

THAYNARA LOPES DOS REIS

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA E SIG EM ESTUDOS DE
INCÊNDIOS FLORESTAIS**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

Orientador: Fillipe Tamiozzo Pereira Torres
Coorientador: Hélio Garcia Leite

**VIÇOSA – MINAS GERAIS
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

R375a Reis, Thaynara Lopes dos, 1994-
2021 Aplicação de aprendizado de máquina e SIG em estudos de
incêndios florestais / Thaynara Lopes dos Reis. – Viçosa, MG,
2021.

1 dissertação eletrônica (72 f.): il. (algumas color.).

Orientador: Fillipe Tamiozzo Pereira Torres.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2021.067>

Modo de acesso: World Wide Web.

1. Incêndios florestais - Previsão - Modelos matemáticos.
2. Incêndios florestais - Prevenção e controle. 3. Redes neurais
(Computação). 4. Inteligência artificial. 5. Fogo. I. Universidade
Federal de Viçosa. Departamento de Engenharia Florestal.
Programa de Pós-Graduação em Ciência Florestal. II. Título.

CDO adpt. CDD 22. ed. 634.943216

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

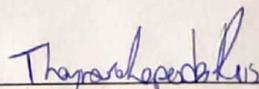
THAYNARA LOPES DOS REIS

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA E SIG EM ESTUDOS DE
INCÊNDIOS FLORESTAIS**

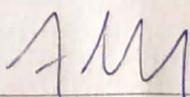
Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

APROVADA: 09 de julho de 2021.

Assentimento:



Thaynara Lopes dos Reis
Autora



Fillipe Tamiozzo Pereira Torres
Orientador

*A Deus, meu tesouro e minha razão de viver,
aos meus pais, pelo amor incondicional, à
minha irmã, por todo apoio e companhia, e ao
meu noivo, por ser meu José, dedico esse
trabalho.*

AGRADECIMENTOS

Essa, provavelmente, é a parte mais difícil de escrever. Reconhecer – com palavras – todo amor e gratidão pelas pessoas não é uma tarefa fácil. Porém, irei tentar e espero que todos aqueles que ajudaram na realização desse trabalho se sintam muito especiais. São eles:

A Deus, pelo dom da vida, por me amar sem medidas, guiar os meus passos, cuidar de mim e me dar forças para não desistir dos meus sonhos.

À Nossa Senhora e toda milícia celeste, pela poderosa intercessão e proteção.

À Igreja Católica, nas figuras dos estimados amigos Pe. Paulo Dionê, pároco da Paróquia Santa Rita de Cássia, Pe. Sérgio José, Pe. Lucas Germano e Pe. Márcio Henrique, por alimentar a minha alma com a Palavra de Deus e com o Pão Vivo descido do céu, a Sagrada Eucaristia, a fim de que eu viva eternamente no reino celeste.

Aos meus pais, Geraldo e Nilce, por serem minha base, pelo carinho, amor e compreensão, e por acreditarem em mim quando eu mesma não acredito. Vocês são essenciais em minha vida. Amo muito vocês!

À minha irmã, Thaís, por sempre me apoiar, incentivar e por celebrar cada vitória que alcanço em minha vida. Te amo muito!

Ao meu noivo, Douglas, pelo respeito, paciência, parceria, cumplicidade, amor e carinho. Em você eu sei que sempre encontrarei um abrigo. Agradeço, principalmente, por me fazer sonhar com o Céu a todo tempo. Amo muito você!

Aos grupos católicos Adolescentes Seguidores de Cristo (ASC), Jovens Seguidores de Cristo (JSC), e Eternos Seguidores de Cristo (ESC), por me presentarem com um pai espiritual, o sr. Cônego José Geraldo Vidigal de Carvalho, e com amigos que são luzes de Deus em minha vida. Vivi e vivo momentos intensos e profundos nesses solos santos, por isso, nunca me contento com o caminho até aqui percorrido! Amo vocês!

Ao excelente orientador, professor Fillipe Tamiozzo, pelas oportunidades e ensinamentos durante todos esses anos. Obrigada também por toda paciência e prontidão em me ajudar, independente da hora.

Ao estimado coorientador, professor Hélio Garcia Leite, por todo conhecimento compartilhado e dúvidas esclarecidas. Seus ensinamentos, generosidade e humildade contribuíram não só para meu crescimento profissional, mas, também, como ser humano.

Ao Vinícius Barros Rodrigues, por todas valiosas correções e sugestões que, certamente, fizeram com que esse trabalho ficasse ainda melhor.

Às minhas amigas, Tamara Braga e Fábiana Souza, pelo excelente convívio e por todo apoio físico e emocional durante esses anos. Vocês são grandes inspirações!

Ao Ricardo Neto, por me auxiliar no desenvolvimento desse trabalho, por ser um grande exemplo de profissional dedicado e que está sempre disposto a ajudar.

Ao Heitor Carvalho, por sempre sanar minhas dúvidas com uma explicação fantástica.

À Universidade Federal de Viçosa, ao Departamento de Engenharia Florestal e ao Programa de Pós-Graduação em Ciência Florestal, por terem oferecido conhecimento para meu crescimento acadêmico e estrutura para a execução deste trabalho.

À agência financiadora desse trabalho, CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), pela bolsa de estudos ao longo desses dois anos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Aos demais amigos e colegas, por me ajudarem ao longo de toda a minha vida, seja com orações ou com a presença de cada um.

Por fim, agradeço a todos que contribuíram direta ou indiretamente para a realização deste trabalho e não foram aqui citados.

“Deves manter – ao longo do dia – uma constante conversa com o Senhor, que se alimente também das próprias ocorrências da tua tarefa profissional. Vai com o pensamento ao Sacrário... e oferece ao Senhor o trabalho que tiveres entre mãos” (São Josemaría Escrivá)

RESUMO

REIS, Thaynara Lopes dos, M.Sc., Universidade Federal de Viçosa, julho de 2021. **Aplicação de aprendizado de máquina e SIG em estudos de incêndios florestais.** Orientador: Fillipe Tamiozzo Pereira Torres. Coorientador: Hélio Garcia Leite.

Os incêndios florestais causam grandes impactos, como desastres ecológicos, diminuição da qualidade da água e perda de vidas humanas e de animais. Entender o comportamento do fogo permite prever as situações de perigo e os impactos dos incêndios. Através de modelos de previsão construídos utilizando redes neurais artificiais (RNA), pode ser possível prever esse comportamento. Para diminuir o perigo de incêndios florestais, é necessário entender as variáveis que mais propiciam o início e propagação do fogo e as áreas mais suscetíveis. Isto é possível a partir da utilização de Sistemas de Informações Geográficas (SIG), onde são criados mapas de suscetibilidade, que avaliam potenciais ocorrências em função de fatores ambientais. Dessa forma, este trabalho foi subdividido em dois capítulos para melhor entender o teor de umidade dos materiais combustíveis, o comportamento do fogo e as variáveis que favorecem a suscetibilidade a incêndios florestais. No primeiro capítulo, configurou-se redes neurais artificiais para previsão da umidade do material combustível de diferentes classes de espessura e do comportamento do fogo em plantios de eucalipto. As variáveis dias sem chuva (Dsch) e umidade relativa do ar (UR) são as que mais contribuem para a umidade do material combustível e a velocidade do vento (VV) e a umidade relativa do ar (UR) são as que mais contribuem para o comportamento do fogo. No segundo capítulo, analisou-se as classes de variáveis ambientais que controlam a ocorrência de incêndios florestais em Coimbra, Portugal, e, a partir delas, confeccionou-se mapas de suscetibilidade a incêndios florestais para a região. As classes que obtiveram maiores porcentagens de áreas queimadas foram: Florestas, >400 m, 0–15° e alto acumulado, para as variáveis uso do solo, proximidades, inclinação do terreno e radiação solar, respectivamente. O SIG se mostrou uma ferramenta eficiente na análise de suscetibilidade a incêndios, pois o modelo escolhido para o mapeamento de suscetibilidade a incêndios na região apresentou maiores somas dos valores das classes “alta” e “altíssima” e menores somas das classes “baixa” e “baixíssima”.

Palavras-chave: RNA. Modelos de previsão. Monitoramento. Suscetibilidade a incêndios. Inteligência artificial. Fogo.

ABSTRACT

REIS, Thaynara Lopes dos, M.Sc., Universidade Federal de Viçosa, July 2021. **Application of machine learning and GIS in forest fires studies.** Advisor: Fillipe Tamiozzo Pereira Torres. Co-Advisor: Hélio Garcia Leite.

Forest fires cause major impacts, such as ecological disasters, reduced water quality and loss of human and animal life. Understanding fire behavior makes it possible to predict danger situations and the impacts of fires. Through prediction models built using artificial neural networks (ANN) it is possible to predict this behavior. To reduce the risk of forest fires, it is necessary to understand the variables that most favor the start and spread of fire and the most susceptible areas. This is possible through the use of Geographic Information Systems (GIS), where risk zoning maps are created, which assess potential occurrences due to environmental factors. Thus, this work was divided into two chapters to better understand the moisture content of combustible materials, the fire behavior and the variables that favor the risk of forest fires. In the first chapter, artificial neural networks were configured to predict the moisture content of combustible material of different thickness classes and fire behavior in eucalyptus plantations. The variables days without rain and relative humidity are the ones that contribute the most to the combustible material humidity and the wind speed and the relative humidity are the ones that contribute the most to the behavior of fire. In the second chapter, we analyzed the classes of environmental variables that control the occurrence of forest fires in Coimbra, Portugal, and, based on them, maps of the risk of forest fires for the region were drawn up. The classes that obtained the highest percentages of burned areas were: Forests, >400 m, 0–15° and high accumulated, for the variables land use, proximity, slope and solar radiation, respectively. The GIS proved to be an efficient tool in the analysis of fire risk, as the model chosen for mapping the risk of fire in the region had the highest sums of the values of the “high” and “very high” classes and the smallest sums of the “low” and “very low”.

Keywords: ANN. Prediction models. Monitoring. Susceptibility to fire. Artificial intelligence. Fire.

LISTA DE FIGURAS

CAPÍTULO 1

Figura 1 – Plantio clonal de híbrido de <i>Eucalyptus urophylla</i> x <i>Eucalyptus grandis</i> com 10 anos de idade em Viçosa, Minas Gerais, Brasil	27
Figura 2 – Contribuição das variáveis para cada componente principal da umidade do material combustível	34
Figura 3 – Contribuição das variáveis para cada componente principal do comportamento do fogo	34
Figura 4 – As variáveis de saída do teste de umidade do material combustível preditas e observadas. Os valores de p-valor do teste F aplicado para avaliar $H_0: [a \ b] = [0 \ 1]$, sendo $Y_{obs} = a + bY_{pred}$	36
Figura 5 – As variáveis de saída do teste de comportamento do fogo preditas e observadas. Os valores de p-valor do teste F aplicado para avaliar $H_0: [a \ b] = [0 \ 1]$, sendo $Y_{obs} = a + bY_{pred}$	38
Figura 6 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100*(Y_{pred} - Y_{obs}) / Y_{obs}$, para $Y =$ umidade do material combustível	39
Figura 7 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100*(Y_{pred} - Y_{obs}) / Y_{obs}$, para $Y =$ comportamento do fogo	40

CAPÍTULO 2

Figura 1 – Cartogramas utilizados para a geração do mapa de suscetibilidade a incêndios em Coimbra, Portugal	55
Figura 2 – Período seco, números de ocorrências médios e áreas queimadas médias mensais do distrito de Coimbra	59
Figura 3 – Áreas queimadas no distrito de Coimbra entre 2001 e 2018	59
Figura 4 – Gráficos ROC dos modelos básicos gerados para o distrito de Coimbra	61
Figura 5 – Mapas gerados pelos modelos básicos no distrito de Coimbra	62

LISTA DE TABELAS

CAPÍTULO 1

Tabela 1 – Variáveis utilizadas no estudo	29
Tabela 2 – Dados descritivos das parcelas experimentais	32
Tabela 3 – Autovalores e variância (%) dos componentes principais que fornecem 81% de toda a variação dos dados de umidade do material combustível ...	33
Tabela 4 – Autovalores e variância (%) dos componentes principais que fornecem 81% de toda a variação dos dados de comportamento do fogo	33
Tabela 5 – Estatísticas das redes escolhidas para estimar a umidade do material combustível	35
Tabela 6 – Estatísticas das redes escolhidas para estimar o comportamento do fogo ..	35
Tabela 7 – Estatísticas das redes escolhidas para estimar a umidade do material combustível e o comportamento do fogo	35

CAPÍTULO 2

Tabela 1 – Notas atribuídas a cada variável analisada de acordo com sua forma de atribuição	56
Tabela 2 – Área (ha) e porcentagem das áreas queimadas de cada variável em Coimbra, Portugal	60
Tabela 3 – Áreas das classes e áreas queimadas em cada classe do melhor modelo gerado para o distrito de Coimbra	62
Tabela 4 – Tamanho das áreas que queimaram mais de uma vez entre 2001 e 2018 no distrito de Coimbra	63

LISTA DE ABREVIATURAS E SIGLAS

%CII	Porcentagem da carga do material classe 2 em relação à carga total
%CI-L	Porcentagem da carga do material classe 1 lenhoso em relação à carga total
%CI-M	Porcentagem da carga de miscelânea em relação à carga total
%CI-V	Porcentagem da carga do material vivo em relação à carga total
ACC	Taxa de acurácia
AUC	Área sob a curva
CCII	Carga do material combustível classe 2
CCI-L	Carga do material combustível classe 1 lenhoso
CCI-M	Carga do material combustível miscelânea
CCI-V	Carga do material combustível vivo
CCT	Carga do material combustível total
CD	Combustível disponível
CI	Material combustível com diâmetro entre 0 e 0,64 cm
CII	Material combustível com diâmetro entre 0,64 e 2,54 cm
CIII	Material combustível com diâmetro entre 2,54 e 7,62 cm
CI-L	Madeira com diâmetro menor que 0,64 cm
CI-M	Material orgânico morto
CIV	Material combustível com diâmetro maior que 7,62 cm
CI-V	Material vivo
COS	Carta de ocupação do solo
DC	Densidade de carga
DGT	Direção geral do território
Dsch	Dias sem chuva
EM	Espessura da manta
EQM	Erro quadrático médio
FN	Falso negativo
FP	Falso positivo
FPR	Taxa positiva falsa
Hch	Altura das chamas
Hcl	Altura do crestamento letal
I	Intensidade do fogo

MDE	Modelo digital de elevação
PCA	Análise de componentes principais
PQ	Profundidade da queima
R	Coefficiente de correlação linear
RMSE	Raiz do erro quadrático médio
RNA	Redes neurais artificiais
ROC	<i>Receiver Operating Characteristic curve</i>
SAF	Sistemas agroflorestais
SIG	Sistemas de informações geográficas
TN	Verdadeiro negativo
T°C	Temperatura do ar
TP	Verdadeiro positivo
TPR	Taxa positiva verdadeira
UC-II	Umidade do material combustível classe 2
UCI-L	Umidade do material combustível classe 1 lenhoso
UCI-M	Umidade do material combustível miscelânea
UCI-V	Umidade do material combustível vivo
UCT	Umidade do material combustível total
UMC	Umidade do material combustível
UR	Umidade relativa do ar
VP	Velocidade da propagação
VV	Velocidade do vento em m/s
\widehat{Y}_i	Valores preditos
Y_i	Valores observados

SUMÁRIO

1. INTRODUÇÃO E JUSTIFICATIVA.....	15
REFERÊNCIAS BIBLIOGRÁFICAS	18
2. OBJETIVOS.....	20
2.1. Objetivo geral.....	21
2.2. Objetivos específicos	21
CAPÍTULO I: Modelagem da umidade do material combustível e do comportamento do fogo em povoamento de eucalipto utilizando aprendizado de máquina.....	22
RESUMO.....	23
ABSTRACT	24
1. INTRODUÇÃO	25
2. MATERIAL E MÉTODOS	27
2.1 Local e dados utilizados.....	27
2.2 Variáveis	28
2.3 Modelagem	30
2.3.1 Análise de componentes principais (Pré-processamento).....	30
2.3.2 Configuração e treinamento das redes neurais artificiais – RNA	31
2.3.3 Avaliação e escolhas das RNA.....	31
2.3.4 Validação Cruzada.....	32
3. RESULTADOS	32
4. DISCUSSÃO	41
5. CONCLUSÕES.....	42
6. REFERÊNCIAS BIBLIOGRÁFICAS	44
CAPÍTULO II: Mapeamento de Suscetibilidade a Incêndios Florestais do Distrito de Coimbra, Portugal.....	49
RESUMO.....	50
ABSTRACT	51
1. INTRODUÇÃO	52
2. MATERIAL E MÉTODOS	53
2.1 Área de estudo e dados utilizados.....	53
2.2 Análises estatísticas e modelos espaciais	56
2.3 Comparação dos modelos.....	58

3. RESULTADOS	59
4. DISCUSSÃO	63
5. CONCLUSÕES.....	66
6. REFERÊNCIAS BIBLIOGRÁFICAS	67
3. CONCLUSÕES GERAIS	71

1. INTRODUÇÃO E JUSTIFICATIVA

Utiliza-se o termo incêndio florestal quando ocorre a propagação livre ou descontrolada do fogo em florestas e outras formas de vegetação (Iembo e Galvani, 2021). Já nas queimas controladas, onde existem objetivos definidos e área delimitada, o fogo é manejado (White e White, 2017).

Quando os incêndios florestais ocorrem de forma natural, como em florestas subtropicais estacionais, e sazonalmente secas, são muito importantes para a manutenção da biodiversidade (Pausas e Keeley, 2019). Porém, quando ocorrem de forma não natural, modificam a paisagem, comprometem a floração e frutificação, causam desastres ecológicos, como diminuição da qualidade da água, do solo e da vegetação, perda de vidas humanas e de animais, problemas respiratórios associados às fumaças emitidas, entre outros (Pourtaghi et al., 2016; Sousa e Cunha, 2018).

Os grandes impactos causados pelos incêndios florestais aumentam a necessidade de métodos de avaliação, planos de prevenção, controle e mitigação de incêndios (Torres et al., 2017; Cavalcante, 2019). Além disso, o melhor entendimento do comportamento do fogo e sua resposta às condições ambientais permite prever as situações de perigo e os impactos dos incêndios. Com isso, as decisões sobre a gestão de combustíveis e dos incêndios serão mais acertadas (dos Reis e Torres, 2018).

Para prever o comportamento do fogo, é necessário o desenvolvimento de modelos de previsão de umidade do material combustível (White, 2018). Tanto os modelos de previsão do comportamento do fogo quanto os de previsão de umidade do material combustível podem ser construídos utilizando alguma técnica de inteligência artificial, como as redes neurais artificiais (RNA) (da Gama Viganó et al., 2017).

A utilização da RNA é mais vantajosa do que outros métodos, porque possui uma facilidade para adicionar variáveis qualitativas de forma eficiente e capacidade de detectar relações não lineares entre a variável de saída e as variáveis de entrada durante todo o seu processo de aprendizagem (dos Reis Martins et al., 2015).

Além de prever o teor de umidade do material e o comportamento do fogo, é necessário diminuir a suscetibilidade a incêndios florestais através do entendimento das variáveis que mais propiciam o início e propagação do fogo. Para o planejamento de ações de redução da suscetibilidade, utiliza-se comumente os Sistemas de Informações Geográficas (SIG), onde são criados mapas de suscetibilidade, que avaliam potenciais ocorrências em função de fatores ambientais (You et al., 2017).

A suscetibilidade das áreas através de fatores inerentes a dados meteorológicos, de relevo, de características florestais e uso da terra é identificada a partir desses mapas (de Omena et al., 2016). Eles podem reunir informações sobre os incêndios de vários anos, mostrando os padrões das áreas de maior ocorrência e servindo como ferramenta de gestão estratégica para atividades de prevenção (Torres et al., 2017).

Com o objetivo de prever e compreender o teor de umidade dos materiais combustíveis, o comportamento do fogo e as variáveis que favorecem a suscetibilidade a incêndios florestais, essa dissertação foi organizada da seguinte maneira:

- **OBJETIVOS** – Este item apresenta o objetivo geral e os objetivos específicos deste trabalho.
- **CAPÍTULO I** – Este capítulo apresenta um estudo de modelagem da umidade do material combustível e do comportamento do fogo, utilizando Redes Neurais Artificiais (RNA). Para isso, foram determinadas as variáveis que melhor explicam a umidade do material combustível e o comportamento do fogo. As RNA foram avaliadas e escolhidas com base no coeficiente de correlação (R), resíduo entre observado e predito, p-valor do teste F de Graybill e na raiz do erro quadrático médio (RMSE).
- **CAPÍTULO II** – Este capítulo apresenta um estudo que analisa as variáveis ambientais que controlam as ocorrências de incêndios florestais. A partir daí, foram confeccionados mapas de suscetibilidade a incêndios florestais para o Distrito de Coimbra, Portugal.
- **CONCLUSÕES GERAIS** – Apresenta um resumo geral a partir dos resultados obtidos e considerações finais importantes sobre o estudo realizado.

REFERÊNCIAS BIBLIOGRÁFICAS

- Cavalcante KL. A importância da prevenção, controle e combate aos incêndios florestais na preservação do meio ambiente. *Brazilian Journal of Development*. 2019;5(12):32346–32354. doi:10.34117/bjdv5n12-304.
- da Gama Viganó HH, de Souza CC, Cristaldo MF, de Jesus L. Redes neurais artificiais na previsão de queimadas e incêndios no pantanal. *Revista Brasileira de Geografia Física*. 2017;10(5):1355–1367. doi:10.26848/rbvf.v.10.p1355-1367.
- de Omena MTR, Taniwaki MH, Schimalski MB, Santos PS, Araki EK. Zoneamento do Risco de Incêndio Florestal para o Parque Nacional de São Joaquim – SC. *Biodiversidade Brasileira*. 2016;6(2):173–186. doi:10.37002/biobrasil.v%25vi%25i.442.
- dos Reis TL, Torres FTP. Avaliação da eficiência de índices de perigo meteorológico de incêndios florestais para o estado de Minas Gerais. *Revista Brasileira de Climatologia*. 2018;1(14):1–9. doi:10.5380/abclima.v1i0.61074.
- dos Reis Martins E, da Silva Binoti MLM, Leite HG, Binoti DHB, Dutra GC. Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais de eucalipto. *Revista Brasileira de Ciências Agrárias*. 2015;10(4):532–537. doi:10.5039/agraria.v10i4a5350.
- Iembo JLV, Galvani E. Vulnerabilidade a incêndios florestais: reflexões acerca do Parque Estadual Do Juquery e seu entorno. *Revista Brasileira de Climatologia*. 2021;28:1–27. doi:10.5380/rbclima.v28i0.77411.
- Pausas JG, Keeley JE. Wildfires as an ecosystem service. *Frontiers in Ecology and the Environment*. 2019;17(5):289–295. doi:10.1002/fee.2044.
- Pourtaghi ZS, Pourghasemi HR, Aretano R, Semeraro T. Investigation of general indicators influencing on forest fire and its susceptibility modeling using different data mining techniques. *Ecological Indicators*. 2016;64:72–84. doi:10.1016/j.ecolind.2015.12.030.
- Sousa DGD, Cunha HFD. Effect of fire on flowering and fruiting of *Anacardium humile* (Anacardiaceae) in cerrado stricto sensu. *Revista Árvore*. 2018;42(6):1–10. doi:10.1590/1806-90882018000600005.
- Torres FTP, Siqueira RG, Moreira GF, Lima GS, Martins SV, Valverde SR. Risk mapping of fires in vegetation in the Serra do Brigadeiro State Park (MG) and surroundings. *Revista Árvore*. 2017;41(4):e410409. doi:10.1590/1806-90882017000400009.
- White BLA, White LAS. Queimadas e incêndios florestais no estado de Sergipe, Brasil, entre 1999 e 2015. *Floresta*. 2017;46(4):561–570. doi:10.5380/rf.v46i4.47036.

- White BLA. Modelos matemáticos de previsão do teor de umidade dos materiais combustíveis florestais finos e mortos. *Ciência Florestal*. 2018;28(1):432–445. doi:10.5902/1980509831622.
- You W, Lin L, Wu L, Ji Z, Yu J, Zhu J, Fan Y, He D. Geographical information system-based forest fire risk assessment integrating national forest inventory data and analysis of its spatiotemporal variability. *Ecological Indicators*. 2017;77:176–184. doi:10.1016/j.ecolind.2017.01.042.

2. OBJETIVOS

2.1. Objetivo geral

Compreender o teor de umidade dos materiais combustíveis, o comportamento do fogo e as variáveis que favorecem a suscetibilidade a ocorrência de incêndios florestais.

2.2. Objetivos específicos

Capítulo I – Modelagem da umidade do material combustível e do comportamento do fogo em povoamento de eucalipto utilizando aprendizado de máquina

- Determinar quais variáveis explicam melhor a umidade do material combustível;
- Determinar quais variáveis explicam melhor o comportamento do fogo;
- Configurar, treinar e aplicar redes neurais artificiais para a modelagem da umidade do material combustível e do comportamento do fogo em plantios de clones de eucalipto e definir a melhor configuração;
- Construir um modelo de predição de incêndios e seu comportamento utilizando aprendizado de máquina;
- Definir as variáveis necessárias para predição de incêndios e do comportamento desses incêndios.

Capítulo II – Mapeamento de Suscetibilidade a Incêndios Florestais do Distrito de Coimbra, Portugal

- Analisar as variáveis ambientais que controlam as ocorrências de incêndios florestais;
- Desenvolver o mapeamento da suscetibilidade a incêndios florestais no Distrito de Coimbra, Região do Centro, Portugal;
- Determinar a metodologia mais eficiente para o mapeamento de suscetibilidade a incêndios na região.

CAPÍTULO I:

**Modelagem da umidade do material combustível
e do comportamento do fogo em povoamento de
eucalipto utilizando aprendizado de máquina**

Modelagem da umidade do material combustível e do comportamento do fogo em povoamento de eucalipto utilizando aprendizado de máquina

Thaynara Lopes dos Reis ^{a,*}, Ricardo Rodrigues de Oliveira Neto ^a, Hélio Garcia Leite ^a, Fillipe Tamiozzo Pereira Torres ^a

^a Departamento de Engenharia Florestal, Universidade Federal de Viçosa (UFV), Av. Peter Henry Rolfs, s/n, Campus Universitário, 36570-900, Viçosa, MG, Brazil.

RESUMO

O teor de umidade do combustível é um dos parâmetros mais importantes que afetam a suscetibilidade à ocorrência de incêndios e o comportamento do fogo. Esse teor influencia fortemente a inflamabilidade, a sustentabilidade e a combustibilidade. A criação de modelos de previsão é uma das técnicas para estimar a umidade do material combustível. Esses modelos de previsão de umidade do material combustível são importantes para o desenvolvimento de modelos de previsão do comportamento do fogo. Eles são construídos utilizando alguma técnica de inteligência artificial, como as redes neurais artificiais (RNA). Com isso, o objetivo desse estudo é definir uma abordagem para a modelagem da umidade do material combustível e do comportamento do fogo em plantios de clones de eucalipto, utilizando RNA. Além disso, determinou-se as variáveis que melhor explicam a umidade do material combustível e as que melhor explicam o comportamento do fogo. O *software* Statistica foi utilizado para o treinamento das redes neurais e utilizou-se a arquitetura multilayer perceptron (MLP). Setenta por cento dos dados foram usados para o treino e os outros trinta para a validação da rede. A avaliação de cada RNA e de cada combinação de variáveis de entrada foi feita com base no coeficiente de correlação (R), resíduo entre observado e predito, p-valor do teste F de Graybill e na raiz do erro quadrático médio (RMSE). As estimativas de umidade das diferentes classes de material combustível e do comportamento do fogo das redes escolhidas apresentaram bons coeficiente de correlação, tanto para o treino (70 e 74%) quanto para a validação (68 e 75%). As variáveis dias sem chuva (Dsch) e umidade relativa do ar (UR) são as que mais contribuem para a umidade do material combustível e a velocidade do vento (VV) e a UR são as que mais contribuem para o comportamento do fogo.

Palavras-chave: RNA; incêndios florestais; modelos de previsão.

ABSTRACT

The creation of predictive models is one of the techniques to estimate the combustible material moisture. These combustible material moisture prediction models are important for the development of fire behavior prediction models. They are built using some artificial intelligence technique, such as artificial neural networks (ANN). Thus, the aim of this study is to define an approach for modeling the moisture of combustible material and fire behavior in eucalyptus clone plantations, using ANN. In addition, the variables that best explain the moisture of the combustible material and those that best explain the fire behavior were determined. The Statistica software was used for training neural networks and the multilayer perceptron (MLP) architecture was used. 70% of the data were used for training and the other 30% for network validation. The evaluation of each ANN and each combination of input variables was based on the correlation coefficient (R), residue between observed and estimated, p-value of Graybill's F test and root mean square error (RMSE). The moisture estimates of the different classes of combustible material and the fire behavior of the chosen networks showed good correlation coefficients, both for training (70 and 74%) and for validation (68 and 75%). The rainless days and relative air humidity variables are the ones that most contribute to the combustible material moisture and the wind speed and relative air humidity are the ones that most contribute to the fire behavior.

Keywords: ANN; forest fires; predictive models.

1. INTRODUÇÃO

Os incêndios destroem milhares de hectares de florestas todos os anos e são responsáveis por cerca de 10% das emissões globais de gases de efeito estufa (Boden et al., 2017; Tuyen et al., 2021). Além disso, têm grande influência sobre os recursos florestais, sucessões ecológicas, conectividade hidrológica e erodibilidade do solo (Johnstone et al., 2011; Fernández et al., 2020; Holloway et al., 2020).

Apesar dos incêndios ocorrerem de forma natural em muitos locais, como em florestas subtropicais estacionais, boreais e sazonalmente secas, a maior parte das suas ocorrências é de origem antrópica (Scheper et al., 2021). Porém, as condições ambientais podem favorecer ou não o desenvolvimento do evento (Torres et al., 2018).

O material combustível, as variáveis climáticas e as características fisiográficas são determinantes sobre ocorrência de incêndios e comportamento do fogo (de Assis et al., 2014). O teor de umidade do combustível é um dos parâmetros mais importantes que afetam a suscetibilidade a ocorrência de incêndios e o comportamento do fogo (Terrah et al., 2020). Este parâmetro representa uma medição direta, física e em escala nominal de suscetibilidade a incêndios (Torres et al., 2018). Esse teor influencia fortemente a inflamabilidade, a sustentabilidade e a combustibilidade (Yebra et al., 2018). A inflamabilidade é a facilidade com que uma substância se inflama por chama ou brilho (ponto de inflamação), a sustentabilidade é uma medida de quão bem um incêndio continuará queimando com ou sem a fonte de calor (ponto de incêndio) e a combustibilidade reflete a rapidez com que o fogo queima (Terrah et al., 2020).

Existem algumas técnicas para estimar a umidade do material combustível. O inventário é a forma mais precisa de quantificar o combustível florestal e obter sua umidade, porém, além de demandar muito tempo, ele é inviável nos casos em que o incêndio já começou ou para a previsão do perigo de ocorrência de incêndios florestais em tempo real (White, 2018). Uma outra forma é através da criação de modelos de previsão de carga e de umidade do material combustível, sendo importantes para o desenvolvimento de modelos de previsão do comportamento do fogo (Beutling, 2012; Santos et al., 2019).

Os modelos de previsão de carga e umidade de combustíveis podem ser construídos utilizando alguma técnica de inteligência artificial, como as redes neurais artificiais (RNA) (da Gama Viganó et al., 2017). Uma RNA é um sistema inspirado no cérebro humano, pelo qual o conhecimento é adquirido por um processo de aprendizagem que pode ser supervisionado ou não supervisionado (Hertz et al., 1991; Haykin, 1998). Assim, como no

sistema nervoso, as redes neurais artificiais são compostas por unidades de processamento (neurônios artificiais) interligadas por pesos sinápticos que propagam os sinais de entrada dos neurônios (Haykin, 2001). O resultado da soma de todas as entradas multiplicadas pelos respectivos pesos sinápticos, transforma os sinais de entrada em estado de ativação, sendo que este estado pode assumir valores binários, bipolares e reais (Machado, 2013).

A facilidade de adicionar variáveis qualitativas de forma eficiente e a capacidade de detectar relações não lineares entre a variável de saída e as variáveis de entrada durante todo o seu processo de aprendizagem são umas das principais vantagens das RNA em relação a outros métodos (dos Reis Martins et al., 2015). Elas também não requerem conhecimento prévio dos processos físicos causadores do incêndio, possibilitam o treinamento contínuo da rede, permitem uma otimização entre os dados de entrada e saída e podem ser aplicadas em sistemas sem soluções específicas (da Gama Viganó et al., 2017).

Muitos artigos de revisão foram publicados recentemente sobre o uso de RNA em incêndios florestais. As RNAs do tipo *Multilayer Perceptron*, com algoritmo *Retropropagation* de aprendizagem, foram utilizadas para a previsão dos focos e das áreas queimadas no Pantanal Sul-Mato-Grossense (da Gama Viganó et al., 2017). Em 2018, foi proposta uma estrutura de detecção precoce de incêndio usando redes neurais convolucionais ajustadas para câmeras de vigilância de CFTV (Circuito Fechado de Televisão), que podem detectar incêndio em diversos ambientes internos e externos (Muhammad et al., 2018). Uma nova metodologia de aprendizado de máquina para análise e predição de padrões espaciais de perigo de incêndio florestal foi proposta a partir de um estudo de caso de incêndio florestal tropical na província de Lao Cai, Vietnã (Bui et al., 2019). Porém, são raros os estudos sobre o uso dessas redes na modelagem de combustíveis e de comportamento do fogo utilizando dados experimentais, justificando a condução da presente pesquisa.

A RNA fornece uma abordagem rápida e flexível para integração de dados e desenvolvimento de modelos. Além disso, a RNA pode, teoricamente, aproximar qualquer função a qualquer nível de precisão, sendo muito útil quando os mecanismos físicos não são lineares, como em pesquisas de comportamento de propagação de incêndios florestais (Chetehouna et al., 2015; Polinova et al., 2019).

Diante do exposto, o objetivo desse estudo é definir uma abordagem para a modelagem da umidade do material combustível e do comportamento do fogo em plantios de clones de eucalipto, utilizando aprendizagem de máquina. Desejou-se também determinar as

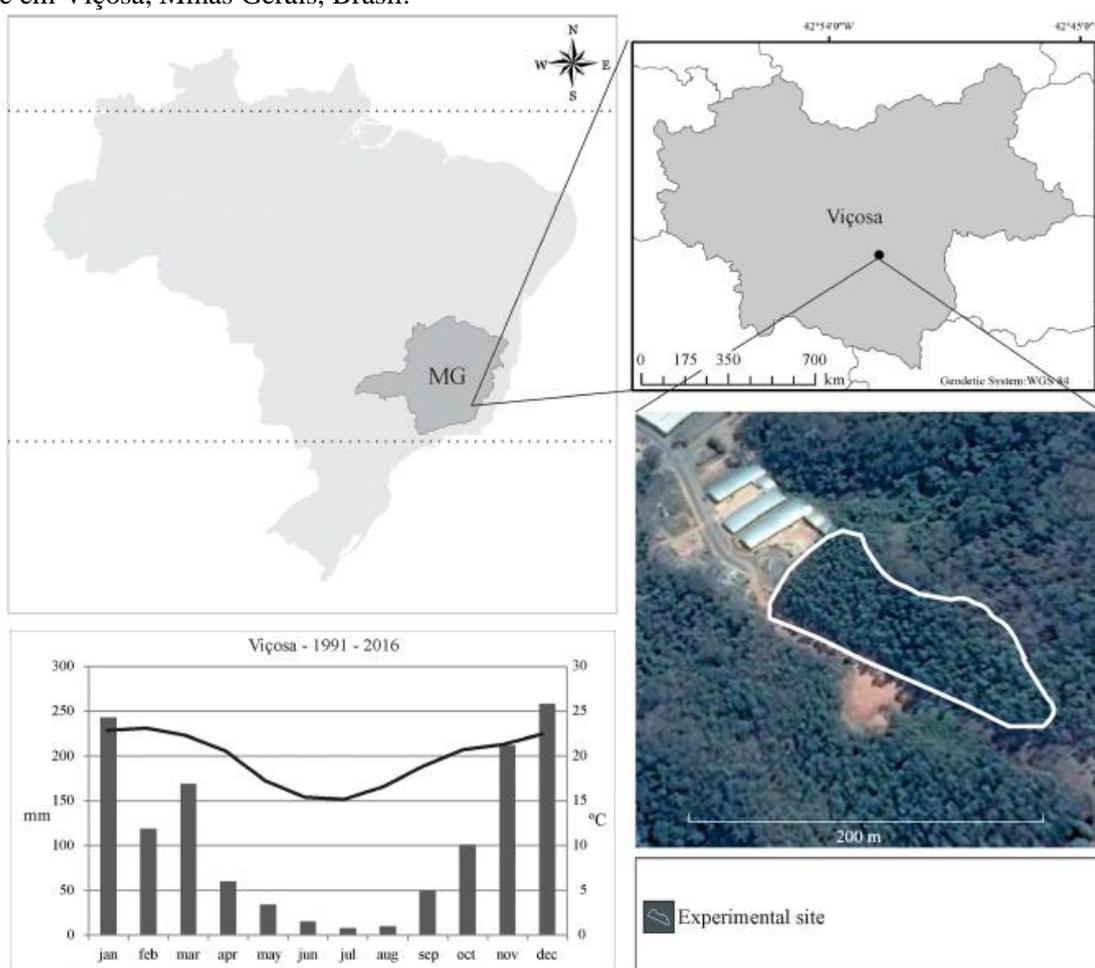
variáveis que explicam melhor a umidade do material combustível e as que explicam melhor o comportamento do fogo.

2. MATERIAL E MÉTODOS

2.1 Local e dados utilizados

Os dados utilizados neste estudo foram coletados no ano de 2016, em um plantio de clones de um híbrido de *Eucalyptus urophylla* x *Eucalyptus grandis* com 10 anos de idade. Esse povoamento de 1,5 hectares está localizado no campus da Universidade Federal de Viçosa, estado de Minas Gerais, sudeste do Brasil, sob espaçamento de 3x3 m, em um terreno com exposição de 302° (noroeste) e inclinação do terreno de 10°, relevo uniforme e condições favoráveis para deposição de combustível florestal (Figura 1).

Figura 1 – Plantio clonal de híbrido de *Eucalyptus urophylla* x *Eucalyptus grandis* com 10 anos de idade em Viçosa, Minas Gerais, Brasil.



(Fonte: Torres et al., 2019)

O clima da região onde se encontra o povoamento é classificado como Cwa, conforme a classificação de Köppen, subtropical úmido com invernos secos e verões úmidos.

A média da temperatura e umidade relativa para o ano de 2016 foi de 20,9°C e 78%, respectivamente, e a precipitação anual para o mesmo ano é de 1167,7 mm (UFV, 2016).

Os dados foram coletados, em 80 dias aleatórios, a partir de queimas controladas entre 01 de julho e 30 de novembro de 2016, período com maior número de incêndios devido a estação seca na região (Torres et al., 2010). Essas queimas foram realizadas em parcelas de 20 m² (2m x 10m) durante os seguintes períodos: às 9h, às 11h, às 13h e às 15h, horários de maior perigo de incêndio (Torres et al., 2017). As parcelas foram queimadas apenas uma vez e utilizou-se a média das quatro queimas diárias, totalizando 80 amostras.

2.2 Variáveis

As medições das variáveis meteorológicas temperatura do ar, umidade relativa do ar e velocidade do vento foram feitas dentro do plantio florestal no início e no final de cada queima. Já a variável dias sem chuva foi calculada com base nos dias que não ocorreram precipitação, segundo os dados fornecidos pela Estação meteorológica da UFV, localizada a 1km do local da queima.

O material combustível foi coletado, antes e depois de cada queima, a partir de quadrantes de 50x50 cm, colocados aleatoriamente em cada parcela. Após a coleta desse material, ele foi separado em quatro categorias, de acordo com a sua espessura: i. material com diâmetro entre 0 e 0,64 cm (CI); ii. 0,64 a 2,54 cm (CII); iii. 2,54 a 7,62 cm (CIII); iv. maior que 7,62 cm (CIV) (Brown, 1982). A classe CI foi subdividida em três subclasses: i. material vivo (CI-V); ii. material orgânico morto, composto principalmente de folhas de eucalipto e gramíneas (CI-M); iii. material lenhoso com diâmetro menor que 0,64 cm (CI-L). A carga e densidade de cada classe de material combustível foram calculadas a partir do peso seco do material combustível depositado no solo.

O material coletado foi colocado em uma estufa para secagem a 75°C até o peso constante ser alcançado para determinar o peso da matéria seca. A umidade do combustível foi obtida pela diferença entre o peso inicial e a matéria seca das amostras dos mesmos quadrantes aleatórios. Para não interferir com a queima, essas amostras foram coletadas anexadas às parcelas, tendo as mesmas condições do material dentro das parcelas. Além disso, para a umidade de cada classe de combustível, a umidade total do combustível (UCT) também foi determinada.

O material consumido pela queima (combustível disponível) foi obtido pela diferença entre o peso antes (combustível total) e após a queima (combustível residual). As amostras foram coletadas, pesadas e retornaram ao local para não atrapalhar a queima. A

profundidade da queima foi estimada pela diferença entre a profundidade do material morto depositado sobre o piso da floresta antes e depois da queima, mediu-se com uma régua no local da queima.

Além da profundidade da queima, a velocidade de propagação, a altura das chamas, o combustível disponível, a intensidade do fogo e a altura do crestamento letal constituem o conjunto de variáveis que determinam o comportamento do fogo. A velocidade de propagação foi obtida visualmente a partir da contagem do tempo médio em que a chama percorreu as distâncias de 1m demarcadas em cada parcela. A altura da chama foi obtida com uma régua, em que se mediu a altura média da chama a cada metro de avanço da linha de fogo. Com os dados do peso do combustível disponível, da velocidade de propagação e do poder calorífico do material úmido (determinado com um calorímetro), foi calculada a intensidade do fogo com a equação de Byram (1959). E com os dados de intensidade do fogo, velocidade do vento e temperatura do ar, foi calculada a altura do crestamento letal (Van Wagner, 1973).

As variáveis obtidas nas coletas feitas em 2016, utilizadas neste estudo, estão na Tabela 1.

Tabela 1 – Variáveis utilizadas no estudo

Variáveis	Descrição	Unidade
T°C	Temperatura do ar	°C
UR	Umidade relativa do ar	%
VV	Velocidade do vento	m/s
Dsch	Dias sem chuva	dias
UCI-M	Umidade do material combustível miscelânea	%
UCI-V	Umidade do material combustível vivo	%
UCI-L	Umidade do material combustível classe 1 lenhoso	%
UC-II	Umidade do material combustível classe 2	%
UCT	Umidade do material combustível total	%
PQ	Profundidade da queima	cm
VP	Velocidade da propagação	m/s
Hch	Altura das chamas	cm
CD	Combustível disponível	g
I	Intensidade do fogo	kw.m ⁻¹
Hcl	Altura do crestamento letal	cm
EM	Espessura da manta	cm
DC	Densidade de carga	kg.m ⁻³
CCI-M	Carga do material combustível miscelânea	kg.m ⁻²
CCI-V	Carga do material combustível vivo	kg.m ⁻²
CCI-L	Carga do material combustível classe 1 lenhoso	kg.m ⁻²
CCII	Carga do material combustível classe 2	kg.m ⁻²
CCT	Carga do material combustível total	kg.m ⁻²

%CI-M	Porcentagem da carga de miscelânea em relação à carga total	%
%CI-V	Porcentagem da carga do material vivo em relação à carga total	%
%CI-L	Porcentagem da carga do material classe 1 lenhoso em relação à carga total	%
%CII	Porcentagem da carga do material classe 2 em relação à carga total	%

Na utilização da RNA para estimar a umidade do material combustível, fez-se 17 diferentes combinações entre as seguintes variáveis de entrada: EM, DC, CCT, CCI-M, CCI-V, CCI-L, CCII, %CI-M, %CI-V, %CI-L, %CII, T°C, UR, VV, Dsch e as variáveis de saída foram: UCI-M, UCI-V, UCI-L, UCII, UCT. Já para estimar o comportamento do fogo, realizou-se 71 diferentes combinações entre as seguintes variáveis de entrada: EM, DC, CCT, CCI-M, %CI-M, %CI-L, T°C, UR, VV, Dsch, UCI-M, UCI-V, UCI-L, UC-II, UCT e as variáveis de saída foram: VP, I, Hch, Hcl, PQ, CD. Sendo realizado, portanto, seis testes para cada modelagem. Cada teste tinha apenas uma variável de saída, com exceção do Teste 6, para explicar a umidade do material combustível, que juntou todas as cinco variáveis de saída.

2.3 Modelagem

2.3.1 Análise de componentes principais (Pré-processamento)

Neste estudo, a quantidade de dados é relativamente pequena em relação ao número de variáveis. Usou-se a Análise de Componentes Principais (PCA) para definir as variáveis que melhor explicam a Umidade do Material Combustível (UMC) e o comportamento do fogo.

Apesar de, na maioria dos estudos usando PCA em conjunto com RNA, a PCA servir para diminuir a quantidade de variáveis de entrada e, conseqüentemente, o tempo de treinamento, neste estudo optou-se por usar todas as variáveis de entrada, independente do resultado (Zekić-Sušac et al., 2013). Isto porque, desejou-se saber se um conjunto de variáveis é mais importante do que uma variável sozinha. Após o treinamento das redes, verificou-se se as variáveis mais importantes, segundo a PCA, estavam presentes no *input* das redes que apresentaram melhor desempenho.

A PCA foi feita utilizando o pacote Facto Mine R do software R 3.6.0 (R Development Core Team, 2019). Como as variáveis são medidas em diferentes unidades, elas foram dimensionadas, através da função de base R *scale*, com o objetivo de torná-las comparáveis (Kassambara, 2017). Foram selecionadas as componentes principais responsáveis por 80% da variância acumulada.

2.3.2 Configuração e treinamento das redes neurais artificiais – RNA

O *software* Statistica (TIBCO Software Inc, 2018) foi utilizado para o treinamento das redes neurais e usou-se a arquitetura MLP (multilayer perceptron), pois, além de possuir uma estrutura simples, ela gera resultados precisos (Haykin, 2009). Setenta por cento dos dados foram usados para o treino e os outros trinta para a validação da rede. O número de neurônios na camada oculta foi definido com base no número de variáveis de entrada (Binoti et al., 2014). Um número excessivo de neurônios na camada oculta pode causar *overfitting*, processo em que ocorre a memorização excessiva dos dados de treinamento, já um pequeno número de neurônios pode causar *underfitting*, o que acarretaria em um grande erro devido a insuficiência de neurônios (Silva et al., 2010). Foram testadas as funções de ativação logística, tangente, identidade, exponencial e seno (Haykin, 2001).

O critério de parada no treinamento das RNA foi o número de ciclos (1000) e o erro quadrático médio (0,0001), ou seja, o treinamento da rede foi interrompido ao atingir algum desses critérios. O número de ciclos é um critério adicional para parar o treinamento quando a precisão especificada se torna inalcançável (Silva et al., 2010). O erro quadrático médio (EQM) é calculado da seguinte forma:

$$EQM = \frac{1}{n} \sum_{i=1}^n (y_{obs} - y_{RNA})^2 \quad (1)$$

Em que, n é o número de elementos na amostra, y_{obs} é o valor observado, e y_{RNA} é o valor predito pela RNA.

2.3.3 Avaliação e escolhas das RNA

A avaliação de cada RNA e de cada combinação de variáveis de entrada foi feita com base no coeficiente de correlação (R), resíduo entre observado e predito, p-valor do teste F de Graybill (1976) e na raiz do erro quadrático médio (RMSE). Sendo que o coeficiente de correlação e o resíduo indicam a relação direta entre os valores observados e preditos, o RMSE mede a precisão e o p-valor ajuda a avaliar quão boa é a rede (Freedman et al., 1980). Nas comparações entre os valores observados e preditos considerou-se \widehat{Y}_i = valores preditos e Y_i = valores observados (Leite et al., 2020; Piñeiroa et al., 2008).

Para escolha da melhor rede de cada um dos testes, considerou-se aquela que tinha valores aproximados do coeficiente de correlação do treino e da validação e um RMSE baixo, quando comparado às outras redes do mesmo teste. Além disso, quanto maior o p-valor, melhor é a rede.

2.3.4 Validação Cruzada

A fim de superar o *underfitting* e evitar o *overfitting*, também foi feita a validação cruzada (*cross-validation*), que é uma das técnicas estatísticas utilizadas para a seleção de melhores topologias (Kohavi, 1995; Ripley, 1996). O objetivo da validação cruzada é avaliar a aptidão de cada rede quando aplicada a um conjunto de dados diferente daquele usado no ajuste dos parâmetros internos (Silva et al., 2010).

Para fazer a divisão do conjunto total de amostras em dois subconjuntos mutuamente exclusivos (subconjuntos de treinamento e teste), utilizou-se o método k-fold, que consiste em dividir aleatoriamente o conjunto total de amostras em k subconjuntos, que pode ser entre 5 e 15, mutuamente excludentes e de tamanhos aproximados (Clarke et al., 2009; Gutttag, 2016).

3. RESULTADOS

Os dados descritivos do experimento podem ser observados na Tabela 2.

Tabela 2 – Dados descritivos das parcelas experimentais

Variáveis	Mínimo	Médio	Máximo
T°C (°C)	14,95	25,93	34,70
UR (%)	30,00	59,12	94,00
VV (m/s)	0,00	2,31	6,00
Dsch (Dias)	0,00	11,25	31,00
UCI-M (%)	10,04	34,40	120,10
UCI-V (%)	13,04	81,56	152,31
UCI-L (%)	9,81	23,63	73,79
UC-II (%)	2,56	23,68	65,47
UCT (%)	10,22	34,42	93,96
PQ (cm)	0,00	3,71	7,85
VP (m/s)	0,00	0,02	0,07
Hch (cm)	0,00	76,60	164,00
CD (g)	0,00	1,76	4,59
I (kw.m-1)	0,00	153,35	779,60
Hcl (cm)	0,00	6,97	31,92
EM (cm)	3,95	7,39	11,98
DC (kg.m-3)	5,79	11,45	19,98
CCI-M (kg.m-2)	0,81	1,83	3,98
CCI-V (kg.m-2)	0,00	0,22	0,92
CCI-L (kg.m-2)	0,18	0,61	1,29
CCII (kg.m-2)	0,00	0,56	1,90
CCT (kg.m-2)	1,47	3,27	6,00
%CI-M (%)	0,24	0,56	0,75
%CI-V (%)	0,00	0,07	0,29
%CI-L (%)	0,05	0,18	0,33
%CII (%)	0,00	0,17	0,48

Realizou-se a PCA com todas as 15 variáveis de entrada dos testes de umidade do material combustível e de comportamento do fogo, separadamente. Limitou-se às componentes que retêm cerca de 80% das informações contidas nos dados. Com isso, cinco componentes principais são responsáveis por 81% da variação dos dados (Tabelas 3 e 4).

Tabela 3 – Autovalores e variância (%) dos componentes principais que fornecem 81% de toda a variação dos dados de umidade do material combustível

Componente principal	Autovalor	Variância (%)	Variância acumulada (%)
1	4,1512	27,6748	27,6748
2	2,6173	17,4486	45,1234
3	2,3799	15,8662	60,9896
4	1,9422	12,9482	73,9379
5	1,1816	7,8772	81,8151

Tabela 4 – Autovalores e variância (%) dos componentes principais que fornecem 81% de toda a variação dos dados do comportamento do fogo

Componente principal	Autovalor	Variância (%)	Variância acumulada (%)
1	5,6389	37,5929	37,5929
2	2,4776	16,5173	54,1102
3	1,9123	12,7490	66,8592
4	1,3146	8,7639	75,6231
5	0,9215	6,1432	81,7663

As variáveis que mais contribuem nas componentes principais da umidade do material combustível são: Dsch (22,9%), %CI-L (19,5%), CCI-M (18,2%), EM (17,6%), CCT (17,1%), CCI-V (16,9%) (Figura 2). E as que mais contribuem nas do comportamento do fogo são: EM (46%), DC (27,3%), %CI-M (23,7%), T°C (22,5%), VV (22,5%), UR (17%) (Figura 3).

Figura 2 – Contribuição das variáveis para cada componente principal da umidade do material combustível

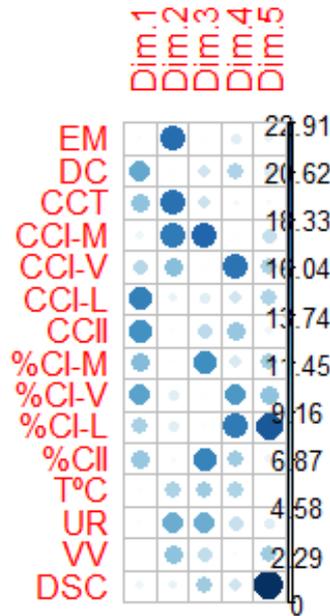
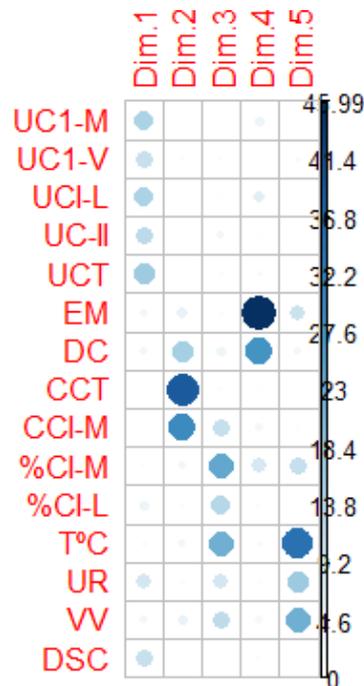


Figura 3 – Contribuição das variáveis para cada componente principal do comportamento do fogo



A partir do resultado dos testes das 17 combinações para explicarem a umidade do material combustível e das 71 para explicarem o comportamento do fogo, uma combinação de variáveis de entrada, juntamente com a configuração da RNA, foi escolhida em cada teste (Tabelas 5, 6 e 7). As estimativas de umidade das diferentes classes de material combustível das combinações escolhidas mostraram um coeficiente de correlação acima de 70% para o

treino da RNA e acima de 68% para a sua validação. Já as estimativas do comportamento do fogo das combinações escolhidas apresentaram coeficientes de correlação acima de 74% para o treino e acima de 75% para a validação.

Tabela 5 – Estatísticas das redes escolhidas para estimar a umidade do material combustível

Teste	RNA	Variáveis de entrada	Variáveis de saída	Correlação		RMSE	
				Treino	Validação	Treino	Validação
1	14	EM, UR, Dsch	UCI-M	0,90	0,89	66,62	155,90
2	9	CCI-V, T°C, UR, Dsch, VV	UCI-V	0,70	0,68	278,14	284,31
3	4	T°C, UR, Dsch	UCI-L	0,94	0,93	11,31	19,53
4	15	EM, T°C, UR, Dsch	UCII	0,70	0,68	38,13	70,48
5	5	UR, Dsch, VV	UCT	0,91	0,91	44,48	42,33
6	6	EM, DC, CCT, CCI-M, CCI-V, CCI-L, CCII, T°C, UR, Dsch, VV	UCI-M, UCI-V, UCI-L, UCII, UCT	0,79	0,78	702,04	711,89

Tabela 6 – Estatísticas das redes escolhidas para estimar o comportamento do fogo

Teste	RNA	Variáveis de entrada	Variáveis de saída	Correlação		RMSE	
				Treino	Validação	Treino	Validação
1	5	UR, Dsch, VV	Velocidade	0,86	0,87	0,00	0,00
2	57	UCI-M, UCI-L, VV, UR, Dsch	Intensidade	0,74	0,77	6478,38	5108,16
3	64	UCT, VV, UR, Dsch, T°C	Altura da chama	0,93	0,92	185,02	133,69
4	50	UCI-L, VV, UR	Altura do crestamento	0,83	0,82	7,88	5,27
5	33	UCI-M, UCI-V, EM	Profundidade	0,87	0,88	0,75	0,58
6	31	UCI-M, EM	Combustível disponível	0,74	0,75	0,31	0,31

Tabela 7 – Estatísticas das redes escolhidas para estimar a umidade do material combustível e o comportamento do fogo

Teste	RNA	Número de neurônios na camada oculta	Função de ativação de entrada	Função de ativação de saída
Umidade do material combustível				
1	14	6	Exponencial	Exponencial
2	9	2	Seno	Exponencial
3	4	4	Logística	Seno
4	15	2	Exponencial	Exponencial

5	5	3	Tangente	Tangente
6	6	2	Seno	Exponencial
Comportamento do fogo				
1	5	4	Exponencial	Logística
2	57	2	Seno	Logística
3	64	9	Seno	Exponencial
4	50	3	Logística	Logística
5	33	6	Tangente	Seno
6	31	4	Logística	Exponencial

O melhor RMSE (%) e o maior coeficiente de correlação foram encontrados no teste 3, tanto para estimar a umidade do material combustível lenhoso da classe 1 (Figura 4c), quanto para a altura da chama (Figura 5c). Com exceção do Teste 6 da umidade do material combustível, todos as redes apresentaram um p-valor maior do que 0,05. Tanto as estatísticas apresentadas quanto o p-valor mostram que não é eficiente estimar a umidade do material combustíveis de todas as classes de espessura em um único teste.

Figura 4 - As variáveis de saída do teste de umidade do material combustível previstas e observadas. Os valores de p-valor do teste F aplicado para avaliar $H_0: [a \ b] = [0 \ 1]$, sendo $Y_{obs} = a + bY_{pred}$

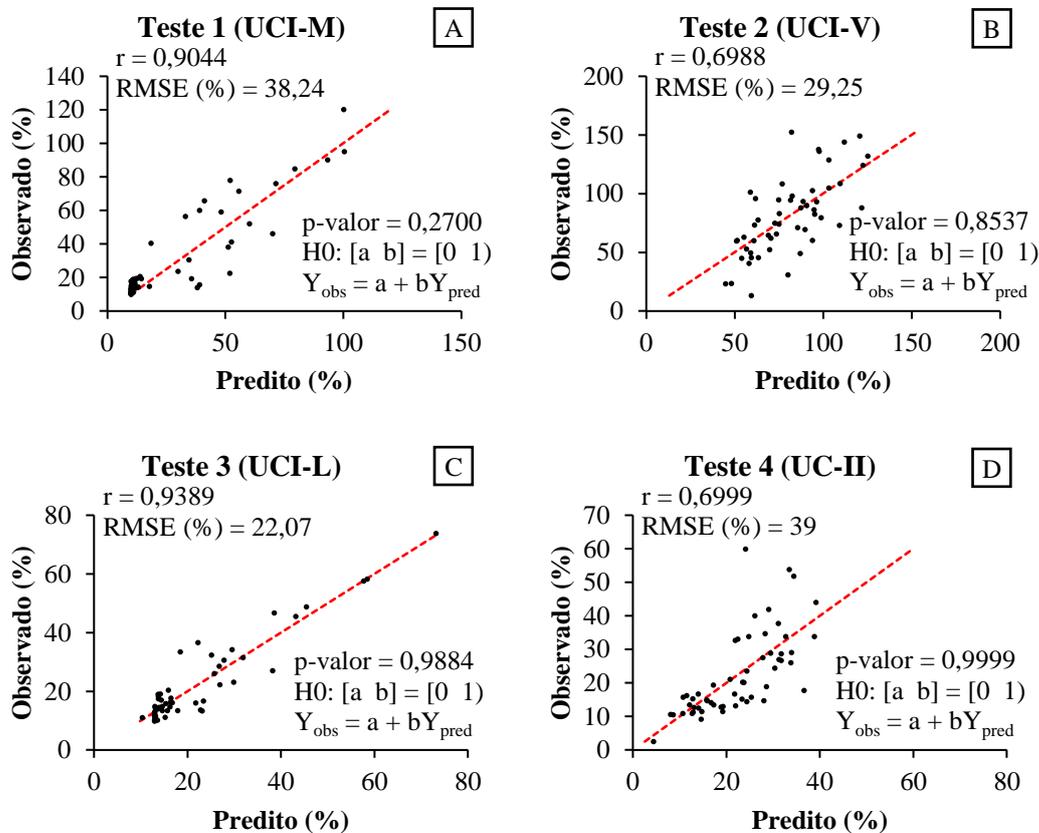


Figura 4 - As variáveis de saída do teste de umidade do material combustível preditas e observadas. Os valores de p-valor do teste F aplicado para avaliar $H_0: [a \ b] = [0 \ 1]$, sendo $Y_{obs} = a + bY_{pred}$ (Continuação)

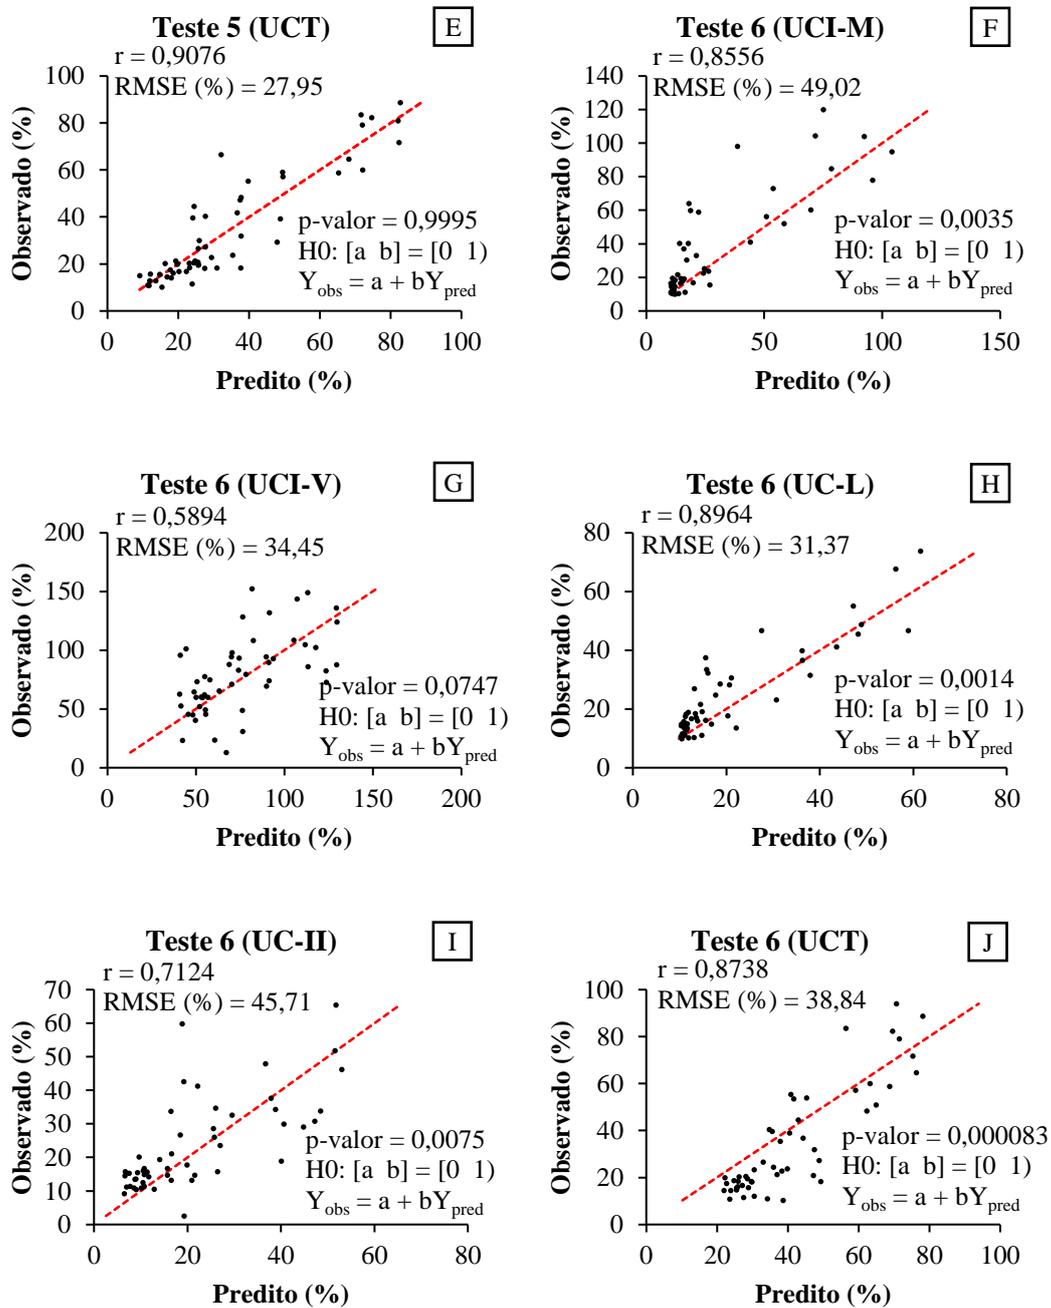
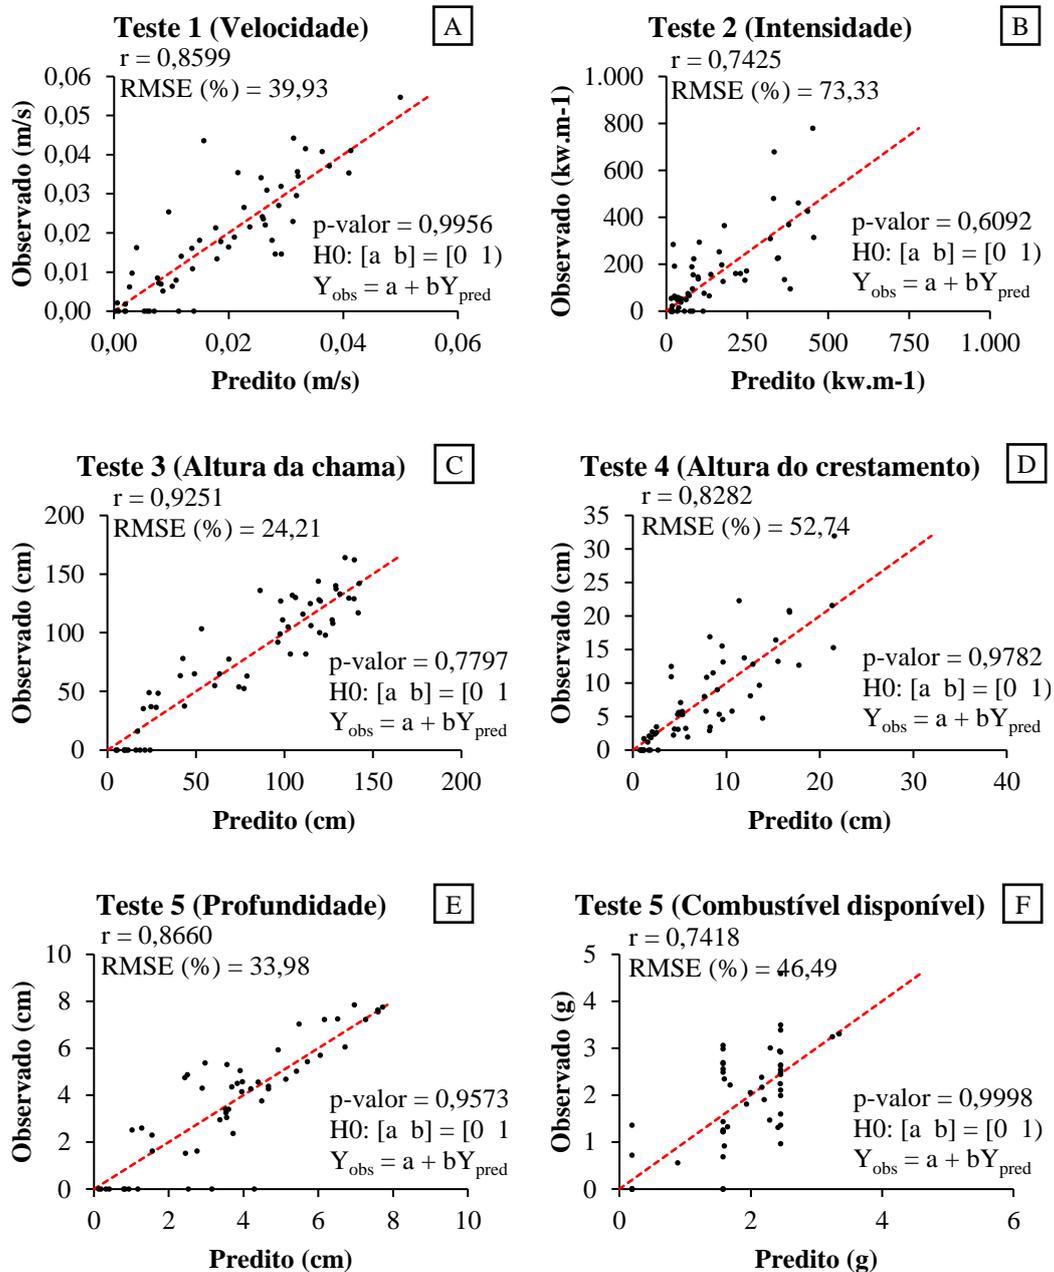


Figura 5 – As variáveis de saída do teste de comportamento do fogo previstas e observadas. Os valores de p-valor do teste F aplicado para avaliar $H_0: [a \ b] = [0 \ 1]$, sendo $Y_{obs} = a + bY_{pred}$



Em alguns casos, as análises estatísticas não são suficientes para avaliar a eficiência da rede, por isso, também foram avaliados os histogramas de porcentagem de casos por classe de resíduo (Figuras 6 e 7). Os gráficos residuais não mostraram tendência no treinamento das redes.

Figura 6 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100 * (Y_{pred} - Y_{obs}) / Y_{obs}$, para Y = umidade do material combustível

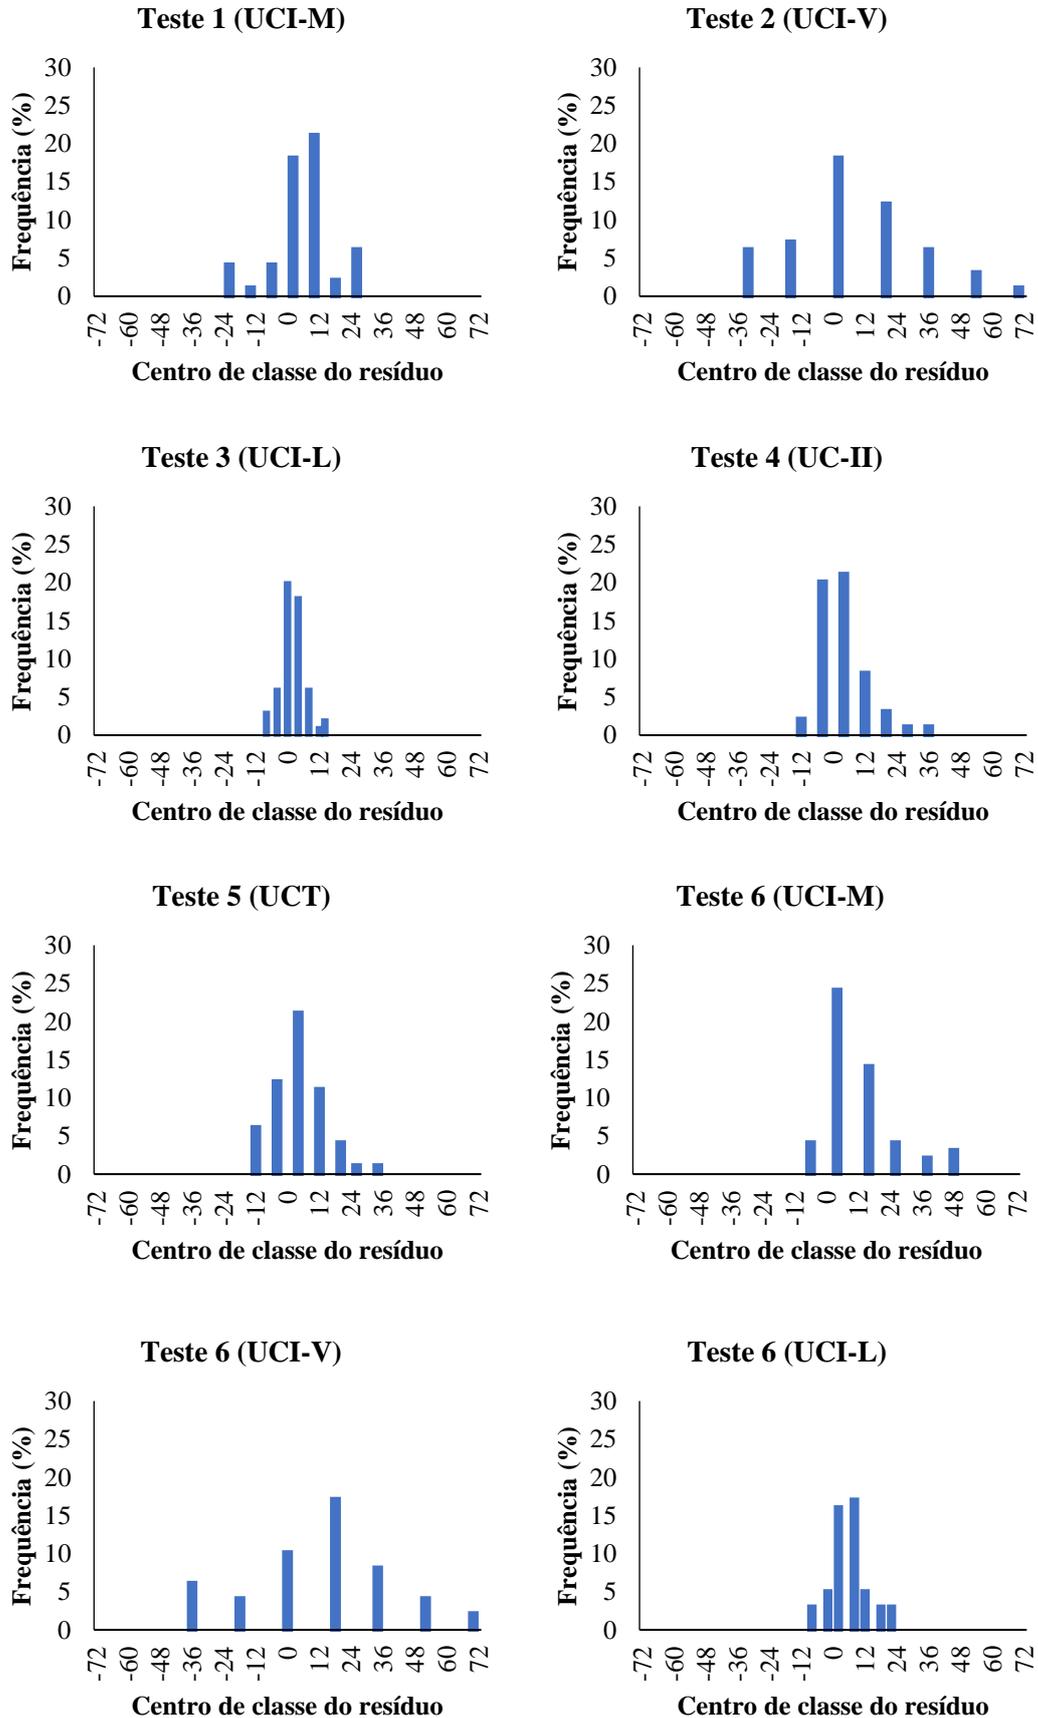


Figura 6 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100 \cdot (Y_{pred} - Y_{obs}) / Y_{obs}$, para Y = umidade do material combustível (Continuação)

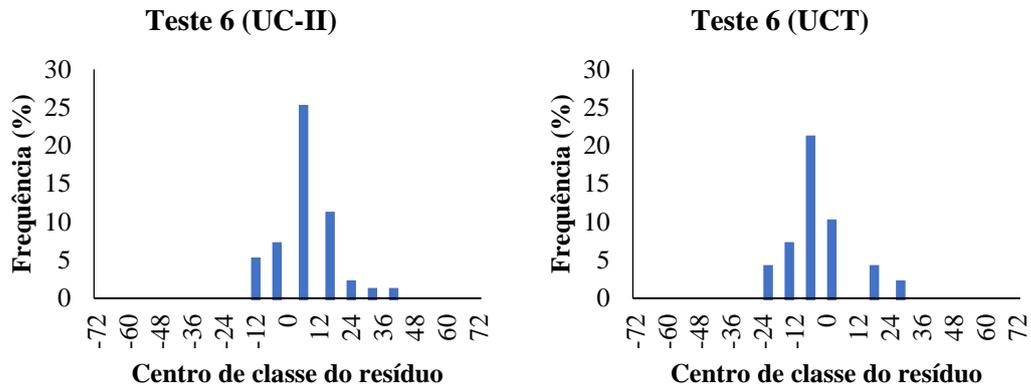


Figura 7 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100 \cdot (Y_{pred} - Y_{obs}) / Y_{obs}$, para Y = comportamento do fogo

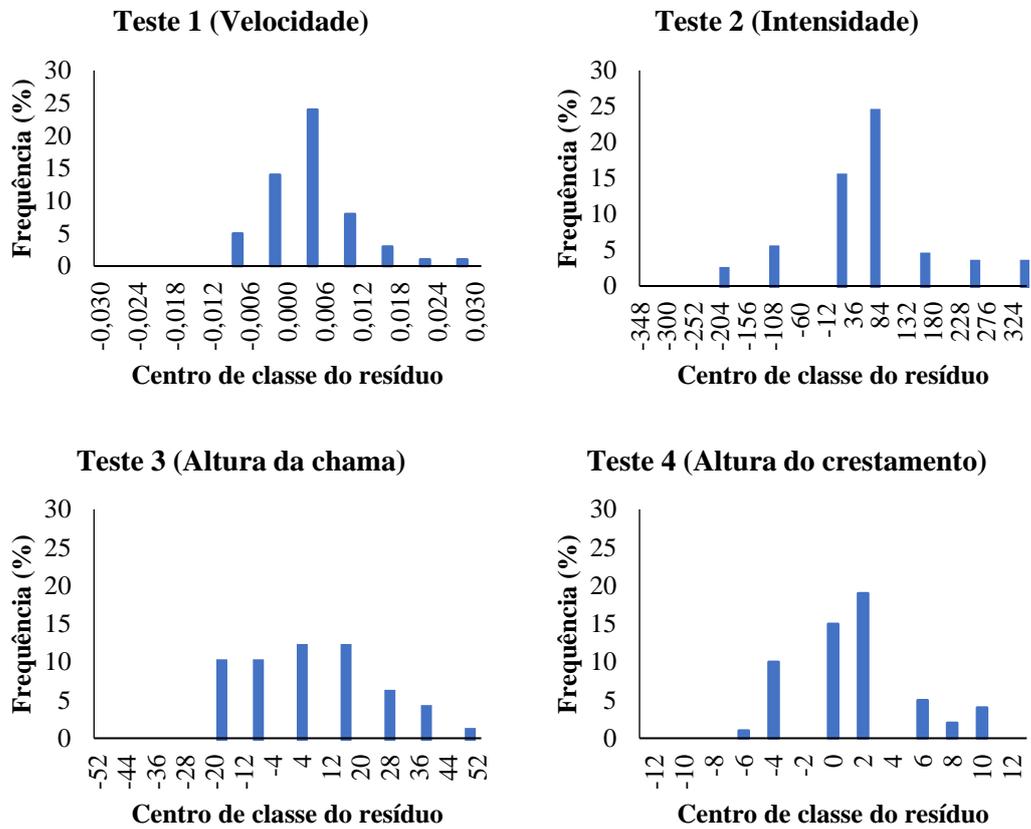
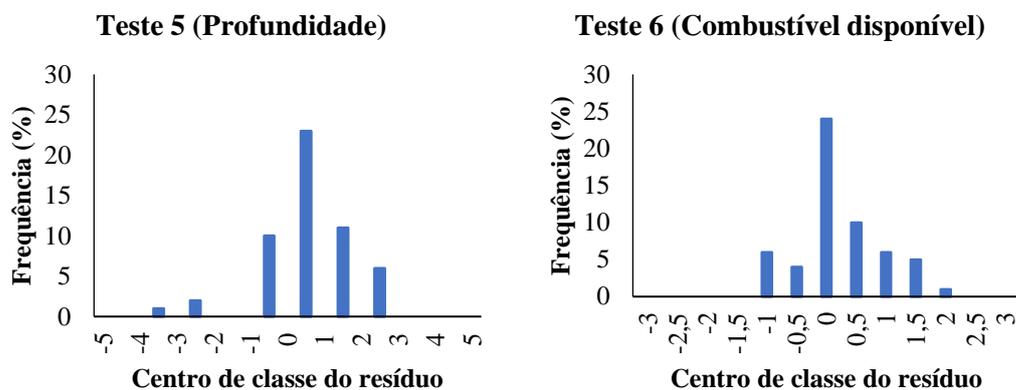


Figura 7 – Frequência de casos por classe de erro relativo percentual, $ER\% = 100 \cdot (Y_{pred} - Y_{obs}) / Y_{obs}$, para $Y =$ comportamento do fogo (Continuação)



4. DISCUSSÃO

As variáveis $Dsch$ e UR estão presentes no conjunto de variáveis de entrada de todas as redes escolhidas para estimar a umidade do material combustível. O caráter cumulativo da variável dias sem chuva no sistema reduz a umidade do combustível, além disso, o diâmetro dos materiais combustíveis e o efeito da umidade relativa do ar são inversamente correlacionados (Wastl et al., 2012; Torres et al., 2010; Torres et al., 2019). Ou seja, quanto maior o diâmetro do material combustível, menor o efeito da umidade relativa do ar sobre ele. A umidade do material combustível com menos de 0,7 cm de diâmetro é mais afetada pela precipitação pluviométrica, pois na ausência da chuva o seu valor depende da troca de vapor entre o material e o ambiente, sendo que esses materiais entram em equilíbrio com a umidade relativa do ar em cerca de uma hora (White et al., 2018).

As variáveis UR e VV estão presentes no conjunto de variáveis de entrada de quase todas as redes escolhidas para determinar o comportamento do fogo. Além disso, segundo a PCA, essas variáveis estão presentes no conjunto das seis variáveis que mais contribuem nas componentes principais do comportamento do fogo. Maior velocidade do vento e menor umidade do ar favorecem a propagação do fogo (Gomes et al., 2020; Hoffmann et al., 2012). Já as variáveis que descrevem o teor de umidade dos diferentes tipos de material combustível não estão presentes neste conjunto das seis variáveis, mas algumas delas estão presentes no *input* da maioria das RNA selecionadas, principalmente a UCI-M. Altos teores de umidade do combustível, principalmente o fino, reduzem a taxa de propagação do fogo (Ray et al., 2005). A velocidade do vento e o conteúdo de umidade do material combustível são as duas variáveis empregadas na caracterização do comportamento do fogo que apresentam maior variabilidade

no período de 24 horas, por isso elas são determinantes para a propagação do fogo e devem ser monitoradas constantemente (Viney e Hatton, 1989).

A alta correlação, tanto do treino quanto da validação, e os altos valores de p-valor em todas as redes selecionadas, mostra que o uso de RNA para prever a umidade do material combustível de diversas espessuras e o comportamento do fogo é eficiente. As correlações para estimar a umidade do material combustível vivo e da classe II são menores, porque esses materiais são mais heterogêneos e suas respostas às condições meteorológicas e ambientais são mais lentas, tornando as análises mais complexas, também os mecanismos de perda e retenção de água são mais complexos no material vivo do que dos combustíveis mortos (Brown, 1986; Alves et al. 2009; Torres et al., 2018).

As variáveis de entrada para estimar a umidade do material combustível são de fácil medição. Em algumas delas, como Dsch, UR, T°C e VV (variáveis meteorológicas), não é necessária a ida a campo. Por sua vez, para estimar o comportamento do fogo, além das variáveis meteorológicas, é fundamental saber a umidade do material combustível presente na área.

O pré-processamento feito através da PCA foi eficiente, visto que todas as redes neurais selecionadas possuem pelo menos uma das variáveis consideradas mais importantes para explicar a umidade do material combustível e o comportamento do fogo. O fato de variáveis consideradas menos importantes, como a T°C e a VV para umidade do material combustível e Dsch e UCI-M para comportamento do fogo, estarem presentes nas variáveis de entrada de boa parte das redes selecionadas, mostra que o conjunto e interação das variáveis é mais importante do que uma única variável.

5. CONCLUSÕES

A técnica de Redes Neurais Artificiais foi aplicada para a previsão da umidade do material combustível de diferentes classes de espessura e do comportamento do fogo após o início do incêndio florestal e apresentou resultados satisfatórios na avaliação de desempenho, sendo adequada para a previsão utilizando tanto as variáveis meteorológicas como variáveis preditoras, quanto as variáveis ambientais. Essa técnica pode ser usada para prever o comportamento do fogo quando o incêndio já começou.

A partir do treinamento das redes e da PCA, conclui-se que as variáveis Dsch e UR são as que mais contribuem para a umidade do material combustível e a VV e UR são as que mais contribuem para o comportamento do fogo. Não são necessárias idas a campo para medir

essas variáveis, diminuindo os custos e o tempo de realização de pesquisas relacionadas a esse tema.

Novos estudos com maior quantidade de amostras podem ser aplicados com a finalidade de aumentar a precisão da técnica RNA e otimizar os resultados de previsão.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Alves MVG, Batista AC, Soares RV, Koehler HS, Pereira JF. Fuel moisture modeling based on meteorological variables. *Floresta*. 2009;39:167–174. doi:10.5380/rf.v39i1.13736.
- Beutling A, Batista AC, Stolle L, Tetto AF, Alves MVG. Caracterização e modelagem de material combustível superficial em povoamentos de *Pinus elliottii*. *Floresta*. 2012;42(3):443–452. doi:10.5380/rf.v42i3.24105.
- Binoti DHB, Binoti MLMS, Leite HG. Configuração de redes neurais para estimação do volume de madeira. *Ciência da Madeira*. 2014;5(1):59-67. doi:10.15210/cmadv5i1.4067.
- Boden TA, Andres RJ, Marland G. Global, regional, and national fossil-fuel co2 emissions (1751-2014)(v. 2017). Environmental System Science Data Infrastructure for a Virtual Ecosystem; Carbon Dioxide Information Analysis Center (CDIAC), Oak Ridge National Laboratory (ORNL), Oak Ridge, TN (United States). doi:10.3334/CDIAC/00001_V2017.
- Brown, J. K. Handbook for inventorying surface fuels and biomass in the Interior West (Vol. 129). US Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station, 1982.
- Brown, J. K. Surface fuel loadings and predicted fire behavior for vegetation types in the northern Rocky Mountains (Vol. 358). US Department of Agriculture, Forest Service, Intermountain Research Station, 1986.
- Bui DT, Hoang ND, Samui P. Spatial pattern analysis and prediction of forest fire using new machine learning approach of Multivariate Adaptive Regression Splines and Differential Flower Pollination optimization: A case study at Lao Cai province (Viet Nam). *Journal of Environmental Management*. 2019;237:476–487. doi:10.1016/j.jenvman.2019.01.108.
- Byram GM. Combustion of forest fuels. In: Davis, K.P. (Ed.), *Forest Fire: Control and Use*. McGraw-Hill, New York, 1959.
- Chetehouna K, El Tabach E, Bouazaoui L, Gascoïn N. Predicting the flame characteristics and rate of spread in fires propagating in a bed of *Pinus pinaster* using Artificial Neural Networks. *Process Safety and Environmental Protection*. 2015;98:50–56. doi:10.1016/j.psep.2015.06.010.
- Clarke B, Fokoue E, Zhang HH. Principles and theory for data mining and machine learning. Springer Science & Business Media, 2009, 786p.
- da Gama Viganó HH, de Souza CC, Cristaldo MF, de Jesus L. Redes neurais artificiais na

- previsão de queimadas e incêndios no pantanal. *Revista Brasileira de Geografia Física*. 2017;10(5):1355–1367. doi:10.26848/rbgf.v.10.p1355-1367.
- de Assis FRV, de Mendonça IFC, da Silva JER, de Lima JR. Uso de geotecnologias na locação espacial de torres para detecção de incêndios florestais no semiárido nordestino. *Floresta* 44 (1): 133–142, 2014. doi:10.5380/rf.v44i1.32618.
- dos Reis Martins E, da Silva Binoti MLM, Leite HG, Binoti DHB, Dutra GC. Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais de eucalipto. *Revista Brasileira de Ciências Agrárias*. 2015;10(4):532–537. doi:10.5039/agraria.v10i4a5350.
- Fernández C, Fernández-Alonso JM, Vega JA. Exploring the effect of hydrological connectivity and soil burn severity on sediment yield after wildfire and mulching. *Land Degradation & Development*. 2020;31(13):1611–1621. doi: 10.1002/ldr.3539.
- Freedman D, Pisani R, Purves R. *Statistics*. W.W.Norton&Company, New York NY, 1980.
- Gomes L, Miranda HS, Silvério DV, Bustamante MMC. Effects and behaviour of experimental fires in grasslands, savannas, and forests of the Brazilian Cerrado. *Forest Ecology and Management*. 2020;458:117804. doi:10.1016/j.foreco.2019.117804.
- Graybill FA. *Theory and Application of the Linear Model*; Duxbury Press: North Scituate, MA, USA, 1976.
- Gutttag J. *Introduction to computation and programming using Python: With application to understanding data*. 2. ed. MIT Press, 2016, 647p.
- Haykin S. *Neural Networks: A Comprehensive Foundation*. 2. ed. New Jersey: Prentice Hall, 1998, 842p.
- Haykin S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001, 898p.
- Haykin SO. *Neural Networks and Learning Machines: International Version*, ed. Upper Saddle River [etc.] Pearson Education, 2009.
- Hertz J, Krogh A, Palmer RG. *Introduction to the theory of Neural Computation*. 1 ed. Boca Raton: Westview Press, 1991, 327p.
- Hoffmann WA, Jaconis S, McKinley K, Geiger E, Gotsh S, Franco AC. Fuels or microclimate? Understanding the drivers of fire feedbacks at savanna-forest boundaries. *Austral Ecology*. 2012;37:634–643. doi:10.1111/j.1442-9993.2011.02324.x.
- Holloway JE, Lewkowicz AG, Douglas TA, Li X, Turetsky MR, Baltzer JL, Jin H. Impact of wildfire on permafrost landscapes: A review of recent advances and future prospects. *Permafrost and Periglacial Processes*. 2020;31(3):371–382. doi:10.1002/ppp.2048.

- Johnstone JF, Rupp TS, Olson M, Verbyla D. Modeling impacts of fire severity on successional trajectories and future fire behavior in Alaskan boreal forests. *Landscape Ecology*. 2011;26 (4):487–500. doi:10.1007/s10980-011-9574-6.
- Kassambara A. *Practical Guide To Principal Component Methods in R (Multivariate Analysis II)*. 1 ed. STHDA. 2017, 170p.
- Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Appears in the International Joint Conference on Artificial Intelligence (IJCAI)*. 1995;14(2):1137–1145.
- Leite RV, Amaral CHD, Pires RDP, Silva CA, Soares CPB, Macedo RP, Silva AAL, Broadbent EM, Mohan M, Leite HG. Estimating stem volume in eucalyptus plantations using airborne LiDAR: A comparison of area-and individual tree-based approaches. *Remote Sensing*. 2020;12(9):1513. doi: 10.3390/rs12091513.
- Machado WC, da Fonseca Júnior ES. Redes neurais artificiais aplicadas na previsão do VTEC no Brasil. *Boletim de Ciências Geodésicas*. 2013;19(2):227–246. doi:10.1590/S1982-21702013000200005.
- Muhammad K, Ahmad J, Baik SW. Early fire detection using convolutional neural networks during surveillance for effective disaster management. *Neurocomputing*. 2018;288:30–42. doi:10.1016/j.neucom.2017.04.083.
- Polinova M, Wittenberg L, Kutiel H, Brook A. Reconstructing pre-fire vegetation condition in the wildland urban interface (WUI) using artificial neural network. *Journal of Environmental Management*. 2019;238:224–234. doi:10.1016/j.jenvman.2019.02.091.
- Piñeiro G, Perelman S, Guerschman JP, Paruelo JM. How to evaluate models: Observed vs. predicted or predicted vs. observed? *Ecological Modelling*. 2008;216:316–322. doi:10.1016/j.ecolmodel.2008.05.006.
- R Development Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2019.
- Ray D, Nepstad D, Moutinho P. Micrometeorological and canopy controls of fire susceptibility in a forested Amazon landscape *Ecological Applications*. 2005;15:1664–1678, doi:10.1890/05-0404.
- Ripley BD. *Pattern Recognition and Neural Networks*. Cambridge University Press. Cambridge, Grã Bretanha, 1996, 403p.
- Sayad YO, Mousannif H, Al Moatassime H. Predictive modeling of wildfires: A new dataset and machine learning approach. *Fire Safety Journal*. 2019;104:130–146.

- doi:10.1016/j.firesaf.2019.01.006.
- Santos MM, Martins TS, Silva DB, Cachoeira JN, Santos GR, Giongo M. Modelagem para estimativa de carga e umidade do material combustível em área de Cerrado. *Journal of Biotechnology and Biodiversity*. 2019;7(1):249–256. doi:10.20873/jbb.uft.cemaf.v7n1.moreirasantos.
- Scheper AC, Verweij PA, van Kuijk M. Post-fire forest restoration in the humid tropics: A synthesis of available strategies and knowledge gaps for effective restoration. *Science of The Total Environment*. 2021;771:144647. doi:10.1016/j.scitotenv.2020.144647.
- Silva IN, Spatti HD, Flauzino RA. *Redes Neurais Artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010, 399p.
- TIBCO Software Inc. (2018). *Statistica (data analysis software system)*, version 13.4.0.14. <http://tibco.com>. 2018.
- Terrah SM, Sabi FZ, Mosbah O, Dilem A, Hamamousse N, Sahila A, Harrouz O, Boutchiche H, Chaib F, Zekri N, Kais A, Clerc JP, Giroud F, Viegas DX. Nonexistence of critical fuel moisture content for flammability. *Fire Safety Journal*. 2020;111(102928):1–7. doi:10.1016/j.firesaf.2019.102928.
- Torres FTP, Ribeiro GA, Martins SV, Lima GS. Determinação do período mais propício às ocorrências de incêndios em vegetação na área urbana de Juiz de Fora, MG. *Revista Árvore*. 2010;34(2):297–303. doi:10.1590/S0100-67622010000200012.
- Torres FTP, Lima GS, Costa AG, Félix GA, Silva-Júnior MR. Forest fire statistics in Brazilian Conservation Units from 2008 to 2012. *Floresta*. 2017;46:531–542. doi:10.5380/rf.v46i3.44199.
- Torres FTP, Romeiro JMN, de Albuquerque Santos AC, de Oliveira Neto RR, Lima GS, Zanuncio JC. Fire danger index efficiency as a function of fuel moisture and fire behavior. *Science of the total environment*. 2018;631–632:1304–1310. doi:10.1016/j.scitotenv.2018.03.121.
- Torres FTP, Silva Júnior MRD, Lima GS. Influência dos Elementos Meteorológicos Sobre o Comportamento do Fogo. *Revista Brasileira de Meteorologia*. 2019;34(1):33–41. doi:10.1590/0102-7786334014.
- Tuyen TT, Jaafari A, Yen HPH, Nguyen-Thoi T, Van Phong T, Nguyen HD, Van Le H, Phuong TTM, Nguyen SH, Prakash I, Pham BT. Mapping forest fire susceptibility using spatially explicit ensemble models based on the locally weighted learning algorithm. *Ecological Informatics*. 2021;63:101292. doi:10.1016/j.ecoinf.2021.101292.

- UNIVERSIDADE FEDERAL DE VIÇOSA – UFV. Departamento de Engenharia Agrícola. Estação Climatológica Principal de Viçosa. Boletim meteorológico 2016. Viçosa, 2016.
- Van Wagner C. Height of crown scorch in forest fires. *Canadian journal of forest research*. 1973;3(3):373–378.
- Viney NR, Hatton TJ. Assessment of existing fine fuel moisture models applied to Eucalyptus litter. *Australian Forestry*. 1989;52(2):82–93. doi:10.1080/00049158.1989.10674540.
- Wastl C, Schunk C, Leuchner M, Pezzatti GB, Menzel A. Recent climate change: long-term trends in meteorological forest fire danger in the Alps. *Agricultural and Forest Meteorology*. 2012;162:1–13. doi:10.1016/j.agrformet.2012.04.001.
- White BLA. Modelos matemáticos de previsão do teor de umidade dos materiais combustíveis florestais finos e mortos. *Ciência Florestal*. 2018;28(1):432–445. doi:10.5902/1980509831622.
- Yebra M, Quan X, Riaño D, Larraondo PR, Van Dijk AI, Cary GJ. A fuel moisture content and flammability monitoring methodology for continental Australia based on optical remote sensing. *Remote Sensing of Environment*. 2018;212:260–272. doi:10.1016/j.rse.2018.04.053.
- Zekić-Sušac M, Šarlija N, Pfeifer S. Combining PCA analysis and artificial neural networks in modelling entrepreneurial intentions of students. *Croatian Operational Research Review*. 2013;4(1):306–317.

CAPÍTULO II:

Mapeamento de Suscetibilidade a Incêndios Florestais do Distrito de Coimbra, Portugal

Mapeamento de Suscetibilidade a Incêndios Florestais do Distrito de Coimbra, Portugal

Thaynara Lopes dos Reis ^{a,*}, Tamara Braga dos Santos ^a, Camila Nascimento Neves ^a, Ludimila Grechi Campostrini ^a, Iara Silva Sampaio ^a, Hélio Garcia Leite ^a, Fillipe Tamiozzo Pereira Torres ^a

^a Departamento de Engenharia Florestal, Universidade Federal de Viçosa (UFV), Av. Peter Henry Rolfs, s/n, Campus Universitário, 36570-900, Viçosa, MG, Brazil.

RESUMO

Os Sistemas de Informações Geográficas (SIG) são uma das ferramentas utilizadas para a criação de mapas de suscetibilidade que avaliam potenciais ocorrências de incêndios florestais em função de fatores ambientais. Essas ocorrências afetam a qualidade do meio ambiente, a vida humana e a economia. Dessa forma, o principal objetivo deste trabalho foi determinar a metodologia mais eficiente para desenvolver o mapeamento de suscetibilidade a incêndios florestais no Distrito de Coimbra, Região do Centro, Portugal. Para isso, criou-se modelos de suscetibilidade a incêndios florestais a partir das variáveis ambientais que mais influenciam na ocorrência desses eventos. A maioria dos modelos tiveram bom desempenho, porém, o Modelo 2, que utilizou a variável radiação, apresentou os maiores valores de Área sob a Curva (AUC) e de Taxa de Acurácia (ACC). Esse modelo também apresentou boa eficiência, visto que as áreas abrangidas por cada classe de suscetibilidade diminuíram com o aumento da suscetibilidade. Além disso, as maiores áreas queimadas estavam nas classes de alta e altíssima suscetibilidade e menores nas classes baixa e baixíssima. O SIG se mostrou uma ferramenta eficiente na análise de suscetibilidade a incêndios, já que apresenta maior precisão no monitoramento e na detecção desses eventos em relação aos métodos tradicionais e uma metodologia mais simples que outros modelos encontrados na literatura. Essa pesquisa mostrou que o mapeamento desenvolvido neste trabalho pode servir como ferramenta de auxílio às autoridades portuguesas na tomada de decisões em relação às melhorias das estratégias de combate de incêndios na região de estudo.

Palavras-chave: Fogo; SIG; suscetibilidade.

ABSTRACT

Geographic Information Systems (GIS) are one of the tools used to create risk maps which evaluate potential occurrences of forest fires as a function of environmental factors. These occurrences affect the quality of the environment, human life and the economy. Thus, the main objective of this work was to determine the most efficient methodology to develop forest fire risk mapping in the District of Coimbra, Centro Region, Portugal. For this, forest fire risk models were created based on the environmental variables that most influence the occurrence of these events. Most models performed well, however, Model 2, which used the radiation variable, presented the highest values for Area Under the Curve (AUC) and Accuracy Rate (ACC). This model also showed good efficiency, as the areas covered by each risk class decreased with the increase in risk. Furthermore, the largest burned areas were in the high and very high risk classes and the smallest in the low and very low risk classes. GIS proved to be an efficient tool in the analysis of fire risk, as it has greater precision in monitoring and detecting these events compared to traditional methods and a simpler methodology than other models found in the literature. This research showed that the mapping developed in this work can serve as a tool to help Portuguese authorities in making decisions regarding improvements in firefighting strategies in the study region.

Keywords: Fire; GIS; susceptibility.

1. INTRODUÇÃO

Os incêndios florestais são distúrbios comuns nas florestas que afetam a qualidade do meio ambiente, a vida humana e a economia (Ying et al., 2018). Eles são uma das maiores fontes globais de emissões de compostos carbônicos, como o CO₂, comprometendo, a nível local e global, a qualidade do ar e do clima (Volkova et al., 2019). Além disso, os incêndios florestais causam distúrbios de dimensões tais que ameaçam constantemente os ecossistemas em todo o mundo (Dwomoh et al., 2019). Eles comprometem a floração e frutificação, causam desastres ecológicos, como diminuição da qualidade da água, do solo e da vegetação, perda de vidas humanas e de animais, problemas respiratórios e de locomoção associados às fumaças emitidas, entre outros (Pourtaghi et al., 2016; Torres et al., 2017; Sousa e Cunha, 2018).

Existem alguns fatores que estão ligados diretamente à ocorrência de incêndios florestais, dentre eles: as variáveis climáticas, o material combustível característico da área e o relevo (de Assis et al., 2014). As variáveis climáticas são um dos fatores determinantes para o início e magnitude do fogo. Isto porque, as condições climáticas determinam, em escala regional, o tipo de vegetação, o teor de umidade do combustível e a quantidade de biomassa (Torres et al., 2017). Já o tipo de material combustível influencia a facilidade de ignição e a velocidade de propagação do fogo (Torres et al., 2018b). O relevo afeta a frequência, a velocidade de propagação e o tamanho das áreas queimadas (Torres et al., 2017).

Em Portugal, os casos de incêndios florestais têm crescido nas últimas décadas, o que fez com que o governo local se preocupasse em entender a causa desses eventos, para, enfim, tomar medidas cada vez mais eficazes para a prevenção da ocorrência de incêndios (Lourenço et al., 2013). O conhecimento da origem dos incêndios florestais se configura como uma ferramenta importante no embasamento de políticas de prevenção e controle que estejam de acordo com a realidade da região (Nunes et al., 2014).

Diante de tantos possíveis impactos causados pelos incêndios florestais, torna-se imprescindível o estudo da suscetibilidade de ocorrência desses eventos. As análises espaciais permitem o planejamento de ações de redução da suscetibilidade. Nesse contexto, os Sistemas de Informações Geográficas (SIG) são uma alternativa para a criação de mapas de suscetibilidade, que avaliam potenciais ocorrências em função de fatores ambientais (You et al., 2017). Os SIG, junto às imagens de satélite, permitem o monitoramento dos pontos de ignição, do perímetro do fogo e das variações de umidade e massa dos combustíveis (Bian et al., 2013).

A modelagem da suscetibilidade a incêndios tem como objetivo descrever e prever a distribuição destes eventos e, em virtude da complexidade do fogo, é coerente que os modelos tenham uma estrutura complexa que represente os diversos fatores que interferem na ignição e propagação das ocorrências (Torres et al., 2017).

Os mapas de suscetibilidade a incêndio permitem a visualização espacial das áreas com maior ou menor suscetibilidade à ocorrência desse evento em um período específico de tempo (Sousa et al., 2021). A suscetibilidade é determinada através de fatores inerentes a dados meteorológicos, de relevo, de características florestais, uso da terra e outros (de Omena et al., 2016). Estes mapas podem reunir informações sobre os incêndios de vários anos, mostrando os padrões das áreas de maior ocorrência e servindo como ferramenta de gestão estratégica para atividades de prevenção (Torres et al., 2017). Essas atividades incluem intensificar a vigilância em áreas de maior suscetibilidade, restringir o acesso a esses locais, construir aceiros preventivos e auxiliar na construção de vias de acesso a locais mais suscetíveis (Kovalsyki et al., 2020).

Diante da problemática ambiental, social e econômica causada pelos incêndios florestais, os objetivos deste trabalho foram analisar as variáveis ambientais que controlam as ocorrências de incêndios florestais, desenvolver o mapeamento da suscetibilidade a incêndios florestais no Distrito de Coimbra, Região do Centro, Portugal, além de determinar a metodologia mais eficiente para o mapeamento de suscetibilidade a incêndios na região.

2. MATERIAL E MÉTODOS

2.1 Área de estudo e dados utilizados

O presente estudo foi referente ao distrito de Coimbra, localizado na região central de Portugal (latitude 40° 12' 20. 30" e longitude -8° 25' 10. 38" W). O clima da região é mediterrânico do tipo CSA (Köppen e Geiger) caracterizado por verões secos e invernos chuvosos (IPMA, 2019). A área do distrito é de aproximadamente 394.800,32 hectares, dos quais 245.364,1 são correspondentes a florestas (DGT, 2010).

O distrito localiza-se exatamente no contato entre duas unidades geomorfológicas com características litológicas e morfológicas contrastantes: o Maciço Antigo Ibérico e a Orla Mesocenozóica Ocidental. No relevo acidentado de Coimbra, além dos principais cursos de água e áreas adjacentes, podem identificar-se cumeadas e colinas particularmente representativas, atravessando e pontuando o território (Fonseca, 2009).

Coimbra corresponde, em termos macroclimáticos, ao domínio mediterrâneo, enquanto numa análise à escala mesoclimática, para as regiões climáticas de Portugal

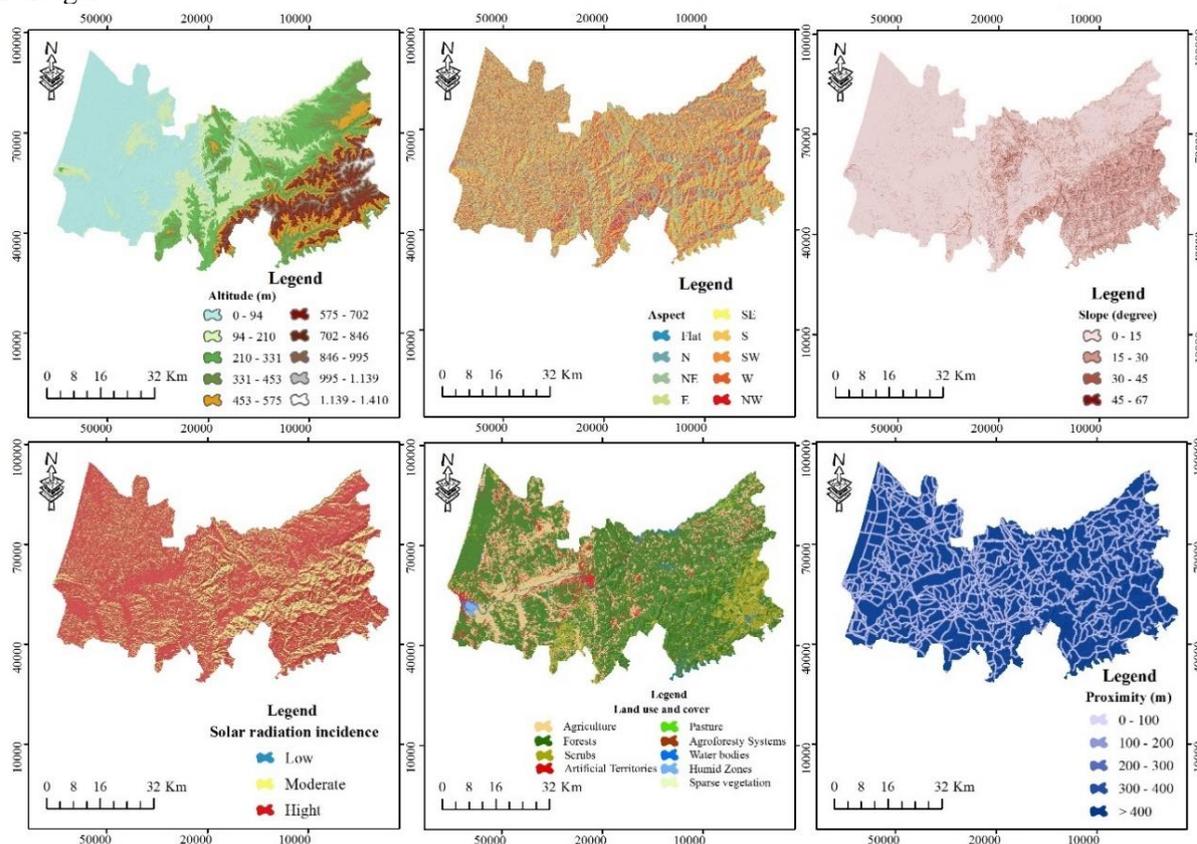
continental, o território municipal integra a região climática de influência atlântica (Medeiros, 2005).

O Modelo Digital de Elevação (MDE) foi elaborado a partir da interpolação das curvas de nível, com equidistância de 5 metros, adquiridas junto à Direção Geral do Território (DGT). A partir do MDE foram gerados os mapas referentes à inclinação do terreno, exposição das vertentes, radiação solar (Figura 1). A inclinação do terreno foi dividida nas classes de 0-15°; 15-30°, 30-45° e >45°. A exposição das vertentes foi dividida nas classes N, NW, NE, W, E, S, SW e SE. A radiação solar foi estabelecida como a média recebida anualmente entre 2000 e 2010 em baixa, média e alta.

O mapa referente ao uso e ocupação do solo (Figura 1), por sua vez, foi gerado a partir de dados da Carta de Ocupação do Solo (COS) do ano de 2010 (resolução espacial de 0,5 m) da DGT. A COS 2010 foi utilizada como limite da série histórica. Sendo assim, os dados entre 1993 e 2010 foram utilizados para gerar os modelos e os dados a partir de 2011 para testar a eficiência dos modelos gerados. Foram vetorizadas as seguintes classes: territórios artificiais; agricultura; pastagem; sistemas agroflorestais (SAF); florestas; espaços descobertos ou com vegetação esparsa; matos; zonas úmidas e corpos d'água. Sendo que, foi considerado territórios artificiais, todas as superfícies artificializadas ou ajardinadas, destinadas às atividades relacionadas com as sociedades humanas. Esta classe inclui áreas de tecido urbano, áreas industriais, áreas comerciais, rede rodoviária e ferroviária, áreas de serviços, jardins ou parques urbanos e equipamentos culturais e de lazer. “Espaços descobertos ou vegetação esparsa” engloba áreas em que a superfície com vegetação arbustiva e herbácea ocupa uma área superior ou igual a 10% e inferior a 25%, e em que a superfície sem vegetação ocupa uma área superior ou igual a 75%. Não inclui áreas em que a superfície coberta por árvores seja superior ou igual 10%. A classe “Matos” compreende áreas naturais de vegetação espontânea, pouco ou muito densa, em que o coberto arbustivo é superior ou igual a 25%. Exclui florestas abertas. “Zonas úmidas” abrange áreas da margem de lagoas, rios e ribeiros ou de brejos e pântanos eutróficos, onde se verifique a predominância de solos húmidos alagados, permanentemente ou temporariamente, por água doce ou salobra. Inclui ainda zonas de águas paradas com coberto vegetal particular, constituído por arbustos baixos e espécies lenhosas ou semilenhosas. “Corpos d'água” compõe-se de superfícies de água doce que incluem cursos de água e planos de água, naturais e artificiais; superfícies de água salgada, que incluem oceanos, e/ou de água salobra que incluem lagoas costeiras e desembocaduras fluviais.

A COS 2010 também foi utilizada para elaborar o mapa proximidades (Figura 1), a partir do estabelecimento de *buffers* sobre todas as vias de acesso existentes, determinando as proximidades de 0-100 m, 100-200 m, 200-300 m, 300-400 m e >400m.

Figura 1 – Cartogramas utilizados para a geração do mapa de suscetibilidade a incêndios em Coimbra, Portugal



O mapa das áreas queimadas na região de estudos foi gerado a partir dos registos recolhidos na cartografia nacional de áreas ardidas, divulgada pelo Instituto da Conservação da Natureza e das Florestas (ICNF, 2019). Esse último mapa foi utilizado para atribuir as notas e para a validação dos modelos. Os dados registados no período entre 2001 e 2010 foram utilizadas para atribuir notas a cada uma das variáveis e as ocorrências entre 2011 e 2018 para testar a eficiência dos modelos.

Para determinar o período seco e, conseqüentemente, a época do ano em que é mais provável a ocorrência de incêndios no distrito de Coimbra, foram utilizados os dados meteorológicos médios e anomalias de temperatura do ar (mínima, média e máxima) e precipitação total mensais, recolhidos junto ao Instituto Português do Mar e da Atmosfera (IPMA, 2019).

2.2 Análises estatísticas e modelos espaciais

A confecção dos cartogramas de suscetibilidade a incêndios florestais foi realizada com o software ArcGIS 10.3.1, no qual também foram gerados os mapas de inclinação do terreno, exposição das vertentes, uso e ocupação do solo, radiação solar acumulada, proximidades das vias de acesso e o das áreas queimadas na região de estudo. A fim de determinar a suscetibilidade a incêndios da área, foi feito o intercruzamento de informações sobre a inclinação do terreno, exposição das vertentes, uso e ocupação do solo, radiação solar acumulada e proximidades.

A primeira análise da modelagem consistiu na atribuição de notas a cada uma das classes das variáveis utilizadas conforme o favorecimento à ocorrência de incêndios. Essas notas foram atribuídas de três formas (Tabela 1). Na primeira, as variáveis (classes das informações do uso do solo, da exposição das vertentes, da radiação solar, da inclinação do terreno e das proximidades) receberam notas de acordo com sua influência no início e propagação do incêndio. Assim, as variáveis mais favoráveis aos incêndios receberam notas mais altas e as menos favoráveis, as mais baixas (Torres et al., 2014). Na segunda, as notas foram proporcionais à área queimada da variável em relação à área queimada total no período. Na terceira forma, as notas foram em função da porcentagem da área queimada em cada variável em função área total da variável.

Tabela 1 – Notas atribuídas a cada variável analisada de acordo com sua forma de atribuição

Classes das variáveis	Formas de dar notas		
	1	2	3
Uso e cobertura do solo			
Áreas agrícolas	2	0,8	1,1
Corpos hídricos	0	1,9	0,7
Espaço descoberto ou vegetação esparsa	6	3,1	6,4
Florestas	8	2,3	5
Matos	10	10	10
Pastagem	4	2,2	0,8
SAF	2	0	0
Territórios artificiais	1	0,7	1,2
Zonas húmidas	0	0,1	0,4
Proximidades			
0 a 100 m	10	6,2	4,4
100 a 200 m	9	6,6	4,8
200 a 300 m	8	7,2	5,4
300 a 400 m	7	7,8	6,3
>400 m	7	10	10
Exposição das vertentes			

Plano	1	1,6	3,2
N	4	7,9	6,7
E	8	9,4	8,7
NE	7	8,4	7,7
NW	5	8,4	6,5
S	10	10	10
SE	9	9,7	9,6
SW	8	9,5	8,5
W	6	8,3	7,3
Inclinação do terreno			
0° a 15°	7	2,9	5,8
15° a 30°	8	8,3	10
30° a 45°	9	10	9,3
Maior que 45°	10	8,5	6,1
Radiação Solar			
Baixo acumulo	8	10	7,6
Médio acumulo	9	5,4	5,2
Alto acumulo	10	4,3	10

De posse da reclassificação dos mapas com as respectivas notas, eles foram intercruzados – através da multiplicação das notas conferidas a cada classe – com pesos diferentes. Os cruzamentos entre os mapas foram realizados conforme metodologia de Torres et al. (2014) e forneceram a suscetibilidade a incêndios. Foram gerados dois mapas para cada forma de atribuição de notas, totalizando seis mapas de suscetibilidade a incêndios de modo a determinar a metodologia de maior eficiência para a área de estudo.

A segunda análise da modelagem consistiu na distribuição das classes de suscetibilidade em função do tamanho da área, cujas classes foram nomeadas como “baixíssima”, “baixa”, “média”, “alta” e “altíssima”. Para se determinar os limites dos valores de cada uma destas classes nos 6 modelos básicos foram testados 5 métodos: Natural Breaks, Quantile, Geometrical Interval, Standard Deviation e Equal Interval (Esri, 2019).

Na terceira análise da modelagem, o mapa das áreas queimadas na região de estudo no período entre 2010 e 2018 foi sobreposto em cada um dos seis mapas de suscetibilidade a incêndios, para realização da validação e avaliação de qual modelo é o mais eficiente para a área de estudo. A performance do modelo mais eficiente foi avaliada a partir do tamanho das áreas queimadas em cada classe e da porcentagem da área total queimada que queimou em cada classe. O ideal é ter maior porcentagem de área queimada em classes de maior suscetibilidade e menor em classes de menor suscetibilidade.

2.3 Comparação dos modelos

Para a comparação dos modelos foi utilizada uma Receiver Operating Characteristic curve (ROC) (Bradley, 1997), que é a representação gráfica do par de valores da taxa positiva verdadeira (TPR) (Equação 1) e da taxa positiva falsa (FPR) (Equação 2), de acordo com as classes de suscetibilidade incêndios. Assim, cada valor do conjunto de dados é classificado em quatro categorias (Bui et al., 2018): i. verdadeiro positivo (TP): somatório das áreas que os modelos classificaram como de suscetibilidade a ocorrências de incêndios (classes altíssima, alta e média) e realmente queimou; ii. falso positivo (FP): somatório das áreas que os modelos julgaram prováveis de ocorrer incêndios (classes altíssima, alta e média) e não queimou; iii. verdadeiro negativo (TN) somatório das áreas que os modelos indicaram uma baixa suscetibilidade a incêndio (classes baixa e baixíssima) e não queimou; e iv. falso negativo (FN): somatório das áreas em que os modelos julgaram que a área tinha baixa suscetibilidade a queimar (classes baixa e baixíssima), mas ocorreu um incêndio. Esta análise permite selecionar o modelo matemático mais eficiente e descartar índices abaixo do ideal.

$$TPR = TP / (TP + FN) \quad (1)$$

$$FPR = FP / (FP + TN) \quad (2)$$

Em que, TPR é a taxa positiva verdadeira; TP é o verdadeiro positivo; FN é o falso negativo; FPR é a taxa positiva falsa; FP é o falso positivo; e TN é o verdadeiro negativo.

Na tentativa de simplificar a análise da ROC, calculou-se a Área sob a Curva (AUC) (Equação 3), que é a probabilidade de uma área queimada, escolhida aleatoriamente, ser classificada pelo modelo como com possibilidade de queimar (altíssima, alta e média), do que uma área não queimada escolhida aleatoriamente (Thach et al., 2018; Bui et al., 2018). Os valores de AUC variam entre 0 e 1. Abaixo de 0.6 significa que o modelo não é adequado, pois sua eficiência está muito próxima ao acaso (50% de chances de errar e/ou de acertar as previsões); valores entre 0.6 e 0.7 apontam desempenho fraco; entre 0.7 e 0.8 moderado; entre 0.8 e 0.9 bom desempenho; e entre 0.9 e 1.0 significa que o modelo apresenta desempenho excelente (Thach et al., 2018; Bui et al., 2018).

$$AUC = (TPR - FPR + 1) / 2 \quad (3)$$

Em que, AUC é a área sob a curva; TPR é a taxa positiva verdadeira; FPR é a taxa positiva falsa.

Outro cálculo realizado foi o da Taxa de Acurácia (ACC) (Equação 4). Ela mede a relação entre o somatório das previsões corretas, ou seja, somatório das áreas que o modelo

previu que queimaria e realmente queimou e o somatório das áreas que o modelo previu que não queimaria e não queimou, e a área total do distrito.

$$ACC = (TP + TN) / (TP+FP+TN+FN) \quad (4)$$

Em que, ACC é a taxa de acurácia; TP é o verdadeiro positivo; TN é o verdadeiro negativo; FP é o falso positivo; e FN é o falso negativo.

Após a escolha do modelo mais eficiente, calculou-se o tamanho das áreas que queimaram mais de uma vez e em qual classe de suscetibilidade elas estavam inseridas. Isto foi feito através da interseção dos polígonos das áreas queimadas entre 2001 e 2018.

3. RESULTADOS

O período seco coincidiu com o período que teve maior ocorrência de incêndios florestais (julho e agosto), porém, as maiores áreas queimadas coincidem com outubro, mês fora da estação seca (Figura 2). Entre os anos de 2001 e 2018, o distrito de Coimbra teve 39,23% do seu território atingido por incêndios (Figura 3).

Figura 2 – Período seco, números de ocorrências médias e áreas queimadas médias mensais do distrito de Coimbra

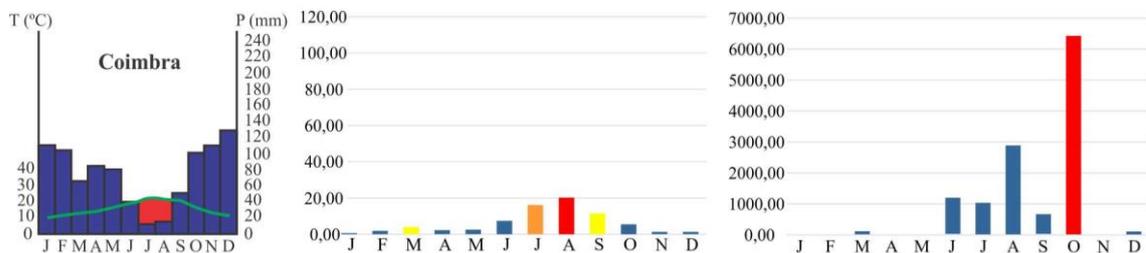
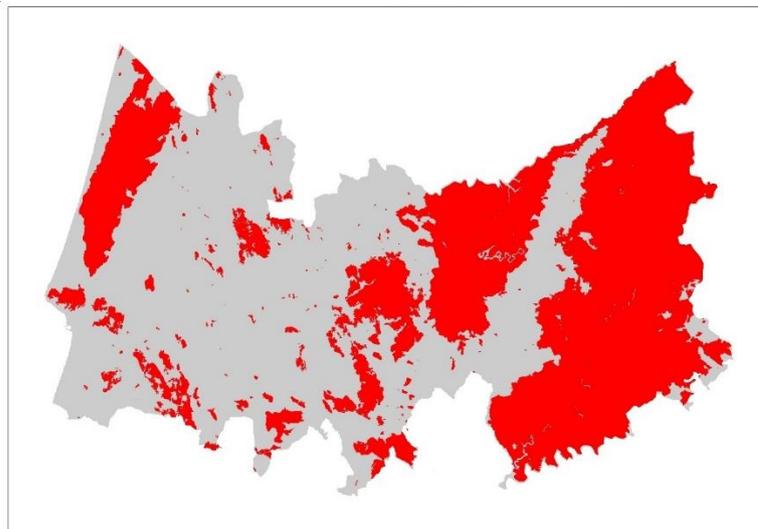


Figura 3 – Áreas queimadas no distrito de Coimbra entre 2001 e 2018



Na tabela 2, é apresentada a percentagem de área queimada em cada uma das classes avaliadas. As classes “Florestas”, “>400 m”, “0-15°” e “alto acumulado” obtiveram maiores percentagens de áreas queimadas nas variáveis uso do solo, proximidades, inclinação do terreno e radiação solar, respectivamente. Já na variável exposição das vertentes, não houve grande variação entre as percentagens de áreas queimadas, mas deve-se destacar que nas “áreas planas” quase não houve incêndio.

Tabela 2 – Área (ha) e percentagem das áreas queimadas de cada variável em Coimbra, Portugal

Classes das variáveis	Hectares	%
Uso e cobertura do solo		
Áreas agrícolas	2689,21	4,2
Corpos hídricos	345,35	0,59
Esp. Desc. ou c/ veg. esp.	322,49	0,53
Florestas	34686,94	56,7
Matos	22359,64	36,6
Pastagem	81,96	0,13
SAF	0	0
Territórios artificiais	617,01	1
Zonas húmidas	4,92	0,01
Proximidades		
0 a 100 m	6949,05	11,4
100 a 200 m	6695,55	11
200 a 300 m	6404,34	10,5
300 a 400 m	6111,99	10
>400 m	34947,21	57,2
Exposição das vertentes		
Plano	14,98	1,6
N	7288,59	11,9
E	7390,2	12,1
NE	6727,18	11
NW	7706,84	12,6
S	8519,43	13,9
SE	6855,82	11,2
SW	8525,38	14
W	8077,58	13,2
Inclinação do terreno		
0° a 15°	29294,29	47,9
15° a 30°	26498,5	43,4
30° a 45°	5205,32	8,52
Maior que 45°	109,42	0,18
Radiação Solar		
Baixo acumulo	609,31	1
Médio acumulo	20782,5	34

O método Equal Interval (Esri, 2019) foi o mais eficiente para a categorização dos modelos de suscetibilidade a incêndio em Coimbra. O modelo que usou a variável radiação solar e o método de atribuição de nota de acordo com a favorabilidade natural ao referido distúrbio ecológico derivou o modelo mais eficiente (Modelo 2). Isto porque, além de apresentar alto valor de TPR e baixo valor de FPR, este modelo possui as maiores percentagens de AUC e ACC (Figura 4). Por outro lado, todas as propostas metodológicas proporcionaram modelos com boa precisão aos incêndios florestais (0,83 ~ 0,90 AUC), exceto o modelo 6 (AUC = 0,62), o qual foi utilizado a variável radiação solar e o método de notas baseado na ponderação da porcentagem de área queimada na variável e sua respectiva área (Figura 5).

Figura 4 – Gráficos ROC dos modelos básicos gerados para o distrito de Coimbra

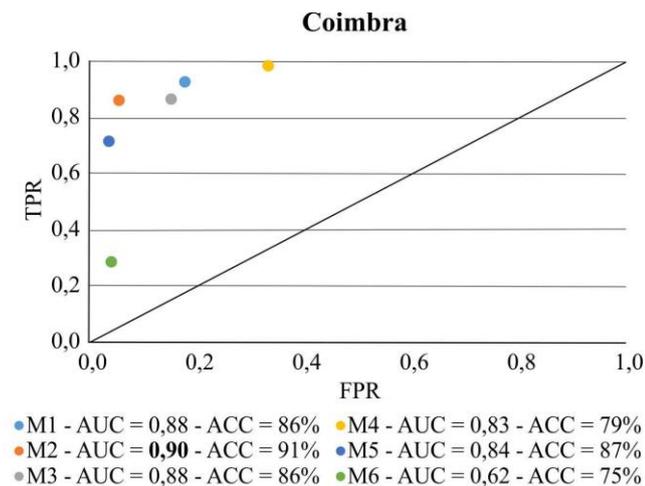
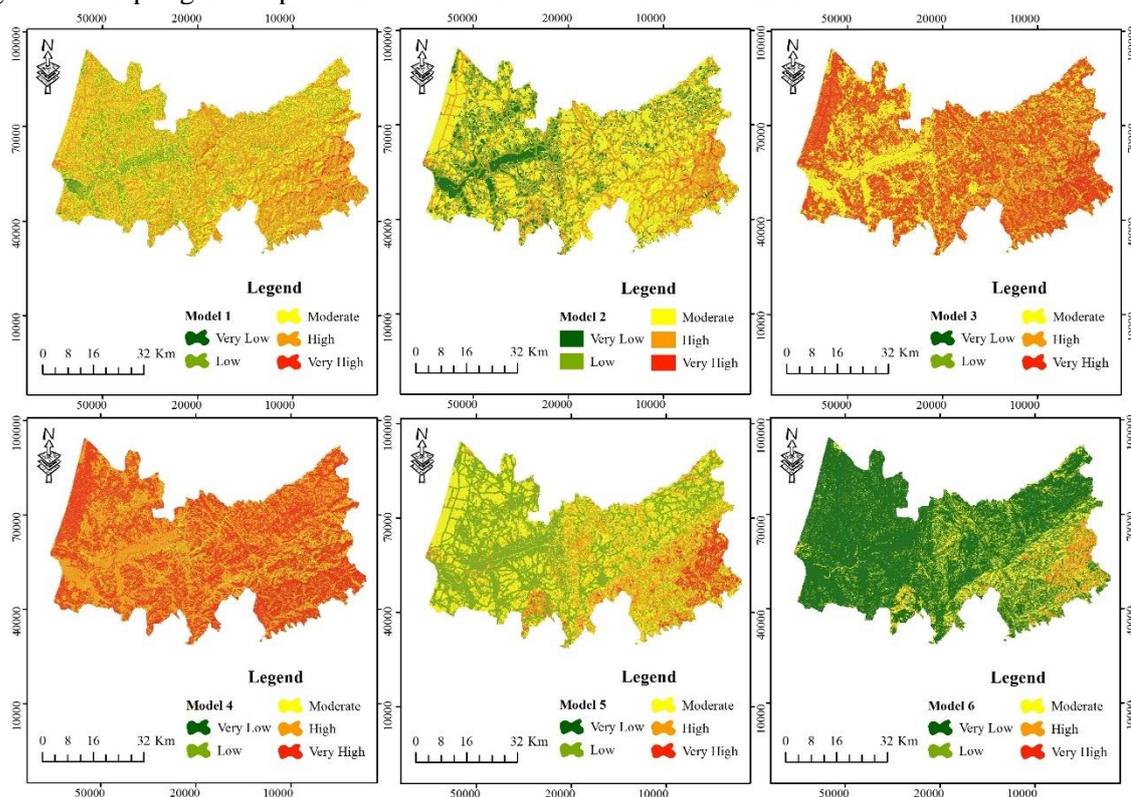


Figura 5 – Mapas gerados pelos modelos básicos no distrito de Coimbra



Na tabela 3, são apresentadas as áreas de cada classe de suscetibilidade a incêndios e as áreas que realmente queimaram em cada classe do modelo 2. Pode-se observar que apenas 4,74% das áreas classificadas como baixíssima suscetibilidade foram queimadas e que 142,30% das áreas de altíssima suscetibilidade queimaram. Esta percentagem maior do que 100 demonstra que algumas áreas queimaram mais de uma vez.

Tabela 3 – Áreas das classes e áreas queimadas em cada classe do melhor modelo gerado para o distrito de Coimbra

Classes	Área das classes		Área queimada em cada classe	
	Hectares	%	Hectares	%
Baixíssima	198.139,25	50,71	9396,07	4,74
Baixa	47.263,18	12,10	11.521,44	24,38
Média	96.227,80	24,63	84.920,69	88,25
Alta	47.074,37	12,05	44.544,06	94,62
Altíssima	2.031,72	0,52	2.891,07	142,30
Total	390.736,32	100,00	153.273,34	39,23

Em relação as áreas que queimaram mais de uma vez, as maiores áreas de recorrências estavam nas classes de mais alta suscetibilidade de queimar, e as menores áreas de recorrência, nas classes com menor suscetibilidade de queimar (Tabela 4).

Tabela 4 – Tamanho das áreas que queimaram mais de uma vez entre 2001 e 2018 no distrito de Coimbra

Classes	Hectare	%
Baixíssima	170,45	0,09
Baixa	131,81	0,28
Média	5.682,52	5,91
Alta	3.322,40	7,06
Altíssima	261,36	12,86
Total	9.568,54	2,45

4. DISCUSSÃO

O mês de outubro apresentou a maior área queimada mesmo sendo um mês fora da estação seca e quando os materiais combustíveis contêm muita umidade. Isso porque, em 2017, a região de Coimbra apresentou o segundo maior registro de temperaturas e o terceiro menor registro de precipitação, ambos desde de 1931. Com isso, o período de estiagem prolongou até o mês de outubro, quando duas ondas de calor, acrescidas da passagem do furacão Ofélia e suas rajadas de vento, possibilitou a queima de cerca de 100.000 ha (ICNF, 2017; IPMA, 2018; Fernandes e Lourenço, 2019). Desconsiderando as ocorrências de 2017, o mês com maior área queimada foi agosto.

Entre 2001 e 2018, o ano de 2005 foi o que Coimbra registrou a maior área queimada. Esse ano registrou o valor mais baixo do total de precipitação desde 1931, entre 500 e 600 mm, e a média da temperatura máxima foi de 21,55°C, correspondendo ao segundo valor mais alto desde 1931 (IPMA, 2005).

As grandes áreas de florestas homogêneas propiciam áreas queimadas com grandes dimensões, justificando o 56,68% de áreas queimadas dessa classe na variável uso do solo. As áreas cobertas por arbustos, herbáceas e outras vegetações estão sendo intensificadas por causa do abandono das áreas rurais, por causa do êxodo rural, e também devido a projetos de reflorestamento. Isso faz com que aumente a quantidade, homogeneidade e conectividade de combustíveis, causando grandes incêndios nos períodos mais secos (Amato et al., 2018; Iriarte-Goñi et al., 2018; Fernandes et al., 2019). Este mesmo tipo de vegetação também foi o mais afetado pelos incêndios florestais em um estudo feito no sul da França, em que mostrou que essa cobertura do solo foi positivamente relacionada ao número de grandes incêndios, enquanto a alta cobertura florestal foi negativamente ligada a este parâmetro (Ganteaume e Jappiot, 2013)

A diminuição da prática de agricultura de baixa intensidade e das práticas de pastoreio, fazendo com que o solo seja coberto por vegetação que queima facilmente, também

contribuiu para a maior porcentagem de área queimada nas áreas com mais de 400m de proximidade (Amato et al., 2018; Iriarte-Goñi et al., 2018).

Em áreas mais acidentadas o material combustível está mais próximo da linha de frente do fogo e, por isso, tende a superaquecer, aumentando a velocidade propagação do fogo (Sousa et al., 2021). Este evento ocorre de forma mais lenta nos declives e a expansão do fogo é, aproximadamente, elíptica, resultando em formas mais alongadas quando o vento e/ou o declive são mais fortes (Ribeiro et al., 2008; Moreira et al., 2010). No entanto, neste estudo, foi verificado que a maior porcentagem de área queimada se concentrou em inclinações abaixo de 30°, devido ao fato deste tipo de relevo ser predominante na região.

A análise da incidência da radiação solar no relevo é essencial no diagnóstico de áreas mais propícias à ocorrência de incêndios florestais, sendo um parâmetro indireto do conteúdo de umidade do material combustível (Brandão e Miranda, 2012; Pereira et al., 2012). A exposição de vertentes influencia a temperatura de um local de acordo com sua posição latitudinal (Torres et al., 2016). Estando a área de estudo localizada no hemisfério Norte, suas vertentes voltadas para o sul são mais quentes e secas, promovendo a perda mais rápida de umidade do material combustível. Altas temperaturas e longos períodos de estiagem promovem a secagem progressiva da matéria orgânica, afetando também o teor de água da vegetação verde e promovendo maior facilidade de ignição e propagação do fogo (Camargos et al., 2015). Também foi possível observar que não houve grande diferença entre as áreas queimadas nas outras orientações de vertentes, já que estas foram menos representativas na área de estudo.

Muitos fatores, ambientais ou não, controlam a ignição e propagação dos incêndios, tornando-se impossível a tarefa de encontrar o melhor modelo universal (Pérez-Sánchez et al., 2017). Por isso, a seleção ou verificação de um modelo de suscetibilidade a incêndio de uma determinada área deve basear-se em critérios estatísticos (Schunk et al., 2017). Os modelos de suscetibilidade a incêndio descrevem e preveem a distribuição dos eventos (Torres et al., 2017). A validação é uma tentativa de aumentar o grau de confiança de que os eventos inferidos por um modelo irão, de fato, ocorrer nas condições assumidas (Paz et al., 2011). Para avaliação da eficiência e validação dos modelos utilizados no mapeamento da suscetibilidade a incêndios, é necessário analisar a relação entre a concentração de ocorrências de incêndios em cada classe de suscetibilidade. Assume-se que a classe de baixíssima suscetibilidade deve compreender a maior extensão da área de estudo e que o tamanho da área abrangida por cada classe de suscetibilidade deve diminuir com o aumento da suscetibilidade,

chegando à classe de altíssima suscetibilidade, com a menor extensão de área (Torres et al., 2017). Assim, é esperado que as classes de menor suscetibilidade (baixíssima e baixa) compreendam as menores somas de ocorrências de incêndios enquanto as classes de maior suscetibilidade (altíssima e alta) deveriam apresentar as maiores somas de ocorrências. Dessa forma, o modelo 2, que usou a radiação solar, foi o mais adequado para mapeamento das ocorrências de incêndio na região do estudo, pois obteve as maiores áreas queimadas nas classes de alta e altíssima suscetibilidade e menores nas classes baixa e baixíssima. Além disso, neste modelo, as áreas classificadas como sendo de maior suscetibilidade a ocorrência de incêndios apresentaram a maior porcentagem de recorrência, onde cerca de 12,86% dessas áreas queimaram mais de uma vez. As notas desse modelo foram atribuídas sem levar em conta o histórico dos incêndios no distrito de Coimbra, e sim, de acordo com a influência de cada variável à ocorrência deles. Com isso, percebe-se que o meio físico, sobretudo o uso do solo e radiação solar, são determinantes nas ocorrências de incêndios. Em lugares onde isto não acontece, a intervenção antrópica acaba mascarando as influências do meio físico.

Todos os modelos apresentaram boa eficiência, sendo esta semelhante às obtidas em estudos que utilizaram metodologias mais complexas como o uso de inteligência artificial e modelos híbridos (Leuenberger et al., 2018; Thach et al., 2018; Bui et al., 2018). Nem sempre as áreas terão profissionais para a criação e atualização desses modelos mais complexos, então, a metodologia desse estudo, por ser mais simples, facilita a modelagem nessas áreas.

Entre as classes preditoras avaliadas, a radiação solar acumulada (RSA) foi determinante no mapeamento de suscetibilidade enquanto a exposição das vertentes não apresentou grandes alterações entre suas variáveis. As áreas com maior radiação solar apresentaram maior porcentagem de área queimada, enquanto as áreas com menores radiações obtiveram a menor fração (Torres et al., 2014). A ocorrência de incêndios florestais de grande magnitude em Portugal e no Sudoeste da Europa tem forte influência da atividade solar na ignição dos mesmos (Gomes e Radovanovic, 2008). Nos períodos de estiagem, a radiação é um dos fatores que mais contribuem para potencializar a ocorrência de incêndios, já que o aumento da temperatura do ar cria um cenário propício à combustão (Viganó et al., 2018).

A maior parte dos incêndios na Europa tem origem antrópica, ou seja, há uma influência substancial na ignição a variável causada pelo homem e esta intervenção antrópica não é prevista nos cálculos (Wastl et al., 2012; San-Miguel-Ayanz et al., 2013; Torres et al., 2018a). Devido a isso, mesmo que o perigo seja máximo, pode não ocorrer o incêndio, ou ainda, mesmo que o perigo seja mínimo, se houver influência antrópica, o evento pode

acontecer. Para que um incêndio ocorra, é necessária a chama inicial para dar início à reação de combustão e não apenas que todas as variáveis estejam favoráveis à ignição inicial e propagação do fogo.

5. CONCLUSÕES

O modelo 2 foi considerado como o mais adequado para o mapeamento de suscetibilidade a incêndios, pois apresentou maiores porcentagens de áreas queimadas nas classes “alta” e “altíssima” e menores nas classes “baixa” e “baixíssima”. A variável radiação solar acumulada foi determinante no mapeamento da suscetibilidade.

O SIG se mostrou uma ferramenta eficiente na análise de suscetibilidade a incêndios, já que apresenta maior precisão no monitoramento e na detecção desses eventos em relação aos métodos tradicionais e uma metodologia mais simples que outros modelos encontrados na literatura.

O mapeamento desenvolvido neste trabalho pode servir como ferramenta de auxílio às autoridades portuguesas na tomada de decisões em relação às melhorias das estratégias de combate de incêndios na região de estudo.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Amato F, Tonini M, Murgante B, Kanevski M. Fuzzy definition of Rural Urban Interface: An application based on land use change scenarios in Portugal. *Environmental Modelling & Software*. 2018;104:171–187. doi:10.1016/j.envsoft.2018.03.016.
- Bian H, Zhang H, Zhou D, Xu J, Zhang Z. Integrating models to evaluate and map grassland fire risk zones in Hulunbuir of Inner Mongolia, China. *Fire Safety Journal*. 2013;61:207–216. doi:10.1016/j.firesaf.2013.09.004.
- Bradley AE. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognit*. 1997;30(7):1145–59. doi:10.1016/S0031-3203(96)00142-2.
- Brandão CB, Miranda RAC. Relações entre elementos climáticos e geográficos nas ocorrências de incêndio florestal no Parque Estadual da Pedra Branca – RJ. *Revista Brasileira de Climatologia*. 2012;10:171–184. doi:10.5380/abclima.v10i1.30597.
- Bui DT, Van Le H, Hoang ND. GIS-based spatial prediction of tropical forest fire danger using a new hybrid machine learning method. *Ecological Informatics*. 2018;48:104–116. doi:10.1016/j.ecoinf.2018.08.008.
- Camargos VLD, Ribeiro GA, Silva AFD, Martins SV, Carmo FMDS. Estudo do comportamento do fogo em um trecho de floresta estacional semidecídua no município de Viçosa, Minas Gerais. *Ciência Florestal*. 2015;25(3):537–545. doi:10.5902/1980509819605.
- de Assis FRV, de Mendonça IFC, da Silva JER, de Lima JR. Uso de geotecnologias na locação espacial de torres para detecção de incêndios florestais no semiárido nordestino. *Floresta*. 2014;44(1):133–142. doi:10.5380/rf.v44i1.32618.
- de Omena MTR, Taniwaki MH, Schimalski MB, Santos PS, Araki EK. Zoneamento do Risco de Incêndio Florestal para o Parque Nacional de São Joaquim – SC. *Biodiversidade Brasileira*. 2016;6(2):173–186. doi:10.37002/biobrasil.v%25vi%25i.442.
- DGT - Direção Geral do Território. Carta de Uso e Ocupação do Solo de Portugal Continental para 2010.
- Dwomoh FK, Wiberly MC, Cochrane MA, Numata I. Forest degradation promotes fire during drought in moist tropical forests of Ghana. *Forest Ecology and Management*. 2019;440:158–168. doi:10.1016/j.foreco.2019.03.014.
- ESRI. Data classification methods. URL. <https://pro.arcgis.com/en/pro-app/help/mapping/layer-properties/data-classification-methods.htm>, Acesso em: julho de

- 2019.
- Fernandes S, Lourenço L. Grandes incêndios florestais de março, junho e outubro (fora do período crítico) em Portugal continental. *Territorium*. 2019;26:15–34. doi:10.14195/1647-7723_26-2_2.
- Fonseca MRM. Coimbra, cidade verde: introdução à análise dos espaços verdes da cidade de Coimbra. FCTUC Arquitetura. 2009.
- Ganteaume A, Jappiot M. What causes large fires in Southern France. *Forest Ecology and Management*. 2013;294:76–85. doi:10.1016/j.foreco.2012.06.055.
- Gomes JFP, Radovanovic M. Solar activity as a possible cause of large forest fires—A case study: Analysis of the Portuguese forest fires. *Science of the total environment*. 2008;394(1):197–205. doi:10.1016/j.scitotenv.2008.01.040.
- ICNF - Instituto da Conservação da Natureza e das Florestas. URL:<https://www.icnf.pt/>, Acesso em: julho de 2019.
- IPMA - Instituto Português do Mar e da Atmosfera. Boletins Climatológicos. URL. <http://www.ipma.pt/pt/oclima/normais.clima/>, Acesso em: dezembro de 2019.
- IPMA - Instituto Português do Mar e da Atmosfera. Boletim meteorológico anual - anos 2002, 2003, 2004, 2005, 2006, 2007, 2008, 2009, 2010, 2011, 2012, 2013, 2014, 2015, 2016, 2017, 2018. Relatório técnico, Instituto Português do Mar e da Atmosfera. URL. <http://www.ipma.pt/pt/oclima/normais.clima/>, Acesso em: dezembro de 2019.
- Iriarte-Goñi I, Ayuda MI. Should Forest Transition Theory include effects on forest fires? The case of Spain in the second half of the twentieth century. *Land Use Policy*. 2018;76:789–97. doi:10.1016/j.landusepol.2018.03.009.
- Kovalsyki B, Tetto AF, Batista AC, Sousa NJ, do Carmo MRB, Soares RV. Forest fire risk zoning for the Vila Velha state park and its surroundings (Ponta Grossa, Paraná). *Floresta*. 2020;50(4):1818–1826. doi:10.5380/rf.v50i4.65974.
- Leuenberger M, Parente J, Tonini M, Pereira MG, Kanevski M. Wildfire susceptibility mapping: Deterministic vs. stochastic approaches. *Environmental Modelling & Software*. 2018;101:194–203. doi:10.1016/j.envsoft.2017.12.019.
- Lourenço L, Fernandes S, Nunes A, Gonçalves AB, Vieira A. Determination of forest fire causes in Portugal (1996–2010). *Flamma*. 2013;4:171–175.
- Medeiros CA. Geografia de Portugal, o ambiente físico. Círculo de Leitores, Lisboa. 2005.
- Moreira F, Catry FX, Silva JS, Rego FC. Ecologia do fogo e gestão das áreas ardidas. 2010:1–327.

- Nunes A, Lourenço L, Fernandes S, Castro ACM. Principais causas dos incêndios florestais em Portugal: Variação espacial no período 2001/12. *Revista Territorium*. 2014;(21):135–146.
- Paz S, Carmel Y, Jahshan F, Shoshany M. Post-fire analysis of pre-fire mapping of fire-risk: a recent case study from Mt. Carmel (Israel). *Forest Ecology and Management*. 2011; 2011(262): 1184–1188. <http://dx.doi.org/10.1016/j.foreco.2011.06.011>.
- Pereira JF, Batista AC, Soares RV. Variação da umidade do material combustível florestal em função de índices de perigo de incêndios. *CERNE*. 2012;18(3):371–376. doi:10.1590/S0104-77602012000300003.
- Pérez-Sánchez J, Senent-Aparicio J, Díaz-Palmero JM, Cabezas-Cerezo J de D. A comparative study of fire weather indices in a semiarid south-eastern Europe region. Case of study: Murcia (Spain). *Science of the Total Environment*. 2017;590–591:761–74. doi:10.1016/j.scitotenv.2017.03.040.
- Pourtaghi ZS, Pourghasemi HR, Aretano R, Semeraro T. Investigation of general indicators influencing on forest fire and its susceptibility modeling using different data mining techniques. *Ecological Indicators*. 2016;64:72–84. doi:10.1016/j.ecolind.2015.12.030.
- Ribeiro L, de Paulo Koproski L, Stolle L, Lingnau C, Soares RV, Batista AC. Zoneamento de riscos de incêndios florestais para a Fazenda Experimental do Canguiri, Pinhais (PR). *Floresta*. 2008;38(3). doi:10.5380/ufv.v38i3.12430.
- Thach NN, Ngo DBT, Xuan-Canh P, Hong-Thi N, Thi BH, Nhat-Duc H, Dieu TB. Spatial pattern assessment of tropical forest fire danger at Thuan Chau area (Vietnam) using GIS-based advanced machine learning algorithms: A comparative study. *Ecological Informatics*. 2018;46:74–85. doi:10.1016/j.ecoinf.2018.05.009.
- Torres FTP, Ribeiro GA, Martins SV, Lima GS. Mapeamento da suscetibilidade a ocorrências de incêndios em vegetação na área urbana de Ubá-MG. *Árvore*. 2014;38(5):811–817. doi:10.1590/S0100-67622014000500005.
- Torres FTP, Ribeiro GA, Martins SV, Lima GS. Influência do relevo nos incêndios em vegetação em Juiz de Fora (MG). *GEOgraphia*. 2016;18(36):170–182.
- Torres FTP, Roque MPB, Lima GS, Martins SV, de Faria ALL. Mapeamento do Risco de Incêndios Florestais Utilizando Técnicas de Geoprocessamento. *Floresta e Ambiente*. 2017;24:e00025615. doi:10.1590/2179-8087.025615.
- Torres FTP, Romeiro JMN, Santos ACDA, de Oliveira Neto RR, Lima GS, Zanuncio JC. Fire danger index efficiency as a function of fuel moisture and fire behavior. *Science of the*

- total environment. 2018a;631–632. doi:10.1016/j.scitotenv.2018.03.121.
- Torres FTP, Lima, GS, Alvares BF. Fire behavior variables and hazard indices of forest fires. *Revista Árvore*. 2018b;42(3):e420306. doi:10.1590/1806-90882018000300006.
- San-Miguel-Ayanz J, Moreno JM, Camia A. Analysis of large fires in European Mediterranean landscapes: Lessons learned and perspectives. *Forest Ecology and Management*. 2013;294:11–22. doi:10.1016/j.foreco.2012.10.050.
- Schunk C, Wastl C, Leuchner M, Menzel A. Agricultural and Forest Meteorology Fine fuel moisture for site- and species-specific fire danger assessment in comparison to fire danger indices. *Agricultural and Forest Meteorology*. 2017;234–235:31–47. doi:10.1016/j.agrformet.2016.12.007.
- Sousa DGD, Cunha HFD. Effect of fire on flowering and fruiting of *Anacardium humile* (Anacardiaceae) in cerrado stricto sensu. *Revista Árvore*. 2018;42(6):1–10. doi:10.1590/1806-90882018000600005.
- Sousa KHS, Centro SCCB, Pereira MA. Zoneamento de Riscos de Incêndios Florestais no Parque Estadual Serra do Rola Moça–MG. *Brazilian Journal of Development*. 2021;7(4):39536–39554. doi: 10.34117/bjdv7n4-307.
- Viganó HHDG, Souza CCD, Cristaldo MF, Reis Neto JFD, Jesus LD. Incêndios no Pantanal de Corumbá, MS: modelagem e previsão a partir das técnicas de análise multivariada. *Ambiente e Água*. 2018;13(5):1–3. doi:10.4136/ambi-agua.2024.
- Volkova L, Roxburg SH, Surawski NC, Meyer CM, Weston CJ. Improving reporting of national greenhouse gas emissions from forest fires for emission reduction benefits: An example from Australia. *Environmental Science and Policy*. 2019;94:49–62. doi:10.1016/j.envsci.2018.12.023.
- Wastl C, Schunk C, Leuchner M, Pezzatti GB, Menzel A. Recent climate change: Long-term trends in meteorological forest fire danger in the Alps. *Agricultural and Forest Meteorology*. 2012;162–163:1–13. doi:10.1016/j.agrformet.2012.04.001.
- Ying L, Han J, Du Y, Shen Z. Forest fire characteristics in China: Spatial patterns and determinants with thresholds. *Forest Ecology and Management*. 2018;424:345–354. doi:10.1016/j.foreco.2018.05.020.
- You W, Lin L, Wu L, Ji Z, Yu J, Zhu J, Fan Y, He D. Geographical information system-based forest fire risk assessment integrating national forest inventory data and analysis of its spatiotemporal variability. *Ecological Indicators*. 2017;77:176–184. doi:10.1016/j.ecolind.2017.01.042.

3. CONCLUSÕES GERAIS

Este trabalho demonstrou que a técnica de Redes Neurais Artificiais apresentou resultados satisfatórios para a previsão da umidade do material combustível de diferentes classes de espessura e do comportamento do fogo. Além disso, o SIG se mostrou uma ferramenta eficiente na análise de suscetibilidade a incêndios, pois o modelo escolhido apresentou maiores somas dos valores das classes “alta” e “altíssima” e menores somas das classes “baixa” e “baixíssima”.

As variáveis Dsch e UR são as que mais contribuem para a umidade do material combustível e a VV e UR são as que mais contribuem para o comportamento do fogo. Não são necessárias idas a campo para medir essas variáveis, diminuindo os custos e o tempo de realização de pesquisas relacionadas a esse tema.

Em Coimbra, as classes que obtiveram maiores porcentagens de áreas queimadas foram: Florestas, >400 m, 0–15° e alto acumulado, para as variáveis uso do solo, proximidades, inclinação do terreno e radiação solar, respectivamente. Já na variável exposição das vertentes, não houve grande variação entre as porcentagens de áreas queimadas.