
**Detecção e Identificação de Notícias Falsas em
Redes Sociais Utilizando Abordagem de Ciência
de Redes**

Jhonathan Alves de Carvalho



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Uberlândia
2024

Jhonathan Alves de Carvalho

**Detecção e Identificação de Notícias Falsas em
Redes Sociais Utilizando Abordagem de Ciência
de Redes**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: Fabíola Souza Fernandes Pereira

Coorientador: Bruno Augusto Nassif Travençolo

Uberlândia

2024

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

C331d
2024 Carvalho, Jhonathan Alves de, 1994-
Detecção e identificação de notícias falsas em redes sociais
utilizando abordagem de Ciência de Redes [recurso eletrônico] /
Jhonathan Alves de Carvalho. - 2024.

Orientadora: Fabíola Souza Fernandes Pereira.
Coorientador: Bruno Augusto Nassif Travençolo.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Ciência da Computação.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2024.5000>
Inclui bibliografia.
Inclui ilustrações.

1. Computação. I. Pereira, Fabíola Souza Fernandes, 1987-,
(Orient.). II. Travençolo, Bruno Augusto Nassif, 1981-, (Coorient.). III.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Ciência da Computação. IV. Título.

CDU: 681.3

André Carlos Francisco
Bibliotecário Documentalista - CRB-6/3408

Agradecimentos

Gostaria de agradecer a todos que contribuíram direta ou indiretamente para o sucesso do meu projeto de detecção e identificação de notícias falsas em redes sociais utilizando a abordagem de ciência de redes.

Em primeiro lugar, agradeço à minha família e amigos pelo apoio incondicional durante todo o processo de pesquisa e desenvolvimento do projeto. Seus incentivos e encorajamentos foram fundamentais para manter a minha motivação e determinação ao longo do caminho.

Gostaria também de agradecer aos meus professores, que forneceram orientação valiosa e apoio acadêmico em cada etapa do projeto. Suas críticas construtivas e sugestões foram cruciais para o desenvolvimento do meu trabalho e para aprimorar minhas habilidades de pesquisa.

Agradeço ainda a todos os indivíduos e organizações que participaram do meu estudo e forneceram dados para a análise de rede. Sem a colaboração deles, este projeto não teria sido possível. Agradeço também aos desenvolvedores de ferramentas de análise de rede, cujos trabalhos me permitiram realizar análises precisas e confiáveis.

Mais uma vez, obrigado a todos que contribuíram para o meu sucesso neste projeto. Sou grato por ter a oportunidade de trabalhar em um projeto tão empolgante e significativo.

“Não podemos mudar o passado, mas podemos começar agora e fazer um novo fim”
(Zig Ziglar)

Resumo

Este trabalho tem o objetivo de aprofundar e fomentar pesquisas sobre as ferramentas tecnológicas computacionais para o combate à disseminação de notícias falsas nas redes sociais, utilizando redes complexas e inteligência artificial. A pesquisa discute a importância de abordar esse tema e como aplicar redes complexas no desenvolvimento de soluções tecnológicas para identificar e combater a disseminação de notícias falsas. A metodologia da pesquisa envolve uma análise profunda dos dados coletados e um estudo sobre as ferramentas computacionais envolvendo inteligência artificial, redes complexas, processamentos de dados e revisões bibliográficas. Para a análise de dados, foi coletado informações sobre a base de dados FakeNewsNet, levando em consideração os relacionamentos das entidades e extraindo características relevantes ao problema. Por fim será empregado técnicas de redes complexas para modelar e fazer a classificação das *fake news* utilizando aprendizado de máquina. Quanto às ferramentas computacionais, serão exploradas técnicas de inteligência artificial, como os classificadores de árvore de decisão, árvore de decisão aleatória e redes neurais profundas. Também será considerado abordagens de processamento de linguagem natural para analisar o conteúdo das notícias e identificar características que possam indicar a veracidade ou falsidade das informações. A pesquisa bibliográfica irá revisar estudos e trabalhos relacionados ao tema, buscando embasamento teórico e referências importantes no campo do combate às *fake news*. Serão exploradas as iniciativas de conscientização e educação do público em relação às *fake news*. As questões levantadas por essa pesquisa reforçam a importância de desenvolver e utilizar ferramentas tecnológicas avançadas para combater às *fake news* e promover a disseminação de informações precisas e confiáveis. A aplicação de redes complexas e inteligência artificial nesse contexto contribui para uma abordagem mais eficiente e sistemática na identificação e combate às *fake news*, visando proteger a sociedade e preservar a integridade da informação nas redes sociais.

Palavras-chave: Fake news. Redes complexas. Aprendizado de máquina.

Abstract

This work aims to deepen and foster research on computational technological tools for combating fake news on social media platforms, utilizing complex networks and artificial intelligence. This research discusses the importance of addressing this issue and how to apply complex networks in the development of technological solutions to identify and combat the dissemination of false information. The research methodology involves in-depth data analysis and a study of computational tools involving artificial intelligence, complex networks, data processing, and literature reviews. For data analysis, information on fake news will be collected using the FakeNewsNet database, taking into account entity relationships and extracting relevant characteristics related to the problem. Finally, complex network techniques will be employed to model and classify fake news using machine learning. Regarding computational tools, techniques of artificial intelligence such as decision trees, random forests, and deep neural networks will be explored. Natural language processing approaches will also be considered to analyze the content of news articles and identify features that can indicate the veracity or falsity of information. The literature review will examine relevant studies and works related to the topic, seeking theoretical foundation and important references in the field of combating fake news. Initiatives aimed at raising awareness and educating the public about fake news will be explored as well. The issues raised by this research underscore the importance of developing and utilizing advanced technological tools to combat fake news and promote the dissemination of accurate and reliable information. The application of complex networks and artificial intelligence in this context contributes to a more efficient and systematic approach in identifying and combating fake news, with the goal of protecting society and preserving the integrity of information on social media platforms.

Keywords: Fake news. Complex networks. Machine learning.

Lista de ilustrações

Figura 1 – Diagrama gráfico sobre as árvores de decisão.	22
Figura 2 – Representação gráfica fornecida pela teoria dos grafos.	29
Figura 3 – Comunidades em redes complexas (BARABÁSI; PÓSFAL, 2016).	32
Figura 4 – Estrutura dos dados coletados da base FakeNewsNet.	41
Figura 5 – Estrutura de dados tabular pré-processado.	42
Figura 6 – Rede egocêntrica criada a partir dos dados colhidos da base de dados FakeNewsNet.	46
Figura 7 – Modelo de redes neurais profundas utilizado.	52
Figura 8 – Matriz de confusão do melhor modelo de árvore de decisão com o conjunto de características de vocábulos e redes complexas.	53
Figura 9 – Matriz de confusão do pior modelo de árvore de decisão com o conjunto de características de vocábulos e redes complexas.	53
Figura 10 – Melhor árvore de decisão encontrada considerando os vocábulos no treinamento da árvore	63
Figura 11 – Árvore de decisão do pior resultado utilizando as características de Vocábulo e redes complexas.	64
Figura 12 – Matriz de confusão do melhor modelo treinado utilizando somente vocábulos.	65
Figura 13 – Matriz de confusão do melhor modelo utilizando características de redes complexas.	65
Figura 14 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatórias utilizando o conjunto de características de vocábulos e redes complexas.	66
Figura 15 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatória com vocábulos.	66
Figura 16 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatória com redes complexas.	67

Figura 17 – Matriz de confusão do melhor modelo previsto sobre as de redes neurais profundas utilizando o conjunto de características de vocábulos e redes complexas.	67
Figura 18 – Melhor matriz de decisão encontrada do modelo de redes neurais profundas treinadas com as características de redes complexas.	68
Figura 19 – Matriz de confusão do melhor modelo previsto sobre as redes neurais profundas treinadas com características de vocábulos.	68
Figura 20 – Melhor modelo de árvores de decisão utilizando 30% para treino.	69
Figura 21 – Melhor modelo de árvores de decisão aleatória utilizando 30% para treino.	69
Figura 22 – Matriz de confusão do melhor modelo sobre redes neurais profundas utilizando 30% para treino.	70
Figura 23 – Frequência da origem de notícias verdadeiras.	70
Figura 24 – Frequência da origem de notícias falsas.	71

Lista de tabelas

Tabela 1 – Matriz de confusão.	24
Tabela 2 – Resumo dos melhores resultados dos experimentos comparados com algoritmos da literatura correlata.	38
Tabela 3 – Top 10 palavras mais frequentes a partir da extração de dados de títulos das notícias.	43
Tabela 4 – Top 10 palavras mais frequentes sobre extração de dados de textos das notícias.	43
Tabela 5 – Top 10 palavras mais frequentes sobre extração de dados de textos dos perfis.	43
Tabela 6 – Top 10 palavras mais frequentes sobre extração de dados de texto das localizações.	44
Tabela 7 – Top 10 palavras mais frequentes sobre extração de dados de texto das linhas do tempo.	44
Tabela 8 – Top 10 palavras mais frequentes sobre extração de dados de texto da descrição dos perfis.	45
Tabela 9 – Distribuição de notícias políticas no FakeNewsNet.	50
Tabela 10 – Divisão do conjunto de dados entre amostras de treino e teste para todos os algoritmos usados neste trabalho.	51
Tabela 11 – Avaliação com árvores de decisão utilizando o conjunto de características de vocábulos e redes complexas.	52
Tabela 12 – <i>F1 Score</i> utilizando árvores de decisão treinada com os vocábulos.	54
Tabela 13 – <i>F1 Score</i> utilizando árvores de decisão e redes complexas.	54
Tabela 14 – <i>F1 Score</i> utilizando árvores de decisão considerando os três conjuntos de características avaliadas.	54
Tabela 15 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos e redes complexas.	55
Tabela 16 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos.	55

Tabela 17 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de redes complexas.	56
Tabela 18 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos ou redes complexas.	56
Tabela 19 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos e redes complexas.	56
Tabela 20 – Avaliação com redes neurais profundas utilizando o conjunto de características de redes complexas.	57
Tabela 21 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos	57
Tabela 22 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos ou redes complexas.	58
Tabela 23 – Comparação entre árvores de decisão e árvores de decisão aleatórias. .	58
Tabela 24 – Comparação utilizando árvores de decisão e árvores de decisão aleatórias somente com características de vocábulos.	58
Tabela 25 – Comparação utilizando árvores de decisão e árvores de decisão aleatórias com redes complexas.	59
Tabela 26 – Comparação utilizando árvores de decisão aumentando a frequência de vocábulos.	59
Tabela 27 – Comparação utilizando árvores de decisão aleatórias aumentando frequência de vocábulos.	59
Tabela 28 – Comparação utilizando redes neurais profundas aumentando frequência de vocábulos.	60
Tabela 29 – Comparação utilizando árvores de decisão com diferentes conjuntos de treino e teste.	60
Tabela 30 – Comparação utilizando árvores de decisão aleatória com diferentes conjuntos de treino e teste.	61
Tabela 31 – Comparação entre os modelos de redes neurais profundas com diferentes conjuntos de treinamento.	61

Sumário

1	INTRODUÇÃO	13
1.1	Motivação	15
1.2	Objetivos e desafios	15
1.3	Hipótese	16
1.4	Contribuições	16
1.5	Organização da dissertação	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	<i>Fake news</i>	17
2.1.1	O que são <i>fake news</i> ?	18
2.1.2	Os efeitos das notícias falsas	18
2.1.3	Como reconhecer <i>fake news</i> ?	20
2.1.4	O papel das mídias sociais e a responsabilidade pessoal no combate às notícias falsas	20
2.2	Algoritmos de classificação, tecnologias e ferramentas para combater notícias falsas	21
2.2.1	Árvores de decisão	22
2.2.2	Medidas de avaliação	23
2.2.3	Redes Neurais	24
2.2.4	Processamento de Linguagem natural e Suas Técnicas	27
2.2.5	Ciência de redes	28
3	TRABALHOS RELACIONADOS	34
3.1	Experimentos comparando com algoritmos da literatura correlata	34
4	PROPOSTA	40
4.1	Obtenção de bases de dados	40

4.2	Metodologia	40
4.2.1	Coleta de dados	41
4.2.2	Pré-processamento dos dados	42
4.2.3	Treinamento e validação do modelo	45
4.2.4	Representação por meio de redes complexas	45
5	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	50
5.1	Experimentos	50
5.1.1	Árvores de decisão	52
5.1.2	Árvores de Decisão Aleatórias	55
5.1.3	Redes neurais profundas	56
5.2	Avaliação dos Resultados	58
5.2.1	Variando a Quantidade de Vocábulos	59
5.2.2	Variando o Conjunto de Treino e Teste	60
5.2.3	Avaliação qualitativa	61
6	CONCLUSÃO	72
6.1	Principais contribuições	73
6.2	Trabalhos futuros	73
6.3	Contribuições em produção bibliográfica	73
	REFERÊNCIAS	74

Introdução

Notícias falsas são as informações criadas propositalmente com o intuito de enganar, criar ódio e manipular a população. Os problemas relacionados às notícias falsas vêm desde o surgimento das máquinas de impressão de 1439 (SHU et al., 2017) com a publicações e veiculações de notícias sensacionalistas. Nas últimas décadas, com a disseminação da internet e das redes sociais, o problema de propagação de notícias falsas foi ampliado. As informações podem ser publicadas em vários meios de comunicação como jornais, revistas, televisão e, mais recentemente, nas redes sociais, sites de compartilhamento de conteúdos na internet e aplicativos de mensagens.

Essa ampla disseminação de notícias falsas pode ter um sério impacto negativo nos indivíduos e na sociedade, visto que geralmente as notícias falsas dentro das redes sociais têm o objetivo de causar tumulto e ódio (SHU et al., 2017). Informações falsas ou *fake news* gera desinformação, divisão, conflito e desconfiança de instituições e da mídia, levando a ações precipitadas, como protestos violentos, boicotes, conflitos entre grupos e até mesmo influenciar o resultado de eleições.

É fato que as redes sociais se tornaram uma importante fonte de notícias e informações para muitas pessoas ao redor do mundo. A facilidade e rapidez com que as informações podem ser compartilhadas nas mídias sociais atraem muitos usuários, mas também é um grande desafio, pois a precisão das informações pode ser comprometida. Em 2016 uma pesquisa destacou que 20% da população adulta dos Estados Unidos da América ¹ consome notícias com frequência pelas redes sociais e a propagação de conteúdo impreciso pelas mídias sociais tem trazido desafios sem precedentes (WU et al., 2019).

Em 2016 durante as eleições americanas, uma notícia falsa foi veiculada e compartilhada por vários usuários nas principais redes sociais como Facebook, Twitter e Reddit, sobre um estabelecimento conhecido como Pizzagate (SHU et al., 2017). Segundo a notícia falsa, dentro da Pizzagate ocorria tráfico de crianças, o que gerou muita repulsão e ódio pelas redes sociais culminando com o disparo de uma arma de fogo dentro do estabelecimento. Felizmente, ninguém ficou ferido no incidente, mas destacou a importância de

¹ <<https://www.reuters.com/article/us-usa-internet-socialmedia/two-thirds-of-american-adults-get-news-from-social-media>>

combater a disseminação de notícias falsas e garantir que as informações compartilhadas nas mídias sociais sejam verificadas e confiáveis.

Já no Brasil as notícias falsas teve um impacto negativo significativo durante a COVID-19 e no que diz respeito ao novo Coronavírus, as *fake news* tomaram conta das redes em uma grande velocidade, talvez tão grande quanto a velocidade de disseminação do novo vírus, essas notícias tiveram um engajamento enorme nas redes sociais, com afirmações de remédios milagrosos, questionamentos sobre a eficácia das vacinas, severidade e origem do vírus, levando várias pessoas a desinformação em massa (JÚNIOR et al., 2020).

Nesse sentido, estes são importantes exemplos de fatos relatados por diversos autores quando se discute sobre notícias falsas e imprecisas dentro das mídias sociais. Portanto, a fim de evitar problemas semelhantes, é imprescindível o desenvolvimento de técnicas e ferramentas para detecção e a identificação de notícias falsas no contexto de redes sociais. O Pizzagate é um lembrete comovente do impacto negativo das notícias falsas na sociedade e, para evitar que situações semelhantes se repitam no futuro, são necessários esforços conjuntos para desenvolver métodos e ferramentas eficazes para detectar e identificar notícias falsas e desinformação nas mídias sociais, sendo um problema recorrente e atual dentro da sociedade.

Deste modo, a ciência de redes – área científica dedicada ao estudo de sistemas complexos por meio de redes complexas – é uma ferramenta poderosa para estudar e entender as redes sociais, conexões entre seus membros e suas comunidades (CHANDRA et al., 2020). Por meio de indicadores sobre as redes sociais e por medidas usadas em ciência de redes, como a centralidade, é possível entender o quanto uma entidade é relevante em uma rede, sendo capaz de identificar quais são os nós mais influentes em uma rede social.

Assim, a definição formal de redes complexas é um conjunto de elementos interconectados por meio de suas interações, e propriedades (BARABÁSI; PÓSFAL, 2016). No âmbito da teoria de grafos, uma rede complexa é formalmente representada como um grafo, composto por nós e arestas que conectam entre si.

A ciência de redes também dispõe de abordagens para identificar comunidades, ou seja, as comunidades em redes complexas refere-se aos conjuntos de nós que estão mais fortemente conectados entre si (BARABÁSI; PÓSFAL, 2016). Nesse sentido, o algoritmo de Louvain é um exemplo de ferramenta capaz de identificar as pequenas e grandes comunidades de uma rede complexa (AIRES; NAKAMURA, 2017). Dentro do contexto das redes sociais e das notícias falsas, as comunidades possuem características semelhantes, como estruturas que se assemelham em sua semântica, escrita, relações de amizades em comum, vocabulário específico e temáticas em comuns (RAIS; NETO; CIDRÃO, 2019). A identificação da comunidade pode ser útil para entender como as informações são compartilhadas entre os grupos de usuários e como a desinformação se espalha.

Assim, esta dissertação faz o uso de redes complexas para classificar notícias, entre falsas e verdadeiras. A validação do trabalho foi feita utilizando a detecção de notícias

falsas dentro da rede social Twitter, utilizando a base de dados chamada FakeNewsNet. A pesquisa levou em consideração as notícias falsas e verdadeiras sobre política, montando uma rede complexa de cada entidade, refazendo as ligações de cada relacionamento e construindo uma rede direcionada sobre a notícia. Nesse sentido é utilizado árvores de decisão, árvores de decisão aleatórias e redes neurais profundas para fazer a classificação de notícias buscando maior performance e interpretabilidade do problema do que os modelos encontrados na literatura correlata.

1.1 Motivação

A motivação de fazer a detecção e a identificação de notícias falsas nas redes sociais é utilizar o poder da computação durante o processamento de linguagem natural que utiliza de recursos de ciência de dados, ciência de redes, inteligência artificial para fazer a distinção entre as notícias.

Neste sentido, a temática utilizando redes complexas e a extração de características sobre a rede tem o intuito de fomentar futuras pesquisas sobre as redes sociais e as *fake news*. Além disso, a pesquisa nessa área é extremamente importante para continuar avançando em técnicas e ferramentas para lidar com esse problema cada vez mais presente na sociedade.

1.2 Objetivos e desafios

Esta pesquisa tem como objetivo principal propor um modelo de aprendizado de máquina capaz de identificar notícias falsas por meio de técnicas de redes complexas, que tenha maior desempenho e interpretabilidade do que os modelos similares existentes na literatura.

Para isso serão utilizados modelos de classificadores de inteligência artificial como as árvores de decisão e redes neurais profundas. Nesse sentido, este objetivo se desdobra em objetivos específicos listados a seguir.

Objetivos Específicos:

- ❑ Propor uma modelagem de redes complexas para a base de dados colhida sobre a FakeNewsNet.
- ❑ Identificar características específicas da rede complexa que levem o modelo a ter maior confiabilidade, e propor modelos de inteligência artificial para a resolução do problema.
- ❑ Analisar as entidades, como o conteúdo de postagem, lista de amigos, ou seja, quem segue quem, dentre outros recursos, como parâmetros de entrada para os modelos de classificação.

1.3 Hipótese

O uso da ciência de redes para explorar as características das mensagens trocadas por usuários durante um determinado tempo tem mostrado bons resultados, podendo extrair perfis de persistência, que refere-se a perfis onde as mensagens permanecessem relevantes, disseminação, onde os perfis das mensagens são compartilhadas alcançando um grande número de pessoas, e entropia, em que os perfis discutem uma grande diversidade de temas (PEREIRA, 2021). Além disso, o uso de técnicas de mineração de textos e aprendizado de máquina possibilita desenvolver modelos de classificação com base nas palavras mais frequentes (CARVALHO et al., 2022).

Nesse sentido, a adição de métricas de rede auxilia na predição de notícias falsas, especialmente em comparação com técnicas tradicionais que se baseiam apenas em indicadores textuais.

1.4 Contribuições

- Proposição de uma abordagem baseada em redes complexas e inteligência artificial para a classificação de notícias falsas nas redes sociais.
- Modelagem de redes complexas e extração de vocábulos para entrada em classificadores de aprendizado de máquina.
- Metodologia eficaz para identificação e classificação de informações falsas, com métricas de avaliação acima de 90% na classificação de notícias.

1.5 Organização da dissertação

A pesquisa foi organizada em cinco principais elementos sendo eles introdução, fundamentação teórica, trabalhos relacionados, proposta, experimentos e conclusão. A introdução contém informações importantes sobre a proposta, motivação, hipóteses e objetivos da pesquisa. A fundamentação teórica abrange o conceito de *fake news*, os seus efeitos dentro da sociedade, o papel das mídias sociais no combate às notícias falsas, como reconhecer uma *fake news*, algoritmos de classificação, além de tecnologias e ferramentas para o combate de notícias falsas. Os trabalhos relacionados conduzem um estudo sobre os resultados de experimentos encontrados na literatura utilizando aprendizado de máquina. A proposta apresenta a metodologia abordada na pesquisa. Os experimentos apontam os resultados da pesquisa utilizando os modelos de aprendizado de máquina obtidos com a pesquisa. Por fim, a conclusão apresenta as principais contribuições da pesquisa.

Fundamentação Teórica

A detecção de notícias falsas nas redes sociais é uma área de estudo que envolve diversas áreas, tais como inteligência artificial, redes complexas e teoria dos grafos. O conceito *fake news* refere-se a informações ou relatos falsos que são disseminados e apresentados como fatos verdadeiros (BARBOSA, 2020) e as redes sociais têm se tornando um terreno fértil para a propagação de informação falsas.

Isso se deve a velocidade em que as informações se espalham e a facilidade em compartilhar informações. Assim, algumas características dentro das redes sociais contribuem para essa desinformação. Plataformas como o Twitter priorizam conteúdos com maior potencial de engajamento, ou seja, postagem com maior número de curtidas, reações, comentários e compartilhamentos, tendem a se destacar dentro da plataforma. As notícias falsas por conterem aspectos e traços de sensacionalismo, fazem com que a atenção e interação com esse tipo de informação sejam mais atrativas para o público, levando a um grande número de interações, compartilhamentos e comentários por parte da população.

Um exemplo relacionado a redes sociais foram as interações dos usuários sobre as notícias falsas sobre o COVID-19, que se alastraram na internet com publicações de informações, como se fossem reais, com embasamento científico, mas que não passaram por um processo de apuração do fato, causando um mar de desinformação (BRANDÃO; SOUZA, 2020).

2.1 *Fake news*

As notícias falsas têm sido objeto de debate e preocupação em todo o mundo, levando a iniciativas de governos, empresas de tecnologia e organizações dentro da sociedade civil para combater as notícias falsas. Com o advento das redes sociais e a facilidade de compartilhamento de informações, as *fake news* têm se tornado um assunto cada vez mais comum e preocupante (LAZER et al., 2018). As notícias falsas podem se espalhar rapidamente nas redes sociais sem que as pessoas verifiquem a veracidade das informações.

Muitas vezes, notícias falsas são criadas para aparentarem serem verídicas usando fontes supostamente confiáveis e citações fictícias.

As *fake news* ou notícias falsas são informações criadas e espalhadas por meio de mídias sociais, jornais, aplicativos de mensagens e outras plataformas online, com o objetivo de manipular a opinião pública, gerar cliques em sites, prejudicar pessoas e organizações (LAZER et al., 2018).

Identificar notícias falsas pode ser difícil, mas existem várias estratégias que podem ajudar a identificar notícias falsas e será discutido posteriormente apresentando tecnologias e métodos eficientes para fazer a sua identificação.

2.1.1 O que são *fake news*?

Muitas vezes as notícias falsas são compartilhadas de fontes que não são confiáveis, contribuindo para uma rápida disseminação, podendo causar danos irreparáveis. Mas afinal o que são notícias falsas, para isso é necessário reforçar que o conceito de *fake news* não é algo novo, mas a sua popularidade e visibilidade aumentaram significativamente com o advento das mídias sociais e a facilidade de divulgação de informações pela internet. O termo notícias falsas ganhou destaque durante as eleições presidenciais dos Estados Unidos em 2016, quando várias notícias falsas foram disseminadas massivamente por meio de redes sociais, principalmente no Twitter, influenciando a opinião pública e a dinâmica eleitoral (ALLCOTT; GENTZKOW, 2017).

Vale ressaltar algumas diferenças entre *fake news*, desinformação e rumor. *Fake news* são informações criadas com o intuito de enganar, fazendo-se parecer notícias verídicas.

Essas informações, por muitas vezes tem motivações políticas, financeiras, sensacionalistas e maliciosas (SANTOS, 2023). A desinformação refere-se à disseminação intencional de informações falsas ou enganosas com o propósito expresso de causar danos ou criar uma impressão errônea (SANTOS, 2023). Por fim, os rumores são informações não verificadas podendo ser falsas ou verdadeiras ao qual são disseminadas entre as pessoas (PONTES et al., 2015).

Por fim, basicamente as *fake news* são informações falsas criadas com o intuito de enganar as pessoas e essa desinformação tem gerado vários efeitos negativos para a sociedade.

2.1.2 Os efeitos das notícias falsas

As *fake news* estão se tornando um problema cada vez maior na sociedade atual e podem ter uma variedade de efeitos negativos sobre a sociedade e seus indivíduos. Geralmente possuem o intuito de manipulação da opinião pública, influenciando sobre um determinado assunto. No meio político, por exemplo, pode afetar candidatos e partidos, criando movimentos sociais desfavoráveis aos candidatos.

Como resultado, isso pode resultar em um ambiente não democrático, com o intuito de influenciar o resultado das eleições (ALLCOTT; GENTZKOW, 2017), ampliando a polarização política e criando ainda mais divisões entre os grupos sociais. Normalmente visa reforçar pontos de vista já pré-existentes, alimentando teorias da conspiração, criando divisões sobre os grupos sociais e dificultando a união das pessoas em discussões e questões de relevância para a sociedade.

As notícias falsas também podem levar a decisões erradas por parte de indivíduos, empresas ou governos promovendo consequências negativas de longo prazo, especialmente quando se trata de saúde. Durante a pandemia do COVID-19, muitas notícias falsas circularam nas redes sociais, levando a muitas pessoas, empresas e governos a tomarem decisões erradas. Uma das notícias falsas mais perigosas foi que a pandemia era uma farsa ou que o vírus não era real. Isso levou muitas pessoas a ignorarem conselhos de saúde, como usar máscaras e manter o distanciamento social (LINDEN; ROOZENBEEK; COMPTON, 2020). Esse tipo de notícia falsa circulou amplamente nas redes sociais. *Fake news* e teorias da conspiração levantaram dúvidas sobre a origem do vírus, eficácia de tratamentos, eficácia de vacinas, bem como sobre a gravidade do vírus. Infelizmente, isso resultou no atraso de alguns governos na tomada de decisões importantes, como, por exemplo, a implementação das medidas de saúde pública necessárias para conter a propagação do vírus.

De fato, a desconfiança da população nas autoridades de saúde pública e aumentando ainda mais a polarização política em torno da pandemia (LINDEN; ROOZENBEEK; COMPTON, 2020).

Importante destacar que as *fake news* também podem afetar negativamente a saúde mental das pessoas, causando medo, ansiedade e estresse desnecessário, principalmente quando abrange assuntos relacionadas a eventos traumáticos, como desastres naturais e ataques terroristas, causando desinformação maciça, que leva a um grande número de pessoas à desinformação (ALTAY; HACQUIN; MERCIER, 2022).

Outro fator crucial são os danos e efeitos negativos à reputação pessoal, que, uma vez fragilizada, inverter a situação pode se tornar algo complexo. Em alguns casos, pode ser difícil para uma pessoa ou organização recuperar sua reputação após serem vítimas de notícias falsas (ALTAY; HACQUIN; MERCIER, 2022).

Ressalta-se que mesmo depois que a informação falsa for revelada, a imagem pública pode permanecer manchada por um grande tempo.

Nesse sentido, as notícias falsas trazem uma série de consequências negativas para a sociedade e para os indivíduos, por isso é importante que as pessoas se conscientizem e sejam críticas em relação às informações que recebem e sempre verifiquem a veracidade das informações antes de compartilhá-las com as demais pessoas.

2.1.3 Como reconhecer *fake news*?

Ao consumir informações nas redes sociais e na internet em geral, é importante saber identificar e reconhecer notícias falsas para evitar a propagação destas informações. Primeiro é necessário verificar as fontes, certificando de que a origem tenha um histórico de confiança com conteúdo de informação correta (SILVA, 2019). Se a fonte for desconhecida ou pouco conhecida é possível que seja uma notícia falsa. Além de verificar a origem da informação é importante buscar por outras referências para confirmar a informação, ou seja, buscar por notícias ou publicações que confirmem a veracidade dos fatos (SILVA, 2019). Se não houver outras fontes confiáveis para confirmar a notícia também é possível que seja uma notícia falsa.

Antes de compartilhar algum conteúdo é importante ler com atenção a íntegra da informação para garantir que todo o conteúdo está de acordo com o título. Muitas vezes as notícias falsas possuem títulos atrativos e podem dizer algo completamente diferente do que o título sugere. Notícias falsas também costumam ter títulos sensacionalistas para chamar a atenção das pessoas, com títulos exagerados ou dramáticos, visa uma reação emocional imediata. Contudo, é possível verificar a confiabilidade da informação simplesmente com o conteúdo da postagem, pois, notícias falsas geralmente contêm erros gramaticais e ortográficos (MOURÃO; ROBERTSON, 2019). Muitas das *fake news* são recicladas de tempos e tempos para enganar a população, ou seja, são mensagens antigas que às vezes são apresentadas como novas, por isso, é necessário verificar a data de postagem para garantir que as notícias sejam atuais e não desatualizadas.

Geralmente essas notícias são tendenciosas, escritas para apoiar a uma determinada opinião ou ponto de vista e muitas vezes, apresentam apenas um lado da história. Portanto, para fazer a detecção e prevenir a disseminação de notícias falsas, é importante verificar a fonte, ler toda a história, verificar outras fontes confiáveis, tomar cuidado com sensacionalismo, erros gramaticais, verificar a data de publicação, buscando evidências que confirme toda a informação.

Por fim, as notícias falsas geralmente apresentam informações sem nenhuma evidência ou fontes confiáveis. Se a notícia não fornecer fontes ou evidências para apoiar as alegações feitas, provavelmente é falsa.

2.1.4 O papel das mídias sociais e a responsabilidade pessoal no combate às notícias falsas

As mídias sociais são uma das principais plataformas para a disseminação de notícias e informações. Com o grande volume de conteúdo compartilhado diariamente, tornou-se mais fácil para as notícias falsas se espalharem e atingirem um grande número de pessoas em um curto espaço de tempo (DONCEL-MARTÍN; CATALAN-MATAMOROS; ELÍAS, 2022).

As plataformas de mídia social, portanto, têm um papel importante na luta contra as notícias falsas. Para combatê-las, estudos recentes utilizando dados das redes sociais como Twitter e algoritmos de aprendizado de máquina têm mostrado bons resultados para gerenciar a grande quantidade de conteúdo que é trocado diariamente para detectar e sinalizar notícias falsas (BODNAR et al., 2014).

No entanto, a responsabilidade de combater as notícias falsas é de todos e a responsabilidade individual é igualmente importante. A conscientização do usuário final é fundamental para combater notícias falsas e evitar que elas se espalhem tão rapidamente.

Cada pessoa tem que assumir a responsabilidade pessoal de verificar a precisão das informações antes do compartilhamento. É imperativo que as pessoas verifiquem a fonte das informações antes de compartilhá-las e evitem compartilhar conteúdos sobre os quais não têm certeza.

É extremamente importante estar ciente de que a divulgação de notícias falsas pode trazer consequências graves, como espalhar informações prejudiciais a organizações ou pessoas, influenciar eleições ou até mesmo prejudicar sua saúde pública. Por isso, é importante ter cuidado ao compartilhar informações nas redes sociais e sempre buscar informações confiáveis em fontes idôneas.

Em suma, a educação é uma das formas mais eficazes de combater as notícias falsas. É importante existir um processo de letramento digital do indivíduo, que consiste no desenvolvimento de habilidades sobre como lidar com as informações e tecnologias da atualidade em um aprendizado contínuo prevenindo a desinformação e promovendo a disseminação de informações confiáveis (SANTOS; PEREIRA, 2023). Além disso, as tecnologias e ferramentas para combater notícias falsas evoluíram rapidamente, principalmente com o desenvolvimento da inteligência artificial e do aprendizado de máquina que será apresentado e discutido a seguir.

2.2 Algoritmos de classificação, tecnologias e ferramentas para combater notícias falsas

O principal objetivo da pesquisa é encontrar atributos relevantes a partir da topologia de rede para serem utilizados como entrada em algoritmos de classificação. Para isso, propõe-se utilizar algoritmos supervisionados que requerem um conjunto de dados de treinamento e alvo, onde cada exemplo de treinamento consiste em uma entrada e a saída desejada correspondente, o objetivo do algoritmo é aprender a relação entre as entradas e saídas de forma a prever corretamente as saídas para novas entradas, especificamente nesta dissertação, serão explorados os algoritmos de árvores de decisão, árvores de decisão aleatórias e redes neurais profundas aos quais serão apresentados a seguir.

2.2.1 Árvores de decisão

As árvores de decisão são uma técnica de aprendizado de máquina que usa uma estrutura de árvore para representar um conjunto de regras de decisão. Cada nó interno da árvore representa uma questão, e os ramos da árvore representam possíveis respostas a essa questão. Os dados trafegam pela árvore, chegando eventualmente a uma folha que representa a avaliação final. As árvores de decisão são algoritmos determinísticos, isso significa que o algoritmo sempre retorna os mesmos resultados quando os dados de entrada seguem as mesmas regras de decisão (CAVALCANTE, 2016).

A Figura 1 demonstra e ilustra um exemplo didático e hipotético de como uma árvore de decisão podem ser utilizada para classificar as notícias falsas, nesse exemplo a árvore de decisão começa com uma pergunta, a característica de comunidades são maior que 6? Caso afirmativo e for maior que 6 ela vai para a direita, logo não é uma notícia falsa, caso contrario ela vai para esquerda, então a árvore de decisão faz outra pergunta, a palavra *news* é maior que 10? Dependendo da resposta a árvore segue por caminhos diferentes, caso for afirmativo, é uma notícia falsa, caso contrario é uma notícia verdadeira.

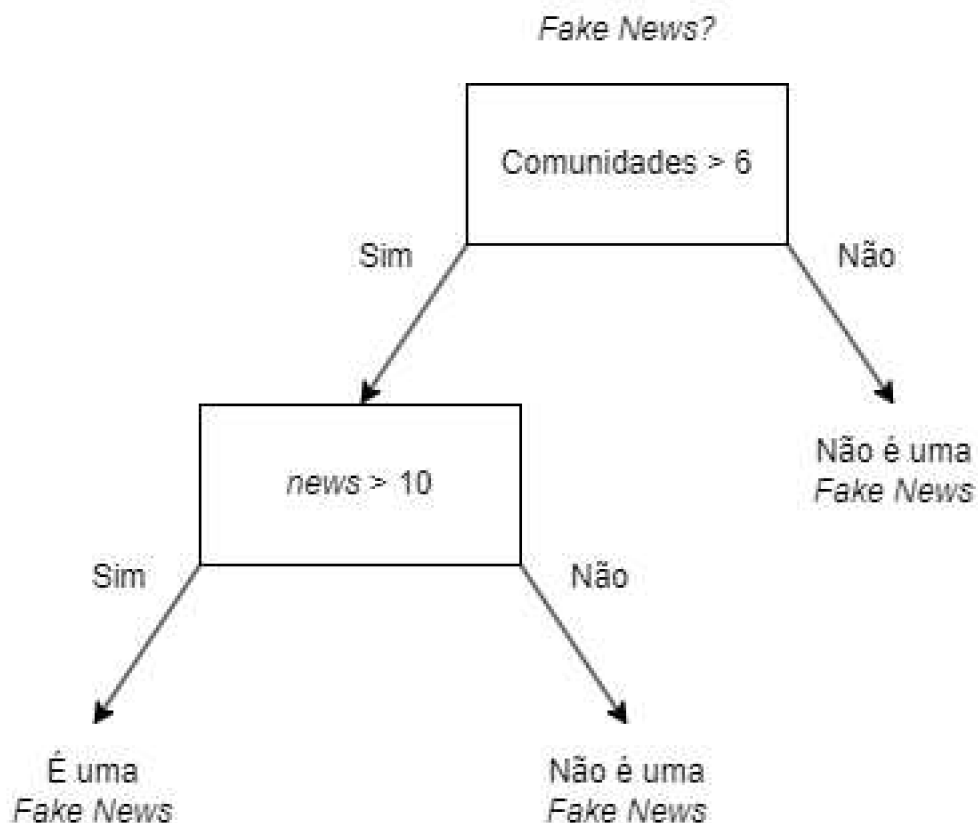


Figura 1 – Diagrama gráfico sobre as árvores de decisão.

A árvore de decisão tem como principal característica classificar resultados binários e prever propriedades discretas, indicando verdadeiro ou falso. Nesse sentido, para uma melhor acurácia é importante selecionar atributos que sejam relevantes para o problema

discutido na dissertação, bem como algoritmos de classificação que consistem em trabalhar sobre dois conjuntos de dados um de treinamento e outro de teste (MONARD; BARANAUSKAS, 2003). O modelo de árvore de decisão é construído com base nessas características, treinando sobre as notícias previamente rotuladas como verdadeiras ou falsas. Com base nas decisões tomadas pela árvore de decisão, uma nova instância pode ser classificada como verdadeira ou falsa. Por exemplo, se uma árvore de decisão confirmar que uma notícia contém palavras-chave comumente associadas a notícias falsas, esta notícia então pode ser classificada como falsa.

O processo de tomada de decisão em uma árvore de decisão é inteiramente determinado pelas regras de divisão e valores de corte em cada nó da árvore. Portanto, se a mesma entrada for passada para a árvore de decisão várias vezes, o algoritmo sempre tomará as mesmas decisões em cada nó da árvore e produzirá o mesmo resultado final.

No entanto, é importante observar que a precisão de uma árvore de decisão pode ser afetada pela qualidade dos dados de entrada e pelas decisões tomadas durante a construção da árvore, como, por exemplo, os hiperparâmetros de entrada e critério de divisões entre as amostras de treino e amostras de validação.

Para isso o pré-processamento de dados é uma etapa importante na análise de dados que envolve a preparação dos dados iniciais para uma análise mais precisa e eficiente. Esta etapa é crítica, pois os dados brutos coletados não estão prontos para análise – os dados geralmente contêm erros, inconsistências, valores ausentes e outros problemas que podem afetar a qualidade dos resultados (BATISTA, 2003).

Nesse sentido, o pré-processamento de dados é uma etapa necessária para que os dados possam ser usados para construir modelos para aprendizado de máquina, análise estatística e outros aplicativos que dependem de dados precisos e confiáveis.

Em suma, as árvores de decisão são algoritmos de aprendizado supervisionado que funcionam criando uma estrutura de árvore que representa todas as decisões possíveis que podem ser tomadas com base na entrada. Cada nó da árvore representa uma questão ou condição sobre os dados, as arestas representam possíveis respostas para essa questão, e as folhas da árvore representam as classes ou categorias finais nas quais os dados podem ser classificados (JÚNIOR, 2018).

2.2.2 Medidas de avaliação

As medidas de avaliação, também conhecidas como indicadores de desempenho, são ferramentas ou métodos usados para medir o sucesso, a eficácia ou a qualidade de um modelo de aprendizado de máquina e desempenha um papel crucial em sua avaliação, fornecendo informações úteis para a tomada de decisões sobre o modelo.

Muitas vezes é utilizado uma matriz de confusão para avaliar o desempenho de um modelo de classificação, basicamente usa-se uma tabela em que se resume as previsões

do modelo com base nos dados de testes reais, permitindo calcular várias métricas de desempenho.

Tabela 1 – Matriz de confusão.

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Existem quatro elementos principais na matriz de confusão: verdadeiros positivos (TP), falsos positivos (FP), falsos negativos (FN) e verdadeiros negativos (TN), como apresenta a Tabela 1.

Várias métricas de avaliação do modelo podem ser calculadas a partir dos valores da matriz de confusão, como acurácia, precisão e revocação. Essas métricas permitem avaliar o desempenho do modelo sob diferentes perspectivas, considerando tanto os erros de classificação quanto a distribuição das amostras em diferentes classes.

A acurácia é a métrica mais simples e direta, representando a proporção de amostras classificadas corretamente pelo modelo em relação ao total de amostras. Já a precisão é uma métrica mais detalhada, que leva em consideração a proporção de amostras corretamente classificadas em cada classe em relação ao total de amostras previstas como aquela classe.

Um verdadeiro positivo ocorre quando o modelo prevê corretamente uma classe positiva, enquanto um falso positivo ocorre quando o modelo prevê incorretamente uma classe positiva. Um falso negativo ocorre quando o modelo prevê incorretamente uma classe negativa, enquanto um verdadeiro negativo ocorre quando o modelo prevê corretamente uma classe negativa.

Nesse trabalho é utilizado a avaliação F1 Score que é uma métrica usada durante o aprendizado de máquina para medir o desempenho de um modelo de classificação, basicamente o F1 Score é uma combinação de duas outras métricas importantes, precisão e revocação, revocação têm o objeto de medir a proporção de exemplos positivos previstos corretamente em relação a todos os exemplos verdadeiramente positivos no conjunto de dados (GIOIA et al., 2021).

2.2.3 Redes Neurais

As redes neurais são um conjunto de algoritmos de aprendizado de máquina que tentam imitar o funcionamento do cérebro humano (SOUSA, 2005). As redes neurais são formadas por camadas de neurônios conectados entre si (PRIETO et al., 2016). Cada neurônio recebe uma entrada, processa essa informação e produz uma saída que é passada para o próximo neurônio, desta forma, as redes neurais conseguem aprender com dados e classificar informações.

Nesse sentido, uma rede neural é composta por um conjunto interconectado de unidades de processamento chamadas neurônios artificiais ou perceptrons. Esses neurônios recebem entradas, realizam cálculos ponderados e produzem saídas. As conexões entre os neurônios são representadas por pesos, que determinam a importância relativa de cada entrada para a saída.

Os neurônios são unidades básicas que processam informações, sendo responsável por receber entrada, ponderar essas entradas com seus pesos e obter a saída.

As conexões sinápticas podem ser unidirecionais ou bidirecionais. Nas redes neurais *feed-forward*, as conexões são unidirecionais, o que significa que as informações fluem em apenas uma direção, da camada de entrada para a camada de saída. Nas redes neurais recorrentes, as conexões são bidirecionais, o que permite que as informações circulem pela rede.

As redes neurais são treinadas por meio de um processo de aprendizado, em que os pesos das conexões são ajustados para otimizar o desempenho do modelo em uma tarefa específica. Esse treinamento é geralmente feito usando conjuntos de dados de treinamento que contêm exemplos rotulados, permitindo que a rede aprenda a associar corretamente as entradas às saídas desejadas (PRIETO et al., 2016).

O modelo de rede neural sequencial consiste em várias camadas sequenciais, onde as camadas são empilhadas umas sobre as outras, no qual, cada camada recebe a saída da camada anterior como entrada, em que os dados trafegam sequencialmente pela rede, passando camada por camada até chegar na camada de saída (BARBOSA, 2021).

Esse modelo sequencial é um tipo de modelo de rede neural *feed-forward* no qual os dados fluem em uma direção, da entrada para a saída, sem *feedback* ou *loops*. Esses modelos são comuns em problemas como classificação, em que o objetivo é prever uma saída categórica com base nos dados de entrada.

A utilização das camadas densas é necessária para conectar todos os neurônios da camada anterior a todos os neurônios da camada atual e isso significa que cada neurônio da camada anterior está conectado a cada neurônio da camada atual por uma conexão ponderada.

Em uma rede neural, as camadas ocultas são camadas intermediárias entre uma camada de entrada e uma camada de saída. Essas camadas são compostas de neurônios que processam a entrada e produzem a saída para a próxima camada. O termo oculto se refere ao fato de que essas camadas não estão diretamente conectadas à entrada ou saída, ou seja, não são visíveis na entrada ou saída da rede. Em vez disso, eles são usados para transformar e processar dados de entrada antes de passá-los para a camada de saída (KIRSTEN, 2009).

Cada camada oculta consiste em uma série de neurônios, que são as principais unidades de processamento em uma rede neural. Cada neurônio recebe um conjunto de entradas, executa cálculos com base em um conjunto de pesos junto com o viés e envia para a

próxima camada.

O número de camadas ocultas em uma rede neural é uma das principais características que determinam sua capacidade de modelagem. Redes com mais camadas ocultas podem capturar relacionamentos mais complexos nos dados de entrada, mas são mais difíceis de treinar e mais propensas a *overfitting*, casos em que a rede não generaliza, isto é, obtém um baixo desempenho na classificação de dados nunca previamente classificados (KIRSTEN, 2009).

Os pesos e *bias* são parâmetros que são ajustados durante o treinamento da rede neural para minimizar a diferença entre a saída da rede e os valores desejados para a saída. Os pesos representam a força da conexão entre as entradas e os neurônios, e o *bias* é um valor constante adicionado à soma ponderada das entradas de cada neurônio.

A função de ativação ReLu é uma função não linear usada em redes neurais para incluir a não linearidade, resolvendo problemas de desempenho e problemas de gradiente (RIZZO; CANATO, 2020). É uma das funções de mais populares no aprendizado de máquina e é usado em muitas aplicações, como visão computacional, processamento de linguagem natural e reconhecimento de fala.

Já a função sigmoid é uma função de ativação não linear comumente usada para garantir que a saída esteja entre 0 e 1. A principal diferença entre funções lineares e não lineares em redes neurais é que as funções lineares produzem saídas proporcionais às entradas, enquanto as funções não lineares permitem que a rede aprenda relações complexas entre entradas e saídas que são importantes para resolver problemas do mundo real (RIZZO; CANATO, 2020).

O algoritmo de Adam combina a ideia do algoritmo Momentum com o algoritmo RMSprop. O algoritmo Momentum usa a média exponencial das direções do gradiente anterior para atualizar os pesos, enquanto o algoritmo RMSprop usa a média exponencial dos quadrados dos gradientes para ajustar a taxa de aprendizado. Adam combina essas duas ideias e usa a estimativa de momento adaptativo e um segundo gradiente de momento para atualizar os pesos (FALCÃO et al., 2019).

O *dropout* em redes neurais é uma técnica usada para evitar *overfitting* durante o treinamento da rede. O *overfitting* ocorre quando uma rede neural se ajusta muito bem aos dados de treinamento, mas generaliza mal para os novos dados.

A técnica de *dropout* envolve a desativação aleatória de um número de neurônios na rede durante cada período de treinamento. Isso força a rede a aprender recursos mais robustos e não depender de neurônios específicos para fazer previsões (SANTOS, 2017).

Durante o treinamento, o *dropout* desativa aleatoriamente alguns neurônios, removendo-os temporariamente da rede. As saídas dos neurônios restantes são então normalizadas para que a soma das saídas permaneça constante. Isso garante que a rede continue a aprender mesmo quando alguns neurônios são desativados.

Isso é muito útil em redes neurais profundas, onde existem muitos neurônios e cone-

xões. Sem o *dropout*, a rede pode superajustar os dados de treinamento e falhar para generalizar para os novos dados. O *dropout* evita esse problema, forçando a rede a aprender recursos mais robustos e generalizáveis.

A principal vantagem das redes neurais profundas é a capacidade de processar dados multidimensionais e complexos, o que permite extrair características relevantes e identificar padrões sutis nos dados de entrada.

Em suma, as redes neurais profundas são um modelo de inteligência artificial capaz de fazer classificações, conseguindo atribuir a uma instância, a uma de duas classes, como verdadeiro ou falso. Para fazer isso, uma rede neural profunda a partir de um conjunto de dados de entrada, usa várias camadas de neurônios artificiais para processar e analisar esses dados. Cada camada da rede consiste em um número de neurônios que executam operações matemáticas nos dados de entrada. À medida que os dados passam pela rede, recursos importantes são revelados e, eventualmente, a rede produz uma saída que pode ser interpretada como uma das duas classes (DOEBBER, 2019). Nesse sentido é uma poderosa ferramenta que pode processar dados complexos e executar tarefas de classificação com eficiência e com o desenvolvimento de tecnologias de hardware e software, as redes neurais profundas estão se tornando mais populares e amplamente utilizadas em vários campos de pesquisa.

2.2.4 Processamento de Linguagem natural e Suas Técnicas

O Processamento de linguagem natural é um campo interdisciplinar da inteligência artificial que se concentra na interação entre computadores e pessoas utilizando a linguagem humana, dedicando no desenvolvimento de algoritmos e modelos de aprendizado de máquina que permita a interpretação e a geração da linguagem humana de maneira satisfatória, desempenhando um papel fundamental em uma ampla gama de aplicações, desde assistentes de voz, traduções automáticas, análises de sentimentos e extração de informações de texto (MAGALHÃES et al., 2020).

Existem alguns campos dentro de processamento de linguagem natural que é preciso ser aprofundado para entender suas aplicações e técnicas. Eles são normalmente são divididos em cinco níveis de análises: fonético, morfológico, sintático, semântico e pragmático, que serão detalhadas a seguir.

O nível fonético possui algumas técnicas capazes de identificar a fala humana e consiste em aplicações como assistentes pessoais que usam ondas sonoras para fazer a interação com a fala humana. Essas aplicações usam técnicas que utilização redes neurais com modelos de linguagem para fazer o reconhecimento automático de fala humana (MAGALHÃES et al., 2020).

O nível morfológico foca na estrutura da palavra e em sua normalização, identificando sufixos e prefixos que compõem as palavras identificando palavras ou expressões isoladas em uma sentença (NETO; TONIN; PRIETCH, 2010), ajudando a entender as palavras

em suas diferentes formas e funções em uma frase. Isso significa que é possível reconhecer as palavras em uma sentença e determinar qual papel ou categoria cada palavra está desempenhando, com base em informações criando um dicionário léxico (CANTARELLI, 1998). São encontradas em aplicações de traduções de texto, que utilizam a morfologia para encontrar correspondências morfológicas entre idiomas, levando a traduções mais eficientes.

Enquanto o analisador léxico-morfológico se concentra na estrutura e classificação das palavras em várias categorias, o analisador sintático opera em um nível mais abrangente, examinando como as palavras se agrupam e formam a estrutura das frases (NETO; TONIN; PRIETCH, 2010), ajudando a aplicações de correção gramatical a terem maior coerência em um texto.

Já a semântica está relacionada ao significado não só de cada palavra, mas também de todo o conjunto resultante delas, em uma de suas aplicações envolve identificar palavras e expressões que indicam sentimentos, descrevendo o sentido das estruturas das palavras que foram reagrupadas (NETO; TONIN; PRIETCH, 2010).

Conforme o processamento da linguagem natural avança, torna-se essencial realizar uma interpretação abrangente usando o nível pragmático que em vez de se concentrar apenas na análise detalhada das partes, como é feito ao examinar informações morfológicas e léxicas, sintáticas e suas regras gramaticais, semânticas e significados, lida com a interpretação do significado real da linguagem (NETO; TONIN; PRIETCH, 2010).

Nesta pesquisa, é utilizado uma biblioteca em Python conhecida como NLTK¹ do inglês *Natural Language Toolkit* que significa kit de ferramentas de linguagem natural, esta biblioteca conta com um conjunto de funções que auxiliam no trabalho com linguagem natural, como normalização de texto, remoção de palavras de parada conhecidas como *stopwords*, que são palavras do português que incluem o, a, e, de, para, entre outras. Essa biblioteca é uma poderosa ferramenta para o processamento de texto durante o processo semântico com recursos lexicais, sendo uma ferramenta valiosa para essa pesquisa.

2.2.5 Ciência de redes

A Teoria dos Grafos é um ramo da Matemática e da Ciência da Computação que estuda as propriedades e os comportamentos de estruturas chamadas de grafos. Os grafos são representações abstratas de relações entre objetos, e eles consistem em dois elementos principais conhecidos como vértices e arestas.

Basicamente vértices são pontos que representam objetos e arestas são linhas que fazem as relações entre os objetos. Normalmente são usados para modelar uma ampla variedade de situações do mundo real, desde redes de computadores e sistemas de transporte até redes sociais e estruturas químicas. A teoria dos grafos fornece ferramentas e técnicas

¹ <<https://www.nltk.org/>>

para analisar e resolver problemas relacionados a essas estruturas (BARABÁSI; PÓSFAL, 2016).

Desse modo, as redes complexas fazem o uso da teoria dos grafos para estudar sistemas compostos por muitos elementos interconectados que exibem comportamentos e propriedades que não podem ser facilmente previstos a partir das características individuais de seus componentes.

Assim a teoria dos grafos é uma das bases essenciais da análise de redes complexas, a qual, fornece uma estrutura para representar e visualizar essas redes. A Figura 2 ilustra uma representação dessa rede, em que cada nó é um objeto, suas arestas representam as conexões e os relacionamentos entre eles. Essa representação permite uma melhor compreensão da estrutura da rede e dos padrões de conexão entre os elementos.

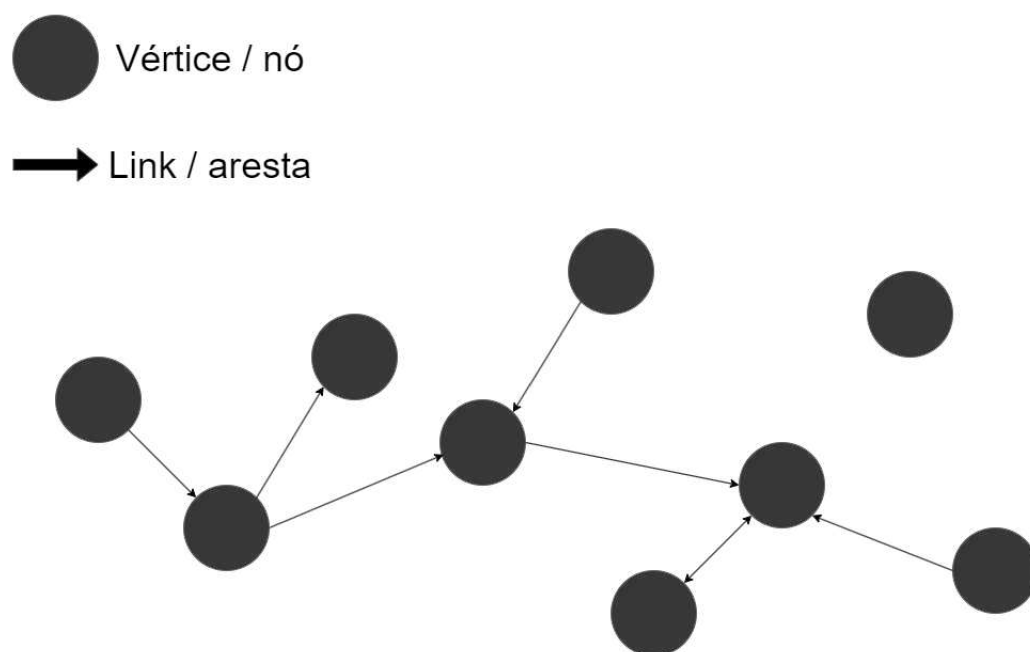


Figura 2 – Representação gráfica fornecida pela teoria dos grafos.

A representação gráfica é uma ferramenta para entender a estrutura da rede, bem como suas propriedades e características. Por meio dessa representação, é possível visualizar e analisar aspectos como centralidade e densidade da rede, permitindo uma melhor compreensão do seu funcionamento e padrões de conexão entre os elementos.

A área de ciência das redes tem se dedicado a construir modelos que se aproximem da realidade. Algumas das abordagens utilizadas são os modelos de redes aleatórias, modelo livre de escala e de pequeno mundo, que serão detalhados a seguir. Esses modelos são tentativas de simular a complexidade das redes reais, de forma que seja possível compreender melhor suas propriedades e comportamentos.

O modelo de rede aleatória basicamente constrói uma rede, baseada em uma probabilidade fixa. Nela, cada nó tem uma probabilidade fixa de se conectar a outro nó da rede,

independentemente de suas propriedades ou do número de conexões que já possui (BARABÁSI; PÓSFAL, 2016).

Isso torna a rede gerada homogênea e irreal em comparação com muitas redes complexas encontradas na natureza e na sociedade. Uma rede heterogênea é uma rede complexa onde os nós têm diferentes propriedades ou atributos, e as arestas representam diferentes tipos de conexões ou relacionamentos entre esses nós.

Basicamente uma rede homogênea possui nós com propriedades semelhantes e conexões semelhantes e uma rede heterogênea possui nós com propriedades diversas e conexões diversas (BARABÁSI; PÓSFAL, 2016).

Nesse sentido, o Twitter não é considerada uma rede homogênea, uma vez que as entidades na rede, como os usuários e suas interações, não possuem a mesma quantidade de conexões ou graus de ligação.

Em redes complexas, utiliza-se o grau como uma medida básica que expressa o número de conexões que um nó possui com outros nós da rede. Ele é definido como o número de arestas conectadas a um dado nó na rede (BARABÁSI; PÓSFAL, 2016). Por exemplo, em uma rede social, a classificação de um usuário pode ser definida como o número de amigos ou quantidade de seguidores, ou seja, o grau é uma medida importante para entender a estrutura e a topologia de uma rede e para identificar nós centrais ou influentes.

Nesse sentido, o Twitter não pode ser considerada uma rede aleatória. Embora o processo de adição de novos seguidores possa ser considerado aleatório, a rede resultante possui uma distribuição de grau não uniforme, o que a torna uma rede livre de escala.

Uma rede livre de escala é um tipo de rede complexa em que o grau dos nós segue uma distribuição de lei de potência, o que significa que alguns nós, conhecidos como hubs, têm um número muito grande de conexões, enquanto a maioria dos nós tem apenas algumas conexões (BARABÁSI; PÓSFAL, 2016).

A lei de potência é uma distribuição de probabilidade que descreve a frequência com que eventos de várias magnitudes ocorrem em um sistema. Em redes complexas, geralmente existe uma distribuição de nós de lei de potência, ou seja, a frequência com que os nós têm um determinado número de conexões (BARABÁSI; PÓSFAL, 2016).

Neste modelo, a estrutura da rede é tal que alguns nós estão mais interconectados que outros, criando *hubs* com muitas conexões, enquanto a maioria dos outros nós tem poucas conexões (BARABÁSI; PÓSFAL, 2016). No entanto, apesar desses *hubs* serem altamente interconectados, o caminho médio entre quaisquer dois nós na rede é relativamente curto, sendo o caminho médio em uma rede complexa uma medida que diz, em média, quantos passos ou saltos são necessários para ir de um ponto a outro na rede, o que significa que a rede é altamente interconectada e as informações podem passar rapidamente por ela.

Esse recurso é importante porque permite que as informações se espalhem rapidamente pela rede, o que é especialmente verdadeiro para redes sociais como o Twitter, em que notícias falsas e informações enganosas podem se espalhar rapidamente.

Ao entender como a Web funciona e como as informações sobre ela se espalham, é possível desenvolver estratégias para limitar a disseminação de informações falsas e incentivar a disseminação de informações precisas e úteis. Alguns usuários podem postar conteúdo ativamente, enquanto outros podem simplesmente consumir conteúdo.

Além disso, pode haver oscilações no número de seguidores, retuítes e curtidas recebidas por cada usuário, o que gera heterogeneidade na distribuição desses valores pela rede.

Por fim, uma rede do mundo pequeno é caracterizada por uma alta densidade de conexões locais e alguns caminhos mais longos conectando diferentes regiões da rede. Em outras palavras, é uma rede na qual os nós são agrupados em comunidades ou grupos bem definidos, mas ainda podem se conectar a outros nós remotos (BARABÁSI; PÓSFAL, 2016).

Em redes sociais como o Twitter, apesar de cada usuário só poder seguir um número limitado de outros usuários, a rede como um todo está conectada por meio de retuítes, menções e *hashtags*. Essa conectividade é um exemplo da propriedade de mundo pequeno das redes complexas, onde existe um caminho de conexão relativamente curto entre quaisquer dois nós da rede e enquanto cada usuário do Twitter só pode seguir um número limitado de outros usuários, a rede como um todo está conectada por meio de retuítes, menções e *hashtags*. Isso cria caminhos de conexão curtos entre dois usuários para que as informações possam se espalhar rapidamente pela rede.

Nesse sentido, a análise de conexão em redes complexas é crucial para entender a estrutura da rede, permitindo identificar padrões e propriedades da rede. Utilizando o algoritmo de Louvain é possível identificar comunidades. As comunidades como demonstra a Figura 3 são usadas para identificar grupos de pessoas que se conectam mais fortemente umas com as outras, ou seja, em redes sociais, por exemplo, são grupos de pessoas que estão mais conectadas entre si do que com o restante da rede (BARABÁSI; PÓSFAL, 2016). Esses grupos podem representar círculos sociais, grupos de amigos, colegas, grupos de interesse e outros tipos de comunidades. As comunidades são excelente métricas para ajudar identificação a disseminação de informações e opiniões dentro das redes sociais, em um determinado grupo é possível entender a dinâmica de influência e o seu poder dentro da rede.

Nas redes sociais, também encontra-se a centralidade, que se refere ao nível de importância de um nó em relação aos outros nós da rede. A centralidade é uma medida importante na teoria de redes complexas porque permite entender a posição de um nó na rede e o papel que desempenha na transmissão e propagação de informações dentro da rede (BARABÁSI; PÓSFAL, 2016).

O grau de centralidade refere-se ao número de conexões que um nó tem com outros nós da rede (BARABÁSI; PÓSFAL, 2016). Os nós de maior centralidade são considerados mais importantes na rede, pois possuem mais conexões e, portanto, maior capacidade de




Figura 3 – Comunidades em redes complexas (BARABÁSI; PÓSFAL, 2016).

influenciar outros nós. A análise de centralidade dentro das redes sociais é útil para identificar os nós mais importantes e influentes em uma rede e para entender a estrutura e a dinâmica da rede (BARABÁSI; PÓSFAL, 2016). Identificar nós com alta centralidade pode ser útil, por exemplo, para entender a propagação de informações ou opiniões em uma rede, ou para identificar indivíduos com maior influência ou poder de liderança.

Nas redes sociais, o grau diz respeito ao número de conexões que um nó tem com outros nós da rede. Em outras palavras, é uma medida do número de amigos, seguidores, conexões ou interações que uma pessoa tem em uma rede social. Por exemplo, em uma rede social como o Twitter, o grau de um usuário pode ser medida pelo número de amigos na rede. Naturalmente, quanto maior for o grau de um usuário, maior seu potencial de influenciar a rede, pois ele tem mais conexões e pode compartilhar informações e opiniões com mais pessoas.

A densidade é uma medida da proporção de conexões existentes para o número máximo possível de conexões entre nós na rede (BARABÁSI; PÓSFAL, 2016). No contexto das redes sociais, a densidade mede o quanto uma rede está conectada, ou seja, quantas conexões existem entre os usuários em relação ao número total de conexões possíveis. A densidade de uma rede social é influenciada pelo número de usuários e pelo número médio de conexões por usuário. Em uma rede social pequena com um número pequeno de usuários e um grande número de conexões, a densidade será alta. Em uma rede social com grande número de usuários e pequeno número de conexões, a densidade será baixa.

A densidade pode ser útil na análise de mídia social para entender a estrutura e a dinâmica da rede, identificar as partes interessadas e avaliar a eficácia do marketing de mídia social e das estratégias de publicidade. Uma rede social de alta densidade pode ser mais propensa à disseminação de informações e opiniões, enquanto uma rede social de baixa densidade pode ser mais propensa ao isolamento e à fragmentação. Por exemplo, em uma rede social como o Twitter, a densidade pode ser medida pela proporção de usuários que se seguem em relação ao número total de conexões possíveis. Alta densidade de rede pode indicar mais interação e interação entre os usuários, enquanto baixa densidade pode indicar menos interação e isolamento.

O coeficiente de associatividade é uma medida da correlação entre os graus dos vizinhos de um nó em uma rede complexa (BARABÁSI; PÓSFAL, 2016). No contexto das redes sociais, o coeficiente de associatividade mede a propensão dos amigos de um usuário a ter o mesmo número de amigos. Por fim, o coeficiente de associatividade é um indicador importante na análise de redes sociais, pois ajuda a entender a estrutura da rede e a identificar grupos de interesse. Em uma rede social, um alto coeficiente de associatividade pode indicar a existência de grupos ou comunidades bem definidas, enquanto um baixo coeficiente de associatividade pode indicar uma estrutura mais aleatória ou menos organizada.

Por exemplo, em uma rede social, o fator de associatividade pode ser usado para entender como as pessoas se agrupam em torno de interesses comuns. Quando a pontuação de associação é alta para um grupo de usuários que compartilham um determinado interesse, isso pode indicar a existência de uma comunidade bem definida em torno desse interesse. Por outro lado, um baixo coeficiente de associatividade pode indicar que esses usuários estão dispersos na rede e não possuem uma estrutura de comunidade bem definida (BARABÁSI; PÓSFAL, 2016).

Portanto, este trabalho utiliza redes direcionadas e estáticas, especificamente do tipo egocêntrica, os detalhes sobre os processos de modelagem e análises serão apresentados posteriormente.

Trabalhos Relacionados

3.1 Experimentos comparando com algoritmos da literatura correlata

Neste capítulo, conduziremos um estudo sobre os resultados de experimentos encontrados na literatura utilizando aprendizado de máquinas para fazer a classificação de notícias utilizando a base de dados FakeNewsNet.

Além disso, os modelos de aprendizado de máquinas foram selecionados baseado em sua relevância e impacto dentro da área de estudo, experimentos que apresentam normalização de dados e utilização de vocábulos para classificação têm mostrado bons resultados para previsão de classes.

Nesse sentido, estudos propostos utilizando inteligência artificial com árvores de decisão e árvores de decisão aleatórias, sobre dois tipos de amostras sobre a base de dados *Fake News* (LIFFERTH, 2018) obtidos do Kaggle que é uma plataforma online de repositórios de dados, uma com dados não processados, que são dados em sua forma bruta, por exemplo, dados sem normalização textual, e outra sobre os dados processados, aplicando normalização textual, os quais têm apresentado resultados significantes (JEHAD; YOUSIF, 2020).

Utilizando um classificador com árvores de decisão e uma etapa sem pré-processamento, ou seja, sem normalização de dados obtiveram resultados de 78,13% e 89,11% de acurácia respectivamente com a etapa de pré-processamento de dados e a normalização.

Além disso, seus resultados mostram que o método utilizando as árvores de decisão foi superior ao algoritmo de árvore de decisão aleatória, que teve resultado de 73,07% sem o pré-processamento de dados contra os 84,97% de acurácia com processamento de dados.

A utilização de inteligência artificial com redes neurais profundas tem sido frequentemente utilizada em pesquisas no campo da análise de dados nos últimos anos. Por exemplo, utilizando redes neurais profundas e um modelo de LSTM (*Long Short-Term Memory*) que é um tipo de aprendizado de máquina especializada em redes neurais re-

correntes que ajuda as máquinas a entenderem sequências de dados longas, como as frases em linguagem natural, conseguem alcançar acurácia de 91,25% a partir de um pré-processamento de dados com informações textuais (KREŠŇÁKOVÁ; SARNOVSKÝ; BUTKA, 2019). Os modelos foram treinados e avaliados sobre um conjunto de dados conhecido como *Fake News* de (LIFFERTH, 2018) obtido nos repositórios de dados do Kaggle, concluindo que os modelos obtiveram um bom desempenho e consistência.

No trabalho de (SANTOS; PARDO, 2021) exploraram medidas de redes complexas combinadas com modelos de inteligência artificial. Utilizando a base de dados Fake.br-Corpus e o método K-Means que é um modelo de aprendizado utilizado para agrupar dados com base em suas semelhanças e a densidade como característica de redes complexas como entrada para o modelo foi possível obter uma acurácia de 69% onde o uso dessas características auxiliaram na identificação dos conteúdos falsos, superando as limitações de abordagens em base linguística, concluindo que notícias falsas e verdadeiras têm características estruturais distintas.

Em (CARVALHO et al., 2022), vídeos do YouTube são analisados do ponto de vista educacional e uma metodologia para classificá-los usando seus comentários. Para classificar os vídeos como educacionais ou não educacionais, foi verificada a frequência das palavras usadas em ambas as categorias, e as palavras mais frequentes foram utilizadas para a classificação. Foram criados oito conjuntos de dados, cada um com um número diferente de palavras mais frequentes. O número de palavras mais frequentes usadas para criar os conjuntos de dados foi de 10, 20, 40, 60, 80, 100, 200 e 8; este último foi selecionado por meio de técnicas de seleção de atributos. Cada vídeo em um conjunto de dados foi representado pelo seu *id*, pelas frequências com que as palavras apareceram nos seus comentários e pela sua classe (educacional ou não educacional). A classificação dos vídeos foi realizada pelos algoritmos RIPPER, J48 e Random Forest. Os classificadores recebem o conjunto de dados e preveem uma classe para vídeos educacionais por meio da frequência das palavras nos seus comentários. O estudo mostra acurácia máxima de 91,30% ao classificar um vídeo educacional e destaca as principais palavras usadas durante a sua classificação.

Utilizando metodologia de redes complexas baseada em propagação sobre a base de dados FakeNewsNet, (MEYERS; WEISS; SPANAKIS, 2020) apresentam em sua pesquisa que as notícias falsas se propagam mais rapidamente e profundamente do que as notícias reais. O trabalho inclui duas principais abordagens, árvores de decisão aleatória e aprendizagem geométrica profunda que se baseia na aprendizagem e classificação de dados utilizando algoritmos e modelos de aprendizado profundo para dados estruturados em formas geométricas, como grafos, alcançando uma acurácia de 73%.

Alguns recursos apresentados em sua pesquisas são interessantes e levaram em consideração a quantidade de seguidores e seguidos, *tweets*, *retweets*, favoritos, tempo médio entre um *tweet* e *retweet*, usuários que foram influenciados durante as próximas 10h dado

um post, entre outras características. Como conclusão, eles demonstram que a melhor combinação de recursos foi a utilização de 8 conjuntos de dados, média de seguidores e seguidos, média de favoritos, média de usuários tocados nas últimas 10h, último e primeiro tempo, número de *tweets*, número de *retweet* e porcentagem de *retweets*, onde utilizaram um classificador de árvores aleatórias para classificar notícias falsas e verdadeiras alcançando uma acurácia de 87%.

Porém, ainda é possível fazer classificações sem usar nenhuma informação textual, (??) utilizam uma técnica conhecida como redes neurais de grafos capaz de classificar notícias falsas somente usando recursos como: se o usuário é verificado, data de criação do usuário, codificado pelo número de meses desde a época em que o Twitter foi fundado, número de seguidores, número de amigos, número de favoritos, status, *timestamp* de data/hora do *tweet* e número de segundos desde que o primeiro *tweet* faz referência à publicação da notícia. A base utilizada por eles também foi a FakeNewsNet e conseguiram uma acurácia de mais de 80%, quando levam em consideração as características de redes complexas sua acurácia sobe para 94%. As características usadas em seu modelo são o grau de entrada, ou seja, o número de usuários que mencionaram usuário i , o grau de saída, ou seja, o número de usuários que foram mencionados pelo usuário i , o grau de entrada ponderado, ou seja, o número de vezes que o usuário i foi mencionado, o grau de saída ponderado, ou seja, o número de vezes que o usuário menciona outros, o número de vizinhos *hop-2*, o número de vizinhos externos *hop-2* e o número de *tweets* da linha do tempo coletados.

Utilizando um modelo de redes neurais em grafos para fazer previsões sobre a base de dados FakeNewsNet, (CHANDRA et al., 2020) conseguem um F1 Score de 94,69%. A pesquisa e análise leva em consideração rede convolucional em grafos e rede de atenção em grafos.

As medidas de centralidade e comunidades em redes temporais têm sido frequentemente usadas como entrada de classificadores para treinar algoritmos de inteligência artificial para prever as notícias falsas (PEREIRA, 2021). As redes temporais textuais, por exemplo, apresentaram ótimos resultados quando levam em consideração as estruturas de modelagem para propagação de rumores dentro da rede social (PEREIRA, 2021).

Duas bases de dados em questão foram estudadas, uma conhecida como “ataque a Charlie Hebdo” e outra chamada de “cerco de Sydney”. Basicamente, as redes temporais são estruturas que se moldam de acordo com o tempo, podendo adicionar ou remover vértices e arestas ao longo do tempo, sendo as redes temporais textuais uma modelagem importante para explorar padrões temporais dentro da rede social (LINHARES, 2016).

As características que foram levadas em consideração para a construção de seu algoritmo foram a disseminação, persistência e entropia dentro da rede, discutindo de forma inédita a classificação de notícias falsas de última hora dentro das redes sociais (PEREIRA, 2021).

Existem diferenças de comportamento na topologia da rede dentro das mídias sociais,

quando se trata de *tweets* de tipo rumor e não rumores (PEREIRA, 2021). Nesse sentido, as características de ciências de redes extraídas da rede são importantes recursos para serem analisadas em redes complexas, como: nós, links, hubs, comunidades, etc. Assim, um classificador baseado em medidas de rede complexas, leva em consideração durante a construção de seu algoritmo conceitos de ciência de redes, como os nós, links, comunidades, densidade, grau, etc. (SANTOS; PARDO, 2021). Os resultados mostram que para a detecção de rumores dentro da rede social as métricas apresentadas foram importantes atributos para explorar o impacto temporal dentro do contexto analisado (PEREIRA, 2021).

Concluindo que as características de redes complexas em notícias falsas são bastante diferentes das notícias verdadeiras e que trabalhos futuros levem em consideração os parâmetros aprendidos sobre as medidas de rede, verificando se os mesmos parâmetros também se encontram em outros idiomas (SANTOS; PARDO, 2021).

Em resumo, a Tabela 2 apresenta de forma resumida os trabalhos relacionados discutidos neste capítulo.

Tabela 2 – Resumo dos melhores resultados dos experimentos comparados com algoritmos da literatura correlata.

Referência	Base de Dados	Modelo de aprendizado	Resultados
(JEHAD; YOUSIF, 2020)	Kaggle - fake-news	Árvores de Decisão	Acurácia de 89,11%
(KREŠŇÁKOVÁ; SARNOVSKÝ; BUTKA, 2019).	Kaggle - fake-news	LSTM	Acurácia de 91,25%
(SANTOS; PARDO, 2021)	Fake.br-Corpus	K-Means	Acurácia de 69%
(CARVALHO et al., 2022)	Comentário de vídeos do YouTube	Random Forest	Acurácia de 91,30%
(MEYERS; WEISS; SPANAKIS, 2020)	FakeNewsNet	Árvores de Decisão Aleatória	Acurácia de 87%.
(HAN; KARUNASEKERA; LECKIE, 2020)	FakeNewsNet	Redes Neurais de Grafos	Acurácia de 94%
(CHANDRA et al., 2020)	FakeNewsNet	Rede Convolutacional em Grafos e Rede de Atenção em Grafos	F1 Score de 94,69%

Os estudos demonstram que diversas técnicas estão sendo empregadas e aprofundadas na literatura para a detecção e classificação de notícias falsas, as abordagens que estão utilizando redes neurais profundas se mostram mais promissoras e relevantes para classificações precisas. Contudo, apesar dos avanços alcançados, ainda existem desafios significativos a serem superados. A detecção de notícias falsas é uma tarefa complexa, especialmente considerando a rápida evolução das estratégias utilizadas pelos propagadores da desinformação.

Proposta

A metodologia empregada foi subdividida em diferentes fases, as quais serão descritas a seguir, abrangendo a pesquisa exploratória sobre a obtenção de dados FakeNewsNet, pesquisa bibliográfica sobre os trabalhos correlatos, pesquisa quantitativa extraindo características da base de dados FakeNewsNet, além da revisão da literatura sobre as técnicas já empregadas na literatura para classificação de notícias.

4.1 Obtenção de bases de dados

A base de dados FakeNewsNet foi a única base de dados encontrada até então na literatura, no contexto de *fake news*, contendo informações como conteúdo da notícia, relações sociais das entidades, localização, etc.

Para isto foram estudados conceitos de extração, mineração e carregamento de dados coletados a partir da base de dados FakeNewsNet, com uma série de parâmetros para extração, dentre eles, lista amigos e seguidores, localização, descrição do perfil, título da notícia, entre outros. A extração, transformação e carregamento de dados é uma importante metodologia utilizada na área de tecnologia da informação. A fase de extração inclui a coleta de dados em bancos de dados, APIs, dentre outros. A etapa de transformação consiste na aplicação de várias regras de limpeza e transformação desses dados para torná-los consistentes e adequados para análises. Por fim, a etapa de carregamento é a inserção dos dados processados em bancos de dados.

4.2 Metodologia

A metodologia utilizada para o desenvolvimento da pesquisa envolve a aplicação de princípios de ciência de dados, incluindo coleta de dados, pré-processamento dos dados, modelagem de redes complexas e aprendizado de máquina. Os detalhes dessas etapas são detalhados nas próximas seções.

4.2.1 Coleta de dados

Os dados foram coletados a partir de um repositório do GitHub conhecido como FakeNewsNet¹, onde é possível fazer o download via API dos dados formando uma base de dados que têm a estrutura de arquivos em formato .json e de pastas como demonstra a Figura 4.

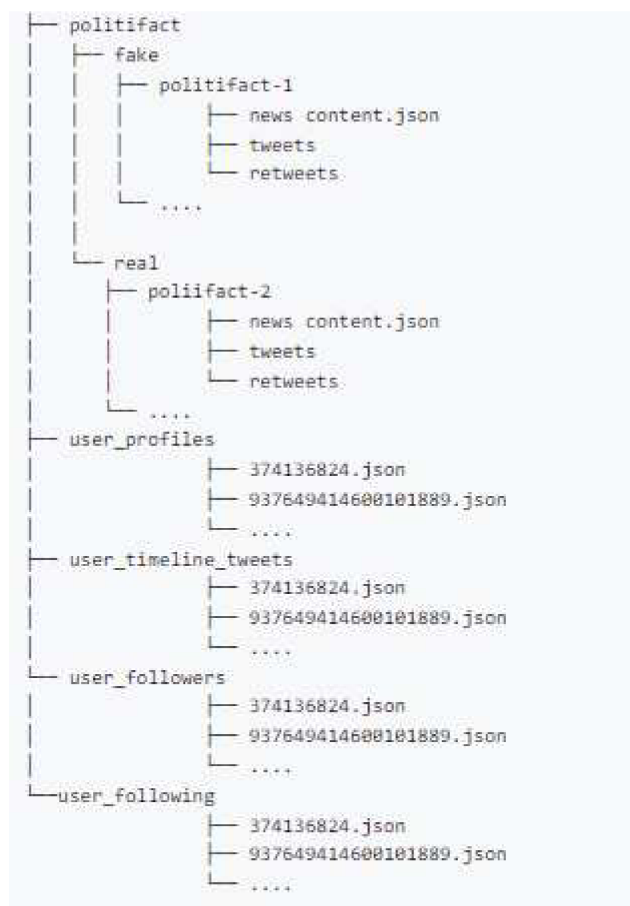


Figura 4 – Estrutura dos dados coletados da base FakeNewsNet.

O formato .json é uma estrutura baseada em texto para representar dados estruturados. No caso da base de dados FakeNewsNet, os arquivos .json possuem informações relevantes para o processamento de dados, como o título, conteúdo, descrição, perfil, localização, relacionamentos, dentre outros.

Cada pasta pode conter nenhum ou vários arquivos .json o qual corresponde a sua respectiva notícia sendo verdadeira ou falsa.

Em resumo a estrutura de pastas do FakeNewsNet foi pensada para facilitar a organização e a análise sobre os dados e pode ser acessada por qualquer pessoa gratuitamente. Por fim os dados e metadados disponíveis sobre cada um dos arquivos serão apresentados no fim da proposta.

¹ <<https://github.com/KaiDMML/FakeNewsNet>>

4.2.2 Pré-processamento dos dados

Foi realizada uma limpeza e pré-processamento dos dados utilizando a linguagem de programação Python para a modelagem de redes complexas e extração do conjunto de dados tabular.

A Figura 5 demonstra os dados tabulares utilizados para a entrada dos modelos de classificação e será discutido posteriormente.

tweets	retweets	textoTitulo-trump	textoNoticia-trump	textoPerfil-trump	rede-nos	rede-links	rede-centralidadeIn	rede-centralidadeOut	rede-centralidadeDegree	rede-assortativity_coefficient	rede-degree-max	rede-degree-media	rede-densidade	textoLocalizacao-usa	textoDescricao-news	textoTimeLine-rt	
326	439	37	0	0	7	89521	2507859	28.014511	28.014511	56.029021	-0.162939	10033	0.112074	0.000313	37	10	3222
458	239	32	0	0	7	129105	9347483	72.402737	72.402737	144.805475	-0.133228	13407	0.103846	0.000561	33	10	3467
465	15	3	0	0	0	8311	51209	6.162335	6.162335	12.324669	-0.183729	5824	0.700758	0.000741	1	1	994
163	15	0	0	0	0	0	0	0.000000	0.000000	0.000000	0.000000	0	0.000000	0.000000	0	0	334
167	1	0	0	0	0	0	0	0.000000	0.000000	0.000000	0.000000	0	0.000000	0.000000	0	0	22
...
715	10	1	0	0	0	10099	361024	35.752030	35.752030	71.504060	-0.149166	5520	0.546589	0.003540	0	0	410
767	42	7	0	0	1	31149	634284	20.363555	20.363555	40.727109	-0.130634	10000	0.321038	0.000654	4	5	1334
72	0	11	0	0	1	0	0	0.000000	0.000000	0.000000	0.000000	0	0.000000	0.000000	9	2	2722
235	0	35	0	0	12	759	5883	7.761214	7.761214	15.522427	-0.278885	799	1.052701	0.010226	52	2	3301

Figura 5 – Estrutura de dados tabular pré-processado.

O pré-processamento de dados é uma fase fundamental na análise de dados, que tem como objetivo preparar os dados iniciais para uma análise mais precisa e eficiente. Essa etapa é crucial, uma vez que os dados brutos coletados não estão prontos para análise, uma vez que geralmente contêm erros, inconsistências, valores ausentes e outros problemas que podem prejudicar a qualidade dos resultados obtidos (BATISTA, 2003). Portanto, é importante realizar essa etapa com cuidado, a fim de garantir que os dados utilizados na análise sejam confiáveis e relevantes para os métodos para a avaliação.

Após a coleta de todo o conjunto de dados do FakeNewsNet foi realizado uma limpeza de dados. Esta é uma etapa importante no pré-processamento de dados que identifica e corrige erros, removendo inconsistências sobre os dados. Essas inconsistências incluem dados sem as notícias, dados que não possuem tweets e dados que não contêm retweets.

Depois de fazer a limpeza dos dados foi realizada uma transformação de dados que é uma etapa que converte dados brutos em um formato mais analítico. Esta etapa inclui a normalização de dados, padronização e codificação categórica de dados preparando a informação para a inserção em algoritmos de inteligência artificial. Em seguida, foi realizada uma seleção de recursos, sendo o primeiro deles a extração de vocábulos. Os vocábulos são as palavras mais frequentes em todos os conjuntos de dados. Nesse sentido, cada categoria dos dados possui vocábulos diferentes.

Os primeiros a serem extraídos foram os vocábulos sobre os títulos de notícias. Como apresentado na Tabela 3, as palavras mais frequentes extraídas do conjunto de dados sobre os títulos foram *trump*, *obama*, *breaking*, *us*, *news*, *president*, *transcript*, *says*, *new* e *clinton*.

Já na Tabela 4 as top 10 palavras mais frequentes do conjunto de dados acerca do texto da notícia foram *people*, *going*, *think*, *president*, *would*, *said*, *know*, *us*, *thats* e *one*.

Tabela 3 – Top 10 palavras mais frequentes a partir da extração de dados de títulos das notícias.

Palavra	Frequência
trump	91
obama	73
breaking	54
us	50
news	49
president	49
transcript	41
says	34
new	34
clinton	29

Tabela 4 – Top 10 palavras mais frequentes sobre extração de dados de textos das notícias.

Palavra	Frequência
people	4.315
going	4.157
think	3.844
president	3.367
would	3.182
said	3.046
know	2.993
us	2.984
thats	2.972
one	2.783

A Tabela 5 apresenta as top 10 palavras mais frequentes do conjunto de dados acerca dos textos dos perfis, que foram *news*, *love*, *us*, *life*, *world*, *conservative*, *im*, *trump*, *politics* e *follow*.

Tabela 5 – Top 10 palavras mais frequentes sobre extração de dados de textos dos perfis.

Palavra	Frequência
news	13.482
love	6.402
us	4.746
life	4.586
world	4.402
conservative	4.396
im	3.960
trump	3.869
politics	3.702
follow	3.491

Sobre as palavras mais frequentes de localização a Tabela 6 apresenta uma amostra das

Tabela 6 – Top 10 palavras mais frequentes sobre extração de dados de texto das localizações.

Palavra	Frequência
usa	40.073
united	14.559
new	14.407
states	12.760
ca	11.441
york	9.268
washington	8.780
ny	8.297
dc	8.116
california	7.065

Tabela 7 – Top 10 palavras mais frequentes sobre extração de dados de texto das linhas do tempo.

Palavra	Frequência
rt	2.243.076
new	240.193
via	237.662
trump	235.458
us	201.058
people	191.489
one	187.306
amp	182.775
like	160.482
dont	139.364

top 10 palavras mais frequentes sobre extração de todo o conjunto de dados de localização, sendo elas *usa*, *united*, *new*, *states*, *ca*, *york*, *washington*, *ny*, *dc* e *california*.

Já a Tabela 7 apresenta a amostra de top 10 palavras mais frequentes sobre todo o conjunto de dados acerca do texto extraído da linha do tempo de cada perfil, contendo *rt*, *new*, *via*, *trump*, *us*, *people*, *one*, *amp*, *like* e *dont*.

Por fim, a Tabela 8 apresenta uma amostra de top 10 palavras mais frequentes sobre todo o conjunto de dados acerca do texto extraído da descrição de cada perfil, contendo *news*, *love*, *life*, *im*, *us*, *politics*, *world*, *retired*, *trump*, *proud*.

A parte de extração de vocábulos foi sintetizada de todo o conjunto de dados, onde para cada pasta de notícia é extraída a quantidade máxima de repetições de cada palavra.

Tabela 8 – Top 10 palavras mais frequentes sobre extração de dados de texto da descrição dos perfis.

Palavra	Frequência
news	25.848
love	19.997
life	12.890
im	12.457
us	11.451
politics	10.934
world	10.760
retired	10.469
trump	10.365
proud	10.148

4.2.3 Treinamento e validação do modelo

Nessa etapa foram utilizadas as bibliotecas `sklearn`², `tensorflow`³ e `keras`⁴ sendo responsáveis para construção, treinamento, previsão, normalização e validação dos modelos de inteligência artificial.

Durante a etapa de treinamento e validação, essas bibliotecas são usadas de forma integrada. O `scikit-learn` pode ser utilizado para pré-processar os dados, dividir o conjunto de dados em treinamento e teste, e fornecer métricas de avaliação, como acurácia e precisão. O `TensorFlow` e o `Keras` são usados para construir e treinar os modelos de inteligência artificial, ajustando os pesos das redes neurais com base nos dados de treinamento. Esses modelos treinados são então usados para fazer previsões em novos dados durante a fase de teste e validação.

4.2.4 Representação por meio de redes complexas

Por meio das redes complexas, a topologia de rede foi pensada nas redes egocêntricas, onde o ego tem o maior grau dentro da rede, sendo o responsável por exercer o domínio sobre as relações, já que a centralidade da rede é sobre o nó ego (DELGADO; SANTOS; CORTES, 2009).

Uma rede egocêntrica é uma sub-rede de uma rede maior centrada em um único nó chamado ego. Na análise de redes sociais, a rede egocêntrica é utilizada para estudar as conexões de um indivíduo com seus contatos imediatos, ou seja, seus amigos mais próximos e seus seguidores em uma rede social (ZHOU; ZAFARANI, 2019). Em suma, as notícias nas redes sociais podem ser representadas em alguns níveis de redes, o primeiro

² <<https://scikit-learn.org/>>

³ <<https://www.tensorflow.org/>>

⁴ <<https://keras.io/>>

deles é o nível ego, seguido pela tríade, comunidade e por fim nível geral de rede (ZHOU; ZAFARANI, 2019).

Nesse sentido, toda a topologia da rede foi pensada em uma rede egocêntrica, levando em consideração o círculo de amizade da entidade, como, seus amigos e os amigos dos amigos que possuem relacionamentos em comum, onde o ego é o nó central, assim todas as análises de redes complexas ocorrem a partir deste nó (DELGADO; SANTOS; CORTES, 2009). A rede foi construída utilizando uma estrutura de grafo e utilizando os sentidos nas arestas foi possível destacar quem é um seguidor e quem a entidade segue, como apresenta a Figura 6.

Basicamente os tweets se relacionam com sua notícia, conectando seus relacionamentos de amizades e extraindo características de texto e redes complexas. O tamanho dos nós também possui um significado importante, destacando em tamanho aqueles que possuem maiores relacionamentos, ou seja, quanto maior a quantidade de ligações, maior o nó ficará na visualização. Logo, o mesmo serve ao contrário, ou seja, quanto menor a quantidade de ligações a entidade tiver, menor será o tamanho do nó em sua visualização.




Figura 6 – Rede egocêntrica criada a partir dos dados colhidos da base de dados Fake-NewsNet.

Os nós em redes complexas são fundamentais para entender a estrutura e a dinâmica de uma rede e para analisar seus padrões e propriedades. A análise de nó permite identificar os nós mais importantes ou influentes em uma rede, entender as propriedades da rede em diferentes níveis e examinar os relacionamentos e interações entre as entidades representadas pelos nós (BARABÁSI; PÓSFAL, 2016).

Analisando a Figura 6 percebe-se a existência e variação de cores, estas variações refletem se uma entidade é ou não uma disseminadora de notícias falsas. A escala de cor varia de laranja para vermelho, sendo a cor laranja a entidade com menor quantidade de postagem e o vermelho, a entidade com a maior quantidade de compartilhamentos de notícias falsas. Assim quando não existem dados sobre uma entidade, a cor do nó é preenchida pela cor preta.

Nesse sentido, foi possível fazer a visualização e o estudo de uma rede sobre a disseminação de notícias falsas, em que as cores refletem a quantidade de disseminação de notícias falsas sobre a entidade, variando de laranja para o vermelho, onde laranja reflete o menor valor e o vermelho o maior valor de compartilhamentos.

Os nós que também são conhecidos como vértices, são pontos na rede que contêm objetos. Neste caso, os nós serão representados como pessoas e os links também conhecidos como arestas, são as conexões que conectam os nós na rede, em uma rede social por exemplo, representa amizades, relacionamentos profissionais, laços familiares e outros tipos de relacionamento, podendo conter diferentes propriedades, como: direção, peso e tipo (BARABÁSI; PÓSFAL, 2016). Sendo assim, as arestas pode ser direcionais ou não direcionadas, dependendo se a conexão entre as entidades são unidirecional ou bidirecional, ou seja, se apenas uma entidade segue, ou se as duas se seguem.

As características de redes complexas foram extraídas levando em consideração a rede egocêntrica de cada pasta de notícia que posteriormente se tornaram dados tabulares utilizando a biblioteca Pandas⁵ como demonstra a Figura 5.

Para a extração de características foi utilizada a linguagem de programação Python e a biblioteca de redes complexas NetworkX⁶. Com uma boa base de dados de vocábulos, a segunda etapa foi a extração de características de redes complexas. As características selecionadas para extração sobre a rede complexa foram: nós, links, comunidades, centralidade de entrada, centralidade de saída, grau de centralidade, grau máximo, média do grau, densidade e coeficiente de associatividade.

Levando em consideração a Figura 6 a soma da centralidade é 2,7959, coeficiente de assortatividade foi -0,4939, comunidades 6, densidade 0,0559, grau máximo de 55, quantidade de nós 50 e quantidade de links de 137. Características como centralidade, coeficiente de assortatividade, comunidades, densidade, grau, nós e links, foram extraídas sobre a rede e serão utilizadas como entrada em classificadores para ter uma melhor interpretabilidade sobre o problema. A modelagem de redes complexas seguiu uma linha de rede egocêntrica como demonstra a Figura 6, levando em consideração os relacionamentos de todas as entidades de uma notícia.

⁵ <<https://pandas.pydata.org/>>

⁶ <<https://networkx.org/>>

Dados dos arquivos .json

news content.json

```
url
text
images
top_img
keywords
authors
canonical_link
title
meta_data.viewport
meta_data.robots
meta_data.og.locale
meta_data.og.type
meta_data.og.title
meta_data.og.site_name
meta_data.og.updated_time
meta_data.article.published_time
meta_data.article.modified_time
meta_data.twitter.card
meta_data.twitter.title
meta_data.twitter.label1
meta_data.twitter.data1
meta_data.twitter.label2
meta_data.twitter.data2
meta_data.google-site-verification
movies
publish_date
source e summary.
```

tweets.json

```
created_at
id
id_str
text
truncated
entities.hashtags
entities.symbols
entities.user_mentions
entities.urls
source
in_reply_to_status_id
in_reply_to_status_id_str
in_reply_to_user_id
in_reply_to_user_id_str
in_reply_to_screen_name
user.id
user.id_str
user.name
user.screen_name
user.location
user.description
user.url
user.entities.description.urls
user.protected
user.followers_count
user.friends_count
user.listed_count
user.created_at
user.favourites_count
user.utc_offset
user.time_zone
user.geo_enabled
user.verified
user.statuses_count
user.lang
user.contributors_enabled
user.is_translator
user.is_translation_enabled
user.profile_background_color
user.profile_background_image_url
user.profile_background_image_https
user.profile_background_tile
user.profile_image_url
user.profile_image_url_https
user.profile_banner_url
user.profile_link_color
user.profile_sidebar_border_color
user.profile_sidebar_fill_color
user.profile_text_color
user.profile_use_background_image
user.has_extended_profile
user.default_profile
user.default_profile_image
user.following
```

retweets

```
created_at
id
id_str
text
truncated
entities.hashtags
entities.symbols
entities.user_mentions
entities.urls
source
in_reply_to_status_id
in_reply_to_status_id_str
in_reply_to_user_id
in_reply_to_user_id_str
in_reply_to_screen_name
user.id
user.id_str
user.name
user.screen_name
user.location
user.description
user.url
user.entities.description.urls
user.protected
user.followers_count
user.friends_count
user.listed_count
user.created_at
user.favourites_count
user.utc_offset
user.time_zone
user.geo_enabled
user.verified
user.statuses_count
user.lang
user.contributors_enabled
user.is_translator
user.is_translation_enabled
user.profile_background_color
user.profile_background_image_url
user.profile_background_image_https
user.profile_background_tile
user.profile_image_url
user.profile_image_url_https
user.profile_banner_url
user.profile_link_color
user.profile_sidebar_border_color
user.profile_sidebar_fill_color
user.profile_text_color
user.profile_use_background_image
user.has_extended_profile
user.default_profile
user.default_profile_image
user.following
user.follow_request_sent
user.notifications
user.translator_type
user.withheld_in_countries
geo
coordinates
place
contributors
retweeted_status.created_at
retweeted_status.id
retweeted_status.id_str
retweeted_status.text
retweeted_status.truncated
retweeted_status.entities.hashtags
retweeted_status.entities.symbols
retweeted_status.entities.user_mentions
retweeted_status.entities.urls
retweeted_status.source
retweeted_status.in_reply_to_status_id
retweeted_status.in_reply_to_status_id_str
retweeted_status.in_reply_to_user_id
retweeted_status.in_reply_to_user_id_str
retweeted_status.in_reply_to_screen_name
retweeted_status.user.id
retweeted_status.user.id_str
retweeted_status.user.name
retweeted_status.user.screen_name
retweeted_status.user.location
retweeted_status.user.description
retweeted_status.user.url
```

user_profiles

```
id
id_str
name
screen_name
location
profile_location
description
url
entities.description.urls
protected
followers_count
friends_count
listed_count
created_at
favourites_count
utc_offset
time_zone
geo_enabled
verified
statuses_count
lang
status.created_at
status.id
status.id_str
status.text
status.truncated
status.entities.hashtags
status.entities.symbols
status.entities.user_mentions
status.entities.urls
status.source
status.in_reply_to_status_id
status.in_reply_to_status_id_str
status.in_reply_to_user_id
status.in_reply_to_user_id_str
status.in_reply_to_screen_name
status.geo
status.coordinates
status.place
status.contributors
status.is_quote_status
status.retweet_count
status.favorite_count
status.favorited
status.retweeted
status.lang
contributors_enabled
is_translator
is_translation_enabled
profile_background_color
profile_background_image_url
profile_background_image_https
profile_background_tile
profile_image_url
profile_image_url_https
profile_link_color
profile_sidebar_border_color
profile_sidebar_fill_color
profile_text_color
profile_use_background_image
has_extended_profile
default_profile
default_profile_image
following
follow_request_sent
notifications
translator_type e withheld_in_countries.
```

user_timeline_tweets

```
created_at
id
id_str
text
truncated
entities.hashtags
entities.symbols
entities.user_mentions
entities.urls
source
in_reply_to_status_id
in_reply_to_status_id_str
in_reply_to_user_id
in_reply_to_user_id_str
```

```

user.follow_request_sent
user.notifications
user.translator_type
user.withheld_in_countries
geo
coordinates
place
contributors
is_quote_status
retweet_count
favorite_count
favorited
retweeted
possibly_sensitive e lang.

```

```

retweeted_status.user.entities.description.urls
retweeted_status.user.protected
retweeted_status.user.followers_count
retweeted_status.user.friends_count
retweeted_status.user.listed_count
retweeted_status.user.created_at
retweeted_status.user.favourites_count
retweeted_status.user.utc_offset
retweeted_status.user.time_zone
retweeted_status.user.geo_enabled
retweeted_status.user.verified
retweeted_status.user.statuses_count
retweeted_status.user.lang
retweeted_status.user.contributors_enabled
retweeted_status.user.is_translator
retweeted_status.user.is_translation_enabled
retweeted_status.user.profile_background_color
retweeted_status.user.profile_background_image_url
retweeted_status.user.profile_background_image_url_https
retweeted_status.user.profile_background_tile
retweeted_status.user.profile_image_url
retweeted_status.user.profile_image_url_https
retweeted_status.user.profile_banner_url
retweeted_status.user.profile_link_color
retweeted_status.user.profile_sidebar_border_color
retweeted_status.user.profile_sidebar_fill_color
retweeted_status.user.profile_text_color
retweeted_status.user.profile_use_background_image
retweeted_status.user.has_extended_profile
retweeted_status.user.default_profile
retweeted_status.user.default_profile_image
retweeted_status.user.following
retweeted_status.user.follow_request_sent
retweeted_status.user.notifications
retweeted_status.user.translator_type
retweeted_status.user.withheld_in_countries
retweeted_status.geo
retweeted_status.coordinates
retweeted_status.place
retweeted_status.contributors
retweeted_status.is_quote_status
retweeted_status.retweet_count
retweeted_status.favorite_count
retweeted_status.favorited
retweeted_status.retweeted
retweeted_status.possibly_sensitive
retweeted_status.lang
is_quote_status
retweet_count
favorite_count
favorited
retweeted
possibly_sensitive e lang.

```

```

in_reply_to_screen_name
user.id
user.id_str
user.name
user.screen_name
user.location
user.description
user.url
user.entities.description.urls
user.protected
user.followers_count
user.friends_count
user.listed_count
user.created_at
user.favourites_count
user.utc_offset
user.time_zone
user.geo_enabled
user.verified
user.statuses_count
user.lang
user.contributors_enabled
user.is_translator
user.is_translation_enabled
user.profile_background_color
user.profile_background_image_url
user.profile_background_image_url_https
user.profile_background_tile
user.profile_image_url
user.profile_image_url_https
user.profile_banner_url
user.profile_link_color
user.profile_sidebar_border_color
user.profile_sidebar_fill_color
user.profile_text_color
user.profile_use_background_image
user.has_extended_profile
user.default_profile
user.default_profile_image
user.following
user.follow_request_sent
user.notifications
user.translator_type
user.withheld_in_countries
geo
coordinates
place
contributors
is_quote_status
retweet_count
favorite_count
favorited
retweeted e lang.

```

Experimentos e Análise dos Resultados

Quando se trata de detectar notícias falsas nas redes sociais, os modelos de classificação e aprendizado de máquina são muito importantes. A classificação é uma técnica de aprendizado de máquina que permite categorizar dados em classes com base em suas características. Neste capítulo são mostrados os experimentos e análise dos resultados obtidos durante a pesquisa utilizando modelos de classificação de árvores de decisão, árvores de decisão aleatórias e redes neurais profundas. Esses modelos foram avaliados utilizando diferentes características extraídas dos dados.

5.1 Experimentos

Nesta seção serão discutidos os experimentos sobre os dados extraídos da base de dados FakeNewsNet, seguido de uma análise e pré-processamento cuidadosa sobre os dados para identificar padrões e relacionamento entre os usuários utilizando de classificadores como árvores de decisão e redes neurais profundas para fazer a detecção de notícias falsas.

Em primeiro lugar foi extraído um vocábulo de top 10 palavras mais frequentes de todo o conjunto de dados que será apresentado em forma de dados tabulares em seguida.

É possível observar a distribuição dos dados colhidos de acordo com as categorias de verdadeiro e falso na Tabela 9, apresentando um resumo do conjunto dos dados processados sobre política do FakeNewsNet. Foram extraídos um total de 787 dados, com um balanceamento de 401 notícias verdadeiras e 386 notícias falsas.

Tabela 9 – Distribuição de notícias políticas no FakeNewsNet.

Notícias Verdadeiras	Notícias Falsas	Total de Amostras
401	386	787

Em todos os experimentos, o conjunto de dados foi dividido em amostras de treinamento e de teste de acordo com a divisão 70/30 amplamente adotada pela literatura, conforme sugerido no trabalho de (DONATTI, 2023), que apresenta um aumentando sobre as chances do algoritmo abranger todos os possíveis casos, já a seleção da quantidade

dos vocábulos foi baseada no trabalho de (CARVALHO et al., 2022) que demonstra uma boa avaliação sobre a quantidade de 10, 50, 100 e 200 vocábulos.

Tabela 10 – Divisão do conjunto de dados entre amostras de treino e teste para todos os algoritmos usados neste trabalho.

Amostras para treino (70%)	Amostras para teste (30%)
550	237

Conjunto de características avaliadas:

- ❑ **Vocábulos:** consiste nos top 10 vocábulos de cada parte da notícia: título, notícia (corpo), texto do perfil, localização, linha do tempo e texto da descrição do perfil. No total são utilizados 60 vocábulos. Nesse sentido a classificação da notícia utilizando vocábulos consiste em saber se existe uma frequência das palavras sobre as características da entrada.
- ❑ **Redes Complexas:** consiste da extração de medidas das redes, como quantidade de nós, quantidade de links, comunidades, centralidade de entrada, centralidade de saída, grau da centralidade, grau máximo, média do grau, densidade e coeficiente de associatividade.
- ❑ **Vocábulos e Redes Complexas:** união dos conjuntos de características de vocábulos e de redes complexas.

Entre os modelos de aprendizado de máquina para fazer a identificação de notícias falsas foram utilizados:

- ❑ Árvores de decisão.

A árvore de decisão foi construída utilizando os seguintes parâmetros: *criterion* como *entropy*, *splitter* como *best*, *max_depth* como *None*, *min_samples_split* como 2, *min_samples_leaf* como 1, *min_weight_fraction_leaf* como 2, *max_features* como *None*, *random_state* como *None*, *max_leaf_nodes* como *None*, *class_weight* como *None*, *min_impurity_decrease* como 0.0 e *ccp_alpha* como 0.0.

- ❑ Árvores de decisão aleatórias.

A árvore de decisão foi construída utilizando os seguintes parâmetros: *criterion* como *entropy*, *n_estimators* como 100, *max_depth* como *None*, *min_samples_split* como 2, *min_samples_leaf* como 1, *min_weight_fraction_leaf* como 0.0, *bootstrap* como *True*, *oob_score* como *False*, *n_jobs* como *None*, *random_state* como *None*, *max_features* como *sqrt*, *warm_start* como *False*, *class_weight* como *None*, *verbose* como 0, *max_samples* como *None*, *max_leaf_nodes* como *None*, *class_weight* como *None*, *min_impurity_decrease* como 0.0, e *ccp_alpha* como 0.0.

□ Redes neurais profundas.

O modelo de rede neural utilizado foi um aprendizado de máquina profundo sequencial utilizando função de ativação *ReLU* e *sigmoid*, otimizador *Adam*, *dropout* de vinte por cento e uma camada oculta com 121 neurônios, como apresenta a Figura 7.

```

model = Sequential()
model.add(Dense(120, activation='relu', input_shape=(len(list(features.columns)),)))
model.add(Dropout(0.2))
model.add(Dense(120, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(1, activation='sigmoid'))
model.compile(loss='binary_crossentropy',
optimizer='adam',
metrics=['accuracy'])
model.fit(x_train.tolist(), y_train.tolist(), epochs=100, verbose=None)

```

Figura 7 – Modelo de redes neurais profundas utilizado.

Esses três modelos foram aplicados em conjunto de dados com os três grupos de características descritos, resultando em um total de nove experimentos.

5.1.1 Árvores de decisão

Utilizando um classificador de árvores de decisão com características de vocábulos e redes complexas, iterando sobre uma repetição de 100 vezes, é possível obter resultados com *F1 Score* médio de 86%, melhor resultado de 88%, e pior avaliação de 84%, como apresenta a Tabela 11.

Tabela 11 – Avaliação com árvores de decisão utilizando o conjunto de características de vocábulos e redes complexas.

<i>F1 Score</i>		
Melhor	Pior	Média
88,13%	84,25%	86,05%

Nesse sentido, a Figura 8 apresenta a matriz de confusão do melhor modelo, que previu 105 notícias como verdadeira e 13 notícias foram previstas como falsas verdadeiras. Quando o modelo prevê notícias falsas, 104 notícias foram previstas corretamente como falsas e 15 formas previstas como falsas positivas.

Considerando a pior avaliação a Figura 9, apresenta a matriz de confusão da previsão do pior modelo, ao qual, previu 101 notícias reais como verdadeiras e 17 foram previstas como falsas verdadeiras. Quando o modelo prevê notícias falsas, o modelo previu 99 notícias falsas como falsas e 20 notícias falsas como verdadeiras.

Analisando a Figura 10, que apresenta a árvore de decisão gerada a partir da melhor avaliação, pode-se observar que quando o vocábulo da localização de Washington, D.C.




Figura 8 – Matriz de confusão do melhor modelo de árvore de decisão com o conjunto de características de vocábulos e redes complexas.




Figura 9 – Matriz de confusão do pior modelo de árvore de decisão com o conjunto de características de vocábulos e redes complexas.

possui uma frequência maior que 5,5 e as conexões de links forem maiores que 4.626.784 logo uma notícia já é tida falsa. Nota-se então que já nos dois primeiros passos da decisão foram usados características tanto dos vocábulos quanto da rede.

A Figura 11 mostra a árvore de decisão obtida para o pior caso. Comparando-se com a Figura 10, as marcações em vermelho indicam as principais alteração dos ramos próximos aos nós folhas da árvore de decisão, impactando no resultado final da avaliação.

O próximo experimento consistiu em treinar as Árvores de Decisão utilizando somente os vocábulos, ou seja, desconsiderando as redes complexas. Quando remove-se as redes complexas dos dados a avaliação cai significativamente, como demonstra a Tabela 12, comprovando que quando utiliza-se vocábulos e redes complexas em conjunto há um ganho aproximado de 9% a 10%.

A Figura 12, apresenta a matriz de confusão do melhor modelo utilizando somente os

Tabela 12 – *F1 Score* utilizando árvores de decisão treinada com os vocábulos.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes Complexas	88,13%	84,25%	86,05%
Vocábulos	78,97%	73,64%	76,35%
Diferença	9,16%	10,61%	9,70%

vocábulos, em que 96 notícias foram prevista corretamente como verdadeiras e 22 notícias como falsas verdadeiras. Quando o modelo prevê notícias falsas 92 foram previstas como notícias falsas e 27 como falsas positivas.

Por fim, o último experimento utilizando Árvores de Decisão considerou somente as características de redes complexas. A Tabela 13 mostra que ao remover os vocábulos e mantendo apenas métricas de redes sobre os dados, a avaliação cai cerca de 15% a 16%.

Tabela 13 – *F1 Score* utilizando árvores de decisão e redes complexas.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes Complexas	88,13%	84,25%	86,05%
Redes Complexas	72,57%	67,82%	70,57%
Diferença	15,56%	16,43%	15,48%

Durante a previsão do melhor modelo utilizando apenas redes complexas no conjunto de dados para a previsão, a Figura 13 apresenta a matriz de confusão, em que o modelo previu 86 notícias verdadeiras e 32 como falsas verdadeiras, prevendo 86 notícias como falsas e 33 notícias como falsas verdadeiras.

Tabela 14 – *F1 Score* utilizando árvores de decisão considerando os três conjuntos de características avaliadas.

Características	Melhor	Pior	Média
Vocábulos	78,97%	73,64%	76,70%
Redes Complexas	72,57%	67,82%	70,57%
Vocábulos e Redes Complexas	88,13%	84,25%	86,05%

Em suma, é importante destacar que uma extração de vocábulos junto das métricas de redes complexas contribuíram significativamente para uma melhor avaliação como demonstra a Tabela 14. O principal benefício das árvores de decisão é que elas são fáceis de interpretar e explicar, o que significa que é possível entender como as classificações foram feitas. No entanto, podem ter dificuldade em trabalhar com dados que possuem muitas características, ou seja, alta dimensionalidade, ou muitas classes diferentes.

5.1.2 Árvores de Decisão Aleatórias

As árvores aleatórias, também conhecidas como florestas aleatórias, são uma coleção de árvores de decisão independentes que trabalham juntas para criar uma classificação. Cada árvore na floresta aleatória é treinada com uma amostra aleatória de entradas e, em seguida, cada árvore produz sua própria classificação. A classificação final é então determinada pela combinação das classificações de todas as árvores (JÚNIOR, 2018).

A Tabela 15 demonstra a utilização do classificador de árvores de decisão aleatórias, utilizando as características vocábulos e redes complexas. Os experimentos foram executados 100 vezes, e foi possível obter uma avaliação média de *F1 Score* de 90%, com melhor resultado de 92%, e pior avaliação de 89%, conforme mostra a Tabela 15.

Tabela 15 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos e redes complexas.

<i>F1 Score</i>		
Melhor	Pior	Média
92,94%	89,34%	90,99%

A Figura 14 apresenta a matriz de confusão do melhor modelo ao qual previu corretamente 108 notícias verdadeiras e 10 notícias falsas verdadeiras. Quando utiliza o modelo para prever notícias falsas o modelo previu corretamente 112 notícias falsas de 7 notícias falsas verdadeiras.

Quando remove-se as redes complexas dos dados, ou seja, utilizando as características do vocábulo, a avaliação cai em média 5% como demonstra a Tabela 16. Portanto, a utilização de redes complexas sobre o conjunto é importante para ter melhores resultados, com aumentos de 5% a 6% nos resultados.

Tabela 16 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes complexas	92,94%	89,34%	90,99%
Vocábulos	87,64%	82,78%	85,75%
Diferença	5,30%	6,56%	5,24%

Para a previsão do melhor modelo somente com vocábulos o modelo previu corretamente 94 notícias verdadeiras e 24 notícias falsas verdadeiras. Utilizando o modelo para prever notícias falsas, foi previsto 101 notícias falsas corretamente e 18 notícias falsas verdadeiras, como demonstra matriz de confusão na Figura 15.

Nesse sentido, removendo os vocábulos e deixando apenas métricas de redes complexas sobre os dados, a avaliação cai cerca de 10% sobre avaliação média como demonstra a Tabela 17.

Tabela 17 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de redes complexas.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes Complexas	92,94%	89,34%	90,99%
Redes Complexas	82,78%	77,44%	80,31%
Diferença	10,16%	11,90%	10,68%

A matriz de confusão da Figura 16, apresenta a previsão do melhor modelo utilizando características da Rede Complexas, em que 94 notícias foram previstas como verdadeiras e 24 notícias foram previstas incorretamente como falsas positivas. Quando o modelo prevê notícias falsas, 101 notícias foram previstas corretamente como falsas e 18 notícias foram previstas como falsas positivas.

Por fim, é importante destacar que a seleção das métricas de vocábulos e redes complexas são importantes atributos para uma boa taxa no aprendizado, apresentando uma boa avaliação como apresenta Tabela 18.

Tabela 18 – Avaliação com árvores de decisão aleatórias utilizando o conjunto de características de vocábulos ou redes complexas.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos	87,64%	82,78%	85,75%
Redes Complexas	82,78%	77,44%	80,31%
Vocábulos e Redes Complexas	92,94%	89,34%	90,99%

5.1.3 Redes neurais profundas

Utilizando redes neurais profundas e *F1 Score* como método de avaliação de desempenho, a Tabela 19 demonstra que a melhor avaliação do modelo foi de 91% em uma execução de 100 vezes teve média de 89% e pior avaliação se 86% com um total de 10 vocábulos.

Tabela 19 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos e redes complexas.

<i>F1 Score</i>		
Melhor	Pior	Média
91,66%	86,06%	89,63%

A matriz de confusão da Figura 17 apresenta a previsão do melhor modelo, demonstrando que 107 notícias verdadeiras foram previstas corretamente como notícias verdadeiras e 11 foram previstas como verdadeiras falsas. Quando o modelo previu notícias falsas, o modelo classificou corretamente 110 notícias falsas e 9 falsas positivas.

Quando se remove as características de vocábulos sobre os dados e utilizando somente as medidas de redes complexas para classificar as notícias há uma redução de 6% na pior avaliação, como demonstra a Tabela 20.

Tabela 20 – Avaliação com redes neurais profundas utilizando o conjunto de características de redes complexas.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes Complexas	91,66%	86,06%	89,63%
Redes Complexas	88,88%	80,00%	86,24%
Diferença	2,78%	6,06%	3,39%

Nesse sentido, o melhor modelo sem utilizar vocábulos conseguiu prever corretamente 102 notícias verdadeiras e 16 notícias foram previstas como falsas verdadeiras. Quando o modelo previu notícias falsas, previu corretamente 108 notícias falsas e 11 notícias falsas positivas, como demonstra a matriz de confusão da Figura 18.

E quando se remove as características de redes complexas, deixando apenas os dados de vocábulos sobre os dados, há uma redução de quase 10% na melhor avaliação, como demonstra a Tabela 21.

Tabela 21 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Vocábulos e Redes Complexas	91,66%	86,06%	89,63%
Vocábulos	80,97%	75,86%	78,90%
Diferença	10,69%	10,20%	10,73%

A Figura 19 demonstra a matriz de confusão do melhor modelo sem utilizar redes complexas, apresentando que o modelo previu corretamente 90 notícias verdadeiras e 28 notícias falsas verdadeiras. Já quando o modelo prevê notícias falsas, 100 foram previstas como falsas verdadeiras e 19 notícias foram previstas como verdadeiras falsas.

É importante destacar que a seleção das métricas de redes complexas e vocábulos são um importante atributo para uma boa taxa no aprendizado, apresentando boa avaliação como a apresenta a Tabela 22.

Em todos os casos de uso, utilizando redes profundas ou árvores de decisão, os resultados foram superiores quando são consideradas para treinamento características de redes complexas junto de vocábulos em todo o conjunto de dados.

Tabela 22 – Avaliação com redes neurais profundas utilizando o conjunto de características de vocábulos ou redes complexas.

Características	<i>F1 Score</i>		
	Melhor	Pior	Média
Redes Complexas	88,88%	80,00%	86,24%
Vocábulos	80,97%	75,86%	78,90%
Vocábulos e Redes Complexas	91,66%	86,06%	89,63%

5.2 Avaliação dos Resultados

Levando em consideração as árvores de decisão e árvores de decisão aleatórias, a Tabela 23 demonstra a comparação de árvores de decisão aleatória sobre as árvores de decisão utilizando os vocábulos e redes complexas, e demonstra que os resultados das árvores aleatórias foram superiores, conseguindo um ganho de mais de 4% na melhor avaliação.

Tabela 23 – Comparação entre árvores de decisão e árvores de decisão aleatórias.

Modelo	<i>F1 Score</i>		
	Melhor	Pior	Média
Árvores de decisão aleatórias	92,94%	89,34%	90,99%
Árvores de decisão	88,13%	84,25%	86,05%
Diferença	4,81%	5,09%	4,94%

Comparando os resultados das árvores de decisão com as árvores de decisão aleatórias sobre os dados somente com vocábulos, sem a utilização de redes complexas, também houve um ganho de avaliação em 8% no melhor resultado utilizando o algoritmo de árvores de decisão aleatórias como demonstra a Tabela 24.

Tabela 24 – Comparação utilizando árvores de decisão e árvores de decisão aleatórias somente com características de vocábulos.

Modelo	<i>F1 Score</i>		
	Melhor	Pior	Média
Árvores de decisão aleatórias com vocábulos	87,60%	82,78%	85,75%
Árvores de decisão com vocábulos	78,97%	73,64%	76,35%
Diferença	8,63%	9,08%	9,40%

Sem considerar as características de vocábulos e utilizando apenas os dados de redes complexas sobre os dados há um ganho de 10% na avaliação no melhor modelo em comparação com as árvores de decisão simples, como demonstra a Tabela 25.

Em suma, todos resultados das árvores de decisão aleatórias foram superiores sobre o mesmo conjunto de dados e nas mesmas condições em comparação com as árvores de decisão. A principal vantagem das árvores aleatórias é que elas são mais eficientes do que as árvores de decisão ao lidar com dados com muitas características e classes

Tabela 25 – Comparação utilizando árvores de decisão e árvores de decisão aleatórias com redes complexas.

Modelo	<i>F1 Score</i>		
	Melhor	Pior	Média
Árvores de decisão aleatórias com redes complexas	82,78%	77,44%	80,31%
Árvores de decisão com redes complexas	72,57%	67,82%	70,57%
Diferença	10,21%	9,62%	9,74%

diferentes. Além disso, elas tendem a fornecer uma classificação mais precisa do que apenas uma árvore de decisão, especialmente quando combinados com outros métodos de pré-processamento de dados. Por outro lado, as árvores de decisão são mais apropriadas para problemas de baixa dimensão, em que a interpretabilidade é importante e o número de classes é limitado.

5.2.1 Variando a Quantidade de Vocábulos

Adicionalmente, foram realizados experimento com diferentes números de vocábulos. Utilizando as árvores de decisão com diferentes quantidades de vocábulos, em uma média de 100 execuções, selecionando a melhor avaliação dentre eles, a avaliação tende a cair significativamente, ou seja, com uma amostra de 70% para treino e 30% para teste, a avaliação caiu 1,63% quando se utiliza um vocabulário de 200 palavras, ao invés de 10, como demonstra a Tabela 26.

Tabela 26 – Comparação utilizando árvores de decisão aumentando a frequência de vocábulos.

Vocábulos			
10	50	100	200
88,13%	88,00%	85,25%	86,50%

Quando utiliza-se árvores de decisão aleatórias, também houve uma pior performance, ou seja, quanto maior a quantidade de vocábulos extraído do conjunto de dados utilizando as árvores de decisão aleatórias como algoritmo de classificação, em uma média de 100 execuções, selecionando a melhor avaliação dentre eles, a avaliação tende a cair, ou seja, com uma amostra de 70% para treino e 30% para teste, a avaliação caiu cerca de 0,14% quanto utiliza-se um vocábulo de 200 palavras ao em vez de 10 como demonstra a Tabela 27.

Tabela 27 – Comparação utilizando árvores de decisão aleatórias aumentando frequência de vocábulos.

Vocábulos			
10	50	100	200
92,94%	92,98%	92,68%	92,80%

Já utilizando redes neurais como algoritmo de classificação em uma média de 100 execuções, selecionando a melhor avaliação dentre eles, a avaliação aumentou cerca de 0,84% quando utiliza-se 200 vocábulos ao em vez de 10, ou seja, em uma amostra de 70% para treino e 30% para teste como demonstra a Tabela 28.

Tabela 28 – Comparação utilizando redes neurais profundas aumentando frequência de vocábulos.

Vocábulos			
10	50	100	200
91,66%	91,98%	92,43%	92,50%

Vale ressaltar que dependendo do algoritmo de inteligência artificial utilizado para fazer a classificação é mais vantajoso selecionar uma quantidade menor de vocábulos do que uma maior diversidade de vocábulos.

5.2.2 Variando o Conjunto de Treino e Teste

Quando se utiliza um tamanho menor de amostra, ou seja, para 50% dos dados sendo para treino e 50% para teste e 30% para treino e 70% para teste, utilizando o algoritmo árvores de decisão em uma média de execução de 100 vezes, a avaliação tende a 5,6% sobre a melhor avaliação do modelo utilizando uma menor quantidade de amostra para treino, sendo 30% para treino e 70% teste conforme a Tabela 29.

Tabela 29 – Comparação utilizando árvores de decisão com diferentes conjuntos de treino e teste.

Treino	Teste	Melhor	Pior	Média	Vocábulos
550 (70%)	237	88,13%	84,25%	86,05%	10
339 (50%)	339	86,81%	82,69%	84,87%	10
236 (30%)	551	82,53%	79,35%	80,65%	10

Utilizando o melhor modelo sobre a amostra de 30% para treino e 70% para teste. A matriz de confusão da Figura 20 apresenta que 218 notícias foram classificadas corretamente como notícias verdadeiras e 57 como falsas verdadeiras. Quando o modelo previu notícias falsas, 234 notícias foram previstas corretamente, enquanto 42 notícias foram previstas como falsas verdadeiras.

Pode-se observar na Tabela 30 que quando se utiliza uma menor quantidade de amostra para treino e teste, utilizando o classificador de árvores de decisão aleatória a avaliação também tende a cair, caindo cerca de 5,73% quando utiliza 30% para treino e 70% para previsão, ao em vez de 70% para treino e 30% para previsão.

A Figura 21 demonstra que quando se utiliza 30% da amostra dos dados para treino e 70% para teste sobre o melhor modelo uma execução de 100 vezes, que foi possível

Tabela 30 – Comparação utilizando árvores de decisão aleatória com diferentes conjuntos de treino e teste.

Treino	Teste	Melhor	Pior	Média	Vocábulo
550 (70%)	237	92,94%	89,34%	90,99%	10
339 (50%)	339	91,74%	88,73%	90,35%	10
236 (30%)	551	91,59%	88,88%	90,20%	10

prever 235 notícias verdadeiramente como verdadeiras, porém 40 notícias foram classificadas como falsas verdadeiras. Quando o modelo prevê notícias falsas, 267 notícias foram previstas corretamente, enquanto 9 notícias foram classificadas como falsas verdadeiras.

Utilizando de redes profundas para fazer a mesma análise, a Tabela 31 demonstra que a avaliação caiu cerca de 2,96% quando utiliza uma quantidade menor de amostra de dados para treino.

Tabela 31 – Comparação entre os modelos de redes neurais profundas com diferentes conjuntos de treinamento.

Treino	Teste	Melhor	Pior	Média	Vocábulo
550 (70%)	237	91,66%	86,06%	89,63%	10
339 (50%)	339	91,11%	87,61%	89,54%	10
236 (30%)	551	88,70%	84,44%	87,03%	10

A Figura 22 demonstra que quando se utiliza 30% da amostra dos dados para treino e 70% para teste sobre o melhor modelo uma execução de 100 vezes, que foi possível prever 221 notícias verdadeiramente como verdadeiras, porém 54 notícias foram classificadas como falsas verdadeiras. Quando o modelo prevê notícias falsas, 263 notícias foram previstas corretamente, enquanto 13 notícias foram classificadas como falsas verdadeiras.

Apesar da avaliação ter caído em todos os modelos de classificação, em nenhum dos modelos a classificação caiu significativamente, ou seja, o trabalho valida que as métricas de redes complexas e métricas de vocábulos são excelentes dados para se trabalhar com classificadores para classificar notícias falsas.

5.2.3 Avaliação qualitativa

A Figura 23 demonstra que 193 notícias verdadeiras foram veiculadas no site *web.archive.org*, tendo o YouTube em segundo lugar com 55 notícias. Porém isso não quer dizer que os sites de origem das notícias são referências para a classificação de notícias verdadeiras sobre os dados.

Pois, a Figura 24 também demonstra que 164 notícias falsas foram veiculadas no site *web.archive.org*, a diferença vem do segundo lugar, em que 15 notícias falsas foram públicas no site *yournewswire.com*.

A origem das notícias não foi usada como entrada para os classificadores, porém as Figuras 23 e 24 demonstram que uma grande concentração de notícias falsas verdadeiras no site *web.archive.org*.

Isso quer dizer que é preciso ter conscientização da sociedade para ajudar a reduzir a disseminação de notícias falsas e informações incorretas. A população deve ser incentivada a verificar a veracidade das informações antes de compartilhar, a fim de evitar a propagação de informações incorretas e prejudiciais, por isso, é importante que as pessoas busquem fontes confiáveis de informação e notícias, a fim de garantir que as informações compartilhadas sejam precisas e baseadas em fatos.

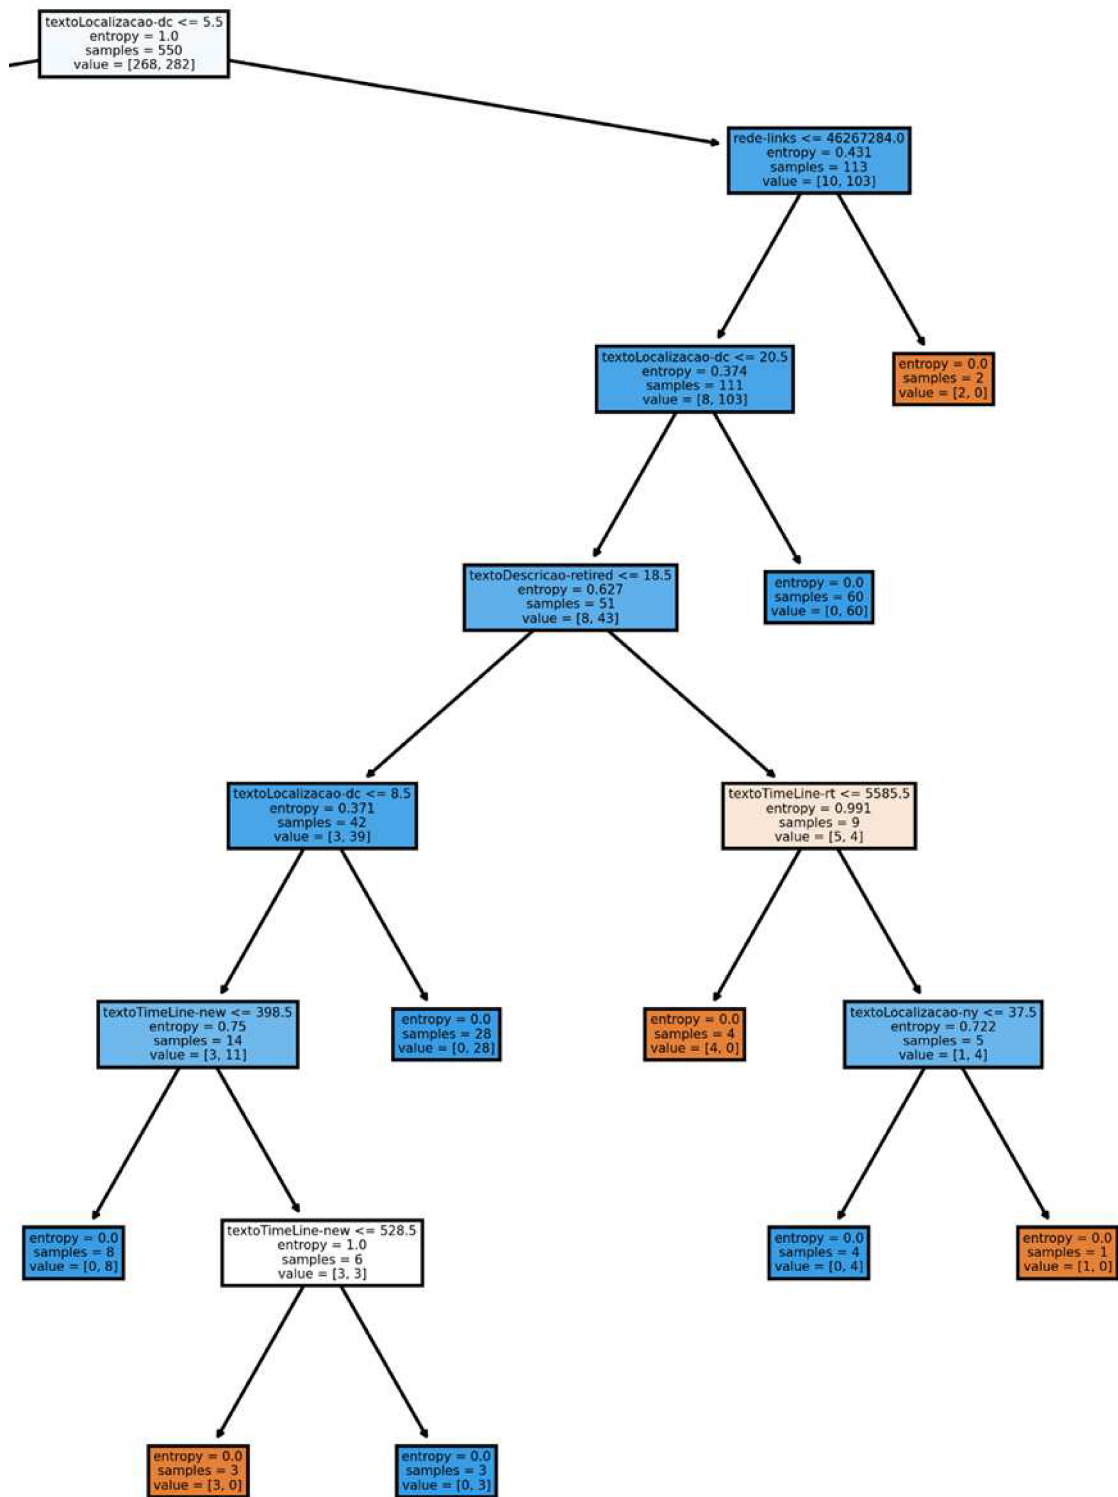


Figura 10 – Melhor árvore de decisão encontrada considerando os vocábulo no treinamento da árvore

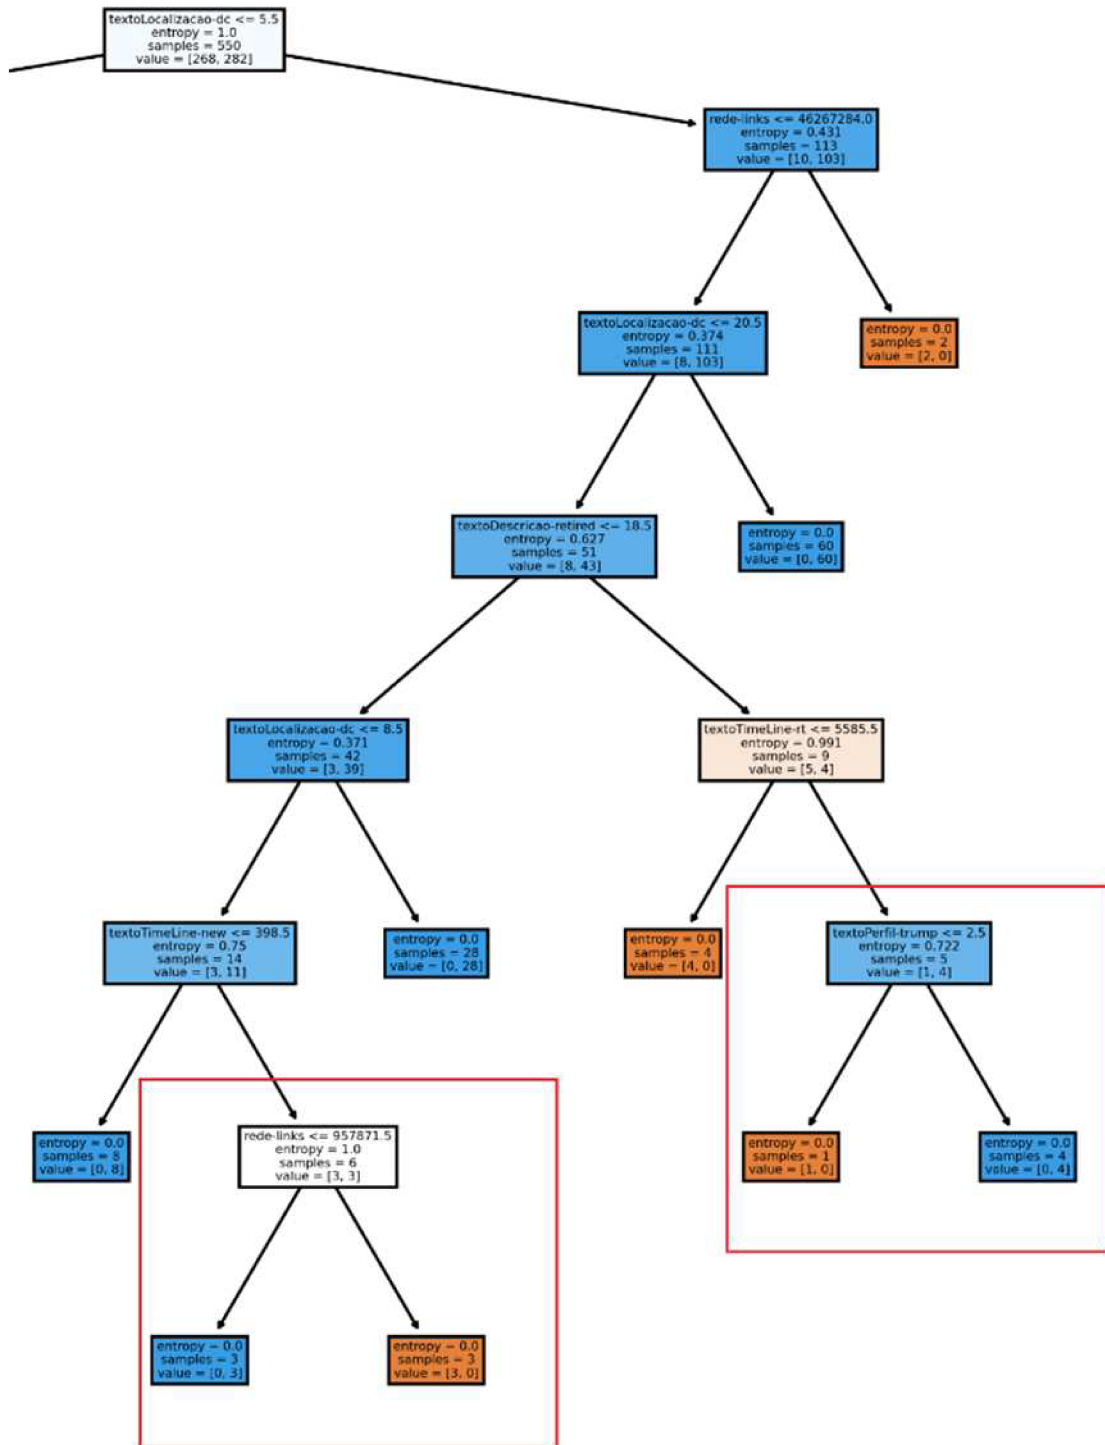


Figura 11 – Árvore de decisão do pior resultado utilizando as características de Vocabulo e redes complexas.




Figura 12 – Matriz de confusão do melhor modelo treinado utilizando somente vocábulos.




Figura 13 – Matriz de confusão do melhor modelo utilizando características de redes complexas.




Figura 14 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatórias utilizando o conjunto de características de vocábulos e redes complexas.




Figura 15 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatória com vocábulos.




Figura 16 – Matriz de confusão do melhor modelo previsto sobre as árvores de decisão aleatória com redes complexas.




Figura 17 – Matriz de confusão do melhor modelo previsto sobre as de redes neurais profundas utilizando o conjunto de características de vocábulos e redes complexas.




Figura 18 – Melhor matriz de decisão encontrada do modelo de redes neurais profundas treinadas com as características de redes complexas.




Figura 19 – Matriz de confusão do melhor modelo previsto sobre as redes neurais profundas treinadas com características de vocábulos.




Figura 20 – Melhor modelo de árvores de decisão utilizando 30% para treino.




Figura 21 – Melhor modelo de árvores de decisão aleatória utilizando 30% para treino.




Figura 22 – Matriz de confusão do melhor modelo sobre redes neurais profundas utilizando 30% para treino.




Figura 23 – Frequência da origem de notícias verdadeiras.




Figura 24 – Frequência da origem de notícias falsas.

Conclusão

Ao longo da elaboração desta dissertação, foram conduzidas pesquisas bibliográficas abrangentes, levantando análises de dados e modelagem de redes complexas sobre a base de dados FakeNewsNet.

Para atingir o objetivo proposto de fazer a classificação de notícias falsas por meio do uso de inteligência artificial e redes complexas, foi empregado três classificadores: árvores de decisão, árvores de decisão aleatórias e redes neurais profundas. A abordagem incluiu a modelagem de redes complexas, ou seja, a extração de características baseadas em ciência de redes e a utilização de vocábulos extraídos sobre o texto dos dados. Como resultado dessas estratégias, foi possível obter uma acurácia e precisão acima de 90%.

No que diz respeito a modelagem de dados utilizando redes complexas, foram utilizadas características extraídas da rede como, nós, links, comunidades, centralidade, assortatividade, densidade e o grau. Os experimentos demonstram que a utilização de redes complexas tiveram repercussões significativas na qualidade da classificação, e que a utilização dos vocábulos são tão importantes quanto as métricas de redes complexas para atingir um bom desempenho. Essas análises ajudaram a compreender que levantar características relevantes sobre o problema que são importantes para alcançar bons resultados.

Para investigar ainda mais sobre a origem das *fake news* foi extraído e apresentado um levantamento dos sites que mais divulgaram notícias falsas e verdadeiras. Essa estratégia apontou a importância de buscar outras fontes para verificar a veracidade das informações antes de compartilhar, evitando assim a propagação de notícias falsas dentro das mídias sociais.

Por fim, com base nas descobertas e no conhecimento adquirido durante a pesquisa, foi possível fazer a classificação das notícias falsas utilizando classificadores e características de ciências de redes. Em suma, estudos sobre as *fake news* permitiram uma compreensão aprofundada do impacto das *fake news* nas redes sociais e a conscientização da população em buscar outras fontes é de suma importância para a construção de um ambiente digital mais confiável e informativo.

6.1 Principais contribuições

Ao realizar os experimentos propostos, as contribuições desta pesquisa foram evidenciadas, validando a hipótese estabelecida. Por meio da aplicação dos classificadores de árvores de decisão, árvores de decisão aleatórias e redes neurais profundas, juntamente com a modelagem de redes complexas e a extração de características específicas, foi possível obter resultados promissores.

Os experimentos demonstraram que a combinação dessas abordagens resultou em uma taxa de acurácia e precisão de mais de 90%, o que é considerado um desempenho significativo na classificação de notícias falsas. Isso reforça a eficácia da utilização da inteligência artificial e das técnicas de redes complexas para combater o problema das *fake news*.

Além disso, vale ressaltar que a validação da hipótese foi obtida ao comparar os resultados dos experimentos com um conjunto de dados diversificado e representativo. A utilização de um amplo conjunto de vocábulos e a consideração das características de redes complexas proporcionaram um entendimento mais abrangente das notícias falsas, permitindo a identificação precisa e assertiva dessas informações enganosas.

Dessa forma, os experimentos realizados com os classificadores propostos e a modelagem de redes complexas forneceram evidências sólidas de que a hipótese formulada foi validada. As contribuições desta pesquisa contribuem para o avanço do campo de detecção de *fake news*, fornecendo abordagens eficazes para identificar e classificar essas informações enganosas de forma precisa e confiável.

6.2 Trabalhos futuros

Em trabalho futuros pretende-se desproblematizar e validar a utilização do modelo em outros cenários, possibilitando que o método seja aplicado em contextos de multi idiomas, ampliando o alcance da detecção de notícias falsas. Além disso é necessário a validação do modelo em outras base de dados com contextos diferentes, levando em consideração novas coleta de dados além de outros idiomas.

6.3 Contribuições em produção bibliográfica

O artigo *Detection of Fake News on Social Media Using Network Science Approach* foi submetido para o periódico *Social Network Analysis and Mining (SNAM)*. Nesse artigo foram reunidas as principais propostas e resultados descritos nesta dissertação.

Referências

- AIRES, V. P.; NAKAMURA, F. G. Detecção de comunidades em redes sociais: Relacionando o método louvain a medidas de centralidade. In: SBC. **Anais do XXXVI Concurso de Trabalhos de Iniciação Científica da SBC**. [S.l.], 2017.
- ALLCOTT, H.; GENTZKOW, M. Social media and fake news in the 2016 election. **Journal of Economic Perspectives**, v. 31, n. 2, p. 211–36, May 2017. Disponível em: <<https://www.aeaweb.org/articles?id=10.1257/jep.31.2.211>>.
- ALTAY, S.; HACQUIN, A.-S.; MERCIER, H. Why do so few people share fake news? it hurts their reputation. **New Media & Society**, v. 24, n. 6, p. 1303–1324, 2022. Disponível em: <<https://doi.org/10.1177/1461444820969893>>.
- BARABÁSI, A.; PÓSFAL, M. **Network Science**. Cambridge University Press, 2016. ISBN 9781107076266. Disponível em: <<http://networksciencebook.com/>>.
- BARBOSA, F. M. **Uso de redes neurais para o problema de previsão de pacientes de alto custo**. Tese (Dissertação de Mestrado) — Fundação Universidade Federal de Mato Grosso do Sul, Campo Grande, 2021.
- BARBOSA, S. Verdade, política e fake news: reflexão à luz da obra de Hannah Arendt. **Boletim Historiar**, v. 7, n. 02, 2020.
- BATISTA, G. E. A. P. A. **Pré-processamento de dados em aprendizado de máquina supervisionado**. Tese (Tese de Doutorado) — Instituto de Ciências Matemáticas e de Computação, São Carlos, 2003.
- BODNAR, T.; TUCKER, C.; HOPKINSON, K.; BILÉN, S. G. Increasing the veracity of event detection on social media networks through user trust modeling. In: **2014 IEEE International Conference on Big Data (Big Data)**. [S.l.: s.n.], 2014. p. 636–643.
- BRANDÃO, R. A.; SOUZA, R. S. DIVULGAÇÃO CIENTÍFICA NA LUTA CONTRA NOTÍCIAS FALSAS EM TEMPOS DE COVID-19. **Recite - Revista Carioca de Ciência Tecnologia e Educação**., Even3, v. 5, n. 2, 2020.
- CANTARELLI, E. M. P. **Acesso a base de dados através da linguagem natural**. Trabalho de conclusão de curso — Universidade Regional Integrada do Alto Uruguai e das Missões - Campus Frederico Westphalen Curso de Informática, 1998.

CARVALHO, H. C. F. B.; DORÇA, F. A.; PITANGUI, C. G.; ASSIS, L. P. d.; ANDRADE, A. V.; TRINDADE, E. A. C. Classificação automática de vídeos educacionais por meio de comentários apoiada por técnicas de aprendizado de máquina: uma análise experimental utilizando o youtube. **Revista Brasileira de Informática na Educação**, v. 30, p. 419–448, set. 2022. Disponível em: <<https://sol.sbc.org.br/journals/index.php/rbie/article/view/2455>>.

CAVALCANTE, L. S. **Amostragem e medidas de qualidade de shapelets**. Tese (Dissertação de Mestrado) — Instituto de Ciências Matemáticas e de Computação, São Carlos, 2016.

CHANDRA, S.; MISHRA, P.; YANNAKOUDAKIS, H.; NIMISHAKAVI, M.; SAEIDI, M.; SHUTOVA, E. **Graph-based Modeling of Online Communities for Fake News Detection**. [S.l.]: arXiv, 2020.

DELGADO, S. S.; SANTOS, S. R. S.; CORTES, M. R. Mapeamento da rede egocêntrica de uma empresa automobilística e seus fornecedores, através da análise de redes sociais: aspectos de cooperação, de confiança e de poder. In: **Anais do XXIX Encontro Nacional de Engenharia de Produção (Enegep)**. [S.l.: s.n.], 2009.

DOEBBER, D. M. **Uso de redes neurais profundas para o aprendizado de funções heurísticas para algoritmos de busca de caminhos**. Trabalho de conclusão de curso — Universidade Federal de Santa Maria, 2019.

DONATTI, L. M. **Aplicação de algoritmos de aprendizado de máquina para a demodulação de sinais de comunicação por luz visível**. Trabalho de conclusão de curso — Universidade Federal de Santa Maria, 2023.

DONCEL-MARTÍN, I.; CATALAN-MATAMOROS, D.; ELÍAS, C. Corporate social responsibility and public diplomacy as formulas to reduce hate speech on social media in the fake news era. **Corporate Communications: An International Journal**, v. 28, p. 340–352, Aug 2022.

FALCÃO, J. V. R.; MOREIRA, V. A.; SANTOS, F. A. O.; RAMOS, C. A. Redes neurais deep learning com tensorflow. **RE3C - Revista Eletrônica Científica de Ciência da Computação**, v. 14, n. 1, 2019.

GIOIA, S.; TORRES, C.; GALDINO, R.; BRIGAGÃO, L.; VALADARES, A.; SECOL, F.; MIGUEL, S. S.; KRUSH, L.; GOSS, P.; VARGAS, A. P. Predição de atendimento à “lei dos 60 dias” dentro do programa de navegação de pacientes com câncer de mama no rio de janeiro. **ALASS**, 2021.

JEHAD, R.; YOUSIF, S. A. Fake news classification using random forest and decision tree (j48). **Al-Nahrain Journal of Science**, v. 23, n. 4, p. 49–55, 2020.

JÚNIOR, J. H. d. S.; RAASCH, M.; SOARES, J. C.; RIBEIRO, L. V. H. A. d. S. Da desinformação ao caos: uma análise das fake news frente à pandemia do coronavírus (covid-19) no brasil. **Cadernos de Prospecção**, v. 13, n. 2, p. 331, abr. 2020. Disponível em: <<https://periodicos.ufba.br/index.php/nit/article/view/35978>>.

JÚNIOR, W. J. A. **MÉTODOS DE OTIMIZAÇÃO HIPERPARAMÉTRICA: UM ESTUDO COMPARATIVO UTILIZANDO ÁRVORES DE DECISÃO E FLORESTAS ALEATÓRIAS NA CLASSIFICAÇÃO BINÁRIA**. Tese

(Dissertação de Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte - MG, 2018.

KIRSTEN, H. A. **Comparação entre os modelos Holt Winters e redes neurais para previsão de séries temporais financeiras**. Tese (Dissertação de Mestrado) — Pontifícia Universidade Católica do Paraná, Curitiba, 2009.

KREŠŇÁKOVÁ, V. M.; SARNOVSKÝ, M.; BUTKA, P. Deep learning methods for fake news detection. In: **2019 IEEE 19th International Symposium on Computational Intelligence and Informatics and 7th IEEE International Conference on Recent Achievements in Mechatronics, Automation, Computer Sciences and Robotics (CINTI-MACRo)**. [S.l.: s.n.], 2019. p. 000143–000148.

LAZER, D. M. J.; BAUM, M. A.; BENKLER, Y.; BERINSKY, A. J.; GREENHILL, K. M.; MENCZER, F.; METZGER, M. J.; NYHAN, B.; PENNYCOOK, G.; ROTHSCHILD, D.; SCHUDSON, M.; SLOMAN, S. A.; SUNSTEIN, C. R.; THORSON, E. A.; WATTS, D. J.; ZITTRAIN, J. L. The science of fake news. **Science**, v. 359, n. 6380, p. 1094–1096, 2018. Disponível em: <<https://www.science.org/doi/abs/10.1126/science.aao2998>>.

LIFFERTH, W. **Fake News**. Kaggle, 2018. Disponível em: <<https://kaggle.com/competitions/fake-news>>.

LINDEN, S. van der; ROOZENBEEK, J.; COMPTON, J. Inoculating against fake news about covid-19. **Frontiers in Psychology**, v. 11, 2020. ISSN 1664-1078. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpsyg.2020.566790>>.

LINHARES, C. D. G. **Técnicas de Análise Visual de Redes Temporais**. Tese (Doutorado) — Universidade Federal de Uberlândia, 2016.

MAGALHÃES, L. H. de et al. **Agrupamento automático de notícias de jornais on-line usando técnicas de machine learning para clustering de textos no idioma português**. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2020.

MEYERS, M.; WEISS, G.; SPANAKIS, G. Fake news detection on twitter using propagation structures. In: DUIJN, M. van; PREUSS, M.; SPAISER, V.; TAKES, F.; VERBERNE, S. (Ed.). **Disinformation in Open Online Media**. Cham: Springer International Publishing, 2020. p. 138–158. ISBN 978-3-030-61841-4.

MONARD, M. C.; BARANAUSKAS, J. A. Indução de regras e árvores de decisão. **Sistemas Inteligentes-fundamentos e aplicações**, sn, v. 1, p. 115–139, 2003.

MOURÃO, R. R.; ROBERTSON, C. T. Fake news as discursive integration: An analysis of sites that publish false, misleading, hyperpartisan and sensational information. **Journalism Studies**, Routledge, v. 20, n. 14, p. 2077–2095, 2019. Disponível em: <<https://doi.org/10.1080/1461670X.2019.1566871>>.

NETO, J. M. O.; TONIN, S. D.; PRIETCH, S. S. Processamento de linguagem natural e suas aplicações computacionais. v. 12, 2010.

PEREIRA, F. Caracterização da propagação de rumores no twitter utilizando redes textuais temporais. In: **Anais do X Brazilian Workshop on Social Network Analysis and Mining**. Porto Alegre, RS, Brasil: SBC, 2021. p. 25–31. ISSN 2595-6094. Disponível em: <<https://sol.sbc.org.br/index.php/brasnam/article/view/16122>>.

- PONTES, L. S. et al. **A influência rumor no bem-estar dos colaboradores das organizações**. Dissertação (Mestrado) — INSTITUTO SUPERIOR DE LÍNGUAS E ADMINISTRAÇÃO DE LEIRIA, 2015. Disponível em: <<http://hdl.handle.net/10437/8869>>.
- PRIETO, A.; PRIETO, B.; ORTIGOSA, E. M.; ROS, E.; PELAYO, F.; ORTEGA, J.; ROJAS, I. Neural networks: An overview of early research, current frameworks and new challenges. **Neurocomputing**, v. 214, p. 242–268, 2016. ISSN 0925-2312. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231216305550>>.
- RAIS, D.; NETO, R. A. F.; CIDRÃO, T. V. Psicologia política e as fake news nas eleições presidenciais de 2018. **Revista do TRE-RS**, v. 24, n. 46, p. 19–51, 2019.
- RIZZO, I. V.; CANATO, R. L. C. Inteligência artificial: funções de ativação. **Revista Prospectus Gestão e Tecnologia**, v. 2, p. 51–65, 2020.
- SANTOS, I. P. P. **Análise de Sentimento Usando Redes Neurais de Convolução**. Tese (Dissertação de Mestrado) — Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2017.
- SANTOS, R. L. S.; PARDO, T. A. S. Structural characterization and graph-based detection of fake news in portuguese. In: SBC. **Anais do XIII Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana**. [S.l.], 2021. p. 199–208.
- SANTOS, V. V. A.; PEREIRA, C. P. Sistema educacional de orientação sobre fake news. In: SBC. **Anais do IV Workshop sobre as Implicações da Computação na Sociedade**. [S.l.], 2023. p. 50–61.
- SANTOS, W. A. L. **Descaminhos da informação em curso: desinformação e luta de classes no Brasil da pós-verdade**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2023.
- SHU, K.; SLIVA, A.; WANG, S.; TANG, J.; LIU, H. Fake news detection on social media: A data mining perspective. **SIGKDD Explor. Newsl.**, Association for Computing Machinery, New York, NY, USA, v. 19, n. 1, p. 22–36, sep 2017. ISSN 1931-0145. Disponível em: <<https://doi.org/10.1145/3137597.3137600>>.
- SILVA, S. S. **FAKE NEWS: REFLEXÕES SOBRE AS REPRESENTAÇÕES DIANTE DAS PSEUDO INFORMAÇÕES**. Dissertação (Trabalho de Conclusão de Curso) — FACULDADE VALE DO CRICARÉ MESTRADO PROFISSIONAL EM GESTÃO SOCIAL, EDUCAÇÃO E DESENVOLVIMENTO REGIONAL, 2019.
- SOUSA, G. **SPINS - um simulador neural para visualização de aspectos de aprendizado utilizando neurônios spiking**. Tese (Dissertação de Mestrado) — UNIVERSIDADE FEDERAL DE SANTA CATARINA, Florianópolis, 2005.
- WU, L.; MORSTATTER, F.; CARLEY, K. M.; LIU, H. Misinformation in social media: Definition, manipulation, and detection. Association for Computing Machinery (ACM), n. 2, p. 80–90, 2019.
- ZHOU, X.; ZAFARANI, R. Network-based fake news detection: A pattern-driven approach. **SIGKDD Explor. Newsl.**, Association for Computing Machinery, New York, NY, USA, v. 21, n. 2, p. 48–60, nov 2019. ISSN 1931-0145. Disponível em: <<https://doi.org/10.1145/3373464.3373473>>.