

**UNIVERSIDADE FEDERAL DO AMAZONAS
INSTITUTO DE CIÊNCIAS EXATAS E TECNOLOGIA
CURSO DE SISTEMAS DE INFORMAÇÃO**

JOSIMAR FARIAS DE OLIVEIRA

**TÉCNICAS DE RECONHECIMENTO E COMBATE A NOTÍCIAS
FALSAS NA INTERNET: UM MAPEAMENTO SISTEMÁTICO**

Itacoatiara – Amazonas

Junho – 2021

JOSIMAR FARIAS DE OLIVEIRA

**TÉCNICAS DE RECONHECIMENTO E COMBATE A NOTÍCIAS
FALSAS NA INTERNET: UM MAPEAMENTO SISTEMÁTICO**

Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Sistemas de Informação.

PROFESSOR DR. RAINER XAVIER DE AMORIM

Itacoatiara – Amazonas

Junho – 2021

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

O48t Oliveira, Josimar Farias de
Técnicas de reconhecimento e combate a notícias falsas na internet : um mapeamento sistemático / Josimar Farias de Oliveira . 2021
41 f.: il. color; 31 cm.

Orientador: Rainer Xavier de Amorim
TCC de Graduação (Sistemas de Informação) - Universidade Federal do Amazonas.

1. Notícias falsas na internet. 2. Mapeamento sistemático. 3. Ferramentas ou metodologias usadas. 4. Combate e reconhecimento. I. Amorim, Rainer Xavier de. II. Universidade Federal do Amazonas III. Título



Ministério da Educação
Universidade Federal do Amazonas
Coordenação do Curso de Sistema de Informação - ICET

FOLHA DE APROVAÇÃO

JOSIMAR FARIAS DE OLIVEIRA

TÉCNICAS DE RECONHECIMENTO E COMBATE A NOTÍCIAS FALSAS NA INTERNET: UM MAPEAMENTO SISTEMÁTICO

Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Sistemas de Informação.

Aprovada em 30 de Junho de 2021

BANCA EXAMINADORA

Prof. Dr. Rainer Xavier de Amorim, Presidente
Universidade Federal do Amazonas

Profa. Dra. Odette Mestrinho Passos, Membro
Universidade Federal do Amazonas

Prof. Me. Anderson Lincoln Vital da Silva, Membro
Universidade Federal do Amazonas

Folha de Aprovação assinada pela Profa. Odette Mestrinho Passos, responsável pela disciplina de Trabalho de Conclusão de Curso (Período: 2020.1), onde atesta a defesa do(a) aluno(a) e a presença dos membros da banca examinadora.



Documento assinado eletronicamente por **Odette Mestrinho Passos, Professor do Magistério Superior**, em 05/07/2021, às 21:01, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0596429** e o código CRC **52E187E9**.

Rua Nossa Senhora do Rosário - Bairro Tiradentes nº 3836 - Telefone:
(92) (92) 99318-2549 CEP 69103-128 Itacoatiara/AM -
ccsiicet@ufam.edu.br

Referência: Processo nº 23105.021536/2021-29

SEI nº 0596429

AGRADECIMENTOS

A caminhada foi longa, árdua e muito difícil em certos momentos, no entanto muitas foram as pessoas que me ajudaram a chegar até aqui e a carregar cada pedra nesse caminho.

Primeiramente agradeço a Deus pelo dom da vida e pela força concedida quando acreditei que não conseguiria mais continuar. Agradeço aos meus familiares e a família da minha esposa que não mediram esforços em me ajudar nos momentos em que mais precisei. A todos os professores e professoras que ao longo dessa jornada contribuíram com a minha formação acadêmica e sempre incentivaram os seus discentes a continuarem e não desistirem, de modo particular, agradecer ao meu orientador que acreditou no meu potencial e me incentivou neste trabalho. Aos meus amigos e colegas que conquistei, pois eles também foram fundamentais nessa conquista, muitos trabalhos em grupos ou duplas, cada um contribuía com o pouco que tinha seja conhecimento nos grupos de estudos ou trocados das bolsas nos cafés da manhã das aulas de sábado, não queríamos que ninguém ficasse para trás.

Por fim, agradeço de forma especial a minha esposa que sempre esteve ao meu lado em cada momento vivido e que ao final dessa etapa da graduação me presentou com um filho e este me encorajou e me inspirou a continuar nesse momento difícil no qual estamos atravessando, obrigado a todos.

TÉCNICAS DE RECONHECIMENTO E COMBATE A NOTÍCIAS FALSAS NA INTERNET: UM MAPEAMENTO SISTEMÁTICO

Josimar Farias de Oliveira, Rainer Xavier de Amorim

Instituto de Ciências Exatas e Tecnologia – Universidade Federal do Amazonas
(ICET/UFAM) – Itacoatiara – Amazonas – Brasil

josimarfarias2013@gmail.com, raineramorim@ufam.edu.br

Resumo. *Com a universalização do acesso à internet e a globalização de mídias sociais, as notícias falsas correm velozmente na internet, capaz de mudar o ecossistema de notícias. Com isso, o objetivo deste trabalho é investigar quais ferramentas, métodos ou estratégias disponíveis para reconhecimento e combate de notícias falsas na internet, bem como mostrar quais dessas ferramentas se mostraram mais eficientes. A metodologia de pesquisa adotada se fundamenta nos princípios da Engenharia de Software Experimental que se baseia na condução de um estudo secundário: o Mapeamento Sistemático. Os resultados obtidos mostraram que os modelos são baseados em aprendizagem de máquina e aprendizagem profundo, utilizando métodos de classificação de texto, sendo avaliados por métricas de validação diferentes com resultados excelentes.*

1. Introdução

De acordo com Shu et al. (2017), a demasiada difusão de notícias falsas pode ocasionar um sério impacto negativo nos cidadãos e na sociedade. Primeiro, notícias falsas podem desequilibrar a realidade do ecossistema de notícias. Por exemplo, notoriamente pode-se perceber que a notícia falsa mais falada foi ainda muito mais divulgada no Facebook do que a mais comumente notícias verdadeiras de grande relevância durante as eleições da presidência dos Estados Unidos da América (EUA) de 2016. Em segundo lugar, as notícias falsas convencem propositalmente as pessoas a aceitarem opiniões tendenciosas ou falsas.

Notícias falsas são normalmente manipuladas por publicitários para disseminar mensagens ou influências políticas. Por exemplo, alguns relatórios mostram que a Rússia criou robôs e contas falsas para espalhar histórias falsas. Terceiro, as notícias falsas transformam o jeito de como as pessoas entendem e respondem a notícias verdadeiras. Por exemplo, algumas notícias falsas são criadas somente para estimular a desconfiança das pessoas e fazê-las ficarem com dúvidas, desestimulando a capacidade de diferenciação do que é verdadeiro ou falso (SHU et al., 2017).

As mídias sociais mostraram-se como uma poderosa fonte de informações para grande parte da população mundial. Lamentavelmente, nem todas as informações que são publicadas são verdadeiras. Mediante datas significativas, como um período eleitoral ou um surto de saúde pública mundial, a informação falsa com intenção ardilosa, popularmente conhecida como “notícia falsa”, pode ocasionar mudança no comportamento social, na justiça pública e na cognição. Fazendo parte da luta contra o

COVID-19, a Organização Mundial da Saúde também abordou o combate à numerosa e veloz incidência de notícias falsas sobre o vírus causado por informações falsas e fatais no que diz respeito a infecções e curas (NGUYEN et al., 2020).

Muitos sites e mídias sociais vêm buscando soluções para detectar notícias falsas. Por exemplo, o Facebook estimula os usuários a reportarem publicações não confiáveis e utiliza verificadores de acontecimentos profissionais para mostrar notícias duvidosas. A verificação manual de acontecimentos também é usada por sites de verificação de fatos, como Snopes, FactCheck, PolitiFact e Full Fact. Para suportar o crescente aumento da quantidade de informações, os sistemas automatizados de verificação de notícias levam em consideração os bancos de dados externos de conhecimento como evidência (NGUYEN et al., 2020).

As notícias escritas são vistas com mais frequência e publicadas em formato de texto com conteúdo diversos, de tal modo as notícias são inumeráveis e cada vez mais difícil de serem acompanhadas manualmente e esforço exclusivamente humano. Com o avanço da Inteligência Artificial (IA) os processos de tomadas de decisão vêm tomando cada vez espaço e grau de importância na sociedade. Com o desenvolvimento dos métodos de aprendizado de máquina na era da IA, é possível explorar os tópicos dos grandes textos de notícias e, em seguida, analisá-los (GUANGCE e LEI, 2021).

Nesse contexto, a metodologia de pesquisa adotada neste trabalho para coletar as informações de forma a cumprir o objetivo, está fundamentada nos princípios da Engenharia de Software Experimental que se baseia na condução de um estudo secundário: Mapeamento Sistemático (MS). O MS fornece uma visão geral de uma área de pesquisa, identificando a quantidade, os tipos de pesquisas realizadas, os resultados disponíveis, além das frequências de publicações ao longo do tempo para identificar tendências (PETERSEN et al., 2008).

Kitchenham e Charters (2007), afirmam que estudos de MS em engenharia de software têm sido recomendados, sobretudo para áreas de pesquisa onde é difícil visualizar a gama de materiais, relevantes e de alta qualidade, que possam estar disponíveis. Assim sendo, a escolha do MS como proposta para a condução desta pesquisa, justifica-se pelo fato do objetivo de o estudo ser apenas identificar e utilizar os resultados obtidos para futuras pesquisas.

Dessa forma, o objetivo deste trabalho é: investigar a aplicabilidade e eficiência das ferramentas, métodos ou estratégias disponíveis atualmente para o reconhecimento e combate de notícias falsas ou fake news na Internet.

Como resultados obtidos nesta pesquisa foram encontrados na etapa inicial do MS 2.502 artigos relacionados com a *string* de busca, após o primeiro filtro 105 artigos foram classificados e por fim no segundo critério de seleção foram selecionados 23 artigos que foram lidos integralmente e extraídas as respostas das questões de pesquisas propostas.

São apresentadas as ferramentas, métodos automáticos disponíveis utilizando

recursos de aprendizagem de máquina e aprendizagem profunda, nas quais são usadas as metodologias como: classificação de texto, *link do Uniform Resource Locator (URL)*, visuais, gráficos, entre outros. Os tipos de testes foram realizados com base nos recursos do corpo do texto, redes sociais e outros, as avaliações métricas para testar a eficácia dos modelos foram baseadas principalmente em: F1- *Score*, Acurácia, Precisão e *Recall*, sendo que os modelos abordados para reconhecimentos de notícias falsas alcançaram êxito esperado pelos autores.

O restante do artigo está organizado da seguinte maneira: a Seção 2 apresenta alguns conceitos relacionados e discute os trabalhos relacionados. A Seção 3 apresenta a metodologia utilizada, enquanto a Seção 4 mostra os resultados e as discussões. A Seção 5 apresenta as conclusões e os trabalhos futuros.

2. Fundamentação Teórica

2.1. Conceitos Relacionados

Notícias Falsas

De acordo com Wang (2020), notícias falsas nem sempre relatam notícias inexistentes. Raramente acontece que toda a notícia seja fabricada, embora a fabricação pura ainda seja uma possível fonte de informações falsas. Em geral, notícias falsas referem-se a mensagens de notícias que contêm informações erradas ou falsas, mas não relatam informações incorretas. No entanto, nem todos os jornais adotam essa definição de notícias falsas.

Ainda segundo Wang (2020), existem vários significados de notícias falsas que precisam ser esclarecidos. Por outro lado, existem alguns termos com significados semelhantes a notícias falsas. Notícias inúteis, pseudo-notícias, fatos alternativos e boatos são termos com significado semelhante a notícias falsas. Nesse caso, notícias falsas referem-se a fatos imprecisos distribuídos no ciberespaço no sentido de que os fatos imprecisos são disseminados online e não no formato de reportagens. Essas mensagens imprecisas ou incorretas são nomeadas como desinformação, má informação e rumores relacionados a notícias falsas.

Para Bondielli e Marcelloni (2019) as notícias falsas podem assumir várias formas e formatos diferentes no ambiente de mídia social, portanto, é ainda mais difícil para detectá-los e contrastá-los com eficiência, tanto manual quanto automaticamente.

Detecção Computacional de Notícias Falsas

Devido à dificuldade de detectar manualmente notícias falsas, Abedalla et al. (2019), relata que a atenção crítica tem sido dedicada a detectar notícias falsas e reconhecer informações confiáveis de vários pesquisadores recentemente. Embora haja diferentes perspectivas para estudar este problema os métodos de aprendizagem de

máquinas são considerados tecnologias promissoras para melhorar as soluções de detecção de notícias falsas.

Além disso, para fornecer a responsabilidade de soluções algorítmicas, os pesquisadores começaram a oferecer detalhes sobre os mecanismos internos de algoritmos de aprendizado de máquina com mais treinos e testes por algoritmos de aprendizado de máquina para apresentar o resultado após a detecção de notícias falsas ocorrerem.

2.2. Trabalhos Relacionados

O artigo de Silva et al. (2019) teve como objetivo mapear o estado da arte na detecção de notícias falsas, definindo notícias buscando encontrar a técnica mais utilizada para o aprendizado de máquina. Para atingir o objetivo seguiram uma revisão sistemática da literatura para engenharia de software, método *Systematic Literature Review* (SLR). Para automatizar o processo SLR, usaram a ferramenta Parsifal, uma ferramenta SLR colaborativa online que permitiu definir um conjunto de palavras-chave, perguntas, string de consulta, critérios de inclusão e exclusão, e definir o conjunto de fontes de pesquisa.

Como principais resultados diferentes de muitas pesquisas que foram encontradas e lidas, chegou-se à conclusão de que o atual estado da arte da detecção automática de notícias falsas é o uso de composição abordagens de análise de rede no aprendizado de máquina escolhas técnicas, concluíram que um novo um conceito mais genérico de notícias falsas pode ser definido, com isso facilitaria a futura metamodelagem do objeto de entrada e permitir uma melhor detecção de desinformação generalizada de agentes a serem fabricados (SILVA et al., 2019).

Em sua monografia Koslowski (2019), apresentou como objetivo analisar a função do trabalho realizado pela agência de *fact-checking* do Brasil, a primeira no país, chamada Lupa, fundada em 2015. A autora fez um levantamento bibliográfico baseado nas referências da área da pesquisa, com aprofundamento no estudo de caso da empresa Lupa. Foi utilizado o método de observação, onde as postagens dos meses de agosto, setembro e outubro de 2019, resultaram em um entendimento de como as informações são checadas pela Lupa e quais os critérios são levados em consideração.

Neste período, ao todo 162 notícias foram averiguadas, sendo a maioria da área política, onde há uma maior propagação de *fake news*. Ademais, reflete sobre a desinformação em uma sociedade democrática, pautando-se no direito à informação, no papel principal do jornalismo e nos desafios que o mesmo vem enfrentando neste século.

Morais et al. (2019) abordaram em seu trabalho, cujo objetivo foi propor e validar um pipeline para mineração de texto com classificação multi-rótulo de notícias incorporado em um Sistema de Apoio à Decisão (SAD) de legitimidade de notícias, classificando documentos em 2 classes conceituais: falso / legítimo e satírico / objetivo. A coleta foi implementada em duas partes: coleta de documentos de portais de preconceito conhecidos e coleta de notícias falsas objetivas de agências de verificação.

Primeiramente, um rastreador *World Wide Web* (Web) foi usado para reunir uma grande quantidade de artigos de notícias de cada site em diversas plataformas digitais. Para cada combinação de classes, exceto para as notícias falsas objetivas, portais que têm um propósito conhecido foram selecionados. Foram utilizadas as agências de checagem de fatos Lupa e Boatos para reunir os documentos utilizados no corpo deste estudo.

Como resultado, Morais et al. (2019) propuseram um SAD em um conjunto de dados da vida real coletado de diferentes fontes de notícias usando uma abordagem multi-rótulo para enfrentar o desafio de classificar quatro combinações de classes: objetivo-legítimo, objetivo-falso, satírico-legítimo e satírico-falso. Além disso, quatro novos recursos textuais foram propostos para melhorar a previsão de desempenho ativo.

Os autores aplicaram um método de aprendizagem de máquina chamado de Florestas Aleatórias ou Florestas de Decisão (RF), a estratégia algorítmica apresentada oprimiu a importância dos recursos tradicionais. O algoritmo Linguagem de Máquina (LM) com melhor resultado foi RF, que obteve bom resultado em abordagens de várias classes e de vários rótulos. Enfim, o melhor desempenho, pontuação F1 foi alcançado por abordagens multi-rótulo com as duas pontuações mais altas derivadas.

As pesquisas de Silva et al. (2019), Koslowski (2019) e Morais et al. (2019) se assemelham a este trabalho por apresentarem métodos, ferramentas e possíveis soluções para o combate e reconhecimento de notícias falsas na internet, bem como abordagens, em seus respectivos trabalhos, a relevância latente com o tema estudado tendo em vista que as notícias falsas atualmente se espalham em um ritmo muito mais rápido com profundo impacto.

Isso torna a detecção de notícias falsas um desafio extremamente importante e que precisa ser levado muito a sério pelas autoridades competentes quanto ao desenvolvimento de softwares que auxiliem nesse processo de combate e reconhecimento das notícias falsas na internet, os trabalhos apresentados não utilizam o mapeamento sistemático como método da pesquisa como está sendo proposto nesta pesquisa.

3. Método da Pesquisa

O MS foi baseado no guidelines desenvolvido por Kitchenham e Chartes (2007) e definido em três etapas: (a) Planejamento do Mapeamento: nesse passo, os objetivos da pesquisa são listados e o protocolo do mapeamento é definido; (b) Condução do Mapeamento: durante essa fase, as fontes para o mapeamento são selecionadas, os estudos são identificados, selecionados e avaliados de acordo com os critérios estabelecidos no protocolo do mapeamento e (c) Resultado do Mapeamento: nessa fase, os dados dos estudos são extraídos e sintetizados para serem publicados.

Nesta etapa foi definido o protocolo de pesquisa, que consiste em definir o objetivo do estudo, especificar as questões da pesquisa, formular a expressão de busca, além de mencionar os procedimentos de extração dos dados e os critérios de seleção de cada publicação. A estrutura do protocolo foi baseada nos trabalhos de Kitchenham e

Charters (2007), conforme descrito a seguir:

3.1. Objetivo e Questões de Pesquisa

O objetivo deste mapeamento sistemático é **analisar** publicações científicas **com o propósito de** explorar o **uso de ferramentas, metodologias ou estratégias para reconhecimento de notícias falsas na internet.**

Sendo assim, este MS busca respostas para as seguintes questões de pesquisa (QP):

- **QP1:** Quais as ferramentas, metodologias ou estratégias disponíveis para reconhecimento e combate a disseminação de notícias falsas na Internet?
- **QP2:** Quais foram os tipos de testes realizados e principais resultados relacionados à sua eficiência na detecção de notícias falsas?

3.2. Fontes, Idioma e Expressão de Busca

Os locais de busca definidos para esta pesquisa serão feitos a partir da busca manual nos anais das conferências nacionais relacionados ao tema investigado nesta pesquisa, apoiados pela SBC (Sociedade Brasileira de Computação), que são: Simpósio Brasileiro de Banco de Dados (SBBDD), Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg), Simpósio Brasileiro de Sistemas Colaborativos (SBSC) e Simpósio Brasileiro de Sistemas de Informação (SBSI). A busca automática realizar-se-á por meio de investigação no Google Acadêmico - *scholar.google.com.br* e na base ACM Digital Library - *https://dl.acm.org*.

Nos anais de conferências serão identificados relatos de experiência e artigos técnicos e nas bibliotecas digitais serão considerados artigos científicos, monografias e dissertação. Serão considerados somente os anais das conferências que estejam acessíveis gratuitamente na Internet.

Idioma e Expressão de Busca

Os idiomas escolhidos são o Inglês (devido à sua adoção pela maioria das conferências, periódicos e editoras da área de pesquisa) e o Português (para incluir trabalhos técnicos publicados em conferências nacionais).

A busca foi restringida usando-se palavras-chave específicas para encontrar as publicações de interesse. A expressão de busca foi definida de acordo com dois dos quatro aspectos indicados em, Peterson et al. (2008): População e Intervenção, conforme a Tabela 1.

Tabela 1. Expressão de busca utilizada para identificar as publicações

<p>Para investigação por busca manual (no idioma Português):</p> <ul style="list-style-type: none"> • População - publicações que fazem referências a notícias falsas na internet (e sinônimos): <ul style="list-style-type: none"> - Palavras-chave: “notícias falsas na internet” OU “disseminação de notícias falsas na web”. • Intervenção - publicações que fazem referências a aplicação de ferramentas, metodologias ou estratégias no combate a notícias falsas que circulam na internet (e sinônimos): <ul style="list-style-type: none"> • Palavras-chave: “métodos de detecção de notícias falsas” OU “estudos teóricos sobre notícias falsas” OU “caracterizações de notícias falsas” OU “estratégias de prevenção de notícias falsas” OU “detecção robôs sociais”. <p>Para investigação por expressão de busca (no idioma Inglês):</p> <ul style="list-style-type: none"> • População - publicações que fazem referências a notícias falsas na internet (e sinônimos): <ul style="list-style-type: none"> - Palavras-chave: “fake news on the internet” OR “dissemination of fake news on the web”. • Intervenção - publicações que fazem referências a aplicação de ferramentas, metodologias ou estratégias no combate a notícias falsas que circulam na internet (e sinônimos): <ul style="list-style-type: none"> - Palavras-chave: “Detection methods of fake news” OR “theoretical studies on fake news” OR “fake news characterizations” OR “fake news prevention strategies” OR “detecting social bots”.

3.3. Critérios de Seleção

Esta pesquisa se restringe à análise de publicações disponíveis de 2015 até a data presente da execução do estudo. A seleção das publicações será realizada em três etapas:

1. Busca preliminar das publicações coletadas nas fontes definidas;
2. Primeiro Filtro de Seleção: por meio de análise do título, o resumo e as palavras-chave e aplicando o critério de seleção “CS1: possuir informações sobre a utilização de ferramentas, metodologias ou estratégias para o reconhecimento de notícias falsas veiculadas na internet”;
3. Segundo Filtro de Seleção: por meio da leitura completa das publicações e aplicando o critério de seleção “CS2: identificar as ferramentas existentes no combate a notícias falsas e quais plataformas as utilizam”.

3.4. Procedimentos de Extração de Dados.

Serão extraídas informações de publicações relevantes para a pesquisa, que serão registradas em tabelas, conforme os campos abaixo, descritos na Tabela 2:

Tabela 2. Campos de coleta de dados

A) Dados da publicação	
Título:	indica o título do trabalho
Autor(es):	nome dos autores
Fonte de publicação:	local de publicação
Ano da publicação:	ano de publicação
Resumo:	texto contendo uma descrição do resumo
B) Dados derivados do objetivo:	
Software desenvolvido:	descrição ferramentas de reconhecimento de notícias falsas mencionado na publicação
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	detalhamento do meio onde foi aplicado a ferramenta, metodologia ou estratégia de reconhecimento de notícias falsas
Aplicação (Testes realizados):	descrição da aplicação, estudo teórico ou relatos de experiência relatados

Principais resultados:	descrição dos resultados obtidos, estudo teórico ou relatos de experiência relatados
-------------------------------	--

Na etapa da Condução, a execução do MS ocorreu entre os meses de março a junho de 2021 e as publicações foram selecionadas de acordo com os critérios estabelecidos no protocolo. Publicações duplicadas, inacessíveis ou indisponíveis na internet foram descartadas. Além disso, foram excluídas as publicações que claramente abordavam outros assuntos não relevantes para a pesquisa.

Foram investigados por buscas manuais os anais no período de 2015 a 2021: SBBD, SBSeg, SBSC e o SBSI. Nas buscas automáticas: Google Acadêmico acessados no [sítio scholar.google.com.br](http://scholar.google.com.br) e na biblioteca digital da ACM Digital Library acessados em: dl.acm.org, onde foram consideradas as 10 primeiras páginas no Google Acadêmico restringidas as publicações de 2015 a 2021, na biblioteca da ACM por igual período de 2015 a 2021, acrescido de filtros de procedimentos, artigos de pesquisa e melhores artigos.

A priori na Tabela 3, são apresentados o total das publicações encontradas e após a primeira análise, de acordo com o 1º filtro (leitura do título, resumo da publicação e palavras-chave), 105 publicações foram selecionadas pelo critério CS1, como apresentado na Tabela 3.

Tabela 3. Publicações encontradas por etapas

Fonte	Início	Após 1º Filtro	Após 2º Filtro
SBBBD	210	0	0
SBSeg	192	1	0
SBSC	130	1	0
SBSI	453	2	1
Google Acadêmico	395	44	2
ACM Digital Library	672	57	20
TOTAL	2.052	105	23

Do total das publicações que resultaram do 1º filtro, todas foram lidas na íntegra e ao final 23 publicações foram selecionadas por estarem de acordo com o critério CS2, como apresentado na Tabela 4.

Tabela 4. Publicações selecionadas após o 2º filtro

ID	Título	Autores	Ano	Fonte
[P01]	Deciding among Fake, Satirical, Objective and Legitimate news: A multi-label classification system	Morais et al., 2019	2019	SBSI/2019
[P02]	Deteção de notícias falsas usando técnicas de deep learning	Guarise, 2019	2019	Google acadêmico /2019
[P03]	Aplicativo Verific.Ai: automatização de checagem de notícias nas eleições brasileiras de 2018	Júnior et al., 2019	2019	Google acadêmico /2019
[P04]	A Closer Look at Fake News Detection: A Deep Learning Perspective	Abdala et al., 2019	2019	ACM Library/ 2019
[P05]	A Fake News Detection Framework Using Social User Graph	Xie et al., 2020	2020	ACM Library/ 2020

[P06]	A Linguistic-Based Method that Combines Polarity, Emotion and Grammatical Characteristics to Detect Fake News in Portuguese	Souza et al., 2020	2020	ACM Library/ 2020
[P07]	A Topic-Agnostic Approach for Identifying Fake News Pages	Castelo et al., 2019	2020	ACM Library/ 2020
[P08]	ACT: Automatic Fake News Classification Through Self-Attention	Aloshban, 2020	2020	ACM Library/ 2020
[P09]	Beyond News Contents: The Role of Social Context for Fake News Detection	Shu et al., 2019b	2019	ACM Library/ 2019
[P10]	CIMTDetect: A Community Infused Matrix-Tensor Coupled Factorization Based Method for FakeNews Detection	Gupta et al., 2018	2018	ACM Library/ 2018
[P11]	Combining Neural, Statistical and External Features for FakeNews Stance Identification	Bhatt et al., 2018	2018	ACM Library/ 2018
[P12]	CSI: A Hybrid Deep Model for Fake News Detection	Ruchansky et al., 2017	2017	ACM Library/ 2017
[P13]	DEFEND: Explainable Fake News Detection	Shu et al., 2019a	2019	ACM Library/ 2019
[P14]	DistrustRank: Spotting False News Domains	Woloszyn and Nejdll, 2019	2019	ACM Library/ 2019
[P15]	EANN: Event Adversarial Neural Networks for Multi-Modal Fake News Detection	Wang et al., 2018	2018	ACM Library/ 2018
[P16]	Early Detection of Fake News “Before It Flies High”	Gereme and Zhu, 2019	2019	ACM Library/ 2019
[P17]	Explainable Machine Learning for Fake News Detection	Reis et al., 2019	2019	ACM Library/ 2019
[P18]	Fake News Detection via Knowledge-driven Multimodal Graph Convolutional Networks	Wang et al., 2020	2020	ACM Library/ 2020
[P19]	FANG: Leveraging Social Context for Fake News Detection Using Graph Representation	Nguyen et al., 2020	2020	ACM Library/ 2020
[P20]	Learning to Detect Misleading Content on Twitter	Boididou et al., 2017	2017	ACM Library/ 2017
[P21]	Leveraging the Crowd to Detect and Reduce the Spread of Fake News and Misinformation	Kim et al., 2018	2018	ACM Library/ 2018
[P22]	Proactive Discovery of Fake News Domains from Real-Time Social Media Feeds	Chen and Freire, 2020	2020	ACM Library/ 2020
[P23]	Tracing Fake-News Footprints: Characterizing Social Media Messages by How They Propagate	Wu and Liu, 2018	2018	ACM Library/ 2018

Para todas as 23 publicações foram preenchidas as informações nos formulários de coletas de dados, Tabela 5, conforme os dados definidos para a extração de dados descritos no protocolo do MS. Todas as tabelas de extração preenchidas, das publicações selecionadas, podem ser consultadas no Apêndice A.

Tabela 5 – Listagem de coleta de dados

A) Dados da publicação: ID [P07]	
Título:	A Topic-Agnostic Approach for Identifying Fake News Pages
Autor(es):	Sonia Castelo, Thais Almeida, Anas Elghafari, Aécio Santos, Kien Pham, Eduardo Nakamura e Juliana Freire
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Apresentamos uma nova abordagem para detectar páginas da web de notícias falsas que utilizam recursos agnósticos de tópico. Por meio de uma avaliação experimental detalhada, mostraram que a abordagem classifica com precisão não apenas notícias políticas conforme os tópicos evoluem ao longo do tempo, mas também notícias de diferentes outros domínios, superando as abordagens baseadas em conteúdo ao usar significativamente menos recursos e não requer nenhum retreinamento frequente. Com isso para atingir este objetivo, propuseram uma classificação agnóstica de tópico (TAG) estratégia que usa recursos linguísticos e de marcação da web para identificar páginas de notícias falsas.
B) Dados derivados do objetivo:	
Software desenvolvido:	TAG (Classificação Agnóstica de Tópicos)
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: SVM + KNN + RF Base de Dados: PoliticalNews, Celebraty e US-Election
Aplicação (Testes realizados):	Método usado: Características: morfológicas, psicológica legibilidade e marcação web Recurso usado: Páginas web (título, conteúdo ou combinação de ambos) Métricas: Acurácia
Principais resultados:	Taxa total: 0,86 O classificador baseado em TAG supera o Detector para todos os conjuntos de dados, indicando que a tarefa de classificação de notícias falsas pode ser efetivamente realizada usando recursos agnósticos de tópico.

4. Resultados e Discussões

Concluída a Seção 3 que aborda a etapa da condução do MS, foi executada a última fase da metodologia aplicada neste trabalho, na qual será a apresentação dos resultados, como também a sua análise. A priori, a resposta da primeira questão de pesquisa será apresentada, juntamente com a análise e discussão dos resultados encontrados, posteriormente será realizado o mesmo procedimento para a segunda questão de pesquisa.

Deste modo, após finalizar as análises e discussões das questões de pesquisas, será possível também concluir o objetivo geral, e, portanto, será concluído o MS realizado neste trabalho.

- Com relação à QP1: **“Quais as ferramentas, metodologias ou estratégias disponíveis para o reconhecimento e combate a disseminação de notícias falsas na Internet?”**

Foram encontrados vários modelos utilizados que compõem a abordagem que visa reconhecer as notícias verdadeiras como também identificar as notícias falsas, em meio

as publicações, no caso, cada publicação selecionada continha um ou mais tipos de modelos usados no desenvolvimento de cada aplicação, nas publicações foram observadas apenas os modelos utilizados na classificação das notícias falsas ou verdadeiras após a sumarização da base de dados para tratamento dos testes e treinamentos de cada abordagem, como também a base de dados, método usado e as etiquetas de classificação das notícias.

Após a investigação e tratamento da coleta dos modelos desenvolvidos, havia uma recomendação para que se pudesse, a partir da abordagem apresentada realizar melhorias nas tecnologias desenvolvidas pois a maioria delas estão limitadas apenas por utilização de classificação texto e baixa escalabilidade devido à complexidade dos algoritmos em detrimento da disseminação, combate e reconhecimento de notícias falsas na internet.

Os recursos textuais costumam ser usados para a incorporação de textos de notícias. Tal incorporação pode ser conduzida no nível da palavra, nível de sentença, ou nível de documento; os resultados são vetores que representam um artigo de notícias e podem ser usados diretamente como entrada para classificadores, por exemplo uma *Support Vector Machine* (SVM) ao prever notícias falsas em um aprendizado de máquina tradicional (SHU et al., 2018).

Essas incorporações em determinado método, no nível da palavra podem ser mais vistos em arquiteturas de rede neural, por exemplo *Convolutional Neural network* (CNN) ou *Recurrent Neural Network* (RNN), para prever notícias falsas dentro de uma estrutura de aprendizado profundo, em que CNNs representam textos de notícias de uma visão local a global, e RNNs capturar as sequências com texto de notícias (WANG et al., 2018).

A escolha da base de dados é fundamental para realizar os testes e treinamentos dos modelos propostos, Guarise (2019) relata que encontrar uma base de dados contendo textos de notícias falsas são mais comuns em bases na língua inglesa e com menor frequência na língua portuguesa, pois ela ainda não é muito explorada, como demonstrado nesta pesquisa proposta (Tabela 3).

Contudo existe uma base que atende aos requisitos propostos em português, o Fake.br, utilizado por Souza et al. (2020) em seus testes, assim como nas pesquisas de Guarise (2019). A razão de utilizar o Fake.br por possuir: textos completos de notícias, e não apenas manchetes ou comentários em textos curtos, além de ser uma base composta por um conjunto balanceado e com rotulação binária fake e não fake bem definida, no conjunto de dados, são encontradas seis categorias diferentes que proporcionam uma diversidade de temas, embora a maior parte das notícias esteja relacionada com temas políticos.

A Tabela 6, mostra as bases de dados, os modelos, métodos e as etiquetas utilizados nas abordagens encontradas na investigação propostas nesta pesquisa.

Tabela 6 – Ferramentas, metodologias e estratégias para reconhecimento e combate a notícias falsas

ID Artigo	Base de Dados	Modelo	Método Usado	Etiquetas
[P01]	Lupa, Boatos e próprio	RF, SVM e KNN	Classificação de texto	Falso/Legítimo e Satírico /Objetivo
[P02]	Fake.Br	RNN e LSTM	Classificação de texto	Falso e Não Falso
[P03]	Fatos e Lupa	DATA MINING	Link URL, Classificação de texto	Notícia verdadeira ou Falsa
[P04]	Artigos de notícias	CNN + Bi-LSTM	Classificação de texto	M1-E1, M1-E2 e M1-E3
[P05]	FakeNewsNet (BuzzFeed e PolitiFact)	RST + SVM, LIWC + SVM, TFIDF + SVM, CASTILLO, RST + CASTILLO, LIWC + CASTILLO, TRIFN, UCEM, AUTORES	Notícias de redes sociais, Classificação de texto e Características do usuário	Só falso, Só verdade e ambos
[P06]	Fake.Br	NB, GRADIENTBOST	Classificação de texto	Falso e Não Falso
[P07]	PoliticalNews, Celebraty e US-Election	SVM + KNN + RF	Características: morfológicas, psicológicas, legibilidade e marcação Web	Título, Conteúdo ou Ambos
[P08]	Snopes, PolitiFact e Fonte Externa	LSTM + DeClarE	Classificação de texto	Verdade total e Meia Verdade; Falso Total e Meio Falso
[P09]	FakeNewsNet (BuzzFeed e PolitiFact)	NB, RF	Relacionamento entre editores, notícias e usuários	"Esquerda", "Menos tendenciosa", "Direita"
[P10]	FakeNewsNet (BuzzFeed e PolitiFact)	SVM	Classificação de texto	Falso e Não Falso
[P11]	Dados Emergentes	LSTM e GRU	Classificação de texto	Concordo, Discordo, Não relacionado ou Discutir
[P12]	Twitter e Weibo	LSTM, RNN	Classificação de texto, Resposta Usuário e Fonte.	Notícia verdadeira ou falsa
[13]	PoliticFact e Gossip	DNN, RNN	Classificação de texto, Resposta Usuário e Fonte.	Notícia verdadeira ou Falsa
[14]	SilimarWeb e Wikipédia	SVM	Link URL, Classificação de texto	Confiável e Não confiável
[15]	Twitter e Weibo	CNN, NERALTALK, VQA, ATT-RNN	Características textuais e Visuais	Falso e Não Falso
[16]	Kaggle George McIntire	RNN, LSTM, CNN, NB	Classificação de texto	Verdadeiro Positivo, Falso Negativo, Falso Positivo e Verdadeiro Negativo

[17]	BuzzFace (BuzzFeed)	GRADIENT BOOSTING	Classificação de texto	Verdade, Verdadeiro e falso, Não Falso
[18]	PHEME e Weibo	KMGCN	Características textuais, Gráficas e Visuais	Falso e Não Falso
[19]	Próprio	LSTM, RNN	Características textuais, Gráficas e Visuais	Neutro apoia, Apoia negativo, Negar, Relatar
[20]	Handbook	RF	Texto, Idioma e Link URL	Falso ou Real
[21]	Twitter e Weibo	CURB	Link URL	Falso ou Verdadeiro
[22]	PoliticalFake News, Politifact	SVM	Link URL	Falso e Não Falso
[23]	Snopes	LSTM, RNN	Link URL	Verdadeiro ou Falso

De acordo com a pesquisa proposta, os métodos mais utilizados para reconhecimento de notícias falsas que compõem os modelos investigados estão destacados na Figura 1. Claramente pode-se perceber que essa metodologia de classificação de texto é abordada mais frequentemente, com pouco mais 78% em relação aos outros.

Entretanto, os estudos realizados também mostram que é possível obter melhores resultados de detecção de notícias falsas quando se considera outras metodologias, tais como: link de internet que são frequentemente compartilhados, como também abordagens visuais ou gráficas, entre outros.

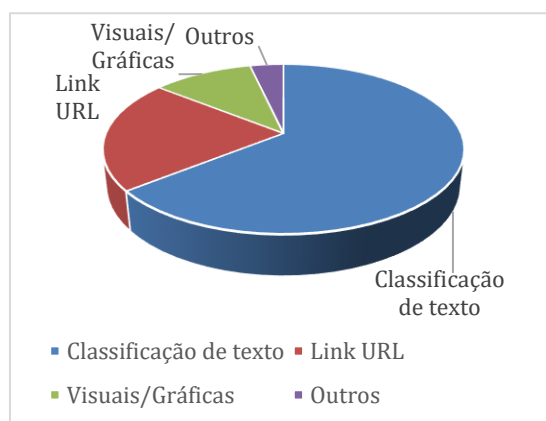


Figura 1 – Metodologias utilizadas reconhecimento e combate a notícias falsas

Para Shu et al. (2019a), é razoável explorar características linguísticas que captam os diferentes estilos de escrita e manchetes sensacionalistas para detectar notícias falsas. Baseado nos recursos linguísticos são extraídos do conteúdo do texto em termos de organizações, de documentos de diferentes níveis, como: parágrafos, palavras, frases e textos para compreender os diferentes aspectos das notícias falsas e reais.

Dados os modelos encontrados neste trabalho, o modelo *Long Short-Term Memory* (LMST) é o algoritmo de aprendizado mais utilizados aparecendo com maior frequência em comparação aos outros modelos, como mostra a Figura 2.

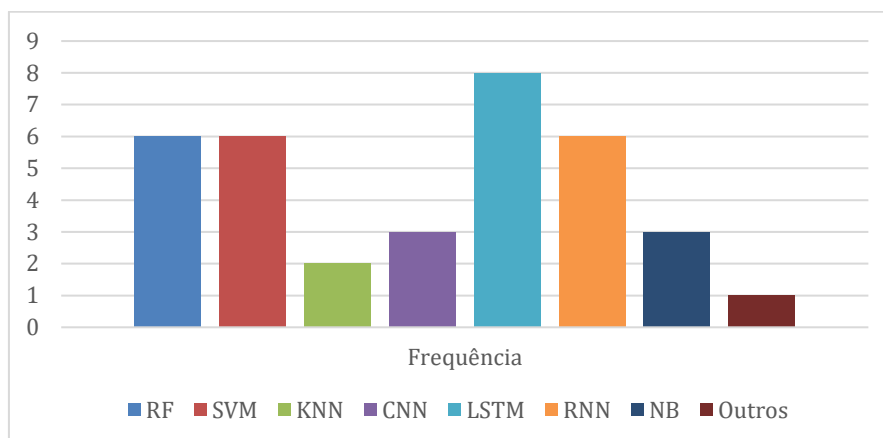


Figura 2 – Modelos utilizados para reconhecimento e combate a notícias falsas

Marumo (2019) ressalta que a rede LSTM consegue ter uma memória de longo prazo mais efetiva do que a RNN ao criar uma unidade de estado de memória interna que adiciona a entrada processada ao invés de multiplicá-la, reduzindo assim o problema de pequenos gradientes. Além disso, ele tem um conceito chamado portão de esquecimento, que usa a entrada anterior para determinar quais estados devem ser lembrados ou esquecidos.

Considerando, as redes sociais como ambiente de testes, treinamento e validação dos modelos propostos, Ruchansky, Seo e Liu (2017) e Wang et al. (2018, 2020), usam Twitter, Weibo ou ambos para experimentos em redes sociais, como destacado na Tabela 6, nas publicações [P12], [P15] e [P18]. As redes sociais aqui destacadas possuem ferramentas de leitura e compartilhamento de notícias bem difundidas.

Por outro lado, as bases utilizadas como fonte de dados por Moraes et al. (2019), Guarise (2019) e Souza et al. (2020) para realização dos testes, treinamento e validação das abordagens propostas na língua portuguesa, foram identificadas: Fake.br, Aos Fatos e Agência Lupa, Tabela 6, publicações [P01],[P02] e [P06].

- Com relação à QP2: **“Quais foram os tipos de testes realizados e principais resultados relacionados à sua eficiência na detecção de notícias falsas?”**

Entre as formas de validação foram encontradas 08 de métricas para avaliar os resultados, tais como: **Acurácia, Precisão, Recall, F1, AUC, FNC, Redução e Própria** para validar os resultados obtidos, na Figura 3 são demonstradas as métricas mais utilizadas nos modelos desenvolvidos.




Figura 3 – Métricas mais utilizadas para validação dos modelos

Nas publicações foi possível as 08 métricas para validar os resultados, desse modo elas foram catalogadas e colocadas em uma tabela para uma melhor análise na qual mostra que foram utilizadas em diferentes recursos usados com mais de um teste realizado em cada recurso. A Tabela 7 apresenta os tipos de teste para cada artigo encontrado.

Tabela 7 – Testes e principais resultados para reconhecimento e combate a notícias falsas

ID Artigo	Recursos Usados	Métricas	Resultados
[P01]	Corpo do texto	Acurácia e F1	0,8
[P02]	Corpo do texto	Acurácia	95,35%
[P03]	Corpo do texto	Própria	Indefinido
[P04]	Corpo do texto	Acurácia	0,712
[P05]	Notícias de redes sociais	Precisão, Recall e F1	BuzzFeed (0,905; 1,0 e 0,950) - PolitiFact (1,0; 1,0 e 1,0)
[P06]	Corpo do texto e título	Acurácia	0,92
[P07]	Páginas Web (título, conteúdo e combinação de ambos)	Acurácia	0,86
[P08]	Corpo do texto	AUC, Precisão e F1	0,75
[P09]	Corpo do texto, usuários, usuários-notícias, editor-notícia	Acurácia, Precisão, Recall e F1	BuzzFeed (0,864; 0,849; 0,893 e 0,870) - PolitiFact (0,878; 0,867; 0,893 e 0,880)
[P10]	Notícias, usuário e comunidade	Precisão, Recall e F1	BuzzFeed (0,729; 0,923; 0,813) - PolitiFact (0,803; 0,842; 0,818)
[P11]	Corpo do texto E título	Score FNC	75,2%
[P12]	Notícias, usuário e comunidade	Acurácia e F1	0,8
[P13]	Corpo do texto, comentário usuários, frase-comentário	Acurácia, Precisão, Recall e F1	GossipCop (0,808; 0,729; 0,782; 0,755) - PolitiFact (0,904; 0,902; 0,956; 0,928)
[P14]	Corpo do texto	Precisão, Recall e F1	(0,8; 0,7659; 0,7825)
[P15]	Corpo do texto e imagem	Acurácia, Precisão, Recall e F1	Twitter (0,715; 0,822; 0,638; 0,719) - Weibo (0,827; 0,847; 0,812; 0,829)
[P16]	Corpo do texto	Acurácia, Precisão, Recall e F1	0,99
[P17]	Corpo do texto de redes sociais	AUC	0,85

[P18]	Corpo do texto e imagem	Acurácia, Precisão, Recall e F1	Weibo (0,8863; 0,9100; 0,9645; 0,8834) – PHEME (0,8756; 0,8762; 0,8765; 0,8764)
[P19]	Corpo do texto, comentário usuários, frase-comentário	AUC	0,7518
[P20]	Corpo do texto, usuários, fonte publicação	Acurácia e F1	(94,06%, 0,934)
[P21]	Corpo do texto de redes sociais	Precisão e Redução	Twitter (0,7) - Weibo (0,9)
[P22]	Corpo do texto de redes sociais	AUC	89%
[P23]	Corpo do texto de redes sociais	F1	0,9124

Sakurai (2019), apresenta estas classificações, conseguindo definir as seguintes métricas de avaliação:

- **Precisão:** este indicador analisa apenas as avaliações positivas dadas, ou seja, a proporção de todas as notícias com notação Falso Negativo (FN) são efetivamente FN.
- **Revocação (*Recall*):** analisa a proporção de notícias que são realmente FN e todas as categorias foram classificadas como FN. Falsos negativos são incluídos na fórmula porque as notícias são, na verdade, FN, mesmo que o detector ou classificador já tenha previsto outra coisa.
- **F1 Score:** A combinação de Precisão e *Recall*, que representa a qualidade geral dos resultados do aprendizado de máquina. É um valor médio harmônico, que ajuda a experimentar com amostragem desproporcional, ou seja, uma biblioteca de informações desigual. Existem mais notícias reais do que notícias falsas e vice-versa
- **Acurácia:** esta é uma métrica simples usada para calcular a proporção entre o número de acertos de classificações positivas e o número total de amostras. Todas as avaliações estão corretas, independentemente de o FN ser separado de todos os repositórios de notícias presentes na amostra

A pesquisa demonstrou também que nos modelos abordados os autores utilizaram em seus trabalhos mais de uma técnica com diferentes experimentos para validar os testes realizados, conforme descritos na Tabela 8.

Tabela 8 – Testes dos modelos para validação dos resultados

Métricas	ID Artigos
F1	[P01], [P05], [P08], [P09], [P10], [P12], [P13], [P14], [P15], [P16], [P18], [P20] e [P23]
Acurácia	[P01], [P02], [P03], [P04], [P06], [P07], [P09], [P12], [P13], [P15], [P16], [P18] e [P20]
Precisão	[P05], [P08], [P09], [P10], [P13], [P13], [P15], [P16], [P18] e [P21]
Recall	[P05], [P09], [P10], [P13], [P14], [P15], [P16] e [P18]

Os recursos mais usados para realização de testes e validação das abordagens propostas encontradas nas pesquisas estão apresentadas na Tabela 9. O recurso utilizado que mais se destaca para validação dos modelos encontrados neste trabalho foi “Corpo de

Texto”, isso já era esperado tendo em vista que os resultados apresentados na questão de pesquisa 1, a metodologia mais usada para reconhecimento de notícias falsas é a classificação de texto.

Tabela 9 – Recursos usados para testes para reconhecimento de notícias falsas

Recursos Usados	ID Artigo	%
Corpo do Texto	[1],[2],[3],[4],[6],[8],[11],[13],[14],[15],[16]e[18]	52,17
Redes Sociais	[5],[17],[19],[21],[22]e[23]	26,08
Outros	[7],[9],[10],[12]e[20]	21,75

Os resultados dos testes, recursos e eficiência abordadas pelos autores Shu et al. (2019a, 2019b), Wang et al. (2018, 2020), Gereme e Zhu (2019) em seus respectivos artigos serão demonstrados na Tabela 10, na qual foram escolhidos com base nos critérios utilizados na Figura 4 e na Tabela 9 para mostrar a eficácia dos seus modelos, o critério estabelecido cruza os resultados dos autores que usam as 4 métricas para teste e usa como recurso o corpo do texto, abordados nos artigos [P09],[P13],[P15],[P16] e [P18].

Tabela 10 – Recursos usados para testes para reconhecimento de notícias falsas

ID Artigo	Base de Dados	Métricas	Resultados Obtidos	Eficácia
[P09]	BuzzFeed	Acurácia	0,864	0,9
		Precisão	0,849	0,8
		Recall	0,893	0,9
		F1	0,87	0,9
	PolitiFact	Acurácia	0,878	0,9
		Precisão	0,867	0,9
		Recall	0,893	0,9
		F1	0,88	0,9
[P13]	GossipCop	Acurácia	0,808	0,8
		Precisão	0,729	0,7
		Recall	0,782	0,8
		F1	0,755	0,8
	PolitiFact	Acurácia	0,904	0,9
		Precisão	0,902	0,9
		Recall	0,956	1
		F1	0,928	0,9
[P15]	Twitter	Acurácia	0,715	0,7
		Precisão	0,822	0,8
		Recall	0,638	0,6
		F1	0,719	0,7
	Weibo	Acurácia	0,827	0,8
		Precisão	0,847	0,8
		Recall	0,812	0,8
		F1	0,829	0,8
[P16]	Kagle	Acurácia	0,9904	1
		Precisão	0,9933	1
		Recall	0,9876	1
		F1	0,9905	1
	GeorgeMeltine	Acurácia	0,9732	1

		Precisão	0,9918	1
		Recall	0,9544	1
		F1	0,9728	1
[P18]	Weibo	Acurácia	0,8863	0,9
		Precisão	0,91	0,9
		Recall	0,9645	1
		F1	0,8834	0,9
	PHEME	Acurácia	0,8756	0,9
		Precisão	0,8762	0,9
		Recall	0,8765	0,9
		F1	0,8764	0,9

Utilizando a função ARRED da Microsoft Excel e considerando apenas 01 (uma) casa decimal na coluna 5, na Tabela 10, para fins didáticos e uma melhor compreensão da eficácia dos modelos propostos nas abordagens dos autores que utilizaram os testes e validação em duas bases de dados com métricas de classificação diferentes.

Nos modelos abordados na Tabela 10, os algoritmos foram capazes de ter uma taxa total entre (0,7; 0,8; 0,9 e 1). O valor é medido entre 0 e 1, quanto mais próximo de 1 melhor é o modelo. A taxa total entre as métricas utilizadas são praticamente iguais, com pouca ou quase nenhuma diferença.

Segundo Borges (2016), a classificação da precisão do algoritmo pode ser da seguinte forma:

- 0.9 - 1.0 > É considerado excelente;
- 0.8 - 0.9 > É considerado muito bom;
- 0.7 - 0.8 > É considerado bom;
- 0.6 - 0.7 > É considerado suficiente;
- 0.6 - 0.5 > É considerado ruim;
- Menor que 0.5 > Não utilizar o teste.

Portanto, a taxa total das métricas mostra que estão bem calibradas e não está havendo nenhum problema no processo. Isso indica que os modelos têm se comportado bem com os diferentes tipos de testes realizados. É perceptível que alguns modelos em determinada métrica obtiveram um desempenho baixo entre as demais, contudo, alcançou uma média de 0.7, isso indica que o modelo ainda é ideal.

5. Conclusão

Dada a relevância do tema na atualidade e a importância do reconhecimento e combate de notícias falsas na internet para a diminuição de seu impacto na sociedade e no ecossistema de notícias. Embora as notícias falsas não são um fenômeno novo, esta onda de atividade em torno de notícias online pode levar a graves repercussões e consideráveis benefícios políticos, econômicos e sociais, esses benefícios encorajam entidades maliciosas a criar, publicar e espalhar notícias falsas.

O objetivo deste trabalho foi investigar quais ferramentas, métodos ou estratégias disponíveis para reconhecimento e combate de notícias falsas na internet. Foram apresentados na discussão dos resultados das questões de pesquisa, as abordagens que geralmente classificam os modelos de detecção de notícias falsas, os tipos de métodos de aprendizado de máquina utilizando métodos: classificação de texto, links da URL, imagem ou gráficos com recursos de contexto social, páginas da internet, redes sociais.

Com os resultados obtidos neste trabalho, é possível concluir que as ferramentas, métodos ou aplicações são uma alternativa para minimizar o problema da disseminação em massa das notícias falsas na internet, de tal modo realizar a análise das notícias em termos de seu conteúdo e são exibidos os modelos, recursos usados, testes, validação e o desempenho das abordagens que se propõem na detecção de notícias falsas.

Em síntese, foi possível analisar que de forma geral os modelos de aprendizado de máquina juntamente com o processamento de linguagem natural que obtiveram resultados positivos para realizar a classificação de notícias falsas. Enfatizando que essa pesquisa se concentra mais em apresentar um conjunto de ferramentas, modelos e onde os testes foram realizados fornecidos pelos autores em suas publicações, disponíveis de forma gratuita na língua inglesa ou portuguesa.

5.1. Limitações

As limitações deste trabalho se relacionaram à:

- A baixa quantidade de artigos nos anais de eventos brasileiros da computação dos quais haviam sido selecionados neste trabalho, fazendo assim com que o número de artigos selecionáveis destas fontes fosse reduzido ou quase nenhum.
- Nas pesquisas automáticas utilizando as *strings* de buscas vários artigos retornaram as pesquisas e de acordo com o escopo deste trabalho pode ter ocorrido de alguns artigos não se enquadrarem completamente nas questões de pesquisas.
- O trabalho se limitou apenas em uma biblioteca digital de referência na computação e com artigos gratuitos.

5.2. Trabalhos Futuros

Com o objetivo de estender e aprimorar os resultados obtidos, algumas das expectativas de trabalhos futuros são apresentadas a seguir:

- Ampliar a pesquisa para outras fontes de busca, como outras bibliotecas digitais, outros idiomas e anais para identificar mais recomendações.
- Incrementar ao escopo do trabalho o impacto das notícias falsas nas eleições.
- Realizar uma pesquisa de campo para elaborar um levantamento de requisitos na perspectiva dos usuários em suas respectivas faixas etárias no discernimento de notícias falsas ou verdadeiras.

- Propor um algoritmo para identificar e combater as notícias falsas veiculadas na internet utilizando outros recursos de detecção de notícias falsas.

Referências

- ABEDALLA, A.; AL-SADI, A. e ABDULLAH, M. *A Closer Look at Fake News Detection: A Deep Learning Perspective*. Anais da 3ª Conferência Internacional sobre Avanços em Inteligência Artificial - (ICAAI). Association for Computing Machinery, Nova York, EUA, p. 24–28, 2019.
- ALOSHBAN, N. *ACT: Automatic Fake News Classification Through Self-Attention*. 12ª Conferência ACM sobre Web Science (WebSci). Association for Computing Machinery, Nova York, EUA, p. 115-124, 2020.
- BASIL, V.; CALDEIRA, G.; ROMBACH, H. *The Experience Factory*. In: *Encyclopedia of Software Engineering*, New York, 1994.
- BHATT, G.; SHARMA, A.; SHARMA, S.; NAGPAL, A.; RAMAN, B. e MITTAL, A. *Combining Neural, Statistical and External Features for FakeNews Stance Identification*. Companion Proceedings of the Web Conference 2018 (WWW '18). Comitê Diretor de Conferências Internacionais da World Wide Web, República e Cantão de Genebra, CHE, p. 1353–1357, 2018.
- BOIDIDOU, C.; PAPADOPOULOS, S.; APOSTOLIDIS, L. e KOMPATSIARIS, Y. *Learning to Detect Misleading Content on Twitter*. International Conference on Multimedia Retrieval (ICMR '17). Association for Computing Machinery, Nova York, EUA, p. 278-286, 2017.
- BONDIELLI, A. e MARCELLONI, F. *A survey on fake news and rumour detection techniques*. Information Sciences, v. 497, p. 38-55, 2019.
- BORGES, L. S. *Medidas de Acurácia diagnóstica na pesquisa cardiovascular*. Int J Cardiovasc Sci, v. 29, n. 3, p. 218-22, 2016.
- CASTELO, S.; THAIS ALMEIDA, T.; ELGHAFARI, A.; SANTOS, A.; PHAM, K.; NAKAMURA, E.; E FREIRE, J.; *A Topic-Agnostic Approach for Identifying Fake News Pages*. Companion Proceedings - World Wide Web Conference (WWW). Association for Computing Machinery, Nova York, EUA, p. 975–980, 2019.
- COSTA, A. V. G. *Classificador de fake news utilizando um modelo de aprendizado de máquina com técnicas de processamento de linguagem natural*. 2020. 39 f. Monografia. Universidade Federal Rural do Semi-Árido – UFRSA, 2020.
- FERREIRA, H. H. *Processamento de linguagem natural e classificação de textos em sistemas modulares*. 2019. 61 f. Trabalho de Conclusão de curso (Bacharelado em Ciência da Computação) - Universidade de Brasília, Brasília.

- GEREME, F. B. e ZHU, W. *Early Detection of Fake News “Before It Flies High”*. Em Anais da 2ª Conferência Internacional sobre Tecnologias de Big Data (ICBDT2019). Association for Computing Machinery, Nova York, EUA, p. 142–148, 2019.
- GUANGCE, R. e LEI, X. *Knowledge Discovery of News Text Based on Artificial Intelligence*. ACM Trans. Asian Low-Resour. Lang. Inf. Process. 20, 1, Article 6 (February 2021), 18 pages, 2021.
- GUARISE, L. *Detecção de notícias falsas usando técnicas de deep learning*. 49 f. Monografia - Instituto de Ciências Matemáticas e de Computação (ICMC/USP), 2019.
- GUPTA, S; THIRUKOVALLURU, R.; SINHA, M. e MANNARSWAMY, S. *CIMTDetect: A Community Infused Matrix-Tensor Coupled Factorization Based Method for FakeNews Detection*. Proceedings of the 2018 IEEE / ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM '18). IEEE Press, p.278-281, 2018.
- HUANG, C. E WANG, X. *Financial Innovation Based on Artificial Intelligence Technologies*. In Proceedings International Conference on Artificial Intelligence and Computer Science (AICS). Association for Computing Machinery, Nova York, EUA, p. 750–754, 2019.
- KIM, J.; TABIBIAN, B.; OH, A.; SCHÖLKOPF, B. e RODRIGUEZ, M. G. *Leveraging the Crowd to Detect and Reduce the Spread of Fake News and Misinformation*. Eleventh ACM International Conference on Web Search and Data Mining (WSDM '18). Association for Computing Machinery, New York, USA, p. 324–332, 2018.
- KITCHENHAM, B.; CHARTERS, S. *Guidelines for Performing Systematic Literature Reviews in Software Engineering*. Relatório Técnico Evidence-Based Software Engineering (EBSE), v. 2.3, 2007.
- KOSLOWSKI, D. R. *Fake News e o Combate à Desinformação: Um Estudo de Caso da Agência de Checagem Lupa*. 2019. 73 f. Monografia (Bacharel em Jornalismo). Universidade Regional do Noroeste do Estado do Rio Grande do Sul.
- MARUMO, F. S. *Deep Learning para classificação de Fake News por sumarização de texto*. 2019. 52 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) -Universidade Estadual de Londrina.
- MEDEIROS, F. DC. e BRAGA, R. B. *Fake News Detection in Social Media: A Systematic Review*. XVI Simpósio Brasileiro de Sistemas de Informação (SBSI'20). Association for Computing Machinery, New York, USA, p. 1-8, 2020.
- MONARD, M. C. e BARANAUSKAS, J. A. *Conceitos Sobre Aprendizado de Máquina. Sistemas Inteligentes Fundamentos e Aplicações*. 1 ed. Barueri-SP: Manole Ltda, 2003. p. 89-114. ISBN 85-204-168.

- MORAIS, J. I.; ABONIZIO, H. Q.; TAVARES, G. M.; FONSECA, A. A. e JÚNIOR, S. B. *Deciding among Fake, Satirical, Objective and Legitimate news: A multi-label classification system*. XV Simpósio Brasileiro de Sistemas de Informação (SBSI), Aracaju. p. 167-174, 2019.
- NGUYEN, V.; SUGIYAMA, K.; NAKOV, P. e KAN, M. *FANG: Leveraging Social Context for Fake News Detection Using Graph Representation*. 29th ACM International Conference on Information & Knowledge Management (CIKM '20). Association for Computing Machinery, Nova York, EUA, p. 1165–1174, 2020.
- PETERSEN, K.; FELDT, R.; MUJTABA, S.; MATISSON, M. *Systematic Mapping Studies in Software Engineering*. In Proceedings of the Evaluation and Assessment in Software Engineering (EASE), Bari, Italy, 2008.
- REIS, J. CS.; CORREIA, A.; MURAI, F.; VELOSO, A. e BENEVENUTO, F. *Explainable Machine Learning for Fake News Detection*. 10th ACM Conference on Web Science (WebSci '19). Association for Computing Machinery, Nova York, EUA, p. 17–26, 2019.
- RUCHANSKY, N.; SEO, S. e LIU, Y. *CSI: A Hybrid Deep Model for Fake News Detection*. Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. Association for Computing Machinery, Nova York, EUA, p. 797–806, 2017.
- SAKURAI, G. Y. *Processamento de Linguagem Natural - Detecção de Fake News*. 2019. 35 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade Estadual de Londrina - Londrina.
- SBPJOR - Associação Brasileira de Pesquisadores em Jornalismo - *APLICATIVO VERIFIC.AI: automatização de checagem de notícias nas eleições brasileiras de 2018*, 2019.
- SHU, K.; CUI, L.; WANG, S.; LEE, D. e LIU, H. *DEFEND: Explainable Fake News Detection*. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19). Association for Computing Machinery, Nova York, EUA, p. 395–405, 2019a.
- SHU, K.; SLIVA, A.; WANG, S.; TANG, J. e LIU, H. *Fake News Detection on Social Media: A Data Mining Perspective*. SIGKDD Explor. Newsl. 19, 1 (junho de 2017), p. 22–36, 2017.
- SHU, K.; WANG, S. E LIU, H. *Beyond News Contents: The Role of Social Context for Fake News Detection*. Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining (WSDM). Association for Computing Machinery, Nova York, EUA, p. 312–320, 2019b.
- SILVA, C. D.; VIEIRA, F.; GARCIA, F. e CRISTINA, A. *Can Machines Learn to Detect Fake News? A Survey Focused on Social Media*. Proceedings of the 52nd Hawaii International Conference on System Sciences, p. 2763-2770, 2019.

- SOUZA, M. P.; SILVA, F. R. M.; FREIRE, P. M. S. e GOLDSCHMIDT, R. R. 2020. *A Linguistic-Based Method that Combines Polarity, Emotion and Grammatical Characteristics to Detect Fake News in Portuguese*. Anais do Simpósio Brasileiro de Multimídia e a Web (WebMedia). Association for Computing Machinery, Nova York, EUA, p. 217–224, 2020.
- TECUCI, G. *Artificial intelligence*. WIREs Comput Stat, v. 4, n.2, p. 168-180, 2012.
- WANG, Y.; MA, F.; JIN, Z.; YUAN, Y.; XUN, G.; JHA, K.; SU, L. e GAO, J. *EANN: Event Adversarial Neural Networks for Multi-Modal Fake News Detection*. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '18). Association for Computing Machinery, Nova York, EUA, p. 849–857, 2018.
- WANG, Y.; QIAN, S.; HU, J.; FANG, Q. e XU, C. *Fake News Detection via Knowledge-driven Multimodal Graph Convolutional Networks*. International Conference on Multimedia Retrieval (ICMR '20). Association for Computing Machinery, Nova York, EUA, p. 540–547, 2020.
- WOLOSZYN, V. e NEJDL, W. *DistrustRank: Spotting False News Domains*. Proceedings of the 10th ACM Conference on Web Science (WebSci '18). Association for Computing Machinery, Nova York, EUA, p. 221–228, 2018.
- WU, L. e LIU, H. *Tracing Fake-News Footprints: Characterizing Social Media Messages by How they Propagate*. Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining (WSDM '18). Association for Computing Machinery, New York, NY, USA, p. 637–645, 2018.
- XIE, Y.; HUANG, X.; Xie, X. e JIANG, S. *A Fake News Detection Framework Using Social User Graph*. Anais da 2ª Conferência Internacional de Engenharia de Big Data (BDE). Association for Computing Machinery, Nova York, EUA, p. 55–61, 2020.
- ZHOUGHAN CHEN, Z. e FREIRE, J. *Proactive Discovery of Fake News Domains from Real-Time Social Media Feeds*. Web Conference 2020 (WWW '20). Association for Computing Machinery, New York, USA, p. 584–592, 2020.

APÊNDICE A - TABELAS DE EXTRAÇÃO DE DADOS DO MAPEAMENTO SISTEMÁTICO

Tabela 11 – Listagem de coleta de dados

A) Dados da publicação: [P01]	
Título:	Deciding among Fake, Satirical, Objective and Legitimate news: A multi-label classification system
Autor(es):	Janaína Ignácio de Moraes, Hugo Queiroz Abonizio, Gabriel Marques Tavares, André Azevedo da Fonseca e Sylvio Barbon Jr.
Fonte de Publicação:	Simpósio Brasileiro de Sistemas de Informação
Ano da Publicação:	2019
Resumo:	Os autores propuseram um Sistema de Apoio à Decisão (SAD) baseado em uma mineração de texto pipeline e um conjunto de novos recursos textuais que usam vários métodos multi-label para classificar artigos de notícias em dois domínios. Para validar a abordagem, um conjunto de métodos multi-rótulo foi avaliado com uma combinação de diferentes classificadores básicos e então comparados para uma abordagem multiclasse. O objetivo desta abordagem é classificar documentos em duas classes conceituais: falso / legítimo e satírico / objetivo, o que perfaz um total de 4 combinações de classe possíveis (objetivo-legítimo, objetivo-falso, satírico-legítimo e satírico-falso).
B) Dados derivados do objetivo:	
Software desenvolvido:	Sistema de Apoio à Decisão
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelos: RF, SVM e KNN Base de Dados: Lupa, Boatos e Própria
Aplicação (Testes realizados):	Método Usado: Classificação de Texto Recursos Usados: Corpo do texto Métricas: Acurácia e F1
Principais resultados:	Taxa total: 0,8 Os resultados relataram que a abordagem proposta foi classificada como adequado (0,80 Pontuação F1) ao abordar o cenário de notícias enganosas do desafio perspectiva desafiadora de modelagem multi-rótulo, superando os métodos multiclasse (0,71 pontuação F1) em um conjunto de dados de notícias da vida real coletados em vários portais de notícias.

Tabela 12 – Listagem de coleta de dados

A) Dados da publicação: [P02]	
Título:	Detecção de notícias falsas usando técnicas de deep learning
Autor(es):	Lucas Guarise
Fonte de Publicação:	Google Acadêmico
Ano da Publicação:	2019
Resumo:	O autor propõe um classificador de notícias na língua portuguesa brasileira com a capacidade de reconhecer notícias falsas utilizando de técnicas de aprendizado profundo. Utilizando pouco tratamento textual, o modelo propõe fazer a classificação de notícias falsas, utilizando o modelo HAN para alcançar o objetivo proposto.
B) Dados derivados do objetivo:	
Software desenvolvido:	Classificador de notícias falsas baseado em Deep Learning
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo: RNN e LSTM Base de Dados: Fake.br (NILC)
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto

	Métricas: Acurácia
Principais resultados:	Taxa total: 95,35% O classificador apresentou desempenho alto para os elementos dentro da base de dados, tanto para o conjunto de treinamento quanto para o conjunto de validação, conseguindo nesse último um recorde de 95,35% de acerto.

Tabela 12 – Listagem de coleta de dados

A) Dados da publicação: [P03]	
Título:	Aplicativo Verific.Ai: automatização de checagem de notícias nas eleições brasileiras de 2018
Autor(es):	Dario Brito Rocha Júnior; Anthony José Da Cunha Carneiro Lins; Alice Cristiny Ferreira De Souza; Luiz Felipe De Oliveira Libório; André Henrique De Brito Leitão e Flávio Henrique Souza Santos
Fonte de Publicação:	Google Acadêmico
Ano da Publicação:	2019
Resumo:	O trabalho propõe desenvolver um software que ajudasse os internautas a terem o discernimento sobre as verdadeiras notícias que circulavam no país nas eleições presidenciais de 2018. A partir daí compreender e estabelecer critérios para facilitar e agilizar a identificação de notícias falsas e verdadeiras na internet. Portanto a ferramenta foi desenvolvida em resultado de uma pesquisa aplicada e detalha o processo de criação, desenvolvimento e teste da plataforma Verific.ai – uma ferramenta de automatização de checagens de links noticiosos para aparelhos que atuam com o sistema operacional Android, que usa, para isso, uma infraestrutura de computação na nuvem (cloud computing) desenvolvida em linguagem de programação Python.
B) Dados derivados do objetivo:	
Software desenvolvido:	Verific.Ai
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: Data mining Base de Dados: Fatos e Lupa
Aplicação (Testes realizados):	Método usado: Link URL e Classificação de texto Recurso usado: Corpo do texto Métrica: Própria
Principais resultados:	Taxa total: Indefinido

Tabela 13 – Listagem de coleta de dados

A) Dados da publicação: [P04]	
Título:	A Closer Look at Fake News Detection: A Deep Learning Perspective
Autor(es):	Ayat Abedalla; Aisha Al-Sadi and Malak Abdullah
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	O trabalho se propõe para aprimorar o problema de notícias falsas e o processo de detecção para receber notícias falsas usando abordagens de aprendizado profundo. Usando o Conjunto de dados do Fake News Challenge (FNC-1), foi desenvolvido diferentes modelos para detectar notícias falsas com base na relação entre o título e o corpo do artigo.
B) Dados derivados do objetivo:	
Software desenvolvido:	Fake News Challenge (FNC-1)
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: CNN, LSTM Base de Dados: Artigos de notícias
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto Métricas: Acurácia

Principais resultados:	Taxa total: 0,712 O melhor modelo proposto alcançou 71,2% de precisão nos dados de teste oficiais, segundo os autores, até a data da pesquisa, esta pontuação não havia sido alcançada em estudos anteriores.
-------------------------------	--

Tabela 14 – Listagem de coleta de dados

A) Dados da publicação: [P05]	
Título:	A Fake News Detection Framework Using Social User Graph
Autor(es):	Yi Xie, Xixuan Huang, Xiaoxuan Xie e Shengyi Jiang
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	O modelo proposto foi baseado em rede social do usuário. Os autores um framework baseado em GraphSage para tarefa de classificação de comportamento de divulgação de notícias do usuário para aprender representações de recursos do usuário, usando multi-head para a representação de recurso do usuário para pesos diferentes ao mesmo tempo, melhor fusão de recursos de usuário e recursos de texto.
B) Dados derivados do objetivo:	
Software desenvolvido:	framework baseado em GraphSage
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: RST, SVM, LIWC, TIFDF, TriFN, Castillo, UCEM Base de dados: FakeNewsNet (BuzzFeed e PolitiFact)
Aplicação (Testes realizados):	Método usado: Notícias de redes sociais, classificação de texto e características do usuário. Recurso usado: Notícias de redes sociais Métricas: Precisão, Recall e F1
Principais resultados:	Taxa total: BuzzFeed (0,905; 1,0; 0,950) - PolitiFact (1,0; 1,0; 1,0). O desempenho do modelo proposto em ambos conjuntos de dados excede o melhor modelo UCEM anterior.

Tabela 15 – Listagem de coleta de dados

A) Dados da publicação: [P06]	
Título:	A Linguistic-Based Method that Combines Polarity, Emotion and Grammatical Characteristics to Detect Fake News in Portuguese
Autor(es):	Marcelo Pereira de Souza, Flávio Roberto Matias da Silva, Paulo Márcio Souza Freire e Ronaldo Ribeiro Goldschmidt.
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	O presente trabalho propõe um método estendido que, além da classificação gramatical e análise de sentimento baseada em polaridade, também usa a análise de emoções ao detectar Notícias Falsas escritas em português. O presente trabalho constrói modelos de aprendizado de máquina voltados à detecção de Fake Notícias. Para tanto, baseia-se na combinação de informações linguísticas, entre elas classificações gramaticais, polaridade e emoções extraídas de escritos de notícias previamente rotuladas como fake e não fake.
B) Dados derivados do objetivo:	
Software desenvolvido:	FNE
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Recurso usado: Naive Bayes, GradientBost. Base de Dados: Fake.br
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto e título Métricas: Acurácia
Principais resultados:	Taxa total: 0,92

	O método proposto apresentou resultados promissores em dados experimentais, obtendo precisão maior que 92%. Em média, o método proposto sobreveio os métodos baseados em polaridade e classificação gramaticais.
--	--

Tabela 16 – Listagem de coleta de dados

A) Dados da publicação:[P07]	
Título:	A Topic-Agnostic Approach for Identifying Fake News Pages
Autor(es):	Sonia Castelo, Thais Almeida, Anas Elghafari, Aécio Santos, Kien Pham, Eduardo Nakamura e Juliana Freire
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Apresentamos uma nova abordagem para detectar páginas da web de notícias falsas que utilizam recursos agnósticos de tópico. Por meio de uma avaliação experimental detalhada, mostraram que a abordagem classifica com precisão não apenas notícias políticas conforme os tópicos evoluem ao longo do tempo, mas também notícias de diferentes outros domínios, superando as abordagens baseadas em conteúdo ao usar significativamente menos recursos e não requer nenhum retreinamento frequente. Com isso para atingir este objetivo, propuseram uma classificação agnóstica de tópico (TAG) estratégia que usa recursos linguísticos e de marcação da web para identificar páginas de notícias falsas.
B) Dados derivados do objetivo:	
Software desenvolvido:	TAG (Classificação Agnóstica de Tópicos)
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: SVM + KNN + RF Base de Dados: PoliticalNews, Celebraty e US-Election
Aplicação (Testes realizados):	Método usado: Características: morfológicas, psicológica legibilidade e marcação web Recurso usado: Páginas web (título, conteúdo ou combinação de ambos) Métricas: Acurácia
Principais resultados:	Taxa total: 0,86 O classificador baseado em TAG supera o Detector para todos os conjuntos de dados, indicando que a tarefa de classificação de notícias falsas pode ser efetivamente realizada usando recursos agnósticos de tópico.

Tabela 17 – Listagem de coleta de dados

A) Dados da publicação: [P08]	
Título:	ACT: Automatic Fake News Classification Through Self-Attention
Autor(es):	Nujud Alosbhan.
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	O trabalho proposto é usado em interações conjuntas entre uma interação e vários artigos de apoio que lhe correspondem. Para a entrada do artigo, foi aplicado a rede neural LSTM. Uma vez que a entrada do artigo é longa por sua natureza, a saída da última etapa do LSTM pode não apresentar o inteiramente da semântica do artigo. O ACT então agrega todas as informações sobre a web contextos do artigo para sua reivindicação alvo, aplicando um voto majoritário para avaliar a reivindicação.
B) Dados derivados do objetivo:	
Software desenvolvido:	ACT - Classificação Automática de Notícias Falsas através de Auto atenção
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Recurso usado: LSTM, DeClarE. Base de Dados: Snopes, PolitiFact e Fonte Externa
Aplicação (Testes realizados):	Método usado: Classificação de texto

	Recurso usado: Corpo do texto Métricas:AUC, Precisão e F1
Principais resultados:	Taxa total: 0,75 A precisão geral do modelo ACT é de 75%. Os autores concluíram que a condução dos experimentos em três diferentes conjuntos reais de dados mundiais, comparando-os com as abordagens de última geração e analisando os resultados, o que mostrou melhorias de desempenho.

Tabela 18 – Listagem de coleta de dados

A) Dados da publicação: [P09]	
Título:	Beyond News Contents: The Role of Social Context for Fake News Detection
Autor(es):	Kai Shu, Suhanh Wang e Huan Liu
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	O contexto social durante o processo de divulgação de notícias nas redes sociais forma o tri-relacionamento inerente, o relacionamento entre editores, notícias e usuários, o que tem potencial para melhorar a detecção de notícias falsas. Os autores propõem uma abordagem que visa explorar informações auxiliares para melhorar a detecção de notícias falsas.
B) Dados derivados do objetivo:	
Software desenvolvido:	TriFN
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: Naive Bayes, Random Forest Base de dados: FakeNewsNet (BuzzFeed e PolitiFact)
Aplicação (Testes realizados):	Método usado: Relacionamento entre editores, notícias e usuários Recurso usado: Corpo do texto, usuários, usuários-notícias, editor-notícia Métricas: Acurácia, Precision, Recall e F1
Principais resultados:	Taxa total: BuzzFeed (0,864; 0,849; 0,893; 0,870) - PolitiFact (0,878; 0,867; 0,893; 0,880). Com esse resultado os autores demonstram que a proposta apresentada supera significativamente outros métodos de linha de base para detecção de notícias.

Tabela 19 – Listagem de coleta de dados

A) Dados da publicação: [P10]	
Título:	CIMTDetect: A Community Infused Matrix-Tensor Coupled Factorization Based Method for Fake News Detection
Autor(es):	Gaurav Bhatt, Aman Sharma, Shivam Sharma, Ankush Nagpal, Balasubramanian Raman e Ankush Mittal.
Fonte de Publicação:	ACM Library
Ano da Publicação:	2018
Resumo:	Neste artigo, foram abordados o problema de detecção das notícias falsas de mídia social, explorando a presença de eco comunidades de câmara (comunidades que compartilham as mesmas crenças) que existem dentro da rede social dos usuários.
B) Dados derivados do objetivo:	
Software desenvolvido:	CIMTDetect
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: SVM Base de dados: Fake NewsNet (BuzzFeed e PolitiFact)
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Notícias, usuário e comunidade Métricas: Precisão, Recall e F1

Principais resultados:	Taxa total: BuzzFeed (0,729; 0,923; 0,813) - PolitiFact (0,803; 0,842; 0,818) O CIMTDetect supera a linha de base com uma margem significativa em ambas as métricas de avaliação, bem como em ambos os conjuntos de dados abordados.
-------------------------------	---

Tabela 20 – Listagem de coleta de dados

A) Dados da publicação: [P11]	
Título:	Combining Neural, Statistical and External Features for Fake News Stance Identification
Autor(es):	Gaurav Bhatt, Aman Sharma, Shivam Sharma, Ankush Nagpal, Balasubramanian Raman e Ankush Mittal.
Fonte de Publicação:	ACM Library
Ano da Publicação:	2018
Resumo:	Nesta pesquisa é explorado uma sub tarefa para identificação de notícias falsas, e essa é a detecção de postura. Dado um artigo de notícias, a tarefa é determinar a relevância do corpo e sua reivindicação. Foi apresentada uma nova ideia que combina o neural, o estatístico e recursos externos para fornecer uma solução eficiente para este problema.
B) Dados derivados do objetivo:	
Software desenvolvido:	FNC-1
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: LSTM e GRU Base de dados: dados emergentes
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto e título Métricas: Score FNC
Principais resultados:	Taxa total: 75,2% Os resultados do conjunto de dados de teste FNC-1 na linha de base atingem uma pontuação de 75,2, que é melhor do que o desempenho e performance de todas as arquiteturas profundas apresentadas na pesquisa.

Tabela 21 – Listagem de coleta de dados

A) Dados da publicação: [P12]	
Título:	CSI: A Hybrid Deep Model for Fake News Detection
Autor(es):	Natali Ruchansky; Sungyong Seo e Yan Liu
Fonte de Publicação:	ACM Library
Ano da Publicação:	2017
Resumo:	Neste trabalho, foi proposto um modelo que combina todas as três características para uma previsão mais precisa e automatizada. Especificamente, foi incorporado o comportamento de ambas as partes, usuários e artigos, e o comportamento de grupo de usuários que propagam notícias falsas. Motivado pelas três características, foi proposto um modelo denominado CSI que é composto por três módulos: Capture, Score e Integrate.
B) Dados derivados do objetivo:	
Software desenvolvido:	CSI
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: LSTM, RNN Base de dados: Twitter e Weibo
Aplicação (Testes realizados):	Método usado: Classificação de texto, Resposta Usuário e Fonte. Recurso usado: Notícias, usuário e comunidade Métricas: Acurácia e F1
Principais resultados:	Taxa total: 0,8

	Experimentalmente na análise de dados do mundo real demonstra que o CSI atinge melhor precisão do que os modelos existentes e extrai representações latentes significativas ressentimentos de usuários e artigos.
--	---

Tabela 22 – Listagem de coleta de dados

A) Dados da publicação: [P13]	
Título:	DEFEND: Explainable Fake News Detection
Autor(es):	Kai Shu, Limeng Cui, Suhang Wang, Dongwon Lee e Huan Liu
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Neste artigo foi proposto a detecção explicável de notícias falsas. Foi desenvolvida uma sub-rede de co-atenção frase-comentário para explorar tanto o conteúdo de notícias quanto os comentários do usuário para capturar em conjunto frases explicáveis e dignas de verificação e comentários do usuário para detecção de notícias falsas.
B) Dados derivados do objetivo:	
Software desenvolvido:	DEFEND
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: DNN, RNN Base de dados: PoliticFact e Gossip
Aplicação (Testes realizados):	Método usado: Classificação de texto, Resposta Usuário e Fonte. Recurso usado: Corpo do texto, comentário usuários, frase-comentário Métricas: Acurácia, Precision, Recall e F1
Principais resultados:	Taxa total: GossipCop (0,808; 0,729; 0,782; 0,755) - PolitiFact (0,904; 0,902; 0,956; 0,928) Foram conduzidos os experimentos extensivos em reais conjuntos de dados mundiais e demonstraram que o método proposto não apenas supera significativamente a detecção de notícias falsas de última geração na pontuação F1, mas também identifica os principais comentários dos usuários que explicam por que uma notícia é falsa, melhor do que as linhas de base em Precisão.

Tabela 23 – Listagem de coleta de dados

A) Dados da publicação: [P14]	
Título:	DistrustRank: Spotting False News Domains
Autor(es):	Vinicius Woloszyn e Wolfgang Nejdl
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Neste artigo, foi proposto o DistrustRank, uma estratégia de aprendizagem semi-supervisionado, algoritmo que identifica sites de notícias não confiáveis com base apenas em uma manchete extraída do link do artigo de notícias. Nas notícias de sites, o artigo de notícias geralmente é compartilhado por meio de um link longo que contém o título das notícias e atua como um bom resumo de o conteúdo do artigo de notícias.
B) Dados derivados do objetivo:	
Software desenvolvido:	DistrustRank:
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: SVM Base de dados: SilimarWeb e Wikipédia
Aplicação (Testes realizados):	Método usado: Link URL, Classificação de texto Recurso usado: Corpo do texto Métricas: Precision, Recall e F1
Principais resultados:	Taxa total: (0,8; 0,7659; 0,7825) Em seus experimentos, o DistrustRank, segundo os autores, supera as abordagens supervisionadas em qualquer classificação e tarefa de classificação.

--	--

Tabela 24 – Listagem de coleta de dados

A) Dados da publicação: [P15]	
Título:	EANN: Event Adversarial Neural Networks for Multi-Modal Fake News Detection
Autor(es):	Yaqing Wang, Fenglong Ma, Zhiwei Jin, Ye Yuan, Guangxu Xun, Kishlay Jha, Lu Su e Jing Gao
Fonte de Publicação:	ACM Library
Ano da Publicação:	2018
Resumo:	Neste artigo foi proposto uma estrutura ponta a ponta chamada Rede Neural Adversarial de Eventos (EANN), que pode derivar recursos invariantes do evento e, assim, beneficiar a detecção de notícias falsas sobre eventos recém-chegados. Isso consiste de três componentes principais: o extrator de recursos multimodais, o falso detector de notícias e o discriminador de eventos.
B) Dados derivados do objetivo:	
Software desenvolvido:	EANN
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: CNN, VQA, NERALTALK, ATT-RNN Base de dados: Twitter e Weibo
Aplicação (Testes realizados):	Método usado: Características textuais e Visuais Recurso usado: Corpo do texto e imagem Métricas: Acurácia, Precisão, Recall e F1
Principais resultados:	Taxa total: Twitter (0,715; 0,822; 0,638; 0,719) - Weibo (0,827; 0,847; 0,812; 0,829) Os resultados experimentais mostram que o modelo EANN proposto podem superar os métodos de última geração e aprender a serem transferíveis representações de recursos.

Tabela 25 – Listagem de coleta de dados

A) Dados da publicação: [P16]	
Título:	Early Detection of Fake News “Before It Flies High”
Autor(es):	Fantahun Bogale Gereme e William Zhu
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Neste trabalho, foi proposto um modelo para detecção precoce de notícias falsas usando aprendizado profundo e conteúdo de notícias. Foi conduzido experimentos em dois conjuntos de dados do mundo real e um terceiro conjunto de dados que é obtido combinando os dois conjuntos de dados e embaralhou-os aleatoriamente.
B) Dados derivados do objetivo:	
Software desenvolvido:	Deep ConvNets
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: RNN, LSTM, CNN, NAIVE BAYES Base de dados: Kaggle e George McIntire
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto Métricas: Acurácia, Precisão, Recall e F1
Principais resultados:	Taxa total: Kagle (0,9904; 0,9933; 0,9876; 0,9905) - GeorgeMeltine (0,9732; 0,9918; 0,9544; 0,9728) Os resultados dos experimentos mostraram que a detecção precoce de notícias falsas usando conteúdo de notícias e aprendizagem profunda, sem esperar pela propagação de notícias, é alcançável e deve receber mais atenção para combater as notícias falsas de forma eficaz antes que se prolifere e engane muitas pessoas

Tabela 26 – Listagem de coleta de dados

A) Dados da publicação: [P17]	
Título:	Explainable Machine Learning for Fake News Detection
Autor(es):	Julio C. S. Reis, André Correia, Fabrício Murai, Adriano Veloso e Fabrício Benevenuto
Fonte de Publicação:	ACM Library
Ano da Publicação:	2019
Resumo:	Neste trabalho, foi conduzida uma profunda investigação exploratória que produziu centenas de milhares de modelos de um amplo e diversificado conjunto de recursos. Esses modelos são imparciais no sentido de que suas características são escolhidas aleatoriamente a partir de um conjunto de recursos disponíveis.
B) Dados derivados do objetivo:	
Software desenvolvido:	Detecção de notícias falsa usando Aprendizado de Máquina
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: Gradient Boosting Base de dados: BuzzFace (BuzzFeed)
Aplicação (Testes realizados):	Método usado: Classificação de texto Recurso usado: Corpo do texto de redes sociais Métricas: AUC
Principais resultados:	Taxa total: 0,85 A abordagem propõe novos recursos, como aqueles relacionados à fonte domínio, que aparecem dentro dos melhores modelos até cinco vezes mais frequentemente do que outros recursos.

Tabela 27 – Listagem de coleta de dados

A) Dados da publicação: [P18]	
Título:	Fake News Detection via Knowledge-driven Multimodal Graph Convolutional Networks
Autor(es):	Sebastian Tschiatschek, Adish Singla, Manuel Gomez Rodriguez, Arpit Merchant e Andreas Krause.
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	O trabalho proposto considera o aproveitamento de sinais de multidão para detectar notícias falsas e é motivado por ferramentas recentemente introduzidas pelo Facebook que permitem aos usuários sinalizar notícias falsas. Ao agregar sinalizadores de usuários, o objetivo é selecionar um pequeno subconjunto de notícias todos os dias, enviá-los para um especialista.
B) Dados derivados do objetivo:	
Software desenvolvido:	KMGCN
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: KMGCN Base de dados: PHEME e Weibo
Aplicação (Testes realizados):	Método usado: Características textuais, Gráficas e Visuais Recurso usado: Corpo do texto e imagem Métricas: Acurácia, Precisão, Recall e F1
Principais resultados:	Taxa total: Weibo (0,8863; 0,9100; 0,9645; 0,8834) - PHEME (0,8756; 0,8762; 0,8765; 0,8764) Nos experimentos foi demonstrado a eficácia da abordagem proposta por meio de experimentos intensivos e mostraram o poder de alavancar a comunidade de sinais para detecção de notícias falsas.

Tabela 28 – Listagem de coleta de dados

A) Dados da publicação: [P19]	
Título:	FANG: Leveraging Social Context for Fake News Detection Using Graph Representation
Autor(es):	Van-Hoang Nguyen, Kazunari Sugiyama, Preslav Nakov e Min-Yen Kan
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	A abordagem do Factual News Graph (FANG), é uma nova forma de representação gráfica de contexto social e estrutura de aprendizagem para detecção de notícias falsas. Ao contrário dos modelos contextuais lá propostos anteriormente que direcionaram performance, o objetivo é no aprendizado de representação.
B) Dados derivados do objetivo:	
Software desenvolvido:	FANG
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: LSTM, RNN Base de dados: Próprio
Aplicação (Testes realizados):	Método usado: Características textuais, Gráficas e Visuais Recurso usado: Corpo do texto, comentário usuários, frase-comentário Métricas: AUC
Principais resultados:	Taxa total: 0,7518 FANG produziu resultados significativos para a tarefa de detecção de notícias falsas, e é robusto no caso de dados de treinamento limitados. As representações aprendidas por FANG generalizam-se para tarefas relacionadas, como prever a verdade do relato de um meio de notícias

Tabela 29 – Listagem de coleta de dados

A) Dados da publicação: [P20]	
Título:	Learning to Detect Misleading Content on Twitter
Autor(es):	Christina Boididou, Symeon Papadopoulos, Lazaros Apostolidis e Yiannis Kompatsiaris
Fonte de Publicação:	ACM Library
Ano da Publicação:	2017
Resumo:	Neste artigo, foi abordado o problema da multimídia enganosa detecção de conteúdo no Twitter em tempo real. Foi proposto uma série de novos recursos e uma nova adaptação de evento de aprendizagem semissupervisionado, abordagem que ajuda a generalizar os recursos de detecção de modelos para conteúdo não visto, mesmo quando o evento de interesse é de natureza diferente em comparação com aquela usada para treinamento.
B) Dados derivados do objetivo:	
Software desenvolvido:	Técnicas de análise de multimídia
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: Random Forest Base de dados: Handbook
Aplicação (Testes realizados):	Método usado: Texto, Idioma e Link URL Recurso usado: Corpo do texto, usuários, fonte publicação Métricas: Acurácia e F1
Principais resultados:	Taxa total: (94,06%, 0,934) O método proposto atingiu o segundo melhor desempenho (F = 0,934), chegando o desempenho a quase igual o melhor executado pelo MCG-IC.

Tabela 30 – Listagem de coleta de dados

A) Dados da publicação: [P21]	
Título:	Leveraging the Crowd to Detect and Reduce the Spread of Fake News and Misinformation
Autor(es):	Jooyeon Kim, Behzad Tabibian, Alice Oh, Bernhard Schölkopf e Manuel Gomez-Rodriguez
Fonte de Publicação:	ACM Library
Ano da Publicação:	2018
Resumo:	Neste artigo, primeiro foi apresentada uma representação flexível do procedimento movido em massa para reduzir a disseminação de notícias falsas e desinformação, usando a estrutura do ponto temporal marcado processos. Em seguida, desenvolveram um algoritmo online escalonável, Curb, para selecionar quais histórias enviar para verificação de fatos e quando fazê-lo para reduzir de forma eficiente a disseminação de desinformação com prováveis garantias.
B) Dados derivados do objetivo:	
Software desenvolvido:	CURB
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: CURB Base de dados: Twitter e Weibo
Aplicação (Testes realizados):	Método usado: Link URL Recurso usado: Corpo do texto de redes sociais Métricas: Precisão e redução
Principais resultados:	Taxa total: (Twitter (0,7) - Weibo (0,9)) Experimentos em dois mundos reais conjuntos de dados coletados do Twitter e do Weibo mostram que nosso algoritmo pode ser capaz de reduzir efetivamente a disseminação de notícias falsas e desinformação.

Tabela 31 – Listagem de coleta de dados

A) Dados da publicação: [P22]	
Título:	Proactive Discovery of Fake News Domains from Real-Time Social Media Feeds
Autor(es):	Zhoushan Chen e Juliana Freire
Fonte de Publicação:	ACM Library
Ano da Publicação:	2020
Resumo:	Neste artigo, foi apresentado um sistema de descoberta automática que exhibe proativamente domínios de notícias falsas antes de serem sinalizados por usuários. O sistema proposto opera em duas etapas: primeiro, ele usa o Twitter feeds para descobrir estruturas de compartilhamento de usuários para descobrir sites de políticas; em seguida, ele usa um classificador agnóstico de tópico para pontuar e classificar domínios recém-descobertos.
B) Dados derivados do objetivo:	
Software desenvolvido:	Sistema de descoberta de notícias falsas de mídia social em tempo real
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: SVM Base de dados: PoliticalFake News, Politifact
Aplicação (Testes realizados):	Método usado: Link URL Recurso usado: Corpo do texto de redes sociais Métricas: AUC
Principais resultados:	Taxa total: 89% Foi provado a capacidade do sistema em descobrir domínios de notícias falsas.

	<p>Mostraram como avaliaram e selecionaram a melhor configuração do modelo.</p> <p>Visualizaram padrões interessantes por trás da rede de notícias falsas dos domínios. Terminamos esta seção com uma caracterização do Twitter contas que tweetam mais domínios falsos.</p>
--	--

Tabela 32 – Listagem de coleta de dados

A) Dados da publicação: [P23]	
Título:	Tracing Fake-News Footprints: Characterizing Social Media Messages by How They Propagate
Autor(es):	Liang Wu e Huan Liu
Fonte de Publicação:	ACM Library
Ano da Publicação:	2018
Resumo:	O presente artigo foca na modelagem de propagação de mensagens em uma rede social. Especificamente, foi proposto uma nova abordagem, Trace Miner, para (1) inferir embeddings de usuários de redes sociais com estruturas de redes sociais; e (2) utilizar um LSTM-RNN para representar e classificar as vias de propagação de uma mensagem.
B) Dados derivados do objetivo:	
Software desenvolvido:	TraceMiner
Tipos de ferramentas, metodologias ou estratégias de reconhecimento:	Modelo usado: LSTM, RNN Base de dados: Snopes
Aplicação (Testes realizados):	Método usado: Link URL Recurso usado: Corpo do texto de redes sociais Métricas: F1
Principais resultados:	Taxa total: 0,9124 Os resultados experimentais em conjuntos de dados do mundo real mostraram a superioridade da abordagem proposta sobre abordagens de última geração na tarefa de detecção de notícias falsas e categorização de notícias.