

Pesquisa Eleitoral em Redes Sociais: Inclusão da Análise de Novas Dimensões *

Renato Miranda Filho^{1,2}, Jussara M. Almeida¹, Gisele L. Pappa¹

¹Departamento de Ciência da Computação
Universidade Federal de Minas Gerais (UFMG)
CEP 31270-010 – Belo Horizonte – MG – Brasil

²Instituto Federal de Minas Gerais (IFMG)
CEP 34515-640 – Sabará – MG – Brasil

{renato.miranda, jussara, glpappa}@dcc.ufmg.br

Abstract. *This paper aims to use public data from social networks to conduct election surveys and studies. Although prior work has already focused on this task, none has taken into account the unique user identification together with inherent factors of the virtual environment, such as sentiment analysis of messages, detection of spammers as well as of journalistic content. Our experimental results show that more elaborate analyses are able to improve the numbers achieved by the method used in other works.*

Resumo. *Este trabalho tem como principal objetivo utilizar dados públicos de redes sociais para realizar pesquisas (análises) eleitorais. Embora alguns trabalhos já tenham focado nessa tarefa, nenhum deles levou em consideração a identificação de usuários únicos aliada a fatores inerentes do ambiente virtual, tais como a análise de sentimentos das mensagens, a detecção de spammers e de conteúdo jornalístico. Os resultados alcançados mostram que análises mais elaboradas são capazes de melhorar os números alcançados pela metodologia empregada em outros trabalhos.*

1. Introdução

Apesar de terem sido inicialmente criadas como meios de comunicação de caráter interpessoal, focando nos contatos entre pessoas e na discussão sobre os assuntos de suas preferências, as redes sociais se tornaram uma fonte de informação riquíssima para acompanhar o que essa população virtual pensa ou vive nos mais diversos contextos, tornando-se, algumas vezes, um instrumento de utilidade pública.

Diversos trabalhos utilizaram dados provenientes de redes sociais para prever resultados de eleições [Tumasjan et al. 2010, Jungherr et al. 2012, Gayo-Avello et al. 2011, Gayo-Avello 2012], padrões de disseminação de doenças [Gomide et al. 2011], ou oferecer a empresas uma visão geral do que o consumidor pensa sobre ela e seus produtos [Culnan et al. 2010]. O impacto das redes sociais virtuais é tamanho que empresas têm hoje departamentos especializados em marketing e relações do consumidor em redes sociais.

*Este trabalho foi parcialmente financiado pela Fapemig, CNPq, CAPES e InWeb.

Se avaliarmos os trabalhos que se propuseram a realizar pesquisas eleitorais por meio de dados coletados em redes sociais verificamos que eles normalmente são baseados em técnicas de contagem. Assim, nenhum deles levou em consideração simultaneamente pontos importantíssimos em análises dessa natureza, tais como: (i) características comportamentais dos usuários (por exemplo, usuários *spammers* e usuários que postam conteúdos jornalísticos deveriam ser desconsiderados destas análises); e (ii) o sentimento das mensagens postadas, uma vez que o texto coletado normalmente não está estruturado.

Com o objetivo de avaliar o impacto dos pontos mencionados acima para a realização de pesquisas eleitorais, este artigo considera o contexto das eleições municipais de 2012 com dados coletados no Twitter referentes aos pleitos de seis municípios: São Paulo (SP), Rio de Janeiro (RJ), Belo Horizonte (MG), Curitiba (PR), Salvador (BA) e Porto Alegre (RS). Assim, após coletar as mensagens referentes aos pleitos ou candidatos das cidades mencionadas, o método identifica cada usuário, caracterizado por um perfil no Twitter, infere e remove usuários considerados *spammers* e jornalísticos e contabiliza os votos conforme o sentimento identificado nas mensagens postadas.

Nós comparamos o número total de acertos da estratégia proposta com os acertos de uma abordagem baseada na contagem de menções, utilizada pela grande maioria dos métodos, assim como com o total de acertos obtidos por institutos tradicionais de pesquisa (IBOPE e DataFolha). Nossos resultados indicam que, comparando com a abordagem baseada na contagem de menções, a estratégia proposta acerta os vencedores de mais cidades, são elas: Belo Horizonte, Salvador e São Paulo, enquanto o método concorrente acertou apenas em Belo Horizonte e Salvador. Mais ainda, embora a abordagem proposta acerte menos que os institutos tradicionais, verificamos que existem cenários nos quais os institutos erraram e a técnica proposta acertou como, por exemplo, Salvador. Tais cenários demonstram que a abordagem proposta pode ser considerada uma técnica complementar para a realização de pesquisas eleitorais.

O resto do artigo está estruturado da seguinte forma, A Seção 2 apresenta alguns trabalhos que serviram de base para este artigo. A Seção 3 descreve o método proposto. A Seção 4 relata os resultados obtidos e a Seção 5 apresenta as conclusões e propostas de continuidade deste trabalho.

2. Trabalhos Relacionados

Dado o grande volume de informação disponível, as redes sociais estão sendo cada vez mais exploradas para monitorar e prever eventos no mundo real como, por exemplo, eleições. Imerso no cenário do pleito parlamentar da Alemanha, ocorrido em 2009, [Tumasjan et al. 2010] observaram que o Twitter é utilizado como uma plataforma para deliberações políticas, inclusive com características de discussões e trocas de ideias. Além disso, os autores também argumentaram que, como preditor do resultado das eleições, a simples contagem de menções aos partidos ou candidatos é capaz de acompanhar pesquisas eleitorais tradicionais e acertar com exatidão o resultado final da eleição. Este trabalho também realizou a análise de sentimentos das mensagens coletadas, traduzindo elas para o inglês e submetendo o texto ao *software* LIWC2007 (*Linguistic Inquiry and Word Count*). Como resultado foi observado que o comportamento dos eleitores se aproxima das ideias difundidas pela campanha eleitoral como, por exemplo, retratando coalisões ou ataques.

Já em [Jungherr et al. 2012] os autores realizaram um experimento sobre as

eleições federais da Alemanha de 2009 com a técnica proposta por [Tumasjan et al. 2010] e não validaram a afirmativa de que é possível prever o resultado final do pleito com a contagem de menções. Os autores apontaram algumas limitações de tal técnica como, por exemplo, a falta de regras bem fundamentadas para a coleta, da escolha dos partidos e do período de tempo correto que deveria se avaliar. O trabalho realizado por [Gayo-Avello et al. 2011] também coloca em xeque o poder preditivo de eleições pelas redes sociais. Neste trabalho, os autores analisaram *tweets* coletados sobre as eleições de 2010 para o congresso americano e não observaram nenhuma relação entre os resultados inferidos a partir dos *tweets* e os resultados eleitorais.

[Gayo-Avello 2012] realizaram uma pesquisa bibliográfica sobre trabalhos que têm como objetivo a previsão eleitoral com base em dados coletados do Twitter, e focaram sua análise em falhas e limitações das abordagens já empregadas. Algumas delas são: i) limitação nas abordagens de contagem de voto, em que muitas vezes é utilizado somente o volume bruto de *tweets* ou de usuários únicos que citaram os candidatos; (ii) análise de sentimento do conteúdo dos *tweets* realizada de forma ingênua; e (iii) falta de emprego de técnicas para detectar boatos e informações falsas.

Um comportamento relevante que devemos identificar e filtrar, tanto quanto possível, da análise é a atuação de usuários *spammers*. Para tal, nós utilizaremos a técnica proposta em [Benevenuto et al. 2010]. Neste trabalho, os autores fizeram um estudo extenso das características das contas de usuários do Twitter cujas mensagens continham palavras típicas ou URLs referentes a termos do *trending topics*. Os usuários foram rotulados manualmente como sendo *spammers* ou não *spammers*, e depois utilizados em um processo de classificação com o método *Support Vector Machine* (SVM). Outros trabalhos, tais como [Lumezanu et al. 2012], também investigaram o comportamento de propagandistas no Twitter identificando padrões nas mensagens que poderiam caracterizar este tipo de comportamento. [Ghosh et al. 2012] identificaram como ocorre a aquisição de seguidores por parte dos usuários *spammers* no Twitter. Já [McCord and Chuah 2011] analisaram a eficácia diferentes algoritmos de classificação, a saber *Random Forest*, SVM, *Naive Bayes* e *K-Nearest Neighbor* (KNN) na tarefa de detectar *spammers* no Twitter, concluindo que o melhor classificador é o *Random Forest*. Nesse trabalho mostramos que o *Random Forest* realmente se comporta melhor que o SVM para o problema em questão.

Outra grande deficiência recorrente em monitoramento e previsões de eventos é a falta de mecanismos utilizados para distinguir, por exemplo, uma simples menção a um candidato de um voto. Assim, a solução proposta neste trabalho é utilizar um método para análise de sentimentos nesta tarefa. A análise de sentimentos de conteúdo textual é abordada em vários trabalhos anteriores. Por exemplo, [Mukherjee et al. 2012] propuseram um sistema multi-etapas, denominado TwiSent. Neste trabalho, os autores abordam alguns problemas inerentes à tarefa de identificar os sentimentos dos *tweets*, tais como: (i) presença de usuários *spammers*; (ii) anomalias no texto como, por exemplo, grafia incorreta; e (iii) a especificidade de entidades no contexto do tema pesquisado.

Já o trabalho apresentado em [Bora 2012] propõe uma abordagem para rotulagem de sentimentos que consiste no uso de um conjunto com 40 palavras de sentimento sugestivo, positivo ou negativo, como um rótulo ruidoso para então treinar um classificador *Naive Bayes*. Uma comparação abordando oito diferentes métodos para análise de sentimentos é realizada por [Gonçalves et al. 2013]. Foi verificado que nenhum dos métodos

avaliados pode ser considerado o melhor independente da fonte do texto. Diversas dessas abordagens foram testadas nesse trabalho, e serão detalhadas na próxima seção.

3. Um Método para Previsão de Eleições no Twitter




Figura 1. Esquema para pesquisa eleitoral

A Figura 1 ilustra o método empregado para melhorar os resultados de previsões eleitorais de forma a não focar somente em menções aos candidatos, mas também abordar outros fatores inerentes do meio virtual. Ele consiste em quatro etapas: (i) preparação dos dados; (ii) identificação da intenção do voto, por meio da análise de sentimento das mensagens postadas pelos usuários; (iii) identificação de usuários legítimos, com a caracterização comportamental dos indivíduos; e (iv) análise dos resultados. A segunda e a terceira etapas representam as maiores contribuições deste trabalho. As próximas subseções detalham como cada uma dessas fases foram implementadas.

3.1. Preparação dos dados

Foram escolhidas 6 capitais de estado para serem analisadas, com base no total de tweets coletados durante o período de análise e na importância econômica das regiões, são elas: Belo Horizonte (MG), Curitiba (PR), Porto Alegre (RS), Rio de Janeiro (RJ), Salvador (BA) e São Paulo (SP). A partir deste momento representaremos os nomes das cidades pelas siglas de seus respectivos estados.

Após definidas as cidades, foi definido um conjunto de termos capazes de identificar cada candidato, como seus nomes. A etapa seguinte foi a coleta dos *tweets* contendo estes termos. Esta coleta foi realizada por meio da API disponibilizada pelo próprio Twitter¹, em que, no fluxo de mensagens, são filtradas aquelas de interesse. Foram então identificados os usuários que postaram as mensagens. A fim de se analisar o comportamento destes usuários, também foram coletados os últimos 200 *tweets* de cada um deles.

Ao total foram coletados 1,295,418 tweets, publicados por 222,412 usuários distintos, entre os dias 18 de julho de 2012 e 17 de outubro de 2012. Em média, cada um destes usuários postou 5.8 *tweets* com algum termo relacionado a um candidato, com uma mediana de 1. O usuário mais frequente postou 5,072 mensagens e o menos frequente 1.

O período de análise das votações foi considerado como as 10 semanas que antecederam ao pleito, ou seja, entre os dias 29 de julho de 2012 e 6 de outubro de 2012. Isto foi feito para evitar possíveis flutuações anormais causadas, por exemplo, pela repercussão dos últimos debates eleitorais. Desta forma, consideramos as últimas 10 semanas com peso linearmente crescente para os votos computados, ou seja, a semana 1 com peso 1, a semana 2 com peso 2, e assim sucessivamente.

¹<http://dev.twitter.com/>

Antes de definirmos este período, avaliamos diversos outros cenários, dentre eles: 1 ou 2 dias, onde pouquíssimos votos eram computados, e o período completo de coleta sem atribuição de pesos, onde acontecimentos momentâneos como, por exemplo, debates eleitorais, interferiam significativamente nos resultados alcançados.

O pré-processamento do texto dos *tweets* consistiu na remoção de acentos, pontuações e palavras conhecidas como *stop-words*, que representam, por exemplo, a classe de palavras dos artigos.

3.2. Análise de sentimentos

Como mostrado na Figura 1, nesta etapa estamos interessados em responder perguntas como: i) qual a opinião do indivíduo? O que o indivíduo pensa? Para tanto, será realizada uma análise de sentimentos nos *tweets* coletados.

Foi observado na literatura que existe uma grande gama de métodos para realização de análises desta natureza. Além disto, os autores de [Gonçalves et al. 2013] observaram que a eficácia de diferentes técnicas varia muito com a fonte do texto analisado, não sendo encontrado nenhum método que ganhasse em todos os cenários possíveis. Logo, considerando as inúmeras aplicações práticas para aplicar tais técnicas, este ainda é um campo fértil para novos estudos.

Entre os métodos mais utilizados para a realização de análise de sentimentos em mensagens de *micro-blogs* estão os seguintes:

- Dicionários léxicos: conjunto de palavras previamente rotuladas como positivas, negativas ou neutras, em que, conforme as ocorrências, indicam as polaridades das mensagens analisadas.
- Algoritmos supervisionados com mensagens classificadas manualmente.
- Algoritmos supervisionados com rótulos baseados em indicadores de emoção, como os *emoticons*.

Neste trabalho, analisamos mensagens que se referem apenas a uma entidade, ou seja, um único candidato. Além disso, utilizamos uma abordagem baseada em um comitê de classificação, onde os *tweets* são rotulados conforme a polaridade indicada pela maioria de três classificadores: léxico, supervisionado com rotulação manual e supervisionado com rotulação automática. Cada classificador atribui +1, caso a mensagem seja positiva, ou -1, caso seja negativa. O classificador léxico também poderá atribuir voto 0 caso nenhum termo rotulado pelo seu dicionário seja encontrado na mensagem analisada ou haja um empate entre termos rotulados como positivos e negativos. Se a soma for positiva a mensagem é considerada positiva. Se a soma for negativa a mensagem é considerada negativa. Caso a soma seja zero a mensagem é descartada das análises. Mais detalhes sobre os classificadores são apresentados nas subseções a seguir.

3.2.1. Dicionário Léxico

Como mencionado anteriormente, o dicionário léxico é formado por um conjunto de palavras rotuladas como representantes de sentimentos positivos, negativos ou neutros. Existem diversos dicionários do idioma inglês bem consolidados para tal tarefa como o MPQA

*Opinion Corpus*² e o *General Inquirer*³. Porém, o mesmo não ocorre para o português, idioma alvo deste trabalho.

Para o português, encontramos na literatura dicionários, por exemplo, constituídos a partir da extração de termos em *blogs* com comentários sobre componentes de veículos [Ribeiro Jr. et al. 2012], ou seja, com termos muito específicos de um dado contexto diferente do avaliado por este trabalho.

Assim, rotulamos um conjunto inicial de palavras específicas para o cenário de eleições com sentimentos positivos ou negativos. Este conjunto foi definido observando o contexto dos *tweets* coletados. Para as eleições verificou-se que normalmente são usados termos para designar a conduta política do candidato ou a vontade do eleitor, tais como “ladrão” e “corrupto” para sentimento negativo, e “apoio” e “voto” para positivo.

Uma prática comum que é realizada em trabalhos deste tipo, para aumentar a cobertura dos termos, é expandir o dicionário inicialmente desenvolvido por dicionários de sinônimos de palavras. Desta forma, expandimos o conjunto inicialmente criado pelo dicionário de sinônimos Dicio⁴ e removemos duplicatas, ou seja, termos que aparecem nas duas listas finais. Obtivemos como resultado um dicionário composto por 194 termos positivos e 292 negativos.

3.2.2. Algoritmo supervisionado - Rotulação manual

Algoritmos supervisionados utilizam informações obtidas por meio de conteúdos rotulados, previamente identificados, para amostras de treino na tarefa de aprendizagem e, então, generalizam as observações feitas para classificar novos dados. Nesta etapa, utilizamos como treinamento um conjunto de 200 *tweets* distintos escolhidos aleatoriamente e rotulados manualmente como positivo ou negativo.

Quatro classificadores foram avaliados: i) SVM; ii) *Random Forest*; iii) *Naive Bayes*; e iv) *Naive Bayes Multinomial*. Todos os resultados foram obtidos usando as versões Weka destes classificadores [Witten and Frank 2005]. O *Naive Bayes Multinomial* (NBM) foi escolhido por ser extremamente rápido e apresentar bons resultados com texto, e o SVM e *Random Forest* por estarem entre os classificadores estado da arte. Em todos os classificadores foram utilizados os parâmetros padrão. Os experimentos foram realizados utilizando um procedimento de validação cruzada de cinco partições.

Os resultados obtidos são apresentados na Tabela 1. Considerando que a melhor taxa de acerto foi obtida pelo algoritmo *Naive Bayes* (80.5%), este será utilizado nesta etapa da análise de sentimentos dos *tweets*.

3.2.3. Algoritmo supervisionado - Rotulação automática

Conforme mostrado por [Hu et al. 2013], indicadores de emoção sugerem que o sentimento contido em uma mensagem é consistente com os sinais presentes nela. Neste

²http://www.cs.pitt.edu/mpqa/opinionfinder_1.html

³<http://www.wjh.harvard.edu/~inquirer/>

⁴<http://www.dicio.com.br>

Tabela 1. Análise de sentimentos - Acurácia obtida com algoritmos supervisionados (%)

Método	Rotulação manual	Rotulação automática
SVM	62.5	65.85
<i>Random Forest</i>	75.5	69.95
<i>Naive Bayes</i>	80.5	67.8
<i>Naive Bayes Multinomial</i>	78	74.8

trabalho utilizamos os *emoticons* “:)” e “:-)” para denotar a polaridade positiva de uma mensagem e “:(” e “:-(” para polaridade negativa. Assim, mensagens com esses símbolos foram automaticamente classificadas como positivas ou negativas, e depois utilizadas como dados de treinamento para um classificador supervisionado.

Dentre as mensagens rotuladas, escolhemos 1,000 distintas de forma aleatória para cada classe, resultando em 2,000 *tweets*, utilizados para treinar os classificadores apresentados na subseção 3.2.2. Os textos de cada mensagem passaram por um pré-processamento em que foram retiradas *stop-words*, pontuações, *emoticons* e termos com frequência menor que três no conjunto, resultando em um total de 1,062 diferentes palavras para descrever a base de dados.

Os resultados de classificação obtidos, considerando um processo com validação cruzada de 5 *folds*, é apresentado na Tabela 1. Considerando que a melhor taxa de acerto foi obtida pelo algoritmo *Naive Bayes Multinomial* (74.8%), este será utilizado nesta etapa da análise de sentimentos dos *tweets*.

3.2.4. Método baseado em comitê de classificação

Como mencionado, nós propomos um método que combina as três abordagens descritas nas seções anteriores - dicionário léxico, *Naive Bayes* com rotulação manual e *Naive Bayes Multinomial* com rotulação automática - por meio de um comitê de classificação. Para avaliarmos o método proposto, comparando-o com os métodos aplicados individualmente, utilizamos 200 *tweets* distintos escolhidos aleatoriamente e rotulados manualmente como positivo ou negativo. Assim, avaliamos a cobertura, ou seja, porcentagem de *tweets* não classificados como neutros, e a acurácia provida por cada método. Os resultados obtidos são mostrados na Tabela 2.

Como podemos observar, o dicionário léxico construído foi capaz de prover uma boa acurácia. No entanto, tal método possui uma baixa cobertura: apenas 43% das mensagens selecionadas foram classificadas como positivas ou negativas.

O método capaz de prover a melhor acurácia foi o classificador supervisionado com mensagens de treinamento rotuladas manualmente. Porém, devido à pouca quantidade de *tweets* rotulados para a etapa de treinamento optamos por utilizar o Comitê de classificação em nosso trabalho, por ser capaz de alcançar uma boa acurácia e uma cobertura razoável. A cobertura do Comitê é menor que as coberturas obtidas com os métodos supervisionados, pois quando ocorre divergência entre rótulos atribuídos pelos diversos classificadores e a soma final é 0 a mensagem é ignorada.

Tabela 2. Análise de sentimentos - avaliação dos métodos

Método	Acurácia (%)	Cobertura (%)
Dicionário Léxico (L)	74.7	43
Supervisionado manualmente (RM)	80.5	100
Supervisionado automaticamente (RA)	63.5	100
Comitê	80.3	79

3.3. Caracterização comportamental

Como mostrado na Figura 1, nesta etapa estamos interessados em responder perguntas como: i) posso confiar no usuário? O perfil é verdadeiro? É um propagandista? É um difusor de conteúdo jornalístico? Esta análise serve para excluirmos de nossas avaliações usuários indesejáveis, ou seja, aqueles cujos *tweets* não representam a opinião de um indivíduo, mas que possuem outras finalidades.

Nesse trabalho, são considerados usuários *spammers* aqueles com interesse de difundir vírus, pornografia ou propagandas. Os usuários jornalísticos, por sua vez, são indivíduos ou organizações que publicam conteúdos jornalísticos, ou seja, conteúdos cuja finalidade seja a difusão de notícias e não de opinião de indivíduos específicos. Assim, consideramos usuários legítimos todos os demais usuários (ou seja, usuários que não são considerados como *spammers* ou jornalísticos).

Para identificarmos a primeira categoria de usuários mencionada foi utilizada a base de dados desenvolvida por [Benevenuto et al. 2010], em que foram manualmente rotulados como *spammers* e não *spammers* um conjunto de 1,065 usuários. Tais usuários são descritos por 62 atributos retratando, por exemplo, a média de *tweets* postados com URL e a média de *tweets* postados com *hashtags*. No trabalho utilizado como referência foi avaliado o poder de classificação dos usuários *spammers* com o algoritmo SVM.

Neste trabalho, além de reproduzirmos os resultados alcançados anteriormente, também avaliamos os algoritmos KNN, *MultiLayer Perceptron* (MLP) e *Random Forest* (RF), utilizando implementações disponibilizadas pela ferramenta Weka com uma validação cruzada de 5 *folds*. Os parâmetros do SVM foram otimizados de forma idêntica ao trabalho anterior, por meio da ferramenta easy provida pelo pacote libSVM, chegando aos seguintes valores: $c = 32.0$ e $g = 0.0078125$.

Para os demais algoritmos foi utilizado a estratégia de projeto simples, ou seja, ignoramos a interação entre os fatores, variando um de cada vez e fixando o valor que proporcionou melhor resultado. Os valores utilizados são: (i) MLP: taxa de aprendizagem = 0.5, camadas escondidas = 1 e momentum = 0.1; (ii) KNN: $k = 10$ e métrica de similaridade = $1/\text{distância}$; e (iii) RF: número de árvores = 20 e profundidade = 10. O algoritmo que obteve os melhores resultados foi o *Random Forest*, tanto em termos de média F1 (0.88) quanto de acurácia (88.64%).

Fizemos ainda testes para reduzir a dimensionalidade da base de dados, utilizando os seguintes métodos para seleção de atributos: *Chi-squared*, *Information Gain* e Algoritmo Genético [Eiben and Smith 2003]. Comparando os 10 melhores atributos selecionados pelos dois primeiros algoritmos eles foram exatamente os mesmos. O mesmo foi observado para os 20 melhores atributos. Já o algoritmo genético selecionou atributos mais diversificados, quando comparado aos dois outros métodos, tendo produzido resultados superiores também. Uma lista completa dos atributos selecionados está disponível

online.⁵

Utilizando os 20 atributos selecionados pelo algoritmo genético no algoritmo de classificação *Random Forest* obteve-se uma média F1 de 0.90 e acurácia de 90.33%, resultado avaliado com 99% de confiança por um teste-t como sendo estatisticamente superior às demais abordagens avaliadas.

A fim de caracterizar usuários jornalísticos, foram coletados usuários que possuíam a substring “notícia” em seus *screen names*. Estes usuários foram representados utilizando os mesmos atributos definidos para as classes anteriores. O atributo “fração de *tweets* com palavras *spam*”, ou seja, palavras que constavam no *trending topics* do Twitter no período da coleta foi substituído por “número de seguidores por seguidos”, pois a relação de tais termos não estava disponível. Desta forma, executamos com o algoritmo *Random Forest*, utilizando os atributos selecionados, um conjunto rotulado de usuários *spammers*, jornalísticos e não *spammers*. Tal processo resultou em uma taxa média de acerto de 88.77%. Assim, a etapa de análise comportamental consistirá no algoritmo *Random Forest* treinado com a base rotulada contendo usuários *spammers*, jornalístico e não *spammers*, descritos por 20 atributos.

4. Resultados

Nossa análise irá focar na previsão do resultado para o acerto do primeiro lugar (p@1) – vencedor das eleições e para os dois primeiros lugares, candidatos que disputam o segundo turno. Como ponto de comparação serão utilizados os acertos encontrados diante dos resultados reais, resultados obtidos avaliando a menção simples e resultados de pesquisas de opinião realizadas pelos renomados institutos: Instituto Brasileiro de Opinião e Estatística⁶ (IBOPE) e DataFolha⁷.

A contabilidade dos votos atribuídos a cada candidato será computada conforme a Equação 1. Observe que são levados em consideração tanto votos positivos quanto negativos. Se um usuário publica mensagens positivas somente sobre um candidato seu voto é conferido a ele. Caso as mensagens publicadas por um usuário expresse um sentimento negativo somente sobre um candidato seu voto é distribuído igualmente entre os candidatos não citados.

$$Votos\ candidato_i = \frac{positivo_i + \sum_{j=1, i \neq j}^N \left(\frac{negativo_j}{N-1} \right)}{\sum_{j=1}^N positivo_j + \sum_{j=1}^N negativo_j} \quad (1)$$

Serão apresentados resultados considerando dois tipos de contabilização de votos: “menção” dos usuários, onde serão permitidos votos múltiplos oriundos de um único indivíduo e “usuários únicos”, em que será computado apenas um voto para cada usuário, que se refere a apenas um candidato durante o período analisado. Um usuário é equivalente a uma conta/perfil no Twitter.

Os resultados obtidos são apresentados na Tabela 3, para a avaliação do vencedor, e na Tabela 4, quando a intenção é descobrir os dois participantes que irão concorrer no

⁵http://www.dcc.ufmg.br/~renato.miranda/brasnam_eleicao.html

⁶<http://www.ibope.com.br/>

⁷<http://datafolha.folha.uol.com.br/>

segundo turno. Note que as duas primeiras colunas apresentam variações das dimensões consideradas (sentimento – Sen e SJ – spam e jornalismo). Quadrados de cor verde representam acertos, brancos os erros e pretos a não realização de pesquisas.

Tabela 3. Resultados Eleições - p@1 (Sen: análise de sentimento; SJ: remoção de usuários *spammers* e jornalísticos) - Quadrados de cor verde representam acertos, brancos os erros e pretos a não realização de pesquisa.

Característica		Resultado											
Sen	SJ	Menção						Usuário único					
		MG	PR	RS	RJ	BA	SP	MG	PR	RS	RJ	BA	SP
X													
	X												
X	X												
Institutos Tradicionais													
IBOPE		-	-	-	-	-	-						
DataFolha		-	-	-	-	-	-						

Tabela 4. Resultados Eleições - Segundo turno (Sen: análise de sentimento; SJ: remoção de usuários *spammers* e jornalísticos) - Quadrados de cor verde representam acertos, brancos os erros e pretos a não realização de pesquisa.

Característica		Resultado											
Sen	SJ	Menção						Usuário único					
		MG	PR	RS	RJ	BA	SP	MG	PR	RS	RJ	BA	SP
X													
	X												
X	X												
Institutos Tradicionais													
IBOPE		-	-	-	-	-	-						
DataFolha		-	-	-	-	-	-						

Como podemos observar, foi possível acertar em um maior número de cidades o vencedor das eleições utilizando o método completo, ou seja, análise de sentimento aliado à exclusão de usuários *spammers* e jornalísticos do que as tradicionais técnicas baseadas na contagem de menção simples. Se por um lado a estratégia do usuário único foi determinante para encontrar o vencedor do PR, ela também prejudicou a correta avaliação para a capital de RS, tanto para o vencedor quanto para os dois candidatos escolhidos para o segundo turno.

A cidade mais crítica para o IBOPE foi a capital de SP, em que não foi possível acertar nem o primeiro nem os dois primeiros colocados, pois foi divulgado empate entre os três primeiros candidatos. Outras cidades em que a pesquisa do IBOPE também falhou foram BA, para o primeiro colocado, e PR, para o segundo turno. Podemos observar que, dentre as 6 cidades escolhidas para análise, o Data Folha divulgou pesquisas em somente 5 delas, sendo que acertou todos os vencedores do primeiro turno nas cidades analisadas e para o segundo turno errou em SP e PR.

Comparando nossos resultados com os cenários mais complicados para os institutos tradicionais só foi possível a correta previsão para o vencedor de SP quando utilizada análise de sentimentos das mensagens, mas para os dois primeiros colocados nenhuma estratégia acertou. A previsão para BA superou o IBOPE, sendo correta em praticamente todos os cenários avaliados, desde a simples menção até o total de análise. A cidade com dados não divulgados pelo DataFolha foi exatamente essa.

Algumas das vantagens da abordagem proposta frente ao método de pesquisa utilizado pelos institutos tradicionais são: (i) redução de custos associados a tarefa de entrevistar indivíduos pessoalmente; (ii) não direcionamento da resposta, ou seja, não existe a figura de um entrevistador que poderá induzir o entrevistado acerca de determinada resposta; e (iii) maior escalabilidade do método, podendo facilmente ser coletadas e analisadas mensagens referentes aos mais diversos pleitos. Logo este tipo de pesquisa pode servir como ferramenta de apoio às pesquisas tradicionais.

Como esperado, prever corretamente os dois primeiros colocados nos pleitos é uma tarefa significativamente mais fácil que acertar somente o vencedor. Nestes casos, foram obtidos resultados semelhantes entre as abordagens avaliadas e os institutos tradicionais de pesquisa.

5. Conclusões e Trabalhos Futuros

Neste artigo apresentamos uma abordagem para realização de pesquisas eleitorais em redes sociais diferente dos métodos anteriormente propostos, que se resumiam na contagem de menções. Esta proposta leva em consideração a identificação de usuários únicos aliado a aspectos inerentes do ambiente virtual, tais como: (i) coleta e pré-processamento; (ii) análise comportamental; e (iii) análise de sentimento, sendo as duas últimas as principais contribuições do trabalho. Algumas importantes definições também foram criadas como, por exemplo, o tempo para coleta das mensagens, a caracterização de usuários legítimos e a diferenciação entre simples menções com a real intenção de voto a um candidato.

Comparando com a abordagem tradicional baseada na contagem de menções, acertamos em mais cidades os candidatos vencedores das eleições. Comparando o total de acertos dos institutos tradicionais frente a abordagem proposta, apesar de acertarmos menos, verificamos que existem cenários que acertamos facilmente e que os institutos tradicionais erraram.

Podemos considerar que os resultados obtidos apresentam uma opinião enviesada por usuários Twitter e, por isso, não foram capazes de alcançar fielmente as respostas reais. No entanto, esse resultado representa de forma mais confiável, comparando com os trabalhos já realizados, a opinião de uma importante parte da sociedade que está em constante crescimento, ou seja, indivíduos que usam redes sociais. Com isso, podemos concluir que a abordagem proposta pode ser um complemento às pesquisas de opinião tradicionais.

Como trabalhos futuros pretendemos desenvolver uma ferramenta para previsão eleitoral que trabalhe *online*, expandir o método proposto para eleições que abrangem grandes territórios como, por exemplo, pleitos presidenciais e estudar as interações entre usuários de diferentes regiões e suas intenções de votos utilizando, para tanto, técnicas de georreferenciamento.

Referências

- Benevenuto, F., Magno, G., Rodrigues, T., and Almeida, V. (2010). Detecting spammers on twitter. In *Collaboration, Electronic messaging, Anti-Abuse and Spam Conference (CEAS)*.
- Bora, N. N. (2012). Summarizing public opinions in tweets. In *Journal Proceedings of CICLing 2012, CICLing 2012*.

- Culnan, M. J., McHugh, P. J., and Zubillaga, J. I. (2010). How large u.s. companies can use twitter and other social media to gain business value. *MIS Quarterly Executive*, 9(4):243–259.
- Eiben, A. E. and Smith, J. E. (2003). *Introduction to Evolutionary Computing*. Springer-Verlag.
- Gayo-Avello, D. (2012). “I wanted to predict elections with twitter and all i got was this lousy paper” – A balanced survey on election prediction using twitter data. *CoRR* - <http://arxiv.org/abs/1204.6441>.
- Gayo-Avello, D., Metaxas, P., and Mustafaraj, E. (2011). Limits of electoral predictions using twitter. In *Int. Conf. on Weblogs and Social Media (ICWSM)*, pages 490–493.
- Ghosh, S., Viswanath, B., Kooti, F., Sharma, N. K., Korlam, G., Benevenuto, F., Ganguly, N., and Gummadi, K. P. (2012). Understanding and combating link farming in the twitter social network. In *Int. Conf. on World Wide Web, WWW '12*, pages 61–70.
- Gomide, J., Veloso, A., Meira, Jr., W., Almeida, V., Benevenuto, F., Ferraz, F., and Teixeira, M. (2011). Dengue surveillance based on a computational model of spatio-temporal locality of twitter. In *Int. Web Science Conference, WebSci '11*, pages 3:1–3:8.
- Gonçalves, P., Araújo, M., Benevenuto, F., and Cha, M. (2013). Comparing and combining sentiment analysis methods. In *Conf. on Online Social Networks, COSN '13*, pages 27–38.
- Hu, X., Tang, J., Gao, H., and Liu, H. (2013). Unsupervised sentiment analysis with emotional signals. In *Int. Conf. on World Wide Web, WWW '13*, pages 607–618.
- Jungherr, A., Jürgens, P., and Schoen, H. (2012). Why the pirate party won the german election of 2009 or the trouble with predictions: A response to Tumasjan, A., Sprenger, T. O., Sander, P. G., & Welpe, I. M. “Predicting elections with twitter: What 140 characters reveal about political sentiment”. *Soc. Sci. Comput. Rev.*, 30(2):229–234.
- Lumezanu, C., Feamster, N., and Klein, H. (2012). #bias: Measuring the tweeting behavior of propagandists. In *Int. Conf. on Weblogs and Social Media (ICWSM)*, pages 210–217.
- McCord, M. and Chuah, M. (2011). Spam detection on twitter using traditional classifiers. In *Int. Conf. on Autonomic and trusted computing, ATC'11*, pages 175–186.
- Mukherjee, S., Malu, A., A.R., B., and Bhattacharyya, P. (2012). Twisent: a multistage system for analyzing sentiment in twitter. In *Int. Conf. on Information and knowledge management, CIKM '12*, pages 2531–2534.
- Ribeiro Jr., S., Jr., Z., Meira Jr., W., and Pappa, G. L. (2012). Positive or negative? using blogs to assess vehicles features. *ENIA - Brazilian Conf. on Intelligent System*.
- Tumasjan, A., Sprenger, T., Sandner, P., and Welpe, I. (2010). Predicting elections with twitter: What 140 characters reveal about political sentiment. In *Int. Conf. on Weblogs and Social Media (ICWSM)*, pages 178–185.
- Witten, I. H. and Frank, E. (2005). *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann, 2nd edition.