



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
UNIDADE ACADÊMICA DE SISTEMAS E COMPUTAÇÃO
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

VALTER VINÍCIUS MARINHO DE LUCENA

**UTILIZANDO WORD EMBEDDINGS PARA VERIFICAR O
ALINHAMENTO POLÍTICO DE DEPUTADOS FEDERAIS
BRASILEIROS ATRAVÉS DE SEUS TWEETS**

CAMPINA GRANDE - PB

2019

VALTER VINÍCIUS MARINHO DE LUCENA

**UTILIZANDO WORD EMBEDDINGS PARA VERIFICAR O
ALINHAMENTO POLÍTICO DE DEPUTADOS FEDERAIS
BRASILEIROS ATRAVÉS DE SEUS TWEETS**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em Ciência
da Computação.**

Orientador: Professor Dr. Leandro Balby Marinho.

CAMPINA GRANDE - PB

2019



L935u Lucena, Valter Vinícius Marinho de.
Utilizando word embeddings para verificar o alinhamento político de deputados federais brasileiros através de seus tweets. / Valter Vinícius Marinho de Lucena. - 2019.

10 f.

Orientador: Prof. Dr. Leandro Balby Marinho.

Trabalho de Conclusão de Curso - Artigo (Curso de Bacharelado em Ciência da Computação) - Universidade Federal de Campina Grande; Centro de Engenharia Elétrica e Informática.

1. Processamento de linguagem natural. 2. Alinhamento político. 3. Tweets políticos. 4. Deputados federais - análise de publicações. 5. Word Embedding Association Test - WEAT. I. Marinho, Leandro Balby. II. Título.

CDU:004(045)

Elaboração da Ficha Catalográfica:

Johnny Rodrigues Barbosa
Bibliotecário-Documentalista
CRB-15/626

VALTER VINÍCIUS MARINHO DE LUCENA

**UTILIZANDO WORD EMBEDDINGS PARA VERIFICAR O
ALINHAMENTO POLÍTICO DE DEPUTADOS FEDERAIS
BRASILEIROS ATRAVÉS DE SEUS TWEETS**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em Ciência
da Computação.**

BANCA EXAMINADORA:

**Professor Dr. Leandro Balby Marinho
Orientador – UASC/CEEI/UFCG**

**Professor Dr. Amdrey Elísio Monteiro Brito
Examinador – UASC/CEEI/UFCG**

**Professor Dr. Tiago Lima Massoni
Disciplina TCC – UASC/CEEI/UFCG**

Trabalho aprovado em: 25 de novembro de 2019.

CAMPINA GRANDE - PB

Utilizando *word embeddings* para verificar o alinhamento político de deputados federais brasileiros através de seus *tweets*.

Trabalho de Conclusão de Curso

Valter Vinícius Marinho de Lucena
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil
valter.lucena@ccc.ufcg.edu.br

Leandro Balby Marinho*
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil
lbmarinho@dsc.ufcg.edu.br

RESUMO

Atualmente, o Twitter é amplamente utilizado pelos políticos como um canal de comunicação mais direto com seus eleitores e opinar sobre vários assuntos. Devido à grande quantidade de conteúdo gerado pelas redes sociais, medir o alinhamento de políticos em relação a determinadas pautas através de seus *tweets* possibilita observar, de forma automática, como os deputados se comportam e se expressam usando essas mídias. Neste trabalho, medimos o alinhamento político de deputados federais brasileiros com relação à Reforma da Previdência aplicando o *Word Embedding Association Test* (WEAT), que quantifica a associação entre conjuntos de palavras. Os resultados encontrados mostram que o método utilizado consegue medir o alinhamento dos deputados à Reforma da Previdência, coincidindo com os posicionamentos assumidos por estes políticos sobre a pauta.

PALAVRAS-CHAVE

Processamento de Linguagem Natural. Alinhamento político. *Word embeddings*. WEAT.

ABSTRACT

Nowadays Twitter is widely used by politicians as a more direct channel of communication with their voters and to give their opinion on various issues. Due to the large amount of content generated on social media, measuring the alignment of politicians in relation to certain subjects through their tweets makes it possible to automatically observe how they behave and express themselves using these media. Here, we measure the political alignment of Brazilian federal deputies with regard to Social Security Reform by applying the Word Embedding Association Test (WEAT), which quantifies association between word sets. The results show that the method used can measure the alignment of deputies to the Social Security Reform, coinciding with the positions taken by these politicians on the subject.

KEYWORDS

Natural Language Processing. Political Alignment. Word Embeddings. WEAT.

* Os autores reêm os direitos, ao abrigo de uma licença Creative Commons Atribuição CC BY, sobre todo o conteúdo deste artigo (incluindo todos os elementos que possam conter, tais como figuras, desenhos, tabelas), bem como sobre todos os materiais produzidos pelos autores que estejam relacionados ao trabalho relatado e que estejam referenciados no artigo (tais como códigos fonte e bases de dados). Essa licença permite que outros distribuam, adaptem e evoluam seu trabalho, mesmo comercialmente, desde que os autores sejam creditados pela criação original.

1 INTRODUÇÃO

A popularização das redes sociais possibilitou sua utilização como uma plataforma para o compartilhamento de opiniões sobre diversos acontecimentos e assuntos. Opiniões em redes sociais, quando devidamente recolhidas e analisadas, permitem não apenas compreender e explicar diversos fenômenos sociais, como também prevê-los [3]. O *Twitter* é uma ótima fonte de coleta de dados sobre a opinião de seus usuários, já que as postagens na rede se dão por meio de textos curtos, denominados *tweets*, que podem ser agrupados através de marcadores, além de facilitar esta aquisição através de uma interface de programação de aplicativos (API).

Muitos políticos utilizam o *Twitter* como um canal para divulgação de suas propostas, para comunicarem-se com seus eleitores e para expressarem opiniões sobre variadas pautas. Graham, Jackson e Boersma [9] destacam que o processo de comunicação no *Twitter* promete uma ruptura com os pronunciamentos rígidos e na mensagem imposta pela máquina partidária na comunicação política, reduzindo a desconexão entre os políticos e aqueles que eles representam.

Como apontado por Marques, Aquino e Miola [11], ao permitir um acompanhamento mais eficiente do exercício político, o *Twitter* fomenta a habilidade dos cidadãos de fiscalizar as atividades das instituições. Já que os políticos são eleitos para representar os interesses da população, é interessante observar como eles se comportam ao utilizar as redes sociais e como expressam suas opiniões nas mesmas.

Devido à alta quantidade de dados gerados pelo *Twitter*, analisar cada *tweet* manualmente é uma tarefa custosa e ineficiente. No entanto, os avanços recentes na área de Processamento de Linguagem Natural (PLN) possibilitaram uma alternativa a este problema [2]. Ao aplicar algoritmos de aprendizagem de máquina em PLN, faz-se necessária a conversão do texto para algum tipo de dado que o algoritmo saiba processar [7]. Na maioria dos casos, esse texto é convertido para um vetor numérico. Representar palavras em vetores numéricos multidimensionais permitem que palavras semanticamente similares sejam posicionadas na mesma região de um espaço vetorial geométrico [1]. Uma alternativa comum para realizar esta conversão é utilizar alguma técnica de *word embeddings*.

O termo *word embeddings* refere-se ao conjunto de técnicas que permitem a representação de um conjunto de palavras de um vocabulário num espaço vetorial de dimensão menor que o tamanho do vocabulário [7]. Além disso, essas técnicas possibilitam, de forma não supervisionada, capturar aspectos semânticos das palavras baseadas apenas no contexto em que elas aparecem, assim como adquirir

um viés estereotipado [5]. Caliskan, Bryson e Narayanan propõem, em [5], um teste estatístico similar ao *Implicit Association Test* (IAT), que demonstra a diferença entre os tempos de resposta para que sujeitos emparelhem dois conceitos que considerem semelhantes, em contraste com dois conceitos que consideram diferentes, para medir o viés adquirido pelo aprendizado de máquina padrão através de dados textuais que refletem o cotidiano humano. O teste desenvolvido foi denominado *Word Embedding Association Test* (WEAT), e utiliza a distância entre um par de vetores como análoga ao tempo de reação no IAT. O WEAT compara esses vetores para um mesmo conjunto de palavras, medindo, caso existam, suas associações.

A fim de automatizar a tarefa de entender o comportamento de políticos ao utilizar o *Twitter*, o presente trabalho propõe utilizar uma adaptação do WEAT nos *tweets* de deputados federais brasileiros com o objetivo de medir seu alinhamento a pautas políticas. Para isto, o WEAT foi aplicado utilizando *word embeddings* treinados com base em textos de notícias nos *tweets* de alguns deputados em exercício com o objetivo de identificar e medir o alinhamento destes com a Reforma da Previdência. Os resultados mostram que o método utilizado consegue medir o alinhamento dos deputados a uma pauta política através de seus *tweets*, coincidindo com os posicionamentos assumidos pelos deputados selecionados.

2 REFERENCIAL TEÓRICO

2.1 Processamento de Linguagem Natural

O Processamento de Linguagem Natural (PLN) é uma área de pesquisa e aplicação que explora como computadores podem ser utilizados para processar e manipular texto ou fala em linguagem natural [6]. Algumas das aplicações mais comuns da PLN são nas áreas de tradução automática, processamento e resumo de texto e reconhecimento de fala. Para isso, é preciso modelar a linguagem a ser processada através de pré-processamentos que a abstraem e estruturam, mantendo apenas as informações consideradas relevantes. As técnicas mais utilizadas incluem tokenização, remoção de *stopwords* e padronização de capitalização [16].

2.1.1 Tokenização.

A tokenização é o processo de segmentação de palavras ou sentenças em unidades denominadas *tokens*. *Tokens* são sequências de caracteres alfabéticos ou alfanuméricos delimitados por um espaço ou sinais de pontuação. Um *token* pode representar uma palavra ou um conjunto de palavras.

2.1.2 Remoção de stopwords.

Stopwords são palavras encontradas com bastante frequência em textos e que são independentes de um tópico específico (por exemplo, conjunções, preposições e artigos). Por este motivo, como apontam Uysal e Gunal [16], *stopwords* são consideradas irrelevantes nas atividades de PLN, sendo retiradas dos *tokens* resultantes do processo de tokenização. Cada linguagem possui suas próprias *stopwords*.

2.1.3 Padronização de capitalização.

Uma outra etapa comum na atividade de pré-processamento é a padronização da capitalização. Este processo assume que o significado das palavras não muda se a palavra é escrita com caracteres maiúsculos ou minúsculos, e consiste na conversão dos caracteres

para uma única forma de capitalização, geralmente convertendo caracteres maiúsculos em minúsculos.

2.2 TF-IDF

O valor TF-IDF é uma medida estatística utilizada para avaliar quão relevante uma palavra é para um documento em uma coleção ou *corpus* [13]. A relevância aumenta proporcionalmente ao número de vezes que uma palavra aparece em um documento, mas é penalizada pela frequência da palavra em todo o *corpus*. Este valor é calculado a partir do produto entre a frequência de um termo em um documento (TF) e a frequência inversa de documentos (IDF), definida pela fórmula

$$IDF(w) = \log_e\left(\frac{M}{k}\right)$$

onde w é uma palavra, M é o número de documentos no *corpus* e k é a quantidade de documentos onde w aparece.

2.3 Word embeddings

Word embeddings são construídos considerando como entrada um conjunto de documentos de texto que leva à construção de um vocabulário e ao aprendizado da representação de uma palavra em um espaço vetorial multidimensional. São amplamente utilizados atualmente em várias atividades de PLN [4].

Um *word embedding* é uma função parametrizada que mapeia palavras de alguma linguagem em um vetor com muitas dimensões. Cada dimensão de um *word embedding* é uma característica que descreve a palavra representada. Os valores dessas dimensões tornam possível medir a similaridade de palavras e extrair seus aspectos sintáticos e semânticos de maneira não supervisionada, levando em consideração apenas o contexto onde essas palavras aparecem, ou seja, o local em um espaço vetorial multidimensional onde os vetores destas palavras estão posicionados.

A figura 1 contém uma simplificação na qual a característica que cada dimensão de um *word embedding* representa é bem definida. Se considerarmos que a primeira dimensão dos *word embeddings* da figura refere-se à característica "animal", então o valor desta dimensão para cada palavra quantifica sua proximidade para o conceito representado pela característica.

	Dimensions					
Word vectors	dog	-0.4	0.37	0.02	-0.34	animal
	cat	-0.15	-0.02	-0.23	-0.23	domesticated
	lion	0.19	-0.4	0.35	-0.48	pet
	tiger	-0.08	0.31	0.56	0.07	fluffy
	elephant	-0.04	-0.09	0.11	-0.06	
	cheetah	0.27	-0.28	-0.2	-0.43	
	monkey	-0.02	-0.67	-0.21	-0.48	
	rabbit	-0.04	-0.3	-0.18	-0.47	
	mouse	0.09	-0.46	-0.35	-0.24	
	rat	0.21	-0.48	-0.56	-0.37	

Figura 1: Simplificação do significado das dimensões de *word embeddings* para representações em quatro dimensões dos nomes de alguns animais. Fonte: *Introduction to Word Vectors*.

2.3.1 Word2Vec.

Um modelo *word2vec* é uma rede neural com uma única camada oculta projetada para reconstruir o contexto das palavras, estimando a probabilidade de uma palavra estar próxima de outra dada como entrada [1]. Essas informações são obtidas através de dois algoritmos propostos por Mikolov *et al.*[12]: *Common Bag Of Words* (CBOW) e *Skip-gram*. O CBOW tenta prever uma palavra com base em um contexto (palavras ao seu redor), e o *Skip-gram* o contexto em que uma palavra aparece, como esquematizado na figura 2.

No entanto, a rede neural não é utilizada após o treinamento do modelo. O objetivo do treinamento é aprender os pesos da camada oculta, pois estes correspondem aos valores das diversas dimensões dos *word embeddings*.

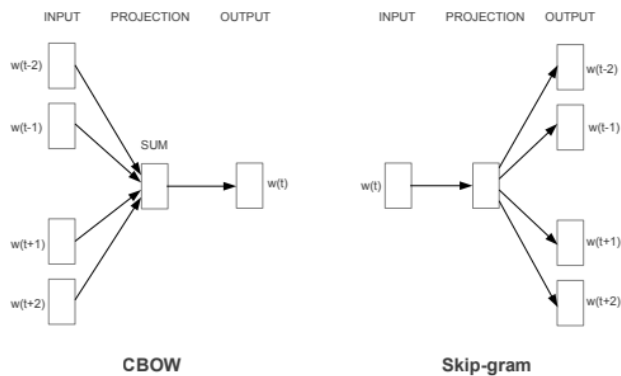


Figura 2: Arquitetura dos algoritmos CBOW e *Skip-gram*. Fonte: *Efficient estimation of word representations in vector space*

As abordagens tradicionais de PNL não capturam relações sintáticas e semânticas entre palavras. Por outro lado, os vetores de palavras representam-nas como vetores multidimensionais de números de ponto flutuante, de forma que palavras semanticamente semelhantes sejam posicionadas em pontos próximos num espaço vetorial. Assim, cada valor do vetor captura uma dimensão do significado da palavra e onde palavras semanticamente semelhantes têm vetores semelhantes.

2.4 WEAT

O WEAT é um teste estatístico proposto por Caliskan, Bryson e Narayanan em [5] aplicado a *word embeddings* que identifica o viés estereotipado adquirido pelo aprendizado de máquina padrão a partir de dados textuais que refletem o cotidiano humano. O teste calcula a similaridade, de acordo com um modelo de *word embedding*, entre cada palavra de dois conjuntos de palavras-alvo X e Y e toda palavra em dois conjuntos de palavras-atributo A e B [14]. Por exemplo, considerando como alvos as palavras *masculino* e *feminino* e como atributos as palavras *violento* e *pacífico*, se notarmos que *masculino* está mais associada à *violento* que *feminino*, e que esta está mais associada à *pacífico* que *violento*, então detectamos um viés. Essa similaridade é avaliada a partir da seguinte fórmula:

$$s(X, Y, A, B) = \sum_{x \in X} s(x, A, B) - \sum_{y \in Y} s(y, A, B)$$

onde $s(w, A, B)$ para uma dada palavra w é calculado por

$$s(w, A, B) = \frac{1}{|A|} \sum_{a \in A} \cos(\vec{w}, \vec{a}) - \frac{1}{|B|} \sum_{b \in B} \cos(\vec{w}, \vec{b})$$

Em outras palavras, $s(w, A, B)$ mede a associação de w com o conjunto de palavras-atributo, e $s(X, Y, A, B)$ a diferença entre a associação dos dois conjuntos de palavras-alvo e os dois conjuntos de palavras-atributo. Qualquer resultado diferente de zero identifica um viés de alguma palavra-alvo em relação a alguma palavra-atributo.

3 MATERIAIS E MÉTODOS

3.1 Dados sobre deputados federais

Os dados utilizados para realizar os experimentos são referentes aos *tweets* dos deputados federais em exercício na 56ª legislatura. Estes dados foram coletados a partir dos Dados Abertos da Câmara dos Deputados [8] e continham informações básicas sobre cada político.

Após isso, observando os perfis seguidos pelo perfil da Câmara dos Deputados no *Twitter*, os *usernames* dos deputados foram adicionados à base de dados inicial. Ao fim deste processo, os dados possuíam as informações descritas na tabela 1.

Tabela 1: Descrição dos dados sobre os deputados

Variável	Descrição
id	Identificador do deputado
nome	Nome do deputado
siglaPartido	Sigla do partido ao qual o deputado é afiliado
siglaUf	Estado ao qual pertence um deputado
idLegislatura	Identificador da legislatura onde o deputado atua
email	Email de contato do deputado
sexo	Sexo do deputado
username	Nome de usuário do perfil do deputado

Em posse dos dados dos deputados e seus respectivos *usernames*, foi realizada a coleta dos seus *tweets*. Devido às limitações do próprio *Twitter* [15], a coleta dos *tweets* de cada deputado foi realizada em etapas. A cada etapa do processo eram coletados os 50 *tweets* anteriores ao último *tweet* coletado. Ao fim do processo, foram coletados em média 2000 *tweets* para os 451 deputados em exercício que possuem um perfil no *Twitter*. Os dados utilizados podem ser encontrados em nosso repositório no GitHub¹. A tabela 2 descreve as informações contidas na base.

3.2 Pré-processamento

Os dados coletados foram pré-processados com o propósito de manter somente as informações relevantes ao contexto da pesquisa e estruturá-los de forma a facilitar sua análise. As técnicas utilizadas foram padronização de capitalização, tokenização e remoção de

¹https://github.com/valterlucena/twitter_deputados

Tabela 2: Descrição dos dados de tweets dos deputados

Variável	Descrição
id_tweet	Identificador do <i>tweet</i>
tweet	Conteúdo do <i>tweet</i>
id_author	Identificador do deputado
user_author	Nome de usuário do deputado

stopwords, e foram aplicadas através das bibliotecas *tokenize* e *corpus* da plataforma NLTK², responsáveis, respectivamente, pela geração dos *tokens* e remoção das *stopwords*. A tabela 3 contém o resultado da aplicação das técnicas descritas para um *tweet*.

3.3 Word embeddings

Os dados utilizados para o treinamento do modelo são notícias dos anos de 2010, 2014 e 2018 obtidas da seção sobre política dos portais Folha de São Paulo (FolhaSP) e Estadão [14]. Cada observação da base refere-se aos *tokens* produzidos a partir do texto de uma notícia pré-processados com as mesmas técnicas descritas na subseção anterior. A escolha dos dados levou em consideração o contexto em que os *word embeddings* seriam usados. Aplicar esses dados de notícias políticas na criação dos *word embeddings* possibilita que os valores de suas dimensões meçam o quanto a palavra que ele representa está relacionada a características políticas aprendidas durante o treinamento. Os *word embeddings* utilizados nos modelos foram criados utilizando o módulo *word2vec* da biblioteca Gensim³.

3.3.1 Criação e treinamento do modelo de word embeddings.

O modelo *Word2Vec* para a criação dos *word embeddings* foi treinado utilizando como parâmetros janelas de duas palavras e vetores de 300 dimensões. O tamanho da janela refere-se à quantidade de palavras anteriores e posteriores à palavra-alvo, ou seja, o que será considerado como o contexto onde a palavra aparece, e o tamanho dois foi escolhido pois, enquanto janelas maiores tendem a capturar informações mais gerais sobre um tópico ou domínio, janelas menores tendem a capturar mais sobre a própria palavra [10]. Já a quantidade de dimensões dos vetores foi escolhida levando em consideração que, ao serem treinados em grandes bases, vetores com mais dimensões capturam relacionamentos semânticos mais sutis entre as palavras [12]. Levy e Goldberg [10] mostram que alcançaram valores semelhantes para métricas como tamanho do vocabulário e quantidade de contextos sintáticos distintos para vetores de 300 e 600 dimensões. O valor 300 foi escolhido, então, buscando minimizar o tempo de treinamento do modelo mantendo resultados similares à abordagem que utiliza 600 dimensões.

A rede neural utilizada no treinamento possuía uma camada de entrada, uma camada oculta com 300 neurônios, e uma camada de saída com 60.041 neurônios. A quantidade de neurônios na camada de saída refere-se ao tamanho do vocabulário da base de treinamento.

O treinamento do modelo ocorreu da seguinte forma: para cada palavra da base, uma palavra do seu contexto era escolhida ao acaso e oferecida como entrada à rede neural na forma de um vetor *one*

*hot encoding*⁴ de 60.041 dimensões. Assim como a camada de saída, o vetor de entrada possui a mesma quantidade de dimensões que o tamanho do vocabulário. A rede, então, oferecia como saída a probabilidade de cada palavra no vocabulário de estar próxima à palavra de entrada. Este procedimento e a estrutura da rede neural utilizada são esquematizados na figura 3.




Figura 3: Estrutura de uma rede neural para treinar word-embeddings de 300 dimensões em um vocabulário de 10 mil palavras. Fonte: Adventures in machine learning.

3.4 WEAT

Para a aplicação do WEAT, faz-se necessária a criação de quatro conjuntos: dois conjuntos de palavras-alvo e dois conjuntos de palavras-atributo. Neste caso, os conjuntos de palavras-alvo contêm as palavras mais relevantes dos *tweets* de um deputado sobre uma pauta específica, enquanto os conjuntos de palavras-atributo contêm palavras semanticamente similares a ideias antagônicas. A relevância das palavras contidas nos *tweets* de um deputado foi calculada através do valor TF-IDF, e os conjuntos de palavras-atributo utilizados foram os conjuntos de palavras relacionadas a *péssimo* e *ótimo* gerados por Sales, Balby e Veloso em [14], disponíveis em seu repositório no GitHub⁵ e expostos na tabela 4. Os conjuntos de palavras relacionadas a *péssimo* e *ótimo* foram escolhidas como atributos pois contêm palavras que representam aspectos negativos e positivos, respectivamente.

A pauta selecionada para a realização do experimento foi a Reforma da Previdência. Esta pauta foi escolhida devido à repercussão causada na mídia, ao envolvimento de muitos parlamentares em sua criação e às mudanças significativas em relação à aposentadoria. A figura 4 mostra a variação do interesse sobre a pauta durante o ano de 2019.

⁴Um vetor onde cada dimensão representa uma palavra do vocabulário. Para uma palavra específica, o valor de cada dimensão será 1 na dimensão referente àquela palavra e 0 nas demais.

⁵<https://github.com/allansales/bias-in-brazilian-elections/tree/master/word-association>

²<https://www.nltk.org/>

³<https://radimrehurek.com/gensim/models/word2vec.html>

Tabela 3: Exemplo da aplicação dos pré-processamentos utilizados nos *tweets*

<i>tweet</i> original	<i>tweet</i> pré-processado
João Gilberto: “ o apagar da velha chama” de uma lenda da música brasileira!	[‘joão’, ‘gilberto’, ‘apagar’, ‘velha’, ‘chama’, ‘lenda’, ‘música’, ‘brasileira’]

Tabela 4: Conjuntos de palavras similares para *péssimo* e *ótimo*.

Atributo	Conjunto
péssimo 1	mau, equivocado, adiantado, preconceituoso, infeliz, injusto, atrasado, inesperado, doloroso, absurdo, triste, incerto, violento
péssimo 2	mau, precário, lamentável, equivocado, desconfortável, desastroso, desfavorável
péssimo 3	mau, equivocado, deprimido, desastroso, isento, preconceituoso, infeliz, desorganizado
ótimo 1	excelente, destacado, interessante, melhor, melhorado, lindo, unico, excepcional, talentoso, inovador, bacana, impressionante, ideal
ótimo 2	excelente, destacado, interessante, melhor, importantíssimo, excepcional, inovador
ótimo 3	excelente, destacado, interessante, melhor, unico, excepcional, inovador, bacana



Figura 4: Interesse ao longo do ano de 2019 sobre a Reforma da Previdência. Fonte: Google Trends

Os conjuntos de palavras-alvo foram formados pelas palavras mais relevantes, de acordo com o TF-IDF, dos *tweets* sobre a pauta em questão dos deputados federais Sâmia Bomfim (PSOL-SP), Eduardo Bolsonaro (PSL-SP), Felipe Rigoni (PSB-ES) e Tabata Amaral (PDT-SP). Os deputados Sâmia Bomfim e Eduardo Bolsonaro foram escolhidos por apresentarem posicionamentos sabidamente contrários em relação a várias outras pautas além da escolhida, e os deputados Felipe Rigoni e Tabata Amaral foram escolhidos por manterem posições contrárias ao seus respectivos partidos com relação à Reforma da Previdência.

A partir disso, procuramos, aqui, associações entre os tweets de deputados federais sobre uma pauta e conceitos que denotam ideias antagônicas. Por exemplo, considerando a Reforma da Previdência, os tweets de Sâmia Bomfim sobre a pauta são mais associados à *péssimo* ou *ótimo*? E os de Eduardo Bolsonaro? E para os deputados

Felipe Rigoni e Tabata Amaral, identificamos as mesmas associações? As diferenças entre essas associações podem ser utilizadas para medir, através de seus *tweets*, o alinhamento de um deputado a pautas políticas.

3.5 Experimento

O WEAT foi aplicado considerando o seguinte modelo: Alvo X vs. Alvo Y em relação a *péssimo* vs. *ótimo*, onde X e Y são instanciados como os *tweets* mais relevantes de dois deputados sobre uma pauta, e *péssimo* e *ótimo* são conjuntos de palavras-atributo semanticamente semelhantes a *péssimo* e *ótimo*, respectivamente. A figura 5 ilustra o conjunto de palavras-alvo para a deputada Sâmia Bomfim sobre previdência. O teste foi realizado para diferentes combinações dos conjuntos atributos utilizados. As combinações estão descritas na tabela 5.

Tabela 5: Conjuntos de palavras-atributo utilizados em cada experimento

Experimento	Conjuntos
1	péssimo 1 vs. ótimo 1
2	péssimo 1 vs. ótimo 2
3	péssimo 1 vs. ótimo 3
4	péssimo 2 vs. ótimo 1
5	péssimo 2 vs. ótimo 2
6	péssimo 2 vs. ótimo 3
7	péssimo 3 vs. ótimo 1
8	péssimo 3 vs. ótimo 2
9	péssimo 3 vs. ótimo 3



Figura 5: Palavras mais relevantes nos *tweets* de Sâmia Bomfim sobre Previdência.

4 RESULTADOS

Qualquer valor diferente de zero nos resultados do WEAT indica viés. Considerando o modelo alvo X vs. alvo Y com relação ao atributo A vs. atributo B , se o valor do WEAT for positivo, então X

está enviesado para A e Y para B, e o inverso acontece se este valor for negativo.

As figuras 6 e 7 mostram os resultados da execução do WEAT para cada experimento realizado. Estes experimentos utilizaram palavras dos *tweets* dos deputados escolhidos sobre a Reforma da Previdência como conjuntos de palavras-alvo em relação a uma combinação diferente de conjuntos de palavras-atributo.

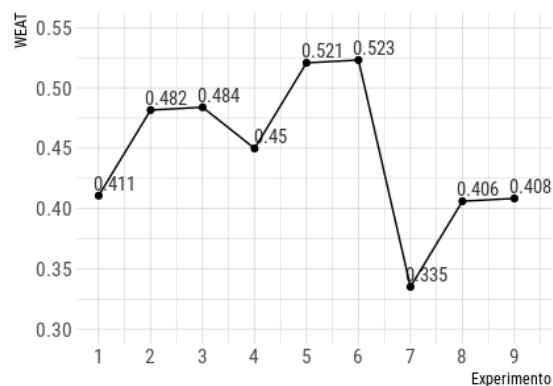


Figura 6: Resultados da execução do WEAT para os *tweets* de Sâmia Bomfim e Eduardo Bolsonaro sobre a Reforma da Previdência. Fonte: elaborado pelo autor.

Na figura 6, os experimentos realizados no modelo *Sâmia vs. Eduardo* com relação à *péssimo vs. ótimo* mostram que os *tweets* de Sâmia Bomfim estão mais associados às palavras do conjunto *péssimo* e os *tweets* de Eduardo Bolsonaro estão mais associados às palavras do conjunto *ótimo* para todas as combinações de conjuntos de palavras-atributo, visto que este valor é sempre positivo, mesmo variando entre cada combinação. Os maiores valores do WEAT foram para a combinação de conjuntos *péssimo 2 vs. ótimo 2* e *péssimo 2 vs. ótimo 3*. A tabela 6 contém uma sumarização dos resultados encontrados em termos de média, mediana e desvio padrão.

Tabela 6: Sumarização dos resultados da aplicação do WEAT para Sâmia Bomfim e Eduardo Bolsonaro

Medida	Valor
Média	0.44657
Mediana	0.44977
Desvio Padrão	0.062081

As medidas descritas na tabela mostram que, de forma geral, Sâmia Bomfim utiliza palavras mais associadas aos conjuntos de palavras-atributo que refletem características negativas (*péssimo*), enquanto que Eduardo Bolsonaro utiliza palavras mais associadas a características positivas (*ótimo*).




Figura 7: Resultados da execução do WEAT para os *tweets* de Felipe Rigoni e Tabata Amaral sobre previdência. Fonte: elaborado pelo autor.

Nos experimentos realizados para o modelo *Felipe vs. Tabata* com relação a *péssimo vs. ótimo*, cujos resultados estão expostos no gráfico da figura 7, o conjunto ao qual as palavras mais relevantes de seus *tweets* sobre a Reforma da Previdência estão mais associados diferem para algumas combinações de conjuntos de palavras-atributo. Durante os três primeiros experimentos considerando diferentes combinações de *péssimo 1*, como os valores do WEAT são negativos, podemos dizer que os *tweets* de Felipe Rigoni estão mais associados às palavras do conjunto *ótimo* e os *tweets* de Tabata associados às palavras do conjunto *péssimo*. Porém, para as combinações considerando os conjuntos *péssimo 2* e *péssimo 3*, os resultados invertem-se, pois o resultado do WEAT para os experimentos com esses conjuntos são todos positivos.

Considerando os posicionamentos dos deputados sobre a Reforma da Previdência, ambos argumentam que, embora discordem de alguns pontos no texto da reforma, contribuíram para a sua melhoria⁶, o que pode ser verificado nos resultados do WEAT para os *tweets* destes deputados sobre a pauta. De forma geral, como observado no gráfico da figura 7 e descrito na tabela 7, os valores do WEAT variam entre positivos e negativos para diferentes combinações de conjuntos de palavras-atributo através de valores próximos a zero, porém com média e mediana positivas. Esses valores indicam que as palavras utilizadas por Felipe Rigoni em *tweets* sobre a Reforma da Previdência associam-se mais aos conjuntos de palavras-atributo que representam características negativas, enquanto Tabata Amaral utiliza palavras mais associadas aos conjuntos que representam características positivas.

5 CONCLUSÃO

Os resultados obtidos através dos experimentos realizados mostram que o WEAT consegue medir o alinhamento de um político a

⁶<https://www1.folha.uol.com.br/poder/2019/07/sob-ameaca-de-expulsao-dissidentes-enfrentam-partidos-por-previdencia.shtml>

Tabela 7: Sumarização dos resultados da aplicação do WEAT para Felipe Rigoni e Tabata Amaral

Medida	Valor
Média	0.096023
Mediana	0.126389
Desvio Padrão	0.1611241

pautas políticas através de seus *tweets*. A utilização de *word embeddings* treinados utilizando dados de notícias sobre política possibilitaram que essas representações capturassem aspectos semânticos inerentes ao escopo utilizado.

Nos experimentos realizados para deputados com posicionamentos sabidamente opostos sobre Reforma da Previdência, os resultados do WEAT mostram que os *tweets* de Sâmia Bomfim associam-se mais a conjuntos que representam aspectos negativos e que os de Eduardo Bolsonaro estão mais associados aos conjuntos que representam aspectos positivos. Em outras palavras, Sâmia Bomfim alinha-se negativamente à reforma, enquanto Eduardo Bolsonaro alinha-se positivamente, o que coincide com como cada deputado votou durante o segundo turno⁷ da avaliação da proposição.

Já nos experimentos realizados para os deputados cujos posicionamentos sobre Reforma da Previdência contrariaram os definidos pelos seus partidos, os valores do WEAT variavam entre positivos e negativos, porém próximos a zero. Isto se deve ao fato de que ambos os deputados teciam críticas a certos pontos do texto da reforma enquanto contribuía na melhoria de outros. No geral, o WEAT, para a maioria dos experimentos, alinhou os *tweets* de Felipe Rigoni sobre a pauta em questão aos conjuntos de palavras que representam aspectos negativos, enquanto que os *tweets* de Tabata Amaral alinham-se aos conjuntos de palavras que representam aspectos positivos.

A metodologia empregada no presente trabalho pode ser utilizada em situações em que o alinhamento de um político em relação a alguma pauta ainda não é conhecido, como um modelo de predição. Para trabalhos futuros, o mesmo método poderia ser aplicado considerando partidos políticos como alvos para medir o alinhamento de um partido a uma pauta.

REFERÊNCIAS

- [1] Jayesh Bapu Ahire. 2018. Introduction to Word Vectors. <https://medium.com/@jayeshbahire/introduction-to-word-vectors-ea1d4e4b84bf>. Online; acessado em 10 out. 2019.
- [2] Jon Ezeiza Alvarez and Hannah Bast. 2017. A review of word embedding and document similarity algorithms applied to academic text.
- [3] Fabricio Benevenuto, Filipe Ribeiro, and Matheus Araújo. 2015. Métodos para análise de sentimentos em mídias sociais. In *Brazilian Symposium on Multimedia and the Web (Webmedia), Manaus, Brasil*.
- [4] Ludovico Boratto, Salvatore Carta, Gianni Fenu, and Roberto Saia. 2016. Using neural word embeddings to model user behavior and detect user segments. *Knowledge-based systems* 108 (2016), 5–14.
- [5] Aylin Caliskan, Joanna Bryson, and Arvind Narayanan. 2017. Semantics derived automatically from language corpora contain human-like biases. *Science* 356 (04 2017), 183–186.
- [6] Gobinda G Chowdhury. 2003. Natural language processing. *Annual review of information science and technology* 37, 1 (2003), 51–89.
- [7] Fernando Enríquez, José A Troyano, and Tomás López-Solaz. 2016. An approach to the use of word embeddings in an opinion classification task. *Expert Systems with Applications* 66 (2016), 1–6.
- [8] Câmara Federal. 2019. Dados Abertos da Câmara Federal. <https://dadosabertos.camara.leg.br/>. Online; acessado em 30 out. 2019.
- [9] Todd Graham, Daniel Jackson, and Marcel Broersma. 2018. The personal in the political on Twitter: Towards a typology of politicians' personalized Tweeting behaviours. In *Managing democracy in the digital age*. Springer, 137–157.
- [10] Omer Levy and Yoav Goldberg. 2014. Dependency-based word embeddings. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*. 302–308.
- [11] Francisco Paulo Jamil Marques, Jackson Alves de Aquino, and Edna Miola. 2014. Deputados brasileiros no Twitter: um estudo quantitativo dos padrões de adoção e uso da ferramenta. (2014).
- [12] Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. 2013. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781* (2013).
- [13] Information Retrieval and Text Mining. [n. d.]. Tf-idf: A Single-Page Tutorial. <https://dadosabertos.camara.leg.br/>. Online; acessado em 02 nov. 2019.
- [14] Allan Sales, Leandro Balby, and Adriano Veloso. 2019. Media Bias Characterization in Brazilian Presidential Elections. In *Proceedings of the 30th ACM Conference on Hypertext and Social Media*. ACM, 231–240.
- [15] Twitter. 2019. Rate limiting - Twitter Developers. <https://developer.twitter.com/en/docs/basics/rate-limiting>. Online; acessado em 30 out. 2019.
- [16] Alper Kursat Uysal and Serkan Gunal. 2014. The impact of preprocessing on text classification. *Information Processing Management* 50, 1 (2014), 104 – 112. <http://www.sciencedirect.com/science/article/pii/S0306457313000964>

⁷<http://especiais.g1.globo.com/politica/2019/o-voto-dos-deputados/>