

文章编号: 1673-8411(2019)02-0007-05

基于 Copula 熵因子选取的 PSO-ELM 台风灾情预测模型

陈燕璇¹, 刘合香^{1,2*}, 倪增华³

(1. 南宁师范大学数学与统计学院, 南宁 530023;

2. 北部湾海洋灾害研究重点实验室, 广西 钦州 535011; 3. 南宁学院, 南宁 530023)

摘要: 采用 ISOMAP-Copula 集成方法, 分别构造台风灾害的致灾源指数、承灾体指数、防灾减灾指数及灾情指数。借助 Copula 熵研究台风灾情与影响因子的相关性, 构造 T 检验的阈值, 筛选与灾情显著相关的影响因子。构建的 ELM 和 PSO-ELM 模型, 分别应用于广西台风灾情的预测。结果表明, 基于 Copula 熵影响因子选取的 PSO-ELM 灾情预测模型的拟合度 (0.9121) 最高, 均方误差 (0.0044) 最小, 说明该模型的预测精度最高, 可为广西台风灾情的预测提供一种新的途径。

关键词: Copula 熵; 相关性; 影响因子; PSO-ELM; 台风灾情

中图分类号: 0212.4

文献标识码: A

PSO-ELM Typhoon Disaster Prediction Model Based on Copula Entropy Factor Selection

Chen Yanxuan¹, Liu Hexiang^{1,2*}, Ni Zenghua³

(1.School of Mathematics and Statistics Sciences, Nanning normal University, Nanning 530023; 2.Key Laboratory of Marine Disaster Research in Beibu Gulf, Qinzhou Guangxi 535011; 3.Nanning University, Nanning 530023)

Abstract: Using ISOMAP-Copula integration method, the source index, body index, disaster prevention and mitigation index and disaster situation index of typhoon disasters are constructed respectively. Copula Entropy is used to study the correlation between typhoon disaster and its influencing factors, and T test threshold is constructed to screen the influencing factors which are significantly related to the disaster. The ELM and PSO-ELM models are applied to predict the typhoon disaster in Guangxi. The results show that PSO-ELM disaster prediction model based on Copula entropy influence factor has the highest fitting degree (0.9121) and the smallest mean square error (0.0044), indicating that the prediction accuracy of the model is the highest and the model can provide a new way for typhoon disaster prediction in Guangxi.

Keywords: copula entropy; relevance; impact factor; PSO-ELM; typhoon disaster

引言

在全球气候变暖的背景下, 登陆我国华南地区的台风强度逐年偏强, 极端台风灾害造成的损失严重^[1-7]。台风灾情是由致灾源、承灾体和防灾减灾等方面相互作用的结果, 从众多影响因子中选取重要影响因子对台风灾情进行预测具有重

要意义。台风灾害影响因子具有多维、属性相关度高等特点^[8], 与灾情具有非线性关系^[9-10], Copula 熵是 Copula 函数和信息熵结合的方法, 能对灾情与影响因子间的线性和非线性关系进行定量描述, 在水文、金融等方面有广泛应用^[11-12]。Copula 函数能根据形式灵活的边际分布和相关性结构构造联合分布来反映综合影响强度, 但是求

收稿日期: 2019-01-30

基金项目: 国家自然科学基金项目 (41665006, 41465003), 南宁学院科研项目 (2018XJ43)

作者简介: 陈燕璇 (1988—), 女, 硕士研究生, 主要从事统计建模研究。E-mail: hx_post@163.com

*通讯作者: 刘合香 (1962—), 女, 教授, 硕士生导师, 主要从事概率统计、数学模型、自然灾害风险分析研究。E-mail: hx_post@163.com

解多维 Copula 函数分布和参数比较困难。极限学习机 (ELM) 是 Huang 等^[13]提出的前馈神经网络, 相比其他神经网络具有结构简单、参数设置简单等优点。由于 ELM 网络的输入权重和偏差矩阵是随机产生, 造成预测结果不稳定。为此, Xu 等^[14]采用粒子群寻找最优的 ELM 网络的输入权重和偏差矩阵。粒子群改进极限学习机 (PSO-ELM) 在经济预测、电力负荷预测等方面已有应用^[15-16]。

针对上述问题, 本文采用提出的等距特征映射算法 (ISOMAP)^[17] 分别对台风灾害致灾源和承灾体等方面影响因子进行非线性降维, 将提取后的二维综合向量与 Copula 函数相结合, 分别构造致灾源指数、承灾体指数、防灾减灾指数和灾情指数。为了比较不同影响选取的台风灾情预测效果, 分别基于 Copula 熵、逐步回归方法对台风影响因子进行提取, 应用 ELM 和 PSO-ELM 分别对广西台风灾情进行预测。

1 资料和方法

1.1 资料来源与预处理

致灾源选取最大风速 X_1 (m/s)、最低气压 X_2 (Pa)、暴雨极值 X_3 (mm) 和暴雨时长 X_4 (h)。数据来自《热带气旋年鉴》^[18] 和中国台风网^[19] 中 1985-2014 年间登陆或影响广西的 44 个台风灾害。承灾体选取单位面积 GDP X_5 (亿元)、人口密度 X_6 (人/km²)、农作物总播种面积 X_7 (khm²)、城镇居民人均居住面积 X_8 (m²) 和农村居民人均居住面积 X_9 (m²)。防灾减灾选取人均 GDP X_{10} (元/人)、就业人数 X_{11} (万人)、每万人在校大学生人数 X_{12} (人)、公路网密度 X_{13} (km/104km²)、每万人拥有床位 X_{14} (床)、每万人拥有医生 X_{15} (人) 电话普及率 X_{16} (部/万人)。承灾体和防灾减灾数据取自 1985-2014 年《广西统计年鉴》^[20]。灾情选取受灾人口 X_{17} (万人)、死亡人口 X_{18} (人)、农作物受灾面积 X_{19} (khm²)、倒塌房屋 X_{20} (千间) 和直接经济损失 X_{21} (千万元)。灾情数据来自广西民政厅、广西气象信息中心和广西防汛抗旱指挥部等的灾情综述统计。

为了消除指标间的量纲影响, 对原始数据进行归一化处理:

$$x_{ij}^* = (x_{ij} - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

其中, x_{\min} 和 x_{\max} 表示同一指标下的最小值和最大值。

1.2 模型输入的因子选取方法

(1) Copula 熵

令 $X \in \mathbb{R}^n$ 是 n 维随机变量, 其边际分布函数为 $G_i(X)$, $U_i = G_i(X)$, $i = 1, 2, \dots, n$. 其中, U_i 服从均匀分布的随机变量^[21], Copula 熵为

$$H_c(u_1, u_2, \dots, u_n) = -\int_0^1 \dots \int_0^1 c(u_1, u_2, \dots, u_n) \cdot \log(c(u_1, u_2, \dots, u_n)) du_1 du_2 \dots du_n \quad (2)$$

其中, $c(u_1, u_2, \dots, u_n)$ 为 Copula 函数的概率密度函数。

若根据定义采用多重积分方法计算 Copula 熵会比较困难, 参考陈璐^[21]的方法, 采用 Monte Carlo 法, 将求 Copula 熵值转化求 $\ln c(U)$ 的数学期望。

令 $U \in [0, 1]$, $i = 1, 2, \dots, n$, 有

$$H_c(u_1, u_2, \dots, u_n) = - \int_{[0,1]^n} c(U) \ln c(U) dU = -E[\ln c(U)] \quad (3)$$

(2) 基于 Copula 熵的影响因子选取原则

设台风灾情指标与致灾源、承灾体和防灾减灾影响因子的 Copula 熵 $H_i \sim N(\mu, \sigma)$, $i = 1, 2, \dots, n$ 。原假设: $\mu = H_0$; 备择假设: $H_i \neq H_0$ 。在检验水平 α 下, 允许犯“原假设为真, 拒绝原假设”错误的概率为 d ^[22], 即

$$p\left\{ \left| \frac{\bar{H} - H_0}{S / \sqrt{n}} \right| \geq t_{\frac{\alpha}{2}}(n-1) \right\} = \alpha \quad (4)$$

其中, \bar{H} 为样本均值, S^2 为样本方差。这里未给出 Copula 熵均值 H_0 , 在接受原假设情况下, 反推求出 H_0 , 即 H_0 的最大值 $H_{0\max}$ ^[23]。

$$\text{令 } \left| \frac{\bar{H} - H_{0\max}}{S / \sqrt{n}} \right| = t_{\frac{\alpha}{2}}(n-1) \quad (5)$$

$$\text{可得 } H_{0\max} = \bar{H} + t_{\frac{\alpha}{2}}(n-1) (S^2 / n)^{\frac{1}{2}} \quad (6)$$

若影响因子与灾情指标间的 Copula 熵满足 $H_i < H_{0\max}$, Copula 熵值越小, 表明二者相关性越强, 该影响因子可以选入作为灾情预测模型的输入, 否则予以删除。

1.3 粒子群改进极限学习机模型

采用粒子群算法 (PSO) 寻找最优的输入权重 w 和偏差矩阵 b , 进而提高预测精度与稳定预测结果^[14]。PSO-ELM 主要计算步骤如下。

(a) 初始化参数, 选取合适的学习因子 C_1 和 C_2 , 确定惯性权重 ω , 最大迭代次数 k , 搜索空间维数 D , 群体个数 N , 设定精度 ϵ 。

(b) 选取的均方误差倒数作为 ELM 训练的适应度函数 f , 即

$$f = 1 / \sum_{i=1}^n (y_i - \hat{y}_i) \quad (7)$$

在同一次迭代中, 首先, 比较 f_i 与个体极值

$pbest$ 的大小, 若 $f_i > pbest$, 则 f_i 代替 $pbest$ 。其次, 比较 f_i 与全局极值 $gbest$ 的大小, 若 $f_i > gbest$, 则 f_i 代替 $gbest$ 。迭代过程中, 粒子通过个体极值 $pbest$ 和全局极值 $gbest$ 来更新速度和位置, 即

$$V^{k+1}(i) = \omega V^k + c_1 r_1 (pbest^k(i) - X^k(i)) + c_2 r_2 (gbest^k(i) - X^k(i)) \quad (8)$$

$$X^{k+1}(i) = X^k(i) + V^{k+1}(i) \quad (9)$$

其中, $V^k(i)$ 表示第 k 次迭代中第 i 个粒子的速度, $X^k(i)$ 表示第 k 次迭代中第 i 个粒子的位置, r_1 和 r_2 为 $[0, 1]$ 的随机数。依次迭代, 直到满足精度要求, 退出程序。

(c) 输出最优适应度的输入权重 w 和偏差矩阵 b , 根据 huang 文献^[13], 计算得到输出权重 β 。

2 模型应用与分析

2.1 基于 ISOMAP-Copula 的台风灾情指数

首先, 采用 ISOMAP 算法^[24] 将台风灾害致灾源、承灾体和防灾减灾各方面的影响因子降维成二维综合指标; 其次, 由核密度估计出综合指标的边际分布; 最后, 根据二维 Gaussian Copula 分布函数即可得到各类指数, 见表 1。

表 1 台风灾害致灾源、承灾体和防灾减灾方面的 ISOMAP-Copula 综合指数

台风 编号	致灾 指数	承灾 指数	防灾 指数	灾情 指数	台风 编号	致灾 指数	承灾 指数	防灾 指数	灾情 指数
8510	0.5522	0.1044	0.8499	0.7427	0602	0.0355	0.1926	0.6212	0.3479
8517	0.0185	0.1044	0.8499	0.5681	0604	0.3515	0.1926	0.6212	0.7785
8609	0.0611	0.1112	0.8069	0.2498	0605	0.0474	0.1926	0.6212	0.2265
8613	0.0411	0.1112	0.8069	0.2000	0606	0.4053	0.1926	0.6212	0.7483
8702	0.1692	0.1203	0.7697	0.3444	0703	0.0528	0.0223	0.6228	0.2998
9107	0.5260	0.0778	0.6800	0.1696	0809	0.2785	0.1275	0.6379	0.4805
9108	0.1479	0.0778	0.6800	0.1787	0812	0.0400	0.1275	0.6379	0.1855
9207	0.2268	0.1098	0.6663	0.1798	0814	0.7283	0.1275	0.6379	0.8816
9302	0.2868	0.1506	0.5682	0.2581	0906	0.0416	0.3339	0.6225	0.2166
9303	0.2345	0.1506	0.5682	0.8563	1003	0.3541	0.2126	0.5645	0.4564
9309	0.3784	0.1506	0.5682	0.6779	1104	0.0479	0.5058	0.8004	0.1749
9403	0.3117	0.0960	0.6334	0.9868	1117	0.6419	0.5058	0.8004	0.6564
9411	0.0391	0.0960	0.6334	0.8431	1208	0.3336	0.4382	0.6586	0.2729
9419	0.2870	0.0960	0.6334	0.1960	1213	0.5616	0.4382	0.6586	0.6117
9506	0.0161	0.1751	0.5732	0.7390	1223	0.3091	0.4382	0.6586	0.2357
9516	0.0776	0.1751	0.5732	0.8805	1309	0.0937	0.6929	0.4542	0.1694
9615	0.5764	0.0403	0.5124	0.9301	1311	0.6641	0.6929	0.4542	0.4799
9713	0.3188	0.0035	0.4866	0.5321	1312	0.0464	0.6929	0.4542	0.2078
0104	0.4742	0.0332	0.5328	0.9612	1319	0.4114	0.6929	0.4542	0.1656
0107	0.3625	0.0332	0.5328	0.2391	1330	0.5790	0.6929	0.4542	0.5458
0114	0.1147	0.0332	0.5328	0.2297	1409	0.7012	0.6467	0.2464	0.8373
0214	0.1908	0.1128	0.6044	0.3640	1415	0.4787	0.6467	0.2464	0.6493

致灾源方面, 根据相对阈值法, 将大于 85% 分位数 (0.5607) 定义为强台风。大于 0.5607 的台风编号分别为 0814, 1409, 1311, 1117,

1330, 1213, 9615。根据中国台风网统计^[19], 0814, 1409, 1311, 1117, 9615 均为强台风等级。两者不同, 是因为《热带气旋等级》国家标准关

于强台风等级是按照最大风速来划分，而本研究不仅考虑最大风速，还考虑暴雨极值等影响因素。灾情方面，最大灾情指数为0.9868，最小灾情指数为0.1656，两者相差0.8212，具有明显区分度，有助于直观地观察与区分不同灾害损失程度。

2.2 台风灾情与影响因子的相关性分析

采用 (3) 式计算 Copula 熵，根据二维 Gaussian

Copula 的定义，随机生成 10000 对相关的矩阵 U ，计算 $\ln c(U)$ 的均值。通过 T 检验确定一个阈值，见表 2。为了便于观察，将 Copula 熵值表绘制成色块图见（图 1），Copula 熵值越小，颜色越接近红色，表明该灾情指标与影响因子的相关性越强。

由表 2 和图 1 可知，与受灾人口、死亡人口显著相关均有暴雨极值和暴雨时长。其中，暴雨时长是造成人员伤亡的最重要的影响因子；倒塌房屋与暴雨极值和暴雨时长具有强关联度；与农

表 2 台风灾害影响因子与灾情指标的 T 检验阈值表

	受灾人口 X_{17}	死亡人口 X_{18}	农作物受灾 面积 X_{19}	倒塌房屋 X_{20}	直接经济 损失 X_{21}	灾情指数 X_{22}
T 检验阈值 (H_{0max})	-0.0495	-0.1033	-0.0597	-0.0924	-0.0758	-0.0589




图 1 台风影响因子与灾情指标的 Copula 熵值图

作物受灾面积、直接经济损失和灾情指数显著性相关均为致灾源方面的影响因子。

综上所述，选取最大风速 X_1 、最低气压 X_2 、暴雨时长 X_3 和暴雨极值 X_4 作为预测模型的输入，其中，灾情指数与暴雨极值的 Copula 熵值为 -0.1857 最小，说明暴雨极值是台风灾害最重要的影响因素。

2.3 基于 Copula 熵及 PSO-ELM 的台风灾情预测模型

选取 75% 的样本进行训练，25% 样本进行检验。在构建 ELM 和 PSO-ELM 时，均选取 sigmoid 函数^[25]。ELM 模型，设隐含层神经元数为 3。PSO-ELM 模型，取隐含层神经元数为 1。为了加速算法收敛，将惯性权重 ω 设为 0.7，同时确定加速系数 C_1 和 C_2 均为 1.5^[26]。设群体个数 N 为 40，最大迭代次数 κ 为 5000 次，精度 ϵ 为 10^{-6} ^[27]。在寻找最优输入权重 $w_{1 \times 4}$ 和偏差矩阵 $b_{1 \times 4}$ 时，共有 8 个未知元素，故设搜索空间维数 D 为 8。分别采用 Copula 熵、

逐步回归对台风影响因子进行选取，应用 ELM 和 PSO-ELM 对台风灾情进行预测。结果见表 3 及图 2。

表 3 基于不同影响因子选取的预测模型对比分析表

影响因子选取方法	影响因子	预测方法	R2	MSE
Copula 熵	X_1, X_2, X_3, X_4	ELM	0.7724	0.0325
		PSO-ELM	0.9121	0.0044
逐步回归	X_1, X_4, X_8, X_{15}	ELM	0.6052	0.0681
		PSO-ELM	0.8097	0.0097

由表 3 可知，基于 Copula 熵影响因子选取的 PSO-ELM 灾情预测模型的拟合度 (0.9121) 最高，均方误差 (0.0044) 最小。而基于逐步回归影响因子选取的 ELM 灾情预测模型的拟合度 (0.6052) 最小，均方误差 (0.0681) 最大。由此可见，影响因子选取方法及预测方法决定了模型的优劣。

基于 Copula 熵影响因子选取的预测模型，均优于逐步回归选取的预测模型。究其原因，Copula




图 2 基于不同影响因子选取的台风灾情预测结果图

Copula熵是一种非线性方法,能筛选出与灾情显著相关的影响因子。逐步回归是基于多元线性回归方法,选取的影响因子为最大风速、暴雨极值、城镇人均居住面积和每万人拥有医生数。模型输入太多弱相关的影响因子会造成信息干扰,影响预测的效果。

由表 3 及图 2,我们可以看到,改进后的 PSO-ELM 模型比传统的 ELM 模型预测效果更好,PSO-ELM 能够提高 ELM 网络的稳定性和预测的精确度,以最大化适应度函数为目标,获得最小的预测误差。实验表明,PSO-ELM 算法在较少的隐含层神经元数能达到较好的预测效果。综上所述,基于 Copula 熵影响因子选取的 PSO-ELM 模型能提取台风灾害的关键影响因子,该模型的预测精度较高。

3 总结与展望

(1) 采用 ISOMAP 算法和 Copula 函数构造各个灾害指数,解决了多维 Copula 函数分布和参数求解的困难,各指数能客观地表征台风灾害致灾源、承灾体、防灾减灾和灾情方面的综合影响强度,与实际情况相吻合。

(2) 采用 T 检验确定一个阈值,若 Copula 熵小于阈值,则为与灾情指数显著相关影响因子。由此选出与灾情指数显著相关的影响因子均为致灾源。

(3) PSO-ELM 模型解决了 ELM 模型输入权重和偏差矩阵不稳定的问题,且在隐含层较少的情况下能达到较高的预测精度,具有较好的学习和泛化能力。

本研究还可以考虑更多影响因素,例如台风登陆路径、风垂直切变等影响因素,进而提高预测台风灾情的准确度。

参考文献:

[1] 何洁琳, 谢敏, 黄卓, 等. 广西气候变化事实 [J]. 气象研究与应用, 2016, 37(3): 11-15.
[2] 罗红磊, 何洁琳, 李艳兰, 等. 气候变化背景下影响广西的主要气象灾害及变化特征 [J]. 气象研究与应用, 2016, 37(1): 10-14.

[3] 胡娅敏, 刘锦奎, 庄旭东, 等. 广东热带气旋气候变化的新特征和应对建议 [J]. 广东气象, 2015, 37(5): 1-4+9.
[4] 黄雪松, 廖雪萍, 覃卫坚. 广西热带气旋特征变化与灾损变化态势 [J]. 气象研究与应用, 2014, 35(1): 2-6.
[5] 李文媛, 杜尧东, 郑璟, 等. 2018 年 7—8 月广东省天气气候特点及其影响评述 [J]. 广东气象, 2018, 40(5): 2+8+1.
[6] 曹梅, 罗曼宁, 关小文. 广东“威马逊”过程致灾因子的分析与风险区划 [J]. 广东气象, 2015, 37(2): 52-54.
[7] 林晓霞, 王硕甫, 冯业荣. 超强台风“威马逊”登陆前快速加强的特征和原因分析 [J]. 广东气象, 2016, 38(3): 33-37.
[8] 彭昱忠, 王谦, 元昌安, 等. 数据挖掘技术在气象预报研究中的应用 [J]. 干旱气象, 2015, 33(1): 19-27.
[9] 谭金凯, 刘合香, 陈燕璇. 华南热带气旋相关物理量场的线性及非线性统计分析研究 [J]. 热带气象学报, 2017, 33(1): 119-126.
[10] 巩在武, 胡丽. 台风灾害评估中的影响因子分析 [J]. 自然灾害学报, 2015, 24(1): 203-213.
[11] 倪增华, 刘合香, 罗彦丽, 等. Copula 函数在广西洪涝灾害的降水概率预测中的应用 [J]. 气象研究与应用, 2014, 35(2): 32-39.
[12] 赵宁, 李兴斯, 孙雪卿. 基于 Copula 熵的基金组合分析 [J]. 数学的实践与认识, 2015, 45(6): 30-38.
[13] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1): 489-501.
[14] Xu Y, Shu Y. Evolutionary Extreme Learning Machine - Based on Particle Swarm Optimization [M]// Advances in Neural Networks-ISNN 2006. Springer Berlin Heidelberg, 2006: 644-652.
[15] 朱正, 陶岚. 基于 ELM 的成本预测方法实证检验 [J]. 统计与决策, 2015(23): 63-65.
[16] 李婉华, 陈羽中, 郭昆, 等. 基于改进粒子群优化的并行极限学习机 [J]. 模式识别与人工智能, 2016, 29(9): 840-849.
[17] Tenenbaum J B, Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323.
[18] 中国气象局. 热带气旋年鉴 1985-2014 年 [M]. 北京: 气象出版社, 1985-2014.
[19] 中国台风网. <http://www.typhoon.gov.cn/>, 2015/07/14. China typhoon network. <http://www.typhoon.gov.cn/>, 2015/07/14.
[20] 广西壮族自治区统计局. 广西统计年鉴 1985-2014 年 [M]. 北京: 中国统计出版社, 1985-2014.
[21] 陈璐. Copula 函数理论在多变量水文分析计算中的应用研究 [M]. 武汉: 武汉大学出版社, 2013.
[22] 茆诗松, 程依明, 濮晓龙. 概率论与数理统计 [M]. 北京: 高等教育出版社, 2011.
[23] 杨慧中, 章军, 陶洪峰. 基于互信息的软测量变量选择 [J]. 控制工程, 2012, 19(4): 563-565.
[24] 陈燕璇, 刘合香, 谭金凯. 基于等距特征映射降维的台风灾情概率神经网络预评估模型 [J]. 灾害学, 2016, 31(3): 20-25.
[25] 樊超, 郭亚菲, 曹培格, 等. 基于主成分分析的粮食产量极限学习机预测模型研究 [J]. 粮食加工, 2017, 42(2): 1-5.

表 7 不同光质 LED 灯各批次补光效果

催花效果	春季第一批	春季第二批	春季第三批	秋季独一批
效果显著	A、B、C	A、B、C	A、B、C	A、B、C
效果依次排列	A > B > C	A ≈ B > C	A ≈ B ≈ C	A > B ≈ C

火龙果为长日照植物, 在光照不足, 适宜温度下, 通过人工补光, 可达到成花诱导效果, 能有效提早花期; 在秋季进行补光, 打破夜长, 可以促使火龙果秋末冬初时正常花芽分化, 实现火龙果花期延长, 每年多产 3~4 批次果, 提高经济效益。但补光催花效果与补光灯的光质有很大关系, 本试验采用 3 种不同光质的 LED 灯, 在春秋二季进行火龙果补光, 共催花四批。在相同田间管理水平下, 红黄灯、黄灯及红兰灯在春季共催生三批花蕾, 平均每株催花现蕾分别为 13.0、13.0、11.3 个, 而对照区仅在第三批平均每株有 0.1 个花蕾。虽然春季红黄光灯、黄光灯催花量相同, 但红黄光灯第一、二批平均每株催花量 4.9 个, 比黄光灯多 0.8 个, 由于越早催花成果, 经济效益越高, 故红黄光灯比黄光灯补光催花更具优势; 在秋季催花虽因阴天多, 日照不足, 但红黄光灯、黄光灯及红兰光灯仍成功平均每株催花现蕾分别为 1.2、0.4、0.3 个, 对照区无花蕾。

参考文献:

- [1] 范万新, 陈丹, 黄颖, 等. 广西种植火龙果的气候条件分析[J]. 气象研究与应用, 2009, 30(2): 54-56.
- [2] 陈菁, 郑良永, 黄杵娜, 等. 火龙果生理生态特性研究进展[J]. 中国南方果树, 2016, 45(4): 164-167.
- [3] 刘友接, 林世明, 黄雄峰, 等. “石火泉”火龙果引种表现及其栽培技术[J]. 中国南方果树, 2015, 44(1): 90-91.
- [4] 邓仁菊, 范建新, 蔡永强. 国内外火龙果研究进展及产业发展现状[J]. 贵州农业科学, 2011, 39(6): 188-192.
- [5] 龙平. 罗甸冬季低温对火龙果产业的影响及对策[J]. 农技服务, 2011, 28(6): 889.
- [6] 张锦祝, 张小石, 罗经权. 丰顺县种植火龙果的农业气候条件分析[J]. 乡村科技, 2018, 2月(中): 110-112.
- [7] 卓福昌, 韦优, 蒋娟娟, 等. 火龙果补光催花试验初探[J]. 中国热带农业, 2018, 82(3): 52-53.
- [8] 雷新南. 火龙果产期调节技术[J]. 农村新技术, 2018, (3): 14-15.
- [9] 赖瑞云, 张雪芹, 林建忠, 等. 补光对大棚火龙果冬季催花的影响[J]. 亚热带植物科学, 2018, 47(3): 286-288.
- [10] 许明, 翁武斌. 台湾常见火龙果产期调节技术[J]. 福建农业科技, 2015, 12: 24-26.
- [11] 胡子有, 潘瑞立, 黄海生, 等. 火龙果冬果栽培关键技术[J]. 中国果树, 2017, (3): 89-91.
- [12] 朱静娴. 人工补光对植物生长发育的影响[J]. 作物研究, 2012, 26(3): 74-78.
- [13] 陈菲, 张信, 于晓莹. LED灯补光对作物生长发育的影响[J]. 现代农业, 2015, (8): 24-25.
- [14] 曲溪, 叶方铭, 宋杰琼, 等. LED灯在植物补光领域的效用探究[J]. 灯与照明, 2008, 32(2): 41-45.
- [15] 韦金霖, 林金红, 翟殷斌. 平果县石山区火龙果种植气候适应性分析[J]. 气象研究与应用, 2018, 39(1): 66-69.
- [16] 胡子有. 火龙果气候适应性分析与广西火龙果种植生态气候区划[J]. 南方园艺, 2015, 26(3): 16-19.
- [17] 解华云, 刘慧, 劳家喜, 等. 钦州市火龙果种植的气候适应性分析[J]. 农业科技通讯, 2015, (4): 283-285.
- [18] 黄艳芳, 秦媛媛, 阮晓静. 广西火龙果产业发展现状及可持续发展对策研究[J]. 热带农业科学, 2017, 37(6): 97-99.
- [19] 肖图舰, 毛永亚, 王壮, 等. 露地补光对贵州热区火龙果产量及产值的影响[J]. 农技服务, 2019, 36(3): 42-43.
- [20] 孙天宇, 于锡宏, 蒋欣梅. 不同光质LED补光对甜瓜果实生长发育及品质的影响[J]. 长江蔬菜, 2017, (20): 72-75.
- [21] 沈红香, 沈漫, 程继鸿. 不同光质补光处理对郁金香生长和开花的影响[J]. 北京农学院学报, 2007, 22(1): 16-18.
- [22] 李雅曼, 郑胤建, 谭星, 等. 不同光质补光对番茄黄化病幼苗生长的影响[J]. 照明工程学报, 2016, 27(5): 68-71.

(上接第 11 页)

- [26] Shi Y, Eberhart R C. Empirical study of particle swarm optimization[C]//Proceeding of the Congress on Evolutionary Computation, 1999: 1945-1950.
- [27] 王杰, 毕浩洋. 一种基于粒子群优化的极限学习[J]. 郑州大学学报(理学版), 2013, 45(1): 100-104.