

## Cálculo do ponto de operação do sistema de potência usando o software WEKA.

## Calculation of the operating point of the power system using the WEKA software.

### RESUMO

David Silva Marques de Souza  
[davids@alunos.utfpr.edu.com](mailto:davids@alunos.utfpr.edu.com)  
Universidade Tecnológica Federal do Paraná, UTFPR, Medianeira, Paraná, Brasil

Jeiciane de Souza Paula  
[jeiciane@alunos.utfpr.edu.com](mailto:jeiciane@alunos.utfpr.edu.com)  
Universidade Tecnológica Federal do Paraná, UTFPR, Medianeira, Paraná, Brasil

Gloria Patricia López  
[gloriap@utfpr.edu.br](mailto:gloriap@utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, UTFPR, Santa Helena, Paraná, Brasil

Hugo Andrés Ruiz Flórez  
[hugoflorez@utfpr.edu.br](mailto:hugoflorez@utfpr.edu.br)  
Universidade Tecnológica Federal do Paraná, UTFPR, Medianeira, Paraná, Brasil

O estudo do fluxo de potência é fundamental para a operação satisfatória do sistema de potência, ele consiste basicamente na determinação dos fasores de tensão de cada um dos nós do sistema. Neste trabalho fora verificado o desempenho de outras metodologias para esta análise, com o auxílio da linguagem de programação Python e os softwares AMPL e WEKA. Afim de realizar esta metodologia foram elaboradas séries de demanda de potência ativa e reativa para cada uma das barras de carga do sistema de potência adotado, o IEEE 14 bus. Com estes dados foram calculados os pontos de operação do sistema, através de um modelo matemático de otimização desenvolvido no AMPL, os quais foram utilizados para o treinamento de três métodos de classificação, o J48, Naive Bayes e K-ésimo vizinho mais próximo, implementados com o auxílio do software WEKA. A maior média de percentual de acerto obtido com o grupo de teste após a devida calibração dos modelos foi de 74.74%, nos métodos Naive Bayes e K-ésimo vizinho mais próximo.

**PALAVRAS-CHAVE:** Sistemas de energia elétrica. Aprendizado do computador. Otimização matemática.

### ABSTRACT

**Recebido:** 19 ago. 2020.

**Aprovado:** 01 out. 2020.

**Direito autoral:** Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



The study of the power flow is fundamental for the satisfactory operation of the power system, it consists of the determination of the voltage phasors of each of the nodes of the system. In this work, the performance of other methodologies for this analysis was verified, with the aid of the Python programming language and the AMPL and WEKA software. To carry out this methodology, a series of active and reactive power demands were elaborated for each of the load bars of the adopted power system, the IEEE 14 bus. With these data, the operating points of the system were calculated, through a mathematical optimization model developed at AMPL, which were used to train three classification methods, the J48, Naive Bayes, and K-nth nearest neighbor, implemented with the help of the WEKA software. The highest average percentage of correctness obtained with the test group after due calibration of the models was 74.74%, in the Naive Bayes and K-nth nearest neighbor methods.

**KEYWORDS:** Electric power systems. Machine learning. Mathematical optimization..



## INTRODUÇÃO

Com o desenvolvimento industrial, tecnológico e científico, a energia elétrica passou a desempenhar um papel fundamental na sociedade para o progresso da civilização e melhoria contínua do padrão de vida do ser humano (STEVENSON, 1986, p. 1). Os sistemas elétricos de potências (SEP) são um dos sistemas responsáveis por fornecerem energia em tempo real, e são compostos por três partes principais: a geração, a transmissão e a distribuição (BLUME, 2007, p.19).

No contexto operacional, o estudo de fluxo de carga (ou fluxo de potência) de um SEP é essencial, haja vista a necessidade do conhecimento dos efeitos das interligações para uma operação satisfatória do sistema estudado (STEVENSON, 1986, p. 5). Este estudo de carga pode ser elaborado por uma série de metodologias computacionais, entre elas há a resolução pelo método de Newton Raphson, e a estimação de estados para um SEP.

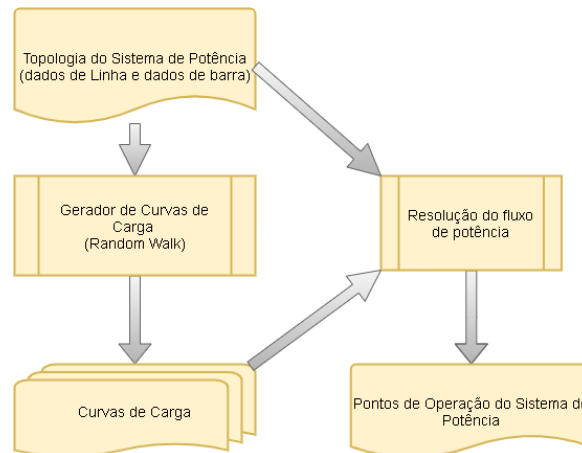
O estudo do fluxo de potência consiste fundamentalmente na determinação dos fasores de tensão de cada nó elétrico do sistema de potência, a partir do conhecimento da topologia do SEP e de seus valores de impedância (DAZA, 2016, p. 169). Os métodos clássicos, citados anteriormente, são muito eficientes para o cálculo convencional do fluxo de potência, contudo, em algumas circunstâncias o problema da não convergência ainda ocorre (FAN, ZHANG, WANG, 2019, p.82).

Diante disto, se faz necessário o estudo e desenvolvimento de outros algoritmos e metodologias para a resolução destes problemas, o presente trabalho tem como objetivo verificar o desempenho de outras metodologias para o cálculo do ponto de operação do sistema de potência, com o auxílio da linguagem de programação Python e os softwares AMPL e WEKA.

## MATERIAL E MÉTODOS

O presente trabalho tem como objetivo testar uma abordagem distinta para o cálculo do ponto de operação do sistema de potência, com esta finalidade, adotou-se o sistema de 14 barras do IEEE como o modelo a ser considerado durante o processo de resolução. A partir deste sistema fora elaborado um banco de dados obtido conforme a metodologia exposta na figura 1.

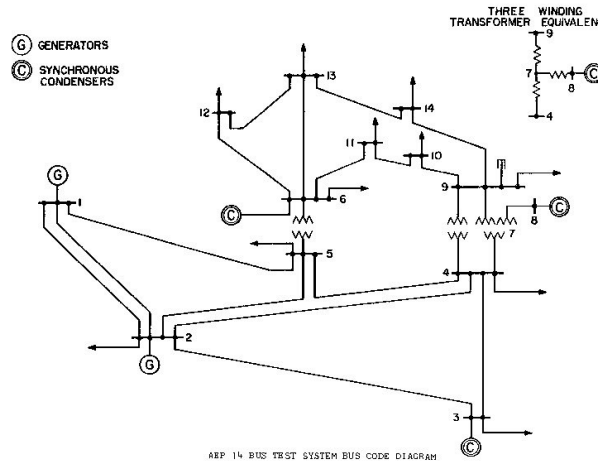
Figura 1 – Fluxograma da construção do banco de dados.



Fonte: Autoria própria (2020).

O processo proposto consiste na criação de perfis de demanda de potência ativa e reativa para as barras dependendo dos elementos elétricos e das grandezas relacionadas às barras, conforme se observa em nosso sistema na figura 2. Em barras do tipo PQ, as barras de carga, são geradas séries de demanda ativa e reativa, enquanto nas demais barras adota-se características constantes. O processo de geração dessas séries foi elaborado a partir do algoritmo de caminhada aleatório (ou random walk), o qual gera 5000 medidas de demanda.

Figura 2 – Topologia do sistema IEEE 14 Bus.

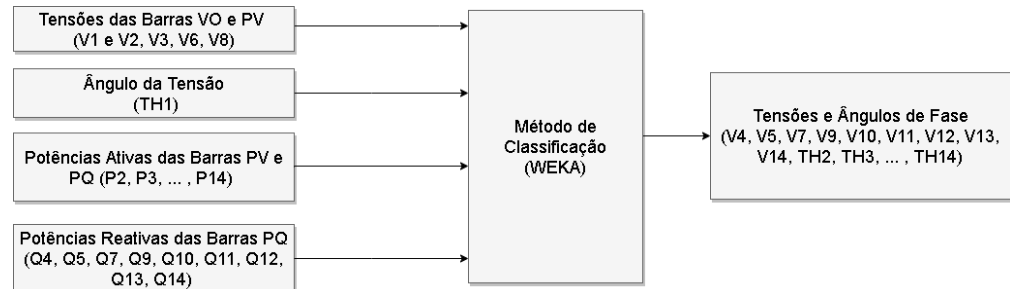


Fonte: Li, Qiao, Sun, Wan, Wang, Xia, Xu e Zhang (2010).

A partir destas séries, fora calculado o ponto de operação dos sistemas para os múltiplos cenários existentes, resultado este necessário para o treinamento supervisionado dos algoritmos J48, Naive Bayes e o k-ésimo vizinho mais próximos (KNN). Estes algoritmos de classificação foram implementados no software WEKA, e treinados e testados a partir da metodologia de validação cruzada 10 vezes, afim de garantir um erro do tipo I adequado, um erro do tipo II baixo e alta replicabilidade do teste de significância, consoante Bouckaert e Frank (2008, p. 10).

A classificação elaborada pelos algoritmos, constitui-se em classificar o cenário ao qual o sistema está submetido em pontos de operação conforme se observa-se na figura 3.

Figura 3 – Simplificação do processo de classificação.



Fonte: Autoria própria (2020).

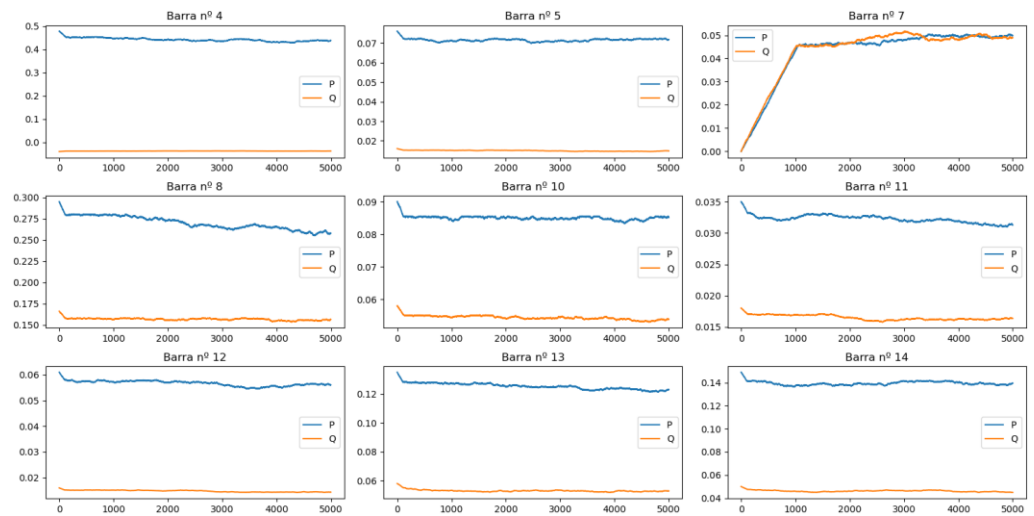
Ao fim do estudo, com a finalidade de verificar qual algoritmo fora mais eficaz aplicou-se o teste Paired corrected T-Tester com o nível de significância de 1%. O teste Paired corrected T-Tester é baseado no teste t de Student (DIETTERICH, 1997), o qual é um método estatístico usado para comparar o resultado obtido por dois grupos de medidas (MORETTIN; BUSSAB, 2010, p. 362). A partir dele é verificado se os resultados não aconteceram por acaso (FERREIRO, 2010, p. 109).

## RESULTADOS E DISCUSSÃO

O modelo matemático elaborado para a resolução do fluxo de potência fora escrito em AMPL, já o algoritmo das caminhas aleatórias fora feito em Python, e a implementação dos métodos de classificação foram elaborados no WEKA. Com a finalidade de trabalhar com as 3 ferramentas fora necessário escrever um algoritmo em Python capaz de se comunicar com o AMPL para que fosse feita a automação da geração do banco de dados a ser usado no treinamento dos modelos de classificação.

O algoritmo implementado para a elaboração dos passos aleatórios fora feito de modo que o tamanho de cada passo fosse adaptado a escala das grandezas ligadas a barra, sendo então obtido após a sua execução as curvas presentes na figura 4. Onde, nela pode-se observar que o eixo y apresenta escalas diferentes entre as barras.

Figura 4 – Curvas de carga.



Fonte: Autoria própria (2020).

A partir dessas séries de carga das barras, fora obtido os pontos operacionais, e treinado então os nossos modelos de classificação com um total de 4500 dados, os quais ao serem submetidos ao grupo de teste (500 dados) obtiveram os resultados presentes na tabela 1.

Tabela 1 – Resultados dos modelos de classificação

Modelo de Classificação	Média do Percentual de Acerto (%)
Naive Bayes	74.74 ± 1.66
J48	62.3 ± 1.8
K-ésimo vizinho mais próximos	74.74 ± 1.66

Fonte: Autoria própria (2020).

A partir dos resultados presentes na tabela 1, observa-se claramente com o percentual de acerto que os melhores modelos de classificação para o nosso problema fora o modelo de Naive Bayes e o modelo K-ésimo vizinho mais próximo. No entanto, estes dois modelos tiveram resultados iguais, então, com a finalidade de verificar qual é significativo melhor, fora feito 3 testes de significância com auxílio do WEKA, e a partir deles, verificou-se que Naive Bayes e o KNN são de fato significativamente melhores que o J48, mas os dois são significativamente iguais.

## CONCLUSÃO

Com a evolução dos recursos computacionais, método iterativos, antes considerados impraticáveis, ganharam espaço no ambiente tecnológico e científico e passaram a ser amplamente utilizados para a resolução de problemas complexos, e sem solução convencional. Esta transformação tecnológica permitiu não só a evolução científica, mas também a evolução empresarial e comercial, com serviços cada vez mais inovadores.

No contexto do setor elétrico, observou-se neste trabalho que dois dos modelos propostos apresentaram o mesmo percentual de acerto após um treinamento com 4500 cenários do sistema de potência. No entanto para uma base de dados maior talvez os modelos de Naive Bayes e o KNN apresentem significância distintas.

Para trabalhos futuros, sugere-se o uso de métodos regressivos para o cálculo do ponto de operação do sistema.

## REFERÊNCIAS

STEVENSON JUNIOR, William D.. **Elementos de Análise de Sistemas de Potência**. 2. ed. São Paulo: McGraw-Hill, 1986.

BLUME, Steven W.. **ELECTRIC POWER SYSTEM BASICS**: for the nonelectrical professional. New Jersey: Ieee Press, 2007. 242 p. (IEEE Press Series on Power Engineering).

DAZA, Salvador Acha. **Electric Power System Fundamentals**. Norwood: Artech House, 2016.

FAN, Mingtian; ZHANG, Zuping; WANG, Chengmin. **Mathematical Models and Algorithms for Power System Optimization**: modeling technology for practical engineering problems. S. I: Academic Press, 2019. 450 p.

LI, Fangxing; QIAO, Wei; SUN, Hongbin; WAN, Hui; WANG, Jianhui; XIA, Yan; XU, Zhao; ZHANG, Pei. Smart Transmission Grid: vision and framework. **Ieee Transactions On Smart Grid**, [S.L.], v. 1, n. 2, p. 168-177, set. 2010. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tsg.2010.2053726>.

BOUCKAERT, Remco R.; FRANK, Eibe. **Evaluating the Replicability of Significance Tests for Comparing Learning Algorithms**. 2008. Disponível em: [https://www.cs.waikato.ac.nz/~eibe/pubs/bouckaert\\_and\\_frank.pdf](https://www.cs.waikato.ac.nz/~eibe/pubs/bouckaert_and_frank.pdf). Acesso em: 03 set. 2020.

DIETTERICH, Thomas G.. **Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms**. 1997. Disponível em: <https://sci2s.ugr.es/keel/pdf/algorithm/articulo/dietterich1998.pdf>. Acesso em: 03 set. 2020.

MORETTIN, Pedro A.; BUSSAB, Wilton de O.. **Estatística Básica**. 6. ed. São Paulo: Saraiva, 2010.

FERREIRA, Pedro Miguel da Silva. **Aplicação de Algoritmos de Aprendizagem Automática para a Previsão de Cancro de Mama**. 2010. 207 f. Dissertação (Mestrado) - Curso de Engenharia de Redes e Sistemas Informáticos, Ciência de Computadores, Universidade do Porto, Porto, 2010. Disponível em: <https://www.dcc.fc.up.pt/~ines/aulas/1516/DM1/TesePedroFerreira.pdf>. Acesso em: 03 set. 2020.