



## Artigo Original

# USO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA A PREDIÇÃO DE OCORRÊNCIAS DE INCÊNDIOS EM VEGETAÇÃO

## USE OF ARTIFICIAL INTELLIGENCE TECHNIQUES TO PREDICT VEGETATION FIRE OCCURRENCES

Flavio Mauricio da Cunha Souza<sup>1</sup>

DOI: 10.17648/revistavigiles-2595-4229-v4n1-12

<sup>1</sup> Corpo de Bombeiros Militar de Minas Gerais.

### RESUMO

As mudanças climáticas ocorridas nas últimas décadas, implicaram em alterações dos períodos chuvosos e de estiagem, que são os principais fatores levados em consideração para o planejamento de órgãos públicos, como o Corpo de Bombeiros Militar de Minas Gerais (CBMMG), no enfrentamento dos incêndios em vegetação. Com o avanço das ferramentas computacionais e a disponibilidade de dados correlativos a ocorrências de incêndios em vegetação, como dados climáticos, algumas técnicas de Inteligência Artificial se tornaram viáveis para predições desse tipo de ocorrência. Neste sentido, esta pesquisa propõe desenvolver uma ferramenta baseada em Redes Neurais Recorrentes (RNN) – Long Short Term Memory (LSTM), que utiliza dados históricos de atendimentos de ocorrências de incêndios em vegetação e de variáveis meteorológicas para a predição destes eventos. A ferramenta desenvolvida apresentou boa acurácia na predição dos períodos mais propensos à ocorrência desses incêndios, podendo ser utilizada pelo comando do CBMMG como fonte de assessoramento.

**Palavras-chave:** Incêndios em vegetação; Inteligência artificial; Predição; Dados climáticos; Planejamento.

### ABSTRACT

*Climate change in recent decades has led to changes in both wet and dry seasons, which are the main factors taken into account for the planning of public bodies, such as the Corpo de Bombeiros Militar de Minas Gerais (CBMMG), regarding vegetation fire fighting. With the development of computational tools and the availability of data related to the occurrence of vegetation fires, such as climate data, some Artificial Intelligence techniques have become viable to predict this type of occurrence. In this sense, this research proposes to develop a tool based on Recurrent Neural Networks (RNN) – Long Short Term Memory (LSTM), which uses historical data from occurrences of fires in vegetation and meteorological variables to predict these events. The developed tool showed good accuracy in predicting the periods most prone to the occurrence of these fires, and can be used by the CBMMG Command as a source of advice.*

**Keywords:** Vegetation fires; Artificial Intelligence; Prediction; Climate data; Planning.

---

Recebido em: 10/05/2021 - Aprovado em: 16/08/2021

E-mail: flavio.cunha@bombeiros.mg.gov.br.

---

## 1 INTRODUÇÃO

Operações em incêndios em vegetação são complexas, envolvem riscos e dificuldades de atuação. O efetivo controle deste tipo de operações, do pessoal envolvido e da dinâmica do fogo, demandam planejamento adequado e gerenciamento correto do emprego dos recursos humanos e logísticos. O planejamento deve preceder qualquer ação e um estudo de situação bem feito deve fornecer os dados necessários para que o planejamento seja adequado e exequível. Com o intuito de antever essas ocorrências e antecipar ações preventivas, neste trabalho propõe-se o desenvolvimento de uma ferramenta computacional que utilize técnicas de inteligência artificial, para indicar de maneira confiável a possibilidade de ocorrências de incêndio em vegetação. O objeto de estudo deste trabalho foi o Parque Estadual Serra Verde (PESV), em Belo Horizonte, Minas Gerais. Em termos de aplicação e uso dos conceitos de redes neurais artificiais, no campo da predição e do combate aos incêndios, vale destacar alguns trabalhos recentemente publicados, tais como apresentados em Fernandes *et al.* (2018a, 2018b, 2020) e Fernandes (2019).

O PESV é uma área de preservação ambiental que fica localizada nas proximidades da Cidade Administrativa de Minas Gerais (CAMG), sede do governo estadual, e de outras edificações residenciais. Por diversos motivos, principalmente em épocas de estiagem, ocorrem focos de incêndios nessa área. A proximidade dos focos de incêndio no PESV às residências e à CAMG geram situações adversas e perigosas a pessoas e bens. Para o rápido e efetivo emprego de bombeiros militares no combate à incêndios nas áreas adjacentes à CAMG, é necessário o empenho de tropa extraordinária do CBMMG, composta pelos militares do quadro administrativo, que trabalham nos vários prédios do complexo, denominado “Quarto Esforço” (MINAS GERAIS, 2017). Esse empenho deve ser bem planejado, de forma que os militares sejam mobilizados o quanto antes, dado o princípio de incêndio, e desmobilizados tão logo o incêndio seja mitigado, para que voltem a desempenhar suas funções administrativas que ficaram suspensas nesse período.

Atualmente, o planejamento para mobilizar esses militares é baseado numa janela de meses fixa no ano, estimada pela média anual de precipitação de chuva no estado de Minas Gerais (MINAS GERAIS, 2018a), chamada de “Período de Estiagem”, que compreende os meses de abril a setembro (MINAS GERAIS, 2018b). Porém, as mudanças climáticas das últimas quatro décadas, percebidas em Minas Gerais, têm causado alterações dessa janela, podendo adiar, atrasar, encurtar ou aumentar o Período de

Estiagem (REBOITA *et al.*, 2018). Essas alterações podem gerar empenhos desnecessários do Quarto Esforço ou sua desmobilização numa época muito suscetível à ocorrência de incêndios naquele local. A previsão desses eventos, em tempo hábil para planejamento, se mostra útil para otimizar o emprego de recursos do CBMMG, bem como minimizar os possíveis danos causados ao PESV, à CAMG e seus usuários e às demais edificações no entorno.

Em incêndios em vegetação, o comportamento do fogo é resultado de interações entre clima, condições do combustível, topografia, técnica de queima e forma de ignição. A umidade dos vegetais varia dependendo da espécie e, independente do percentual de umidade interna, o vegetal pode entrar em combustão. Porém, somente quando a umidade interna do vegetal apresenta valores menores que 12%, há a possibilidade de propagação das chamas (TORRES, 2016). No período de estiagem, há o acúmulo na superfície do solo de folhas secas, gravetos e pequenas lascas de árvores, de diâmetro inferior a 6 mm, que pode, em contato com o ar quente e seco, num período superior a uma hora, passar de úmido ( $> 50\%$ ) para valores inferiores a 12%. Ou seja, mesmo após um dia de chuvas, essa vegetação, em contato direto com a radiação do sol e a baixa umidade do ar, poderá ficar em condições de propagar rapidamente um incêndio (TORRES, 2016). Temperaturas ambiente elevadas, associadas à baixa umidade relativa do ar, aumentam a evaporação nos vegetais, tornando-os mais secos e, conseqüentemente, mais combustíveis. Portanto, o clima local e suas variáveis meteorológicas influem diretamente nos ecossistemas e processos biológicos (TORRES, 2016).

Com base em análises utilizando estatísticas cruzadas da correlação de Pearson( $r$ ), que é uma medida de associação linear entre variáveis (FIGUEIREDO FILHO; SILVA JÚNIOR, 2016), as variáveis meteorológicas que mais contribuem para a ocorrência de incêndios em vegetação são: umidade relativa máxima e mínima, precipitação, velocidade do vento e radiação solar (VIGANO, 2017).

Métodos de inteligência artificial, como a Rede Neural Artificial *Multilayer Perceptron* (RNA/MLP), com o algoritmo *backpropagation* para recalcular os pesos das ligações entre neurônios de diferentes camadas, foram utilizados para a previsão de incêndios e queimadas, tendo obtido resultados significantes em biomas como florestas no norte de Portugal (SAFI; BOUROMI, 2013), ecossistemas de florestas no Mediterrâneo (SATIR *et al.*, 2016) e no pantanal brasileiro (VIGANO *et al.*, 2017), valendo destacar também os trabalhos realizados recentemente na Região Metropolitana de Belo Horizonte desenvolvido por Fernandes (2019).

Entretanto, os resultados referenciados mostram que esse método funcionou muito bem para situações em que foram consideradas poucas ou apenas uma variável de entrada e grandes massas de dados históricos, como no caso do pantanal brasileiro (VIGANO *et al.*, 2017), tendo sua acurácia diminuída quando foram aumentadas as variáveis de entrada e foi reduzido o período de tempo analisado de dados históricos.

Este é um fato importante para este trabalho, uma vez que o CBMMG digitalizou seus registros de ocorrências a partir de 2012, sendo inviável a consulta de dados históricos anteriores.

Outra abordagem para a previsão de incêndio florestais, também em Portugal, foi a substituição do *backpropagation* pelo *Particle Swarm Optimization* (PSO) para determinar os pesos da RNA, a fim de diminuir o erro considerando maior quantidade de variáveis e menor período de dados históricos para o treinamento da rede (STORER; GREEN, 2016). Neste caso, a substituição do algoritmo de cálculo dos pesos da RNA melhorou e diminuiu significativamente o erro, mas outros tipos de ações, como a quebra de variáveis discretas em unidades menores, ano em mês, por exemplo, se mostraram mais eficientes para este fim.

Para uma análise eficiente das abordagens citadas e dos resultados desta pesquisa para a previsão de incêndios em vegetação é fundamental o entendimento do conceito de séries temporais. As séries temporais são observações de variáveis feitas de forma sequencial ao longo do tempo. Devido a sua estrutura, uma série temporal apresenta várias características, como tendência e sazonalidade e, através delas, é possível encontrar padrões que podem facilitar previsões. Tendência é uma variação, ascendente ou descendente, que se mantém como um padrão durante um certo período de tempo (MORETTIN; TOLOI, 2004). Uma série temporal é sazonal (periódica) quando os fenômenos se repetem a cada período idêntico de tempo, afetando o comportamento da série consistentemente ao longo de sua duração. O menor período para este fenômeno repetitivo é chamado de período sazonal (MORETTIN; TOLOI, 2004), como é o caso dos incêndios em vegetação.

Além do conceito de séries temporais, para facilitar o entendimento da ferramenta proposta nesta pesquisa, é necessário definir o que é uma Rede Neural Artificial (RNA). A RNA pode ser definida como uma estrutura matemática não-linear, capaz de representar arbitrariamente processos não-lineares que relacionam entradas e saídas de um sistema. Em suma, deve ser uma estrutura com potencial de aplicação em situações que requeiram a classificação de padrões, aproximação de funções, aprendizado em áreas de difíceis

modelagens, de previsão, e com frequentes mudanças de ambiente (HAYKIN, 2009). O neurônio artificial é inspirado numa abstração do funcionamento de um neurônio real, que pode ser descrita pela Equação 2.1,

$$y = \varphi \left( \sum_{i=1}^m w_i x_i + b \right) \quad (2.1)$$

em que  $x_1, x_2, \dots, x_m$  são os sinais de entrada;  $w_1, w_2, \dots, w_m$  os respectivos pesos sinápticos;  $b$  é um bias,  $\varphi(\cdot)$  uma função de ativação e  $y$  a saída.

Vários neurônios interconectados, em uma ou mais camadas, formam redes que têm a capacidade de reproduzir com muita precisão diversos tipos de modelos complexos.

As redes neurais alimentadas diretamente, ou *feedforward neural networks*, são os tipos mais comuns de redes neurais. Elas são caracterizadas pelas conexões entre os neurônios que não formam laços fechados. Ou seja, o fluxo de informações ocorre apenas no sentido das entradas para as saídas, não há realimentação da rede. Essas redes são compostas por camadas conectadas em sequência e as camadas fundamentais dessas redes são: camada de entrada, camada interna, ou oculta, e camada de saída (SILVA, 2019). Geralmente, são utilizadas redes densamente conectadas, isto é, todo neurônio é conectado a todos os neurônios de sua camada posterior.

Um dos algoritmos mais utilizados e comuns para o treinamento e correção de erros de uma rede neural diretamente alimentada é denominado *backpropagation* (LINNAINMAA, 1976). Esse algoritmo apresenta ao modelo, descrito pela rede neural, um conjunto de pares de entradas e saídas conhecidos. A partir do vetor de entrada, o modelo calcula a saída e, em seguida, o erro determinado por uma função que compara a saída calculada com a saída desejada. Por fim, os pesos das conexões entre os nós da rede são ajustados a fim de minimizar esse erro, geralmente pelo método do gradiente. Para isto, deve ser obtida a derivada parcial do erro relativo a cada peso ajustável. Cada ciclo desse processo é chamado de época. O número de épocas, é o número de vezes que todo o conjunto de dados é passado através da rede neural durante o treinamento (JANG; SUN; MIZUTANI, 1997). Atualizar os pesos e outros parâmetros com apenas em uma época não é suficiente, já que levaria ao subajuste (*underfitting*). À medida que o número de épocas aumenta, mais vezes o peso e outros parâmetros são atualizados na rede neural, e assim, a precisão do treinamento e a precisão da validação aumentarão. No entanto, quando o número de épocas atinge um certo ponto, a acurácia da validação começa a diminuir, enquanto a acurácia do treinamento ainda está aumentando. Isso significa que o modelo está

superajustando (*overfitting*). Assim, o número ideal de épocas é o ponto em que a acurácia da validação atinge seu valor mais alto.

Em problemas que tratam de séries temporais, um tipo de rede neural que tem ganhado campo e sendo bastante utilizada são as redes neurais recorrentes (RNN), que possui pelo menos um laço fechado. Seu modelo equivalente, diretamente alimentado, é obtido pela sequência de entradas de dados de interações passadas. Essa arquitetura permite, de maneira mais simplificada, processar dados sequenciais, de forma que os estados das entradas anteriores são propagados, como um tipo de memória. A ideia principal é que uma RNN pode ser alimentada de modo reverso, com dados relevantes ao modelo. A retropropagação dos erros em RNNs é chamada retropropagação através do tempo, ou *backpropagation through time* (WERBOS, 1990).

Porém, a habilidade de RNNs convencionais trabalharem com informações das entradas passadas é restrita, pois, dificilmente consegue treinar relações de longo prazo. O gradiente propagado por muitos estágios tende a se perder ou divergir (GOODFELLOW *et al.*, 2016). Para evitar esse tipo de problema com o gradiente, são usadas arquiteturas especiais de redes recorrentes, como a *Long Short-Term Memory* (LSTM).

*Long Short-Term Memory* (LSTM) é um tipo especial de RNN proposto por Hochreiter e Schmidhuber (1997) para solucionar o problema do treinamento de dependências de longo prazo.

Em redes com muitas camadas, como é o caso das LSTM, alguns problemas são comuns de acontecer. Um deles ocorre se a rede é iniciada com uma taxa de aprendizagem muito alta. Nesse contexto, os pesos de cada unidade da camada oculta de neurônios se tornarão muito grandes positivos ou negativos. As derivadas dos erros nestas unidades se tornarão muito pequenas e o erro não decrescerá. Neste caso, geralmente, um platô é confundido com um mínimo local.

Uma alternativa para essa situação é o algoritmo de otimização *RMSprop*, que divide a taxa de aprendizagem para um peso, pela média corrente das magnitudes dos gradientes recentes para aquele peso. O *RMSprop* combina a ideia de apenas usar o sinal do gradiente com a ideia de adaptar o tamanho do passo separadamente para cada peso (KURBIEL; KHALEGHIAN, 2017).

## 2 MÉTODO

### 2.1 Contexto



Considerando os aspectos positivos e negativos, indicados na introdução, dos trabalhos apresentados por (VIGANO *et al.*, 2017) e (STORER; GREEN, 2016), e a necessidade de prever as ocorrências de incêndios no PESV com o menor erro possível, trabalhando com múltiplas variáveis num período curto de tempo de dados históricos, decidiu-se, para este trabalho, testar uma nova abordagem com o uso de Redes Neurais Recorrentes (RNN), que são aplicadas amplamente em previsões envolvendo séries temporais (MANDIC; CHAMBERS, 2001). O que também é apresentado em trabalhos como os de Anochi e Campos Velho (2014), bem como em Fernandes (2019) e Fernandes *et al.* (2020). Neste trabalho, serão levadas em consideração apenas a tendência e a sazonalidade. Como há dependências de longos prazos entre as variáveis de entrada com a saída desejada, as LSTM se mostram promissoras neste caso.

Com base nos registros históricos de atendimento do CBMMG, as ocorrências de incêndios em vegetação no PESV e dos dados históricos das variáveis meteorológicas do banco de dados do INMET, uma rede neural recorrente do tipo LSTM foi construída para ter como entradas esses registros e dados, fornecendo como saída a previsão de novas ocorrências.

De posse desta previsão, é possível analisar o uso de redes LSTM para este tipo de problema de forma quantitativa, por meio do método de validação cruzada da rede, e também de forma qualitativa, se atende às necessidades do comando do CBMMG quanto à uma ferramenta de assessoramento.

O interesse neste tipo de trabalho não é prever apenas quantas ocorrências podem acontecer num período de tempo, mas também saber quando esse período terá início e fim, já que esse tipo de dado é sazonal.

Para se ter um prazo razoável para o planejamento de tomadas de decisões relativas às ações preventivas e de combate aos incêndios em vegetação no PESV, foi definido que o intervalo de interesse para as previsões fosse de um ano, de modo que a previsão do período de estiagem possa ser visualizada por completo antes dele se iniciar.

## 2.2 Materiais utilizados


Para a realização deste projeto foram utilizados um computador pessoal, *notebook* com processador *intel i3* e 4 Gb de memória *RAM*, Ambiente de Desenvolvimento Integrado (IDE) genérico para desenvolvimento de códigos de programação, linguagem *Python* de programação e diversas das suas bibliotecas.

## 2.3 Dados

Os dados utilizados como entradas da rede neural construída foram os registros de ocorrências atendidas pelo CBMMG no PESV, no período entre 01/01/2013 e 31/12/2018, solicitados junto ao Centro Integrado de Defesa Social (CINDS-BM), e os dados meteorológicos da estação meteorológica 83587 (Latitude: -19,93; Longitude: -43,93) do INMET, em Belo Horizonte, disponíveis no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP).

O BDMEP oferece dados de uma gama de variáveis meteorológicas diferentes. Os que selecionados para a utilização neste trabalho, dentre aqueles citados na seção 2.2.4, tiveram como critérios a disponibilidade da variável no BDMEP e baixa quantidade de dados faltantes ou trocados. Sendo assim, as variáveis meteorológicas selecionadas foram umidade relativa do ar e precipitação. Os dados de históricos de ocorrências, além de servirem de comparação com os dados de saída – previsões – da rede, também foram utilizados como entradas, uma vez que este tipo de dado como entrada obteve maior eficiência na minimização dos erros de previsão no trabalho de Viganò (2017).

Figura 1 - Representação gráfica dos dados utilizados neste trabalho



Fonte: Elaborado pelo autor.

Considerando a acentuada sazonalidade dos dados e a necessidade do planejamento das ações num prazo razoável, definiu-se a divisão do período total em meses. Portanto, as variáveis trabalhadas, que fazem parte da base de dados do problema,



são as médias mensais de umidade relativa do ar, as precipitações totais mensais e os totais mensais de ocorrências atendidas pelo CBMMG, no PESV, ao longo de 72 meses, exibidos pelos gráficos da Figura 1.

Definida a base de dados, devido a sua heterogeneidade, foram necessários tratamentos prévios. Primeiramente, foram detectados dados faltantes ou com valores espúrios. Para este tipo de problema, foi utilizada interpolação para o preenchimento desses dados, de modo a minimizar a interferência deles na rede. Outro tipo de tratamento, foi a normalização desses dados, por se tratarem de informações de diferentes ordens de grandeza, através de uma transformação linear para o intervalo [0,1].

Como as LSTM trabalham com previsões baseadas em séries temporais e considerando as características da base de dados, foi criada uma estrutura de dados previsores em que cada previsão é feita com base em informações dos doze meses anteriores. Esta estrutura é formada pelo processo de “janelamento móvel”, semelhante ao utilizado por Bastos (2018).

Assim, na construção da estrutura de previsores deste trabalho, a janela de dados foi de  $n = 12$  meses e o passo utilizado foi de  $j = 1$ . Esse processo foi repetido em número de deslocamentos  $k = 60$ , para percorrer todo o período de dados, criando uma estrutura de previsores tridimensional de dimensões  $d = n \times p \times k$ , sendo  $p$  o número de variáveis previsoras (ou atributos previsores).

Para este trabalho, foram separados do total de 72 meses, dados dos 60 meses primeiros para treinamento da rede e os 12 meses restantes para testes.

## 2.4 Estrutura e implementação da rede neural

A RNA utilizada foi uma rede LSTM, com três atributos previsores, três camadas ocultas, sendo que a primeira possui 100 neurônios e as duas seguintes 50 neurônios. A camada de saída possui apenas um neurônio com função de ativação linear. Essa configuração foi estabelecida empiricamente. O algoritmo de otimização utilizado para minimizar os erros dos pesos na rede foi o *RMSprop*, a função de custo foi o MSE e a métrica utilizada foi o Erro Médio Absoluto (*Mean Absolut Error* - MAE). O MAE mede a acurácia da previsão pela média das magnitudes dos erros das previsões e é mais utilizado quando se pretende medir o erro da previsão na mesma unidade que a série original.

## 2.5 Testes de validação

Para validar a RNA LSTM implementada nessa pesquisa, foi utilizada a validação cruzada k-fold, com base em Amaral (2017), que consiste numa técnica computacional aplicada a modelos de predição, que usa todas as amostras de dados disponíveis como amostras de treinamento e teste. O conceito se resume em repartir os dados em K conjuntos, de tamanhos aproximados. Um desses conjuntos é usado para testes e os outros K-1 conjuntos são usados para estimação de parâmetros e cálculo de erro. Este processo é realizado K vezes, assim garantindo que todos os dados sejam, ao menos uma vez, parte do conjunto de testes. No final das K iterações, o Erro Médio Absoluto (MAE - *Mean Absolute Error*) é calculado considerando todos os conjuntos. O processo descrito avalia a capacidade de predição do modelo (AMARAL, 2017).


Considerando a validação cruzada k-fold, já que na base de dados utilizada constam 72 registros de cada atributo, definiu-se k=6. Consequentemente, a base de dados foi dividida em seis subconjuntos, onde cada subconjunto tem 12 registros, que corresponde exatamente a divisão em anos dos dados e coincide com a quantidade de informações testadas na rede.

### 3 RESULTADOS

#### 3.1 Dinâmica da LSTM implementada


A rede LSTM implementada recebeu a estrutura de dados de treinamento por 100 épocas e *batch size*, número de exemplos de treinamento, que são apresentados no modelo antes que o peso e os bias sejam atualizados, igual a 30, gerando como saída os dados exibidos nas Figuras 2 e 3 e na Tabela 1.

Figura 2 - Gráficos dos eventos reais de ocorrências registrados e das previsões feitas pela rede LSTM implementada no período total da base de dados



Fonte: Elaborado pelo autor.

Figura 3 - Gráficos dos eventos reais de ocorrências registrados e das previsões feitas pela rede LSTM implementada somente na parte de teste (últimos 12 meses da Figura 2)



Fonte: Elaborado pelo autor.

Tabela 1 - Métricas da rede LSTM

| Média eventos reais | Média previsões | MSE (Erro mínimo pesos) | MAE (Previsões/Eventos reais) |
|---------------------|-----------------|-------------------------|-------------------------------|
| 2,1667              | 1,6680          | 0,01348                 | 0,9624                        |

Fonte: Elaborado pelo autor.

## 4 DISCUSSÃO

Analizando os gráficos das Figuras 2 e 3, pode-se observar que as tendências das previsões dadas pelo modelo gerado pela rede LSTM coincidem com as tendências dos dados de eventos reais de ocorrências de incêndios em vegetação no PESV, principalmente nas vizinhanças, de quando o número de eventos para ambos é igual a 2. Outros fatos interessantes ao observar os pontos próximos de evento igual a 2, é que nesses pontos foram onde ocorreu a menor taxa de erro entre as previsões e eventos reais e eles aconteceram, geralmente, nas épocas de início e de término do período de estiagem. Levando em consideração os dados do teste apresentados na Figura 3 e as análises supracitadas, tomando o período entre a previsão com tendência crescente e valor próximo a 2 e a previsão com tendência decrescente e valor próximo a 2, são abarcadas 92,3% das ocorrências de incêndio em vegetação, no PESV, do ano de 2018. Resultados semelhantes são verificados repetindo-se esta mesma linha de raciocínio para os dados de treinamento e as previsões do modelo para estes dados. Nos anos de 2014 e 2017 este período se deu entre os meses de maio e setembro, o que ajudaria o comando do CBMMG na decisão de empenhar o Quarto Esforço um mês depois do que ele foi empenhado, sem prejuízos das ações no PESV. Portanto, os pontos das previsões em torno do valor 2 se mostram ótimos candidatos para a tomada de decisão do comando do CBMMG para empenho ou desmobilização do Quarto Esforço.

A tabela 1 revela que, se compararmos as previsões com os eventos reais, ponto-a-ponto, existe um erro de previsão da rede na ordem de aproximadamente 44%.

Os resultados dos erros absolutos obtidos para os k testes e a média destes erros pelo teste de validação cruzada k-fold são apresentados na tabela 2, onde é possível perceber que para diferentes partes do conjunto de dados tomados como treinamento e como teste, o MAE das previsões teve um desvio médio de aproximadamente 47%. Tendo por base os resultados das tabelas 1 e 2, verifica-se que a precisão deste modelo preditivo

foi afetada, muito provavelmente, pelo banco de dados limitado e pela variância entre os dados de um ano em relação aos demais.

Tabela 2 - Validação Cruzada k=6

| K   | 1      | 2      | 3      | 4      | 5      | 6      | Média MAE | Desvio Média MAE |
|-----|--------|--------|--------|--------|--------|--------|-----------|------------------|
| MAE | 2,0725 | 2,5873 | 0,5412 | 0,9628 | 0,6776 | 1,3886 | 1,3707    | 0,6445           |

Fonte: Elaborado pelo autor.

## 5 CONCLUSÃO

De acordo com os resultados apresentados, é possível concluir que o uso de uma RNA do tipo LSTM para a previsão de ocorrências de incêndios em vegetação, no caso do PESV, não teve uma precisão muito grande. Entretanto, considerando os períodos de maior incidência deste tipo de ocorrência e as tendências em torno do valor 2, essa abordagem pode ter utilidade prática, sendo possível assessorar o comando do CBMMG no planejamento da mobilização e desmobilização do Quarto Esforço.

As maiores dificuldades para o desenvolvimento dessa ferramenta se deram pelo banco de dados limitado e pela construção, de forma empírica, da estrutura da RNA, uma vez que ainda não se tem uma técnica bem consolidada para determinar qual é o número ideal de neurônios em cada camada ou qual é o otimizador ideal para a rede.

Outras possibilidades para melhorar a precisão desse tipo de predição são testar outros tipos de RNA para a predição de incêndios em vegetação, no PESV, e comparar os resultados com os desta LSTM desenvolvida, utilizar esta LSTM em outros tipos de previsões que possuam conjuntos de dados maiores ou fazer modificações nesta LSTM para melhorar seu desempenho e testar outros intervalos de previsão para a mesma rede.

Além disso, uma sugestão seria o georreferenciamento desses dados, a exemplo do que é desenvolvido em várias pesquisas com o emprego de Sistemas de Informação Geográfica. Adicionalmente, sugere-se a integração com várias outras tecnologias, incluindo a logística de deslocamento e o monitoramento em tempo real das ocorrências e do combate aos incêndios.

## REFERÊNCIAS

AMARAL, R. P. F. **Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais**. 2017. Dissertação (Mestrado em Modelagem Computacional) – Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.

ANOCHI, J. A.; CAMPOS VELHO, H. F. de. **Optimization of feedforward neural network by Multiple Particle Collision Algorithm**. 2014. *IEEE Symposium on Foundations of Computational Intelligence (FOCI)*, 2014, pp. 128-134. DOI: 10.1109/FOCI.2014.7007817.

BASTOS, M. V. C. **Utilização de otimização evolucionária multiobjetivo no treinamento de redes neurais artificiais para a predição de tendência em séries financeiras**. 2018. Monografia (Graduação em Engenharia de Sistemas) - Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2018.

FERNANDES, L. C. **Modelagem de risco de incêndios florestais utilizando redes neurais artificiais aplicada às regiões metropolitanas**. 2019. Dissertação (mestrado em Análise e Modelagem de Sistemas Ambientais) - Universidade Federal de Minas Gerais: Belo Horizonte, 2019.

FERNANDES, L. C.; ELMIRO, M. A. T.; NERO, M. A.; TEMBA, P. C. The use of remote sensing techniques by Modis (MCD45A1) images using to identify and evaluate burned areas in the metropolitan region of Belo Horizonte - MG, Brazil. **Sustentabilidade em debate**, v. 11, 2020.

FERNANDES, L. C.; FERNANDES, R. S. C.; NERO, M. A.; TEMBA, P. C. Fire Risk Modeling Using Artificial Neural Networks. *In: Rodrigues, H. C.; et al. (Org.). EngOpt 2018 Proceedings of the 6th International Conference on Engineering Optimization*. 1 ed. Cham, Switzerland: Springer Nature Switzerland AG, v. 1, 2018a.

FERNANDES, L. C.; NERO, M. A.; TEMBA, P. C.; SOARES FILHO, B. S. Modelagem de risco de incêndios florestais: uma visão geral. **SODEBRÁS**, v. 13, 2018b.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, 2016.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016.

HAYKIN, S. **Neural networks and learning machines**. 3 ed. [S.l.]: Prentice Hall/Pearson, 2009.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-term Memory. **Neural Computation**, v. 9, n. 8, 1997. DOI:10.1162/neco.1997.9.8.1735.

JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. **Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence**. [S.l.]: Prentice Hall, 1997.

KURBIEL, T.; KHALEGHIAN, S. **Training of deep neural networks based on distance measures using RMSProp**. CoRR, abs/1708.01911, 2017.

LINNAINMAA, S. Taylor expansion of the accumulated rounding error. **BIT Numerical Mathematics**, v. 16, 1976. DOI: 10.1007/BF01931367.

MANDIC, D. P.; CHAMBERS, J. A. **Recurrent Neural Networks for Prediction: Learning algorithms, architectures, and stability**. London: John Wiley & Sons Ltd, 2001.



MINAS GERAIS. Corpo de Bombeiros Militar de Minas Gerais. **Memorando n. 3149 - EMBM: 4º esforço.** Belo Horizonte, 2018a.

MINAS GERAIS. Corpo de Bombeiros Militar de Minas Gerais. **Memorando n. 3153 - EMBM: Período Sazonal.** Belo Horizonte, 2018b.

MINAS GERAIS. Corpo de Bombeiros Militar de Minas Gerais. **Memorando n. 3143 - EMBM: Atuação em ocorrências de combate a incêndios florestais nas imediações da CAMG durante o Período de Estiagem 2017 e orientações 4º esforço.** Belo Horizonte, 2017.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais.** São Paulo: ABE- Projeto Fisher e Editora Edgard Blucher, 2004.

REBOITA, M. S.; MARRAFON, V. H. A.; LLOPART, M.; ROCHA, R.P. Cenários de mudanças climáticas projetados para o estado de Minas Gerais. **Revista Brasileira de Climatologia**, 2018. DOI: 10.5380/abclima.v1i0.60524.

SAFI, Y.; BOUROMI, A. Prediction of Forest Fires Using Artificial Neural Networks. **Applied Mathematical Sciences**, v. 7, n. 6, 2013.

SATIR, O.; BERBEROGLU, S.; DONMEZ, C. Mapping regional forest fire probability using artificial neural network model in a Mediterranean forest ecosystem. **Geomatics, Natural Hazards and Risk**, v. 7, n. 5, 2016. DOI: 10.1080/19475705.2015.1084541

SILVA, J. T. F. **Um Modelo Computacional de Redes Neurais para Localização de Faltas em Redes de Distribuição.** 2019. Monografia (Graduação em Engenharia de Controle e Automação) - Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2019.

STORER, J.; GREEN, R. PSO Trained Neural Networks for Predicting Forest Fire Size: A Comparison of Implementation and Performance. *In: International Joint Conference on Neural Networks (IJCNN)*, 2016. **Anais [...]** IEEE: Vancouver, 2016. DOI: 10.1109/ijcnn.2016.7727265.

TORRES, F. T. P. Relações entre fatores climáticos e ocorrências de incêndios florestais na cidade de Juiz de Fora(MG). **Caminhos de Geografia** - revista on line, v. 18, n. 7, 2016.

VIGANO, H. H. G. *et al.* Redes Neurais Artificiais na Previsão de Queimadas e Incêndios no Pantanal. **Revista Brasileira de Geografia Física**, v. 10, n. 5, 2017. DOI: 10.26848/rbgf.v.10.p1355-1367.

VIGANO, H. H. G. **Redes Neurais Artificiais e Análise Multivariada de Séries Temporais para a Modelagem da Previsão de Queimadas e Incêndios no Pantanal.** 2017. Tese (Doutorado em Meio Ambiente e Desenvolvimento Regional) - Universidade Anhanguera-Uniderp: Campo Grande, 2017.

WERBOS, P. J. Backpropagation through time: What it does and how to do it. **Proceedings of the IEEE**, v. 78, n. 10, 1990. DOI: 10.1109/5.58337.