UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS - CAMPUS BAURU
DEPARTAMENTO DE COMPUTAÇÃO
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

JOÃO VITOR LOPES DA SILVA

MINERAÇÃO DE DADOS APLICADO À GESTÃO DE ENERGIA ELÉTRICA

BAURU
Novembro/2019

JOÃO VITOR LOPES DA SILVA

MINERAÇÃO DE DADOS APLICADO À GESTÃO DE ENERGIA ELÉTRICA

Trabalho de Conclusão de Curso do Curso de Bacharelado em Ciência da Computação da Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Campus Bauru.
Orientador: Prof. Dr. Kleber Rocha de Oliveira

BAURU
Novembro/2019

João Vitor Lopes da Silva Mineração de Dados Aplicado à Gestão de Energia Elétrica/ João Vitor Lopes da Silva. – Bauru, Novembro/2019- 48 p. : il. (algumas color.) ; 30 cm.
Orientador: Prof. Dr. Kleber Rocha de Oliveira
Trabalho de Conclusão de Curso – Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Ciência da Computação, Novembro/2019.
1. Energia Elétrica 2. Ciencia de Dados 3. Aprendizado de Máquina Não Supervisionado

João Vitor Lopes da Silva

Mineração de Dados Aplicado à Gestão de Energia Elétrica

Trabalho de Conclusão de Curso do Curso de Bacharelado em Ciência da Computação da Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Campus Bauru.

Banca Examinadora

Prof. Dr. Kleber Rocha de Oliveira
Orientador
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Computação

Prof. Dr. Kelton Augusto Pontara da Costa
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Computação

Profª. Drª. Simone das Graças Domingues Prado
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Computação

Bauru, _____ de _____ de _____.

Agradecimentos

Agradeço à minha família por acreditarem em mim e por todo apoio e incentivo para que minha graduação fosse possível.

Agradeço aos professores com quem tive contato ao longo do curso, por todo conhecimento técnico e experiências de vida compartilhados.

Aos amigos e colegas feitos em Bauru, com quem pude crescer como pessoa e participar de histórias que jamais esquecerei.

"A leitura do mundo precede a leitura da palavra."
(Paulo Freire)

Resumo

A energia elétrica é um recurso importante das sociedades atuais e a continuidade de sua distribuição é um dos indicadores mais relevantes na gestão de energia. Este projeto teve como objetivo analisar uma base de dados da distribuidora CPFL Paulista em busca de características que possam contribuir para a melhoria do serviço prestado aos consumidores, através de técnicas de aprendizagem de máquina.

Palavras-chave: Ciência de dados, energia elétrica, aprendizado de máquina não supervisionado.

Abstract

Electricity is an important resource of today's societies and the continuity of its distribution is one of the most relevant indicators in energy management. This project aimed to analyze a database of distributor CPFL Paulista in search of characteristics that can contribute to the improvement of the service provided to consumers through machine learning techniques.
Keywords: Data science, electricity, unsupervised machine learning.

Lista de figuras

Lista de tabelas

Lista de abreviaturas e siglas

ANEEL	Agência Nacional de Energia Elétrica
CPFL	Companhia Paulista de Força e Luz
CSS	*Cascading Style Sheets*
CSV	*Comma-Separated Values*
DEC	Duração Equivalente de Interrupção Por Unidade Consumidora
FEC	Frequência Equivalente de Interrupção Por Unidade Consumidora
HTML	*Hypertext Markup Language*
HTTP	*Hypertext Transfer Protocol*
PCA	*Princial Components Analysis*
Pip	*Package Installer for Python*
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
XML	*Extensible Markup Language*

Sumário

1 Introdução

A disponibilização de energia elétrica está diretamente atrelada à vida das pessoas na sociedade contemporânea, seja em termos de qualidade de vida e conforto doméstico como em termos de produção e indústria (MEHL, 2012).

Dada esta importância, faz-se relevante o estudo sobre a qualidade deste insumo. A Agência Nacional de Energia Elétrica (ANEEL) é o orgão responsável pela regulação dos padrões de qualidade à que as empresas do setor devem responder. Estes padrões podem ser de naturezas distintas como geração, transmissão, distribuição e comercialização de energia.

Pelo fato de estar ligada ao consumidor final mais evidentemente, a distribuição é um dos principais itens da gestão de energia elétrica (MARTINHO, 2009).

Conforme a ANEEL recebe indicadores de continuidade de distribuição coletados pelas concessionárias, bases de dados surgem e podem ser empregadas em diversas técnicas computacionais, como as da ciência de dados.

Ciência de dados é um termo muito recorrente na área da computação. O volume de dados armazenados pelos sistemas de computador só tende a crescer, visto que a cada dia surgem novos dispositivos de armazenamento, transmissão e processamento de informações (FERREIRA, 2008).

Dispondo de uma base de dados viável, torna-se possível a aplicação de técnicas de ciência de dados para buscar maior entendimento e soluções dos problemas encontrados na gestão de energia elétrica.

1.1 Objetivos

O objetivo geral deste trabalho foi elaborar um projeto de ciência de dados, usando bases de dados de indicadores de continuidade da distribuição de energia elétrica, para identificar padrões que possam apoiar a gestão de energia. Este objetivo geral foi dividido em outros, menores.

Primeiramente foi realizado um estudo conceitual sobre ciência de dados e aprendizado de máquina. Este estudo foi necessário para definir quais ferramentas e técnicas seriam usadas no projeto. Definidas as ferramentas, iniciou-se a fase de desenvolvimento onde foi feita a escolha e aquisição da base de dados, preparação dos dados e o treinamento dos algoritmos de aprendzado de máquina. Por fim, foi feita a análise dos resultados dos treinamentos e a criação de visualizações gráficas destes.

1.2 Organização da Monografia

Este trabalho está organizado da seguinte forma.

O capítulo 2 traz a fundamentação teórica, com conceitos de ciência de dados, extração de dados na *web* e aprendizado de máquina.

No capítulo 3 são apresentadas as ferramentas utilizadas para o desenvolvimento do projeto.

O capítulo 4 detalha a base de dados escolhida e os processos para sua extração e padronização de seus valores. Com a base de dados preparada, é apresentado o processo de treinamento dos algoritmos de aprendizado de máquina.

No capítulo 5 são apresentados os resultados dos treinamentos.

O capítulo 6 traz conclusões do projeto e considerações sobre trabalhos futuros.

2 Fundamentação Teórica

2.1 Ciência de Dados

Ciência de dados consiste na aplicação de métodos quantitativos e qualitativos sobre grandes quantidades de dados, para resolução de problemas e predição de resultados (WALLER; FAWCETT, 2013).

Ela trata de estudar o dado em todo o seu ciclo de vida: da produção ao descarte, através de processos, modelos e tecnologias (AMARAL, 2016). O ciclo de vida do dado está ilustrado na figura 1.

Figura 1 – Ciclo de vida do dado.

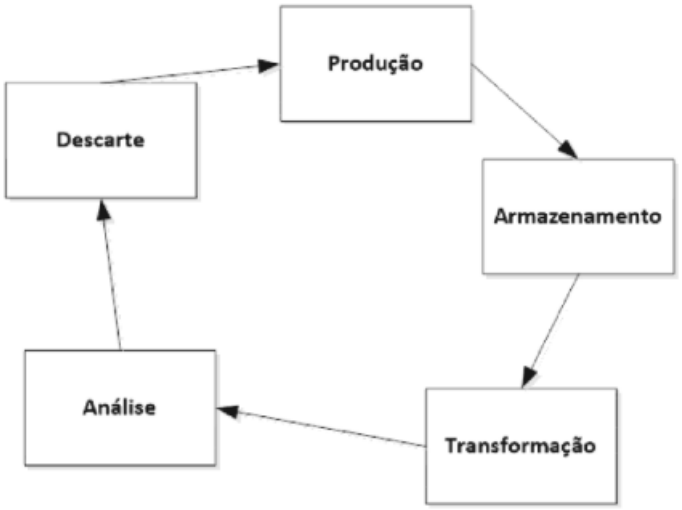

Fonte: Amaral (2016)

A Ciência de Dados pode ser dividida numa série de tarefas, cujo objetivo final é a descoberta de conhecimento. As tarefas são: seleção, pré-processamento, transformação, mineração dos dados e avaliação de resultados (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). A figura 2, mostra cada etapa do processo de Ciência de Dados e o produto derivado de cada uma delas.

Nas seções a seguir, serão definidos alguns conceitos e técnicas relacionados às diferentes fases do processo de Ciência de Dados.

Figura 2 – Tarefas que compõem a Ciência de Dados e produtos derivados de cada uma delas.

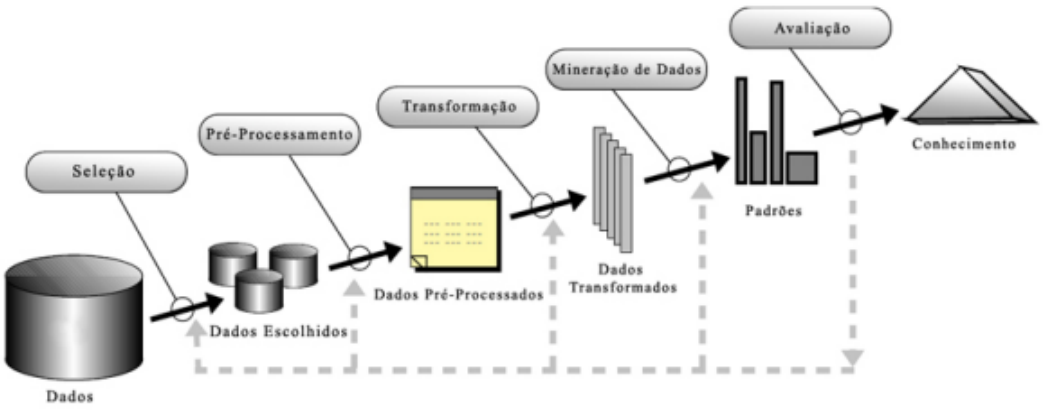

Fonte: Camilo e Silva (2009)

2.2 Web Scraping

Uma das técnicas que pode ser usada para a etapa de seleção é a raspagem (*scraping*) de dados na web. Raspagem de dados é a atividade de coletar dados automaticamente de páginas na internet. Isso é alcançado por meio de um programa que se comunica à um servidor, recupera dados (geralmente em formato *Hypertext Markup Language* (HTML) e outros tipos de arquivos que compõem páginas *web*) e analisa este documento em busca de um conjunto de informações específico (MITCHELL, 2018).

2.3 Pré-processamento e Transformação dos Dados

Pré-processamento e transformação de dados consistem na preparação destes para a etapa de mineração. Como subdivisões da etapa de pré-processamento há a limpeza e integração de dados (CAMILO; SILVA, 2009).

Na limpeza, são definidas estratégias para lidar com problemas como características faltantes nos dados, dados inconsistentes, dados duplicados, etc. Exemplos de estratégias possíveis para atacar o problema de característica faltante em um dado podem ser a completa remoção dele ou a atribuição de um valor médio.

Muitas vezes os dados são obtidos de fontes diferentes, exigindo a integração deles em um formato comum preestabelecido.

Diferentes algoritmos de mineração usam diferentes formatos de dados. Há algoritmos que trabalham apenas com valores numéricos, enquanto outros trabalham com valores categóricos. Assim, na fase de transformação de dados são empregadas técnicas para transformar dados categóricos em numéricos ou o contrário, normalizar dados, onde as características devem respeitar a mesma escala, entre outras (CAMILO; SILVA, 2009).

2.4 Mineração de Dados

Mineração de dados pode ser compreendida como uma tarefa multidisciplinar, onde dado um conjunto de dados, sob limitações aceitáveis de eficiência computacional, são aplicadas técnicas estatísticas, de reconhecimento de padrões, de visualização, etc. a fim de testar hipóteses, encontrar relacionamentos inesperados e de resumir os dados para melhor compreensão deles (CAMILO; SILVA, 2009).

A maioria dos métodos de mineração de dados são baseados em técnicas testadas de estatística ou de aprendizagem de máquina: classificação, regressão, agrupamento, etc (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

2.5 Aprendizado de Máquina

Aprendizagem de máquina é uma área da Inteligência Artificial que tem como objetivo o desenvolvimento de técnicas computacionais sobre o aprendizado e a construção de sistemas que podem adquirir conhecimento automaticamente. O sistema que pode adquirir conhecimento de forma automática é aquele que toma decisões adequadas, porque conhece soluções de problemas similares (MONARD; BARANAUSKAS, 2003).

Os algoritmos de aprendizado de máquina podem ser divididos em dois tipos: supervisionados e não-supervisionados.

2.5.1 Aprendizado de Máquina Supervisionado

Os algoritmos supervisionados de aprendizado de máquina são aqueles onde os dados possuem rótulos que identificam suas classes. Classe é a meta que se deseja aprender e fazer predições a respeito (MONARD; BARANAUSKAS, 2003). O conjunto de dados é então divido em conjunto de treinamento e de teste.

Com o conjunto de treinamento, o algoritmo aprende sobre os relacionamentos entre as características do dado e seu rótulo. Depois, este aprendizado é usado para fazer predições sobre as classes dos dados desconhecidos até o momento, no conjunto de teste.

Se o rótulo pertencer à um conjunto de valores discretos, o algoritmo é de classificação. Se for parte de um conjunto de valores contínuos, o algoritmo resolve problemas de regressão (MONARD; BARANAUSKAS, 2003).

2.5.2 Aprendizado de Máquina Não Supervisionado

Para algoritmos de aprendizado de máquina não supervisionados, que serão o foco desta monografia, são fornecidos dados que não possuem nenhum rótulo. Portanto, neste tipo de análise não há interesse em fazer predições.

O objetivo destes algoritmos é o descobrimento de fatos interessantes sobre o conjunto de dados, como formas de visualizá-los, presença de subgrupos (*clusters*) ou a identificação das características que mais os definem.

Por não possuir dados rotulados que informem sobre sua verdadeira natureza, as técnicas que envolvem algoritmos não supervisionados necessitam de atenção especial na interpretação de resultados. Diferentes abordagens em relação aos dados podem levar à diferentes conclusões (JAMES et al., 2013).

Alguns algoritmos, como o K-Means por exemplo, requerem que seja definido previamente o número de agrupamentos a encontrar, mesmo que isto seja um dos fatos que se deseja descobrir acerca do problema.

Dados descritos por distribuição normal podem apresentar resultados diferentes dos mesmos dados não normalizados.

A presença de valores atípicos é um fator que pode distorcer um *cluster*, uma vez que mesmo que ocorra agrupamentos de observações, um certo conjunto delas pode ter características diferentes entre si e de todas os outras (JAMES et al., 2013).

Para evitar conclusões incorretas, adota-se uma abordagem exploratória, onde são testadas diversas variações dos formatos dos dados e de parâmetros que influenciam nos agrupamentos. Então, conclusões podem ser formuladas com base nos resultados, atuando como ponto de partida para estudos mais específicos (JAMES et al., 2013).

2.5.3 Análise de Componentes Principais

Descobrir a dimensionalidade intrínseca de uma base de dados é uma tarefa fundamental na Ciência de Dados (MINKA, 2001).

Neste algoritmo de aprendizado não supervisionado, busca-se descobrir quais combinações de características dos dados são mais representativas. Isso pode ser útil para criar visualizações gráficas de problemas com grande número de dimensões.

O algoritmo busca minimizar o número de dimensões e manter o máximo da variação dos dados quanto possível. As variáveis para aplicação deste método devem estar em mesma escala, para que uma não se sobresaia sobre as outras (JAMES et al., 2013).

2.5.4 K-Means

No algoritmo K-Means, o objetivo é dividir todas as observações em um número inteiro k de grupos, idealmente não sobrepostos (JAMES et al., 2013). O algoritmo procura separar os dados minimizando o somatório das k variâncias intra agrupamento W, conforme a equação

2.1.

$$minimizar_{C_1,\ldots,C_k}\{\sum_{k=1}^{k} W(C_k)\} \tag{2.1}$$

Na figura 3 é possível observar uma representação gráfica dos *clusters* finais definidos pelo K-Means com parâmetro $k = 3$, aplicado numa base de dados simulada.

Figura 3 – Exemplo de execução do K-Means com $k = 3$

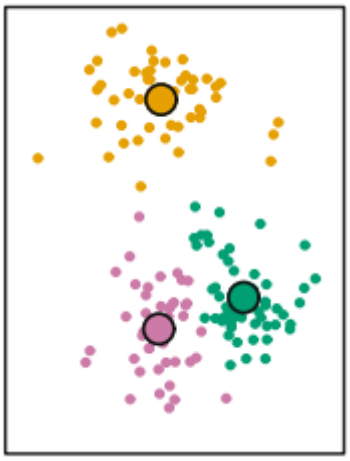

Fonte: James et al. (2013)

Existem diversas técnicas para determinar o número ideal de grupos. Uma delas é o método visual chamado Método do Cotovelo (*Elbow Method*). Nesta abordagem, o número de grupos k é iniciado em 1 e é aumentado em 1 a cada passo.

Em cada passo é calculado o custo de treinamento. Entre certos números de grupos, este custo pode cair drasticamente. Ao atingir um número de grupos onde a taxa de decrescimento do custo seja menor, temos a formação do cotovelo (KODINARIYA; MAKWANA, 2013). Na figura 4, observa-se a formação de cotovelo quando $k = 2$.

A formação do cotovelo informa um meio termo entre um baixo número de agrupamentos, onde é possível existir dados juntos que deveriam estar separados, e um alto número de agrupamentos, que podem possuir dados separados que deveriam estar juntos.

2.5.5 Avaliação de Performance de Agrupamento

Uma das métricas utilizadas para avaliar a performance de um estimador é o Coeficiente de Silhueta. Nesta avaliação, é analisado o quanto os dados de um determinado *cluster* estão agrupados entre si e quão separados os *clusters* estão uns dos outros (ROUSSEEUW, 1987).

O coeficiente é calculado pela fórmula 2.2, onde a representa a distância média entre uma observação e as demais dentro do mesmo agrupamento e b representa a distância média

Figura 4 – Formação de cotovelo para detecção do melhor número de agrupamentos para o K-Means.

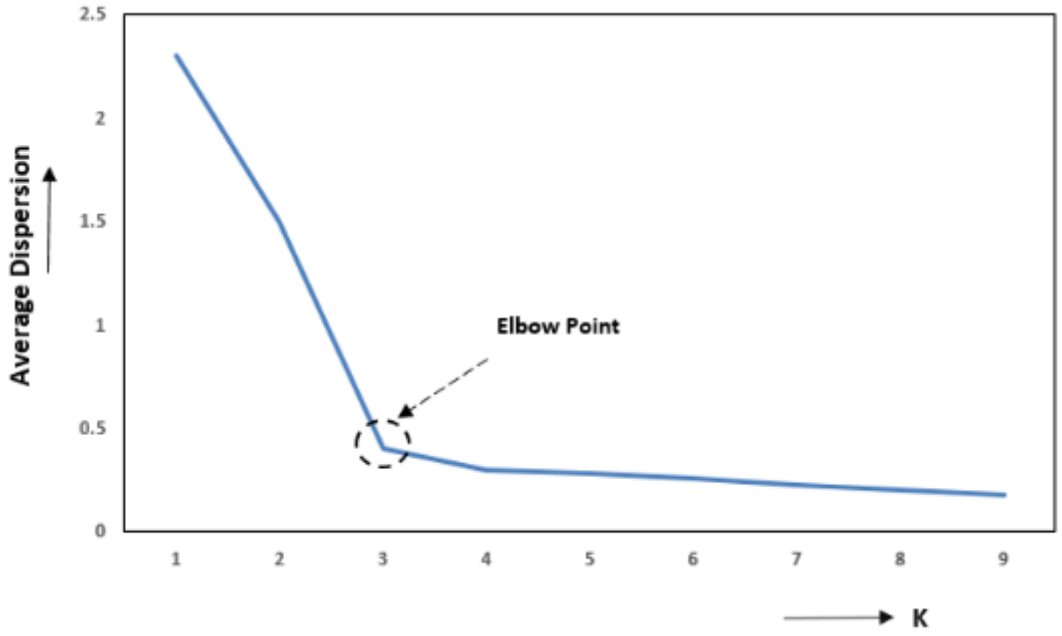

Fonte: Dangeti (2017)

entre uma observação e todas as observações do agrupamento mais próximo:

$$s = \frac{b - a}{max\{a, b\}} \tag{2.2}$$

Com base nos conceitos estudados, foi feita a escolha das ferramentas e técnicas adequadas para a continuidade do trabalho.

3 Metodologia

Neste capítulo serão apresentadas as principais ferramentas utilizadas para o desenvolvimento do projeto.

3.1 Jupyter Notebook

O ambiente escolhido para o desenvolvimento foi o Colaboratory da empresa Google. Ele consiste em Notebooks Jupyter gratuitos e que podem ser acessados diretamente de um navegador web. Todo o processamento é feito na nuvem e os códigos podem ser facilmente compartilhados e salvos.

A escolha do Colaboratory se deu pelo fato dos Notebooks Jupyter serem uma tecnologia projetada para suportar o fluxo de trabalho científico. Um Notebook Jupyter é uma interface web, *open-source* organizada em células. Estas podem conter uma ou mais linhas de código, podem ser executadas individualmente e o resultado da execução de cada uma é salvo diretamente abaixo dela. Outra vantagem é poder integrar trechos de texto plano, imagens, tabelas e gráficos para fins informativos do projeto (KLUYVER et al., 2016).

Na Figura 5, há uma demonstração do ambiente.

Figura 5 – Exemplo do ambiente Colaboratory Jupyter Notebook.

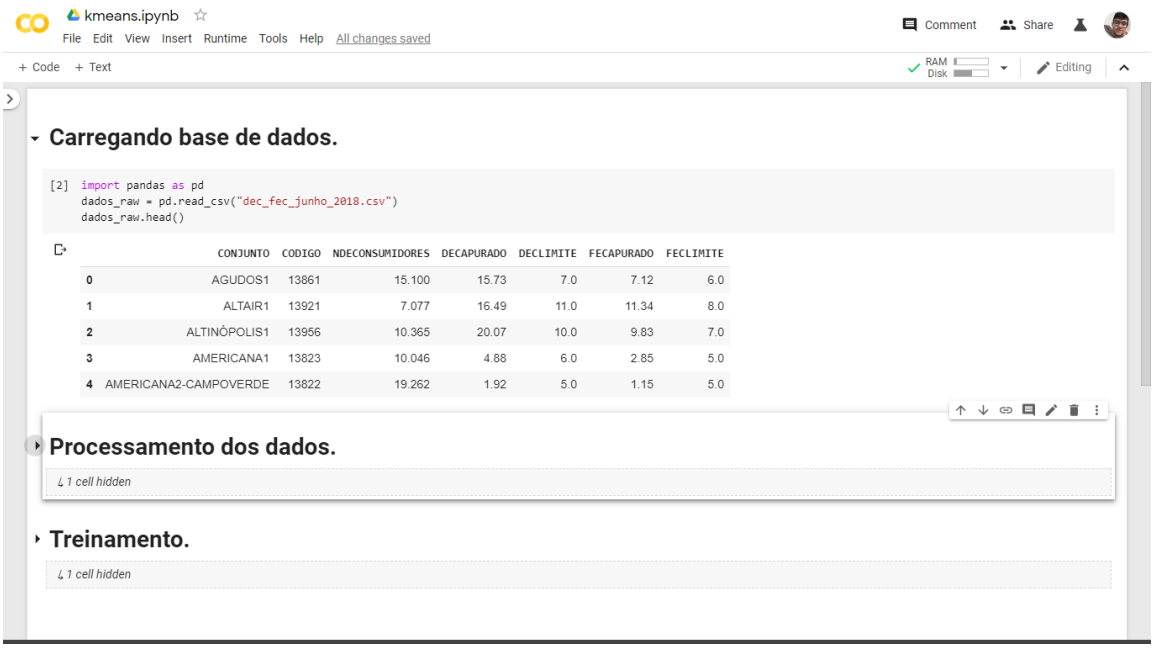

Fonte: Elaborado pelo autor.

Dentre as diversas linguagens de programação disponíveis para se trabalhar dentro de

Notebooks Jupyter, a escolhida para este projeto foi o Python versão 3, por familiaridade do autor, por possuir diversas bibliotecas para aprendizado de máquina e uma sintaxe de fácil leitura. Dessa forma, a reprodução e entendimento dos códigos do projeto tornam-se muito eficientes.

3.2 Scrapy

O Scrapy é um framework *open-source*, escrito em Python para *web crawling* e *web scraping*. Ele consiste num conjunto de aplicações integradas capazes de fazer o gerenciamento de requisições pelo protocolo *Hypertext Transfer Protocol* (HTTP), baixar páginas web e expor classes chamadas *spiders*, responsáveis por conter a lógica de analisar respostas HTTP e extrair os dados desejados da página (MYERS; MCGUFFEE, 2015).

Na figura 6, há um diagrama representando o fluxo de dados na arquitetura do Scrapy.

Figura 6 – Diagrama da arquitetura do Scrapy.

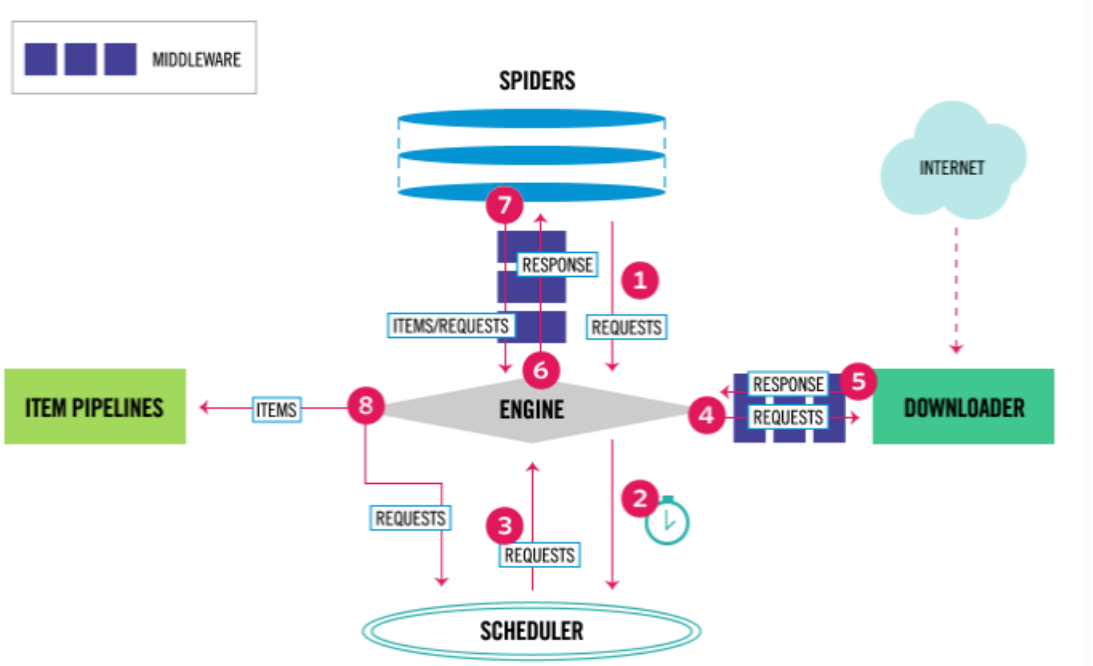

Fonte: Scrapy (2019)

Para esta monografia, o Scrapy foi utilizado para extrair os dados de treinamento da página da ANEEL e exportá-los como um arquivo no formato *Comma-Separated Values* (CSV).

3.3 Scikit-learn

Scikit-learn é um módulo Python que integra muitos algoritmos de aprendizado de máquina para problemas supervisionados e não supervisionados. O foco da biblioteca é a

facilidade de uso, por sua interação em alto nível, performance e documentação bem detalhada com referências de classes e tutoriais.

Os objetos centrais deste módulo são os estimadores, que possuem métodos em comum como treinar e predizer. O primeiro recebe a base de dados como parâmetro e aprende com ela. O segundo, mais aplicado à problemas de aprendizado supervisionado, usa o conjunto de testes para estimar valores.

No módulo também estão presentes funcionalidades de pré-processamento de dados como um método que os normaliza, uma vez que existem algoritmos de aprendizado de máquina sensíveis à valores cuja ordem de grandeza é diferente dos demais. Há também métodos para avaliar quão bem um determinado treinamento foi feito (PEDREGOSA et al., 2011).

Por ser construído no ecossistema científico do Python, a biblioteca Scikit-learn pode ser incorporada em diversos domínios, além da análise e exploração estatística de dados. Outros módulos deste ecossistema científico são o NumPy, Pandas e SciPy.

3.4 NumPy

Um dos componentes principais do ecossistema científico Python é o pacote NumPy. Este pacote é importante porque ele tem estruturas de dados que servem como base para muitas outras bibliotecas (PEDREGOSA et al., 2011).

Nele estão definidos:

- Um objeto equivalente à um vetor multidimensional chamado ndarray, rápido e eficiente.
- Funções de álgebra liner, transformada de *Fourier* e geração de números aleatórios.
- Ferramentas de leitura e escrita de bases de dados formatadas como vetores em disco.
- Ferramentas para integração de códigos Python com outras linguagens como C, C++, Fortran.

Além da alta velocidade de processamento de vetores, o NumPy é capaz de otimizar o armazenamento de dados numéricos, facilitando a passagem desses dados entre diferentes algoritmos (MCKINNEY, 2012). A Figura 7 mostra a estrutura de um *ndarray*.

Um método dos objetos de tipo *ndarray* muito utilizado pelo NumPy para análise de dados é o *shape*, ou formato, que informa o número de dimensões em uma base de dados e o quanto o índice pode variar em cada uma delas. Na figura 8, há um exemplo de uso do método *shape*, indicando que a base de dados contém 225 observações, cada uma com 5 características.

Figura 7 – Representação da estrutura de um *ndarray* Numpy.

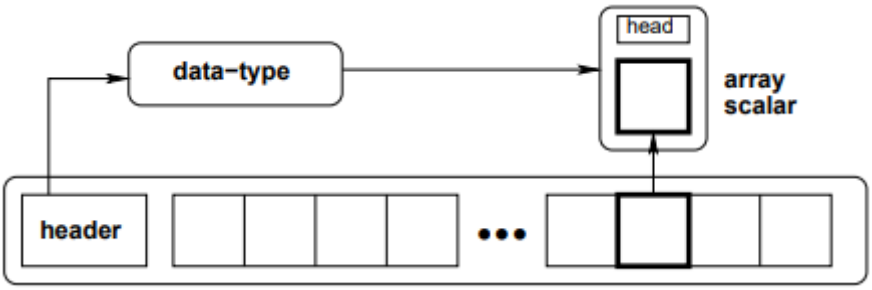

Fonte: Oliphant (2006)

Figura 8 – Uso do método shape de um objeto ndarray.

```
from sklearn.preprocessing import StandardScaler
scaler = StandardScaler()
dados_escalados = scaler.fit_transform(dados_raw)
dados_escalados.shape
```

```
(225, 5)
```

Fonte: Elaborado pelo autor.

3.5 Pandas

Pandas é um módulo Python que contém diversas ferramentas para a manipulação de dados estruturados. Ele combina a performance otimizada do NumPy com a flexibilidade presente na representação dos dados na forma de planilhas e bancos de dados relacionais (MCKINNEY, 2012).

Em desenvolvimento desde 2008, a bilbioteca Pandas tem como objetivo unir as ferramentas de análise de dados em Python, uma linguagem de propósito geral, com as funcionalidades de linguagens de bancos de dados.

É comum que as bases de dados de problemas reais tenham um formato tabular, onde cada linha representa uma observação diferente e as colunas representam características variadas dessas observações. Pode-se usar o *ndarray* do NumPy para manter esta base. No entanto, problemas podem surgir pelo fato de muitas funcionalidades do NumPy exigirem que todos os dados dentro do vetor sejam do mesmo tipo. Outro problema decorrente do uso direto do *ndarray* é que haveria uma perda na facilidade de uso.

Para contornar esses problemas, o Pandas define sua estrutura de dados principal, *DataFrame*, como uma tabela que é uma coleção de colunas independentes, cada uma representada por um *ndarray* (MCKINNEY, 2011).

Algumas das funcionalidades presentes no Pandas são a capacidade de lidar com valores faltantes na base de dados, juntar diferentes bases de dados e agrupar dados conforme um critério definido.

3.6 SciPy

O módulo SciPy é um conjunto de algoritmos para problemas específicos da computação científica (MCKINNEY, 2012). Alguns dos pacotes são:

- *integrate*: rotinas de integração numérica e de resolução de equações diferenciais.
- *linalg*: rotinas de álgebra linear e decomposição de matrizes.
- *optimize*: otimização de funções e algoritmos para cálculo de raízes.
- *stats*: testes estatísticos, distribuições normais de probabilidades.

3.7 Matplotlib

O pacote Matplotlib é responsável por criar visualizações gráficas 2D em diversas linguagens de programação. O foco está na facilidade de uso e em diversas funcionalidades disponíveis como símbolos, gráficos temporais, *antialiasing*, etc (BARRETT et al., 2005).

4 Desenvolvimento

Neste capítulo serão apresentados aspectos do desenvolvimento do projeto, com detalhes sobre a base de dados esolhida e como as ferramentas mencionadas no capítulo anterior foram empregadas. O desenvolvimento foi dividido em duas etapas: aquisição de dados e treinamento do algoritmo de aprendizado de máquina.

4.1 Base de dados

A base de dados utilizada neste projeto é disponibilizada pela ANEEL, orgão responsável por regulamentar políticas quanto a exploração e utilização dos serviços de energia elétrica, bem como definir padrões de qualidade que devem ser atendidos pelas empresas do setor.

As modalidades de regulação são de natureza técnica, onde são observados dados da geração, transmissão e distribuição de energia, financeira ou de pesquisa e desenvolvimento.

A base de dados escolhida diz respeito à dois indicadores da qualidade de distribuição de energia elétrica, Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), da distribuidora Companhia Paulista de Força e Luz (CPFL) no ano de 2018. Os indicadores são medidos pelas concessionárias e enviados à ANEEL, para que esta avalie a continuidade da energia elétrica oferecida à população (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2018a). Na figura 9 há um fluxograma detalhando o processo de apuração dos indicadores de continuidade.

Figura 9 – Fluxograma do Processo de Apuração e Avaliação dos Indicadores de Continuidade de Distribuição Elétrica.

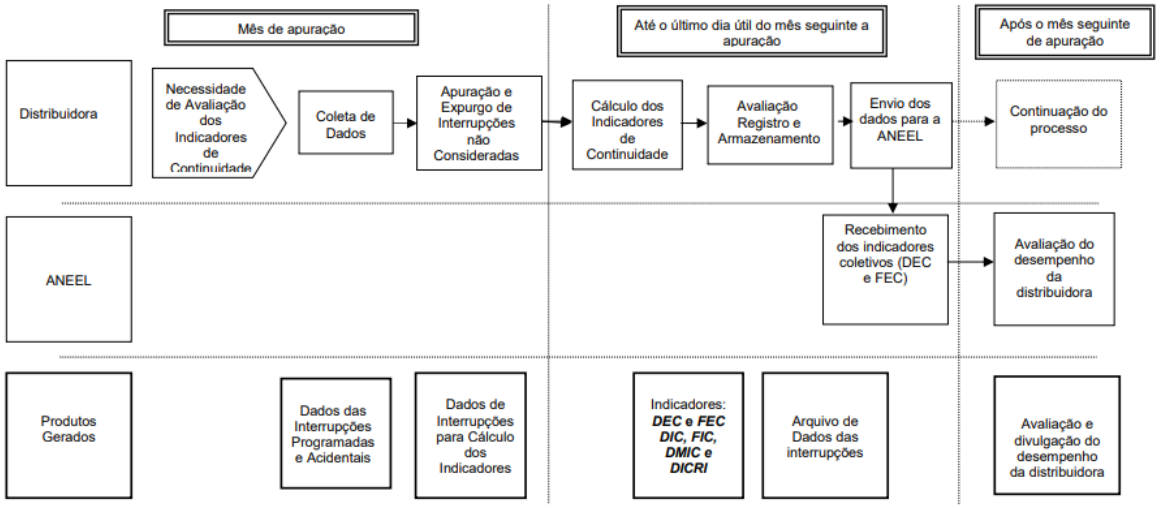

Fonte: AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (2018b)

Conforme determinado no manual regulatório Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2018b), DEC e FEC são expressos por:

(a) Duração Equivalente de Interrupção por Unidade Consumidora (DEC)

$$DEC = \frac{\sum_{i=1}^{Cc} DIC_i}{Cc} \tag{4.1}$$

(b) Frequência Equivalente de Interrupção por Unidade Consumidora (FEC)

$$DEC = \frac{\sum_{i=1}^{Cc} FIC_i}{Cc} \tag{4.2}$$

onde:

i = índice de unidades consumidoras atendidas;

Cc = número total de unidades consumidoras faturadas do conjunto no período de apuração;

DIC(i) = Duração de Interrupção Individual por Unidade Consumidora, excluindo-se as centrais geradoras;

FIC(i) = Frequência de Interrupção Individual por Unidade Consumidora, excluindo-se as centrais geradoras.

Os dados da base correspondem à 225 conjuntos regionais do estado de São Paulo atendidos pela CPFL Paulista e para cada um deles existem 23 características diferentes que foram medidas e são representadas por colunas. As duas primeiras colunas são informativas e indicam o nome do conjunto e seu código perante à ANEEL. O restante das características são:

- Número de consumidores: número de unidades consumidoras no conjunto.
- DECTOT: total de todos os DECs, ou seja, a duração total das interrupções.
- FECTOT: total de todos os FECs, ou seja, a quantidade total das interrupções.
- DECXP: DEC de interrupção de origem externa ao sistema de distribuição e programada.
- FECXP: FEC de interrupção de origem externa ao sistema de distribuição e programada.
- DECXN: DEC de interrupção de origem externa ao sistema de distribuição e não programada.
- FECXN: FEC de interrupção de origem externa ao sistema de distribuição e não programada.
- DECIP: DEC de interrupção de origem interna ao sistema de distribuição e programada.

- FECIP: FEC de interrupção de origem interna ao sistema de distribuição e programada.
- DECIND: DEC de interrupção de origem interna não programada e não expurgável.
- FECIND: FEC de interrupção de origem interna não programada e não expurgável.
- DECINE: DEC de interrupção de origem interna não programada e ocorrida em situação de emergência, não ocorrida em Dia Crítico.
- FECINE: FEC de interrupção de origem interna não programada e ocorrida em situação de emergência, não ocorrida em Dia Crítico
- DECINC: DEC de interrupção de origem interna ao sistema de distribuição, não programada e ocorrida Dia Crítico.
- FECINC: FEC de interrupção de origem interna ao sistema de distribuição, não programada e ocorrida Dia Crítico
- DECINO: DEC de interrupção de origem interna não programada, vinculadas a racionamento ou alívio de carga solicitado pelo ONS, não ocorrida em Dia Crítico.
- FECINO: FEC de interrupção de origem interna não programada, vinculadas a racionamento ou alívio de carga solicitado pelo ONS, não ocorrida em Dia Crítico.
- DECIPC: DEC de interrupção de origem interna ao sistema distribuição, programada e ocorrida em Dia Crítico.
- FECIPC: FEC de interrupção de origem interna ao sistema distribuição, programada e ocorrida em Dia Crítico
- DECXPC: DEC de interrupção de origem externa ao sistema distribuição, programada e ocorrida em Dia Crítico.
- FECXPC: FEC de interrupção de origem externa ao sistema distribuição, programada e ocorrida em Dia Crítico.
- DECXNC: DEC de interrupção de origem externa ao sistema distribuição, não programada e ocorrida em Dia Crítico.
- FECXNC: FEC de interrupção de origem externa ao sistema distribuição, não programada e ocorrida em Dia Crítico.

Na figura 10 pode-se observar uma amostra da base de dados, como ela é apresentada no portal eletrônico da ANEEL.

Figura 10 – Amostra da base de dados.

CONJUNTO	CÓDIGO	Nº DE CONSUMIDORES	DECTOT	FECTOT	DECXP	FECXP	DECXN	FECXN	DECIP	FECIP	DECIND	FECIND
Agudos 1	13861	15.100	**16,55**	**7,76**	0,00	0,00	0,00	0,00	3,20	0,69	12,53	6,43
Altair 1	13921	7.077	**23,23**	**14,50**	0,00	0,00	0,00	0,00	1,53	0,35	14,96	10,99
Altinópolis 1	13956	10.365	**22,26**	**10,41**	0,00	0,00	0,00	0,00	4,52	1,43	15,55	8,40
Americana 1	13823	10.046	**5,21**	**3,20**	0,00	0,00	0,00	0,00	1,44	0,34	3,44	2,51
Americana 2-Campo Verde	13822	19.262	**3,06**	**1,91**	0,00	0,00	0,00	0,00	0,59	0,18	1,33	0,97
Americana 4-Jardim	13826	45.176	**7,30**	**4,49**	0,00	0,00	0,00	0,00	2,61	0,58	2,52	2,73
Americana 5-Ipe	13821	25.899	**6,14**	**4,27**	0,00	0,00	0,00	0,00	1,61	0,33	3,06	2,77
Americana 6-Cillos	13825	22.916	**2,72**	**1,65**	0,00	0,00	0,00	0,00	0,86	0,26	1,30	1,08

Fonte: AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (2018a)

4.2 Aquisição de dados

Com a base de dados determinada, inicia-se a etapa de aquisição dos dados. Nesta fase, foi desenvolvido um programa para raspagem de dados utilizando a ferramenta Scrapy. Ele pode ser instalado pelo gerenciador de pacotes *package installer for Python* (Pip) do Python. O produto final desta etapa é um arquivo em formato CSV, onde a primeira linha corresponde aos nomes das colunas da tabela e as linhas seguintes correspondem às observações. Este formato foi escolhido por ser adequado para carregamento no módulo Pandas do Python. A figura 11 mostra a estrutura de diretórios do projeto Scrapy desenvolvido.

Figura 11 – Estrutura de projeto Scrapy.

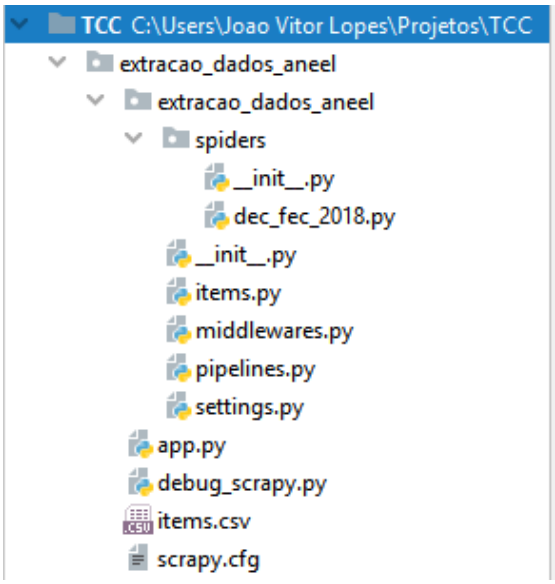

Fonte: Elaborado pelo autor.

Dois conceitos do Scrapy serão utilizados nesta fase: Spider para a extração dos dados e Pipeline de item para a formatação deles.

4.2.1 Extração de Dados

Executada na fase de extração de dados, a Spider é o componente responsável por acessar páginas web e analisá-las em busca de informações relevantes. Para seu funcionamento, ela deve conter o método *start_requests*, onde o endereço da página com as informações será acessado, e o método *parse* que contém a resposta do acesso e é onde ocorre a extração.

Para extrair dados de uma página HTML com Scrapy, deve-se definir por qual tipo de dado se deseja buscar. Na página *online* da ANEEL, os dados são apresentados estruturadamente numa tabela. Com o auxílio das ferramentas de desenvolvedor do navegador Google Chrome, pode-se observar como é a estrutura da tabela. A figura 12 ilustra esta estrutura.

Figura 12 – Estrutura do HTML da base de dados.

Fonte: Elaborado pelo autor.

Na imagem, os dados necessários correspondem à todas as *tags* HTML <tr>, dentro da tag HTML <table>, cuja classe é "tab_indice". Desta forma, sabendo a hierarquia de tags que corresponde aos itens desejados, pode-se informar à Spider o que é relevante para o projeto.

Na implementação da Spider há uma chamada ao método xpath, que recebe como parâmetro uma *string*. O Xpath é uma tecnologia que modela um documento em formato HTML ou *Extensible Markup Language* (XML) como uma árvore de nós (CLARK; DEROSE, 1999), que podem ou não ter atributos como texto, identificadores *Cascading Style Sheets* (CSS), etc.

Assim avança-se um nível da árvore correspondente com o uso do caractere / na *string* passada como parâmetro. Ao usar duas vezes este caractere, avança-se quantos níveis forem necessários até encontrar o nó ou atributo referenciado em sequência.

Um nó pode ser referenciado por seu nome e é possível usar seletores CSS para identificá-los mais precisamente.

Após este filtro, o método *extract* retorna todas as linhas da tabela na forma de um vetor de cadeias de caracteres. Em seguida, cada linha deste vetor é passada para o próximo componente do Scrapy.

4.2.2 Formatação de Dados

Na fase de formatação de dados, outro componenete da arquitetura do Scrapy é executado: os *Pipelines* de Item. Um *pipeline* é uma classe que recebe um item extraído de uma página, faz determinado processamento nele e lança este item modificado para o próximo *pipeline*, se houver. Neste projeto foram definidos quatro pipelines, detalhados a seguir.

4.2.2.1 Separa e Mapeia Colunas

Neste *pipeline*, a linha recebida é analisada em termos de quantidade de colunas. Essa quantidade é obtida por meio de um *xpath* que busca as *tags* HTML <td> (*table data*) dentro da linha. O formato de interesse de uma linha é aquele que apresenta 25 colunas, sendo que as demais são descartadas.

O método *extract* é novamente empregado, retornando um vetor onde cada posição representa uma coluna da linha. Iterando sobre este vetor, acessa-se cada coluna removendo espaços em branco e tabulações e também substituindo o caractere vírgula pelo caractere ponto, para que não haja erros ao gerar o arquivo final CSV, onde a vírgula deve ser usada como separador entre dois campos.

Após, é feito um mapeamento das colunas em uma estrutura de dados do Python chamada *dict*. Um *dict* é um dicionário de chaves e valores, onde as chaves foram definidas como o index da coluna e os valores seu conteúdo. A figura 13 apresenta a implementação deste *pipeline*.

Figura 13 – Implementação do *ParseColumnsPipeline*.

```
class ParseMapColumnsPipeline(object):
    def process_item(self, item, spider):
        item_selector = Selector(text=item["linha"])
        colunas = item_selector.xpath("//td//text()").extract()

        # Ignorando título da tabela.
        if len(colunas) != 25:
            DropItem("Descartando linha que corresponde à cabeçalho ou campos que não serão usados\n{}".format(item))

        # Se a linha possui 25 colunas, ela se refere aos nomes das colunas ou dados em si.
        else:
            # Criando dict para cada observação.
            dicionario = dict()
            for index, c in enumerate(colunas):
                dicionario[str(index)] = c.strip().replace(',', '.') # Removendo espaços.
            return dicionario
```

Fonte: Elaborado pelo autor.

4.2.2.2 Limpeza de Dados

O próximo *pipeline* deste fluxo faz a limpeza do dado correspondente à coluna de número de consumidores. No dado original, há um ponto final separando a casa de milhar do valor. Para que este ponto não fosse interpretado erroneamente como um separador decimal, é feita uma substituição de ponto por uma cadeia de caracteres vazia. A figura 14 apresenta a implementação deste *pipeline*.

Figura 14 – Implementação do *CleanFieldsPipeline*.

```
class CleanFieldsPipeline(object):
    def process_item(self, item, spider):
        # Removendo o caractere '.' do número de consumidores.
        item["2"] = item["2"].replace('.', '')
        return item
```

Fonte: Elaborado pelo autor.

4.2.2.3 Formatador CSV

Neste *pipeline* ocorre a transformação dos valores do dicionário de volta em um vetor de cadeias de caracteres. Isso é feito porque existem recursos de um vetor Python que permitem a concatenação dos elementos do vetor em uma cadeia de caracteres, sendo possível definir um delimitador entre eles. Assim, cada linha da tabela sai deste *pipeline* totalmente formatada. A figura 15 apresenta a implementação deste *pipeline*.

Figura 15 – Implementação do *CSVFormatPipeline*.

```
class CSVFormatPipeline(object):
    def process_item(self, item, spider):
        colunas = list(item.values())
        linha_formato_csv = ','.join(colunas)
        return {"linha": linha_formato_csv}
```

Fonte: Elaborado pelo autor.

4.2.2.4 Escritor de Arquivo CSV

Neste último *pipeline*, cada linha que chega é escrita no final de um arquivo criado com a extensão CSV. A figura 16 apresenta a implementação deste *pipeline*.

Figura 16 – Implementação do *CSVWriterPipeline*.

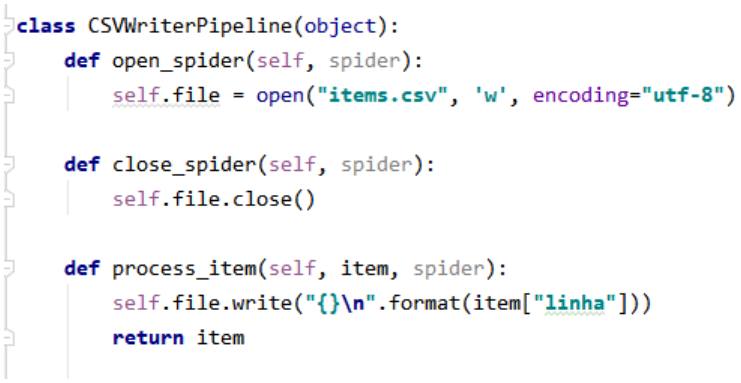

```
class CSVWriterPipeline(object):
    def open_spider(self, spider):
        self.file = open("items.csv", 'w', encoding="utf-8")

    def close_spider(self, spider):
        self.file.close()

    def process_item(self, item, spider):
        self.file.write("{}\n".format(item["linha"]))
        return item
```

Fonte: Elaborado pelo autor.

4.3 Treinamento

Após a aquisição e preprocessamento de dados, foi iniciada a fase de treinamento. Neste trabalho, foram aplicados dois algoritmos de aprendizado não supervisionado diferentes: Análise de Componentes Principais (PCA) e K-Means. O algoritmo PCA será aplicado em estudos da dimensionalidade da base de dados e o K-Means fará o agrupamento de dados em um número de grupos predeterminado.

O código 4.1 é o responsável pelo carregamento da base de dados nos dois algoritmos, através da biblioteca *pandas*.

Código 4.1 – Carregamento da base de dados com *pandas*

```
import pandas as pd
# Lendo a base de dados para a variavel dados_raw.
dados_raw = pd.read_csv("dec_fec_2018.csv")
```

Outra tarefa comum à todos os algoritmos foi a separação das colunas relevantes para treinamento. As duas primeiras colunas da base de dados, CONJUNTO e CÓDIGO, são desconsideradas nos treinamentos. O código 4.2 faz esta separação.

Código 4.2 – Separação das colunas relevantes.

```
colunas = list(dados_raw.columns)
# Colunas de indice 2 ate o indice final do vetor.
dados_para_escalar = dados_raw[colunas[2:]]
```

Em sequência, foi realizada a normalização dos dados, necessária nos treinamento dos dois estimadores. Isto foi feito com a classe *scale* do módulo *preprocessing* da biblioteca *Sklearn* conforme o algoritmo do código 4.3.

Código 4.3 – Normalização de dados.

```
from sklearn.preprocessing import scale
dados_escalados = scale(dados_para_escalar)
```

A tarefas seguintes incluem as chamadas dos métodos de treinamento dos algoritmos e dos métodos para visualização gráfica dos resultados.

4.3.1 Análise de Componentes Principais

Com os dados normalizados, duas estratégias foram estudadas com o PCA. Uma delas busca avaliar o melhor número de componentes que definem o problema através da redução de dimensionalidade e a outra busca visualizar graficamente os dois componentes mais significativos.

Para analisar o melhor número de componentes que definem o problema, usou-se o algoritmo PCA sem informar qualquer quantidade de componentes. Neste cenário, o algoritmo decide que o número máximo de componentes é dado pelo mínimo entre o total de observações e o número de características delas.

Nesta base de dados, há 255 observações com 23 características cada, portanto, o número de componentes máximo foi 23. Com este dado, o estimador calcula a quantidade de variância acumulada para cada número de componentes variando entre zero e 23. O código 4.4 mostra o treinamento do algoritmo. O segundo treinamento do estimador foi feito com base no número ideal obtido do primeiro.

Código 4.4 – Executando PCA sem definição do número de componentes.

```
from sklearn.decomposition import PCA
# Instancia classe PCA sem definir numero de componentes.
pca_n = PCA().fit(dados_escalados)
```

4.3.2 K-Means

Após a normalização dos dados para o treinamento do algoritmo K-Means, foi necessário definir o número de *clusters* ideal. Para tal, foi utilizado o Método do Cotovelo.

O K-Means foi treinado para número de agrupamentos variando entre 1 e 100 com os dados originais e também normalizados. O número 100 foi escolhido arbitrariamente.

O custo de treinamento foi recuperado para cada treinamento e então um gráfico foi construído com o objetivo de encontrar visualmente o ponto do cotovelo.

O algoritmo do código 4.5 define uma função que recebe como parâmetro o número de agrupamentos desejados, treina os dados com K-Means e retorna uma lista composta pelo número de grupos e o custo associado ao treinamento (atributo *inertia_*).

Código 4.5 – Função que calcula o erro associado ao treinamento do K-Means para *k clusters*.

```
from sklearn.cluster import KMeans
def kmeans(k, dados):
  modelo = KMeans(n_clusters=k)
  modelo.fit(dados)
  return [k, modelo.inertia_]
```

Com os resultados dos treinamentos para os dados normalizados e originais, os gráficos apresentados pelas figuras 17 e 18 foram impressos.

Figura 17 – Identificação do número adequado de agrupamentos para o K-Means com dados não normalizados.

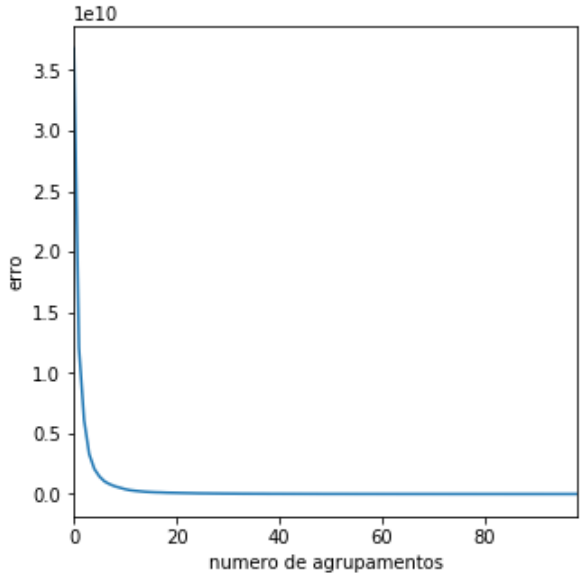

Fonte: Elaborado pelo autor.

Percebe-se dois resultados muito distintos. Dados não normalizados indicaram que o número adequado de agrupamentos k é 3 enquanto os mesmos dados normalizados indicaram que o valor apropriado para k é aproximadamente 20.

Os resultados do K-Means para a base de dados não normalizada não são interessantes para este trabalho. O agrupamento foi feito inteiramente com base na variável número de consumidores, por esta possuir ordem de grandeza maior que a das outras. Isso pode ser percebido no gráfico gerado pelo treinamento, conforme a figura 19.

Figura 18 – Identificação do número adequado de agrupamentos para o K-Means com dados normalizados.

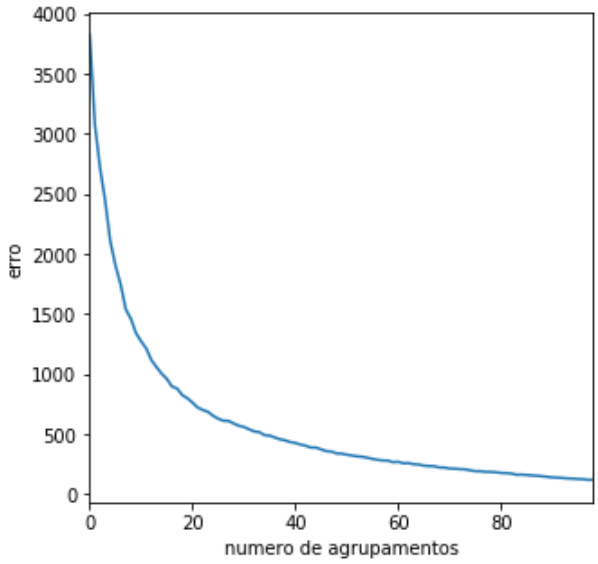

Fonte: Elaborado pelo autor.

Figura 19 – K-Means para k = 3 com dados não normalizados.

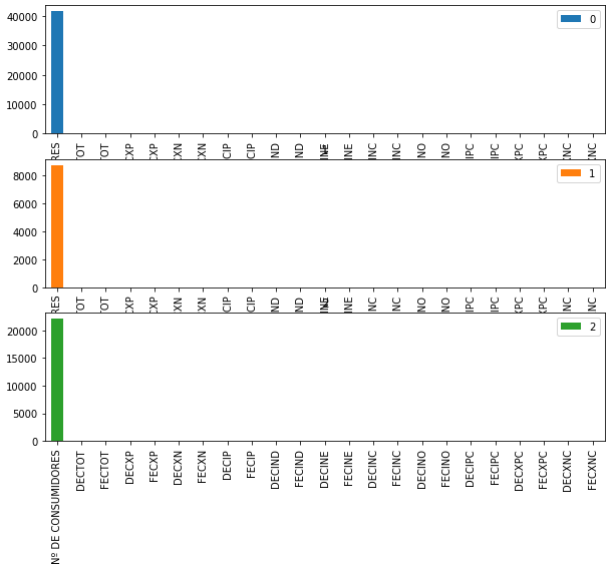

Fonte: Elaborado pelo autor.

Embora o número ideal de grupos definido pelo Método do Cotovelo para dados normalizados tenha sido aproximadamente 20, o treinamento dos dados também foi realizado com um número menor de agrupamentos $k = 3$, para fins exploratórios.

5 Resultados

Neste capítulo serão analisados os resultados dos treinamentos de cada estimador utilizado na fase de desenvolvimento.

5.1 PCA

O resultado do método de treinamento *fit* do estimador PCA é uma variável com diversos atributos. O atributo *explained_variance_ratio_* devolve um vetor de tamanho igual ao número de componentes, onde cada posição representa a quantidade de variação dos dados explicada por ele.

Na primeira execução do estimador, não foi definido um número de componentes. Por isso, o algoritmo foi executado para todos os valores inteiros entre 0 e 23.

Um gráfico da variância acumulada pelo número de componentes foi construído com a biblioteca Matplotlib. A figura 20 mostra este gráfico.

Figura 20 – Análise do melhor número de componentes.

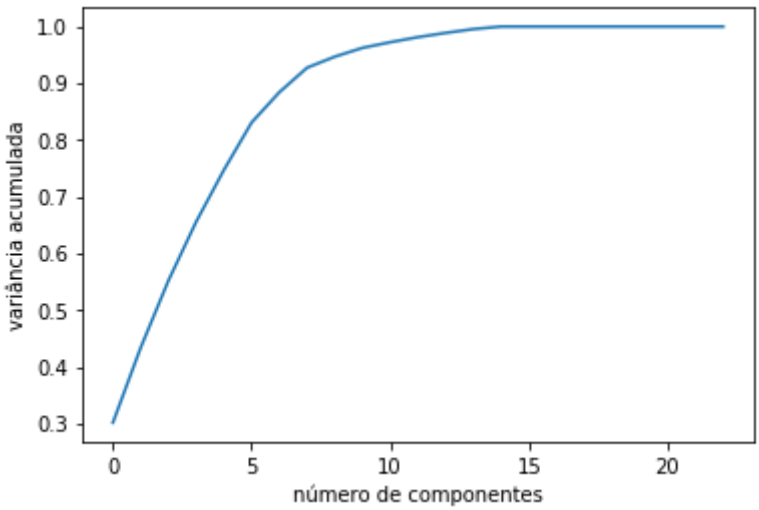

Fonte: Elaborado pelo autor.

Verifica-se no gráfico que a variância acumulada aumenta conforme o número de componentes cresce. Cada um desses componentes corresponde à uma combinação linear das 23 dimensões originais e busca maximizar a variância dos dados.

Pode-se observar que aproximadamente 90% da variação presente nos dados pode ser resumida em 7 componentes principais, correspondendo à uma diminuição de mais de um terço

da dimensionalidade inicial do problema. Por este motivo, determinou-se que 7 seria o número ideal de componentes para aprofundamento no estudo.

Uma vez determinado que 7 é um número de componentes que representa o problema sem perder muitas informações, o PCA foi executado novamente recebendo 7 como parâmetro.

Na figura 21, que mostra a quantidade de variação obtida para cada um dos 7 componentes, pode-se observar que há uma combinação linear das variáveis que por si só corresponde à 30% da variabilidade do conjunto todo. Assim, a base de dados foi redefinida em termos dos 7 componentes principais através do código 5.1.

Figura 21 – Variação explicada por cada componente.

```
array([0.30157916, 0.13204124, 0.11825075, 0.10379361, 0.09131434,
       0.08377087, 0.05340664])
```

Fonte: Elaborado pelo autor.

Código 5.1 – Redefinindo base de dados em termos dos 7 componentes principais.

```
# Unindo os conjuntos aos valores de principais componentes.
df_principal = pd.DataFrame(data=melhores_pca_7,
                            columns=['pc1', 'pc2', 'pc3', 'pc4',
                                     'pc5', 'pc6', 'pc7'])

df_final = pd.concat([df_principal, dados_raw[['CONJUNTO']]],
                     axis=1)
```

A figura 22 mostra o formato da base de dados redefinida.

Figura 22 – Visualização parcial da base de dados redefinida em termos dos 7 componentes principais.

	p1	p2	pc3	pc4	pc5	pc6	pc7	CONJUNTO
0	2.172784	0.589842	-0.644912	0.082274	-0.942317	-0.551558	-0.958559	Agudos 1
1	6.985909	-2.575659	2.300316	-1.508522	3.122319	-0.888337	-0.360362	Altair 1
2	4.964859	1.200955	1.645339	-1.424635	-0.640189	1.070273	-1.161340	Altinópolis 1
3	-1.565635	0.389560	-0.244720	-0.543875	0.163264	0.190893	-0.708446	Americana 1
4	-2.561165	-0.239952	-0.404781	-0.497320	0.810837	-0.299731	0.330227	Americana 2-Campo Verde

Fonte: Elaborado pelo autor.

Com base nos valores dos 7 componentes, foi elaborado o gráfico da figura 23 com as duas dimensões mais significativas da variabilidade.

Figura 23 – Componentes mais significativos para explicar a variabilidade.

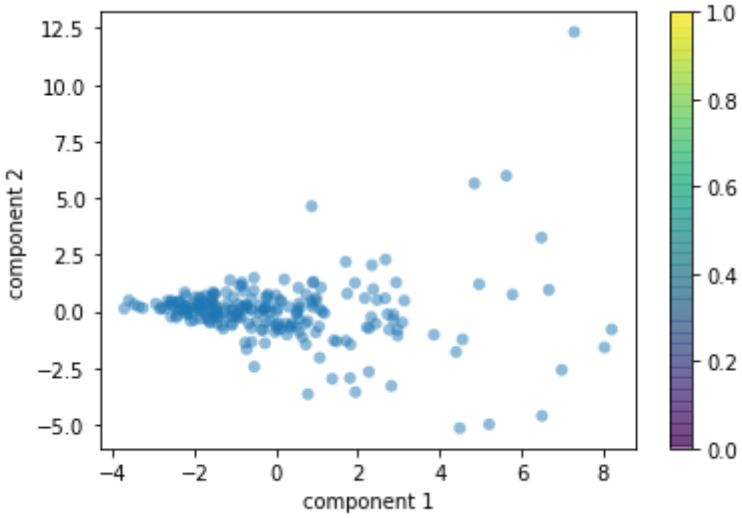

Fonte: Elaborado pelo autor.

Ao observar a imagem, deve-se lembrar que o grande aglomerado de observações pode não corresponder à dados realmente parecidos. Com a diminuição de dimensionalidade perde-se informações, como o quão distantes esses dados estariam se fossem consideradas as outras 5 dimensões não representadas no gráfico, por exemplo.

No entanto, observa-se no gráfico a presença de conjuntos considerados *outliers*, ou seja, que estão afastados do restante. O código 5.2 identifica pelo nome alguns destes conjuntos no gráfico. A figura 24 mostra os *outliers*.

Código 5.2 – Identificando *outliers* no gráfico.

```
# Plot dos dois componentes principais.
plt.scatter(melhores_pca_7[:, 0], melhores_pca_7[:, 1],
            edgecolor='none', alpha=0.5,
            cmap=plt.cm.get_cmap('prism', 10))
plt.xlabel('component␣1')
plt.ylabel('component␣2')
plt.colorbar();

# Identificando outliers.
p1s = melhores_pca_7[:, 0]  # Eixo x.
p2s = melhores_pca_7[:, 1]  # Eixo y.
conjuntos = df_final["CONJUNTO"]  # Nomes dos conjuntos.
```

```
for i, conjunto in enumerate(conjuntos):
  if (p1s[i] > 6) and (p2s[i] > 2.5 or p2s[i] < 2):
    plt.annotate(conjunto, (p1s[i], p2s[i]))
```

Figura 24 – Identificação de alguns conjuntos considerados *outliers*.

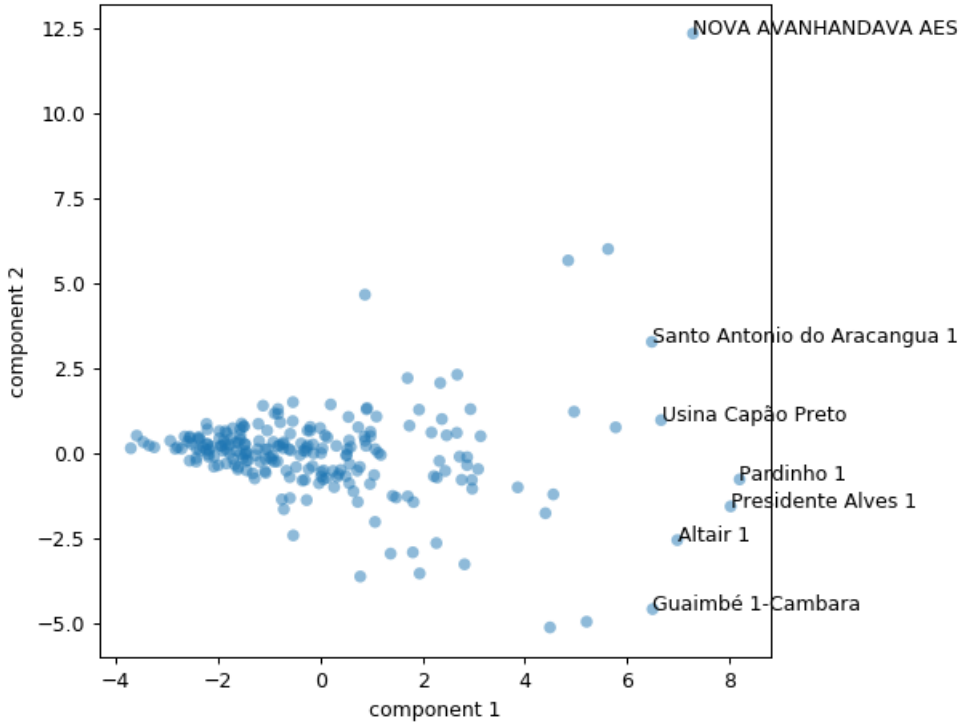

Fonte: Elaborado pelo autor.

Nesta abordagem, o conjunto NOVA AVANHANDAVA AES é o que mais se destaca.

5.2 K-Means

5.2.1 K-Means para 3 Agrupamentos

A figura 25 ilustra os agrupamentos formados no treinamento do K-Means para $k = 3$.

Quando se busca identificar 3 grupos utilizando K-Means, percebe-se visualmente algumas diferenças. O grupo 2 apresenta valores muito grandes para as variáveis DECXN e FECXN quando comparado aos demais. O grupo 0, por outro lado, apresenta os melhores indicadores na maioria das variáveis e o maior número de consumidores.

Os números de observações em cada agrupamento se encontram na tabela 1.

A tabela indica que os conjuntos do grupo 2, identificados na base de dados por NOVA AVANHANDAVA AES e VALPARAISO CTEEP, foram capazes de, sozinhos, caracterizar um único agrupamento. Este resultado reforça as observações do estimador PCA, que indicou o conjunto NOVA AVANHANDAVA AES como um *outlier*.

Figura 25 – K-Means para k = 3 com dados normalizados.

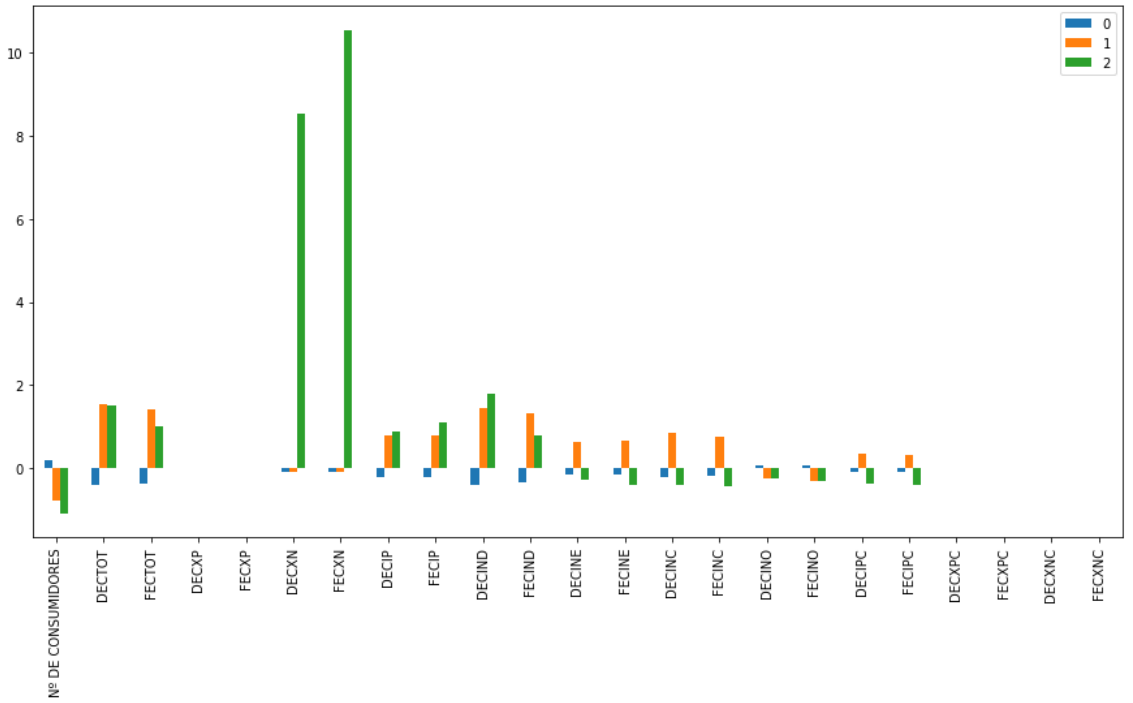

Fonte: Elaborado pelo autor.

Tabela 1 – Número de observações por agrupamento.

Grupo	Número de observações
0	177
1	46
2	2

Fonte: Elaborada pelo autor.

5.2.2 K-Means para 20 agrupamentos

Para o treinamento do K-Means com $k = 20$, foram obtidos grupos mais específicos. Na figura 26, pode-se observar que o grupo 3, composto por 11 conjuntos, é o que apresenta maiores valores para o indicador DECXN. A tabela 2 mostra a quantidade de conjuntos agrupados em cada *cluster*.

Pela observação da tabela, pode-se verificar agrupamentos distintos em relação ao número de observações. Esta informação pode ser útil para identificar grupos com poucas observações e altas taxas de interrupção de energia, candidatos à planos de ação mais urgentes e rápidos de executar, como é o caso do agrupamento 3.

Estratégias de gestão podem ser tomadas observando cada grupo isoladamente. A figura 27 ilustra o grupo 9, que destaca-se por apresentar maiores taxas de frequência com que as interrupções ocorrem, em contraste à maioria dos grupos onde a duração das interrupções é maior.

Figura 26 – K-Means para k = 20 com dados normalizados.

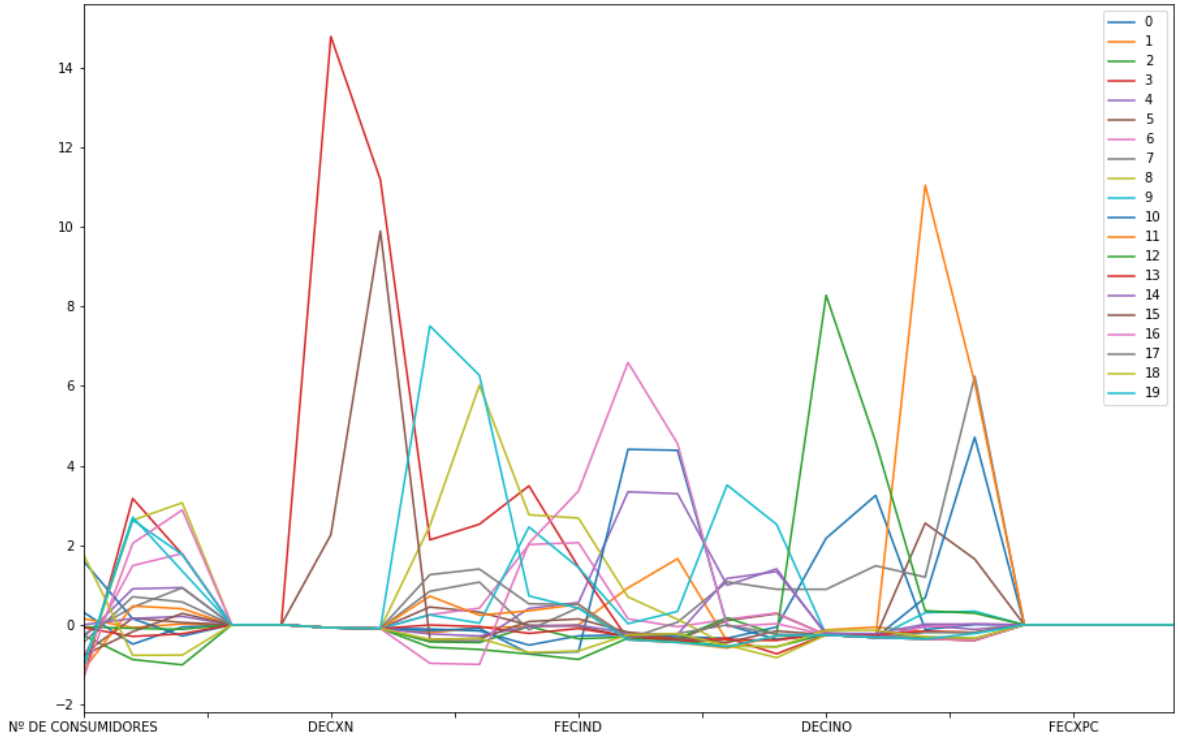

Fonte: Elaborado pelo autor.

Figura 27 – Indicadores do agrupamento 9.

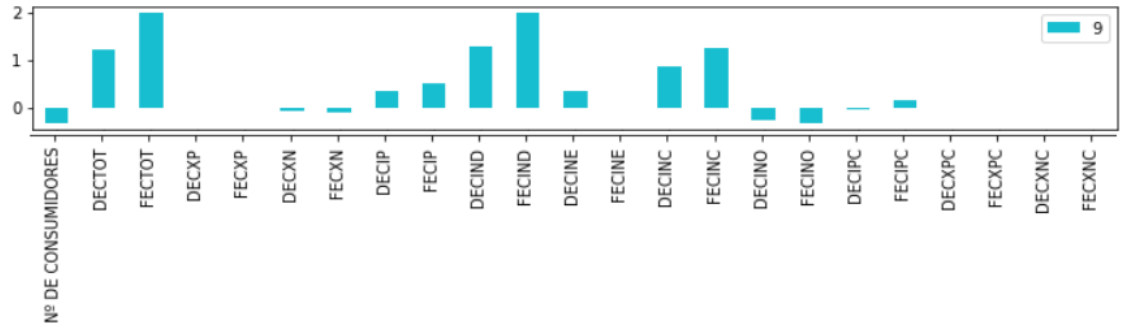

Fonte: Elaborado pelo autor.

Tabela 2 – Número de observações por agrupamento quando $k = 20$

Grupo	Número de observações
0	30
1	7
2	6
3	11
4	8
5	1
6	39
7	48
8	2
9	2
10	2
11	1
12	9
13	6
14	1
15	9
16	2
17	12
18	2
19	27

Fonte: Elaborada pelo autor.

5.3 Avaliação dos Estimadores

A métrica Coeficiente de Silhueta para avaliação de estimadores foi apliacada sobre o K-Means buscando comparar os treinamentos com diversos valores de agrupamentos. A tabela 3 mostra estes resultados.

Tabela 3 – Coeficiente de Silhueta para o estimador K-Means.

Número de grupos	Coeficiente de Silhueta
2	0.3890
3	0.3835
5	0.2843
10	0.1865
20	0.1896

Fonte: Elaborada pelo autor.

Nesta métrica, os valores podem variar entre -1 e 1 e quanto maior o coeficiente calculado, mais definidos são os agrupamentos. Valores de coeficiente próximos de 0 são indicativos de sobreposição de *clusters* (ROUSSEEUW, 1987).

Observa-se na tabela que existe sobreposição de *clusters* para diversos valores de k.

Embora o Método do Cotovelo tenha indicado que o número de agrupamentos ideal é 20, o Coeficiente de Silhueta indica que menos agrupamentos seja uma representação mais bem definida do problema.

6 Conclusão

Nesta monografia, foram explorados diversos conceitos da Ciência de Dados na gestão de energia elétrica.

Foi possível a utilização de ferramentas do ambiente de desenvolvimento da linguagem Python, desde as fases de extração de dados, até o treinamento de algoritmos de aprendizado de máquina.

Pela natureza exploratória do aprendizado de máquina não supervisionado, o intuito dessa análise foi a busca de padrões que se repetem entre estimadores e a criação de visualizações gráficas que ajudem na interpretação dos dados.

Ambos os estimadores treinados no trabalho mostraram bons resultados no aspecto de identificação de *outliers*. Identificar valores atípicos é uma tarefa importante, porque pode criar prioridades, auxiliando organizações na administração de seus recursos.

Com 3 agrupamentos, observou-se que existe um conjunto de áreas administradas pela CPFL que apresentam alto número de consumidores e bons indicadores de continuidade, embora este grupo seja o que apresenta maiores índices de racionamento de energia elétrica.

Para 20 agrupamentos, observou-se uma separação muito voltada às diferentes caracteristicas do dados.

O *outlier* mais relevante identificado em ambos os estimadores foi o conjunto NOVA AVANHANDAVA AES.

Diante destas análises, pode-se concluir que o presente estudo foi capaz de cumprir seu objetivo, trazendo considerações iniciais acerca da qualidade da distribuição de energia elétrica feita pela CPFL Paulista.

6.1 Trabalhos Futuros

Como sugestão de trabalhos futuros, pode-se considerar o treinamento de outros algoritmos de aprendizado não supervisionado ou supervisionado.

Pode-se unir conhecimentos específicos do domínio do problema aos treinamentos dos estimadores, para que sejam mais assertivos.

É possível também criar bases de dados com indicadores de diferentes concessionárias de energia elétrica e comparar realidades brasileiras distintas.

Referências

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *Indicadores Coletivos de Continuidade (DEC e FEC)*. 2018. Disponível em : <https://www.aneel.gov.br/indicadores-coletivos-de-continuidade>. Acesso em: 25 ago. de 2019.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST*. [S.l.], 2018.

AMARAL, F. *Introdução à Ciência de Dados: mineração de dados e big data*. [S.l.]: Alta Books Editora, 2016.

BARRETT, P.; HUNTER, J.; MILLER, J. T.; HSU, J.-C.; GREENFIELD, P. matplotlib–a portable python plotting package. In: *Astronomical data analysis software and systems XIV*. [S.l.: s.n.], 2005. v. 347, p. 91.

CAMILO, C. O.; SILVA, J. C. d. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. *Universidade Federal de Goiás (UFC)*, p. 1–29, 2009.

CLARK, J.; DEROSE, S. *XML path language (XPath) version 1.0*. 1999.

DANGETI, P. *Statistics for machine learning*. [S.l.]: Packt Publishing Ltd, 2017.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. *AI magazine*, v. 17, n. 3, p. 37–37, 1996.

FERREIRA, H. M. Uso de ferramentas de aprendizado de máquina para prospecção de perdas comerciais em distribuição de energia elétrica. [sn], 2008.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. *An introduction to statistical learning*. [S.l.]: Springer, 2013. v. 112.

KLUYVER, T.; RAGAN-KELLEY, B.; PÉREZ, F.; GRANGER, B.; BUSSONNIER, M.; FREDERIC, J.; KELLEY, K.; HAMRICK, J.; GROUT, J.; CORLAY, S.; IVANOV, P.; AVILA, D.; ABDALLA, S.; WILLING, C. Jupyter notebooks – a publishing format for reproducible computational workflows. In: LOIZIDES, F.; SCHMIDT, B. (Ed.). *Positioning and Power in Academic Publishing: Players, Agents and Agendas*. [S.l.], 2016. p. 87 – 90.

KODINARIYA, T. M.; MAKWANA, P. R. Review on determining number of cluster in k-means clustering. *International Journal*, v. 1, n. 6, p. 90–95, 2013.

MARTINHO, E. *Distúrbios da energia elétrica*. [S.l.]: Saraiva Educação SA, 2009.

MCKINNEY, W. pandas: a foundational python library for data analysis and statistics. *Python for High Performance and Scientific Computing*, v. 14, 2011.

MCKINNEY, W. *Python for data analysis: Data wrangling with Pandas, NumPy, and IPython*. [S.l.]: "O'Reilly Media, Inc.", 2012.

MEHL, E. L. Qualidade da energia elétrica. *UNIVERSIDADE FEDE-RAL DO PARANÁ–UFPR*, 2012.

MINKA, T. P. Automatic choice of dimensionality for pca. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2001. p. 598–604.

MITCHELL, R. *Web Scraping with Python: Collecting More Data from the Modern Web*. [S.l.]: "O'Reilly Media, Inc.", 2018.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, p. 32, 2003.

MYERS, D.; MCGUFFEE, J. W. Choosing scrapy. *Journal of Computing Sciences in Colleges*, Consortium for Computing Sciences in Colleges, v. 31, n. 1, p. 83–89, 2015.

OLIPHANT, T. E. *A guide to NumPy*. [S.l.]: Trelgol Publishing USA, 2006. v. 1.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, Elsevier, v. 20, p. 53–65, 1987.

SCRAPY. *Architecture overview*. 2019. Disponível em : <https://docs.scrapy.org/en/latest/topics/architecture.html>. Acesso em: 18 set. de 2019.

WALLER, M. A.; FAWCETT, S. E. Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management. *Journal of Business Logistics*, Wiley Online Library, v. 34, n. 2, p. 77–84, 2013.