



Implementação de uma Ferramenta de Pré-análise de Interrupções com Causas Não Identificadas Utilizando Redes Neurais de Kohonen

Tema: Qualidade de Energia

Autores: Fabrício Augusto de Souza – Copel DIS, Rodger Vitoria Pereira – Copel DIS, Marcelo Favoretto Castoldi – UTFPR-CP, Alessandro Goedel – UTFPR-CP, Wesley Angelino de Souza – UTFPR-CP

Co-Autores: -

Empresa: Copel Distribuição S.A.

Resumo

A crescente demanda por qualidade de energia no setor elétrico tem desafiado as concessionárias a melhorar o desempenho de seus sistemas e buscar alternativas de atender seus clientes de forma satisfatória. Neste contexto, o objetivo deste trabalho é apresentar um método capaz de classificar interrupções sem causas identificadas em equipamentos no sistema elétrico, considerando múltiplas classes que incluem aspectos de qualidade do fornecimento (como os indicadores DEC e FEC) e satisfação dos clientes, proporcionando às concessionárias de distribuição de energia subsídios para a priorização dos casos mais relevantes. A metodologia tem como base as redes neurais artificiais de Kohonen e, para identificação das classes, utiliza técnicas de visualização dos mapas auto-organizáveis, como Plano de Componentes, Mapa de *Ulltsch* (matriz-U), Mapa *Hits* e Mapa de Atributos. Os resultados obtidos na validação da proposta são baseados em dados reais e demonstram um elevado nível de acuracidade, alcançando valores próximos de 97%, além de ganhos na ordem de 86% na redução do tempo das análises, ora realizadas manualmente. Desta forma, a utilização de técnicas de inteligência artificial no tratamento de interrupções do sistema elétrico demonstra ser uma grande aliada na melhoria do desempenho e na satisfação dos consumidores.

1. Introdução

No contexto da qualidade do fornecimento de energia, é interessante destacar que, atualmente na maioria das concessionárias do setor elétrico brasileiro, a alocação dos recursos operacionais e de manutenção é orientada pelos indicadores de qualidade estabelecidos pela autoridade reguladora, geralmente definidos como índices médios por unidade consumidora. Assim, interrupções significativas no sistema elétrico frequentemente são analisadas e tratadas após sua ocorrência, possibilitando encontrar oportunidades de melhoria para que situações inicialmente não identificadas e com grande impacto nos indicadores de qualidade de energia não se repitam por situações iguais ou similares (MOLOI, ABE, NNACHI & JORDAAN, 2019, p. 1-5).

No entanto, a atuação das concessionárias considerando somente a perspectiva dos indicadores de qualidade é limitada, fornecendo apenas uma dimensão da experiência do cliente (TRAGOONTHAI & CHAITUSANEY, 2017, p. 600-603), (POPOVIC, KNEZEVIC & POPOVI, 2019, p. 171-181) e (MOHAMMADI, MASHHADI & SHAHIDEHPUR, 2019, p. 3840-3848). É comum existir interrupções no sistema que não

impactam significativamente os indicadores, uma vez que atingem apenas uma pequena parcela de consumidores. Ainda assim, estas interrupções podem causar grandes transtornos àqueles que a sofrem, tais como desligamentos de duração ou de frequências elevadas em pequenos grupos de clientes rurais.

Para as concessionárias o processo de investigação das interrupções menos significativas é um desafio, pois nem sempre é possível analisá-las ou tratá-las posteriormente, mesmo aquelas sem causas identificadas, devido a dinâmica com que ocorrem por toda extensão do sistema. Contudo, quando acontecem com frequência ou são muito duradoras, podem ter um impacto significativo na percepção dos clientes sobre a qualidade dos serviços prestados. Além disso, estudos indicam que, a medida que a duração das interrupções aumenta, os custos associados a ela aumentam quase que exponencialmente (HOSSEINI, MAHOOR & KHODAEI, 2018, p. 5470-5472).

Um processo que auxilia no tratamento de grandes volumes de interrupções no sistema elétrico é a classificação delas, este assunto tem sido abordado na literatura recente. Os autores em (MOHAMMADIAN, AMINIFAR, AMJADY & SHAHIDEHPOUR, 2021, p. 4906-4914) apresentam um classificador baseado na teoria de decisão de Bayes para a previsão de interrupções em componentes da rede elétrica. O classificador proposto é comparado com outras técnicas existentes, como *Support Vector Machine* (SVM) e técnicas de redes neurais artificiais (RNAs), sendo avaliadas pela métrica *F2-Score*, onde a metodologia proposta obteve a melhor pontuação 96.66. Contudo, estes estudos se concentram no conceito de resiliência do sistema elétrico apenas em eventos severos.

Neste contexto, a classificação de falhas é um processo muito importante para a análise da causa das interrupções para posterior restauração e/ou regularização do sistema (GUO, YANG & CHEN, 2019, p. 6905-6913). Desta forma, é interessante ressaltar que os mapas auto-organizáveis de Kohonen (*Self Organizing Map* - SOM) vêm sendo aplicados com êxito em várias áreas da ciência, como destacam os autores em (YAN, LI & LIU, 2020, p. 106259) e (ABIODUN, ALAYANDE, FASHAWE, et al., 2019, p. 158820-158846). Inclusive, devido a sua notável característica de classificação, os mapas auto-organizáveis de Kohonen já foram utilizados em técnicas híbridas de classificação e localização de faltas em sistemas de distribuição de energia elétrica (SOUZA, CASTOLDI, GOEDTEL & SILVA, 2020, p. 106627).

Logo, este trabalho propõe uma metodologia baseada em RNAs para identificar e classificar equipamentos de proteção responsáveis por interrupções no fornecimento de energia com causas não identificadas, que provocam grande impacto nos indicadores DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e FEC (Frequência Equivalente de Interrupção por Unidade Consumidora), e que apresentam grande potencial de gerar insatisfação aos clientes da concessionária, devido a sua elevada duração e/ou frequência. A metodologia proposta é um ponto que contribui para o processo investigativo das causas das interrupções, permitindo o tratamento adequado dos problemas que elas geram no sistema elétrico (DOOSTAN & CHOWDHURY, 2017, p. 1-5).

Além disso, o método integra duas temáticas nem sempre correlacionadas: a contribuição das interrupções nos índices de qualidade e seu impacto na satisfação dos clientes. Isso fornece às concessionárias subsídios para priorizar os casos mais relevantes de acordo com a estratégia adotada pela empresa. Assim, as contribuições deste trabalho consistem em: i) um método simples, porém eficiente, baseado em mapas auto-organizáveis de Kohonen (SOM), para a classificação de equipamentos de proteção que sofreram falhas no sistema elétrico de distribuição; ii) uma metodologia que dispensa a definição de saídas desejadas no processo de classificação dos equipamentos, uma vez que o algoritmo se auto-organiza a partir dos dados de entrada, o que proporciona uma melhor versatilidade e adaptabilidade na aplicação da técnica; iii) ainda, a técnica foi testada e validada com dados de um sistema de distribuição real, demonstrando eficácia em aplicações práticas no cotidiano de concessionárias de energia elétrica.

Este artigo está dividido em seis seções: a primeira refere-se a introdução; a segunda apresenta um contexto sobre os indicadores de continuidade do fornecimento de energia; a terceira explora sobre as RNAs com

ênfase nas redes de Kohonen; a quarta descreve a metodologia desenvolvida; a quinta detalha os resultados obtidos; e a sexta expõe as conclusões deste trabalho.

2. Desenvolvimento

2.1. Indicadores de Continuidade do Fornecimento de Energia

A continuidade do fornecimento de energia elétrica é um dos itens que abrangem o conceito de confiabilidade do sistema de distribuição e está diretamente ligado a qualidade do fornecimento. Esta é medida por meio do número e da duração das interrupções do fornecimento de energia no sistema (MUROS, SARA-CHO & MAESTRE, 2022, p. 108666).

No Brasil, os índices de continuidade são divididos em dois grupos: i) os indicadores individuais e, ii) os indicadores de conjunto (coletivos). Estes, são calculados para períodos de apuração mensais, trimestrais e/ou anuais. Os índices coletivos são definidos e calculados da seguinte forma: o DEC refere-se a duração equivalente de interrupção por unidade consumidora, expressa em horas e centésimos de hora. Já o FEC é a frequência equivalente de interrupção por unidade consumidora, expressa em número de interrupções e centésimos do número de interrupções. As equações equivalentes à apuração mensal são expressas em (1) e (2) (MOHAMMADI, MASHHADI & SHAHIDEHPOUR, 2019, p. 3840-3848):

$$DEC = \frac{\sum_{i=1}^{NUC} DIC(i)}{NUC} \quad (1) \quad FEC = \frac{\sum_{i=1}^{NUC} FIC(i)}{NUC} \quad (2)$$

onde: i é o índice de unidades consumidoras atendidas em baixa tensão (BT) ou média tensão (MT) faturadas do conjunto de consumidores; NUC é o número total de unidades consumidoras faturadas do conjunto no período de estudo, atendidas em BT ou MT; $DIC(i)$ é a duração de interrupção individual por unidade consumidora, expressa em horas e centésimos de hora; e $FIC(i)$ é a frequência de interrupção individual por unidade consumidora, expressa em interrupções e centésimos de interrupções.

Entretanto, uma forma simples de mensurar o impacto das interrupções nos indicadores de continuidade é calcular: i) o número de consumidores afetados multiplicado pelas horas de desligamento (consumidor x hora) e ii) o número de consumidores afetados multiplicado pela quantidade de interrupções ocorridas em um mesmo equipamento no período analisado (consumidor interrompido). Assim, valores altos de consumidor x hora e consumidor interrompido, indicam maior contribuição dos equipamentos estudados nos indicadores de DEC e FEC, respectivamente.

Nesse contexto, as interrupções no fornecimento de energia elétrica podem ser classificadas pela duração (curta duração ou duradouras) e pelo tipo (programadas ou não programadas) (HEYLEN, DECONINCK & HERTEM, 2018, p. 554-568). As interrupções não programadas são categorizadas segundo o fato gerador, sendo as causas mais comuns: árvores tocando a rede, objetos estranhos na rede, descargas atmosféricas e abaloamento de postes. Ainda, existem causas não identificadas, ou seja, situações em que a equipe responsável pela inspeção e o restabelecimento de energia não detecta, inicialmente, a origem do desligamento no sistema elétrico.

Desta forma, este trabalho propõe uma metodologia capaz de classificar interrupções de energia no sistema elétrico de distribuição, considerando sua relevância para os indicadores de qualidade abordados nesta seção, bem como aspectos que possuem forte relação com a satisfação dos clientes, como duração e frequência das interrupções. Assim, devido à não linearidade e complexidade do problema, o método

alternativo utiliza redes neurais artificiais (RNA), especificamente Redes de Kohonen, cujas características e funcionamento são detalhados na próxima seção.

2.2. Redes de Kohonen

As redes de Kohonen, desenvolvidas pelo finlandês Teuvo Kohonen entre 1982 e 1984, são inspiradas no córtex cerebral humano, sendo organizadas em duas camadas: uma de entrada e uma de saída, como ilustrado na Figura 1(a). As entradas são denotadas por x_1, x_2, \dots, x_n ; os neurônios por 1 a n_1 ; e, as saídas da rede são representadas por $y_1, y_2 \dots y_{n_1}$. Seu processo de aprendizagem é o não supervisionado e acontece de maneira competitiva (DA SILVA, SPARTI, FLAUZINO, LIBONI & ALVES, 2017) e (HUIXIAN, 2020, p. 68828-68841). Durante o aprendizado, um neurônio pode influenciar a resposta de saída de outros neurônios, representadas pelas conexões laterais na rede.

A rede é caracterizada por um arranjo topológico de neurônios que gera como saída representações unidimensionais ou bidimensionais (mapas de Kohonen) do conjunto de informações apresentadas em suas entradas, formando assim padrões ou agrupamentos de dados (*clusters*) que posteriormente são interpretadas no intuito de classificar, detectar similaridades e/ou extrair características das amostras. A Figura 1(b) apresenta a disposição do mapa de Kohonen com os neurônios de saída dispostos de maneira bidimensional, e cada vetor x_1, \dots, x_n , na camada de entrada está conectado a todos os neurônios da camada de saída por meio de vetores de pesos w_{ij} .




Figura 1: (a) Estrutura neural básica (b) Mapa de Kohonen com neurônios de saída usados de forma bidimensional

O funcionamento das redes de Kohonen se fundamenta na concorrência entre os neurônios para serem ativados, onde o objetivo dos neurônios é se sair vencedor desta competição, pois assim terá o ajuste de seus pesos sinápticos (e de seus vizinhos) proporcionais aos valores de entrada apresentados, garantindo seu aperfeiçoamento para a próxima iteração. O neurônio na camada de saída que vence essa competição é chamado de neurônio vencedor (*winner-takes-all neuron*) (ALVES & LEAL, 2021, p. 1959-1966). A regra que define qual será o neurônio vencedor é o nível de proximidade entre o vetor de pesos de cada neurônio e o vetor de entrada contendo os elementos da k -ésima amostra apresentados na entrada da rede. Esta distância é definida como a distância euclidiana destes dois parâmetros, conforme a equação (3). Já a equação (4) mostra os ajustes realizados a cada iteração.

$$c_i = \arg\min ||d(t) - w_i|| \quad (3)$$

$$w_i(t+1) = w_i(t) + \alpha(\tau)\eta_{ci}(t, \tau)(d(t) - w_i) \quad (4)$$

onde: c_i é o neurônio que possui a menor distância entre $d(t)$ dos dados de entrada (x_1, x_2, \dots, x_n), w_i do neurônio vencedor, $w_i(t)$ é o peso i na iteração t , $\alpha(\tau)$ a taxa de aprendizagem da rede e $\eta_{ci}(t, \tau)$ a atualização da vizinhança em gaussiana dependente da iteração na fase de treinamento.

Neste tipo de RNA, os ajustes dos pesos dos neurônios não ocorrem apenas nos neurônios vencedores, mas também nos neurônios vizinhos aos vencedores, conforme equação (4). Assim, a equação (5) mostra como a largura da vizinhança varia em função do tempo. Nesta, um valor de aprendizagem inicial α_{ini} possui decaimento exponencial em função da época em razão do número de épocas E .

$$\alpha(\tau) = \alpha_{ini} \exp\left(-\frac{\tau}{E}\right) \quad (5)$$

A taxa de aprendizagem do mapa varia ao longo do treinamento da rede. As equações (6) e (7) demonstram este processo, em que a atualização da vizinhança é dada por (6), e a convergência da rede é possível por meio da equação (7). Assim, o processo de aprendizado do algoritmo de treinamento é concluído quando não há mudanças significativas nos pesos com o passar das iterações expressas na equação (4).

$$\eta_{ci}(t, \tau) = \exp\left(-\frac{(P_c(t) - P_t)^2}{2\sigma^2(\tau)}\right) \quad (6) \quad \lim_{\tau \rightarrow \infty} \eta_{ci}(t, \tau) = 0 \quad (7)$$

Além disso, geralmente, na fase de treinamento dos mapas auto-organizáveis de Kohonen são realizados diversos testes com parâmetros e/ou topologias variadas para que seja feita a escolha do mapa que melhor represente o conjunto de dados a ele submetido. Portanto, faz-se necessário ferramentas que auxiliem na escolha de tais mapas. Neste contexto, as medidas mais utilizadas para verificação de sua qualidade são o Erro Médio de Quantização (*Quantization Error* - QE) e o Erro Topográfico (*Topographic Error* – TE) (SOUSA, PIRES & DEL-MORAL-HERNANDEZ, 2020, p. 349-362). O primeiro é dado pela média das distâncias entre cada vetor de entrada e o vetor de pesos do neurônio vencedor correspondente, e o segundo quantifica a capacidade do mapa em representar o conjunto de dados de entrada (DOMINIK, 2021, p. 104420). As equações (8) e (9), respectivamente, exibem como são calculadas estas medidas.

$$\epsilon_Q = \frac{1}{A} \sum ||d(t) - c_i|| \quad (8) \quad \epsilon_T = \frac{1}{A} \sum_{i=1}^A u(d(t)) \quad (9)$$

Em que A corresponde a quantidade de vetores de entrada e c_i ao vetor de pesos do neurônio *Best Matching Unit* (BMU), referente a $d(t)$ que é o vetor de entrada. Ainda, o símbolo $||.||$ representa a distância euclidiana entre os vetores citados. Em que $u(d(t))$ assume os valores de 1 se o 1º e o 2º BMUs não forem adjacentes, ou 0, se forem adjacentes.

2.3. Metodologia

Identificar e classificar os equipamentos de proteção que sofreram interrupções considerando apenas o aspecto da contribuição nos indicadores não é uma tarefa complexa. Além disso, quando se pretende aliar a esta condição conceitos que correlacionam a satisfação do cliente em relação ao fornecimento de energia elétrica, o problema começa adquirir ainda mais complexidade. Assim, este trabalho apresenta um método capaz de classificar quais equipamentos de um sistema de distribuição tiveram as interrupções de energia que impactaram nos indicadores de continuidade e/ou quais não impactaram e tiveram interrupções com elevadas frequência e duração.

O método proposto tem como base o uso de mapas auto-organizáveis de Kohonen, um tipo de RNA que apresenta bons resultados para problemas semelhantes a este (SOUZA, CASTOLDI, GOEDTEL & SILVA, 2020, p. 106627), sendo desenvolvido e dividido em 5 etapas. Na primeira etapa os dados das interrupções são obtidos por meio da exportação dos sistemas da concessionária. Eles são dados estruturados e fornecidos na extensão .csv (*Comma-separated values*), onde cada linha corresponde a uma interrupção de um equipamento do sistema. As linhas são identificadas com um número único que equivale à interrupção, além de informações como: a região que pertence, a data de início e término, a duração, o tipo da interrupção, a quantidade de consumidores e o número do equipamento afetados, ainda a causa e componente que deram origem à interrupção, entre outros dados menos relevantes.

Entretanto, após a primeira etapa faz-se necessário um pré-processamento das informações coletadas do sistema da concessionária, com o objetivo de agrupá-las e correlacioná-las por equipamento que sofreu as interrupções, para que assim sejam obtidas as variáveis de entrada das RNAs, que correspondem a terceira etapa da metodologia. Nesta última, as interrupções após serem agrupadas também possuem suas características agrupadas por equipamento. Tendo seus atributos de quantidade de interrupções, duração das interrupções, quantidade de consumidores x hora e quantidade de consumidores interrompidos, somados e apresentados por equipamento do sistema de distribuição.

Desta forma, com os dados preparados por meio das etapas anteriores, a quarta etapa é reservada para a fase de treinamento e operação das RNAs. Por fim, a última etapa consiste em apresentar os resultados da rede, ou seja, seus dados de saída para consequente interpretação de seus mapas auto-organizáveis. Logo, na terceira etapa foram definidas as 4 seguintes variáveis de entrada para as RNAs: i) a quantidade de consumidores x hora; ii) a quantidade de consumidores interrompidos; iii) a quantidade de interrupções com causa não identificada, e; iv) a soma da duração destas interrupções, sendo todas elas computadas por equipamento de proteção em um período de análise previamente selecionado. As duas primeiras referem-se à aspectos relacionados ao impacto nos indicadores de continuidade do fornecimento de energia e as duas últimas referem-se à aspectos relacionados à satisfação dos clientes.

Ainda, para facilitar a análise dos dados, foi definida mais uma variável de entrada: v) o tipo do equipamento de proteção referente aos dados das outras quatro entradas, que podem ser religadores automáticos (RAs), chaves fusíveis (CFs), chaves religadoras (CRs), entre outros. Já após o treinamento e operação da rede SOM é possível obter em sua saída, através da interpretação de seus mapas auto-organizáveis, os equipamentos que sofreram as interrupções que deverão ser analisadas e tratadas, conforme a classificação de prioridade relacionada aos aspectos previamente estabelecidos.

Além disso, foram definidos parâmetros para os mapas auto-organizáveis de Kohonen. O arranjo de vizinhança escolhido para a RNA proposta é o arranjo hexagonal, normalmente esta topologia apresenta resultados melhores em relação ao arranjo quadrado, o que pode proporcionar a formação de mapas com melhor qualidade visual dos clusters (GUALTIERI, 2017, p. 295-311).

As redes que apresentaram os melhores resultados foram aquelas com a função de vizinhança do tipo Gaussiana e os parâmetros descritos na Tabela 1, sendo que estes valores respeitam a orientação dada pelo autor (HAYKIN, 2001) para uma melhor convergência dos mapas auto-organizáveis.

Tabela 1: Parâmetros dos Mapas Auto-organizáveis de Kohonen

| Parâmetros da Rede | |
|------------------------------------|------|
| Taxa de Aprendizagem Inicial | 0.1 |
| Taxa de Aprendizagem Final | 0.01 |
| τ - <i>Constante de Tempo</i> | 1000 |
| Número de Épocas | 5000 |

A arquitetura da rede proposta é similar a apresentada na Figura 1(b), onde as entradas são o tipo do equipamento, o número de interrupções, a duração das interrupções (em horas), o número de consumidores interrompidos e o número de consumidor x hora por equipamento no período estudado, sendo representadas pelos vetores x_1 , x_2 , x_3 , x_4 e x_5 , respectivamente. Estes dados foram normalizados em um intervalo de 0 a 1, e testados em diversas topologias.

Para estudo e validação da ideia, foram extraídos do banco de dados da Companhia Paranaense de Energia (Copel Distribuição) 8.737 interrupções duradouras com causas não identificadas durante todo o ano de 2019, no sistema elétrico do estado do Paraná - Brasil da região norte da área de concessão desta empresa. Após o pré-processamento dos dados, estas interrupções foram agrupadas em 4.958 equipamentos, cada um com suas variáveis de entrada para as RNAs. Desta forma, para treinamento das RNAs foram utilizados 90% do total destas amostras, ou seja, 4.462 amostras de equipamentos com seus respectivos tipos, quantidades de interrupções, a soma de suas durações, consumidores interrompidos e consumidores x hora. Já para validação/operação foram utilizados 10% do total das amostras, ou seja, 496 amostras.

Por fim, o método de análise dos mapas contou com a utilização de técnicas como Plano de Componentes, Mapa de *Ulltsch* (matriz-U), Mapa *Hits* e Mapa de Atributos. A rede que apresentou melhores resultados em relação ao tempo de resposta e capacidade de clusterização foi a topologia de arranjo hexagonal 11x17, cujos resultados são apresentados na seção a seguir.

2.4. Resultados

Como resultado do melhor treinamento notou-se tanto a convergência como a estabilidade dos valores de pesos sinápticos obtidos pela rede, onde ao final das 5.000 épocas alcançou-se valores de Erro de Quantização (QE) e Erro de Topologia (TE) iguais a 0.017283 e 0.095158, respectivamente. Ao término do treinamento, uma das formas de análise dos mapas auto-organizáveis é verificar a disposição de cada componente do vetor de entrada em seus respectivos mapas, sendo este método chamado de Planos de Componentes (FERLES, PAPANIKOLAOU & NAIDOO, 2018, p. 112-131). A Figura 2 apresenta o resultado dos Planos de Componentes após o treinamento da RNA proposta.

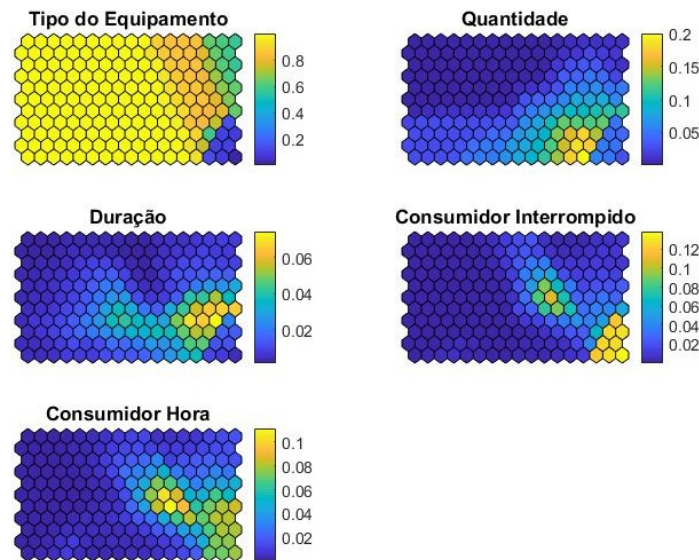


Figura 2: Representação dos planos de ativação dos componentes

Nota-se em cada um dos componentes uma nítida distinção dos clusters. No primeiro mapa de título Tipo do Equipamento, situado no canto superior à esquerda, estão distribuídos os tipos de equipamentos utilizados nas amostras. A cor azul de tonalidade mais escura, situada no canto inferior direito deste mapa, representa os equipamentos do tipo RAs (religadores automáticos) e as de cor amarela representam os equipamentos do tipo CF (chave fusível). O segundo mapa, título Quantidade, refere-se à quantidade de interrupções com causa não identificada. Os equipamentos que possuem maior número de interrupções estão na cor amarela e estão concentrados no canto inferior direito deste mapa. O mapa chamado Duração (terceiro mapa) refere-se à duração destas interrupções, sendo os equipamentos que possuem maiores durações aqueles concentrados à direita do mapa, na cor amarela. Já o mapa de título Consumidor Interrompido refere-se à quantidade de consumidores interrompidos nestas amostras, onde aqueles que tem maior contribuição estão concentrados no canto inferior direito e ao centro do lado direito, ambos em uma tonalidade de cor amarela. Por fim, o quinto mapa é referente à quantidade de consumidores x hora que estes equipamentos contribuíram, onde a maior quantidade está concentrada ao centro e no canto inferior do lado direito, e estão tendendo para cor amarela. Logo, é interessante ressaltar que os valores nas escalas da Figura 2 estão normalizados em um intervalo de 0 a 1 para as referidas grandezas.

Uma outra forma de representação que pode auxiliar na interpretação dos mapas auto-organizáveis é o mapa de *Utsch* (matriz-U) ou matriz de distâncias, que também é uma excelente ferramenta para análise dos agrupamentos gerados pelos mapas auto-organizáveis (LI, FANG, HUANG, WEI & ZHANG, 2018, p. 37-46). A Figura 3 apresenta esta matriz após o treinamento elaborado. Em regra, a formação de clusters tem como fronteira as distâncias entre os neurônios vizinhos nas regiões do mapa.




Figura 3: Representação da matriz de distâncias entre os neurônios

Na Figura 3 as tonalidades azul escuro representam os vales e a medida que as tonalidades vão mudando, de acordo a escala *colorbar* ao lado da imagem, as distâncias vão aumentando, o que significa a formação de *clusters* cada vez mais definidos. Para a fase de validação e operação da rede, após a interpretação dos mapas decorrentes do treinamento, como já mencionado, faz-se necessário a elaboração do chamado Mapa de Atributos, ou Mapa de Contexto, onde são identificadas as regiões que possuem as amostras que serão classificadas e tratadas. A técnica utilizada para identificação das classes é feita pela denormalização dos valores dos pesos sinápticos de cada um dos neurônios tendo como referência cada uma das entradas da rede. É interessante esclarecer que foram adotados os seguintes critérios para a determinação da relevância para as classes: i) equipamentos que tiveram 7 ou mais interrupções no período estudado foram caracterizados como elevada frequência (quantidade de interrupção); ii) aqueles cuja a soma das interrupções performaram 20 horas ou mais de duração foram considerados com elevada duração, e; iii) aqueles que contribuíram com igual ou mais de 1.200 consumidor hora interrompido (CHI) ou 1.200 consumidor interrompido (CI), no período, foram classificados como de elevado impacto nos indicadores. Desta forma, a Figura 4 ilustra o resultado deste Mapa de Atributos onde as cores simbolizam: o roxo, aquelas amostras ou equipamentos que possuem interrupções que tiveram elevado impacto nos indicadores e foram de elevada duração; o azul, aquelas amostras ou equipamentos que impactaram pouco nos indicadores, porém aconteceram com elevada frequência; já a cor verde representa amostras que também tiveram baixa relevância nos indicadores mas, quando ocorreram, foram de elevada duração; a cor vermelha referem-se aos equipamentos cujas suas interrupções contribuíram significativamente nos indicadores. Por fim, as amostras que tiveram como neurônios vencedores aqueles que estão na cor branca, não se enquadram nos critérios citados e não possuem relevância para serem analisadas ou tratadas.

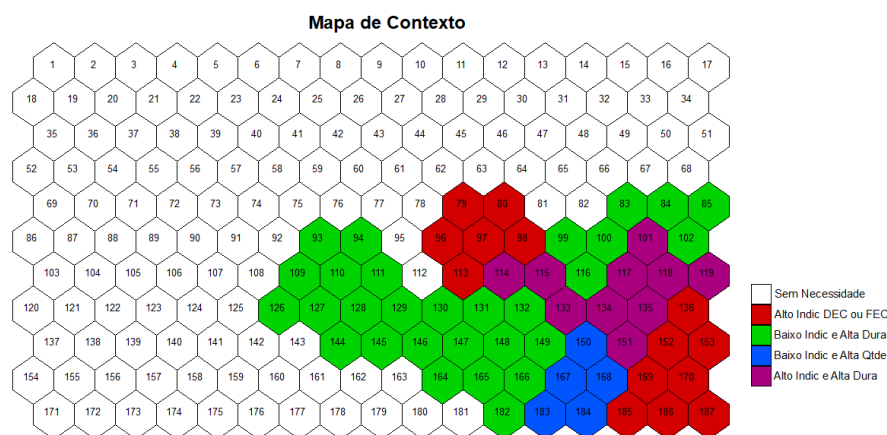


Figura 4: Representação do Mapa de Atributos da RNA

Portanto, em um dos testes de validação foram utilizadas 10% do total das 4.958 amostras pré-processadas, ou seja, 496 equipamentos com suas respectivas variáveis de entrada. Como resultado, após alguns segundos (aproximadamente 20 segundos), a rede classificou e separou 67 amostras dos equipamentos que deverão ser considerados para uma análise mais aprofundada com a verificação de possíveis oportunidades de melhoria e/ou ações relacionadas à manutenção. Ou seja, aproximadamente 13,5% da quantidade total de equipamentos com causas não identificadas inicialmente processadas na etapa de validação. Destas, 4 foram classificadas como de elevado impacto nos indicadores e duração, 4 como de elevada quantidade, 34 como de elevada duração e 14 com elevado impacto nos indicadores. A primeira, segunda e terceira situação impactam diretamente na satisfação do cliente considerando a qualidade dos serviços prestados pela concessionária. A rede também apresentou 11 amostras que foram classificadas erroneamente, ou seja, apenas 2,22% delas. Desta forma, a metodologia proposta apresentou uma acurácia de 97,78%.

Outro aspecto interessante de ser analisado é o tempo despreendido nas análises das interrupções feitas pelo especialista. O tempo médio que um especialista necessita para analisar um equipamento, suas respectivas interrupções, suas causas e devidas ações, é de aproximadamente 4 minutos, considerando uma análise exploratória nos sistemas de registro de interrupções de forma manual. Com esta informação, torna-se possível mensurar a relevância da utilização da metodologia proposta. É importante ressaltar que sem uma ferramenta de seleção e priorização dos equipamentos a serem analisados, um especialista deve analisar todos eles, buscando encontrar aqueles que possuem interrupções relevantes com causas não identificadas que merecem tratamento. Desta forma, considerando que na fase de validação 496 equipamentos deveriam ser analisados por um especialista e que cada análise dura aproximadamente 4 minutos, esta atividade duraria em torno de 1.984 minutos, ou seja, mais de 33 horas, sem o uso da metodologia. Já com a utilização do método proposto, testado e validado na região norte da Copel Distribuição durante o ano de 2019, o especialista deveria analisar somente os equipamentos e suas interrupções selecionadas pela ferramenta, ou seja, 67 equipamentos. Logo, essa atividade poderia ser feita em aproximadamente 268 minutos, ou seja, pouco mais de 4 horas e 20 minutos, garantindo uma redução de mais de 86% no tempo necessário para a análise e o tratamento dos casos, o que corrobora com a eficácia na aplicabilidade desta técnica.

3. Conclusão

Este trabalho apresenta os resultados de um estudo de caso da Copel Distribuição no uso de uma metodologia alternativa capaz de identificar e classificar os equipamentos de proteção, que tiveram interrupções de energia, contemplando parâmetros que expressam a insatisfação dos clientes quanto aos serviços prestados pela concessionária, tais como um elevado número de interrupções e duração. Também foram considerados parâmetros que relacionam a contribuição dos equipamentos nos indicadores de qualidade DEC e FEC, permitindo assim que sejam incluídas nas análises e priorizações com o intuito de identificar suas causas e oportunidades de melhoria para redução de tais indicadores, com foco contínuo na satisfação dos clientes.

A metodologia proposta destaca-se pelo nível de assertividade elevado de 97,78% na classificação dos equipamentos com interrupções inicialmente não identificadas, sendo um método testado e validado com dados reais de um sistema de distribuição real da concessionária. Além de apresentar uma redução significativa nos tempos de análise praticados por seus especialistas, perfazendo um ganho de 86% no caso estudado.

É interessante ressaltar que a aplicação da técnica seleciona para a análise somente os equipamentos com interrupções que são relevantes. Isso garante a assertividade no tratamento de casos considerados problemáticos, aqueles que inicialmente possuem causas não identificadas, que podem passar despercebidos com a aplicação de outros métodos. Desta forma, os resultados obtidos com a aplicação da rede de Kohonen na classificação de padrões de interrupções do sistema elétrico se mostraram satisfatórios, sendo possível separar de maneira eficiente os casos que merecem importância daqueles com menor relevância. Isto valida a grande aplicabilidade deste tipo de rede em problemas considerados não lineares, com grande volume e diversidade de informações, que são comuns na rotina das empresas do setor.

Por fim, diante ao dinamismo das ocorrências nas redes de distribuição das concessionárias do setor, ter uma ferramenta que classifica automaticamente, de maneira rápida e eficiente as interrupções passíveis de análise e ações corretivas, é de vital importância para melhoria dos indicadores de continuidade e, conseqüentemente, da imagem da companhia. Ainda, proporciona um ganho significativo na agilidade desta atividade podendo refletir em benefícios consideráveis de produtividade no âmbito destas organizações.

4. Referências bibliográficas

- MOLOI, K.; ABE, B. T.; NNACHI, A. F.; JORDAAN, J. A. Root Cause Analysis and Performance Enhancement For Power System Network: A Case Study. *IEEE AFRICON*, Accra, Ghana, 2019. p. 1-5. Doi: 10.1109/AFRICON46755.2019.9133913.
- TRAGOONTHAI, S.; CHAITUSANEY, S. Optimal budget allocation for preventive maintenance of distribution system considering customer outage cost and reliability indices. *14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 2017, p. 600-603. Doi: 10.1109/ECTICon.2017.8096309.
- POPOVIC, Z. N.; KNEZEVIC, S. D.; POPOVI, D. S. Risk-Based Allocation of Automation Devices in Distribution Networks With Performance-Based Regulation of Continuity of Supply. *IEEE Transactions on Power Systems*, v. 34, n. 1, p. 171-181, jan. 2019. Doi: 10.1109/TPWRS.2018.2857412.
- MOHAMMADI, R.; MASHHADI, H. R.; SHAHIDEHPOUR, M. Market-Based Customer Reliability Provision in Distribution Systems Based on Game Theory: A Bi-Level Optimization Approach. *IEEE Transactions on Smart Grid*, v. 10, n. 4, p. 3840-3848, jul. 2019. Doi: 10.1109/TSG.2018.2839598.
- HOSSEINI, Z. S.; MAHOOR, M.; KHODAEI, A. AMI-Enabled Distribution Network Line Outage Identification via Multi-Label SVM. *IEEE Transactions on Smart Grid*, v. 9, n. 5, p. 5470-5472, set. 2018. Doi: 10.1109/TSG.2018.2849845.
- MOHAMMADIAN, M.; AMINIFAR, F.; AMJADY, N.; SHAHIDEHPOUR, M. Data-Driven Classifier for Extreme Outage Prediction Based On Bayes Decision Theory. *IEEE Transactions on Power Systems*, v. 36, n. 6, p. 4906-4914, nov. 2021. Doi: 10.1109/TPWRS.2021.3086031.
- GUO, M.-F.; YANG, N.-C.; CHEN, W.-F. Deep-Learning-Based Fault Classification Using Hilbert–Huang Transform and Convolutional Neural Network in Power Distribution Systems. *IEEE Sensors Journal*, v. 19, n. 16, p. 6905-6913, 15 ago. 2019. Doi: 10.1109/JSEN.2019.2913006.
- YAN, C.; LI, M.; LIU, W. Prediction of bank telephone marketing results based on improved whale algorithms optimizing S-Kohonen network. *Applied Soft Computing*, v. 92, p. 106259, 2020. ISSN 1568-4946.
- ABIODUN, O. I. et al. Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition. *IEEE Access*, v. 7, p. 158820-158846, 2019. Doi: 10.1109/ACCESS.2019.2945545.

SOUZA, F. A.; CASTOLDI, M. F.; GOEDEL, A.; SILVA, M. A cascade perceptron and Kohonen network approach to fault location in rural distribution feeders. *Applied Soft Computing*, v. 96, p. 106627, 2020. ISSN 1568-4946.

DOOSTAN, M.; CHOWDHURY, B. H. Power distribution system equipment failure identification using machine learning algorithms. *IEEE Power & Energy Society General Meeting*, Chicago, IL, USA, 2017, p. 1-5. Doi: 10.1109/PESGM.2017.8274109.

MUROS, F. J.; SARACHO, D.; MAESTRE, J. M. Improving supply quality in distribution power networks: A game-theoretic planning approach. *Electric Power Systems Research*, v. 213, p. 108666, 2022. ISSN 0378-7796.

HEYLEN, E.; DECONINCK, G.; HERTEM, D. V. Review and classification of reliability indicators for power systems with a high share of renewable energy sources. *Renewable and Sustainable Energy Reviews*, v. 97, p. 554-568, 2018. ISSN 1364-0321.

DA SILVA, I. N.; SPARTI, D. H.; FLAUZINO, R. A.; LIBONI, L. H. B.; ALVES, S. F. dos R. *Artificial Neural Networks. A Practical Course*. Springer, 2017.

HUIXIAN, J. The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network. *IEEE Access*, v. 8, p. 68828-68841, 2020. Doi: 10.1109/ACCESS.2020.2986946.

ALVES, E.; LEAL, A. Application of Kohonen self-organizing map for clustering negative cloud-to-ground lightning electric field waveforms. *IEEE Latin America Transactions*, v. 19, n. 11, p. 1959-1966, nov. 2021. Doi: 10.1109/TLA.2021.9475850.

SOUZA, M.; PIRES, R.; DEL-MORAL-HERNANDEZ, E. SOMprocessor: A high throughput FPGA-based architecture for implementing Self-Organizing Maps and its application to video processing. *Neural Networks*, v. 125, p. 349-362, 2020. ISSN 0893-6080.

DOMINIK, O. A data-scattering-preserving adaptive self-organizing map. *Engineering Applications of Artificial Intelligence*, v. 105, p. 104420, 2021. ISSN 0952-1976.

GUALTIERI, G. Improving investigation of wind turbine optimal site matching through the self-organizing maps. *Energy Conversion and Management*, v. 143, p. 295-311, 2017. ISSN 0196-8904.

HAYKIN, S. *Redes Neurais: princípios e prática* (traduzido). 2ª ed., Porto Alegre: Bookman, 2001.

FERLES, C.; PAPANIKOLAOU, Y.; NAIDOO, K. J. Denoising Autoencoder Self-Organizing Map (DASOM). *Neural Networks*, v. 105, p. 112-131, 2018. ISSN 0893-6080.

LI, Z.; FANG, H.; HUANG, M.; WEI, Y.; ZHANG, L. Data-driven bearing fault identification using improved hidden Markov model and self-organizing map. *Computers & Industrial Engineering*, v. 116, p. 37-46, 2018. ISSN 0360-8352.