# 融合ASPP机制的可解释卷积神经网络在野火 蔓延预测中的应用

#### 周乐民

中铁二院工程集团有限责任公司,四川 成都

收稿日期: 2024年11月12日; 录用日期: 2024年12月13日; 发布日期: 2024年12月23日

#### 摘要

森林生态系统因野外火灾而遭受的破坏在全球范围内引发了重大关注。随着近年来野火的严重性和发生 频率的增加,对高效预测模型的需求变得尤为迫切。本研究介绍了一种集成了有向金字塔池化(Atrous Spatial Pyramid Pooling, ASPP)机制的卷积神经网络(Convolutional Neural Network, CNN)模型,旨在 提高野火蔓延预测的准确性。鉴于现有人工神经网络算法的"黑箱"特性限制了其在解释性方面的应用, 本研究提出了一种新型的可解释CNN模型,即融合ASPP机制的CNN-ASPP。该模型利用包含环境变量的 "次日野火蔓延"数据集进行性能评估,与当前先进的机器学习方法,如随机森林(Random Forest, RF)、 支持向量机(Support Vector Machine, SVM)、人工神经网络(Artificial Neural Network, ANN)以及另一 种CNN模型进行了比较。实验结果表明,在7×7邻域大小条件下,CNN-ASPP模型的F1-score高达97%, 显著优于其他机器学习方法的90% F1-score。此外,本研究还通过梯度加权类激活映射(Gradient-Weighted Class Activation Mapping, Grad-CAM)算法,对CNN-ASPP模型中的不同卷积层进行了解释, 揭示了较大扩张率(Dilation Rates, DR)在提取输入数据中更有意义特征方面的优势。本研究的发现对于 开发更透明、更精确的野火蔓延预测模型具有重要意义,对森林资源管理和野火预防策略的制定具有深 远的影响。

#### 关键词

火灾,卷积神经网络,深度学习,智能预测,可解释模型

## Application of Interpretable Convolutional Neural Networks Incorporating ASPP Mechanism in Wildfire Spread Prediction

#### Lemin Zhou

China Railway Eryuan Engineering Group Co., Ltd., Chengdu Sichuan

Received: Nov. 12th, 2024; accepted: Dec. 13th, 2024; published: Dec. 23rd, 2024

#### Abstract

Forest ecosystems have been persistently affected by wildfires, leading to a concern worldwide. The severity and frequency of wildfires have escalated in recent years, necessitating more effective prediction models. This study presents an application of convolutional neural networks (CNNs) for wildfire spread prediction, focusing on the use of atrous spatial pyramid pooling (ASPP) mechanisms in these networks, aiming to improve the accuracy of wildfire spread prediction. However, the blackbox nature of these algorithms has not been fully explored. To bridge this gap, we proposed an explainable CNN model with an ASPP mechanism (CNN-ASPP) in this study. More specifically, we utilize the Next Day Wildfire Spread dataset, which includes environmental variables, to evaluate the performance of our model. The proposed model is compared with state-of-the-art machine learning (ML) methods, including random forest (RF), support vector machine (SVM), artificial neural network (ANN), and another CNN model. Our results showed that CNN-ASPP achieved an F1-score of 97%, outperforming the ML methods with an F1-score of 90% for a neighborhood size of 7 × 7. We also opened the black box and tried to explain different convolutional layers based on the gradientweighted class activation mapping (Grad-CAM) algorithm. Our findings indicate that larger dilation rates (DRs) can extract more meaningful features from the input data. This study contributes to the development of more transparent and accurate models for wildfire spread prediction, which could have significant implications for forest management and wildfire prevention strategies.

## **Keywords**

Fire, Convolutional Neural Networks, Deep Learning, Intelligent Prediction, Interpretable Model

Copyright © 2024 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). http://creativecommons.org/licenses/by/4.0/

## 1. 引言

森林是地球上最宝贵的自然资源之一[1]。森林带来了无数好处,是地球可持续发展不可或缺的一部 分。这些益处横跨各个领域,包括经济、环境、社会和文化领域[2]。森林在全球碳循环中也发挥着关键 作用,是重要的碳汇。森林能够吸收二氧化碳,减少大气中的温室气体含量[3]。然而,森林砍伐或退化 造成的森林损失会对全球碳循环产生严重影响,导致大气中的二氧化碳含量增加。近年来,野火的严重 程度和频率不断增加,对世界各地的森林造成了广泛的破坏[4]。因此,必须制定有效的政策,保护这些 宝贵的自然资源免受野火侵袭。

高效的野火应急响应需要准确预测野火全天的蔓延情况。这对于资源分配和快速应对野火爆发至关 重要。然而,预测野火蔓延是一个复杂的过程,已被证明具有挑战性[5]。长期以来,开发精确的野火蔓 延预测模型一直是野火研究界的目标[6]。文献中通常使用两种野火蔓延数值模型。第一种是基于物理和 化学现象建模的物理模型,如计算流体动力学(Computational Fluid Dynamics, CFDs)模型[7]。第二种方法 是基于传播速度(Rate of Spread, RoS)的经验模型,将传播速度、坡度、风和植被特性联系起来[8]。然而, 这些方法需要大量计算资源,非常耗时。例如,单个处理器需要计算 872,000 分钟(约 600 天)才能完成一 次野火蔓延模拟[9]。

近年来,研究人员采用机器学习(Machine Learning, ML)算法来提高野火预测的准确性[10]-[12]。例如,Markuzon 和 Kolitz于 2009 年进行的一项研究利用随机森林(Random Forest, RF)、贝叶斯网络(Bayesian

Networks, BN)和 K-Nearest Neighbors (KNN)来预测野火是否会在点火两天后变大[13]。另一项研究介绍了 FirePred,这是一种使用多时数据集预测野火蔓延的模型。不过,研究人员没有明确指出哪一时段的数据 对预测更有意义,他们的模型被认为过于复杂[14]。此外,还有人提出了一种深度卷积逆图网络(Deep Convolution Inverse Graph Network, DCIGN),利用环境变量来估计野火前沿的空间演变。卷积神经网络(Convolutional Neural Network, CNN)的输出是一个空间网格,与野火到达像素的可能性相对应。尽管利用火区 模拟器(Fire Area Simulator, FARSITE)基于物理模拟的 6 小时燃烧图实现了 80%的平均灵敏度和 89%的平 均精确度,但该模型需要大量的计算资源[15]。

随着时间的推移,野火的规模也会发生变化,这就凸显了适应这种变化的策略的必要性。最近的研究在计算机视觉应用中引入了有向空间金字塔集合(Atrous Spatial Pyramid Pooling, ASPP)机制[16]。之前的研究已将该机制应用于预测野火蔓延[14] [17] [18]。然而,该机制在野火蔓延预测中的黑箱性质仍未得到探索。为了弥补这一不足,本研究将重点放在使用配备 ASPP 机制的可解释 CNN 模型(CNN-ASPP)预测全美国(U.S.)的野火蔓延。因此,本研究的主要目标可概括为:1)使用可解释人工智能(Explainable Artificial Intelligence, XAI)解释 ASPP 模块提取的特征,以及它们与使用梯度加权类激活映射(Gradient-Weighted Class Activation Mapping, Grad-CAM)的模型输出之间的关系;2)将 CNN-ASPP 结果与传统的基于 ML 的模型进行比较。通过关注这些目标,本研究旨在提高预测模型在野火蔓延预测中的透明度和适用性,从而有助于制定更有效的野火管理策略。

#### 2. 数据集



**Figure 1.** Study area and wildfire site distribution 图 1. 研究区域及野火点分布

本文选取美国自 2012~2020 年所公开记录的野火数据作为野火点,该数据详细记录了野火发生的精确位置以及时间。图 1 显示了研究区域以及 2012 年至 2020 年间相应的野火地点。同时,基于一个名为"次日野火蔓延"的新公开数据集开展本文的研究数据。该数据集包括海拔高度、风向和风速、最低和最高温度、湿度、降水、干旱指数、归一化差异植被指数(Normalised Difference Vegetation Index, NDVI)和能量释放分量,作为野火蔓延预测的各种信息来源,该数据集主要用于研究基于观测数据预测野火蔓

延模型的潜力[19]。这些数据源在空间和时间维度上都是一致的,为预测模型训练提供了一个特征丰富的数据集。该数据集是独一无二的,因为它将二维火灾数据与多个解释变量(如地形、植被、天气、干旱指数和人口密度)结合在一起,并在二维区域内对齐。这个特征丰富的数据集可作为一个基准,用于开发基于遥感数据的野火传播模型,提前期为一天。

#### 3. 方法

野火蔓延预测与图像分割任务有相似之处,因此,图像金字塔的概念是考虑不同尺度野火的不同形状和大小的重要方法。这种方法提高了分割精度。在类似金字塔的方法中,先从不同尺度提取特征,然后再进行插值和合并。然而,分别计算每个尺度的特征图会增加网络的规模,并可能导致过度拟合。为了有效结合多尺度信息,有人提出了空间金字塔池化(Spatial pyramid pooling, SPP) [20]。SPP 最初是为了解决物体检测中的随机输入大小问题而开发的。SPP 是一种将随机图像尺寸划分为多个分区、分别汇集这些分区并将它们连接起来以生成与输入图像相关的固定尺寸特征图的技术。虽然 SPP 能有效捕捉图像的多尺度特征,但在图像分割任务中,它在汇集过程中会丢失像素细节。为了解决这个问题,本文提出使用 ASPP。在 ASPP 中的正常池化层被具有不同扩张率(Dilation Rates, DRs)的无齿(含孔)卷积所取代。通过合并从每个 DR 提取的特征来创建最终特征向量。这种方法可以实现不同的感受野,使模型能够捕捉到图像中更多的细节信息。图 2 展示了带有 ASPP 模块版本的 CNN-ASPP 模型,用于野火蔓延预测。



**Figure 2.** CNN-ASPP model architecture for wildfire spread prediction 图 2. 用于野火蔓延预测的 CNN-ASPP 模型架构

本文所提出的方法首先应用两个卷积层从输入数据中提取 64 和 128 个特征。然后,将第二个卷积层 的输出通过 DRs 分别为 1、3、6 和 12 的四个无级卷积层,将这些特征组合起来。每个卷积层包括 32 个 滤波器,内核大小为 3×3。这一过程可以提取多尺度特征。随后,两个卷积层(每个卷积层有 32 个滤波 器,内核大小为 3×3)被应用于合并特征。为了对提取的特征进行归一化处理,最后一个卷积层的输出会 在最后一个卷积层之前输送到一个批量归一化层,最终生成预测图。

然后,归一化特征被传递到一个带有滤波器和核大小为1×1的卷积层。最后的卷积层使用 Sigmoid 函数获得每个像素的燃烧概率值。除最后一个卷积层外,所有卷积层都使用了整流线性单元(Rectified linear unit, ReLU)激活函数。

在本研究中,精确度(P)、召回率(R)、F1-分数(F1-score)和总体准确率(OA)被用于验证分析和综合模型评估,其定义如下:

$$P = \frac{TP}{TP + FP} \tag{1}$$

$$R = \frac{TP}{TP + FN} \tag{2}$$

$$F1 - \text{score} = 2 \times \frac{P \times R}{P + R} \tag{3}$$

$$OA = \frac{TP + TN}{TP + FN + FP + TN}$$
(4)

其中, TP、FP、TN、FN 分别为正确预测的野火蔓延点、错误预测的野火蔓延点、正确预测的未蔓延野火点、错误预测的未蔓延野火点。

此外,本文还使用了 Tversky 指数(Tversky index, TI)作为损失函数。公式(1)表示 TI 损失公式,其中  $\alpha \pi \beta$  是满足  $\alpha + \beta = 1$  条件的两个参数。在本研究中,设定  $\alpha = 0.7 \pi \beta = 0.3$ 。

$$TI = 1 - \frac{TP}{TP + \alpha FN + FP}$$
(5)

## 4. 实验结果

#### 4.1. 实验设置

CNN-ASPP 模型使用 Tensorflow 实现。测试和训练在 Inter i7-11700H 2.5 GHz 处理器、16 GB 内存 和 NVIDIA GTX 2060Ti 显卡上进行,训练过程中涉及 8616 个训练样本和 685 个验证样本。训练阶段的 批量大小设定为 8。在训练过程中, CNN-ASP 模型的学习率设定为 0.0004,并使用贪婪搜索技术进行了 200 次迭代。

#### 4.2. 模型比较结果

**Table 1.** Comparison of models in terms of *OA*, precision, recall, *F*1-score and training time **表 1.** 各个模型在 *OA*、精确度、召回率、*F*1-score 和训练时间方面的比较

 模型	邻域大小	OA	R	Р	F1-score	训练时间(小时)
RF	$3 \times 3$	83.72	81.90	86.57	84.17	3.2
	$5 \times 5$	82.57	80.36	86.21	83.18	3.8
	$7 \times 7$	88.19	88.64	87.61	88.12	5.4
SVM	$3 \times 3$	81.45	79.53	84.69	82.03	38.6
	$5 \times 5$	80.26	78.28	84.29	81.02	53.4
	$7 \times 7$	85.81	90.74	85.67	85.79	82.7
ANN	$3 \times 3$	81.77	79.81	84.67	82.35	3.4
	$5 \times 5$	80.59	78.28	89.55	81.35	4.7
	$7 \times 7$	90.20	90.74	82.35	90.14	5.8
CNN-ASPP	-	96.46	99.37	93.51	96.35	4.3
CNN	-	89.25	89.79	88.58	89.18	3.1

表1从OA、P、R、F1-score和训练时间等方面对所提出的模型与其他著名的ML方法进行了比较。

虽然 RF、SVM 和人工神经网络(Artificial Neural Network, ANN)没有被提议用于野火蔓延预测任务,但本研究在输入像素周围的正方形中提取了三种不同大小的邻域(即 3、5 和 7),以提供上下文空间信息。可以看出,所有采用 7 × 7 邻域大小的 ML 模型都取得了与 CNN 和 CNN-ASPP 相当的结果,而采用 7 × 7 邻域大小的 ANN 则优于其他 ML 模型。如表 1 所示,SVM 模型的训练速度大大低于其他两种 ML 模型。 总体而言,根据邻域大小的不同,ML 模型在评估指标和训练时间方面的表现都非常不错。与其他模型相比,CNN-ASPP 模型的训练时间适中。在 CNN-ASPP 模型中,数据准备是最重要的步骤。因此,CNN 模型在数据准备方面更具适应性,而 ML 模型则需要进行邻域特征提取,从而增加了计算成本。

#### 4.3. CNN-ASPP 模型的定性结果

CNN-ASPP 模型可以根据天气条件、燃料状况或地形,在下一个时间步骤中有效区分燃烧和未燃烧的像素。图 3 显示了 CNN-ASPP 模型的正确和错误预测示例。



**Figure 3.** CNN-ASPP model predictions for ten validation samples. Green: not burned, red: burned classes. The black box indicates where the model failed to accurately predict burn and not burned pixels

**图 3.** 十个验证样本的 CNN-ASPP 模型预测结果。绿色:未烧毁,红色:烧毁。黑框 表示模型未能准确预测烧毁和未烧毁像素的位置

## 5. 讨论

深度学习技术由于结构复杂、涉及参数众多,通常被视为"黑箱"。这种复杂性使得解释成为一项 具有挑战性的任务。然而,在决策过程中,了解结果的可靠性至关重要,这就需要清楚地了解模型的输 出结果。要对模型进行恰当的解释,关键是要解释模型的每个组成部分,如过程、预测和提取的特征。 这是因为理解这些组成部分可以深入了解模型的决策过程和驱动其输出的因素[21]。在本节中,根据本文 利用 ASPP 模块增强简单 CNN 的核心理念,旨在阐明从 DR 中提取特征的解释。提取的特征指的是 ASPP 模块的基本组件,这些组件是根据 Grad-CAM 算法确定的。



**Figure 4.** Histograms of R<sup>2</sup> values for all data based on different DRs 图 4. 基于不同 DR 的所有数据 R<sup>2</sup> 值直方图



**Figure 5.** ASPP-CNN predictions at different DRs (shaded pixels are wildfire spread labels) 图 5. 不同 DR 下的 ASPP-CNN 预测结果(阴影部分为野火蔓延标签像素)



**Figure 6.** Linear regression model results between the Grad-CAM output of the last convolution layer and the Grad-CAM output of extracted features by the convolution layer equipped with DRs of 1, 3, 6, and 12 in the CNN-ASPP model 图 6. 在 CNN-ASPP 模型中,最后一个卷积层的 Grad-CAM 输出结果与卷积层提取特征的 Grad-CAM 输出结果之间 的线性回归模型结果,卷积层的 DR 分别为 1、3、6 和 12

为了确定不同 DR 对提取特征的贡献,本文使用了线性回归模型,以找出预测结果与 DR Grad-CAM 输出之间的相关性。热图被视为 X,而 CNN-ASPP 模型中最后一个卷积层的 Grad-CAM 输出被视为 Y,然后使用 R 平方(R<sup>2</sup>)来衡量数据点与拟合线的相关程度。

为了解 DR 与其 Grad-CAM 行为之间的差异,本文对所有数据样本应用了回归模型,并收集了它们 的 R<sup>2</sup> 值。然后生成了与每个 DR 相对应的直方图,并分析了每个受检 DR 的 R<sup>2</sup> 值直方图(见图 4)。直方 图显示,DR 值越小,CNN 的感受野越小,R<sup>2</sup> 值也就越小。相反,DR 越大,R<sup>2</sup> 值越高,这表明较大的 DR 有助于预测正确的野火掩码。图 5 和图 6 通过显示一个数据样本及其相应的回归结果证实了这一观 察结果。DR = 12 的 R<sup>2</sup> 值最高,在 0.2 到 0.3 之间,而 DR = 1 和 DR = 3 的 R<sup>2</sup> 值最低,在 0 到 0.1 之间。 这表明,在 CNN-ASPP 模型中,DR = 6 和 DR = 12 提取的特征与最终预测图之间存在很强的关系。相 反,CNN-ASPP 模型中 DR = 1 和 DR = 3 提取的特征与最终预测图之间的关系则不那么明显。ASPP 模块 中较高的 DR 值可用于提取野火蔓延预测任务中的一般模式,而较低的 DR 值则最适合小规模野火蔓延,在预测野火的小边缘和曲线方面有一定的优势。然而,高 DR 值和低 DR 值对于准确的野火预测任务都 是必要的,因为它们可以互相帮助,同时捕捉大的和详细的小模式。这些结果与之前将 ASPP 模块用于 分割任务的研究结果一致[22]。

#### 6. 结论

本文使用了一个名为"次日野火蔓延"的数据集来预测美国境内的野火蔓延情况。此外,本文还将 所提出的 CNN-ASPP 模型与 ANN、SVM 和 RF 这三种不同的著名机器学习方法进行了比较,以证明其 效率。综合实验结果和分析,得出以下结论:

1. CNN-ASPP 模型在野火蔓延预测任务中表现出色,其性能优于现有的机器学习方法,这验证了 ASPP 机制在提高模型预测能力方面的有效性。

2. 通过 Grad-CAM 算法的解释,揭示了不同扩张率对特征提取的影响,表明较大的扩张率有助于模型捕捉更多细节信息,从而提高预测的准确性。

3. 本研究的 CNN-ASPP 模型不仅提高了野火蔓延预测的准确性,而且通过解释算法增强了模型的可 解释性,这对于森林管理和野火预防策略的制定具有重要意义。

4. 尽管 CNN-ASPP 模型在本研究中取得了良好的预测效果,但仍存在改进空间。未来的研究可以探 索将变换器模型(如视觉变换器)和迁移学习技术应用于野火蔓延预测,以进一步提高模型的泛化能力和 适应性。

综上所述,本研究提出的 CNN-ASPP 模型为野火蔓延预测提供了一种新的、有效的技术手段,对于提升野火管理的科学性和预防措施的有效性具有重要的理论和实践价值。

## 参考文献

- [1] Liang, H., Zhang, M. and Wang, H. (2019) A Neural Network Model for Wildfire Scale Prediction Using Meteorological Factors. *IEEE Access*, **7**, 176746-176755. <u>https://doi.org/10.1109/access.2019.2957837</u>
- [2] Calkin, D.E., Thompson, M.P. and Finney, M.A. (2015) Negative Consequences of Positive Feedbacks in US Wildfire Management. *Forest Ecosystems*, 2, Article No. 9. <u>https://doi.org/10.1186/s40663-015-0033-8</u>
- [3] Marjani, M. and Mesgari, M.S. (2023) The Large-Scale Wildfire Spread Prediction Using a Multi-Kernel Convolutional Neural Network. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4, 483-488. <u>https://doi.org/10.5194/isprs-annals-x-4-w1-2022-483-2023</u>
- [4] Bjanes, A., De La Fuente, R. and Mena, P. (2021) A Deep Learning Ensemble Model for Wildfire Susceptibility Mapping. *Ecological Informatics*, **65**, Article ID: 101397. <u>https://doi.org/10.1016/j.ecoinf.2021.101397</u>
- [5] Jaafari, A., Zenner, E.K. and Pham, B.T. (2018) Wildfire Spatial Pattern Analysis in the Zagros Mountains, Iran: A Comparative Study of Decision Tree Based Classifiers. *Ecological Informatics*, **43**, 200-211.

https://doi.org/10.1016/j.ecoinf.2017.12.006

- [6] Zhai, C., Zhang, S., Cao, Z. and Wang, X. (2020) Learning-Based Prediction of Wildfire Spread with Real-Time Rate of Spread Measurement. *Combustion and Flame*, 215, 333-341. <u>https://doi.org/10.1016/j.combustflame.2020.02.007</u>
- [7] Linn, R., Reisner, J., Colman, J.J. and Winterkamp, J. (2002) Studying Wildfire Behavior Using Firetec. International Journal of Wildland Fire, 11, 233-246. <u>https://doi.org/10.1071/wf02007</u>
- [8] Rothermel, R.C. (1972) A Mathematical Model for Predicting Fire Spread in Wildland Fuels (Vol. 115). Intermountain Forest and Range Experiment Station, Forest Service, US Department of Agriculture.
- [9] Allaire, F., Mallet, V. and Filippi, J. (2021) Emulation of Wildland Fire Spread Simulation Using Deep Learning. *Neural Networks*, 141, 184-198. <u>https://doi.org/10.1016/j.neunet.2021.04.006</u>
- [10] Oliveira, S., Oehler, F., San-Miguel-Ayanz, J., Camia, A. and Pereira, J.M.C. (2012) Modeling Spatial Patterns of Fire Occurrence in Mediterranean Europe Using Multiple Regression and Random Forest. *Forest Ecology and Management*, 275, 117-129. <u>https://doi.org/10.1016/j.foreco.2012.03.003</u>
- [11] Rodrigues, M. and de la Riva, J. (2014) An Insight into Machine-Learning Algorithms to Model Human-Caused Wildfire Occurrence. *Environmental Modelling & Software*, **57**, 192-201. <u>https://doi.org/10.1016/j.envsoft.2014.03.003</u>
- [12] Murali Mohan, K.V., Satish, A.R., Mallikharjuna Rao, K., Yarava, R.K. and Babu, G.C. (2021) Leveraging Machine Learning to Predict Wild Fires. 2021 2nd International Conference on Smart Electronics and Communication (ICOSEC), Trichy, 7-9 October 2021, 1393-1400. <u>https://doi.org/10.1109/icosec51865.2021.9591952</u>
- [13] Markuzon, N. and Kolitz, S. (2009) Data Driven Approach to Estimating Fire Danger from Satellite Images and Weather Information. 2009 IEEE Applied Imagery Pattern Recognition Workshop (AIPR 2009), Washington, 14-16 October 2009, 1-7. <u>https://doi.org/10.1109/aipr.2009.5466309</u>
- [14] Marjani, M., Ahmadi, S.A. and Mahdianpari, M. (2023) FirePred: A Hybrid Multi-Temporal Convolutional Neural Network Model for Wildfire Spread Prediction. *Ecological Informatics*, 78, Article 102282. <u>https://doi.org/10.1016/j.ecoinf.2023.102282</u>
- [15] Hodges, J.L. and Lattimer, B.Y. (2019) Wildland Fire Spread Modeling Using Convolutional Neural Networks. *Fire Technology*, 55, 2115-2142. <u>https://doi.org/10.1007/s10694-019-00846-4</u>
- [16] Chen, L., Papandreou, G., Kokkinos, I., Murphy, K. and Yuille, A.L. (2018) DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis* and Machine Intelligence, 40, 834-848. <u>https://doi.org/10.1109/tpami.2017.2699184</u>
- [17] Marjani, M., Mahdianpari, M. and Mohammadimanesh, F. (2024) CNN-BiLSTM: A Novel Deep Learning Model for Near-Real-Time Daily Wildfire Spread Prediction. *Remote Sensing*, 16, Article 1467. https://doi.org/10.3390/rs16081467
- [18] Ghali, R. and Akhloufi, M.A. (2023) Deep Learning Approaches for Wildland Fires Using Satellite Remote Sensing Data: Detection, Mapping, and Prediction. *Fire*, 6, Article 192. <u>https://doi.org/10.3390/fire6050192</u>
- [19] Huot, F., Hu, R.L., Goyal, N., Sankar, T., Ihme, M. and Chen, Y. (2022) Next Day Wildfire Spread: A Machine Learning Dataset to Predict Wildfire Spreading from Remote-Sensing Data. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-13. <u>https://doi.org/10.1109/tgrs.2022.3192974</u>
- [20] He, K., Zhang, X., Ren, S. and Sun, J. (2015) Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **37**, 1904-1916. <u>https://doi.org/10.1109/tpami.2015.2389824</u>
- [21] Samek, W., Montavon, G., Vedaldi, A., Hansen, L.K. and Müller, K.R. (2019) Explainable AI: Interpreting, Explaining and Visualizing Deep Learning (Vol. 11700). Springer Nature. <u>https://doi.org/10.1007/978-3-030-28954-6</u>
- [22] Kang, H. and Chen, C. (2019) Fruit Detection and Segmentation for Apple Harvesting Using Visual Sensor in Orchards. Sensors, 19, Article 4599. <u>https://doi.org/10.3390/s19204599</u>