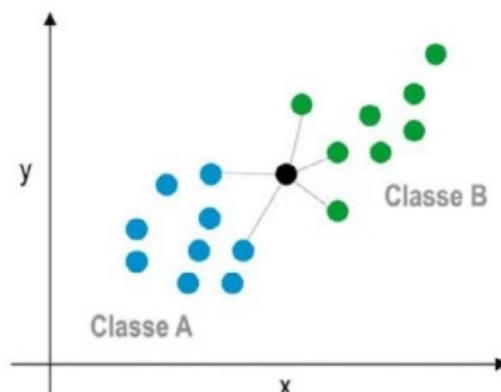
Decisão, Floresta Aleatória e Redes Neurais as quais serão detalhadas nas subseções a seguir.

2.3.1 *K-Nearest Neighbors* (KNN)

O método *K-Nearest Neighbors* (KNN) é explicado por Silva, Peres e Boscaroli (2016) como um algoritmo que classifica um caso de classe desconhecida ao compará-lo com casos de classe já conhecida, o que caracteriza um aprendizado baseado em instâncias. Silva, Peres e Boscaroli (2016) complementam que o princípio utilizado nesse método é o de armazenar o conjunto de treino e comparar a instância de teste com as instâncias armazenadas a cada vez que uma instância de teste é apresentada. Ele também é conhecido como algoritmo preguiçoso, do inglês *lazy learning*, pois como esclarece Castro e Ferrari (2016), não há um treinamento prévio, já que apenas quando se pretende classificar um novo objeto que sua saída é determinada.

A aplicação do KNN é apresentada por Goldschmidt, Bezerra e Passos (2015) a partir de três passos, primeiramente deve ser calculada a distância do novo exemplar em relação aos exemplares do conjunto de referência, depois disso, são identificados os k exemplares desse conjunto que estiverem mais próximos do exemplar de teste e, no terceiro passo, dentre os k exemplares identificados, a classe mais frequente é verificada. Castro e Ferrari (2016) esclarecem que o número de vizinhos mais próximos (k) é o único parâmetro que deve ser indicado para a aplicação do KNN. A Figura 2 exemplifica a aplicação do modelo.

Figura 2 - KNN



Fonte: Adaptado de Mariano *et al.* (2021, p. 207).

Considerando k igual a 5, quando o novo exemplar de teste é inserido ele é comparado aos cinco vizinhos mais próximos. Nesse caso, dentre os vizinhos analisados, três são pertencentes a classe B e dois a classe A, dessa maneira, o novo registro é classificado como pertencente a classe B.

Para a avaliação do método KNN podem ser citadas como exemplo duas métricas de distâncias dentre as diversas existentes, as distâncias Euclidiana e de Manhattan. Segundo Goldschmidt, Bezerra e Passos (2015), a Euclidiana é referente à medida de distância entre dois pontos em linha reta (Equação 1), enquanto a distância de Manhattan é medida entre os mesmos dois pontos, contudo, é feita ao longo dos eixos cartesianos em ângulos retos (Equação 2).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (2)$$

2.3.2 Naïve Bayes

O classificador *Naïve Bayes*, de acordo com Darwiche (2009) *apud* Castro e Ferrari (2016) é um classificador estatístico com base no Teorema de *Bayes* e ele é utilizado para prever a probabilidade de um objeto pertencer a determinada classe. Segundo Sayfullina *et al.* (2015) esse classificador é chamado de “ingênuo”, pois assume que todos os atributos são independentes, condicionados à classe saída.

Goldschmidt, Bezerra e Passos (2015) explica que o classificador *Naïve Bayes* é baseado em dois passos, o primeiro é calcular as probabilidades condicionais $P(C = c|R), i = 1, 2, \dots, k$, em que c são possíveis valores do atributo-alvo C e R uma nova instância a ser classificada, o segundo é designar a classe de saída c em que $P(C = c|R)$ tenha o valor máximo.

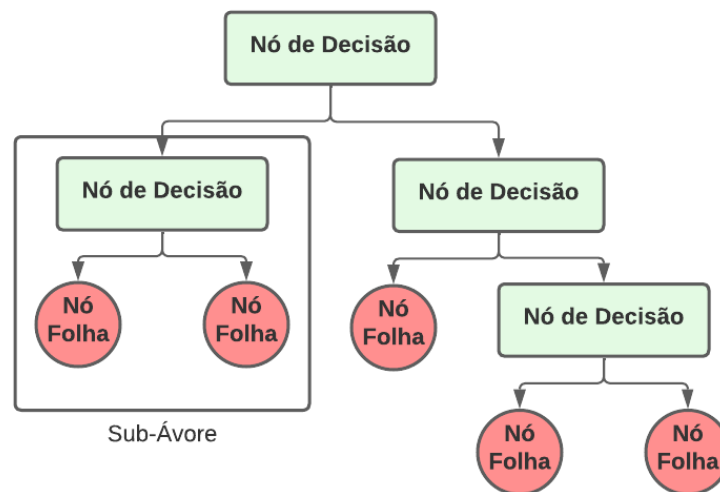
Dentre os tipos de modelos do método *Naïve Bayes* estão o modelo Gaussiano, Multinomial e Bernoulli.

2.3.3 Árvore de Decisão

A árvore de decisão é um classificador organizado em formato de árvore que, segundo Rohan e Kumari (2021), é conhecida dessa maneira pois tem início em nó

raiz que se ramifica em formato de galhos. Ainda para Rohan e Kumari (2021), é constituída de dois diferentes tipos de nós: o nó de decisão e o nó folha. O nó de decisão é referente às decisões que geram ramificações na árvore, enquanto o nó folha corresponde às ramificações dessas decisões e não contém novas ramificações, representado assim o valor ou classe de saída y , como apresentado na Figura 3.

Figura 3 – Árvore de Decisão



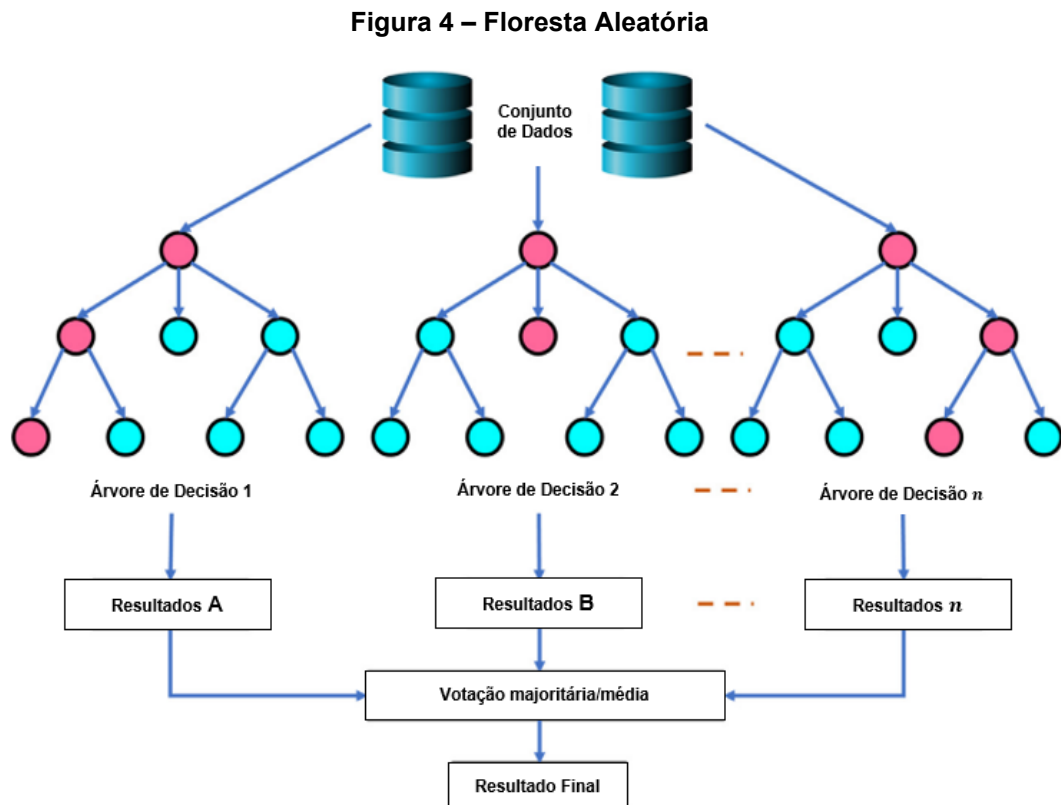
Fonte: Adaptado de Rohan e Kumari (2021, p. 1312).

De acordo com Castro e Ferrari (2016) o nó raiz corresponde ao ponto mais alto da árvore e os caminhos da raiz até um nó folha representam diferentes regras de classificação. Mariano *et al.* (2021) explica que elementos de classes desconhecidas podem ser classificados e testados após a construção da árvore de decisões.

2.3.4 Floresta Aleatória

O método floresta aleatória, do inglês *random forest*, é um método do tipo *ensemble*, que de acordo com Galiano *et al.* (2012) se baseia na premissa básica de que um conjunto de classificadores realiza previsões melhores do que um classificador individual. Segundo Petkovic *et al.* (2018), esse método consiste em um conjunto de árvores de decisão, as quais geram uma “floresta” de classificadores que vota por uma determinada classe, por meio de um algoritmo de *bagging* sem poda.

Nesse sentido, a floresta aleatória é definida por Breiman (2001) como um classificador que consiste na coleção de classificadores em formato de árvore $\{h(x, \theta_k), k = 1, \dots\}$ em que θ_k são vetores randômicos independentes e igualmente distribuídos e cada árvore atribui um voto unitário para a classe mais popular na entrada x . A representação da floresta aleatória pode ser observada na Figura 4.



Fonte: Adaptado de Liu *et al.* (2021, p. 10).

Para treinar a floresta aleatória, Petkovic *et al.* (2018) indica que dois parâmetros devem ser fornecidos, o número de árvores e o número de variáveis utilizadas para avaliar cada nó, as quais são aleatoriamente selecionadas.


2.3.5 Redes Neurais

Castro e Ferrari (2016) afirmam que as redes neurais artificiais (RNAs) são uma das ferramentas de processamento de dados mais poderosas e modernas atualmente. De acordo com Goldschmidt, Bezerra e Passos (2015), uma RNA consiste em uma técnica computacional baseada em um sistema neural biológico simplificado, a qual desenvolve um modelo matemático com capacidade de

associação, generalização, aprendizado, abstração e robustez. Além disso, Goldschmidt, Bezerra e Passos (2015) complementam que a técnica procura por conexões, cria modelos automaticamente e realiza correções com o objetivo de reduzir o seu erro.

Dentre os modelos de redes neurais está o MLP (*multilayer perceptron*), segundo Sharifi, Sharafian e Ai (2021) esse modelo é caracterizado como uma rede neural de conexões de sentido positivo (*feedforward*) e é composto por três tipos de camadas, a camada de entrada, de saída e ainda uma ou mais camadas escondidas entre as outras duas. Conforme é explicado por Driss *et al.* (2017), a camada de entrada contém os recursos de entrada da rede, já a primeira camada escondida recebe as entradas ponderadas e envia os dados da camada anterior para a próxima, por fim, a camada de saída é aquela que contém o resultado da classificação. A representação desse modelo de redes neurais pode ser observada na Figura 5.

Figura 5 – Redes Neurais (MLP)



Fonte: Adaptado de Driss *et al.* (2017, p. 2).

Para a construção e avaliação do modelo, Castro e Ferrari (2016) indicam que os parâmetros mais comuns, no caso das redes neurais, são os valores dos pesos da rede, o número de camadas e o número de neurônios.

2.4 Métricas de Desempenho

A avaliação da qualidade de um classificador pode ser feita por meio da matriz de confusão. Ela apresenta, segundo Han, Kamber e Pei (2012), a quantidade de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

Essas classes são explicadas por Castro e Ferrari (2016) da seguinte maneira:

- Verdadeiro Positivo (VP): caso em que uma instância de classe positiva (real) é classificado como positivo (predito);
- Verdadeiro Negativo (VN): caso em que uma instância de classe negativa (real) é classificado como negativo (predito);
- Falso Positivo (FP): caso em que uma instância de classe negativa (real) é classificado como positivo (predito). Também pode ser chamado de erro tipo 1;
- Falso Negativo (FN): caso em que uma instância de classe positiva (real) é classificado como negativo (predito). Também pode ser chamado de erro tipo 2.

Quadro 1 - Matriz de Confusão

Classe Original	Classe Predita - Positiva	Classe Predita - Negativa
Positiva	VP	FN
Negativa	FP	VN

Fonte: Castro e Ferrari (2016, p. 160).

A partir da matriz de confusão é possível, de acordo com Han, Kamber e Pei (2012), avaliar algumas métricas, como acurácia, sensibilidade (ou *recall*) e precisão.

A acurácia é explicada por Castro e Ferrari (2016) como a divisão entre o número de acertos pela quantidade total de possibilidades, o que retrata a taxa de conformidade dos valores medidos em relação aos valores reais. O cálculo da acurácia é representado pela Equação 3:

$$Acurácia = \frac{VP+VN}{VP+FP+VN+FN} \quad (3)$$

A sensibilidade ou *recall* é também conhecida, segundo Han, Kamber e Pei (2012), como a taxa de verdadeiros positivos, a qual indica a proporção em que as classes positivas são identificadas corretamente. A Equação 4 demonstra o cálculo da sensibilidade:

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (4)$$

Castro e Ferrari (2016) explicam que a qualidade do algoritmo pode ser medida pela precisão, que é representada pela quantidade de instâncias de classe positiva sobre o total de instâncias classificadas como positivas, como na Equação 5:

$$\text{Precisão} = \frac{VP}{VP+FP} \quad (5)$$

De acordo com Mariano *et al.* (2021) a partir da precisão e sensibilidade também é possível mensurar o *F1-score*, que considera essas duas métricas para o seu cálculo como mostra a Equação 6:

$$F1 - score = 2 * \frac{\text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} \quad (6)$$

2.5 Corrupção, Ética e Confiança

A corrupção no Brasil, segundo Costa *et al.* (2020), tomou proporções em larga escala nas décadas recentes e teve seu ápice com a descoberta de múltiplos escândalos a nível nacional. Essa situação causa graves impactos para o país, Blanchet e Azoia (2017) explicam que a corrupção afeta o crescimento econômico e proporciona uma menor prosperidade, pois empresas evitam realizar investimentos em um ambiente no qual a corrupção gera maiores custos na atividade econômica.

Luz e Capodeferro (2021) defendem que os custos advindos da corrupção afetam em diversos aspectos da sociedade e podem ser classificados em custos políticos, sociais, ambientais e econômicos. Segundo Luz e Capodeferro (2021), um dos impactos que pode ser definido dentro dos custos é a perda de confiança no governo.

Oliveira (2014) argumenta que a confiança nas ferramentas de controle da administração pública é a base para as instituições públicas obterem credibilidade perante a população. Além disso, de acordo com Covey (2017) a ética é essencial para a confiança. Mattos (2017) afirma que assegurar e fomentar a ética nos colaboradores é fundamental para manter uma excelente reputação institucional, no entanto, isso não é suficiente. Por essa perspectiva, Mattos (2017) explica que também é fundamental que a imagem institucional seja fortalecida por meio de ações concretas, tanto para o público externo quanto para o interno.

Fockink (2019) explica que a confiança depositada nas instituições está relacionada à sua capacidade de cumprir a finalidade para a qual foram criadas de maneira íntegra, eficaz e honesta. Nesse sentido, a confiança entre os agentes públicos representa um fator relevante, pois afeta a percepção externa de credibilidade. Uma das perspectivas de confiança na liderança estudada por Dirks e Ferrin (2002) é a baseada em caráter, na qual o comportamento dos liderados é influenciado por como percebem algumas características de seus líderes, como justiça, confiabilidade habilidade e integridade.

Segundo Fabossi (2019) as equipes conseguem ser mais produtivas e transparentes em situações de conflito se houver uma relação de confiança entre seus integrantes, o que proporciona maior comprometimento, responsabilidade e melhores resultados, como apresentado na Figura 6.

Figura 6 - Comportamentos das equipes que entregam os melhores resultados



Fonte: Lencioni (2015) *apud* Fabossi (2019).

No entanto, Fabossi (2019) afirma que em equipes sem relações de confiança, predominam situações de ausência de colaboração, apreensão ao expressar erros, fraquezas, dúvidas e até opiniões, o que prejudica o desempenho de todo o time. De acordo com Oliveira (2014) o processo para fortalecer a confiança é progressivo e sua consolidação favorece a implantação de um padrão de administração simplificado nas instituições públicas.

2.6 Trabalhos Correlatos

A aplicação de técnicas de *machine learning* para o estudo da corrupção e ética em nível organizacional ainda é um campo pouco explorado, o que pode ser percebido pela maior parte de publicações na área estar relacionada a fraudes ou aspectos financeiros. Delimitando-se para o objetivo dessa pesquisa, de predizer o nível de confiança nos gestores e colegas de trabalho, não foram encontrados trabalhos semelhantes por meio de uma pesquisa básica e não sistemática. No entanto, foi possível encontrar trabalhos que abordam temas relacionados ao objetivo deste trabalho, com destaque para a aplicação de *machine learning* para estudar aspectos de corrupção. A procura por trabalhos correlatos foi feita em um portal internacional, *ScienceDirect*, com termos como *machine learning*, *classification*, *corruption* e *trust* e no Google Acadêmico com os termos *machine learning*, *classificação*, *corrupção* e *confiança*, as buscas foram realizadas com diferentes combinações dessas palavras-chave. Dentre os trabalhos considerados relevantes, todos foram descritos a seguir.

Lima e Delen (2020) aplicaram e compararam as técnicas Floresta Aleatória, Redes Neurais Artificiais e *Support Vector Machine* (SVM) para explorar os mais importantes preditores para o índice de percepção da corrupção em 132 países. O conjunto de dados utilizado foi obtido a partir da combinação de várias fontes, sendo elas: “*Ease of Doing Business Indexes*”, “*The Heritage Foundation*”, “*Transparency International*” e “*The Human Development Reports of the United Nations Development program*”.

A avaliação dos modelos foi realizada por meio da análise da acurácia geral e acurácia individual das classes de saída (Alta Corrupção, Baixa Corrupção, Muito Alta Corrupção e Muito Baixa Corrupção). Com isso, a técnica que apresentou a maior acurácia foi a Floresta Aleatória, com uma acurácia geral de 85,77% e maior acurácia na predição de todas as classes. Além disso, os resultados indicaram que a integridade do governo, direitos de propriedade, eficácia judicial e índice de educação são os fatores que mais influenciaram na definição do nível de significância da corrupção.

Balaniuk *et al.* (2013) propuseram um método de avaliação de risco de corrupção associado a agências governamentais, a partir de um modelo que aplica

classificadores probabilísticos, construído com a técnica Naïve Bayes. O objetivo foi apoiar um modelo genérico de avaliação de risco que pudesse ser utilizado por organizações de auditoria do governo. O modelo foi testado no Tribunal de Contas da União (TCU) em dados relativos a todos os contratos públicos firmados pela administração federal entre 1997 e 2011.

Neiva (2018) aplicou técnicas de *machine learning* com o objetivo de classificar empresas que firmaram contratos fraudulentos com o Governo Federal brasileiro, por meio de dados de despesas efetuadas pelo governo entre 2011 e 2017, relacionados com o Cadastro de Empresas Inidôneas e Suspensas e o Cadastro Nacional de Empresas Punidas. As técnicas utilizadas foram SVM, *Bagging*, *Boosting*, Floresta Aleatória, Redes Neurais Artificiais e Regressão Logística, em que a maior acurácia foi obtida pelo método SVM, com 89,41% de acertos. Além disso, as técnicas Floresta Aleatória e *Bagging* apresentaram a menor quantidade de falsos positivos, com precisão de 98,05% e 99,62% respectivamente.

Domashova e Politova (2021) construíram o conjunto de dados inicial para análises sobre corrupção com dados do *Corruption Perception Index* (CPI), Fundo Monetário Internacional (FMI), indicadores da Organização das Nações Unidas (ONU) sobre os Objetivos do Desenvolvimento Sustentável (ODS) e do projeto *Doing Business* do Banco Mundial. A partir do conjunto elaborado, foi utilizada a tarefa de clusterização para dividir os países do mundo em grupos homogêneos de acordo com suas características e, após a separação, também foi aplicada a tarefa de classificação com o intuito de prever o nível de corrupção nos países, de acordo com cada cluster. A classificação foi feita com os métodos de Floresta Aleatória, *AdaBoost*, *Gradient Boosting* e *Bagging*, em que a maior acurácia encontrada foi pelo método de *Bagging*, com um valor de 89%.

Carvalho *et al.* (2014) aplicou a tarefa de classificação a fim de mensurar o risco de corrupção de funcionários públicos baseado em dados de filiação de partidos políticos, o qual foi comparado com um modelo desenvolvido por especialistas, já utilizado pelo Departamento de Pesquisa e Informações Estratégicas (DIE) na CGU. Para construir o conjunto de dados, foram utilizados três métodos de discretização implementados no software Weka, *Multi-interval Discretization*, *Equal-Frequency Binning* e *Proportional k-Interval Discretization*. Na sequência foram aplicadas as

técnicas de classificação Redes Bayesianas, Floresta Aleatória, SVM, e Redes Neurais Artificiais com o algoritmo *backpropagation*.

Desses modelos, a Floresta Aleatória apresentou resultados um pouco melhores que os demais métodos e com uma melhora significativa em relação ao modelo dos especialistas. A precisão se manteve em 86%, o *recall* foi maior, com 15 *p.p.* a mais de corruptos previstos, a medida *kappa* teve um ganho de 13 *p.p.*, a porcentagem de classificação correta foi 7 *p.p.* maior e o erro absoluto médio foi 12 *p.p.* menor.

Blasio, D'Ignazio e Letta (2022) utilizaram o algoritmo de Árvore de Decisão para classificar crimes de corrupção em municípios italianos a partir de uma base de dados que incluía informações entre 2008 e 2014, o foco principal do estudo foram crimes de colarinho branco. Foram definidas duas variáveis de saída binárias, uma para se a taxa de crimes de colarinho branco por 1.000 habitantes era positiva ou não e outra que indicava se essa taxa aumentou em relação ao ano anterior. As variáveis preditoras consistiram em características socioeconômicas, geográficas, demográficas e biofísicas.

O conjunto foi dividido com dados até 2012 para treino e 2013 e 2014 para teste, sendo que o conjunto de treino foi balanceado pela técnica SMOTE para aplicação do algoritmo. A acurácia para a classificação da taxa de crimes foi de 85% para 2013 e 85,3% para 2014, já para a variação da taxa entre os anos foi de 74,5% para 2013 e 76,6% para 2014.

Li *et al.* (2020) coletaram dados da API pública do *Twitter* a fim de detectar mensagens geradas pelos usuários que envolvam experiências com corrupção. O estudo aplicou uma metodologia de aprendizado de máquina não supervisionado com o uso de processamento de linguagem natural (NLP), mais especificamente, a técnica *Biterm (Biterm Topic Model)*. Foram analisados no total 22.180.425 *tweets* e apenas 0,0001% incluíam autorrelatos de corrupção. A avaliação da pesquisa foi de que a maioria dessas postagens parece estar associada a notícias ou informações da mídia, para as quais os usuários expressaram suas reações.

Quadro 2 - Trabalhos Correlatos

Autores	Objetivo	Técnicas	Abrangência Geográfica
Lima e Delen (2020)	Explorar os mais importantes preditores para o índice de percepção da corrupção.	Floresta Aleatória, Redes Neurais Artificiais e <i>Support Vector Machine</i> (SVM).	Mundo.
Balaniuk et al. (2013)	Propor um método de avaliação de risco de corrupção associado a agências governamentais, a partir de um modelo que aplica classificadores probabilísticos.	<i>Naïve Bayes</i> .	Brasil.
Neiva (2018)	Classificar empresas que firmaram contratos fraudulentos com o Governo Federal brasileiro.	<i>Support Vector Machine</i> (SVM), <i>Bagging</i> , <i>Boosting</i> , Floresta Aleatória, Redes Neurais Artificiais e Regressão Logística.	Brasil.
Domashova e Politova (2021)	Aplicar métodos de análise de dados para análise sobre corrupção, em particular, análise de cluster e métodos de aprendizado de máquina.	Floresta Aleatória, <i>AdaBoost</i> , <i>Gradient Boosting</i> e <i>Bagging</i> .	Mundo.
Carvalho et al. (2014)	Mensurar o risco de corrupção de funcionários públicos baseado em dados de filiação de partidos políticos e comparar com um modelo desenvolvido por especialistas.	Redes Bayesianas, Floresta Aleatória, SVM, e Redes Neurais Artificiais com <i>backpropagation</i> .	Brasil.
Blasio, D'Ignazio e Letta (2022)	Classificar a taxa de crimes de colarinho branco em municípios italianos.	Árvore de Decisão	Itália.
Li et al. (2020)	Deteção de autorrelatos de experiências com corrupção em mensagens do <i>Twitter</i> .	<i>Biterm</i> (<i>Biterm Topic Model</i>)	Mundo.

Fonte: Autoria própria (2022).

3. METODOLOGIA

Esta seção descreve o conjunto de dados utilizados na pesquisa, os recursos aplicados e as etapas desenvolvidas desde a extração dos dados até a obtenção dos resultados.

Quanto a natureza da pesquisa é de abordagem quantitativa, pois é feita a aplicação de um modelo de inteligência computacional para exploração e análise de uma base de dados. De acordo com Prodanov e Freitas (2013) a pesquisa quantitativa pressupõe que tudo pode ser mensurável, o que implica em expressar informações e opiniões em valores numéricos, a fim de realizar análises e classificações.

Quanto ao objetivo da pesquisa é explicativa, pois busca interpretar e justificar os resultados advindos da aplicação da mineração de dados. Segundo Prodanov e Freitas (2013) corresponde a esclarecer as razões e causas por trás dos fenômenos observados, a partir do registro, análise, classificação e interpretação.

Quanto ao método é uma simulação, pois são utilizadas técnicas computacionais para simular cenários a partir do conjunto de dados estudado. Vicente (2005) explica que é desenvolvido um modelo com base nos dados atuais e a partir de novos dados podem ser realizadas novas projeções, as quais podem ou não ser confirmadas.

3.1 Descrição do Conjunto de Dados

O conjunto de dados explorado no presente trabalho foi extraído das respostas da pesquisa “Ética e Corrupção no Serviço Público Federal”, realizada pelo Banco Mundial em parceria com a Controladoria Geral da União (CGU), entre 28 de abril e 28 de maio de 2021. O conjunto de dados inicial foi baixado em formato csv do site do Banco Mundial, disponível em <https://microdata.worldbank.org/index.php/catalog/4300/related-materials>, o qual é composto por 21.356 instâncias, 55 atributos e pode ser dividido em sete dimensões, descritas no Quadro 3.

Quadro 3 – Categorias da Pesquisa

Dimensão	Descrição	Classificação das Variáveis	Quantidade de Atributos
Informações Gerais	Respostas sobre região de trabalho, ministério, gênero, se o cargo é comissionado ou não, e grau de educação.	Qualitativa Nominal	5 questões
Gestão de Recursos Humanos (HR)	Opinião sobre o sistema de promoções, nomeação para cargos comissionados, remuneração, comportamentos antiético.	Qualitativa Nominal e Ordinal	4 questões
Normas e Regulamentos (NR)	Avaliação da organização em relação ao cumprimento das normas, transparência de atos e decisões administrativas, influência de <i>Lobby</i> na transparência e competitividade e programas sobre ética.	Qualitativa Ordinal	8 questões
Avaliação de Comportamentos (CA)	Opinião de quantos agentes públicos da organização praticam determinados atos antiéticos, razões para o envolvimento de agentes públicos em práticas corruptas e grau de confiança em dirigentes e demais agentes públicos da organização.	Qualitativa Nominal e Ordinal	9 questões
Experiências (EE)	Práticas antiéticas já observadas em servidores, pressão para cometer atos antiéticos e nível hierárquico de agentes que exerceram pressão indevida.	Qualitativa Nominal	4 questões
Impacto do COVID19 (C19)	Mudanças de comportamentos e atitudes desde o início da pandemia de COVID-19.	Qualitativa Ordinal	7 questões
Mecanismos de Relatório (RM)	Segurança para realizar denúncias, dificuldades para realizar denúncias, realização de denúncias, repercussão das denúncias e medidas eficazes na redução de corrupção.	Qualitativa Nominal	5 questões
Questões Randômicas	Perguntas distribuídas randomicamente sobre perfis fictícios de servidores públicos para avaliação da propensão de envolvimento com a corrupção.	Qualitativa Nominal	3 questões
Identificação do Formulário	Informações de identificação do formulário	Qualitativa Nominal	10 campos

Fonte: Autoria própria (2023).

3.2 Recursos Utilizados

O pré-processamento dos dados e a aplicação de técnicas de *machine learning* foram feitos por meio da plataforma *Jupyter Notebook*, versão 6.3.0, com a

linguagem de programação *Python*, versão 3.8.8. Além disso, foram utilizadas bibliotecas complementares, descritas no Quadro 4 com as respectivas finalidades.

Quadro 4 – Bibliotecas Utilizadas

Biblioteca	Finalidade
<i>Pandas</i>	Manipulação do conjunto de dados.
<i>Seaborn</i>	Visualização de dados.
<i>Matplotlib</i>	Visualização de dados.
<i>Scikit-learn</i>	Aplicação das técnicas de <i>machine learning</i> , análise de hiperparâmetros e seleção de variáveis.

Fonte: Autoria própria (2023).

3.3 Etapas da Pesquisa

A importação dos dados foi realizada diretamente do arquivo com extensão “csv”, disponibilizado pelo Banco Mundial, sem nenhuma modificação prévia. Foi criado um conjunto de dados no *Python* para iniciar o pré-processamento, o qual foi realizado em alguns passos iniciais.

O primeiro passo foi a remoção de variáveis que não seriam utilizadas no modelo, sendo elas:

- as da categoria de “Identificação do Formulário”, pois não correspondiam a questões aplicadas aos respondentes;
- as da categoria de “Questões Randômicas”, pois não foram aplicadas de maneira equivalente a todos os respondentes;
- uma questão da categoria “Normas e Regulamentos”, pois era relacionada ao respondente e não a experiências com os agentes públicos da organização;
- as da categoria “Impacto do COVID19”, pois não havia o objetivo de limitar a análise ao período de pandemia;
- uma questão da categoria “Experiências” e uma da categoria “Mecanismos de Relatório”, pois não foram aplicadas de maneira equivalente a todos os respondentes;

- uma questão da categoria “Informações Gerais”, pois era relacionada a identificação do ministério de atuação e não havia uma quantidade de respondentes uniforme entre os ministérios.

Após a seleção das variáveis iniciais, foram excluídas as instâncias com quaisquer dados faltantes, o que resultou em uma redução para 17.497 instâncias e 28 atributos.

As variáveis de saída avaliadas pelo modelo são as respostas a duas perguntas da categoria “Avaliação de Comportamentos”: “qual é o seu grau de confiança nas decisões e atos dos dirigentes da sua organização?” (CA3a) e “qual é o seu grau de confiança nas decisões e atos dos demais agentes públicos da sua organização?” (CA3b). As respostas originais são representadas em uma escala de cinco opções, “muito fraca, fraca, satisfatória, boa e excelente” e ainda uma opção de “prefiro não responder”. Durante o pré-processamento, elas foram reclassificadas de acordo com o Quadro 5.

Quadro 5 – Reclassificação das Variáveis de Saída

Resposta Original	Resposta Reclassificada
Muito Fraca	Fraca
Fraca	Fraca
Satisfatória	Regular
Boa	Boa
Excelente	Boa
Prefiro não responder	Vazio

Fonte: Autoria própria (2022).

Com as variáveis reorganizadas, foram novamente removidas as instâncias com dados faltantes, correspondentes àqueles que sinalizaram “prefiro não responder” em relação as perguntas sobre o nível de confiança. Após esse passo o número de instâncias totalizou 16.281 e o número de atributos não foi modificado.

Na sequência optou-se por remover as instâncias em que a resposta para a variável de saída foi regular, a partir desse ponto, o conjunto de dados passa a ser separado para cada variável de saída, o conjunto referente a pergunta CA3a fica com 11.951 instâncias e o referente a pergunta CA3b fica com 11.020 instâncias. Com a base de dados pré-processada foram separados os conjuntos de treino e teste, com 70% e 30% das instâncias respectivamente.

Devido às respostas serem qualitativas, tais variáveis foram binarizadas, com exceção das duas possíveis variáveis de saída, CA3a e CA3b. Com isso, a quantidade de atributos aumentou para 162.

A fim de melhor selecionar os atributos de entrada para o modelo, foi realizada uma análise de correlação entre as variáveis por meio do coeficiente ϕ , que segundo Lira e Chaves Neto (2006) é um método aplicável para variáveis dicotômicas. Apenas para verificar a correlação foi necessário binarizar também as variáveis de saída. A partir dessa análise foram selecionados os atributos com uma correlação ao menos fraca com as variáveis de saída, ou seja, com um coeficiente de correlação maior que 0,3 ou menor que -0,3. Essa restrição na faixa de correlação foi definida de maneira empírica. Dos atributos selecionados, também foi avaliada a correlação entre eles, para retirar variáveis de entrada com correlação forte entre si. A correlação foi aplicada separadamente para o conjunto da pergunta CA3a e CA3b e ao final os atributos selecionados foram unificados. Desse modo, a partir das análises foi possível reduzir a quantidade de variáveis de entrada para 39 (Apêndice A).

Devido a binarização é possível que a mesma pergunta corresponda a mais de uma variável, contudo, com respostas diferentes. Um exemplo é a pergunta “CA1c - Quantos agentes públicos da sua organização deixam de seguir as regras quando houver demanda do seu supervisor para isso?”, em que possui duas variáveis atreladas “CA1c - Muitos” e “CA1c - Nenhum”. Dessa maneira, a resposta para cada uma delas pode ser 1, se o respondente selecionou a opção, ou 0, se o respondente não selecionou. Além disso, é possível que a resposta para ambas seja 0, pois outras possíveis respostas foram removidas após a análise de correlação. Nos casos em que a pergunta permitia a seleção de mais de uma resposta, pode haver mais de uma variável atrelada àquela pergunta com a resposta 1.

A partir do conjunto de treino foi realizada a análise de hiperparâmetros por meio do *GridSearchCV* e aplicada a validação cruzada com o método *k-fold*, sendo *k-fold*=10, para os algoritmos *K-Nearest Neighbors* (KNN), Árvore de Decisão, Floresta Aleatória e Redes Neurais. O algoritmo *Naïve Bayes* foi utilizado a partir do modelo de Bernoulli, no entanto, sem a análise por meio do *GridSearchCV*, por não ser aplicável. De acordo com Sayfullina et al. (2015), o modelo de Bernoulli é útil quando aplicado em matrizes binárias, e por essa razão, é o mais adequado para aplicação

no presente trabalho. Esses algoritmos foram escolhidos por representarem técnicas clássicas e que atendem a complexidade do conjunto de dados estudado.

Após a aplicação do *GridSearchCV* foram analisados os parâmetros que obtiveram melhor acurácia para cada técnica no conjunto de treino. Os parâmetros testados podem ser observados nos Quadros 6 e 7.

Quadro 6 – Análise de Hiperparâmetros CA3a

Técnica	Parâmetros	Testes
KNN	<i>n_neighbors</i>	2, 5, 10, 20 , 30, 100
	<i>metric</i>	<i>minkowski, hamming, jaccard</i>
<i>Naïve Bayes</i>	-	-
Árvore de Decisão	<i>min_samples_leaf</i>	5, 10 , 20, 50
	<i>max_depth</i>	5 , 10, <i>None</i>
	<i>criterion</i>	<i>gini</i> , <i>entropy</i>
Floresta Aleatória	<i>n_estimators</i>	50, 100, 200 , 500
	<i>min_samples_leaf</i>	5, 10, 20 , 50
Redes Neurais	<i>hidden_layer_sizes</i>	10 , 30, 50
	<i>activation</i>	<i>logistic, tanh, relu</i>
	<i>max_iter</i>	200, 500, 1000, 2000

Fonte: Autoria própria (2023).

Quadro 7 - Análise de Hiperparâmetros CA3b

Técnica	Parâmetros	Testes
KNN	<i>n_neighbors</i>	2, 5, 10, 20, 30 , 100
	<i>metric</i>	<i>minkowski, hamming, jaccard</i>
<i>Naïve Bayes</i>	-	-
Árvore de Decisão	<i>min_samples_leaf</i>	5, 10 , 20, 50
	<i>max_depth</i>	5 , 10, <i>None</i>
	<i>criterion</i>	<i>gini</i> , <i>entropy</i>
Floresta Aleatória	<i>n_estimators</i>	50, 100, 200, 500
	<i>min_samples_leaf</i>	5 , 10, 20, 50
Redes Neurais	<i>hidden_layer_sizes</i>	10, 30 , 50
	<i>activation</i>	<i>logistic, tanh, relu</i>
	<i>max_iter</i>	200, 500, 1000, 2000

Fonte: Autoria própria (2023).

Dessa maneira, foram aplicadas as técnicas de classificação no conjunto de teste com os melhores parâmetros avaliados por cada algoritmo. Além disso, foram feitas análises complementares a fim de comparar os resultados entre elas:

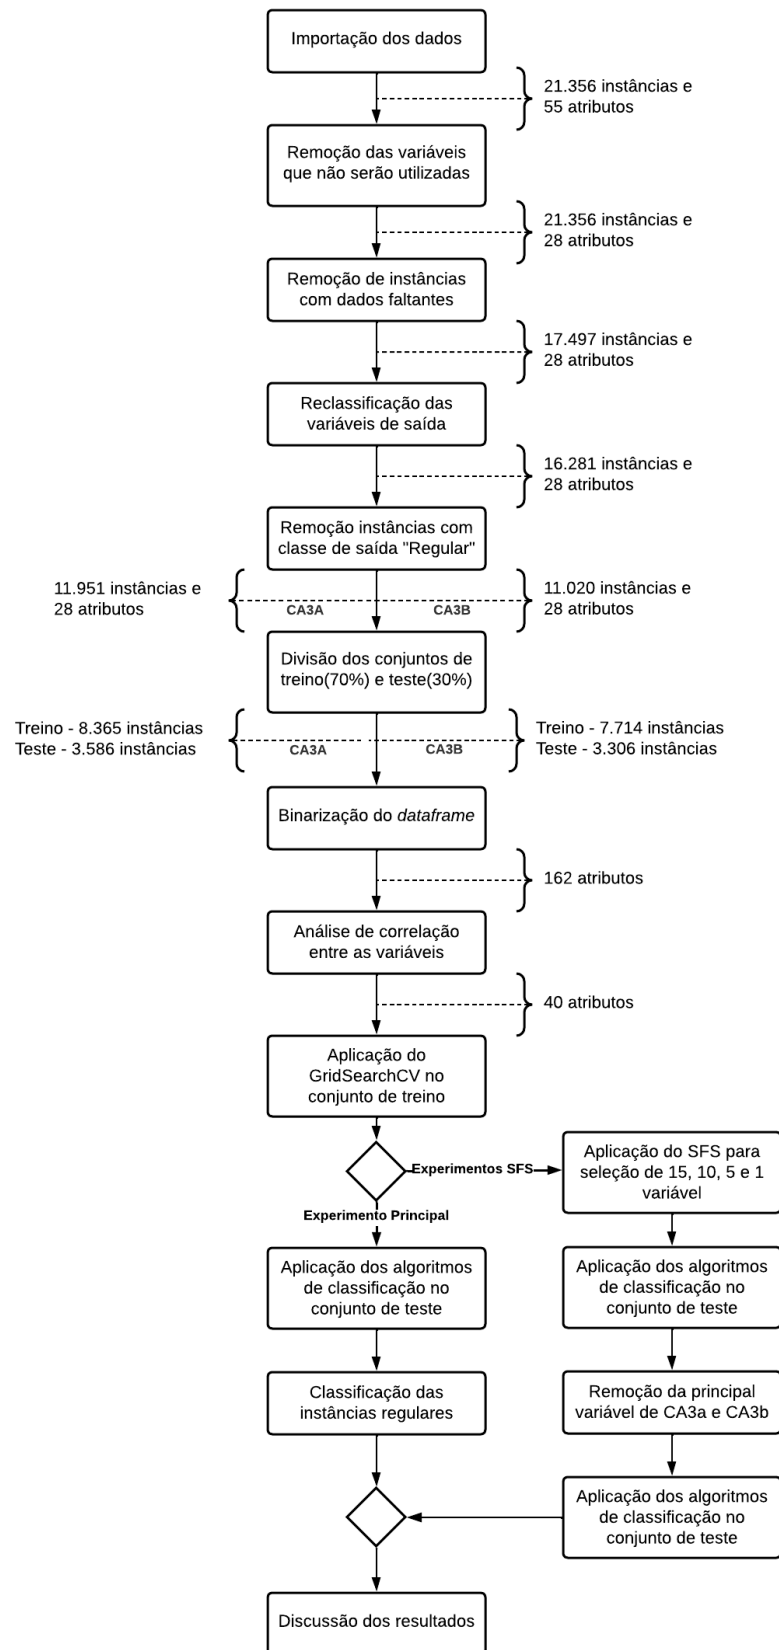
- aplicação do método de *Sequential Feature Selector* dentre as variáveis selecionadas pela análise de correlação para nova seleção de 15, 10, 5 e 1 variáveis;
- aplicação novamente do experimento com 39 atributos, no entanto, sem as principais variáveis de entrada indicadas pelo *Sequential Feature Selector* para as perguntas CA3a e CA3b.

Por fim, foi aplicado o teste nas respostas regulares que foram removidas, com o objetivo de avaliar como os algoritmos classificam as respostas neutras entre boa e fraca.

Também foi feita a aplicação dos algoritmos de classificação para o conjunto de dados com todas as variáveis anteriores a análise de correlação e para os conjuntos de dados apenas com as principais variáveis utilizadas pelo algoritmo da árvore de decisão, no entanto, não gerou novas informações relevantes para discussão no trabalho.

A Figura 7 representa o resumo de todas as etapas descritas.

Figura 7 – Fluxograma das Etapas da Pesquisa



Fonte: Autoria própria (2023).


4. RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos a partir da aplicação dos algoritmos de mineração de dados e contém análises a respeito da comparação entre os diferentes experimentos realizados.

4.1 Análise de Classes

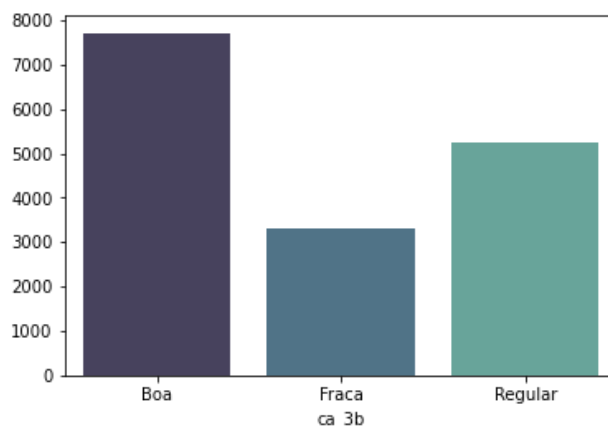
O conjunto de dados processado apresentou a seguinte distribuição de respostas referentes às variáveis de saída, como mostram as Figuras 8 e 9.

Figura 8 – Distribuição das classes sobre confiança em seus gestores (CA3a)



Fonte: Autoria própria (2023).

Figura 9 – Distribuição das classes sobre confiança em seus demais servidores (CA3b)



Fonte: Autoria própria (2023).


Para a pergunta sobre a confiança dos agentes públicos em relação a seus gestores (CA3a) houve 7.316 respostas “Boa”, 4.635 “Fraca” e 4.330 “Regular”. Já

para a pergunta sobre o nível de confiança em relação aos demais agentes públicos (CA3b) foram 7.711 respostas “Boa”, 3.309 “Fraca” e 5.261 “Regular”. Em ambos os casos, as instâncias com resposta “Regular” foram removidas para a aplicação dos algoritmos de mineração de dados.

4.2 Mineração de Dados


O primeiro passo para a aplicação dos algoritmos foi a avaliação dos melhores parâmetros no conjunto de treino para o *K-Nearest Neighbors* (KNN), Árvore de Decisão (AD), Floresta Aleatória (FA) e Redes Neurais (RNA), a partir de uma combinação de variações realizadas com o auxílio da biblioteca *GridSearchCV*. A Figura 10 e a Figura 11 apresentam a distribuição dos resultados referentes às variações feitas para CA3a e CA3b respectivamente.

Figura 10 – *GridSearchCV* CA3a



Fonte: Autoria própria (2023).

Figura 11 – GridSearchCV CA3b



Fonte: Autoria própria (2023).

Ambas as saídas apresentaram comportamento semelhante em relação aos melhores resultados obtidos por cada algoritmo. A técnica da Floresta Aleatória é a que apresentou a maior mediana e a menor discrepância entre a maior e menor acurácia encontrada dentro do conjunto de treino. O valor máximo dentre todos os algoritmos foi obtido pelas Redes Neurais, contudo, essa também foi a técnica com a maior amplitude de resultados. Os algoritmos KNN e Árvore de Decisão não apresentaram uma grande amplitude, mas foram observados *outliers* para CA3a e CA3b.

Após a análise de hiperparâmetros finalizada, foram aplicados os algoritmos de mineração de dados no conjunto de teste para a classificação da confiança dos agentes públicos em relação a seus gestores (CA3a) e demais servidores (CA3b) no. No primeiro experimento foram utilizadas as 39 variáveis obtidas a partir da análise de correlação, nos demais foi aplicado o método *Sequential Feature Selector* (SFS), com o objetivo de selecionar um menor número de variáveis de entrada para testar a acurácia e demais métricas de desempenho. A Tabela 1 mostra a acurácia obtida em cada técnica e em cada experimento realizado para a variável de saída CA3a e a Tabela 2 para a variável CA3b.

Tabela 1 - Acurácia CA3a

Experimentos	KNN	Naïve Bayes	Árvore de Decisão	Floresta Aleatória	Redes Neurais
39 Variáveis	0,85	0,85	0,85	0,87	0,87
SFS - 15 Variáveis	0,84	0,84	0,85	0,86	0,86
SFS - 10 Variáveis	0,85	0,83	0,85	0,85	0,85
SFS - 5 Variáveis	0,81	0,83	0,82	0,83	0,84
SFS - 1 Variável	0,77	0,76	0,77	0,77	0,76

Fonte: Autoria própria (2023).

Tabela 2 - Acurácia CA3b

Experimentos	KNN	Naïve Bayes	Árvore de Decisão	Floresta Aleatória	Redes Neurais
39 Variáveis	0,85	0,81	0,84	0,85	0,84
SFS - 15 Variáveis	0,83	0,85	0,84	0,84	0,85
SFS - 10 Variáveis	0,83	0,84	0,85	0,84	0,83
SFS - 5 Variáveis	0,82	0,84	0,84	0,84	0,85
SFS - 1 Variável	0,79	0,78	0,78	0,78	0,79

Fonte: Autoria própria (2023).

No caso em que foi aplicada a biblioteca *GridSearchCV* para a análise de hiperparâmetros sobre os 39 atributos selecionados após a análise de correlação, a acurácia atingiu o melhor resultado, de 87% para a pergunta CA3a com as técnicas de Floresta Aleatória e Redes Neurais e de 85% para a pergunta CA3b com as técnicas KNN e Floresta Aleatória.

Os resultados indicam uma tendência de queda da acurácia em relação a diminuição do número de atributos de entrada para a classificação de respostas da pergunta CA3a, no entanto, para a pergunta CA3b os resultados são praticamente estáveis até 5 variáveis e chega a aumentar para a técnica *Naïve Bayes*, de 81% com 39 atributos para 84% com apenas 5 atributos.

O teste com a seleção de apenas um atributo visa identificar a dependência daquele atributo selecionado para o desempenho do modelo, no entanto, foi possível observar uma queda na acurácia de até 11 *p.p.* para o algoritmo de Redes Neurais ao classificar a confiança nos gestores. Além disso, as outras métricas também mostram o impacto da remoção de variáveis dos modelos, como mostra os resultados da precisão apresentados na Tabela 3 para a pergunta CA3a e Tabela 4, para a pergunta CA3b.

Tabela 3 – Precisão CA3a

Experimentos	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
39 Variáveis	0,87	0,82	0,90	0,78	0,86	0,83	0,88	0,85	0,89	0,83
SFS - 15 Variáveis	0,84	0,84	0,90	0,75	0,88	0,81	0,87	0,85	0,88	0,82
SFS - 10 Variáveis	0,86	0,84	0,90	0,74	0,86	0,82	0,87	0,83	0,86	0,83
SFS - 5 Variáveis	0,87	0,73	0,87	0,76	0,84	0,80	0,85	0,79	0,85	0,81
SFS - 1 Variável	0,87	0,67	0,87	0,64	0,87	0,67	0,87	0,67	0,87	0,65

Fonte: Autoria própria (2023).

Tabela 4 – Precisão CA3b

Experimentos	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
39 Variáveis	0,89	0,76	0,91	0,66	0,89	0,75	0,88	0,76	0,88	0,75
SFS - 15 Variáveis	0,85	0,78	0,90	0,74	0,88	0,73	0,87	0,77	0,89	0,75
SFS - 10 Variáveis	0,85	0,76	0,89	0,72	0,89	0,73	0,87	0,76	0,87	0,74
SFS - 5 Variáveis	0,84	0,75	0,88	0,74	0,87	0,77	0,88	0,77	0,89	0,74
SFS - 1 Variável	0,80	0,73	0,80	0,72	0,80	0,70	0,80	0,70	0,81	0,73

Fonte: Autoria própria (2023).

No modelo com uma variável, para a pergunta CA3b a precisão cai entre 7 e 11 *p.p.* quando a confiança é classificada como boa e para a pergunta CA3a a precisão chega a ser menor do que 70% para todos os algoritmos quando a confiança é classificada como fraca. Esse aspecto indica que o maior número de variáveis é importante para a melhoria nas demais métricas além da acurácia.

Em relação aos demais experimentos também é possível verificar que para ambas as perguntas a precisão é maior quando o algoritmo classifica a resposta como boa do que quando classifica como fraca, comportamento também observado para as métricas de *recall* e *F1-Score* como é observado na Tabela 5 para CA3a e Tabela 6 para CA3b.

Tabela 5 - Métricas de Desempenho 39 Variáveis CA3a

Métrica	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
Precisão	0,87	0,82	0,90	0,78	0,86	0,83	0,88	0,85	0,89	0,83
Recall	0,89	0,78	0,85	0,85	0,90	0,76	0,91	0,81	0,89	0,82
F1-Score	0,88	0,80	0,88	0,82	0,88	0,80	0,89	0,83	0,89	0,83

Fonte: Autoria própria (2023).

Tabela 6 - Métricas de Desempenho 39 Variáveis CA3b

Métrica	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
Precisão	0,89	0,76	0,91	0,66	0,89	0,75	0,88	0,76	0,88	0,75
Recall	0,90	0,73	0,82	0,81	0,89	0,73	0,91	0,72	0,90	0,71
F1-Score	0,89	0,74	0,86	0,72	0,89	0,74	0,89	0,74	0,89	0,73

Fonte: Autoria própria (2023).

Nesse caso, todas as métricas obtiveram piores resultados quando a confiança é “Fraca”. Enquanto os melhores resultados foram entre 91% e 89% quando a confiança é “Boa”, os melhores resultados quando a confiança é “Fraca” variaram entre 85% e 83% para CA3a e entre 81% e 74% para CA3b.

Além disso, o experimento com as variáveis obtidas por meio da análise de correlação foi novamente realizado, mas sem o principal atributo selecionado pelo SFS para cada variável de saída, EE2 – “Nunca observei atos de corrupção” para CA3a e CA1f – “Muitos” para CA3b. A diferença em pontos percentuais dos resultados antes e depois da remoção desses atributos é apresentada nas Tabelas 7 e 8.

Tabela 7 – CA3a: Sem atributos SFS – 1 variável x 39 Variáveis em p.p.

Métricas	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
Acurácia	1	1	0	0	0	0	-1	-1	-1	-1
Precisão	-1	0	1	-1	1	-1	0	3	1	0
Recall	0	-2	0	1	0	-1	2	0	0	0
F1-Score	-1	-1	1	1	0	0	0	1	0	1

Fonte: Autoria própria (2023).

Tabela 8 – CA3b: Sem atributos SFS – 1 variável x 39 Variáveis em *p.p.*

Métricas	KNN		Naïve Bayes		Árvore de Decisão		Floresta Aleatória		Redes Neurais	
	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca	Boa	Fraca
Acurácia	-2	-2	1	1	-1	-1	0	0	1	1
Precisão	1	3	0	0	2	3	1	-2	0	-1
Recall	1	2	0	-1	0	5	-1	3	0	0
F1-Score	1	2	-1	-1	9	4	0	1	0	0

Fonte: Autoria própria (2023).

A acurácia não variou mais de 1 *p.p.* para mais ou para menos na pergunta CA3a e na pergunta CA3b teve sua maior redução em 2 *p.p.* com o algoritmo KNN, o que indica que apesar das principais variáveis de entrada selecionadas pelo experimento com o SFS terem sido consideradas com a maior relevância, os modelos não possuem dependência delas. As demais métricas também não indicaram queda no desempenho, em média, a precisão, *recall* e *F1-score* não apresentaram redução em *p.p.*

4.3 Análise de Variáveis

Outro fator importante é a análise das principais variáveis consideradas pelos modelos, para isso, foram avaliadas quais foram as variáveis de entrada selecionadas pelo SFS quando delimitado a cinco atributos e quais foram as maiores importâncias atribuídas pela Árvore de Decisão quando aplicada às 39 variáveis. A Tabela 9 mostra a frequência dos atributos selecionados pelo SFS após todos os cinco algoritmos aplicados e para ambas as variáveis de saída.

Tabela 9 – Frequência de seleção de atributos pelo SFS com 5 Variáveis

Pergunta	Resposta	Geral	CA3a	CA3b
ee_2 - Nos últimos 3 anos na sua organização, em quais das seguintes práticas você já observou servidores em exercício atuando de forma antiética?	Nunca observei atos de corrupção	10	5	5
nr_1b - Os atos e decisões administrativas são devidamente transparentes	Discordo totalmente	9	4	5
ca_1f - Quantos agentes públicos da sua organização obtêm benefícios profissionais em função vínculos com pessoas importantes (políticos, autoridades,...)	Muitos	5	0	5
hr_4 - Nos últimos 3 anos, você já se sentiu prejudicado devido a comportamento pouco ético em alguma dessas atividades?	Não me senti prejudicado no período	4	4	0
nr_1b - Os atos e decisões administrativas são devidamente transparentes	Concordo totalmente	4	4	0
ca_1f - Quantos agentes públicos da sua organização obtêm benefícios profissionais em função vínculos com pessoas importantes (políticos, autoridades,...)	Nenhum	4	4	0
nr_1b - Os atos e decisões administrativas são devidamente transparentes	Discordo parcialmente	4	0	4
nr_1a - As normas e regulamentos são rigorosamente cumpridos	Discordo totalmente	2	1	1
ee_1 - Na sua organização, quais das seguintes práticas você já observou em servidores no exercício de suas funções?	Nenhuma das anteriores	2	1	1
ca_1b - Quantos agentes públicos da sua organização solicitam dinheiro ou presentes para cumprir suas funções	Nenhum	2	0	2
ca_1e - Quantos agentes públicos da sua organização contratam uma empresa porque mantém vínculo remunerado ou de amizade nessa empresa	Nenhum	2	0	2
hr_2 - Possuir familiares, amigos ou conexões pessoais ou políticas na sua organização	Possuir familiares, amigos ou conexões pessoais ou políticas na sua organização	1	1	0
nr_1a - As normas e regulamentos são rigorosamente cumpridos	Concordo totalmente	1	1	0

Fonte: Autoria própria (2023).

Em todos os algoritmos utilizados para a classificação, tanto da confiança nos gestores, quanto nos demais agentes públicos, o atributo mais frequente foi sobre a observação ou não de atos de corrupção, sendo selecionado em todos os casos. O segundo atributo mais selecionado é se o respondente discorda totalmente que os atos e decisões administrativas são transparentes, o qual não foi selecionado apenas pelo KNN para a pergunta CA3a. Essas duas variáveis foram relevantes para ambas

as classificações, no entanto, as outras que apresentaram maior frequência foram selecionadas apenas para uma das saídas.

Para a classificação de confiança nos gestores, três atributos foram selecionados por quatro dos cinco algoritmos aplicados, se o respondente se sentiu prejudicado por algum comportamento pouco ético, se concorda totalmente que os atos e decisões administrativas são transparentes e se nenhum agente público da organização já obteve benefícios profissionais em função vínculos com pessoas importantes.

Na avaliação de confiança em relação aos demais agentes públicos da organização, os atributos que também se destacaram foram se muitos agentes públicos já obtiveram benefícios profissionais em função vínculos com pessoas importantes e se discorda parcialmente que os atos e decisões administrativas são transparentes.

É possível verificar que por conta da binarização alguns atributos selecionados são derivados da mesma pergunta, por exemplo, em relação a transparência de decisões administrativas, para a qual foram selecionados atributos referentes a três escalas diferentes, discordo totalmente, discordo parcialmente e concordo totalmente. Nesse sentido, o Quadro 8 apresenta um resumo das principais variáveis de entrada indicadas pelo SFS, que foram selecionadas por quatro ou cinco algoritmos e estão relacionadas a quatro perguntas.

Quadro 8 – Principais Atributos SFS

Pergunta	Resposta
ca_1f - Quantos agentes públicos da sua organização obtêm benefícios profissionais em função vínculos com pessoas importantes (políticos, autoridades,...)	Muitos
	Nenhum
ee_2 - Nos últimos 3 anos na sua organização, em quais das seguintes práticas você já observou servidores em exercício atuando de forma antiética?	Nunca observei atos de corrupção
hr_4 - Nos últimos 3 anos, você já se sentiu prejudicado devido a comportamento pouco ético em alguma dessas atividades?	Não me senti prejudicado no período
nr_1b - Os atos e decisões administrativas são devidamente transparentes	Concordo totalmente
	Discordo parcialmente
	Discordo totalmente

Fonte: Autoria própria (2023).

As Tabelas 10 e 11 mostram como foi a resposta dada para o grau de confiança de acordo com a resposta para cada uma das principais variáveis selecionadas. Essas informações ajudam a entender a relação das variáveis de saída com esses atributos.

Tabela 10 – Distribuição de Respostas Principais Variáveis – CA3a

Atributo	Resposta	Fraca	Boa
ee_2 - Nunca observei atos de corrupção	0	3811	1970
	1	824	5346
hr_4 - Não me senti prejudicado no período	0	3805	2525
	1	830	4791
ca_1f - Nenhum	0	4333	3702
	1	302	3614
nr_1b - Concordo totalmente	0	4493	4001
	1	142	3315
nr_1b - Discordo parcialmente	0	3006	6681
	1	1629	635
nr_1b - Discordo totalmente	0	2961	7172
	1	1674	144
ca_1f - Muitos	0	2568	6882
	1	2067	434

Fonte: Autoria própria (2023).

Tabela 11 – Distribuição de Respostas Principais Variáveis – CA3b

Atributo	Resposta	Fraca	Boa
ee_2 - Nunca observei atos de corrupção	0	2776	2373
	1	533	5338
hr_4 - Não me senti prejudicado no período	0	2752	2967
	1	557	4744
ca_1f - Nenhum	0	3074	4191
	1	235	3520
nr_1b - Concordo totalmente	0	3199	4529
	1	110	3182
nr_1b - Discordo parcialmente	0	2181	6825
	1	1128	886
nr_1b - Discordo totalmente	0	2040	7381
	1	1269	330
ca_1f - Muitos	0	1707	7091
	1	1602	620

Fonte: Autoria própria (2023).

A pergunta EE2 indica que mais 70% dos respondentes têm a mesma resposta para a observação de casos de corrupção e grau de confiança, ou seja, a maioria dos respondentes quando nunca presenciaram atos de corrupção apontam ter uma boa confiança nos dirigentes e colegas e quando já observaram tendem a ter uma confiança fraca. No entanto, quando observado algum tipo de corrupção a confiança nos agentes públicos é menos afetada do que nos gestores. A pergunta HR4 apresentou o mesmo tipo de relação.

A pergunta CA1f avalia a percepção do respondente sobre a quantidade de dirigentes e agentes públicos que obtêm benefícios profissionais em função vínculos com pessoas importantes e foram selecionados dois atributos referentes a essa questão, as respostas “Muitos” e “Nenhum”. Se respondido “Nenhum”, a grande maioria indica uma boa confiança, mas se essa opção não for selecionada o grau de confiança é mais distribuído, isso porque além dessas duas opções também poderia serem assinalados “Todos” ou “Poucos”. Se respondido “Muitos”, a grande maioria indica uma confiança fraca, contudo, ao contrário do outro atributo analisado, se na opinião do respondente não existem muitos agentes que praticam esse tipo de ato, mais de 70% para CA3a e mais de 80% para CA3b possuem uma boa confiança.

A última questão presente nos principais atributos selecionados foi a NR1b que avalia em uma escala de “Concordo totalmente” até “Discordo totalmente” se o respondente acredita que os atos e decisões administrativas são transparentes. Nessa escala, os atributos escolhidos pelo SFS foram “Concordo totalmente”, “Discordo parcialmente” e “Discordo totalmente”.

As respostas indicaram que aproximadamente 70% do total instâncias não concordam totalmente com essa afirmação, mas dos que concordam, mais de 95% consideram a confiança como boa para CA3a e CA3b. No mesmo sentido, quando não há discordância parcial ou total cerca de 70% das vezes a confiança também é considerada boa em relação aos gestores e mais de 75% em relação aos demais agentes públicos. Essa maior frequência pode ser um indicador por esses atributos relacionados a discordância terem um peso maior para a saída CA3b.

Além disso a partir da aplicação do algoritmo da Árvore de Decisão também é possível avaliar quais foram os principais atributos considerados para a classificação das instâncias, a fim de comparar com a seleção do SFS. As Tabelas 12 e 13 mostram os cinco atributos com maior importância para cada variável de saída.

Tabela 12 – Maiores Importâncias Árvore de Decisão – CA3a

Atributo	Importância
ee_2 - Nunca observei atos de corrupção	0,2932
nr_1b - Discordo totalmente	0,1004
nr_1b - Discordo parcialmente	0,0974
hr_2 - Possuir familiares, amigos ou conexões pessoais ou políticas na sua organização	0,0299
rm_2 - O processo de denúncia/investigação não é imparcial	0,0201

Fonte: Autoria própria (2023).

Tabela 13 - Maiores Importâncias Árvore de Decisão – CA3b

Atributo	Importância
ee_2 - Nunca observei atos de corrupção	0,2336
nr_1b - Discordo totalmente	0,0909
nr_1b - Discordo parcialmente	0,0639
ca_1f - Muitos	0,0331
hr_1 - É influenciada por amizades	0,0253

Fonte: Autoria própria (2023).

Os quatro atributos com maior importância para classificação de CA3a e CA3b também foram selecionados pelo SFS em ao menos um dos algoritmos. Contudo, o atributo com quinto maior peso é diferente, para CA3a esse atributo foi se o respondente vê a falta de imparcialidade nos processos de denúncia e investigação como uma das principais dificuldades enfrentadas para denunciar casos de corrupção e para CA3b, se o sistema de promoção e ascensão na organização é influenciada por amizades.

As importâncias atribuídas pela Árvore de Decisão dão destaque maior aos três primeiros atributos, sendo que o primeiro possui mais de 20% de importância e do quarto em diante a diferença já é menor do que 1 *p.p.* entre eles.

Os principais atributos selecionados pelo SFS e pela Árvore de Decisão indicam que a confiança do agente público nos dirigentes e nos demais funcionários públicos de sua organização estão pautados em quatro aspectos principais, sendo que cada um deles está relacionado a uma categoria diferente do questionário. A observação de casos de corrupção (EE - Experiências), conduta antiética (HR – Gestão de Recursos Humanos), favorecimento indevido (CA – Avaliação de Comportamentos) e transparência dentro da organização (NR – Normas e Regulamentos).


A transparência é abordada por Covey (2017) que afirma que as pessoas tendem a não confiar naquilo que é desconhecido. Desse modo, dar abertura e clareza sobre as ações e decisões tomadas ajuda a tornar a organização mais transparente e conseqüentemente aumentar a confiança.

A relevância da ética para a confiança é corroborada pelo estudo de Ilyas, Abid e Ashfaq (2020) o qual aponta que uma liderança ética gera confiança não apenas nos dirigentes, mas na organização como um todo e pode inclusive despertar maior engajamento em seus colaboradores. Soderberg e Romney (2022) explicam que um dos fatores chave para a confiança são os comportamentos, sendo dois deles a liderança pelo exemplo e integridade. A visão do líder como um espelho pode ser uma razão para a classificação de confiança nos gestores alcançar maior acurácia, pois qualquer desvio ético, falta de transparência, caso de corrupção recai de maneira mais acentuada sobre a percepção que a equipe tem da liderança da organização.

4.4 Classificação de instâncias regulares


As instâncias regulares que foram removidas foram testadas com o objetivo de avaliar se serão classificadas com uma “Boa” ou “Fraca” confiança. A Figura 12 apresenta a classificação para a variável CA3a e a Figura 13 para CA3b.

Figura 12 – Classificação Regulares CA3a



Fonte: Autoria própria (2023).

Figura 13 – Classificação Regulares CA3b



Fonte: Autoria própria (2023).

A classificação apontou que a maior parte das respostas que classificam o nível de confiança como regular representam, na verdade, uma confiança boa. Uma hipótese é que seja devido ao nome dado a classe regular originalmente, que era “Satisfatória”. Esse termo pode ser entendido como um grau de confiança que atende minimamente as expectativas do respondente e as respostas nas perguntas selecionadas como atributos de entrada demonstram um viés mais positivo do que negativo em relação a essa percepção.

O algoritmo *Naive Bayes* é o que apresentou o maior número de classificações de instâncias regulares como fracas. O que pode explicar esse cenário é que no experimento com 39 atributos esse algoritmo obteve os piores resultados na métrica de precisão quando a confiança é fraca, o que aponta uma tendência a classificar como fraca mais instâncias do que deveria.

5. CONCLUSÃO

O presente estudo teve como objetivo classificar o grau de confiança de servidores públicos federais em relação aos dirigentes (CA3a) e demais agentes públicos da organização em que atuam (CA3b). A análise foi realizada a partir de uma base de dados pública disponibilizada pelo Banco Mundial em que continha respostas de um questionário aplicado nos órgãos públicos federais com perguntas sobre a percepção dos respondentes em relação a gestão de recursos humanos, normas e regulamentos, avaliação de comportamentos, experiências e mecanismos de relatório ou denúncia, com foco principal em aspectos éticos.

O estudo comparou as métricas de desempenho entre cinco algoritmos de classificação, *K-Nearest Neighbors* (KNN), *Naïve Bayes*, Árvore de Decisão, Floresta Aleatória e Redes Neurais, a partir de cinco experimentos contendo diferentes quantidades de atributos em sua entrada: 39; 15; 10; 5 e 1. Para a classificação de confiança nos gestores as maiores acurácias foram obtidas pelo modelo com 39 atributos e pelos algoritmos Floresta Aleatória e Redes Neurais, com um resultado de 87%. Com a diminuição do número de atributos foi possível verificar que a acurácia apresentou uma tendência de queda. Por outro lado, não houve uma queda na mesma proporção para a acurácia na classificação da confiança nos agentes públicos, que teve em 85% seu melhor resultado.

A classificação com apenas uma variável identificou atributos que exercem uma grande influência sobre o resultado dos algoritmos, no entanto, dependem de mais atributos para alcançarem um resultado satisfatório, principalmente em relação à métrica de precisão. Além disso, ao ser realizado um novo experimento sem essas variáveis, a acurácia não caiu mais de 1 *p.p.* para CA3a e 2 *p.p.* para CA3b.

Outro resultado apontado pela pesquisa foi de que os algoritmos tiveram maior acerto para classificar a confiança quando considerada como “Boa” do que quando considerada como “Fraca”.

Uma importante contribuição do estudo é a avaliação dos principais atributos selecionados pelos algoritmos para a classificação do nível de confiança. Ao analisar as cinco variáveis de entrada selecionadas pelo SFS e as cinco maiores importâncias atribuídas pela árvore de decisão foram identificados os quatro principais fatores que influenciaram na classificação do grau de confiança, a observação de casos de

corrupção, conduta antiética, favorecimento indevido e transparência dentro da organização.

A implantação ou melhoria de ações internas que promovam a transparência em relação aos atos e decisões administrativas, como por exemplo práticas de gestão a vista, relatórios e reuniões de alinhamento, podem ser decisivas no enfrentamento a corrupção e aumento da confiança nos gestores e colegas de trabalho. Além de ter sido um dos principais aspectos utilizados pelo modelo na classificação da confiança, o aumento da transparência também influencia em outros fatores decisivos, pois dificulta a ocorrência de práticas corruptas e antiéticas.

Como limitação deste estudo, levou-se consideração apenas as perguntas e respostas disponíveis no conjunto de dados explorado, dessa maneira, pode haver outros fatores que influenciam na confiança dentro de uma organização que não foram avaliados. Para pesquisas futuras, poderão ser aplicados outros experimentos com o objetivo de alcançar melhores resultados, além disso, após a próxima aplicação do questionário será possível utilizar as atuais respostas e os melhores parâmetros obtidos para testar a classificação da confiança em um novo conjunto de dados.

REFERÊNCIAS

AL-NABI, D. L. A.; AHMED, S. S. Survey on Classification Algorithms for DataMining:(Comparison and Evaluation). **The International Institute for Science, Technology and Education (IISTE)**, [S. l.], v. 4, n. 8, 2013. ISSN 2222-2863. Disponível em: <https://core.ac.uk/download/pdf/234644652.pdf>. Acesso em 4 jun. 2022.

BALANIUK, R. et al. Corruption risk analysis using semi-supervised naïve Bayes classifiers. **International Journal of Reasoning-based Intelligent Systems**, v. 5, n. 4, p. 237, jan. 2013. Disponível em: https://www.researchgate.net/publication/264816498_Corruption_risk_analysis_using_semi-supervised_naive_Bayes_classifiers. Acesso em: 10 nov. 2022.

BLANCHET, L. A.; AZOIA, V. T. A transparência na administração pública, o combate à corrupção e os impactos no desenvolvimento. **Revista do Direito**, n. 51, p. 157-175, jan. 2017. Disponível em: <https://online.unisc.br/seer/index.php/direito/article/view/8897>. Acesso em: 17 set. 2022.

BLASIO, G. D; D'IGNAZIO, A.; LETTA, M. Gotham city. Predicting 'corrupted' municipalities with machine learning. **Technological Forecasting and Social Change**, v. 184, [S.l.], nov. 2022. DOI: <https://doi.org/10.1016/j.techfore.2022.122016>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162522005376>. Acesso em: 20 mai. 2023.

BREIMAN, L. Random Forests. **Machine Learning**, The Netherlands, v. 45, p. 5-32, out. 2001. Disponível em: <http://www.cs.columbia.edu/~jebara/6772/papers/nigam99text.pdf>. Acesso em: 24 set. 2022.

CAMILO, Cássio Oliveira; SILVA, João Carlos da. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas**. 2009. 29 f. Relatório técnico (Mestrado em Ciência da Computação) – Instituto de Informática Universidade Federal de Goiás, Goiânia, 2009. Disponível em: <https://ww2.inf.ufg.br/node/355>. Acesso em 4 jun. 2022.

CARVALHO, R. S. et al. Using Political Party Affiliation Data to Measure Civil Servants' Risk of Corruption. *In: 2014 BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS, 2014, São Carlos. Anais [...]*. [S.l.]: Institute of Electrical and Electronics Engineers, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6984825>. Acesso em: 11 nov. 2022.

CASTRO, L.N.D.; FERRARI, D.G. **Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações**. São Paulo: Editora Saraiva, 2016. 978-85-472-0100-5. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/978-85-472-0100-5/>. Acesso em: 17 set. 2022.

COSTA, C. L. de O. *et al.* A corrupção no setor público brasileiro. **Research, Society and Development**, v. 9, n. 10, 2020, Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/9056/7967>. Acesso em: 24 out. 2022.

COVEY, S. M. R. **A Velocidade da Confiança**. Rio de Janeiro: Editora Alta Books, 2017. *E-book*. ISBN 9788550812755. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788550812755/>. Acesso em: 29 out. 2022.

DIRKS, K. T.; FERRIN, D. L. Trust in leadership: Meta-analytic findings and implications for research and practice. **Journal of Applied Psychology**, v. 87, n. 4, p. 611–628, 2002. Disponível em: <https://psycnet.apa.org/record/2002-15406-001>. Acesso em 10 nov. 2022.

DOMASHOVA, J.; POLITOVA, A. The Corruption Perception Index: analysis of dependence on socio-economic indicators. **Procedia Computer Science**, v. 190, p. 193–203, jul. 2021. DOI: <https://doi.org/10.1016/j.procs.2021.06.024>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050921012679>. Acesso em: 11 nov. 2022.

DRISS, S; SOUA, M.; KACHOURI, R.; AKIL, M. A comparison study between MLP and convolutional neural network models for character recognition. *In: SPIE COMMERCIAL + SCIENTIFIC SENSING AND IMAGING*, 1, 2017, Anaheim, Estados Unidos da América. **Anais [...]**. [S.l.]: Research Gate, 2017. Disponível em: https://www.researchgate.net/publication/316613582_A_comparison_study_between_MLP_and_Convolutional_Neural_Network_models_for_character_recognition. Acesso em: 17 set. 2022.

DUTRA, C. C.; LOPES, K. M. G. **Dados abertos uma forma inovadora de transparência**. Disponível em: <https://www.administracao.go.gov.br/noticias/279-gest%C3%A3o/modernizacao/boaspraticas/20015-dados-abertos-uma-forma-inovadora-de-transparenci.html>. Acesso em: 27 ago. 2022.

FABOSSI, M. **O fator confiança**. São Paulo: Editora Saraiva, 2019. *E-book*. ISBN 9788557173392. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788557173392/>. Acesso em: 30 out. 2022.

FAYYAD, Usama; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, [S. l.], v. 17, n. 3, p. 37, 1996. DOI: 10.1609/aimag.v17i3.1230. Disponível em: <https://ojs.aaai.org/index.php/aimagazine/article/view/1230>. Acesso em: 4 jun. 2022.

FIGUEIREDO, Carla Regina Bortolaz de; CABRAL, Flávio Garcia. Inteligência artificial: machine learning na Administração Pública. **International Journal of Digital Law**, Belo Horizonte, ano 1, n. 1, p. 79-95, jan./abr. 2020. Disponível em: <https://journal.nuped.com.br/index.php/revista/article/view/figueiredov1n1/263>. Acesso em: 4 jun. 2022.

FILGUEIRAS, F. A tolerância à corrupção no Brasil: uma antinomia entre normas morais e prática social. **Opinião Pública**, Campinas, v. 15, n. 2, p.386-421, 2009. DOI: <https://doi.org/10.1590/S0104-62762009000200005>. Disponível em: <https://www.scielo.br/j/op/a/8vW5w5whdMLRD3sqWPV6fgg/?lang=pt>. Acesso em: 23 abr. 2023.

FOCKINK, Caroline. Os efeitos negativos da corrupção nas instituições públicas e no regime democrático. **Revista de Direitos Fundamentais & Democracia**, Curitiba, v. 24, n. 3, p. 181-210, set./dez. 2019. ISSN 1982-0496. DOI: 10.25192/issn.1982-0496.rdfd.v24i31331. Disponível em: <https://revistaeletronicardfd.unibrasil.com.br/index.php/rdfd/article/view/1331/630>. Acesso em: 4 jun. 2022.

GOLDSCHMIDT, R. **Data Mining**. Porto Alegre: Grupo A Educação S.A., 2015. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595156395/>. Acesso em: 17 set. 2022.

HAN J.; KAMBER M.; PEI J. **Data Mining: Concepts and Techniques**. Waltham, Estados Unidos da América: Elsevier, 2012. *E-book*. Disponível em: <http://myweb.sabanciuniv.edu/rdehkharghani/files/2016/02/The-Morgan-Kaufmann-Series-in-Data-Management-Systems-Jiawei-Han-Micheline-Kamber-Jian-Pei-Data-Mining.-Concepts-and-Techniques-3rd-Edition-Morgan-Kaufmann-2011.pdf>. Acesso: 17 set. 2022.

ILYAS, S.; ABID, G.; ASHFAQ, F. Ethical leadership in sustainable organizations: The moderating role of general self-efficacy and the mediating role of organizational trust. **Sustainable Production and Consumption**, v. 22, p.195-204, abr. 2020. DOI: <https://doi.org/10.1016/j.spc.2020.03.003>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352550919304324>. Acesso em: 22 mai. 2023.

KUMAR, Raj; VERMA, Rajesh; **Classification Algorithms for Data Mining: A Survey. International Journal of Innovations in Engineering and Technology (IJJET)**, [S. l.], v. 1, n. 2. 2012. ISSN: 2319-1058. Disponível em: <http://ijjet.com/wp-content/uploads/2012/09/2-1.pdf>. Acesso em 4 jun. 2022.

LAROSE, D.; LAROSE, C. **Discovering knowledge in data: An Introduction to Data Mining**. Hoboken, New Jersey: John Wiley & Sons. 2014. *E-book*. Disponível em: https://doc.lagout.org/Others/Data%20Mining/Discovering%20Knowledge%20in%20Data_%20An%20Introduction%20to%20Data%20Mining%20%282nd%20ed.%29%20%5BLarose%20%26%20Larose%202014-06-30%5D.pdf. Acesso em: 24 out. 2022.

LI, J. *et al.* Detection of self-reported experiences with corruption on twitter using unsupervised machine learning. **Social Sciences & Humanities Open**, v. 2, [S.l.], set. 2020. DOI: <https://doi.org/10.1016/j.ssaho.2020.100060>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2590291120300498>. Acesso em: 20 mai. 2023.

LIMA JUNIOR, O. P. de. Ética, corrupção e responsabilidade social do agente público. **Revista Ciências Humanas**, [S. l.], v. 3, n. 1. 2010. DOI: 10.32813/2179-1120.2010.v3.n1.a230. Disponível em: <https://www.rchunitau.com.br/index.php/rch/article/view/230>. Acesso em: 28 ago. 2022.

LIMA, M. S. M.; DELEN, D. Predicting and explaining corruption across countries: A machine learning approach. **Government Information Quarterly**, [S.l.], v. 37, n. 1. 2020. DOI: <https://doi.org/10.1016/j.giq.2019.101407>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0740624X19302473>. Acesso em: 02 set. 2022.

LIRA, S. A.; CHAVES NETO, A. Coeficientes de correlação para variáveis ordinais e dicotômicas derivados do coeficiente linear de Pearson. **Ciência & Engenharia**, Uberlândia, v. 15, n. 1/2, p. 45-53, jan./dez. 2006. ISSN: 1983-4071. Disponível em: https://www.researchgate.net/publication/277236614_Coeficientes_de_correlacao_para_variaveis_ordinais_e_dicotomicas_derivados_do_coeficiente_linear_de_Pearson. Acesso em: 20 mai. 2023.

LIU, J. *et al.* Data Mining and Information Retrieval in the 21st century: A bibliographic review. **Computer Science Review**, [S. l.], v. 34, n. 100193, nov. 2019. DOI: <https://doi.org/10.1016/j.cosrev.2019.100193>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1574013719301297>. Acesso em: 24 out. 2022.

LUO, Q. Advancing Knowledge Discovery and Data. *In: MINING FIRST INTERNATIONAL WORKSHOP ON KNOWLEDGE DISCOVERY AND DATA MINING (WKDD 2008)*, 1., 2008, Adelaide. **Anais [...]**, Adelaide: Institute of Electrical and Electronics Engineers, 2008. p. 3-5. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4470338>. Acesso em: 24 out. 2022.

LUZ, G.; CAPODEFERRO, M. W. Corrupção, instituições e desenvolvimento. **A Economia em Revista - AERE**, v. 29, n. 3, 17 abr. 2022. Disponível em: <https://periodicos.uem.br/ojs/index.php/EconRev/article/view/60749>. Acesso em: 24 out. 2022.

MAHESH, B. Machine Learning Algorithms - A Review. **International Journal of Science and Research (IJSR)**, [S.l.], v. 9, n. 1, 2020. ISSN: 2319-7064. DOI: 10.21275/ART20203995. Disponível em: https://www.researchgate.net/publication/344717762_Machine_Learning_Algorithms_-_A_Review. Acesso em: 4 jun. 2022.

MARIANO, D. C. B. *et al.* **Data Mining**. Porto Alegre: Grupo A, 2021. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786556900292/>. Acesso em: 24 set. 2022.

MATOS, F. G. D. **Ética na Gestão Empresarial**. 3. ed. São Paulo: Editora Saraiva, 2017. *E-book*. ISBN 9788547209810. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788547209810/>. Acesso em: 29 out. 2022.

NASTESKI, V. **An overview of the supervised machine learning methods**. 2017. 11 f. Artigo Faculty of Information and Communication Technologies, Bitola, Macedonia, 2017. DOI 10.20544/HORIZONS.B.04.1.17.P05. Disponível em: https://www.researchgate.net/publication/328146111_An_overview_of_the_supervised_machine_learning_methods. Acesso em: 4 jun. 2022.

NEIVA, W. da F. **Uma avaliação dos métodos de inteligência artificial para a classificação de empresas corruptas através da modelagem das relações público privadas**. 2018. Monografia (Bacharelado em Administração) - Faculdade de Economia, Administração e Contabilidade, Universidade de Brasília, Brasília-DF, 2018. Disponível em: https://bdm.unb.br/bitstream/10483/23856/1/2018_WagnerDaFonsecaNeiva.pdf. Acesso em: 11 nov. 2022.

NIETO, D.O. THE WORLD BANK. **Pesquisa Sobre Ética e Corrupção no Serviço Público 2021, A Perspectiva dos Servidores**. Disponível em: <https://microdata.worldbank.org/index.php/catalog/4300/related-materials>. Acesso em: 25 mar. 2022.

OLIVEIRA, D. de P. R. D. **Administração Pública: Foco na Otimização do Modelo Administrativo**. São Paulo: Atlas, 2014. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788522490042/>. Acesso em: 29 out. 2022.

PETKOVIC, D. *et al.* Improving the explainability of Random Forest classifier – user centered approach. *In: PACIFIC SYMPOSIUM ON BIOCOMPUTING 2018*, 2018, Kohala Coast, Hawaii. **Anais [...]**. [S.l]: WORLD SCIENTIFIC, 2018, p. 204-215.

PIATETSKY-SHAPIO, G. *et al.* What are the grand challenges for data mining?: KDD-2006 panel report. *In: CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING*, 12, 2006, Philadelphia. **Anais [...]**, Philadelphia: ACM SIGKDD Explorations Newsletter, 2006, p 70-77. Disponível em: <https://dl.acm.org/doi/pdf/10.1145/1233321.1233330>. Acesso em: 24 out. 2022.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2ª Ed. Novo Hamburgo: Feevale, 2013. *E-book*. Disponível em: <https://www.feevale.br/Comum/midias/0163c988-1f5d-496f-b118-a6e009a7a2f9/E-book%20Metodologia%20do%20Trabalho%20Cientifico.pdf>. Acesso em: 09 maio 2022.

RAMOS, L. de O.; CUNHA, L. G.; OLIVEIRA, F. L. de.; SAMPAIO, J. de O. FUNDAÇÃO GETÚLIO VARGAS. Escola de Direito de São Paulo. **Relatório ICJ Brasil**. São Paulo: 2021. Disponível em: <https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/30922/Relato%cc%81rio%20ICJBrasil%202021.pdf?sequence=1&isAllowed=y>. Acesso em: 09 maio 2022.

RODRIGUEZ-GALIANO, V.F., *et al.* An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v. 67, p.93-104, dez. 2011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271611001304>. Acesso em: 24 set. 2022.

ROHAN, R.; KUMARI, L. V. R. Classification of Sleep Apneas using Decision Tree Classifier. *In*: INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING AND CONTROL SYSTEMS (ICICCS), 5., 2021, Madurai, India. **Anais [...]**. Madurai, India: Institute of Electrical and Electronics Engineers, 2021, p. 1310-1316.

SAYFULLINA, L. *et al.* Efficient Detection of Zero-day Android Malware Using Normalized Bernoulli Naive Bayes. *In*: 2015 IEEE TRUSTCOM/BIGDATASE/ISPA, 3., 2015, Helsinki. **Anais [...]**, Helsinki: Institute of Electrical and Electronics Engineers, 2015, p. 198-205. Disponível em: <https://ieeexplore.ieee.org/document/7345283>. Acesso em: 24 out. 2022.

SILVA, L.A. da.; PERES, S. M.; BOSCARIOLI, C. **Introdução à Mineração de Dados - Com Aplicações em R**. Rio de Janeiro: Elsevier, 2016. *E-book*. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595155473/>. Acesso em: 24 set. 2022.

SHARIFI, A.; SHARAFIAN, A.; AI, Q. Adaptive MLP neural network controller for consensus tracking of Multi-Agent systems with application to synchronous generators. **Expert Systems with Applications**, [S.l.], v. 184, dez. 2021. DOI: <https://doi.org/10.1016/j.eswa.2021.115460>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417421008733>. Acesso em: 17. set. 2022.

SODERBERG, A. T.; ROMNEY, A. C.; ASHFAQ, F. Building trust: How leaders can engender feelings of trust among followers. **Business Horizons**, v. 65, p.173-182, mar. 2022. DOI: <https://doi.org/10.1016/j.bushor.2021.02.031>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0007681321000331>. Acesso em: 22 mai. 2023.

SOOFI, A. A.; AWAN, A. Classification Techniques in Machine Learning: Applications and Issues. **Journal of Basic & Applied Sciences**, [S. l.], v. 13, p. 459–465, 2017. DOI: [10.6000/1927-5129.2017.13.76](https://doi.org/10.6000/1927-5129.2017.13.76). Disponível em: <https://setpublisher.com/pms/index.php/jbas/article/view/1715>. Acesso em: 4 jun. 2022.

SOUZA, P. R. V. de; TOMAZI, B. G.; SANTOS, B. S. dos. Utilização de técnicas de classificação em conjunto de dados sobre inclusão financeira: um estudo baseado em países latino-americanos. **Brazilian Journal of Production Engineering**, [S. l.], v. 8, n. 1, p. 73–91, 2022. DOI: 10.47456/bjpe.v8i1.37019. Disponível em: <https://periodicos.ufes.br/bjpe/article/view/37019>. Acesso em: 12 set. 2022.

VICENTE, Paulo. O uso de simulação como metodologia de pesquisa em ciências sociais. **Cadernos EBAPE.BR**, vol. 3, n. 1, p.1-9, 2005. E-book. Disponível em: <https://www.redalyc.org/articulo.oa?id=323227811008>. Acesso em: 09 maio 2022.

APÊNDICE A - Quadro com variáveis de entrada

Pergunta	Resposta	Correlação CA3A - Boa	Correlação CA3B - Boa
ca_1a - Quantos agentes públicos da sua organização aceitam dinheiro ou presentes de particulares para cumprir suas funções	Muitos	-0,2780	-0,3271
ca_1b - Quantos agentes públicos da sua organização solicitam dinheiro ou presentes para cumprir suas funções	Nenhum	0,4599	0,4140
ca_1c - Quantos agentes públicos da sua organização deixam de seguir as regras quando houver demanda do seu supervisor para isso	Muitos	-0,3910	-0,4174
	Nenhum	0,4201	0,3560
ca_1d - Quantos agentes públicos da sua organização usam de sua posição para conseguir um emprego para um amigo ou familiar	Muitos	-0,3796	-0,4027
	Nenhum	0,4183	0,3699
ca_1e - Quantos agentes públicos da sua organização contratam uma empresa porque mantém vínculo remunerado ou de amizade nessa empresa	Muitos	-0,3362	-0,3782
	Nenhum	0,4659	0,4141
ca_1f - Quantos agentes públicos da sua organização obtêm benefícios profissionais em função vínculos com pessoas importantes (políticos, autoridades,...)	Muitos	-0,4631	-0,4612
	Nenhum	0,4452	0,3728
ee_1 - Na sua organização, quais das seguintes práticas você já observou em servidores no exercício de suas funções?	Contratar uma empresa porque mantém vínculo remunerado ou de amizade nessa empresa	-0,3080	-0,3205
	Deixar de seguir as regras quando houver pressão do seu supervisor	-0,3812	-0,3259

ee_1 - Na sua organização, quais das seguintes práticas você já observou em servidores no exercício de suas funções?	Favorecer particulares em compras ou contratações públicas	-0,2967	-0,3148
	Nenhuma das anteriores	0,4679	0,4061
	Obter benefícios profissionais em função de vínculos com políticos ou autoridades	-0,4299	-0,3642
	Priorizar interesses não legítimos nas estratégias e projetos da organização	-0,4409	-0,3909
	Usar de sua posição para ajudar um amigo ou familiar	-0,3621	-0,3541
ee_2 - Nos últimos 3 anos na sua organização, em quais das seguintes práticas você já observou servidores em exercício atuando de forma antiética?	Compras e contratações de serviços ou obras	-0,3214	-0,3258
	Formulação de políticas, projetos ou programas	-0,3814	-0,3274
	Nunca observei atos de corrupção	0,5391	0,4880
ee_3 - Nos últimos três anos, você já sofreu pressão para:	Flexibilizar as regras e procedimentos da organização	-0,3343	-0,2897
	Ignorar um ato indevido	-0,3342	-0,3381
	Não sofri pressão indevida no período	0,4433	0,4049
hr_1 - Qual é sua opinião a respeito do sistema de promoção e ascensão na sua organização?	É influenciada por amizades	-0,3619	-0,3160

hr_1 - Qual é sua opinião a respeito do sistema de promoção e ascensão na sua organização?	É influenciada por conexões políticas	-0,3979	-0,3234
	É transparente	0,3443	0,3216
hr_2 - Quais das seguintes condições você diria que têm mais importância para alguém ser nomeado para um cargo comissionado em sua organização?	Favorecer ou premiar pessoalmente quem escolhe os ocupantes dos cargos	-0,3391	-0,3021
	Habilidades específicas necessárias à atividade	0,3635	0,2942
	Possuir familiares, amigos ou conexões pessoais ou políticas na sua organização	-0,4341	-0,3465
hr_4 - Nos últimos 3 anos, você já se sentiu prejudicado devido a comportamento pouco ético em alguma dessas atividades?	Não me senti prejudicado no período	0,4645	0,4100
	Seleção e ocupação de cargos comissionados	-0,3544	-0,2996
nr_1a - As normas e regulamentos são rigorosamente cumpridos	Concordo totalmente	0,4467	0,3787
	Discordo parcialmente	-0,3576	-0,3373
	Discordo totalmente	-0,3292	-0,3631
nr_1b - Os atos e decisões administrativas são devidamente transparentes	Concordo totalmente	0,4540	0,3800
	Discordo parcialmente	-0,3291	-0,2680

nr_1b - Os atos e decisões administrativas são devidamente transparentes	Discordo totalmente	-0,4633	-0,4434
rm_1 - Você se sentiria seguro o suficiente para denunciar eventual conduta ilícita na sua organização?	Não	-0,3502	-0,3176
rm_2 - Quais são as principais dificuldades que os agentes públicos enfrentam para denunciar casos de corrupção?	O processo de denúncia/investigação não é imparcial	-0,3345	-0,2823