

XXVI JORNADAS DE JOVENS PESQUISADORES
ASSOCIAÇÃO DE UNIVERSIDADES DO GRUPO MONTEVIDÉU – AUGM

ANEXO I

FORMULÁRIO DE IDENTIFICAÇÃO
XXVI – JORNADAS DE JOVENS PESQUISADORES

<u>Informações pessoais</u>	Nome:	Luiza Cintra Fernandes	
	E-mail principal:	luizacintra@gmail.com	
	E-mail alternativo:	luiza_cintra_@hotmail.com	
	Telefone celular:	(12) 99728-2855	
	Telefone residencial:		
	Data de nascimento:	17/02/1992	
	RG:	48.733.779-7	
	Data de expedição RG:	15/09/2010	
	CPF:	399.318.108-58	
	Endereço:	Av. Miguel Perrela, no 766, apt 503 bl 3	
		cep: 31330-290, Belo Horizonte-MG, Brazil	
<u>Passaporte (se tiver)</u>	País onde nasceu:	Brasil	
	Nome conforme consta no passaporte:	Luiza Cintra Fernandes	
	País de cidadania:	Brasil	
	Número:	FT968601	
	Válido até:	27/08/2027	
<u>Dados acadêmicos</u>	Curso na UFMG:	Análise e Modelagem de Sistemas Ambientais	
	Nível acadêmico:	mestrado	
	Número de Matrícula:	2017656237	

24. Meio Ambiente

Modelagem de risco de incêndio utilizando Redes Neurais Artificiais

Fernandes, Luiza C.¹; luizacintra@gmail.com; Cintra, Rosangela S. C.²; rocindra@gmail.com; Nero, Marcelo A.¹; marcelo-nero@ufmg.br; Temba, Plínio C.; temba.mobile@gmail.com

¹ Universidade Federal de Minas Gerais (UFMG)

² Instituto Nacional de Pesquisas Espaciais (INPE)

Resumo

Incêndios florestais causam muitas alterações no clima e no meio ambiente, sendo uma das grandes preocupações relacionadas ao meio ambiente, sua prevenção e controle. Assim, para auxiliar no planejamento de atividades para sua prevenção, o cálculo do risco de incêndios se faz uma importante ferramenta, determinando a probabilidade das ocorrências destes em determinado local. Este trabalho tem como objetivo fazer o mapeamento das regiões de risco de incêndio no Município de Belo Horizonte. A modelagem proposta será realizada através de Redes Neurais Artificiais (RNA) com treinamento supervisionado. Espera-se obter uma rede neural para fazer a previsão de áreas propícias aos incêndios, apresentando as variáveis de entrada de qualquer período que se deseja determinar. Esta estimativa dará o delineamento de áreas prioritárias através de mapas que auxiliarão em atividades de prevenção e alocação de equipes brigadistas, buscando minimizar possíveis danos causados pelos incêndios. O que se concluiu foi que usar RNA para prever áreas de risco de fogo é uma metodologia que obtém boas respostas, mas é necessário se ter cuidado na escolha das variáveis de entrada. Nesse estudo a rede pode encontrar muito bem os pontos de incêndio, mas não reconheceu com muito acurácia áreas de baixo risco.

Palavras-Chave: Risco de Incêndios, Redes Neurais Artificiais, Modelagem

Modelagem de risco de incêndio utilizando Redes Neurais Artificiais

Fernandes, Luiza C.¹; Cintra, Rosangela S. C.²; Nero, Marcelo A.¹; Temba, Plínio C.

luizacintra@gmail.com; rocintra@gmail.com; marcelo-nero@ufmg.br;

temba.mobile@gmail.com

¹ Universidade Federal de Minas Gerais (UFMG)

² Instituto Nacional de Pesquisas Espaciais (INPE)

Resumo

Incêndios florestais causam muitas alterações no clima e no meio ambiente, sendo uma das grandes preocupações relacionadas ao meio ambiente, sua prevenção e controle. Assim, para auxiliar no planejamento de atividades para sua prevenção, o cálculo do risco de incêndios se faz uma importante ferramenta, determinando a probabilidade das ocorrências destes em determinado local. Este trabalho tem como objetivo fazer o mapeamento das regiões de risco de incêndio no Município de Belo Horizonte. A modelagem proposta será realizada através de Redes Neurais Artificiais (RNA) com treinamento supervisionado. Espera-se obter uma rede neural para fazer a previsão de áreas propícias aos incêndios, apresentando as variáveis de entrada de qualquer período que se deseja determinar. Esta estimativa dará o delineamento de áreas prioritárias através de mapas que auxiliarão em atividades de prevenção e alocação de equipes brigadistas, buscando minimizar possíveis danos causados pelos incêndios. O que se concluiu foi que usar RNA para prever áreas de risco de fogo é uma metodologia que obtêm boas respostas, mas é necessário se ter cuidado na escolha das variáveis de entrada. Nesse estudo a rede pode encontrar muito bem os pontos de incêndio, mas não reconheceu com muito acurácia áreas de baixo risco.

Palavras-Chave: Risco de Incêndios, Redes Neurais Artificiais, Modelagem

Introdução

Incêndios florestais são uma das grandes preocupações relacionada com o meio ambiente, pois devastam grandes proporções de florestas, campos e regiões agrícolas. Entre os seus principais impactos estão à destruição da fauna e flora, erosão, degradação do solo, enfraquecimento das árvores, destruição de habitats, danos à saúde humana e redução da beleza da paisagem (Roy, 2004). Além de causar aumento de gases na atmosfera, tais como: CO₂ (dióxido de carbono), CH₄ (gás metano) e NO_x (óxidos nitrosos), responsáveis pelo aumento do efeito estufa e de problemas respiratórios (Ichoku & Kaufman, 2005).

O cálculo do risco de incêndios consiste em verificar a probabilidade de ocorrer incêndio em determinado local, ou seja, determinar a chance de ignição (Hardy, 2005). Assim é possível se fazer uma avaliação crítica da ocorrência de incêndios, para se ter o monitoramento e prevenção de queimadas dessas áreas, para isso são necessárias ferramentas objetivas (Chuvienco et al., 2010).

A importância em se determinar áreas com maior risco de incêndio está relacionada com o planejamento de atividades para sua prevenção. Assim, é possível determinar as estações em que ocorrem mais queimadas, permitindo queimadas controladas ou prevenção e combate destas, permite ainda informar a população dos riscos e fazer programas de educação ambiental e em casos extremos limitar o acesso à área (Nunes, 2006).

As variáveis usadas para o cálculo do risco de incêndio podem ser de dois tipos: uma derivada de fatores que não mudam em um curto período de tempo, chamadas estáticas, e aquelas que variam em períodos mais curtos, chamadas dinâmicas. As primeiras englobam declividade, tipos de vegetação, tipos de solo, e proximidade de estradas e assentamentos. Das variáveis podem-se citar as variáveis meteorológicas, como, temperatura, intensidade do vento, umidade entre outras (López, San-Miguel-Ayanz, & Burgan, 2002).

Há várias abordagens para se modelar o risco de fogo: métodos estatísticos, como regressão logística, métodos quantitativos e qualitativos, baseados em conhecimento de especialista, como a análise multicritério. Além de métodos de inteligência artificial, como Redes Neurais Artificiais (RNA) e Lógica Fuzzy, que têm sido muito usados e retornado resultados de grande acurácia como (Alonso-Betanzos et al., 2003; Ferreira, Koproski, & Zanotta, 2011; Goldarag, Mohammadzadeh, & Ardakani, 2016; Luiz de Sá de Oliveira, 2013; Maeda, Formaggio, Shimabukuro, Arcoverde, & Hansen, 2009; Silva & Pontes, 2011).

A região Sudeste do Brasil apresenta muitos focos de incêndio no inverno, quando o tempo está mais seco, o que coincidem com o registro do aumento de concentrações de material particulado no ar, dados observados pelas estações de monitoramento do ar da Fundação Estadual do Meio Ambiente (FEAM) de Minas Gerais.

Assim o objetivo deste artigo é mapear áreas de risco de incêndios na cidade de Belo Horizonte, localizada no estado de Minas Gerais, na região Sudeste do Brasil. A modelagem proposta é criar uma rede neural artificial com treinamento supervisionado. Esta RNA fará a previsão de áreas mais propícias a incêndios, apresentando as variáveis de entrada de qualquer período que se deseja determinar. Esta estimativa dará o delineamento de áreas prioritárias através de mapas que auxiliarão em atividades de prevenção e alocação de equipes brigadistas, buscando minimizar possíveis danos causados pelos incêndios.

Área de Estudo

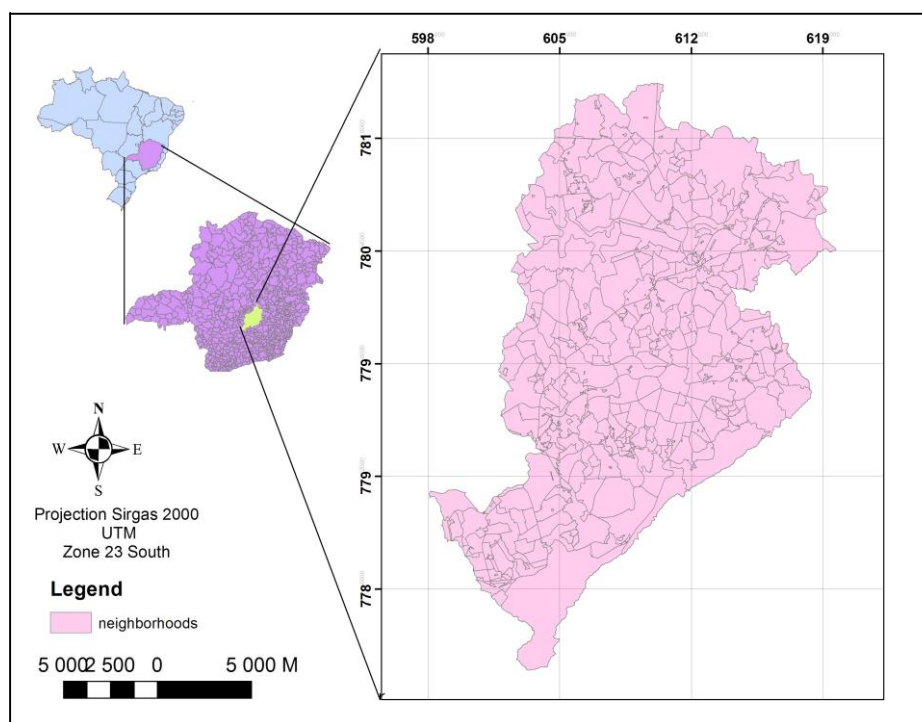


Figura 1 - Localização área de estudo

Com 330,01 km² de área, a cidade de Belo Horizonte (Figura 1) tem uma população de 2,4 milhões segundo o censo de 2010 e uma densidade de 7167 hab/km². Possui um PIB per capita de aproximadamente 35000 reais, e um IDH de 0,81 (IBGE, 2017). Estando inserida na terceira maior região metropolitana do Brasil, denominada por Veloso et al. (1991) uma “Área de Tensão Ecológica”. É uma faixa de transição e contato entre dois grandes biomas: o Cerrado e a Mata Atlântica, ambos internacionalmente considerados como "hotspots" de Biodiversidade, demandando medidas concretas de proteção e conservação. É uma cidade muito arborizada, com 82.7 % dos domicílios urbanas em vias públicas com arborização. Sendo suas fisionomias vegetais originais representadas por campos, cerrado, savanas e floresta tropical, que estão espalhados em parques municipais ou institutos federais pela cidade (Secretaria Municipal de Planejamento, 2000).

O clima da região onde se encontra a área de estudo é definido por NIMER (1979), como Tropical subquente semi-úmido e estação de seca bem definida, com duração de 4 a 5 meses, entre abril e setembro. Sendo que 80% dos casos de precipitação anual na cidade ocorrem durante a estação chuvosa (LUCAS & ABREU, 2004). A Região do Município de Belo Horizonte, apresenta épocas de baixa umidade, principalmente no inverno, devido à

presença de anticiclones que trazem massas de ar seco e abaixam a temperatura e umidade. Em um estudo (Franca, 2009) foi observado que a umidade relativa do ar na cidade está decrescendo. Essa baixa umidade deixa a região propícia a incêndios florestais.

Materias e Métodos

Variáveis de entrada

Declividade: Afeta o comportamento do vento e a direção, o fogo propaga mais rápido em regiões de maior declividade, afetando a intensidade e a direção do fogo (Vadrevu, Eaturu, & Badarinath, 2010). A declividade foi calculada pela função *terrain*, no pacote *raster* do programa R, aonde os dados de elevação usados de entrada foram do SRTM (Shuttle Radar Topography Mission), que está disponível no site da USGS (n.d.).

Aspecto: Descreve a orientação do terreno e é importante para ter-se o conhecimento das faces que tem maior influência do calor direto do sol, que afeta a taxa de secagem do material combustível (Juvanhol, 2014). O cálculo do aspecto foi feito com a mesma função da declividade.

Uso e cobertura do solo: Compreende a caracterização da cobertura do solo e suas localidades. Assim é possível saber a distribuição e quantificação de áreas de vegetação, campos, agricultura, áreas urbanas, entre outras (Prudente, 2010). A vegetação afeta o tipo e as propriedades do material combustível e condições meteorológicas associadas. Essa variável é também importante para conhecer a influência humana através de proximidades a estradas e assentamentos. O mapa usado foi produzido pela Prodabel (Companhia de Informática e Informação da cidade de Belo Horizonte) em 2012. A classificação foi extraída utilizando como referência as imagens ortorretificadas, através de interpretações visuais e prática manual para as classes temáticas. As classes da imagem original possuíam 3 níveis de detalhes, que foram agrupados em 29 classes. O mapa foi transformado em *raster* com um tamanho de célula de 100m, no programa ArcGis.

Variáveis meteorológicas: Foram coletados do INMET (Instituto Nacional de Meteorologia do Brasil) de estações automáticas e manuais. Mapas mensais, de 2014 a 2016, de todos os parâmetros foram interpolados usando a função *Thin Plate Spline*, do pacote *rgdal* do R.

Temperatura média: Representa a energia interna do movimento de átomos e moléculas, importante na fase de combustão (Hamadeh, Karouni, Daya, & Chauvet, 2017). Temperaturas mais altas deixam a vegetação mais susceptível a incêndios, predispondo-a a ignição, e reduzindo a umidade do material (Liu & Zhang, 2015). Os dados usados estão em graus Celsius.

Pressão do ar: As mudanças meteorológicas dependem da pressão atmosférica. Pressões mais altas tendem a ter maiores temperaturas e baixa umidade, deixando

condições climáticas propícias a fogo (Liu & Zhang, 2015). Os dados usados estão em hPa.

Umidade Relativa do ar: Representa a relação entre a quantidade de água no ar e o máximo de água que o ar consegue segurar na mesma temperatura e pressão (Hamadeh et al., 2017). Quanto maior a umidade do ar, maior a absorção de umidade pelo material combustível (Liu & Zhang, 2015).

Velocidade do Vento: É o movimento do ar na distância horizontal por unidade de tempo. Pode acelerar a evaporação de água do material combustível, deixando-o seco e inflamável. O vento também aumenta o fornecimento de oxigênio, aumentando as condições para combustão (Liu & Zhang, 2015). A unidade usada é em m/s.

Radiação: Representa a quantidade de energia do sol recebida pela Terra na forma de ondas eletromagnéticas. Este tipo de radiação é a principal fonte de energia que o globo possui, e sua distribuição variável no tempo e no espaço é o gerador de todos os processos atmosféricos (Liu & Zhang, 2015). A unidade utilizada é em Kj/m^2 .

Variável de Saída: Dados de Incêndio

Produtos de fogo ativo têm informações sobre localização e hora de incêndios que ocorreram na hora da passada do satélite, dados em forma de uma lista de pixels de fogo com suas localizações e datas. Neste artigo foram usados dois produtos de fogo ativo: Near real-time(NRT) Moderate Resolution Imaging Spectroradiometer (MODIS) Thermal Anomalies/Fire locations- Collection 6, que usam produtos da faixa (MOD14/ MYD14), com resolução de 1 km e Near real-time (NRT) Suomi National Polar-orbiting Partnership (Suomi-NPP) Visible Infrared Imaging Radiometer Suite (VIIRS) Active Fire detection produto, que tem resolução de 375 m.

Os pontos de fogo foram especializados de acordo com suas coordenadas, convertidos em *raster*, com resolução de 1km, onde o valor 1 representa ocorrência de incêndios e 0 representa não ocorrência.

Arranjo dos dados

Todos os dados foram colocados na mesma projeção, Sirgas 2000, na mesma extensão e resolução, usando o pacote *rgdal* do R. Resultando em uma grade regular de 100 m, com 313 linhas e 217 colunas.

Os meses de agosto, setembro e outubro foram selecionados devido sua frequência de incêndios. Para cada pixel de fogo no mapa foram relacionadas cada um dos 8 parâmetros, gerando amostras de entrada para a RNA. Para as amostras de não ocorrência de fogo eram muito maiores que os de ocorrência, a área foi dividida em quadrados de 1 km e foram selecionados pontos aleatórios.

Os dados de 2014 a 2015 foram usados para ajustar a RNA, e as amostras foram divididas: treinamento (60%), validação (20%) e teste (20%). E os dados de 2016 foram usados para avaliar o desempenho da RNA, sendo usados pixels da área toda.

Redes Neurais Artificiais

Uma rede neural é constituída de unidades de processamento simples que trabalham em paralelo, armazenando conhecimento experimental e tornando-o disponível para uso. Se assemelhando ao cérebro em dois aspectos: o conhecimento adquirido pela rede pelo processo de aprendizagem e as forças de conexão entre os neurônios, conhecidas como pesos sinápticos, que armazenam o conhecimento adquirido (Haykin, 2001). Entre seus benefícios estão a possibilidade de não linearidade, o fato de mapear entradas e saídas, através de treinamento supervisionado, que permite a RNA a ser adaptável, modificando seus pesos sinápticos de acordo com mudanças no meio ambiente (Haykin, 2001).

Há muitas arquiteturas para a RNA, destas o *Perceptron* Multicamadas de alimentação direta é o mais usado, representado na Figura 2, que tem duas camadas escondidas, sendo que cada entrada (x) é multiplicada por um peso (w) e a soma das entradas com os pesos e o viés(b) resulta em uma função de transferência ($f(x)$), que se transforma em entrada para a camada seguinte. A camada de entrada representa o nó de fonte, que provê os sinais iniciais e a camada de saída é a resposta a entrada (Haykin, 2001).

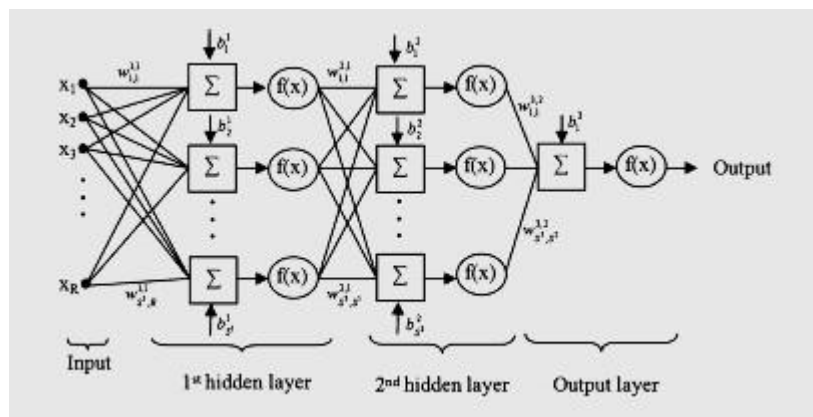


Figura 2 – Modelo de um Perceptron Multicamadas

A função de transferência é importante porque restringe a amplitude do sinal do neurônio de saída, podendo definir ou não a linearidade da saída. As utilizadas nesse artigo são a sigmoide logística (Eq. 1) e a linear (Eq. 2).

$$f(v)=nv \quad (1)$$

$$f(v) = \frac{1}{1 + \exp(-\beta v)} \quad (2)$$

O treinamento da RNA é muito importante para o aprendizado da rede e melhorar seu desempenho. É usado um processo iterativo de ajuste dos pesos e viés. Geralmente os dados são divididos em 3 subgrupos. O primeiro consiste nos padrões fornecidos à rede para os ajustes dos seus parâmetros (aprendizagem), o segundo conjunto tem a tarefa da verificação da capacidade de generalização da rede (validação) e o conjunto de teste tem a tarefa de testar o comportamento da rede neural com dados novos (Anochi & Campos Velho, 2014). O aprendizado supervisionado é o treinamento aonde é dada a saída desejada e os parâmetros são ajustados baseados nestes (Goulart et al., 2006).

O treinamento é geralmente feito pelo algoritmo de retro-propagação (backpropagation), baseado na regra Delta que minimiza a função de erro. Consistindo em dois passos: o passo para frente e o passo para trás, aonde o erro é retro-propagado da camada de saída para a de entrada. E o delta é dado pelo gradiente da função de transferência. O algoritmo Levenberg-Marquardt que foi utilizado nesse artigo, diferente da retro-propagação, que possui um algoritmo de descida mais íngreme, é uma aproximação ao método de Newton, usado para acelerar a convergência do algoritmo de aprendizado de retro-propagação.

Esses algoritmos foram implementados pelo “neural network toolbox” do matlab.

Resultados e Discussão

Depois de testar várias arquiteturas de rede com diferentes números de neurônios na camada escondida, o menor erro foi obtido com 15 neurônios na camada escondida. Assim a RNA final tinha 8 neurônios na camada de entrada, 15 neurônios na camada oculta e 1 na de saída. A função de transferência usada foi a sigmoide logística na primeira camada e função linear na segunda camada e foi treinada com o algoritmo Levenberg-Marquardt.

Dos resultados os valores próximos de 1 foram considerados como alto risco, e os próximos de 0 como baixo risco de incêndios. Na Tabela 1 pode ser vista a classificação dos pixels dos dados usados para ajustar a RNA. O que pode ser notado foi que a maioria dos pixels foram considerados como alto risco, por outro lado, os pontos de ocorrência de fogo corresponderam com áreas de alto risco, o que é um bom resultado.

Tabela 1 - Resultados da RNA com os dados de ajuste da rede

Porcentagem	Risco	Pixels	Pixels de ocorrência de fogo
0-0.25	Baixo	3.84%	0.05%
0.25-0.5	Medio	2.83%	0.36%

0.5-0.75	Alto	9.01%	6.95%
0.75-1	Muito Alto	84.33%	92.64%

Nos dados de 2016 (Tabela 2), que não foram usados no ajuste da RNA, pode ser visto que quase todos os pixels foram classificados como alto e muito alto. E todos os pontos de ocorrência de fogo foram classificados em áreas de risco muito alto.

Tabela 2 - Resultados da RNA com dados de 2016

Data	Porcentagem	Risco	Pixels	Pixels de ocorrência de fogo
agosto/2016	0-0.25	Baixo	0.0%	0.0%
	0.25-0.5	Medio	0.9%	0.0%
	0.5-0.75	Alto	4.3%	0.0%
	0.75-1	Muito Alto	94.8%	100.0%
setembro/2016	0-0.25	Baixo	0.0%	0.0%
	0.25-0.5	Medio	0.0%	0.0%
	0.5-0.75	Alto	3.8%	0.0%
	0.75-1	Muito Alto	96.2%	100.0%
outubro/2016	0-0.25	Baixo	0.0%	0.0%
	0.25-0.5	Medio	6.1%	0.0%
	0.5-0.75	Alto	8.1%	0.0%
	0.75-1	Muito Alto	85.8%	100.0%

Assim a rede pode reconhecer os pontos de fogo muito bem, mas também quase toda área foi reconhecido como alto risco. Isso pode ser devido a pequena variação dos parâmetros meteorológicos na área inteira, já que são a maioria das entradas (5 entradas). Também foram selecionados meses que continham condições meteorológicas similares, como baixa precipitação e umidade, sendo esperado áreas de alto risco de incêndios nessa época. A maior parte da área é classificada como urbana, e é visto na literatura que a proximidade a áreas urbanas tem risco de incêndio mais alto por causa da influência humana, então esse pode ter sido outro fator de influência.

Goldarag et al. (2016) fez uma abordagem similar com uma rede neural com 12 variáveis (declividade, aspecto, cobertura do solo, NDVI, temperatura do ar, dias com precipitação, duração do sol, vento predominante, umidade relativa, altitude, distancia de estradas e da cidade), sendo 6 variáveis dinâmicas e 6 estáticas em uma área de 268 km², sendo que foram previstos 95% dos pontos de fogo. Alonso-Betanzos et al. (2003) usou sua rede apenas com parâmetros meteorológicos em uma área de 360 km², e teve uma acurácia de 80 %. Maeda et al. (2009) usou de entrada imagens NDVI, que são muito sensíveis a mudanças na vegetação, e obteve um Erro quadrático médio de 0.07.

Conclusão

Usar Redes Neurais Artificiais para prever áreas de risco de fogo é uma metodologia que obtêm boas respostas, mas é necessário se ter cuidado na escolha das variáveis de entrada. Nesse estudo a rede pode encontrar muito bem os pontos de incêndio, mas não reconheceu com muito acurácia áreas de baixo risco.

Em estudos futuros podem ser adicionadas mais variáveis estáticas, como imagens NDVI e distância a rodovias e assentamentos. Também será interessante ao estudo verificar um período maior de tempo, para verificar mudanças de estações em variáveis meteorológicas.

Referências

- Alonso-Betanzos, A., Fontenla-Romero, O., Guijarro-Berdiñas, B., Hernández-Pereira, E., Paz Andrade, M. I., Jiménez, E., ... Carballas, T. (2003). An intelligent system for forest fire risk prediction and fire fighting management in Galicia. *Expert Systems with Applications*, 25(4), 545–554. [https://doi.org/10.1016/S0957-4174\(03\)00095-2](https://doi.org/10.1016/S0957-4174(03)00095-2)
- Anochi, J. A., & Campos Velho, H. F. de. (2014). Optimization of feedforward neural network by Multiple Particle Collision Algorithm. In *2014 IEEE Symposium on Foundations of Computational Intelligence (FOCI)* (pp. 128–134). Orlando, FL: IEEE. <https://doi.org/10.1109/FOCI.2014.7007817>
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Salas, J., Martín, M. P., ... Zamora, R. (2010). Development of a framework for fire risk assessment using remote sensing and geographic information system technologies. *Ecological Modelling*, 221(1), 46–58. <https://doi.org/10.1016/j.ecolmodel.2008.11.017>
- Ferreira, M. P., Koproski, L., & Zanotta, D. C. (2011). Uma abordagem fuzzy no zoneamento de risco de incêndio. In *In: XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR* (pp. 4555–4562). Curitiba, PR. Retrieved from https://www.researchgate.net/publication/277816639_Uma_abordagem_fuzzy_no_zoneamento_de_risco_de_incendio
- Franca, R. R. da. (2009). *Anticiclones e umidade relativa do ar: um estudo sobre o clima de Belo Horizonte*. Universidade Federal de Minas Gerais.
- Goldarag, Y. J., Mohammadzadeh, A., & Ardakani, A. S. (2016). Fire Risk Assessment Using Neural Network and Logistic Regression. *Journal of the Indian Society of Remote Sensing*, 44(6), 885–894. <https://doi.org/10.1007/s12524-016-0557-6>
- Goulart, D. A., Tacla, M. A., Marback, P. M. F., Solé, D., Paranhos, A., Perez, H. B., ... Sato, E. H. (2006). Redes neurais artificiais aplicadas no estudo de questionário de varredura

- para conjuntivite alérgica em escolares. *Arquivos Brasileiros de Oftalmologia*, 69(5), 707–713. <https://doi.org/10.1590/S0004-27492006000500017>
- Hamadeh, N., Karouni, A., Daya, B., & Chauvet, P. (2017). Using correlative data analysis to develop weather index that estimates the risk of forest fires in Lebanon & Mediterranean: Assessment versus prevalent meteorological indices. *Case Studies in Fire Safety*, 7, 8–22. <https://doi.org/10.1016/j.csfs.2016.12.001>
- Hardy, C. C. (2005). Wildland fire hazard and risk: Problems, definitions, and context. *Forest Ecology and Management*, 211(1–2), 73–82. <https://doi.org/10.1016/J.FORECO.2005.01.029>
- Haykin, S. (2001). *Redes Neurais: Princípios e prática* (2a ed.). Porto Alegre: Bookman.
- IBGE, (Instituto Brasileiro de Geografia e Estatística). (2017). Panorama Belo Horizonte. Retrieved from <https://cidades.ibge.gov.br/brasil/mg/belo-horizonte/panorama>
- Ichoku, C., & Kaufman, Y. J. (2005). A method to derive smoke emission rates from MODIS fire radiative energy measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 43(11), 2636–2649. <https://doi.org/10.1109/TGRS.2005.857328>
- Juvanhol, R. S. (2014). *Modelagem da vulnerabilidade à ocorrência e propagação de incêndios florestais*. Universidade Federal do Espírito Santo.
- Liu, D., & Zhang, Y. (2015). Research of regional forest fire prediction method based on multivariate linear regression. *International Journal of Smart Home*, 9(1), 13–22. <https://doi.org/10.14257/ijsh.2015.9.1.02>
- López, A. S., San-Miguel-Ayanz, J., & Burgan, R. E. (2002). Integration of satellite sensor data, fuel type maps and meteorological observations for evaluation of forest fire risk at the pan-European scale. *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431160110107761>
- LUCAS, T. P. B., & ABREU, M. L. (2004). Caracterização climática dos padrões de ventos associados a eventos extremos de precipitação em Belo Horizonte - MG. *Cadernos de Geografia*, 14(23), 135–152.
- Luiz de Sá de Oliveira, A. (2013). Modelagem espacial de predição de riscos de incêndios com lógica fuzzy, comparação e validação.
- Maeda, E. E., Formaggio, A. R., Shimabukuro, Y. E., Arcoverde, G. F. B., & Hansen, M. C. (2009). Predicting forest fire in the Brazilian Amazon using MODIS imagery and artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 11(4), 265–272. <https://doi.org/10.1016/j.jag.2009.03.003>
- NIMER, E. (1979). *Climatologia do Brasil*. Rio de Janeiro.
- Nunes, R. S. (2006). FMA + - um novo índice de perigo de incêndios florestais para o estado do Paraná - Brasil. *Floresta*, 36(1), 75–91.
- Prudente, T. D. (2010). *Geotecnologias Aplicadas ao mapeamento de risco de incêndio*

florestal no parque nacional da chapada dos veadeiros e área de entorno.

Universidade Federal de Uberlândia.

Roy, P. S. (2004). Forest fire and degradation assessment using satellite remote sensing and geographic information system. In M. V. K. Sivakumar, P. S. Roy, K. Harmsen, & S. K. Saha (Eds.), *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology* (pp. 361–400). Geneva, Switzerland: World Meteorological Organisation.

Secretaria Municipal de Planejamento. (2000). Plano global para a área do Isidoro: Flora e cobertura vegetal. Prefeitura Municipal de Belo Horizonte, Belo Horizonte. Retrieved from <http://plataformaurbanismobiopolitico.indisciplinar.com/wp-content/uploads/2015/11/Plano-global-para-a-área-do-Isidoro-flora-e-cobertura-vegetal.pdf>

Silva, I. D. B. da, & Pontes, A. C. F. J. (2011). Elaboração de um Fator de Risco de Incêndios Florestais utilizando Lógica Fuzzy, *21*, 113–128.

USGS, (U.S. Department of the Interior U.S. Geological Survey). (n.d.). EarthExplorer. Retrieved from <https://earthexplorer.usgs.gov/>

Vadrevu, K. P., Eaturu, A., & Badarinath, K. V. S. (2010). Fire risk evaluation using multicriteria analysis—a case study. *Environmental Monitoring and Assessment*, *166*(1–4), 223–239. <https://doi.org/10.1007/s10661-009-0997-3>

VELOSO, H.P.; RANGEL FILHO, A.L.R.; LIMA, J. C. . (1991). *Classificação da vegetação brasileira, adaptada a um sistema universal*. IBGE, Rio de Janeiro.