Nota Técnica

# OUVIDORIA-GERAL DO DF: UMA ANÁLISE DOS COMENTÁRIOS DA POPULAÇÃO

Brasília, setembro de 2019

codeplan
COMPANHIA DE PLANEJAMENTO DO DISTRITO FEDERAL

Secretaria de Economia
do Distrito Federal

Governo do Distrito Federal

**GOVERNO DO DISTRITO FEDERAL**
**Ibaneis Rocha**
Governador

**Paco Britto**
Vice-Governador

**SECRETARIA DE ECONOMIA DO DISTRITO FEDERAL**
**André Clemente Lara de Oliveira**
Secretário

**COMPANHIA DE PLANEJAMENTO DO DISTRITO FEDERAL - CODEPLAN**
**Jeansley Lima**
Presidente

**Juliana Dias Guerra Nelson Ferreira Cruz**
Diretora Administrativa e Financeira

**Bruno de Oliveira Cruz**
Diretor de Estudos e Pesquisas Socioeconômicas

**Daienne Amaral Machado**
Diretora de Estudos e Políticas Sociais

**Erika Winge**
Diretora de Estudos Urbanos e Ambientais

## EQUIPE RESPONSÁVEL


**Diretoria de Estudos e Pesquisas Socioeconômicas - DIEPS/Codeplan**
**Gerência de Estudos Regionais e Metropolitanos - GEREM/DIEPS/Codeplan**

- Henrique de Mello de Assunção - Assistente I



**Revisão e copidesque**
Eliane Menezes

**Editoração Eletrônica**
GEREM/DIEPS

# RESUMO

O presente trabalho analisa os comentários livres das manifestações de cidadãos na Ouvidoria-Geral do Distrito Federal, com o objetivo de gerar informações que auxiliem no aprimoramento das ações da Controladoria Geral do Distrito Federal e de outros gestores interessados.

A base de dados analisada consiste em dados socioeconômicos do cidadão, referentes ao tipo do protocolo gerado e aos comentários realizados. Observou-se que a maioria dos comentários tem caráter negativo e o teor dos comentários é correlacionado com características socioeconômicas dos indivíduos.

Por fim, utilizou-se uma ferramenta *text mining* que gera um resumo dos comentários referentes a um órgão, o que permite ao gestor ter informações desse órgão lendo apenas os comentários mais relevantes.



**PALAVRAS-CHAVE:** Ouvidoria Geral; Análise de Sentimento; Distrito Federal.

# SUMÁRIO

RESUMO 2

1. INTRODUÇÃO ..... 4

2. DADOS ..... 5

3. ANÁLISE DO CORPO DO TEXTO DOS COMENTÁRIOS ..... 7
3.1. Comentários ..... 7
3.2. Avaliação de Sentimento ..... 8
3.3. Resumidor ..... 13

4. CONCLUSÃO ..... 14

REFERÊNCIAS BIBLIOGRÁFICAS ..... 15

# 1. INTRODUÇÃO

A Ouvidoria-Geral é um importante órgão para a interação do cidadão com o governo. Usando serviços da Ouvidoria, o cidadão pode fazer denúncias, reclamações, solicitações, elogios e sugestões ou repassar informações ao governo. Os dados gerados pela interação entre a Ouvidoria e os cidadãos são mantidos pela Controladoria Geral do Distrito Federal (CGDF). Esses dados representam uma possível fonte de informação sobre as ações do governo, a recepção destas pelo cidadão e da avaliação das respostas às demandas realizadas no canal. Sendo assim, é fundamental a utilização desses dados para obter informações úteis para a população e para o governo.

Tendo como objeto de estudo dados de 2018 da Ouvidoria disponibilizados pela CGDF e a Companhia de Planejamento do Distrito Federal (Codeplan), realizou-se um conjunto de análises sobre esses dados que tiveram como objetivo testar ferramentas para uso da CGDF, assim como obter informações sobre as interações entre os cidadãos e a Ouvidoria. As avaliações foram feitas de modo a serem complementares a estudos como OUV-DF (2018).

Avaliou-se os comentários gerados pelos cidadãos. Esta análise é composta da avaliação de características textuais dos comentários, da avaliação do grau de polaridade dos comentários realizados, se positivos, neutros ou negativos, utilizando aprendizado de máquinas, do cruzamento da polaridade dos comentários com características socioeconômicas dos cidadãos e, por fim, aplicou-se um método de resumir textos a suas partes mais relevantes, o que gerou um subconjunto do texto.

As análises desenvolvidas, em especial a avaliação de polaridade (sentimento) dos comentários e o resumo dos comentários por órgão automatizam uma série de rotinas e servem para nortear uma avaliação mais acurada da qualidade dos serviços prestados. Essa automatização permite a liberação de pessoal para outras atividades assim como gera produtos possíveis de serem utilizados pelos gestores para a melhoria de políticas públicas. Estes temas também são referentes ao Acordo de Cooperação Técnica 01/2016 firmado entre a Codeplan e a Controladoria Geral do Distrito Federal (CGDF).

As análises realizadas seguem modelos encontrados na literatura para avaliação de dados, avaliação de textos e aplicação de modelos de aprendizado de máquinas (DEY *et al.*, 2016). Utilizou-se o software R e os pacotes *dplyr* (WICKHAM *et al.*, 2019), *tidytext* (SILGE; ROBINSON, 2016), *stopwords* (BENOIT; MUHR; WATANABE, 2017), *viridis* (GARNIER, 2018), *ggridges* (WILKE, 2018), *readxl* (WICKHAM; BRYAN, 2019), *janitor* (FIRKE, 2019), *e1071* (MEYER *et al.*, 2019) e *quanteda* (BENOIT *et al.*, 2018).

## 2. DADOS

Este estudo utilizou duas bases de dados disponibilizadas pela Controladoria Geral do Distrito Fedral (CGDF). As duas bases são referentes ao ano de 2018 e foram enviadas pela internet para a Codeplan e contêm informações sobre as interações do cidadão com a Ouvidoria. Cada interação com a Ouvidoria gera um protocolo que durante esta interação pode ser que seja realizada uma série de perguntas ao cidadão, dependendo do meio de contato. As duas bases enviadas contêm informações sobre os protocolos gerados. A primeira tabela é menor, com dados de 18.156 protocolos com comentários, enquanto a segunda contém dados de 193.109 protocolos, dos quais, 33.999 possuem questões. Dos protocolos que possuíam questões, 20.047 tinham comentários.

Os protocolos referem-se a vários órgãos dos governo do Distrito Federal, com oitenta diferentes órgãos na primeira base e oitenta e seis diferentes órgãos na segunda base. As duas bases apresentam diferentes tipos de órgãos distritais tais como administrações regionais, secretarias de governo e empresas públicas.

A primeira base enviada contém informações de cada questão perguntada ao cidadão ao longo do protocolo, tais como o conteúdo da questão, o número do protocolo, a resposta do cidadão, classificação do protocolo, o assunto, o órgão e a situação do protocolo (resolvida, não resolvida e respondida).Já a segunda base contém informações sobre a pergunta realizada, a resposta, o número do protocolo, a faixa de renda, a formação, a raça/cor do indivíduo, endereço, sexo e órgão, referentes a cada pergunta realizada para o cidadão. Essas bases possibilitam diferentes análises de acordo com os dados presentes.

Realizou-se uma comparação entre as duas bases utilizadas de modo a validar os dados obtidos e obter mais informações sobre os dados. Nesta comparação, foram observados os protocolos referentes a cada órgão e se estes valores eram semelhantes entre as duas bases. Foram considerados apenas os protocolos com questões da segunda base de modo que as duas bases fossem semelhantes e a comparação pudesse ser realizada. Observou-se que a proporção de interações do cidadão com cada órgão é semelhante entre as bases. Um exemplo disto é que ambas as bases apresentam o mesmo órgão com maior número de interações, o DFTRANS. Isso ocorre, pois, nesse ano, houve um aumento expressivo da quantidade de reclamações referentes ao passe livre estudantil (OUV-DF, 2018). As informações sobre os dez órgãos que obtiveram mais interações em ambos os grupos, considerando protocolos com comentários, podem ser vistas na Tabela 1.

**Tabela 1** – Órgãos com maior número de protocolos

| Órgão | Nº de protocolos 1ª base | Proporção do total na 1ª base | Nº de protocolos 2ª base | Proporção do total na 2ª base |
|---|---|---|---|---|
| DFTRANS | 4.997 | 28% | 8.878 | 26% |
| SES | 1.661 | 9% | 3.569 | 10% |
| AGEFIS | 1.535 | 8% | 2.986 | 9% |
| NOVACAP | 1.318 | 7% | 2.626 | 8% |
| DETRAN | 1.364 | 8% | 2.616 | 8% |
| SEDESTMIDH | 631 | 3% | 1.395 | 4% |
| SEMOB | 1.087 | 6% | 1.212 | 4% |
| CEB | 585 | 3% | 1.090 | 3% |
| SEFAZ | 546 | 3% | 1.089 | 3% |
| IBRAM | 530 | 3% | 1.048 | 3% |

Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018

Segundo a OUV-DF (2018), houve um grande aumento de interações com a Ouvidoria referentes ao passe livre. A prevalência do passe livre como assunto da interação pode ser observada na primeira base. Protocolos referentes ao passe livre correspondem a 19,10% dos protocolos da primeira base, mais do que quatro vezes a proporção do segundo colocado, tapa-buracos, com 4,10%. Este comportamento atípico de 2018 pode influenciar em alguns resultados da avaliação e deve ser considerado na interpretação destes. Os principais assuntos da primeira base de dados podem ser observados na Tabela 2.

**Tabela 2** – Assuntos com maior número de comentários

| Assunto | Nº de protocolos | Proporção do total de protocolos |
|---|---|---|
| Cartão Estudante - passe livre estudantil - SBA | 3.567 | 20% |
| Tapa-Buraco - manutenção de vias públicas | 744 | 4% |
| Fiscalização - poluição sonora | 516 | 3% |
| Conduta do motorista de ônibus | 477 | 3% |
| Servidor Público | 459 | 3% |
| Descumprimento de tabela horária dos ônibus | 427 | 2% |
| Atendimento em unidade de saúde pública | 404 | 2% |
| Funcionamento de poste de iluminação | 377 | 2% |
| Poda de árvore | 362 | 2% |
| Solicitação de extrato de cartão - DFTRANS | 313 | 2% |

Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018

Uma importante consideração a fazer é que ambas as bases referem-se a interações do cidadão com a Ouvidoria no período eleitoral de 2018. Este fato pode alterar como o cidadão interage com os diversos órgãos públicos assim como a resposta desses órgãos ao cidadão. Por fim, vale ressaltar que OUV-DF (2018) e outros estudos realizados pela CGDF avaliam os dados da Ouvidoria e proveem informações relevantes sobre a ferramenta, constituindo fontes de informações para os interessados na Ouvidoria.

# 3. ANÁLISE DO CORPO DO TEXTO DOS COMENTÁRIOS

## 3.1. Comentários

A primeira base de dados enviada pela Ouvidoria foi utilizada para análise das características textuais dos comentários. Escolheu-se essa base por conter informações das classificações dos protocolos. Os comentários dessa base foram analisados quanto à sua estrutura, utilizando-se para tal o número de caracteres do comentário. Avaliou-se se existe alguma diferença entre as classificações disponíveis (Solicitação, Denúncia e Reclamação), e que a classificação Solicitação foi subdividida em dois grupos: Solicitação e Solicitação Mista. O primeiro grupo resume as interações nas quais se perguntou o que desagradou ao cidadão na resposta para a Ouvidoria, enquanto o segundo refere-se aos casos em que se perguntou ao cidadão tanto o que lhe agradou quanto o que lhe desagradou. Avaliou-se também se existe alguma diferença entre a estrutura dos comentários feitos para diferentes órgãos. Nas análises realizadas, foram removidos três comentários com mais de 500 caracteres por estes serem valores extremos que não adicionavam informações ao padrão de comentários e prejudicavam a avaliação e observação dos resultados.

A primeira constatação é que há uma diferença significativa entre o número de caracteres usados entre os quatro grupos avaliados: Solicitação, Solicitação Mista, Denúncia e Reclamação. As pessoas escrevem mais em Denúncias, Solicitações e Reclamações do que escrevem em Solicitações Mistas, ou seja, as pessoas deixam mais comentários sobre o que lhes desagradou do que quando comentam sobre o que lhes agradou e desagradou. A distribuição de caracteres por comentário pode ser observada no Gráfico 1. Denúncias e reclamações apresentam distribuições semelhantes, enquanto solicitação apresenta um pico maior em torno dos 50 caracteres e solicitação mista, um pico muito superior a cerca de 30 caracteres.

**Gráfico 1** – Densidade do número de caracteres por classificação do protocolo

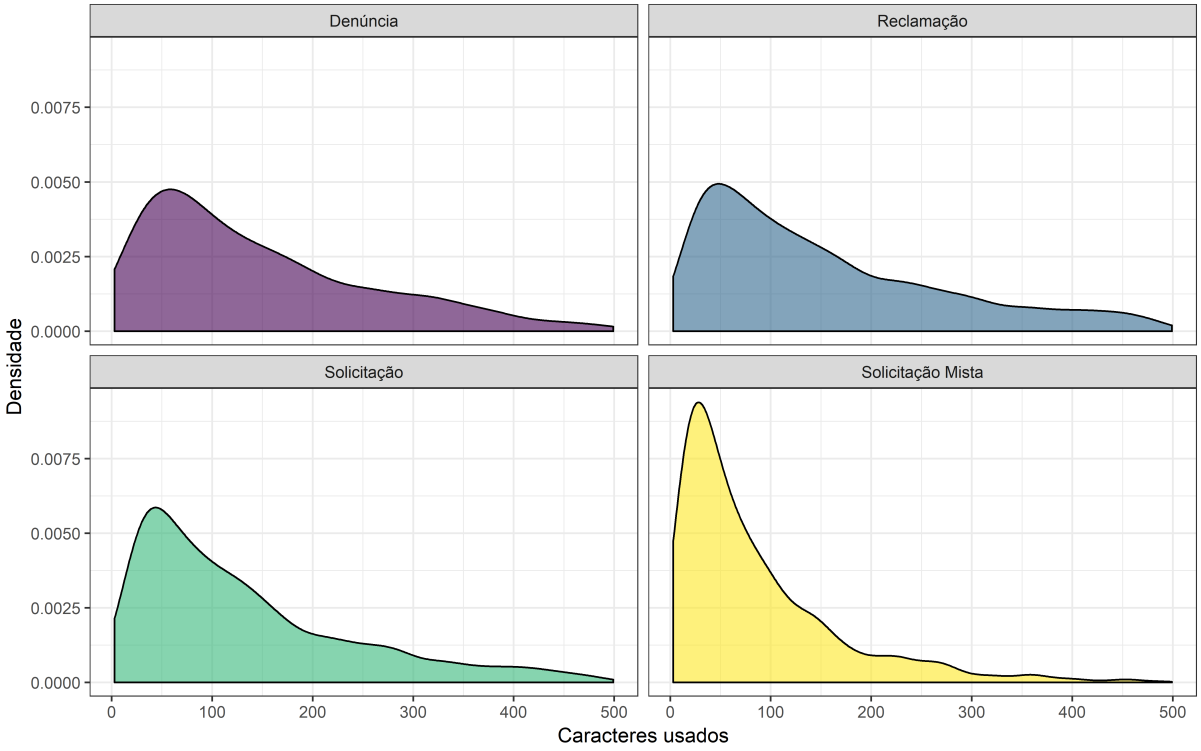


Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018

A avaliação textual também foi realizada para os órgãos com mais de cem comentários. A análise foi limitada a órgãos com mais de cem comentários de modo a não adicionar órgãos com poucos comentários que prejudicassem a avaliação e para facilitar a interpretação dos resultados. Observa-se que existe diferença entre os comentários feitos para os diferentes órgãos. As interações com a Secretaria de Educação são as que levam o

cidadão a escrever mais; esta diferença é estatisticamente significativa quando se compara esta secretaria com qualquer outro órgão. A distribuição de caracteres para os órgãos selecionados pode ser observada no Gráfico 2.

**Gráfico 2** – Densidade do número de caracteres por classificação do protocolo

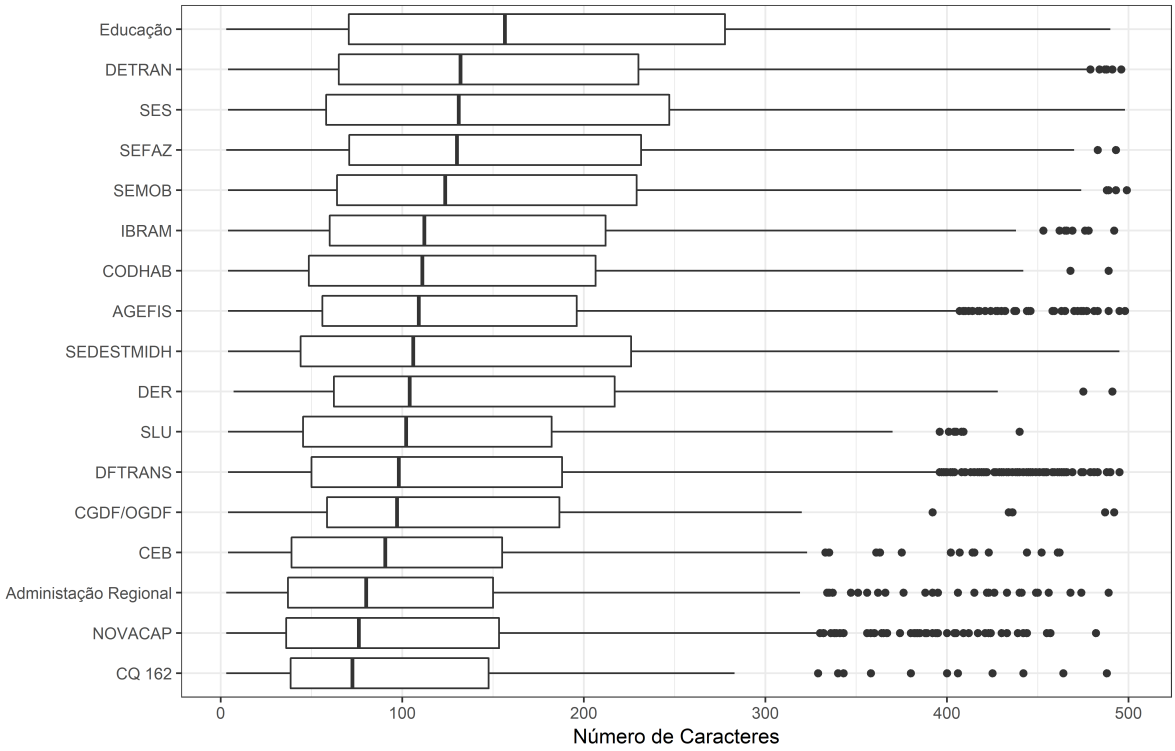


Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018

### 3.2. Avaliação de Sentimento

A segunda base de dados enviada pela Ouvidoria foi utilizada na análise de sentimentos. Esta base contém uma informação importante dos comentários realizados para a Ouvidoria; é o grau de satisfação expresso nele. Infelizmente, a comunicação humana é complexa e obter um valor de satisfação ou insatisfação de um conjunto de textos não é trivial, em particular quando há milhares de textos a serem analisados. Devido à importância da informação textual, foram desenvolvidos métodos de classificação dos textos de acordo com o sentimento que expressa e, em especial, quanto a sua polaridade, ou seja, se o comentário é positivo ou negativo. Atualmente há quatro principais tipos de métodos de classificação de texto:

- Avaliação humana;
- Avaliação por dicionários;
- Avaliação por aprendizado supervisionado;
- Avaliação por aprendizado não supervisionado.

A avaliação humana consiste na classificação do texto por leitores humanos de acordo com categorias de interesse. A avaliação por dicionários utiliza dicionários preexistentes, em geral criados por especialistas na língua de interesse, para obter informações do sentimento do texto de acordo com os dicionários usados. Os últimos dois tipos de avaliação citados utilizam técnicas computacionais de modo a classificar o texto. O aprendizado supervisionado utiliza um subconjunto de textos já classificados de acordo com as categorias de interesse, um algoritmo observa padrões nesses textos e os relacionam com estas categorias e, então, segundo os padrões observados, os textos são classificados de acordo com as categorias de interesse. Por fim, o aprendizado não supervisionado observa padrões no texto e os classifica de acordo com categorias não preestabelecidas pelo analista.

Escolheu-se fazer uma avaliação por aprendizado supervisionado, por esta obter os melhores resultados na literatura avaliada e nos testes iniciais. Entre os diferentes métodos possíveis, foi selecionado o algoritmo *Nayve Bayes* por obter os melhores resultados nos testes iniciais e pela sua facilidade de implementação (DEY *et al.*, 2016). *Nayve Bayes* é um algoritmo de aprendizado supervisionado, em que o algoritmo utiliza o teorema de Bayes e a hipótese de independência das características consideradas.

As seguintes etapas foram seguidas na implementação do algoritmo:

1. Classificou-se manualmente um subconjunto de comentários;
2. O texto foi pré-processado de modo a poder ser processável pelo algoritmo;
3. Estes comentários classificados foram então utilizados para treinar um modelo de classificação de comentários com o algoritmo *Nayve Bayes*;
4. Os comentários foram classificados segundo o modelo obtido no item três.

É necessário que um subconjunto dos comentários seja classificado manualmente, de modo que o algoritmo tenha uma base inicial com a qual possa *aprender* a classificar os comentários. Portanto, foram classificados 876 comentários nas categorias neutro-bom, ruim e péssimo. Os comentários foram selecionados aleatoriamente, classificando-se vários blocos de comentários ao longo dos dados. Como os comentários foram selecionados aleatoriamente, espera-se que não haja viés de seleção, porém existe alguma variação da classificação devido ao fato de se classificar uma amostra do total de comentários.

Também é necessário transformar os comentários em uma base de dados que seja possível de ser processada pelo algoritmo. Desta forma, utilizou-se o pacote *quanteda* (BENOIT *et al.*, 2018) para remover as *stopwords*, remover números, remover símbolos e lematizar os comentários. Os comentários foram transformados em vetores de valores binários que continham informações se os comentários continham ou não determinadas palavras e determinados bigramas de palavras. As palavras consideradas por este vetor foram selecionadas a partir dos comentários avaliados manualmente. Este vetor que é usado pelo algoritmo *naive Bayes* para a classificação do comentário.

Os comentários foram classificados em três categorias: **péssimo**, **ruim** e **neutro-bom**. Devido à maioria das interações com a Ouvidoria ser de teor negativo, as classificações têm uma tendência negativa e a divisão nas três categorias permite uma avaliação razoável da satisfação dos comentários, além de limitar o número de categorias a serem classificadas pelo modelo, facilitando sua implementação. As categorias foram agregadas por meio de transformações numéricas, o que se considerou péssimo como -1, ruim como 0 e 1 como neutro-bom.

O modelo selecionado não é perfeito, porque comete uma série de erros de classificação. Esta é uma característica comum dos modelos de classificação. Buscou-se reduzir a quantidade de *erros graves*, o caso em que o classificador considerava um comentário neutro-bom como péssimo ou o inverso. Abaixo, mostra-se um exemplo de resultados obtidos com o classificador:

1. Exemplos de comentários classificados como Neutro-Bom:
   (a) ”Disseram que me ligaram, mas não tenho registro no meu celular da ligação.”
   (b) ”O atendimento do servidor *[nome do servidor]* foi muito solícito e prestativo e me ajudou a resolver essa questão.”
2. Exemplos de comentários classificados como Ruins:
   (a) ”A falta de um prazo para corrigir o problema identificado.”
   (b) ”Não resolveu nada!”
3. Exemplos de comentários classificados como Péssimos:
   (a) ”Nao retiraram o lixo e aqui informaram que foi retirado, isso não é verdade, pois moro nesta rua e vejo a montanha de lixo todos os dias... e não adiantou informar quem são as pessoas que emporcalham o ambiente, nada acontece e continuam jogando lixo em qualquer lugar ... totalmente insatisfeita...”

Como era de se esperar, devido à preponderância de interações de caráter negativo, a maioria dos comentários foi classificada como ruim, seguida pela categoria péssimo e por fim a categoria neutro-bom. Foram 12.659 dos comentários que tiveram a classificação ruim, representando 63,15% do total, 4.187 foram classificados como péssimos, 20,89%, e 3.201 tiveram a classicação neutro-bom o que representa 15,97%.

O pequeno valor de comentários de caráter positivo está relacionado à natureza da interação do cidadão com a Ouvidoria. Entretanto, é possível tornar a interação mais positiva ao melhorar o serviço público e a resposta ao cidadão. Desta forma, é possível utilizar os valores obtidos nesta avaliação como parâmetro para a avaliação da qualidade da interação dos cidadãos em anos futuros.

Criou-se uma nuvem de palavras dos comentários classificados como neutros-bons; esta nuvem pode ser observada no Gráfico 3. Essa nuvem permite avaliar quais palavras os cidadãos mais utilizam em comentários com teor positivo e avaliar se pode ser observado algum padrão. Observou-se que os cidadãos costumam utilizar palavras referentes ao tempo de serviço como presteza, agilidade, rápido e demora em comentários de teor positivo indicando que a resolução célere da demanda é um fator relevante para a avaliação positiva por parte do cidadão. Outro ponto observado é a utilização de palavras indicando resolubilidade da demanda, como resolução, execução e resolvido, apontando que a resolução da demanda do cidadão é um fator relevante para este ter uma visão positiva do serviço público.

**Gráfico 3** – Nuvem de palavras dos comentários classificados como neutros-bons

Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018

### 3.2.1 Cruzamento com informações socioeconômicas

Os resultados de sentimentos foram cruzados com as variáveis de sexo, formação e faixa de renda. Observa-se que a classificação dos comentários está correlacionada com as características dos cidadãos que fizeram a interação. Mulheres tendem a fazer comentários mais negativos do que homens; a diferença entre elas é significativa ($p$-valor < 0,05) considerando o método de agregação utilizado. A diferença entre os dois grupos pode ser visualizada no Gráfico 4.

O cruzamento da formação não demonstrou nenhuma tendência clara; é possível que diferentes produtos afetem os diferentes níveis de formação. Um exemplo disso é o aumento do número de queixas quanto ao passe livre estudantil que afetou mais os cidadãos com ensino superior incompleto do que o restante da população. A polaridade média por nível de formação deste cruzamento pode ser observada no Gráfico 5.

**Gráfico 4** – Polaridade do comentário de acordo com o sexo do cidadão

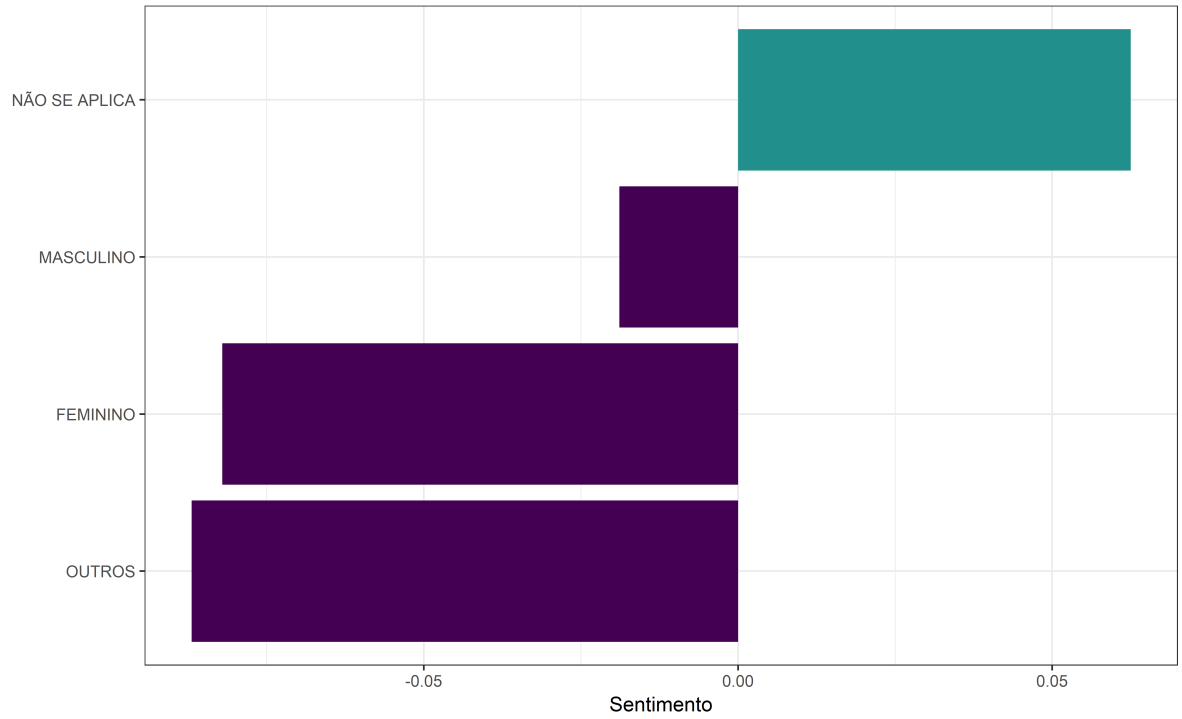


Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018. Classificação dos comentários: neutro/bom (+1), ruim (0) e péssimo (-1)

O cruzamento das classificações dos comentários com a faixa de renda do cidadão que fez a interação mostra uma tendência clara: quanto maior a renda do cidadão que fez a interação, maior a probabilidade de um comentário neutro-bom e menor a probabilidade de um comentário péssimo. Esta tendência pode ser observada no Gráfico 6.

**Gráfico 5** – Polaridade do comentário de acordo com a Formação do cidadão

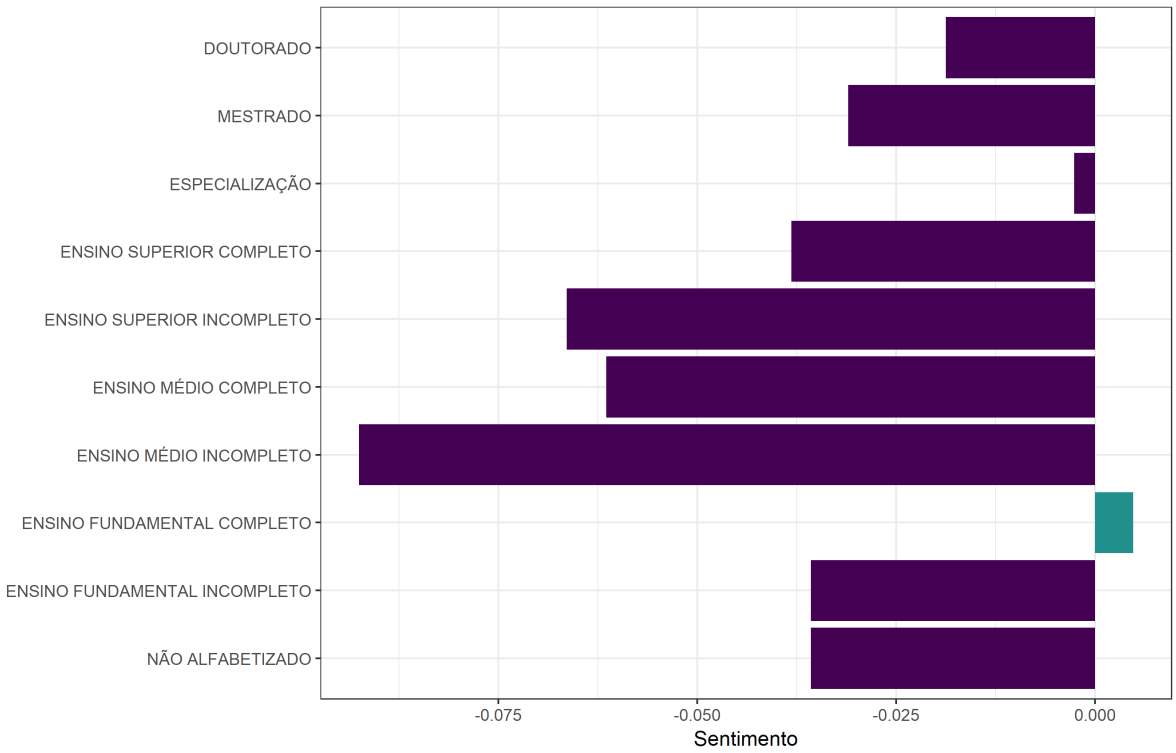


Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018. Classificação dos comentários: neutro/bom (+1), ruim (0) e péssimo (-1)

**Gráfico 6** – Polaridade do comentário de acordo com a faixa de renda do cidadão

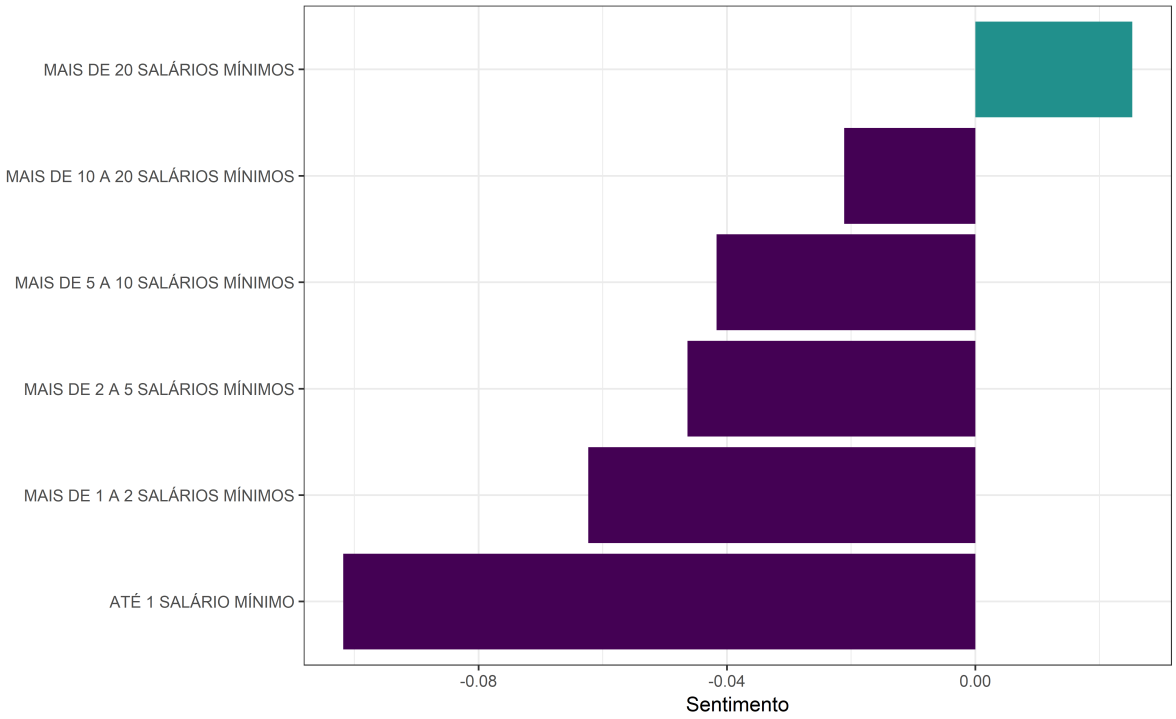


Fonte: Elaboração própria a partir dos dados da Ouvidoria 2018. Classificação dos comentários: neutro/bom (+1), ruim (0) e péssimo (-1)

### 3.3. Resumidor

Existe uma grande quantidade de comentários para cada órgão. O volume de comentários feitos pode chegar à casa dos milhares, tornando improdutiva a leitura de todos eles pelo gestor. Com o objetivo de auxiliar o entendimento do gestor sobre as interações feitas pelos usuários, criou-se um resumidor dos comentários realizados de cada órgão. Utilizou-se técnicas de Processamento de Linguagem Natural para obter comentários significativos.

A ferramenta cria uma rede dos comentários - em que cada comentário é um nó dessa rede - que é conectada por palavras que estes compartilham. Os comentários mais importantes são os comentários centrais dessa rede. Esses comentários seriam os melhores comentários para se ler caso se queira ter uma ideia geral de todos os comentários, lendo-se o mínimo possível.

De modo a exemplificar o resultado desta ferramenta, abaixo, tem-se um exemplo dos quatro comentários mais significativos referentes à Secretaria de Segurança Pública de acordo com o algoritmo utilizado.

1. ”resposta vazia e sem qualquer prazo”;

2. ”a resposta é vaga e não atende a situação exposta na reclamação formulada; problema persiste, a rua continua interditada, o buraco aberto expondo a risco de vida a população lindeira e demais transeuntes, a calçada destruída, o risco iminente e nenhuma providência efetiva foi adotada pela administração pública, que é gestora dos interesses públicos;”

3. ”o tempo passa, o problema continua e nada de concreto é realmente realizado pela administração pública. Serão necessários danos ainda mais gravosos para que sejam adotadas providências eficazes para a resolução do problema? Vidas poderão ser perdidas, o patrimônio público e privado ameaça ruir e nada é feito;”

4. ”eu fiz meu cadastro no cdp/ centro de detenção provisória, e portanto minha visita já é na semana que vem e ainda não liberou, o meu não é recadastramento, a minha portanto vai ser a primeira visita.”

Estes comentários podem ser usados para representar o conjunto de todos os comentários. O gestor, então, poderia ler os principais comentários e ter uma noção dos comentários realizados pelos cidadãos. Este ganho de informação possibilitaria uma melhor compreensão do gestor do seu órgão.

Uma fraqueza da ferramenta apresentada é sua vulnerabilidade ao uso de *spam*, ou seja, vários comentários similares feitos pela mesma pessoa. Caso isso ocorra, é possível que apareçam apenas comentários desse tipo entre os compreendidos como mais relevantes. Avanços futuros podem tornar a ferramenta mais robusta.

# 4. CONCLUSÃO

A presente nota técnica observou uma série de características dos comentários feitos no sistema da Ouvidoria. Avaliou-se as características textuais dos comentários, a polaridade dos comentários por meio de aprendizado de máquinas, o cruzamento dos dados de polaridade com dados socioeconômicos e por último propôs-se um resumidor dos dados da Ouvidoria. Estes métodos geram informações para melhor conhecimento e uso dos dados da Ouvidoria-Geral do Distrito Federal.

Observou-se que as diferentes manifestações têm características textuais diferentes, com denúncias e reclamações e com mais similaridades entre si; outro fato é que solicitações em que o cidadão foi atendido geram comentários mais curtos do que os demais tipos de interações. Além disso, observa-se que os cidadãos escrevem mais em interações referentes à Secretaria de Educação do que em outros órgãos comparáveis.

Avaliou-se que a polaridade dos comentários feitos é devido à base da Ouvidoria ser uma base de interações geralmente negativas com o governo; a maioria dos comentários tem teor negativo. Entretanto esta negatividade não está distribuída homogeneamente entre todos os grupos. Mulheres fazem comentários de teor mais negativo do que homens, pessoas mais ricas fazem comentários de teor mais positivo do que pessoas de renda mais baixa. Além disso, existe uma diferença de polaridade nos comentários dos diferentes órgãos.

Por fim, foi feito um resumidor dos comentários referentes a cada órgão. O resumidor permite que o gestor tenha uma noção das manifestações feitas sobre o órgão de interesse lendo uma quantidade reduzida de comentários. Isso permite economia de tempo dos gestores interessados e ganho de informação sobre os serviços realizados. É necessário um avanço neste tipo de ferramenta, de modo que ela possa ser mais robusta ao uso de *spam* por parte dos usuários.

## REFERÊNCIAS

BENOIT, K.; MUHR, D.; WATANABE, K. **stopwords: Multilingual Stopword Lists**. [S.l.], 2017. R package version 0.9.0. Disponível em: <https://CRAN.R-project.org/package=stopwords>.

BENOIT, K. *et al.* quanteda: An r package for the quantitative analysis of textual data. **Journal of Open Source Software**, v. 3, n. 30, p. 774, 2018. Disponível em: <https://quanteda.io>.

DEY, L. *et al.* Sentiment analysis of review datasets using naive bayes and k-nn classifier. **arXiv preprint arXiv:1610.09982**, 2016.

FIRKE, S. **janitor: Simple Tools for Examining and Cleaning Dirty Data**. [S.l.], 2019. R package version 1.2.0. Disponível em: <https://CRAN.R-project.org/package=janitor>.

GARNIER, S. **viridis: Default Color Maps from 'matplotlib'**. [S.l.], 2018. R package version 0.5.1. Disponível em: <https://CRAN.R-project.org/package=viridis>.

MEYER, D. *et al.* **e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien**. [S.l.], 2019. R package version 1.7-1. Disponível em: <https://CRAN.R-project.org/package=e1071>.

OUVIDORIA-DF. Ouvidoria Geral do Distrito Federal. **Relatório de Gestão 2015-2018**. 2018. <http://www.ouvidoria.df.gov.br/wp-content/uploads/2018/05/Relat%C3%B3rio-Anual-2018-Final.pdf>. Online; acessado em 05/06/2019.

SILGE, J.; ROBINSON, D. tidytext: Text mining and analysis using tidy data principles in r. **JOSS**, The Open Journal, v. 1, n. 3, 2016. Disponível em: <http://dx.doi.org/10.21105/joss.00037>.

WICKHAM, H.; BRYAN, J. **readxl: Read Excel Files**. [S.l.], 2019. R package version 1.3.1. Disponível em: <https://CRAN.R-project.org/package=readxl>.

WICKHAM, H. *et al.* **dplyr: A Grammar of Data Manipulation**. [S.l.], 2019. R package version 0.8.0.1. Disponível em: <https://CRAN.R-project.org/package=dplyr>.

WILKE, C. O. **ggridges: Ridgeline Plots in 'ggplot2'**. [S.l.], 2018. R package version 0.5.1. Disponível em: <https://CRAN.R-project.org/package=ggridges>.

**Companhia de Planejamento do Distrito Federal - Codeplan**
Setor de Administração Municipal
SAM, Bloco H, Setores Complementares
Ed. Sede Codeplan
CEP: 70620-080 - Brasília-DF
Fone: (0xx61) 3342-2222
www.codeplan.df.gov.br
codeplan@codeplan.df.gov.br