

Association for Information Systems

AIS Electronic Library (AISeL)

ISLA 2021 Proceedings

Latin America (ISLA)

8-9-2021

Efeitos da análise de sentimentos sobre crenças de tomadores de decisão: Evidências ex-ante e ex-post

Altamar Alencar Cardoso

Universidade Federal da Paraíba, altamar.alencar@gmail.com

Pedro Jacome

Universidade Federal da Paraíba, oitentabarradois@hotmail.com

Follow this and additional works at: <https://aisel.aisnet.org/isla2021>

Recommended Citation

Cardoso, Altamar Alencar and Jacome, Pedro, "Efeitos da análise de sentimentos sobre crenças de tomadores de decisão: Evidências ex-ante e ex-post" (2021). *ISLA 2021 Proceedings*. 19.

<https://aisel.aisnet.org/isla2021/19>

This material is brought to you by the Latin America (ISLA) at AIS Electronic Library (AISeL). It has been accepted for inclusion in ISLA 2021 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.

Efeitos da análise de sentimentos sobre crenças de tomadores de decisão:

Evidências ex-ante e ex-post

Artigo Completo

Altamar Alencar Cardoso
Doutorando do Programa de Pós-
Graduação em Administração
PPGA-UFPB
altamar.alencar@gmail.com

Pedro Jácome de Moura Junior
Professor Doutor do Programa de
Pós-Graduação em Administração
PPGA-UFPB
pjacome@sti.ufpb.br

Abstract

Given the growing interest from companies in data science solutions and the need to make decisions in more complex environments. The aim of this paper is to provide evidence of how data science solutions can help decision makers adjust/modify their beliefs. The methodology used consists of developing an artifact from the perspective of a Design Science Research combined with the framework for data science projects, CRISP-DM. A solution for analyzing the sentiment of posts on the Twitter social network was built for the 14 main water supplies in Brazil. As a result, the most frequent possible causes of negative feeling were identified, contributing to the decision maker's belief update.

Keywords

Data science, decision making, natural language processing, beliefs.

Resumo

Diante do crescente interesse por parte das empresas de soluções de ciências de dados e da necessidade de tomar decisões em ambientes mais complexos. O objetivo deste trabalho é fornecer evidência de como soluções de ciências de dados podem auxiliar o tomador de decisão a ajustar/modificar suas crenças. A metodologia utilizada consiste no desenvolvimento de um artefato a partir da perspectiva de uma Design Science Research combinada com o framework para projetos de ciência de dados, CRISP-DM. Construiu-se uma solução de análise de sentimento de postagens na rede social do Twitter referente às 14 principais empresas de saneamento do Brasil. Como resultado, identificou-se as possíveis causas mais frequentes de geração de sentimento negativo, contribuindo para atualização de crença do tomador de decisão.

Palavras-chave

Ciência de dados, tomada de decisão, processamento de linguagem natural, crenças.

Introdução

A ciência de dados é considerada a área de trabalho mais atraente do século XXI (Davenport & Patil, 2012) devido ao potencial de integrar conhecimentos de estatística, matemática e computação e aplica-los para solução de problemas de interesse da

sociedade. Embora ainda haja dúvidas em relação à sua natureza – se um ramo da ciência ou um conjunto de técnicas com inspiração científica (De Moura Jr., 2021) – ciência de dados, estratégias analíticas e técnicas específicas têm sido desenvolvidas e empregadas intensamente por governos, academia e indústria. Data mining (ou mineração de dados, em tradução livre) é uma das estratégias mais empregadas para análise de negócios em ciência de dados, e o seu uso tem promovido uma espécie de “corrida do ouro” (Chun, 2018, p. 5474) em busca do suposto conhecimento escondido em meio ao grande “dilúvio” de dados (Bell et al., 2009, p. 1297), disponíveis nas mais diversas formas.

A explosão de dados, fenômeno popularmente conhecido como big data (Bell et al., 2009), tem despertado o interesse de várias organizações para aplicação de técnicas estabelecidas em ciências de dados na solução de problemas de negócios. Contudo, há um longo percurso a ser percorrido desde a identificação de um problema até a formulação de uma solução com fundamento em dados e na forma de se trabalhar com eles (Griffin, 2020; Pearl & Mackenzie, 2018). Identificar um problema de negócio é, sobretudo, supor relações entre variáveis e elaborar uma explicação plausível (lógica abdutiva) sobre o fenômeno de interesse (Cox III & Boyd, 2020), geralmente relacionado ao desempenho organizacional. Este processo (identificação de variáveis relacionadas e possível explicação) depende das crenças do tomador de decisão sobre a causa do comportamento do fenômeno (Prusty & Mohapatra, 2016).

O comportamento do tomador de decisão na ótica cognitiva ainda é um tema de incipiente interesse acadêmico (Nassif, 2019), embora se saiba que vieses cognitivos atuam de modo inconsciente, influenciando o decisor a adotar estratégias (heurísticas, por exemplo) que por um lado reforçam os seus pressupostos (visão de mundo, crenças e valores) mas que também podem representar desvios de racionalidade e baixa qualidade da decisão (Falcão & De Moura Jr., 2019). Uma das estratégias comumente adotadas para atenuação da influência de desvios de racionalidade e aprimoramento da qualidade da decisão é o uso de ciência de dados para apoio ao processo decisório, vide Schneider & Leyer (2019), por exemplo.

No entanto, o uso de tecnologias específicas por parte do tomador de decisão (recursos de inteligência artificial, por exemplo) pode esbarrar em limitações do próprio decisor. Bellini (2018) define três dimensões que limitam o uso efetivo de TI: acesso, cognição e comportamento. Enquanto possa-se supor que a maioria dos decisores tenham acesso a recursos básicos de TI (hardware, software e conectividade), sua capacidade cognitiva (memória, processamento simultâneo de informações e subjetividade) e o modo como habitualmente se comportam em relação à TI (vícios, p. ex) podem comprometer a sua (e a da organização) efetividade digital.

Portanto, o desempenho organizacional depende, em alguma medida, das crenças e comportamentos dos decisores. Crenças derivam de ações tornadas hábitos, em um processo de institucionalização que conduz a conhecimento legitimado socialmente (Berger & Luckmann, 1967). Sabe-se que crenças podem ser modificadas quando mudanças ocorrem nos hábitos (ibidem), o que suporta o argumento de que as crenças de um tomador de decisão podem ser reforçadas ou atualizadas (modificadas) em consequência da utilização de técnicas de ciências de dados, quando estas técnicas demonstram aumento da eficiência na tomada de decisão, especialmente ao definir mais precisamente os problemas de negócio. Este é o desafio deste trabalho: fornecer evidências empíricas de que soluções de ciências de dados podem auxiliar o tomador de decisão a ajustar/modificar suas crenças. Presume-se que evidências dessa natureza contribuam para aumentar a confiabilidade de projetos de ciências de dados, pavimentando o caminho para decisões orientadas por dados (Provost & Fawcett, 2013) e gestão baseada em evidências (Pfeffer & Sutton, 2006).

O ano é 2020 e o diretor-presidente de uma grande empresa de saneamento questiona a seus subordinados, em um grupo de WhatsApp, o motivo de tantas postagens negativas nas redes sociais, com relação à empresa que dirige. Logo várias explicações (usando lógica

abdutiva) são apresentadas e todas, em princípio, fundamentam-se em crenças não suportadas por dados. De acordo com Hymowitz, C. (2003), os diretores assumem múltiplas atividades e necessitam, cada vez mais, explorar informações que estão além dos relatórios financeiros. Contudo, segundo o mesmo autor, é frequente a quantidade de corporações que possuem dificuldades em integrar dados e reportar informação útil, sem que sobrecarregar os diretores com minúcias.

Desta forma, o problema do diretor-presidente parece ser algo que afeta a vários de seus colegas de profissão. É crescente o número de empresas que estão prestando mais atenção na sua imagem na internet, monitorando e tomando ações proativas para elevar a sua reputação (Thompson, 2003).

Os autores, na época, professor e aluno de uma disciplina em ciências de dados, e participantes de projeto de mesma natureza, envolvendo a academia e a empresa de saneamento em questão, decidiram aplicar conhecimentos da disciplina para enriquecer o entendimento da empresa sobre o problema de negócio, com informações baseadas em dados. Nasce então o resultado aqui relatado, um artefato de ciências de dados desenvolvido na perspectiva de uma Design Science Research (DSR).

A escolha da abordagem de DSR deve-se à adequação do caso à natureza da pesquisa prescritiva (Dresch, Lacerda e Antunes Junior, 2015). Não se busca encontrar explicações sobre o que faz uma pessoa postar determinada frase, mas sim, criar um artefato capaz de relacionar cada postagem individual, em um contexto maior das postagens de milhares de pessoas sobre dezenas de empresas de saneamento, de modo a extrair informações úteis para a tomada de decisão assertiva, verificando-se, em seguida, em que medida essa nova informação (desconhecida a priori) influenciou crenças do decisor.

Este trabalho foi baseado no método proposto para condução de uma DSR por Dresch, Lacerda e Antunes Junior (2015). A organização das seções seguiram a sequência deste método: esta primeira parte apresenta a identificação e contextualização do problema; a segunda parte apresenta como foi construída a proposição do artefato a partir de uma revisão da literatura; na terceira são descritas as técnicas, ferramentas e passos utilizados na construção do artefato; a quarta parte são relatados os resultados da avaliação do artefato; por fim, são apresentadas as conclusões sobre o artefato, bem como generalizações para o entendimento da ciência de dados para negócios.

Revisão da literatura

Para a construção de um artefato é importante ter ciência que ele deve resolver o problema da instância para a qual ele está sendo desenvolvido, mas sua utilidade será maior, quanto maior for a amplitude de contextos que ele atingir. Explorar bem o ambiente externo, e as classes de artefatos, ajudam a identificar as melhores ferramentas disponíveis, bem como permitirá que o artefato a ser desenvolvido, esteja vinculado a uma classe de artefatos.

Perguntas de negócio do tipo explicar o que aconteceu, está acontecendo ou poderá acontecer em processos como os de marketing, logística e finanças são comumente respondidas com três principais técnicas de ciências de dados Griffin (2020). Contudo, este seria uma das três grandes perguntas, o que acontece? As duas perguntas subsequentes são: Porque (causa) acontece e que ações posso tomar?

O modelo CRISP-DM é um artefato consolidado para mineração de dados (Provost & Fawcett, 2013). Este framework coloca como premissa para um bom projeto de mineração, o entendimento do problema de negócio e em seguida, mas de maneira iterativa, os dados disponíveis.

Uma pesquisa de ciência de dados, se faz com dados, não deve ser por acaso que o CRISP-DM representa a base de dados está no centro de todo o ciclo do desenvolvimento. Desta forma, é importante saber quais dados se tem acesso, e quais informações eles suportam. A

pergunta de negócio da empresa de saneamento já indica qual base de dados ela endereça: redes sociais. Portanto, a base de dados para exploração de informação e conhecimento serão os dados disponíveis em redes sociais, não só da empresa em questão, mas de outras empresas de saneamento, para realização de comparações.

Para o problema de negócio em estudo, os dados escolhidos para serem explorados são as postagens da rede social do Twitter, devido: disponibilizar um Application Programming Interface (API); permitir o resgate das postagens por tópico; possuir texto limitado em tamanho e com foco na expressão de sentimento.

Partiu-se do pressuposto que para o tomador de decisão, seria útil saber se sua empresa possui mais postagens negativas que a média das empresas do mesmo setor. Também seria útil saber qual a fonte de insatisfação, a natureza dessas postagens negativas. Desta forma, considerou-se como sucesso para o desenvolvimento do artefato, a capacidade de ele conseguir classificar as postagens em redes sociais, não só o sentimento (positivo ou negativo), mas também a natureza deste sentimento.

A partir da identificação dos requisitos do artefato, e do entendimento da classe de problemas que ele está inserido - um problema de ciência de dados, mais precisamente, de processamento de linguagem natural (PLN). Realizou-se uma revisão de literatura, avaliando as bases IEEE e ACM, e levando em consideração também a literatura cinzenta sobre práticas de uso de PLN. Identificando o trabalho de Kathuria et al (2019) como o ponto de partida relevante para o desenvolvimento do artefato.

Um dos motivos da escolha do artigo de Kathuria et al (2019) como ponto de partida, foi a utilização de uma etapa, caracterizada pela conversão de palavras em vetores (Work2Vec), um avanço que mostrou aumentar a eficiência do processamento de linguagem natural em relação aos demais trabalhos analisados. Bem como a indicação de bibliotecas para facilitar a implementação desta técnica de Work2Vec e demais etapas do processo.

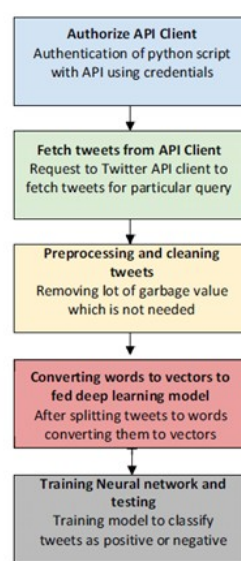


Figura 1. Sequência de tarefas conforme Kathuria et al (2019)

Identificou-se os trabalhos de Gupta et al (2018), Xiong et al (2020) e Susilawati (2016) uma busca por padrões de dados sobre organizações industriais, crise hídrica e qualidade de serviços públicos através de postagens no Twitter. Todos eles buscaram extrair alguma informação destes dados para resolver problemas reais. Contudo, Xiong et al (2020) e

Susilawati (2016) não testaram diversas técnicas de PLN. Já Gupta (2018), embora relacione a base de dados no Twitter com outras bases e realize vários testes com algoritmos de classificação diversos, ele não busca identificar outras características além do sentimento contido nas postagens.

Este trabalho também tem a intenção de resolver um problema real. O seu avanço consiste na extração de características além da classificação de sentimento positivo-neutro-negativo e na utilização da técnica de vetorização do texto. Detalhes do desenvolvimento serão explorados na parte seguinte deste trabalho.

Metodologia

A plataforma do Twitter disponibiliza um credenciamento para acesso à sua API através de justifica de uso. Foi apresentando o objetivo do uso dos dados e o nível de acesso necessário. A partir de uma análise, provavelmente automatizada, em poucos instantes foi liberado o acesso via API.

As requisições via script python tinham como objetivo recuperar postagens citando o nome de cada uma das 14 empresas de saneamento analisadas. Estas empresas foram selecionadas pela semelhança com a empresa foco desde trabalho.

A pesquisa por tópico retorna postagens dos últimos sete dias, portanto, toda semana, durante um ano, a base de dados era atualizada, resultando em um volume de mais de 80 mil postagens. As mensagens acumuladas foram classificadas quanto ao sentimento (negativo, positivo, neutro) e natureza (operacional, comercial, visão da empresa), resultado em um total de 897 postagens classificadas.

A classificação foi realizada através de conhecimento subjetivo do próprio pesquisador, que também é funcionário da empresa de saneamento, e portanto, possui conhecimentos de especialista. Desta forma, a base de dados de treinamento também foi construída no escopo deste trabalho. Diferente dos trabalhos de Araújo et al (2013) e Kathuria et al (2019) que estavam explorando o método, e portanto, utilizaram bases já rotuladas.

A justificativa de criar uma base de treinamento de dados específica para empresas de saneamento, se dá pelo fato de que o problema de negócio indica a necessidade de identificar não só o sentimento, mas também a natureza. Partiu-se do pressuposto que esta segunda tarefa seria melhor desempenhada com a classificação de uma base de dados para captar tal natureza.

Além de que, embora sejam dados, não são fatos livres de subjetividade. De acordo com Crawford (2013), à medida que dependemos mais dos resultados automatizados de Big Data, corremos o risco de tomar decisões ao interpretar errado os resultados. Desta forma, conhecer como os dados foram gerados (neste caso, rotulados) é parte do processo de construção do artefato.

Após rotulação, iniciou-se a limpeza das postagens. Retirando as stopwords para língua portuguesa. Utilizamos nuvens de palavras para entender os contextos e identificar novas stopwords. Aplicar a nuvem de palavras para cada subconjunto de dados, contribuiu para identificar qual o contexto estava mais relacionado com os sentimentos negativos e suas causas (natureza).

A etapa de transformar os dados de texto em vetores é fundamental, pois transforma cada texto em um vetor, cuja "direção" depende da semântica da postagem. A partir da vetorização, podemos tratar o texto com modelagem matemática, permitindo utilizar os principais algoritmos de classificação.

A base de dados com rótulo (897 postagens) foi dividida para realização de treinamento e teste. Esta divisão é importante para validar o modelo, uma vez que a comparação dos

rótulos com a classificação do modelo, para “novos” dados (dados não utilizados no treinamento).

Estas postagens rotuladas pelo humano, serviram de base de conhecimento para o processo de treinamento da inteligência artificial. A resposta do melhor algoritmo foi comparada com a classificação humana, permitindo ao pesquisador rever seu julgamento inicial sobre algumas postagens.

A avaliação da eficiência técnica do artefato foi realizada através de estatísticas extraídas da matriz de confusão: acurácia, precisão, revogação e f-score (uma média harmônica entre precisão e revogação).

Algoritmo	Regressão logística	Rede MLP	SVM	Árvore de decisão
Precisão Média	50,33%	33,3%	47,36%	46,65%
Precisão de classificação de sentimento negativo	63,41%	-	59,50%	55,88%

Tabela 1. Resultados dos algoritmos de classificação utilizados

Após aceitação da capacidade do modelo, ele pôde ser aplicado em toda a base de dados, as mais de 80 mil postagens salvas em um ano. Para comunicação dos resultados, foram geradas novas nuvens de palavras, para cada subconjunto, agora, considerando todo o universo de dados, classificados pelo algoritmo. Também foram utilizados gráficos de barras para comparar os resultados entre empresas de saneamento. Por fim, foi criado um dashbord para manipular os resultados por empresa e época.

A acurácia dos modelos, embora não tão altas, estão consistentes com outros trabalhos de análise de sentimento (Mikolov, 2013). Acurácia dos métodos utilizados por Araújo et al (2013), embora superiores, foram baseados em apenas duas classes (positivos e negativos), não levando em consideração os neutros. No entanto, verificamos a existência de muitas postagens que possuíam apenas um caráter informativo envolvendo o nome de uma empresa de saneamento. Portanto, decidimos por utilizar as três classes: negativo, positivo e neutro.

No entanto, a validade da acurácia do modelo é condição necessária, mas não suficiente para a adoção do artefato. Desta forma, embora seja forte a curiosidade de refinar cada vez mais a base de dados e o algoritmo utilizado, é importante compreender que esses ganhos marginais podem comprometer negativamente o resultado do negócio do artefato: apresentar uma informação suficientemente fundamenta em dados para a tomada de decisão.

Portanto, para validar a capacidade do artefato, de gerar informação útil, foi elaborado um questionário online para o diretor-presidente avaliar se o artefato é útil para ajudá-lo a esclarecer suas crenças sobre o assunto e poder tomar decisão baseada em dados.

Ao validar os resultados do artefato, o diretor pontou sobre o resultado do benchmark: “podemos ver que temos problemas comuns, especialmente quando temos problemas operacionais e, quem sabe, trocar experiências com outras melhores”. Ou seja, o artefato mostrou que o problema (fenômeno) não é específico da sua empresa que ele dirige; bem como é possível identificar empresas que possuem um desempenho melhor, e que podem servir de fonte de aprendizado. Na próxima parte exploraremos esses resultados.

Resultados e discussões

Após desenvolvimento e validação do artefato, é hora de comunicar os resultados. Apresentar o valor que estão por trás dos dados, o “ouro” que foi possível minerar a partir dos dados disponíveis na internet, para o nosso problema de negócio. A decomposição do problema de negócio, levantando pelo presidente da companhia, levou ao primeiro questionamento: Será que uma grande frequência de postagens negativas relacionadas a sua empresa é um fenômeno anormal?

O gráfico de barras da figura 01 apresenta a quantidade de postagens negativas e positivas classificadas pelo artefato desenvolvido. Observa-se uma variabilidade da quantidade de postagens, que pode estar relacionada com a quantidade de cliente e a cultura de uso da rede social que diverge de empresa para empresa. Contudo, um padrão é perceptível, que as empresas apresentam uma quantidade bem superior de postagens negativas em relação as postagens positivas.

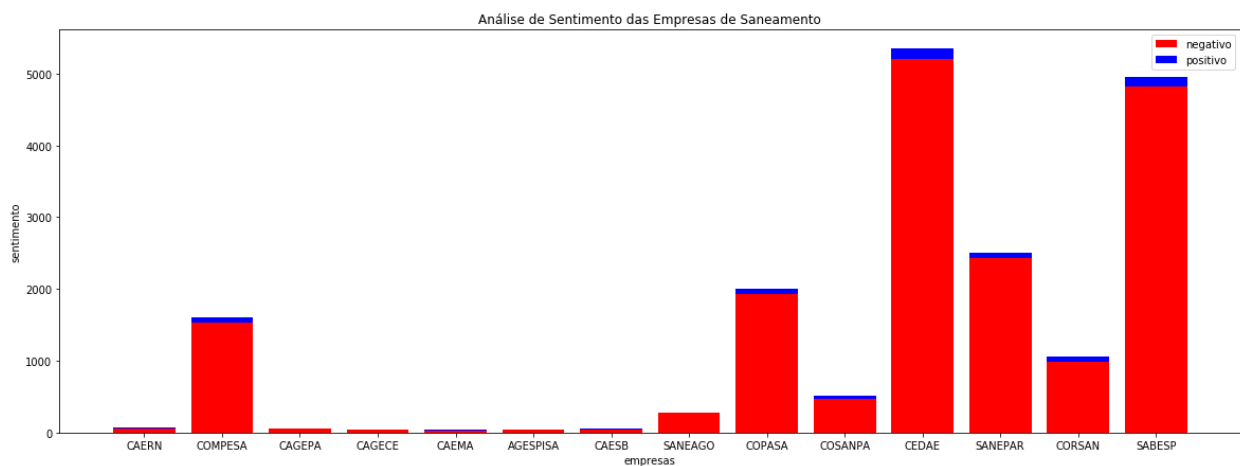


Figura 2. Resultado da análise de sentimento por empresa de saneamento

Logo, diante destas evidências, é podemos presumir que para a população das empresas de saneamento analisadas, é esperado que as postagens negativas sejam maioria. Desta forma, o presidente da empresa pode rejeitar a ideia de que possa está enfrentando um problema anormal do ponto de vista da quantidade de postagens negativas.

Mesmo sabendo que o problema não é fenômeno anormal da sua empresa, o diretor-presidente poderia querer investir para reduzir a quantidade de postagens negativas em relação as positivas, pois ele poderia supor que ser a empresa de saneamento com menor quantidade relativa de postagens negativas, promoveria alguma vantagem competitiva. Desta forma, seria útil para o mesmo saber qual a natureza do serviço que está gerando as postagens negativas para investir assertivamente.

Para tanto, apresentou-se o resultado das postagens negativas por natureza, também classificadas pelo artefato. O gráfico de barras na figura 02 apresenta o percentual de cada natureza do total das postagens negativas de cada empresa analisada. Constatou-se uma baixa frequência para a natureza de ordem comercial para todas as empresas. Oito empresas apresentaram um nível de natureza operacional maior que o nível de visão geral da empresa, dentre elas, está a empresa foco deste trabalho. Portanto, este resultado sugere que a maneira assertiva de reduzir a imagem negativa da empresa na rede social do Twitter, seria investir na resolução dos problemas de natureza operacional.

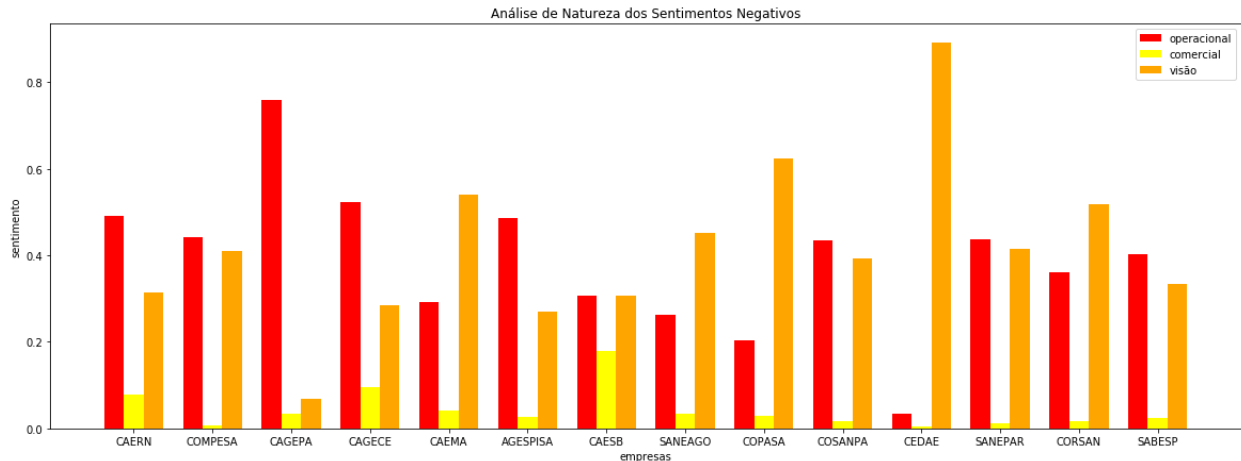


Figura 3. Resultado da análise de natureza dos sentimentos negativos por empresa de saneamento

Entretanto, para ser mais assertivo ainda, seria útil confirmar o tipo de problema está gerando a insatisfação de ordem operacional. Utilizou-se então o gráfico do tipo nuvem de palavras, para aprestar o contexto geral que está por trás da insatisfação de natureza operacional, as palavras apresentadas reforçaram a crença que o problema operacional está relacionado ao desabastecimento de água.

Uma análise dos termos apresentadas na nuvem de palavras da figura 03 reforça a crença de que o problema de desabastecimento de água é o principal motivo que levam as pessoas a expressarem sua insatisfação de natureza operacional acerca das empresas de saneamento na rede social. Caso verdadeiro, uma maneira eficiente de atenuar as postagens negativas relacionadas a questões operacionais, seria garantir a continuidade do abastecimento de água. Soluções para identificar a falta d'água com antecedência podem ser úteis para essa finalidade.

A última contribuição para geração de informação útil a partir de dados de redes sociais, foi o dashboard online para consultar o resultado da classificação, em que através de vários filtros disponíveis (empresa, período, sentimento, natureza e se foi verificado por humano). Com este dashboard é possível responder várias perguntas típicas de negócio, todas suportadas pelos dados.

Conclusão

Para auxiliar o presidente da empresa de saneamento na tomada de decisão, o artefato desenvolvido forneceu evidências empíricas específicas: (1) uma grande quantidade de postagens negativas é algo comum para as empresas de saneamento; (2) questões operacionais são a principal causa da geração de insatisfação com relação à sua empresa; e (3) a insatisfação de natureza operacional está relacionada principalmente com o desabastecimento de água.

Os resultados mostram-se úteis para a tomada de decisão ao revelar que uma maior frequência de postagens de cunho negativo é uma característica comum das empresas de saneamento. É possível também identificar a causa (natureza) dos sentimentos negativos, possibilitando o direcionamento das ações de melhoria da satisfação do cliente.

O artefato também possibilitou uma melhor compreensão do problema de negócio, antes algo que não havia sido cogitado no início da pesquisa, mas que os dados acabaram revelando quando apresentaram uma classificação de máquina divergente da classificação

por humanos. Em sua grande maioria, eram casos em que a própria empresa relatava publicamente problema de falta de água. Este achado promoveu o debate de que a política de divulgação de falta de água em rede social pode ser substituída por uma comunicação mais direta com os clientes afetados, reduzindo o risco de queda de reputação da empresa.

Desta forma, consideramos que o artefato de inteligência artificial contribuiu para questionar crenças dos envolvidos: (i) o profissional que classificou a base de teste e validação, fazendo-o repensar seu entendimento sobre certo tipo de postagem e seu impacto na imagem da empresa; e (ii) o diretor presidente da empresa, ao ser municiado com informação útil para tomada de decisão, pôde reavaliar seu entendimento sobre o assunto e escolher uma estratégia mais adequada.

Este trabalho apresentou um esforço para quantificação de uma informação subjetiva, de uma quantidade considerável de informação que está disponível para todas as empresas de saneamento utilizarem – as postagens em redes sociais. Mas que para isto, cada uma empresa precisa internalizar a competência de encontrar informações e conhecimento a partir de fontes de dados diversas.

Uma limitação identificada na fase de validação é a possibilidade de a visão do pesquisador não corresponder a visão do decisor sobre a natureza e o sentimento das postagens, bem como a consistência da rotulagem na base de treinamento, criando um possível viés no primeiro caso, e no segundo, diminuindo a acurácia. Recomenda-se se quando possível, os dados devem ser rotulados pelo próprio tomador de decisão, e deve se buscar aplicar uma mesma regra de rotulagem em toda a base de treinamento.

De fato, o artefato só respondeu a 1ª das grandes questões, como descreve Griffin (2020), a de descrever o que está acontecendo. Contudo, o resultado do artefato apresenta elementos que sugerem, mais precisamente, uma rede nomológica de causa e efeito dos sentimentos negativos e sua natureza, sobretudo a natureza operacional como grande causadora da insatisfação em redes sociais.

Uma vez validado no nível de negócio, o artefato poderá continuar classificando as postagens periodicamente (toda semana, por exemplo). Uma oportunidade de uso do artefato é permitir a realização de experimentos de campo, de forma a quantificar ações e seus efeitos na reputação online da empresa. Ou seja, investimentos em ações pontuais no tempo, como campanhas publicitárias, ações de conscientização e educação do consumidor, poderão ser quantificadas quanto ao seu retorno em termos de imagem positiva.

Desta forma, o artefato respondeu à primeira grande questão, mas não explica porque isso acontece e quais ações devem ser tomadas. Até onde sabemos, essas escolhas ainda são de domínio exclusivo do tomador de decisão.

Referências

- Araújo, M., Gonçalves, P., Benevenuto, F., & Cha, M. 2013. "Métodos para análise de sentimentos no twitter," Proceedings of the 19th Brazilian symposium on Multimedia and the Web (WebMedia'13). Sn,
- Bell, G., Hey, T., & Szalay, A. 2009. "Beyond the data deluge," *Science* (323:5919), pp. 1297-1298.
- Bellini, C. G. P. 2018. "The ABCs of effectiveness in the digital society," *Communications of the ACM* (61:7), pp. 84-91.
- Berger, P. and Luckmann, T. 1967. *The Social Construction of Reality: A Treatise in the Sociology of Knowledge*, Penguin Books.
- Chun, S. H. 2018. "Machine learning techniques and statistical methods for business applications: Implications on Big Data gold rush," *Advanced Science Letters* (24:7), pp. 5474-5477.

- Cox III, J. F., & Boyd, L. H. 2020. "Using the theory of constraints' processes of ongoing improvement to address the provider appointment scheduling system design problem," *Health Systems* (9:2), pp. 124-158.
- Crawford, K. 2013. "The hidden biases in big data," *Harvard business review* (1:4).
- Davenport, T. H., & Patil, D. J. 2012. "Data scientist," *Harvard business review* (90:5), pp. 70-76.
- De Moura Jr., P. J. 2021. "Is data science a science? The essence of phenomenon and the role of theory in the emerging field," *Kybenetes*, ahead-of-print.
- Dresch, A., Lacerda, D. P., & Júnior, J. A. V. A. 2015. *Design science research: Método de pesquisa para avanço da ciência e tecnologia*. Bookman Editora.
- Falcão, R. P. A., & De Moura Jr., P. J. 2019. "Desvios de racionalidade e o papel do administrador em processos de negociação," *Gestão & Aprendizagem* (8:2), pp. 7-24.
- Griffin, D. K. 2020. "The Big Three: A Methodology to increase data science ROI by answering the questions companies care about," arXiv preprint arXiv:2002.07069.
- Gupta, N., Crosby, H., Purser, D., Javis, S., & Guo, W. 2018. "Twitter usage across industry: A spatiotemporal analysis," in *2018 IEEE Fourth International Conference on Big Data Computing Service and Applications (BigDataService)*, pp. 64-71.
- Hymowitz, C. 2003. "How to be a good director.," *Wall Street Journal* (R1), p.27.
- Kathuria, R. S., Gautam, S., Singh, A., Khatri, S., & Yadav, N. 2019. "Real Time Sentiment Analysis On Twitter Data Using Deep Learning (Keras)," in *2019 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, pp. 69-73.
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. 2013. "Efficient estimation of word representations in vector space," arXiv preprint arXiv:1301.3781.
- Nassif, M. E. 2019. "Crença e tomada de decisão: perspectiva de análise do comportamento gerencial para o estudo de uso de informação," *Ciência Da Informação*, (48:2).
- Pearl, J., Mackenzie, D. 2018. *The book of why: The new science of cause and effect*. Basic Books.
- Pfeffer, J., & Sutton, R. I. 2006. "Evidence-based management," *Harvard business review* (84:1), pp. 1-11.
- Provost, F., & Fawcett, T. 2013. *Data Science for Business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media, Inc.
- Prusty, S. K., & Mohapatra, P. K. J. 2016. "Modelling judgment and decision making process using system dynamics," in *Proceedings of the 34th international conference of the System Dynamics Society*, Delft, Netherlands, July, pp. 17-21.
- Schneider, S., & Leyer, M. 2019. "Me or information technology? Adoption of artificial intelligence in the delegation of personal strategic decisions," *Managerial and Decision Economics* (40:3), pp. 223-231.
- Thompson, N. 2003. "More companies pay heed to their 'word of mouse' reputation," *The New York Times* (6:23).
- Xiong, J., Hswen, Y., & Naslund, J. A. 2020. "Digital surveillance for monitoring environmental health threats: A case study capturing public opinion from twitter about the 2019 Chennai Water Crisis," *International journal of environmental research and public health* (17:14), pp. 5077.