



基于粒子群算法和BP神经网络的多因素林火等级预测模型

王磊, 郝若颖, 刘玮, 温作民

引用本文:

王磊, 郝若颖, 刘玮, 等. 基于粒子群算法和BP神经网络的多因素林火等级预测模型[J]. 林业工程学报, 2019, 4(3): 137-144.

在线阅读 View online: <https://doi.org/10.13360/j.issn.2096-1359.2019.03.021>

您可能感兴趣的其他文章

Articles you may be interested in

基于气象和时空因子的森林火险等级预测

Prediction of forest fire danger rating based on meteorological and space-time factors

林业工程学报. 2018, 3(3): 102-110 <https://doi.org/10.13360/j.issn.2096-1359.2018.03.017>

基于气象因子深度学习的森林火灾预测方法

Research on forest fire prediction method based on deep learning

林业工程学报. 2019, 4(3): 132-136 <https://doi.org/10.13360/j.issn.2096-1359.2019.03.020>

基于无线传感网的森林火灾FWI系统分析

Study on forest fire FWI system based on wireless sensor networks

林业工程学报. 2015, 29(1): 105-109 <https://doi.org/10.13360/j.issn.1000-8101.2015.01.030>

基于Gompit回归模型的大兴安岭林火预测模型及驱动因子研究

Study on prediction model and driving factors of forest fire in Da Hinggan Mountains using Gompit regression method

林业工程学报. 2019, 4(4): 135-142 <https://doi.org/10.13360/j.issn.2096-1359.2019.04.020>

便携式小区域森林火险天气等级测报仪的研制

Development of portable small area forest fire risk forecasting instrument

林业工程学报. 2015, 29(2): 115-119 <https://doi.org/10.13360/j.issn.1000-8101.2015.02.028>

基于粒子群算法和 BP 神经网络的多因素 林火等级预测模型

王磊, 郝若颖, 刘玮, 温作民

(南京林业大学经济管理学院, 南京 210037)

摘要:针对现有小尺度林火预测模型预测结果有效性、可扩展性等方面的不足,通过考虑多种火险因素,构建 BP 神经网络预测模型以提高预测精度,在此基础上借助粒子群算法加快 BP 神经网络收敛速度,进而提出一种混成的多因素森林火险等级预测模型 particle swarm optimization based back-propagation neural network (PSO-BP)。所构建的预测模型,能够同时考虑气候因素(日最高气温、日平均气温、24 h 降水量、连旱天数、日照时数、日平均相对湿度、日平均风速)、地形地貌因素(海拔、坡度、坡向、土壤含水量)、可燃物因素(植被类型、可燃物含水率、地被物载量)、人为因素(人口密度、距人类活动区域的距离)16 个变量。基于南京林业大学下蜀林场森林防火实验站传感器网络所采集的实际数据及现场测量数据,通过一组试验验证提出模型的有效性。结果表明:基于训练数据集及检验样本所构建的模型能够开展有效的火险等级预测;模型的计算复杂度较单独使用 BP 神经网络模型明显下降。

关键词:森林火险等级;林火因子;BP 神经网络;粒子群算法;多因素森林火险等级预测模型

中图分类号:TP315

文献标志码:A

文章编号:2096-1359(2019)03-0137-08

A multi-factor forest fire risk rating prediction model based on particle swarm optimization algorithm and back-propagation neural network

WANG Lei, HAO Ruoying, LIU Wei, WEN Zuomin

(College of Economics and Management, Nanjing Forestry University, Nanjing 210037, China)

Abstract: Forest fire destroys woodlands and forest resources, and emits massively greenhouse gases. It has been recognized as a series disaster for the sustainability of forests. Prediction of the risk rating for forest fire early warning has been a hot topic and widely investigated in recent years. To prevent forest fire and mitigate loss, an effective forest fire risk rating prediction desires for a real-time and region-related result. The relevant existing studies have proposed some forest fire risk rating prediction approaches. Nevertheless, the exiting approaches still cannot meet the previously mentioned forest fire prevention application requirements. Firstly, different models fit well for different regions (concerning climates and fuel types, etc.). Seldom approaches can scale for different regions. Secondly, the prediction results are split by days. To perform short-term multi-factor forest fire risk rating prediction and guarantee the accuracy and scalability of prediction model, we investigated the machine learning methodologies in this paper and proposed a particle swarm optimization (PSO)-based back-propagation (PSO-BP) neural network model. Specially, we incorporated the following 16 forest fire dangerous factors based on the existing reports in PSO-BP, i.e., meteorological factors (e.g., daily maximum air temperature, daily average air temperature, 24-hour rainfall, the number of dry days, hours of sunshine, daily average relative humidity, and daily average wind velocity), terrain factors (e.g., altitude, gradient, exposure, and soil water content), combustible factors (e.g., types of vegetation, fuel moisture content, and content of forest litter), and human factor (e.g., density of population, distance to the human activity sites). As for the PSO-BP model, we firstly used BP neural network as the foundation technology to construct the prediction model. To guarantee the performance in terms of computational complexity of the prediction model, we then adopted PSO algorithm to speed up the convergence speed of BP neural network training process. We also presented a case study based on the data collected via the sensor-network-based forest fire prevention experimental station, Xiashu Forest, Nanjing Forestry University, China. The experimental results suggested that: 1) The PSO-BP prediction model constructed based on the training data set can effectively predict the forest fire danger ratings in the near-future for the study re-

收稿日期:2018-05-25

修回日期:2018-08-28

基金项目:教育部人文社会科学研究青年基金项目(18YJJCZH170);国家自然科学基金重点项目(18AGL017);南京林业大学青年科技创新基金(CX2016031);南京林业大学大学生创新训练计划(201810298016Z;2018NFUSPITP267;2018NFUSPITP293)。

作者简介:王磊,男,博士,副教授,研究方向为服务计算、大数据计算、森林防火。E-mail: leiwangchn@163.com

gion; and 2) The efficiency in terms of computational complexity for training the prediction model using the PSO-BP is better than that of those models using solely BP neural network.

Keywords: forest fire danger rating; forest fire factor; back-propagation neural network; particle swarm optimization; particle swarm optimization based back-propagation (PSO-BP) neural network

森林对于生态环境以及人类生活、生产意义重大。目前世界森林面积达 40 亿 hm^2 , 受自然或人为因素的影响, 每年全球发生森林火灾次数高达几十万次, 受灾面积达几百万公顷。20 世纪 80 年代以来, 随着全球气候持续变暖, 极端天气事件增多, 每年森林火灾的发生次数呈上升趋势。森林火灾烧毁森林植被, 破坏森林资源, 在短期内释放大量的温室气体, 对环境造成较大破坏, 严重影响森林可持续发展^[1-2]。森林火险等级预报是降低森林火灾发生的重要技术手段, 具有重要的应用价值。

森林火灾的发生受到多方面因素的影响, 不同区域, 由于受气候、地形、植被类型、人为因素等不同影响, 火灾发生风险变化较大^[3-4]。目前相关研究主要基于气象、遥感等数据, 提供大范围、中长期森林火险等级预测, 如以天为单位或以月为单位的火险等级预测, 而对于特定区域的森林火险短期预测研究尚少。以往研究中所提出的预测模型, 因选取的火险因子不一, 不同的模型有其固有的适用范围, 较难精确、实时地预测火险等级^[5-7]。近年来, 随着人工智能技术的发展, 基于传感器网络的实时数据采集系统, 能够采用智能化方法构建多因素森林火险等级预测模型, 开展准确、实时的小尺度预测, 对于有效保护林火防控重点区域的森林资源、节约林火防控经费具有重要意义^[8-13]。笔者综合考虑气候因素、地形地貌因素、人为因素, 3 类共 16 个林火因子, 通过集成粒子群算法和 BP 神经网络模型, 提出一种混成的多因素森林火险等级预测模型 particle swarm optimization based back-propagation (PSO-BP) neural network, 并以试验验证本方法的有效性。

1 研究区概况

1.1 环境特征

选取下蜀林场作为研究区域, 林场位于江苏省句容市 ($31^{\circ}59'N$, $119^{\circ}14'E$)。林场地形起伏不大, 较为平缓, 属低山丘陵区, 区内武岐山最高峰海拔 377.8 m, 空青山 322.6 m; 丘陵区海拔约 100 m; 谷地海拔约 75 m, 相对高差 302.8 m。研究区土壤以黄棕壤和山地黄棕壤为主, 腐殖质层 10~20 cm, 土壤表层腐殖质含量 (质量分数) 约为 2.5%。植被为常绿落叶混交林。林场内部和周围场地有部分居住区。

1.2 气候条件

研究区属北亚热带季风气候, 干湿寒暑四季分明, 光照充足, 水热资源丰富。年均气温为 15.2°C , 年均日照 2 157 h, 日照百分率为 49%。年均降水量 1 055.6 mm, 降水量年际变化较大, 较高年份达 1 408.3 mm (1962 年), 较少为 425.2 mm (1978 年), 降水集中在夏季。年均空气相对湿度 79%。

1.3 防火实验站

下蜀林场建有森林防火实验站, 位于厂部后方开阔地带 ($32^{\circ}06'N$, $118^{\circ}79'E$)。实验站设有一个通量塔 (高 50 m) 采集常规气象数据 (环境温度、大气压力、空气湿度、风向、风速等) 以及其他森林环境参数 (如 CO_2 绝对浓度、水汽密度等) (碳通量系统, 美国, IRGASON)、森林凋落物含量检测传感器设备 (SR50A 声波深度传感器, 美国, CR200X)、预埋地下的土壤含水量等传感器 (土壤温度水分速测仪, 美国, T-350)、树木胸径测量传感器等。另外, 实验站还设有光学、红外双镜头林火监控设备 (红外热成像云台摄像机, 中国深圳, PVP-HQ2-775-TM-300) (安装于通量塔顶, 监控距离为 10 km)。以上设备所采集的数据全部存储于塔底信息采集服务器 (存放在集装箱中)。作为本研究的基础平台, 实验站通过传感器网络采集并存储实时数据。以 2018 年 8 月 2 日 20:37 实时数据为例, 本研究预测模型相关变量的传感器采集数据主要包括: 气温 29.06°C 、风速 5.03 m/s 、相对湿度 79.32%、降雨量 0.00 mm、森林凋落物厚度 16.20 cm、土壤含水率 0.19% 等。这些参数被用于训练模型及火险等级预测。

2 基于 PSO-BP 的火险等级预测模型

BP 神经网络作为目前运用最广泛的神经网络模型之一, 具有结构简单、较强的非线性映射能力、良好的自学习能力、可高精度逼近任意函数等优点^[14-17]。BP 神经网络算法采用梯度下降算法, 从训练数据中开展学习, 以输出误差平方最小为目标, 采用误差反向传播, 以训练网络节点权值和偏置值^[18]。当 BP 神经网络的结构 (层数、每层节点个数) 较复杂时, 这一算法会表现出学习速度慢、易陷入局部极小值、稳定性差等不足^[19-20]。

另一个广泛使用的机器学习算法为粒子群优

化算法 (particle swarm optimization, PSO), 这类算法通过群体智能开展学习, 具有较好的全局寻优能力。笔者提出基于粒子群优化的 BP 神经网络算法 (PSO-based BP neural network, PSO-BP), 将粒子群优化算法引入 BP 神经网络模型中, 以加快传统 BP 神经网络算法的收敛速度。具体步骤: 将 BP 神经网络中各层的连接权值和阈值作为粒子进行编码, 用粒子群位置向量代替, 通过算法不断迭代, 得到最优种群粒子, 解码转化成最优解, 进而作为 BP 神经网络全局最优的连接权值和阈值, 从而建立粒子群优化 BP 神经网络算法模型。以基于粒子群优化算法改进的 BP 神经网络建立森林火险短期预测模型, 相较于运用标准 BP 神经网络建立的模型而言, PSO-BP 神经网络模型较好地解决了标准 BP 神经网络模型固有的易陷入局部极小值、稳定性差、训练时间长等不足。将实际数据输入模型后, 可以更快、更准确地输出预测结果 (具体的火险等级)。

2.1 变量选择

基于综合性、全面性和可获得性原则, 所选取的风险因子既能综合、全面反映森林火灾发生的相关情况, 又能在研究区域中搜集到相关风险因子的量化数据。参考已有的工作^[1-5, 11], 本研究选取日最高气温、日平均气温、24 h 降水量等 16 个林火相关变量构建 PSO-BP 模型 (表 1)。由表 1 可以看出, 16 个变量分为气候因素、地形地貌因素、可燃物因素和人为因素 4 个维度, 全面、综合地描述导致森林火灾发生的各种因素, 可以有效地预测林火的发生。

表 1 模型变量

Table 1 Variables used in predicted model

变量类型	变量代码	变量名称
气候因素	x_1	日最高气温
	x_2	日平均气温
	x_3	24 h 降水量
	x_4	连旱天数
	x_5	日照时数
	x_6	日平均相对湿度
	x_7	日平均风速
地形地貌因素	x_8	海拔
	x_9	坡度
	x_{10}	坡向
	x_{11}	土壤含水量
可燃物因素	x_{12}	植被类型
	x_{13}	可燃物含水率
	x_{14}	地被物载量
人为因素	x_{15}	人口密度
	x_{16}	距人类活动区域的距离

为提高预测模型的可扩展性 (可应用于不同气候条件下的区域), 本研究所选取的部分变量, 对于某个特定区域而言可能存在某种相关性, 如土壤含水量和可燃物含水率; 日最高气温和日平均气温; 连旱天数和 24 h 降水量等。但这些变量及其之间的相关性对于不同区域而言可能存在较大差异。如: 土壤含水量和可燃物含水率, 当降雨发生后, 因地质条件不同, 不同地区可能出现土壤含水量较为接近, 而可燃物含水率存在较大差异的情况。有关这些变量间的相关性与区域地形、地质条件、气候等因素之间关系等方面的内容不在本研究范围内。

2.2 数据来源及处理

本研究数据来自研究区森林防火实验站传感器所采集的数据以及现场测量结果, 数据采集时间为 2017 年 1—12 月。为分析 PSO-BP 模型的可用性及其性能, 从采集数据中随机选取 8 760 组 (每组包括 16 个变量值) 作为数据集。对于每组数据, 结合其实时森林火险气象等级预报结果, 并邀请林火预防专家对火险等级 (中华人民共和国气象行业标准 QX/T 77—2007《森林火险气象等级》) 进行人工校对, 分为 5 个不同等级。随机选取标注火险等级的 256 组数据作为训练集, 1 752 组数据作为检验样本, 用于训练预测模型。其他 1 752 组数据作为测试集, 用于测试模型的有效性。

不同的火险因子变量, 其参数的值域不同。此外, 有些参数值越大, 火灾风险越大; 有些参数值越小, 火灾风险越大。另一方面, 本研究所用的 BP 神经网络模型的隐含层采用 Sigmoid 函数作为激活函数, 该函数的值域为 $[0, 1]$ 。针对以上问题, 本研究首先对数据进行归一化处理。即将各个参数的值映射到 $[0, 1]$ 区间, 且保证其值越大, 火灾风险越大。

采用最小最大变换法对不同参数进行归一化处理^[21]。对于值越大火灾风险越大的指标 (即 $x_1, x_2, x_4, x_5, x_7, x_9, x_{14}, x_{15}$), 采用以下公式进行归一化:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

对于值越大火灾风险越小的指标 (即 $x_3, x_6, x_8, x_{11}, x_{13}, x_{16}$), 其归一化方法为:

$$y = \frac{x_{\max} - x}{x_{\max} - x_{\min}} \quad (2)$$

式中: y 为归一化处理后的数值; x 为某一参数的原始值; x_{\max} 为该参数取值集合中的最大值; x_{\min} 为该

参数取值集合中的最小值。

对于所选取的 16 个变量,如果是定量指标,采用公式(1)或(2)计算;如果是定性指标,则借鉴层次分析法(Saaty^[22]的 1~9 评价方法),首先定性描述其火灾风险,然后将其转化为定量值。定性指标变量值的处理方法如表 2 所示。根据下蜀林场的植被分布特征,按火灾发生风险由大到小顺序,将植被类型分为 4 类:杂草、灌木林、混交林、人工林。对于坡向而言,由于阳坡光线好,地被物更易干燥,加大火灾风险;而迎风会带来水汽,降低火灾风险。因此,本研究按火灾发生风险大小顺序,将坡向分为阳坡(背风)、阳坡(迎风)、阴坡(背风)、阴坡(迎风)4 种坡向。根据火灾发生风险的大小将以上 4 种植被类型和坡向定性为:火灾发生风险极大、火灾发生风险较大、火灾发生风险一般、火灾发

表 2 非定量的变量值处理方法

植被类型	坡向	定性描述	定量值
杂草	阳坡(背风)	火灾发生风险极大	4
灌木林	阳坡(迎风)	火灾发生风险较大	3
混交林	阴坡(背风)	火灾发生风险一般	2
人工林	阴坡(迎风)	火灾发生风险较小	1

生风险较小。上述 4 种定性对应的定量值分别为 4, 3, 2, 1。得到定量值后,使用公式(1)将相应的变量值归一化。

2.3 PSO-BP 模型构建过程

参考文献[18, 20],将粒子群优化算法引入 BP 神经网络模型。粒子群优化算法是计算机领域的一种群体智能优化算法,该算法基于鸟群捕食现象提出,通过搜寻当前离食物最近的鸟的周围区域,逐渐逼近最优解。在算法中,用适应度值、速度和位置 3 个指标表示粒子(鸟)的运动特征。粒子群优化算法具有较好的全局寻优能力。

本研究将 BP 神经网络中各层的连接权值和阈值建模为粒子进行编码,用粒子群位置向量代替,通过算法不断迭代,得到最优种群粒子。在此基础上,解码转化成最优解,作为 BP 神经网络全局最优的连接权值和阈值,建立粒子群优化 BP 神经网络算法模型。

PSO-BP 神经网络模型构建过程如图 1 所示。首先构建一个 4 层 BP 神经网络(包括 2 个隐层)。基于神经网络,初始化粒子群的初始位置值和速度值。每个粒子对应 BP 神经网络中的一个隐层节点,每个粒子群代表一组 BP 神经网络中连接权值

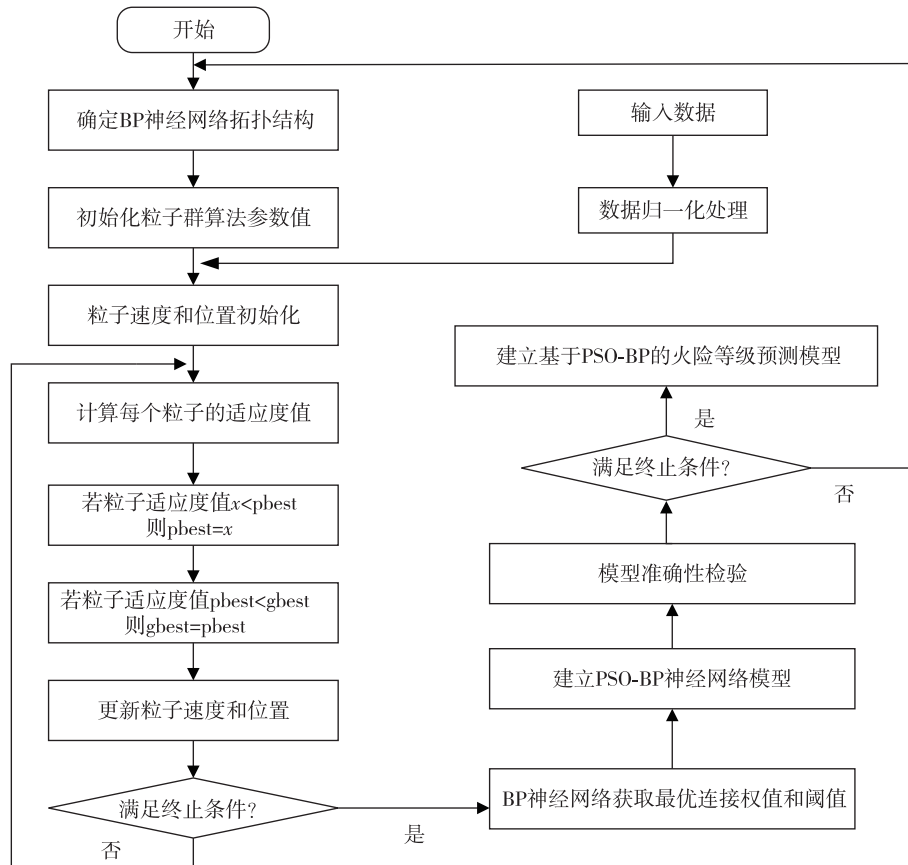


图 1 粒子群算法优化 BP 神经网络模型建立流程图

Fig. 1 Schematic view of algorithm for training a PSO-BP model

和阈值,解码后得到 BP 神经网络模型。

为了构建神经网络模型,通过更新粒子群的速度和位置逼近最优解。其中,粒子适应度值 F 的计算公式如下:

$$F = \sum_{i=1}^N \text{abs}(y_i - t_i) \quad (3)$$

式中: y_i 代表样本 i 的观测值; t_i 代表样本 i 的预测值; N 表示样本数量; abs 为取绝对值函数。

在此基础上不断更新粒子的速度和位置,直到迭代误差达到设定的精度 e 或迭代次数达到预设的最大迭代次数 N_{num} 。当迭代停止时,适应度值最小的粒子所对应的位置即为最优解。将粒子群优

化算法求得的最优种群粒子解码,得到 BP 神经网络最优连接权值和阈值,建立模型。

3 模型验证

3.1 PSO-BP 预测模型及其有效训练阈值

根据 2.2 部分所述,将数据分为训练数据集、检验样本和测试数据集。训练数据集中的前 25 组数据如表 3 所示(每一列为一组数据)。为构建训练数据集,通过征求林火管理专家意见,对每一列(一组完整的输入数据 $x_1 \sim x_{16}$)标注相应的火险等级(因变量 y)。在训练模型的过程中,首先根据 2.2 部分所述的预处理方法对输入数据进行归一化处理。

表 3 PSO-BP 模型训练数据集示例
Table 3 Demonstration of training data set for PSO-BP

变量	训练数据																								
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
x_1	27	27	27	27	33	33	33	33	22	22	22	22	17	17	17	17	11	11	11	11	6	6	6	6	27
x_2	22	18	17	16	25	22	23	20	16	15	16	17	11	10	11	12	6	7	6	6	2	1	0	1	18
x_3	10	3	5	17	23	10	9	13	1	15	8	28	9	2	1	30	15	8	1	7	18	2	7	16	9
x_4	5	8	12	17	3	1	8	14	7	4	9	10	1	4	9	4	9	15	4	6	10	1	11	9	5
x_5	18	5	14	10	15	12	8	10	6	7	17	4	9	7	14	18	5	14	10	15	12	8	10	6	7
x_6	42	30	28	35	68	60	29	32	25	51	38	44	54	39	24	73	38	23	24	32	30	31	25	31	36
x_7	5	3	1	8	10	3	7	6	4	1	11	8	4	5	2	5	3	1	8	10	3	7	6	4	1
x_8	350	50	120	280	160	220	100	80	300	90	150	30	95	140	70	450	70	120	380	160	220	100	80	300	90
x_9	20	15	8	30	45	15	30	50	12	25	18	55	21	13	19	20	15	8	30	45	15	30	50	12	25
x_{10}	2	3	1	4	2	1	4	3	1	4	2	2	3	4	1	2	3	1	4	2	1	4	3	1	4
x_{11}	14	10	9	12	19	17	9	8	7	16	9	14	16	13	6	20	10	6	6	7	7	7	6	7	8
x_{12}	4	4	1	2	1	1	3	4	1	1	1	3	4	4	3	8	9	3	1	3	3	10	9	8	2
x_{13}	36	28	26	35	68	60	29	32	25	51	35	40	50	35	22	60	35	23	20	32	30	31	25	31	36
x_{14}	10	20	11	18	8	5	6	14	16	12	4	9	8	23	10	10	20	11	18	8	5	6	14	16	12
x_{15}	10	20	11	18	8	5	6	14	16	12	4	9	8	23	10	10	20	11	18	8	5	6	14	16	12
x_{16}	10	20	11	18	8	5	6	14	16	12	4	9	8	23	10	10	20	11	18	8	5	6	14	16	12
因变量 y	3	4	3	2	5	5	3	2	1	4	3	3	4	2	1	4	4	2	1	3	2	3	1	2	3

通过训练数据集,构建 PSO-BP 预测模型,并进行预测。为保证预测模型的有效性,在构建 PSO-BP 模型的过程中,本研究参考文献[23]中的方法,逐步增大隐含层节点个数,首先通过训练集数据训练模型,待训练过程收敛后,根据检验样本测试预测误差,当经检验样本验证预测误差小于某一停止训练阈值(δ)时停止训练过程,否则重新开展一轮训练。通过以上方法逐步提高所构建预测模型的精度。最终确定隐含层节点个数为 23,停止训练阈值 $\delta=0.1500$ 。

3.2 火险等级预测结果分析

采用 Matlab 软件,根据 3.1 部分所述方法,通过训练数据集和检验样本,确定 BP 神经网络模型参数,建立 PSO-BP 神经网络模型。在此基础上,

运用所构建的 PSO-BP 神经网络模型进行火险等级预测。输入如表 4 所示的测试数据(从测试数据集随机选取)后,15 组测试数据在模型中计算后得到火险等级(表 5)。由表 5 可见,火险等级实际预测结果与测试数据集中标注结果相比较,只有第 8 组数据相差一个等级,表明 PSO-BP 模型具有有效性。

参考文献[5]中方法,采用 SPSS V.18.0 软件,利用多因素 Logistic 回归分析方法,设定 $x_1 \sim x_{16}$ 为自变量, y 为因变量,构建拟合模型,使用逐步回归方法,剔除不显著变量,进而分析森林火灾的风险因素。结果表明:日最高气温(x_1),日平均气温(x_2),24 h 降水量(x_3),日照时数(x_5),日平均相对湿度(x_6),可燃物含水率(x_{13})6 个因素对森林

火灾发生具有较大影响,结果与文献[5]一致。这一结果表明,空气湿度、可燃物含水率与森林火灾发生具有相关性。在相同的地形、地貌、人为因素等非气象因素条件下,空气、地被物越干燥,火灾风

险越大。气候因素的变化会影响森林空气、地被物的相对湿度^[10],因此,在森林火险预测中,需关注气温、降水量、日照时数等因素。

表4 PSO-BP 测试数据及预测结果

Table 4 Tested data and predicted results of PSO-BP model

变量代码	测试数据														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
x_1	33	22	17	11	6	19	28	28	37	38	6	18	22	26	21
x_2	24	18	11	5	1	8	18	24	32	33	2	12	18	17	16
x_3	12	3	5	2	11	3	0	0	12	3	6	3	1	5	22
x_4	4	8	10	3	5	5	4	2	0	3	0	5	9	11	0
x_5	17	4	9	7	14	8	12	12	13	13	10	13	6	8	6
x_6	41	31	24	26	39	25	12	18	35	20	38	16	28	26	34
x_7	11	8	4	5	2	4	1	3	4	3	4	2	8	1	4
x_8	150	30	95	140	70	97	90	130	133	74	126	88	90	120	250
x_9	18	55	21	13	19	19	23	16	24	46	24	24	53	9	12
x_{10}	2	2	3	4	1	3	4	4	2	3	2	2	2	1	1
x_{11}	9	8	6	6	10	6	4	8	13	7	9	2	8	9	7
x_{12}	1	3	1	1	2	1	1	2	3	3	3	2	3	2	1
x_{13}	41	31	24	26	39	26	13	26	53	25	26	24	25	24	43
x_{14}	4	9	8	23	10	22	28	29	13	12	22	23	11	14	15
x_{15}	4	9	8	23	10	14	12	8	2	3	3	4	9	9	14
x_{16}	4	9	8	23	10	12	4	16	13	12	19	5	8	7	17

表5 火险等级预测结果与标注结果比较

Table 5 Comparison of predicted results and labeled results in the tested data set

测试数据组	预测火险等级	标注火险等级	测试数据组	预测火险等级	标注火险等级
1	4	4	9	1	1
2	2	2	10	2	2
3	1	1	11	1	1
4	1	1	12	3	3
5	2	2	13	3	3
6	2	2	14	3	3
7	5	5	15	1	1
8	1	2			

3.3 性能比较

为验证 PSO-BP 模型有效性并分析其性能,首先随机生成神经网络连接权值和阈值,通过训练集数据和检验样本分别训练经过粒子群优化的 BP 神经网络(PSO-BP)与基本的 BP 神经网络模型,其中,将模型训练过程中的最大迭代次数 N_{max} 设为 50。其次,基于测试集数据使用经训练的 PSO-BP 模型、BP 神经网络模型分别进行预测。对于 BP 神经网络和 PSO-BP,分别重复执行 10 次训练模型过程,并基于测试数据集开展预测。在此基础上比较不同方法在训练模型过程中的时间复杂度和所构建模型的预测结果准确率。采用均方根误差计算每个模型的预测误差,模型的预测误差

(P_{RMSE})为:

$$P_{\text{RMSE}} = \sqrt{\frac{\sum_i (p_i - l_i)^2}{N}} \quad (4)$$

式中: p_i 为第 i 个样本的预测等级; l_i 为第 i 个预测样本所采用的测试数据中标注的火险等级; N 为预测样本数。

不同方法的比较结果见表 6。由表 6 可见,与 BP 神经网络模型相比,PSO-BP 模型迭代次数减少,训练时间减短。PSO-BP 模型在 10 次运行中,预测结果准确率略高于 BP 模型,高于 3.2 部分所述多因素 Logistic 回归模型预测结果准确率(Logistic 回归模型预测误差为 0.324 75)。PSO-BP 模型预测结果准确率的波动幅度低于 BP 模

型,体现出更高的鲁棒性。预测模型10次预测结果的预测误差均低于停止训练阈值(δ),表明所构建的预测模型具有较好的可扩展性。这是因为未经过粒子群算法优化的神经网络模型在训练过程中会进入误差曲面平坦区域,导致收敛速度变慢,甚至出现陷入局部极小值而导致训练失败的情况。通过使用检验样本,可以提高所构建预测模型的可用性。通过引入粒子群优化算法,可以加快在训练模型过程中参数向最优解逼近的速度,从而提高模型的有效性。由此可见,PSO-BP模型更具实用性。

表6 两种模型10次运行结果比较
Table 6 Comparison of 10 runs of BP neural network and PSO-BP models

模型	执行标号	迭代次数	误差/ $\times 10^{-1}$	时间/s
BP 神经网络模型	1	269	0.148 76	14.013 6
	2	271	0.147 03	14.128 0
	3	243	0.149 78	12.682 4
	4	197	0.139 67	10.280 0
	5	220	0.146 93	11.476 0
	6	262	0.143 27	13.680 8
	7	194	0.145 60	10.144 8
	8	222	0.148 70	11.559 2
	9	220	0.139 72	11.476 0
	10	230	0.146 41	12.016 8
PSO-BP 模型	1	243	0.132 17	12.682 4
	2	215	0.133 45	11.216 0
	3	186	0.124 65	9.687 2
	4	175	0.132 84	9.136 0
	5	137	0.135 16	7.160 0
	6	207	0.127 65	10.789 6
	7	162	0.134 00	8.480 8
	8	157	0.129 93	8.200 0
	9	179	0.129 85	9.344 0
	10	205	0.133 18	10.685 6

4 结 论

以南京林业大学下蜀林场为研究区域,结合下蜀林场的具体情况,确定气候因素、地形地貌因素、可燃物因素、人为因素中16个林火发生相关因子作为预测参数。在此基础上,运用基于粒子群优化算法改进的BP神经网络建立森林火险短期预测PSO-BP模型,PSO-BP模型较好地弥补了BP神经网络模型易陷入局部极小值、稳定性差、训练时长不定等问题。PSO-BP模型可更快、更准确地输出结果。根据PSO-BP模型算法,运用Matlab软件,建立了研究区火险等级预测原型系统。经测试,原型系统可较好地分析处理16个火险因素的数据,预测出相对应的火险等级,可为研究区的防火管理

工作提供依据,该模型也可以向具有相关数据条件的林场推广。

本研究建立的研究区火险等级预测原型系统是一个面向林班的小尺度系统。在森林火险预测中,可以提高预测精度,且随着数据的实时更新,能够进行实时预测。在今后的研究工作中将引入更多森林火险相关因子、更为精确地预测模型,进一步提高小尺度林火等级预测性能。

参考文献(References):

- [1] 郭江. 森林防火信息服务平台的设计与实现[D]. 北京: 北京林业大学, 2015.
GUO J. Design and implementation of information service platform for forest fire prevention [D]. Beijing: Beijing Forestry University, 2015.
- [2] TIAN X R, ZHAO F J, SHU L F, et al. Distribution characteristics and the influence factors of forest fires in China[J]. Forest Ecology and Management, 2013, 310: 460-467. DOI: 10.1016/j.foreco.2013.08.025.
- [3] POURTAGHI Z S, POURGHASEMI H R, ARETANO R, et al. Investigation of general indicators influencing on forest fire and its susceptibility modeling using different data mining techniques[J]. Ecological Indicators, 2016, 64: 72-84. DOI: 10.1016/j.ecolind.2015.12.030.
- [4] 梁慧玲, 郭福涛, 苏漳文, 等. 基于随机森林算法的福建省林火发生主要气象因子分析[J]. 火灾科学, 2015, 24(4): 191-200. DOI: 10.3969/j.issn.1004-5309.2015.04.02.
LIANG H L, GUO F T, SU Z W, et al. Analysis of meteorological factors on forest fire occurrence of Fujian based on random forest algorithm[J]. Fire Safety Science, 2015, 24(4): 191-200.
- [5] 苏漳文, 刘爱琴, 郭福涛, 等. 基于气象因子的福建省森林火险预测模型[J]. 森林与环境学报, 2015, 35(4): 370-375. DOI: 10.13324/j.cnki.jfcf.2015.04.013.
SU Z W, LIU A Q, GUO F T, et al. Model to predict forest fire occurrence in Fujian Province based on meteorological factors[J]. Journal of Forest and Environment, 2015, 35(4): 370-375.
- [6] 王伟. 基于森林火险指数的森林火险区划研究[J]. 林业资源管理, 2015(4): 79-83. DOI: 10.13466/j.cnki.lyzygl.2015.04.014.
WANG W. Study on forest fire risk zone based on forest fire risk index[J]. Forest Resources Management, 2015(4): 79-83.
- [7] 曹姗姗. 小尺度森林火险等级预测模型研究[D]. 北京: 中国林业科学研究院, 2014.
CAO S S. Small-scale forest fire danger rating prediction [D]. Beijing: Chinese Academy of Forestry, 2014.
- [8] SAKR G E, ELHAJJ I H, MITRI G. Efficient forest fire occurrence prediction for developing countries using two weather parameters[J]. Engineering Applications of Artificial Intelligence, 2011, 24(5): 888-894. DOI: 10.1016/j.engappai.2011.02.017.
- [9] 张运林, 张恒, 金森. 季节和降雨对细小可燃物含水率预测模型精度的影响[J]. 中南林业科技大学学报, 2015, 35(8): 5-12. DOI: 10.14067/j.cnki.1673-923x.2015.08.002.
ZHANG Y L, ZHANG H, JIN S. Effects of season change and

- rainfall on forecast model accuracy of predicting fire fuels in forests in Pangu Forest Farm[J]. *Journal of Central South University of Forestry & Technology*, 2015, 35(8): 5-12.
- [10] 何泽能, 唐晓萍, 谭炳全. 森林火险气象条件及等级预报初探——以重庆市沙坪坝区为例[J]. *灾害学*, 2013, 28(2): 46-50. DOI: 10.3969/j.issn.1000-811X.2013.02.010
- HE Z N, TANG X P, TAN B Q. Study on meteorological condition and forecast of forest fire danger grading: a case study in Shapingba district of Chongqing[J]. *Journal of Catastrophology*, 2013, 28(2): 46-50.
- [11] 王磊, 童振超, 陈书林, 等. 森林防火智能化综合管理系统研究[J]. *林业经济*, 2014, 36(12): 113-116. DOI: 10.13843/j.cnki.lyjj.2014.12.024.
- WANG L, TONG Z C, CHEN S L, et al. Study on the intelligent and integrated management information system for forest fire[J]. *Forestry Economics*, 2014, 36(12): 113-116.
- [12] 于森. 北京房山林火发生预测模型及小班火险等级区划研究[D]. 北京: 北京林业大学, 2016.
- YU M. The research of forest fire prediction model in Fangshan District, Beijing and subplot fire danger rating division[D]. Beijing: Beijing Forestry University, 2016.
- [13] 吴琳, 张智光. 我国“互联网+林业”的技术-产业-运作三维发展路径[J]. *世界林业研究*, 2018, 31(4): 1-7. DOI: 10.13348/j.cnki.sjlyyj.2018.0063.y.
- WU L, ZHANG Z G. Research on three-dimensional technology-industry-operation development path of “internet + forestry” in China[J]. *World Forestry Research*, 2018, 31(4): 1-7.
- [14] 张月琴, 刘翔, 孙先洋. 一种改进的BP神经网络算法与应用[J]. *计算机技术与发展*, 2012, 22(8): 163-166. DOI: 10.3969/j.issn.1673-629X.2012.08.042.
- ZHANG Y Q, LIU X, SUN X Y. An improved algorithm of BP neural network and its application[J]. *Computer Technology and Development*, 2012, 22(8): 163-166.
- [15] 焦斌, 叶明星. BP神经网络隐层单元数确定方法[J]. *上海电机学院学报*, 2013, 16(3): 113-116, 124. DOI: 10.3969/j.issn.2095-0020.2013.03.002.
- JIAO B, YE M X. Determination of hidden unit number in a BP neural network[J]. *Journal of Shanghai Dianji University*, 2013, 16(3): 113-116, 124.
- [16] 郝娟. 基于粒子群算法优化BP神经网络的SRM磁链模型[J]. *机械制造与自动化*, 2018, 47(2): 130-132. DOI: 10.19344/j.cnki.issn1671-5276.2018.02.035.
- HAO J. SRM flux linkage model of optimizing BP neural network based on PSO algorithm[J]. *Machine Building & Automation*, 2018, 47(2): 130-132.
- [17] YU F, XU X Z. A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network[J]. *Applied Energy*, 2014, 134: 102-113. DOI: 10.1016/j.apenergy.2014.07.104.
- [18] 张德慧, 张德育, 刘清云, 等. 基于粒子群算法的BP神经网络优化技术[J]. *计算机工程与设计*, 2015, 36(5): 1321-1326. DOI: 10.16208/j.issn1000-7024.2015.05.040.
- ZHANG D H, ZHANG D Y, LIU Q Y, et al. BP neural network optimized by improved PSO[J]. *Computer Engineering and Design*, 2015, 36(5): 1321-1326.
- [19] LIU C J, DING W F, LI Z, et al. Prediction of high-speed grinding temperature of titanium matrix composites using BP neural network based on PSO algorithm[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 89(5/6/7/8): 2277-2285. DOI: 10.1007/s00170-016-9267-z.
- [20] 江丽. 基于粒子群与模拟退火算法的BP网络学习方法研究[D]. 合肥: 安徽大学, 2013.
- JIANG L. Research on BP neural network learning based on particle swarm optimization and simulated annealing algorithm[D]. Hefei: Anhui University, 2013.
- [21] WANG L, ZHAO Q J, WEN Z M, et al. RAFFIA: short-term forest fire danger rating prediction via multiclass logistic regression[J]. *Sustainability*, 2018, 10(12): 4620. DOI: 10.3390/su10124620.
- [22] SAATY T L. Decision making with the analytic hierarchy process[J]. *International Journal of Services Sciences*, 2008, 1(1): 83. DOI: 10.1504/ijssci.2008.017590.
- [23] 楼文高, 乔龙. 基于神经网络的金融风险预警模型及其实证研究[J]. *金融论坛*, 2011, 16(11): 52-61. DOI: 10.16529/j.cnki.11-4613/f.2011.11.001.
- LOU W G, QIAO L. Early warning model of financial risks and empirical study based on neural network[J]. *Finance Forum*, 2011, 16(11): 52-61.

(责任编辑 曹会聪)