



Wildfire Forecasting near Transmission Lines via Artificial Neural Networks

Lucas B. Cruz, Carlos Alexandre M. Nascimento,
Fernando A. Assis, Rodolfo A. R. Moura and
Marco Aurélio O. Schroeder

EasyChair preprints are intended for rapid
dissemination of research results and are
integrated with the rest of EasyChair.

October 13, 2023

Previsão de Queimadas nas Proximidades de Linhas de Transmissão via Redes Neurais Artificiais

Lucas Botelho da Cruz * Carlos Alexandre M. Nascimento **
Fernando A. Assis * Rodolfo A. R. Moura *
Marco Aurélio O. Schroeder *

* Programa de Pós-Graduação em Engenharia Elétrica, PPGEI,
Universidade Federal de São João del-Rei, UFSJ, São João del-Rei,
MG, (e-mails: lucas.botelhobai@gmail.com, fernandoassis@ufsj.edu.br,
moura@ufsj.edu.br, schroeder@ufsj.edu.br)

** Companhia Energética de Minas Gerais, Cemig, Belo Horizonte,
MG (e-mail: caxandre@cemig.com.br)

Abstract: Wildfires are one of the main causes of unscheduled shutdowns in Brazil's power grid. Therefore, tools that help predict these events in the vicinity of transmission lines (TLs) can significantly collaborate in operation planning tasks. In this context, the present work proposes a methodology that employs the artificial neural network Multi-Layer Perceptron in order to carry out wildfire forecasting in the vicinity of TLs based on meteorological data from the region of interest, representing an important indicator of aid in decision-making in relation to planning the operation of electrical power systems. A case study carried out to forecast fires in the region of the city of Uberlândia - MG, through which a 500 kV TL of the national interconnected system passes, points to a promising performance of the proposed method. Accuracy rates of 82% and 84% are obtained for forecasts in the year 2019 for the evaluated region.

Resumo: As queimadas e incêndios florestais são causas de desligamentos não programados na rede elétrica de potência do Brasil. Diante disso, ferramentas que auxiliem na previsão destes eventos nas proximidades de linhas de transmissão (LTs) podem colaborar significativamente nas tarefas de planejamento da operação e manutenção. Neste contexto, propõe-se uma metodologia que emprega uma rede neural artificial *Perceptron* Multicamadas (*Multi-Layer Perceptron* - MLP) a fim de realizar previsões de queimadas nas proximidades de LTs com base em dados meteorológicos da região de interesse, representando um importante indicador de auxílio na tomada de decisões em relação ao planejamento da operação e manutenção de sistemas elétricos de potência. Um estudo de caso realizado para previsão de queimadas na região da cidade de Uberlândia - MG, por onde passa uma linha de 500 kV do Sistema Interligado Nacional (SIN), aponta um desempenho promissor do método proposto. Índices de acurácia de 82% e 84% são obtidos para previsões no ano de 2019 para a região avaliada.

Keywords: Transmission line shutdowns; Artificial Neural Network; Wildfires forecasting; Electric power system.

Palavras-chaves: Desligamentos de linhas de transmissão; Rede Neural Artificial; Previsão de queimadas; Sistema elétrico de potência.

1. INTRODUÇÃO

Um sistema elétrico de potência (SEP) é formado pelo conjunto de todas as instalações e equipamentos destinados à geração, transmissão e distribuição de energia elétrica. O segmento de transmissão, especificamente, é formado por grandes redes que consistem da interligação, por meio de longas linhas, das usinas de geração aos grandes centros de consumo. Um SEP interligado proporciona maiores níveis de confiabilidade e qualidade no atendimento às cargas, além de propiciar uma melhor integração das diferentes fontes de geração, permitindo otimizar o uso de recursos energéticos e reduzir os custos com a produção de energia.

No entanto, de acordo com Bichels (2018), grandes sistemas interligados, com grande quantidade de componentes (linhas de transmissão - LTs, transformadores, chaves seccionadoras, relés etc.) podem apresentar grandes problemas na ocorrência de falhas, que eventualmente levam a grandes desligamentos não programados e provocam impactos econômicos e sociais de graves consequências. No caso do Brasil, por exemplo, o Sistema Interligado Nacional (SIN) apresenta grandes dimensões, fazendo com que as LTs que o compõem fiquem expostas a diversos fatores que podem levá-las à indisponibilidade.

Várias são as causas de desligamentos não programados na rede de transmissão, sendo as condições meteorológicas

adversas (i.e., descargas atmosféricas, chuvas/temporais, ventos fortes etc.) e as queimadas e incêndios florestais as principais ameaças à garantia de continuidade dos serviços. De acordo com os dados fornecidos pelo Operador Nacional do Sistema (ONS, 2023), no Brasil, do total de 2124 perturbações em LTs registradas na rede básica do SIN para o ano de 2022, por exemplo, 740 (34,84%) foram decorrentes da ocorrência de condições meteorológicas adversas e 250 perturbações (11,77%) resultaram da ocorrência de queimadas nas proximidades das linhas.

Neste contexto, ferramentas capazes de prever, com certa precisão, a ocorrência dos eventos que possam causar o desligamento de LTs representam um importante auxílio aos planejadores da operação e manutenção do SEP. Com base nessas ferramentas, melhores decisões podem ser tomadas nas definições de serviços, como, por exemplo, a programação de manutenções de equipamentos, que não devem acontecer em momentos em que o sistema possa apresentar fragilidades. Portanto, no presente artigo é proposta uma metodologia baseada em informações meteorológicas e no uso de rede neural artificial (RNA) para previsão de queimadas nas proximidades de LTs. O algoritmo de RNA *Perceptron* Multicamadas (*Multi-Layer Perceptron* - MLP) é empregado para composição da metodologia de previsão. As informações de entrada correspondem a dados meteorológicos e históricos de queimadas observados para a região de interesse na análise de previsão.

2. DESLIGAMENTOS DE LINHAS DE TRANSMISSÃO

Desligamentos em um SEP são eventos que provocam a indisponibilidade de ativos (e.g., LTs e subestações), podendo ou não gerar corte de carga. Esses desligamentos podem ser programados ou não. É importante destacar que as concessionárias que participam da rede básica (segmento de transmissão do SEP) recebem pela disponibilidade de seus ativos. Portanto, a ocorrência de perturbações que levem ao desligamento não programado de elementos, tornando-os indisponíveis, além de gerar degradação da confiabilidade do sistema, implica de forma significativa na redução de suas receitas.

Conforme apontado pelo ONS, as queimadas se caracterizam como umas das principais causas de perturbações em linhas de transmissão nos SEPs (ONS, 2023). Para os anos de 2019 a 2022, por exemplo, as perturbações por queimadas correspondem a 18,47%, 24,66%, 26,77% e 11,77%, respectivamente, do total de perturbações registradas nesses anos. Vale comentar que, em todos esses anos, nas causas das perturbações, as queimadas ficaram atrás apenas das condições meteorológicas adversas.

No caso do Brasil, em que o período de julho a dezembro corresponde à época de seca na maior parte do país, normalmente é verificado um aumento na ocorrência de queimadas. Esta observação é confirmada pela maior incidência de perturbações causadas por queimadas nesse período, conforme informações do ONS (2023) que podem ser vistas no gráfico de perturbações para os anos de 2019 a 2022 mostrado na Figura 1, que contém também uma curva para a média das perturbações registradas.




Figura 1. Perturbações originadas por queimadas ao longo dos anos de 2019 a 2022 - Adaptado de (ONS, 2023).

Durante a ocorrência de uma queimada nas proximidades de um ativo de transmissão, há uma maior chance de curto-circuito na rede devido à alteração da rigidez elétrica do ar (Robledo-Martinez et al., 1991). Isso se deve à maior presença de particulado (fuligem) suspenso no ar durante a queimada e ao aumento da temperatura do ar nas proximidades do ativo, que podem culminar na ruptura da rigidez dielétrica na cadeia de isoladores. Maiores detalhes sobre as relações de desligamentos não programados de LTs com a ocorrência de incêndios são discutidos por Costa (2021).

Neste ponto, é importante comentar que os SEPs são constantemente reforçados a fim de melhorar os seus níveis de confiabilidade, de forma que fiquem preparados para ocorrências de eventos que colocam em risco a integridade da rede de transmissão. No entanto, é interessante também dispor de estratégias de auxílio relacionadas à previsão desses eventos. Nas programações gerais que envolvem as tarefas de planejamento (geração, manutenção etc.), pode ser considerada, por exemplo, a possibilidade dos sistemas estarem mais suscetíveis a desligamentos quando queimadas são previstas com base nessas ferramentas.

Trabalhos da literatura apresentam iniciativas de obtenção de ferramentas capazes de prever, com um mínimo de precisão, a ocorrência de queimadas, sendo este o tema principal de investigação no presente trabalho. Na próxima seção, são apresentados e comentados alguns desses trabalhos.

3. PREVISÃO DE QUEIMADAS

Nami et al. (2017) investigam técnicas automatizadas do sistema de informações geográficas (*Geographical Information System* - GIS) integradas ao modelo quantitativo de função de crença evidencial orientada por dados (*Evidential Belief Function* - EBF) para prever o padrão espacial da probabilidade de incêndios florestais em uma parte da ecorregião da Hircania, norte do Irã. Os resultados do modelo são utilizados para produzir um mapa de distribuição de probabilidade de incêndio florestal. O método de modelagem EBF escolhido pelos autores é um modelo matemático para raciocínio com incerteza, que tem a capacidade de lidar com conjuntos de dados heterogêneos e incompletos, representando uma estrutura flexível para aceitar a incerteza e combinar crenças de múltiplas fontes

de evidência. Para a validação do modelo no trabalho, os autores utilizam os dados do GIS. Após tratamento das variáveis de entrada, os autores obtiveram um modelo que alcançou valores de 84,14% e 81,03% para taxas de sucesso e previsão, respectivamente.

Segundo Nami et al. (2017), os resultados mostraram que a estrutura EBF baseada em GIS foi bem sucedida para identificar áreas propensas a incêndios. O mapa de probabilidade derivado do modelo revelou que as zonas de probabilidade moderada, alta e muito alta cobrem quase 60% da área terrestre e a probabilidade de ocorrência de incêndio é fortemente dependente da infraestrutura humana e atividades associadas.

Outro trabalho que pode ser citado é o realizado por Liang et al. (2019), que consiste na avaliação de desempenho entre diferentes modelos de rede neurais aplicados na predição do índice de severidade do incêndio. O trabalho utiliza os dados climáticos das estações de meteorologia da província de Alberta (Canadá), bem como as ocorrências de incêndio pelo Banco Nacional de Incêndios do Canadá (CNFDB) como dados de entrada da RNA. O tamanho da área queimada e a duração do incêndio foram usados para estimar a escala de um incêndio florestal. Tomando os fatores meteorológicos como valores de entrada, uma RNA de retropropagação (*Backpropagation Neural Network* - BPNN), uma RNA recorrente (*Recurrent Neural Network* - RNN) e memória de curto e longo prazo (*Long Short-Term Memory* - LSTM) foram implementadas para estabelecer modelos de previsão. Dos métodos de classificação avaliados, o LSTM exibiu a maior precisão, com 90,9%. De forma geral, os resultados verificados no trabalho indicam, segundo os autores, que é possível prever a escala de um incêndio florestal no início de sua ocorrência usando informações meteorológicas.

Destaca-se que os trabalhos de Nami et al. (2017) e de Liang et al. (2019) não tratam especificamente da previsão de queimadas para o estudo de desligamentos de LTs, mas carregam informações importantes em relação ao tema e mostram que é possível realizar esses estudos. Para citar um exemplo de esforço dedicado de forma mais direta a esta tarefa específica, mais recentemente, no ano de 2021, um modelo para prever se uma LT vai ou não sofrer um desligamento quando exposta a um incêndio florestal é proposto por Costa (2021). Históricos de desligamentos causados por queimadas nos anos de 2018 e 2019, e informações relacionadas ao tipo de vegetação, são levados em consideração nesse trabalho, que correlaciona a carga de incêndio em uma região com o número de desligamentos de LTs. Índices de acerto na ordem de 73,00% são verificados.

Outro exemplo interessante de iniciativa que relaciona os desligamentos de LTs com a ocorrência de queimadas pode ser verificado no trabalho de Khan and Ghassemi (2022). O trabalho realizado pelos autores visa integrar o risco de incêndio florestal com a vulnerabilidade das linhas aéreas através de uma abordagem probabilística. Um modelo combinado de probabilidade de interrupção de linha (*Combined Line Outage Probability* - CLOP) é desenvolvido para calcular o risco de interrupção. Este método fornece a probabilidade combinada de uma queda de linha enquanto leva vários fatores em consideração, como falha de envelhecimento baseada no equilíbrio de




Figura 2. Fluxograma da metodologia proposta.

calor dinâmico, quebra de tensão normalmente distribuída e desarme de linha devido à mudança na classificação do condutor. No trabalho, é estabelecida a relação entre a probabilidade de interrupção da linha e as localizações físicas das linhas e incêndios florestais.

4. METODOLOGIA PROPOSTA

No presente trabalho, considerando a relação entre desligamentos de LTs e ocorrência de queimadas em suas proximidades, conforme experiências citadas na seção anterior, é proposta uma metodologia para realizar a previsão de queimadas nas proximidades de LTs. Essa metodologia é baseada no emprego da rede neural MLP, que tem como parâmetros de entrada informações meteorológicas observadas na região de interesse do estudo.

4.1 Ajuste do Modelo de Previsão

Um fluxograma simplificado, que representa a estrutura geral da metodologia proposta para obtenção do modelo de previsão de queimadas, pode ser visto na Figura 2. Neste fluxograma, o primeiro passo consiste na definição da região geográfica de interesse. Essa região deve contemplar um trecho ou toda a LT para a qual se pretende realizar estudos na rede.

Em seguida, para a região de interesse, devem ser obtidos e tratados os dados diários a serem utilizados na predição de queimadas, que possam afetar a operação da LT. No presente trabalho, esses dados são obtidos a partir da base do Instituto Nacional de Meteorologia (INMET, 2023), sendo eles:

- Temperatura máxima (°C);
- Umidade máxima (%);
- Velocidade do vento (km/h);
- Máxima precipitação diária (mm).

Esses dados meteorológicos nas bases do INMET são obtidos hora a hora para cada dia do histórico. Assim, para obtenção dos valores diários, são calculadas as médias aritméticas das 24 horas de cada dia. Apenas para a precipitação não é calculado um valor médio diário, sendo utilizado o maior valor verificado no dia.

Além dessas informações, é necessário também conhecer a informação relacionada à ocorrência ou não de queimada na região de interesse para as datas do histórico considerado, uma vez que a RNA utilizada neste trabalho é

index	datahora	satelite	pais	estado	municipio	bioma
20	2014/01/04 00:07:24	NOAA-16N	Brasil	MINAS GERAIS	UBERLANDIA	Cerrado
21	2014/01/04 04:50:00	NPP-375D	Brasil	MINAS GERAIS	UBERLANDIA	Cerrado
22	2014/01/04 04:50:00	NPP-375D	Brasil	MINAS GERAIS	UBERLANDIA	Cerrado
129	2014/01/04 04:50:00	NPP-375D	Brasil	MINAS GERAIS	UBERLANDIA	Cerrado

Figura 3. Banco de dados do INPE - Estrutura.

categorizada como um algoritmo supervisionado de classificação. Para obtenção dessa informação, é utilizada a base de dados do Instituto Nacional de Pesquisas Espaciais (INPE, 2023). Em relação a esses dados, é importante destacar que para uma mesma ocorrência de queimada (na mesma região) mais de um registro pode ser realizado, conforme ilustrado na Figura 3, onde é apresentada uma pequena porção desses dados ainda não tratados. Isso ocorre devido ao fato de uma mesma região ser percorrida por mais de um satélite em horários diferentes, o que pode acarretar uma prospecção do andamento do incêndio na região ou a mesma detecção do foco de incêndio de um satélite que percorreu a região anteriormente. Como o dado de interesse é apenas a ocorrência de incêndio em determinada região para uma data, é necessário aplicar um filtro à base de dados, a fim de se obter apenas uma informação por dia. Ou seja, para cada dia do período avaliado, verifica-se se pelo menos um satélite capturou um foco de incêndio na região de interesse.

Por fim, é importante destacar que é também adicionada às informações de entrada apresentadas à RNA como variável categórica a estação do ano correspondente a cada data. Para tanto, são considerados os seguintes intervalos:

- Outono: 21 de março a 21 de junho;
- Inverno: 21 de junho a 23 de setembro;
- Primavera: 23 de setembro a 21 de dezembro;
- Verão: 21 de dezembro a 21 de março.

Após a obtenção e tratamento dos dados, é realizada a etapa de treinamento (aprendizado) da rede neural MLP. Os detalhes de treinamento e emprego dessa RNA são apresentados na próxima subseção.

4.2 Rede Neural MLP Empregada

O algoritmo de redes neurais artificiais escolhido para o processamento dos dados no presente trabalho trata-se da MLP (*Multi-Layer Perceptron*), que possui mais de uma camada intermediária (*hidden layers*) (Haykin, 2000). Para treinamento da MLP (i.e., ajuste do modelo de previsão) é utilizado o algoritmo *Backpropagation*. Este algoritmo, basicamente, usa o sinal de erro propagado na direção inversa das unidades da camada de saída.

Para realização dos estudos de desempenho apresentados neste artigo, a MLP é aplicada por meio da biblioteca *sklearn*, versão 1.0.2, implementada na linguagem *Python* (Pedregosa et al., 2011). No Quadro 1 são apresentados os parâmetros que definem a rede MLP aplicada no estudo. Estes ajustes foram realizados de forma empírica e maiores detalhes sobre o que representa cada um deles podem ser encontrados em (Pedregosa et al., 2011).

Conforme dados do Quadro 1, os dados de entrada são normalizados por meio da biblioteca *StandardScaler* do *Python*, que padroniza os valores para uma mesma escala.

Normalização das entradas:	<i>StandardScaler</i>
<i>Hidden layers</i> :	(10,10)
Função de ativação:	ReLU
Função de otimização:	ADAM
Número máximo de épocas:	500

Quadro 1: Parâmetros da rede MLP.

Como função de ativação, foi empregada a ReLU, que tem como saída um valor nulo quando recebe na entrada valores inferiores ou iguais a 0. Já quando recebe valores maiores que 0, tem como saída o próprio valor. Portanto, nem todos os neurônios são ativados ao mesmo tempo. Já para a função de otimização, é escolhida a “ADAM” (*Adaptive Moment Estimation*) (Diederik P. Kingma, 2015), que é um algoritmo adaptativo de otimização da taxa de aprendizado desenvolvido especificamente para o treinamento de redes neurais profundas.

4.3 Avaliação de Desempenho do Modelo de Predição

A fim de verificar o desempenho do modelo de predição obtido, são empregadas algumas métricas de performance, que são calculadas com base nos resultados de predição comparados com os eventos observados. As métricas consideradas são as apresentadas nas seguintes equações:

$$\text{Acurácia} = \frac{VP + VN}{\text{total de amostras avaliadas}} \quad (1)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2)$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad (3)$$

$$\text{F1 Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (4)$$

em que *VP* (verdadeiro positivo) e *VN* (verdadeiro negativo) representam, respectivamente, casos de predição correta de ocorrência e de não ocorrência de queimada; e *FP* (falso positivo) e *FN* (falso negativo) equivalem, respectivamente, a predições incorretas de ocorrência e de não ocorrência de queimada.

A Acurácia indica a performance geral do modelo, observando qual a acurácia geral em relação ao total de elementos avaliados. A Precisão é uma métrica que contabiliza *VPs* em relação ao total de classificações positivas efetuadas pelo modelo, sendo uma métrica interessante quando eventos de *FP* impactam o modelo de forma direta. A métrica *Recall* contabiliza as predições de *VPs* efetuadas pelo modelo em relação ao total de acertos. Nesse caso, é uma métrica interessante quando o número de *FNs* impacta o modelo de forma mais direta. Por fim, a métrica *F1 Score* representa uma média harmônica entre as métricas *Recall* e Precisão. Um baixo valor de *F1 Score* indica que a Precisão ou o *Recall* tem um valor baixo.

Na análise das métricas apresentadas considera-se que, quanto maior o valor observado, melhor é o desempenho do modelo obtido. Na aplicação da metodologia proposta neste trabalho, o cálculo dessas métricas é também realizado por meio da biblioteca *sklearn* do *Python* (Pedregosa et al., 2011).

Tabela 1. Matriz confusão - Caso 1.

Valor Real		Valor Predito	
		Positivo	Negativo
Positivo		108	45
Negativo		22	190

Tabela 2. Relatório de predição - Caso 1.

Acurácia	Precisão	Recall	F1 Score
0,8164	0,8308	0,7059	0,7633

5. RESULTADOS

Para avaliação de desempenho, a metodologia proposta foi aplicada para previsão de queimadas nas proximidades de uma LT que passa pelo território da cidade de Uberlândia - MG. A escolha dessa região se deu pela quantidade de dados meteorológicos necessários que estão disponíveis nas bases de dados do INMET e do INPE. A LT da rede básica sob análise opera em 500 kV, ligando a subestação de Nova Ponte e a usina hidrelétrica (UHE) Itumbiara C1 (LT 500 kV Nova Ponte - UHE Itumbiara C1).

Para realização do estudo de aplicação da metodologia, as bases de dados do INMET e do INPE foram acessadas e as informações de entrada citadas na Seção 4 foram obtidas para o período compreendido entre os anos de 2013 e 2019. Os dados dos anos de 2013 até 2018 foram então utilizados para treinamento da rede MLP, que teve seu desempenho avaliado na tarefa de previsão de queimadas para o ano de 2019. Dois casos de avaliação foram realizados:

- **Caso 1:** previsão de queimadas na região de interesse para todo o ano de 2019 (janeiro a dezembro);
- **Caso 2:** previsão de queimadas na região de interesse apenas para o segundo semestre do ano de 2019 (julho a dezembro).

A realização de um estudo específico para o segundo semestre de 2019, conforme proposta de avaliação no Caso 2, se justifica pela maior ocorrência de queimadas nesse período do ano, conforme dados históricos informados pelo ONS e apresentados no Seção 2.

5.1 Avaliação do Caso 1

A Tabela 1 apresenta a matriz de confusão obtida com a aplicação do modelo e a Tabela 2 apresenta os valores dos parâmetros de avaliação de desempenho para o Caso 1.

Verifica-se que para o período de avaliação do Caso 1, que corresponde a todo o ano de 2019, segundo os dados do INPE (2023) foi contabilizado um total de 153 dias com focos de incêndio na região de interesse. Após aplicação da metodologia proposta, verificou-se que a rede MLP treinada indicou a ocorrência de 130 dias com focos de incêndios para esse período, sendo que 108 deles (casos de *VP*) efetivamente ocorreram na data prevista. Ou seja, a RNA indicou 83,08% dos focos de incêndio que realmente ocorreram no território de Uberlândia no ano de 2019. Verifica-se também que 190 dos dias em que não ocorreram foco de incêndio foram corretamente previstos pela RNA (casos de *VN*). É possível ainda constatar que 22 (ou 14,38%) dias com focos de queimada indicados pela RNA não aconteceram de fato (casos de *FP*), e 45 (ou 29,41%)





Figura 4. Distribuição de previsões da RNA em relação ao evento de ocorrência de queimadas.

Figura 5. Distribuição de previsões do tipo *VP* da RNA em relação ao evento de ocorrência de queimadas.

focos de queimada que efetivamente aconteceram deixaram de ser indicados pela RNA (casos de *FN*).

De acordo com os resultados da Tabela 2, verifica-se que a RNA apresentou uma Acurácia de 0,8164, ou seja, a RNA fez 81,64% de previsões corretas entre *VPs* e *VNs*. A Precisão foi de 0,8308 na indicação de dias nos quais as queimadas aconteceram para o ano de 2019. Em relação à métrica *Recall*, o valor encontrado foi de 0,7059, apontando que alguns dias em que ocorreram incêndio deixaram de ser previstos pela RNA. Por fim, pela métrica *F1 Score*, verifica-se que há um equilíbrio razoável entre as métricas de Precisão e *Recall*.

A fim de melhor ilustrar o desempenho da RNA, é apresentada na Figura 4 a distribuição das previsões realizadas em relação ao evento de ocorrência de queimadas ao longo do ano de 2019, representada pela curva em laranja. No gráfico, é possível também visualizar pela curva em azul a distribuição de focos de queimada registradas no período segundo dados do INPE. Na Figura 5, que carrega uma informação análoga, a curva em laranja representa a distribuição apenas das previsões corretas em relação ao evento de ocorrência de queimadas (ou seja, de *VPs*).

As formas das curvas nos gráficos das Figuras 4 e 5 indicam que a RNA apresenta uma boa tendência de previsão, principalmente durante o segundo semestre do ano, de maior ocorrência de focos de queimada. A qualidade superior da previsão nesse período é confirmada pelos resultados do Caso 2 apresentados a seguir.

Tabela 3. Matriz confusão - Caso 2.

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	86	16
	Negativo	13	67

Tabela 4. Relatório de predição - Caso 2.

Acurácia	Precisão	Recall	F1 Score
0,8407	0,8687	0,8431	0,8557

5.2 Avaliação do Caso 2

Para o Caso 2, as Tabelas 3 e 4 apresentam, respectivamente, a matriz de confusão e os valores dos parâmetros de desempenho verificados apenas para o segundo semestre do ano de 2019, que totaliza 182 dias. Nesse período, ocorreram, de acordo com os dados do INPE, 102 dias com foco de incêndio na região de interesse.

Dos 102 dias com focos de queimada, 86 (ou 84,31%) foram previstos pela RNA, o que implica no valor 0,8431 para a métrica *Recall*. Além disso, dos 80 dias em que não ocorreram focos de queimada, 67 (83,75%) foram corretamente indicados pela RNA. A Acurácia e a Precisão da RNA foram, respectivamente, de 0,8407 e 0,8687. A métrica *F1 Score* nesse caso, de 0,8557, indica um melhor equilíbrio entre as métricas de Precisão e *Recall*.

Em relação ao Caso 1, verifica-se uma melhora geral dos resultados para o período de maior ocorrência de incêndio (segundo semestre do ano). Portanto, pode-se concluir para o estudo aqui realizado que a metodologia proposta apresenta melhor desempenho para esse período.

5.3 Considerações Finais

Vale informar que apenas um treinamento foi realizado para a RNA na realização dos dois casos de avaliação (Casos 1 e 2). Isso significa que dados históricos do primeiro semestre também foram utilizados como informação para treinamento da RNA mesmo quando o interesse era o de previsão apenas para o segundo semestre do ano.

Informa-se ainda que conformações da MLP com diferentes tipos de funções de ativação, como sigmóide e tangente hiperbólica, foram testadas nos estudos. No entanto, apresentaram resultados inferiores para os mesmos ajustes considerados. Também foi avaliada a redução do número de neurônios nas camadas ocultas, o que também ocasionou um impacto negativo na qualidade dos resultados. Por fim, foi verificada a mudança da função de otimização do modelo, o que não apresentou mudança de desempenho.

6. CONCLUSÕES

As queimadas e incêndios florestais nas proximidades da rede elétrica são causas de desligamentos não programados de LTs, que podem impactar severamente na segurança operativa do sistema. Dada a importância deste evento para a tomada de decisão nas tarefas de planejamento da operação e da manutenção de um sistema elétrico de potência, é proposta no presente trabalho uma metodologia de previsão de queimadas baseada no uso de uma rede neural artificial (RNA) e de dados meteorológicos.

A partir do estudo de caso realizado para avaliação de desempenho do método proposto, foi possível perceber que a RNA apresentou uma boa performance. Apesar de não acertar a previsão de ocorrência dos focos de queimadas para todos os dias dos períodos analisados, verificaram-se boas tendências de predição, apontando que sua aplicação pode ser considerada como um indicador auxiliar para a tomada de decisões.

É importante destacar que é possível melhorar a precisão do método de previsão proposto considerando a localização exata de todo o trecho que a LT analisada percorre. Na avaliação preliminar aqui apresentada, são verificados os dados meteorológicos apenas de uma região atravessada pela LT. Além disso, os dados meteorológicos considerados correspondem a toda a região contemplada (de interesse analisada), e não só das proximidades do trecho da LT. Portanto, é muito importante destacar que o método aqui proposto deve ser utilizado apenas de forma auxiliar pelos planejadores e operadores do sistema elétrico.

REFERÊNCIAS

- Bichels, A. (2018). *Sistemas Elétricos de Potência - Métodos de Análise e Solução*. Curitiba: Editora da UTFPR.
- Costa, T.R.V. (2021). Faixas de segurança de linhas de transmissão e seu modelo de desempenho frente aos incêndios florestais. Tese de Doutorado - UNB.
- Diederik P. Kingma, J.B. (2015). Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations*.
- Haykin, S. (2000). *Redes Neurais, Princípios e Prática*. Bookman.
- INMET (2023). Banco de dados meteorológicos. <<https://bdmep.inmet.gov.br>>. Online [Acesso em Março 2023].
- INPE (2023). Banco de dados de queimadas. <<https://queimadas.dgi.inpe.br/queimadas/portal>>. Online [Acesso em Março 2023].
- Khan, I. and Ghassemi, M. (2022). A probabilistic approach for analysis of line outage risk caused by wildfires. *Int. J. Electr*, 139, 108042.
- Liang, H., Zhang, M., and Wang, H. (2019). A neural network model for wildfire scale prediction using meteorological factors. *IEEE Access*, 7, 176746–176755.
- Nami, M., Jaafari, A., Fallah, M., and Nabiuni, S. (2017). Spatial prediction of wildfire probability in the Hyrcanian ecoregion using evidential belief function model and gis. *Int J Environ Sci Technol*, 15.
- ONS (2023). Indicadores de desempenho do SIN. <<http://www.ons.org.br/Paginas/resultados-da-operacao/qualidade-do-suprimento-paineis.aspx>>. Online, [Acesso em Novembro de 2022].
- 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., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Robledo-Martinez, A., Guzman, E., and Hernandez, J. (1991). Dielectric characteristics of a model transmission line in the presence of fire. *IEEE Transactions on Electrical Insulation*, 26(4), 776–782.