

Transformação Digital no combate ao Coronavírus – COVID-19:

Uma experiência da Controladoria Geral do Estado de Goiás

Resumo

A pandemia causada pelo Corona Vírus – COVID-19 causou um impacto significativo nos serviços públicos. Em especial, trouxe uma digitalização maciça de serviços que eram ofertados presencialmente. De forma complementar houve uma grande pressão nos canais oficiais, quer seja para buscar um serviço, quer seja para denunciar um fato. A informação qualificada e oficial se torna um elemento no combate a pandemia. Saber onde buscar informação, denunciar um fato ou obter uma resposta qualificada são passos essenciais para maximização da eficiência do processo de tomada de decisões do cidadão, especialmente em um cenário de tamanha incerteza. O Estado tem papel fundamental seja como indutor, executor ou provedor dos meios necessários para que informação e tomada de decisões sejam efetivos nesse momento.

Conectado pela crescente demanda o Estado de Goiás, por meio da Controladoria Geral do Estado, publicou uma série de ferramentas tecnológicas com o objetivo de levar informação ao cidadão, fomentar o controle social e melhora das políticas públicas de combate ao Coronavírus.

Este documento busca evidenciar como se deu adoção e implantação de ferramentas tecnológicas no que tange a transformação dos canais de ouvidoria no Estado de Goiás por meio da Controladoria Geral do Estado em ações no combate a pandemia do Coronavírus. O documento busca evidenciar como ocorreu a transformação dos canais de ouvidoria por meio de técnicas de aprendizado de máquina e visualizações de dados.

Palavras Chaves: Coronavírus, transformação, digital.

Introdução

A pandemia global de COVID-19, causada pelo novo coronavírus SARS-CoV-2, é uma emergência de saúde pública que afeta todos os serviços ofertados pelo Estado, sejam estes relacionados a saúde, segurança, educação ou aspectos econômicos. Em pouco menos de três meses, passamos de relatos distantes de uma nova doença emergente na China para ver cidades fechadas e serviços públicos levados ao extremo.

Governantes e líderes estão na posição invejável de ter que tomar decisões quase impossíveis, sobre a melhor forma de lidar com uma situação que tem se propagado de forma cada vez mais rápida e contundente. Saber responder a tais problemas e desafios de forma rápida e eficaz é fundamental para gerar credibilidade no setor público.

Nesse momento de pressão por serviços públicos, a posse de dados relevantes e, acima de tudo, saber como utilizá-los é o diferencial para se prestar um melhor atendimento à população.

Neste contexto, uma das principais informações que faltam aos tomadores de decisão é a identificação de como os cidadãos se relacionam com os canais oficiais, em especial de ouvidoria, e como o Estado responde de forma estruturada e eficiente a esse cidadão.

No dia 13/03/2020 o Governo do Estado de Goiás publicou o decreto 9.633, que dispõe sobre a decretação de emergência na saúde pública do Estado de Goiás, em razão da disseminação do novo coronavírus (2019-nCoV). O texto traz diversas restrições de funcionamento de atividades comerciais.

Nesse sentido a população foi incentivada a denunciar, via canal de ouvidoria, sobre ocorrências e violações de descumprimento do decreto.

O sistema de Participação e Controle social da Controladoria Geral do Estado de Goiás é composto por três esferas: ouvidoria, transparência e participação social. Esses pilares são suportados por ferramentas tecnológicas fundamentais para o desenvolvimento de ações estruturadas de combate e contenção a pandemia.

Neste momento de crise, a Controladoria-Geral do Estado decidiu divulgar um canal de denúncia para capturar as demandas e alertas da sociedade. Dentro de tal cenário, o número de acessos aos canais oficiais apresentou crescimento tão exponencial para realidade vivenciada que houve uma saturação da capacidade de atendimento do órgão. O vertiginoso crescimento do número de manifestações e solicitações apresentadas ao sistema estadual de ouvidoria – em contraste com o volume médio de manifestações apresentadas em cenários de estabilidade – evidenciam uma clara demanda pela

construção de canais mais eficientes de comunicação entre o cidadão e o aparato estatal, especialmente em um cenário onde a atuação do Estado se faz crucial no amparo a população imersa em tal cenário de potenciais riscos e incertezas no que tange a saúde e oferta de serviços públicos.

Assim, foi necessário aplicar de técnicas de inteligência artificial e design etnográfico como instrumentos para analisar os dados obtidos e construir melhores respostas para as demandas apresentadas pela população.

Como resultado dessa intervenção, a Controladoria-Geral do Estado, desenvolveu dois produtos, que fazem uso de um mecanismo de inteligência artificial, para fazer frente a esta crescente demanda e otimizar a pronta resposta a população: CoronaInfo e CoronaTransp. A hipótese apresentada neste artigo é de que tais mecanismos desempenham um papel crucial na maximização da eficiência do processo de troca informações entre Estado e população, auxiliando no processo de análise dos dados e, conseqüentemente, com potencial para se tornarem instrumentos efetivos na construção de políticas públicas capazes de reduzir, ou controlar, os danos causados por tal cenário de incerteza e instabilidade.

CoronaInfo

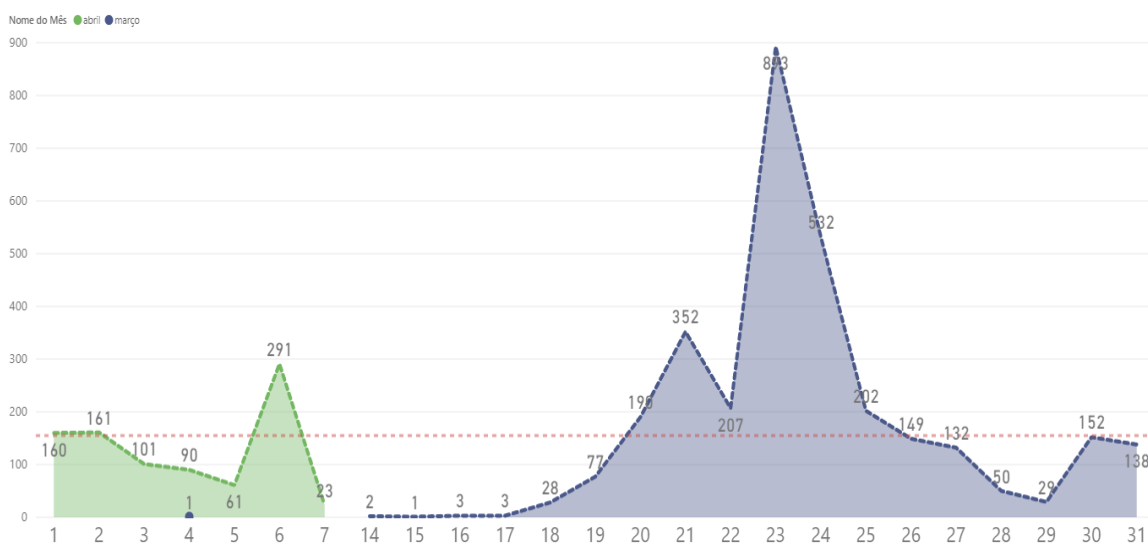
Um dos mecanismos adotados pelo Governo de Goiás, através da Controladoria-Geral do Estado, foi o desenvolvimento e implementação de um sistema baseado no uso da inteligência artificial: o CoronaInfo. O estabelecimento de tal sistema se deu em um contexto onde os canais de atendimento tradicionalmente utilizados no contato diário com o cidadão goiano foram complementarmente exauridos. A infraestrutura anteriormente existente apresentava capacidade de atendimento de cerca de 500 demandas por mês. Subitamente, foi necessário responder cerca de 800 demandas em um único dia. Neste sentido, o significativo crescimento do volume de manifestações realizados pelos cidadãos goianos evidencia um cenário onde o coronavírus suscita a necessidade de se desenvolver uma maior capacidade de tratamento dos dados oriundos de tais manifestações – para que estes sejam compreendidos e apresentados de forma inteligível, facilitando o processo de tomada de decisões.

Assim sendo, a metodologia de análise desenvolvida pelo CoronaInfo se deu através de coleta dos dados das solicitações efetuadas mediante uso do sistema de ouvidoria. Quando o canal foi disponibilizado, houve um aumento exponencial na

demanda de atendimento as manifestações apresentadas pelos cidadãos. Como já dito, em um único dia, a Ouvidoria-Geral do Estado recebeu mais de 800 denúncias que versavam sobre estabelecimentos descumprindo o decreto do governo goiano. Para isso, foi criado o CoronaInfo. A ferramenta de inteligência artificial, que utiliza técnicas de *machine learning*, foi desenvolvida para construir perfis de atendimento segmentados para um conjunto de interação de usuários. O objetivo da ferramenta, portanto, é identificar os perfis de interação nos canais de ouvidoria do Estado de Goiás.

Foram avaliados o perfil da população que interage nos canais de ouvidoria, além de uma análise textual com técnicas de clusterização. Como base amostral, foram analisadas 4.028 manifestações realizadas no Sistema de Ouvidoria do Estado de Goiás, entre os dias 13/03/2020 e 07/04/2020 – conforme figura 1.

Figura 1 – Número de manifestações recebidas pela Ouvidoria-Geral do Estado



Fonte: Controladoria-Geral do Estado de Goiás

As manifestações foram então divididas, utilizando como critério a natureza da solicitação apresentada pelo cidadão. Como pode ser visto na figura 2, durante o intervalo temporal definido para tratamento dos dados, a porção majoritária das manifestações versaram sobre comunicação e solicitação – sendo, na maior parte das vezes, comunicações e solicitações referentes à estabelecimentos descumprindo as normas vigentes no período de quarentena decretado no Estado.

Figura 2 – Manifestações recebidas entre os dias 13/03/2020 e 07/04/2020, separadas por sua natureza.



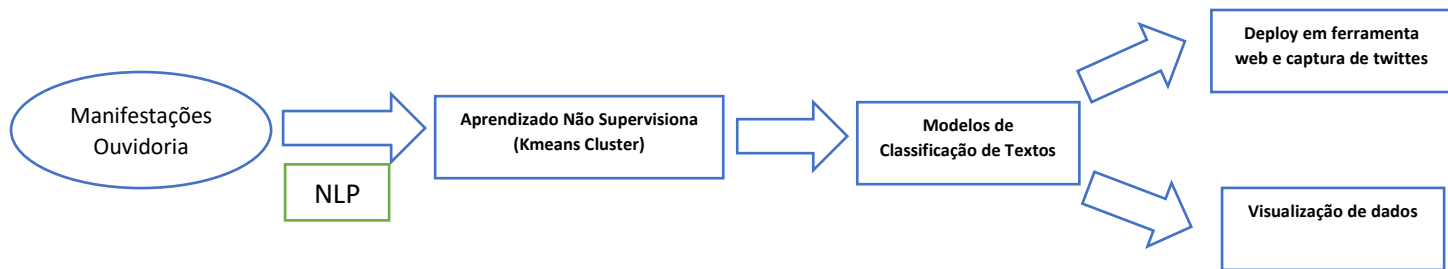
Fonte: Controladoria-Geral do Estado de Goiás

Neste sentido, considerando-se a natureza das manifestações encaminhadas pelos cidadãos no período estabelecido – versando majoritariamente acerca da comunicação de descumprimentos do decreto. Torna-se evidente de que forma o tratamento otimizado dos dados das solicitações, através do CoronaInfo, facilita ao tomador de decisões a compreensão acerca das demandas de seu público. Neste caso, torna-se evidente a necessidade de um papel mais ativo do Estado no reforço ao cumprimento do decreto de quarentena e isolamento – para, então, reduzir o número de denúncias referentes ao descumprimento de tal norma e efetivando os benefícios do isolamento social como método de contenção a expansão desenfreada do contágio.

Machine Learning – Processamento de Linguagem de Texto

Com o objetivo de automatizar e processar os textos de interação foram aplicadas técnicas de *processamento de linguagem natural (PLN)*. O processamento de linguagem se preocupa em interpretar texto escrito por humanos e reproduzir conhecimento. A construção da solução envolveu diversas etapas de processamento e modulação de vários algoritmos representados pelo seguinte frame de atuação (figura 3).

Figura 3 - Arquitetura de um sistema genérico de mineração de texto



Fonte: Feldman & Sanger (2006) – Tradução dos autores – Adaptação própria

A técnica aplicada envolve agrupar textos em grupos que façam mais sentido, em um número k de grupos. O número k de grupos pode, ou não, ser conhecido previamente. Como nosso objetivo aqui foi agrupar textos de reclamação em k categorias, usamos o recurso de clusterização com k-means.

A primeira etapa para preparação do texto foi criação a de uma *bag of words*. Segundo Rodrigo Vieira “O Bag of Words e o TF-IDF são técnicas que nos ajudam com o processo de converter sentenças de texto em vetores numéricos”. O *bag of words* (saco de palavras) é uma representação simplificada usada no processo de linguagem natural e recuperação de informação. Nesse modelo, qualquer informação sobre a gramática ou a ordem das palavras é descartada, ele transforma a sacola de palavras em um conjunto de termos e suas respectivas frequências. Ainda segundo Rodrigo Vieira:

Quando aplicamos o bag of words geramos um vetor esparso (com muitos valores igual a zero), a medida que seu texto aumenta, a quantidade de features também vai aumentar, ou seja teremos um vetor ainda mais esparso, isso é um problema pois vetores esparsos requerem mais memória e recursos computacionais ao modelar.

É importante fazermos uma análise de importância das palavras, para identificar aquelas que realmente podem agregar significado à uma sentença. Para isso, é usual empregarmos a técnica da frequência inversa. Com o TF-IDF (term frequency—inverse document frequency), consideramos a frequência de uma palavra na sentença, dividido pelo número de documentos em que ela aparece.

Figura 4 – Formula de cálculo TF-IDF

estejam o mais próximos possível, assumindo que quanto mais próximos eles estiverem, mais parecidos eles são. E literalmente próximos, uma vez que o momento de inércia para os dados em questão é calculado como a soma do quadrado das distâncias de cada ponto ao centro do agrupamento.

Assim, utilizando-se as dimensões geradas na vetorização das sentenças (lembrando que cada palavra é uma dimensão) e sua relativa frequência (TFIDF), tenta-se separar os clusters maximizando as distâncias entre a média da distância dos pontos (reclamações, no caso). Matematicamente, essa expressão fica:

Figura 5 – Fórmula do Modelo K-Means

$$\text{objective function} \leftarrow J = \sum_{j=1}^k \sum_{i=1}^n \underbrace{\|x_i^{(j)} - c_j\|^2}_{\text{Distance function}}$$

Fonte:

Figura 6 – Geração de Cluster.

```

Cluster de Texto

[ ] #ajustar dataframe
dfObj = [e for e in comentarios["manifestacao"] if isinstance(e, str)]
dfObj = pd.DataFrame(dfObj)

[ ] #importa bibliotecas
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.preprocessing import normalize
from sklearn.cluster import KMeans
from sklearn.metrics.pairwise import cosine_similarity
vectorizer = TfidfVectorizer() # variar parametros (L1/L2, etc)
X = vectorizer.fit_transform(comentarios["manifestacao"])
X = normalize(X)

[ ] kmeans = KMeans(
    n_clusters = 8, # variar
    n_init = 15,
    max_iter = 450,
    init = 'k-means++'
)

[ ] #treinar com kmeans
kmeans.fit(X)


```

Fonte: elaboração do autor¹

¹ https://github.com/ferreirabruno7/Text_analyze/blob/master/geracao_ouvidoria_covid_19.ipynb

Podemos perceber, então, que os clusters se formam de maneira clara, com fronteira razoavelmente bem definida. Contudo, devido a dimensionalidade, não podemos definir qual número de clusters faz mais sentido apenas pelos resultados

Figura 7 – Distribuição de Cluster no Hiperplano .

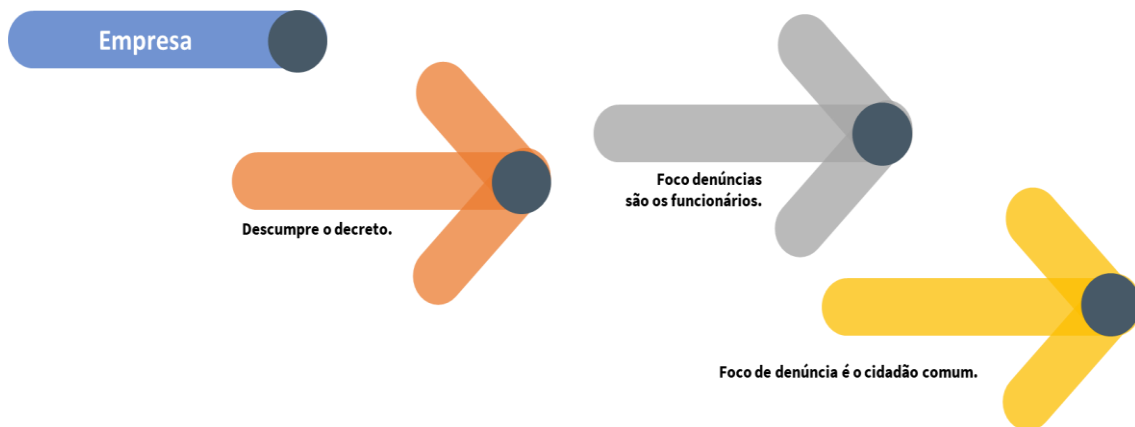


Fonte:

Foi possível identificar que uma parcela considerável das interações realizadas no portal segue uma mesma lógica processual. As manifestações costumam seguir uma mesma estrutura lógica de pensamento:

- O funcionário tem dúvida se sua empresa deve estar aberta, assim ele cria uma denúncia.
- O cidadão tem dúvida sobre uma atividade deve estar funcionando, então o cidadão uma denúncia.

Figura 8 – Lógica processual das manifestações apresentadas a Ouvidoria-Geral do Estado



Fonte: Controladoria-Geral do Estado de Goiás

Resultados dos Cluster:

Cluster	Manifestações	%
1. Atividades em Funcionamento, funcionários e aglomerações	600	28.18
2. Denúncia do cidadão sobre serviços abertos	438	20.57
3. Funcionários Solicitando Proteção	303	14.23
4. Entretenimento	353	15.88
5. Empresas de portas fechadas	167	7.84
6. Lojas de Decorações	156	7.33
7. Bares abertos	112	5.26

Caracterização dos grupos

1- Atividades em Funcionamento, funcionários e aglomerações:

- Empresas situadas em Goiânia que estão em atividade, funcionários relatam que estão trabalhando em grandes aglomerações;
- Funcionários solicitando quarentena
- Recomendação: chamar FECOMERCIO e Associação Comercial e recomendar o fechamento das atividades proibidas.

2- Denúncia do cidadão sobre serviços abertos

- Cidadão comum que denuncia o funcionamento de lojas;
- Cidadão tem pouca compreensão do decreto publicado.

3- Funcionários Solicitando Proteção

- Funcionários relatam que não possuem proteção no trabalho, trabalhando em situação de risco;
- Relatam a falta de álcool em gel, máscaras, luvas, água e sabão;
- Funcionários reclamando que a empresa não presta assistência técnica;
- Foco em grandes indústrias, empresa de call center (OI, Mega comunicações), confecções e contabilidade;

4- Entretenimento

- Cidadão relata que atividades de diversão estão funcionando de forma livre.

5- Empresas de portas fechadas

- Funcionário relata que sua empresa mantém atividades de portas fechadas;
- Funcionário relata que são obrigados a trabalhar.

6- Lojas de Decorações

- Funcionário e cidadão relata que lojas de departamentos estão funcionando com aglomerações.

7- Bares Abertos

- Cidadão relata que bares estão funcionando vendendo bebidas e tendo aglomerações.

Classificação de Textos

Para realizar a classificação do cluster de texto, foi aplicado um algoritmo *naive bayes* com utilizações multinominais. Este recurso foi utilizado pois obteve uma melhor performance em classe prioritárias, com precisão de aproximadamente 98% em tais classes .

O *Naive Bayes* é um algoritmo probabilístico simples baseado no teorema de Bayes. Este utiliza dados de treino para formar um modelo probabilístico baseado na evidência das *features* nos dados. O algoritmo supõe que há uma independência entre as *features* do modelo. Isso significa que a presença de uma determinada *feature* não tem nenhuma relação com as outras.

O teorema de Bayes calcula a probabilidade $P(c/x)$ em que c é a classe dos possíveis resultados e x é o exemplo dado que deve ser classificado, representando algumas características.

$$P(c|x) = P(x|c) * P(c) / P(x)$$

Naive Bayes são usados principalmente em problemas de processamento de linguagem natural (PLN). Naive Bayes prevê a tag de um texto. Eles calculam a probabilidade de cada marca para um determinado texto e, em seguida, produzem a marca com a mais alta.

Quando aplicamos esse tipo de abordagem a classificação de textos, é necessário a aplicação de várias etapas de pré-processamento de textos.

Suposições:

- A ordem das palavras no documento X não faz diferença, mas repetições de palavras fazem.
- As palavras aparecem independentemente uma da outra, dada a classe do documento.

Com base nessas premissas, temos as seguintes equações para estimar $P(X/y)$:

$$P(w_1, \dots, w_n | Y = y) = \prod_{i=1}^n P(w_i | Y = y) \quad (1)$$

$$P(W = w_i | Y = y) = \frac{\text{count}(W = w_i \ \& \ Y = y)}{\text{count}(Y = y)} \quad (2)$$

Assim, é possível realizar a conversão de texto em uma matriz de termo frequência, dessa forma, podemos classificá-las segundo um dos grupamentos previamente de criados.

Figura 9 – Tabela de manifestações segundo cluster

manifestacao	status_atual	desc_status	sigla	nome	tipo_manifestacao	assunto	sub_assunto	tokens	cluster
Elogio com sugestão de ações	55	Finalizado pela ouvidoria do Órgão.	SGG/GOVERNADORIA	Secretaria Geral da Governadoria	Elogio	Saúde	Corona Vírus - Denúncia, solicitação ou inform...	['Elogio', 'com', 'sugestão', 'de', 'ações']	3
Na empresa BTCC (prestadora de Serviços para O...	55	Finalizado pela ouvidoria do Órgão.	SES	Secretaria de Estado da Saúde	Comunicação	Saúde	Corona Vírus - Denúncia, solicitação ou inform...	['Na', 'empresa', 'BTCC', '(', 'prestadora', '...',	5
Considerando o decreto do Sr. Governador quant...	55	Finalizado pela ouvidoria do Órgão.	SEAD	Secretaria de Estado de Administração (Antiga ...	Comunicação	Saúde	Corona Vírus - Denúncia, solicitação ou inform...	['Considerando', 'o', 'decreto', 'do', 'Sr.', '...',	5
Em meio a grave pandemia de	55	Finalizado pela ouvidoria do	SSP	Sec. Estado da Segurança Pública	Comunicação	Saúde	Corona Vírus - Denúncia, solicitação ou	['Em', 'meio', 'a', 'grave', 'pandemia',	5

Fonte: elaboração do autor

Figura 10 – Resultado do Modelo de Classificação

```
print(classification_report(resultados, classes))
```

	precision	recall	f1-score	support
0	0.92	1.00	0.96	12
1	0.54	0.89	0.68	76
2	0.82	0.73	0.78	415
3	0.79	0.80	0.79	549
4	0.77	0.88	0.82	178
5	0.90	0.77	0.83	595
6	0.74	0.86	0.80	186
7	0.70	0.83	0.76	118
accuracy			0.80	2129
macro avg	0.77	0.85	0.80	2129
weighted avg	0.81	0.80	0.80	2129

Fonte: elaboração do autor²

Figura 11 – Previsão de Textos para dados não treinados

```
pickle.dump(tfidfVectorizer, open("/content/drive/My Drive/Colab Notebooks/tfidfVectorizer.pkl", "wb"))
```

```
model = pickle.load(open("/content/drive/My Drive/Colab Notebooks/model_ouvidoria.pkl", 'rb'))
```

```
#teste modelo exportado  
testes4 = ['Temos que fechar as indústrias, somos todos vetores de uma possível transmissão']  
freq_testes_4 = vectorizer.transform(testes4)
```

```
result = model.predict(vectorizer.transform(testes4))  
result
```

```
array([5])
```

```
result_val = model.predict(freq_text_)  
result_val
```

```
array([5, 5, 5, ..., 2, 5, 5])
```

Fonte: elaboração do autor

Deploy

Após o desenvolvimento do se fez necessário realizar o *deploy*, colocar em produção o algoritmo, o objetivo final é disponibilizá-lo na produção. Muitas vezes, quando trabalhamos em um projeto de aprendizado de máquina, nos concentramos muito em Análise Exploratória de Dados (EDA), Engenharia de Recursos, ajustes com hiper-parâmetros etc. Mas tendemos a esquecer nosso principal objetivo, que é extrair valor real do modelo previsões.

A implantação de modelos de aprendizado de máquina ou a colocação de modelos em produção significa disponibilizar seus modelos para os usuários ou sistemas finais. No entanto, há complexidade na implantação de modelos de aprendizado de máquina. Esta publicação tem como objetivo começar a colocar em produção seus modelos treinados de aprendizado de máquina usando a API do Flask.


Estrutura do Projeto

Este projeto tem três partes:

srv2.py - contém APIs do Flask que recebem detalhes de vendas por meio de chamadas de GUI ou API, calcula o valor previsto com base em nosso modelo e o retorna.

HTML / CSS - contém o modelo HTML e o estilo CSS para permitir ao usuário inserir detalhes das vendas e exibir as vendas previstas no terceiro mês.

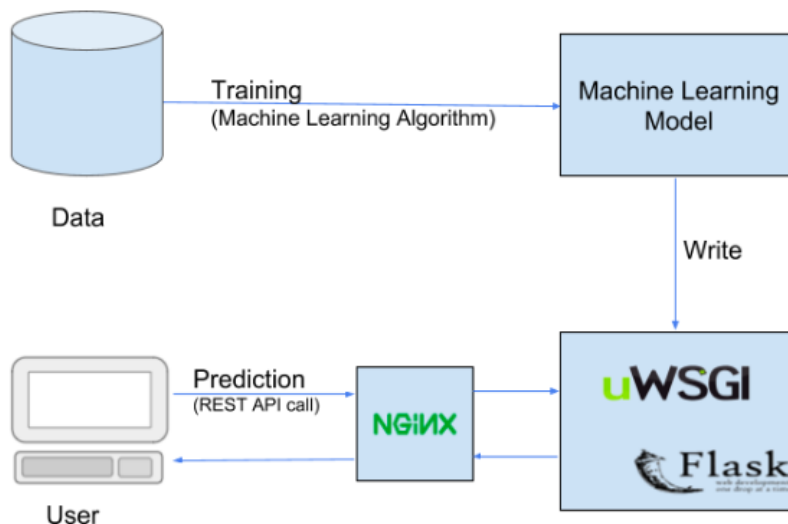
Figura 12 – Estrutura do Projeto



Fonte: elaboração do autor

O sistema opera na seguinte arquitetura proposta:

Figura 13 – Arquitetura Proposta



Fonte: Pipeline for deployment of a Machine Learning model

O arquivo `srv2.py` é o ponto central de operação do projeto, ele realiza requisição do arquivo html para chamada da página, carrega o modelo probabilístico e retorna o resultado conforme os parâmetros processados.

Figura 14 – Estrutura do Arquivo de Processamento

```


14 app = Flask(__name__, static_url_path='/static')
15 model = pickle.load(open("model/model_ouvidoria.pkl", 'rb'))
16 vector = pickle.load(open("model/tfidfVectorizer.pkl", 'rb'))
17
18
19 @app.route('/')
20 def display_gui():
21     return render_template('template_2.html')
22 @app.route('/verificar', methods=['POST'])
23 def verificar():
24
25
26     texto = request.form['texto']
27     texto2 = [texto]
28     x_tfidf = vector.transform(texto2).toarray()
29
30
31
32
33
34
35
36     print("\n")
37
38     classe = model.predict(x_tfidf)
39     classe_2 = int(classe[0])
40     print("Classe Predita: {}".format((classe_2)))
41
42     return render_template('template_2.html', classe=(classe_2))
  
```

Figura 15 – Link Público

Previsão de Status

Texto

O município de Águas Lindas de Goiás, os comércios estão abrindo normalmente com muitas aglomerações , não respeitando o distanciamento social, relembrando que a cidade é extremamente populosa.



Verificar

Resultado do Cluster

Atividades em Funcionamento, funcionários e aglomerações

Link de Acesso: <http://ferreirabruno7.pythonanywhere.com/>

Conclusão

O presente trabalho buscou evidenciar como melhorar a interação nos canais de ouvidoria em tempos de aumento expressivo da demanda, resultado das medidas adotadas para contenção da pandemia do COVID-19 no âmbito do Estado de Goiás e seu Sistema de Ouvidorias gerido pela Controladoria-Geral do Estado. Os resultados obtidos com a adoção e desenvolvimento do sistema CoronaInfo, bem como a experiência vivenciada durante o atendimento a tal demanda de manifestações, evidenciam que apenas com adoção de tecnologias orientadas para maximização da eficiência, é possível realizar atendimento qualificado, segmentado e assertivo. Com adoção de aprendizagem de máquina a Controladoria Geral do Estado de Goiás pode melhorar a qualidade de atendimento em grande escala.

Com a segmentação de interações das manifestações foi possível realizar atendimento qualificado a cada grupo de interação previamente mapeado. Contribuindo para o aumento da eficiência no que tange tanto o tempo necessário para resposta/resolução da manifestação, bem como na qualidade do serviço oferecido pelos servidores envolvidos no atendimento em relação ao cidadão solicitante.

Com intuito de atuar preventivamente na análise das licitações para aquisição de bens e serviços ligados à pandemia foi possível disponibilizar informações para que a população possa fazer o controle social sobre os gastos. O cidadão poderá acompanhar a atualização das informações de solicitação de ouvidoria. Isto qualifica um direito do cidadão poder entender como o Governo de Goiás está interagindo com os usuários que se manifestam nos canais oficiais.

Tendo em vista tais apontamentos e os dados apresentados no presente estudo, chega-se à conclusão que o desenvolvimento e implementação do CoronaInfo, no contexto do atendimento as solicitações e demandas do cidadão durante o período de isolamento social no Estado de Goiás, confirmam a hipótese de que sua adoção foi benéfica no sentido de maximizar a capacidade de atendimento, eficiência na resposta e resolução mais ágil de demandas referentes ao poder executivo estadual.

Referências

Lei nº 4.320, de 17 de março de 1964. Estatui normas gerais de Direito Financeiro para elaboração e controle dos orçamentos e balanços da União, dos Estados, dos Municípios e do Distrito Federal.

Lei Complementar n. 101, de 4 de maio de 2000. Estabelece normas de finanças públicas voltadas para a responsabilidade fiscal e dá outras providências. Diário Oficial [da] República Federativa do Brasil, Brasília, DF, 05 mai. 2000. Seção 1, p. 1.

ABRANCHES, Sergio. Presidencialismo de coalizão: o dilema institucional brasileiro. Dados: Revista de Ciências Sociais, Rio de Janeiro: IUPERJ, vol. 31, n. 1, p. 3-55, 1988. Akgül M and Kırılıdoğ M (2015) Internet censorship in Turkey. *Internet Policy Review* 4(2): 1–21. DOI: 10.14763/2015.2.366.

Akgündüz YE, van den Berg M and Hassink W (2018) The Impact of Refugee Crises on Host Labor Markets: The Case of the Syrian Refugee Crisis in Turkey. *IDEAS Working Paper Series from RePEc* 32(1). Oxford University Press: 19–40. DOI: 10.1093/wber/lhx021.

Akser M (2018) News Media Consolidation and Censorship in Turkey: From Liberal Ideals to Corporatist Realities. *Mediterranean Quarterly* 29(3): 78–97. DOI: 10.1215/10474552-7003180.

Al Jazeera (2014) ‘İstanbul’u alan Türkiye’yi alır’. *Al Jazeera*, 1 March. Available at: <http://www.aljazeera.com.tr/haber-analiz/istanbulu-alan-turkiyeyi-alir>.

Alsup B (2019) Twitter co-founder: Donald Trump is a ‘master of the platform’. *Boston Herald*, 23 May. Available at: <https://www.bostonherald.com/2019/05/23/twitter-co-founder-donald-trump-is-a-master-of-the-platform/>.

Altaylı F (2019) YSK teoremi: Tam ama üçte bir. *Habertürk*, 7 May. Available at: <https://www.haberturk.com/yazarlar/fatih-altayli-1001/2454022-ysk-teoremi-tam-ama-ucte-bir>.

Ataman B and Çoban B (2018) Counter-surveillance and alternative new media in Turkey. *Information Communication and Society* 21(7): 1014–1029. DOI: 10.1080/1369118X.2018.1451908.