

Association for Information Systems

AIS Electronic Library (AISeL)

ISLA 2022 Proceedings

Latin America (ISLA)

8-8-2022

Uma análise da acurácia obtida e datasets utilizados em algoritmos de identificação de fake news

Humberto Fernandes Villela

Fábio Corrêa

Jurema Suely de Araújo Nery Ribeiro

Air Rabelo

Emerson Eustáquio Costa

Follow this and additional works at: <https://aisel.aisnet.org/isla2022>

This material is brought to you by the Latin America (ISLA) at AIS Electronic Library (AISeL). It has been accepted for inclusion in ISLA 2022 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.

Uma análise da acurácia obtida e *datasets* utilizados em algoritmos de identificação de *fake news*

Humberto Fernandes Villela

Doutorando, Universidade FUMEC
humberto.villela@gmail.com

Fábio Corrêa

Professor, Universidade FUMEC
fabiocontact@gmail.com

**Jurema Suely de Araújo Nery
Ribeiro**

Professora, Universidade FUMEC
jurema.nery@gmail.com

Air Rabelo

Professor, Universidade FUMEC
air@fumec.br

Emerson Eustáquio Costa
Professor, Universidade FUMEC
emerson@fumec.br

Abstract

Fake news can be understood as a version of an original piece of news with high dissemination capacity and the objective of deceiving, causing ambiguity or falsehood. It is mainly propagated through social media, its use being intentional and difficult to identify. In this context, researchers have been working on technological mechanisms to detect them. Thus, this research aims to analyze the accuracy obtained and the datasets used in fake news identification algorithms. This is an exploratory research with a qualitative approach, which makes use of a research strategy protocol to identify studies with the intention of analyzing them. As a result, we have the Stacking Method, Bidirectional Recurrent Neural Network (BiRNN) and Convolutional Neural Network (CNN) algorithms, with 99.94%, 99.82% and 99.80% accuracy, respectively. Kaggle, Weibo and FNC are the most frequently used datasets. It is suggested, for future research, to carry out research in addition to news about politics, the area that was the main motivator for the growth of research from 2017, and the use of hybrid methods for the process of identifying fake news.

Keywords

Algorithms, accuracy, *fake news detection*, artificial intelligence.

Resumo

As *fake news* podem ser compreendidas como uma versão de uma notícia original com capacidade de alta difusão e objetivo de enganar, causar ambiguidade ou falsidade. É principalmente propagada por meio de mídias sociais, sendo seu uso intencional e de difícil identificação. Neste contexto, pesquisadores tem atuado em mecanismos tecnológicos para detectá-las. Desse modo, esta pesquisa tem por objetivo analisar a acurácia obtida e os *datasets* utilizados em algoritmos de identificação de *fake news*. Trata-se de uma pesquisa exploratória de abordagem qualitativa, que faz uso de um protocolo de estratégia de pesquisa para

identificar estudos com o intento de analisá-los. Por resultado, têm-se os algoritmos *Stacking Method*, *Bidirectional Recurrent Neural Network (BiRNN)* e o *Convolutional Neural Network (CNN)*, com 99,94%, 99,82% e 99,80% de acurácia, respectivamente. O Kaggle, Weibo e FNC se apresentam como *datasets* mais recorrentemente utilizados. Sugere-se, por pesquisas futuras, a realização de pesquisas além de notícias sobre política, a área que foi a principal motivadora para o crescimento das pesquisas a partir de 2017, e o uso de métodos híbridos para o processo de identificação de *fake news*.

Palavras-chave

Algoritmos, acurácia, *fake news*, inteligência artificial.

Introdução

A constante necessidade de se informar em um mundo progressivamente conectado e ubíquo (onipresente) já faz parte da rotina das pessoas. A facilidade de se comunicar com a rede está cada vez mais simplificada e descentralizada. Pessoas e dispositivos conectados, por meio da *Internet of Things (IoT)*, se comunicam por meio da rede a todo momento, culminando em um elevado volume de dados.

Esse expressivo volume de dados trafegando na rede, muitas vezes referenciado como *Big Data*, composto por informações textuais e multimídia, tem produzido informações de valor. Sobre esta ótica Agarwal *et al.* (2020) advoga que os dados estão se tornando um ativo valioso e auferem maior relevância quando são transformados em informações e conhecimento.

Neste cenário, Ali *et al.* (2021) expressam a ideia de hiper-conectividade, sendo essa composta pela alta conexão de equipamentos e dados, bem como integração em tempo real de informações, velocidade de transmissão elevada, facilidade de comunicação e acesso às informações em nível mundial. É um caminho em constante evolução tecnológica e informacional, repleto de possibilidades e também de problemas, a exemplo das notícias falsas, denominadas *fake news*.

As *fake news* podem ser compreendidas como uma versão modificada de uma notícia original com a capacidade de alta difusão e objetivo de enganar, causar ambiguidade ou falsidade. Esse tipo de informação, que é principalmente propagada por meio de mídias sociais, é intencional e de difícil identificação. Desse modo, as *fake news* são um tipo específico de desinformação e, assim como o boato e o SPAM, possuem capacidade de gerar impactos políticos, econômicos e, ou, sociais (Zhang *et al.*, 2016; Islam *et al.*, 2020).

Ressalta-se que as *fake news* não são novas. Em 1835 o jornal norte americano New York Sun publicou uma série de notícias falsas sobre a suposta descoberta de vida na lua, sendo esse caso conhecido pela expressão *Great Moon Hoax* (Shabani & Sokhn, 2018). Contudo, no contexto da hiper-conectividade, as mídias sociais impulsionaram a propagação desse tipo de notícia.

As plataformas de mídias sociais possuem uma infinidade de desinformação, o que chamou a atenção de pesquisadores no desenvolvimento de mecanismos para detectá-las (Jiang *et al.*, 2021, 2020; Goldani, Momtazi & Safabakhsh, 2021; Birunda & Devi, 2021; Sahoo & Gupta, 2021; Goel *et al.*, 2021; Pardamean & Pardede, 2021). A Comissão Europeia estabeleceu um grupo de especialistas para aconselhar e para debater sobre iniciativas políticas a fim de combater as *fake news* e a disseminação da desinformação online (Assad & Erascu, 2018). No entanto, as abordagens de detecção consistem em classificar uma informação de forma binária (verdadeira ou falsa) (Zhang *et al.*, 2019), mas as sutilezas da linguagem humana imputam complexidade aos algoritmos para essa classificação.

Não obstante, Collins *et al.* (2021) subdivide as *fake news* em *clickbait*, propaganda, sátira e paródia, hoaxes e outros (roubo de nome, fraude jornalística, etc). Desse modo, as nuances da linguagem humana

tornam complexa a identificação dessas categorias de notícias falsas. A exemplo, a sátira e paródia tende ao sarcasmo e humor e a análise léxica algorítmica deve considerar essa nuance para denominar uma notícia como verdadeira ou falsa.

Neste ínterim, ratifica-se que as mídias sociais são o maior alvo das *fake news* e isso se dá pela sua facilidade e amplitude para a disseminação de informações. Outra questão que favorece a propagação de *fake news* é a sua capacidade de imitar as notícias tradicionais, confundindo as pessoas e dificultando o combate a informações falsas (Islam *et al.*, 2020). Desse modo, um boato pode ser verdadeiro ou falso e a ausência ou a demora de um posicionamento pelas entidades oficiais, envolvidas no boato, favorece sua disseminação (Abouzeid *et al.*, 2019).

Ruchansky, Seo e Liu (2017) afirmam que muitas pessoas lucram com a publicação de *fake news online*, pois quanto mais provocadora a notícia for, maior será a resposta e maior o lucro obtido por essa. Um boato, ante a determinado contexto, pode ser bastante rentável para alguém ou para alguma organização. Portanto, Asaad e Erascu (2018) assinalam que o uso do pensamento crítico é um importante aliado no combate à disseminação da desinformação.

Embora seja complexa a identificação de *fake news* por algoritmos, a exemplo da sátira e paródia, o volume de informações na rede é expressivo; portanto, se apresenta como inviável atribuir aos humanos a responsabilidade de classifica-las (Agarwal *et al.*, 2020). Ahmad *et al.* (2020) argumentam que há uma série de técnicas que podem ser usadas para classificar artigos como falsos com base no seu conteúdo textual. Muitas delas fazem uso de sites de verificação, como o PolitiFact¹ e o Snopes². Há ainda repositórios mantidos por pesquisadores, com listas de sites considerados falsos ou ambíguos. O pensamento crítico humano, nesses casos, é necessário para classificar a notícia como falso ou verdadeiro (Ahmad *et al.*, 2020).

Ahmed, Traore e Saad (2017) e Ahmad *et al.* (2020) recomendam o uso de algoritmos de Inteligência Artificial (IA), na extração de características linguísticas de artigos textuais, por meio de treinamento de *machine learning* (aprendizado de máquina). Agarwal *et al.* (2020) propuseram, como mais uma forma ao identificar notícias falsas, rotular ou classificar uma determinada notícia ou artigo em uma escala definida, dando assim ao leitor uma ideia sobre a credibilidade daquele texto publicado. Outra técnica de IA utilizada no processo de identificação de desinformação é a aprendizagem profunda (*deep learning*). Para Agarwal *et al.* (2020) a natureza da autoaprendizagem e os mapas de recursos deram ao *deep learning* uma vantagem expressiva em comparação com outros métodos estatísticos de modelagem e aprendizagem.

Aslam *et al.* (2021) entendem que os esforços devem ser empreendidos na construção de um sistema automatizado para classificar as notícias em reais ou falsas, objetivando uma maior acurácia – o quão próximo o valor computado imputa uma notícia como verdadeira ou falsa (Chapra & Canale, 2016) – na classificação, pois as pesquisas mostraram que somente 54% dos humanos conseguem detectar fraudes sem assistência especial. Jiang *et al.* (2021) concordam com Aslam *et al.* (2021) e acrescentam a essencialidade do uso da tecnologia, quando afirmam que o uso de ferramentas automatizadas para detectar notícias falsas, como máquinas ou modelos de aprendizagem e aprendizagem profunda, tornaram-se requisitos essenciais neste processo de identificação.

A acurácia para identificação de *fake news* por algoritmo é definida como o quão próximo o valor computado imputa uma notícia como verdadeira ou falsa (Chapra & Canale, 2016). Essa está diretamente relacionada ao idioma das notícias, sendo esse tratado em *dataset* (conjunto de dados) (Ahuja & Kumar, 2020). Desse modo, esta pesquisa se fundamenta nas recomendações de Ahmed, Traore e Saad (2017), Ahmad *et al.* (2020), Agarwal *et al.* (2020), Aslam *et al.* (2021) e Jiang *et al.* (2021) quanto ao uso de algoritmos para identificação de *fake news*. Porquanto, têm-se por objetivo desta investigação: analisar a acurácia obtida e os *datasets* utilizados em algoritmos de identificação de *fake news*.

Acredita-se que esta pesquisa contribui ao evidenciar algoritmos e *datasets* mais exitosos na identificação de *fake news*, de modo a apoiar pesquisadores na escolha dessas ferramentas, haja vista a variedade de opções supracitadas. Assim, a contribuição teórica se destaca por apresentar algoritmos e *datasets* com acurácia expressiva e por prover meio para sua identificação e aplicação prática para a identificação de *fake*

¹ <https://www.politifact.com/>

² <https://www.snopes.com/>

news. Ademais, por explorar a *fake news*, sendo esse um fenômeno com impactos políticos, econômicos e sociais e, portanto, busca-se fomentar a discussão acerca dessa temática e aliar a importância da computação e dos Sistemas de Informação nas tratativas relacionadas a esse fenômeno.

Procedimentos metodológicos

Esta pesquisa apresenta natureza exploratória e abordagem qualitativa, haja vista que busca compreender a acurácia obtida e os *datasets* utilizados em algoritmos de identificação de *fake news*, bem como identificar quais são esses *datasets* e algoritmos. Para isso, faz-se uso de um protocolo de estratégia de pesquisa (Quadro 1), fundamentado em Dresch, Lacerda e Antunes Júnior (2015), para identificar pesquisas realizadas nesta temática.

Item	Descrição
Questões de Pesquisa (QP)	QP1. Qual a acurácia dos principais algoritmos utilizados na identificação de <i>fake news</i> ? QP2. Quais <i>datasets</i> (conjunto de dados) utilizados para a identificação de <i>fake news</i> ? QP3. Quais as principais recomendações para estudos futuros?
Descritores (Strings Pesquisadas)	SP1. ("computational techniques") AND ("fake news") OR (disinformation) OR (misinformation) OR (malinformation)) SP2. ("técnicas computacionais") AND ("fake news") OR (desinformação OR "má informação") SP3. ("fake news detection") OR ("disinformation detection") OR ("misinformation detection") OR ("malinformation detection") SP4. ("detecção de fake news") OR ("detecção de desinformação") OR ("detecção de má informação")
Critérios de Exclusão (CE)	CE1. Artigos em idioma diferente do inglês ou português. CE2. Resumos, relatórios técnicos, estudos secundários, apresentação ou revisões sistemáticas. CE3. Artigos incompletos ou indisponíveis para <i>download</i> . CE4. Não aborda o uso de algoritmos para identificação de <i>fake news</i> . CE5. Não apresenta métodos ou acurácia na identificação de <i>fake news</i> . CE6. Algoritmos com acurácia inferior a 90%. CE7. Artigos duplicados.
Espaço temporal	Publicações entre 2010 e 2021
Campos de busca	Título, resumo e palavras-chave.
Idiomas	Português e inglês
Bases de dados	ACM Digital Library, IEEE Xplore, Scopus, Science Direct, Springer, Web of Science, EBSCO.

Quadro 1. Protocolo de estratégia de pesquisa

Assim, considera-se a busca em sete bases para análise de algoritmos no contexto de *fake news*. Esta escolha é pautada no critério de abrangência. A ACM Digital Library e IEEE Xplore são bases profícuas no tema, sendo adicionadas as demais bases e o idioma português para ampliação da busca.

Resultados

A aplicação da pesquisa, por meio das *strings* pesquisadas (SP1, SP2, SP3, SP4), foi realizada em 10/06/2021 e resultou em 507 artigos, distribuídos nas sete bases de dados. Dessa monta três foram desconsiderados pelo critério de exclusão CE1, 77 pelo CE2, 78 referentes ao CE3, 161 atinentes ao CE4, 47 relacionados ao CE5 e 23 pertinentes ao CE6, totalizando 389 artigos não condizentes aos intentos desta pesquisa. Do total remanescente de 118 artigos, 80 eram duplicados e foram desconsiderados, haja vista que a busca considerou sete bases. Assim, a monta de 38 pesquisas artigos perfazem a amostra desta pesquisa.

Os 38 artigos científicos foram lidos na íntegra, mediante ao intento de analisar as questões de pesquisa (QP1, QP2 e QP3 no Quadro 1). Em relação a QP1 (Qual a acurácia dos principais algoritmos utilizados na identificação de *fake news*?), o Quadro 2 apresenta os resultados obtidos por meio dos artigos analisados.

Autoria	Algoritmo	Acurácia
1) Jiang <i>et al.</i> (2021)	<i>Stacking Method</i>	99,94%
2) Jiang <i>et al.</i> (2020)	<i>Bidirectional Recurrent Neural Network (BiRNN)</i>	99,82%
3) Goldani, Momtazi e Safabakhsh (2021)	<i>Convolutional Neural Network (CNN)</i>	99,80%
4) Birunda e Devi (2021)	<i>Gradient Boosting</i>	99,50%
5) Sahoo e Gupta (2021)	<i>Long short-term memory (LSTM)</i>	99,40%
6) Goel <i>et al.</i> (2021)	<i>Robustly Optimized BERT Pretraining Approach (RoBERTa)</i>	99,30%
7) Pardamean e Pardede (2021)	<i>Bidirectional encoder representation of transformers (BERT)</i>	99,23%
8) Kaliyar <i>et al.</i> (2020a)	<i>Convolutional Neural Network (CNN)</i>	99,10%
9) Albahr e Albahr (2020)	<i>Naive Bayes</i>	99,00%
10) Gereme <i>et al.</i> (2021)	<i>Convolutional Neural Network (CNN)</i>	99,00%
11) Nasir, Khan e Varlamis (2021)	<i>Hybrid CNN-RNN</i>	99,00%
12) Kaliyar, Goswami e Narang (2021)	<i>Fake news detection in social media with a BERT-based (FakeBERT)</i>	98,90%
13) Dadkhah <i>et al.</i> (2021)	<i>AWD-LSTM</i>	98,79%
14) Goldani, Safabakhsh e Momtazi (2021)	<i>CNN com marginloss</i>	98,36%
15) Sridhar e Sanagavarapu (2021)	<i>BiLSTM-CapsNet</i>	97,96%
16) Umer <i>et al.</i> (2020)	<i>CNN-LSTM</i>	97,80%
17) Thakur <i>et al.</i> (2020)	<i>Gradient Boosting (GB)</i>	97,59%
18) Agarwal <i>et al.</i> (2020)	<i>CNN+RNN</i>	97,21%
19) Ayoub, Yang e Zhou (2021)	<i>DistilBERT</i>	97,20%
20) Yu <i>et al.</i> (2020)	<i>IARNet</i>	96,90%
21) Xie <i>et al.</i> (2021)	<i>Stance Extraction and Reasoning Network (SERNet)</i>	96,63%
22) Ozbay e Alatas (2019)	<i>Grey Wolf Optimization (GWO)</i>	96,50%
23) Fang <i>et al.</i> (2019)	<i>SMHA-CNN</i>	95,50%
24) Kaliyar <i>et al.</i> (2020b)	<i>DeepNet</i>	95,20%
25) Faustini e Covões (2020)	<i>Random Forest (RF)</i>	95,00%
26) Varshney e Vishwakarma (2020)	<i>Random Forest</i>	95,00%
27) Ahuja e Kumar (2020)	<i>S-HAN</i>	93,63%
28) Ivancov, Sarnovsk e Maslej-kre (2021)	<i>LSTM</i>	93,56%
29) Verma <i>et al.</i> (2021)	<i>WELFake</i>	92,60%
30) Wang <i>et al.</i> (2021)	<i>SemSeq4FD</i>	92,60%
31) Kumar, Anurag e Pratik (2021)	<i>EchoFakeD</i>	92,30%
32) Song <i>et al.</i> (2021)	<i>CARMN</i>	92,20%
33) Sharma, Garg e Shrivastava (2021)	<i>BiLSTM</i>	91,51%
34) Albahr (2021)	<i>SVM-RNN-GRUs bidirecionais</i>	91,20%
35) Torgheh <i>et al.</i> (2021)	<i>GRU-LSTM-CNN</i>	90,80%
36) Bahad, Saxena e Kamal (2020)	<i>BiLSTM-RNN</i>	91,08%
37) Lakshmanarao, Swathi e Kiran (2019)	<i>Random Forest</i>	90,70%

38) Li et al. (2020)	MCNN-TFV	90,10%
----------------------	----------	--------

Quadro 2. Acurácia dos principais algoritmos utilizados na identificação de fake news

No Quadro 2 foram listados algoritmos cuja acurácia foi igual ou superior a 90%. A acurácia é definida como o quão próximo o valor computado imputa uma notícia como verdadeira ou falsa (Chapra & Canale, 2016). O algoritmo *Convolutional Neural Network* (CNN) foi utilizado (Quadro 2) por seis artigos, sendo três como CNN (artigos 3, 8 e 10), um como modelo híbrido ou Hybrid CNN-RNN (artigo 11), um como CNN com *marginloss* (artigo 14) e o CNN-LSTM (artigo 16). A acurácia mais elevada foi atingida por Goldani, Momtazi e Safabakhsh (2021), com 99,80% (artigo 3), sendo o CNN um tipo de aprendizagem profunda (*deep learning*), para identificação de fake news. Mediante aos artigos analisados (Quadro 2), destaca-se a evolução da ciência no processo de identificação de fake news (Figura 1).




Figura 1. Evolução das implementações de algoritmo para detecção de fake news

A acurácia superior a 90% somente foi alcançada a partir de 2019, sendo que as 21 maiores acurácias datam entre 2020 e 2021. Goldani, Momtazi e Safabakhsh (2021), Kumar, Anurag e Pratik (2021) citam as eleições presidenciais norte-americanas de 2016 como o maior motivador para as pesquisas aplicadas à identificação de desinformação e, ou, fake news.

Em relação à QP2 (Quais datasets [conjunto de dados] utilizados para a identificação de fake news?), têm-se vários datasets utilizados para a aplicação das técnicas de identificação de fake news (Quadro 3).

Dataset	Ocorrências
ISOT (Kaggle)	6
Kaggle Fake News	6
LIAR (Kaggle)	5
Kaggle	4
Weibo	3
Fake News Challenges (FNC)	2
PolitiFact (Kaggle)	2
COVID-19 Fake News	1
Btvlfestyle	1
NewsFN	1
Fake News Amharic	1
Fakeddit	1
Facebook profiles	1
FakeNewsAMT	1
BuzzFeed (Kaggle)	1
Kaggle Indonesia data	1

Twitter	1
---------	---

Quadro 3. Datasets utilizados nos algoritmos de detecção de fake news

Os *datasets* estão diretamente relacionados ao idioma das notícias (Ahuja & Kumar, 2020), sendo aliados ao funcionamento dos algoritmos. Dentre os utilizados se destacam o Kaggle (uma plataforma da Google, utilizada por cientistas de dados) que contempla diversos *datasets* em sua plataforma para estudos de IA. O Kaggle foi o maior fornecedor de *datasets* (ISOT, Kaggle Fake News, LIAR, Kaggle, PolitiFact, BuzzFeed, Kaggle Indonesia data) dos artigos analisados (Quadro 2). Após os *datasets* da Kaggle, o mais utilizado foi o Weibo (um *microblog* chinês, similar ao Twitter), com 3 ocorrências; FNC, com 2 ocorrências; e os demais com apenas uma ocorrência.

No que tange a QP3 (Quais as principais recomendações para estudos futuros?), são apresentadas algumas perspectivas, como a utilização de outro idioma no *dataset*. A precisão da identificação de *fake news* para os autores não depende apenas do algoritmo, mas também do idioma do *dataset* utilizado. Portanto, Jiang *et al.* (2021) e Ahuja e Kumar (2020) recomendam a extensão de estudos por meio da aplicação da pesquisa em *datasets* de outros idiomas.

A classificação de *fake news* por meio de um modelo de pontuação, como um *score* para notícias falsas, é outra sugestão de pesquisa. O modelo de pontuação se justifica pela dificuldade em classificar uma informação somente como falso ou verdadeiro (Agarwal *et al.*, 2020), haja vista a complexidade inerente a linguagem humana e outros aspectos, como a área da notícia, a exemplo da economia e política.

A combinação de modelos, gerando modelos híbridos, é uma recomendação destacada por Jiang *et al.* (2020), Pardamean e Pardede (2021) e Kaliyar, Goswami e Narang (2021). Outra recomendação feita foi o uso de algoritmos baseados em *deep learning* em futuras pesquisas e compreender como essa técnica pode ajudar na identificação de *fake news* (Bahad, Saxena & Kamal, 2020).

Muitas pesquisas foram direcionadas para as informações textuais. Song *et al.* (2021), Varshney e Vishwakarma (2020) recomendaram pesquisas sobre a exploração de informações visuais em busca de *fake news*. Goel *et al.* (2021) destacam a importância em ampliar mais as pesquisas sobre *fake news* em outras áreas, haja vista que muitas se restringiram à identificação de *fake news* em *datasets* exclusivos sobre política.

Fang *et al.* (2019) recomendaram compreender como o classificador detecta profundamente a *fake news* e como modificar ou substituir algumas palavras-chave por sinônimos, de modo a evitar o método de detecção que se baseia na semântica de notícias falsas (falsos positivos, falsos negativos).

Para Albahar (2021), o desafio é grande e os pesquisadores precisam dedicar mais atenção para entender os padrões das estruturas de notícias e ao que é considerado como falso no universo digital. Para o pesquisador, as *fake news* digitais continuam a adquirir novos formatos, sendo difícil distinguir notícias falsas inseridas em uma grande notícia.

Conclusão

Esta pesquisa teve por objetivo analisar a acurácia obtida e os *datasets* utilizados em algoritmos de identificação de *fake news*. Para isso, foram investigadas três questões. Quanto a acurácia dos principais algoritmos (questão 1) utilizados na identificação de *fake news* (QP1), destacam-se o *Stacking Method* com 99,94% de acurácia, o *Bidirectional Recurrent Neural Network (BiRNN)*, com 99,82%, e o *Convolutional Neural Network (CNN)*, com 99,80%. O CNN foi utilizado em seis pesquisas, sendo o CNN um tipo de aprendizagem profunda (*deep learning*), para identificação de *fake news*. Há uma evolução da ciência no processo de identificação de *fake news*, haja vista que a acurácia superior a 90% foi alcançada a partir de 2019, sendo que as 21 maiores acurácias datam entre 2020 e 2021.

Em relação aos *datasets* (conjunto de dados) utilizados para a identificação de *fake news* (questão 2), o Kaggle apresenta maior predominância, possivelmente por contemplar diversos *datasets* em sua plataforma para estudos de IA. Após o Kaggle se apresenta o *dataset* Weibo (*microblog* chinês, similar ao Twitter) e FNC, considerando o número de ocorrências nos estudos analisados.

As principais recomendações para estudos futuros (questão 3) são: a utilização de outros idiomas nos *datasets*; a classificação de *fake news* por meio de um modelo de pontuação (*score*); modelos híbridos; o uso de algoritmos baseados em *deep learning*; a exploração de informações visuais em busca de *fake news*; ampliação das pesquisas em outras áreas; a substituição de palavras-chave por sinônimos; e o entendimento dos padrões das estruturas de notícias

Enfatiza-se que a acurácia de 90% é considerada um resultado relevante neste complexo processo de identificação de *fake news*. A maior parte das pesquisas utilizaram *datasets* em ambientes controlados (como Kaggle, por exemplo) ou sem informações atualizadas em tempo real (redes sociais), mas poucas pesquisas foram aplicadas em ambientes de redes sociais (local onde ocorre maior difusão de desinformação).

Isso demonstra que as técnicas computacionais estão avançando, contudo, considerando os artigos analisados nesta pesquisa, ainda há necessidade de mais pesquisas aplicadas a redes sociais. Assim, sugere-se por pesquisas futuras, a necessidade de estender as pesquisas além de notícias sobre política, a área que foi a principal motivadora para o crescimento das pesquisas a partir de 2017, e o uso de métodos híbridos para o processo de identificação de *fake news*.

Referências

- Abouzeid, A., Granmo, O.C., Webersik, C. & Goodwin, M. (2019). "Causality-based Social Media Analysis for Normal Users Credibility Assessment in a Political Crisis" in *Proceedings of 25th Conference of Open Innovations Association (FRUCT)*, Helsinki, Finland, pp. 1-14. <https://doi.org/10.23919/FRUCT48121.2019.8981500>
- Agarwal, A., Mittal, M., Pathak, A. & Goyal, L. M. (2020). Fake News Detection Using a Blend of Neural Networks: An Application of Deep Learning. *SN Computer Science*, 1(3),1-9.
- Ahmad, I., Yousaf, M., Yousaf, S., and Ahmad, M. O. (2020). Fake News Detection Using Machine Learning Ensemble Methods. *Hindawi*, 1-11. <https://doi.org/10.1155/2020/8885861>
- Ahmed, H., Traore, I. & Saad, S. (2017). "Detection of Online Fake News Using N-Gram Analysis and Machine Learning Techniques" in *Proceedings of International conference on intelligent, secure, and dependable systems in distributed and cloud environments*, Springer, Cham, pp. 127-138
- Ahuja, N. & Kumar, S. (2020). "S-HAN: Hierarchical Attention Networks with Stacked Gated Recurrent Unit for Fake News Detection" in *Proceedings 8th International Conference on Reliability, Infocom Technologies and Optimization*, Noida, India, pp. 873-877.
- Albahar, M. (2021). A hybrid model for fake news detection: Leveraging news content and user comments in fake news. *IET Information Security*, 15(2), 169-177.
- Albahr, A., & Albahar, M. (2020). An empirical comparison of fake news detection using different machine learning algorithms. *International Journal of Advanced Computer Science and Applications*, 11(9), 146-152.
- Ali, H., Khan, M. S., AlGhadhban, A., Alazmi, M., Alzamil, A., Al-Utaibi, K. & Qadir, J. (2021). All Your Fake Detector Are Belong to Us: Evaluating Adversarial Robustness of Fake-news Detectors Under Black-Box Settings. *IEEE Access*, 9, 81678-81692.
- Asaad, B. & Erascu, M. (2018). "A tool for fake news detection". In *Proceedings 2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*, Timisoara, Romania, pp. 379-386. <https://doi.org/10.1109/SYNASC.2018.00064>
- Aslam, N., Ullah Khan, I., Alotaibi, F. S., Aldaej, L. A. & Aldubaikil, A. K. (2021). Fake detect: A deep learning ensemble model for fake news detection. *Hindawi*, 1-8. <https://doi.org/10.1155/2021/5557784>
- Ayoub, J., Yang, X. J. & Zhou, F. (2021). Combat COVID-19 infodemic using explainable natural language processing models. *Information Processing & Management*, 58(4), 1-11. <https://doi.org/10.1016/j.ipm.2021.102569>
- Bahad, P., Saxena, P. & Kamal, R. (2020). Fake News Detection using Bi-directional LSTM-Recurrent Neural Network. *Procedia Computer Science*, 165,74-82.
- Birunda, S. S. & Devi, R. K. (2021). "A Novel Score-Based Multi-Source Fake News Detection using Gradient Boosting Algorithm" in *Proceedings of International Conference on Artificial Intelligence and Smart Systems (ICAIS)*, Coimbatore, India, pp. 406-414. <https://doi.org/10.1109/ICAIS50930.2021.9395896>

- Chapra, S.C., & Canale, R.P. (2016). *Métodos Numéricos para Engenharia-7ª Edição*. McGraw Hill Brasil.
- Collins, B., Hoang, D.T., Nguyen, N.T. & Hwang, D. (2021). Trends in combating fake news on social media – a survey. *Journal of Information and Telecommunication*, 5(2):247–266.
- Dadkhah, S., Shoeleh, F., Yadollahi, M.M., Zhang, X. & Ghorbani, A.A. (2021). A real-time hostile activities analyses and detection system. *Applied Soft Computing*, 104, 1–28. <https://doi.org/10.1016/j.asoc.2021.107175>
- Dresch, A., Lacerda, D.P. & Antunes Júnior, J. A. V. (2015). Design science research: método de pesquisa para avanço da ciência e tecnologia. Bookman Editora.
- Fang, Y., Gao, J., Huang, C., Peng, H. & Wu, R. (2019). Self multi-head attention-based convolutional neural networks for fake news detection. *PloS one*, 14(9), 1–13. <https://doi.org/10.1371/journal.pone.0222713>
- Faustini, P.H.A. & Covões, T.F. (2020). Fake news detection in multiple platforms and languages. *Expert Systems with Applications*, 158, 1–9. <https://doi.org/10.1016/j.eswa.2020.113503>
- Gereme, F., Zhu, W., Ayall, T. & Alemu, D. (2021). Combating fake news in “low-resource” languages: Amharic fake news detection accompanied by resource crafting. *Information*, 12(1), 1–9. <https://doi.org/10.3390/info12010020>
- Goel, P., Singhal, S., Aggarwal, S. & Jain, M. (2021). “Multi Domain Fake News Analysis using Transfer Learning” in *Proceedings 5th International Conference on Computing Methodologies and Communication (ICCMC)*, Erode, India, pp. 1230–1237. <https://doi.org/10.1109/ICCMC51019.2021.9418411>
- Goldani, M. H., Momtazi, S. & Safabakhsh, R. (2021). Detecting fake news with capsule neural networks. *Applied Soft Computing*, 101, 1–8. <https://doi.org/10.1016/j.asoc.2020.106991>
- Goldani, M. H., Safabakhsh, R. & Momtazi, S. (2021). Convolutional neural network with margin loss for fake news detection. *Information Processing & Management*, 58(1), 1–12. <https://doi.org/10.1016/j.ipm.2020.102418>
- Islam, M.R., Liu, S., Wang, X. & Xu, G. (2020). Deep learning for misinformation detection on online social networks: a survey and new perspectives. *Social Network Analysis and Mining*, 10(1), 1–20.
- Ivancová, K., Sarnovský, M. & Maslej-Krcšňáková, V. (2021). “Fake news detection in Slovak language using deep learning techniques” in *Proceedings of 19th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, Herl'any, Slovakia, pp. 255–260. <https://doi.org/10.1109/SAMI50585.2021.9378650>
- Jiang, T., Li, J. P., Haq, A. U. & Saboor, A. (2020). “Fake News Detection using Deep Recurrent Neural Networks” in *Proceedings of 17th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*, Chengdu, China, pp. 205–208. <https://doi.org/10.1109/ICCWAMTIP51612.2020.9317325>
- Jiang, T.A.O., Li, J.P., Haq, A.U., Saboor, A. & Ali, A. (2021). A novel stacking approach for accurate detection of fake news. *IEEE Access*, 9, 22626–22639. <https://doi.org/10.1109/ACCESS.2021.3056079>
- Kaliyar, R.K., Goswami, A. & Narang, P. (2021). FakeBERT: Fake news detection in social media with a BERT-based deep learning approach. *Multimedia tools and applications*, 80(8), 11765–11788.
- Kaliyar, R.K., Goswami, A., Narang, P., & Sinha, S. (2020a). FNDNet – A deep convolutional neural network for fake news detection. *Cognitive Systems Research*, 61:32–44.
- Kaliyar, R.K., Kumar, P., Kumar, M., Narkhede, M., Namboodiri, S. & Mishra, S. (2020b). “DeepNet: an efficient neural network for fake news detection using news-user engagements” in *Proceedings of 5th International Conference on Computing, Communication and Security (ICCCS)*, Patna, India, pp. 1–6). <https://doi.org/10.1109/ICCCS49678.2020.9277353>
- Kumar, R., Anurag, K. & Pratik, G. (2021). EchoFakeD: improving fake news detection in social media with an efficient deep neural network. *Neural Computing and Applications*, 33(14), 8597–8613.
- Lakshmanarao, A., Swathi, Y. & Kiran, T.S.R. (2019). An efficient fake news detection system using machine learning. *International Journal of Innovative Technology and Exploring Engineering*, 8(10), 3125–3129.
- Li, Q., Hu, Q., Lu, Y., Yang, Y. & Cheng, J. (2020). Multi-level word features based on CNN for fake news detection in cultural communication. *Personal and Ubiquitous Computing*, 24(2):259–272.
- Nasir, J.A., Khan, O.S. & Varlamis, I. (2021). Fake news detection: A hybrid CNN-RNN based deep learning approach. *International Journal of Information Management Data Insights*, 1(1), 1–13. <https://doi.org/10.1016/j.jjime.2020.100007>

- Ozbay, F.A. & Alatas, B. (2019). A novel approach for detection of fake news on social media using metaheuristic optimization algorithms. *Elektronika ir Elektrotechnika*, 25(4),62–67.
- Pardamean, A. & Pardede, H.F. (2021). Tuned bidirectional encoder representations from transformers for fake news detection. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(3), 1667-1671.
- Ruchansky, N., Seo, S. & Liu, Y. (2017). “CSI: A hybrid deep model for fake news detection” in *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, pp. 797-806.
- Sahoo, S. R. and Gupta, B. B. (2021). Multiple features based approach for automatic fake news detection on social networks using deep learning. *Applied Soft Computing*, 100, 1-16. <https://doi.org/10.1016/j.asoc.2020.106983>
- Shabani, S. & Sokhn, M. (2018). “Hybrid machine-crowd approach for fake news detection” in *Proceedings of 4th International Conference on Collaboration and Internet Computing (CIC)*, Philadelphia, PA, USA, pp. 299-306. <https://doi.org/10.1109/CIC.2018.00048>
- Sharma, D.K., Garg, S. & Shrivastava, P. (2021). “Evaluation of tools and extension for fake news detection” in *Proceedings of International Conference on Innovative Practices in Technology and Management (ICIPTM)*, Noida, India, pp. 227-232. <https://doi.org/10.1109/ICIPTM52218.2021.9388356>
- Song, C., Ning, N., Zhang, Y. & Wu, B. (2021). A multimodal fake news detection model based on crossmodal attention residual and multichannel convolutional neural networks. *Information Processing and Management*, 58(1),1-14.
- Sridhar, S. & Sanagavarapu, S. (2021). “Fake news detection and analysis using multitask learning with BiLSTM CapsNet model” in *11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, Noida, India, pp. 905-911. <https://doi.org/10.1109/Confluence51648.2021.9377080>
- Thakur, A., Shinde, S., Patil, T., Gaud, B. & Babanne, V. (2020). “MYTHYA: Fake News Detector, Real Time News Extractor and Classifier” in *Proceedings of 4th International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, pp. 982-987. <https://doi.org/10.1109/ICOEI48184.2020.9142971>
- Torghesh, F., Keyvanpour, M.R., Masoumi, B. & Shojaedini, S.V. (2021). “A Novel Method for Detecting Fake news: Deep Learning Based on Propagation Path Concept” in *Proceedings of 26th International Computer Conference, Computer Society of Iran (CSICC)*, Tehran, Iran, pp. 1-5. <https://doi.org/10.1109/CSICC52343.2021.9420601>
- Umer, M., Imtiaz, Z., Ullah, S., Mehmood, A., Choi, G.S. & On, B.W. (2020). Fake news stance detection using deep learning architecture (CNN-LSTM). *IEEE Access*, 8, 156695-156706.
- Varshney, D. & Vishwakarma, D.K. (2021). Hoax news-inspector: a real-time prediction of fake news using content resemblance over web search results for authenticating the credibility of news articles. *Journal of Ambient Intelligence and Humanized Computing*, 12(9), 8961-8974.
- Verma, P.K., Agrawal, P., Amorim, I. & Prodan, R. (2021). WELFake: Word Embedding Over Linguistic Features for Fake News Detection. *IEEE Transactions on Computational Social Systems*, 8(4),881-893.
- Wang, Y., Wang, L., Yang, Y. & Lian, T. (2021). SemSeq4FD: Integrating global semantic relationship and local sequential order to enhance text representation for fake news detection. *Expert Systems with Applications*, 166,1-12.
- Xie, J., Liu, S., Liu, R., Zhang, Y. & Zhu, Y. (2021). “SeRN: Stance extraction and reasoning network for fake news detection” in *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Toronto, ON, Canada, pp. 2520-2524. <https://doi.org/10.1109/ICASSP39728.2021.9414787>
- Yu, J., Huang, Q., Zhou, X. & Sha, Y. (2020). “Iarnet: An information aggregating and reasoning network over heterogeneous graph for fake news detection” in *Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, pp. 1-9. <https://doi.org/10.1109/IJCNN48605.2020.9207406>
- Zhang, H., Alim, M.A., Li, X., Thai, M.T. & Nguyen, H.T. (2016). Misinformation in online social networks: Detect them all with a limited budget. *ACM Transactions on Information Systems*, 34(3),1-24.
- Zhang, Q., Lipani, A., Liang, S. & Yilmaz, E. (2019). “Reply-aided detection of misinformation via bayesian deep learning” In *Proceedings of 19 the world wide web conference*, pp. 2333-2343. <https://doi.org/10.1145/3308558.3313718>