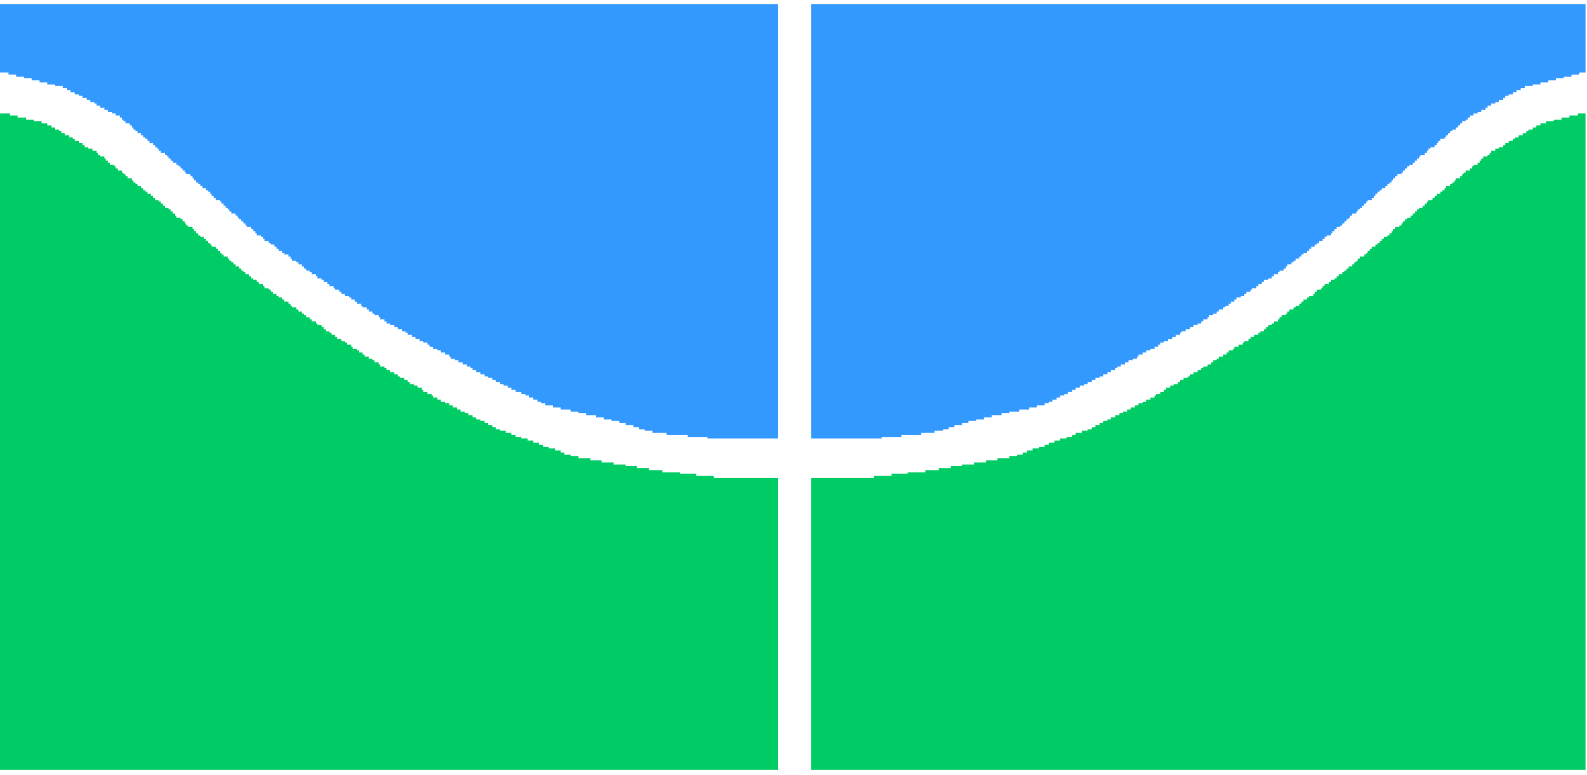

Universidade de Brasília - UnB
Faculdade UnB Gama - FGA
Engenharia de Software

Análise de textos parlamentares

Autor: Matheus Souza Fernandes
Orientador: Prof. Dr. Fábio Macedo Mendes

Brasília, DF
2016

Matheus Souza Fernandes

Análise de textos parlamentares

Monografia submetida ao curso de graduação em (Engenharia de Software) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia de Software).

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Prof. Dr. Fábio Macedo Mendes

Brasília, DF

2016

Matheus Souza Fernandes
Análise de textos parlamentares/ Matheus Souza Fernandes. – Brasília, DF, 2016-
45 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Fábio Macedo Mendes

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB
Faculdade UnB Gama - FGA , 2016.

1. processamento de linguagem natural. 2. aprendizado de máquina. I. Prof. Dr. Fábio Macedo Mendes. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Análise de textos parlamentares

CDU 02:141:005.6

Matheus Souza Fernandes

Análise de textos parlamentares

Monografia submetida ao curso de graduação em (Engenharia de Software) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia de Software).

Trabalho aprovado. Brasília, DF, 01 de junho de 2013:

Prof. Dr. Fábio Macedo Mendes
Orientador

Paulo Roberto Miranda Meirelles
Convidado 1

Titulação e Nome do Professor
Convidado 02
Convidado 2

Brasília, DF
2016

Resumo

O resumo deve ressaltar o objetivo, o método, os resultados e as conclusões do documento. A ordem e a extensão destes itens dependem do tipo de resumo (informativo ou indicativo) e do tratamento que cada item recebe no documento original. O resumo deve ser precedido da referência do documento, com exceção do resumo inserido no próprio documento. (. . .) As palavras-chave devem figurar logo abaixo do resumo, antecedidas da expressão Palavras-chave:, separadas entre si por ponto e finalizadas também por ponto. O texto pode conter no mínimo 150 e no máximo 500 palavras, é aconselhável que sejam utilizadas 200 palavras. E não se separa o texto do resumo em parágrafos.

Palavras-chaves: latex. abntex. editoração de texto.

Abstract

This is the english abstract.

Key-words: latex. abntex. text editoration.

Lista de ilustrações

Figura 1 – Exemplo de clusterização 25
Figura 2 – Diagrama de Voronoy de 20 pontos 26
Figura 3 – k centróides (coloridos) recebem valores iniciais. 26
Figura 4 – Cálculo das distâncias entre os pontos e os centróides. 27
Figura 5 – Novos centróides definidos pela media dos elementos do *cluster*. 27
Figura 6 – O algorítmo converge quando nenhum ponto muda de *cluster*. 27
Figura 7 – Comparação entre distância euclidiana e de manhattan 28
Figura 8 – Representação do teste de caixa-preta 31

Lista de tabelas

Tabela 1 – Exemplos de *Stop Words* 24

Listings

2.1 Representação de um trecho no modelo bag-of-words 21

Sumário

Listings **13**

1 INTRODUÇÃO **17**
1.1 Contextualização **17**
1.2 Objetivo **18**
1.2.1 Contribuições Tecnológicas 18
1.2.2 Contribuições Científicas 18
1.3 Metodologia **18**
1.4 Organização do Trabalho **19**

2 PROCESSAMENTO DE LINGUAGEM NATURAL **21**
2.1 Modelo *bag-of-words* **21**
2.1.1 Representação dos Termos 21
2.1.1.1 *Boolean* 21
2.1.1.2 *Term Frequency* 22
2.1.1.3 *Term Frequency - Inverse Document Frequency* 22
2.1.2 Dimensionalidade dos documentos 22
2.1.2.1 Stemização 23
2.1.2.2 *Stop Words* 23
2.2 Clusterização **25**
2.2.1 Algorítmo *k-means* 25
2.2.1.1 Distância entre os pontos 27

3 ENGENHARIA DE SOFTWARE **29**
3.1 *Framework* de gerenciamento *SCRUM* **29**
3.1.1 Time *SCRUM* 29
3.1.1.1 *Product Owner* 29
3.1.1.2 Time de Desenvolvimento 29
3.1.1.3 *Scrum Master* 29
3.1.2 Eventos do *SCRUM* 30
3.1.2.1 *Sprint* 30
3.1.2.2 Reunião de planejamento de *sprint* 30
3.1.2.3 Revisão de *sprint* 30
3.1.3 Artefatos do *SCRUM* 30
3.1.3.1 *Backlog* de produto 30
3.1.3.2 *Backlog* de *sprint* 31

3.2 Testes de Software 31
3.2.1 Classificação dos Testes 31
3.2.1.1 Testes de caixa-preta 31

REFERÊNCIAS 33

APÊNDICES 35

APÊNDICE A – PRIMEIRO APÊNDICE 37

APÊNDICE B – SEGUNDO APÊNDICE 39

ANEXOS 41

ANEXO A – PRIMEIRO ANEXO 43

ANEXO B – SEGUNDO ANEXO 45

1 Introdução

1.1 Contextualização

O desenvolvimento de novas ferramentas de interação entre governo e sociedade é fundamental para o avanço da democracia (MAZONI, 2011). Porém, torna-se imprecindível a aplicação do conceito de Dados Abertos por parte do Governo para que essas novas ferramentas tenham efeitos significativos para a sociedade.

O conceito para Dado Aberto a ser considerado para esse trabalho é o definido pela Open Knowledge (2016), onde é estabelecido que um dado (ou um conhecimento) é aberto quando estiver livre para uso, reuso e redistribuição. Ou seja, a informação deve estar disponível à todos, sem restrições de *copyright*, patentes ou outros mecanismos de controle. Além disso, esses dados devem ser independentes de tecnologia, basear-se em formatos padronizados, ser desvinculados de ferramentas que os originaram, permitir sua manipulação por máquinas e possuir metadados, permitindo que seja identificada sua natureza, origem e qualidade (DINIZ, 2010).

No contexto governamental, os Dados Abertos fortalecem três características indispensáveis para a democracia: transparência, participação e colaboração (MAZONI, 2011). Onde a transparência tem o papel de informar a sociedade sobre as ações que estão sendo tomadas ou que serão tomadas pelo governo, a participação permite que os cidadãos auxiliem o poder público a elaborar políticas mais eficazes e a colaboração entre a sociedade, diferentes níveis de governo e a iniciativa privada aprimoram a eficácia do Estado.

De acordo com a Lei n°12.527/2011, também conhecida como Lei de Acesso à Informação, qualquer cidadão, sem necessidade de justificativa, pode solicitar dados ou informações à qualquer órgão ou entidade pública dos poderes Executivo, Legislativo e Judiciário, além do Ministério Público, nas esferas Federal, Estadual e Municipal (BRASIL, 2011). Para atender à lei mencionada anteriormente, a Câmara dos Deputados (2016) criou um portal que tem como objetivo disponibilizar dados brutos para a utilização em aplicações que permitam a percepção mais efetiva das atividades parlamentares, desenvolvidas pelos cidadãos e entidades da sociedade civil.

A publicação de dados pressupõe o uso de tecnologias que garantam que eles possam ser acessados e reutilizados por máquinas. No entanto, não garante que os dados estarão disponíveis da melhor forma, mas permite que sejam utilizadas da maneira e conveniência do interessado, de tal forma que possibilita o cruzamento de diferentes bases dados e a exibição destes de forma que possam ser melhor apresentados à sociedade (DINIZ, 2010).

1.2 Objetivo

O objetivo desse trabalho é utilizar técnicas de processamento de linguagem natural para, através da análise dos discursos e proposições dos parlamentares, determinar um perfil temático para os deputados, bem como evidenciar o termos mais utilizados em seus discursos e proposições e, assim, permitir que o cidadão veja, de forma comparativa, o que seus representantes no parlamento mais dizem em seus discursos e o que mais dizem em suas proposições.

1.2.1 Contribuições Tecnológicas

- Implementar biblioteca Python para consumo de dados abertos governamentais, com foco nos dados abertos da Câmara dos deputados.
- Implementar aplicação Django para utilização e persistência dos dados abertos governamentais, também com foco nos dados aberto da Câmara dos deputados.
- Implementar sistema web de comparação entre discursos e proposições parlamentares, a ser detalhado no decorrer deste trabalho.

1.2.2 Contribuições Científicas

- Estudo teórico sobre Processamento de Linguagem Natural.
- Estudo teórico sobre métodos estatísticos aplicados à análise de textos.

1.3 Metodologia

Devido à natureza desse trabalho, nota-se que o modelo de pesquisa adequado de possuir características tanto da pesquisa exploratória, para conhecer o que já foi estudado sobre o tema e delimitar um campo de trabalho, quanto da pesquisa experimental, uma vez que o próprio objeto de estudo será colocado em condições técnicas de observação e manipulação experimental para a criação de condições adequadas para o seu tratamento. Outro método de pesquisa que será utilizado é a pesquisa-ação, onde existirão ciclos de coleta e análise de dados. A cada ciclo, a análise dos dados do ciclo anterior servirão de insumo para tomadas de decisão no desenvolvimento do projeto.

Durante a fase de desenvolvimento do sistema, pretende-se utilizar uma abordagem de ágil, com a aplicação de algumas práticas adaptadas do *framework* Scrum:

- Nas retrospectivas de *sprint*, serão realizadas avaliações, para identificar os pontos fortes e fracos da *sprint* que terminou, bem como propor possíveis ações que poderão ser tomadas para mitigar os pontos fracos, na próxima *sprint*.

- *Daily meetings*, onde serão feitos comentários sobre o que foi realizado no dia e dúvidas poderão ser reportadas. Acontecerão diária e remotamente, para o melhor acompanhamento do orientador.
- As *sprints* terão sua duração definida posteriormente.
- Será definido um *backlog* de produto e um para cada *sprint*.
- Quadro de tarefas de definição de pronto.

1.4 Organização do Trabalho

2 Processamento de Linguagem Natural

Este capítulo contém o referencial teórico que diz respeito ao Processamento de Linguagem Natural.

2.1 Modelo *bag-of-words*

A grande parte dos dados a serem utilizados nesse trabalho está disposto em formato de texto, ou seja, um formato não estruturado e que dificulta a extração de informações. Portanto, faz-se necessário um pré-processamento do texto a ser utilizado e um método comum é o modelo *bag-of-words*, onde o texto é representado em forma de um vetor de palavras que ocorrem no texto (MATSUBARA et al., 2003).

A representação de um texto no modelo mencionado é feita através de um dicionário, onde suas chaves são os termos presentes no documento e os valores são suas respectivas frequências no texto. Tendo o seguinte trecho "fui à padaria e comprei pão" como exemplo, o seguinte dicionário é sua representação no modelo *bag-of-words*:

```
bag_of_words = {
    "fui": 1,
    "à": 1,
    "padaria": 1,
    "e": 1,
    "comprei": 1,
    "pão": 1,
}
```

Listing 2.1 – Representação de um trecho no modelo bag-of-words

Com isso, é fácil ver que, utilizando essa representação, a ordem das palavras se torna irrelevante, ou seja, as frases "e comprei fui padaria pão à" e "à pão comprei padaria e fui" também teriam as mesmas representações.

CITAR COLLECTIONS.COUNTER

2.1.1 Representação dos Termos

2.1.1.1 *Boolean*

Essa medida usa a representação binária para os termos presentes nos documentos, onde o valor de a_{ij} é 0 quando o termo não acontece nenhuma vez no documento ou 1 quando acontece uma ou mais vezes. Porém, essa medida é muito simples e, geralmente,

modelos estatísticos levam em consideração também a frequência com que os termos se repetem nos documentos (SALTON; BUCKLEY, 1988).

2.1.1.2 *Term Frequency*

Ao contrário da medida mencionada anteriormente, a medida *term frequency* considera a quantidade de ocorrencias do termo t dentro do documento

$$f_t = \frac{n_t}{N}, \tag{2.1}$$

onde n_t é a quantidade de vezes que o termo t aparece dentro do documento e N a quantidade total de termos do documento.

Porém, alguns termos podem aparecer na maioria dos documentos e, dessa forma, raramente fornecem informações úteis que possam diferenciá-los em uma tarefa de mineração de textos (MATSUBARA et al., 2003).

2.1.1.3 *Term Frequency - Inverse Document Frequency*

Para representar melhor os documentos, pode ser utilizado um fator de ponderação, para que os termos que aparecem na maioria dos documentos tenham uma representação menor do que aqueles que raramente aparecem (MATSUBARA et al., 2003). Segundo JONES (1972), a especificidade de um termo pode ser quantificada por uma função inversa do número de documentos em que ele ocorre, essa função varia entre 0 e $logN$, onde N é o número total de documentos e $d(t_j)$ a quantidade de documentos nos quais o termo t_j aparece ao menos uma vez:

$$idf(t_j) = log\frac{N}{d(t_j)} \tag{2.2}$$

Portanto, o valor final de a_{ij} é dado pela equação:

$$tfidf(t_j, d_i) = freq(t_j, d_i) \cdot idf(t_j) \tag{2.3}$$

2.1.2 Dimensionalidade dos documentos

Representar uma coleção de documentos no modelo *bag-of-words* significa que cada documento será representado por um dicionário que deve conter todos os termos presentes em toda a coleção de documentos. Exemplificando, suponha que são analisados 10 documentos e, em média, são retirados 200 novos termos de cada um. Logo, o tamanho médio dos dicionários será de, aproximadamente, 2000, ou seja, um dicionário de alta dimensão. Agora, considere que em dois desses 10 documentos ocorram apenas 10 novos termos. Temos então que os dicionários que representam esses documentos terão, em

grande parte, valor nulo. Ou seja, quanto maior o tamanho da coleção de documentos, bem como a quantidade de termos presentes neles, maior será a porcentagem de valores nulos (MATSUBARA et al., 2003). Entretanto, existem métodos cujo objetivo é diminuir a dimensionalidade desses dicionários, dentre eles temos a transformação de cada termo no radical que o originou, utilizando algorítmos de *stemming*.

2.1.2.1 Stemização

A stemização (do inglês, *stemming*) é o processo de reduzir palavras flexionadas à sua raíz, porém essa redução não precisa, necessariamente, chegar à raiz morfológica da palavra. A raiz obtidada geralmente é o suficiente para mapear palavras relacionadas à uma raiz comum, mesmo se esta não for uma raiz válida. O estudo de algorítmos de *stemming* é foco de pesquisas desde a década de 60 e o primeiro algorítmo foi publicado por Lovins (1968).

A consequência da aplicação de algorítmos de *stemming* consiste na remoção de prefixos ou sufixos de um termo e até mesmo na transformação de verbos para suas formas no infinitivo. Por exemplo, as palavras **ouvir**, **ouvi**, **ouviriam**, **ouve** e **ouvindo** seriam reduzidas para um mesmo *stem*: **ouv**. Por isso esse método diminui a dimensionalidade dos vetores dentro de uma *bag-of-words*, ao invés de analizar a frequência dos termos, a análise é feita sob a quantidade de vezes que um *stem* aparece em um documento.

É evidente que os algorítmos de *stemming* são dependentes do idioma dos termos a serem analisados. O algorítmo de Porter (1980), um dos algorítmos de *stemming* mais conhecidos, que remove os sufixos de termos em inglês, tem sido amplamente utilizado, referenciado e adaptado desde sua criação. Para a língua portuguesa, o algorítmo de *stemming* também é uma adaptação do algorítmo de Porter, e a principal diferença é que as línguas provenientes do latim possuem formas verbais conjugadas em sete tempos e com sete terminações distintas.

Devido ao fato de uma linguagem ter tantas regras e exceções, é pouco provavél que o algorítmo de *stemming* retorne o mesmo *stem* para todas as palavras que tenham a mesma origem ou radical morfológico. Pode-se dizer, também, que a medida que o algorítmo vai se tornando específico o suficiente para atender todas essas regras e exceções, na tentativa de minimizar a quantidade de *stems* diferentes para palavras com um mesmo radical, a eficiência do algorítmo diminui (IMAMURA, 2001).

2.1.2.2 *Stop Words*

Palavras que possuem pouco ou nenhum valor semântico, como *"e"*, *"de"* e *"seus"*, são conhecidas como *Stop Words* e, por não agregarem valor à analise textual, são removidas antes de ser realizado o processamento (RAJARAMAN; ULLMAN, 2011). Essas palavras não são exclusividade de uma linguagem específica, elas estão presentes em todas

e, geralmente, representam a maioria dos termos de um texto. No caso da língua inglesa, por exemplo, palavras como *"of"* e *"the"* também não possuem nenhum valor para a análise. Apesar das *Stop Words* estarem presentes na maior parte dos idiomas, essa lista de palavras varia de acordo com a linguagem que está sendo analisada (LOPES, 2015). O quadro abaixo mostra uma lista de palavras que serão retiradas do processamento.

de	os	tua	tem	estão	da	lhes	essas
e	é	foi	nossas	muito	o	se	tuas
tu	por	as	sua	aquele	entre	não	ele
delas	minhas	às	nos	pela	havia	me	como
ser	aqueles	nossa	vocês	eu	ter	tenho	suas
está	isso	pelos	estes	tinha	depois	foram	este
para	só	quem	deles	isto	um	eles	do
vos	mais	mesmo	num	dele	será	minha	a
no	teus	à	você	em	meus	esses	pelas
com	ao	dela	há	que	na	nosso	te
aos	dos	ou	aquela	era	uma	das	esta
teu	nem	já	até	seja	esse	mas	quando
aquelas	nossos	têm	também	seus	lhe	meu	seu
ela	elas	estas	nós	sem	essa	fosse	qual
		pelo	nas	numa	aquilo		

Tabela 1 – Exemplos de *Stop Words*

2.2 Clusterização

Quando temos um conjunto de elementos, naturalmente tentamos estabelecer padrões entre eles. Uma forma que pode ser utilizada para definir esses padrões é analisar o conjunto e determinar uma distância entre seus componentes, de forma que quanto mais parecidos dois elementos são, mais próximos eles estão. Sendo assim, a figura abaixo mostra um conjunto de elementos com duas características: forma (quadrado, círculo e triângulo) e cor (tons de vermelho, verde e azul). Ao lado temos os mesmos elementos, porém agrupados em três conjuntos, onde os elementos de cada um possuem características semelhantes. No grupo 1, por exemplo, todos os elementos possuem uma tonalidade de vermelho e o formato quadrado.

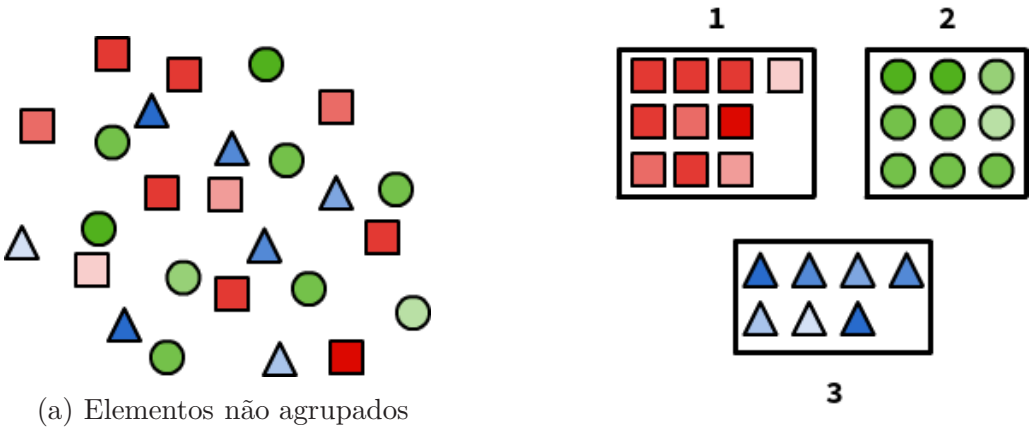

(a) Elementos não agrupados

(b) Elementos agrupados

Figura 1 – Exemplo de clusterização

A clusterização é uma técnica da mineração de dados que consiste, justamente, em realizar o procedimento descrito acima: organizar um conjunto de elementos, usualmente representados por vetores ou pontos em um espaço multidimensional, em *clusters* (ou agrupamentos), de acordo com alguma medida de similaridade. Ela representa uma das principais etapas da análise de dados, denominada análise de *clusters* (JAIN; MURTY; FLYNN, 1999).

Não existe uma técnica de clusterização universal, capaz de revelar toda a variedade de estruturas que podem estar presentes em conjuntos de dados multidimensionais. O que dificulta a definição de um único algorítmo de clusterização, até mesmo porque os algorítmos dependem implicitamente de certas hipóteses a respeito da forma dos clusters na definição da medida de similaridade e dos critérios de agrupamento (ESTIVILL-CASTRO, 2002).

2.2.1 Algorítmo *k-means*

O algorítmo de clusterização *k-means*, proposto por Lloyd (1957), tem o objetivo de dividir N elementos em k grupos, onde cada elemento pertence ao *cluster* mais próximo, o que resulta em uma divisão do espaço de dados semelhante ao Diagrama de Voronoy (1908):

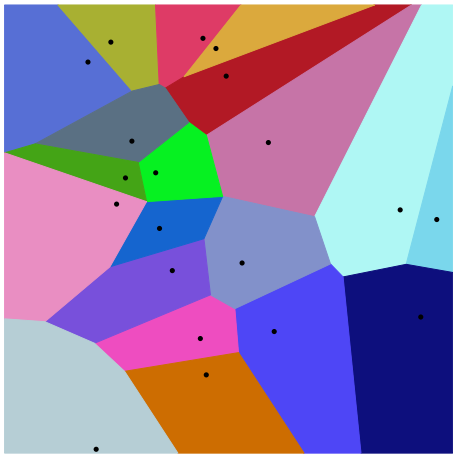

Figura 2 – Diagrama de Voronoy de 20 pontos

Com a aplicação desse algorítmo, o erro quadrático sobre os *clusters* tende a diminuir a medida que a quantidade de *clusters* aumenta. E definimos uma quantidade fixa de *clusters*, pois uma vez que a quantidade de clusters se iguala à quantidade de elementos o erro é zero. Os principais passos do algorítmo são:

1. **Gerar centróides:** neste passo os k centróides recebem valores iniciais.

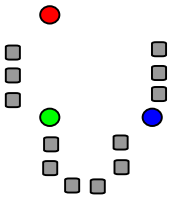

Figura 3 – k centróides (coloridos) recebem valores iniciais.

2. **Calcular distâncias:** aqui são calculadas as distâncias entre cada ponto e os centróides. É a parte com maior peso computacional do algorítmo, já que o calculo é realizado para cada ponto.

3. **Classificar os pontos:** cada ponto deve ser classificado de acordo com a distância entre ele e o centróide de cada *cluster*. Ou seja, o ponto vai pertencer ao *cluster* cujo centróide está mais próximo. O algorítmo converge quando, em uma iteração, nenhum ponto mudar de *cluster*.

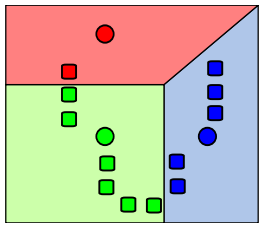

Figura 4 – Cálculo das distâncias entre os pontos e os centróides.

4. **Calcular novos centróides:** para cada *cluster*, um novo centróide é definido como a média desses pontos.

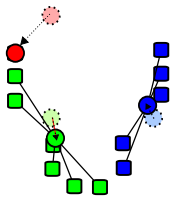

Figura 5 – Novos centróides definidos pela media dos elementos do *cluster*.

5. **Repetir até convergir:** retorna ao passo 2.

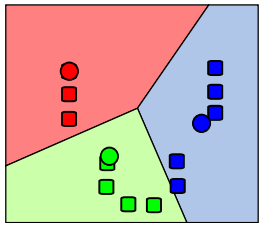

Figura 6 – O algorítmo converge quando nenhum ponto muda de *cluster*.

2.2.1.1 Distância entre os pontos

Na segunda etapa do algorítmo *k-means* são calculadas as distâncias de cada ponto até cada cluster, para posteriormente colocá-los no *cluster* mais próximo. Tal distância pode ser calculada de diversas maneiras, como a Distância Euclidiana e a Distância de Manhattan, ou *Hamming*, que são as mais comuns (DEZA; DEZA, 2009).

A distância euclidiana entre dois pontos, $A = a_1, a_2, a_3, \ldots, a_n$ e $B = b_1, b_2, b_3, \ldots, b_n$, em um espaço n-dimensional, é dada pela equação:

$$dist(A, B) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + (a_3 - b_3)^2 + \ldots + (a_n - b_n)^2} \tag{2.4}$$

$$dist(A, B) = \sqrt{\sum_{i=1}^{n} (a_i - b_i)^2} \tag{2.5}$$

Já a distância de Manhattan entre dois pontos, $A = a_1, a_2, a_3, \ldots, a_n$ e $B = b_1, b_2, b_3, \ldots, b_n$, em um espaço n-dimensional, é dado pela soma das diferenças absolutas de suas coordenadas:

$$dist(A, B) = \sqrt{|a_1 - b_1| + |a_2 - b_2| + |a_3 - b_3| + \ldots + |a_n - b_n|} \tag{2.6}$$

$$dist(A, B) = \sqrt{\sum_{i=1}^{n} |a_i - b_i|} \tag{2.7}$$

Em ambos os casos, temos que a distância entre do ponto A ao ponto B é a mesma distância do ponto B ao ponto A.

(a) Distância Euclidiana

(b) Distância de Manhattan

Figura 7 – Comparação entre distância euclidiana e de manhattan

3 Engenharia de Software

Este capítulo contém o referencial teórico que diz respeito à Engenharia de Software utilizada nesse trabalho.

3.1 *Framework* de gerenciamento *SCRUM*

O *SCRUM* é um *framework* de gerenciamento de projetos cuja característica principal é o desenvolvimento de um produto complexo e tem como objetivo entregar o produto com o maior valor agregado possível (SUTHERLAND; SCHWABER, 1995).

Segundo Sutherland e Schwaber (1995) os três pilares que sustentam o *SCRUM* são:

- **Transparência:** manter os resultados sempre visíveis aos interessados, para que todos possam ter um mesmo ponto de vista.
- **Inspeção:** deve-se, frequentemente, inspecionar os artefatos gerados, desde que esse processo não atrapalhe o real trabalho.
- **Adaptação:** uma vez encontrado um erro em qualquer artefato, deve-se ajustar o mesmo o mais rápido possível, para evitar maiores erros.

3.1.1 Time *SCRUM*

O time *SCRUM* é formado por três partes distintas: o *product owner*, o time de desenvolvimento e o *scrum master* (SUTHERLAND; SCHWABER, 2013).

3.1.1.1 *Product Owner*

Responsável por manter os itens no *backlog* do produto, tornando ele visível e claro a todos, garantindo que o time de desenvolvimento entenda-os.

3.1.1.2 Time de Desenvolvimento

Composto por desenvolvedores, o time de desenvolvimento é responsável por transformar o *backlog* do produto em incrementos de software.

3.1.1.3 *Scrum Master*

É o responsável pelo cumprimento das práticas do *SCRUM*, facilitando os eventos propostos pelo *framework*, trabalhando em conjunto com o *product owner* para o esclare-

cimentos dos itens do *backlog* para a equipe de desenvolvimento, além de liderar o time em seu autogerenciamento.

3.1.2 Eventos do *SCRUM*

No *SCRUM*, todos os eventos possuem uma duração determinada, que varia de acordo com a necessidade do projeto e equipe. São eles: *sprint*, reunião de planejamento de *sprint* e revisão da *sprint* (SUTHERLAND; SCHWABER, 2013).

3.1.2.1 *Sprint*

A *sprint* é o evento mais importante, pois ela agrupa todos os outros eventos. Uma *sprint* possui um tempo fixo, que pode variar de acordo com a necessidade da equipe, e pode ser composta de outras atividades e eventos do *SCRUM*, como reuniões diárias, desenvolvimento do produto, retrospectivas, etc. Uma *sprint* sempre começa quando uma acaba (SUTHERLAND; SCHWABER, 2013).

3.1.2.2 Reunião de planejamento de *sprint*

Ocorre sempre no início de cada *sprint* e, como resultado da reunião, é definido o que será feito durante a *sprint* que se inicia. A partir disso, é criado o *backlog* de *sprint*, onde estão presentes as metas da *sprint*.

3.1.2.3 Revisão de *sprint*

Acontece no final de cada *sprint* e tem como objetivo a apresentação dos resultados obtidos durante a *sprint* que passou, tanto o que foi concluído quanto o que não foi, bem como as justificativas para a não completude. Nessa reunião, todos os membros do time devem estar presentes.

3.1.3 Artefatos do *SCRUM*

Durante o andamento do projeto, alguns artefatos são produzidos, com o objetivo de guiar a equipe e facilitar o entendimento comum entre todos os envolvidos (SUTHERLAND; SCHWABER, 2013).

3.1.3.1 *Backlog* de produto

É uma lista com todas as atividades que precisam ser feitas para que o produto final seja concluído. Essa lista evoluí junto com o projeto, uma característica do modelo de desenvolvimento iterativo e incremental.

3.1.3.2 *Backlog* de *sprint*

Assim como o *backlog* de produto, porém com um escopo menor. O *backlog* de *sprint* lista todas as atividades que foram planejadas para uma determinada *sprint*.

3.2 Testes de Software

O desenvolvimento de software é uma atividade que envolve várias atividades e, muitas vezes, diferentes pessoas, o que acaba por favorecer a inserção de defeitos no produto. Além disso, o mal entendimento dos requisitos pode resultar na produção de algo que não foi solicitado pelo cliente (TRODO, 2009).

Os testes de software representam, então, uma atividade que compõe o processo de verificação de validação do software e consiste em uma análise dinâmica do código-fonte, ou seja, o código deve ser executado para que os testes possam ocorrer. Isso possibilita a identificação de erros, bem como a prevenção de inserção de novos erros, quando os testes são automatizados (BARBOSA et al., 2009).

3.2.1 Classificação dos Testes

Os testes de software podem ser classificados, dentre outras categorias, em testes de caixa-preta e testes de caixa-branca (BARBOSA et al., 2009).

3.2.1.1 Testes de caixa-preta

Esse tipo de teste tem como objetivo avaliar o produto em relação aos requisitos funcionais e não-funcionais. A figura abaixo mostra o funcionamento de um teste de caixa-preta, onde são utilizados determinados dados de entrada no software e os resultados obtidos são comparados com as expectativas para os dados de entrada (BARBOSA et al., 2009).

Figura 8 – Representação do teste de caixa-preta

Referências

BARBOSA, E. F. et al. Introdução ao teste de software. 2009. Disponível em: <http://www.duguay.com.br/uploads/arquivos/apostilaUSP_Teste_de_Software.pdf>. Citado na página 31.

BRASIL. *Lei nº 12.527, de 18 de novembro de 2011.Regula o acesso à informações*. 2011. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12527.htm>. Acesso em: 4 out 2016. Citado na página 17.

CÂMARA DOS DEPUTADOS. *Dados Abertos da Câmara dos Deputados*. 2016. Disponível em: <http://www2.camara.leg.br/transparencia/dados-abertos/perguntas-e-respostas>. Acesso em: 4 out 2016. Citado na página 17.

DEZA, E.; DEZA, M. M. *Encyclopedia of Distances*. [S.l.]: Springer, 2009. 94 p. Citado na página 27.

DINIZ, V. *Como Conseguir Dados Governamentais Abertos*. Brasília, Brasil, 2010. Citado na página 17.

ESTIVILL-CASTRO, V. Why so many clustering algorithms — a position paper. *ACM SIGKDD Explorations Newsletter*, 2002. Citado na página 25.

IMAMURA, C. Y. Pré-processamento para extração de conhecimento de bases textuais. 2001. Citado na página 23.

JAIN, A.; MURTY, M.; FLYNN, P. Data clustering: A review. In: *ACM Computing Surveys*. [S.l.: s.n.], 1999. v. 31, p. 264–323. Citado na página 25.

JONES, K. S. A statistical interpretation of term specificity and its application in retrieval. *Journal of Documentation*, v. 28, p. 11–21, 1972. Citado na página 22.

LLOYD, S. P. Least square quantization in pcm. *IEEE Transactions on Information Theory*, p. 129–137, 1957. Citado na página 25.

LOPES, E. D. Utilização do modelo skip-gram para representação distribuída de palavras no projeto media cloud brasil. 2015. Citado na página 24.

LOVINS, J. B. Development of a stemming algorithm. In: *Mechanical Translation and Computational Linguistics*. [S.l.: s.n.], 1968. Citado na página 23.

MATSUBARA, E. T. et al. *PreTexT: uma ferramenta para pré-processamento de textos utilizando a abordagem bag-of-words*. 2003. Citado 3 vezes nas páginas 21, 22 e 23.

MAZONI, M. V. F. *Dados Abertos para a Democracia na Era Digital*. Brasília, Brasil, 2011. 80 p. Citado na página 17.

OPEN KNOWLEDGE. About. 2016. Disponível em: <https://okfn.org/about/>. Acesso em: 4 out 2016. Citado na página 17.

PORTER, M. F. An algorithm for suffix stripping. *Program electronic library and information systems*, 1980. Citado na página 23.

RAJARAMAN, A.; ULLMAN, J. D. Data mining. In: *Mining of Massive Datasets*. [S.l.: s.n.], 2011. Citado na página 23.

SALTON, G.; BUCKLEY, C. Term-weighting approaches in automatic text retrieval. 1988. Citado na página 22.

SUTHERLAND, J. V.; SCHWABER, K. Business object design and implementation. *OOPSLA '95 workshop proceedings*, The University of Michigan, p. 118, 1995. Citado na página 29.

SUTHERLAND, J. V.; SCHWABER, K. Guia do scrum um guia definitivo para o scrum: As regras do jogo. 2013. Disponível em: <http://www.scrumguides.org/docs/scrumguide/v1/Scrum-Guide-Portuguese-BR.pdf>. Citado 2 vezes nas páginas 29 e 30.

TRODO, L. D. Uso de métricas nos testes de software. Universidade Federal do Rio Grande do Sul, 2009. Disponível em: <http://www.lume.ufrgs.br/bitstream/handle/10183/18574/000730980.pdf>. Citado na página 31.

VORONOY, G. Nouvelles applications des paramètres continus à la théorie des formes quadratiques. *Journal für die Reine und Angewandte Mathematik*, 1908. Citado na página 25.

Apêndices

APÊNDICE A – Primeiro Apêndice

Texto do primeiro apêndice.

APÊNDICE B – Segundo Apêndice

Texto do segundo apêndice.

Anexos

ANEXO A – Primeiro Anexo

Texto do primeiro anexo.

ANEXO B – Segundo Anexo

Texto do segundo anexo.