

SuMCET: Support Machines on Clustered Electric Transformers

Uma ferramenta para predição de falhas em transformadores elétricos clusterizados

Paulo Branco ^{1,2}  orcid.org/0000-0001-8363-1534

Victor Mendonça Azevêdo ²  orcid.org/0000-0003-2943-4622

Danilo R. B. de Araújo ^{2,3}  orcid.org/0000-0002-4822-0390

¹ Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil,

² Fundação para Inovações Tecnológicas (FITec), Recife, Brasil,

³ Departamento de Computação, Universidade Federal Rural de Pernambuco, Recife, Brasil.

E-mail do autor principal: Paulo Branco prbl@poli.br

Resumo

Com os avanços tecnológicos, a energia elétrica se tornou responsável pelo funcionamento de diversas atividades modernas, entre elas as financeiras, hospitalares e relativas à segurança. Os transformadores, componentes do processo de distribuição elétrica são peças fundamentais para que todas essas atividades permaneçam em pleno funcionamento. O presente trabalho propõe uma abordagem de predição de falhas em transformadores agrupados por causa de falha, utilizando *Support Vector Machines (SVM)*. Com uma acurácia média acima de 70% nas predições, a abordagem proposta desempenhou um papel satisfatório elencando os transformadores que possuem as maiores probabilidades de falha. Por fim, foi proposta uma ferramenta gráfica que implementa o preditor desenvolvido com intuito de facilitar as atividades de manutenção das redes elétricas, a *SuMCET*.

Palavras-Chave: Predição de Falhas; Aprendizagem de máquina; Transformadores; Clusterização.

Abstract

With technological advances, electric power became responsible for the operation of several modern activities, including financial, hospital and safety related. Transformers, components of the electrical distribution process, are fundamental parts for all these activities to remain fully operational. The present work proposes a failure prediction approach in transformers grouped by failure cause using Support Vector Machines. With an average accuracy above 70% in predictions, the proposed approach played a satisfactory role in listing the transformers that have the highest failure probability. Finally, the SuMCET, a graphical tool that implements the developed predictor is also being proposed in order to facilitate the maintenance activities of the electric networks.

Key-words: Failure prediction; Machine learning; Transformers; Clusterization.

1 INTRODUÇÃO

As falhas em máquinas causam grandes transtornos num sistema de operações e podem ser definidas como qualquer alteração de forma, tamanho ou propriedade de materiais de uma estrutura, máquina ou parte da máquina que interfira na capacidade de desempenhar de maneira satisfatória seus objetivos [1].

No contexto da contenção desses transtornos, a manutenção dos equipamentos pode acontecer em dois momentos: pré ou pós a ocorrência de falhas. A primeira é concebida como corretiva, uma vez que tenta reparar determinada anomalia causadora dos problemas já observados. Por outro lado, a segunda tem como principal objetivo antecipar possíveis avarias. A manutenção pré falha ainda pode se subdividir em preventiva, quando estabelece intervalos regulares de revisões, como no caso da quilometragem de veículos, ou preditiva, quando tenta prover, a partir do monitoramento das condições mecânicas, eficiência operacional e outros indicadores de desempenho, informações que, aliadas à modelos probabilísticos, sejam capazes de indicar estratégias mais eficiente de manutenção [2].

Os transformadores, componentes fundamentais das redes de distribuição elétrica (Figura 1), têm como finalidade a conversão de diversos tipos de tensão, permitindo a transmissão de energia em altas tensões desde a estação geradora até às linhas de distribuição. Com isso, reduzem as chances de perda por aquecimento dos fios, e possibilitam um distanciamento seguro entre as usinas e as unidades consumidoras [3].



Figura 1: Representação esquemática da rede de distribuição elétrica. Da esquerda para a direita: estação geradora, transformador que aumenta tensão para transmissão, linhas de transmissão, transformador que reduz a tensão para distribuição, linhas de distribuição e unidade consumidora.

Dada sua importância, a indisponibilidade de equipamentos suplentes considerando o custo elevado de aquisição, e os prazos de ordem mensal em reparos, fabricação e transporte, a ocorrência de falhas nos transformadores acarreta diversos

transtornos tanto para as companhias elétricas como para os consumidores.

Assim, um mecanismo de predição de falhas aplicado às redes de distribuição elétrica, em específico aos transformadores, se faz necessário para otimizar o funcionamento dos mesmos e reduzir os impactos causados por suas falhas.

Este trabalho propõe uma nova implementação desses mecanismos de predição solicitada, inicialmente, por uma companhia elétrica real que enxergou a necessidade de tornar inteligente o motor de gerenciamento de manutenção das falhas em seus transformadores. Por motivos de confidencialidade, tanto o nome da empresa, como os dados que pudessem infringir esse acordo foram substituídos por valores fictícios para a publicação deste artigo.

Seguindo a linha de raciocínio da importância desses preditores, Gross *et al* [4] desenvolveram em seu trabalho uma abordagem que utiliza inteligência artificial, *boosting*, nos cabos alimentadores de distribuição de energia da cidade de Nova York, analisando a suscetibilidade de falhas desses equipamentos. Para transformadores, especificamente, Liu e Wang [5] e Lin *et al* [6] também aplicaram técnicas de *machine learning* (*Support Vector Machines* e *Long Short-Term Memory Deep Belief Network*, respectivamente) na predição de falhas. Para realização das predições, ambas as abordagens focam exclusivamente na quantidade de gás dissolvido dos transformadores como atributo de entrada dos modelos.

A implementação do preditor proposto, assim como Liu e Wang, utiliza a lógica das *Support Vector Machines* (SVM's). Entretanto, as abordagens diferem quando o presente trabalho utiliza uma assinatura de atributos engenheirados apenas do registro de frequência de falhas de transformadores (FIC) observadas durante o período de três anos (2012-2014) para agrupar as causas de falha, e então, aplicar um modelo de aprendizado supervisionado *online* específico por grupo. O principal objetivo da abordagem é a redução dos gastos operacionais e financeiros do sistema como um todo, reportando um prognóstico de possíveis avarias e evidenciando padrões recorrentes no histórico de falhas. Além disso, busca-se um direcionamento com enfoques específicos das equipes de manutenção, uma vez que as causas de falha estarão agrupadas e reveladas. Considerando a base de dados disponibilizada, e o conjunto limitado de atributos presente nos registros,

foram obtidos resultados satisfatórios com 100% de acurácia para as predições, nos melhores casos.

Ainda, o presente trabalho propõe uma ferramenta gráfica que aplica a implementação do modelo pensado para a predição das falhas nos transformadores. Intitulada *SuMCET* (*Support Machines on Clustered Electric Transformers*), a ferramenta tem como objetivo otimizar o planejamento de manutenção das redes de distribuição elétrica.

O restante do trabalho está organizado da seguinte forma. A Seção 2 apresenta o embasamento teórico das técnicas de aprendizagem de máquina. A Seção 3 apresenta a metodologia do trabalho, explicando as etapas realizadas até a obtenção dos resultados. A Seção 4 aponta os resultados alcançados trazendo em paralelo as discussões decorrentes desses resultados. Por fim, a Seção 5 apresenta as conclusões.

2 REFERENCIAL TEÓRICO

A inteligência artificial (IA) progrediu vertiginosamente nas duas últimas décadas alcançando patamares que vão além dos laboratórios acadêmicos, e culminam em aplicações práticas de uso comercial. Seja em visão computacional, reconhecimento de fala, processamento de linguagem natural ou controle de robôs, além de outras aplicações, a IA vem ganhando força e desponta como uma área bastante promissora [7].

Buscando a construção de sistemas que, ao longo do tempo, melhoram seu desempenho através de experiências, a IA pode ser resumida em três grandes tarefas: classificação, regressão e clusterização. A seguir, baseado nas técnicas pensadas para a realização deste trabalho, as tarefas de classificação e de clusterização serão explanadas de forma breve. Para mais detalhes, consulte as referências [8, 9, 10, 11].

2.1 Clusterização

Clusterização é, em sua essência, uma tarefa de IA não supervisionada. Essa categoria de tarefas se baseia na ideia do cérebro aprender mesmo sem uma recompensa ou penalidade associada ao ato. Ou seja, para a clusterização não há um rótulo que define se o

aprendizado está, de fato, indo bem ou mal, porém, ainda assim consegue-se extrair conhecimento [8].

Dessa forma, a clusterização visa agrupar automaticamente os dados segundo algum critério de semelhança previamente estabelecido. Ela segue o padrão de comportamento primitivo humano de entender características do singular a partir de características comuns ao todo [9].

No presente trabalho, a clusterização foi utilizada com o intuito de criar grandes grupos de causas de falha que estivessem correlacionados entre si e, a partir daí, obter predições mais precisas.

2.2 Classificação

A classificação, ao contrário da clusterização, compõe a categoria de tarefas supervisionadas da IA, onde, cada instância está associada a um rótulo previamente conhecido que se configura como alvo da tarefa [10].

Dentre as abordagens de classificação, a Support Vector Machine é um algoritmo que busca definir um ou vários hiperplanos que separem as classes relativas ao problema de forma a maximizar as margens, regiões de fronteira desses hiperplanos [11].

Para o presente trabalho a técnica de SVM foi utilizada sobre o resultado da clusterização, definindo fronteiras entre os grupos de causas de falha.

3 METODOLOGIA

Uma visão geral da metodologia aplicada na predição das falhas está representada na Figura 2. A estratégia se divide em três grandes etapas: 1) Clusterização das causas de falha; 2) Processamento pré-aprendizado dos dados agrupados na etapa anterior e; 3) Aplicação do modelo de aprendizagem, obtendo como resultado um ranking de transformadores que possuem as maiores probabilidades de falha.

Após a execução das três etapas, a definição dos melhores parâmetros e a realização dos devidos testes, a metodologia do trabalho seguiu com a implementação da ferramenta gráfica *SuMCET*.

O banco de dados disponibilizado para realização do trabalho contém 35.141 registros de interrupções

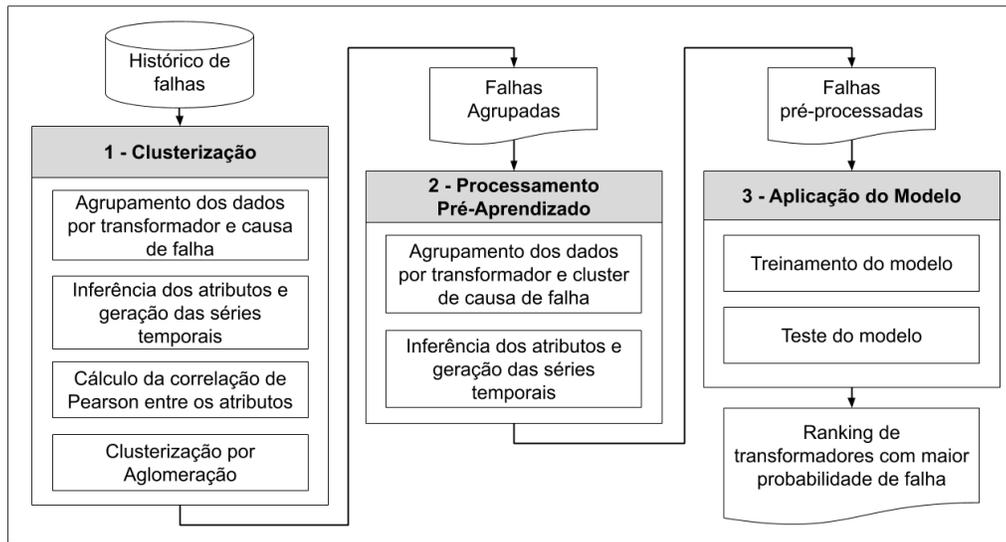


Figura 2. Representação esquemática da metodologia aplicada.

de funcionamento de transformadores elétricos observados numa janela de tempo que vai de janeiro de 2012 até dezembro de 2014. As interrupções podem se referir a falhas ou paradas programadas. O banco ainda apresenta os seguintes números: 1.830 transformadores, 7 subestações e 119 causas de interrupções agrupadas em 18 grandes classes. A Tabela 1 exemplifica a disposição dos dados em dois registros presentes no banco.

Baseado no panorama apresentado pelos atributos dispostos na Tabela 1, cada coluna segue descrita a seguir da esquerda para a direita: 1) Ano da ocorrência da falha; 2) Mês da ocorrência da falha; 3) Subestação; 4) Alimentador; 5) Bloco do alimentador; 6) Identificador do transformador; 7) Potência; 8) Grupo da causa do evento de falha; 9) Causa do evento de falha; 10) Duração de interrupção individual por unidade consumidora (DIC); 11) Frequência de interrupção individual por unidade consumidora (FIC).

Tabela 1. Fragmento do histórico de falhas dos transformadores.

1	2	3	4	5	6	7	8	9	10	11
2012	7	X	A1	B1	4	75	DEFEITO EM ISOL	PINO DANIF.	2,8	1,0
2014	2	Y	A2	B5	7	75	FALHA E EQUIP.	DEF. N CHAVE	8,1	39,0

O método descrito nesta seção foi concebido com o intuito de identificar grupos de causas de falhas que possuem padrões similares de correlação entre as características extraídas do banco e o alvo definido da

predição. A emersão desses clusters, em tese, aumentaria a acurácia de previsão de modelos específicos, possibilitando a extração de informações mais relevantes para um modelo de previsão.

Além do método, uma ferramenta baseada em ambiente web também foi proposta com o intuito de tornar o processo de previsão mais intuitivo. Intitulada *SuMCET (Support Machines on Clustered Electric Transformers)*, a ferramenta se utiliza dos benefícios gráficos para criar um ambiente atrativo para o usuário que utilizá-la.

Todo o desenvolvimento, tanto método, como aplicação, foi realizado utilizando a linguagem de programação *Python* versão 3.7 com o suporte das bibliotecas: *scikit-learn* (v. 0.21.3), *pandas* (v. 0.25.1), *matplotlib* (3.1.1) e do *framework django* (2.2.6).

3.1 Etapa 1: Clusterização

A etapa inicial se baseou na engenharia dos atributos disponíveis no banco, partindo do pressuposto que os transformadores permaneceram ativos nos meses em que não foram registradas interrupções de funcionamento. Assim, uma série temporal com o atributo FIC (Frequência de Interrupção Individual por Unidade Consumidora) foi construída para cada transformador e cada causa de falha (Figura 3-cima). A partir da série criada, novos atributos foram inferidos por mês, são eles: o total de falhas nos três últimos meses (3MF), quantidade de

meses desde a última falha (UF), total de falhas registradas desde o início das observações (TF) e a média de meses em que o transformador permanece ativo (MA). Como alvo da previsão, outra série temporal, agora binária, foi criada para cada transformador e para cada causa de falha. Essa série armazena a ocorrência de falha (um) ou ausência de falha (zero) para os três meses que sucedem o mês corrente. A Figura 3-baixo apresenta, para o mesmo transformador e causa de falha da Figura 3-cima, a série alvo calculada.

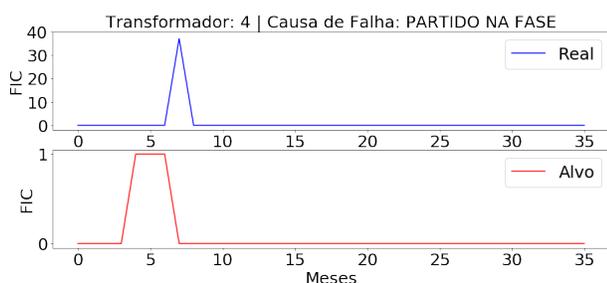


Figura 3. (cima) Série temporal das ocorrências de falha do transformador 4, para a causa "Partido na fase". O eixo X representa a frequência de falhas (FIC) e o eixo Y os meses contabilizados continuamente, onde o mês 0 representa o janeiro de 2012 e o mês 35, dezembro de 2014. (baixo) Série alvo binária do transformador 4 para a causa "Partido na fase", que corresponde à previsão de ocorrências de falha em até 3 meses futuros.

Além dos atributos inferidos, o identificador do transformador, a potência e a subestação, atributos presentes na Tabela 1, foram adicionados numa nova tabela (Tabela 2). Os dois primeiros meses (janeiro e fevereiro de 2012) e os três últimos (outubro, novembro e dezembro de 2014) do intervalo total de tempo de observações foram removidos da nova tabela pela inexistência de dados para o cálculo dos atributos e da série alvo, respectivamente. A fim de facilitar o processamento, as colunas de causa de falha e subestação foram mapeadas em valores numéricos inteiros.

Tabela 2. Fragmento da tabela gerada a partir dos atributos inferidos para a causa de falha "PARTIDO NA FASE". Ainda, três atributos presentes na Tabela 1 (o identificador do transformador, a subestação e a potência) foram adicionados.

Transf.	Sub.	Pot.	Mês	3MF	UF	TF	MA	Alvo
4	6	75,00	3	0	2	0	3	0
4	6	75,00	5	0	4	0	5	1

O coeficiente de correlação de Pearson foi calculado entre cada um dos atributos normalizados e a série 31

alvo, separados por causa de falha. Apenas o identificador do transformador foi removido desse processo. Por fim, mais uma tabela foi gerada (Tabela 3), onde, cada linha representa uma causa de falha e cada coluna representa a correlação estabelecida entre o atributo e a série alvo.

Tabela 3. Fragmento da tabela de correlações entre os atributos e a série alvo.

	Sub.	Pot.	Mês	3MF	UF	TF	MA
33	4,18 E-02	1,12 E-02	-0,08	0,026	-0,115	-0,48	-0,001
22	-8,733 E-03	-9,055 E-04	0,030	-0,018	0,142	-0,063	0,186

A Tabela 3 representa um espaço amostral com 7 dimensões, cada uma representada por um atributo. Buscando sintetizar os dados e facilitar a visualização e compreensão, foi aplicada uma técnica de redução de dimensionalidade que tenta manter o máximo de variância dos atributos presentes no espaço inicial, a *Principal Component Analysis (PCA)*. Assim, foram executados experimentos com novos espaços amostrais de duas e três dimensões.

Finalizando a etapa 1, foram realizados testes de desempenho com alguns dos principais algoritmos de clusterização presentes na biblioteca *scikit-learn*, dentre eles: *DBSCAN*, *OPTICS*, *Spectral Clustering*, *MiniBatch K-Means*, *Agglomerative Clustering* e *KNN*. Para avaliação dos algoritmos, todo o processo de predição foi realizado. O algoritmo de clusterização por aglomeração (*Agglomerative Clustering*) obteve o melhor desempenho, medido pela acurácia final das predições (descrito na etapa 3), e foi aplicado sobre o resultado da *PCA*. Esse algoritmo realiza sucessivas mesclagens dos dados em grupos, até que um número definido de agrupamentos seja atingido. E o que caracteriza o agrupamento de uma amostra é a distância, aqui definida como a mínima variância entre ela e os grupos ou o restante das amostras (*ward*). Foram realizados testes com dois até seis grupos de causas de falha.

3.2 Etapa 2: Processamento Pré-Aprendizado

A etapa 2 é uma fase de preparação dos dados para aplicação do modelo de aprendizagem baseada na clusterização realizada na etapa anterior.

Separados em cluster por causa de falha, novas séries com frequência de falhas e alvos e atributos inferidos foram calculados seguindo os moldes da Figura 3. Para esses cálculos, as causas de falha agrupadas no mesmo cluster foram contabilizadas de forma única na série de ocorrências como grandes grupos de falhas.

3.3 Etapa 3: Aplicação do Modelo

A criação do modelo de aprendizado foi delimitada inicialmente por testes com quatro classificadores diferentes: *Random Forest*, *AdaBoost*, *Multilayer Perceptron* e *Support Vector Machine*. Assim como os algoritmos de clusterização, todo o processo de predição foi realizado para avaliação da performance dos classificadores. Em ambos os testes, os resultados foram suprimidos a fim de focar nos algoritmos que, de fato, obtiveram as melhores predições.

O SVM foi escolhido como classificador, pois, além de desempenhar os melhores resultados nos testes, se concentra na definição de uma fronteira de decisão entre as classes que estão sendo colocadas no problema. Assim, para o caso dos transformadores, a saída do classificador implementado foi pensada como um modelo probabilístico, onde o resultado final apresenta duas porcentagens de probabilidade, uma de falha (classe 1) e outra de ausência de falha (classe 2). A construção desse modelo probabilístico utiliza a calibragem de Platt que transforma a saída do modelo de classificação numa distribuição de probabilidade sobre as classes.

Um modelo *online* de SVM foi treinado para cada grupo de causa de falhas resultante da etapa de clusterização. Inicialmente, os classificadores foram treinados com falhas referentes aos anos de 2012 e 2013, assim, configurando como alvo da predição os meses de Janeiro a Março de 2014. Em seguida, o mês de Janeiro de 2014 é adicionado ao conjunto dos dados de treinamento e é feita uma nova rodada de previsões para os meses de Fevereiro a Abril de 2014, e assim por diante até o fim do ano de 2014 (Figura 4). Os *kernels* utilizados nos modelos foram os de base radial, considerando a possível não-linearidade do problema.



Figura 4. Esquema do funcionamento da divisão de treinamento e teste da base. O classificador é treinado para prever os meses em laranja com base nos meses em azul.

Após o final do processamento, a abordagem de aprendizado gerou como saída - para cada mês do ano de testes - uma probabilidade de falha para cada transformador. Para a avaliação do desempenho, foram excluídas as probabilidades dos transformadores com valores menores que 60% e, em seguida, listadas em ordem decrescente. E para eles foram verificadas na série alvo correspondente, se de fato houve algum tipo de falha registrada para o mês em questão.

3.4 Desenvolvimento da Aplicação

O desenvolvimento da ferramenta gráfica aconteceu subdividido em módulos que, na interface, representam opções que usuário poderá selecionar, conforme apresentado no esquema da Figura 5.

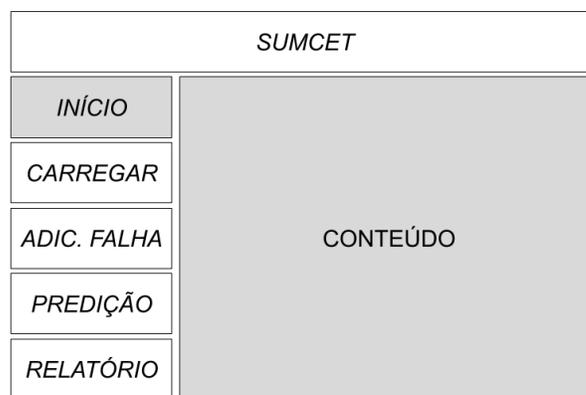


Figura 5. Esquema de módulos e telas da ferramenta de predição desenvolvida.

O módulo Início (*home*) apresenta uma visão geral da aplicação, as funcionalidades e dispõe de um tutorial de uso. No módulo Carregar (*load*), o usuário poderá carregar o histórico de falhas de transformadores, optar pela validação e pela clusterização. O Adicionar Falha (*add*), permitirá ao usuário adicionar novos registros de falha de transformadores. No módulo de Predição (*prediction*),

o usuário realizará as predições de falhas. Por fim, o módulo Relatório (*report*) apresentará ao usuário um relatório estruturado e interativo sobre as previsões e sobre o histórico de falhas selecionado.

4 RESULTADOS E DISCUSSÕES

Conforme detalhado na metodologia, os resultados apresentados a seguir se restringem à avaliação dos transformadores com maiores probabilidades de falha. Dessa forma, a Figura 6 exibe as porcentagens de acurácia média para todas as combinações de parâmetros entre o número de componentes *PCA* e o número de clusters, com variados tamanhos de *ranking* de probabilidade de transformadores.

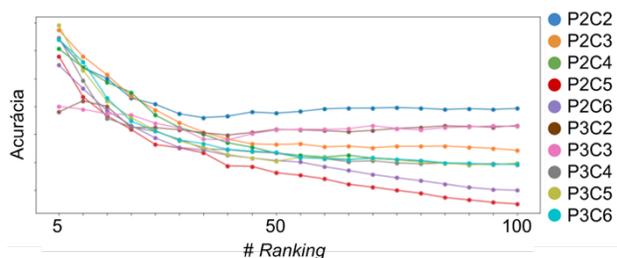


Figura 6. Acurácia média dos testes realizados com as combinações de parâmetros entre o número de componentes *PCA* e o número de clusters. O eixo X representa o tamanho do ranking observado para medição da acurácia. O eixo Y representa o valor de acurácia obtida para cada tamanho de ranking. Cada cor de linha representa uma combinação de parâmetros utilizada.

A média apresentada na Figura 6 foi calculada, inicialmente, por alvo de predição e por cluster, e

depois uma nova média foi calculada, obtendo assim o valor único presente na figura referenciada. Dessa forma, observa-se que a combinação de parâmetros *PCA* = 2 e *cluster* = 2 (P2C2) ao longo das variações de tamanho de ranking, obteve o melhor desempenho, mantendo uma taxa de acurácia acima de 65%. Entretanto, utilizando o requisito estipulado pela empresa que evidenciou o problema, tamanho 15 de *ranking*, a combinação de parâmetros *PCA* = 2 e *cluster* = 3 (P2C3) está 0,66% a frente da segunda colocada. Logo, desse ponto em diante do trabalho, o foco dos resultados e discussões será a combinação de parâmetros P2C3.

A Figura 7 apresenta o resultado da clusterização descrito pela etapa 1 da metodologia aplicado sobre o conjunto de treinamento.

Um grande grupo de causas de falha (azul) emergiu da clusterização realizada, conforme apontado na Figura 7, representando aproximadamente 61% de todas as causas presentes no histórico de falhas.

Já na etapa de predição, a Figura 8 expande a média apresentada na Figura 6 exibindo o desempenho das predições de P2C3 ao longo do ano de 2014.

A Figura 8 revela que o cluster 3, em média, obteve melhor desempenho nas predições, superando a acurácia dos outros dois clusters em todos os trimestres alvo, exceto os que vão de Março à Maio, de Maio à Junho e de Julho à Agosto, meses em que, geralmente, se concentra a maior quantidade de chuvas. Atributos relacionados ao tempo, como

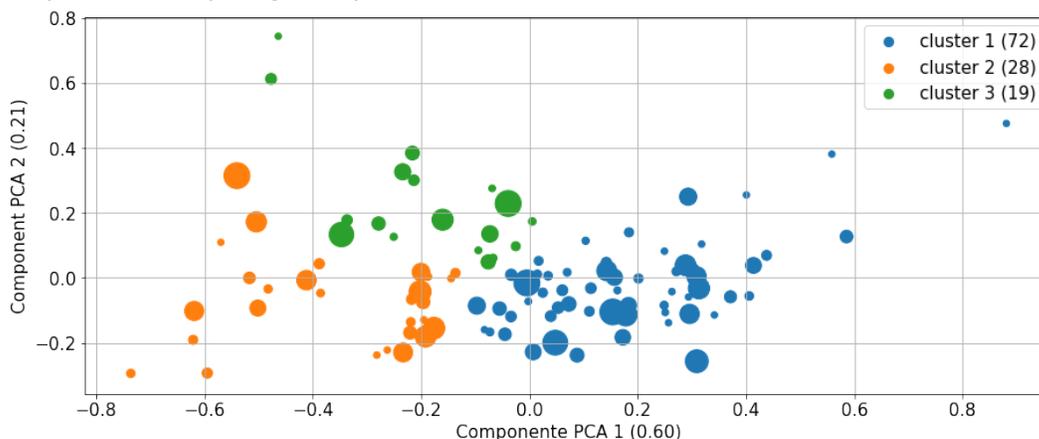


Figura 7. Resultado da clusterização das causas de falha para P2C3. O eixo X e o eixo Y representam as componentes 1 (correspondente a 60% de variância) e 2 (correspondente a 21% de variância) do *PCA*, respectivamente. O grupo representado pela cor azul possui 72 causas de falhas, o laranja possui 28 e o verde, 19. O tamanho dos pontos é proporcional à quantidade de transformadores que falharam pela respectiva causa.

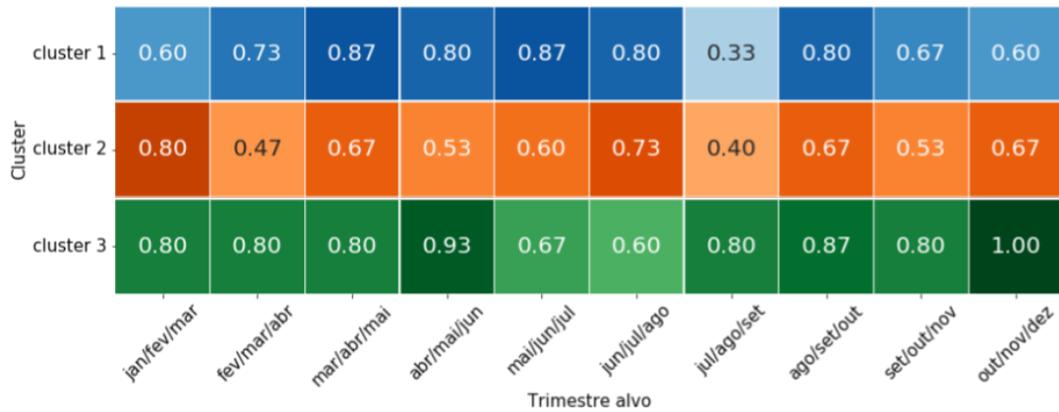


Figura 8. Acurácia detalhada das predições de falha referente à combinação de parâmetros P2C3. O eixo X representa o trimestre alvo da predição para o ano de 2014. O eixo Y representa os clusters.



Figura 9. Tela inicial da aplicação SuMCET.

variação de temperatura e umidade, não foram levados em consideração nesta análise, apesar de, possivelmente, influenciarem no funcionamento dos transformadores. Outro ponto que merece atenção é o fato de que, para os 3 clusters, existem causas de falha relacionadas à fatores externos à rede elétrica, tornando a tarefa de predição ainda mais complexa. Casos como 'QUEIMADO POR PÁSSARO', 'PODA DE ÁRVORES' e 'VANDALISMO' para os clusters 1, 2 e 3, respectivamente, são alguns exemplos que podem representar ruído na predição final do modelo.

Para a interface gráfica, a fim de exemplificar o resultado final do desenvolvimento, a Figura 9 apresenta sua tela inicial.

5 CONCLUSÕES

O presente trabalho propõe uma nova abordagem de predição de falhas em transformadores de rede elétrica que utiliza a frequência das mesmas para clusterizar suas causas. Em seguida, a abordagem aplica um modelo SVM específico para cada grupo gerado, resultando assim um ranking de probabilidades de falha para os transformadores. Foram obtidos resultados satisfatórios com uma média de 70,66% de acurácia para as predições com a melhor combinação de parâmetros, dentro do

escopo de especificações da empresa que requisitou a solução. Além disso, uma ferramenta gráfica também foi proposta com intuito de tornar mais ágil o planejamento de manutenção da rede elétrica da empresa, minimizando os custos e maximizando o tempo de funcionamento dos transformadores.

Trabalhos futuros buscarão incluir predições com atributos relacionados ao clima e uma filtragem criteriosa das causas de falha.

Agradecimentos

Este trabalho não seria possível sem o apoio financeiro e intelectual proveniente do Acordo de Cooperação Técnica nº 001/2018 entre FACEPE, SECTI, POLI-UPE e FITec.

Referências

- [1] COLLINS, J. A. Failure of materials in mechanical design: analysis, prediction, prevention. New York: Wiley, 1993.
- [2] MOBLEY, R. K. A Introduction to Predictive Maintenance. Massachusetts: Butterworth Heinemann, 2002.
- [3] JORDÃO, R. G. Transformadores. São Paulo: Blucher, 2002
- [4] GROSS, P; BOULANGER, A; ARIAS, M; WALTZ, D. L; LONG, P. M; LAWSON, C; ANDERSON, R; KOENIG, M; MASTROCINQUE, M; FAIRECHIO, W; JOHNSON, J. A; LEE, S; DOHERTY, F; KRESSNER, A. Predicting electricity distribution feeder failures using machine learning susceptibility analysis. Em: The 18th Conference on Innovative Applications of Artificial Intelligence IAAI 2006. Massachusetts, 2006.
- [5] LIU, T; WANG, Z. Design of Power Transformer Fault Diagnosis Model Based on Support Vector Machine. Em: 2009 International Symposium on Intelligent Ubiquitous Computing and Education. IEEE, 2009.
- [6] LIN, J; SU, L; YAN, Y; SHENG, G; XIE, D; JIANG, X. Prediction Method for Power Transformer Running State Based. Em: LSTM_DBN Network. Energies, vol. 11, n. 7, p. 1880, 2018.
- [7] JORDAN, M. I; MITCHELL, T. M. Machine Learning: Trends, perspectives, and prospects. Science, vol. 349, n. 6245, p. 255-260, 2015.
- [8] BARLOW, H. B. Unsupervised Learning. Em: Unsupervised Learning: Foundations of Neural Computation, The MIT Press, p. 1-17, 1999.
- [9] XU, R; WUNSCH, D. Clustering. New Jersey: IEEE Press, 2008.
- [10] KOTSIANTIS, S. B. Supervised Machine Learning: A review of Classification. Informatica. vol 31, n.3, p. 249-268, 2007.
- [11] NOBLE, W. What is a support vector machine? Em: Nature Biology, vol 24, n. 12, p. 1565-1567, 2006.