

降雨条件下蒙古栎和樟子松林地地表死可燃物含水率预测方法的修正与比较

胡同欣 马灵感 高源廷 范佳乐 孙龙*

(东北林业大学林学院 哈尔滨 150040)

摘要:【目的】分析降雨条件对地表细小死可燃物含水率(FPMC)的影响,分别建立机器学习模型和传统模型对降雨条件下的可燃物含水率进行预测,并对所建立的预测模型进行评价和比较。【方法】选择东北地区典型阔叶树种蒙古栎和针叶树种樟子松,以其地表细小死可燃物作为研究对象,通过进行室内模拟降雨实验探究降雨对地表可燃物含水率的影响,分别采用直接估计法和卷积神经网络(CNN)构建预测模型,并结合野外实验数据对直接估计法所得模型进行修正,最终进行比较分析。【结果】与未经修正的直接估计法相比,修正后直接估计法的预测精度显著提高, R^2 由0.85-0.94提高到0.94-0.96;MAE由9.18%~18.33%下降到6.86%~10.74%,MRE由3.97%~17.18%下降到3.53%~14.48%。相比于卷积神经网络模型的 R^2 在0.90以上,MAE在8.11%以下,MRE在8.87%以下,修正后直接估计法的预测精度较高。【结论】降雨条件下的预测结果表明,室内可燃物含水率呈对数增长的趋势;降雨和上一时刻可燃物含水率对预测模型具有显著影响,关系模型和非线性模型均能较好地预测室内降雨条件下的可燃物含水率。其中,修正后的直接估计法预测效果最好。
关键词: 细小可燃物含水率; 预测模型; 直接估计法; 卷积神经网络

Influence of the Mixed Modes of Larch and Birch on Soil Faunal Community in Mountain Area of Northern Hebei, China

Hu Tongxin Ma Linggan Gao Yuanling Fan Jiale Sun Long*

(College of Forestry Northeast Forestry University Harbin 150040)

Abstract: 【Objective】Analyze the impact of rainfall conditions on the moisture content of surface fuel moisture content (FMC), establish machine learning models and traditional models to predict the moisture content of surface fuel under rainfall conditions, and evaluate and compare the established prediction models. 【Method】Selecting the broad-leaved forest *Quercus mongolica* and coniferous forest *Pinus sylvestris* var. *mongolica* in northeast China, surface dead fine fuel as the research object, by indoor simulated rainfall experiment to explore the influence of rainfall for the surface fuel moisture content, combined with the direct estimation method to modify the fine fuel moisture content prediction model, finally using field data will be revised directly estimation method, the direct estimation method and convolution neural network (CNN) model is used in the comparison. 【Result】Compared with the unmodified direct estimation method, the modified direct estimation method significantly improves the prediction accuracy, and the goodness of fit (R^2) increases from 0.85-0.94 to 0.94-0.96; MAE decreased from 9.18%-18.33% to 6.86%-10.74%, MRE decreased from 3.97%-17.18% to 3.53%-14.48%. Compared with the convolutional neural network model, the R^2 is above 0.90, the MAE is below 8.11%, and the MRE is below 8.87%, indicating high prediction accuracy. 【Conclusion】Under the condition of rainfall simulation results show that indoor fuel moisture content in the form of logarithmic increase trend. Rainfall and last fuel moisture content have a significant impact on the fuel moisture content prediction model, and both the relational model and nonlinear model perform well in predicting fuel moisture content under indoor rainfall conditions. Comparing the three models, it can be concluded that the modified direct estimation method has the best prediction effect.

Key words: Fine fuel moisture content; Prediction models; Direct estimation method; Convolutional neural networks

1 简介

森林火灾在全球范围内不断发生,并且从未来气候变化的趋势来看仍呈现增加趋势(McColl-Gausden *et al.*, 2017)。可燃物是决定森林火灾发生的基本因素之一,是森林火灾燃烧的物质基础(Matthews, 2013)。森林地表细小可燃物的含水率是影响森林火灾蔓延和燃烧速度的重要因素之一,越来越被认为是森林火灾综合治理的关键,并在火灾风险评估中得到了广泛的应用(Cawson *et al.*, 2019)。地表细小死可燃物的含水率对气象因子和森林结构引起的小气候变化较为敏感。它是森林火险等级的重要指标,是影响火灾行为变化的关键参数(Brown *et al.*, 2022; Slijepcevic *et al.*, 2018)。因此,预测森林地表细小死可燃物含水率并提高其精度对森林火灾预测具有重要意义。

降雨作为一种非常重要的气象因子,对森林火灾有着重要的影响。总的来说,从年际变化的角度来看,降雨有助于增加地表可燃物负荷,从而增加火灾的风险。从季节变化的角度来看,火灾季节的降雨可以增加可燃物的含水率,从而降低火灾风险及其带来的危害(Reddy *et al.*, 2021; Pellizzaro *et al.*, 2007; Mondal *et al.*, 2016)。随着降雨量的增加,可燃物所能承载的降雨比例越小,可燃物的初始含水率越高,其对雨水的吸收越少(Lopes *et al.*, 2014; Bilgili *et al.*, 2019)。降雨对地表细小死可燃物含水率的影响极为明显,但过程复杂,不能简单地将等雨量直接与含水率的变化联系起来,这其中还包括土壤吸收和地表蒸发等过程(Alvarado *et al.*, 2020),这些复杂的过程对地表可燃物含水率的预测提出了一定的挑战。

目前,关于森林可燃物含水率的研究很多,预测方法主要有遥感估计法、气象要素回归法、平衡含水率估计法和过程模型四大类(Matthews, 2013)。平衡含水率法是目前预测死可燃物含水率的主流方法,许多国家的森林火险预测都采用该方法预测可燃物含水率(De Jong *et al.*, 2016)。Simard 法是根据木材的失水过程来预测可燃材料的含水率,Nelson 作为一种半物理模型,具有较高的精度(Simard, 1968; Nelson, 1984)。但只考虑温度和湿度为主要因素,未考虑降雨的影响,因此在降雨条件下产生较大的偏差。为了预测降雨条件下的可燃物含水率,Lopes 等(2014)阐述了降雨与可燃物之间关系的变化,并提出了 3 种利用日降雨量数据估算可燃物含水率变化的模型。Bilgili 等(2019)在平衡含水率的基础上,结合风速、降雨量和气压差,建立了预测可燃物含水率的动态模型。Lee 等(2010)在春季防火期间,在韩国永东地区建立了基于不同森林密度的可燃物含水率变化预测模型,以降雨后第 2 天至第 6 天的地表枯死可燃物为样本,该模型测量了不同直径的可燃物含水率变化。

随着计算机技术的发展,机器学习等预测模型已开始用于预测地表可燃物含水率。其中,神经网络应用最为广泛。如 Fan 等(2021)使用长、短时记忆网络模型(LSTM)预测可燃物含水率,并结合可燃物湿度棒数据,使用随机森林、人工神经网络(ANN)等方法进行研究,结果表明 LSTM 在描述时间序列数据的动态变化方面表现良好。Masinda 等(2021)利用随机森林对东北地区地表可燃物含水率进行了预测,预测精度较高。卷积神经网络作为深度学习的经典算法之一,与传统神经网络相比,通过卷积核大大减少了参数的数量,实现了局部相关,达到了参数共享的效果,减少人为干预,最大限度地搜索信息特征,从而提高预测精度(Dhaka *et al.*, 2021)。然而,目前还缺乏将卷积神经网络等机器学习方法与传统方法进行比较分析的研究。

建立可燃物在降雨条件下的变化模型有利于更准确地了解雨后可燃物含水率的变化情况,更有效地预测火险时期,在提高可燃物含水率预测和森林火险预测的模型精度方面具有非常重要的意义。因此,本研究选择东北地区典型针叶和阔叶树种樟子松(*Pinus sylvestris* var. *mongolica*)和蒙古栎(*Quercus mongolica*)的地表细小死可燃物作为研究对象,结合室内模拟实验和野外测量数据,基于直接估计法、修正后的直接估计法和卷积神经网络对降雨条件下可燃物含水率进行预测。

2 材料与方法

2.1 研究区域

研究区域位于黑龙江省哈尔滨市帽儿山实验林场(127°34'~127°40'E,45°24'~45°33'N)。它南北长约 30 公里,东西长约 26 公里,总面积 26496 hm²。森林覆盖率约 85%,森林蓄积量 205 万 hm³。研究区属长白山植物区系,属大陆性季风气候,主要是东北地区典型的天然次生林和人工林,是由地带性顶层植被阔叶红

松林破坏后形成的。主要树种为蒙古栎、白杨和白桦。在 2021 年秋季防火季,对帽儿山实验林场蒙古栎林和樟子松林的地表可燃物、半腐殖质、腐殖质和土壤进行了采集。

2.2 实 方法

2.2.1 室内模拟降雨实验

在实验样地收集地表可燃物,收集样品带回实验室,放入烘箱,105℃干燥 24 h 至绝对干燥后称重。计算可燃物含水率的式(1):

$$FMC = \frac{W_H - W_D}{W_D} \times 100\% \quad (1)$$

式中 FMC 为可燃物含水率(%); W_H 为可燃物湿重(g); W_D 为可燃物干重(g)。

预先制备不同初始可燃物含水率的样品。降雨对床层可燃物含水率动态变化的影响受初始床层可燃物含水率的影响。因此,在实验中需要设置不同的初始床层含水率进行定量分析。考虑到在模拟降雨条件下的实验室内,如果选择干燥可燃物进行实验,床层含水率会在短时间内迅速增加,影响实验结果,因此将可燃物床设置为 4 个初始含水率梯度:5%、25%、50%、75%(Zhang *et al.*, 2020)。将干燥后的可燃物分成不同的重量,放在称量台上。利用含水率计算公式计算不同可燃物的初始含水率。加入所需水分,置于密封袋中放置 24 小时,使水分充分吸收,密封袋使水分完全吸收,实验前再次测量密封袋以确定可燃物含水率,确保可燃物含水率的准确性。

床层致密度是指可燃物床层的体积密度与颗粒密度之比。可燃床层的密度设置为 3 个梯度:0.01、0.02、0.03。因此,取绝干质量分别为 4g、8g 和 12g 的蒙古栎样品,取绝干质量分别为 3g、6g 和 9g 的樟子松样品,放置在直径为 20 cm、高度为 2.5cm 的圆形网篮中,实现不同梯度的床料密实度。每个梯度重复 3 次,共制备 9 个样品(Zhang *et al.*, 2020)。

根据自然界的降雨梯度设置,以及降雨强度的不同,将其分为小雨、中雨、暴雨和暴雨四个降雨强度梯度,在具体操作中设置了 2mm/h、4mm/h、10mm/h 和 16mm/h 的处理进行模拟降雨实验,观察不同降雨强度下可燃物含水率的变化。

为了模拟田间真实的可燃物床层,将采集到的样品按照枯落物-半腐殖质-腐殖质-土壤的顺序从上到下装入矩形种植篮中,并将装有实验样品的圆形网篮嵌入模拟田间床的种植篮中。将模拟室外条件的种植篮放置在铁架上,并使用模拟降雨装置进行喷洒。调整合适的降雨位置,每隔 10 分钟取出圆网篮称重计算含水率,直至含水率不再变化。实验装置如图 1 所示。




图 1 降雨模拟实 仪器

Fig. 1 Rainfall simulating experiment device

2.2.2 野外实验

2021 年秋季防火季,采用随机分布法在研究区蒙古栎林和樟子松林设置监测点,放置地表细小可燃物含水率野外自动记录监测仪器(Masinda *et al.*, 2022; Yu *et al.*, 2022; Fan *et al.*, 2023)。本仪器以自动称重设备

为基础,可长时间连续监测可燃物含水率,并具有小型气象站的功能,可自动测量气象要素,包括:空气温度、相对湿度、风速、降雨量和光照强度。

该仪器的主要工作原理是利用称重法监测可燃物的含水率,首先将可燃物装入尼龙网袋中,下部与土壤表面接触,上部不被覆盖,保证其与环境的水汽交换,通过高精度拉力传感器按一定的周期自动提升样品,测定样品重量;为了实现对可燃物样品湿重的连续测量,前期分别对可燃物样品干重进行测量,得到实时的样品含水率。同时自动采集离地 1.2 m 处的气温、大气相对湿度、风速、光照强度等气象因子(Yu *et al.*, 2022; Fan *et al.*, 2023)。任意时间段的采样周期可设置为 0.05~24h,本研究的步长设置为 0.5h。为了保证测量的准确性,在测量前将现场测量值与室内称重值(精度 0.1 g)进行比较并参数化,直至误差最小化。研究时间为 7~10 月,共采集蒙古栎 6000 组和樟子松 4500 组可燃物水分数据。样地信息如表 1 所示。

表 1 样地信息

Table 1. Sample plots information

Forest type	Altitude (m)	Location	Aspect	Mean DBH(cm)	Mean height(m)	Canopy density
<i>Quercus mongolica</i>	395	Middle	Northeast	18.40±6.33	15.20±3.72	0.70±0.22
<i>Pinus sylvestris</i> var. <i>mongolica</i>	380	Middle	Southwest	15.80±3.59	16.47±5.47	0.40±0.35

2.3 数据分析

2.3.1 建立降雨与可燃物含水率关系模型

利用降雨实验数据绘制不同降雨强度下两种可燃物的吸水曲线。在室内模拟实验中,采用随机森林相对重要度特征排序,研究不同因素对可燃物含水率增加的影响(Breiman, 2001)。根据室内降水增长的可燃物含水率数据,构建模型如下式(2) (Fang *et al.*, 2003):

$$P = t \times R_t \quad (2)$$

式中 P 为降雨量; T 是时间; R_t 是降雨强度。

根据模拟实验数据,对室内降雨与可燃物含水率之间的关系进行了线性、非线性和关系模型建模。为了防止模型出现过拟合等问题,将数据分为 70% 的训练集和 30% 的测试集,以获得更好更稳定的模型。

2.3.2 野外可燃物含水率预测

1. 直接估计法

直接估计法是一种考虑可燃物水分扩散的物理过程,通过实验获得相关参数的半物理方法(Catchpole *et al.*, 2001),利用实时含水率数据和现场获得的气象数据,在短时间间隔内准确估算 FMC,具有较好的适用性。为了使结果更加准确,直接估计法(以下简称 Nelson 法(Nelson, 1984)和 Simard 法(Simard, 1968)中选择基于半物理的 Nelson 模型和基于统计的 Simard 模型作为平衡含水率响应方程。根据最小二乘法对模型参数进行估计,得到 FMC 的预测模型。

该方法主要基于 Byram(1963)提出的地表可燃物含水率微分方程,如式(3)所示:

$$\frac{dM}{dt} = \frac{E - M}{\tau}$$

式中 dM/dt 为可燃物含水率在 t 周期内的变化值; M 为可燃物含水率值(%); E 为可燃物平衡含水率(%); τ 表示可燃物材料时滞(h)。上述公式中的平衡含水率可用 Nelson 模型或 Simard 模型计算。Nelson 平衡含水率模型如式(4)所示:

$$E = \alpha + \beta \log\left(-\frac{RT}{m} \log H\right) \quad (4)$$

式中 R 为通用气体常数,其值为 $8.314 \text{ J} \cdot \text{K}^{-1} \cdot \text{mol}^{-1}$; T 为空气温度(K); H 为相对湿度(%); m 为 H_2O 的相对分子质量,为 $18 \text{ g} \cdot \text{mol}^{-1}$; α 和 β 是待估计的参数。

Simard 平衡含水率模型如式(5)所示:

$$E = \begin{cases} 0.03 + 0.2626H - 0.00104HT & H < 10 \\ 1.76 + 0.1601H - 0.0266T & 10 \leq H \leq 50 \\ 21.06 - 0.4944H + 0.005565H^2 - 0.00063HT & H \geq 50 \end{cases} \quad (5)$$

式中 E 为平衡含水率(%); T 为空气温度($^{\circ}\text{C}$); H 为相对湿度(%).

将平衡含水率模型(4)和式(5)代入式(3)的离散方程, 得到:

$$m_i = \lambda^2 m_{i-1} + \lambda(1 - \lambda)E_{i-1} + (1 - \lambda)E_i \quad (6)$$

其中 m_i 为 t_i (%)时刻的 FMC; m_{i-1} 为 t_{i-1} 时刻的 FMC (%); E_i 为 t_i (%)时刻的平衡含水率; E_{i-1} 为时刻 t_{i-1} 的平衡含水率(%); $\lambda = \exp(-\delta t / (2\tau))$; $\tau = -\delta t / (2 \ln \lambda)$; 我们研究的时间步长为 0.5 h, 因此 Δt 为 0.5 h.

2. 修正直接估计法

降雨后可燃物含水率预测模型为:

$$M_i = \lambda^2 m_{i-1} + \lambda(1 - \lambda)E_{i-1} + (1 - \lambda)E_i + FMCI_p. \quad (7)$$

其中 $FMCI_p$ 为降雨导致可燃物含水率增加的部分。

根据现场实际含水率数据, 采用非线性估计方法对模型参数进行拟合, 得到模型参数。同时, 为了观察模型在不同样本上的表现, 防止模型出现过拟合等问题, 将数据分为 70%的训练集和 30%的测试集, 以获得更好更稳定的模型。

3.卷积神经网络模型(CNN)

卷积神经网络(Convolutional neural network, CNN)是深度学习领域的经典算法之一(LeCun *et al.*, 2015; Greff *et al.*, 2016), 它具有局部连接和权值共享的特点, 可以对原始数据进行高维映射处理, 有效提取数据特征(Li *et al.*, 2022)。CNN 由卷积层、池化层和全连接层组成。在卷积层, 神经元的局部连接和卷积核的权值共享模式可以大大减少训练过程中的参数数量, 提高模型的训练速度。在池化层, 通过对原始数据的抽象理解, 对特征维数进行降维, 有效减少了训练参数的数量, 降低了模型过拟合的程度, 提高了特征数据的提取效率。卷积层与池化层交替使用, 不仅可以最大限度地有效提取输入数据的潜在特征, 还可以减少人工提取特征所带来的误差(Dhaka *et al.*, 2021)。在本研究中, 卷积神经网络预测主要利用了 R 中的 torch 包, 卷积神经网络原理图如图 2 所示:




图 2 卷积神经网络的过程示意图

Fig. 2 Schematic diagram of the process of convolutional neural network

2.3.3 模型评价与比较

计算 3 种模型的拟合优度 R^2 、平均绝对误差(MAE)和平均相对误差(MRE), 分别以实测值为横坐标、预测值为纵坐标, 绘制可燃物含水率预测模型 1:1 散点拟合图, 进行模型评价与比较。最后, 通过时间序列对不同模型结果的预测效果进行比较分析。计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (M_i - M_j)^2}{\sum_{i=1}^n (M_i - \bar{M}_i)^2} \quad (8)$$

$$MAE = \sum_{i=1}^n |M_i - M_j| \quad (9)$$

$$MRE = \sum_{i=1}^n \frac{|M_i - \bar{M}_i|}{\bar{M}_i} * 100\% \quad (10)$$

式中 M_i 为可燃物含水率的测量值(%); $\bar{M}_i$ 表示可燃物含水率预测值(%); $\bar{M}_i$ 表示测量到的可燃物平均含水率。

3.结果

3.1 室内可燃物含水率的动态变化

不同降雨强度、床层密实度和初始含水率下蒙古栎地表可燃物含水率的动态变化表明(图 3):不同降雨强度条件下蒙古栎林地地表可燃物含水率随时间呈对数形式增加。含水率达到饱和后,基本停止上升,总体呈现先快后慢的波动增长趋势。降雨强度减小,达到饱和含水率所需的时间也增加,在一定程度上难以达到与降雨强度大时相同的饱和含水率。在不同的降雨强度下,床层的吸水率也不同。一般来说,当降雨强度较大时,可燃物在初始阶段的吸水率也较高。随着降水的增加,后期可燃物吸水率曲线逐渐趋于平缓。降雨后蒙古栎地表可燃物的饱和含水率一般在 300%以上。不同床层密度下可燃物含水率的总体趋势是相同的,床层密度为 0.02 时,可燃物含水率的增加更为迅速。在不同初始含水率处理下,初始含水率为 75% 的可燃物吸水率显著低于初始含水率为 5% 的可燃物吸水率。




图 3 不同降雨强度下蒙古栎可燃物床层含水率动态变化

Fig. 3 Dynamic variation of moisture content in fuel bed of *Quercus mongolica* under different rainfall intensities

不同降雨强度、不同床层密实度和不同初始含水率下樟子松可燃物床层含水率的动态变化(图 4)表明,不同处理下樟子松可燃物床层含水率的变化趋势与蒙古栎相似,并且随着时间的增加,樟子松可燃物床层含水率的变化趋势也呈对数增长趋势。降雨条件下可燃物的饱和含水率大于 150%,远低于蒙古栎。在小降雨强度下,饱和水分水平较低。在不同可燃物初始含水率的处理中可以看出,初始含水率越大,可燃物含水率的增长空间越小,吸水率越低,可燃物含水率曲线之间的差异越大。




图 4 不同降雨强度下樟子松可燃物床层含水率动态变化

Fig. 4 Dynamic variation of moisture content in fuel bed of *Pinus sylvestris* var. *mongolica* under different rainfall intensities

3.2 可燃物含水率增长影响因素排序

由图 5 可知，根据随机森林的相对特征重要性，在室内模拟降雨实验中，在相同降雨条件下，上一时刻的可燃物含水率是影响可燃物含水率增长的主要因素，而初始含水率和床层密实度对可燃物含水率增长的影响不是很重要。与蒙古栎可燃物样本相比，樟子松可燃物样本含水率的结果相似，降雨和上一时刻可燃物含水率对樟子松可燃物床含水率的增加也有重要影响。




图 5 室内模拟实 不同林型可燃物含水率增长 动因子重要性排序(a:蒙古栎;b:樟子松;Fmc:可燃物含水率)

Fig. 5 Ranking of importance of the drivers of moisture content growth in different stands in indoor simulation experiments (a: *Quercus mongolica*; b: *Pinus sylvestris* var. *mongolica*; Fmc: fuel moisture content)

3.3 降雨-可燃物含水率增长模型

根据降雨实验中获得的影响可燃物含水率增长的重要因子分析，对两种可燃物分别建立了线性模型、非线性模型和关系模型，通过分析可以看出，在对蒙古栎含水率的预测结果中，关系模型表现较好，而对樟子松含水率的预测结果中，非线性模型表现较好；樟子松总体模型优于蒙古栎，如表 2 所示。

表 2 降雨作用下可燃物含水率增长模型

Table 2 Model of moisture content growth of fuel due to rainfall					
Fuel type	Model	Equation	R ²	MAE	MRE

				(%)	(%)
<i>Quercus mongolica</i>	Linear model	$FMCI_p = 0.408 - 0.43m_{i-1} + 0.021P_i + 0.112smc$	0.74	32.12	24.39
	Nonlinear model	$FMCI_p = 0.987 - 0.92m_{i-1} + 0.209m_{i-1}^2 + 0.01P_i$	0.78	29.82	18.91
	Relational model	$FMCI_p = 0.045P_i(smc - m_{i-1})$	0.80	11.32	9.79
<i>Pinus sylvestris</i> var. <i>mongolica</i>	Linear model	$FMCI_p = 0.219 - 0.498m_{i-1} + 0.015P_i + 0.002smc$	0.82	19.61	16.44
	Nonlinear model	$FMCI_p = 0.602 - 0.998m_{i-1} + 0.341m_{i-1}^2 + 0.012P_i$	0.87	12.32	18.83
	Relational model	$FMCI_p = 0.034P_i(smc - m_{i-1})$	0.73	27.54	20.03

3.4 野生可燃物含水率动态

监测期间，蒙古栎和樟子松地表可燃物含水率随时间变化显著($p<0.05$)。蒙古栎地表可燃物含水率波动显著，总体呈现先增加后减少再增加再减少的趋势(图 6)。这是因为 7 月多雨，降雨频率也高，使得蒙古栎的地表可燃物含水率连续多日保持在较高水平。蒙古栎地表可燃物含水率最大值为 378.11%，最小值为 5.14%，平均值为 $72.73\pm49.54\%$ 。但在无降雨的 7 月中下旬，可燃物含水率保持在较低水平，含水率变化相对较小。在樟子松地表可燃物含水率监测数据中，可以看出，与蒙古栎地表可燃物含水率相比，降雨时和降雨前樟子松地表可燃物含水率水平显著低于蒙古栎($p<0.05$)；樟子松可燃物含水率最高为 261.61%，最低为 1.18%，平均值为 $48.16\pm43.72\%$ 。降雨过程中，樟子松地表可燃物含水率的增加幅度小于蒙古栎，保持了樟子松地表可燃物含水率的统一水平。




图 6 野外可燃物含水率动态变化(a:蒙古栎;b:樟子松)

Fig 6 Dynamic change of moisture content of fuel in the wild (a: *Quercus mongolica*; b: *Pinus sylvestris* var. *mongolica*)

3.5 修正后的直接估计法

在室内实验预测模型的基础上，对直接估计法进行了修正，得到了不同可燃物含水率预测模型的参数。从表 3 中的参数和评价指标可以看出，与未经修正的模型相比，两种修正后的直接估计法在预测地表可燃物含水率方面的拟合程度都有所提高；对于蒙古栎地表可燃物，未经修正的 Nelson 法拟合度 R^2 为 0.85，未经修正的 Simard 法拟合度为 0.90，修正后的 Nelson 法拟合度提高到 0.96，修正后的 Simard 法拟合度提高到 0.94；对于樟子松地表可燃物，未修正的 Nelson 法预测拟合度 R^2 为 0.90，未修正的 Simard 法预测拟合度 R^2 为 0.94，修正后的 Nelson 法预测拟合度提高到 0.95，修正后的 Simard 法预测拟合度提高到 0.96。

由此可见，对 Nelson 法进行修正对提高预测精度更为有效。

表 3 修正后和未修正的直接估计法模型估计参数及误差

Table 3 Revised and Uncorrected Direct Estimation Method Model Estimation Parameters and Errors						
Model	Parameters/Errors	Modified direct estimation method			Uncorrected direct estimation method	
		<i>Quercus</i>	<i>Pinus</i>	<i>sylvestris</i>	<i>Quercus</i>	<i>Pinus</i>
		<i>mongolica</i>	var. <i>mongolica</i>		<i>mongolica</i>	var. <i>mongolica</i>
Nelson	α	1.081	2.144		0.595	0.445
	β	-0.294	-0.209		-0.161	-0.091
	λ	0.982	0.994		0.899	0.921
	R ²	0.96	0.95		0.85	0.90
	MAE (%)	8.27	6.86		18.33	9.85
	MRE (%)	7.84	6.12		10.91	17.18
	λ	0.999	0.988		0.989	0.995
Simard	R ²	0.94	0.96		0.90	0.94
	MAE (%)	10.74	7.19		10.74	12.19
	MAE (%)	14.48	3.53		14.48	3.97

3.6 卷积神经网络模型

3.6.1 随机森林模型中气象因子的相对重要度筛选

图 7 显示，随机森林气象因子的相对重要度排序是基于监测的气象数据和地表可燃物含水率数据，结果表明，湿度、温度和降雨量对蒙古栎和樟子松地表可燃物含水率有显著影响；其中湿度对两者地表可燃物含水率的影响最为显著。不同之处在于，在蒙古栎林中，湿度和降雨对可燃物含水率的影响较大，而在樟子松地表可燃物中，湿度和温度对可燃物含水率的影响最大。




图 7 气象因子对地表可燃物含水率的相对重要性排序(a:蒙古栎;b:樟子松)

Fig. 7 Ranking of the relative importance of meteorological variables on the moisture content of fuel on the surface (a: *Quercus mongolica*; b: *Pinus sylvestris* var. *mongolica*)

3.6.2 卷积神经网络模型整定参数

在模型的参数调优中，一般通过训练集和测试集之间的函数损失来判断是否为最优。基于卷积神经网络的地表可燃物含水率预测模型分析，蒙古栎地表可燃物含水率的模型训练损失和测试损失在初始阶段有一定的波动，但随着训练次数(epoch)的增加。训练数据集和测试数据集的损失函数开始逐渐减小，同时两条曲线在 50 次处逐渐接近，说明均方误差逐渐减小，模型达到一定效果(图 8)。利用卷积神经网络预测樟子松地表可燃物含水率的模型参数调整过程与蒙古栎地表可燃物含水率的过程相似。在迭代开始时，测试损失很小，但训练损失和测试损失之间有细微的区别。经过不断迭代，两者逐渐趋近，说明其效果良好。




图 8 不同地表可燃物含水率卷积神经网络模型的训练集和测试集损失结果(a:蒙古栎;b:樟子松)

Fig. 8 Loss results of training and test sets of different surface fuel convolutional neural network models(a: *Quercus mongolica*; b: *Pinus sylvestris* var. *mongolica*)

3.6.3 卷积神经网络模型参数调优

采用卷积神经网络模型预测地表可燃物含水率结果，蒙古栎地表可燃物含水率预测拟合度 R^2 为 0.93，MAE 为 6.05%，MRE 为 8.87%；樟子松地表可燃物含水率预测拟合度 R^2 为 0.90，MAE 为 8.11%，MRE 为 4.23%(表 4)。这表明对蒙古栎地表可燃物含水率的预测结果优于樟子松地表可燃物含水率。

表 4 卷积神经网络模型对不同可燃物含水率预测的误差

Table 4 Errors of convolutional neural network models for moisture content of fuel on different surfaces			
Forest Type	R^2	MAE(%)	MRE(%)
<i>Quercus mongolica</i>	0.93	6.05	8.87
<i>Pinus sylvestris</i> var. <i>mongolica</i>	0.90	8.11	4.23

3.7 模型性能评价

3.7.1 不同模型预测结果的散点拟合比较

与未经修正的直接估计法相比，无论是 Nelson 法还是 Simard 法都有了一定程度的改进，特别是在一些含水率较高的地区，在樟子松林预测效果的提高更为明显(图 10)。

对于卷积神经网络模型的预测，拟合线两侧的分布也接近均匀，在樟子松林中 R^2 也较好(图 9)。




图 9 蒙古栎不同预测模型实测值与预测值比较

Fig. 9 Comparison of measured values and predicted values of different prediction models of *Quercus mongolica*

图 10 为不同预测模型下樟子松地表可燃物含水率预测结果与实测值的散点拟合，与蒙古栎的预测结果相似。修正后的直接估计法，无论是采用 Nelson 法还是 Simard 法作为嵌入模型，其性能都优于未修正的直接估计法。从图 10 可以看出，修正后的直接估计法的拟合线更接近 1:1 线，散点分布的面积更小，说明模型的性能更好。与未经修正的直接估计法相比，在含水量较高的区域，预测性能的提高更为显著。对于卷积神经网络模型的预测，拟合线两侧的分布也接近均匀， R^2 也更好。但可以看出，未经修正的直接估计法在预测樟子松地表可燃物含水率方面的效果也优于卷积神经网络




图 10 樟子松不同预测模型的实测值和预测值散点比较

Fig. 10 Comparison of measured values and scatter of predicted values of different prediction models of *Pinus sylvestris* var. *mongolica*

3.7.2 不同模型预测结果的时间序列比较

图 11 为不同模型对蒙古栎地表可燃物含水率预测结果的时间序列比较。可以看出,在不同的预测模式下,同一日期的总体趋势是一致的,主要表现为降雨期间的显著波动,而大多数日期的含水率水平较低。由于不同模型的精度和特性不同,修正后的直接估计法的两种模型都显示出较好的效果(图 11)。未修正的直接估计法虽然总体趋势一致,但在含水率曲线开始上升的时刻(即降雨后)模型响应较慢,导致降雨开始时预测值较低,降雨结束后预测值过高;对于卷积神经网络,该模型总体上具有较高的精度,预测值和实测值的曲线比较一致,但在某些时刻会出现波动。




图 11 不同模型预测蒙古栎林结果的时间序列比较

Fig. 11 Time series comparison of prediction results of different models of *Quercus mongolica*

图 12 为不同模型对樟子松可燃物含水率预测结果的时间序列比较。从中可以看出,几种不同的模型在预测地表可燃物方面具有一致的总体性能趋势。修正后的直接估计法的两种模型均取得了良好的效果。但与实测值曲线相比,由于可燃物含水率存在饱和点,修正后的直接估计法在峰值时段也可能存在过估计现象,而未经修正的直接估计法也可能总体趋势一致,但降雨开始后,估计值较低,降雨结束后,可能出现过估计现象;从时间序列曲线的对比来看,卷积神经网络模型精度也很高,在某些日期仍然波动频繁,但曲线变化总体上是一致的。




图 12 不同模型预测樟子松林结果的时间序列对比图

Fig. 12 Time series comparison chart of prediction results of different models of *Pinus sylvestris* var. *mongolica*

4 讨论

4.1 降雨对可燃物含水率预测模型构建的影响

在模拟降雨实验中,可燃物含水率在实验初期呈现急剧增加和变化的趋势。这是因为死可燃物的水分由叶结构内的水分和表面自由水组成,同时可燃物在干燥条件下对降水的吸收空间很大,容易出现尖峰变化(Baranovskiy *et al.*, 2022; Viegas *et al.*, 1992),这与 Baksic 等(2017)研究可燃物含水率的时间动态变化是一致的。两种地表可燃物的含水率差异主要是由于蒙古栎在可燃物形态结构上的叶面积更大,分解程度更高,导致整体含水率更高。而樟子松(*Pinus sylvestris* var. *mongolica*) 地表可燃物呈小针状,分解程度较低(Yu *et al.*, 2018)。同时可以看出,通过降雨实验得到的可燃物饱和含水率与现场降雨条件下的测量值存在一定的差异,这可能是由于可燃物含水率对降水的响应存在滞后效应(Zhang *et al.*, 2020)。

我们的研究发现,上一时刻可燃物含水率对可燃物含水率的增加有显著的影响。这是因为在相同的降雨条件下,上一时刻可燃物含水率越高,降雨比例越低,反之亦然。这在许多预测模型中也得到了充分体现(Slijepcevic *et al.*, 2015; Ganatsas *et al.*, 2011)。降雨在实验中对可燃物含水率的增加有显著的影响,降雨可以被可燃物床层直接吸收和储存,这在许多研究中得到了证实(Matthews *et al.*, 2006; Anderson *et al.*, 2009)。在本实验中,可燃物密度并未显著增加可燃物的含水率,但在 Zhang 等(2020)的研究中,可燃物床层密度对可燃物含水率有显著影响。这可能是因为可燃物密度具有双重作用,不仅可以拦截降雨,还可以增加可

燃物之间的水汽交换。

在 3 种降雨条件下蒙古栎地表可燃物含水率增长预测模型中, 关系模型优于线性和非线性模型。这可能是由于关系模型中可燃物饱和含水率是确定的, 基于上一时刻的可燃物含水率, 降雨条件下可燃物含水率的增加空间是有限的。因此, 3 种模型之中关系模型所反映的变化是最大的(Keane *et al.*, 2020)。然而, 由于缺乏明确表达水分吸收和扩散的方程, 该模型的精度难以提高到更高的水平(Cruz *et al.*, 2016)。在樟子松地表可燃物含水率增长预测模型中, 非线性模型表现较好。虽然关系模型可以简洁地表达降雨条件下可燃物含水率的变化, 但不同的可燃物床层的温度、湿度的变化会影响可燃物含水率的变化。因此, 非线性模型虽然原理简单, 且容易出现过拟合现象(Oddi *et al.*, 2019), 但其准确性和灵活性仍优于线性回归模型。与 Lopes 等(Lopes *et al.*, 2014)利用降雨强度、降雨变化和初始可燃物含水率 3 种因子对降雨条件下可燃物含水率进行线性建模相比, R^2 略低, 但模型更简洁高效。因此, 本研究旨在通过 3 种模型的建立, 进一步探究降雨与可燃物含水率之间的数学关系, 有利于寻找降雨与可燃物含水率具有代表性和归纳性的物理模型(Liu *et al.*, 2007)。

4.2 降雨条件下可燃物含水率的 动因素

在影响因子研究中, 湿度是影响两种林型可燃物含水率变化的显著因素, 这与许多研究结果一致(Britton *et al.*, 1973; Zhang *et al.*, 2017)。空气中的水分子不断移动, 并与地表可燃物中的水一起渗透, 导致可燃物含水率的变化。降雨可以直接影响可燃物的含水率, 且降雨对蒙古栎含水率的影响比对樟子松更为显著。这主要是由于可燃物结构的差异, 以及水分的吸收和蒸发, 不仅受到外界气象因素的影响, 还受到内部水分转移的影响(Babera *et al.*, 2023)。阔叶林地表可燃物床层相对疏松, 地表更容易受到水分吸收和光照强度的影响(Schunk *et al.*, 2013)。在针叶林中, 可燃物重叠, 其内部水分交换路径要复杂得多, 水分流失的大小和速度也不同(Flannigan *et al.*, 2016), 这也与 Bilgili (2019)的结果相似。David 等(2010)使用饱和压差、叶面积指数和降雨量来预测巴西热带雨林的地表可燃物含水率, 在较高的实测值下, 预测值被低估, 结果与 Masinda 等(2021)的研究相似。但本研究并没有低估降雨对可燃物含水率的影响, 这可能是由于可燃物含水率和气象数据中包含了大量的降雨周期数据, 也可能是由于本研究针对降雨条件下可燃物含水率的增长, 专门建立了饱和含水率与以往可燃物含水率之间的关系。然而, 在某些时候, 可能会出现轻微的高估现象, 这可能是由于地表可燃物床层结构的不连续变化(Schiks *et al.*, 2015)。温度对可燃物的含水率有显著影响, 研究结果与之前相似(Matthews, 2013; Viney, 1991)。然而, 降雨条件会减弱温度对可燃物含水率增加的影响, 但温度在降雨前后的影响仍然十分显著(Chae *et al.*, 2017)。此外, 风速和光照强度对研究中可燃物含水率的影响相对较小。这主要是由于森林中树冠遮荫导致光照强度的变化, 以及森林中植被的遮挡导致风速的减慢(Wang *et al.*, 2023)。也可能是由于采集数据的时间间隔较短, 不能更有效地反映风对可燃物含水率的影响。

4.3 模型评价与比较

本研究构建了两种林型地表可燃物含水率的 3 种预测模型。其中, 修正后的直接估计法预测拟合 R^2 最高, 误差值较小, 说明该模型对可燃物含水率的解释效果好, 预测误差小, 精度高。修正后的直接估计法与未修正的直接估计法的对比也证实了修正后的直接估计法在降雨条件下的模型结果更好, 整体预测精度提高。蒙古栎林下地表可燃物的含水率预测精度高于樟子松林, 这可能是由于蒙古栎属于阔叶林, 可燃物床结构比针叶林更简单、更均匀, 这一结果与 Yu 等(2021)的研究结果相似。Zhang 等(2022)使用直接估计法预测可燃物的含水率, 其误差值远高于本研究。这主要是由于其研究的步长为 24 小时, 而本研究的步长为半小时, 具有更高的精度。这也证实了模型的精度在一定程度上与数据的获取步长有关(Yu *et al.*, 2021; Fan *et al.*, 2023)。在直接估计法中, 需要根据实验数据对 Nelson 模型的参数进行估计, β 是 Nelson 模型中的一个重要参数, β 的取值可以直接反映平衡含水率对温度和湿度的敏感性。 β 绝对值越高, 可燃物对温度和湿度的敏感性越强, 保水能力越弱(Nelson, 1984)。在本研究中, 蒙古栎的 β 绝对值大于樟子松。阔叶林地表可燃物的持水能力强于针叶林。这与 Zhang 等(2020)和 Yu 等(2021)的研究结果不同。这是因为不同

类型的可燃物和采样时间会影响可燃物的理化性质和结构特征。但即使在修正后的直接估计法中,也只讨论了温度、湿度和降雨量作为影响因子,需要进一步探索更多的因子变化和更有效的预测模型(Pickering *et al.*, 2021)。

虽然卷积神经网络的预测精度低于直接估计法,但其拟合度 R^2 也很好,体现了深度学习的优势。与 Lee 等(2020)利用机器学习预测 10 个时滞的地表可燃物含水率的研究结果类似,卷积神经网络具有较高的准确性。这是因为卷积神经网络具有优势,它可以快速捕捉可燃物含水率与气象因子数据之间的非线性关系,解决过拟合问题。与传统的数学建模相比,它具有简单、快速、建模准确等优点,并且可以处理大量数据,显著提高了可燃物含水率预测模型的精度(Wu *et al.*, 2022)。Masinda 等(2021)使用随机森林预测地表可燃物含水率, R^2 最高达到 0.86, 略低于卷积神经网络,这可能是因为卷积神经网络更适合大数据集,具有更好的特征挖掘能力,但研究表明随机森林也具有很高的应用潜力和发展空间。卷积神经网络模型的 MAE 和 MRE 值也较低,在 4.23% ~ 8.87% 之间。然而,与一些机器学习研究相比,误差相对较高,这可能与气象因素的选择有关(Aguado *et al.*, 2007),例如本文中未考虑土壤湿度因素。土壤水分对地表可燃物含水率的影响已经得到了清楚的证明,土壤水分的变化比地表可燃物更具连续性。因此,未来可以考虑与土壤含水量模型耦合,以获得更好的结果(Rakhmatulina *et al.*, 2021; Li *et al.*, 2022); Fan 等(2021)使用 FSMM-LSTM 预测的 R^2 为 0.91, 准确度与本研究结果相当。LSTM 与卷积神经网络属于相同的网络结构,但 LSTM 本身在时序上有一定的优势。同时,这个研究在一定程度上直接采集了森林小气候中的气象因子,避免了地形的影响。

然而,在本研究中,直接估计法和卷积神经网络模型的高准确率依赖于大量的仪器数据采集来进行模型训练,数据中的某些异常值减少了样本数量。因此,在未来的研究中,还应加大时间跨度,获取更大量的数据样本,同时继续探索精度更高的模型(Shmuel *et al.*, 2022)。同时在本研究也可以看出,降雨对模型预测精度的影响是显著的,其重要机制在未来的研究中值得关注。此外,还应考虑季节和可燃物对天气条件响应的滞后对地表可燃物含水率的影响,以提高可燃物含水率预测的准确性。

5 总结

本研究对不同降雨强度下东北地区蒙古栎林和樟子松林地地表可燃物含水率的变化进行了室内模拟实验,并基于含水率数据和气象数据建立了含水率预测模型,并对直接估计法进行了修正,实现了野外可燃物含水率的有效预测。最后,分析了野外可燃物含水率的动态变化及其主要影响因子,并与未修正的直接估计法和卷积神经网络进行了比较。根据模型误差分析和实测值与预测值的比较,表明在室内降雨条件下,降雨和上一时刻可燃物含水率对未来可燃物含水率有显著影响;在野外实验中,修正后的直接估计法具有最好的预测精度,特别是在降雨条件下对可燃物含水率可以进行有效预测。虽然卷积神经网络模型中的拟合结果略低,但整体预测精度较高,可以满足森林火险预测的要求。本研究模型的建立和修正对于提高降雨条件下地表可燃物含水率预测模型的精度具有重要意义,对东北地区森林火灾的预测和管理也具有重要的参考价值。

参 考 文 献

- Aguado I, Chuvieco E, R Borén, *et al.* 2007. Estimation of dead fuel moisture content from meteorological data in Mediterranean areas. Applications in fire danger assessment. *International Journal of Wildland Fire*, 16(4):390-397.
- Alvarado S T, Andela N, Silva T, *et al.* 2020. Thresholds of fire response to moisture and fuel load differ between tropical savannas and grasslands across continents. *Global Ecology and Biogeography*, 29(2):331-344.
- Anderson, SAJ, Anderson, WR. 2009. Predicting the elevated dead fine fuel moisture content in gorse (*Ulex europaeus* L.) shrub fuels. *Canadian Journal of Forest Research*, 39(12):2355-2368.
- Babera I, Paritsis J, Ammassari L *et al.* 2023. Microclimate and species composition shape the contribution of fuel moisture to positive fire-vegetation feedbacks. *Agricultural & Forest Meteorology*, 330:1-14.
- Bakšić, N, Bakšić, D, Jazbec, A. 2017. Hourly fine fuel moisture model for *Pinus halepensis* (Mill.) litter. *Agricultural and Forest*

Meteorology, 243:93-99.

Baranovskiy, N.V. Kirienko, V.A. 2022. Forest Fuel Drying, Pyrolysis and Ignition Processes during Forest Fire: A Review. *Processes*, 10(1):89.

Batchelor, J. L.; Rowell, E.; Prichard, S. *et al.* 2023. Quantifying Forest Litter Fuel Moisture Content with Terrestrial Laser Scanning. *Remote Sens*, 15:1482.

Bilgili E, Coskuner K A, Usta Y, *et al.* 2019. Diurnal surface fuel moisture prediction model for Calabrian pine stands in Turkey. *iForest - Biogeosciences and Forestry*, 12(3):262-271.

Britton C M, Countryman C M, Wright H A, *et al.* 1973. The effect of humidity, air temperature, and wind speed on fine fuel moisture content. *Fire Technology*, 9(1):46-55.

Brown T P, Inbar A, Duff T J, *et al.* 2022. The sensitivity of fuel moisture to forest structure effects on microclimate. *Agricultural and Forest Meteorology*, 316:108857.

Breiman, 2001. Random forests Machine Learning, 45(1): 5-32.

Catchpole EA, Catchpole WR, Viney NR, *et al.* 2001. Estimating fuel response time and predicting fuel moisture content from field data. *International Journal of Wildland Fire*, 10: 215-222.

Cawson J G, Duff T J. 2019. Forest fuel bed ignitability under marginal fire weather conditions in Eucalyptus forests. *International Journal of Wildland Fire*, 28(3):198-204.

Chae HM, Jeon BR, Lee SY, *et al.* 2017. Effects of Weather Factors on Fuel Moisture Contents of Forestland in Chuncheon, South Korea. *Journal of The Faculty of Agricultural Kyushu University*, 62(1):23-29.

Cruz M G, Kidnie S, Matthews S *et al.* 2016. Evaluation of the predictive capacity of dead fuel moisture models for Eastern Australia grasslands. *International Journal of Wildland Fire*, 25(9):995-1001

David R Brando N P. 2010. Predicting moisture dynamics of fine understory fuels in a moist tropical rainforest system: results of a pilot study undertaken to identify proxy variables useful for rating fire danger. *New Phytologist*, 187(3):720-732.

de Dios, V. R., Fellows, A W, Nolan, R H, *et al.* 2015. A semi-mechanistic model for predicting the moisture content of fine litter. *Agricultural & Forest Meteorology*, 203:64-73.

De Jong M C, Wooster M J, Kitchen K, *et al.* 2016. Calibration and evaluation of the Canadian Forest Fire Weather Index (FWI) System for improved wildland fire danger rating in the United Kingdom. *Natural Hazards and Earth System Sciences*, 16(5):1217-1237.

Dhaka, V.S.; Meena, S.V.; Rani, G.; *et al.* 2021. A Survey of Deep Convolutional Neural Networks Applied for Prediction of Plant Leaf Diseases. *Sensors*, 21: 4749.

Fan C, He B. 2021. A Physics-Guided Deep Learning Model for 10-h Dead Fuel Moisture Content Estimation. *Forests*, 12: 933.

Fang Rk. 2003. Dictionary of Environmental Science. Science Press. BeiJing, 398.

Fan J L, Hu T X, Ren J S, *et al.* 2023. A comparison of five models in predicting surface dead fine fuel moisture content of typical forests in Northeast China. *Frontiers in Forests and Global Change*, 6:1122087.

Flannigan M.D, Wotton B.M, Marshall GA, *et al.* 2016. Fuel moisture sensitivity to temperature and precipitation: climate change implications. *Climatic Change*, 134(1/2):59-71.

Ganatsas P, Antonis M, Marianthi T. 2011. Development of an adapted empirical drought index to the Mediterranean conditions for use in forestry. *Agricultural & Forest Meteorology*, 151(2):241-250.

González ADR, Hidalgo JAV, González JGÁ. 2009. Construction of empirical models for predicting Pinus sp. dead fine fuel moisture in NW Spain. I: Response to changes in temperature and relative humidity. *International Journal of Wildland Fire*, 18:71-83.

Greff K, Srivastava R K, J Koutník, *et al.* 2016. LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks & Learning Systems*, 28(10):2222-2232.

Hiers J K, Stauhammer CL, O'Brien JJ. *et al.* 2019. Fine dead fuel moisture shows complex lagged responses to environmental conditions in a saw palmetto (*Serenoa repens*) flatwoods Science Direct. *Agricultural and Forest Meteorology*, 266:20-28.

Keane R E, Holsinger L M, Smith H Y, *et al.* 2020. Drying rates of saturated masticated fuelbeds from Rocky Mountain mixed-conifer stands. *International Journal of Wildland Fire*, 29:57-69.

Yann, L.; Yoshua, B.; Geoffrey, H. 2015. Deep learning. *Nature*, 521:436-444.

Lee H, Won M, Yoon S, *et al.* 2020. Estimation of 10-Hour Fuel Moisture Content Using Meteorological Data: A Model Inter-Comparison Study. *Forests*, 11:982.

Lei Wei-Dong, Yu Ying, Li Xing-Hui, *et al.* 2022. Estimating dead fine fuel moisture content of forest surface, based on wireless sensor

- network and back-propagation neural network. *International Journal of Wildland Fire*, 31(4):369-378.
- Lin G F, Wang C M. 2007. A nonlinear rainfall-runoff model embedded with an automated calibration method – Part 1: The model. *Journal of Hydrology*, 341(3-4):186-195.
- Li Zhao, Marta Yebra, Albert IJM, *et al.* 2022. Representing vapour and capillary rise from the soil improves a leaf litter moisture model. *Journal of Hydrology*, 612:128087.
- Lopes S, Viegas D X, Lemos L *et al.* 2014. Rainfall effects on fine forest fuels moisture content.
- Matthews, Stuart. 2006. A process-based model of fine fuel moisture. *International Journal of Wildland Fire*, 15(2):155-168.
- Matthews, S. 2013. Dead fuel moisture research: 1991-2012. *International Journal of Wildland Fire*, 23:78-92.
- Masinda M M. 2021. Prediction models of dead fuel moisture content and estimation of forest fire risk in a typical forest ecosystem in the northeast of China. Northeast Forestry University.
- Masinda, M.M., Li, F., Liu, Q. *et al.* 2021. Prediction model of moisture content of dead fine fuel in forest plantations on Maoer Mountain, Northeast China. *Journal of Forestry Research*. 32(5):2023-2035.
- Masinda MM, Li F, Qi L, *et al.* 2022. Forest fire risk estimation in a typical temperate forest in Northeastern China using the Canadian forest fire weather index: case study in autumn 2019 and 2020. *Natural hazards*, 111: 1085-1101.
- McColl-Gausden, SC, Bennett, L. T, Clarke, H G. *et al.* 2022. The fuel-climate-fire conundrum: How will fire regimes change in temperate eucalypt forests under climate change? *Global Change Biology*, 28:5211-5226.
- Mondal N, Sukumar R .2016. Fires in Seasonally Dry Tropical Forest: Testing the Varying Constraints Hypothesis across a Regional Rainfall Gradient. *PloS one*, 11(7).
- Nelson, R. M. 1984. A method for describing equilibrium moisture content of forest fuels. *Can. J. For. Res.* 14:597-600.
- Oddi F J, Miguez F E, Ghermandi L, *et al.* 2019. A nonlinear mixed-effects modeling approach for ecological data: Using temporal dynamics of vegetation moisture as an example. *Ecology and Evolution*, 9(18): 10225-10240.
- Pellizzaro G, Cesaraccio C, Duce P, *et al.* 2007. Relationships between seasonal patterns of live fuel moisture and meteorological drought indices for Mediterranean shrubland species. *International Journal of Wildland Fire*, 16(2):232-241.
- Pickering BJ, Duff, TJ, Baillie C, *et al.* 2021. Darker, cooler, wetter: forest understories influence surface fuel moisture. *Agricultural and Forest Meteorology*, 300(1):108311.
- Rakhmatulina E, Stephens S, Thompson S .2021. Soil moisture influences on Sierra Nevada dead fuel moisture content and fire risks. *Forest Ecology and Management*, 496(3): 119379.
- Reddy P J, Sharples, JJ, Lewis, SC. *et al.* 2021. Modulating influence of drought on the synergy between heatwaves and dead fine fuel moisture content of bushfire fuels in the Southeast Australian region. *Weather and Climate Extremes*, 31:100300.
- Schiks T J, Wotton B M .2015. Modifying the Canadian Fine Fuel Moisture Code for masticated surface fuels. *International Journal of Wildland Fire*, 24(1):79-91.
- Schunk C, Leutner C, Leuchner M, *et al.* 2013. Equilibrium moisture content of dead fine fuels of selected central European tree species. *International Journal of Wildland Fire*, 22(6):797-809.
- Shmuel A, Ziv Y, Heifetz E .2022. Machine-Learning-based evaluation of the time-lagged effect of meteorological factors on 10-hour dead fuel moisture content. *Forest Ecology and Management*, 505:119897.
- Simard, A. J. 1968. The moisture content of forest fuels – 1. A review of the basic concepts. Canadian Department of Forest and Rural Development, Forest Fire Research Institute, Information Report FF-X-14. (Ottawa, ON)
- Si-Young Lee, Chun-Geun, *et al.* 2010. Development of Prediction Model of Fuel Moisture Changes in the Spring for the Pine Forest Located the Yeongdong Region (Focused on the Fallen Leaves and Soil Moisture Level). *Fire Science and Engineering*, 24(2):67-75.
- Slijepcevic, Anderson, W R, *et al.* 2015. Evaluating models to predict daily fine fuel moisture content in eucalypt forest. *Forest Ecology Management*, 335: 261-269.
- Slijepcevic A, Anderson W R, Matthews S. 2018. An analysis of the effect of aspect and vegetation type on fine fuel moisture content in eucalypt forest. *International Journal of Wildland Fire*, 27: 190-202.
- Viegas D, Viegas M, Ferreira A. 1992. Moisture Content of Fine Forest Fuels and Fire Occurrence in Central Portugal. *International Journal of Wildland Fire*, 2(2):69-86.
- Viney, N. R. 1991. A review of fine fuel moisture modelling. *Int. J. Wildland Fire* 1, 215-234.
- Dhaka VS, Meena SV, Rani G *et al.* 2021. A Survey of Deep Convolutional Neural Networks Applied for Prediction of Plant Leaf Diseases. *Sensors*. 21(14):4749.
- 王 珊,冯仲科,郁 壮等.模拟降雨下以小时为步长的崇礼区典型林分地表细小死可燃物含水率预测模型[J].应用与环境生物学

报:1-15[2023-07-17].

(Wang S, Feng Z K, Yu Z, *et al.* 2022. Prediction model of surface dead fine fuel moisture content by a one-hour time step in typical stand under simulated rainfall in the Chongli District, Zhangjiakou City, China. Chinese Journal of Applied And Environmental Biology.[in Chinese])

吴香华,华亚婕,官元红等.基于 CNN-Attention-BP 的降水发生预测研究[J].南京信息工程大学学报(自然科学版),2022,14(02):148-155.

(Wu X H, Hua Y J, Guan Y H, *et al.* 2022. Application of CNN-Attention-BP to precipitation forecast. Nanjing University of Information Science & Technology, 14(02):148-155.[in Chinese])

Yu H Z, Shu L F, Deng J F. *et al.* 2018. Prediction models and the extrapolation effects for water content of surface dead fuels in the typical stand of the Great Xing'an Mountains of China by one-hour time step. Chinese Journal of Applied Ecology, 29(12): 3959-3968.

Yu, H., Shu, L F, Yang G. *et al.* 2021. Comparison of vapour-exchange methods for predicting hourly twig fuel moisture contents of larch and birch stands in the Daxinganling Region, China. International Journal of Wildland Fire, 30:462-466.

于宏洲,柳慧,张运林等.地表细小可燃物含水率野外自动记录监测系统设计与实验[J].森林工程,2022,38(05):38-47.

(Yu Hz, Liu H, Zhang Y l *et al.* 2022. Design and Experiment of Monitoring System for Surface Fine Fuel Moisture. Forest Engineering, 38(5):38-47. [in Chinese])

Z. Li, F. Liu, W. Yang, S. Peng *et al.* 2022, A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. Transactions on Neural Networks and Learning Systems, 33(12): 6999-7019.

Zhang, J L, Cui, X Y, Wei, R. *et al.* 2017. Evaluating the applicability of predicting dead fine fuel moisture based on the hourly fine fuel moisture code in the south-eastern Great Xina'an mountains of China. International Journal of Wildland Fire, 26(2):167-175.

Zhang, Y.; Sun, P. 2020. Study on the Diurnal Dynamic Changes and Prediction Models of the Moisture Contents of Two Litters. Forests , 11: 95.

Zhang Y L, Sun P, Man Z Y. 2020. Effects of indoor simulated rainfall on moisture contents of litter beds of red pine and Mongolian oak. Journal of Central South University of Forestry & Technology, 40(9):1-10.

Zhang Y L, Xiang M, Ding B. 2022. Applicability analysis of direct estimation method for predicting litter moisture content in different layers. Journal of Central South University of Forestry & Technology, 42(7):9-19.