



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

SARA BANDEIRA COUTINHO

Seleção de ensemble heterogêneo para a detecção de Fake News

Recife

2023

SARA BANDEIRA COUTINHO

Seleção de ensemble heterogêneo para a detecção de Fake News

Trabalho apresentado ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Inteligência computacional

Orientador (a): George Darmiton da Cunha Cavalcanti

Coorientador (a): Rafael Menelau Oliveira e Cruz

Recife

2023

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

C871s Coutinho, Sara Bandeira
Seleção de ensemble heterogêneo para a detecção de fake news / Sara Bandeira Coutinho. – 2023.
185 f.: il., fig., tab.

Orientador: George Darmiton da Cunha Cavalcanti.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2023.
Inclui referências e apêndices.

1. Inteligência computacional. 2. Diversidade. I. Cavalcanti, George Darmiton da Cunha (orientador). II. Título.

006.31 CDD (23. ed.) UFPE - CCEN 2023-157

Sara Bandeira Coutinho

“Seleção de ensemble heterogêneo para a detecção de Fake News”

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação. Área de Concentração: Inteligência Computacional

Aprovado em: 2 de agosto de 2023.

BANCA EXAMINADORA

Prof. Adiel Teixeira de Almeida Filho
Centro de Informática / UFPE

Prof. Dr. Ellen Polliana Ramos Souza
Unidade Acadêmica de Serra Talhada / UFRPE

Prof. Dr. George Darmiton da Cunha Cavalcanti
Centro de Informática / UFPE
(Orientador)

AGRADECIMENTOS

Sinto-me realizada por chegar até aqui e compreendo que isso jamais seria possível sem todo o apoio que obtive durante o mestrado. Agradeço primeiramente a Deus que me deu essa oportunidade e me susteve durante todo esse período, guiando-me até aqui.

Agradeço aos meus orientadores, George Darmiton e Rafael Menelau, os quais, com maestria, me guiaram nesta pesquisa. Indubitavelmente o suporte acadêmico que obtive de vocês foi essencial e faço notória minha gratidão por acreditarem em mim, pela disponibilidade, pela paciência e pelo apoio dados.

Ademais, agradeço a minha família que esteve ao meu lado em todos os momentos durante a realização desta pesquisa. De igual modo, o apoio de vocês foi essencial e foi muito especial para mim. Por fim, agradeço a todos que, de alguma forma, contribuíram para meu crescimento nesta pesquisa, e, em particular, a minha amiga Cynthia, a qual estimo muito sucesso em seu doutorado. A todos, meus sinceros agradecimentos.

RESUMO

A disseminação de *Fake News* tornou-se um dos problemas da sociedade atual. Uma solução para esse problema é detectar a veracidade dos textos das notícias usando sistemas automatizados, dada a existência da dificuldade do ser humano de detectá-las, concernente ao viés de confirmação, as preferências pessoais que influenciam os sistemas de recomendação, bem como a grande quantidade de dados gerados *online*, que inviabiliza uma inspeção manual. Diversas abordagens relacionadas ao aprendizado de máquina têm sido propostas na literatura. Dentre elas, o uso de sistemas de múltiplos classificadores mostrou-se promissor por obter resultados melhores do que sistemas que usam apenas um classificador. No entanto, para serem eficientes, esses sistemas precisam de que seus classificadores sejam diversos, e para isso, na literatura, algumas estratégias são encontradas para obtê-la, tal qual o uso de classificadores heterogêneos e uma análise sobre agrupamentos de classificadores, construídos a partir da informação de dissimilaridade entre eles. Contudo, esse tipo de abordagem demanda uma inspeção visual. Como alternativa, este trabalho propõe um sistema de múltiplos classificadores que seleciona subconjuntos de um *pool* de classificadores heterogêneos, a partir de uma análise automática sob diferentes níveis de dissimilaridade entre os classificadores. Deseja-se que os classificadores selecionados sejam diversos e, para esse fim, cada classificador no *pool* é representado usando a medida de diversidade e um algoritmo de agrupamento hierárquico, que agrupa os classificadores semelhantes, facilitando a seleção dos classificadores mais diversos. Em complemento, para esta etapa, considerou-se escolhê-los a partir daqueles que apresentaram um maior desempenho, em uma análise individual, nas métricas de avaliação, a fim de que fosse obtido um subconjunto com maior diversidade e com classificadores que tiveram uma maior capacidade de generalização. Nos experimentos, foram considerados seis conjuntos de dados, de diferentes contextos e quantidades de classe. O método proposto foi comparado com outras três heurísticas de seleção e com abordagens da literatura. As métricas adotadas para avaliar os resultados foram acurácia, precisão, revocação e medida f1. O método proposto apresentou resultados promissores, alcançando o maior desempenho, com relação aos demais, em 3 dos 6 conjuntos adotados, os quais apresentaram apenas duas classes.

Palavras-chaves: detecção de fake news; sistema de múltiplos classificadores; diversidade; agrupamento hierárquico.

ABSTRACT

The spread of Fake News has become one of the problems of today's society. A solution to this problem is to detect the veracity of news texts using automated systems given the difficulty for humans to detect them, concerning confirmation bias, personal preferences that influence recommendation systems, as well as the large amount of data generated online, that makes manual inspection unfeasible. Several approaches related to machine learning have been proposed in the literature. Among them, the use of multiple classifier systems has shown to be promising for obtaining better results than systems that use only one classifier. However, to be efficient, these systems need their classifiers to be diverse, and for this, in the literature, some strategies are found to obtain it, such as the use of heterogeneous classifiers and an analysis of the groupings of classifiers, constructed from the dissimilarity information between them. However, this type of approach demands a visual inspection. As an alternative, this work proposes a multiple classifier systems that selects subsets of a pool of heterogeneous classifiers, from an automatic analysis under different levels of dissimilarity between the classifiers. It is desired to the selected classifiers to be diverse, and to that end, each classifier in the pool is represented using the diversity measure and a hierarchical clustering algorithm that groups similar classifiers, making it easier to select the most diverse classifiers. In addition, for this stage, it was considered to choose them from those that presented a greater performance, in an individual analysis, in the evaluation metrics, in order to obtain the subset with greater diversity and with classifiers that had a greater generalization ability. In the experiments, six datasets were considered, from different contexts and class quantities. The method was compared with three other selection heuristics and with literature approaches. The metrics adopted to evaluate the results were accuracy, precision, recall and f1 score. The proposed method presented promising results, reaching the highest performance, to the others, in 3 of the 6 adopted datasets, which presented only two classes.

Keywords: fake news detection; multiple classifier systems; diversity; hierarquical clustering.

LISTA DE FIGURAS

Figura 1 – Processo da detecção de <i>Fake News</i>	19
Figura 2 – Aplicação das técnicas de BoW.	22
Figura 3 – Fluxograma do processo de um MCS.	24
Figura 4 – Ilustração do método proposto.	35
Figura 5 – Parâmetros da <i>linkage</i>	41
Figura 6 – Estrutura de um dendrograma genérico.	42
Figura 7 – Diferentes estados do sistema para valores de k diferentes para seleção no dendrograma.	43
Figura 8 – Representação de tabela com exemplos dos grupos A, B, C e D.	45
Figura 9 – Fluxo das etapas de normalização do texto.	54
Figura 10 – Nuvens de palavras a partir do conjunto Senti.	55
Figura 11 – Maiores resultados obtidos pelo Liar para o grupo D e cada métrica de avaliação, considerando os valores de k , variando de 1 a 40.	60
Figura 12 – Resultados obtidos para o cálculo das métricas sobre as classificações no conjunto Liar considerando MCS com diferentes grupos dos quais a quantidade de elementos varia em função do k	61
Figura 13 – Número de acertos pelo número de k para o conjunto de dados Liar, grupo D e métrica acc.	62
Figura 14 – Desempenho dos grupos.	68
Figura 15 – Dados obtidos após a aplicação da técnica CV em diferentes conjuntos.	69
Figura 16 – Mapa de calor sobre o tempo gasto para execução de etapas de treinamento dos pares monolíticos e grupos A, B, C e D para o Liar.	73
Figura 17 – Gráficos de bolha apresentando os maiores resultados obtidos pelo método proposto para cada métrica em cada conjunto.	81
Figura 18 – Gráficos de linha para resultados das métricas em função do k	82

LISTA DE TABELAS

Tabela 1 – Trabalhos que aplicaram a aprendizagem de máquina para a detecção de FN.	29
Tabela 2 – Vantagens e limitações encontradas pelo método proposto.	48
Tabela 3 – Características dos conjuntos de dados Liar, Senti, Covid, Fa-Kes, Ott e Kaggle.	51
Tabela 4 – Hiper-parâmetros usados em cada algoritmo.	57
Tabela 5 – Correlação das métricas com k para cada meta-classificador adotado no grupo D.	61
Tabela 6 – Pares e combinações de pares mais frequentes nos MCS que obtiveram os maiores resultados.	67
Tabela 7 – Resultados encontrados na literatura e pelo método proposto para cada conjunto de dados e métrica acc.	71
Tabela 8 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Liar.	83
Tabela 9 – Lista com os grupos obtidos para cada valor de k para o conjunto Liar.	84
Tabela 10 – Resultados dos classificadores para o conjunto Liar.	89
Tabela 11 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Senti.	92
Tabela 12 – Lista com os grupos obtidos para cada valor de k para o conjunto Senti.	93
Tabela 13 – Resultados dos classificadores para o conjunto Senti.	99
Tabela 14 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Covid.	102
Tabela 15 – Lista com os grupos obtidos para cada valor de k para o conjunto Covid.	103
Tabela 16 – Resultados dos classificadores para o conjunto Covid.	109
Tabela 17 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Fa-Kes.	112
Tabela 18 – Lista com os grupos obtidos para cada valor de k para o conjunto Fa-Kes.	117
Tabela 19 – Resultados dos classificadores para o conjunto Fa-Kes.	122
Tabela 20 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Ott.	127
Tabela 21 – Lista com os grupos obtidos para cada valor de k para o conjunto Ott.	132

Tabela 22 – Resultados dos classificadores para o conjunto Ott.	137
Tabela 23 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Kaggle.	142
Tabela 24 – Lista com os grupos obtidos para cada valor de k para o conjunto Kaggle.	147
Tabela 25 – Resultados dos classificadores para o conjunto Kaggle.	152
Tabela 26 – Resultados do teste de aderência para o conjunto Fa-Kes. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	159
Tabela 27 – Resultados do teste de aderência para o conjunto Ott. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	162
Tabela 28 – Resultados do teste de aderência para o conjunto Kaggle. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	166
Tabela 29 – Resultados do teste de hipótese para conjunto Fa-Kes. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	172
Tabela 30 – Resultados do teste de Hipótese para o conjunto Ott. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	178
Tabela 31 – Resultados do teste de Hipótese para o conjunto Kaggle. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do <i>p-value</i> obtido entre parêntesis.	185

LISTA DE ABREVIATURAS E SIGLAS

A	Algoritmos de classificação
acc	Acurácia
BoW	Bag-of-Words
CNN	Convolutional Neural Network
CV	Count Vectorizer
E	Técnicas de representação de características
ET	Extra Trees
f1	Medida f1
FAST	Fasttext
GLOVE	Global Vectors of Word representation
KNN	K-Nearest Neighbors
LR	Logistic Regression
M	Matriz de dissimilaridade
MCS	Sistema de Múltiplos Classificadores
MLP	Multi-Layer Perceptron
NB	Naive Bayes
NLP	Processamento de Linguagem Natural
pre	Precisão
rec	Revocação
RF	Random Forest
SVM	Support Vector Machine
TF-IDF	Term Frequency – Inverse Document Frequency
W2V	Word2Vec
WE	Word Embedding

LISTA DE SÍMBOLOS

Γ	Conjunto de dados de treino
Γ'	Conjunto de dados de treino após o pré-processamento
δ	Conjunto de dados de validação
γ	Conjunto de dados de teste
E	Conjunto de técnicas de representação de características com uma quantidade m de elementos. $E = \{E_0, E_1, E_2, \dots, E_m\}$.
e	Sentença após a aplicação da técnica E . $e = \{e_0, e_1, e_2, \dots, e_m\}$
A	Conjunto de algoritmos de classificação com uma quantidade n de elementos. $A = \{A_0, A_1, A_2, \dots, A_n\}$
a	Predições após a aplicação do algoritmo de classificação. $a = \{a_0, a_1, a_2, \dots, a_n\}$
M	Matriz de dissimilaridade de dimensão $(m \times n) \times (m \times n)$

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	15
1.2	OBJETIVO	17
1.3	CONTRIBUIÇÕES	17
1.4	ESTRUTURA DA DISSERTAÇÃO	18
2	BASE CONCEITUAL	19
2.1	PROCESSAMENTO DE LINGUAGEM NATURAL	20
2.2	APRENDIZAGEM DE MÁQUINA	24
3	TRABALHOS RELACIONADOS	28
3.1	ABORDAGENS PARA A DETECÇÃO DE <i>FAKE NEWS</i>	28
4	MÉTODO PROPOSTO	34
4.1	PRÉ-PROCESSAMENTO E REPRESENTAÇÃO DE CARACTERÍSTICAS	36
4.2	TREINAMENTO DOS ALGORITMOS	36
4.3	MATRIZ DE DISSIMILARIDADE	37
4.4	SELEÇÃO DOS SUBCONJUNTOS	39
4.5	INTEGRAÇÃO DO SUBCONJUNTO	46
4.6	VANTAGENS E LIMITAÇÕES DO MÉTODO	47
5	METODOLOGIA EXPERIMENTAL	50
5.1	CONJUNTOS DE DADOS	50
5.2	PRÉ-PROCESSAMENTO	53
5.3	HIPER-PARÂMETROS DOS ALGORITMOS	56
5.4	MÉTRICAS DE AVALIAÇÃO	57
6	RESULTADOS E DISCUSSÕES	59
6.1	ANÁLISE DO DESEMPENHO	59
6.2	ANÁLISE DO CUSTO COMPUTACIONAL	72
6.3	SÍNTESE DOS RESULTADOS	73
7	CONCLUSÃO	75
	REFERÊNCIAS	77
	APÊNDICE A – RESULTADOS GERAIS PARA O MÉTODO PRO-	
	POSTO	80

APÊNDICE B – RESULTADOS LIAR	83
APÊNDICE C – RESULTADOS SENTI	92
APÊNDICE D – RESULTADOS COVID	102
APÊNDICE E – RESULTADOS FA-KES	111
APÊNDICE F – RESULTADOS OTT	126
APÊNDICE G – RESULTADOS KAGGLE	141
APÊNDICE H – RESULTADOS TESTES ESTATÍSTICOS	156

1 INTRODUÇÃO

A propagação de notícias falsas é um problema que ocorreu em vários momentos da história da humanidade. De acordo com (POSETTI; MATTHEWS, 2018), há mais de 2000 anos, no Império Romano houve uma disputa de poder em que Otaviano propagou notícias falsas sobre Antônio, a fim de obter vantagens sobre seu concorrente. Um meio de comunicação que sempre foi muito utilizado para a divulgação de mensagens foi a fala. Contudo, foi relatado em (POSETTI; MATTHEWS, 2018) o uso de moedas para gravação de textos nelas. Dessa forma, as ideias eram propagadas de outra maneira, o que provavelmente possibilitou alcançar rapidamente um público maior do que somente através da comunicação verbal.

Com o passar dos anos, os meios de comunicação se diversificaram, sobretudo devido ao avanço tecnológico, o qual possibilitou o desenvolvimento de ambientes virtuais. Através destes, o mundo inteiro passou a se conectar rápido e facilmente, impulsionado pela massificação da internet, da criação de redes sociais e de aplicativos, como também pelo desenvolvimento de dispositivos eletrônicos. Assim, o acesso à informação tornou-se democratizado e veloz, proporcionando muitos benefícios à sociedade. Entretanto, o espalhamento das notícias falsas, comumente denominadas de *Fake News* (FN), foi um fator recorrente e, desta vez, de forma mais intensa, gerando diversas consequências negativas à sociedade.

Dentre as áreas sociais impactadas negativamente pela propagação das FN, tem-se a política. De acordo com (ALLCOTT; GENTZKOW, 2017), em 2016, é possível que a eleição presidencial americana tenha sido marcada pela influência da propagação de notícias falsas, sobretudo, impulsionado pelo fato de as pessoas considerarem como verídicas mensagens compartilhadas nas redes sociais que corroborem com suas tendências pessoais, o que pode gerar um viés político. Ademais, a saúde também foi outra área fortemente impactada, uma vez que, dado o isolamento social durante a pandemia da Covid-19, em meados dos anos 2020, o uso das mídias sociais se tornou essencial para a comunicação. Segundo (PATWA et al., 2021), o compartilhamento das informações nesse período foi tão intenso e rápido que ocasionou em uma grande quantidade de informações, fenômeno conhecido como infodemia. Com isso, de acordo com (SURENDRAN et al., 2021), uma grande quantidade de notícias falsas sobre a Covid-19 foram espalhadas, trazendo desinformação à população durante um cenário mundial extremamente delicado. Devido a consequências como essas, em áreas tão importantes para a sociedade, tornou-se imprescindível o combate à propagação das FN.

1.1 MOTIVAÇÃO

A fim de evitar o compartilhamento das notícias falsas, em primeiro lugar, é necessário que elas sejam identificadas. Todavia, fazer essa classificação é uma tarefa que pode ser difícil para o ser humano, em decorrência do fator viés de confirmação, relatado em (BEAUVAIS, 2022), que o induz a acreditar no que for mais convincente. Além disso, de acordo com as ideias de (BUZEA; TRAUSAN-MATU; REBEDEA, 2022), à medida que o usuário de uma mídia social a utiliza, ele compartilha informações que podem indicar suas preferências, facilitando com que receba notícias das quais esteja mais propenso a acreditar, especialmente sendo um público mais jovem, cuja maioria costuma utilizar frequentemente mídias sociais. Ademais, segundo as ideias de (ALONSO et al., 2021), o uso intenso dessas mídias e a rápida propagação das notícias culminam numa elevada quantidade de dados gerados online, que inviabiliza uma inspeção manual. Em resposta a essas dificuldades, soluções baseadas em recursos computacionais foram desenvolvidas, a fim de que fosse possível identificar o tipo de notícia de modo mais rápido e eficiente durante a classificação do conteúdo textual.

Sob esse contexto, na literatura, encontram-se diversas propostas de aprendizagem de máquina para soluções computacionais de detecção de FN. Muitas delas utilizam sistemas híbridos, os quais, consoante as ideias de (WOŹNIAK; GRANA; CORCHADO, 2014), baseiam-se no uso de um conjunto de elementos, como os classificadores, que aproveitam o potencial de cada um deles para aperfeiçoar juntos determinada atividade, tal qual é adotado no trabalho (WANG, 2017) para a detecção de FN. Seguindo essa linha, uma abordagem de classificação promissora, descrita em (LUDMILA, 2004), é o uso de Sistemas de Múltiplos Classificadores (MCS), o qual se baseia na obtenção de um tipo de sistema híbrido, ou *ensemble*, composto a partir de um grupo selecionado de classificadores para obter um único classificador final com uma maior capacidade de generalização, haja vista a união dos aprendizados que o compõem. Em (DIETTERICH, 2000), são destacados os aspectos representacional, estatístico e computacional que fazem esse tipo de abordagem ser vantajosa para a classificação. A respeito de cada um deles, o representacional está relacionado no que tange a encontrar uma fronteira de separação, mais adaptada em problemas que apresentam uma distribuição complexa dos dados; o computacional por possibilitar um treinamento eficiente em pequenos conjuntos de dados; e o estatístico dada a redução da probabilidade de erro de classificação.

Sendo assim, para que a adoção do MCS de fato proporcione essas vantagens, os classificadores do conjunto precisam aprender de forma diferente para capturarem os padrões nas

mais diversas representações de dados e, dessa forma, seja reduzir a chance de erro do sistema. De acordo com (SANTANA et al., 2006), escolher classificadores que não possuam aprendizado redundante é uma atividade difícil, sendo possível que não ocorra aumento da capacidade de generalização a depender das escolhas. Ainda, compreende-se que pode não ser simples identificar como os classificadores aprenderão em determinados dados, dificultando, em uma primeira análise, inferir-se quais aprendem diferentemente entre si. Especialmente considerando o aprendizado de padrões em textos, que requer, além da utilização de algoritmos de aprendizagem, uma transformação numérica para tal, como no caso da classificação de FN.

Além disso, corroborando com essa linha, em (LUDMILA, 2004) é destacada a relevância da presença de diversidade num comitê de classificadores, elucidando em suas ideias que esta reside no fato dos classificadores acertarem em dados diferentes, de modo a garantir que eles aprendam em diferentes regiões de competência, o que significa em diferentes locais do espaço de dados em que eles estejam concentrados. O efeito da diversidade em um conjunto de classificadores é de sobremodo relevante que, segundo as ideias de (SANTANA et al., 2006), um subconjunto de classificadores que apresente uma diversidade maior entre si, é capaz de aprender tão quanto o conjunto total, do qual foi selecionado, ratificando a importância dela para o desempenho do MCS.

Tendo em vista que obter a diversidade num conjunto de classificadores é difícil, na literatura alguns aspectos foram apontados como catalisadores para isso. Em (HSU; SRIVASTAVA, 2009), um primeiro fator mencionado é o uso de conjuntos heterogêneos de classificadores, ou seja, quando estes são obtidos por técnicas diferentes, o conjunto de classificadores é capaz de alcançar uma diversidade maior do que quando são obtidos por técnicas iguais, seja através de técnicas de representação de características dos textos ou seja por meio de algoritmos, para o caso da detecção de FN. Além disso, um segundo aspecto interessante, de acordo com as ideias de (LUDMILA, 2004), é a realização de uma análise sobre grupos de classificadores observados em um agrupamento, construído a partir da informação de dissimilaridade entre eles, como apoio à detecção dos classificadores mais diversos entre si, encontrados em grupos diferentes. Nesse viés, em (CRUZ; SOUSA; CAVALCANTI, 2022), foi utilizada uma abordagem baseada na construção de um gráfico, de 2 dimensões, denominado *Classifier Projection Space* (CPS), para detecção visual dos grupos, pela proximidade de elementos de um mesmo grupo no gráfico dada a similaridade entre eles, e posterior seleção manual dos classificadores. Em contrapartida, em (LUDMILA, 2004) é apresentada ainda a possibilidade de analisar esses grupos a partir de diferentes níveis de similaridade através do agrupamento hierárquico. Isto sugere que,

embora um conjunto de classificadores apresente diversidade, pode haver um subconjunto de elementos dentro dele que também seja diverso entre si e obtenha um desempenho diferente, logo sendo interessante realizar uma análise da diversidade nesse sentido para a escolha dos classificadores.

Dessa forma, compreende-se que a adoção de um MCS pode ser uma solução que atenda satisfatoriamente a detecção de FN. Além disso, nota-se que é imprescindível avaliar a diversidade existente entre os classificadores para se obter um MCS que apresente as 3 vantagens citadas anteriormente. Ainda, constata-se que existem estratégias que podem ser adotadas para alcançar essa diversidade entre os classificadores. Em posse disso, resume-se, para este trabalho, as seguintes motivações: a necessidade de solucionar o problema da propagação de FN pela identificação delas via sistemas computacionais de classificação de notícias, as vantagens que podem ser trazidas ao desempenho do processo classificatório mediante a adoção de um MCS para construção desses sistemas, bem como a dificuldade em se obter um sistema que seja diverso e ainda a existência de aspectos que apoiem a análise da diversidade, as quais serviram de base para nortear o objetivo do trabalho.

1.2 OBJETIVO

A partir das motivações relatadas na Seção 1.1, este trabalho propõe um método que seleciona, automaticamente, um subconjunto diverso, do *pool* de classificadores, para detecção de FN. O subconjunto selecionado se constitui um ensemble heterogêneo pois é composto por classificadores formados através da adoção de diferentes técnicas de representação de características e algoritmos de aprendizagem. A seleção do subconjunto é realizada após uma análise da diversidade dos classificadores utilizando agrupamento hierárquico, a fim de encontrar os classificadores, ou seja, os pares de técnicas de representação de características e de classificador, que sejam complementares, observando diferentes níveis de semelhança entre eles e, com o apoio de uma heurística, são selecionados os subconjuntos, focando no desempenho obtido pelos classificadores individualmente em uma métrica de avaliação.

1.3 CONTRIBUIÇÕES

Partindo do objetivo desta pesquisa, a proposta foi avaliada considerando 6 conjuntos de dados e 4 métricas de avaliação, além da comparação com outras 3 heurísticas de sele-

ção do subconjunto de classificadores e abordagens da literatura. Dessa forma, as principais contribuições deste trabalho são:

1. Uso de MCS aplicado à detecção de FN.
2. Estratégia para selecionar automaticamente os pares (técnicas de extração de características, classificador) mais diversos que serve como um elo para o desempenho final do sistema de MCS na atividade de classificação.
3. A adoção de diferentes recursos na metodologia experimental a partir de estudos sobre a literatura de detecção de FN.


1.4 ESTRUTURA DA DISSERTAÇÃO

A partir desta seção, o trabalho está disposto em 6 capítulos que descrevem com mais detalhes os principais aspectos desta pesquisa. O Capítulo 2 apresenta os conceitos relativos a FN que sustentam o entendimento do método e da temática trabalhada. O Capítulo 3 relata um estudo sobre a literatura, mostrando trabalhos relacionados e suas abordagens para detectar FN. No Capítulo 4, apresenta-se por sua vez, o método proposto, sua arquitetura e cada uma das suas etapas, destacando o aspecto inovador que o método traz. O Capítulo 5 descreve a metodologia experimental adotada com relação aos conjuntos de dados, às etapas de pré-processamento, aos hiper-parâmetros e às métricas. Por conseguinte, o Capítulo 6 consiste na apresentação dos resultados obtidos e das análises feitas. Por fim, o Capítulo 7 mostra as conclusões do trabalho e as direções futuras à pesquisa.

2 BASE CONCEITUAL

Este capítulo tem por objetivo apresentar alguns conceitos relativos à detecção de FN como apoio ao entendimento do trabalho. A Figura 1 apresenta um fluxo dessa atividade, ilustrando o processo de aprendizado de padrões dos textos das notícias, por meio de um classificador de FN, que, a partir disso, é capaz de prever as classes de novos dados de notícias. Para construí-lo, na figura são mostradas duas principais etapas, que são o processamento de linguagem natural e a aprendizagem de máquina, sobre as quais serão vistas definições e compreensões pertinentes. O capítulo encontra-se dividido da seguinte forma: a Seção 2.1 apresenta os conceitos relacionados ao processamento de linguagem natural e a Seção 2.2 os de aprendizado de máquina, compreendendo as técnicas de aprendizagem adotadas no trabalho.

Figura 1 – Processo da detecção de *Fake News*.



Fonte: A autora (2023).

2.1 PROCESSAMENTO DE LINGUAGEM NATURAL

O aprendizado dos padrões textuais é um processo que demanda a conversão da linguagem humana para de máquina, a fim de obter representações numéricas correspondentes aos textos e que sirvam de entrada aos algoritmos de classificação. As técnicas relacionadas a essa transformação estão inseridas numa área da ciência da computação denominada de Processamento de Linguagem Natural (NLP). De acordo com (BENGFORT; BILBRO; OJEDA, 2018), compreende-se que elas permitem que as características dos textos sejam extraídas, de modo que seja possível representá-los através dos números. Na Figura 1, é possível visualizar o papel dela no processo da detecção de FN através da conversão do formato dos dados.

As principais técnicas de NLP relacionadas ao trabalho são relativas ao pré-processamento e à representação de características textuais. Dessas, o primeiro remete a normalização textual, a fim de que este seja simplificado para, posteriormente, ser convertido a números. Sua saída remete a textos reduzidos com a presença das palavras e um formato padronizado e que são mais significativos à indicação do padrão a ser aprendido. Dentre os principais procedimentos relacionados à normalização, com base no que é apresentado em (BENGFORT; BILBRO; OJEDA, 2018) e (KHAN et al., 2021), para o presente trabalho elenca-se os seguintes:

- Conversão do texto para minúsculo. Este procedimento diz respeito a conversão de todas as letras do texto para o formato padrão de escrita minúsculo.
- Remoção de contração. Neste procedimento é promovida a retirada de contrações existentes entre palavras. Assim, um grupo de palavras que esteja na forma contraída é transformado para a forma original de modo que são obtidas as palavras primitivas completas e separas.
- Remoção de pontuações. Este procedimento diz respeito à retirada de pontuações tais quais ?,!, .
- Remoção de palavras irrelevantes. este procedimento busca a remoção de palavras que sejam irrelevantes ao contexto, como endereços específicos, números e palavras menos frequentes, por exemplo, que ocorreram uma única vez no *corpus* completo.
- Remoção de *stopwords*. Este procedimento remete a retirada de palavras que não agregam muito sentido ao contexto, como artigos e preposições.

- *Stemming*: a aplicação dessa técnica está relacionada ao procedimento que promove a obtenção de um formato padrão das palavras. Para isso, ela busca a transformação das palavras de um formato derivado a um primitivo correspondente a sua raiz.

Completando a etapa de processamento de linguagem natural nos dados, a partir dos textos normalizados, as técnicas de representação de características são responsáveis pela conversão deles ao formato numérico propriamente dito. Consoante as ideias de (VAJJALA et al., 2020), o NLP possibilita que a aprendizagem de máquina consiga reconhecer os padrões e fazer diversas tarefas tais quais a classificação textual. Dentre elas, algumas mais tradicionais são pertencentes aos grupos de Bag-of-Words (BoW) e Word Embedding (WE).

O BoW se baseia em representações obtidas mediante a frequência das palavras. A ideia principal dele é verificar o conjunto de palavras existente no *corpus*, ou seja, no conjunto das palavras encontradas nos textos, correspondente ao dicionário, e, a partir disso, atribuir algum número contabilizando a frequência de um termo do dicionário presente no texto. Duas técnicas desse grupo são Count Vectorizer (CV) e Term Frequency – Inverse Document Frequency (TF-IDF), cujas descrições são relatadas a seguir:

- CV. Com base nas ideias apresentadas por , (GANESH; PRIYA; NANDAKUMAR, 2021), esta técnica considera todas as palavras do *corpus* e, à medida que elas aparecem na sentença textual analisada, esta é representada no formato de vetor, cujas coordenadas correspondem às frequências de cada termo. Portanto, os elementos mais frequentes admitem valores maiores.
- TF-IDF. Esta técnica, assim como o CV, também se baseia na ideia de considerar todo o *corpus* para a representação dos elementos textuais. Contudo, de acordo com as ideias de (LI, 2021), ela analisa a frequência daquele termo no documento textual e pondera ela, inversamente, por um fator que considera todos os documentos que compuseram o dicionário e indica o número de vezes que ele ocorreu. Dessa forma, a frequência do termo leva em conta uma relevância não apenas a nível global do dicionário, mas também pela ocorrência em diferentes documentos. Assim, quando um termo é muito frequente em um único documento, estando apenas nele, isso pode indicar sua importância em determinado contexto e, conseqüentemente, o valor obtido para esse termo é maior, e vice-versa.

frequência de elementos nos documentos considerados.

As técnicas de BoW, por serem baseadas nas frequências dos elementos textuais, podem gerar vetores de representações com diferentes tamanhos, dependendo do *corpus* considerado. Em cenários que existem vários documentos, eles podem alcançar grandes dimensões, dificultando a aprendizagem do texto para a detecção de FN. Contrapondo essa situação, o segundo grupo composto pelas técnicas de WE apresentam tamanho fixo de suas representações. Elas são baseadas em estatística dos elementos das sentenças e, através do cálculo das probabilidades de ocorrência deles, são capazes de capturar relações de semântica do texto. Neste trabalho serão utilizadas Word2Vec (W2V), Global Vectors of Word representation (GLOVE) e Fasttext (FAST). A lista a seguir apresenta uma descrição de cada uma delas:

- W2V. Esta técnica foi proposta por (MIKOLOV et al., 2013), a fim representar características textuais através de representações densas das palavras, pelas quais é considerado o contexto nos quais elas estão inseridas, a partir das palavras que estão próximas à elas, e assim é capturado o sentido delas em suas representações. Além disso, (MIKOLOV et al., 2013) destaca que é viável representar as características textuais a partir de uma grande quantidade de dados.
- GLOVE. Esta técnica foi proposta por (PENNINGTON; SOCHER; MANNING, 2014), cujas ideias demonstram que ela se baseia na criação de uma matriz de co-ocorrência, com os elementos textuais verificados nas linhas e nas colunas, com a finalidade de calcular a probabilidade condicional de ocorrência deles. Por meio dos cálculos estatísticos, ela é capaz de considerar a palavra com relação a todo o corpus no qual ela pertence, indo além do contexto observado pelas palavras mais próximas à ela.
- FAST. A técnica foi proposta por (BOJANOWSKI et al., 2017), cuja descrição leva a compreender-se que ela funciona similar ao W2V, mas introduz o uso de representações obtidas a partir da estrutura do elemento textual aprendido, especificamente os caracteres dele. Dessa forma, pela combinação dos caracteres, ela permite considerar mais palavras em seu aprendizado.


Com base nas 5 abordagens apresentadas, embora elas estejam agregadas em 2 grupos distintos, vale notar que cada uma delas dispõe de uma proposta singular de representação. Dessa forma, a partir da aplicação delas, é possível alcançar informações quanto a sintaxe e

semântica dos textos de forma distinta, o que pode ser interessante ao reconhecimento de padrões do classificador da FN em concordância ao objetivo da pesquisa.

2.2 APRENDIZAGEM DE MÁQUINA

Além do NLP, uma segunda etapa pertinente ao processo de detecção de FN apresentada na Figura 1 é a aprendizagem de máquina. Ela é quem faz, por meio de recursos computacionais, o reconhecimento dos padrões sobre os dados numéricos, a fim de que seja obtido o classificador textual das FN. Para isso, ela utiliza algoritmos e técnicas de aprendizagem que são capazes de obter regras dos dados e aplicá-las às novas entradas.

Figura 3 – Fluxograma do processo de um MCS.



Fonte: A autora (2023). A primeira etapa, à esquerda, corresponde a geração, a segunda, ao meio, à seleção e a terceira, à direita, à integração.

Conforme ilustrado na Figura 1, no processo de aprendizagem pode haver a presença das classes dos dados. A área da aprendizagem de máquina, que trabalha dessa forma para detectar as regras, é o aprendizado supervisionado. Existem diversos algoritmos capazes de aprender dessa maneira, tais quais Support Vector Machine (SVM) e Logistic Regression (LR). Dentro desse grupo de aprendizes, pode ser observado um sub-grupo especializado em aprendizado baseado em redes neurais, assim como trabalha o Multi-Layer Perceptron (MLP). Ainda um sub-grupo específico se destaca dentro deste, obtido pelas redes com camadas profundas, da mesma maneira que o algoritmo Convolutional Neural Network (CNN). Sintetizando os principais algoritmos adotados neste trabalho, a seguir é apresentada uma lista contendo uma descrição sobre o funcionamento deles:

- SVM. Citado em (AHMAD et al., 2020), este algoritmo propõe a construção de hiperplanos para servirem como fronteiras de separação entre as classes. Através do aprendizado delas, ele pode resolver satisfatoriamente problemas que apresentam uma separação

linear. Além disso, consegue separar classes em regiões que apresentam uma maior complexidade, a partir da função de *kernel*, a qual possui, de acordo com as ideias de (AHMAD et al., 2020), alguns de seu tipo são *Sigmoid*, *Polinomial* e Gaussiano.

- LR. Também citado por (AHMAD et al., 2020), este algoritmo é capaz de classificar 2 classes com base nas probabilidades de ocorrência de cada uma. Para isso, nele é definido um limiar que separa as chances de ocorrência de cada uma, de forma que abaixo dele é classificada como uma das classes e acima como a oposta. Com base nisso, ele consegue aprender os padrões e classificar novos dados.
- NB. O Naive Bayes (NB), seguindo as ideias apresentadas em (PATIL, 2022), é um algoritmo que se baseia no cálculo da probabilidade de um evento ocorrer, a chamada probabilidade a posteriori, dada a ocorrência de um outro anterior, a probabilidade a priori, multiplicada pela probabilidade de ocorrência do evento e dividido pela probabilidade de ocorrência do evento anterior. A partir do cálculo dessas estatísticas, ele é capaz de fazer a classificação. Uma característica interessante é que os eventos analisados pelo Naive Bayes são considerados isolados, o que o torna conhecido por ter um aprendizado ingênuo.
- RF. O algoritmo Random Forest (RF), de acordo com as ideias de (AHMAD et al., 2020), tem por base outro algoritmo conhecido por Árvore de decisão. Neste, são construídos ramos a partir de nós com limiares de decisão definidos por diversos critérios, tal qual a importância dos atributos. A partir disso, as classes finais são previstas pelas regras aprendidas nos ramos da árvore. O RF consiste numa técnica que considera um conjunto de várias árvores treinadas cada uma em diferentes partições do conjunto de dados. Com a união dessas árvores, o RF possibilita que a generalização do modelo seja maior que das árvores individualmente.
- ET. O Extra Trees (ET), de acordo com (PATIL, 2022), é um algoritmo similar ao RF, mas apresenta diferença pois além de selecionar as variáveis mais importantes nas árvores de decisão e as amostras do conjunto para treiná-las, no treinamento das variáveis de cada árvore ocorre uma separação aleatória dos dados. Por isso, este algoritmo, que também usa um conjunto de árvores, pode generalizar melhor que o treino delas individualmente e ainda também do que o RF, uma vez que introduz um fator randômico a mais que ele.

- MLP. Este algoritmo, descrito em (AHMAD et al., 2020), consiste em uma rede neural artificial com múltiplas camadas de neurônios como camadas ocultas. Dessa forma, ele recebe as entradas, processa nas camadas e encontra as saídas de classes previstas pelo modelo. O processamento ocorre de acordo com o funcionamento de um neurônio artificial: os pesos multiplicam as entradas e todas elas são somadas, adicionado a um viés. Em seguida é aplicada uma função de ativação nele, a fim de encontrar a saída final. Se o valor for maior que o limiar estabelecido na função, ele é de uma das classes. Caso contrário, pertence a outra. É importante destacar, ainda, alguns exemplos de funções adotadas nessa etapa, tais quais a *Sigmoid* e a *Relu*. Assim esse processo ocorre até a última camada. Com a adoção de múltiplas, o MLP é capaz de resolver problemas não linearmente separáveis. Seu aprendizado ocorre considerando a otimização dos pesos que são encontrados nas camadas. Contudo, possui número limitado de camadas não chegando a ser uma rede profunda.
- CNN. Este algoritmo, citado em (NASIR; KHAN; VARLAMIS, 2021), assim como o MLP, se baseia na construção de uma rede neural artificial. Contudo, apresenta mais camadas ocultas, que permite descobrir padrões mais complexos. As camadas dessa rede são ditas convolucionais, pois aplicam transformações de convolução, com as quais duas operações dadas geram uma terceira função. Sendo assim, ele aprende detalhes dos dados e é conhecido por obter um bom aprendizado.
- KNN. O K-Nearest Neighbors (KNN) foi citado em (AHMAD et al., 2020), o qual é um algoritmo que se baseia na aprendizagem por instâncias de dados. Ele considera os hiper-parâmetros de valor k , que representa a quantidade de dados próximos a instância que são considerados, e a métrica da distância. Dessa forma, a partir desses hiper-parâmetros, é verificada pelo algoritmo a classe dos vizinhos dentro da região delimitada pela distância e a que for predominante é atribuída àquela instância de dado.

Como cada um desses algoritmos aprende de forma diferente, a capacidade de realizar previsões corretamente, pelo classificador, varia de acordo com a escolha do modelo. Ademais, com o objetivo de potencializar a classificação e a capacidade de generalização deles, ou seja, de previsões corretas em novos dados, têm sido adotada a abordagem Sistema de Múltiplos Classificadores (MCS). Ela consiste na combinação de modelos de aprendizagem para composição de um aprendiz final capaz de prever em diferentes regiões de competência e abranger

espaços de dados a mais que os algoritmos individualmente.

Conforme descrito em (CRUZ; SABOURIN; CAVALCANTI, 2018), o funcionamento de um MCS se dá em 3 etapas: geração, seleção e integração. A Figura 3 ilustra o processo de formação de um MCS, apresentando cada uma delas em ordem de ocorrência. A etapa de geração é o momento por meio do qual os algoritmos e as técnicas de classificação são escolhidos para classificar as entradas. Em seguida, ocorre a seleção, na qual alguns desses aprendizes são selecionados, a fim de que sejam integrados, na etapa de integração, e venham a constituir o aprendiz final, que prediz as classes finais obtidas como saídas.

De acordo com (LUDMILA, 2004), o grupo de técnicas que correspondem a MCS é formado por elementos que se diferenciam segundo os modelos que utilizam. Caso eles sejam homogêneos, a técnica segue uma abordagem de seleção. Nessa perspectiva, exemplos delas são o *bagging*, cuja combinação deles ocorre em paralelo, e *boosting*, a qual acontece em série. Caso os modelos sejam heterogêneos, a abordagem é de fusão, tal qual trabalha a técnica de empilhamento, que utiliza um meta-classificador para unir o aprendizado dos diferentes modelos treinados na etapa anterior de modo paralelo.

Concordante ao exposto no Capítulo 1, essa estrutura do empilhamento se configura uma abordagem interessante capaz de garantir diversas vantagens de aprendizado. O sistema pode cobrir desvantagens representacionais observadas em cada classificador singular. Além disso, seguindo (LUDMILA, 2004), ele pode não ser capaz de classificar todas as instâncias corretamente, dependendo da capacidade dos integrantes do sistema. Todavia, com a união dos aprendizados, o classificador final aproxima-se mais do modelo ideal, com uma maior capacidade de generalização. Isso porque, com a união de aprendizados de algoritmos, que aprendem de forma diferente, padrões em problemas de maior complexidade podem ser aprendidos por meio da seleção dos aprendizes mais diversos, possibilitando uma possível redução de esforços computacionais para a aprendizagem e permitindo que diversos problemas sejam resolvidos. Ademais, a probabilidade de acertar uma instância aumenta, uma vez que ele consegue abranger um número maior de regiões do espaço de dados, entretanto, é imprescindível que sejam selecionados classificadores com diversidade.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta um estudo sobre as abordagens usadas em sistemas para a detecção de FN, os quais estão relacionados aos conceitos vistos no Capítulo 2. Na Seção 3.1 é disposta uma síntese sobre trabalhos da área com seus respectivos detalhes. São verificadas as abordagens e as configurações do protocolo experimental adotadas por cada um. Ao final da seção, é apresentada uma lista, resumindo observações a respeito das análises sobre os trabalhos, tendo em vista direcionar o método proposto e as escolhas necessárias à condução dos experimentos.

3.1 ABORDAGENS PARA A DETECÇÃO DE *FAKE NEWS*

Tabela 1 – Trabalhos que aplicaram a aprendizagem de máquina para a detecção de FN.

Referência	Dados	Representação	Algoritmo	Abordagem	Classes	Métrica
(WANG, 2017)	Liar	W2V	SVM, LR, Bi-LSTM, CNN	CNN-Bi-LSTM	6	acurácia
(HANSRAJH; ADELIYI; WING, 2021)	Liar, Isot	TF-IDF (palavra <i>n-gram</i>)	LR, Linear Discriminant Analysis, Stochastic Gradient Descent(SGD), Ridge Regression, SVM	Blending Ensemble Learning(BLD)	2	acurácia, precisão, revocação, medida f1, AUC, ROC AUC
(PRIYA; KUMAR, 2021)	Covid-19	TF-IDF (caractere, palavra)	SVM, RF, LR, KNN, NB, Gradient Boosting(GB), Decision Tree(DT), AdaBoost (AB), Deep Neural Network (DNN), CNN	SVM-DNN-CNN	2	medida f1
(NASIR; KHAN; VARLAMIS, 2021)	Isot, Fa-Kes	GLOVE	LR, RF, Multinomial NB, SGD, KNN, DT, AB, CNN, RNN	CNN-RNN	2	acurácia, precisão, revocação, medida f1
(AHMAD et al., 2020)	Isot, Kaggle(FN, FN Detection), Combinado	Linguistic Inquiry and Word Count(LIWC)	RF, LR, SVM, MLP, KNN	Voting(RF, LR, KNN), Voting(LR, Linear SVM(LSVM), Classification and regression trees(CART)), Bagging (DT), AB, Boosting (XGBoost)	2	acurácia, precisão, revocação, medida f1

Fonte: A autora (2023). São apresentados a referência, o conjunto de dados, a técnica de representação, o algoritmo, a abordagem adotada, o número de classes e a métrica de avaliação adotada por cada um nas respectivas colunas Referência, Dados, Representação, Algoritmo, Abordagem, Classes e Métrica.

Embora o problema da propagação das FN ter ocorrido desde épocas da antiguidade, a intensidade com que ele adveio nos últimos anos, dada a velocidade com que as notícias foram espalhadas, conjuntamente ao crescimento do nível de desinformação, conduziu a atenção da academia em busca de soluções para resolvê-lo. Diversos esforços foram feitos para cobrir desafios existentes no estudo do problema, com soluções que se mostraram satisfatórias e eficientes. A Tabela 1 apresenta uma amostra de trabalhos que foram desenvolvidos para esse fim, mostrando detalhes relacionados às abordagens adotadas por cada um deles.

Para construir a tabela, foi realizada uma revisão da literatura, através de pesquisas na base *Google Scholar* ¹, considerando como critérios artigos que foram sugeridos como resultados mais relevantes pela busca, que trabalharam com conjuntos de dados sobre política ou saúde, tais quais o Liar e o Covid-19, ou foram publicados em até 3 anos, e que utilizaram abordagens com sistemas híbridos ou *ensemble*. Por isso, a busca baseou-se nos seguintes termos: (*ensemble fake news detection*), (*fake news detection hybrid*), ou ainda (*ensemble fake news detection covid*) e (*ensemble fake news detection liar*).

Considerando os trabalhos selecionados, o (WANG, 2017) adotou um sistema híbrido para fazer a detecção das FN. Ele utilizou um modelo composto por camadas de uma CNN seguidas por um modelo Bi-LSTM. Ele justifica a adoção da abordagem escolhida pelo fato de que a junção dos modelos é capaz de classificar melhor que modelos não combinados. De fato, os melhores resultados do trabalho foram obtidos a partir desse sistema. Além disso, os experimentos foram feitos sobre um conjunto de dados Liar. O autor o propõe a fim de disponibilizar para a academia um conjunto de dados que possibilite o estudo do problema. Neste, são consideradas 6 classes, permitindo a avaliação da abordagem num cenário multi-classe. O trabalho utiliza apenas o W2V para o processamento da linguagem natural, além dos textos adota outros meta-dados, tal qual o estado de origem e afiliações partidárias, para o aprendizado, e ainda avalia os resultados a partir da métrica acurácia.

Além do (WANG, 2017), outros trabalhos também adotaram sistemas híbridos em suas abordagens. Sobretudo, compostos por algoritmos baseados em redes neurais. O trabalho (NASIR; KHAN; VARLAMIS, 2021) utilizou um sistema composto por CNN e RNN. Ele utilizou a técnica GLOVE para a representação de características sobre os conjuntos de dados Isot e Fa-kes, considerando classificação binária. Ele adotou acurácia, precisão, revocação e medida f1 para avaliação do seu sistema. Por conseguinte, o trabalho (PRIYA; KUMAR, 2021) adotou um sistema híbrido, composto por mais algoritmos, considerando para isso o SVM, DNN e

¹ <https://scholar.google.com/>

CNN. Nele, foi adotado o TF-IDF, n-gram a níveis de carácter e palavra, para a representação de características dos textos do conjunto Covid-19 com classificação binária e utilizou a medida f1 para avaliação de seus resultados. Nele, é justificado que o uso de aprendizagem profunda no sistema permite um desempenho melhor. Contudo, observa-se que em ambos trabalhos, os sistemas utilizam todos os algoritmos que foram escolhidos para o aprendizado final, explorando uma variação de 2 ou 3 modelos diferentes.

Uma outra linha de abordagem adotada por (AHMAD et al., 2020) é o uso de sistemas comitês, ou *ensemble*. Ele adota essa vertente a fim de utilizar o aprendizado de cada componente do sistema, ao invés de um sistema composto por vários componentes juntos, como os sistemas híbridos apresentados nos trabalhos anteriores. Nele, são adotados a técnica *Voting* para 2 sistemas, um composto pelos algoritmos RF, LR, KNN e outro pelo LR, LSVM, CART, além o Bagging, pelo DT, AdaBoosting e Boosting pelo XGBoost. O trabalho adota 4 conjuntos de dados, Isot, Kaggle FN, Kaggle FN Detection e um combinado entre eles, mostrando que é importante avaliar a atividade de detecção de FN a partir de conjuntos com diferentes contextos. O aprendizado foi feito a partir do extrator de recursos LIWC e da classificação binária. Além disso, a avaliação utilizando as métricas acurácia, precisão, revocação e medida f1 permitiu verificar que diferentes abordagens obtiveram o maior desempenho em cada uma das métricas, sendo importante a adoção das 4.

Além do uso de sistemas híbridos de comitês compostos através das técnicas *Bagging*, *Boosting* e *Voting*, uma outra abordagem adotada foi o uso do (BLD). Ele foi utilizado em (HANSRAJH; ADELIYI; WING, 2021) e se baseia no aprendizado de empilhamento, ou *stacking*, considerando os conjuntos de treinamento, validação e teste a partir de partições diferentes dos dados. Dessa forma, a partir do treinamento dos diferentes classificadores no conjunto de treino, e predição no de validação, as saídas são combinadas e o meta-classificador prediz sobre os dados de teste. No trabalho, foi adotado o TF-IDF, a nível n-gram, para representação de características sobre os conjuntos Liar e Isot considerando classificação binária. Além disso, foram adotadas as métricas acurácia, precisão, revocação, medida f1, AUC e ROC AUC para avaliação dos resultados. Vale notar, ainda, que os resultados obtidos para o conjunto Liar nesse trabalho foram superiores aos do (WANG, 2017). Apesar de utilizarem técnicas diferentes, observa-se que a complexidade dos dados ao tratar o problema com 6 e 2 classes impacta na capacidade de classificação. Entretanto, foi observado que, em ambos trabalhos, foram tratados cenários que consideraram o uso de 2 classes no processo de aprendizagem.

Ademais, observando ainda a abordagem adotada pelo trabalho (HANSRAJH; ADELIYI; WING,

2021), a vantagem da adoção do BLD sobre os sistemas híbridos é a de unir os aprendizados ao invés de ter que considerar todos dentro de um único aprendiz e, sobre os outros modelos de comitês, esse benefício reside no fato de poder aprender heterogeneamente. Todavia, em (HANSRAJH; ADELIYI; WING, 2021) o sistema utilizou todos os algoritmos que foram escolhidos para compor o seu aprendizado sem avaliar necessariamente a ocorrência de redundância entre as classificações. O trabalho ainda apresenta, como propostas futuras, a importância da avaliação da técnica considerando mais conjuntos de dados, além de diferentes técnicas de processamento textual, para a representação de características e de diversos algoritmos de classificação.

Tendo em vista a vantagem do uso de sistemas híbridos e de comitê, uma abordagem não utilizada pelos trabalhos da Tabela 1, mas encontrada na literatura de trabalhos referentes a classificação textual, é o uso de MCS. No trabalho (CRUZ; SOUSA; CAVALCANTI, 2022), é demonstrado que fazer a seleção dos classificadores que aprendem complementarmente para compor o sistema pode potencializar a capacidade de generalização do aprendizado. Isso corrobora com as ideias de (LUDMILA, 2004), de que a adoção de um sistema de comitê traz vantagens no aprendizado, a partir da análise da diversidade entre seus classificadores. O trabalho (CRUZ; SOUSA; CAVALCANTI, 2022) utiliza a análise da distância entre as classificações, a partir da métrica *double-fault*, e detecta grupos analisando a dissimilaridade entre os aprendizes como forma de verificar a diversidade entre eles. O sistema proposto é vantajoso frente a outros aprendizados em conjunto, contudo, ainda requer uma análise visual para a identificação dos grupos formados e considera a seleção de um elemento aleatório do grupo para ser representante dele ao compor o sistema final.

Seguindo a linha de (CRUZ; SOUSA; CAVALCANTI, 2022), é utilizada uma variedade de técnicas de extração de características do texto e de algoritmos. Nele, foram adotadas as técnicas CV, TF-IDF, W2V, GLOVE e FASTTEXT, aqui denominado de FAST, para a representação de características, e os algoritmos SVM, LR, RF, NB, EXTRA, MLP, CNN e KNN, demonstrando uma variedade de técnicas consideradas para execução do método, o que é um ponto interessante a ser adotado. Além disso, faz um comparativo de resultados obtidos por conjuntos com 2 e 3 classes, o que configura cenários de classificação binária e multi-classe, sendo outro aspecto interessante. Atentando para todos os aspectos notados nas análises dos trabalhos encontrados na literatura, a lista a seguir traz um levantamento de observações obtidas considerando as abordagens utilizadas por cada um e suas respectivas configurações do experimento, as quais são:

- É interessante a adoção de diversos conjuntos de dados para a atividades de detecção de FN, a fim de avaliar melhor o método proposto.
- A adoção de um MCS pode trazer um aprendizado em conjunto capaz de obter uma maior generalização a partir de uma seleção de classificadores.
- É importante do uso de uma variedade de técnicas de representação de características e de algoritmos de classificação para a compor o MCS, incluindo algoritmos de aprendizagem de máquina e de aprendizado profundo.
- A complexidade dos dados referentes ao número de classes pode impactar os resultados, sendo interessante fazer análises sobre os 2 cenários de classificação binária e multi-classe.
- Considerando a importância da diversidade em um MCS, é relevante utilizar uma técnica para a etapa da seleção dos classificadores para compor o MCS.
- É interessante adotar ao menos as métricas acurácia, precisão, revocação e medida f1 para a avaliação dos resultados: pois são métricas complementares, e com elas é possível comparar com os trabalhos relacionados.

Desse modo, os pontos apresentados nessa lista serviram de base para a escolha do método proposto, assim como para a determinação das configurações do experimento.


4 MÉTODO PROPOSTO

Este capítulo apresenta a descrição do método proposto, o qual foi construído mediante as observações constatadas sobre os trabalhos relacionados no Capítulo 3. Além disso, ele foi inspirado na arquitetura proposta em (CRUZ; SOUSA; CAVALCANTI, 2022), pela qual é obtido um MCS aplicado em atividade de classificação textual. Desta arquitetura, o método proposto foi composto por algumas etapas similares, relacionadas a geração e a integração dos classificadores. Quanto a seleção deles, na arquitetura de base, ela ocorre manualmente. Logo, em alternativa, o método proposto traz outras etapas para a seleção, como forma de inovação do método, mas conserva a premissa da busca pela diversidade entre os classificadores. Além disso, na arquitetura proposta em (CRUZ; SOUSA; CAVALCANTI, 2022), a seleção ocorre mediante a quantidade de grupos detectados visualmente em um gráfico com os classificadores, ao passo que o método proposto busca explorar diferentes quantidades de grupos encontrados e obter um subconjunto de classificadores selecionados para cada uma delas, como forma de enriquecer a busca pela diversidade. Primeiramente, são apresentadas a visão geral do método e a descrição do seu funcionamento. Em seguida, as Seções 4.1, 4.2, 4.3, 4.4 e 4.5 trazem uma explicação detalhada de cada um de seus passos. Por fim, a seção 4.6 resume as vantagens e as limitações encontradas pelo método.

A Figura 4 ilustra o método proposto. A descrição das siglas presentes na figura está disposta na Lista de Símbolos. Na figura, o método é composto de 2 fases: (i) treinamento e (ii) teste. A fase (i) compreende o treinamento dos classificadores sobre os dados de treinamento e a predição deles sobre dados de validação. Em seguida, é construída uma matriz que armazena a informação sobre a dissimilaridade existente entre eles, a qual é obtida a partir do cálculo das diferenças entre as predições deles. A partir disso, é feita uma seleção, a fim de obter subconjuntos de classificadores, cada um contendo diferentes quantidades de elementos, para que componham um MCS. A segunda fase (ii) consiste na integração dos elementos de cada subconjunto obtido em um aprendiz final correspondente ao MCS. Por fim, são feitas as predições de cada sistema sobre os dados de teste.

Em relação ao funcionamento do método, ele ocorre da seguinte forma: na fase (i) o conteúdo das sentenças no conjunto de dados de treinamento é pré-processado a fim de que seja reduzido. Caso as classes sejam dispostas no conjunto de dados em formato textual, elas também são categorizadas numericamente, de forma que um nome de uma classe passa a ser

Figura 4 – Ilustração do método proposto.



Fonte: A autora (2023). O método é composto por 2 fases: (i) treinamento e (ii) teste. O conjunto de dados Γ corresponde aos dados de treinamento, δ aos de validação e γ aos de teste. A fase (i) consiste no treinamento dos classificadores e do cálculo da dissimilaridade existente entre as previsões feitas por eles. Nela os dados de treinamento são pré-processados e transformados em formato numérico por m técnicas de representação de características e alimentam os n algoritmos de classificação para a obtenção do *pool* de classificadores. As previsões deles são feitas nos dados de validação e o cálculo da dissimilaridade resulta numa matriz simétrica com $m \times n$ linhas e $m \times n$ colunas, em que $m \times n$ é correspondente aos classificadores obtidos, portanto, equivalendo a quantidade pares obtidos pelas combinações de técnicas de representação e algoritmos. Em seguida, é construído o agrupamento hierárquico, a partir da matriz, e é aplicada a heurística proposta para seleção dos subconjuntos de pares, dentre o *pool* de classificadores, que comporão o MCS. Na fase (ii) é feita a integração dos pares de cada MCS e as previsões sobre o conjunto de teste.

representado por um número, até que todas as classes estejam em formato numérico. Em seguida, são aplicados consecutivamente uma técnica de representação de características nos textos, para convertê-los ao formato numérico, e um algoritmo de classificação. A partir do *pool* de classificadores obtidos são feitas previsões nos dados de validação e é construída a matriz de dissimilaridade, com base no cálculo das diferenças entre as classes obtidas por eles. Após isso, é feita a seleção dos subconjuntos de classificadores, considerando a diversidade do aprendizado entre eles, para serem utilizados na próxima fase. Na (ii) ocorre a integração dos classificadores de cada subconjunto e é feita a previsão sobre os dados de teste. Assim, a partir desse fluxo de passos, o método proposto permite que ao final seja obtido um MCS para a classificação textual, em cuja atividade se enquadra a detecção de FN.

4.1 PRÉ-PROCESSAMENTO E REPRESENTAÇÃO DE CARACTERÍSTICAS

O pré-processamento é uma das etapas iniciais do método que é responsável pela preparação dos dados para o reconhecimento dos padrões. Por isso, ela permite que os conteúdos textuais sejam simplificados para que a etapa consecutiva, de representação de características, seja feita. Esta, por sua vez, é a etapa do método responsável pela transformação das sentenças textuais para o formato numérico, com a finalidade de servirem de entrada aos algoritmos. Na literatura, são encontradas diversas Técnicas de representação de características (E), dentre as quais, nesse trabalho foram adotadas algumas comumente usadas com o propósito de verificar a existência de diversidade entre os classificadores, as quais foram: CV(GANESH; PRIYA; NANDAKUMAR, 2021; PRIYA; KUMAR, 2021) e TF-IDF(LI, 2021; GANESH; PRIYA; NANDAKUMAR, 2021; PRIYA; KUMAR, 2021; KALIYAR et al., 2020; NASIR; KHAN; VARLAMIS, 2021), como técnicas BoW, além de GLOVE (KALIYAR et al., 2020; NASIR; KHAN; VARLAMIS, 2021), W2V (KALIYAR et al., 2020) e FAST (TAHER; MOUSSAOUI; MOUSSAOUI, 2022), como técnicas de WE.

As técnicas são aplicados nas partições dos conjuntos de dados: treinamento, validação e teste. O conjunto final apresenta a seguinte estrutura: E_{GLOVE} , E_{W2V} , E_{FAST} , E_{CV} , E_{TF-IDF} . Nesse contexto, a implementação delas foi feita utilizando as bibliotecas do *Python Scikit-learn* ¹ para o CV e TF-IDF, e *Zeugma* ² para o GLOVE, FAST e W2V (GARCIA et al., 2015). Conforme mencionado no Capítulo 2, vale ressaltar que as BoW e WE, por serem propostas diferentes, de acordo com (CRUZ; SOUSA; CAVALCANTI, 2022), a adoção delas contribui para que seja possível obter maior diversidade no MCS final.

4.2 TREINAMENTO DOS ALGORITMOS

Essa etapa é aplicada após a conversão dos textos ao formato numérico a fim de que sejam aprendidos os padrões de cada classe e sejam feitas as predições. Para tanto, são adotados 8 Algoritmos de classificação (A), os quais são comumente encontrados na literatura para a classificação textual, sobretudo para a detecção de FN. Os algoritmos escolhidos são: SVM(CRUZ; SOUSA; CAVALCANTI, 2022; SINGH, 2022; PRIYA; KUMAR, 2021), LR (CRUZ; SOUSA; CAVALCANTI, 2022; SINGH, 2022; LI, 2021; HANSRAJH; ADELIYI; WING, 2021; PRIYA; KUMAR,

¹ <https://scikit-learn.org/stable/>

² <https://pypi.org/project/zeugma/0.41/>

2021; NASIR; KHAN; VARLAMIS, 2021; AHMAD et al., 2020), RF (CRUZ; SOUSA; CAVALCANTI, 2022; SINGH, 2022; PRIYA; KUMAR, 2021; KALIYAR et al., 2020; NASIR; KHAN; VARLAMIS, 2021; AHMAD et al., 2020), NB (CRUZ; SOUSA; CAVALCANTI, 2022; UPADHAYAY; BEHZADAN, 2020), MLP, ET (CRUZ; SOUSA; CAVALCANTI, 2022), CNN (CRUZ; SOUSA; CAVALCANTI, 2022; PRIYA; KUMAR, 2021; KALIYAR et al., 2020; NASIR; KHAN; VARLAMIS, 2021), KNN (CRUZ; SOUSA; CAVALCANTI, 2022; SINGH, 2022; PRIYA; KUMAR, 2021; KALIYAR et al., 2020; NASIR; KHAN; VARLAMIS, 2021; AHMAD et al., 2020). Portanto, o conjunto utilizado para cada técnica de representação de característica foi $ASVM$, ALR , ARF , ANB , $AMLP$, $AEXTRA$, $ACNN$, $AKNN$.

Vale ressaltar que, da mesma forma que as técnicas de representação de características, foi escolhido este conjunto para o treinamento dos algoritmos haja vista que ele apresenta modelos que aprendem de maneiras diferentes, o que é propício para o estudo da diversidade num MCS, atendendo ao objetivo da pesquisa. Nota-se que, no conjunto, existe a presença de diversos paradigmas de aprendizagem, uma vez que o SVM aprende, por exemplo, partir de hiperplanos de separação, o LR da modelagem estatística, o RF e ET por meio de regras encontradas por árvores de decisão, o NB a partir do cálculo de probabilidades, o MLP e o CNN a partir de redes neurais, sendo o primeiro com uma ou poucas camadas e o segundo a partir do aprendizado profundo em camadas convolucionais. O KNN também apresenta uma proposta diferente de aprendizagem, a qual está baseada na distância entre os vizinhos mais próximos. De acordo com (LUDMILA, 2004), diferentes regiões de classificação são obtidas pra cada um, o que permite que o aprendizado em conjunto pelo MCS se beneficie disso. Conforme proposto em (CRUZ; SOUSA; CAVALCANTI, 2022), as previsões desses classificadores, para as próximas etapas do método, são feitas sobre o conjunto de validação para evitar a ocorrência de sobre-ajuste. Vale destacar ainda que os algoritmos foram implementados usando as bibliotecas do *Python Scikit-learn* e *Tensorflow*[3]¹.

4.3 MATRIZ DE DISSIMILARIDADE

Nesta etapa, é verificada a dissimilaridade entre os classificadores com o objetivo de que seja obtida a informação sobre a diversidade existente entre o aprendizado deles. No trabalho de (LUDMILA, 2004) é proposto que seja calculada uma matriz que contenha a informação sobre a semelhança existente entre os classificadores, a partir de uma análise de cada dois pares deles. Por isso, nesta etapa o cálculo utiliza as previsões dos pares formados pelas técnicas

¹ <https://www.tensorflow.org/>

de representação de características e algoritmos (E, A) e aplica uma métrica para calcular o quão parecidos eles são. Para tal, foi adotada a *double-fault*, também adotada em (CRUZ; SOUSA; CAVALCANTI, 2022), cujo trabalho destaca em suas ideias que ela é apropriada para mensurar o desempenho de um conjunto de classificadores, pois considera 2 pares quaisquer e calcula a proporção de erros iguais obtidos entre eles. Com isso, ela viabiliza mensurar a dissimilaridade entre os pares, obtendo assim a informação a respeito da sua diversidade. Sua fórmula está representada pela Equação 4.1. A Matriz de dissimilaridade (M) é composta por uma quantidade de linhas e de colunas iguais e correspondentes ao número de pares existentes e o valor de cada campo é o resultado da métrica. Para a implementação dela foi adotada a biblioteca *Python DESlib*⁴ (CRUZ et al., 2020).

$$double - fault = \frac{N_{00}}{N_{00} + N_{01} + N_{10} + N_{11}} \quad (4.1)$$

Na Equação 4.1, o índice 0 indica o número de instâncias classificadas incorretamente e o 1 ao corretamente. Assim o numerador indica o total de instâncias classificadas incorretamente por ambos pares, enquanto que o denominador da Equação apresenta o somatório das quantidades classificadas por ambos nos 4 seguintes cenários: corretamente ou incorretamente por ambos, ou ainda corretamente por um e incorretamente pelo outro, com relação aos 2 classificadores do par. Assim, de acordo com (CRUZ; SOUSA; CAVALCANTI, 2022), ela tende a valer 1 quando ambos os pares errarem as mesmas instâncias, indicando que eles são menos dissimilares ou até mesmo iguais. Quando eles erram instâncias diferentes, o numerador é reduzido e a métrica tende a se aproximar de 0, indicando que os pares são mais dissimilares. Dessa forma, como em (CRUZ; SOUSA; CAVALCANTI, 2022), para que os valores mais altos obtidos pelo cálculo indiquem maior dissimilaridade entre os pares, adotou-se o cálculo do inverso da métrica, correspondente ao valor 1 dividido pelo valor encontrado pela métrica. A seguir é apresentada a estrutura da matriz M na Equação 4.2:

$$M = \begin{bmatrix} d(1,1) & d(1,2) & \dots & d(1, m \times n) \\ d(2,1) & d(2,2) & \dots & d(2, m \times n) \\ \vdots & \vdots & \ddots & \vdots \\ d(m \times n, 1) & d(m \times n, 2) & \dots & d(m \times n, m \times n) \end{bmatrix} \quad (4.2)$$

⁴ <https://deslib.readthedocs.io/en/latest/>

Em M , a letra d simboliza o cálculo do inverso da métrica *double-fault*. Cada ponto da matriz indica a dissimilaridade entre 2 pares de classificadores. Nela, o número de linhas é equivalente ao de colunas, ambos correspondendo ao número de pares (E_m, A_n) , em uma matriz quadrada. Portanto, a diagonal principal dela, trata da aplicação da métrica entre aquele par e ele mesmo, enquanto que os demais resultados traduzem a dissimilaridade de pares diferentes. Vale ressaltar que, por apresentar os índices das colunas e linhas iguais, a matriz é simétrica. Desta forma, a matriz serve de base para a etapa de seleção no método proposto.

4.4 SELEÇÃO DOS SUBCONJUNTOS

Esta é a última etapa da fase (i) do método, a qual apresenta uma estratégia para que a seleção do MCS se dê de forma automática. No trabalho (CRUZ; SOUSA; CAVALCANTI, 2022) ela ocorre manualmente, sendo seguidas etapas de redução da dimensionalidade da matriz e plotagem de um gráfico, com as projeções dos classificadores, para verificação visual dos grupos existentes entre eles e seleção manual dos representantes de cada um. Assim é obtido um subconjunto final com elementos correspondentes aos classificadores escolhidos, que podem apresentar maior chance de diversidade entre si. Seguindo esta mesma linha da busca pela diversidade, conforme apresentado em (LUDMILA, 2004), também é possível identificar os grupos de classificadores, pela informação da diversidade da matriz, utilizando o agrupamento hierárquico, pelo qual podem ser observados níveis de hierarquia, viabilizando uma análise da diversidade a partir de diferentes níveis de similaridade entre eles, se constituindo uma abordagem interessante para a seleção do método proposto.

Partindo da ideia do uso do agrupamento hierárquico na seleção do método, nota-se que adotar este agrupamento é interessante pois, além de possibilitar a exploração dos níveis hierárquicos, encontrando-se subconjuntos para cada um deles, ele também viabiliza que seja adotada uma heurística para explorar esses níveis, em busca do classificador a ser adicionado ao subconjunto, de forma a tornar a seleção automática e a fazer com que a escolha do classificador não seja aleatória, como alternativa a seleção apresentada em (CRUZ; SOUSA; CAVALCANTI, 2022). Além disso, ganha-se uma flexibilidade quanto a escolha da métrica adotada para a regra de busca da heurística, levando a seleção proposta a se basear tanto na análise de diversidade, quanto no desempenho, obtido pelo classificador, na escolhida. Portanto, a seleção proposta é composta por dois passos: (i) agrupamento e a (ii) aplicação da heurística

h. O (i) permite identificar a semelhança de comportamento existente entre os classificadores, já o (ii) possibilita que seja selecionado um subconjunto, do *pool*, contendo os representantes dos agrupamentos que satisfizerem a regra da busca da heurística. Dessa forma, subconjunto final é selecionado, em cada nível da hierarquia.

Para que o agrupamento seja feito, é construído um gráfico aplicada a *linkage*. Esta é uma estratégia que permite posicionar os elementos que estão sendo agrupados dentro da estrutura hierárquica por meio da verificação da dissimilaridade existente entre eles. Para isso, ela usa parâmetro que funciona como uma função de ligação entre grupos e que pode ser *Complete*, *Single*, *Average* ou *Centroid*. Para cada um deles é adotada uma lógica diferente. Tendo por base as ideias apresentadas em (MURTAGH; CONTRERAS, 2012), a seguir é apresentada uma lista sobre a descrição de cada um deles e a respectiva equação utilizada no seu cálculo. A distância entre os grupos é representada pelo nome *dist* e foram considerados, para exemplo, grupos genéricos G_1 , com i elementos, e o G_2 , com j elementos, para efeitos de apresentação do cálculo.

1. *Complete*. Este parâmetro calcula todas as dissimilaridades entre os elementos par a par de 2 grupos e armazena o maior deles. Seu cálculo está representado na Equação 4.3.

$$dist(G_1, G_2) = \max dist(G_1(i), G_2(j)) \quad (4.3)$$

2. *Single*. Este parâmetro faz o mesmo que o *Complete*, mas armazena o menor deles. Seu cálculo está representado na Equação 4.4.


$$dist(G_1, G_2) = \min dist(G_1(i), G_2(j)) \quad (4.4)$$

3. *Average*. Este parâmetro também mensura a dissimilaridade entre os elementos, mas calcula a média da dissimilaridade entre o elemento de um grupo, e todos os demais, do outro grupo. Seu cálculo está representado na Equação 4.5, o qual consiste no somatório do resultado obtido, para uma análise de todos os pontos considerados 2 a 2, pela distância entre dois centroides dividido pelo produto do norma deles.

$$dist(G_1, G_2) = \sum_{i=1, j=1}^{\max(i), \max(j)} \frac{dist(G_1(i), G_2(j))}{|G_1| \times |G_2|} \quad (4.5)$$

4. *Centroid*. Este parâmetro calcula a dissimilaridade entre os centroides dos grupos analisados. Seu cálculo está representado na Equação 4.6, pela qual é calculada a norma da diferença, elevado ao quadrado, entre os centroides de dois grupos.

$$dist(G_1, G_2) = |centroide_{G_1} - centroide_{G_2}|^2 \quad (4.6)$$

Figura 5 – Parâmetros da *linkage*.


Fonte: A autora (2023).

A escolha de um dentre os parâmetros apresentados é dependente da distribuição dos dados, tornando-os mais ou menos adequados para o cálculo das ligações entre os grupos. Para visualizar esse comportamento, a Figura 5 ilustra um exemplo de dados escolhidos aleatoriamente para os grupos G_1 e G_2 . Os dados de G_1 estão representados em vermelho e de G_2 em verde, e as ligações de cada parâmetro pela linha pontilhada na cor cinza. Na (c), a lógica foi demonstrada para um dado, mas no cálculo consideram-se todos. Na (d), a representação dos centroides dos grupos está representado pelo dado na cor azul em cada um deles.

Pela figura, percebe-se que os cenários, os quais os grupos apresentam pelo menos um dos dados mais distantes dos demais, desfavorecem o cálculo feito pela *Complete*, pois destoa da realidade dos dados. Entretanto, quando existe apenas poucos dados mais próximos e a maioria está mais distante, ocorre o mesmo para a *Single*. Logo, uma alternativa é considerar a *Average* por se basear na média das distâncias entre os dados de cada grupo. Por isso, ela foi adotada no trabalho, a fim de que o agrupamento seja feito considerando informações sobre a distribuição dos dados correspondentes aos classificadores.

Portanto, partindo da escolha do agrupamento hierárquico e do parâmetro *Average* para a

Figura 6 – Estrutura de um dendrograma genérico.




Fonte: A autora (2023). Na figura são observados pontos distribuídos em uma estrutura de aglomeração divisiva, numa hierarquia top-down. Os pontos possuem alturas distintas e estão mais próximos tanto horizontalmente quanto verticalmente daqueles que são mais similares e mais distantes dos mais dissimilares. A similaridade também é mostrada pela cor das linhas. Pontos em linhas de mesma cor são de agrupamentos similares e de cores diferentes, de dissimilares.

linkage, a hierarquia é construída considerando os dados obtidos pela matriz de dissimilaridade M da etapa anterior do método. Dessa forma, os classificadores são colocados na estrutura de acordo com as diversidades de seus aprendizados. A visualização dessa hierarquia é feita através do gráfico dendrograma, cujo um exemplo é apresentado no gráfico de dimensão $2-d$ na Figura 6.


Observando o gráfico no eixo das abscissas, este contém pontos de X_1 até X_n , os quais, no método proposto, equivalem aos classificadores obtidos pelos pares (E, A) . Os ramos encontrados na hierarquia diferem em 4 cores: azul, amarelo, verde e vermelho. A distância vertical traduz a quantidade de agrupamentos que são formados e a horizontal a proximidade e a similaridade entre os pontos encontrados num determinado grupo. Por isso, foi adotado o agrupamento hierárquico divisivo, correspondente a estrutura apresentada pela figura, para que fosse feita uma análise *top-down*, ou seja, no sentido do topo a base do gráfico, da seleção dos pares.

Nessa perspectiva, a verificação é feita a partir da aplicação da heurística h . A Figura


Figura 7 – Diferentes estados do sistema para valores de k diferentes para seleção no dendrograma.




(a) k é igual a 1.



(b) k é igual a 2.



(c) k é igual a 3.



(d) k é igual a $m \times n$.

Fonte: A autora (2023).

7 ilustra o funcionamento dessa análise para a seleção dos MCS referente à aplicação da heurística h no agrupamento no passo (ii) e, através dela, é possível considerar cada vez que um número diferente de grupos é admitido, consistindo em um novo estado do sistema. A partir de cada grupo, a heurística verifica os elementos de cada um e busca aquele que traz o maior resultado para a métrica de avaliação adotada, repetindo esse passo até que encontre o representante de cada grupo considerado. Ao final, é obtido um MCS composto apenas pela quantidade de elementos correspondente à quantidade de grupos considerados, contendo os pares (E, A) que foram selecionados. Esse processo é reproduzido até que todos os estados do sistema sejam considerados, ou seja, levando-se em conta a existência de apenas 1 grupo até o máximo de grupos que possam ser encontrados. Dessa forma, podem ser exploradas as diferentes combinações de MCS, assim como analisado o desempenho de cada uma e ainda comparado o comportamento das diferentes técnicas de E e A na composição deles.

Para ilustrar melhor como é feita essa seleção do método no dendrograma, é traçada uma linha horizontal, paralela ao eixo das abscissas, para servir de suporte para a detecção de cada novo estado do sistema na análise. A linha é posicionada ao topo do gráfico e percorre uma trajetória, no sentido de cima a baixo, até coincidir com o eixo das abscissas. Durante

essa trajetória, diferentes pontos de cruzamento com as linhas coloridas do dendrograma são encontrados. Eles indicarão a quantidade de grupos considerados e o número de elementos para compor o MCS. A medida que um novo cruzamento é obtido, um novo estado do sistema é encontrado e, conseqüentemente, um novo MCS. Dessa maneira, h permite a detecção e a seleção do MCS com maior diversidade, a partir dessa quantidade de k grupos.

Vale demonstrar, ainda, que na Figura 7 são ilustradas 4 configurações da linha para diferentes k grupos. No (a), o valor de k é 1 e a linha não cruza nenhum ponto. Nele todos os pares são considerados pertencentes a um único grupo. O que dentre eles traz melhor resultado para uma métrica analisada é selecionado por h para ser o MCS correspondente a esse valor de k . No (b), a linha cruza 2 pontos, encontrando 2 grupos dos quais 2 elementos são selecionados para o MCS. O primeiro grupo é formado pelos elementos de linhas amarelas, as quais são ramificações do primeiro cruzamento, e o segundo pelas linhas verdes e vermelhas, pelos ramos do segundo cruzamento. No (c), o k é igual a 3. Portanto, 3 grupos foram encontrados, um pelos ramos amarelos, outro pelos verdes e outro pelos vermelhos. Os elementos de maior desempenho para cada um deles são selecionados e compõem um MCS com 3 elementos. É evidente que, à medida que a linha caminha para a parte inferior do Gráfico, ela cruza mais pontos até a base, na qual a quantidade de pares $m \times n$ coincide com a de grupos k do MCS, onde cada par é equivalente ao melhor representante do grupo formado apenas por ele mesmo.

A partir da aplicação da heurística h , é possível fazer uma análise, considerando todos os pares (E, A) adotados no método. A lógica de funcionamento dela é descrita no *Algorithm 1*. Para suportar essa lógica, foi adotada a função $f_cluster$ ⁵, que obtém os k grupos formados a partir do cálculo da função *linkage* sobre a matriz de dissimilaridade e fornece o número do grupo ao qual o par pertence. A heurística busca os grupos dentre k diferentes configurações e, dentro de cada uma, o elemento que obteve maior valor de desempenho para métrica de avaliação, indicando um resultado de ótimo local. Com isso, é considerado o acerto e a diversidade pela quantidade de grupos para a seleção do sistema. A heurística repete seu processo de busca a cada novo estado do sistema, desde configurações em que todos sejam de um grupo até que cada classificador represente um único grupo. Dessa forma, é possível analisar o comportamento do MCS dado o incremento de um novo par e, considerando os $m \times n$ pares possíveis, ao final são obtidos $m \times n$ MCS. Esses comitês são combinados na próxima etapa da integração.

A heurística permite a seleção dos MCS através das métricas acurácia, precisão, revocação e

⁵ <https://docs.scipy.org/doc/scipy/reference/generated/scipy.cluster.hierarchy.fcluster.html>

Algorithm 1 heurística h **Entrada :** M : matriz de dissimilaridade ($m \times n$) δ' : Conjunto dos Pares e respectivas métricas calculadas sobre as predições de cada par.**Saída:**Conjunto com $m \times n$ MCS.

```

1:  $MCS \leftarrow \emptyset$ 
2:  $Z \leftarrow linkage(M)$ 
3: for  $metricas, par$  in  $\delta'$  do:
4:   for  $k$  in  $m \times n$  do:
5:      $grupo(par, k) \leftarrow f\_cluster(Z, k)$ 
6:     for  $grupo(par, k)$  in  $grupo(k)$  do
7:       if  $\max(metrica(par))$  is True then:
8:          $MCS = MCS + par$ 
9:       end if
10:    end for
11:  return  $MCS$ 
12: end for
13:

```

medida f1. O parâmetro Z , que é inserido para a função $f_cluster$, representa a matriz calculada usando a função de ligação e todos os grupos candidatos. O critério utilizado foi *distance*, uma vez que com este algoritmo é possível, a partir da distância entre os classificadores, encontrar os n MCS para a combinação do subconjunto selecionado que é a próxima etapa.

Figura 8 – Representação de tabela com exemplos dos grupos A, B, C e D.

CV-SVM	TFIDF-SVM	W2V-SVM	GLOVE-SVM	FAST-SVM
CV-LR	TFIDF-LR	W2V-LR	GLOVE-LR	FAST-LR
CV-RF	TFIDF-RF	W2V-RF	GLOVE-RF	FAST-RF
CV-NB	TFIDF-NB	W2V-NB	GLOVE-NB	FAST-NB
CV-MLP	TFIDF-MLP	W2V-MLP	GLOVE-MLP	FAST-MLP
CV-EXTRA	TFIDF-EXTRA	W2V-EXTRA	GLOVE-EXTRA	FAST-EXTRA
CV-KNN	TFIDF-KNN	W2V-KNN	GLOVE-KNN	FAST-KNN
CV-CNN	TFIDF-CNN	W2V-CNN	GLOVE-CNN	FAST-CNN

Fonte: A autora (2023). Na figura um MCS para o A formado a partir do SVM está destacado na cor vermelha. O para o B formado a partir do CV está na cor azul. O C formado por todos pela cor verde. Os pares que compõem o D pela cor roxa.

Para fazer o comparativo do grupo encontrado pela heurística proposta, foi adotada por base a proposta de (CRUZ; SOUSA; CAVALCANTI, 2022), exceto para o grupo proposto pelo trabalho. Assim, serão formados 4 grupos a partir de diferentes heurísticas aplicadas ao espaço

amostral formado pelos pares das 40 combinações entre as 5 técnicas de representações de categorias e os 8 classificadores. A descrição dos grupos está disposta a seguir:

- **Grupo A** - Grupo composto por um comitê homogêneo de pares formados a partir de um único algoritmo de classificação e cada uma das diferentes técnicas representação de características. Ao todo 5 pares são obtidos para cada classificador distinto e um total de 8 comitês diferentes.
- **Grupo B** - Grupo composto por um comitê homogêneo de pares formados a partir de uma única técnica de representação de categorias e cada um dos diferentes classificadores. Ao todo 8 pares são obtidos para cada técnica e 5 comitês diferentes.
- **Grupo C** - Grupo composto por um comitê heterogêneo, considerando todos os 40 pares possíveis pares. Esse grupo serve pra verificar o desempenho a partir do uso de todos. Apenas 1 comitê é gerado.
- **Grupo D** - Grupo composto a partir do método proposto, explorando através da heurística proposta a formação do agrupamento hierárquico desde a adoção de 1 único par até os 40 possíveis pares. Dessa forma, 40 comitês são gerados ao todo e a quantidade de pares varia para cada um, indo numa progressão aritmética crescente que começa a partir do 1 e vai até o 40 com variação de 1 par a mais para cada novo termo dela.

A Figura 8 apresenta, em complemento as descrições anteriores, uma visualização de uma tabela com exemplos de cada grupo, os quais foram escolhidos aleatoriamente dentre os comitês de cada um. O A está indicado pela seleção na linha de cor vermelha, o B pela cor azul, o C pela verde e os pares de uma grupo D pela cor roxa.

4.5 INTEGRAÇÃO DO SUBCONJUNTO

A partir do conjunto de classificadores selecionado na fase (i), é nessa etapa que ocorre a integração do aprendizado deles, a fim de compor o MCS ao final, para cada subconjunto. Com base na proposta de (CRUZ; SOUSA; CAVALCANTI, 2022), o empilhamento adotado consiste no treino do meta-classificador, a partir dos resultados de classificação obtidos pelos dados do conjunto de validação. De acordo com as ideias de (CRUZ; SOUSA; CAVALCANTI, 2022), são formados vetores pelos suportes correspondentes a cada classe de predições. Então, esse meta-classificador faz a agregação do MCS, ao combinar as saídas obtidas, na etapa de treino, e

fornecer as previsões finais sobre dados do conjunto de teste. Dessa forma, a meta-classificação pode levar a atividade de classificação a apresentar uma melhor generalização. Em (CRUZ; SOUSA; CAVALCANTI, 2022) é adotado o LR como meta-classificador e, visando explorar mais de uma técnica para estudar o comportamento de diferentes algoritmos, foram escolhidos 3 algoritmos para isto, os quais foram LR, RF e NB, utilizados em outros trabalhos para a meta-classificação. O LR foi adotado (CRUZ; SOUSA; CAVALCANTI, 2022), o RF foi adotado em (CRUZ; SABOURIN; CAVALCANTI, 2015), e o NB, por sua vez, foi adotado em (BOLDRIN et al., 2022; CRUZ; SABOURIN; CAVALCANTI, 2015).

4.6 VANTAGENS E LIMITAÇÕES DO MÉTODO

O método proposto apresenta algumas vantagens, que podem ser identificadas com relação a literatura, mas também há limitações. Elas estão dispostas na Tabela 2.

As vantagens apresentadas na Tabela 2 mostram que, similar a proposta em (CRUZ; SOUSA; CAVALCANTI, 2022), a solução tem potencial de incremento de novas técnicas de representação de categorias, assim como de outros classificadores, além dos que são adotados no experimento, para a etapa de geração do MCS. Desse modo, o conjunto de combinações de pares aumentará, caracterizando escalabilidade ao método. Por isso, o método, em alternativa a outras abordagens da literatura para detecção de FN, como (SANTANA et al., 2006), explora classificadores compostos por uma variedade de técnicas. Na etapa de seleção, o método proposto apresenta a possibilidade de usar outra métrica para mensurar a dissimilaridade entre os grupos de classificadores. Além disso, ele também viabiliza uma análise considerando diferentes níveis de dissimilaridade e, através da heurística, uma seleção automática, como outra opção a seleção proposta em (CRUZ; SOUSA; CAVALCANTI, 2022), a qual foca nos grupos encontrados em uma única análise visual e requer uma seleção manual para obter os sub-conjuntos. Outra vantagem trazida pelo método é a exploração de diversas métricas para a seleção, pois, conforme apontado em (SANTANA et al., 2006), a maioria de métodos de seleção de sistemas com múltiplos classificadores geralmente, ao adotar alguma métrica para a seleção, usa a acurácia e o método proposto possibilita que sejam consideradas outras métricas para tanto. Uma outra vantagem é a possibilidade do uso de novos algoritmos ou melhorias para a meta-classificação na etapa de integração. Ainda, o método pode ser aplicável em outras atividades de classificação.

Por outro lado, a cerca das limitações encontradas pelo método, tem-se, assim como a

Tabela 2 – Vantagens e limitações encontradas pelo método proposto.

Vantagens

Exploração de uma grande variedade de pares (E, A) .
 Escalabilidade do método quanto a adição de: novas técnicas de representação (E) , de algoritmos de classificação (A) e de meta-classificação.
 Possível adoção de outra métrica para o cálculo da dissimilaridade entre os pares (E, A) .
 Exploração de diversos níveis de dissimilaridade para obtenção dos subconjuntos, a partir de uma análise sobre diferentes quantidades de grupos de classificadores.
 Seleção automática dos subconjuntos de classificadores.
 Exploração de diversos algoritmos para etapa de meta-classificação.
 Aplicação do método para outras atividades de classificação.

Limitações

Necessidade de mais recursos computacionais à medida que forem inseridas novas técnicas na etapa de geração do MCS.
 Desempenho do agrupamento hierárquico limitado a capacidade de diferenciação da métrica adotada para o cálculo da dissimilaridade entre os pares (E, A) .
 O método não apoia uma visibilidade direta do desempenho da técnica, seja de representação de características, seja o algoritmo, ou ainda o meta-classificador, uma vez que foca no classificador final, obtido pela combinação dessas técnicas e da integração dos subconjuntos.
 A heurística adotada para a seleção não considera todas as possíveis combinações para o MCS, mas busca o subconjunto seguindo a hierarquia obtida durante o agrupamento.
 A aplicação do método considera uma análise do agrupamento hierárquico a partir de um aprendizado estático.

Fonte: A autora (2023).

proposta em (CRUZ; SOUSA; CAVALCANTI, 2022), a escalabilidade do método vai de encontro aos recursos computacionais necessários para obter a diversidade no subconjunto selecionado. Além disso, assim como este mesmo trabalho, o desempenho do agrupamento é limitado pela capacidade de diferenciação da métrica adotada, a *double-fault*. O método, por se tratar de uma abordagem que visa um sistema *ensemble*, não viabiliza diretamente uma visibilidade do desempenho da técnica, seja a de representação, ou a de algoritmo, ou de meta-classificação, mas do classificador final. Assim, este se constitui uma limitação, fazendo-se necessárias análises pelas técnicas, a fim de averiguar, com mais detalhes, o desempenho de cada uma. Outro ponto de limitação é que a heurística proposta não é capaz de analisar todas as combinações possíveis que se obtém através da Equação 4.7, em que C , nesse caso, é o símbolo para a combinação de n tomados k elementos, k é o número de agrupamentos considerados no agrupamento e varia de 1 a $m \times n$, que é o total de pares (E, A) considerado. Ao invés de explorar todos os elementos, ela segue a hierarquia, ao contrário da equação em que a ordem de seleção

não importa. Um exemplo é quando k é 1, ela seleciona o par de melhor resultado ao invés de explorar todos os possíveis elementos nesse estado. Por isso, nem todas as combinações são exploradas pelo método. Ao considerar o valor de n na equação sendo 40, ao total obtêm-se 1.099.511.627.775 possíveis combinações para MCS, dentre as quais pelo método apenas 40 são exploradas. Por fim, ainda vale notar que o método considera um aprendizado estático para a formação do MCS, em que os modelos selecionados são os mesmos para todas as instâncias de teste. Outras propostas de sistemas, como em (SANTANA et al., 2006), se baseiam em seleção dinâmica, cujo agrupamento é selecionado de acordo com um único dado de instância de teste, o que pode ser mais vantajoso em alguns cenários. Portanto, essas limitações são pontos que podem ser revistos e as vantagens mais exploradas em pesquisas futuras.

$$\sum_{n=1}^n C_k^n = \frac{n!}{(n-1)!1!} + \frac{n!}{(n-2)!2!} + \dots + \frac{n!}{(n-n)!n!} = n! \sum_{n=1}^n \frac{1}{(n-k)!k!} \quad (4.7)$$

5 METODOLOGIA EXPERIMENTAL

Este capítulo apresenta a metodologia experimental utilizada. Os experimentos foram conduzidos visando atender ao objetivo do trabalho, considerando a construção de uma proposta de seleção do MCS para a detecção de FN. Para isso, foram feitas as explorações e as análises sobre os seguintes pontos:

1. Uso de diferentes pares (E, A) .
2. Uso de conjuntos de dados com diferentes contextos e quantidade de classes.
3. Uso de diferentes algoritmos meta-classificadores para a etapa de integração na construção do MCS.

A partir desses pontos, com relação ao experimento, a Seção 5.1 é referente aos conjuntos de dados adotados, a Seção 5.2 apresenta o pré-processamento utilizado, a Seção 5.3 mostra os hiper-parâmetros adotados e, por fim, a Seção 5.4 apresenta as métricas de avaliação utilizadas. Ademais, os arquivos relacionados ao desenvolvimento do experimento estão disponíveis, no *Github*, no repositório: https://github.com/SaraBCoutinho/Pesquisa_Mestrado.

5.1 CONJUNTOS DE DADOS

Foram adotados 6 conjuntos de dados públicos utilizados pela literatura na detecção de FN, todos contendo dados textuais no idioma inglês e sido utilizados em outros trabalhos da literatura. Além disso, a maior parte deles possui contextos diferentes entre si. Esses dados foram obtidos por diversas fontes tais quais biblioteca *Datasets*, *Github*, *Zenodo* e o *Kaggle*.

A Tabela 3 apresenta as principais características de cada um desses conjuntos. A coluna dados corresponde ao nome do conjunto, a Ano ao ano em que foi apresentado por algum trabalho, a Contexto, referente ao tipo de assunto que é retratado, a coluna Divisão para indicar se ele já apresenta partições de treinamento, validação e teste, a Instâncias, mostrando a quantidade de dados dele, a Atributos, referente a quantidade de características apresentadas por cada um e a Classes, equivalente ao número de classes apresentadas.

Em complemento aos detalhes de cada conjunto mostrados na tabela, a seguir é apresentada uma breve descrição de cada um deles:

- **Liar**. Este conjunto corresponde ao Liar e foi proposto em 2017, por (WANG, 2017), sendo desde então um dos mais adotados na literatura. De acordo com (WANG, 2017),

Tabela 3 – Características dos conjuntos de dados Liar, Senti, Covid, Fa-Kes, Ott e Kaggle.

Dados	Ano	Contexto	Divisão	Instâncias	Atributos	Classes
Liar	2017	Político	Sim	12836	14	6
Sentimental Liar	2020	Político	Sim	12836	14	2
Covid-19	2020	Saúde	Sim	10700	3	2
Fa-Kes	2019	Guerra	Não	804	7	2
Ott. et Al	2011-2013	Turismo	Não	1600	5	2
Kaggle	2018	Diversos	Não	4009	4	2

Fonte: A autora (2023).

ele contém notícias sobre fatos políticos obtidas a partir da POLITIFACT.COM, as quais foram checadas pelo editor da POLITIFACT.COM. O conjunto está disponível na biblioteca *Python Datasets* ³. Ao todo, ele possui 14 atributos, dentre os quais *label*, *statement* são correspondentes à classe e à sentença, respectivamente. Ao todo são encontradas 6 classes: *pants-fire*, *false*, *barely-true*, *half-true*, *mostly-true* e *true*. Possui mais de 12,8 mil instâncias, das quais 10269 são do conjunto de treino, 1283 de validação e 1284 de teste.

- **Senti.** Este conjunto é o Sentimental Liar, que foi proposto em 2020 por (UPADHAYAY; BEHZADAN, 2020), mas para este trabalho adotou-se o nome Senti. Ele apresenta as mesmas sentenças textuais do Liar, diferindo na categorização das classes a qual tem por base as emoções. Por isso, de acordo com a proposta de (UPADHAYAY; BEHZADAN, 2020), nele as classes *pants-fire*, *false*, *barely-true*, *half-true* representam a classe de notícias falsas, enquanto que *mostly-true* e *true*, as verdadeiras, o que configura, por ser uma quantidade inferior de classes, uma complexidade menor ao dados que a observada em Liar.
- **Covid.** Este conjunto, neste trabalho denominado por Covid, corresponde ao conjunto de dados Covid-19, proposto em 2020 por (PATWA et al., 2021), e contém registros de *tweets* relacionados à pandemia Covid e, de acordo com as ideias de (PATWA et al., 2021), o contexto no qual ele foi produzido foi marcado por medidas de isolamento social e digitalização intensificada, o que aumentou o índice de postagens e gerou a necessidade de preocupação com a veracidade das notícias. De acordo com (PATWA et al., 2021), ele foi criado manualmente com registros de postagens de notícias falsas encontradas em redes sociais e as notícias verdadeiras foram obtidas em páginas do

³ <https://huggingface.co/datasets/liar>

Twitter com verificação oficial como contas oficiais do governo, Organização Mundial da Saúde (OMS), Centros de Controle e Prevenção de Doenças (CDC), Covid India Seva, Conselho Indiano de Pesquisa Médica (ICMR), além de outros importantes canais de notícias. A verificação da veracidade das notícias utilizaram sites *Polifact*, *Snopes* e *Boomlive* e API do *Twitter* como suporte. Possui 3 atributos, dentre eles *tweet* e *label* correspondentes ao conteúdos da notícia e a classe respectivamente. Apresenta 2 classes: *fake* e *true*. Ao todo, possui 10,7 mil instâncias, das quais 6420 instâncias são do conjunto de treino, 2140 de validação e 2140 de teste. Está disponível no *Github* ⁴.

- **Fa-Kes.** O conjunto Fa-Kes contém registros sobre a guerra da Síria, conflito que se iniciou em meados de 2011. Os dados foram obtidos e extraídos a partir de uma plataforma de *crowdsourcing* chamada *CrowdFlower*. A checagem dos fatos foi feita com a Syrian Violations Documentation Center (VDC database) e os dados foram obtidos pelo Zenodo⁵. As notícias do Fa-Kes, por sua vez, estão divididas em 2 classes: 0 e 1, correspondendo às falsas e às verdadeiras, respectivamente, das quais, 463 são da classe 0 e 378 da 1, totalizando 804 instâncias. Apenas uma partição com todos os dados foi disponibilizada. Dentre os atributos que compõem o conjunto estão: *labels* e o *article_content*, que é a característica que contém o texto da notícia.
- **Ott.** Este conjunto, denominado neste trabalho como apenas Ott, corresponde ao Ott. et Al. e contém a união de avaliações negativas e positivas a respeito de hotéis populares em Chicago. Ele foi apresentado nos trabalhos (OTT et al., 2011), em 2011, considerando as avaliações positivas, e em (OTT; CARDIE; HANCOCK, 2013), em 2013, com as avaliações negativas. De acordo com (OTT et al., 2011), foram obtidas avaliações pelo *TripAdvisor* ⁶, que é um site de viagens com informações turísticas. Os dados foram obtidos no Kaggle ⁷ através de um único arquivo. O conjunto possui 5 características: *deceptive*, *hotel*, *polarity*, *source* e *text*. O *deceptive* contém 2 classes, *truthful*, quando a notícia é verdadeira e *deceptive*, quando falsa. O conteúdo dela está representado pela característica *text*. Ao total, o conjunto apresenta 1600 notícias no total, das quais metade é de caráter positivo e a outra negativa, descrita na *polarity*. Destas 400 são

⁴ https://github.com/diptamath/covid_fake_news

⁵ <https://zenodo.org/record/2607278#.ZA0MQXbMLcc>

⁶ <https://www.tripadvisor.com/>

⁷ <https://www.kaggle.com/datasets/rtatman/deceptive-opinion-spam-corpus>

positivas verdadeiras, 400 positivas falsas, 400 são negativas verdadeiras e 400 negativas falsas.

- **Kaggle.** Este conjunto foi utilizado por (AHMAD et al., 2020), em estudo sobre proposta de modelos *ensemble*, e corresponde ao Kaggle Fake-News detection, mas, para este trabalho, adotou-se o nome Kaggle. Os dados foram disponibilizados, a 5 anos, em arquivo único no Kaggle ⁸ e trazem notícias sobre diversos assuntos, como política, esportes, entretenimento, projetos de On-shore e mudanças climáticas. Ademais, possui 4009 registros, dos quais 3352 são únicos. Ao todo, cada registro possui 4 características: *URL*, *headline*, *body* e *label*. O campo *body* traz o conteúdo do registro e o *label* a classe dele. A classe 0 corresponde à falsa, totalizando 2137 registros. A 1 à verdadeira, com 1872, respectivamente. Os registros verdadeiros foram obtidos de fontes como *CNN*, *New York Times* e *Reuters* e falsos pelo *Beforeitnews*.

Observando as descrições de todos os conjuntos de dados, considerando os contextos das notícias, nota-se que a detecção de FN foi um fator importante. Em cenários políticos, nos quais uma eleição é decisiva para o futuro de um país, de pandemia, nos quais se busca a saúde física e a mental, de guerra, em que o objetivo é manter a paz e segurança, em tomadas de decisões sobre roteiros de viagem, isto é, todas as situações que uma informação verdadeira agrega valor. Esse foi um fator que motivou a escolha dos conjuntos anteriormente citados, juntamente a presença da diversidade entre os contextos.

5.2 PRÉ-PROCESSAMENTO

Para a etapa de pré-processamento, cuja descrição de seu propósito foi apresentado no Capítulo 4, a Figura 9 retrata o fluxo que foi seguido na aplicação de técnicas para a normalização textual, o qual se baseia nas etapas feitas pelo trabalho (KHAN et al., 2021) que foram disponibilizadas no *Github* ⁹. Foram usadas as bibliotecas *Regex* ¹⁰ e *NLTK* ¹¹, do *Python*, para a aplicação deles. O passo 1 consistiu na remoção de pontuações e de contrações, este último para que todas as palavras usadas estivessem presentes por completo. O passo 2 se deu na correção ortográfica das palavras. Em continuação, o passo 3 promoveu a remoção de

⁸ <https://www.kaggle.com/datasets/jruvika/fake-news-detection>


⁹ https://github.com/Tawkat/Fake-News-Detection/blob/master/Codes/Neural_Network_based_Methods/DataPrep/Clean_Texts.py

¹⁰ <https://docs.python.org/3/library/re.html>

¹¹ <https://www.nltk.org/>

URLs e endereços de IP, a fim de simplificar as sentenças, retirando palavras que não acrescentam informação relevante à detecção. O 4, por sua vez, na transformação das palavras para o formato minúsculo. O 5 no *stemming*, com o objetivo de encurtar as palavras a uma parte menor que as represente. O 6 na remoção de *stopwords* e o 7 na remoção de palavras que foram menos frequentes, assim, optou-se por remover as que ocorreram apenas 1 vez no conjunto, ambos com a finalidade de eliminar palavras que não agreguem muito sentido a expressão e possam ser dispensáveis, encurtando o tamanho das sentenças.

Figura 9 – Fluxo das etapas de normalização do texto.



Fonte: A autora (2023).

Para ilustrar o que ocorre nesse processo, a seguir tem-se um exemplo da aplicação dele em um texto do conjunto Liar:

- Entrada: *Says the Annies List political group supports third-trimester abortions on demand.*
- Saída : *say list polit group support thirdtrimest abort demand.*

e TF-IDF, consideraram o tamanho do vetor de traços igual ao vocabulário do corpus para cada instância. O vetor foi o tamanho do corpus. Os modelos Word Embedding(WE), que são GLOVE, W2V e FAST, consideraram um tamanho fixo definido para cada instância do corpus.

Além do pré-processamento do conteúdo das notícias, foi observado que alguns dos conjuntos foram disponibilizados apresentando as classes como dados categóricos em formato de texto. Por isso, foi feita ainda uma conversão dessas classes para números. No caso do conjunto Covid, as classes *fake* e *true*, foram transformadas para 0 e 1 respectivamente, assim com para o Ott foi considerada como 0 a classe *deceptive* e como 1 a *truthful*. Além disso, ainda com relação às classes, nos conjuntos Covid, Fa-Kes, Ott e Kaggle notou-se um equilíbrio entre as quantidades de dados de cada uma delas. Para o Liar e Senti, apesar do cenário ser diferente dos demais, não foi constatado nos trabalhos (WANG, 2017) e (UPADHAYAY; BEHZADAN, 2020) a adoção de alguma técnica para balancear as classes, por isso não foi adotado nenhum balanceamento para o experimento.

5.3 HIPER-PARÂMETROS DOS ALGORITMOS

Os hiper-parâmetros adotados para a classificação foram baseados nos utilizados no trabalho (CRUZ; SOUSA; CAVALCANTI, 2022), o qual, através de uma proposta de solução também para uma atividade relacionada a classificação textual, adotou a técnica de *grid-search* para encontrar os melhores parâmetros para cada classificador. Dessa forma, os mesmos valores e hiper-parâmetros para os algoritmos de classificação são adotados para este trabalho. Vale notar que em (CRUZ; SOUSA; CAVALCANTI, 2022) os conjuntos possuíam 2 ou 3 classes, o que é diferente do cenário apresentado pelo Liar, adotado pelo presente trabalho, que possui 6 classes. Para os meta-classificadores foram utilizados os hiper-parâmetros padrões ao importá-los da biblioteca *Scikit-learn*. Todos eles estão na Tabela 4.

Dentre os modelos apresentados, o MLP e o CNN são baseados em aprendizagem neural. Para eles, foram adotadas as arquiteturas propostas em (CRUZ; SOUSA; CAVALCANTI, 2022). O MLP foi construído com uma única camada oculta de 100 neurônios. Já a CNN adotou uma arquitetura 1D-CNN usada em (CRUZ; SOUSA; CAVALCANTI, 2022; ZHANG; LUO, 2019; GIBERT et al., 2018):

1. **Embedding** - Camada de entrada para as representações de características a partir dos textos.
2. **Dropout1** - Camada de *dropout* para incorporar um fator de regularização na rede admi-

Tabela 4 – Hiper-parâmetros usados em cada algoritmo.

Algoritmo	Hiper-parâmetros	Etapa
SVM	Kernel [Linear Sigmoid rbf] Gamma [0.1 1 0.5]	Classificação
LR	Penalty [l1 l2]	Classificação
LR	Penalty [none]	Meta-classificação
RF	N_estimators [10 20 50]	Classificação
RF	N_estimators [100]	Meta-classificação
NB	Alpha [0.1 0.5 1] Fit_prior [False True]	Classificação
NB	Alpha [none] Fit_prior [none]	Meta-classificação
MLP	Ativação [relu logistic] Solver [adam lbfgs]	Classificação
ET	N_estimators [10 20 50]	Classificação
CNN	Ativação [sigmoid ReLU] Otimizador [rmsprop adam]	Classificação
KNN	N_neighbors [3 5]	Classificação

Fonte: A autora (2023). A coluna da esquerda representa o algoritmo de classificação e a segunda, da direita, o nome dos respectivos hiper-parâmetros, os tipos e os valores adotados para cada caso. A coluna Etapa indica se o algoritmo foi utilizado na classificação ou na meta-classificação.

tindo uma taxa de 20%.

3. **Convolution1** - Camada convolucional 1D contendo 64 filtros, com tamanho do kernel de 3 e tamanho do passo igual a 1.

4. **Subsampling1** - Camada para redução da dimensionalidade convolucional, correspondendo a operação de *pooling* 1D Max.

5. **FC1** - Camada totalmente conectada, contendo 256 neurônios.

6. **Dropout2** - Camada de inserção de fator de regularização após a totalmente conectada, contendo uma taxa de *dropout* de 20%.

7. **Softmax** - Camada final para a classificação, com base nas probabilidades para cada classe. A sua configuração varia de acordo com a quantidade de classes no conjunto.

Vale observar que, para a última camada dessa arquitetura, foram considerados parâmetros conforme a quantidade de classes, variando de 2, quando a classificação era binária, ou 6, quando multi-classe.

5.4 MÉTRICAS DE AVALIAÇÃO

Para a avaliação dos resultados, 3 dos conjuntos de dados foram disponibilizados já com partições de treino, validação e teste. Nos outros 3 que apresentaram todos os dados em

uma única partição, foi adotada a técnica *cross-validation* como alternativa para avaliação dos resultados utilizando esses conjuntos. Conforme utilizado em (AHMAD et al., 2020), para o conjunto Kaggle, foi adotado para o experimento o uso de 10 *folds*.

Quanto às métricas de avaliação dos classificadores, na Literatura a adoção delas varia de acordo com o conjunto de dados. Para o Liar, Senti, Fa-Kes, Ott e Kaggle a métrica Acurácia (*acc*) foi adotada em (HANSRAJH; ADELIYI; WING, 2021; OTT et al., 2011; AHMAD et al., 2020). Para o Senti e Covid foram utilizadas Precisão (*pre*), Revocação (*rec*) e Medida *f1* (*f1*) em (HANSRAJH; ADELIYI; WING, 2021; UPADHAYAY; BEHZADAN, 2020; PRIYA; KUMAR, 2021). Para ambos conjuntos, Liar e Senti, que possuem o mesmo conteúdo de notícias, mas quantidades de classes diferentes, foi adotada *acc* em (WANG, 2017; RASOOL et al., 2019). O uso dessa mesma métrica para avaliar esses conjuntos apoiará a análise comparativa entre as duas categorias de classificação.

Observou-se, também, que a maior parte dos conjuntos de dados usados neste experimento possuem uma quantidade de dados equilibrada para cada classe, exceto o Liar. Embora exista essa diferenciação no balanceamento dos dados, na literatura foi adotada a acurácia e, portanto, admitiu-se adotá-la neste experimento. Em suma, as métricas escolhidas são: *acc*, *pre*, *rec* e *f1*. Seguindo as ideias que foram apresentadas em (AHMAD et al., 2020), as fórmulas de cada uma estão apresentadas nas equações 5.1, 5.2, 5.3, 5.4 respectivamente:

$$acc = \frac{VP + VN}{VP + VN + FP + FN} \quad (5.1)$$

$$pre = \frac{VP}{VP + FP} \quad (5.2)$$

$$rec = \frac{VP}{VP + FN} \quad (5.3)$$

$$f1 = \frac{2 \times pre \times rec}{pre + rec} \quad (5.4)$$

Nas fórmulas das equações 5.1, 5.2, 5.3 aparecem as variáveis *VP*, *VN*, *FP* e *FN*, as quais correspondem respectivamente a verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Isso quer dizer que os dados que foram corretamente classificados e pertencem à classe verdadeira são representados por *VP* e da falsa por *VN*. Já os que são classificados incorretamente e são verdadeiros correspondem aos *FN* e os que são falsos aos *FP*.

6 RESULTADOS E DISCUSSÕES


Este capítulo apresenta os resultados e as discussões obtidos a partir da aplicação do método descrito no Capítulo 4 através das configurações experimentais retratadas no Capítulo 5. Para conduzir as análises sob a ótica do objetivo da pesquisa, foram observados 2 aspectos de avaliação: os acertos e erros obtidos pela classificação feita e o custo computacional. O desenvolvimento de cada um deles é tratado nas seguintes seções: o primeiro na seção Análise do desempenho 6.1, e o segundo na Análise do custo computacional 6.2. Ao final do capítulo é apresentada uma terceira seção contendo uma síntese dos resultados encontrados a fim de demonstrar se é vantajosa a adoção do método proposto para a detecção de FN.

6.1 ANÁLISE DO DESEMPENHO

O principal objetivo desta seção é analisar o desempenho da classificação feita pelo método proposto frente as demais abordagens de seleção adotadas nesse trabalho e as da literatura. Para isso, são analisados os resultados obtidos pelo método e é verificado, através das métricas de avaliação, se eles superam os outros. Desse modo, é possível validar se a adoção da arquitetura proposta é favorável ao processo de detecção de FN. Tendo em vista que o método proposto promove a exploração de diversas configurações de MCS, a partir da formação deles com diferentes quantidades de classificadores, a Figura 11 apresenta representações correspondentes aos maiores resultados obtidos pelo método e a dimensão delas corresponde ao número de k pares de classificadores utilizados pelo MCS, ou seja, ao tamanho do subconjunto. Dessa forma, quanto maior o círculo, mais pares foram utilizados e vice-versa. Os resultados da figura foram obtidos para o conjunto Liar e cada uma das métricas de avaliação adotadas. Escolheu-se, aqui, este conjunto, pois é o que dispõe de uma maior quantidade de classes, a fim de analisar o comportamento dos meta-classificadores e os resultados das métricas em um cenário no qual a probabilidade de acerto da classe é menor que o binário. Para os demais conjuntos os gráficos estão no Apêndice A. Na figura, as cores das representações variam de acordo com o meta-classificador utilizado, sendo a cor vermelha para o LR, azul para o RF e verde para o NB. O eixo das abscissas corresponde a métrica que foi adotada e das ordenadas ao respectivo valor do resultado calculado por elas.

Pela figura, observa-se que, dentre as representações, as do LR obtiveram os maiores

Figura 11 – Maiores resultados obtidos pelo Liar para o grupo D e cada métrica de avaliação, considerando os valores de k , variando de 1 a 40.




Fonte: A autora (2023). O tamanho das representações varia em função do valor do k . As representações em vermelho correspondem aos resultados obtidos pelo meta-classificador LR, em azul pelo RF e, em verde, pelo NB.

círculos, indicando que ele utilizou mais classificadores nos seus sistemas que obtiveram os maiores resultados. Em seguida, está o RF e, por fim, com representações bem menores que os anteriores, o NB. Embora este apresente pequenos círculos, a maioria de seus resultados, exceto para a métrica acc, ou foram o maior ou ficaram numa região do gráfico próxima ao maior resultado encontrado por um dos meta-classificadores. Dessa maneira, os sistemas das representações do NB foram capazes de aprender tão quanto os outros, ainda que tenham usado um número menor de aprendizes. Isso demonstra que a adoção de um tipo específico de algoritmo, como meta-classificador, pode impactar os resultados de modo que, mesmo com uma quantidade menor de classificadores compondo o MCS, pode-se obter um bom desempenho, assim como pode ocorrer o contrário.

Em complemento à análise anterior, a Figura 12 ilustra as curvas correspondentes aos resultados obtidos para o conjunto Liar, variando a quantidade de classificadores no sistema. Quanto aos demais conjuntos, as figuras encontram-se no Apêndice A. Da mesma forma que a figura anterior, os resultados apresentados foram obtidos a partir de cada um dos meta-classificadores, utilizando as mesmas cores da figura para as representações de cada um. Na

Figura 12 – Resultados obtidos para o cálculo das métricas sobre as classificações no conjunto Liar considerando MCS com diferentes grupos dos quais a quantidade de elementos varia em função do k .



Fonte: A autora (2023). Os resultados foram calculados a partir dos meta-classificadores LR, RF e NB. A linha vermelha representa os resultados obtidos para LR, a azul para o RF e a verde para o NB. Em cima de cada gráfico tem-se, respectivamente, a métrica considerada: o primeiro gráfico, à esquerda, corresponde aos resultados para a métrica acc, o segundo à métrica pre, o terceiro à métrica rec e o quarto à métrica f1.

figura cada um dos gráficos apresenta resultados para cada uma das métricas, dos quais o primeiro corresponde a acc, o segundo a pre, o terceiro a rec e o quarto para f1. O eixo das abscissas dos quadrantes equivale ao valor de k e do eixo das ordenadas ao resultado encontrado pela métrica.

Pela Figura 12, observa-se que nos 2 primeiros gráficos o RF obteve as curvas que, em geral, estão visivelmente mais altas e nos 2 últimos foi o LR. Entretanto, o NB obteve picos próximos aos dos demais. O ponto mais alto da curva do NB nas 4 métricas é obtido por quantidades k de classificadores menores que 10. Já do LR varia em torno de 20 e RF entre 10 e 20. Nesse contexto, nota-se que no geral é difícil identificar um padrão comportamento, seja de crescimento ou decrescimento, das curvas exceto as do NB que decrescem dado o aumento do k .

Tabela 5 – Correlação das métricas com k para cada meta-classificador adotado no grupo D.

Meta-classificador	Métrica			
	acc	pre	rec	f1
LR	0,0	-0,2	-0,5	0,2
RF	0,5	0,4	0,4	-0,4
NB	-0,8	-0,1	-0,1	-0,4


Fonte: A autora (2023).

Para validar essa observação, foi calculada a correlação de *Pearson* entre a variável k e o resultado da métrica obtido. A Tabela 5 apresenta os resultados obtidos para cada métrica e meta-classificador, a partir dos resultados observados na Figura 12. Observa-se que apenas o meta-classificador NB apresentou na métrica acc uma correlação forte, embora negativa, entre a variável k e o resultado obtido pelo cálculo da acc. Isso corrobora com a análise anterior de

que não é simples detectar uma relação linear entre a quantidade de classificadores adotados e a métrica obtida pelo MCS, reforçando a ideia da necessidade de seleção do sistema. Além disso, vale destacar que a quantidade de classificadores no MCS que acerta mais para o NB tende a ser pequena, utilizando-se a métrica acc.

Ademais, outra observação na Figura 12 é que os maiores resultados obtidos na maioria das curvas se deu considerando aproximadamente metade dos classificadores. Isso indica que a adoção do método proposto para a seleção do MCS, dada a imprevisibilidade do comportamento da métrica pelo valor do k , apresenta-se vantajosa, pois promove a exploração de grupos com k classificadores, dentre 1 a 40, para compor o sistema, de forma a possibilitar encontrar o que traz a maior métrica e possui o aprendizado mais diverso entre eles.

Figura 13 – Número de acertos pelo número de k para o conjunto de dados Liar, grupo D e métrica acc.



Fonte: A autora (2023).

A presença da diversidade e da capacidade de acerto por uma quantidade de classificadores em torno da metade deles pode ser verificada também através da análise Oracle. De acordo com as ideias de (LUDMILA, 2004), a avaliação de um MCS por ela permite apoiar as avaliações sobre o nível de acerto do sistema. Ela apresenta a quantidade de acertos máxima alcançada por um sistema à proporção que um novo classificador é adicionado a ele, o que corresponde ao crescimento do valor do k do MCS. Dessa maneira, é verificado se existe no sistema ao menos um classificador capaz de prever corretamente um novo dado. Ao final é somado a quantidade de instâncias do conjunto de dados que podem ser preditas corretamente por pelo menos um desses que compõem o MCS.

Para ilustrar a análise do Oracle, a Figura 13 mostra a curva que resume os resultados obtidos por ela, considerando os MCS obtidos pelo grupo D pelo conjunto Liar e a métrica acc. No eixo das abscissas está a variável k e no das ordenadas a quantidade de acertos do

sistema, equivalente ao oracle. Verifica-se que o número de acerto aumenta à medida que o k aumenta, contudo, o comportamento desse crescimento varia de acordo com o k . Observa-se que quando ele varia até o intervalo em torno de 10, a curva se expande rapidamente. Após isso, o número de acertos apresenta uma variação menor dado o aumento do k . Dessa maneira, a aprendizagem, considerando mais classificadores no MCS, apresenta-se mais redundante. Em contrapartida, quando ele é composto por poucos elementos o número de acertos é menor. Assim, é ratificada a ideia da presença de diversidade por meio da seleção de um grupo deles e que apoia a ocorrência do aumento da quantidade de acertos do sistema.

Ainda analisando os resultados obtidos pelo método proposto, no que concerne aos classificadores utilizados por esses MCS, que obtiveram os maiores resultados para cada métrica, os quais para o conjunto Liar estão representados na Figura 11, a lista a seguir apresenta as combinações de pares E, A que compuseram cada um desses sistemas. Para analisar detalhadamente as associações que foram utilizadas, são relatados os grupos obtidos para todos os conjuntos de dados e as métricas de avaliação adotadas. Em complemento, as tabelas com cada um dos resultados obtidos para todos os grupos e métricas do conjunto Liar estão no Apêndice B, do Senti no C, do Covid no D, do Fa-Kes no E, do Ott no F e o do Kaggle no G. É importante destacar que na análise dos resultados, escolheu-se o grupo que obteve o maior resultado a partir do menor valor de k , tendo em vista que ele apresenta aprendizes mais diversos entre si.

Liar:

- **(acc)** CV-ET, TF-IDF-RF, GLOVE-RF, W2V-SVM, TF-IDF-ET, MLP-W2V, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, MLP-TF-IDF, FAST-KNN, FAST-NB, W2V-KNN, W2V-ET, TF-IDF-KNN.
- **(pre)** W2V-SVM.
- **(rec)** TF-IDF-CNN, MLP-W2V, CV-ET, W2V-RF, FAST-RF, FAST-NB, TF-IDF-RF, FAST-MLP, TF-IDF-ET, TF-IDF-SVM, W2V-LR, MLP-TF-IDF, W2V-SVM, FAST-SVM, GLOVE-RF, W2V-KNN, TF-IDF-KNN, GLOVE-SVM, FAST-KNN, W2V-ET, CV-KNN.
- **(f1)** MLP-W2V, FAST-RF, W2V-RF, CV-ET, TF-IDF-ET, TF-IDF-SVM, TF-IDF-RF, FAST-MLP, MLP-TF-IDF, W2V-LR, FAST-NB, FAST-SVM, W2V-SVM, TF-IDF-CNN, GLOVE-RF, W2V-KNN, FAST-KNN, TF-IDF-KNN, GLOVE-SVM, W2V-ET, CV-KNN.

Senti:

- (acc) W2V-SVM.
- (pre) W2V-SVM.
- (rec) W2V-SVM, W2V-KNN, FAST-NB, FAST-MLP, TF-IDF-SVM.
- (f1) W2V-SVM, W2V-KNN, FAST-NB, FAST-MLP, TF-IDF-SVM.

Covid:

- (acc) TF-IDF-SVM, CV-ET, TF-IDF-NB, CV-MLP, W2V-LR, MLP-TF-IDF, TF-IDF-ET, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, MLP-W2V, FAST-SVM, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-ET, FAST-LR, FAST-RF, W2V-ET, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, MLP-GLOVE, GLOVE-RF, GLOVE-ET, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB.
- (pre) TF-IDF-SVM, CV-ET, TF-IDF-NB, FAST-SVM, CV-MLP, MLP-TF-IDF, TF-IDF-ET, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-CNN, W2V-SVM, TF-IDF-RF, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-ET, FAST-LR, FAST-RF, W2V-ET, W2V-RF, FAST-KNN, GLOVE-CNN, GLOVE-SVM, MLP-GLOVE, GLOVE-RF, CV-KNN, FAST-NB, GLOVE-KNN.
- (rec) TF-IDF-SVM, CV-ET, W2V-LR, TF-IDF-NB, CV-MLP, MLP-TF-IDF, TF-IDF-ET, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, CV-CNN, W2V-CNN, FAST-SVM, MLP-W2V, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-ET, FAST-RF, FAST-LR, W2V-ET, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-RF, MLP-GLOVE, GLOVE-ET, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB.
- (f1) TF-IDF-SVM, CV-ET, TF-IDF-NB, FAST-SVM, CV-MLP, MLP-TF-IDF, TF-IDF-ET, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-KNN, W2V-CNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-ET, FAST-LR, FAST-RF, W2V-ET, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-RF, MLP-GLOVE, FAST-NB, GLOVE-CNN, GLOVE-KNN, CV-KNN.

Fa-Kes:

- (**acc**) TF-IDF-KNN, W2V-KNN, W2V-LR, CV-NB, W2V-SVM, GLOVE-NB, TF-IDF-CNN, GLOVE-SVM, CV-KNN, CV-RF, FAST-SVM, FAST-KNN, FAST-CNN, FAST-NB, CV-SVM, W2V-RF, CV-ET, GLOVE-ET, TF-IDF-SVM, GLOVE-KNN, W2V-NB, MLP-GLOVE, CV-MLP, MLP-TF-IDF, GLOVE-CNN, CV-LR, W2V-ET, TF-IDF-ET, FAST-RF, W2V-CNN, FAST-ET, FAST-MLP, TF-IDF-RF, CV-CNN, MLP-W2V.
- (**pre**) CV-NB, TF-IDF-KNN, W2V-KNN, CV-KNN, GLOVE-NB, FAST-KNN, W2V-SVM, W2V-LR, FAST-CNN, CV-SVM, GLOVE-SVM, CV-RF, TF-IDF-CNN, FAST-SVM, W2V-RF, FAST-NB, GLOVE-ET, CV-ET, TF-IDF-SVM, GLOVE-KNN, W2V-NB, CV-MLP, MLP-GLOVE, MLP-TF-IDF, TF-IDF-ET, W2V-ET, CV-LR, FAST-RF, W2V-CNN, FAST-ET, TF-IDF-RF, FAST-MLP, MLP-W2V, CV-CNN, GLOVE-CNN.
- (**rec**) W2V-SVM.
- (**f1**) W2V-SVM.

Ott:

- (**acc**) MLP-TF-IDF, TF-IDF-SVM, CV-MLP, CV-NB, TF-IDF-NB, TF-IDF-ET, CV-ET, CV-LR, TF-IDF-RF, TF-IDF-CNN, CV-SVM, MLP-W2V, FAST-SVM, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-ET, W2V-NB, FAST-ET, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-LR, CV-CNN, GLOVE-RF, MLP-GLOVE, FAST-LR, GLOVE-ET, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN.
- (**pre**) TF-IDF-SVM, W2V-NB, W2V-CNN, CV-NB, TF-IDF-KNN, MLP-TF-IDF, CV-MLP, CV-ET, TF-IDF-ET, FAST-CNN, GLOVE-CNN, TF-IDF-RF, CV-SVM, FAST-MLP, CV-LR, CV-RF, CV-KNN, W2V-SVM, FAST-RF, FAST-SVM, W2V-KNN, W2V-LR, W2V-RF, W2V-ET, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-RF, FAST-LR, GLOVE-ET, MLP-GLOVE, CV-CNN, GLOVE-KNN.
- (**rec**) CV-CNN, MLP-TF-IDF, CV-MLP, TF-IDF-SVM, FAST-SVM, CV-NB, CV-LR, W2V-CNN, TF-IDF-ET, W2V-NB, CV-ET, CV-SVM, W2V-SVM, TF-IDF-RF, W2V-LR, MLP-GLOVE, W2V-RF, FAST-MLP, FAST-CNN, CV-RF, CV-KNN, GLOVE-SVM, FAST-RF, W2V-KNN, FAST-LR, FAST-NB, TF-IDF-KNN, FAST-KNN, GLOVE-ET, GLOVE-KNN, GLOVE-CNN.

- **(f1)** MLP-TF-IDF, TF-IDF-SVM, CV-MLP, CV-NB, TF-IDF-NB, TF-IDF-ET, CV-ET, CV-LR, TF-IDF-CNN, CV-SVM, TF-IDF-RF, FAST-SVM, W2V-SVM, FAST-CNN, FAST-MLP, CV-RF, TF-IDF-KNN, W2V-LR, W2V-RF, FAST-RF, CV-CNN, W2V-NB, W2V-ET, W2V-KNN, W2V-CNN, FAST-ET, FAST-NB, GLOVE-LR, GLOVE-SVM, MLP-GLOVE, FAST-KNN, FAST-LR, GLOVE-RF, GLOVE-ET, GLOVE-NB, GLOVE-KNN, CV-KNN, GLOVE-CNN.

Kaggle:

- **(acc)** W2V-KNN, TF-IDF-SVM, FAST-CNN, CV-MLP, MLP-TF-IDF, FAST-SVM, CV-ET, TF-IDF-ET, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-ET, W2V-NB, W2V-ET, GLOVE-CNN, GLOVE-RF, FAST-KNN, MLP-GLOVE, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB.
- **(pre)** TF-IDF-SVM, MLP-TF-IDF, FAST-CNN, CV-MLP, FAST-MLP, W2V-SVM, CV-KNN, CV-ET, TF-IDF-ET, GLOVE-CNN, W2V-RF, FAST-NB, MLP-GLOVE, FAST-LR, FAST-KNN, GLOVE-KNN.
- **(rec)** CV-CNN, TF-IDF-ET, CV-ET, CV-RF, TF-IDF-CNN, TF-IDF-SVM, CV-MLP, FAST-CNN, MLP-TF-IDF, TF-IDF-RF, W2V-LR, CV-NB, CV-SVM, TF-IDF-NB, TF-IDF-LR, FAST-MLP, FAST-ET, W2V-KNN, W2V-ET, W2V-RF, W2V-SVM, FAST-KNN, TF-IDF-KNN, FAST-RF, FAST-NB, GLOVE-ET, FAST-SVM, GLOVE-CNN, GLOVE-RF, GLOVE-KNN, GLOVE-SVM, FAST-LR, W2V-NB, MLP-GLOVE, W2V-CNN, CV-KNN, GLOVE-NB.
- **(f1)** W2V-KNN, TF-IDF-SVM, CV-MLP, FAST-CNN, MLP-TF-IDF, FAST-SVM, CV-ET, TF-IDF-ET, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, W2V-ET, GLOVE-CNN, FAST-KNN, MLP-GLOVE, FAST-LR, GLOVE-KNN, CV-KNN.

Pela lista apresentada, diferentes combinações foram observadas para cada métrica e conjunto de dados. Dentre elas algumas estiveram mais frequentes, estando presentes em diversos MCS. Entretanto, uma delas se apresentou como o único componente dos sistemas reportados, a qual foi o W2V-SVM. Além disso, a Tabela 6 apresenta o suporte dos 5 pares ou conjuntos de pares que foram mais frequentes entre os elementos da lista .

Conforme verificado pela análise da lista, de fato o W2V-SVM foi o par que obteve o maior suporte, o qual foi de 1,000. Isso significa que ele esteve presente em todos os 24 grupos da

Tabela 6 – Pares e combinações de pares mais frequentes nos MCS que obtiveram os maiores resultados.

Técnica	Suporte
W2V-SVM	1,000
TF-IDF-SVM, FAST-NB	0,792
W2V-SVM, FAST-NB, FAST-MLP	0,792
FAST-NB, FAST-MLP, TF-IDF-SVM, W2V-SVM	0,792
FAST-NB, W2V-SVM	0,792

Fonte: A autora (2023). Para a obtenção da tabela, foram considerados, dentre os 40 grupos analisados pelo método, a partir de cada conjunto de dados e métrica de avaliação. A coluna Classificadores apresenta os pares ou conjunto deles e a Suporte o valor de frequência encontrado para eles.

lista, além de compor sozinho alguns grupos. Esse desempenho dele pode ser explicado pelo fato de que o W2V é uma técnica capaz de identificar o contexto das sentenças, seja uma sentença verdadeira ou falsa. Em posse disso, o SVM estabelece as fronteiras de separação que conseguem distinguir a classificação do texto, seja em cenários com 2 ou 6 classes. Por isso, a combinação deles dois promove essa vantagem de aprendizado em alguns dos *corpus* dos conjuntos adotados.


Quanto às combinações dos pares apresentados na 6, as técnicas de representação mais frequentes foram W2V, TF-IDF e FAST, associadas aos algoritmos SVM, KNN e MLP. Isso demonstra que estes os algoritmos possuem boa capacidade de aprendizado associados a técnicas de representação estatística, tais quais W2V e FAST, pois apresentam um maior suporte dentre os maiores resultados. Ademais, o TF-IDF associado ao SVM também é uma técnica que apresenta bons resultados e traz diversidade quando aprende junto com outros pares de aprendizado estatístico.

Em adição as análises anteriores, comparando o desempenho do método proposto com os dos demais grupos, a Figura 14(b) retrata o percentual dos resultados em que cada um deles foi a abordagem que apresentou o maior resultado para a métrica de avaliação. Para isso, foram considerados o grupo dos classificadores monolíticos e A, B, C e D, apresentados na etapa de seleção do Capítulo 5. Cada uma dessas categorias é representada numa cor diferente: o grupo dos monolíticos de cinza claro, grupo A de cinzento-ardósia claro, B de cinza, C de cinzento-ardósia e D de cinzento-ardósia escuro. Na construção da figura foram considerados todos os resultados obtidos e verificados os maiores valores por cada conjunto de dados e métrica, assumido como o melhor resultado encontrado. Para os conjuntos Fa-kes, Ott e Kaggle foram consideradas as médias dos *folds* como resultado a ser comparado. Além

Figura 14 – Desempenho dos grupos.

Dados	acc	pre	rec	f1
Liar	Monolítico	Monolítico	C	Monolítico
Senti	D	D	D	D
Covid	Monolítico	Monolítico	Monolítico	C
Fa-Kes	Monolítico	Monolítico	Monolítico	Monolítico
Ott	B	Monolítico	D	Monolítico
Kaggle	C	D	Monolítico	D

(a) Tabela com grupo por conjunto e métrica.




(b) Percentual que cada grupo alcançou o melhor resultado frente aos demais, considerando todos os conjuntos de dados e métricas adotados.

Fonte: A autora (2023).

disso, quando mais de um grupo alcançou o maior resultado, foi considerado o grupo que o obteve a partir de uma quantidade menor de elementos. Os registros detalhados de cada um estão na tabela da Figura 14(a).

O grupo composto por classificadores monolíticos foi o que mais esteve presente, obtendo aproximadamente 54,2% dos resultados dentre os que foram analisados. Em seguida foi o grupo D com aproximadamente 29,2%, obtido pelo método proposto. O grupo C também teve um percentual próximo, com 12,5%. Por conseguinte, o grupo B com aproximadamente 4,2%. O grupo A não obteve nenhum resultado que superou os demais para nenhuma das métricas e conjunto de dados. Apesar do grupo D não ter obtido o maior resultado em todos os conjuntos e métricas, ele apresentou um desempenho melhor que os grupos A, B e C, demonstrando que a heurística de seleção do método pode ser vantajosa no aprendizado em alguns dos dados adotados. Entretanto, vale notar através dos resultados obtidos, que alguns classificadores monolíticos foram capazes de aprender, em determinados contextos, melhor que os demais grupos, incluindo o grupo D.

Figura 15 – Dados obtidos após a aplicação da técnica CV em diferentes conjuntos.



Fonte: A autora (2023).

Ademais, outra observação interessante pela tabela da Figura 14 é que o grupo D alcançou todos os melhores resultados para o conjunto Senti, mas nenhum para o Liar. Contudo, ambos os conjuntos possuem o mesmo *corpus*, diferindo apenas na quantidade de classes que consideram. Um possível fator que pode ter influenciado nesse resultado advém dos hiper-parâmetros adotados para a etapa de aprendizado, os quais foram utilizados considerando cenários com 2 ou 3 classes. Para entender o comportamento dos dados de cada um desses cenários, a Figura 15 apresenta a transformação aplicada pelo CV no conjunto de dados Liar, na (a) e Senti, na (b).

Observa-se na figura que é mais fácil visualizar os pontos das classes 0 e 1 na Figura (b) do que encontrá-los dentre as 6 classes do (a). Por isso, a probabilidade de errar a classe para o conjunto Liar é maior do que para o Senti. Dessa forma, em um cenário com menos complexidade dos dados, o sistema apresentou maiores valores para as métricas e, por isso, um melhor desempenho. Contudo, vale ressaltar que resultados do método para o Liar ficaram próximos aos melhores que foram encontrados, conforme apresentado no Apêndice B pelas acurácias obtidas pelo FAST-MLP e pelo D-RF. Dessa forma, isso aponta para um ponto de possível melhoria do método e sugere que sejam investigados, em pesquisas futuras, o ajuste dos modelos para esses cenários e formas de lidar com cenários de complexidade maior.

Para validar estatisticamente os resultados obtidos pelo método proposto frente aos demais grupos, foi realizado um teste de Hipótese. Para isso, foram considerados os comparativos entre cada classificador monolíticos e grupos A, B e C, sendo estes obtidos a partir de cada meta-classificador. O teste foi aplicado aos conjuntos de dados Fa-Kes, Ott e Kaggle, os quais possuem 10 amostras correspondentes a cada *fold*. Primeiramente, é feito um teste de

aderência por classificador em cada conjunto de dados e métrica, para verificar a distribuição das amostras. Se ela for semelhante a uma curva gaussiana, aplica-se um teste paramétrico. Caso contrário, outro teste não paramétrico é escolhido. O teste utilizado é Shapiro-Wilk, com $\alpha = 0,05$. As hipóteses para este teste são:

- H_0 : a distribuição dos dados é semelhante a uma curva gaussiana.
- H_1 : a distribuição de dados não é semelhante a uma curva gaussiana.

No teste de aderência escolhido, caso os resultados rejeitem H_0 , a distribuição dos dados não é semelhante a uma curva gaussiana e um teste de hipótese não paramétrico deve ser adotado. Caso não rejeitem H_0 , há indícios de que a distribuição dos dados é semelhante a uma curva gaussiana e o teste deve ser paramétrico. Os resultados, os quais estão no Apêndice H, mostram que a maioria deles não rejeitou H_0 , contudo uma parte rejeitou e, por esse motivo, adotou-se para o teste de hipótese o teste Wilcoxon, o qual é não-paramétrico. O *p-value* considerado como limiar foi de 0,05. Como etapa posterior foi feito o teste de hipótese. Para este as hipóteses são:

- H_0 : não há diferença significativa entre o classificador comparado e o grupo D.
- H_1 : existe uma diferença significativa entre o classificador comparado e o grupo D.

O teste foi feito para os grupos D-LR, D-RF e D-NB, comparados cada um deles 2 a 2, a todos os classificadores sejam monolíticos ou dos grupos A, ou B, ou C. Para as análises dos resultados, no cenário em que o *p-valor* for menor que 0,05, H_0 é rejeitada. Isso quer dizer que há evidência estatística para sustentar a afirmação de que existe uma diferença significativa entre os resultados do grupo D e do que ele é comparado. Caso este valor seja maior que 0,05, H_0 não é rejeitada e não há diferença significativa entre eles. Os resultados, que estão apresentados no Apêndice H, demonstram que a maioria deles foi significativa estatisticamente com relação ao outro classificador comparado. Dentre os resultados que não rejeitaram H_0 , nenhum dos classificadores apresentou essa rejeição para todas as métricas e/ou conjuntos de dados.

Além das análises comparativas entre o grupo D e os demais grupos citados anteriormente, é interessante verificar o desempenho do método proposto mediante resultados de abordagens alternativas encontradas na literatura, a fim de verificar se os valores estão próximos ao es-

Tabela 7 – Resultados encontrados na literatura e pelo método proposto para cada conjunto de dados e métrica acc.

Dados	Referência	Abordagem	Resultado	<i>Baseline</i>	Elbow	Método proposto
Liar	(WANG, 2017)	Híbrido CNN	0,274	0,167	0,232	0,241
Senti	(HANSRAJH; ADELIYI; WING, 2021)	BDL	0,608	0,500	0,664	0,677
Covid	(SURENDRAN et al., 2021)	CNN-LSTM	0,930	0,500	0,898	0,931
Fa-Kes	(NASIR; KHAN; VARLAMIS, 2021)	CNN-RNN	0,600	0,500	0,499 (0,037)	0,526
Ott	(OTT et al., 2011)	LIWC + <i>Bigrams</i> + SVM	0,898	0,500	0,800 (0,033)	0,865
Kaggle	(AHMAD et al., 2020)	RF	0,950	0,500	0,931 (0,026)	0,987

Fonte: A autora (2023). Os maiores resultados apresentados estão destacados em negrito.

perado. Para tanto, foi considerada uma abordagem da literatura utilizada para cada um dos conjuntos de dados.

Para complementar a comparação com outras abordagens alternativas, também foi adotado um *Baseline* correspondente a um classificador aleatório. O cálculo da sua métrica corresponde a acc e considera a divisão de 100% de acerto pela quantidade de classes. Por esse motivo, na comparação dessas abordagens apenas a acc foi verificada. O conjunto de dados de 2 classes obteve em 50% (0,5) e o de 6 aproximadamente 16,7% (0,167).

Por fim, uma última abordagem adotada, comumente usada em problemas de agrupamento, é o método *Elbow*. De acordo com as ideias de (D'SILVA; SHARMA, 2020), este se baseia na determinação do número ótimo de grupos para encontrar a quantidade ideal de agrupamentos, observando o equilíbrio da distância entre os grupos e entre os elementos dele. Dessa forma, uma comparação com essas abordagens pode enriquecer a análise a respeito do desempenho do método.

Pela Tabela 7, observa-se que alguns resultados obtidos pelo método proposto foram melhores do que a literatura e sempre melhores que os obtidos pelo *Baseline*. O método proposto superou os resultados obtidos pela literatura nas métricas acc e pre de Senti e também acc, em Ott e Kaggle. Em Fa-Kes o resultado de acc foi igual ao encontrado na literatura. Nas demais

métricas e conjuntos de dados, os resultados da literatura foram maiores. Alguns trabalhos adotaram mais categorias, além dos textos dos conteúdos das notícias, para o aprendizado, tal qual fez o (WANG, 2017) e obteve o resultado superior ao da acurácia obtida pelo método no conjunto Liar. Sugere-se, portanto, como melhorias futuras no método estudar essa ideia a fim de se verificar a obtenção de melhor desempenho dele.


Outra observação importante identificada por meio da tabela é a diferença dos valores obtida pelas métricas em diferentes conjuntos de dados. Nota-se que o intervalo de valores alcançados por elas difere bastante. Alguns dos fatores que podem ter influenciado no aprendizado são o tamanho do conjunto de dados, o *corpus* utilizado e a quantidade de classes. Embora esse comportamento seja observado, o intervalo de valores dos resultados obtidos é próximo ao da literatura, ratificando que o método é capaz de obter resultados equiparáveis aos da literatura.

6.2 ANÁLISE DO CUSTO COMPUTACIONAL

Em adição as análises da seção anterior sobre a classificação feita pelo método, esta seção tem por objetivo analisar o comportamento do uso dos recursos computacionais frente aos experimentos do método proposto, com o propósito de verificar se ele compensa computacionalmente. A Figura 16 apresenta um mapa de calor sobre o custo computacional gasto em termos de tempo, em segundos, para o treinamento dos classificadores dos grupos A, B, C e D, os quais foram obtidos a partir da técnica de empilhamento, utilizando ambiente colab com CPU. Os resultados apresentados são, ainda, obtidos pelo Liar, o qual é um dos maiores conjuntos adotados no experimento. Foram consideradas as formações de cada um deles pelos 3 meta-classificadores LR, RF e NB.

Além dos grupos apresentados na figura, o treinamento dos 40 modelos monolíticos do Liar utilizou no total aproximadamente 5.455 segundos. Na figura, o grupo D foi o que demandou mais tempo, sobretudo utilizando o meta-classificador RF. Isto se deu provavelmente pelo método propor a construção de 40 combinações diferentes, o que é um número maior que dos demais. Apesar disso, o maior tempo apresentado na figura foi de aproximadamente 700 segundos, o que demonstra ser um tempo viável dada a quantidade de combinações exploradas. Além disso, tendo em vista um menor tempo utilizado pelo NB com relação aos demais meta-classificadores, é interessante atentar na escolha do algoritmo utilizado para a meta-classificação, pois ele pode impactar consideravelmente no tempo de treinamento.

Figura 16 – Mapa de calor sobre o tempo gasto para execução de etapas de treinamento dos pares monolíticos e grupos A, B, C e D para o Liar.



Fonte: A autora (2023). A escala à direita corresponde aos segundos gastos por cada abordagem. Os menores valores se aproximam do tom de cinza mais fraco enquanto que os maiores de uma nuance mais forte.

6.3 SÍNTESE DOS RESULTADOS

A partir dos resultados apresentados nas seções anteriores desse capítulo e das discussões feitas, foram levantados os pontos a seguir como síntese do que foi verificado:

1. Observou-se que é difícil perceber um padrão do valor de k que traz o maior resultado para a métrica de avaliação.
2. Foi observada uma variedade de técnicas de representação de características e algoritmos de classificação entre os MCS que obtiveram os maiores resultados para cada conjunto de dados e de métrica.
3. Os algoritmos mais frequentes juntos foram KNN, SVM e MLP associados às técnicas W2V, TF-IDF e FAST.

4. Em alguns conjuntos de dados e métricas, o grupo D conseguiu alcançar melhores resultados com relação as outras abordagens verificadas e aos resultados da literatura.
5. A maior parte dos resultados obtidos pelo grupo D foram estatisticamente significantes com relação aos monolíticos e grupos A, B e C.
6. O método proposto obteve melhor performance em cenários binários que multi-classe.
7. O método proposto apresentou uma performance equiparável com a literatura em conjuntos de dados de contextos diversos e e superou todos os resultados obtidos pelo *Baseline* e pelo *Elbow*.
8. O método proposto foi viável computacionalmente, sobretudo a partir do uso do meta-classificador NB.

A partir dessa síntese, verificou-se que o método proposto foi capaz de trazer resultados promissores uma vez que eles foram comparáveis aos demais e foram viáveis computacionalmente. Além disso, a dificuldade observada em identificar que classificadores são diversos justificou a adoção do método, dada a sua exploração de diferentes níveis de diversidade para obtenção do classificador. Entretanto, vale ressaltar que por ele não ter alcançado o melhor desempenho em nenhuma das métricas de alguns conjuntos de dados, é interessante serem exploradas melhorias a fim de potencializar a capacidade de generalização do sistema encontrado.

7 CONCLUSÃO

A detecção de FN é uma atividade de classificação textual importante para evitar a desinformação. Tendo em vista esse tipo de tarefa, os MCS têm sido uma abordagem promissora, contudo, encontrar um sistema que possua uma maior capacidade de generalização não é simples, uma vez que é essencial que este apresente diversidade entre seus classificadores. Por isso, o presente trabalho teve por objetivo propor um método para selecionar um subconjunto do *pool* de classificadores, apresentando diversidade, aplicado à detecção de FN. Após um estudo da literatura, adotou-se classificadores heterogêneos e a abordagem de agrupamento hierárquico em resposta a necessidade de se ter uma seleção do sistema, além de trazer a possibilidade de explorar diversas formações, considerando diferentes níveis de dissimilaridade, para o compor.

Para tanto, o método proposto foi composto por 2 fases: fase (i), correspondente ao treinamento dos classificadores, e fase (ii), ao teste. Na (i), foram treinados os classificadores a partir da aplicação de 5 técnicas de representação de características, a saber CV, TF-IDF, GLOVE, W2V e FAST, e, em seguida, de 8 algoritmos, os quais foram SVM, LR, RF, NB, ET, MLP, CNN e KNN. As combinações entre eles geraram ao final 40 classificadores, com os quais foram feitas as predições. Para verificar a diversidade entre eles foi construída uma matriz de dissimilaridade, usando uma métrica *double-fault* e, logo após, foi feita a seleção utilizando a heurística proposta com base na diversidade existente entre eles e no desempenho de métrica observados. Por fim, foi feita a integração dos MCS encontrados e as predições finais.

Para analisar o desempenho obtido pelo método proposto, o experimento considerou 6 conjuntos de dados: Liar, Senti, Covid, Fa-Kes, Ott e Kaggle, com diferentes contextos e quantidades de classes, dentre os quais o Liar contém 6 e os demais apenas 2 classes. Aos dados textuais foi aplicado um pré-processamento para normalização das sentenças e, quando necessário, as classes foram transformadas em números. Para a avaliação do desempenho foram adotadas as métricas acc, pre, rec e f1. Os resultados foram calculados para os pares de classificadores monolíticos, grupo A, com comitês gerados a partir de um classificador, variando as técnicas de representação de características, grupo B gerado a partir de uma técnica e diferentes classificadores, grupo C com todos os pares e, por fim, grupo D gerado a partir da heurística proposta. Por conseguinte, para gerar esses últimos 4 grupos foram

adotados 3 meta-classificadores: LR, RF e NB.

No que tange aos resultados encontrados pelo experimento, observou-se que o grupo D obteve um maior desempenho para alguns conjuntos de dados, sobretudo o Senti, de classificação binária. Além disso, o MCS que obteve o maior valor de acerto foi composto geralmente por quantidades de classificadores próximas a 20, com pares que apresentaram variedade nas técnicas de representação e de algoritmos. Dentre eles, um classificador que esteve frequentemente presente nos MCS obtidos foi o SVM-W2V. Ademais, a maioria dos resultados encontrados pelo método proposto apresentaram significância estatística com relação aos demais grupos e modelos monolíticos. Ainda com relação à literatura, ao modelo *Baseline* e à abordagem usando *Elbow* para seleção, os resultados do método, para a métrica acc, também apresentaram um desempenho superior ou próximo ao maior. Por fim, o grupo D apresentou-se como uma solução viável em termos de custo computacional e os meta-classificadores de melhor desempenho e menor custo computacional foram NB e LR.

Dessa maneira, o trabalho mostrou sua contribuição ao propor um MCS para a detecção de FN, obtido a partir do agrupamento hierárquico trazido como inovação e principal vantagem à adoção do método. A abordagem proposta mostrou que foi possível obter resultados promissores e equiparáveis com outros resultados encontrados na literatura. Para concluir, como melhorias e trabalhos futuros, seguindo o Capítulo 4 e as análises dos resultados, propõe-se explorar mais as vantagens do método e buscar soluções para as suas limitações. Dessa forma, sugere-se que sejam adotados novas técnicas de representação de características e algoritmos a fim de possibilitar aumento da diversidade do sistema. Além disso, podem ser utilizados conjuntos de dados em outros idiomas e contextos, acrescentadas novas características, além do conteúdo da notícia, para fornecer mais informações ao aprendizado, bem como pode ser feito um novo ajuste de hiper-parâmetros aos conjuntos usados. Outra melhoria pode advir da busca por soluções ótimas para o método. Por fim, outra opção que pode ser interessante, proposta em (BOLDRIN et al., 2022), é a adoção de uma abordagem de empilhamento multi-nível como possível melhoria a etapa de integração do método.

REFERÊNCIAS


- AHMAD, I.; YOUSAF, M.; YOUSAF, S.; AHMAD, M. O. Fake news detection using machine learning ensemble methods. *Complexity*, Hindawi Limited, v. 2020, p. 1–11, 2020.
- ALLCOTT, H.; GENTZKOW, M. Social media and fake news in the 2016 election. *Journal of economic perspectives*, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203-2418, v. 31, n. 2, p. 211–236, 2017.
- ALONSO, M. A.; VILARES, D.; GÓMEZ-RODRÍGUEZ, C.; VILARES, J. Sentiment analysis for fake news detection. *Electronics*, MDPI, v. 10, n. 11, p. 1348, 2021.
- BEAUVAIS, C. Fake news: Why do we believe it? *Joint Bone Spine*, Elsevier, v. 89, n. 4, p. 105371, 2022.
- BENGFORT, B.; BILBRO, R.; OJEDA, T. *Applied text analysis with Python: Enabling language-aware data products with machine learning*. [S.l.]: "O'Reilly Media, Inc.", 2018.
- BOJANOWSKI, P.; GRAVE, E.; JOULIN, A.; MIKOLOV, T. Enriching word vectors with subword information. *Transactions of the association for computational linguistics*, MIT Press, v. 5, p. 135–146, 2017.
- BOLDRIN, F. C.; CANTAO, A. H.; TINÓS, R.; BARANAUSKAS, J. A. Multi-level stacking. In: SBC. *Anais do XIX Encontro Nacional de Inteligência Artificial e Computacional*. [S.l.], 2022. p. 1–12.
- BUZEA, M. C.; TRAUSAN-MATU, S.; REBEDEA, T. Automatic fake news detection for romanian online news. *Information*, MDPI, v. 13, n. 3, p. 151, 2022.
- CRUZ, R. M.; HAFEMANN, L. G.; SABOURIN, R.; CAVALCANTI, G. D. Deslib: A dynamic ensemble selection library in python. *The Journal of Machine Learning Research*, JMLRORG, v. 21, n. 1, p. 283–287, 2020.
- CRUZ, R. M.; SABOURIN, R.; CAVALCANTI, G. D. Meta-des. h: A dynamic ensemble selection technique using meta-learning and a dynamic weighting approach. In: IEEE. *2015 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2015. p. 1–8.
- CRUZ, R. M.; SABOURIN, R.; CAVALCANTI, G. D. Dynamic classifier selection: Recent advances and perspectives. *Information Fusion*, Elsevier, v. 41, p. 195–216, 2018.
- CRUZ, R. M.; SOUSA, W. V. de; CAVALCANTI, G. D. Selecting and combining complementary feature representations and classifiers for hate speech detection. *Online Social Networks and Media*, Elsevier, v. 28, p. 100194, 2022.
- DIETTERICH, T. G. Ensemble methods in machine learning. In: SPRINGER. *Multiple Classifier Systems: First International Workshop, MCS 2000 Cagliari, Italy, June 21–23, 2000 Proceedings 1*. [S.l.], 2000. p. 1–15.
- D'SILVA, J.; SHARMA, U. Unsupervised automatic text summarization of konkani texts using k-means with elbow method. *Int J Eng Res Technol*, p. 2380–2384, 2020.
- GANESH, P.; PRIYA, L.; NANDAKUMAR, R. Fake news detection—a comparative study of advanced ensemble approaches. In: IEEE. *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)*. [S.l.], 2021. p. 1003–1008.

- GARCIA, L. P.; SÁEZ, J. A.; LUENGO, J.; LORENA, A. C.; CARVALHO, A. C. de; HERRERA, F. Using the one-vs-one decomposition to improve the performance of class noise filters via an aggregation strategy in multi-class classification problems. *Knowledge-Based Systems*, Elsevier, v. 90, p. 153–164, 2015.
- GIBERT, O. D.; PEREZ, N.; GARCÍA-PABLOS, A.; CUADROS, M. Hate speech dataset from a white supremacy forum. *arXiv preprint arXiv:1809.04444*, 2018.
- HANSRAJH, A.; ADELIYI, T. T.; WING, J. Detection of online fake news using blending ensemble learning. *Scientific Programming*, Hindawi Limited, v. 2021, p. 1–10, 2021.
- HSU, K.-W.; SRIVASTAVA, J. Diversity in combinations of heterogeneous classifiers. In: SPRINGER. *Advances in Knowledge Discovery and Data Mining: 13th Pacific-Asia Conference, PAKDD 2009 Bangkok, Thailand, April 27-30, 2009 Proceedings 13*. [S.l.], 2009. p. 923–932.
- KALIYAR, R. K.; GOSWAMI, A.; NARANG, P.; SINHA, S. Fndnet—a deep convolutional neural network for fake news detection. *Cognitive Systems Research*, Elsevier, v. 61, p. 32–44, 2020.
- KHAN, J. Y.; KHONDAKER, M. T. I.; AFROZ, S.; UDDIN, G.; IQBAL, A. A benchmark study of machine learning models for online fake news detection. *Machine Learning with Applications*, Elsevier, v. 4, p. 100032, 2021.
- LI, K. Haha at fakedes 2021: A fake news detection method based on tf-idf and ensemble machine learning. In: *IberLEF@ SEPLN*. [S.l.: s.n.], 2021. p. 630–638.
- LUDMILA, I. *Combining pattern classifiers: methods and algorithms*. [S.l.]: Wiley, 2004.
- MIKOLOV, T.; CHEN, K.; CORRADO, G.; DEAN, J. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013.
- MURTAGH, F.; CONTRERAS, P. Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 2, n. 1, p. 86–97, 2012.
- NASIR, J. A.; KHAN, O. S.; VARLAMIS, I. Fake news detection: A hybrid cnn-rnn based deep learning approach. *International Journal of Information Management Data Insights*, Elsevier, v. 1, n. 1, p. 100007, 2021.
- OTT, M.; CARDIE, C.; HANCOCK, J. T. Negative deceptive opinion spam. In: *Proceedings of the 2013 conference of the north american chapter of the association for computational linguistics: human language technologies*. [S.l.: s.n.], 2013. p. 497–501.
- OTT, M.; CHOI, Y.; CARDIE, C.; HANCOCK, J. T. Finding deceptive opinion spam by any stretch of the imagination. In: *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*. Portland, Oregon, USA: Association for Computational Linguistics, 2011. p. 309–319. Disponível em: <<https://aclanthology.org/P11-1032>>.
- PATIL, D. R. Fake news detection using majority voting technique. *arXiv preprint arXiv:2203.09936*, 2022.


- PATWA, P.; SHARMA, S.; PYKL, S.; GUPTHA, V.; KUMARI, G.; AKHTAR, M. S.; EKBAL, A.; DAS, A.; CHAKRABORTY, T. Fighting an infodemic: Covid-19 fake news dataset. In: SPRINGER. *Combating Online Hostile Posts in Regional Languages during Emergency Situation: First International Workshop, CONSTRAINT 2021, Collocated with AAAI 2021, Virtual Event, February 8, 2021, Revised Selected Papers 1*. [S.l.], 2021. p. 21–29.
- PENNINGTON, J.; SOCHER, R.; MANNING, C. D. Glove: Global vectors for word representation. In: *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*. [S.l.: s.n.], 2014. p. 1532–1543.
- POSETTI, J.; MATTHEWS, A. A short guide to the history of ‘fake news’ and disinformation. *International Center for Journalists*, v. 7, n. 2018, p. 2018–07, 2018.
- PRIYA, A.; KUMAR, A. Deep ensemble approach for covid-19 fake news detection from social media. In: IEEE. *2021 8th International Conference on Signal Processing and Integrated Networks (SPIN)*. [S.l.], 2021. p. 396–401.
- RASOOL, T.; BUTT, W. H.; SHAUKAT, A.; AKRAM, M. U. Multi-label fake news detection using multi-layered supervised learning. In: *Proceedings of the 2019 11th international conference on computer and automation engineering*. [S.l.: s.n.], 2019. p. 73–77.
- SANTANA, A.; SOARES, R. G.; CANUTO, A. M.; SOUTO, M. C. de. A dynamic classifier selection method to build ensembles using accuracy and diversity. In: IEEE. *2006 Ninth Brazilian Symposium on Neural Networks (SBRN'06)*. [S.l.], 2006. p. 36–41.
- SINGH, L. Hybrid ensemble for fake news detection: An attempt. In: SPRINGER. *Data Engineering for Smart Systems: Proceedings of SSIC 2021*. [S.l.], 2022. p. 101–108.
- SURENDRAN, P.; NAVYASREE, B.; KAMBHAM, H.; KUMAR, M. A. Covid-19 fake news detector using hybrid convolutional and bi-lstm model. In: IEEE. *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*. [S.l.], 2021. p. 01–06.
- TAHER, Y.; MOUSSAOUI, A.; MOUSSAOUI, F. Automatic fake news detection based on deep learning, fasttext and news title. *International Journal of Advanced Computer Science and Applications*, Science and Information (SAI) Organization Limited, v. 13, n. 1, 2022.
- UPADHAYAY, B.; BEHZADAN, V. Sentimental liar: Extended corpus and deep learning models for fake claim classification. In: IEEE. *2020 IEEE International Conference on Intelligence and Security Informatics (ISI)*. [S.l.], 2020. p. 1–6.
- VAJJALA, S.; MAJUMDER, B.; GUPTA, A.; SURANA, H. *Practical natural language processing: a comprehensive guide to building real-world NLP systems*. [S.l.]: O'Reilly Media, 2020.
- WANG, W. Y. “liar, liar pants on fire”: A new benchmark dataset for fake news detection. *ArXiv*, abs/1705.00648, 2017.
- WOŹNIAK, M.; GRANA, M.; CORCHADO, E. A survey of multiple classifier systems as hybrid systems. *Information Fusion*, Elsevier, v. 16, p. 3–17, 2014.
- ZHANG, Z.; LUO, L. Hate speech detection: A solved problem? the challenging case of long tail on twitter. *Semantic Web*, IOS Press, v. 10, n. 5, p. 925–945, 2019.

APÊNDICE A – RESULTADOS GERAIS PARA O MÉTODO PROPOSTO


Figura 17 – Gráficos de bolha apresentando os maiores resultados obtidos pelo método proposto para cada métrica em cada conjunto.




(a) Resultados para o conjunto Liar.




(b) Resultados para o conjunto Senti.




(c) Resultados para o conjunto Covid.



(d) Resultados para o conjunto Fa-Kes.




(e) Resultados para o conjunto Ott.



(f) Resultados para o conjunto Kaggle.

Fonte: A autora (2023). Cada representação varia de tamanho da circunferência em função do respectivo k adotado. Cada cor corresponde a um algoritmo de meta-classificação adotado, conforme indicado na legenda da figura.

Figura 18 – Gráficos de linha para resultados das métricas em função do k.



Fonte: A autora (2023). Os quadrantes, da esquerda para direita, correspondem aos resultados das respectivas métricas acc, pre, rec e f1. Cada cor de linha corresponde a um algoritmo de meta-classificação adotado, conforme indicado na legenda do quadrante superior à esquerda apresentado na figura. Os quadrantes das letras (a), (b), (c), (d) correspondem aos resultados obtidos para o conjunto Liar, (e), (f), (g), (h) aos obtidos para o Senti, (i), (j), (k), (l) para o Covid, (m), (n), (o), (p) para o Fa-Kes, (q), (r), (s), (t) para o Ott, e por fim os (u), (v), (w), (x) para o Kaggle.

APÊNDICE B – RESULTADOS LIAR

Tabela 8 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Liar.

Valor	LR				RF				NB			
k	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,200	0,229	0,248	0,179	0,194	0,196	0,187	0,186	0,240	0,247	0,210	0,152
2	0,193	0,195	0,222	0,181	0,224	0,216	0,198	0,201	0,236	0,234	0,217	0,182
3	0,200	0,201	0,227	0,192	0,232	0,213	0,207	0,202	0,224	0,208	0,233	0,200
4	0,207	0,212	0,234	0,201	0,224	0,222	0,210	0,211	0,229	0,219	0,236	0,209
5	0,214	0,221	0,238	0,209	0,234	0,233	0,213	0,215	0,237	0,244	0,257	0,218
6	0,209	0,222	0,243	0,203	0,240	0,227	0,214	0,202	0,210	0,225	0,241	0,197
7	0,201	0,204	0,229	0,194	0,224	0,231	0,217	0,212	0,212	0,205	0,240	0,197
8	0,211	0,215	0,240	0,205	0,234	0,223	0,211	0,209	0,217	0,212	0,247	0,202
9	0,212	0,217	0,242	0,207	0,240	0,236	0,216	0,211	0,207	0,210	0,244	0,195
10	0,215	0,218	0,247	0,211	0,238	0,227	0,220	0,212	0,214	0,211	0,248	0,202
11	0,213	0,214	0,244	0,209	0,231	0,240	0,216	0,213	0,214	0,209	0,252	0,201
12	0,211	0,214	0,244	0,208	0,233	0,238	0,214	0,212	0,204	0,200	0,243	0,191
13	0,211	0,214	0,243	0,208	0,235	0,236	0,214	0,210	0,207	0,212	0,245	0,194
14	0,212	0,216	0,240	0,209	0,235	0,234	0,216	0,201	0,204	0,216	0,240	0,194
15	0,212	0,216	0,240	0,209	0,237	0,236	0,215	0,207	0,204	0,216	0,240	0,194
16	0,222	0,227	0,250	0,220	0,235	0,235	0,217	0,204	0,198	0,209	0,229	0,187
17	0,217	0,219	0,244	0,213	0,234	0,226	0,211	0,203	0,196	0,201	0,231	0,183
18	0,215	0,220	0,241	0,212	0,234	0,237	0,215	0,209	0,195	0,212	0,229	0,184
19	0,224	0,230	0,250	0,222	0,241	0,240	0,217	0,206	0,190	0,203	0,223	0,180
20	0,224	0,231	0,251	0,223	0,239	0,240	0,216	0,206	0,187	0,197	0,221	0,176
21	0,228	0,230	0,258	0,226	0,236	0,237	0,212	0,206	0,196	0,216	0,234	0,185
22	0,222	0,223	0,250	0,221	0,236	0,233	0,211	0,204	0,196	0,216	0,234	0,186

23	0,225 0,227 0,254 0,224 0,237 0,235 0,215 0,203 0,197 0,212 0,235 0,185
24	0,215 0,219 0,241 0,214 0,235 0,233 0,214 0,201 0,189 0,204 0,230 0,176
25	0,214 0,219 0,236 0,213 0,235 0,235 0,211 0,201 0,192 0,207 0,233 0,179
26	0,211 0,216 0,234 0,210 0,234 0,231 0,212 0,204 0,196 0,214 0,235 0,182
27	0,219 0,224 0,243 0,218 0,237 0,232 0,215 0,205 0,197 0,213 0,238 0,183
28	0,215 0,221 0,236 0,215 0,233 0,234 0,215 0,202 0,194 0,205 0,234 0,180
29	0,211 0,214 0,233 0,210 0,235 0,227 0,209 0,202 0,199 0,212 0,237 0,185
30	0,209 0,212 0,229 0,207 0,236 0,232 0,215 0,202 0,195 0,215 0,235 0,181
31	0,204 0,207 0,225 0,203 0,236 0,225 0,214 0,202 0,194 0,217 0,235 0,179
32	0,210 0,212 0,231 0,209 0,239 0,231 0,213 0,201 0,194 0,214 0,233 0,180
33	0,213 0,214 0,233 0,212 0,236 0,231 0,216 0,198 0,193 0,214 0,232 0,179
34	0,203 0,204 0,218 0,201 0,240 0,232 0,212 0,198 0,193 0,214 0,232 0,179
35	0,203 0,205 0,218 0,201 0,241 0,228 0,216 0,203 0,198 0,218 0,238 0,184
36	0,210 0,210 0,223 0,207 0,238 0,230 0,212 0,198 0,196 0,214 0,236 0,183
37	0,203 0,203 0,215 0,200 0,240 0,235 0,214 0,198 0,200 0,220 0,239 0,186
38	0,205 0,206 0,216 0,202 0,239 0,229 0,216 0,201 0,198 0,222 0,237 0,185
39	0,203 0,204 0,215 0,201 0,240 0,240 0,216 0,201 0,200 0,232 0,237 0,188
40	0,203 0,204 0,216 0,201 0,238 0,231 0,213 0,201 0,196 0,226 0,234 0,183

Fonte: A autora (2023). Os maiores resultados estão em destacados em negrito.

Tabela 9 – Lista com os grupos obtidos para cada valor de k para o conjunto Liar.

k	Grupo
1	W2V-SVM
2	FAST-MLP, W2V-SVM
3	FAST-MLP, W2V-SVM, W2V-RF

- 4 FAST-MLP, W2V-SVM, W2V-RF, W2V-KNN
- 5 FAST-MLP, W2V-SVM, W2V-RF, FAST-SVM, W2V-KNN
- 6 FAST-MLP, W2V-SVM, W2V-RF, FAST-SVM, W2V-KNN, FAST-NB
- 7 FAST-MLP, TF-IDF-RF, W2V-SVM, W2V-RF, FAST-SVM, W2V-KNN, FAST-NB
- 8 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, FAST-SVM, W2V-KNN, FAST-NB
- 9 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, FAST-SVM, FAST-RF, W2V-KNN, FAST-NB
- 10 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, FAST-SVM, FAST-RF, FAST-KNN, FAST-NB, W2V-KNN
- 11 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, W2V-LR, FAST-RF, FAST-KNN, FAST-SVM, FAST-NB, W2V-KNN
- 12 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, W2V-LR, FAST-RF, FAST-KNN, FAST-SVM, FAST-NB, W2V-KNN, W2V-EXTRA
- 13 FAST-MLP, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, W2V-RF, W2V-LR, FAST-RF, TF-IDF-SVM, FAST-KNN, FAST-SVM, FAST-NB, W2V-KNN, W2V-EXTRA
- 14 FAST-MLP, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-RF, W2V-LR, FAST-RF, TF-IDF-SVM, FAST-KNN, FAST-SVM, FAST-NB, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 15 FAST-MLP, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-RF, W2V-LR, FAST-RF, TF-IDF-SVM, TF-IDF-CNN, FAST-SVM, FAST-NB, FAST-KNN, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 16 FAST-MLP, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-NB, FAST-KNN, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 17 CV-EXTRA, TF-IDF-RF, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, FAST-NB, FAST-KNN, W2V-KNN, W2V-EXTRA, TF-IDF-KNN

- 18 CV-EXTRA, TF-IDF-RF, GLOVE-RF, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, FAST-SVM, TF-IDF-CNN, FAST-MLP, FAST-NB, FAST-KNN, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 19 CV-EXTRA, TF-IDF-RF, GLOVE-RF, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 20 CV-EXTRA, TF-IDF-RF, GLOVE-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, W2V-KNN, W2V-EXTRA, TF-IDF-KNN
- 21 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, W2V-KNN, W2V-EXTRA, TF-IDF-KNN, CV-KNN
- 22 CV-EXTRA, TF-IDF-RF, GLOVE-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, W2V-KNN, W2V-EXTRA, TF-IDF-KNN, CV-KNN
- 23 CV-EXTRA, TF-IDF-RF, GLOVE-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, FAST-RF, TF-IDF-SVM, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, GLOVE-LR, W2V-KNN, W2V-EXTRA, TF-IDF-KNN, CV-KNN
- 24 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, W2V-RF, FAST-SVM, TF-IDF-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-EXTRA, TF-IDF-KNN, CV-KNN
- 25 CV-EXTRA, GLOVE-RF, TF-IDF-RF, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, W2V-RF, FAST-SVM, TF-IDF-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-EXTRA, CV-CNN, TF-IDF-KNN, CV-KNN

- 26 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, W2V-RF, FAST-SVM, TF-IDF-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-EXTRA, CV-CNN, TF-IDF-KNN, CV-KNN
- 27 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, W2V-RF, FAST-SVM, FAST-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, FAST-KNN, TF-IDF-CNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-EXTRA, CV-CNN, TF-IDF-KNN, CV-KNN
- 28 CV-EXTRA, GLOVE-RF, TF-IDF-RF, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, W2V-RF, FAST-SVM, FAST-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, CV-KNN
- 29 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, W2V-RF, FAST-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-CNN, W2V-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, CV-KNN
- 30 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, W2V-RF, FAST-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, W2V-EXTRA, CV-KNN
- 31 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, CV-NB, FAST-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, FAST-NB, GLOVE-SVM, FAST-RF, GLOVE-LR, W2V-KNN, W2V-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, W2V-EXTRA, CV-KNN

-
- 32 CV-EXTRA, GLOVE-RF, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, W2V-EXTRA, CV-KNN
- 33 CV-EXTRA, FAST-LR, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, CV-SVM, TF-IDF-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, TF-IDF-KNN, W2V-EXTRA, CV-KNN
- 34 CV-EXTRA, FAST-LR, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, CV-NB, FAST-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, CV-KNN
- 35 CV-EXTRA, FAST-LR, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, CV-NB, FAST-CNN, FAST-SVM, FAST-MLP, CV-RF, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN
- 36 CV-EXTRA, TF-IDF-RF, FAST-LR, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-RF, GLOVE-EXTRA, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN

- 37 CV-EXTRA, TF-IDF-RF, FAST-LR, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-SVM, CV-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-LR, CV-RF, GLOVE-EXTRA, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN
- 38 CV-EXTRA, FAST-LR, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, W2V-NB, TF-IDF-LR, CV-SVM, TF-IDF-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-LR, CV-RF, GLOVE-EXTRA, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-RF, FAST-NB, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN
- 39 CV-EXTRA, TF-IDF-RF, FAST-LR, W2V-SVM, TF-IDF-EXTRA, W2V-MLP, W2V-LR, TF-IDF-NB, TF-IDF-LR, CV-SVM, TF-IDF-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-LR, CV-RF, GLOVE-EXTRA, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-NB, FAST-RF, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-NB, W2V-CNN, FAST-EXTRA, CV-CNN, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN
- 40 CV-EXTRA, FAST-LR, TF-IDF-RF, TF-IDF-EXTRA, W2V-SVM, W2V-MLP, W2V-LR, TF-IDF-NB, TF-IDF-LR, CV-SVM, TF-IDF-SVM, CV-NB, FAST-SVM, FAST-CNN, FAST-MLP, CV-LR, CV-RF, GLOVE-EXTRA, TF-IDF-MLP, GLOVE-CNN, TF-IDF-CNN, CV-MLP, GLOVE-SVM, FAST-NB, FAST-RF, GLOVE-LR, W2V-KNN, W2V-RF, GLOVE-RF, W2V-NB, W2V-CNN, CV-CNN, FAST-EXTRA, GLOVE-NB, FAST-KNN, GLOVE-KNN, W2V-EXTRA, TF-IDF-KNN, GLOVE-MLP, CV-KNN

Fonte: A autora (2023). Para cada métrica altera a ordem, mas são os mesmos grupos.

Tabela 10 – Resultados dos classificadores para o conjunto Liar.

Classificador	acc	pre	rec	f1	Classificador	acc	pre	rec	f1
CV-SVM	0,228	0,217	0,213	0,212	A-NB-LR	0,173	0,191	0,191	0,164

TF-IDF-SVM	0,231 0,241 0,209 0,209	A-MLP-LR	0,187 0,189 0,189 0,182
W2V-SVM	0,257 0,266 0,227 0,22	A-EXTRA-LR	0,200 0,206 0,206 0,192
GLOVE-SVM	0,232 0,207 0,200 0,187	A-KNN-LR	0,202 0,203 0,203 0,194
FAST-SVM	0,248 0,227 0,209 0,169	A-CNN-LR	0,196 0,203 0,203 0,194
CV-LR	0,239 0,239 0,223 0,226	A-SVM-RF	0,251 0,251 0,251 0,205
TF-IDF-LR	0,235 0,230 0,212 0,21	A-LR-RF	0,224 0,209 0,209 0,193
GLOVE-LR	0,235 0,206 0,201 0,178	A-RF-RF	0,216 0,176 0,176 0,197
W2V-LR	0,235 0,229 0,209 0,205	A-NB-RF	0,214 0,197 0,197 0,183
FAST-LR	0,234 0,221 0,202 0,182	A-MLP-RF	0,230 0,222 0,222 0,195
CV-RF	0,222 0,209 0,202 0,197	A-EXTRA-RF	0,224 0,175 0,175 0,189
TF-IDF-RF	0,235 0,229 0,212 0,208	A-KNN-RF	0,191 0,189 0,189 0,173
GLOVE-RF	0,209 0,206 0,185 0,179	A-CNN-RF	0,231 0,198 0,198 0,184
W2V-RF	0,231 0,224 0,203 0,196	A-SVM-NB	0,213 0,197 0,197 0,189
FAST-RF	0,225 0,204 0,197 0,188	A-LR-NB	0,217 0,215 0,215 0,193
CV-NB	0,24 0,238 0,234 0,235	A-RF-NB	0,193 0,194 0,194 0,187
TF-IDF-NB	0,239 0,235 0,228 0,229	A-NB-NB	0,192 0,191 0,191 0,169
GLOVE-NB	0,214 0,177 0,184 0,164	A-MLP-NB	0,224 0,203 0,203 0,192
W2V-NB	0,200 0,210 0,214 0,191	A-EXTRA-NB	0,214 0,226 0,226 0,206
FAST-NB	0,226 0,233 0,241 0,219	A-KNN-NB	0,212 0,204 0,204 0,196
CV-MLP	0,214 0,205 0,205 0,205	A-CNN-NB	0,192 0,195 0,195 0,181
TF-IDF-MLP	0,213 0,203 0,198 0,199	B-CV-LR	0,196 0,207 0,207 0,191
GLOVE-MLP	0,227 0,221 0,199 0,187	B-TF-IDF-LR	0,193 0,203 0,203 0,185
W2V-MLP	0,226 0,214 0,211 0,21	B-W2V-LR	0,197 0,207 0,207 0,192
FAST-MLP	0,258 0,246 0,234 0,231	B-GLOVE-LR	0,178 0,189 0,189 0,173
CV-EXTRA	0,238 0,232 0,217 0,214	B-FAST-LR	0,203 0,212 0,212 0,201
TF-IDF-EXTRA	0,239 0,227 0,215 0,212	B-CV-RF	0,230 0,206 0,206 0,194
GLOVE-EXTRA	0,210 0,186 0,184 0,177	B-TF-IDF-RF	0,216 0,196 0,196 0,214

W2V-EXTRA	0,235 0,239 0,205 0,195	B-W2V-RF	0,237 0,195 0,195 0,201
FAST-EXTRA	0,233 0,262 0,211 0,211	B-GLOVE-RF	0,211 0,195 0,195 0,182
CV-KNN	0,202 0,215 0,176 0,154	B-FAST-RF	0,242 0,211 0,211 0,211
TF-IDF-KNN	0,205 0,206 0,192 0,168	B-CV-NB	0,207 0,218 0,218 0,186
GLOVE-KNN	0,200 0,189 0,180 0,177	B-TF-IDF-NB	0,203 0,222 0,222 0,183
W2V-KNN	0,224 0,217 0,204 0,203	B-W2V-NB	0,213 0,232 0,232 0,201
FAST-KNN	0,207 0,192 0,185 0,182	B-GLOVE-NB	0,180 0,194 0,194 0,161
CV-CNN	0,193 0,201 0,202 0,169	B-FAST-NB	0,186 0,186 0,186 0,177
TF-IDF-CNN	0,224 0,229 0,215 0,195	C-LR	0,197 0,198 0,198 0,195
W2V-CNN	0,212 0,212 0,220 0,207	C-RF	0,243 0,260 0,260 0,189
GLOVE-CNN	0,228 0,213 0,197 0,172	C-NB	0,197 0,235 0,235 0,186
FAST-CNN	0,203 0,214 0,213 0,186	D-LR	0,228 0,231 0,258 0,226
A-SVM-LR	0,197 0,205 0,205 0,182	D-RF	0,241 0,240 0,220 0,215
A-LR-LR	0,204 0,227 0,227 0,194	D-NB	0,240 0,247 0,257 0,218
A-RF-LR	0,200 0,211 0,211 0,193		

Fonte: A autora (2023). Os maiores resultados obtidos estão em destacados em negrito.

APÊNDICE C – RESULTADOS SENTI

Tabela 11 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Senti.

k	LR				RF				NB			
	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,598	0,577	0,581	0,577	0,564	0,520	0,520	0,520	0,677	0,685	0,566	0,535
2	0,612	0,594	0,600	0,593	0,598	0,538	0,523	0,525	0,664	0,624	0,584	0,580
3	0,614	0,603	0,612	0,601	0,607	0,534	0,529	0,515	0,649	0,604	0,583	0,583
4	0,615	0,604	0,613	0,602	0,605	0,538	0,525	0,513	0,647	0,602	0,583	0,583
5	0,631	0,617	0,626	0,617	0,617	0,539	0,532	0,511	0,650	0,609	0,595	0,597
6	0,621	0,610	0,619	0,608	0,621	0,551	0,530	0,519	0,653	0,614	0,601	0,604
7	0,624	0,613	0,621	0,611	0,624	0,559	0,536	0,517	0,657	0,620	0,609	0,612
8	0,624	0,613	0,622	0,611	0,633	0,564	0,538	0,524	0,654	0,617	0,608	0,610
9	0,620	0,611	0,620	0,608	0,625	0,549	0,528	0,504	0,652	0,613	0,602	0,605
10	0,616	0,604	0,613	0,602	0,636	0,564	0,537	0,515	0,654	0,618	0,611	0,613
11	0,617	0,607	0,616	0,604	0,633	0,573	0,540	0,521	0,648	0,614	0,611	0,612
12	0,625	0,617	0,626	0,614	0,639	0,570	0,539	0,513	0,643	0,611	0,611	0,611
13	0,616	0,608	0,617	0,604	0,637	0,578	0,537	0,515	0,641	0,611	0,611	0,611
14	0,617	0,609	0,618	0,605	0,639	0,580	0,542	0,519	0,639	0,608	0,609	0,609
15	0,611	0,604	0,613	0,600	0,641	0,583	0,546	0,524	0,634	0,604	0,605	0,604
16	0,612	0,604	0,613	0,600	0,641	0,591	0,550	0,531	0,631	0,603	0,605	0,604
17	0,613	0,606	0,615	0,602	0,643	0,591	0,551	0,532	0,635	0,607	0,609	0,608
18	0,606	0,598	0,607	0,594	0,643	0,588	0,546	0,526	0,637	0,609	0,611	0,610
19	0,609	0,600	0,608	0,597	0,647	0,595	0,551	0,532	0,638	0,609	0,611	0,609
20	0,611	0,603	0,612	0,599	0,649	0,602	0,552	0,532	0,641	0,613	0,615	0,614
21	0,609	0,601	0,609	0,597	0,651	0,600	0,552	0,533	0,634	0,607	0,610	0,608

22	0,608	0,600	0,608	0,596	0,651	0,599	0,555	0,533	0,633	0,606	0,610	0,608
23	0,607	0,603	0,612	0,597	0,649	0,599	0,553	0,534	0,634	0,610	0,615	0,611
24	0,606	0,601	0,610	0,595	0,651	0,602	0,556	0,537	0,621	0,599	0,605	0,600
25	0,606	0,601	0,610	0,595	0,650	0,601	0,555	0,540	0,621	0,599	0,605	0,600
26	0,606	0,601	0,610	0,595	0,651	0,605	0,557	0,539	0,625	0,604	0,610	0,605
27	0,610	0,606	0,615	0,600	0,652	0,606	0,555	0,538	0,634	0,613	0,620	0,614
28	0,608	0,605	0,614	0,599	0,651	0,601	0,555	0,540	0,634	0,613	0,619	0,614
29	0,605	0,601	0,610	0,595	0,651	0,608	0,557	0,543	0,631	0,613	0,620	0,613
30	0,604	0,600	0,609	0,594	0,651	0,605	0,556	0,539	0,630	0,611	0,618	0,612
31	0,609	0,605	0,614	0,599	0,652	0,604	0,557	0,540	0,627	0,609	0,616	0,609
32	0,606	0,601	0,610	0,596	0,651	0,603	0,552	0,537	0,628	0,609	0,616	0,610
33	0,606	0,601	0,610	0,596	0,651	0,598	0,556	0,536	0,627	0,609	0,617	0,610
34	0,601	0,597	0,605	0,591	0,651	0,599	0,555	0,537	0,627	0,609	0,616	0,609
35	0,599	0,592	0,600	0,588	0,649	0,599	0,556	0,536	0,630	0,612	0,619	0,612
36	0,600	0,593	0,601	0,589	0,649	0,598	0,552	0,535	0,628	0,612	0,619	0,612
37	0,605	0,599	0,607	0,594	0,645	0,591	0,548	0,528	0,623	0,606	0,613	0,606
38	0,608	0,603	0,612	0,598	0,646	0,589	0,547	0,528	0,620	0,604	0,611	0,604
39	0,607	0,602	0,610	0,597	0,647	0,596	0,548	0,525	0,624	0,608	0,616	0,608
40	0,602	0,597	0,605	0,592	0,646	0,595	0,546	0,522	0,626	0,610	0,617	0,609

Fonte: A autora (2023). Os maiores resultados estão em destacados em negrito.

Tabela 12 – Lista com os grupos obtidos para cada valor de k para o conjunto Senti.

k	Grupo
1	W2V-SVM
2	W2V-SVM, FAST-MLP

- 3 TF-IDF-SVM, FAST-MLP, W2V-SVM
- 4 TF-IDF-SVM, W2V-KNN, FAST-MLP, W2V-SVM
- 5 TF-IDF-SVM, W2V-KNN, FAST-MLP, W2V-SVM, FAST-NB
- 6 TF-IDF-SVM, W2V-KNN, FAST-MLP, TF-IDF-KNN, W2V-SVM, FAST-NB
- 7 TF-IDF-SVM, W2V-KNN, FAST-MLP, TF-IDF-KNN, W2V-SVM, FAST-NB, W2V-RF
- 8 TF-IDF-SVM, FAST-KNN, FAST-MLP, TF-IDF-KNN, W2V-SVM, FAST-NB, W2V-RF, W2V-KNN
- 9 FAST-SVM, FAST-KNN, FAST-MLP, TF-IDF-KNN, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, W2V-KNN
- 10 FAST-SVM, FAST-KNN, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, TF-IDF-KNN, W2V-KNN
- 11 FAST-SVM, FAST-KNN, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, TF-IDF-KNN, CV-NB, W2V-KNN
- 12 FAST-SVM, FAST-KNN, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, TF-IDF-KNN, CV-NB, TF-IDF-MLP, W2V-KNN
- 13 FAST-SVM, FAST-KNN, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, W2V-CNN, TF-IDF-KNN, CV-NB, TF-IDF-MLP, W2V-KNN
- 14 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, W2V-CNN, TF-IDF-KNN, CV-NB, TF-IDF-MLP, W2V-KNN
- 15 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, W2V-CNN, TF-IDF-KNN, CV-NB, FAST-CNN, TF-IDF-MLP, W2V-KNN
- 16 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, FAST-NB, W2V-RF, W2V-CNN, TF-IDF-KNN, CV-NB, FAST-CNN, CV-MLP, TF-IDF-MLP, W2V-KNN

- 17 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-SVM, FAST-NB, W2V-RF, W2V-CNN, TF-IDF-KNN, CV-NB, FAST-CNN, CV-MLP, TF-IDF-MLP, W2V-KNN
- 18 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-SVM, FAST-NB, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, CV-MLP, TF-IDF-MLP, W2V-KNN
- 19 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-SVM, FAST-NB, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, W2V-KNN
- 20 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-NB, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, W2V-KNN
- 21 W2V-LR, FAST-KNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, FAST-NB, W2V-KNN
- 22 W2V-LR, GLOVE-CNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN
- 23 W2V-LR, GLOVE-CNN, FAST-SVM, FAST-MLP, TF-IDF-EXTRA, TF-IDF-SVM, GLOVE-RF, W2V-SVM, GLOVE-SVM, FAST-EXTRA, W2V-RF, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN
- 24 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, TF-IDF-SVM, GLOVE-RF, W2V-SVM, GLOVE-SVM, FAST-EXTRA, W2V-RF, FAST-MLP, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN

- 25 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, TF-IDF-SVM, GLOVE-RF, W2V-SVM, GLOVE-SVM, FAST-EXTRA, W2V-RF, FAST-MLP, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 26 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, TF-IDF-SVM, GLOVE-RF, W2V-SVM, GLOVE-SVM, FAST-EXTRA, W2V-RF, FAST-MLP, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 27 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, GLOVE-RF, W2V-SVM, GLOVE-SVM, FAST-EXTRA, W2V-RF, FAST-MLP, W2V-CNN, CV-KNN, CV-NB, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 28 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, W2V-RF, FAST-MLP, W2V-CNN, CV-KNN, CV-NB, FAST-RF, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 29 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, CV-KNN, CV-NB, FAST-RF, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 30 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, CV-KNN, CV-NB, FAST-RF, TF-IDF-KNN, FAST-CNN, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN

- 31 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, CV-KNN, W2V-MLP, FAST-RF, TF-IDF-KNN, FAST-CNN, CV-NB, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 32 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, W2V-SVM, GLOVE-RF, GLOVE-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, CV-NB, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 33 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, W2V-SVM, GLOVE-RF, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, CV-NB, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, CV-CNN, TF-IDF-CNN
- 34 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, W2V-SVM, GLOVE-RF, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, CV-NB, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, CV-CNN, TF-IDF-CNN
- 35 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, W2V-SVM, GLOVE-RF, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, W2V-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, CV-CNN, TF-IDF-CNN

- 36 W2V-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, W2V-SVM, GLOVE-RF, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, TF-IDF-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, W2V-NB, CV-CNN, TF-IDF-CNN
- 37 TF-IDF-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, W2V-SVM, GLOVE-RF, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, W2V-LR, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, TF-IDF-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, W2V-NB, CV-CNN, TF-IDF-CNN
- 38 TF-IDF-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, GLOVE-RF, W2V-SVM, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-LR, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, W2V-LR, GLOVE-LR, W2V-EXTRA, W2V-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, TF-IDF-NB, CV-SVM, CV-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, W2V-NB, CV-CNN, TF-IDF-CNN
- 39 TF-IDF-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, GLOVE-RF, W2V-SVM, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-LR, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, W2V-LR, GLOVE-LR, W2V-EXTRA, GLOVE-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, TF-IDF-NB, CV-SVM, CV-MLP, W2V-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, W2V-NB, CV-CNN, TF-IDF-CNN

40 TF-IDF-LR, GLOVE-CNN, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, GLOVE-EXTRA, TF-IDF-RF, GLOVE-RF, W2V-SVM, GLOVE-SVM, TF-IDF-SVM, FAST-EXTRA, FAST-LR, FAST-MLP, W2V-RF, W2V-CNN, CV-RF, W2V-LR, CV-LR, GLOVE-LR, W2V-EXTRA, GLOVE-MLP, CV-KNN, FAST-RF, TF-IDF-KNN, FAST-CNN, GLOVE-NB, CV-NB, TF-IDF-NB, CV-SVM, CV-MLP, W2V-MLP, TF-IDF-MLP, FAST-KNN, FAST-NB, W2V-KNN, GLOVE-KNN, W2V-NB, CV-CNN, TF-IDF-CNN

Fonte: A autora (2023). Para cada métrica altera a ordem, mas são os mesmos grupos.

Tabela 13 – Resultados dos classificadores para o conjunto Senti.

Classificador	acc	pre	rec	f1	Classificador	acc	pre	rec	f1
CV-SVM	0,606	0,552	0,544	0,543	A-NB-LR	0,599	0,591	0,591	0,587
TF-IDF-SVM	0,640	0,585	0,558	0,55	A-MLP-LR	0,611	0,602	0,602	0,599
W2V-SVM	0,675	0,682	0,564	0,532	A-EXTRA-LR	0,588	0,585	0,585	0,578
GLOVE-SVM	0,646	0,61	0,515	0,438	A-KNN-LR	0,575	0,568	0,568	0,563
FAST-SVM	0,641	0,321	0,5	0,391	A-CNN-LR	0,583	0,589	0,589	0,577
CV-LR	0,629	0,572	0,554	0,549	A-SVM-RF	0,631	0,561	0,561	0,523
TF-IDF-LR	0,638	0,576	0,543	0,525	A-LR-RF	0,639	0,583	0,583	0,531
GLOVE-LR	0,638	0,563	0,516	0,457	A-RF-RF	0,632	0,574	0,574	0,519
W2V-LR	0,645	0,589	0,539	0,509	A-NB-RF	0,637	0,571	0,571	0,529
FAST-LR	0,651	0,611	0,533	0,484	A-MLP-RF	0,621	0,543	0,543	0,517
CV-RF	0,632	0,566	0,538	0,52	A-EXTRA-RF	0,616	0,566	0,566	0,519
TF-IDF-RF	0,638	0,578	0,548	0,534	A-KNN-RF	0,568	0,524	0,524	0,526
GLOVE-RF	0,630	0,549	0,521	0,483	A-CNN-RF	0,634	0,585	0,585	0,547
W2V-RF	0,651	0,603	0,545	0,515	A-SVM-NB	0,658	0,616	0,616	0,594
FAST-RF	0,645	0,589	0,536	0,500	A-LR-NB	0,643	0,603	0,603	0,597

CV-NB	0,615 0,597 0,604 0,597	A-RF-NB	0,638 0,597 0,597 0,592
TF-IDF-NB	0,611 0,590 0,595 0,590	A-NB-NB	0,634 0,598 0,598 0,596
GLOVE-NB	0,623 0,537 0,518 0,484	A-MLP-NB	0,643 0,603 0,603 0,595
W2V-NB	0,58 0,558 0,561 0,557	A-EXTRA-NB	0,644 0,603 0,603 0,594
FAST-NB	0,601 0,573 0,575 0,574	A-KNN-NB	0,640 0,583 0,583 0,538
CV-MLP	0,596 0,553 0,551 0,551	A-CNN-NB	0,615 0,591 0,591 0,592
TF-IDF-MLP	0,585 0,544 0,543 0,543	B-CV-LR	0,588 0,589 0,589 0,580
GLOVE-MLP	0,646 0,592 0,546 0,523	B-TF-IDF-LR	0,586 0,582 0,582 0,576
W2V-MLP	0,610 0,565 0,560 0,561	B-W2V-LR	0,600 0,584 0,584 0,583
FAST-MLP	0,648 0,599 0,572 0,568	B-GLOVE-LR	0,589 0,580 0,580 0,576
CV-EXTRA	0,645 0,594 0,562 0,554	B-FAST-LR	0,603 0,594 0,594 0,591
TF-IDF-EXTRA	0,645 0,591 0,552 0,536	B-CV-RF	0,627 0,592 0,592 0,512
GLOVE-EXTRA	0,652 0,610 0,541 0,503	B-TF-IDF-RF	0,629 0,572 0,572 0,521
W2V-EXTRA	0,640 0,572 0,525 0,479	B-W2V-RF	0,641 0,566 0,566 0,521
FAST-EXTRA	0,638 0,564 0,520 0,471	B-GLOVE-RF	0,648 0,541 0,541 0,469
CV-KNN	0,638 0,577 0,543 0,524	B-FAST-RF	0,627 0,553 0,553 0,530
TF-IDF-KNN	0,634 0,573 0,544 0,529	B-CV-NB	0,610 0,586 0,586 0,587
GLOVE-KNN	0,602 0,543 0,536 0,533	B-TF-IDF-NB	0,621 0,591 0,591 0,592
W2V-KNN	0,606 0,553 0,546 0,545	B-W2V-NB	0,639 0,600 0,600 0,595
FAST-KNN	0,606 0,551 0,543 0,541	B-GLOVE-NB	0,649 0,607 0,607 0,592
CV-CNN	0,531 0,553 0,556 0,529	B-FAST-NB	0,640 0,601 0,601 0,597
TF-IDF-CNN	0,482 0,550 0,545 0,480	C-LR	0,603 0,598 0,598 0,593
W2V-CNN	0,627 0,568 0,550 0,544	C-RF	0,648 0,612 0,612 0,529
GLOVE-CNN	0,648 0,618 0,518 0,444	C-NB	0,622 0,608 0,608 0,607
FAST-CNN	0,620 0,576 0,570 0,571	D-LR	0,631 0,617 0,626 0,617
A-SVM-LR	0,621 0,605 0,605 0,604	D-RF	0,652 0,608 0,557 0,543
A-LR-LR	0,606 0,598 0,598 0,594	D-NB	0,677 0,685 0,620 0,614

A-RF-LR	0,581	0,580	0,580	0,572
---------	-------	-------	-------	-------

Fonte: A autora (2023). Os maiores resultados obtidos estão em destacados em negrito.

APÊNDICE D – RESULTADOS COVID

Tabela 14 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Covid.

k	LR				RF				NB			
	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,893	0,893	0,894	0,893	0,852	0,853	0,853	0,852	0,894	0,894	0,895	0,894
2	0,893	0,892	0,893	0,892	0,885	0,882	0,882	0,884	0,884	0,884	0,885	0,884
3	0,898	0,897	0,898	0,898	0,892	0,894	0,894	0,892	0,889	0,888	0,889	0,889
4	0,897	0,896	0,897	0,897	0,888	0,888	0,888	0,889	0,892	0,892	0,892	0,892
5	0,923	0,923	0,923	0,923	0,919	0,919	0,918	0,919	0,907	0,907	0,907	0,907
6	0,926	0,925	0,926	0,926	0,921	0,920	0,921	0,921	0,918	0,917	0,918	0,918
7	0,924	0,924	0,924	0,924	0,920	0,920	0,921	0,921	0,915	0,915	0,916	0,915
8	0,922	0,922	0,922	0,922	0,922	0,921	0,923	0,923	0,914	0,913	0,914	0,913
9	0,920	0,919	0,919	0,919	0,922	0,923	0,924	0,923	0,917	0,917	0,918	0,917
10	0,919	0,918	0,919	0,919	0,924	0,923	0,925	0,924	0,916	0,916	0,916	0,916
11	0,918	0,918	0,918	0,918	0,924	0,924	0,925	0,924	0,914	0,913	0,914	0,913
12	0,917	0,917	0,917	0,917	0,924	0,924	0,924	0,924	0,914	0,914	0,915	0,914
13	0,918	0,917	0,918	0,918	0,924	0,923	0,926	0,924	0,911	0,910	0,911	0,911
14	0,918	0,918	0,918	0,918	0,924	0,924	0,924	0,925	0,913	0,913	0,914	0,913
15	0,916	0,916	0,917	0,916	0,924	0,923	0,924	0,923	0,913	0,913	0,914	0,913
16	0,924	0,924	0,925	0,924	0,927	0,926	0,927	0,927	0,915	0,915	0,916	0,915
17	0,925	0,924	0,925	0,925	0,927	0,927	0,928	0,928	0,919	0,918	0,919	0,919
18	0,925	0,924	0,925	0,925	0,929	0,929	0,929	0,929	0,919	0,919	0,920	0,919
19	0,926	0,926	0,926	0,926	0,929	0,928	0,929	0,928	0,920	0,920	0,921	0,920
20	0,926	0,926	0,926	0,926	0,928	0,928	0,929	0,928	0,920	0,919	0,920	0,920
21	0,924	0,924	0,925	0,924	0,927	0,929	0,929	0,928	0,920	0,919	0,920	0,920

22	0,926 0,926 0,926 0,926 0,929 0,928 0,929 0,928 0,921 0,920 0,921 0,920
23	0,926 0,926 0,926 0,926 0,928 0,928 0,929 0,928 0,918 0,918 0,919 0,918
24	0,926 0,926 0,926 0,926 0,928 0,928 0,928 0,928 0,918 0,918 0,919 0,918
25	0,924 0,924 0,924 0,924 0,929 0,928 0,930 0,929 0,920 0,920 0,921 0,920
26	0,927 0,926 0,927 0,927 0,929 0,929 0,930 0,930 0,919 0,919 0,920 0,919
27	0,926 0,926 0,927 0,926 0,929 0,929 0,929 0,930 0,919 0,919 0,920 0,919
28	0,930 0,930 0,931 0,930 0,930 0,930 0,930 0,929 0,920 0,919 0,920 0,920
29	0,930 0,930 0,931 0,930 0,930 0,929 0,930 0,930 0,920 0,920 0,921 0,920
30	0,930 0,930 0,931 0,930 0,930 0,930 0,931 0,930 0,921 0,921 0,922 0,921
31	0,931 0,931 0,931 0,931 0,930 0,930 0,930 0,929 0,921 0,921 0,922 0,921
32	0,930 0,930 0,931 0,930 0,930 0,929 0,930 0,930 0,921 0,921 0,922 0,921
33	0,928 0,928 0,928 0,928 0,930 0,930 0,930 0,930 0,921 0,920 0,921 0,920
34	0,929 0,929 0,930 0,929 0,930 0,930 0,930 0,930 0,919 0,918 0,919 0,919
35	0,929 0,929 0,930 0,929 0,931 0,930 0,931 0,931 0,921 0,920 0,921 0,920
36	0,927 0,927 0,927 0,927 0,931 0,930 0,931 0,930 0,921 0,920 0,921 0,920
37	0,930 0,930 0,931 0,930 0,932 0,931 0,932 0,931 0,921 0,921 0,922 0,921
38	0,930 0,930 0,931 0,930 0,931 0,930 0,931 0,931 0,921 0,921 0,922 0,921
39	0,931 0,931 0,932 0,931 0,931 0,930 0,931 0,930 0,923 0,923 0,924 0,923
40	0,931 0,931 0,932 0,931 0,930 0,931 0,931 0,930 0,923 0,923 0,923 0,923

Fonte: A autora (2023). Os maiores resultados estão em destacados em negrito.

Tabela 15 – Lista com os grupos obtidos para cada valor de k para o conjunto Covid.

k	Grupo
1	W2V-SVM
2	W2V-SVM, FAST-NB

- 3 W2V-SVM, FAST-NB, FAST-MLP
- 4 W2V-SVM, FAST-NB, W2V-KNN, FAST-MLP
- 5 TF-IDF-SVM, FAST-NB, W2V-SVM, W2V-KNN, FAST-MLP
- 6 TF-IDF-SVM, FAST-NB, W2V-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP
- 7 TF-IDF-SVM, FAST-NB, W2V-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP, GLOVE-CNN
- 8 TF-IDF-SVM, FAST-NB, W2V-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP, GLOVE-CNN, GLOVE-KNN
- 9 TF-IDF-SVM, TF-IDF-KNN, W2V-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP, FAST-NB, GLOVE-CNN, GLOVE-KNN
- 10 TF-IDF-SVM, TF-IDF-KNN, W2V-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP, FAST-NB, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 11 TF-IDF-SVM, TF-IDF-KNN, W2V-SVM, FAST-SVM, TF-IDF-MLP, W2V-KNN, FAST-MLP, FAST-NB, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 12 TF-IDF-SVM, TF-IDF-KNN, FAST-RF, FAST-SVM, TF-IDF-MLP, W2V-KNN, W2V-SVM, FAST-MLP, FAST-NB, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 13 TF-IDF-SVM, TF-IDF-KNN, FAST-RF, FAST-SVM, TF-IDF-MLP, W2V-KNN, FAST-KNN, W2V-SVM, FAST-MLP, FAST-NB, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 14 TF-IDF-SVM, TF-IDF-KNN, FAST-RF, FAST-SVM, TF-IDF-MLP, W2V-KNN, FAST-KNN, W2V-SVM, FAST-MLP, FAST-NB, CV-KNN, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 15 TF-IDF-SVM, TF-IDF-KNN, FAST-RF, FAST-SVM, TF-IDF-MLP, W2V-KNN, FAST-KNN, W2V-SVM, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 16 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, TF-IDF-MLP, W2V-KNN, FAST-KNN, W2V-SVM, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, GLOVE-CNN, GLOVE-KNN

- 17 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-KNN, FAST-KNN, W2V-SVM, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 18 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-KNN, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, GLOVE-CNN, GLOVE-KNN
- 19 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-CNN, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, FAST-KNN, GLOVE-CNN, GLOVE-KNN
- 20 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-CNN, GLOVE-SVM, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, FAST-KNN, GLOVE-CNN, GLOVE-KNN
- 21 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-CNN, GLOVE-SVM, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 22 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-CNN, GLOVE-SVM, CV-NB, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, GLOVE-RF, CV-KNN, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 23 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, W2V-CNN, FAST-CNN, GLOVE-SVM, CV-NB, W2V-SVM, W2V-KNN, TF-IDF-KNN, FAST-MLP, FAST-NB, FAST-LR, CV-KNN, W2V-RF, FAST-KNN, GLOVE-RF, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 24 TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-CNN, GLOVE-SVM, FAST-CNN, CV-NB, W2V-SVM, W2V-KNN, W2V-CNN, TF-IDF-KNN, FAST-MLP, FAST-NB, FAST-LR, CV-KNN, W2V-RF, FAST-KNN, GLOVE-RF, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN

- 25 TF-IDF-SVM, CV-EXTRA, FAST-RF, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, GLOVE-SVM, FAST-CNN, CV-NB, W2V-SVM, W2V-KNN, W2V-CNN, TF-IDF-KNN, FAST-MLP, FAST-NB, FAST-LR, CV-KNN, W2V-RF, FAST-KNN, GLOVE-RF, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 26 TF-IDF-SVM, CV-EXTRA, FAST-RF, CV-MLP, FAST-SVM, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, GLOVE-SVM, CV-NB, W2V-SVM, W2V-CNN, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-NB, FAST-LR, CV-KNN, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-RF, GLOVE-CNN, GLOVE-KNN
- 27 TF-IDF-SVM, CV-EXTRA, FAST-RF, CV-MLP, FAST-SVM, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, GLOVE-SVM, CV-NB, W2V-SVM, W2V-CNN, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-NB, FAST-LR, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-RF, GLOVE-CNN, GLOVE-KNN, CV-KNN
- 28 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, GLOVE-SVM, FAST-CNN, CV-NB, W2V-SVM, W2V-CNN, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-NB, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-RF, GLOVE-CNN, GLOVE-KNN, CV-KNN
- 29 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, GLOVE-SVM, CV-NB, W2V-SVM, TF-IDF-RF, W2V-KNN, W2V-CNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-NB, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-MLP, GLOVE-RF, GLOVE-CNN, GLOVE-KNN, CV-KNN
- 30 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-KNN, W2V-CNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-NB, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-CNN, GLOVE-KNN, CV-KNN

- 31 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-KNN, W2V-CNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, FAST-NB, GLOVE-CNN, GLOVE-KNN, CV-KNN
- 32 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, CV-MLP, FAST-SVM, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, GLOVE-KNN, CV-KNN
- 33 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, FAST-SVM, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, W2V-KNN, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN
- 34 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, W2V-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, W2V-KNN, FAST-SVM, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN
- 35 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, W2V-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, CV-SVM, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, W2V-KNN, FAST-SVM, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB

- 36 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, W2V-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, CV-SVM, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, FAST-SVM, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB
- 37 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, CV-MLP, W2V-LR, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, W2V-MLP, FAST-SVM, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB
- 38 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, W2V-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, W2V-MLP, CV-RF, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-SVM, FAST-EXTRA, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB
- 39 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, CV-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, FAST-CNN, CV-SVM, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, W2V-MLP, CV-RF, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-SVM, FAST-EXTRA, W2V-LR, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, CV-KNN, GLOVE-NB
- 40 TF-IDF-SVM, CV-EXTRA, TF-IDF-NB, CV-LR, CV-MLP, TF-IDF-MLP, TF-IDF-EXTRA, TF-IDF-CNN, CV-SVM, FAST-CNN, CV-NB, W2V-SVM, TF-IDF-RF, W2V-CNN, CV-CNN, W2V-MLP, CV-RF, TF-IDF-KNN, TF-IDF-LR, FAST-MLP, FAST-SVM, FAST-EXTRA, W2V-LR, FAST-LR, FAST-RF, W2V-EXTRA, W2V-RF, W2V-KNN, FAST-KNN, GLOVE-SVM, GLOVE-MLP, GLOVE-RF, GLOVE-EXTRA, FAST-NB, GLOVE-CNN, W2V-NB, GLOVE-KNN, GLOVE-LR, CV-KNN, GLOVE-NB

Fonte: A autora (2023). Para cada métrica altera a ordem, mas são os mesmos grupos.

Tabela 16 – Resultados dos classificadores para o conjunto Covid.

Classificador	acc	pre	rec	f1	Classificador	acc	pre	rec	f1
CV-SVM	0,914	0,914	0,893	0,903	A-NB-LR	0,904	0,904	0,906	0,905
TF-IDF-SVM	0,924	0,924	0,921	0,922	A-MLP-LR	0,927	0,927	0,922	0,925
W2V-SVM	0,912	0,912	0,881	0,896	A-EXTRA-LR	0,928	0,928	0,915	0,922
GLOVE-SVM	0,842	0,842	0,836	0,839	A-KNN-LR	0,916	0,916	0,889	0,903
FAST-SVM	0,861	0,861	0,879	0,870	A-CNN-LR	0,930	0,930	0,904	0,917
CV-LR	0,923	0,923	0,894	0,908	A-SVM-RF	0,935	0,935	0,914	0,926
TF-IDF-LR	0,902	0,902	0,888	0,895	A-LR-RF	0,916	0,916	0,904	0,909
GLOVE-LR	0,780	0,780	0,835	0,807	A-RF-RF	0,903	0,903	0,888	0,896
W2V-LR	0,860	0,860	0,869	0,864	A-NB-RF	0,906	0,906	0,890	0,901
FAST-LR	0,840	0,840	0,884	0,861	A-MLP-RF	0,927	0,927	0,918	0,924
CV-RF	0,915	0,915	0,870	0,892	A-EXTRA-RF	0,935	0,935	0,903	0,921
TF-IDF-RF	0,909	0,909	0,879	0,893	A-KNN-RF	0,894	0,894	0,875	0,884
GLOVE-RF	0,842	0,842	0,796	0,818	A-CNN-RF	0,933	0,933	0,901	0,915
W2V-RF	0,879	0,879	0,809	0,842	A-SVM-NB	0,93	0,93	0,916	0,923
FAST-RF	0,875	0,875	0,821	0,847	A-LR-NB	0,914	0,914	0,901	0,907
CV-NB	0,911	0,911	0,88	0,896	A-RF-NB	0,926	0,926	0,879	0,902
TF-IDF-NB	0,901	0,901	0,906	0,904	A-NB-NB	0,913	0,913	0,888	0,900
GLOVE-NB	0,733	0,733	0,778	0,755	A-MLP-NB	0,931	0,931	0,922	0,927
W2V-NB	0,796	0,796	0,797	0,797	A-EXTRA-NB	0,932	0,932	0,894	0,912
FAST-NB	0,834	0,834	0,780	0,806	A-KNN-NB	0,913	0,913	0,879	0,896
CV-MLP	0,925	0,925	0,909	0,917	A-CNN-NB	0,930	0,930	0,908	0,919

TF-IDF-MLP	0,907 0,907 0,911 0,909	B-CV-LR	0,935 0,935 0,907 0,921
GLOVE-MLP	0,832 0,832 0,825 0,829	B-TF-IDF-LR	0,937 0,937 0,924 0,930
W2V-MLP	0,892 0,892 0,897 0,895	B-W2V-LR	0,910 0,910 0,906 0,908
FAST-MLP	0,876 0,876 0,887 0,881	B-GLOVE-LR	0,875 0,875 0,850 0,862
CV-EXTRA	0,932 0,932 0,896 0,913	B-FAST-LR	0,924 0,924 0,895 0,909
TF-IDF-EXTRA	0,928 0,928 0,914 0,921	B-CV-RF	0,932 0,932 0,919 0,926
GLOVE-EXTRA	0,841 0,841 0,82 0,83	B-TF-IDF-RF	0,938 0,938 0,927 0,932
W2V-EXTRA	0,882 0,882 0,827 0,853	B-W2V-RF	0,915 0,915 0,899 0,906
FAST-EXTRA	0,877 0,877 0,833 0,854	B-GLOVE-RF	0,868 0,868 0,833 0,851
CV-KNN	0,955 0,955 0,514 0,669	B-FAST-RF	0,912 0,912 0,896 0,902
TF-IDF-KNN	0,931 0,931 0,834 0,88	B-CV-NB	0,938 0,938 0,913 0,925
GLOVE-KNN	0,765 0,765 0,876 0,817	B-TF-IDF-NB	0,938 0,938 0,921 0,929
W2V-KNN	0,822 0,822 0,89 0,855	B-W2V-NB	0,908 0,908 0,896 0,902
FAST-KNN	0,818 0,818 0,889 0,852	B-GLOVE-NB	0,857 0,857 0,839 0,848
CV-CNN	0,935 0,935 0,846 0,888	B-FAST-NB	0,905 0,905 0,884 0,894
TF-IDF-CNN	0,896 0,896 0,912 0,904	C-LR	0,941 0,941 0,923 0,932
W2V-CNN	0,866 0,866 0,939 0,901	C-RF	0,947 0,947 0,922 0,933
GLOVE-CNN	0,758 0,758 0,945 0,841	C-NB	0,937 0,937 0,909 0,923
FAST-CNN	0,919 0,919 0,882 0,900	D-LR	0,931 0,931 0,932 0,931
A-SVM-LR	0,930 0,930 0,921 0,925	D-RF	0,932 0,931 0,932 0,931
A-LR-LR	0,923 0,923 0,904 0,914	D-NB	0,923 0,923 0,924 0,923
A-RF-LR	0,917 0,917 0,887 0,901		

Fonte: A autora (2023). Os maiores resultados estão em destacados em negrito.

APÊNDICE E – RESULTADOS FA-KES

Tabela 17 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Fa-Kes.

k	LR				RF				NB			
	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,491 (0,044)	0,520 (0,047)	0,494 (0,078)	0,504 (0,053)	0,503 (0,041)	0,529 (0,038)	0,507 (0,078)	0,516 (0,058)	0,502 (0,038)	0,523 (0,028)	0,713 (0,164)	0,595 (0,064)
2	0,486 (0,044)	0,514 (0,045)	0,499 (0,055)	0,505 (0,045)	0,496 (0,045)	0,524 (0,043)	0,535 (0,064)	0,531 (0,046)	0,504 (0,036)	0,528 (0,031)	0,647 (0,123)	0,575 (0,049)
3	0,491 (0,035)	0,520 (0,034)	0,513 (0,053)	0,515 (0,032)	0,496 (0,036)	0,518 (0,035)	0,525 (0,080)	0,520 (0,041)	0,486 (0,035)	0,514 (0,036)	0,573 (0,134)	0,534 (0,069)
4	0,496 (0,028)	0,522 (0,025)	0,524 (0,054)	0,522 (0,037)	0,490 (0,014)	0,519 (0,015)	0,541 (0,037)	0,529 (0,025)	0,486 (0,032)	0,513 (0,033)	0,565 (0,122)	0,531 (0,066)
5	0,495 (0,027)	0,522 (0,026)	0,518 (0,059)	0,519 (0,038)	0,490 (0,019)	0,520 (0,018)	0,529 (0,045)	0,522 (0,029)	0,488 (0,038)	0,515 (0,037)	0,546 (0,096)	0,526 (0,055)
6	0,500 (0,031)	0,530 (0,035)	0,500 (0,052)	0,513 (0,031)	0,499 (0,025)	0,522 (0,026)	0,532 (0,067)	0,526 (0,030)	0,502 (0,04)	0,528 (0,039)	0,549 (0,086)	0,536 (0,050)
7	0,499 (0,031)	0,529 (0,034)	0,499 (0,052)	0,512 (0,030)	0,496 (0,023)	0,519 (0,019)	0,530 (0,054)	0,525 (0,039)	0,503 (0,041)	0,529 (0,041)	0,560 (0,080)	0,542 (0,045)

8	0,507 (0,034)	0,537 (0,038)	0,503 (0,054)	0,518 (0,036)	0,494 (0,031)	0,520 (0,029)	0,539 (0,067)	0,523 (0,039)	0,49 (0,041)	0,518 (0,041)	0,532 (0,065)	0,523 (0,039)
9	0,507 (0,034)	0,537 (0,038)	0,503 (0,054)	0,518 (0,036)	0,495 (0,031)	0,520 (0,033)	0,528 (0,061)	0,522 (0,038)	0,490 (0,041)	0,518 (0,041)	0,532 (0,065)	0,523 (0,039)
10	0,492 (0,035)	0,520 (0,034)	0,493 (0,060)	0,505 (0,043)	0,491 (0,030)	0,518 (0,034)	0,524 (0,060)	0,525 (0,037)	0,499 (0,038)	0,526 (0,036)	0,544 (0,070)	0,533 (0,042)
11	0,486 (0,033)	0,513 (0,033)	0,490 (0,061)	0,501 (0,045)	0,495 (0,030)	0,523 (0,030)	0,54 (0,047)	0,526 (0,032)	0,493 (0,045)	0,520 (0,039)	0,535 (0,092)	0,524 (0,058)
12	0,491 (0,028)	0,519 (0,027)	0,501 (0,056)	0,509 (0,037)	0,498 (0,035)	0,52 (0,033)	0,540 (0,050)	0,531 (0,032)	0,493 (0,041)	0,520 (0,039)	0,532 (0,096)	0,522 (0,059)
13	0,491 (0,028)	0,519 (0,027)	0,501 (0,056)	0,509 (0,037)	0,497 (0,035)	0,521 (0,030)	0,54 (0,051)	0,531 (0,033)	0,493 (0,041)	0,520 (0,039)	0,532 (0,096)	0,522 (0,059)
14	0,492 (0,028)	0,520 (0,027)	0,500 (0,056)	0,508 (0,037)	0,502 (0,027)	0,527 (0,029)	0,553 (0,045)	0,540 (0,030)	0,487 (0,038)	0,513 (0,035)	0,520 (0,108)	0,512 (0,067)
15	0,492 (0,029)	0,521 (0,028)	0,500 (0,056)	0,509 (0,037)	0,507 (0,030)	0,535 (0,028)	0,558 (0,039)	0,547 (0,026)	0,497 (0,039)	0,525 (0,035)	0,533 (0,094)	0,525 (0,055)
16	0,498 (0,029)	0,526 (0,028)	0,505 (0,053)	0,514 (0,035)	0,511 (0,030)	0,538 (0,028)	0,563 (0,037)	0,548 (0,026)	0,501 (0,033)	0,529 (0,034)	0,525 (0,101)	0,521 (0,058)

17	0,500 (0,044)	0,527 (0,041)	0,508 (0,062)	0,517 (0,047)	0,513 (0,029)	0,538 (0,030)	0,561 (0,041)	0,548 (0,031)	0,499 (0,042)	0,530 (0,043)	0,518 (0,093)	0,518 (0,056)
18	0,503 (0,048)	0,531 (0,045)	0,512 (0,061)	0,520 (0,048)	0,515 (0,030)	0,540 (0,029)	0,571 (0,038)	0,556 (0,029)	0,502 (0,038)	0,532 (0,040)	0,513 (0,103)	0,516 (0,063)
19	0,508 (0,052)	0,533 (0,048)	0,518 (0,074)	0,525 (0,059)	0,519 (0,026)	0,541 (0,026)	0,568 (0,040)	0,555 (0,028)	0,498 (0,039)	0,528 (0,038)	0,513 (0,099)	0,515 (0,059)
20	0,505 (0,050)	0,531 (0,046)	0,516 (0,070)	0,523 (0,055)	0,514 (0,031)	0,536 (0,025)	0,563 (0,042)	0,548 (0,028)	0,495 (0,047)	0,528 (0,050)	0,501 (0,094)	0,508 (0,056)
21	0,504 (0,058)	0,530 (0,054)	0,518 (0,073)	0,523 (0,061)	0,514 (0,024)	0,538 (0,023)	0,569 (0,038)	0,554 (0,024)	0,495 (0,046)	0,528 (0,048)	0,499 (0,106)	0,506 (0,063)
22	0,504 (0,057)	0,531 (0,054)	0,515 (0,072)	0,522 (0,060)	0,505 (0,032)	0,529 (0,027)	0,557 (0,038)	0,544 (0,026)	0,494 (0,051)	0,526 (0,052)	0,500 (0,104)	0,507 (0,065)
23	0,504 (0,057)	0,531 (0,054)	0,515 (0,072)	0,522 (0,060)	0,504 (0,026)	0,528 (0,025)	0,55 (0,036)	0,540 (0,024)	0,496 (0,044)	0,528 (0,048)	0,494 (0,104)	0,504 (0,064)
24	0,503 (0,055)	0,530 (0,051)	0,515 (0,070)	0,522 (0,057)	0,504 (0,029)	0,533 (0,029)	0,556 (0,032)	0,538 (0,027)	0,499 (0,043)	0,530 (0,046)	0,495 (0,102)	0,506 (0,063)
25	0,504 (0,049)	0,531 (0,046)	0,513 (0,067)	0,521 (0,052)	0,499 (0,029)	0,528 (0,027)	0,554 (0,037)	0,538 (0,026)	0,503 (0,044)	0,534 (0,047)	0,507 (0,097)	0,515 (0,060)

26	0,501 (0,052)	0,528 (0,048)	0,502 (0,069)	0,514 (0,054)	0,505 (0,030)	0,531 (0,030)	0,551 (0,031)	0,539 (0,026)	0,498 (0,039)	0,528 (0,040)	0,5 (0,116)	0,507 (0,068)
27	0,509 (0,044)	0,538 (0,045)	0,509 (0,046)	0,522 (0,042)	0,505 (0,029)	0,530 (0,03)	0,546 (0,037)	0,535 (0,031)	0,496 (0,050)	0,527 (0,053)	0,495 (0,121)	0,503 (0,075)
28	0,509 (0,041)	0,538 (0,042)	0,506 (0,035)	0,521 (0,034)	0,503 (0,031)	0,526 (0,031)	0,548 (0,035)	0,535 (0,031)	0,489 (0,045)	0,521 (0,050)	0,479 (0,117)	0,491 (0,070)
29	0,514 (0,035)	0,543 (0,037)	0,521 (0,044)	0,531 (0,034)	0,501 (0,035)	0,525 (0,032)	0,547 (0,043)	0,535 (0,033)	0,487 (0,049)	0,518 (0,054)	0,481 (0,115)	0,492 (0,072)
30	0,514 (0,032)	0,542 (0,034)	0,513 (0,046)	0,526 (0,034)	0,497 (0,032)	0,525 (0,036)	0,547 (0,045)	0,536 (0,032)	0,495 (0,050)	0,527 (0,055)	0,491 (0,114)	0,501 (0,069)
31	0,511 (0,033)	0,539 (0,034)	0,516 (0,056)	0,526 (0,041)	0,500 (0,033)	0,524 (0,033)	0,551 (0,042)	0,533 (0,036)	0,495 (0,049)	0,527 (0,053)	0,494 (0,114)	0,503 (0,07)
32	0,511 (0,029)	0,539 (0,029)	0,520 (0,048)	0,528 (0,034)	0,501 (0,033)	0,525 (0,03)	0,560 (0,046)	0,538 (0,031)	0,493 (0,049)	0,526 (0,057)	0,493 (0,116)	0,501 (0,071)
33	0,512 (0,029)	0,539 (0,030)	0,521 (0,049)	0,529 (0,035)	0,496 (0,034)	0,522 (0,030)	0,557 (0,037)	0,537 (0,033)	0,488 (0,051)	0,521 (0,056)	0,484 (0,110)	0,494 (0,071)
34	0,524 (0,028)	0,550 (0,026)	0,535 (0,050)	0,542 (0,036)	0,496 (0,038)	0,524 (0,033)	0,564 (0,041)	0,537 (0,035)	0,497 (0,046)	0,531 (0,052)	0,493 (0,110)	0,503 (0,066)

35	0,526 (0,026)	0,552 (0,025)	0,535 (0,050)	0,543 (0,035)	0,498 (0,034)	0,522 (0,034)	0,552 (0,040)	0,538 (0,032)	0,493 (0,047)	0,528 (0,054)	0,487 (0,106)	0,498 (0,064)
36	0,520 (0,030)	0,546 (0,028)	0,532 (0,057)	0,538 (0,040)	0,499 (0,034)	0,524 (0,032)	0,56 (0,042)	0,539 (0,032)	0,494 (0,051)	0,530 (0,061)	0,482 (0,100)	0,498 (0,064)
37	0,520 (0,030)	0,546 (0,028)	0,532 (0,057)	0,538 (0,040)	0,499 (0,033)	0,524 (0,031)	0,557 (0,044)	0,538 (0,034)	0,494 (0,051)	0,530 (0,061)	0,482 (0,100)	0,498 (0,064)
38	0,520 (0,029)	0,547 (0,028)	0,532 (0,053)	0,538 (0,038)	0,500 (0,038)	0,523 (0,034)	0,554 (0,039)	0,537 (0,036)	0,498 (0,051)	0,533 (0,060)	0,488 (0,103)	0,502 (0,065)
39	0,519 (0,030)	0,546 (0,029)	0,527 (0,051)	0,536 (0,038)	0,500 (0,037)	0,524 (0,036)	0,558 (0,040)	0,539 (0,037)	0,498 (0,041)	0,532 (0,049)	0,491 (0,103)	0,503 (0,061)
40	0,519 (0,029)	0,546 (0,029)	0,526 (0,051)	0,535 (0,037)	0,501 (0,037)	0,527 (0,035)	0,566 (0,037)	0,543 (0,036)	0,502 (0,038)	0,538 (0,050)	0,474 (0,096)	0,497 (0,056)

Fonte: A autora (2023). Os resultados correspondem a média dos 10 *folds* e o valor entre parêntesis ao desvio-padrão da amostra. Os maiores resultados obtidos estão em destacados em negrito.

Tabela 18 – Lista com os grupos obtidos para cada valor de k para o conjunto Fa-Kes.

k	Grupo
1	W2V-SVM
2	FAST-MLP, W2V-SVM
3	FAST-MLP, W2V-RF, W2V-SVM
4	FAST-MLP, FAST-NB, W2V-SVM, W2V-RF
5	W2V-KNN, FAST-NB, W2V-SVM, W2V-RF, FAST-MLP
6	W2V-KNN, FAST-NB, W2V-SVM, W2V-RF, FAST-KNN, FAST-MLP
7	W2V-KNN, FAST-NB, W2V-SVM, FAST-SVM, W2V-RF, FAST-KNN, FAST-MLP
8	W2V-KNN, FAST-NB, W2V-SVM, FAST-SVM, W2V-RF, FAST-KNN, FAST-MLP, W2V-MLP
9	W2V-KNN, FAST-NB, W2V-SVM, FAST-SVM, W2V-RF, TF-IDF-CNN, FAST-KNN, FAST-MLP, W2V-MLP
10	W2V-KNN, TF-IDF-KNN, W2V-SVM, FAST-SVM, W2V-RF, TF-IDF-CNN, FAST-KNN, FAST-NB, FAST-MLP, W2V-MLP
11	W2V-KNN, TF-IDF-KNN, W2V-SVM, FAST-SVM, W2V-RF, TF-IDF-CNN, FAST-KNN, FAST-NB, TF-IDF-EXTRA, W2V-MLP, FAST-MLP
12	W2V-KNN, TF-IDF-KNN, W2V-SVM, FAST-SVM, W2V-RF, TF-IDF-CNN, FAST-KNN, FAST-NB, TF-IDF-EXTRA, FAST-RF, W2V-MLP, FAST-MLP
13	W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-KNN, FAST-NB, TF-IDF-EXTRA, FAST-RF, W2V-MLP, FAST-MLP
14	W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-KNN, FAST-CNN, FAST-NB, TF-IDF-EXTRA, FAST-RF, W2V-MLP, FAST-MLP
15	W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-CNN, FAST-SVM, FAST-KNN, FAST-CNN, TF-IDF-SVM, FAST-NB, TF-IDF-EXTRA, FAST-RF, W2V-MLP, FAST-MLP

- 16 W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-CNN, TF-IDF-RF, FAST-SVM, FAST-KNN, FAST-CNN, TF-IDF-SVM, FAST-NB, TF-IDF-EXTRA, FAST-RF, W2V-MLP, FAST-MLP
- 17 W2V-KNN, TF-IDF-KNN, W2V-LR, W2V-RF, W2V-SVM, TF-IDF-CNN, TF-IDF-RF, FAST-SVM, FAST-KNN, FAST-CNN, TF-IDF-SVM, FAST-NB, TF-IDF-EXTRA, FAST-RF, CV-MLP, W2V-MLP, FAST-MLP
- 18 W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-RF, TF-IDF-CNN, FAST-SVM, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, W2V-MLP, CV-MLP, W2V-EXTRA, FAST-MLP
- 19 W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, TF-IDF-RF, TF-IDF-CNN, FAST-SVM, GLOVE-KNN, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, W2V-MLP, CV-MLP, W2V-EXTRA, FAST-MLP
- 20 W2V-KNN, TF-IDF-KNN, W2V-SVM, W2V-LR, W2V-RF, FAST-SVM, TF-IDF-CNN, TF-IDF-RF, GLOVE-KNN, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, TF-IDF-EXTRA, FAST-RF, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, FAST-MLP
- 21 W2V-KNN, TF-IDF-KNN, W2V-RF, W2V-SVM, W2V-LR, TF-IDF-RF, TF-IDF-CNN, FAST-SVM, GLOVE-KNN, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, CV-EXTRA, FAST-RF, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, FAST-MLP
- 22 W2V-KNN, TF-IDF-KNN, W2V-RF, W2V-SVM, W2V-LR, TF-IDF-RF, GLOVE-KNN, TF-IDF-CNN, FAST-SVM, FAST-KNN, FAST-CNN, TF-IDF-SVM, FAST-NB, CV-EXTRA, FAST-RF, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, W2V-CNN, FAST-MLP
- 23 TF-IDF-KNN, W2V-KNN, W2V-LR, W2V-RF, W2V-SVM, TF-IDF-CNN, GLOVE-KNN, TF-IDF-RF, FAST-SVM, FAST-KNN, FAST-CNN, FAST-NB, TF-IDF-SVM, CV-EXTRA, FAST-RF, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, W2V-CNN, FAST-MLP, CV-CNN

-
- 24 W2V-KNN, TF-IDF-KNN, W2V-LR, W2V-RF, W2V-SVM, FAST-SVM, GLOVE-KNN, TF-IDF-CNN, TF-IDF-RF, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, CV-EXTRA, FAST-RF, GLOVE-CNN, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, W2V-CNN, FAST-MLP, CV-CNN
- 25 W2V-KNN, TF-IDF-KNN, GLOVE-NB, W2V-RF, W2V-SVM, W2V-LR, FAST-SVM, GLOVE-KNN, TF-IDF-CNN, TF-IDF-RF, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, CV-EXTRA, FAST-RF, GLOVE-CNN, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, W2V-CNN, FAST-MLP, CV-CNN
- 26 W2V-KNN, TF-IDF-KNN, W2V-LR, W2V-RF, W2V-SVM, GLOVE-NB, FAST-SVM, GLOVE-KNN, TF-IDF-CNN, TF-IDF-RF, FAST-KNN, FAST-NB, FAST-CNN, TF-IDF-SVM, CV-EXTRA, FAST-RF, GLOVE-CNN, W2V-MLP, TF-IDF-MLP, CV-MLP, W2V-EXTRA, TF-IDF-EXTRA, FAST-EXTRA, W2V-CNN, FAST-MLP, CV-CNN
- 27 W2V-KNN, TF-IDF-KNN, W2V-LR, W2V-RF, GLOVE-NB, W2V-SVM, TF-IDF-CNN, TF-IDF-RF, FAST-SVM, GLOVE-KNN, FAST-KNN, FAST-CNN, TF-IDF-SVM, FAST-NB, CV-EXTRA, W2V-NB, GLOVE-CNN, TF-IDF-MLP, CV-MLP, W2V-MLP, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, CV-CNN
- 28 TF-IDF-KNN, W2V-KNN, W2V-SVM, CV-NB, W2V-LR, GLOVE-NB, TF-IDF-CNN, GLOVE-KNN, FAST-SVM, TF-IDF-RF, FAST-KNN, TF-IDF-SVM, FAST-CNN, W2V-RF, FAST-NB, CV-EXTRA, W2V-NB, CV-MLP, GLOVE-CNN, W2V-MLP, TF-IDF-MLP, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, CV-CNN
- 29 TF-IDF-KNN, W2V-KNN, W2V-LR, CV-NB, W2V-SVM, GLOVE-NB, GLOVE-KNN, TF-IDF-RF, FAST-SVM, TF-IDF-CNN, FAST-KNN, FAST-CNN, FAST-NB, TF-IDF-SVM, W2V-RF, CV-EXTRA, W2V-NB, W2V-MLP, TF-IDF-MLP, CV-MLP, GLOVE-CNN, W2V-EXTRA, TF-IDF-EXTRA, CV-LR, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, CV-CNN

-
- 30 W2V-KNN, TF-IDF-KNN, GLOVE-NB, W2V-LR, CV-NB, W2V-SVM, CV-RF, GLOVE-KNN, TF-IDF-CNN, FAST-SVM, FAST-KNN, TF-IDF-SVM, FAST-CNN, FAST-NB, W2V-RF, CV-EXTRA, W2V-NB, W2V-MLP, TF-IDF-MLP, CV-MLP, GLOVE-CNN, CV-LR, W2V-EXTRA, TF-IDF-EXTRA, FAST-RF, W2V-CNN, FAST-EXTRA, FAST-MLP, TF-IDF-RF, CV-CNN
- 31 TF-IDF-KNN, W2V-KNN, CV-NB, GLOVE-NB, W2V-SVM, W2V-LR, CV-KNN, CV-RF, FAST-SVM, TF-IDF-CNN, FAST-KNN, FAST-CNN, FAST-NB, TF-IDF-SVM, W2V-RF, CV-EXTRA, GLOVE-KNN, W2V-NB, W2V-MLP, TF-IDF-MLP, CV-MLP, GLOVE-CNN, CV-LR, W2V-EXTRA, TF-IDF-EXTRA, FAST-RF, W2V-CNN, FAST-EXTRA, FAST-MLP, TF-IDF-RF, CV-CNN
- 32 TF-IDF-KNN, W2V-KNN, GLOVE-NB, CV-NB, W2V-LR, W2V-SVM, TF-IDF-CNN, CV-KNN, FAST-SVM, CV-RF, FAST-KNN, TF-IDF-SVM, FAST-CNN, W2V-RF, FAST-NB, CV-EXTRA, GLOVE-KNN, W2V-NB, TF-IDF-MLP, GLOVE-CNN, CV-MLP, GLOVE-MLP, CV-LR, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 33 TF-IDF-KNN, W2V-KNN, W2V-LR, CV-NB, W2V-SVM, GLOVE-NB, TF-IDF-CNN, CV-KNN, CV-RF, FAST-SVM, FAST-KNN, FAST-CNN, FAST-NB, W2V-RF, CV-SVM, TF-IDF-SVM, CV-EXTRA, GLOVE-KNN, W2V-NB, GLOVE-MLP, CV-MLP, TF-IDF-MLP, GLOVE-CNN, CV-LR, W2V-EXTRA, TF-IDF-EXTRA, FAST-RF, W2V-CNN, FAST-EXTRA, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 34 TF-IDF-KNN, W2V-KNN, GLOVE-NB, CV-NB, W2V-LR, W2V-SVM, TF-IDF-CNN, CV-KNN, FAST-SVM, CV-RF, FAST-KNN, FAST-CNN, FAST-NB, W2V-RF, CV-SVM, TF-IDF-SVM, GLOVE-EXTRA, CV-EXTRA, GLOVE-KNN, W2V-NB, TF-IDF-MLP, GLOVE-CNN, CV-MLP, GLOVE-MLP, CV-LR, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP

- 35 TF-IDF-KNN, W2V-KNN, W2V-LR, CV-NB, W2V-SVM, GLOVE-NB, TF-IDF-CNN, GLOVE-SVM, CV-KNN, CV-RF, FAST-SVM, FAST-KNN, FAST-CNN, FAST-NB, CV-SVM, W2V-RF, CV-EXTRA, GLOVE-EXTRA, TF-IDF-SVM, GLOVE-KNN, W2V-NB, GLOVE-MLP, CV-MLP, TF-IDF-MLP, GLOVE-CNN, CV-LR, W2V-EXTRA, TF-IDF-EXTRA, FAST-RF, W2V-CNN, FAST-EXTRA, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 36 TF-IDF-KNN, W2V-KNN, GLOVE-NB, W2V-SVM, CV-NB, W2V-LR, CV-KNN, FAST-SVM, GLOVE-SVM, CV-RF, TF-IDF-CNN, FAST-KNN, CV-SVM, FAST-NB, FAST-CNN, W2V-RF, CV-EXTRA, TF-IDF-SVM, GLOVE-EXTRA, GLOVE-KNN, W2V-NB, GLOVE-MLP, GLOVE-CNN, TF-IDF-MLP, TF-IDF-NB, CV-MLP, TF-IDF-EXTRA, W2V-EXTRA, CV-LR, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 37 TF-IDF-KNN, W2V-KNN, W2V-LR, W2V-SVM, CV-NB, GLOVE-NB, CV-KNN, FAST-SVM, GLOVE-SVM, FAST-LR, TF-IDF-CNN, FAST-KNN, CV-SVM, FAST-CNN, FAST-NB, W2V-RF, CV-EXTRA, TF-IDF-SVM, GLOVE-EXTRA, GLOVE-KNN, W2V-NB, CV-RF, GLOVE-MLP, GLOVE-CNN, TF-IDF-MLP, TF-IDF-NB, CV-MLP, TF-IDF-EXTRA, W2V-EXTRA, CV-LR, FAST-RF, FAST-EXTRA, W2V-CNN, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 38 TF-IDF-KNN, W2V-KNN, W2V-LR, W2V-SVM, CV-NB, GLOVE-NB, CV-KNN, FAST-SVM, GLOVE-SVM, FAST-LR, TF-IDF-CNN, FAST-KNN, CV-SVM, FAST-NB, FAST-CNN, W2V-RF, TF-IDF-SVM, CV-EXTRA, GLOVE-EXTRA, GLOVE-KNN, CV-RF, W2V-NB, GLOVE-CNN, TF-IDF-MLP, CV-MLP, TF-IDF-NB, GLOVE-MLP, CV-LR, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, GLOVE-LR, FAST-EXTRA, W2V-CNN, FAST-MLP, TF-IDF-RF, CV-CNN, W2V-MLP
- 39 TF-IDF-KNN, W2V-KNN, W2V-LR, CV-NB, GLOVE-NB, W2V-SVM, GLOVE-SVM, CV-KNN, FAST-SVM, FAST-LR, TF-IDF-CNN, FAST-KNN, W2V-RF, FAST-NB, CV-SVM, FAST-CNN, TF-IDF-SVM, GLOVE-EXTRA, CV-EXTRA, GLOVE-KNN, W2V-NB, CV-RF, GLOVE-MLP, TF-IDF-MLP, TF-IDF-NB, GLOVE-CNN, CV-MLP, CV-LR, TF-IDF-EXTRA, W2V-EXTRA, FAST-RF, GLOVE-LR, W2V-CNN, FAST-EXTRA, FAST-MLP, GLOVE-RF, CV-CNN, W2V-MLP, TF-IDF-RF

40	TF-IDF-KNN, W2V-KNN, TF-IDF-LR, CV-NB, GLOVE-NB, W2V-SVM, W2V-LR, GLOVE-SVM, FAST-LR, CV-KNN, FAST-SVM, TF-IDF-CNN, FAST-KNN, CV-SVM, FAST-NB, W2V-RF, FAST-CNN, TF-IDF-SVM, GLOVE-EXTRA, CV-EXTRA, GLOVE-KNN, W2V-NB, CV-RF, GLOVE-MLP, CV-MLP, TF-IDF-MLP, TF-IDF-NB, GLOVE-CNN, CV-LR, W2V-EXTRA, TF-IDF-EXTRA, GLOVE-LR, FAST-RF, W2V-CNN, FAST-EXTRA, FAST-MLP, GLOVE-RF, CV-CNN, W2V-MLP, TF-IDF-RF
----	---

Fonte: A autora (2023). Para cada *fold* e métrica altera a ordem, mas os grupos são os mesmos.

Tabela 19 – Resultados dos classificadores para o conjunto Fa-Kes.

Classificador	acc	pre	rec	f1
CV-SVM	0,514(0,044)	0,541(0,041)	0,534(0,050)	0,537(0,042)
TF-IDF-SVM	0,532(0,035)	0,552(0,031)	0,610(0,038)	0,580(0,029)
W2V-SVM	0,527(0,007)	0,528(0,004)	0,973(0,021)	0,685(0,007)
GLOVE-SVM	0,522(0,012)	0,525(0,006)	0,983(0,024)	0,685(0,011)
FAST-SVM	0,528(0,000)	0,528(0,000)	1,000(0,000)	0,691(0,000)
CV-LR	0,493(0,030)	0,521(0,028)	0,507(0,048)	0,513(0,032)
TF-IDF-LR	0,520(0,029)	0,525(0,016)	0,941(0,078)	0,673(0,033)
GLOVE-LR	0,501(0,020)	0,516(0,010)	0,874(0,091)	0,647(0,0330)
W2V-LR	0,528(0,000)	0,528(0,000)	1,000(0,000)	0,691(0,000)
FAST-LR	0,528(0,000)	0,528(0,000)	1,000(0,000)	0,691(0,000)
CV-RF	0,507(0,039)	0,535(0,040)	0,526(0,060)	0,529(0,043)
TF-IDF-RF	0,541(0,030)	0,559(0,028)	0,628(0,024)	0,591(0,022)
GLOVE-RF	0,483(0,023)	0,509(0,021)	0,558(0,065)	0,531(0,036)
W2V-RF	0,514(0,028)	0,538(0,025)	0,574(0,045)	0,555(0,029)
FAST-RF	0,506(0,060)	0,531(0,053)	0,596(0,058)	0,561(0,049)

CV-NB	0,529(0,041)	0,554(0,039)	0,549(0,052)	0,552(0,043)
TF-IDF-NB	0,533(0,017)	0,548(0,014)	0,658(0,052)	0,597(0,024)
GLOVE-NB	0,484(0,024)	0,508(0,018)	0,627(0,110)	0,558(0,051)
W2V-NB	0,499(0,025)	0,524(0,021)	0,572(0,047)	0,546(0,029)
FAST-NB	0,519(0,042)	0,537(0,032)	0,634(0,072)	0,581(0,047)
CV-MLP	0,529(0,032)	0,552(0,031)	0,579(0,045)	0,564(0,031)
TF-IDF-MLP	0,526(0,029)	0,548(0,026)	0,579(0,042)	0,563(0,028)
GLOVE-MLP	0,502(0,025)	0,52(0,015)	0,712(0,116)	0,598(0,046)
W2V-MLP	0,506(0,037)	0,525(0,030)	0,607(0,178)	0,554(0,088)
FAST-MLP	0,497(0,029)	0,516(0,017)	0,682(0,165)	0,582(0,068)
CV-EXTRA	0,528(0,032)	0,549(0,027)	0,599(0,053)	0,572(0,034)
TF-IDF-EXTRA	0,524(0,029)	0,543(0,025)	0,618(0,058)	0,577(0,032)
GLOVE-EXTRA	0,475(0,037)	0,503(0,035)	0,534(0,057)	0,517(0,039)
W2V-EXTRA	0,491(0,038)	0,516(0,032)	0,580(0,050)	0,546(0,037)
FAST-EXTRA	0,504(0,028)	0,527(0,024)	0,587(0,057)	0,554(0,035)
CV-KNN	0,505(0,035)	0,531(0,036)	0,527(0,081)	0,527(0,053)
TF-IDF-KNN	0,530(0,022)	0,553(0,020)	0,571(0,049)	0,561(0,030)
GLOVE-KNN	0,496(0,025)	0,522(0,022)	0,548(0,054)	0,534(0,032)
W2V-KNN	0,527(0,012)	0,547(0,011)	0,602(0,050)	0,573(0,022)
FAST-KNN	0,536(0,023)	0,556(0,022)	0,602(0,046)	0,577(0,027)
CV-CNN	0,519(0,019)	0,527(0,015)	0,849(0,253)	0,634(0,105)
TF-IDF-CNN	0,522(0,024)	0,526(0,011)	0,913(0,200)	0,658(0,083)
W2V-CNN	0,498(0,040)	0,520(0,073)	0,592(0,300)	0,515(0,172)
GLOVE-CNN	0,494(0,038)	0,364(0,252)	0,560(0,398)	0,439(0,306)
FAST-CNN	0,516(0,040)	0,528(0,051)	0,620(0,275)	0,543(0,161)
A-SVM-LR	0,484(0,032)	0,514(0,033)	0,500(0,054)	0,505(0,031)
A-LR-LR	0,499(0,032)	0,529(0,031)	0,487(0,052)	0,506(0,033)

A-RF-LR	0,519(0,032)	0,546(0,033)	0,540(0,065)	0,541(0,042)
A-NB-LR	0,496(0,040)	0,523(0,040)	0,519(0,062)	0,52(0,048)
A-MLP-LR	0,491(0,034)	0,519(0,035)	0,486(0,068)	0,500(0,045)
A-EXTRA-LR	0,518(0,032)	0,543(0,031)	0,538(0,059)	0,540(0,041)
A-KNN-LR	0,515(0,050)	0,543(0,048)	0,509(0,065)	0,525(0,054)
A-CNN-LR	0,505(0,032)	0,535(0,034)	0,507(0,053)	0,519(0,035)
A-SVM-RF	0,506(0,038)	0,531(0,040)	0,540(0,041)	0,541(0,037)
A-LR-RF	0,486(0,031)	0,516(0,027)	0,521(0,087)	0,521(0,035)
A-RF-RF	0,521(0,044)	0,554(0,042)	0,578(0,089)	0,548(0,057)
A-NB-RF	0,508(0,043)	0,524(0,035)	0,564(0,062)	0,551(0,042)
A-MLP-RF	0,482(0,022)	0,526(0,033)	0,526(0,061)	0,519(0,034)
A-EXTRA-RF	0,526(0,041)	0,549(0,043)	0,560(0,061)	0,550(0,036)
A-KNN-RF	0,504(0,037)	0,528(0,043)	0,500(0,042)	0,501(0,037)
A-CNN-RF	0,490(0,033)	0,527(0,043)	0,526(0,072)	0,520(0,028)
A-SVM-NB	0,499(0,043)	0,528(0,041)	0,559(0,069)	0,540(0,034)
A-LR-NB	0,493(0,028)	0,515(0,025)	0,551(0,268)	0,500(0,160)
A-RF-NB	0,514(0,041)	0,537(0,041)	0,581(0,150)	0,550(0,083)
A-NB-NB	0,475(0,050)	0,500(0,046)	0,558(0,085)	0,526(0,062)
A-MLP-NB	0,505(0,03)	0,527(0,023)	0,605(0,095)	0,560(0,049)
A-EXTRA-NB	0,507(0,035)	0,528(0,039)	0,581(0,267)	0,525(0,142)
A-KNN-NB	0,510(0,055)	0,535(0,053)	0,569(0,081)	0,550(0,056)
A-CNN-NB	0,515(0,034)	0,543(0,036)	0,531(0,073)	0,534(0,043)
B-CV-LR	0,512(0,032)	0,538(0,030)	0,521(0,079)	0,528(0,051)
B-TF-IDF-LR	0,491(0,045)	0,518(0,042)	0,509(0,056)	0,513(0,045)
B-W2V-LR	0,496(0,029)	0,523(0,029)	0,480(0,070)	0,499(0,047)
B-GLOVE-LR	0,499(0,034)	0,526(0,032)	0,516(0,049)	0,520(0,037)
B-FAST-LR	0,494(0,037)	0,522(0,036)	0,515(0,034)	0,518(0,030)

B-CV-RF	0,492(0,033)	0,516(0,017)	0,562(0,057)	0,525(0,024)
B-TF-IDF-RF	0,514(0,043)	0,528(0,044)	0,560(0,083)	0,539(0,06)
B-W2V-RF	0,506(0,034)	0,534(0,022)	0,541(0,041)	0,525(0,043)
B-GLOVE-RF	0,486(0,038)	0,521(0,032)	0,565(0,052)	0,524(0,031)
B-FAST-RF	0,499(0,033)	0,536(0,030)	0,542(0,068)	0,522(0,043)
B-CV-NB	0,515(0,042)	0,543(0,044)	0,544(0,057)	0,542(0,040)
B-TF-IDF-NB	0,510(0,041)	0,541(0,051)	0,475(0,154)	0,495(0,091)
B-W2V-NB	0,491(0,027)	0,521(0,031)	0,508(0,120)	0,507(0,062)
B-GLOVE-NB	0,484(0,031)	0,513(0,027)	0,576(0,093)	0,538(0,044)
B-FAST-NB	0,502(0,030)	0,529(0,027)	0,572(0,099)	0,545(0,040)
C-LR	0,519(0,029)	0,546(0,029)	0,526(0,051)	0,535(0,037)
C-RF	0,505(0,029)	0,531(0,035)	0,564(0,072)	0,544(0,047)
C-NB	0,499(0,040)	0,534(0,050)	0,472(0,089)	0,495(0,054)
D-LR	0,526(0,026)	0,552(0,025)	0,535(0,050)	0,543(0,035)
D-RF	0,519(0,026)	0,541(0,026)	0,571(0,038)	0,556(0,029)
D-NB	0,504(0,036)	0,538(0,050)	0,713(0,164)	0,595(0,064)

Fonte: A autora (2023). Os maiores resultados obtidos estão em destacados em negrito.

APÊNDICE F – RESULTADOS OTT

Tabela 20 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Ott.

k	LR			RF			NB					
	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,788 (0,019)	0,782 (0,025)	0,799 (0,033)	0,790 (0,020)	0,693 (0,023)	0,698 (0,027)	0,684 (0,044)	0,692 (0,028)	0,786 (0,020)	0,780 (0,023)	0,798 (0,033)	0,789 (0,021)
2	0,792 (0,024)	0,784 (0,033)	0,809 (0,031)	0,796 (0,023)	0,761 (0,026)	0,767 (0,038)	0,750 (0,035)	0,760 (0,026)	0,792 (0,023)	0,783 (0,031)	0,811 (0,028)	0,796 (0,021)
3	0,855 (0,024)	0,857 (0,028)	0,852 (0,033)	0,854 (0,024)	0,848 (0,023)	0,853 (0,026)	0,844 (0,031)	0,850 (0,024)	0,849 (0,019)	0,853 (0,020)	0,844 (0,042)	0,848 (0,022)
4	0,854 (0,023)	0,856 (0,027)	0,852 (0,032)	0,854 (0,023)	0,849 (0,025)	0,851 (0,028)	0,848 (0,031)	0,849 (0,023)	0,850 (0,020)	0,851 (0,016)	0,848 (0,038)	0,849 (0,022)
5	0,855 (0,024)	0,856 (0,024)	0,855 (0,038)	0,855 (0,026)	0,852 (0,026)	0,857 (0,032)	0,850 (0,034)	0,852 (0,027)	0,851 (0,026)	0,850 (0,028)	0,853 (0,040)	0,851 (0,027)
6	0,854 (0,025)	0,857 (0,025)	0,851 (0,035)	0,853 (0,026)	0,853 (0,026)	0,855 (0,032)	0,851 (0,030)	0,852 (0,026)	0,850 (0,026)	0,851 (0,026)	0,849 (0,043)	0,850 (0,028)
7	0,856 (0,024)	0,859 (0,027)	0,852 (0,036)	0,855 (0,025)	0,855 (0,025)	0,858 (0,031)	0,852 (0,029)	0,855 (0,024)	0,851 (0,025)	0,852 (0,028)	0,850 (0,041)	0,850 (0,027)

8	0,857 (0,025)	0,860 (0,031)	0,853 (0,035)	0,856 (0,026)	0,852 (0,025)	0,855 (0,034)	0,854 (0,031)	0,853 (0,025)	0,851 (0,026)	0,854 (0,029)	0,846 (0,040)	0,85 (0,028)
9	0,855 (0,025)	0,858 (0,028)	0,853 (0,035)	0,855 (0,026)	0,855 (0,027)	0,857 (0,034)	0,85 (0,033)	0,853 (0,028)	0,850 (0,028)	0,851 (0,030)	0,849 (0,042)	0,849 (0,029)
10	0,855 (0,026)	0,856 (0,028)	0,854 (0,036)	0,854 (0,027)	0,854 (0,029)	0,859 (0,034)	0,850 (0,034)	0,853 (0,029)	0,850 (0,025)	0,852 (0,026)	0,848 (0,039)	0,850 (0,027)
11	0,857 (0,026)	0,857 (0,027)	0,857 (0,036)	0,857 (0,027)	0,854 (0,026)	0,857 (0,029)	0,851 (0,037)	0,852 (0,027)	0,851 (0,022)	0,852 (0,023)	0,850 (0,034)	0,851 (0,023)
12	0,857 (0,025)	0,857 (0,027)	0,857 (0,036)	0,856 (0,025)	0,854 (0,026)	0,858 (0,029)	0,851 (0,037)	0,854 (0,026)	0,850 (0,023)	0,851 (0,024)	0,850 (0,034)	0,850 (0,024)
13	0,858 (0,023)	0,859 (0,029)	0,857 (0,035)	0,857 (0,024)	0,857 (0,023)	0,859 (0,030)	0,856 (0,036)	0,856 (0,024)	0,850 (0,021)	0,851 (0,022)	0,849 (0,034)	0,850 (0,022)
14	0,858 (0,024)	0,860 (0,027)	0,856 (0,040)	0,857 (0,025)	0,857 (0,024)	0,858 (0,031)	0,857 (0,034)	0,856 (0,025)	0,853 (0,025)	0,854 (0,026)	0,853 (0,038)	0,853 (0,026)
15	0,86 (0,022)	0,862 (0,026)	0,858 (0,035)	0,860 (0,023)	0,857 (0,023)	0,858 (0,030)	0,855 (0,037)	0,858 (0,024)	0,853 (0,022)	0,855 (0,025)	0,851 (0,034)	0,853 (0,023)
16	0,859 (0,022)	0,861 (0,027)	0,857 (0,034)	0,859 (0,023)	0,856 (0,023)	0,857 (0,030)	0,856 (0,034)	0,857 (0,024)	0,854 (0,023)	0,856 (0,026)	0,852 (0,037)	0,854 (0,024)

17	0,859 (0,025)	0,859 (0,027)	0,861 (0,040)	0,859 (0,026)	0,858 (0,023)	0,856 (0,031)	0,864 (0,034)	0,858 (0,022)	0,856 (0,020)	0,857 (0,023)	0,856 (0,028)	0,856 (0,020)
18	0,859 (0,024)	0,86 (0,029)	0,858 (0,042)	0,858 (0,026)	0,856 (0,022)	0,855 (0,032)	0,861 (0,035)	0,858 (0,023)	0,857 (0,022)	0,858 (0,027)	0,857 (0,032)	0,858 (0,023)
19	0,861 (0,024)	0,861 (0,028)	0,861 (0,040)	0,860 (0,025)	0,858 (0,023)	0,856 (0,032)	0,860 (0,034)	0,858 (0,023)	0,858 (0,023)	0,860 (0,028)	0,857 (0,033)	0,858 (0,023)
20	0,860 (0,025)	0,862 (0,030)	0,860 (0,040)	0,860 (0,026)	0,857 (0,023)	0,857 (0,03)	0,860 (0,033)	0,857 (0,023)	0,862 (0,024)	0,863 (0,029)	0,861 (0,033)	0,861 (0,025)
21	0,860 (0,023)	0,862 (0,029)	0,858 (0,036)	0,860 (0,024)	0,856 (0,022)	0,855 (0,031)	0,858 (0,034)	0,857 (0,023)	0,859 (0,022)	0,860 (0,024)	0,859 (0,035)	0,859 (0,023)
22	0,861 (0,021)	0,861 (0,027)	0,863 (0,035)	0,861 (0,022)	0,857 (0,021)	0,857 (0,030)	0,859 (0,034)	0,857 (0,022)	0,858 (0,022)	0,861 (0,026)	0,855 (0,036)	0,858 (0,024)
23	0,860 (0,023)	0,859 (0,029)	0,862 (0,035)	0,860 (0,023)	0,857 (0,022)	0,857 (0,031)	0,859 (0,033)	0,857 (0,022)	0,861 (0,022)	0,862 (0,026)	0,861 (0,033)	0,861 (0,023)
24	0,860 (0,023)	0,860 (0,029)	0,861 (0,035)	0,860 (0,023)	0,857 (0,022)	0,857 (0,030)	0,859 (0,035)	0,857 (0,022)	0,859 (0,020)	0,861 (0,024)	0,857 (0,034)	0,859 (0,022)
25	0,860 (0,022)	0,859 (0,029)	0,861 (0,035)	0,860 (0,023)	0,856 (0,023)	0,856 (0,031)	0,859 (0,033)	0,857 (0,022)	0,858 (0,021)	0,860 (0,026)	0,858 (0,033)	0,858 (0,022)

26	0,859 (0,021)	0,858 (0,028)	0,862 (0,035)	0,860 (0,022)	0,857 (0,023)	0,856 (0,031)	0,860 (0,033)	0,857 (0,023)	0,858 (0,022)	0,860 (0,026)	0,856 (0,035)	0,857 (0,023)
27	0,859 (0,022)	0,858 (0,029)	0,862 (0,035)	0,860 (0,022)	0,857 (0,022)	0,856 (0,030)	0,860 (0,034)	0,857 (0,022)	0,858 (0,021)	0,860 (0,025)	0,855 (0,032)	0,857 (0,021)
28	0,858 (0,022)	0,857 (0,028)	0,861 (0,036)	0,858 (0,023)	0,857 (0,022)	0,855 (0,030)	0,860 (0,033)	0,857 (0,023)	0,857 (0,020)	0,860 (0,023)	0,853 (0,034)	0,856 (0,021)
29	0,859 (0,023)	0,858 (0,029)	0,861 (0,034)	0,859 (0,023)	0,857 (0,023)	0,857 (0,031)	0,859 (0,032)	0,857 (0,021)	0,857 (0,020)	0,860 (0,024)	0,853 (0,034)	0,856 (0,021)
30	0,862 (0,020)	0,865 (0,028)	0,858 (0,030)	0,861 (0,020)	0,863 (0,020)	0,862 (0,032)	0,866 (0,027)	0,863 (0,019)	0,861 (0,020)	0,863 (0,027)	0,859 (0,032)	0,861 (0,021)
31	0,862 (0,020)	0,865 (0,029)	0,859 (0,031)	0,862 (0,020)	0,862 (0,020)	0,862 (0,033)	0,867 (0,026)	0,863 (0,018)	0,861 (0,020)	0,863 (0,026)	0,859 (0,029)	0,861 (0,020)
32	0,863 (0,020)	0,865 (0,028)	0,861 (0,032)	0,863 (0,021)	0,863 (0,021)	0,861 (0,033)	0,866 (0,026)	0,863 (0,019)	0,862 (0,021)	0,864 (0,026)	0,860 (0,033)	0,862 (0,022)
33	0,864 (0,021)	0,868 (0,029)	0,861 (0,033)	0,864 (0,021)	0,863 (0,020)	0,862 (0,033)	0,866 (0,027)	0,863 (0,019)	0,862 (0,019)	0,863 (0,025)	0,860 (0,031)	0,861 (0,02)
34	0,864 (0,021)	0,868 (0,029)	0,861 (0,033)	0,864 (0,021)	0,863 (0,020)	0,862 (0,033)	0,866 (0,027)	0,863 (0,019)	0,862 (0,019)	0,863 (0,025)	0,860 (0,031)	0,861 (0,020)

35	0,864 (0,021)	0,867 (0,030)	0,861 (0,032)	0,863 (0,021)	0,862 (0,021)	0,862 (0,033)	0,865 (0,027)	0,863 (0,019)	0,861 (0,022)	0,862 (0,027)	0,859 (0,031)	0,860 (0,022)
36	0,863 (0,021)	0,866 (0,030)	0,861 (0,032)	0,863 (0,021)	0,863 (0,020)	0,862 (0,033)	0,864 (0,028)	0,863 (0,019)	0,859 (0,021)	0,861 (0,025)	0,858 (0,034)	0,859 (0,022)
37	0,863 (0,021)	0,866 (0,030)	0,861 (0,032)	0,863 (0,021)	0,862 (0,020)	0,861 (0,032)	0,866 (0,027)	0,862 (0,019)	0,858 (0,022)	0,861 (0,023)	0,855 (0,036)	0,858 (0,023)
38	0,863 (0,021)	0,867 (0,030)	0,860 (0,030)	0,863 (0,021)	0,864 (0,020)	0,864 (0,032)	0,867 (0,025)	0,865 (0,019)	0,860 (0,021)	0,863 (0,026)	0,858 (0,031)	0,860 (0,022)
39	0,865 (0,019)	0,866 (0,029)	0,864 (0,032)	0,865 (0,020)	0,865 (0,021)	0,862 (0,032)	0,866 (0,026)	0,864 (0,020)	0,861 (0,022)	0,862 (0,027)	0,86 (0,032)	0,861 (0,023)
40	0,865 (0,020)	0,866 (0,029)	0,864 (0,032)	0,864 (0,020)	0,864 (0,020)	0,863 (0,032)	0,867 (0,026)	0,865 (0,020)	0,86 (0,022)	0,863 (0,027)	0,857 (0,032)	0,859 (0,022)

Fonte: A autora (2023). Os resultados correspondem a média dos 10 *fold*s e o valor entre parêntesis ao desvio-padrão da amostra. Os maiores resultados obtidos estão em destacados em negrito.

Tabela 21 – Lista com os grupos obtidos para cada valor de k para o conjunto Ott.

k	Grupo
1	W2V-SVM
2	W2V-SVM, FAST-MLP
3	W2V-SVM, TF-IDF-SVM, FAST-MLP
4	W2V-SVM, TF-IDF-SVM, FAST-MLP, GLOVE-CNN
5	W2V-SVM, TF-IDF-SVM, CV-MLP, FAST-MLP, GLOVE-CNN
6	W2V-SVM, TF-IDF-SVM, CV-MLP, FAST-MLP, FAST-SVM, GLOVE-CNN
7	W2V-SVM, TF-IDF-SVM, CV-MLP, FAST-MLP, FAST-SVM, W2V-KNN, GLOVE-CNN
8	W2V-SVM, TF-IDF-SVM, CV-MLP, FAST-MLP, FAST-SVM, W2V-KNN, FAST-KNN, GLOVE-CNN
9	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, FAST-MLP, FAST-SVM, W2V-KNN, FAST-KNN, GLOVE-CNN
10	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, FAST-MLP, CV-LR, FAST-SVM, W2V-KNN, FAST-KNN, GLOVE-CNN
11	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, FAST-MLP, CV-LR, TF-IDF-RF, W2V-KNN, FAST-KNN, FAST-SVM, GLOVE-CNN
12	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, FAST-MLP, CV-LR, TF-IDF-RF, W2V-KNN, FAST-KNN, FAST-SVM, GLOVE-KNN, GLOVE-CNN
13	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, TF-IDF-EXTRA, CV-LR, TF-IDF-RF, W2V-KNN, FAST-KNN, FAST-SVM, FAST-MLP, GLOVE-KNN, GLOVE-CNN
14	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, TF-IDF-EXTRA, CV-LR, TF-IDF-RF, TF-IDF-KNN, FAST-KNN, FAST-SVM, FAST-MLP, W2V-KNN, GLOVE-KNN, GLOVE-CNN
15	W2V-RF, TF-IDF-SVM, CV-MLP, W2V-SVM, TF-IDF-EXTRA, CV-LR, TF-IDF-RF, TF-IDF-KNN, FAST-KNN, FAST-SVM, FAST-MLP, W2V-KNN, CV-KNN, GLOVE-CNN, GLOVE-KNN

- 16 W2V-RF, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-LR, TF-IDF-RF, TF-IDF-KNN, W2V-SVM, FAST-KNN, FAST-SVM, FAST-MLP, W2V-KNN, CV-KNN, GLOVE-CNN, GLOVE-KNN
- 17 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-LR, W2V-SVM, TF-IDF-KNN, TF-IDF-RF, FAST-SVM, FAST-KNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, GLOVE-CNN, GLOVE-KNN
- 18 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-LR, W2V-SVM, TF-IDF-KNN, TF-IDF-RF, FAST-SVM, FAST-CNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-CNN, GLOVE-KNN
- 19 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-LR, W2V-SVM, W2V-CNN, TF-IDF-RF, FAST-SVM, FAST-CNN, TF-IDF-KNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-CNN, GLOVE-KNN
- 20 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-SVM, W2V-CNN, TF-IDF-RF, FAST-SVM, FAST-CNN, TF-IDF-KNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-CNN, GLOVE-KNN
- 21 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-SVM, W2V-CNN, TF-IDF-RF, FAST-SVM, FAST-CNN, TF-IDF-KNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 22 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, W2V-CNN, W2V-SVM, FAST-SVM, FAST-CNN, TF-IDF-KNN, FAST-MLP, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 23 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, W2V-SVM, W2V-CNN, FAST-CNN, FAST-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN

-
- 24 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, W2V-SVM, TF-IDF-RF, FAST-CNN, FAST-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-CNN, GLOVE-KNN
- 25 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, W2V-SVM, TF-IDF-RF, FAST-CNN, FAST-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 26 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, W2V-CNN, CV-SVM, FAST-CNN, FAST-SVM, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 27 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, FAST-RF, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, CV-SVM, TF-IDF-RF, FAST-CNN, FAST-SVM, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 28 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, W2V-CNN, CV-SVM, FAST-CNN, FAST-SVM, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-RF, FAST-RF, W2V-KNN, CV-KNN, FAST-KNN, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 29 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, FAST-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, CV-SVM, TF-IDF-RF, FAST-SVM, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, FAST-RF, W2V-RF, W2V-KNN, CV-KNN, FAST-KNN, CV-CNN, FAST-LR, GLOVE-MLP, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN

-
- 30 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, CV-SVM, TF-IDF-RF, FAST-SVM, FAST-CNN, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, FAST-RF, W2V-RF, W2V-KNN, CV-KNN, FAST-NB, FAST-KNN, CV-CNN, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 31 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, W2V-CNN, CV-SVM, TF-IDF-RF, FAST-SVM, FAST-CNN, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, FAST-RF, W2V-RF, W2V-KNN, CV-KNN, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, GLOVE-CNN, GLOVE-KNN
- 32 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, CV-SVM, W2V-CNN, TF-IDF-RF, FAST-SVM, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, FAST-RF, W2V-RF, W2V-KNN, W2V-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-CNN, GLOVE-KNN
- 33 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, CV-SVM, W2V-CNN, FAST-SVM, FAST-CNN, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, FAST-RF, W2V-RF, W2V-KNN, W2V-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-CNN, GLOVE-KNN
- 34 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-CNN, TF-IDF-RF, CV-SVM, FAST-CNN, FAST-SVM, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-CNN, GLOVE-KNN

- 35 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-CNN, TF-IDF-RF, CV-SVM, FAST-CNN, FAST-SVM, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN
- 36 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, TF-IDF-CNN, CV-SVM, FAST-SVM, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, FAST-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN
- 37 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, W2V-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, CV-SVM, TF-IDF-CNN, TF-IDF-RF, FAST-CNN, FAST-SVM, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, FAST-RF, W2V-RF, W2V-KNN, W2V-EXTRA, FAST-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-LR, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN
- 38 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, TF-IDF-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, CV-SVM, TF-IDF-RF, TF-IDF-CNN, FAST-CNN, FAST-SVM, W2V-SVM, TF-IDF-KNN, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, W2V-NB, FAST-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-LR, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN
- 39 TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, TF-IDF-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-RF, TF-IDF-CNN, CV-SVM, W2V-MLP, FAST-SVM, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, W2V-NB, FAST-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-LR, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN

40	TF-IDF-MLP, TF-IDF-SVM, CV-MLP, CV-NB, TF-IDF-NB, TF-IDF-EXTRA, CV-EXTRA, CV-LR, TF-IDF-CNN, CV-SVM, TF-IDF-RF, W2V-MLP, TF-IDF-LR, FAST-CNN, TF-IDF-KNN, W2V-SVM, FAST-MLP, CV-RF, W2V-LR, FAST-SVM, W2V-CNN, W2V-RF, FAST-RF, W2V-KNN, W2V-EXTRA, W2V-NB, FAST-EXTRA, FAST-NB, FAST-KNN, GLOVE-SVM, GLOVE-LR, CV-CNN, GLOVE-RF, GLOVE-MLP, FAST-LR, GLOVE-EXTRA, CV-KNN, GLOVE-NB, GLOVE-CNN, GLOVE-KNN
----	---

Fonte: A autora (2023). Para cada *fold* e métrica altera a ordem, mas os grupos são os mesmos.

Tabela 22 – Resultados dos classificadores para o conjunto Ott.

Classificador	acc	pre	rec	f1
CV-SVM	0,821(0,022)	0,829(0,027)	0,810(0,031)	0,819(0,023)
TF-IDF-SVM	0,857(0,022)	0,855(0,029)	0,861(0,025)	0,858(0,022)
W2V-SVM	0,789(0,019)	0,776(0,025)	0,814(0,021)	0,794(0,017)
GLOVE-SVM	0,658(0,027)	0,652(0,022)	0,675(0,046)	0,663(0,032)
FAST-SVM	0,726(0,012)	0,724(0,008)	0,732(0,033)	0,727(0,018)
CV-LR	0,828(0,022)	0,832(0,026)	0,821(0,029)	0,826(0,022)
TF-IDF-LR	0,810(0,022)	0,792(0,03)	0,844(0,017)	0,817(0,019)
GLOVE-LR	0,649(0,021)	0,643(0,021)	0,669(0,028)	0,655(0,021)
W2V-LR	0,729(0,019)	0,719(0,018)	0,752(0,036)	0,735(0,021)
FAST-LR	0,646(0,029)	0,646(0,031)	0,649(0,025)	0,648(0,026)
CV-RF	0,771(0,022)	0,801(0,032)	0,722(0,028)	0,759(0,021)
TF-IDF-RF	0,803(0,013)	0,827(0,013)	0,766(0,030)	0,795(0,017)
GLOVE-RF	0,633(0,012)	0,641(0,017)	0,608(0,031)	0,624(0,016)
W2V-RF	0,727(0,014)	0,732(0,018)	0,718(0,040)	0,724(0,020)
FAST-RF	0,723(0,028)	0,735(0,027)	0,696(0,045)	0,715(0,033)

CV-NB	0,856(0,017)	0,880(0,031)	0,825(0,025)	0,851(0,017)
TF-IDF-NB	0,849(0,016)	0,894 (0,029)	0,794(0,021)	0,841(0,016)
GLOVE-NB	0,583(0,020)	0,583(0,020)	0,584(0,041)	0,583(0,026)
W2V-NB	0,688(0,009)	0,684(0,010)	0,699(0,024)	0,691(0,012)
FAST-NB	0,694(0,019)	0,702(0,018)	0,674(0,028)	0,688(0,021)
CV-MLP	0,839(0,027)	0,843(0,031)	0,833(0,034)	0,838(0,027)
TF-IDF-MLP	0,857(0,017)	0,858(0,025)	0,856(0,024)	0,857(0,017)
GLOVE-MLP	0,652(0,025)	0,646(0,034)	0,679(0,047)	0,661(0,025)
W2V-MLP	0,785(0,025)	0,774(0,043)	0,814(0,056)	0,791(0,024)
FAST-MLP	0,776(0,032)	0,781(0,059)	0,779(0,073)	0,776(0,032)
CV-EXTRA	0,821(0,015)	0,844(0,023)	0,787(0,022)	0,814(0,015)
TF-IDF-EXTRA	0,819(0,019)	0,839(0,034)	0,791(0,027)	0,814(0,019)
GLOVE-EXTRA	0,631(0,022)	0,638(0,023)	0,606(0,028)	0,621(0,024)
W2V-EXTRA	0,724(0,037)	0,739(0,039)	0,693(0,048)	0,715(0,040)
FAST-EXTRA	0,713(0,028)	0,731(0,030)	0,674(0,037)	0,701(0,030)
CV-KNN	0,590(0,019)	0,785(0,061)	0,251(0,045)	0,377(0,051)
TF-IDF-KNN	0,740(0,023)	0,816(0,032)	0,621(0,034)	0,705(0,028)
GLOVE-KNN	0,615(0,017)	0,620(0,017)	0,593(0,032)	0,606(0,022)
W2V-KNN	0,696(0,027)	0,713(0,030)	0,658(0,054)	0,684(0,035)
FAST-KNN	0,679(0,024)	0,702(0,032)	0,623(0,026)	0,660(0,024)
CV-CNN	0,723(0,056)	0,725(0,109)	0,811(0,189)	0,740(0,060)
TF-IDF-CNN	0,748(0,04)	0,792(0,081)	0,712(0,185)	0,727(0,088)
W2V-CNN	0,786(0,033)	0,826(0,046)	0,736(0,120)	0,771(0,054)
GLOVE-CNN	0,552(0,042)	0,648(0,154)	0,488(0,419)	0,42(0,282)
FAST-CNN	0,771(0,031)	0,789(0,065)	0,764(0,142)	0,763(0,059)
A-SVM-LR	0,857(0,024)	0,857(0,026)	0,858(0,034)	0,857(0,025)
A-LR-LR	0,824(0,028)	0,822(0,027)	0,825(0,036)	0,824(0,029)

A-RF-LR	0,815(0,027)	0,815(0,019)	0,814(0,052)	0,814(0,031)
A-NB-LR	0,858(0,019)	0,874(0,032)	0,838(0,021)	0,855(0,018)
A-MLP-LR	0,855(0,027)	0,855(0,028)	0,857(0,039)	0,855(0,028)
A-EXTRA-LR	0,841(0,020)	0,845(0,034)	0,838(0,032)	0,840(0,020)
A-KNN-LR	0,777(0,014)	0,783(0,022)	0,769(0,029)	0,775(0,015)
A-CNN-LR	0,815(0,026)	0,816(0,041)	0,817(0,042)	0,815(0,026)
A-SVM-RF	0,85(0,026)	0,843(0,027)	0,854(0,038)	0,850(0,030)
A-LR-RF	0,811(0,032)	0,815(0,021)	0,804(0,048)	0,814(0,033)
A-RF-RF	0,806(0,018)	0,815(0,013)	0,798(0,050)	0,801(0,026)
A-NB-RF	0,846(0,014)	0,848(0,029)	0,847(0,033)	0,844(0,015)
A-MLP-RF	0,852(0,023)	0,847(0,030)	0,860(0,034)	0,853(0,019)
A-EXTRA-RF	0,829(0,021)	0,832(0,044)	0,822(0,028)	0,824(0,024)
A-KNN-RF	0,734(0,034)	0,733(0,035)	0,748(0,039)	0,734(0,031)
A-CNN-RF	0,811(0,023)	0,804(0,031)	0,811(0,046)	0,807(0,021)
A-SVM-NB	0,846(0,023)	0,848(0,023)	0,845(0,037)	0,846(0,025)
A-LR-NB	0,824(0,029)	0,822(0,027)	0,826(0,040)	0,824(0,030)
A-RF-NB	0,814(0,023)	0,816(0,021)	0,811(0,043)	0,813(0,026)
A-NB-NB	0,856(0,018)	0,873(0,030)	0,836(0,024)	0,854(0,018)
A-MLP-NB	0,854(0,028)	0,851(0,027)	0,858(0,037)	0,854(0,029)
A-EXTRA-NB	0,831(0,018)	0,834(0,03)	0,829(0,034)	0,831(0,019)
A-KNN-NB	0,772(0,021)	0,785(0,023)	0,752(0,035)	0,767(0,024)
A-CNN-NB	0,815(0,027)	0,816(0,040)	0,816(0,046)	0,815(0,027)
B-CV-LR	0,866 (0,020)	0,872(0,027)	0,86(0,028)	0,865 (0,020)
B-TF-IDF-LR	0,86(0,020)	0,858(0,026)	0,864(0,033)	0,86(0,020)
B-W2V-LR	0,818(0,021)	0,811(0,031)	0,830(0,035)	0,820(0,021)
B-GLOVE-LR	0,657(0,020)	0,656(0,022)	0,660(0,030)	0,658(0,021)
B-FAST-LR	0,804(0,027)	0,809(0,034)	0,798(0,038)	0,803(0,028)

B-CV-RF	0,858(0,016)	0,862(0,030)	0,861(0,024)	0,862(0,019)
B-TF-IDF-RF	0,861(0,016)	0,857(0,030)	0,866(0,034)	0,858(0,015)
B-W2V-RF	0,804(0,023)	0,812(0,046)	0,800(0,036)	0,804(0,027)
B-GLOVE-RF	0,644(0,029)	0,638(0,033)	0,623(0,042)	0,635(0,026)
B-FAST-RF	0,789(0,018)	0,804(0,045)	0,769(0,048)	0,782(0,027)
B-CV-NB	0,859(0,022)	0,861(0,027)	0,857(0,032)	0,859(0,023)
B-TF-IDF-NB	0,861(0,022)	0,859(0,027)	0,863(0,029)	0,861(0,022)
B-W2V-NB	0,802(0,023)	0,791(0,033)	0,824(0,034)	0,807(0,022)
B-GLOVE-NB	0,668(0,023)	0,667(0,024)	0,671(0,040)	0,668(0,026)
B-FAST-NB	0,782(0,027)	0,788(0,031)	0,771(0,042)	0,779(0,029)
C-LR	0,864(0,020)	0,866(0,031)	0,864(0,032)	0,864(0,020)
C-RF	0,864(0,021)	0,864(0,034)	0,866(0,027)	0,863(0,018)
C-NB	0,860(0,020)	0,861(0,026)	0,860(0,032)	0,860(0,020)
D-LR	0,865(0,019)	0,868(0,029)	0,864(0,032)	0,865(0,020)
D-RF	0,865(0,021)	0,864(0,032)	0,867(0,026)	0,865(0,019)
D-NB	0,862(0,024)	0,864(0,026)	0,861(0,033)	0,862(0,022)

Fonte: A autora (2023). Os maiores resultados obtidos estão em destacados em negrito. Para resultados iguais foi considerado o obtido utilizando menos elementos no grupo.

APÊNDICE G – RESULTADOS KAGGLE

Tabela 23 – Resultados obtidos para cada métrica e meta-classificador em cada valor de k para o conjunto Kaggle.

k	LR				RF				NB			
	acc	pre	rec	f1	acc	pre	rec	f1	acc	pre	rec	f1
1	0,914 (0,007)	0,905 (0,015)	0,912 (0,016)	0,909 (0,007)	0,891 (0,012)	0,891 (0,015)	0,876 (0,019)	0,883 (0,013)	0,914 (0,008)	0,907 (0,015)	0,911 (0,016)	0,909 (0,008)
2	0,914 (0,007)	0,904 (0,013)	0,915 (0,014)	0,909 (0,007)	0,914 (0,008)	0,911 (0,015)	0,904 (0,018)	0,907 (0,008)	0,912 (0,006)	0,902 (0,015)	0,912 (0,018)	0,907 (0,007)
3	0,927 (0,006)	0,921 (0,012)	0,924 (0,018)	0,922 (0,007)	0,929 (0,006)	0,920 (0,015)	0,928 (0,016)	0,922 (0,005)	0,922 (0,006)	0,916 (0,016)	0,919 (0,013)	0,917 (0,006)
4	0,980 (0,005)	0,975 (0,011)	0,983 (0,005)	0,979 (0,006)	0,982 (0,004)	0,979 (0,008)	0,983 (0,010)	0,981 (0,005)	0,978 (0,004)	0,975 (0,010)	0,980 (0,007)	0,977 (0,004)
5	0,980 (0,005)	0,975 (0,012)	0,984 (0,005)	0,979 (0,005)	0,982 (0,004)	0,979 (0,007)	0,983 (0,010)	0,981 (0,004)	0,978 (0,004)	0,973 (0,011)	0,980 (0,006)	0,976 (0,005)
6	0,979 (0,005)	0,974 (0,009)	0,982 (0,01)	0,978 (0,005)	0,981 (0,004)	0,978 (0,008)	0,983 (0,009)	0,981 (0,004)	0,978 (0,005)	0,975 (0,008)	0,979 (0,011)	0,977 (0,005)
7	0,979 (0,004)	0,974 (0,009)	0,982 (0,008)	0,978 (0,005)	0,982 (0,005)	0,979 (0,008)	0,982 (0,010)	0,980 (0,005)	0,979 (0,004)	0,975 (0,007)	0,980 (0,011)	0,977 (0,005)

8	0,979 (0,005)	0,975 (0,009)	0,981 (0,008)	0,978 (0,005)	0,981 (0,004)	0,979 (0,008)	0,983 (0,010)	0,980 (0,005)	0,978 (0,005)	0,975 (0,008)	0,980 (0,011)	0,977 (0,006)
9	0,979 (0,005)	0,975 (0,009)	0,981 (0,008)	0,978 (0,005)	0,982 (0,004)	0,979 (0,008)	0,983 (0,010)	0,981 (0,005)	0,979 (0,005)	0,975 (0,009)	0,980 (0,012)	0,977 (0,006)
10	0,981 (0,005)	0,977 (0,009)	0,984 (0,008)	0,980 (0,005)	0,984 (0,005)	0,979 (0,008)	0,986 (0,012)	0,982 (0,005)	0,981 (0,004)	0,976 (0,010)	0,984 (0,009)	0,980 (0,004)
11	0,985 (0,004)	0,979 (0,008)	0,989 (0,007)	0,984 (0,005)	0,986 (0,005)	0,983 (0,007)	0,989 (0,010)	0,985 (0,005)	0,983 (0,004)	0,978 (0,008)	0,985 (0,009)	0,981 (0,005)
12	0,985 (0,004)	0,979 (0,007)	0,990 (0,008)	0,985 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,009)	0,985 (0,004)	0,983 (0,004)	0,977 (0,008)	0,986 (0,008)	0,982 (0,005)
13	0,985 (0,004)	0,979 (0,007)	0,990 (0,008)	0,984 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,009)	0,985 (0,004)	0,982 (0,004)	0,977 (0,008)	0,985 (0,009)	0,981 (0,005)
14	0,985 (0,004)	0,979 (0,007)	0,990 (0,007)	0,984 (0,004)	0,986 (0,004)	0,982 (0,007)	0,988 (0,009)	0,985 (0,004)	0,983 (0,004)	0,977 (0,008)	0,986 (0,008)	0,982 (0,004)
15	0,985 (0,004)	0,979 (0,007)	0,990 (0,007)	0,984 (0,004)	0,986 (0,004)	0,982 (0,007)	0,988 (0,009)	0,985 (0,005)	0,982 (0,004)	0,978 (0,008)	0,985 (0,008)	0,981 (0,004)
16	0,985 (0,004)	0,979 (0,007)	0,990 (0,006)	0,984 (0,004)	0,986 (0,004)	0,984 (0,007)	0,988 (0,008)	0,985 (0,004)	0,982 (0,003)	0,977 (0,008)	0,985 (0,007)	0,981 (0,004)

17	0,985 (0,003)	0,979 (0,006)	0,990 (0,007)	0,984 (0,003)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,982 (0,003)	0,977 (0,008)	0,985 (0,007)	0,981 (0,004)
18	0,985 (0,004)	0,979 (0,006)	0,990 (0,007)	0,984 (0,004)	0,986 (0,003)	0,983 (0,007)	0,988 (0,009)	0,985 (0,004)	0,982 (0,004)	0,977 (0,008)	0,985 (0,008)	0,981 (0,004)
19	0,986 (0,004)	0,980 (0,006)	0,990 (0,007)	0,985 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,986 (0,004)	0,981 (0,004)	0,976 (0,008)	0,985 (0,009)	0,980 (0,004)
20	0,986 (0,004)	0,98 (0,006)	0,99 (0,007)	0,985 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,981 (0,004)	0,976 (0,008)	0,985 (0,009)	0,980 (0,004)
21	0,985 (0,004)	0,978 (0,006)	0,990 (0,007)	0,984 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,981 (0,004)	0,976 (0,009)	0,985 (0,009)	0,980 (0,004)
22	0,985 (0,004)	0,978 (0,007)	0,990 (0,007)	0,984 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,981 (0,004)	0,976 (0,009)	0,984 (0,008)	0,980 (0,004)
23	0,985 (0,004)	0,978 (0,007)	0,990 (0,007)	0,984 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,981 (0,004)	0,976 (0,009)	0,984 (0,008)	0,980 (0,004)
24	0,984 (0,004)	0,977 (0,007)	0,99 (0,007)	0,984 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,007)	0,985 (0,004)	0,98 (0,004)	0,975 (0,009)	0,984 (0,007)	0,979 (0,004)
25	0,984 (0,004)	0,978 (0,007)	0,990 (0,007)	0,983 (0,004)	0,986 (0,004)	0,983 (0,007)	0,988 (0,008)	0,985 (0,004)	0,981 (0,004)	0,975 (0,009)	0,984 (0,008)	0,980 (0,005)

26	0,985 (0,004)	0,979 (0,008)	0,989 (0,007)	0,984 (0,004)	0,987 (0,003)	0,984 (0,007)	0,988 (0,007)	0,986 (0,003)	0,982 (0,004)	0,977 (0,009)	0,985 (0,008)	0,981 (0,004)
27	0,984 (0,004)	0,978 (0,007)	0,989 (0,007)	0,984 (0,004)	0,987 (0,003)	0,984 (0,007)	0,988 (0,007)	0,986 (0,003)	0,982 (0,003)	0,977 (0,009)	0,985 (0,008)	0,981 (0,004)
28	0,984 (0,005)	0,979 (0,008)	0,989 (0,009)	0,984 (0,005)	0,986 (0,003)	0,983 (0,006)	0,988 (0,008)	0,985 (0,003)	0,981 (0,003)	0,976 (0,008)	0,984 (0,008)	0,980 (0,004)
29	0,984 (0,004)	0,979 (0,007)	0,989 (0,009)	0,984 (0,005)	0,986 (0,003)	0,983 (0,006)	0,988 (0,008)	0,986 (0,003)	0,981 (0,004)	0,976 (0,008)	0,984 (0,009)	0,980 (0,004)
30	0,984 (0,004)	0,979 (0,007)	0,989 (0,009)	0,984 (0,005)	0,986 (0,003)	0,983 (0,006)	0,988 (0,008)	0,985 (0,003)	0,981 (0,004)	0,976 (0,008)	0,984 (0,009)	0,980 (0,004)
31	0,984 (0,005)	0,978 (0,007)	0,989 (0,008)	0,984 (0,005)	0,986 (0,003)	0,983 (0,007)	0,987 (0,007)	0,985 (0,003)	0,982 (0,004)	0,977 (0,009)	0,984 (0,009)	0,980 (0,004)
32	0,984 (0,005)	0,978 (0,008)	0,989 (0,008)	0,984 (0,005)	0,986 (0,003)	0,983 (0,007)	0,987 (0,007)	0,985 (0,003)	0,981 (0,004)	0,976 (0,008)	0,984 (0,009)	0,980 (0,004)
33	0,985 (0,005)	0,978 (0,008)	0,990 (0,009)	0,984 (0,005)	0,986 (0,003)	0,983 (0,007)	0,987 (0,007)	0,985 (0,003)	0,981 (0,004)	0,976 (0,008)	0,984 (0,009)	0,980 (0,004)
34	0,985 (0,005)	0,978 (0,009)	0,990 (0,009)	0,984 (0,005)	0,986 (0,003)	0,983 (0,007)	0,987 (0,007)	0,985 (0,003)	0,981 (0,004)	0,976 (0,008)	0,984 (0,009)	0,980 (0,004)

35	0,986 (0,004)	0,980 (0,005)	0,991 (0,006)	0,985 (0,004)	0,987 (0,004)	0,983 (0,007)	0,989 (0,006)	0,986 (0,004)	0,982 (0,003)	0,977 (0,009)	0,986 (0,008)	0,981 (0,004)
36	0,986 (0,004)	0,980 (0,006)	0,991 (0,006)	0,985 (0,004)	0,987 (0,003)	0,984 (0,008)	0,988 (0,006)	0,986 (0,003)	0,982 (0,003)	0,977 (0,009)	0,986 (0,007)	0,981 (0,003)
37	0,986 (0,003)	0,978 (0,006)	0,992 (0,005)	0,985 (0,004)	0,987 (0,003)	0,984 (0,007)	0,989 (0,006)	0,986 (0,004)	0,983 (0,003)	0,978 (0,009)	0,986 (0,007)	0,982 (0,003)
38	0,985 (0,004)	0,979 (0,006)	0,991 (0,007)	0,984 (0,005)	0,987 (0,003)	0,984 (0,007)	0,989 (0,006)	0,986 (0,004)	0,982 (0,003)	0,976 (0,009)	0,986 (0,007)	0,981 (0,004)
39	0,986 (0,005)	0,980 (0,006)	0,990 (0,006)	0,985 (0,005)	0,987 (0,003)	0,983 (0,007)	0,988 (0,006)	0,986 (0,003)	0,982 (0,003)	0,976 (0,009)	0,986 (0,007)	0,981 (0,004)
40	0,986 (0,004)	0,980 (0,006)	0,990 (0,004)	0,985 (0,004)	0,987 (0,003)	0,983 (0,007)	0,988 (0,006)	0,986 (0,003)	0,983 (0,003)	0,977 (0,010)	0,987 (0,008)	0,982 (0,003)

Fonte: A autora (2023). Os resultados correspondem a média dos 10 folds e o valor entre parêntesis ao desvio-padrão da amostra. Os maiores resultados obtidos estão em destacados em negrito.

Tabela 24 – Lista com os grupos obtidos para cada valor de k para o conjunto Kaggle.

k	Grupo
1	W2V-SVM
2	W2V-SVM, FAST-NB
3	W2V-SVM, FAST-MLP, FAST-NB
4	W2V-SVM, FAST-MLP, TF-IDF-MLP, FAST-NB
5	W2V-SVM, FAST-MLP, TF-IDF-MLP, FAST-NB, W2V-RF
6	W2V-SVM, FAST-MLP, CV-MLP, TF-IDF-MLP, FAST-NB, W2V-RF
7	W2V-SVM, FAST-KNN, CV-MLP, TF-IDF-MLP, FAST-NB, FAST-MLP, W2V-RF
8	W2V-SVM, GLOVE-CNN, CV-MLP, TF-IDF-MLP, FAST-NB, FAST-MLP, W2V-RF, FAST-KNN
9	W2V-SVM, GLOVE-CNN, CV-MLP, TF-IDF-MLP, GLOVE-KNN, FAST-MLP, W2V-RF, FAST-NB, FAST-KNN
10	TF-IDF-SVM, GLOVE-CNN, CV-MLP, TF-IDF-MLP, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, FAST-KNN
11	TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, GLOVE-CNN, FAST-KNN
12	TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, GLOVE-CNN, FAST-KNN
13	TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, GLOVE-CNN, FAST-KNN, GLOVE-MLP
14	TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, CV-KNN, GLOVE-CNN, FAST-KNN, GLOVE-MLP
15	TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, GLOVE-KNN, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, CV-KNN, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR

- 16 TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, CV-KNN, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, GLOVE-KNN
- 17 TF-IDF-SVM, FAST-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, CV-KNN, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, GLOVE-KNN
- 18 TF-IDF-SVM, FAST-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN
- 19 TF-IDF-SVM, W2V-KNN, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN
- 20 TF-IDF-SVM, W2V-KNN, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-RF, FAST-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN
- 21 TF-IDF-SVM, W2V-KNN, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-RF, FAST-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-SVM, GLOVE-KNN
- 22 TF-IDF-SVM, W2V-KNN, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-RF, FAST-NB, W2V-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM
- 23 TF-IDF-SVM, W2V-KNN, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-EXTRA, FAST-RF, W2V-NB, W2V-EXTRA, GLOVE-CNN, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB

- 24 TF-IDF-SVM, W2V-KNN, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-RF, FAST-RF, FAST-EXTRA, W2V-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB
- 25 TF-IDF-SVM, W2V-KNN, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, TF-IDF-KNN, W2V-RF, FAST-EXTRA, FAST-RF, W2V-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB
- 26 W2V-KNN, TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, W2V-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB
- 27 W2V-KNN, TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, W2V-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB
- 28 W2V-KNN, TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-SVM, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, W2V-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB
- 29 W2V-KNN, TF-IDF-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-SVM, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB

-
- 30 TF-IDF-CNN, TF-IDF-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-SVM, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-EXTRA, FAST-RF, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB
- 31 TF-IDF-SVM, TF-IDF-CNN, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-SVM, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB
- 32 TF-IDF-SVM, TF-IDF-CNN, CV-MLP, FAST-CNN, TF-IDF-MLP, FAST-SVM, CV-SVM, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB
- 33 TF-IDF-CNN, TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, FAST-SVM, CV-SVM, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB, GLOVE-NB
- 34 TF-IDF-CNN, TF-IDF-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, W2V-LR, CV-SVM, FAST-SVM, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB, GLOVE-NB

- 35 TF-IDF-SVM, TF-IDF-CNN, FAST-CNN, CV-MLP, TF-IDF-MLP, W2V-LR, CV-CNN, CV-SVM, FAST-SVM, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB, GLOVE-NB
- 36 TF-IDF-CNN, TF-IDF-SVM, FAST-CNN, CV-MLP, TF-IDF-MLP, W2V-LR, CV-CNN, CV-SVM, CV-RF, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-SVM, FAST-LR, CV-KNN, GLOVE-KNN, GLOVE-SVM, FAST-NB, W2V-NB, GLOVE-NB
- 37 TF-IDF-CNN, TF-IDF-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, W2V-LR, CV-CNN, CV-SVM, CV-RF, TF-IDF-LR, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-EXTRA, FAST-RF, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-SVM, FAST-LR, CV-KNN, GLOVE-SVM, GLOVE-KNN, FAST-NB, W2V-NB, GLOVE-NB
- 38 TF-IDF-CNN, TF-IDF-SVM, CV-MLP, FAST-CNN, TF-IDF-MLP, W2V-LR, CV-CNN, CV-SVM, CV-RF, TF-IDF-LR, TF-IDF-RF, CV-EXTRA, TF-IDF-EXTRA, W2V-MLP, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-SVM, FAST-LR, CV-KNN, GLOVE-SVM, GLOVE-KNN, FAST-NB, W2V-NB, GLOVE-NB
- 39 TF-IDF-SVM, TF-IDF-CNN, CV-MLP, FAST-CNN, TF-IDF-MLP, W2V-LR, CV-CNN, CV-SVM, CV-RF, TF-IDF-LR, CV-EXTRA, TF-IDF-RF, TF-IDF-EXTRA, W2V-MLP, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-RF, FAST-EXTRA, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-SVM, FAST-LR, CV-KNN, GLOVE-SVM, GLOVE-KNN, FAST-NB, W2V-NB, GLOVE-LR, GLOVE-NB

40 TF-IDF-SVM, TF-IDF-CNN, CV-MLP, FAST-CNN, TF-IDF-MLP, CV-LR, CV-CNN, CV-SVM, CV-RF, TF-IDF-LR, CV-EXTRA, TF-IDF-RF, TF-IDF-EXTRA, W2V-MLP, CV-NB, FAST-MLP, W2V-SVM, W2V-CNN, W2V-RF, TF-IDF-KNN, FAST-EXTRA, FAST-RF, TF-IDF-NB, W2V-EXTRA, GLOVE-CNN, W2V-LR, GLOVE-EXTRA, W2V-KNN, GLOVE-RF, FAST-KNN, GLOVE-MLP, FAST-SVM, FAST-LR, CV-KNN, GLOVE-SVM, GLOVE-KNN, FAST-NB, W2V-NB, GLOVE-LR, GLOVE-NB

Fonte: A autora (2023). Para cada *fold* e métrica altera a ordem, mas os grupos são os mesmos.

Tabela 25 – Resultados dos classificadores para o conjunto Kaggle.

Classificador	acc	pre	rec	f1
CV-SVM	0,959(0,007)	0,96(0,009)	0,954(0,015)	0,957(0,007)
TF-IDF-SVM	0,981(0,005)	0,974(0,011)	0,986(0,007)	0,98(0,006)
W2V-SVM	0,914(0,008)	0,895(0,017)	0,927(0,015)	0,911(0,008)
GLOVE-SVM	0,835(0,011)	0,813(0,017)	0,842(0,023)	0,827(0,012)
FAST-SVM	0,86(0,008)	0,822(0,014)	0,896(0,014)	0,857(0,007)
CV-LR	0,968(0,004)	0,973(0,008)	0,959(0,008)	0,966(0,004)
TF-IDF-LR	0,945(0,01)	0,946(0,014)	0,937(0,016)	0,941(0,011)
GLOVE-LR	0,751(0,009)	0,745(0,013)	0,714(0,025)	0,729(0,012)
W2V-LR	0,882(0,009)	0,866(0,019)	0,886(0,013)	0,876(0,008)
FAST-LR	0,844(0,009)	0,83(0,018)	0,84(0,017)	0,835(0,009)
CV-RF	0,955(0,006)	0,927(0,010)	0,981(0,010)	0,953(0,006)
TF-IDF-RF	0,964(0,008)	0,935(0,016)	0,992(0,005)	0,962(0,009)
GLOVE-RF	0,865(0,012)	0,851(0,018)	0,865(0,014)	0,858(0,012)
W2V-RF	0,891(0,010)	0,869(0,021)	0,905(0,019)	0,886(0,010)
FAST-RF	0,895(0,010)	0,878(0,017)	0,901(0,017)	0,889(0,010)

CV-NB	0,945(0,007)	0,922(0,016)	0,964(0,009)	0,943(0,007)
TF-IDF-NB	0,923(0,010)	0,881(0,017)	0,967(0,010)	0,922(0,009)
GLOVE-NB	0,677(0,016)	0,634(0,016)	0,738(0,021)	0,682(0,015)
W2V-NB	0,781(0,014)	0,72(0,017)	0,873(0,019)	0,789(0,013)
FAST-NB	0,776(0,017)	0,705(0,021)	0,899(0,017)	0,79(0,014)
CV-MLP	0,976(0,005)	0,975(0,007)	0,975(0,011)	0,975(0,005)
TF-IDF-MLP	0,983(0,004)	0,979(0,008)	0,984(0,007)	0,982(0,005)
GLOVE-MLP	0,842(0,013)	0,826(0,018)	0,841(0,019)	0,833(0,013)
W2V-MLP	0,928(0,007)	0,933(0,019)	0,912(0,029)	0,922(0,009)
FAST-MLP	0,918(0,011)	0,92(0,028)	0,906(0,04)	0,912(0,013)
CV-EXTRA	0,954(0,005)	0,916(0,012)	0,993(0,005)	0,953(0,005)
TF-IDF-EXTRA	0,960(0,006)	0,925(0,012)	0,994 (0,005)	0,958(0,005)
GLOVE-EXTRA	0,867(0,009)	0,838(0,014)	0,887(0,016)	0,862(0,010)
W2V-EXTRA	0,897(0,010)	0,862(0,017)	0,929(0,016)	0,894(0,010)
FAST-EXTRA	0,897(0,008)	0,868(0,015)	0,919(0,009)	0,893(0,008)
CV-KNN	0,826(0,013)	0,895(0,019)	0,712(0,017)	0,793(0,015)
TF-IDF-KNN	0,905(0,009)	0,884(0,015)	0,918(0,016)	0,901(0,009)
GLOVE-KNN	0,836(0,013)	0,805(0,021)	0,859(0,023)	0,831(0,013)
W2V-KNN	0,868(0,017)	0,821(0,020)	0,921(0,021)	0,868(0,016)
FAST-KNN	0,872(0,015)	0,830(0,022)	0,915(0,014)	0,870(0,014)
CV-CNN	0,973(0,007)	0,968(0,018)	0,977(0,015)	0,972(0,008)
TF-IDF-CNN	0,968(0,015)	0,969(0,022)	0,963(0,041)	0,965(0,018)
W2V-CNN	0,960(0,027)	0,959(0,018)	0,957(0,069)	0,956(0,033)
GLOVE-CNN	0,875(0,025)	0,873(0,063)	0,870(0,092)	0,866(0,034)
FAST-CNN	0,964(0,012)	0,964(0,019)	0,961(0,034)	0,962(0,014)
A-SVM-LR	0,980(0,005)	0,975(0,010)	0,981(0,009)	0,978(0,005)
A-LR-LR	0,969(0,004)	0,970(0,010)	0,963(0,009)	0,967(0,005)

A-RF-LR	0,966(0,006)	0,950(0,012)	0,980(0,011)	0,965(0,006)
A-NB-LR	0,944(0,007)	0,922(0,015)	0,963(0,011)	0,942(0,006)
A-MLP-LR	0,979(0,005)	0,974(0,009)	0,982(0,009)	0,978(0,005)
A-EXTRA-LR	0,968(0,004)	0,951(0,008)	0,983(0,007)	0,967(0,004)
A-KNN-LR	0,926(0,006)	0,914(0,015)	0,928(0,014)	0,921(0,007)
A-CNN-LR	0,982(0,005)	0,976(0,009)	0,986(0,007)	0,981(0,005)
A-SVM-RF	0,981(0,005)	0,977(0,008)	0,985(0,012)	0,981(0,005)
A-LR-RF	0,970(0,005)	0,970(0,013)	0,962(0,011)	0,968(0,006)
A-RF-RF	0,971(0,005)	0,969(0,012)	0,969(0,011)	0,970(0,005)
A-NB-RF	0,945(0,010)	0,936(0,020)	0,949(0,019)	0,942(0,009)
A-MLP-RF	0,982(0,005)	0,979(0,007)	0,982(0,011)	0,98(0,005)
A-EXTRA-RF	0,972(0,006)	0,967(0,010)	0,975(0,010)	0,971(0,006)
A-KNN-RF	0,920(0,011)	0,912(0,019)	0,917(0,017)	0,915(0,009)
A-CNN-RF	0,982(0,005)	0,978(0,008)	0,980(0,008)	0,980(0,006)
A-SVM-NB	0,979(0,005)	0,974(0,010)	0,981(0,008)	0,977(0,005)
A-LR-NB	0,969(0,005)	0,970(0,009)	0,963(0,009)	0,967(0,005)
A-RF-NB	0,962(0,006)	0,942(0,013)	0,979(0,009)	0,960(0,006)
A-NB-NB	0,940(0,007)	0,927(0,015)	0,947(0,019)	0,937(0,008)
A-MLP-NB	0,978(0,004)	0,974(0,008)	0,980(0,011)	0,977(0,005)
A-EXTRA-NB	0,962(0,005)	0,940(0,008)	0,983(0,007)	0,961(0,005)
A-KNN-NB	0,921(0,010)	0,9(0,023)	0,935(0,014)	0,917(0,009)
A-CNN-NB	0,981(0,006)	0,976(0,008)	0,984(0,008)	0,98(0,006)
B-CV-LR	0,983(0,003)	0,978(0,005)	0,986(0,008)	0,983(0,003)
B-TF-IDF-LR	0,984(0,003)	0,980(0,007)	0,987(0,007)	0,983(0,003)
B-W2V-LR	0,972(0,006)	0,966(0,009)	0,975(0,008)	0,970(0,006)
B-GLOVE-LR	0,922(0,012)	0,906(0,022)	0,932(0,022)	0,918(0,012)
B-FAST-LR	0,974(0,005)	0,967(0,011)	0,978(0,011)	0,972(0,005)

B-CV-RF	0,982(0,002)	0,982(0,007)	0,982(0,010)	0,982(0,004)
B-TF-IDF-RF	0,984(0,003)	0,980(0,008)	0,984(0,008)	0,982(0,003)
B-W2V-RF	0,972(0,004)	0,970(0,010)	0,971(0,008)	0,968(0,007)
B-GLOVE-RF	0,927(0,013)	0,921(0,021)	0,921(0,022)	0,922(0,012)
B-FAST-RF	0,972(0,003)	0,969(0,008)	0,970(0,013)	0,97(0,005)
B-CV-NB	0,980(0,004)	0,976(0,007)	0,982(0,010)	0,979(0,004)
B-TF-IDF-NB	0,983(0,003)	0,980(0,008)	0,985(0,007)	0,983(0,003)
B-W2V-NB	0,964(0,007)	0,960(0,015)	0,964(0,017)	0,962(0,007)
B-GLOVE-NB	0,891(0,008)	0,875(0,021)	0,898(0,022)	0,886(0,008)
B-FAST-NB	0,961(0,004)	0,955(0,012)	0,962(0,013)	0,959(0,004)
C-LR	0,986(0,004)	0,981(0,006)	0,991(0,004)	0,986(0,004)
C-RF	0,988 (0,002)	0,984(0,008)	0,987(0,006)	0,986(0,003)
C-NB	0,984(0,002)	0,978(0,009)	0,988(0,007)	0,983(0,002)
D-LR	0,986(0,004)	0,980(0,006)	0,992(0,005)	0,985(0,004)
D-RF	0,987(0,003)	0,984 (0,007)	0,989(0,010)	0,986 (0,004)
D-NB	0,983(0,004)	0,978(0,008)	0,987(0,008)	0,982(0,005)

Fonte: A autora (2023). Os maiores resultados obtidos estão em destacados em negrito. Para resultados iguais foi considerado o obtido utilizando menos elementos no grupo.

APÊNDICE H – RESULTADOS TESTES ESTATÍSTICOS

	acc	pre	rec	f1
CV-SVM	H1 (0.016)	H1 (0.029)	H0 (0.124)	H1 (0.023)
TFIDF-SVM	H0 (0.514)	H0 (0.770)	H0 (0.376)	H0 (0.690)
W2V-SVM	H0 (0.389)	H0 (0.833)	H0 (0.415)	H0 (0.425)
GLOVE-SVM	H1 (0.001)	H1 (0.002)	H1 (0.003)	H1 (0.000)
FAST-SVM	H0 (1.000)	H0 (1.000)	H0 (1.000)	H0 (1.000)
CV-LR	H0 (0.826)	H0 (0.674)	H0 (0.195)	H1 (0.016)
TFIDF-LR	H1 (0.000)	H1 (0.000)	H1 (0.002)	H1 (0.000)
GLOVE-LR	H0 (0.290)	H0 (0.284)	H0 (0.636)	H0 (0.408)
W2V-LR	H0 (1.000)	H0 (1.000)	H0 (1.000)	H0 (1.000)
FAST-LR	H0 (1.000)	H0 (1.000)	H0 (1.000)	H0 (1.000)
CV-RF	H0 (0.116)	H0 (0.070)	H0 (0.212)	H0 (0.941)
TFIDF-RF	H0 (0.211)	H0 (0.197)	H1 (0.014)	H0 (0.568)
GLOVE-RF	H0 (0.811)	H0 (0.753)	H0 (0.540)	H0 (0.425)
W2V-RF	H0 (0.683)	H0 (0.635)	H0 (0.324)	H0 (0.815)
FAST-RF	H0 (0.302)	H0 (0.208)	H0 (0.246)	H0 (0.545)
CV-NB	H1 (0.031)	H1 (0.019)	H0 (0.653)	H0 (0.669)
TFIDF-NB	H1 (0.000)	H1 (0.005)	H0 (0.630)	H0 (0.793)
GLOVE-NB	H0 (0.649)	H0 (0.271)	H0 (0.394)	H0 (0.783)
W2V-NB	H0 (0.164)	H0 (0.142)	H0 (0.639)	H0 (0.788)
FAST-NB	H0 (0.537)	H0 (0.685)	H0 (0.574)	H0 (0.752)
CV-MLP	H1 (0.025)	H0 (0.082)	H0 (0.598)	H0 (0.746)
TFIDF-MLP	H0 (0.569)	H0 (0.610)	H0 (0.858)	H0 (0.651)
GLOVE-MLP	H0 (0.909)	H0 (0.605)	H0 (0.294)	H0 (0.584)
W2V-MLP	H0 (0.959)	H0 (0.728)	H0 (0.531)	H0 (0.276)

FAST-MLP	H0 (0.715)	H0 (0.433)	H0 (0.437)	H0 (0.385)
CV-EXTRA	H0 (0.787)	H0 (0.982)	H0 (0.350)	H1 (0.004)
TFIDF-EXTRA	H0 (0.957)	H0 (0.881)	H0 (0.370)	H0 (0.801)
GLOVE-EXTRA	H0 (0.595)	H0 (0.712)	H0 (0.965)	H0 (0.305)
W2V-EXTRA	H0 (0.576)	H0 (0.481)	H0 (0.531)	H0 (0.388)
FAST-EXTRA	H0 (0.769)	H0 (0.658)	H0 (0.261)	H0 (0.644)
CV-KNN	H0 (0.379)	H0 (0.569)	H0 (0.449)	H0 (0.083)
TFIDF-KNN	H0 (0.599)	H0 (0.604)	H0 (0.541)	H0 (0.100)
GLOVE-KNN	H0 (0.234)	H0 (0.235)	H0 (0.768)	H0 (0.715)
W2V-KNN	H0 (0.449)	H0 (0.620)	H0 (0.678)	H0 (0.402)
FAST-KNN	H0 (0.833)	H0 (0.665)	H0 (0.289)	H0 (0.602)
CV-CNN	H1 (0.000)	H1 (0.006)	H1 (0.000)	H1 (0.000)
TFIDF-CNN	H1 (0.003)	H1 (0.015)	H1 (0.000)	H1 (0.000)
W2V-CNN	H0 (0.769)	H0 (0.256)	H0 (0.704)	H0 (0.131)
GLOVE-CNN	H0 (0.066)	H1 (0.000)	H1 (0.008)	H1 (0.001)
FAST-CNN	H0 (0.332)	H0 (0.361)	H0 (0.225)	H1 (0.021)
A-SVM-LR	H0 (0.212)	H0 (0.740)	H0 (0.743)	H0 (0.991)
A-LR-LR	H0 (0.255)	H0 (0.460)	H0 (0.166)	H0 (0.427)
A-RF-LR	H0 (0.188)	H0 (0.386)	H0 (0.573)	H0 (0.270)
A-NB-LR	H0 (0.545)	H0 (0.644)	H0 (0.661)	H0 (0.551)
A-MLP-LR	H0 (0.393)	H0 (0.352)	H0 (0.334)	H0 (0.776)
A-EXTRA-LR	H0 (0.094)	H0 (0.130)	H0 (0.563)	H0 (0.684)
A-KNN-LR	H0 (0.896)	H0 (0.897)	H0 (0.467)	H0 (0.544)
A-CNN-LR	H0 (0.947)	H0 (0.860)	H0 (0.134)	H0 (0.461)
A-SVM-RF	H0 (0.271)	H1 (0.026)	H0 (0.154)	H0 (0.444)
A-LR-RF	H0 (0.346)	H0 (0.307)	H0 (0.196)	H0 (0.739)
A-RF-RF	H0 (0.185)	H0 (0.169)	H0 (0.111)	H0 (0.076)

A-NB-RF	H0 (0.907)	H1 (0.007)	H0 (0.758)	H0 (0.381)
A-MLP-RF	H0 (0.813)	H0 (0.711)	H0 (0.301)	H0 (0.801)
A-EXTRA-RF	H0 (0.361)	H1 (0.026)	H0 (0.409)	H0 (0.126)
A-KNN-RF	H0 (0.123)	H0 (0.316)	H0 (0.206)	H0 (0.858)
A-CNN-RF	H0 (0.786)	H0 (0.210)	H0 (0.453)	H0 (0.848)
A-SVM-NB	H0 (0.601)	H0 (0.553)	H0 (0.843)	H0 (0.927)
A-LR-NB	H0 (0.726)	H0 (0.068)	H0 (0.311)	H0 (0.072)
A-RF-NB	H0 (0.659)	H0 (0.658)	H0 (0.654)	H1 (0.017)
A-NB-NB	H0 (0.061)	H1 (0.019)	H0 (0.350)	H0 (0.167)
A-MLP-NB	H0 (0.902)	H0 (0.635)	H0 (0.310)	H0 (0.643)
A-EXTRA-NB	H0 (0.066)	H0 (0.306)	H0 (0.193)	H0 (0.068)
A-KNN-NB	H0 (0.747)	H0 (0.592)	H0 (0.308)	H1 (0.041)
A-CNN-NB	H0 (0.134)	H0 (0.158)	H0 (0.706)	H0 (0.664)
B-CV-LR	H0 (0.629)	H0 (0.301)	H0 (0.783)	H0 (0.836)
B-TFIDF-LR	H0 (0.297)	H0 (0.302)	H0 (0.494)	H0 (0.568)
B-W2V-LR	H0 (0.208)	H0 (0.136)	H0 (0.265)	H0 (0.589)
B-GLOVE-LR	H0 (0.082)	H0 (0.119)	H0 (0.714)	H0 (0.404)
B-FAST-LR	H0 (0.149)	H0 (0.369)	H0 (0.494)	H0 (0.901)
B-CV-RF	H0 (0.307)	H0 (0.412)	H0 (0.936)	H0 (0.980)
B-TFIDF-RF	H0 (0.945)	H1 (0.012)	H0 (0.739)	H0 (0.474)
B-W2V-RF	H0 (0.567)	H0 (0.384)	H0 (0.575)	H0 (0.611)
B-GLOVE-RF	H0 (0.584)	H0 (0.532)	H0 (0.250)	H0 (0.806)
B-FAST-RF	H0 (0.954)	H0 (0.726)	H0 (0.455)	H0 (0.598)
B-CV-NB	H0 (0.130)	H0 (0.143)	H0 (0.774)	H0 (0.922)
B-TFIDF-NB	H0 (0.843)	H0 (0.972)	H0 (0.288)	H0 (0.803)
B-W2V-NB	H0 (0.087)	H1 (0.029)	H0 (0.541)	H0 (0.371)
B-GLOVE-NB	H1 (0.004)	H0 (0.087)	H0 (0.378)	H0 (0.516)

B-FAST-NB	H1 (0.044)	H0 (0.112)	H0 (0.933)	H0 (0.504)
C-LR	H0 (0.643)	H0 (0.568)	H0 (0.121)	H0 (0.810)
C-RF	H0 (0.400)	H0 (0.775)	H0 (0.105)	H0 (0.190)
C-NB	H0 (0.860)	H0 (0.545)	H0 (0.848)	H0 (0.773)
D-LR	H0 (0.789)	H0 (0.183)	H0 (0.523)	H0 (0.558)
D-RF	H0 (0.903)	H0 (0.510)	H0 (0.446)	H0 (0.632)
D-NB	H0 (0.566)	H0 (0.935)	H0 (0.749)	H0 (0.606)

Tabela 26 – Resultados do teste de aderência para o conjunto Fa-Kes. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.

	acc	pre	rec	f1
CV-SVM	H0 (0.767)	H0 (0.745)	H1 (0.011)	H0 (0.456)
TFIDF-SVM	H0 (0.628)	H0 (0.175)	H0 (0.083)	H0 (0.799)
W2V-SVM	H0 (0.342)	H1 (0.045)	H0 (0.264)	H0 (0.773)
GLOVE-SVM	H0 (0.420)	H0 (0.368)	H0 (0.790)	H0 (0.685)
FAST-SVM	H1 (0.014)	H0 (0.312)	H0 (0.282)	H1 (0.045)
CV-LR	H0 (0.838)	H0 (0.193)	H0 (0.437)	H0 (0.986)
TFIDF-LR	H0 (0.591)	H0 (0.783)	H0 (0.305)	H0 (0.634)
GLOVE-LR	H0 (0.988)	H0 (0.812)	H0 (0.488)	H0 (0.859)
W2V-LR	H0 (0.287)	H0 (0.091)	H0 (0.347)	H0 (0.935)
FAST-LR	H0 (0.436)	H0 (0.467)	H0 (0.806)	H0 (0.664)
CV-RF	H0 (0.408)	H1 (0.029)	H0 (0.489)	H0 (0.853)
TFIDF-RF	H0 (0.402)	H0 (0.189)	H0 (0.576)	H0 (0.839)
GLOVE-RF	H1 (0.004)	H1 (0.029)	H0 (0.769)	H0 (0.862)
W2V-RF	H0 (0.085)	H0 (0.152)	H0 (0.074)	H0 (0.277)

FAST-RF	H0 (0.849)	H0 (0.603)	H0 (0.472)	H0 (0.544)
CV-NB	H1 (0.037)	H0 (0.352)	H1 (0.031)	H0 (0.181)
TFIDF-NB	H0 (0.058)	H0 (0.342)	H0 (0.603)	H0 (0.119)
GLOVE-NB	H0 (0.523)	H0 (0.111)	H1 (0.047)	H0 (0.267)
W2V-NB	H0 (0.632)	H0 (0.714)	H0 (0.709)	H0 (0.380)
FAST-NB	H0 (0.117)	H0 (0.910)	H0 (0.189)	H1 (0.007)
CV-MLP	H0 (0.679)	H1 (0.010)	H0 (0.485)	H0 (0.887)
TFIDF-MLP	H0 (0.715)	H0 (0.888)	H0 (0.803)	H0 (0.814)
GLOVE-MLP	H0 (0.560)	H0 (0.055)	H0 (0.933)	H1 (0.042)
W2V-MLP	H0 (0.276)	H0 (0.222)	H0 (0.106)	H0 (0.277)
FAST-MLP	H0 (0.892)	H0 (0.853)	H0 (0.411)	H0 (0.956)
CV-EXTRA	H0 (0.468)	H1 (0.031)	H0 (0.864)	H0 (0.174)
TFIDF-EXTRA	H0 (0.095)	H0 (0.097)	H0 (0.772)	H0 (0.464)
GLOVE-EXTRA	H0 (0.580)	H0 (0.223)	H0 (0.580)	H0 (0.636)
W2V-EXTRA	H1 (0.006)	H0 (0.221)	H0 (0.302)	H1 (0.023)
FAST-EXTRA	H0 (0.084)	H0 (0.256)	H0 (0.231)	H0 (0.142)
CV-KNN	H0 (0.364)	H0 (0.570)	H0 (0.095)	H0 (0.226)
TFIDF-KNN	H0 (0.442)	H0 (0.625)	H0 (0.344)	H0 (0.146)
GLOVE-KNN	H0 (0.575)	H0 (0.328)	H0 (0.901)	H0 (0.163)
W2V-KNN	H1 (0.049)	H0 (0.333)	H0 (0.957)	H0 (0.344)
FAST-KNN	H0 (0.420)	H0 (0.906)	H0 (0.053)	H0 (0.333)
CV-CNN	H0 (0.063)	H0 (0.369)	H0 (0.147)	H0 (0.059)
TFIDF-CNN	H0 (0.221)	H0 (0.688)	H0 (0.502)	H1 (0.048)
W2V-CNN	H0 (0.793)	H0 (0.791)	H0 (0.097)	H0 (0.790)
GLOVE-CNN	H1 (0.024)	H1 (0.019)	H1 (0.047)	H1 (0.020)
FAST-CNN	H0 (0.854)	H0 (0.510)	H0 (0.177)	H0 (0.260)
A-SVM-LR	H0 (0.969)	H0 (0.360)	H1 (0.039)	H0 (0.980)

A-LR-LR	H0 (0.421)	H0 (0.999)	H0 (0.338)	H0 (0.571)
A-RF-LR	H0 (0.436)	H0 (0.537)	H0 (0.634)	H0 (0.627)
A-NB-LR	H0 (0.235)	H0 (0.789)	H0 (0.419)	H0 (0.336)
A-MLP-LR	H0 (0.089)	H0 (0.566)	H0 (0.251)	H0 (0.282)
A-EXTRA-LR	H0 (0.185)	H0 (0.740)	H0 (0.524)	H0 (0.224)
A-KNN-LR	H0 (0.223)	H0 (0.816)	H0 (0.445)	H0 (0.728)
A-CNN-LR	H0 (0.956)	H0 (0.315)	H1 (0.020)	H0 (0.867)
A-SVM-RF	H0 (0.948)	H0 (0.218)	H0 (0.587)	H0 (0.667)
A-LR-RF	H0 (0.817)	H1 (0.006)	H0 (0.730)	H0 (0.997)
A-RF-RF	H0 (0.472)	H1 (0.017)	H0 (0.767)	H0 (0.994)
A-NB-RF	H0 (0.937)	H0 (0.338)	H0 (0.815)	H0 (0.566)
A-MLP-RF	H0 (0.364)	H0 (0.719)	H1 (0.028)	H0 (0.260)
A-EXTRA-RF	H0 (0.524)	H0 (0.496)	H0 (0.146)	H0 (0.866)
A-KNN-RF	H0 (0.715)	H0 (0.706)	H0 (0.215)	H0 (0.810)
A-CNN-RF	H0 (0.639)	H0 (0.102)	H0 (0.606)	H0 (0.747)
A-SVM-NB	H0 (0.911)	H0 (0.352)	H0 (0.311)	H0 (0.603)
A-LR-NB	H0 (0.496)	H0 (0.955)	H0 (0.545)	H0 (0.500)
A-RF-NB	H0 (0.968)	H0 (0.374)	H0 (0.378)	H0 (0.860)
A-NB-NB	H0 (0.576)	H0 (0.102)	H0 (0.853)	H0 (0.431)
A-MLP-NB	H0 (0.438)	H0 (0.363)	H0 (0.071)	H0 (0.283)
A-EXTRA-NB	H0 (0.748)	H0 (0.213)	H0 (0.177)	H0 (0.790)
A-KNN-NB	H0 (0.914)	H0 (0.320)	H0 (0.743)	H0 (0.649)
A-CNN-NB	H0 (0.290)	H0 (0.195)	H1 (0.008)	H0 (0.990)
B-CV-LR	H0 (0.077)	H1 (0.031)	H1 (0.027)	H0 (0.068)
B-TFIDF-LR	H0 (0.466)	H0 (0.535)	H1 (0.003)	H0 (0.222)
B-W2V-LR	H0 (0.865)	H0 (0.330)	H1 (0.012)	H0 (0.746)
B-GLOVE-LR	H0 (0.083)	H0 (0.964)	H0 (0.462)	H0 (0.053)

B-FAST-LR	H0 (0.399)	H0 (0.235)	H0 (0.294)	H0 (0.978)
B-CV-RF	H0 (0.195)	H0 (0.966)	H0 (0.301)	H0 (0.075)
B-TFIDF-RF	H0 (0.615)	H0 (0.752)	H1 (0.016)	H0 (0.213)
B-W2V-RF	H0 (0.947)	H0 (0.172)	H0 (0.441)	H0 (0.714)
B-GLOVE-RF	H0 (0.143)	H0 (0.485)	H1 (0.047)	H0 (0.792)
B-FAST-RF	H0 (0.237)	H0 (0.143)	H1 (0.036)	H0 (0.926)
B-CV-NB	H0 (0.321)	H0 (0.968)	H0 (0.573)	H0 (0.491)
B-TFIDF-NB	H0 (0.926)	H0 (0.830)	H1 (0.022)	H0 (0.893)
B-W2V-NB	H0 (0.113)	H1 (0.036)	H1 (0.004)	H0 (0.464)
B-GLOVE-NB	H0 (0.496)	H0 (0.584)	H0 (0.327)	H0 (0.952)
B-FAST-NB	H0 (0.821)	H0 (0.423)	H0 (0.162)	H0 (0.868)
C-LR	H0 (0.541)	H0 (0.519)	H0 (0.152)	H0 (0.377)
C-RF	H0 (0.295)	H0 (0.115)	H0 (0.868)	H0 (0.527)
C-NB	H0 (0.522)	H0 (0.685)	H0 (0.166)	H0 (0.617)
D-LR	H0 (0.149)	H0 (0.345)	H0 (0.072)	H0 (0.133)
D-RF	H0 (0.237)	H0 (0.122)	H0 (0.064)	H0 (0.289)
D-NB	H0 (0.592)	H0 (0.881)	H1 (0.046)	H0 (0.875)

Tabela 27 – Resultados do teste de aderência para o conjunto Ott. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.

	acc	pre	rec	f1
CV-SVM	H0 (0.648)	H0 (0.798)	H0 (0.095)	H0 (0.674)
TFIDF-SVM	H0 (0.173)	H0 (0.338)	H0 (0.271)	H0 (0.280)
W2V-SVM	H0 (0.929)	H0 (0.345)	H0 (0.343)	H0 (0.802)
GLOVE-SVM	H1 (0.043)	H0 (0.358)	H0 (0.372)	H0 (0.214)

FAST-SVM	H0 (0.448)	H0 (0.235)	H0 (0.873)	H0 (0.161)
CV-LR	H0 (0.825)	H0 (0.063)	H0 (0.297)	H0 (0.587)
TFIDF-LR	H0 (0.137)	H0 (0.455)	H0 (0.891)	H0 (0.237)
GLOVE-LR	H0 (0.912)	H0 (0.459)	H1 (0.039)	H0 (0.264)
W2V-LR	H0 (0.488)	H0 (0.504)	H0 (0.255)	H0 (0.400)
FAST-LR	H0 (0.050)	H0 (0.071)	H0 (0.053)	H1 (0.036)
CV-RF	H0 (0.634)	H0 (0.788)	H0 (0.517)	H0 (0.588)
TFIDF-RF	H0 (0.661)	H0 (0.241)	H1 (0.011)	H0 (0.731)
GLOVE-RF	H0 (0.114)	H0 (0.251)	H0 (0.854)	H0 (0.512)
W2V-RF	H1 (0.027)	H0 (0.514)	H0 (0.648)	H0 (0.265)
FAST-RF	H0 (0.586)	H0 (0.986)	H0 (0.171)	H0 (0.879)
CV-NB	H0 (0.838)	H0 (0.550)	H0 (0.320)	H0 (0.594)
TFIDF-NB	H0 (0.728)	H0 (0.869)	H1 (0.042)	H0 (0.924)
GLOVE-NB	H1 (0.026)	H0 (0.303)	H0 (0.428)	H1 (0.022)
W2V-NB	H0 (0.363)	H0 (0.166)	H0 (0.299)	H0 (0.640)
FAST-NB	H0 (0.578)	H0 (0.732)	H0 (0.966)	H0 (0.488)
CV-MLP	H0 (0.084)	H0 (0.737)	H0 (0.484)	H0 (0.135)
TFIDF-MLP	H0 (0.271)	H0 (0.411)	H0 (0.412)	H0 (0.135)
GLOVE-MLP	H0 (0.944)	H0 (0.497)	H1 (0.024)	H0 (0.974)
W2V-MLP	H0 (0.154)	H0 (0.995)	H0 (0.264)	H0 (0.186)
FAST-MLP	H0 (0.604)	H0 (0.134)	H0 (0.443)	H0 (0.967)
CV-EXTRA	H0 (0.844)	H0 (0.934)	H0 (0.102)	H0 (0.766)
TFIDF-EXTRA	H0 (0.845)	H0 (0.642)	H0 (0.142)	H0 (0.904)
GLOVE-EXTRA	H0 (0.896)	H0 (0.438)	H0 (0.446)	H0 (0.787)
W2V-EXTRA	H0 (0.261)	H0 (0.874)	H0 (0.768)	H0 (0.382)
FAST-EXTRA	H0 (0.297)	H0 (0.962)	H0 (0.637)	H0 (0.371)
CV-KNN	H0 (0.375)	H0 (0.760)	H0 (0.094)	H0 (0.312)

TFIDF-KNN	H0 (0.733)	H0 (0.841)	H0 (0.365)	H0 (0.577)
GLOVE-KNN	H0 (0.964)	H0 (0.987)	H0 (0.952)	H0 (0.982)
W2V-KNN	H0 (0.987)	H0 (0.164)	H0 (0.258)	H0 (0.994)
FAST-KNN	H0 (0.120)	H0 (0.673)	H0 (0.163)	H1 (0.040)
CV-CNN	H0 (0.188)	H1 (0.046)	H0 (0.570)	H0 (0.251)
TFIDF-CNN	H1 (0.048)	H0 (0.231)	H1 (0.003)	H1 (0.019)
W2V-CNN	H1 (0.000)	H0 (0.825)	H1 (0.000)	H1 (0.000)
GLOVE-CNN	H1 (0.034)	H0 (0.891)	H0 (0.135)	H1 (0.001)
FAST-CNN	H0 (0.486)	H0 (0.317)	H1 (0.043)	H0 (0.361)
A-SVM-LR	H0 (0.290)	H0 (0.202)	H0 (0.736)	H0 (0.413)
A-LR-LR	H0 (0.058)	H0 (0.149)	H0 (0.071)	H0 (0.208)
A-RF-LR	H0 (0.524)	H0 (0.731)	H0 (0.322)	H0 (0.862)
A-NB-LR	H0 (0.418)	H0 (0.634)	H0 (0.172)	H0 (0.264)
A-MLP-LR	H0 (0.193)	H0 (0.183)	H0 (0.051)	H0 (0.168)
A-EXTRA-LR	H0 (0.924)	H0 (0.890)	H1 (0.017)	H0 (0.965)
A-KNN-LR	H1 (0.044)	H0 (0.224)	H0 (0.410)	H0 (0.179)
A-CNN-LR	H0 (0.927)	H0 (0.563)	H0 (0.713)	H0 (0.919)
A-SVM-RF	H0 (0.057)	H0 (0.518)	H0 (0.142)	H0 (0.117)
A-LR-RF	H0 (0.634)	H0 (0.086)	H0 (0.386)	H0 (0.136)
A-RF-RF	H0 (0.244)	H0 (0.573)	H0 (0.265)	H0 (0.673)
A-NB-RF	H0 (0.526)	H0 (0.815)	H0 (0.336)	H0 (0.619)
A-MLP-RF	H0 (0.636)	H0 (0.789)	H0 (0.073)	H0 (0.932)
A-EXTRA-RF	H0 (0.409)	H0 (0.406)	H0 (0.241)	H0 (0.861)
A-KNN-RF	H0 (0.552)	H0 (0.506)	H0 (0.412)	H0 (0.698)
A-CNN-RF	H0 (0.707)	H0 (0.797)	H0 (0.318)	H0 (0.986)
A-SVM-NB	H0 (0.127)	H1 (0.048)	H0 (0.606)	H0 (0.124)
A-LR-NB	H1 (0.007)	H1 (0.026)	H1 (0.026)	H1 (0.017)

A-RF-NB	H0 (0.347)	H0 (0.380)	H0 (0.192)	H0 (0.234)
A-NB-NB	H0 (0.408)	H0 (0.511)	H0 (0.393)	H0 (0.592)
A-MLP-NB	H0 (0.595)	H0 (0.797)	H1 (0.023)	H0 (0.436)
A-EXTRA-NB	H0 (0.434)	H0 (0.140)	H0 (0.293)	H0 (0.251)
A-KNN-NB	H0 (0.070)	H0 (0.457)	H0 (0.529)	H0 (0.188)
A-CNN-NB	H0 (0.766)	H0 (0.339)	H0 (0.924)	H0 (0.730)
B-CV-LR	H0 (0.219)	H0 (0.583)	H0 (0.593)	H0 (0.404)
B-TFIDF-LR	H0 (0.634)	H0 (0.577)	H0 (0.120)	H0 (0.643)
B-W2V-LR	H0 (0.938)	H0 (0.054)	H0 (0.292)	H0 (0.943)
B-GLOVE-LR	H0 (0.219)	H0 (0.883)	H0 (0.197)	H0 (0.538)
B-FAST-LR	H0 (0.653)	H0 (0.893)	H0 (0.984)	H0 (0.670)
B-CV-RF	H0 (0.629)	H0 (0.162)	H0 (0.278)	H0 (0.450)
B-TFIDF-RF	H0 (0.173)	H0 (0.298)	H0 (0.104)	H0 (0.220)
B-W2V-RF	H0 (0.085)	H0 (0.412)	H0 (0.599)	H0 (0.833)
B-GLOVE-RF	H0 (0.232)	H0 (0.965)	H0 (0.893)	H0 (0.211)
B-FAST-RF	H0 (0.088)	H0 (0.245)	H1 (0.016)	H1 (0.005)
B-CV-NB	H0 (0.265)	H0 (0.846)	H0 (0.345)	H0 (0.537)
B-TFIDF-NB	H1 (0.019)	H0 (0.320)	H0 (0.700)	H1 (0.039)
B-W2V-NB	H0 (0.513)	H0 (0.539)	H0 (0.087)	H0 (0.603)
B-GLOVE-NB	H0 (0.227)	H0 (0.660)	H0 (0.915)	H0 (0.878)
B-FAST-NB	H0 (0.327)	H0 (0.992)	H0 (0.071)	H0 (0.303)
C-LR	H0 (0.058)	H0 (0.156)	H0 (0.261)	H0 (0.064)
C-RF	H0 (0.453)	H0 (0.210)	H1 (0.016)	H0 (0.345)
C-NB	H0 (0.367)	H0 (0.828)	H0 (0.164)	H0 (0.767)
D-LR	H1 (0.001)	H0 (0.362)	H0 (0.490)	H1 (0.008)
D-RF	H0 (0.495)	H0 (0.157)	H0 (0.063)	H0 (0.874)
D-NB	H0 (0.217)	H0 (0.297)	H0 (0.291)	H0 (0.217)

Tabela 28 – Resultados do teste de aderência para o conjunto Kaggle. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.

Métrica	acc			pre		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)
SVM-TFIDF	H0 (0.26)	H0 (0.625)	H0 (0.432)	H0 (0.173)	H0 (0.322)	H0 (0.375)
SVM-W2V	H0 (0.084)	H0 (0.139)	H0 (0.232)	H1 (0.002)	H1 (0.002)	H1 (0.006)
SVM-GLOVE	H1 (0.049)	H0 (0.105)	H0 (0.086)	H1 (0.004)	H1 (0.002)	H1 (0.006)
SVM-FAST	H0 (0.064)	H0 (0.131)	H0 (0.192)	H1 (0.004)	H1 (0.002)	H1 (0.01)
LR-CV	H1 (0.002)	H1 (0.01)	H1 (0.012)	H1 (0.002)	H1 (0.01)	H1 (0.002)
LR-TFIDF	H1 (0.049)	H0 (0.084)	H0 (0.084)	H1 (0.004)	H1 (0.004)	H1 (0.006)
LR-GLOVE	H1 (0.004)	H1 (0.006)	H1 (0.014)	H1 (0.002)	H1 (0.002)	H1 (0.004)
LR-W2V	H0 (0.064)	H0 (0.131)	H0 (0.192)	H1 (0.004)	H1 (0.002)	H1 (0.01)
LR-FAST	H0 (0.064)	H0 (0.131)	H0 (0.192)	H1 (0.004)	H1 (0.002)	H1 (0.01)
RF-CV	H1 (0.027)	H1 (0.02)	H1 (0.028)	H1 (0.027)	H1 (0.02)	H1 (0.027)
RF-TFIDF	H0 (0.594)	H0 (0.846)	H0 (0.514)	H0 (0.514)	H0 (0.492)	H0 (0.322)
RF-GLOVE	H1 (0.006)	H1 (0.004)	H1 (0.014)	H1 (0.006)	H1 (0.004)	H1 (0.01)
RF-W2V	H1 (0.037)	H0 (0.064)	H0 (0.086)	H1 (0.037)	H1 (0.049)	H0 (0.064)
RF-FAST	H0 (0.084)	H0 (0.084)	H0 (0.232)	H0 (0.084)	H0 (0.084)	H0 (0.131)
NB-CV	H0 (0.275)	H0 (0.374)	H0 (0.441)	H0 (0.275)	H0 (0.314)	H0 (0.441)
NB-TFIDF	H0 (0.193)	H0 (0.492)	H0 (0.322)	H0 (0.105)	H0 (0.232)	H0 (0.232)
NB-GLOVE	H1 (0.011)	H1 (0.002)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H1 (0.004)
NB-W2V	H1 (0.006)	H1 (0.014)	H1 (0.02)	H1 (0.006)	H1 (0.011)	H1 (0.02)
NB-FAST	H0 (0.086)	H0 (0.232)	H0 (0.275)	H0 (0.064)	H0 (0.193)	H0 (0.131)

MLP-CV	H0 (0.109)	H0 (0.441)	H0 (0.322)	H0 (0.105)	H0 (0.375)	H0 (0.322)
MLP-TFIDF	H0 (0.123)	H0 (0.232)	H0 (0.275)	H0 (0.11)	H0 (0.139)	H0 (0.232)
MLP-GLOVE	H1 (0.01)	H1 (0.02)	H1 (0.027)	H1 (0.004)	H1 (0.002)	H1 (0.01)
MLP-W2V	H1 (0.049)	H1 (0.049)	H0 (0.084)	H1 (0.027)	H1 (0.01)	H0 (0.084)
MLP-FAST	H1 (0.014)	H1 (0.037)	H1 (0.037)	H1 (0.004)	H1 (0.002)	H1 (0.02)
EXTRA-CV	H0 (0.11)	H0 (0.375)	H0 (0.322)	H0 (0.064)	H0 (0.232)	H0 (0.232)
EXTRA-TFIDF	H0 (0.086)	H0 (0.131)	H0 (0.232)	H0 (0.064)	H0 (0.11)	H0 (0.214)
EXTRA-GLOVE	H1 (0.004)	H1 (0.002)	H1 (0.006)	H1 (0.004)	H1 (0.002)	H1 (0.006)
EXTRA-W2V	H1 (0.02)	H1 (0.01)	H1 (0.049)	H1 (0.02)	H1 (0.006)	H1 (0.027)
EXTRA-FAST	H1 (0.018)	H1 (0.027)	H0 (0.064)	H1 (0.01)	H1 (0.027)	H0 (0.064)
KNN-CV	H1 (0.02)	H0 (0.064)	H1 (0.036)	H1 (0.014)	H1 (0.049)	H1 (0.028)
KNN-TFIDF	H0 (0.193)	H0 (0.557)	H0 (0.275)	H0 (0.16)	H0 (0.375)	H0 (0.232)
KNN-GLOVE	H1 (0.017)	H1 (0.01)	H1 (0.014)	H1 (0.01)	H1 (0.006)	H1 (0.014)
KNN-W2V	H0 (0.105)	H0 (0.16)	H0 (0.155)	H1 (0.049)	H0 (0.105)	H0 (0.084)
KNN-FAST	H0 (0.275)	H0 (0.695)	H0 (0.343)	H0 (0.232)	H0 (0.432)	H0 (0.193)
CNN-CV	H1 (0.037)	H0 (0.105)	H0 (0.105)	H1 (0.01)	H1 (0.002)	H1 (0.014)
CNN-TFIDF	H0 (0.131)	H0 (0.084)	H0 (0.172)	H1 (0.006)	H1 (0.002)	H1 (0.02)
CNN-W2V	H1 (0.008)	H1 (0.02)	H1 (0.004)	H1 (0.002)	H1 (0.037)	H1 (0.002)
CNN-GLOVE	H1 (0.004)	H1 (0.027)	H1 (0.027)	H1 (0.004)	H1 (0.002)	H1 (0.037)
CNN-FAST	H0 (0.066)	H0 (0.322)	H0 (0.11)	H1 (0.027)	H0 (0.105)	H1 (0.027)
A-SVM-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-LR-LR	H1 (0.002)	H1 (0.01)	H1 (0.008)	H1 (0.002)	H1 (0.01)	H1 (0.004)
A-RF-LR	H0 (0.058)	H0 (0.084)	H1 (0.038)	H1 (0.049)	H0 (0.084)	H1 (0.02)
A-NB-LR	H1 (0.002)	H1 (0.006)	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.004)
A-MLP-LR	H1 (0.002)	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.006)
A-EXTRA-LR	H1 (0.037)	H0 (0.084)	H0 (0.123)	H1 (0.037)	H0 (0.064)	H0 (0.105)
A-KNN-LR	H0 (0.086)	H0 (0.16)	H1 (0.049)	H0 (0.064)	H0 (0.16)	H1 (0.049)

A-CNN-LR	H1 (0.011)	H1 (0.006)	H1 (0.021)	H1 (0.006)	H1 (0.004)	H1 (0.021)
A-SVM-RF	H1 (0.027)	H1 (0.02)	H0 (0.084)	H1 (0.037)	H0 (0.105)	H0 (0.084)
A-LR-RF	H1 (0.006)	H1 (0.002)	H1 (0.02)	H1 (0.004)	H1 (0.002)	H1 (0.004)
A-RF-RF	H0 (0.275)	H0 (0.105)	H0 (0.193)	H0 (0.193)	H0 (0.232)	H0 (0.322)
A-NB-RF	H1 (0.01)	H1 (0.01)	H1 (0.049)	H1 (0.004)	H1 (0.004)	H1 (0.002)
A-MLP-RF	H1 (0.002)	H1 (0.002)	H1 (0.008)	H1 (0.014)	H1 (0.01)	H1 (0.014)
A-EXTRA-RF	H0 (0.154)	H0 (0.492)	H0 (0.322)	H0 (0.173)	H0 (0.232)	H0 (0.375)
A-KNN-RF	H1 (0.014)	H1 (0.02)	H0 (0.064)	H1 (0.02)	H1 (0.027)	H0 (0.064)
A-CNN-RF	H1 (0.011)	H1 (0.014)	H1 (0.017)	H1 (0.037)	H0 (0.084)	H0 (0.084)
A-SVM-NB	H1 (0.008)	H1 (0.049)	H1 (0.006)	H1 (0.002)	H1 (0.037)	H1 (0.004)
A-LR-NB	H1 (0.006)	H1 (0.002)	H1 (0.014)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-RF-NB	H0 (0.064)	H0 (0.16)	H0 (0.086)	H1 (0.02)	H0 (0.105)	H0 (0.064)
A-NB-NB	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-MLP-NB	H1 (0.002)	H1 (0.02)	H1 (0.008)	H1 (0.002)	H1 (0.02)	H1 (0.002)
A-EXTRA-NB	H1 (0.014)	H1 (0.027)	H0 (0.064)	H1 (0.01)	H1 (0.011)	H1 (0.027)
A-KNN-NB	H1 (0.049)	H0 (0.16)	H0 (0.105)	H1 (0.037)	H0 (0.084)	H0 (0.105)
A-CNN-NB	H1 (0.028)	H0 (0.084)	H0 (0.107)	H1 (0.02)	H1 (0.049)	H1 (0.049)
B-CV-LR	H1 (0.01)	H1 (0.02)	H1 (0.01)	H1 (0.01)	H1 (0.02)	H1 (0.01)
B-TFIDF-LR	H1 (0.006)	H1 (0.006)	H1 (0.004)	H1 (0.006)	H1 (0.006)	H1 (0.004)
B-W2V-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.006)	H1 (0.02)	H1 (0.021)	H1 (0.006)	H1 (0.01)	H1 (0.02)
B-FAST-LR	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.002)
B-CV-RF	H1 (0.006)	H1 (0.006)	H1 (0.02)	H1 (0.006)	H1 (0.002)	H1 (0.02)
B-TFIDF-RF	H1 (0.015)	H0 (0.051)	H1 (0.02)	H1 (0.004)	H1 (0.049)	H1 (0.002)
B-W2V-RF	H1 (0.021)	H1 (0.002)	H1 (0.01)	H1 (0.02)	H1 (0.002)	H1 (0.006)
B-GLOVE-RF	H1 (0.004)	H1 (0.01)	H1 (0.01)	H1 (0.006)	H1 (0.027)	H1 (0.037)
B-FAST-RF	H1 (0.014)	H1 (0.01)	H1 (0.027)	H1 (0.02)	H1 (0.01)	H0 (0.084)

B-CV-NB	H0 (0.064)	H0 (0.064)	H1 (0.02)	H0 (0.064)	H0 (0.064)	H1 (0.02)
B-TFIDF-NB	H1 (0.049)	H1 (0.02)	H0 (0.064)	H1 (0.049)	H1 (0.02)	H1 (0.049)
B-W2V-NB	H1 (0.008)	H1 (0.004)	H1 (0.01)	H1 (0.004)	H1 (0.004)	H1 (0.01)
B-GLOVE-NB	H1 (0.008)	H1 (0.002)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H1 (0.004)
B-FAST-NB	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.002)
C-LR	H1 (0.008)	H1 (0.037)	H1 (0.038)	H1 (0.008)	H1 (0.027)	H1 (0.037)
C-RF	H1 (0.01)	H1 (0.006)	H1 (0.015)	H1 (0.006)	H1 (0.002)	H1 (0.004)
C-NB	H1 (0.01)	H1 (0.006)	H1 (0.002)	H1 (0.014)	H1 (0.014)	H1 (0.008)
Métrica	rec			f1		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)	H1 (0.049)
SVM-TFIDF	H0 (0.173)	H0 (0.322)	H0 (0.375)	H0 (0.173)	H0 (0.322)	H0 (0.375)
SVM-W2V	H1 (0.002)	H1 (0.002)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H1 (0.006)
SVM-GLOVE	H1 (0.004)	H1 (0.002)	H1 (0.006)	H1 (0.004)	H1 (0.002)	H1 (0.006)
SVM-FAST	H1 (0.004)	H1 (0.002)	H1 (0.01)	H1 (0.004)	H1 (0.002)	H1 (0.01)
LR-CV	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.002)
LR-TFIDF	H1 (0.004)	H1 (0.004)	H1 (0.006)	H1 (0.004)	H1 (0.004)	H1 (0.006)
LR-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
LR-W2V	H1 (0.004)	H1 (0.002)	H1 (0.01)	H1 (0.004)	H1 (0.002)	H1 (0.01)
LR-FAST	H1 (0.004)	H1 (0.002)	H1 (0.01)	H1 (0.004)	H1 (0.002)	H1 (0.01)
RF-CV	H1 (0.027)	H1 (0.02)	H1 (0.027)	H1 (0.027)	H1 (0.02)	H1 (0.027)
RF-TFIDF	H0 (0.514)	H0 (0.492)	H0 (0.322)	H0 (0.514)	H0 (0.492)	H0 (0.322)
RF-GLOVE	H1 (0.006)	H1 (0.004)	H1 (0.01)	H1 (0.006)	H1 (0.004)	H1 (0.01)
RF-W2V	H1 (0.037)	H1 (0.049)	H0 (0.064)	H1 (0.037)	H1 (0.049)	H0 (0.064)
RF-FAST	H0 (0.084)	H0 (0.084)	H0 (0.131)	H0 (0.084)	H0 (0.084)	H0 (0.131)
NB-CV	H0 (0.275)	H0 (0.314)	H0 (0.441)	H0 (0.275)	H0 (0.314)	H0 (0.441)
NB-TFIDF	H0 (0.105)	H0 (0.232)	H0 (0.232)	H0 (0.105)	H0 (0.232)	H0 (0.232)

NB-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
NB-W2V	H1 (0.006)	H1 (0.011)	H1 (0.02)	H1 (0.006)	H1 (0.011)	H1 (0.02)
NB-FAST	H0 (0.064)	H0 (0.193)	H0 (0.131)	H0 (0.064)	H0 (0.193)	H0 (0.131)
MLP-CV	H0 (0.105)	H0 (0.375)	H0 (0.322)	H0 (0.105)	H0 (0.375)	H0 (0.322)
MLP-TFIDF	H0 (0.11)	H0 (0.139)	H0 (0.232)	H0 (0.11)	H0 (0.139)	H0 (0.232)
MLP-GLOVE	H1 (0.004)	H1 (0.002)	H1 (0.01)	H1 (0.004)	H1 (0.002)	H1 (0.01)
MLP-W2V	H1 (0.027)	H1 (0.01)	H0 (0.084)	H1 (0.027)	H1 (0.01)	H0 (0.084)
MLP-FAST	H1 (0.004)	H1 (0.002)	H1 (0.02)	H1 (0.004)	H1 (0.002)	H1 (0.02)
EXTRA-CV	H0 (0.064)	H0 (0.232)	H0 (0.232)	H0 (0.064)	H0 (0.232)	H0 (0.232)
EXTRA-TFIDF	H0 (0.064)	H0 (0.11)	H0 (0.214)	H0 (0.064)	H0 (0.11)	H0 (0.214)
EXTRA-GLOVE	H1 (0.004)	H1 (0.002)	H1 (0.006)	H1 (0.004)	H1 (0.002)	H1 (0.006)
EXTRA-W2V	H1 (0.02)	H1 (0.006)	H1 (0.027)	H1 (0.02)	H1 (0.006)	H1 (0.027)
EXTRA-FAST	H1 (0.01)	H1 (0.027)	H0 (0.064)	H1 (0.01)	H1 (0.027)	H0 (0.064)
KNN-CV	H1 (0.014)	H1 (0.049)	H1 (0.028)	H1 (0.014)	H1 (0.049)	H1 (0.028)
KNN-TFIDF	H0 (0.16)	H0 (0.375)	H0 (0.232)	H0 (0.16)	H0 (0.375)	H0 (0.232)
KNN-GLOVE	H1 (0.01)	H1 (0.006)	H1 (0.014)	H1 (0.01)	H1 (0.006)	H1 (0.014)
KNN-W2V	H1 (0.049)	H0 (0.105)	H0 (0.084)	H1 (0.049)	H0 (0.105)	H0 (0.084)
KNN-FAST	H0 (0.232)	H0 (0.432)	H0 (0.193)	H0 (0.232)	H0 (0.432)	H0 (0.193)
CNN-CV	H1 (0.01)	H1 (0.002)	H1 (0.014)	H1 (0.01)	H1 (0.002)	H1 (0.014)
CNN-TFIDF	H1 (0.006)	H1 (0.002)	H1 (0.02)	H1 (0.006)	H1 (0.002)	H1 (0.02)
CNN-W2V	H1 (0.002)	H1 (0.037)	H1 (0.002)	H1 (0.002)	H1 (0.037)	H1 (0.002)
CNN-GLOVE	H1 (0.004)	H1 (0.002)	H1 (0.037)	H1 (0.004)	H1 (0.002)	H1 (0.037)
CNN-FAST	H1 (0.027)	H0 (0.105)	H1 (0.027)	H1 (0.027)	H0 (0.105)	H1 (0.027)
A-SVM-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-LR-LR	H1 (0.002)	H1 (0.01)	H1 (0.004)	H1 (0.002)	H1 (0.01)	H1 (0.004)
A-RF-LR	H1 (0.049)	H0 (0.084)	H1 (0.02)	H1 (0.049)	H0 (0.084)	H1 (0.02)
A-NB-LR	H1 (0.002)	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.004)

A-MLP-LR	H1 (0.002)	H1 (0.004)	H1 (0.006)	H1 (0.002)	H1 (0.004)	H1 (0.006)
A-EXTRA-LR	H1 (0.037)	H0 (0.064)	H0 (0.105)	H1 (0.037)	H0 (0.064)	H0 (0.105)
A-KNN-LR	H0 (0.064)	H0 (0.16)	H1 (0.049)	H0 (0.064)	H0 (0.16)	H1 (0.049)
A-CNN-LR	H1 (0.006)	H1 (0.004)	H1 (0.021)	H1 (0.006)	H1 (0.004)	H1 (0.021)
A-SVM-RF	H1 (0.037)	H0 (0.105)	H0 (0.084)	H1 (0.037)	H0 (0.105)	H0 (0.084)
A-LR-RF	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.004)
A-RF-RF	H0 (0.193)	H0 (0.232)	H0 (0.322)	H0 (0.193)	H0 (0.232)	H0 (0.322)
A-NB-RF	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.004)	H1 (0.002)
A-MLP-RF	H1 (0.014)	H1 (0.01)	H1 (0.014)	H1 (0.014)	H1 (0.01)	H1 (0.014)
A-EXTRA-RF	H0 (0.173)	H0 (0.232)	H0 (0.375)	H0 (0.173)	H0 (0.232)	H0 (0.375)
A-KNN-RF	H1 (0.02)	H1 (0.027)	H0 (0.064)	H1 (0.02)	H1 (0.027)	H0 (0.064)
A-CNN-RF	H1 (0.037)	H0 (0.084)	H0 (0.084)	H1 (0.037)	H0 (0.084)	H0 (0.084)
A-SVM-NB	H1 (0.002)	H1 (0.037)	H1 (0.004)	H1 (0.002)	H1 (0.037)	H1 (0.004)
A-LR-NB	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-RF-NB	H1 (0.02)	H0 (0.105)	H0 (0.064)	H1 (0.02)	H0 (0.105)	H0 (0.064)
A-NB-NB	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-MLP-NB	H1 (0.002)	H1 (0.02)	H1 (0.002)	H1 (0.002)	H1 (0.02)	H1 (0.002)
A-EXTRA-NB	H1 (0.01)	H1 (0.011)	H1 (0.027)	H1 (0.01)	H1 (0.011)	H1 (0.027)
A-KNN-NB	H1 (0.037)	H0 (0.084)	H0 (0.105)	H1 (0.037)	H0 (0.084)	H0 (0.105)
A-CNN-NB	H1 (0.02)	H1 (0.049)	H1 (0.049)	H1 (0.02)	H1 (0.049)	H1 (0.049)
B-CV-LR	H1 (0.01)	H1 (0.02)	H1 (0.01)	H1 (0.01)	H1 (0.02)	H1 (0.01)
B-TFIDF-LR	H1 (0.006)	H1 (0.006)	H1 (0.004)	H1 (0.006)	H1 (0.006)	H1 (0.004)
B-W2V-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.006)	H1 (0.01)	H1 (0.02)	H1 (0.006)	H1 (0.01)	H1 (0.02)
B-FAST-LR	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.002)
B-CV-RF	H1 (0.006)	H1 (0.002)	H1 (0.02)	H1 (0.006)	H1 (0.002)	H1 (0.02)
B-TFIDF-RF	H1 (0.004)	H1 (0.049)	H1 (0.002)	H1 (0.004)	H1 (0.049)	H1 (0.002)

B-W2V-RF	H1 (0.02)	H1 (0.002)	H1 (0.006)	H1 (0.02)	H1 (0.002)	H1 (0.006)
B-GLOVE-RF	H1 (0.006)	H1 (0.027)	H1 (0.037)	H1 (0.006)	H1 (0.027)	H1 (0.037)
B-FAST-RF	H1 (0.02)	H1 (0.01)	H0 (0.084)	H1 (0.02)	H1 (0.01)	H0 (0.084)
B-CV-NB	H0 (0.064)	H0 (0.064)	H1 (0.02)	H0 (0.064)	H0 (0.064)	H1 (0.02)
B-TFIDF-NB	H1 (0.049)	H1 (0.02)	H1 (0.049)	H1 (0.049)	H1 (0.02)	H1 (0.049)
B-W2V-NB	H1 (0.004)	H1 (0.004)	H1 (0.01)	H1 (0.004)	H1 (0.004)	H1 (0.01)
B-GLOVE-NB	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.004)
B-FAST-NB	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.002)
C-LR	H1 (0.008)	H1 (0.027)	H1 (0.037)	H1 (0.008)	H1 (0.027)	H1 (0.037)
C-RF	H1 (0.006)	H1 (0.002)	H1 (0.004)	H1 (0.006)	H1 (0.002)	H1 (0.004)
C-NB	H1 (0.014)	H1 (0.014)	H1 (0.008)	H1 (0.014)	H1 (0.014)	H1 (0.008)

Tabela 29 – Resultados do teste de hipótese para conjunto Fa-Kes. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.

Métrica	acc			pre		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-TFIDF	H1 (0.002)	H1 (0.014)	H1 (0.011)	H1 (0.002)	H1 (0.02)	H1 (0.028)
SVM-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

LR-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-CV	H1 (0.038)	H0 (0.064)	H0 (0.16)	H1 (0.024)	H0 (0.193)	H0 (0.086)
NB-TFIDF	H1 (0.01)	H1 (0.02)	H1 (0.02)	H1 (0.011)	H1 (0.02)	H1 (0.008)
NB-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-TFIDF	H1 (0.038)	H0 (0.105)	H1 (0.037)	H1 (0.027)	H0 (0.131)	H1 (0.037)
MLP-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

CNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-LR	H1 (0.002)	H1 (0.008)	H1 (0.008)	H1 (0.004)	H0 (0.064)	H1 (0.014)
A-LR-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.004)
A-NB-LR	H1 (0.049)	H0 (0.105)	H0 (0.213)	H1 (0.02)	H0 (0.084)	H0 (0.131)
A-MLP-LR	H1 (0.02)	H1 (0.037)	H1 (0.021)	H1 (0.027)	H0 (0.084)	H1 (0.037)
A-EXTRA-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-RF	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-LR-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-NB-RF	H1 (0.008)	H1 (0.006)	H1 (0.006)	H1 (0.002)	H1 (0.01)	H1 (0.004)
A-MLP-RF	H1 (0.002)	H1 (0.01)	H1 (0.008)	H1 (0.011)	H1 (0.027)	H1 (0.002)
A-EXTRA-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.01)	H1 (0.004)
A-LR-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)
A-RF-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-NB	H1 (0.006)	H1 (0.027)	H1 (0.027)	H1 (0.002)	H0 (0.064)	H1 (0.02)
A-MLP-NB	H1 (0.004)	H1 (0.014)	H1 (0.011)	H1 (0.01)	H1 (0.037)	H1 (0.01)
A-EXTRA-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

A-CNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-LR	H1 (0.011)	H0 (0.131)	H0 (0.324)	H1 (0.004)	H0 (0.77)	H0 (0.26)
B-TFIDF-LR	H1 (0.017)	H1 (0.037)	H1 (0.015)	H1 (0.02)	H0 (0.275)	H1 (0.049)
B-W2V-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-RF	H1 (0.006)	H1 (0.008)	H0 (0.085)	H1 (0.002)	H1 (0.004)	H1 (0.015)
B-TFIDF-RF	H1 (0.015)	H0 (0.066)	H1 (0.049)	H1 (0.037)	H0 (0.275)	H0 (0.084)
B-W2V-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-NB	H1 (0.004)	H1 (0.021)	H1 (0.014)	H1 (0.004)	H0 (0.084)	H1 (0.049)
B-TFIDF-NB	H1 (0.004)	H1 (0.049)	H1 (0.015)	H1 (0.002)	H0 (0.16)	H1 (0.038)
B-W2V-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
C-LR	H1 (0.012)	H1 (0.049)	H0 (0.438)	H1 (0.027)	H0 (0.322)	H0 (0.123)
C-RF	H0 (0.064)	H0 (0.105)	H0 (0.189)	H1 (0.008)	H0 (0.232)	H0 (0.066)
C-NB	H1 (0.007)	H1 (0.037)	H1 (0.007)	H1 (0.004)	H0 (0.193)	H1 (0.037)
Métrica	rec			f1		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-TFIDF	H0 (0.105)	H1 (0.015)	H0 (0.064)	H1 (0.002)	H1 (0.014)	H1 (0.015)
SVM-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-CV	H1 (0.008)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

LR-TFIDF	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-CV	H0 (0.131)	H0 (0.064)	H0 (0.105)	H0 (0.064)	H1 (0.037)	H0 (0.131)
NB-TFIDF	H0 (0.105)	H1 (0.014)	H0 (0.105)	H1 (0.02)	H1 (0.02)	H1 (0.027)
NB-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-CV	H1 (0.004)	H1 (0.002)	H1 (0.011)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-TFIDF	H0 (0.193)	H1 (0.027)	H0 (0.193)	H1 (0.027)	H0 (0.105)	H1 (0.049)
MLP-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-W2V	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-CV	H1 (0.004)	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-TFIDF	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

KNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-W2V	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-LR	H0 (0.084)	H1 (0.02)	H0 (0.109)	H1 (0.002)	H1 (0.004)	H1 (0.006)
A-LR-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-LR	H0 (0.16)	H0 (0.084)	H0 (0.192)	H0 (0.064)	H0 (0.066)	H0 (0.232)
A-MLP-LR	H1 (0.049)	H1 (0.021)	H1 (0.049)	H1 (0.011)	H1 (0.027)	H1 (0.02)
A-EXTRA-LR	H1 (0.049)	H1 (0.01)	H1 (0.027)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-KNN-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-LR	H1 (0.004)	H1 (0.004)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-RF	H0 (0.084)	H1 (0.02)	H1 (0.049)	H1 (0.004)	H1 (0.002)	H1 (0.006)
A-LR-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-RF	H0 (0.084)	H1 (0.014)	H0 (0.084)	H1 (0.01)	H1 (0.004)	H1 (0.01)
A-MLP-RF	H1 (0.01)	H1 (0.002)	H1 (0.014)	H1 (0.002)	H1 (0.012)	H1 (0.002)
A-EXTRA-RF	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-RF	H1 (0.004)	H1 (0.002)	H1 (0.008)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-NB	H1 (0.006)	H1 (0.002)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-LR-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-NB	H0 (0.131)	H1 (0.037)	H0 (0.109)	H1 (0.014)	H1 (0.038)	H1 (0.049)

A-MLP-NB	H1 (0.02)	H1 (0.012)	H1 (0.027)	H1 (0.008)	H1 (0.004)	H1 (0.006)
A-EXTRA-NB	H1 (0.006)	H1 (0.004)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-NB	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-LR	H0 (0.105)	H0 (0.131)	H0 (0.375)	H1 (0.049)	H0 (0.064)	H0 (0.441)
B-TFIDF-LR	H0 (0.105)	H1 (0.02)	H0 (0.084)	H1 (0.013)	H1 (0.027)	H1 (0.021)
B-W2V-LR	H1 (0.004)	H1 (0.004)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-RF	H0 (0.084)	H1 (0.049)	H0 (0.109)	H1 (0.02)	H1 (0.004)	H0 (0.139)
B-TFIDF-RF	H0 (0.084)	H1 (0.014)	H0 (0.105)	H1 (0.006)	H1 (0.049)	H1 (0.049)
B-W2V-RF	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-NB	H0 (0.084)	H1 (0.027)	H0 (0.123)	H1 (0.004)	H1 (0.01)	H1 (0.01)
B-TFIDF-NB	H0 (0.105)	H1 (0.027)	H0 (0.16)	H1 (0.01)	H1 (0.049)	H1 (0.033)
B-W2V-NB	H1 (0.004)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
C-LR	H0 (0.11)	H0 (0.084)	H0 (0.213)	H1 (0.037)	H1 (0.027)	H0 (0.374)
C-RF	H0 (0.105)	H0 (0.084)	H0 (0.105)	H0 (0.064)	H0 (0.131)	H0 (0.173)
C-NB	H0 (0.105)	H1 (0.027)	H0 (0.131)	H1 (0.002)	H1 (0.014)	H1 (0.02)

Tabela 30 – Resultados do teste de Hipótese para o conjunto Ott. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.

Métrica	acc			pre		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)
SVM-TFIDF	H1 (0.002)	H1 (0.002)	H0 (0.097)	H1 (0.002)	H1 (0.002)	H1 (0.049)
SVM-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.002)	H1 (0.038)
LR-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.027)	H1 (0.006)	H1 (0.037)
MLP-TFIDF	H1 (0.002)	H1 (0.002)	H0 (0.141)	H1 (0.028)	H1 (0.004)	H0 (0.138)
MLP-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

EXTRA-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.006)	H1 (0.049)
CNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.02)	H1 (0.01)	H1 (0.049)
CNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.004)	H1 (0.004)	H1 (0.004)
CNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-LR	H1 (0.002)	H1 (0.008)	H1 (0.01)	H1 (0.006)	H1 (0.015)	H1 (0.02)
A-LR-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.008)
A-RF-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-MLP-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.008)	H1 (0.002)	H1 (0.002)
A-EXTRA-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-LR	H1 (0.002)	H1 (0.002)	H0 (0.084)	H1 (0.004)	H1 (0.02)	H0 (0.074)
A-SVM-RF	H1 (0.002)	H1 (0.002)	H1 (0.027)	H1 (0.01)	H1 (0.002)	H1 (0.024)
A-LR-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.015)	H1 (0.002)	H1 (0.008)
A-NB-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

A-MLP-RF	H1 (0.002)	H1 (0.002)	H1 (0.042)	H0 (0.058)	H1 (0.002)	H0 (0.094)
A-EXTRA-RF	H1 (0.008)	H1 (0.002)	H1 (0.006)	H1 (0.004)	H1 (0.004)	H1 (0.02)
A-KNN-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-RF	H1 (0.008)	H1 (0.011)	H0 (0.105)	H1 (0.007)	H1 (0.004)	H0 (0.262)
A-SVM-NB	H1 (0.002)	H1 (0.002)	H1 (0.008)	H1 (0.004)	H1 (0.004)	H1 (0.007)
A-LR-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.008)
A-RF-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-MLP-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-EXTRA-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.05)	H1 (0.002)	H1 (0.004)	H0 (0.068)
B-CV-LR	H1 (0.01)	H1 (0.004)	H0 (0.121)	H1 (0.033)	H1 (0.014)	H0 (0.138)
B-TFIDF-LR	H1 (0.033)	H1 (0.01)	H0 (0.677)	H0 (0.127)	H1 (0.006)	H0 (0.234)
B-W2V-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-RF	H1 (0.008)	H1 (0.002)	H1 (0.037)	H0 (0.512)	H1 (0.049)	H0 (0.833)
B-TFIDF-RF	H1 (0.021)	H1 (0.013)	H0 (0.526)	H0 (0.107)	H1 (0.006)	H0 (0.307)
B-W2V-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-NB	H1 (0.002)	H1 (0.002)	H1 (0.007)	H1 (0.02)	H1 (0.006)	H1 (0.012)
B-TFIDF-NB	H1 (0.007)	H1 (0.002)	H0 (0.275)	H0 (0.075)	H1 (0.002)	H0 (0.311)
B-W2V-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)

C-LR	H1 (0.011)	H1 (0.042)	H0 (0.131)	H1 (0.011)	H1 (0.002)	H0 (0.634)
C-RF	H0 (0.492)	H0 (0.495)	H1 (0.012)	H0 (0.549)	H0 (0.258)	H0 (0.131)
C-NB	H1 (0.014)	H1 (0.01)	H0 (0.251)	H0 (0.084)	H1 (0.02)	H1 (0.017)
Métrica	rec			f1		
	D-LR	D-RF	D-NB	D-LR	D-RF	D-NB
SVM-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-TFIDF	H1 (0.007)	H1 (0.011)	H0 (0.102)	H1 (0.002)	H1 (0.002)	H0 (0.083)
SVM-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
SVM-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
LR-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-CV	H1 (0.002)	H1 (0.002)	H1 (0.028)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-TFIDF	H0 (0.34)	H0 (0.953)	H0 (0.299)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
RF-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
NB-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-CV	H1 (0.004)	H1 (0.008)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-TFIDF	H1 (0.008)	H1 (0.002)	H1 (0.006)	H1 (0.002)	H1 (0.002)	H0 (0.183)

MLP-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
MLP-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-CV	H0 (0.833)	H0 (0.26)	H0 (0.057)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-TFIDF	H0 (0.719)	H0 (0.398)	H0 (0.057)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
EXTRA-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-CV	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-TFIDF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-W2V	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
KNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-CV	H1 (0.014)	H1 (0.014)	H1 (0.037)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-TFIDF	H1 (0.008)	H1 (0.012)	H1 (0.012)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-W2V	H1 (0.02)	H1 (0.038)	H0 (0.064)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-GLOVE	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
CNN-FAST	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-SVM-LR	H1 (0.007)	H1 (0.008)	H1 (0.008)	H1 (0.002)	H1 (0.004)	H1 (0.014)
A-LR-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-LR	H1 (0.011)	H1 (0.028)	H1 (0.024)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-MLP-LR	H1 (0.002)	H1 (0.002)	H1 (0.007)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-EXTRA-LR	H1 (0.004)	H1 (0.021)	H1 (0.027)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-LR	H1 (0.02)	H0 (0.058)	H0 (0.181)	H1 (0.002)	H1 (0.002)	H0 (0.084)
A-SVM-RF	H1 (0.018)	H1 (0.011)	H0 (0.172)	H1 (0.002)	H1 (0.002)	H0 (0.125)

A-LR-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-MLP-RF	H1 (0.002)	H1 (0.002)	H1 (0.018)	H1 (0.007)	H1 (0.002)	H1 (0.049)
A-EXTRA-RF	H1 (0.004)	H1 (0.011)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.004)
A-KNN-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-RF	H1 (0.007)	H1 (0.011)	H1 (0.027)	H1 (0.008)	H1 (0.004)	H1 (0.044)
A-SVM-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.008)
A-LR-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-RF-NB	H1 (0.004)	H1 (0.01)	H1 (0.01)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-NB-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-MLP-NB	H1 (0.002)	H1 (0.002)	H1 (0.007)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-EXTRA-NB	H1 (0.014)	H1 (0.033)	H0 (0.079)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-KNN-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
A-CNN-NB	H1 (0.018)	H1 (0.024)	H1 (0.035)	H1 (0.002)	H1 (0.002)	H1 (0.05)
B-CV-LR	H1 (0.02)	H1 (0.024)	H0 (0.207)	H1 (0.01)	H1 (0.006)	H0 (0.23)
B-TFIDF-LR	H1 (0.01)	H1 (0.006)	H0 (0.19)	H1 (0.028)	H1 (0.006)	H0 (0.766)
B-W2V-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-LR	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-LR	H1 (0.004)	H1 (0.006)	H1 (0.004)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-RF	H1 (0.002)	H1 (0.008)	H1 (0.008)	H1 (0.008)	H1 (0.008)	H0 (0.492)
B-TFIDF-RF	H1 (0.01)	H1 (0.006)	H1 (0.037)	H1 (0.007)	H1 (0.002)	H0 (0.341)
B-W2V-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-RF	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-CV-NB	H1 (0.015)	H1 (0.015)	H1 (0.02)	H1 (0.002)	H1 (0.002)	H1 (0.007)
B-TFIDF-NB	H1 (0.008)	H1 (0.002)	H1 (0.02)	H1 (0.007)	H1 (0.002)	H0 (0.375)

B-W2V-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-GLOVE-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
B-FAST-NB	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)	H1 (0.002)
C-LR	H1 (0.017)	H0 (0.311)	H0 (0.236)	H1 (0.011)	H0 (0.067)	H0 (0.084)
C-RF	H1 (0.015)	H1 (0.012)	H0 (0.139)	H0 (0.172)	H0 (0.094)	H1 (0.041)
C-NB	H1 (0.017)	H1 (0.05)	H0 (0.739)	H1 (0.01)	H1 (0.01)	H0 (0.327)

Tabela 31 – Resultados do teste de Hipótese para o conjunto Kaggle. Na tabela o resultado H0 corresponde a hipótese Não rejeita H0 e H1 a rejeita H0. É apresentado também o valor do *p-value* obtido entre parêntesis.