

东北地区典型细小死可燃物含水率预测及 5 种模型比较

范佳乐¹ 胡同欣¹ 任劲松² 刘祺³ 孙龙^{1*}

(1. 东北林业大学 哈尔滨 150040; 2. 内蒙古第一机械集团 包头 014030; 3. 辽宁省应急管理厅森林防灭火应急保障中心 沈阳 110041)

摘要:【目的】细小可燃物含水率(FFMC)是火灾风险评估中的一个关键因素,它对林火的蔓延和发展有着重要的影响。目前,基于机器学习对其进行预测的方法很多,但很少有人关注它们与传统模型比较,这导致了机器学习模型在 FFMC 预测中的应用存在一定的局限性。【方法】以半小时为步长,对中国东北地区 4 种典型森林的 FFMC 进行长期野外观测,分析 FFMC 的动态变化及其驱动因素,建立 5 种不同的预测模型,并对其性能进行了比较。【结果】总体来看,半物理模型(Nelson 法, MAE 为 0.566~1.332; Simard 法, MAE 为 0.457~1.250)表现最好,机器学习模型(随机森林模型, MAE 为 1.666~1.933; 广义加性模型, MAE 为 2.534~4.485)表现稍差,线性回归模型(MAE 为 2.798~5.048)表现最差。【结论】Simard 法、Nelson 法和随机森林模型表现出较好的性能,它们的 MAE 和 RMSE 几乎都小于 2%。此外,它还表明机器学习模型也可以准确地预测 FFMC,它们具有很大的潜力,因为它们可以在未来通过引入新的变量和数据的方法来不断发展模型,提高准确度和适应性。本研究为今后 FFMC 预测的选择和发展提供了依据。

关键词: 细小可燃物含水率、预测模型、温度、相对湿度、随机森林、人工林、广义加性模型

A comparison of five models in predicting surface dead fine fuel moisture content of typical forests in Northeast China

Abstract: 【Objective】 The spread and development of wildfires are deeply affected by the fine fuel moisture content (FFMC), which is a key factor in fire risk assessment. At present, there are many new prediction methods based on machine learning, but few people pay attention to their comparison with traditional models, which leads to some limitations in the application of machine learning in predicting FFMC. 【Method】 Therefore, we made long-term field observations of surface dead FFMC by half-hour time steps of four typical forests in Northeast China, analyzed the dynamic change in FFMC and its driving factors. Five different prediction models were built, and their performances were compared. 【Result】 By and large, our results showed that the semi-physical models (Nelson method, MAE from 0.566 to 1.332; Simard method, MAE from 0.457 to 1.250) perform best, the machine learning models (Random Forest model, MAE from 1.666 to 1.933; generalized additive model, MAE from 2.534 to 4.485) perform slightly worse, and the Linear regression model (MAE from 2.798 to 5.048) performs worst. 【Conclusion】 The Simard method, Nelson method and Random Forest model showed great performance, their MAE and RMSE are almost all less than 2%. In addition, it also suggested that machine learning models can also accurately predict FFMC, and they have great potential because it can introduce new variables and data in future to continuously develop. This study provides a basis for the selection and development of FFMC prediction in the future.

Key words: fine fuel moisture content, prediction model, temperature, relative humidity, Random Forest, plantations, generalized additive model

森林火灾是地球上最严重的自然灾害之一,对生态平衡和气候变化有重大影响,并造成巨大的经济损失和人员伤亡(Andela *et al.*, 2017; Bowman *et al.*, 2020; Bar-Massada *et al.*, 2020; Liu 等, 2021)。东北地区是中国森林火灾的重灾区之一,尤其是黑龙江省(孙萍等, 2018)。据统计,2003-2016年,东北地区共发生森林火灾 4290 起,累计受害森林面积 1,410,702 公顷,占总面积的 25.37% (Li, 2021)。此外,随

着气候变化的影响,森林火灾趋势不断加剧,火灾季节不断延长(Jolly *et al.*, 2015; Artés *et al.*, 2019)。因此,准确预测森林火灾的发生以减少甚至避免损失非常重要(Quan *et al.*, 2021年)。

以往研究表明,可燃物、气象因素、地形条件和人为因素对森林火灾的发生和发展有重要影响(Bilgili *et al.*, 2019; Kang *et al.*, 2020; Pham *et al.*, 2020)。其中,可燃物是森林火灾发生的物质基础和首要条件(Wehner *et al.*, 2017; Sun *et al.*, 2018)。可燃物含水率(FMC)影响引燃、蔓延速率(ROS)、辐射效率和能量释放,也是准确评估森林火险(Tian *et al.*, 2011; Holsinger *et al.*, 2016; Bilgili *et al.*, 2019)的重要依据。细小死可燃物含水率主要取决于外部气象因素,与活可燃物相比,其含水率往往较低(Viegas *et al.*, 1992; Riano *et al.*, 2005; Resco de Dios *et al.*, 2015)。细小死可燃物含水率(FFMC)是许多森林火险等级系统的关键指标,已被广泛应用于火灾管理(Matthews, 2014; Zhang *et al.*, 2017; Ellis *et al.*, 2022)。地表可燃物通常指林地表面时滞在 1-h 以内的枯草、落叶、针叶等(Gould *et al.*, 2011)。在相同的外部条件下,地表细小死可燃物含水率的变化速率快于其他可燃物和活可燃物(Gonzalez *et al.*, 2009; Lei *et al.*, 2022; Palomino *et al.*, 2022)。因此,测量地表 FFMC、研究其动态变化并进行预测具有重要意义。温度和相对湿度是影响 FFMC 的主要气象因素,它们直接影响可燃物与大气环境之间的水蒸气交换,二者具有协同作用(Viney, 1991; Matthews *et al.*, 2006; Alves *et al.*, 2009; Masinda *et al.*, 2021)。风、降水和太阳辐射等其他气象因素也直接或间接地影响着 FFMC,使其变化过程更加复杂(Slijepcevic *et al.*, 2018; Zhang *et al.*, 2020; Lindberg *et al.*, 2021; Zhang *et al.*, 2021; Lei *et al.*, 2022)。

FFMC 的测量方法很多,最常用的是干燥法和直接测量法,但这些方法仍存在一定的局限性(Viney, 1991; Matthews, 2010; Schunk *et al.*, 2016; Yan *et al.*, 2018; Cawson *et al.*, 2020; Lei *et al.*, 2022)。因此,分析气象因素与 FFMC 变化之间的关系以建立准确的预测模型是当前研究的重点(Aguado *et al.*, 2007; Pellizzaro *et al.*, 2007; Zhang *et al.*, 2021)。以前的研究使用许多传统模型预测 FFMC,包括经验模型、半物理模型和物理模型(Simard, 1968 年; Catchpole *et al.*, 2001 年; Matthews, 2006 年; Masinda *et al.*, 2021 年; Rakhmatulina *et al.*, 2021 年)。线性回归模型是一种典型的经验模型,它基于统计建立 FFMC 与气象因子之间的关系。该模型应用简单,但准确性和推断能力较差,模型误差可达 15%或更多(Matthews *et al.*, 2010; Sun *et al.*, 2015; Masinda *et al.*, 2021)。Catchpole 等(2001)提出了基于相关时滞和平衡含水率(EMC)建立预测模型的直接估计法,该方法可直接利用野外气象数据(温度和相对湿度)准确估算 FFMC。它已被美国(NFDRS)和加拿大(CFDRS)等主流森林火险等级系统所采用(Jin *et al.*, 2012; Rakhmatulina *et al.*, 2021)。其主要预测方程来源于基于物理的扩散方程,相关参数的估算主要通过实验获得,属于半物理模型(Jin *et al.*, 2010; Slijepcevic *et al.*, 2013)。然而,其,预测误差随着时间间隔的增加而增大(de Groot *et al.*, 2005; Matthews, 2014; Zhang *et al.*, 2021)。Zhang 和 Sun(2020)认为,过度简化 FFMC 的昼夜变化会增加模型误差,这提醒我们在更短的时间步长(1 小时或更短)下进行研究(Jin *et al.*, 2010; Masinda *et al.*, 2022)。物理模型具有较高的预测精度,但其结构复杂,应用前需要对模型参数进行大量的修改工作(Nelson, 2000; Matthews, 2006; Matthews *et al.*, 2006)。

此外,近年来机器学习也为 FMC 预测模型的建立提供了一些新的方法。与物理模型和经验模型不同,该方法不需要考虑 FMC 变化的复杂物理过程,可以描述自变量和因变量之间的复杂关系,具有物理模型和经验模型的优点。目前,机器学习已广泛应用于医学、生物学、生态学和森林火灾预测等领域(da Silva *et al.*, 2019; Coker *et al.*, 2021; Yuan *et al.*, 2021; Capps *et al.*, 2021)。Lee 等(2020)基于随机森林和支持向量机的机器学习算法建立了 10-h FMC 预测模型,并与回归模型和物理模型进行了比较。Fan 和 He(2021)将长短期记忆(LSTM)网络与基于物理过程的有效可燃物棒水分模型(FSMM)相结合来估计可燃物棒含水率。Lei 等(2022)提出了一种基于无线传感器网络(WSN)和反向传播(BP)神经网络的 FFMC 估算方法。目前,利用机器学习算法预测 FMC 的研究已成为当前研究的热点之一。然而,机器学习与经验模型、物理模型等传统预测方法之间的比较研究仍然缺乏,导致机器学习方法在该领域的应用存在一定的局限性。

中国东北地区作为北方森林生态系统向温带森林的过渡地带，是中国森林火灾最严重的地区之一。该地区主要林种为柯来松 (*Pinus koraiensis*)、蒙古松 (*Pinus sylvestris* var. *mongolica*)、桧木 (*Larix gmelinii*) 和桦木 (*Betula platyphylla*)，其林下落叶已成为该地区的主要可燃物，因此具有很大的森林火灾潜在风险 (Zhang et al.)。

本研究的目的是比较机器学习模型和传统模型的性能，分析两者的优缺点，找到适合东北地区 FFMC 准确预测的方法。采用无损采样的方法，以半小时为单位，在野外连续监测秋季火灾季节 FFMC 的动态变化。同时对气象要素进行了测定，分析了 FFMC 动态变化的驱动因素。采用半物理模型 (包括 Nelson 法和 Simard 法)、机器学习模型 (包括随机森林模型 (RF) 和广义相加模型 (GAM)) 和线性回归模型 (LR) 建立 FFMC 预测模型，并对各模型的性能进行评价和比较。研究结果对今后 FFMC 模型的选择和发展具有参考价值，也可为东北地区消防管理水平的提高提供依据。

1 研究区概况

研究区域为黑龙江省哈尔滨市东北林业大学帽儿山实验林场 (127°29'-127°44'E, 45°14'-45°29'N) (图 1)。森林覆盖率为 85%，森林总蓄积量为 20,500 km² (Zhang et al., 2020)，南北跨度约 30 公里，东西跨度约 26 公里。该地区以山地和丘陵为主，坡度较缓，海拔约 200-600 米。属温带大陆性季风气候，年平均气温 2.8℃，7 月最高平均气温 34℃，1 月最低平均气温 -40℃，大于 10℃ 的积温约 2300℃。年降雨量主要集中在 7 月和 8 月，年平均降水量为 700 毫米。主要土壤类型为典型的黑褐色森林土壤。主要树种有：红松 (*P. koraiensis*)、落叶松 (*L. gmelinii*)、白桦 (*B. platyphylla*)、蒙古栎 (*Quercus mongolica*)、胡桃楸 (*Juglans mandshurica*)、水曲柳 (*Fraxinus mandshurica*) 等。

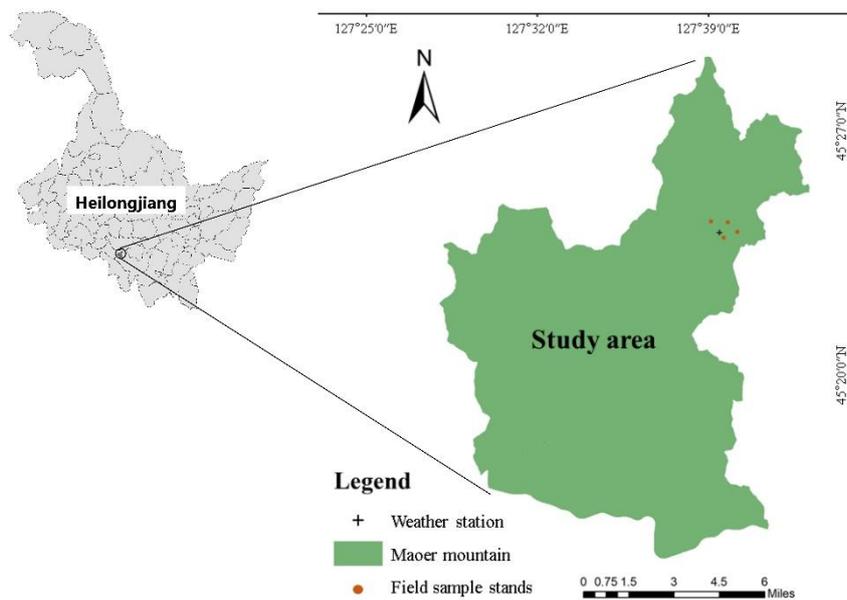


图 1 研究区域示意图

Fig. 1 The location of the study area

2 研究方法

2.1 样地设置

我们选取了这 4 种典型森林类型的人工林，以其表层落叶为研究对象。选取研究区内 4 种典型林分的人工林作为野外样地，于 2018 年 9 月 5 日至 9 月 10 日在每片林分设置 50 m×50 m 标准样地并进行勘查 (样林信息见表 1)。采用随机分布法在每个样林中均匀布设 5 个采样点，并放置 FMC 仪采集含水率和气象数据，以所有采样点的平均值代表该林。

表 1 研究样地基本概况

Table 1. The information of sample stands

Forest type	Elevation (m)	Mean height (m)	Mean DBH (cm)	Canopy density	Location	Aspect	Mean litter thickness (cm)	Standard error (cm)
<i>P. koraiensis</i>	389	22	19.70	0.60	Up Slope	South	5.70	0.24
<i>P. sylvestris</i> var. <i>mongolica</i>	413	25	18.51	0.55	Middle Slope	West	4.90	0.22
<i>L. gmelinii</i>	385	21	14.24	0.65	Down Slope	Southwest	4.30	0.19
<i>B. platyphylla</i>	417	19	20.13	0.50	Up Slope	Northwest	7.20	0.29

2.2 研究方法

从 2018 年 9 月 15 日至 11 月 15 日（涵盖整个秋季防火期），我们使用可燃物含水率自动测量仪器以半小时为间隔连续、自动测量实时的 FFMC 和气象数据。该测量仪可实时监测 FFMC，具有微型气象站的功能，是一种由电池和太阳能持续供电的自动称重设备（Masinda *et al.*, 2021 年, 2022 年）。它可以定时自动测量可燃物质量、温度、相对湿度、风速和太阳辐射。为了保证测量的准确性，在测量前，我们使用砝码（100 克、200 克和 500 克）对测量仪得到的数值进行校准（误差 0.01 克）。具体使用过程如下。在每个森林类型的样点放置计量器，采集样点附近的表层枯落细粒薪炭，带回实验室烘干称重，记录重量为薪炭干重。将采集的薪炭装入一个 30 cm×30 cm×6 cm 的筐中，在其上表面覆盖不锈钢网，以防止可燃物掉落。在此之前，称量篮子和不锈钢网的重量，由于它们的吸水性很差，因此吸水量可以忽略不计。校准计量器后，将篮子放回地块的地面上，并将其连接到计量器上。计量器每隔半小时对篮子称重一次，以计算 FFMC。在称重的同时，测量并记录离地面 1 米处的温度、相对湿度、风速和太阳辐射。降水数据从附近的固定气象站（距离采样点 2 公里以内）采集。我们可以通过热点传输数据和更改仪表的设置。在实验过程中，有一小部分数据由于设备本身的问题或缺电而丢失，我们对剩余的数据进行建模和分析。

2.3 数据分析

2.3.1 基本统计数据

在研究期间，分别收集了红松、樟子松、落叶松和白桦的 1121、2118、2310 和 1367 个数据记录。首先，对采集的数据进行基本的统计分析，计算出每各森林中的 FFMC 以及气象因子和 FFMC 的最大值、最小值和平均值。以采样日期为横坐标，FFMC 为纵坐标，绘制了各类型森林含水率动态变化曲线，并分析了其驱动因素。

2.3.2 预测模型

我们使用五种不同的方法分别建立半物理模型、机器学习模型和线性回归模型来预测 FFMC。之前的研究已经应用了这 5 种模型，并得出结论认为它们适用于预测 FFMC，且准确率相对较高（Catchpole *et al.*, 2001; Matthews, 2006; Lee *et al.*, 2020; Zhang *et al.*, 2020; Masinda *et al.*, 2021, 2022）。在本研究中，70%的数据用于训练模型，其余 30%用于测试和比较模型性能。每个模型的描述如下。

(1) 半物理模型

直接估计法考虑了可燃物水分扩散的物理过程，相关参数通过实验获得，属于半物理模型（Catchpole *et al.*, 2001; Jin *et al.*, 2012）。该模型使用简单、准确。利用实时含水率数据和现场气象数据，可在短时间内准确估算 FFMC，具有良好的适用性。是目前应用最广泛的方法之一。为了使结果更加准确，在直接估

计法中选择了基于半物理的 Nelson 模型 (Nelson, 1984) 和基于统计的 Simard 模型 (Simard, 1968) 作为 EMC 响应方程 (以下简称 Nelson 法和 Simard 法)。

该方法主要基于 Byram (1963) 提出的表面可燃物含水率微分方程, 如式 (1) 所示:

$$\frac{dM}{dt} = \frac{E-M}{\tau} \quad (1)$$

其中, M 表示细可燃物含水率 (%), E 表示平衡含水率 (%), τ 表示时滞 (h)。

将 Byram 水分微分方程(1)离散化, 得到以下方程。

$$M(t_i) = \lambda^2 M_{i-1} + \lambda(1-\lambda)E_{i-1} + (1-\lambda)E_i \quad (2)$$

式中 $M(t_i)$ 为时间 t_i 时的 FFMC (%); M_{i-1} 为时间 t_{i-1} 时的 FFMC (%); E_i 为时间 t_i 时的平衡含水率 (%); E_{i-1} 为时间 t_{i-1} 时的平衡含水率 (%); λ 是根据最小二乘法估算的模型参数, $\lambda = \exp(-\delta t / (2\tau))$; $\tau = \delta t / (2 \ln \lambda)$; Δt 是指研究中的时间步长, 因此 $\Delta t = 0.5h$ 半物理模型使用 R 软件包 "tidyverse" 实现。

上式中的平衡含水率可通过 Nelson 模型或 Simard 模型计算。Nelson 平衡含水率模型如式 (3) 所示:

$$E = \alpha + \beta \log \Delta G = \alpha + \beta \log \left(-\frac{RT}{m} \log H \right) \quad (3)$$

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, 其值为 $18 \text{ g} \cdot \text{mol}^{-1}$; α 和 β 是根据最小二乘法估算的模型参数。

Simard 平衡含水率模型见式 (4):

$$E = \begin{cases} 0.03 + 0.626H - 0.00104HT & H < 10 \\ 1.76 + 0.1601H - 0.0266T & 10 \leq H < 50 \\ 21.06 - 0.4944H + 0.005565H^2 - 0.00063HT & H \geq 50 \end{cases} \quad (4)$$

其中, E 为平衡含水率 (%), T 为气温 ($^{\circ}\text{C}$), H 为相对湿度 (%)。

(2) 随机森林

随机森林是一种基于决策树的综合学习算法, 可以描述线性和非线性关系, 而无需对自变量或因变量进行额外假设 (Breiman, 2001; Kamińska, 2019)。RF 可以随机的从原始样本中提取多个样本, 对每个样本进行决策树建模, 然后综合多个决策树的预测结果, 通过投票得到最终预测结果 (Gigović *et al.*, 2019)。RF 能够克服多因素、多维度数据之间复杂的非线性关系, 具有较高的预测精度。与 bagging 和 boosting 相比, RF 具有更快的学习速度, 对异常值和噪声具有良好的容错能力。此外, 许多研究利用 RF 对 FFMC 进行预测, 并显示出优异的性能 (Lee *et al.*, 2020; Fan *et al.*, 2021; Masinda *et al.*, 2021) 在 RF 中需要调整的参数数量相对较少, 即生长树的数量 (ntree) 和在每个节点分割节点的预测变量数量 (mtry) (Lee *et al.*, 2020)。根据 Kuhn 和 Johnson (2013) 的建议, ntree 设置为 1500。为了确定 mtry 的最佳值, 我们从 2 开始不断尝试, 比较模型的均方根误差 (RMSE)、平均绝对误差 (MAE) 和 R^2 值, 最终得到最佳模型。定量分析了自变量在模型中的重要性和显著性。利用 R 软件包 "randomForest" 和 "rfPermute" 实现了 RF 模型。

(3) 广义加性模型

广义加法模型是广义线性模型 (GLM) 的半参数扩展, 是一种机器学习模型。它是由数据驱动的非参数回归模型, 而非统计分布模型。GAM 通过链接函数建立响应变量的数学期望值与解释变量的平滑函数之间的关系 (Gomez-Rubio, 2018)。GAM 的优势在于可以使用多种不同的链接函数来拟合响应变量与多个解释变量之间的非线性和非单调关系 (Masinda *et al.*, 2021)。它可以解释响应变量 (定性或半定量的不连续变量) 如何随解释变量的变化而变化, 并且不需要预先设定模型参数 (Guisan *et al.*, 2002)。因此, GAM 具有高度的灵活性, 能够有效揭示隐藏在数据中的生态关系。GAM 可以简单地拟合多种气象因子与

FFMC 之间的非线性关系，并将其集合在一个模型中。此外，Masinda 等（2021）的研究也表明，其预测 FFMC 的精度与 RF 相似。模型如下

$$n=g(\mu)=s_0+\sum_{i=1}^p s_i(x_i) \tag{5}$$

其中 $\mu = E(Y|x_1, x_2 \dots x_p)$ n 是线性预测值、 s_0 是截距、 $s_i(\cdot)$ 是非参数平滑函数、 x_i 是自变量， $s_i(x_i)$ 是平滑项。该模型不需要 Y 对 x 的任何假设，由随机分量 Y 、加法分量 n 和联系函数组成。 $s_i(\cdot)$ 。

由于 GAM 是一个 "加法"假设，重要的交互作用 $x_j \times x_k$ 可能在模型中缺失，只能手动添加（Wood 等，2013）。本研究分别采用广义交叉验证法（GCV）和限制极大似然法（REML）建立 GAM，并通过 R^2 值和解释力对两种方法进行比较。GAM 由 R 语言包 "mgcv" 实现。

(4) 线性回归模型

线性回归模型是一个经验模型。通过正向逐步回归分析法分析对 FFMC 有显著影响的气象因子，建立回归模型，如式（6）所示：

$$M=\sum_{i=1}^n x_i b_i \tag{6}$$

其中 M 为 FFMC， x_i 为选定的气象因子， b_i 为待估算的参数。LR 使用 R 软件包 "tidyverse" 实现。

2.3.3 模型评估和比较

对每组数据进行了统计分析。检验了数据分布的正态性、方差的均匀性、残差的独立性和模型解释变量的一致性。为检验上述方法建立的模型的准确性，计算了模型的 MAE 和 RMSE，如式（7）和（8）所示。

$$MAE=\frac{1}{n}\sum_{i=1}^n |M_i-\widehat{M}_i| \tag{7}$$

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^n (M_i-\widehat{M}_i)^2} \tag{8}$$

其中 M_i 是 FFMC 的测量值（%），而 \widehat{M}_i 是 FFMC 的预测值（%）。

3 结果与分析

3.1 FFMC 的动态变化

表 2 列出了 4 种森林类型地表可燃物 FFMC 的统计数据。樟子松中 FFMC 的平均值和变化幅度最大，最大值为 39.2%，最小值为 9.8%，平均值为 23.2%；白桦的幅度最小，最大值为 30.8%，最小值为 9.4%；红松的平均值最小，为 19.8%。

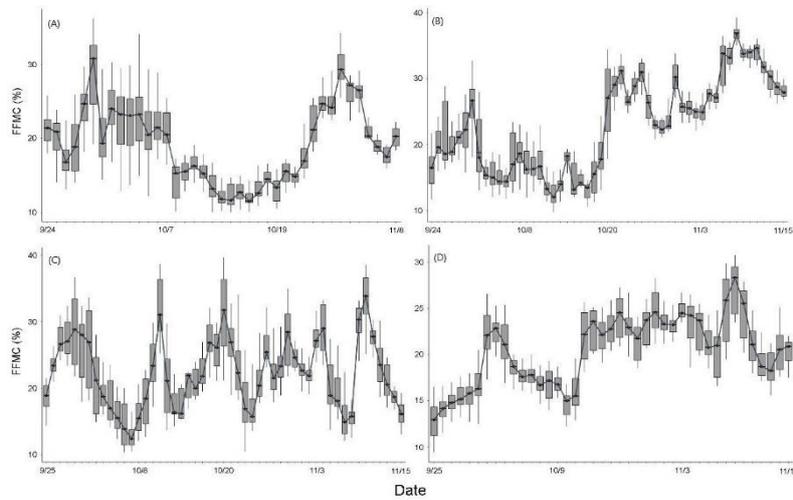
各森林类型 FFMC 的动态变化趋势相似，均呈现出先上升、后下降、再上升的特点（图 2）。除白桦在 9 月 29 日前后出现第一个峰值外，其他林分均在 9 月 29 日前后出现第一个峰值。随后，FFMC 逐渐下降，在 10 月 6 日至 10 月 19 日期间通常低于 20%，恢复到正常水平。在此期间，10 月 9 日左右又出现了一次小的降雨，使樟子松和落叶松的 FFMC 呈小幅上升趋势。10 月 19 日后，受降雪影响，FFMC 呈上升趋势，并于 10 月 20 日前后第二次达到峰值。白桦 FFMC 动态变化略晚于其他林分，FFMC 在 9 月 25 日开始逐渐上升，10 月 3 日达到第一个峰值，之后逐渐下降，直到 10 月 16 日前后出现上升趋势，之后含水率保持相对稳定。

表 2 不同林分地表死可燃物含水率统计

Table 2. Statistics on the moisture content of surface dead fuels in different forest stands

Forest type	N	Maximum (%)	Minimum (%)	Mean (%)
<i>P. koraiensis</i>	1121	36.1	10.1	19.8
<i>P. sylvestris</i> var. <i>mongolica</i>	2118	39.2	9.8	23.2
<i>L. gmelinii</i>	2310	39.6	10.4	22.6

B. platyphylla 1367 30.8 9.4 20.7



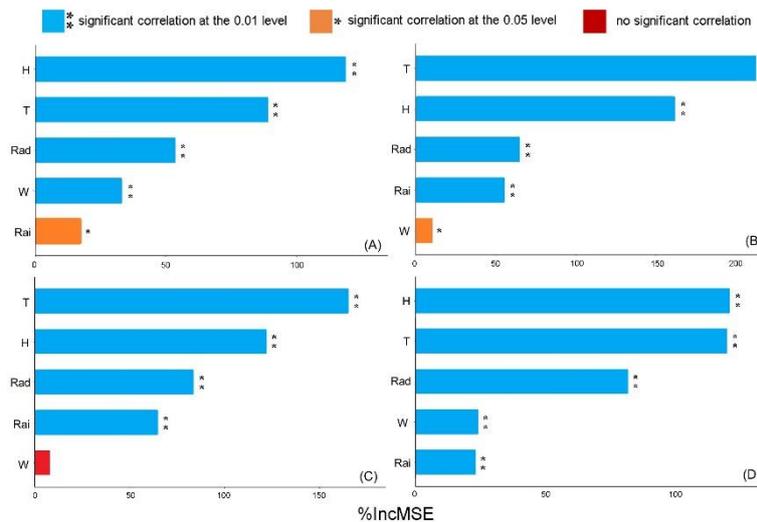
(A) 红松; (B) 樟子松; (C) 落叶松; (D) 白桦

图 2 不同林分内可燃物含水率动态变化趋势

Fig. 2 The dynamic change trend of fuel moisture content under different forest stands

3.2 气象因子的影响

利用随机森林模型对不同森林中气象因子的重要性进行了排序 (图 3)。在所有森林类型中, 温度、相对湿度和太阳辐射对 FFMC 均有显著影响 ($P < 0.01$), 温度和相对湿度在所有森林类型中的重要性均大于其他因子。降雨量对所有森林类型的 FFMC 均有显著影响, 但显著性水平不同 ($P < 0.05$ 在红松中, $P < 0.01$ 在其他森林中)。风对红松和白桦的 FFMC 有明显影响 ($P < 0.01$), 但对落叶松森林没有影响。综上所述, 由于森林结构的差异和空间异质性的存在, 气象因子对每种森林的影响不同。温度和相对湿度是影响地表可燃物含水率的主要气象因子。



T 是温度, H 是相对湿度, Rai 是降雨量, W 是风速, Rad 为太阳辐射;

**表示在 0.01 水平上显著相关, *表示在 0.05 水平上显著相关;

(A) 红松; (B) 樟子松; (C) 落叶松; (D) 白桦

图 3 基于均方误差的随机森林法的变量重要性

Fig. 3 Variable importance measures with the Random Forest method based on mean squared error

3.3 模型

3.3.1 模型参数

(1) 半物理模型

在红松、樟子松、落叶松和白桦中, Nelson 法预测模型的 R^2 为 0.853~0.980,时滞分别为 5.193 h、35.589 h、20.708 h 和 41.542 h。Simard 方法的预测模型的 R^2 在 0.847~0.980 之间,时滞分别为 27.635 h、83.208 h、35.589 h 和 124.875 h(表 3)。除红松外, 其它 3 种森林的 R^2 值约为 0.970。时间滞后与 FFMC 的变化速率有关, 时间滞后越大, 变化速率越慢。在 4 个森林中, Simard 方法的时滞大于 Nelson 方法的时滞, 两种方法的时滞在 4 个森林中由小到大依次为: 白桦、樟子松、落叶松和红松。

表 3 Nelson 模型和 Simard 模型的估计参数和拟合优度统计量

Table 3. Estimated parameters and goodness-of-fit-statistics of the Nelson model and Simard model

Model	Parameters	<i>P. sylvestris</i>			
		<i>P. koraiensis</i>	var.	<i>L. gmelinii</i>	<i>B. platyphylla</i>
			<i>mongolica</i>		
Nelson	α	0.330	0.489	0.275	0.128
	β	-0.081	-0.190	-0.057	0.056
	λ	0.953	0.993	0.988	0.994
	τ	5.193	35.589	20.708	41.542
	R^2	0.853	0.980	0.964	0.968
	MAE	1.332	0.596	0.578	0.566
	RMSE	1.840	1.137	0.898	0.717
Simard	λ	0.991	0.997	0.993	0.998
	τ	27.653	83.208	35.589	124.875
	R^2	0.847	0.980	0.964	0.970
	MAE	1.250	0.537	0.579	0.457
	RMSE	1.736	0.882	0.900	0.747

(2) 随机森林

每次分割尝试的变量个数(mtry)会在一定程度上影响模型的性能。通过不断尝试发现, 在所有森林中, 当 mtry 为 4 时, 训练和验证效果最好, 因此 mtry 被确定为 4 (表 4)。在所有森林中, RF 建立的预测模型的 R^2 范围为 0.903 到 0.935。

表 4 随机森林模型的参数和拟合优度统计量

Table 4. Parameters and goodness-of-fit-statistics of the Random Forest model

Forest type	mtry	R^2	MAE	RMSE
<i>P. koraiensis</i>	4	0.906	1.813	2.191
<i>P. sylvestris</i> var. <i>mongolica</i>	4	0.903	1.933	2.400
<i>L. gmelinii</i>	4	0.914	1.826	2.229
<i>B. platyphylla</i>	4	0.935	1.666	2.173

(3) 广义加法模型

表 5 (GCV 法) 和表 6 (REML 法) 显示了 4 个森林的 GAM 估计参数和自由度。在红松、樟子松、落叶松和白桦中, GCV 法各森林的 R^2 分别为 0.267、0.319、0.235 和 0.350, 解释力分别为 29.5%、31.9%、25.3%和 36.2%。在 REML 方法中, 各森林的 R^2 分别为 0.261、0.313、0.228 和 0.346, 解释力分别为 28.5%、31.2%、24.3%和 35.4%。模型的性能相对较差。比较 R^2 和解释力, 可以得出 GCV 方法比 REML 方法性能更好的结论。因此, 以下研究选择了用 GCV 方法建立的 GAM (以下提到的所有 GAM 都是用 GCV 方法建立的)。

GAM 中平滑项的自由度越大, 解释变量与响应变量之间的非线性关系越显著。所有森林的温度和相对湿度的自由度都明显大于其他三个解释变量的自由度, 因此它们与 FFMC 之间的非线性关系最为显著。GCV 值是评价模型平稳性的参数之一, GCV 值越小, 模型的平稳性越高, 拟合度越好。四种森林的 GCV 值从低到高的顺序如下: 白桦、红松、落叶松和樟子松。

表 5 GCV 法的模型参数和平滑项的自由度

Table 5. Model parameters and degrees of freedom of smoothing terms with the GCV method.

T is temperature; H is relative humidity; Rai is rainfall; W is wind speed; Rad is solar radiation. s_0 is the parametric coefficient, and $edf.s()$ is the estimated degree of freedom.

Forest type	s_0	edf.s(T)	edf.s(H)	edf.s(Rai)	edf.s(W)	edf.s(Rad)	GCV	R^2	Dev (%)
<i>P. koraiensis</i>	2.974	8.623	7.536	1.000	2.548	4.105	1.106	0.267	29.5
<i>P. sylvestris</i> var. <i>mongolica</i>	3.131	7.940	7.602	2.446	1.001	1.222	1.459	0.319	31.9
<i>L. gmelinii</i>	3.102	8.382	8.194	7.864	1.000	5.787	1.193	0.235	25.3
<i>B. platyphylla</i>	3.027	8.607	6.605	6.638	1.687	1.001	0.508	0.350	36.2

表 6 REML 法的模型参数和平滑项的自由度

Table 6. Model parameters and degrees of freedom of smoothing terms with the REML method

Forest type	s_0	edf.s(T)	edf.s(H)	edf.s(Rai)	edf.s(W)	edf.s(Rad)	REML	R^2	Dev (%)
<i>P. koraiensis</i>	2.975	7.549	6.031	1.001	1.404	4.350	468.730	0.261	28.5
<i>P. sylvestris</i> var. <i>mongolica</i>	3.131	6.547	7.004	2.876	1.000	1.038	1062.400	0.313	31.2
<i>L. gmelinii</i>	3.102	7.542	7.461	4.834	1.000	2.766	997.990	0.228	24.3
<i>B. platyphylla</i>	3.027	8.378	6.585	1.690	1.777	1.000	189.600	0.346	35.4

表 7 广义加性模型的拟合优度统计量

Table 7. The goodness-of-fit-statistics of Generalized additive model

	<i>P. koraiensis</i>	<i>P. sylvestris</i> var. <i>mongolica</i>	<i>L. gmelinii</i>	<i>B. platyphylla</i>
MAE	3.655	4.485	4.115	2.534
RMSE	4.386	5.295	5.501	3.101

(4) 线性回归模型

采用正向逐步选择法建立线性回归模型，筛选气象因子并建立最佳模型。结果如表 8 所示，所有森林均选择温度、相对湿度和降雨量作为模型的气象因子。结果如表 8 所示，在所有森林中，温度、相对湿度和降雨均被选作模型的气象因子。此外，红松还选择了风速作为模型的气象因子，樟子松和落叶松也选择了太阳辐射作为模型的气象因子。预测模型的 R^2 范围为 0.147 至 0.244。

表 8 线性回归模型的参数和拟合优度统计量

Table 8. Parameters and goodness-of-fit-statistics of the linear regression models

Forest type	Equation	R^2	MAE	RMSE
<i>P. koraiensis</i>	$M = 14.639 - 0.106T_i + 0.144H_i - 3.361W_i + 2.997R_i$	0.156	3.932	4.576
<i>P. sylvestris</i> var. <i>mongolica</i>	$M = 31.105 - 0.547T_i - 0.083H_i + 5.784R_i + 0.003Ra_i$	0.244	5.048	5.972
<i>L. gmelinii</i>	$M = 7.866 + 0.171T_i + 0.205H_i + 3.659R_i + 0.001Ra_i$	0.147	4.394	5.348
<i>B. platyphylla</i>	$M = 24.155 - 0.189T_i - 0.043H_i + 4.241R_i$	0.201	2.798	3.352

3.3.2 模型误差比较

根据训练数据建立预测模型后，通过测试数据对模型的性能进行评估，并根据测试数据计算模型误差。如图 4 所示，比较了各森林中不同方法建立的模型的 MAE 和 RMSE。Nelson 方法的模型误差（MAE 和 RMSE）范围为 0.566%-1.840%；Simard 方法的模型误差范围为 0.457%-1.736%；RF 方法的模型误差范围为 1.666%-2.400%；GAM 方法的模型误差范围为 2.534%-5.501%；LR 方法的模型误差范围为 2.798%-5.972%。

比较同一方法下不同森林的预测精度，对于 RF 法、GAM 法和 LR 法，各森林的预测精度从高到低依次为白桦、红松、落叶松和樟子松。在 Nelson 法和 Simard 法中，拟合的预测模型准确度最高，樟子松和落叶松次之，红松最低。总体而言，无论采用哪种方法，白桦的预测模型准确率在所有森林中都是最高的。

比较同一森林中不同模型的精度，GAM 和 LR 的准确率明显低于其他方法，模型误差较大，且 GAM 略优于 LR。Nelson 方法、Simard 方法和 RF 表现出良好的性能，大多数森林中的模型误差均小于 2%，明显高于 GAM 和 LR。对于这三种方法，在红松、樟子松和白桦中，Simard 法准确率最高，Nelson 法次之，RF 法最低。在落叶松中，Nelson 法的准确度最高，Simard 法次之，RF 法也最低。而且，Nelson 方法和 Simard 方法的预测精度在所有森林中都非常接近。总的来说，属于半物理模型的 Nelson 方法和 Simard 方法比属于机器学习模型的随机森林法表现得更好。

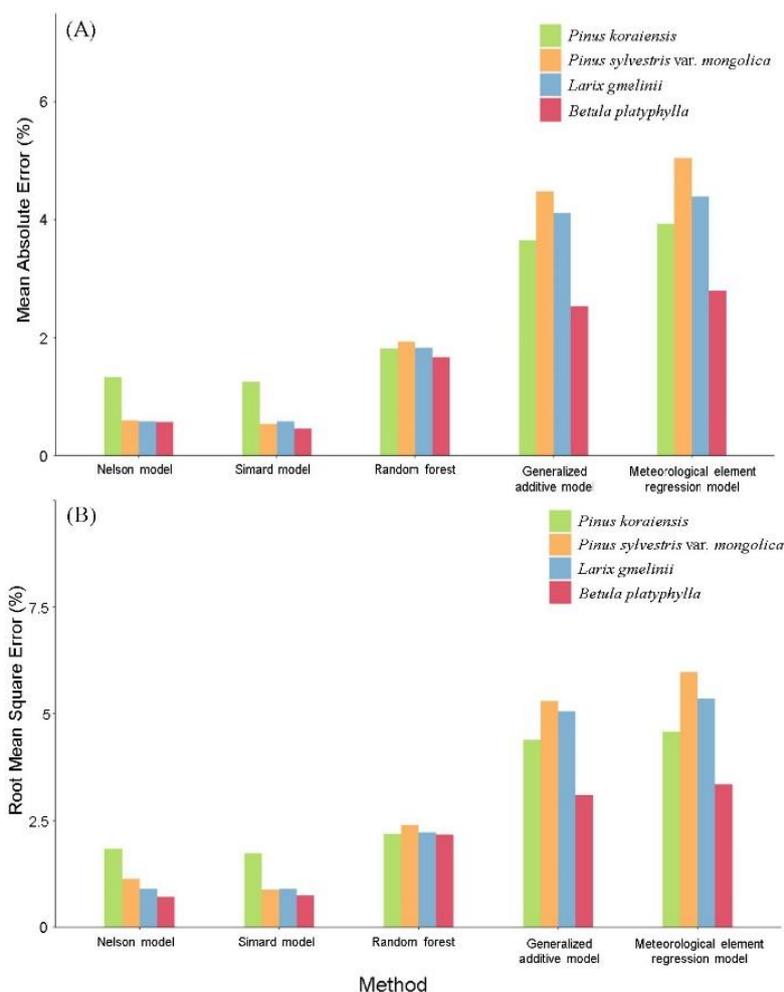
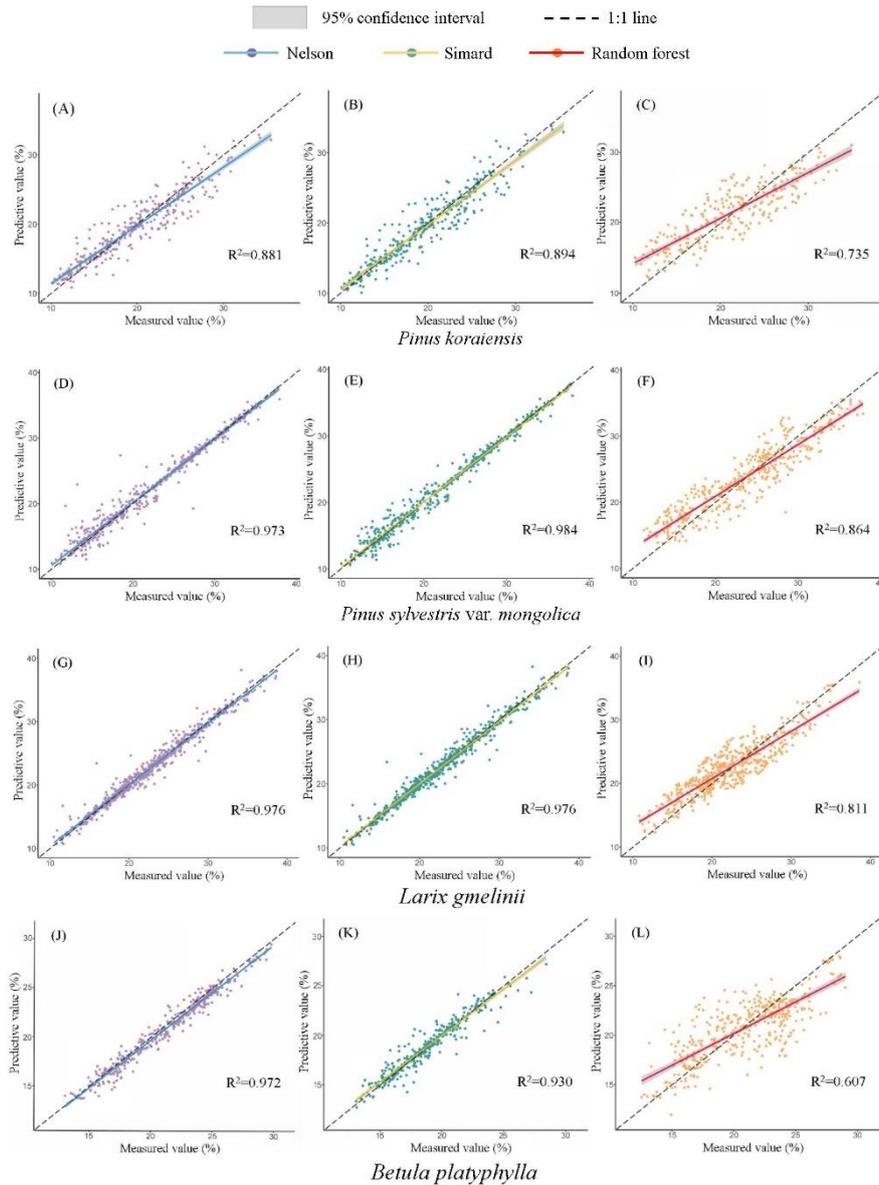


图 4 各林分可燃物含水率预测模型误差比较。

Fig. 4 Comparison of fuel moisture content model errors in each forest

3.3.3 模型性能评估

与其他三种方法相比，GAM 和 LR 的预测性能明显较低，因此下文不再对其进行研究。将测试数据的实测值与基于训练数据建立的 Nelson 方法、Simard 方法和 RF 方法的预测值进行比较，如图 5 所示。在所有森林中，Nelson 法和 Simard 法的预测值与实测值基本一致，拟合线的 R^2 在 0.881~0.984 之间，Simard 法的精度略高于 Nelson 法。对于 RF，所有林分的预测值与实测值均存在一定的偏差，拟合线的 R^2 在 0.607~0.864 之间，当 FFMC 低于约 21% 时模型高估，而当 FFMC 高于约 21% 时模型低估，尤其是白桦。因此，可以认为 RF 的预测精度略低于其他两种方法。综上所述，5 种方法在所有林分中的预测准确率从高到低排序为 Simard 法>Nelson 法>RF 法>GAM 法>LR 法。



(A), (B) 和 (C) 红松; (D), (E) 和 (F) 樟子松; (G), (H) 和 (I) 落叶松; (J), (K) 和 (L) 白桦

图 5 各林分含水率模型的预测值和实测值的 1:1 误差散点图

Fig. 5 1:1 error scatter plot of the predicted and measured values of each forest

4 讨论

4.1 气象因子分析

通过 RF 模型对气象变量重要性的定量分析表明, 温度、相对湿度和太阳辐射对所有森林的 FFMC 均有显著影响, 尤其是温度和相对湿度, 其重要性大于其他三个气象因子。该结果与之前的研究(Viney, 1991; Slijepcevic *et al.*, 2013; Nyman *et al.*, 2015; Zhang *et al.*, 2017; Masinda *et al.*, 2021; Yu *et al.*, 2021) 相似, 温度和相对湿度是最重要的气象因子, 直接影响 FFMC。风对 FFMC 的影响受地形、森林结构、树冠密度等因素的影响。本研究中, 只有红松和白桦的 FFMC 受风的影响显著 ($P < 0.01$), 这与 Bilgili 等 (2019) 以及 Zhang 和 Sun (2020) 的研究结果相似。这是因为研究期间采集风速数据的时间间隔较短, 不能反映风对 FFMC 的影响。此外, 它低估了降雨对 FFMC 的影响, 这与 Masinda 等 (2021) 的结果相同。这可能是由于降雨量和持续时间较短, 收集到的数据大多为零, 因此无法反映其重要性。

4.2 模型参数

在半物理模型中, Nelson 平衡含水率模型的参数需要根据实验数据进行估算。在红松、樟子松、落叶松和白桦中, α 值分别为 0.330、0.489、0.275 和 0.128, β 值分别为-0.081、-0.190、-0.057 和 0.056。这与前人的研究结果相似, Sun 等 (2015) 发现 α 值在 0.087~0.594 之间, Slijepcevic 等 (2013) 发现 α 值在 0.28~0.41 之间。Zhang 和 Sun (2020) 发现, 红松和蒙古的 α 值分别为 0.0039 和 0.2458。除了可燃物种类的影响外, 造成差异的原因还与测量方法和时间步长有关。在以往的研究中, 最短的时间步长为 1 h, 而我们测定的是整个秋季火季的含水率数据, 时间步长为半小时。 β 值可以直接反映平衡含水率对温度和湿度的敏感性, β 的绝对值越大, 表明可燃物对温度和湿度的敏感性越强, 可燃物的持水能力越弱 (Nelson, 1984)。在本研究中, β 的绝对值从高到低对四种森林进行了如下排序: 在本研究中, β 的绝对值从高到低的顺序依次为: 樟子松、红松、落叶松和白桦, 即阔叶层的持水能力强于针叶层。这与 Zhang 和 Sun (2020) 以及 Yu 等 (2021) 的研究结果不同。这是因为不同的可燃物类型和采样季节会影响可燃物的理化性质、枯落物层的堆积比等结构特征, 从而导致不同的结果。

4.3 模型评价和比较

采用 5 种不同的方法建立了各森林地表枯落物预测模型, 并根据实验数据对模型的准确性和适用性进行了评价。 R^2 反映了不同模型在不同森林类型中的拟合优度。对于 Nelson 法和 Simard 法, 它们的 R^2 值非常接近, 除红松为 0.853 左右外, 其余 3 种森林类型均为 0.970 左右, 说明回归线与观测值拟合得非常好。对于 RF 法, 其 R^2 在 0.903~0.935 之间, 与上述两种方法相似, 也显示出良好的拟合效果。但 GAM 和 LR 的 R^2 分别为 0.235~0.350 和 0.147~0.244, 明显低于其他三种方法, 拟合程度较差, 精度较低。通过对模型误差的比较可以得出, 无论采用哪种方法, 白桦预测模型的准确度在所有森林中都是最高的。这是因为白桦属于阔叶树, 叶片小而平, 结构较针叶简单而均匀, 因此采用相同的方法预测精度较高, 这与余国强等 (2021) 的研究结果相似。

比较了不同方法的准确性。在所有森林中, 五种方法的准确性从高到低排序如下: Simard 法>Nelson 法>RF>GAM>LR。基于直接估计法的 Nelson 法和 Simard 法精度最高, 这可能与本研究中数据采集的时间间隔较短 (半小时) 有关 (de Groot *et al.*, 2005; Matthews, 2010, 2014)。结果与之前的大多数研究相似, Simard 方法的预测精度略高于 Nelson 方法 (Jin *et al.*, 2012; Sun *et al.*, 2015; Zhang *et al.*, 2020)。RF 和 GAM 虽然都属于机器学习算法, 但其理论不同 (Breiman, 2001; Gomez-Rubio, 2018; Kamińska, 2019), 因此预测模型的准确性表现出明显的差异。RF 的性能明显优于 GAM, 它更适用于 FPMC 预测 (Lee *et al.*, 2020; Masinda *et al.*, 2021)。然而, 其精度仍略低于 Nelson 方法和 Simard 方法。如图 5 所示, RF 低估了大数值, 高估了小数值。这是由其自身的原理决定的, RF 倾向于中间预测值, 极端观测值使用更接近这些观测值的响应值的平均值进行估计 (Zhang *et al.*, 2012; Wolfensberger *et al.*, 2021)。LR 的结果与 GAM 相似, 明显低于其他三种方法 (Sun 等, 2015; Masinda 等, 2021; Yu 等, 2021)。由于它们都是基于 FPMC 与气象因子之间的线性或非线性关系, 气象因子的选择对模型的精度影响很大。然而, 我们在本研究中没有考虑土壤水分和以前气象因子的影响 (Zhang *et al.*, 2020)

总的来说, 半物理模型 (Nelson 法和 Simard 法) 的精度最高, 机器学习模型的精度稍差, 线性回归模型 (LR) 的精度最差。Lee 等人 (2020) 的研究表明, 对于 10-h 的 FPMC, 机器学习模型的精度高于过程模型, 这与我们的研究结果不同。这是由于可燃物的大小不同, 我们以 1-h 的细小可燃物为研究对象, 其失水和吸水速度比 10-h 可燃物快。半物理模型精度最高的潜在原因之一可能是时间间隔较短, 在实际应用中, 精度会随着时间间隔的增加而降低 (de Groot *et al.*, 2005; Matthews, 2014; Zhang *et al.*, 2021)。虽然

机器学习模型的准确率略低，但未来可以引入新的变量和数据，不断发展模型，具有很大的应用潜力。但是，机器学习模型还有一点值得注意，就是模型不能用公式来描述，这对未来的应用可能会有一定的限制。因此，在今后的研究中，我们应重点研究 Reichstein 等（2019）提出的数据驱动（如机器学习）和过程驱动（如物理模型和半物理模型）相结合的方法，建立混合模型，实现优势互补。此外，还应考虑更多的机器学习模型。

FFMC 的预测精度必须达到约 1%-2% 的 MAE 才能满足火险预测的精度要求（Trevitt, 1991; Pippen, 2008）。结果表明，Simard 法、Nelson 法和 RF 法在所有森林中的模型误差均小于 2%。它们优于 Catchpole 等人（2001）报告的 0.8% 至 1.9% 的 MAE 范围，以及 Matthews 和 McCaw（2006）报告的分别为 1.3% 和 9.4% 的 MAE 和 MRE（平均相对误差）；与 Zhang 和 Sun（2020）以及 Masinda 等人（2021）的研究结果相似。这 3 种模型均可用于预测 4 种森林的 FFMC，其精度均能满足要求。此外，研究还证明 RF 也适用于预测 FFMC，其模型性能良好。GAM 和 LR 的误差值相对较大，不适合预测 FFMC。本研究还存在一定的局限性，如未考虑季节、气象因素的滞后性以及坡度、坡向等地形条件对 FFMC 的影响。在今后的研究中，应充分考虑不同森林特征和地形条件对 FFMC 的影响及其动态变化，为提高 FFMC 预测的准确性和适用性提供理论支持。

5 结论

本文研究了东北地区 4 个典型森林地表细小死可燃物含水率的动态变化及其主要驱动因子，采用 5 种不同的方法建立了 FFMC 预测模型，并基于实验数据对其性能进行了比较。结果表明，各森林 FFMC 的动态变化趋势相似，温度和相对湿度是 FFMC 的主要驱动因素。从模型误差和实测值与预测值的比较来看，半物理模型（Nelson 法和 Simard 法）表现最好，机器学习模型（RF 和 GAM）表现稍差，线性回归模型（LR），表现最差。其中，基于 Nelson 法、Simard 法和 RF 法的预测模型精度满足森林火险预测的要求。本研究的模型比较结果对未来 FFMC 预测模型的研究方向以及东北地区的森林火灾管理和预测具有一定的参考价值。

参 考 文 献

- Aguado, I., Chuvieco, E., Borén, R., Nieto, H. (2007). Estimation of dead fuel moisture content from meteorological data in Mediterranean areas. Applications in fire danger assessment. *Int. J. Wildland Fire* 16, 390-397.
- Alves, M. V. G., Batista, A. C., Soares, R. V., Ottaviano, M., & Marchetti, M. (2009). Fuel moisture sampling and modeling in *Pinus elliottii* Engelm. plantations based on weather conditions in Paraná-Brazil. *iForest* 2, 99-103.
- Andela, N., Morton, D. C., Giglio, L., Chen, Y., van der Werf, G. R., Kasibhatla, P. S., et al. (2017). A human-driven decline in global burned area. *Science* 356, 1356-1362.
- Artés, T., Oom, D., De Rigo, D., Durrant, T. H., Maianti, P., Libertà, G., et al. (2019). A global wildfire dataset for the analysis of fire regimes and fire behaviour. *Sci. Data* 6, 1-11.
- Bar-Massada, A., and Lebrija-Trejos, E. (2020). Spatial and temporal dynamics of live fuel moisture content in eastern Mediterranean woodlands are driven by an interaction between climate and community structure. *Int. J. Wildland Fire* 30, 190-196.
- Bilgili, E., Coskuner, K. A., Usta, Y., Goltas, M. (2019). Modeling surface fuels moisture content in *Pinus brutia* stands. *J. For. Res.* 30, 577-587.
- Bowman, D. M., Kolden, C. A., Abatzoglou, J. T., Johnston, F. H., van der Werf, G. R., Flannigan, M. (2020). Vegetation fires in the Anthropocene. *Nat. Rev. Earth Environ.* 1, 500-515.
- Bovill, W., Hawthorne, S., Radic, J., Baillie, C., Ashton, A., Lane, P., et al. (2015). Effectiveness of automated fuelsticks for predicting

- the moisture content of dead fuels in Eucalyptus forests. In '21st International Congress on Modelling and Simulation, 29 November–4 December 2015, Gold Coast, Australia'. 201–207.
- Breiman, L. (2001). Random Forests. *Mach. Learn.* 45, 5–32.
- Byram, G. M., and Nelson, R. M. (1963). An Analysis of the drying Process in Forest Fuel Material. In 'General Technical Report, US Department of Agriculture Forest Service, Southern Research Station'. 1–38.
- Capps, S. B., Zhuang, W., Liu, R., Rolinski, T., Qu, X. (2021). Modelling chamise fuel moisture content across California: a machine learning approach. *Int. J. Wildland Fire* 31, 136-148.
- Catchpole, E. A., Catchpole, W. R., Viney, N. R., McCaw, W. L., Marsden-Smedley, J. B. (2001). Estimating fuel response time and predicting fuel moisture content from field data. *Int. J. Wildland Fire* 10, 215-222.
- Cawson, J. G., Nyman, P., Schunk, C., Sheridan, G. J., Duff, T. J., Gibos, K., et al. (2020). Estimation of surface dead fine fuel moisture using automated fuel moisture sticks across a range of forests worldwide. *Int. J. Wildland Fire* 29, 548-559.
- Coker, E. S., Martin, J., Bradley, L. D., Sem, K., Clarke, K., Sabo-Attwood, T. (2021). A time series analysis of the ecologic relationship between acute and intermediate PM_{2.5} exposure duration on neonatal intensive care unit admissions in Florida. *Environ. Res.* 196, 110374.
- da Silva Marques, D., Costa, P. G., Souza, G. M., Cardozo, J. G., Barcarolli, I. F., Bianchini, A. (2019). Selection of biochemical and physiological parameters in the croaker *Micropogonias furnieri* as biomarkers of chemical contamination in estuaries using a generalized additive model (GAM). *Sci. Total Environ.* 647, 1456-1467.
- de Groot, W. J., and Wang, Y. (2005). Calibrating the fine fuel moisture code for grass ignition potential in Sumatra, Indonesia. *Int. J. Wildland Fire* 14, 161-168.
- Ellis, T. M., Bowman, D. M., Jain, P., Flannigan, M. D., Williamson, G. J. (2022). Global increase in wildfire risk due to climate-driven declines in fuel moisture. *Glob Chang Biol.* 28, 1544-1559.
- Fan, C., and He, B. (2021). A Physics-Guided Deep Learning Model for 10-h Dead Fuel Moisture Content Estimation. *Forests* 12, 933.
- Gigović, L., Pourghasemi, H. R., Drobnjak, S., Bai, S. (2019). Testing a new ensemble model based on SVM and Random Forest in forest fire susceptibility assessment and its mapping in Serbia's Tara National Park. *Forests* 10, 408.
- Gomez-Rubio, V. (2018). Generalized Additive Models: An Introduction with R. *J. Stat. Softw.* 86, 1-5.
- Gould, J. S., McCaw, W. L., Cheney, N. P. (2011). Quantifying fine fuel dynamics and structure in dry eucalypt forest (*Eucalyptus marginata*) in Western Australia for fire management. *For. Ecol. Manag.* 262, 531–546.
- Guisan, A., Edwards Jr, T. C., Hastie, T. (2002). Generalized linear and generalized additive models in studies of species distributions: setting the scene. *Ecol. Modell.* 157, 89-100.
- Holsinger, L., Parks, S. A., Miller, C. (2016). Weather, fuels, and topography impede wildland fire spread in western US landscapes. *For. Ecol. Manag.* 380, 59-69.
- Jin, S., and Li, L. (2010). Validation of the method for direct estimation of timelag and equilibrium moisture content of forest fuel. *Sci. Silvae Sin.* 46, 95-105.
- Jin, S., and Chen, P. (2012). Modelling drying processes of fuelbeds of Scots pine needles with initial moisture content above the fibre saturation point by two-phase models. *Int. J. Wildland Fire* 21, 418-427..
- Jolly, W. M., Cochrane, M. A., Freeborn, P. H., Holden, Z. A., Brown, T. J., Williamson, G. J., et al. (2015). Climate-induced variations in global wildfire danger from 1979 to 2013. *Nat. Commun.* 6, 1-11.
- Kamińska, J. A. (2019). A Random Forest partition model for predicting NO₂ concentrations from traffic flow and meteorological conditions. *Sci. Total Environ.* 651, 475-483.
- Kang, Y., Jang, E., Im, J., Kwon, C., Kim, S. (2020). Developing a new hourly forest fire risk index based on catboost in South Korea. *Appl. Sci.* 10, 8213.
- Lee, H., Won, M., Yoon, S., Jang, K. (2020). Estimation of 10-Hour Fuel Moisture Content Using Meteorological Data: A Model Inter-Comparison Study. *Forests* 11, 982.
- Lei, W. D., Yu, Y., Li, X. H., Xing, J. (2022). Estimating dead fine fuel moisture content of forest surface, based on wireless sensor network and back-propagation neural network. *Int. J. Wildland Fire* 31, 369-378.
- Li, Y. (2021) Study on Temporal and Spatial Variation of Forest Fire and Fire Risk Prediction in Large-scale Areas. [dissertation/master's thesis]. [Beijing]: Beijing Forestry University.
- Lindberg, H., Aakala, T., Vanha-Majamaa, I. (2021). Moisture content variation of ground vegetation fuels in boreal mesic and sub-xeric mineral soil forests in Finland. *Int. J. Wildland Fire* 30, 283-293.
- Liu, N., Lei, J., Gao, W., Chen, H., Xie, X. (2021). Combustion dynamics of large-scale wildfires. *Proc. Combust. Inst.* 38, 157-198.
- Masinda, M. M., Li, F., Liu, Q., Sun, L., Hu, T. (2021). Prediction model of moisture content of dead fine fuel in forest plantations on Maoer Mountain, Northeast China. *J. For. Res.* 32, 2023-2035.

- Masinda, M. M., Li, F., Qi, L., Sun, L., Hu, T. (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. *Nat Hazards* 111, 1085-1101.
- Matthews, S. (2006). A process-based model of fine fuel moisture. *Int. J. Wildland Fire* 15, 155–168.
- Matthews, S., and McCaw, W. L. (2006). A next-generation fuel moisture model for fire behaviour prediction. *For. Ecol. Manag.* 234, S91.
- Matthews, S. (2010). Effect of drying temperature on fuel moisture content measurements. *Int. J. Wildland Fire* 19, 800-802.
- Matthews, S., Gould, J., McCaw, L. (2010). Simple models for predicting dead fuel moisture in eucalyptus forests. *Int. J. Wildland Fire* 19, 459-467.
- Matthews, S. (2014). Dead fuel moisture research: 1991–2012. *Int. J. Wildland Fire* 23, 78-92.
- Nelson, R. M. (1984). A method for describing equilibrium moisture content of forest fuels. *Can. J. For. Res.* 14, 597-600.
- Nelson, R. M. (2000) Prediction of diurnal change in 10-h fuel stick moisture content. *Can. J. For. Res.* 30, 1071-1087.
- Nyman, P., Metzen, D., Noske, P. J., Lane, P. N., Sheridan, G. J. (2015). Quantifying the effects of topographic aspect on water content and temperature in fine surface fuel. *Int. J. Wildland Fire* 24, 1129-1142.
- Palomino, A. F., Espino, P. S., Reyes, C. B., Rojas, J. A. J., y Silva, F. R. (2022). Estimation of moisture in live fuels in the mediterranean: Linear regressions and Random Forests. *J. Environ. Manage.* 322, 116069.
- Pham, B. T., Jaafari, A., Avand, M., Al-Ansari, N., Dinh Du, T., Yen, H. P. H., et al. (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry* 12, 1022.
- Pippen, B. G. (2008). Fuel moisture and fuel dynamics in woodland and heathland vegetation of the Sydney Basin. PhD thesis, School of Physical, Environmental and Mathematical Sciences, University of New South Wales.
- Quan, X., Xie, Q., He, B., Luo, K., Liu, X. (2021). Corrigendum to: Integrating remotely sensed fuel variables into wildfire danger assessment for China. *Int. J. Wildland Fire* 30, 822-822.
- Rakhmatulina, E., Stephens, S., Thompson, S. (2021). Soil moisture influences on Sierra Nevada dead fuel moisture content and fire risks. *For. Ecol. Manag.* 496, 119379.
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N. (2019) Deep learning and process understanding for data-driven Earth system science. *Nature* 566, 195-204.
- Resco de Dios, V. R., Fellows, A. W., Nolan, R. H., Boer, M. M., Bradstock, R. A., Domingo F, et al. (2015). A semi-mechanistic model for predicting the moisture content of fine litter. *Agric For Meteorol* 203, 64-73.
- Riano, D., Vaughan, P., Chuvieco, E., Zarco-Tejada, P., Ustin, S. (2005). Estimation of fuel moisture content by inversion of radiative transfer models to simulate equivalent water thickness and dry matter content: analysis at leaf and canopy level. *IEEE Geosci. Remote. Sens. Lett.* 43, 819–826.
- Schunk, C., Ruth, B., Leuchner, M., Wastl, C., Menzel, A. (2016). Comparison of different methods for the in situ measurement of forest litter moisture content. *Nat. Hazards Earth Syst. Sci.* 16, 403–415.
- Slijepcevic, A., Anderson, W. R., Matthews, S. (2013). Testing existing models for predicting hourly variation in fine fuel moisture in eucalypt forests. *For. Ecol. Manag.* 306, 202-215.
- Slijepcevic, A., Anderson, W. R., Matthews, S., Anderson, D. H. (2018). An analysis of the effect of aspect and vegetation type on fine fuel moisture content in eucalypt forest. *Int. J. Wildland Fire* 27, 190-202.
- 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)
- Sun, P., Yu, H., Jin, S. (2015). Predicting hourly litter moisture content of larch stands in Daxinganling Region, China using three vapour-exchange methods. *Int. J. Wildland Fire* 24, 114-119.
- Sun, P., and Zhang, Y. (2018). A probabilistic method predicting forest fire occurrence combining firebrands and the weather-fuel complex in the northern part of the Daxinganling Region, China. *Forests* 9, 428.
- Tian, X., McRae, D. J., Jin, J., Shu, L., Zhao, F., Wang, M. (2011). Wildfires and the Canadian Forest Fire Weather Index system for the Daxing'anling region of China. *Int. J. Wildland Fire* 20, 963-973.
- Trevitt, A. C. F. (1991). Weather parameters and fuel moisture content: standards for fire model inputs. In 'Proceedings of the Conference on Bushfire Modelling and Fire Danger Rating Systems', 11–12 July 1988, Canberra, ACT. (Eds NP Cheney, AM Gill) (CSIRO Division of Forestry: Canberra, ACT)
- Viegas, D. X., Viegas, M. T. S. P., Ferreira, A. D. (1992). Moisture content of fine forest fuels and fire occurrence in central Portugal. *Int. J. Wildland Fire* 2, 69–86.
- Viney, N. R. (1991). A review of fine fuel moisture modelling. *Int. J. Wildland Fire* 1, 215-234.
- Wehner, M. F., Arnold, J. R., Knutson, T., Kunkel, K. E., and LeGrande, A. N. (2017). "Droughts, floods, and wildfires," in Climate science special report: Fourth national climate assessment, volume I [wuebbles. Editors D. W. Fahey, K. A. Hibbard, D. J. Dokken, B.

- C. Stewart, and T. K. Maycock (Washington, DC, USA: U.S. Global Change Research Program), 231–256.
- Wolfensberger, D., Gabella, M., Boscacci, M., Germann, U., Berne, A. (2021). RainForest: a random forest algorithm for quantitative precipitation estimation over Switzerland. *Atmos Meas Tech* 14, 3169-3193.
- Wood, S. N., Scheipl, F., Faraway, J. J. (2013). Straightforward intermediate rank tensor product smoothing in mixed models. *Stat Comput* 23, 341-360.
- Yan, X. F., Zhao, Y. J., Cheng, Q., Zheng, X. L., Zhao, Y. D. (2018). Determining forest duff water content using a low-cost standing wave ratio sensor. *Sensors* 18, 647.
- Yu, H., Shu, L., Yang, G., Deng, J. (2021). Comparison of vapour-exchange methods for predicting hourly twig fuel moisture contents of larch and birch stands in the Daxinganling Region, China. *Int. J. Wildland Fire* 30, 462-466.
- Yuan, J., Wu, Y., Jing, W., Liu, J., Du, M., Wang, Y., Liu, M. (2021). Non-linear correlation between daily new cases of COVID-19 and meteorological factors in 127 countries. *Environ. Res.* 193, 110521.
- Zhang, G., and Lu, Y. (2012). Bias-corrected random forests in regression. *J. Appl. Stat.* 39, 151-160.
- Zhang, J. L., Cui, X. Y., Wei, R., Huang, Y., Di, X. Y. (2017). Evaluating the applicability of predicting dead fine fuel moisture based on the hourly Fine Fuel Moisture Code in the south-eastern Great Xing'an Mountains of China. *Int. J. Wildland Fire* 26, 167-175.
- Zhang, R., Hu, H., Qu, Z., Hu, T. (2021). Diurnal variation models for fine fuel moisture content in boreal forests in China. *J. For. Res.* 32, 1177-1187.
- Zhang, Y., and Sun, P. (2020). Study on the diurnal dynamic changes and prediction models of the moisture contents of two litters. *Forests* 11, 95.