

## 基于 PSO-BP 神经网络的机坪泛光照明优化预测模型

郑美春<sup>1</sup>, 沈良忠<sup>1</sup>, 李岳<sup>2</sup>, 蔡靖<sup>2</sup>

(1. 温州商学院信息工程学院, 浙江 温州 325035; 2. 中国民航大学交通科学与工程学院, 天津 300300)

**摘要:** 机坪泛光照明设计的影响因素众多,影响着泛光照明效率与安全。本研究在 DIALux evo 软件中模拟了 315 组仿真照明方案,用来开发照度预测模型。以水平照度、垂直照度、均匀度、眩光值以及分区照度指标作为模型输入,以高杆灯安装高度、LED 灯数、垂直俯仰角作为模型输出,基于粒子群优化(PSO,particle swarm optimization)和反向传播(BP,back propagation)神经网络构建预测模型,并与 BP 神经网络构建的预测模型对比分析。结果表明:与 BP 神经网络算法相比,本研究所提出的 PSO-BP 神经网络的效率更高,模型拟合精度更高,且避免了 BP 神经网络算法易陷入局部最优解的问题。本文建立的优化模型对预设场景的照度预测结果与仿真试验结果高度一致,表明该模型在工程应用中具有较好的预测精度。

**关键词:** PSO-BP 神经网络;机坪泛光照明;高杆灯;LED 灯;优化模型

中图分类号: V351.32 文献标志码: A 文章编号: 1674-5590(2025)06-0054-07

## Optimization and prediction model of apron floodlighting based on PSO-BP neural network

ZHENG Meichun<sup>1</sup>, SHEN Liangzhong<sup>1</sup>, LI Yue<sup>2</sup>, CAI Jing<sup>2</sup>

(1. College of Information Engineering, Wenzhou Business College, Wenzhou 325035, Zhejiang, China;

2. College of Transportation Science and Engineering, CAUC, Tianjin 300300, China)

**Abstract:** The design of apron floodlighting is influenced by numerous factors, which affect the efficiency and safety of floodlighting. In this study, 315 sets of lighting schemes were simulated in DIALux evo software to develop an illuminance prediction model. Horizontal illuminance, vertical illuminance, uniformity, glare rating, and zonal illuminance were used as model inputs, while the installation height of high-mast lights, number of LEDs, and vertical tilt angle were used as model outputs. A prediction model based on particle swarm optimization (PSO) and back propagation (BP) neural network was constructed and compared with a model built using BP neural network. The results show that the proposed PSO-BP neural network is more efficient and has higher model fitting accuracy than the BP neural network algorithm, and it avoids the problem of local optima inherent in the BP neural network algorithm. The predicted illuminance results for the preset scenes using the established optimized model were highly consistent with the simulation test results, indicating that the model has good predictive accuracy in engineering applications.

**Key words:** PSO-BP neural network; apron floodlighting; high-mast light; LED light; optimization model

机坪泛光照明设计是关系到机场整体布局和使用功能的重点环节,主要作用是提供充分的照明环境,使飞行区内地面运行区域照度指标满足航空器起降与停放等操作需要,对保证航空运行安全、提高航班效率具有重要意义。根据 2012 年的一项调查,由机坪泛光照明产生的电能消耗在机场整体运行能耗中排名第一,是决定机场节能水平的关键节点<sup>[1]</sup>。因此,

实施机坪泛光照明优化设计对控制温室气体排放和降低机场运行成本有重要意义。

民航业在泛光照明系统的节能运行改造方面有丰富的实践经验<sup>[2]</sup>,如通过更换符合节能标准的高效 LED 灯具降低整体能耗水平,调节照明参数和优化照明方案改善照度分布效果。值得注意的是,与泛光照明设计关联的变量因素众多,包括 LED 灯发光性能、

灯具数量、照明高度、投射角度、照明场地几何形状、安装位置限制等,因此,想要快速直接地获取最优照明方案并不容易。当前,在工程实践中严重依赖设计者的经验和主观印象,并配合大量的照度软件仿真计算,照明方案组合设计偏于粗放,尚未形成一种科学、高效的照明方案优化设计方法。

对此,以往研究主要围绕完善机坪照度测量方法、优化灯具数量和光源排列等单一照度影响因素开展研究,工程应用与指导能力有限<sup>[3-4]</sup>。自 21 世纪以来,以反向传播(BP, back propagation)神经网络算法为代表的各类人工智能神经网络工具快速发展,为解决上述问题提供了新的技术思路。

基于此,本文提出了一种基于粒子群优化(PSO, particle swarm optimization)和 BP 神经网络算法的泛光照明优化预测模型。该模型综合考虑了各种可变因素,如灯具数量、照明高度、投射角度、安装限制等,可实现对复杂模糊问题的精确处理。

## 1 建模方法

### 1.1 模型组成

建立基于 BP 神经网络算法的机坪泛光照明优化预测模型需要大量数据集作为分析基础<sup>[5-6]</sup>。数据集的来源主要有照度仪现场测量或 DIALux evo 照度仿真 2 类常见方式。照度仪测量方式存在测试效率低下,受照度仪精度、人工操作偏差、环境背景光等多重因素影响的缺点,可考察的数据类型相对较少。与之相比,DIALux evo 照度仿真在高效获取多工况组合、大规模数据集方面优势明显。

当前 DIALux evo 工程应用大多是对单个停机位范围内的照度分析,这对于无航空器停泊状态来说是适合的。但当航空器通过引导停靠停机位时,不可避免地会对泛光照明光线产生复杂的折射和反射效果,并在其底部产生大范围的阴影区域(照度显著低于正常值)。文献[7]基于 VNISI 软件探讨了飞机与泛光照明的遮蔽关系,并综合照明效果给出了最经济的高杆灯布置方案。其分析表明,由于飞机机身遮挡造成的机坪照度降幅在 5~10 lx 之间,需在照明设计阶段引起重视,但后续讨论与工程应用不足。

为获取更接近实际运行状态下的机坪泛光照明数据集,提高 BP 神经网络算法训练精度,本文建立了带有航空器的精细化机坪泛光照明仿真模型。选取 A320 飞机作为代表机型,采用 3DS Max 软件建模,不考虑机身涂装对表面反光效果的影响,蒙皮基础色为

白色,根据涂层材料确定反射率(reflectance index)取值范围在 29%~70%之间。停机位可停放 C 类等级飞机,最大翼展为 36 m,相邻停机位安全距离为 4.5 m;依据国内某中部机场和众多机场实测数据,确定 C 类停机位多边形轮廓线样式,如图 1 所示。其中:AS1 和 AS2 为相邻停机位;HM1~HM7 为高杆灯安装点位。为使 BP 神经网络算法训练结果更具普遍性,多个停机位按照并列方式排布。相邻停机位轮廓线围合形成的三角形区域,可作为地面服务设备(GSE, ground service equipment)的预留空间,泛光照明所需高杆灯即位于 GSE 区域内部。高杆灯底座相对于停机位安装位置在 GSE 内部可变,其平面位置坐标与其他常规设计参数(安装高度、灯具数量、垂直俯仰角)共同作为 BP 神经网络算法的输出项,从而对模型训练效果及参数优化效果进行评价。




图 1 组合 C 类停机位排列

Fig.1 Arrangement of combined C-class aircraft stands

### 1.2 模型参数分析

以往机坪泛光照明设计标准主要考察机坪水平照度、垂直照度和照明均匀度(机坪最小照度与平均照度的比值)3 项指标。根据国际民航组织和国际民航《民用机场机坪泛光照明技术要求》(MH/T 6108—2014)相关规定<sup>[8-9]</sup>,正常使用机坪的水平照度  $E_h$  和垂直照度  $E_v$  应大于 20 lx,且照明均匀度不低于 0.25。考虑到眩光对地面运行的影响风险,眩光值(GR, glare rating)不应超过 50。对于无航班运行服务的机坪区域,上述机坪的水平照度和垂直照度要求可适当降低。

值得注意的是,上述机坪泛光照明设计标准仅完成对整体照明环境的量化评估,对不同地面作业区域的局部照明环境缺乏量化指标,对航空器遮蔽阴影的影响考虑不足。对此,依托上述精细化的机坪泛光照明仿真模型提出 4 种分区照度指标,具体包括:

(1) 指标  $E_{front}$  考察机身下方前起落架周围照度,是地面拖车推出飞机时的主要作业区域,与航空器存在碰撞风险;

(2) 指标  $E_{wing}$  考察机身两侧机翼下方区域照度,

加油车与飞机在此进行供油管线连接,与航空器存在剐蹭风险;

(3)指标  $E_{middle}$  考察机身中段两侧下方机腹区域照度,行李装卸人员和车辆在此集中作业,与航空器存在碰撞风险;

(4)指标  $E_{tail}$  考察机身尾部区域照度,是飞行员实施起飞前外部检查的重点区域,由于与高杆灯距离较大存在照明不足风险。整体与分区照度指标考察范围如图 2 所示。




图 2 整体与局部照度评价范围

Fig.2 Overall and local illumination evaluation range

为确保基于 DIALux evo 仿真的数据集的全面性,并充分涵盖常规高杆灯安装方案和典型 LED 灯投射方向工况。高杆灯的安装高度设定在 15~25 m 之间,按照 2.5 m 的增量划分 5 种安装工况;LED 灯的数量共有 4、5、6 盏 3 种情况;投射垂直俯仰角共有 65°、50°、35° 3 种情况,投射水平角在 210°~330° 范围内均匀分布。本研究共考察了 7 种高杆灯的安装点位,如图 1 中所标注,依次编号为 HM1~HM7,采用 DIALux evo 软件对上述共 315 组工况逐一仿真分析,提取各工况的整体与分区照度指标量化数据,作为 BP 神经网络算法训练的输入项<sup>[10-13]</sup>。

### 1.3 数据集处理

由于 BP 神经网络在运算过程中涉及求导运算,数据集中的数据必须为数值型,如向量、矩阵或纯数值,才能满足连续可导函数条件。

机坪泛光照明预测结果的输出项,通常是以各种定性属性作为特征值,例如优、良、中、差等,显然不是数值型数据,需对其进行转换<sup>[14]</sup>。以高杆灯的安装点位为例,本研究规定其输出的量化范围为 1.1~1.7,分别对应上述安装点位的 7 个位置。本研究将 315 组 BP 神经网络运算数据集随机划分为训练样本和测试样

本,分别为 280 组和 35 组;利用训练样本对神经网络模型进行训练,并用测试样本进行验证,以提高预测的准确性与可靠性。

## 2 PSO-BP 神经网络原理

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络。针对机坪泛光照明问题,本研究建立的 BP 神经网络结构如图 3 所示,图 3 中共包含 3 层前馈网,即输入层、隐含层和输出层。其中,输入层包含 8 个节点,输出层包含 4 个节点,可看作是一个 8 维向量到一个 4 维向量的映射。隐含层神经元的数量是需要考虑的重要参数之一,如果使用的隐含层神经元数量太少,网络就不够健壮,无法做出好的预测。相反,冗余的隐含层神经元还会导致过拟合<sup>[15]</sup>。

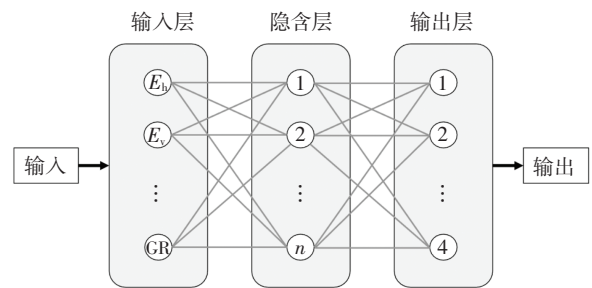


图 3 机坪泛光照明网络结构模型

Fig.3 Structure model of apron floodlighting network

基于文献[16]的研究选取激励函数,同时为了消除数据量纲差异的影响,加快模型收敛速度,将输入变量线性归一化到(-1,1)之间,并用 PSO 算法对权值和偏置项等网络的核心参数进行了优化。在 PSO 算法中,每一个潜在的优化解都被抽象为  $d$  维搜索空间中的一个“粒子”。所有粒子均有一个由优化目标函数决定的适应度值,用于评价其当前位置的优劣。此外,每个粒子还被赋予一个速度,该速度决定了其下一次移动的方向和距离。在迭代过程中,粒子会根据自身以及整个群体的历史最优经验来动态调整飞行轨迹,从而在解空间中进行搜索。

假设在一个  $d$  维的目标搜索空间中,存在一个由  $N$  个粒子组成的种群,则第  $i$  个粒子的位置可表示为一个  $d$  维向量,即

$$\mathbf{X}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,d}) \tag{1}$$

式中: $\mathbf{X}_i$  代表粒子  $i$  的完整空间位置; $x_{i,d}$  则特指粒子  $i$  在第  $d$  维空间中的具体坐标分量。

对应地,第  $i$  个粒子的飞行速度  $\mathbf{V}_i$  也是一个  $d$  维的向量,即

$$V_i = (v_{i,1}, v_{i,2}, \dots, v_{i,d}) \quad (2)$$

式中,  $v_{i,d}$  代表粒子  $i$  在第  $d$  维空间上的速度分量。

在搜索过程中,每个粒子会记录其自身到目前为止所发现的最优位置,这被称为个体极值(personal best position),可表示为

$$p_{\text{best}} = (p_{i,1}, p_{i,2}, \dots, p_{i,d}) \quad (3)$$

式中:  $p_{\text{best}}$  是粒子  $i$  的个体最优解向量;  $p_{i,d}$  是该粒子在其历史轨迹中于第  $d$  维空间上找到的最优坐标。

整个粒子群在整个迭代过程中搜索到的最优位置为全局极值(global best position),可表示为

$$g_{\text{best}} = (p_{g,1}, p_{g,2}, \dots, p_{g,d}) \quad (4)$$

式中:  $g_{\text{best}}$  代表整个粒子群发现的历史最优解向量;  $p_{g,d}$  指这个全局最优位置向量在第  $d$  维空间上的坐标分量。

在找到这 2 个最优值时,粒子根据以下公式来更新自己的速度  $v_{i,d}'$  和位置  $x_{i,d}'$ ,可表示为

$$v_{i,d}' = w \times v_{i,d} + c_1 r_1 (p_{i,d} - x_{i,d}) + c_2 r_2 (p_{i,d} - x_{i,d}) \quad (5)$$

$$x_{i,d}' = x_{i,d} + v_{i,d}' \quad (6)$$


式中:  $c_1$  和  $c_2$  为学习因子;  $w$  为惯性权重;  $r_1$  和  $r_2$  为  $[0, 1]$  范围内的均匀随机数。在本研究的算法实现中,学习因子  $c_1$  和  $c_2$  的取值基于常见的 PSO 参数设置均设定为 2.0,以确保算法在搜索空间中具有较好的探索和开发能力。在每次迭代中,粒子会依据其个体最优位置和种群的全局最优位置来更新自身的速度和位置。

### 3 建模结果与讨论

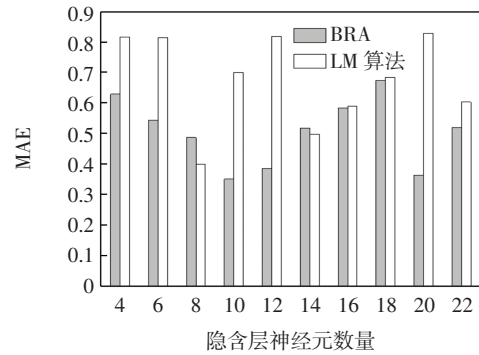
#### 3.1 模型优化

为了获得最优的 BP 神经网络的训练效果,分别采用 Levenberg-Marquardt (LM) 算法和贝叶斯正则化算法 (BRA, Bayesian regularization algorithm) 对不同隐含层神经元数量下的训练效果进行量化分析,以平均绝对误差 (MAE, mean absolute error) 作为比较的依据,结果如图 4 所示。从图 4 可以看出,大部分情况下,使用 BRA 训练的模型相比使用 LM 算法训练的模型具有更低的 MAE 值,且更加稳定,更适合泛光照明分析类型,因此,选用 BRA 作为模型训练算法。

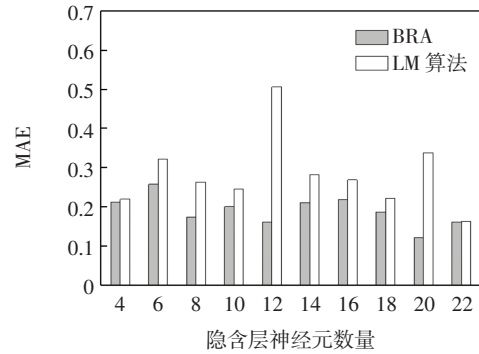
隐含层神经元数量是决定神经网络表示能力和学习能力的关键参数。基于上述数据集,本研究采用的 BP 神经网络模型的隐含层神经元数量确定为 12 个。决定 BP 神经网络训练效果的另一关键因素是初始权重和偏置值的取值。对于普通 BP 神经网络训练,上述参数通常是由 Matlab 随机选取的,这有可能导致模型 MAE 结果的不稳定。对此,采用 PSO 算法优化 BP 神经网络训练效果。图 5 中横轴为迭代次数,纵轴为测




(a) GSE 点位



(b) 安装高度



(c) 灯具数量



(d) 垂直俯仰角

图 4 测试集数据中 LM 算法和 BRA 训练的不同隐含层神经元数量下 MAE 值

Fig.4 MAE values of the number of different hidden layer neurons trained by the LM algorithm and BRA in the test set data




图 5 PSO 算法优化过程

Fig.5 Optimization process of PSO algorithm

试数据集与模型预测输出之间的均方根误差(RMSE,

root mean square error),也称为适应度值  $F$ 。 $F$  会随迭代次数增加而逐步降低直至收敛,误差也随之减小,通过 PSO 算法优化后可在最后一代获得最优化模型。

### 3.2 模型验证

以随机抽取的 35 组数据集作为 BP 神经网络测试样本,经过预处理、寻优、预测输出等步骤,获取各工况下泛光照明输出项特征参数,并与实际泛光照明安装方案进行比较,结果如图 6 所示。通过相对误差分析确定 BP 神经网络模型和改进的 PSO-BP 模型预测准确性。从图 6 可以看出,多数情况下 PSO-BP 网络较 BP 网络预测值都更贴近实际值。

图 7 为测试集数据相对误差与回归曲线,可以

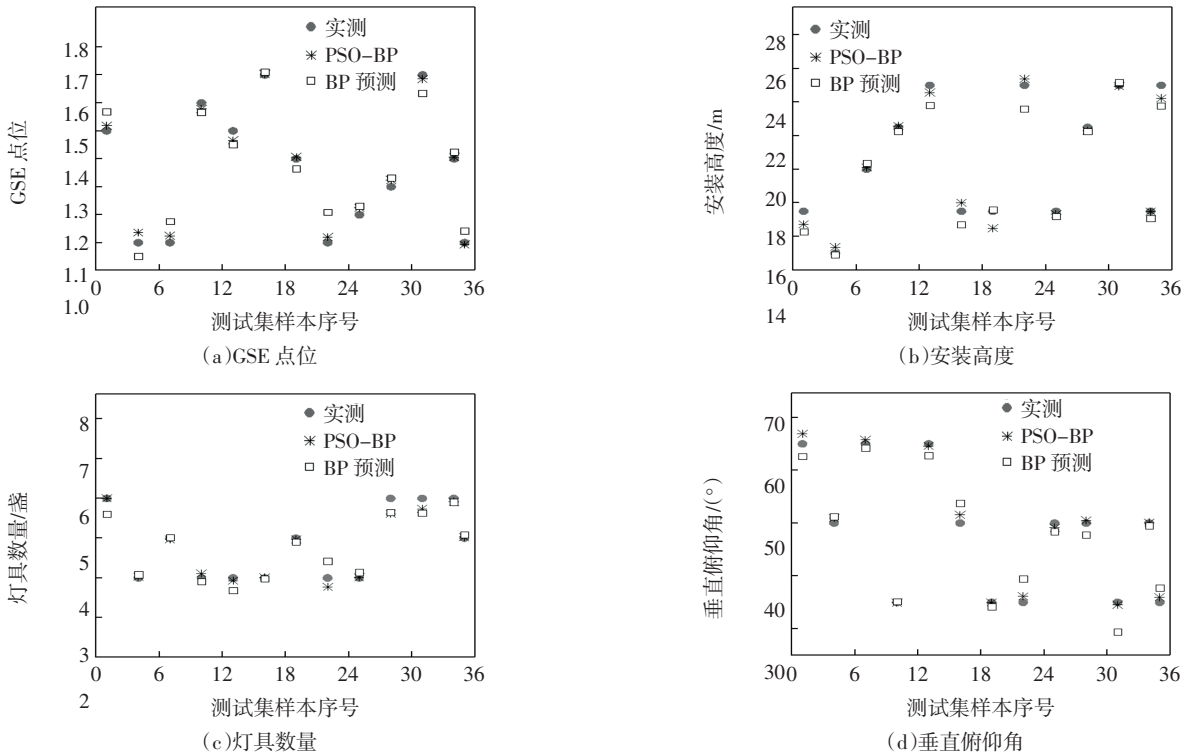


图 6 实测值与两类预测值散点图

Fig.6 Scatter plots of measured values and two types of predicted values




图 7 测试集数据相对误差与回归曲线

Fig.7 Relative error and regression curve of test set data

看出,图 7(a)中大部分相对误差(预测值与实测值的差值)小于 3%;图 7(b)中,35 组测试集预测值与实际值展现了良好的相关性, $R$  值大于 0.96,这表明本研究所建立的优化 PSO-BP 模型具有较高的预测精度。

当前行业泛光照明仅是以满足标准要求作为组织设计目标,需要经过大量仿真模拟和试算获得可行的照明方案,因而成本高昂。若要进一步满足局部照度要求,所需试算分析工作量将呈几何级数增长,这将极大地限制分析效率的提升。使用 PSO-BP 照度预测模型,可大幅提升照明方案设计效率。具体照明设计流程如图 8 所示。

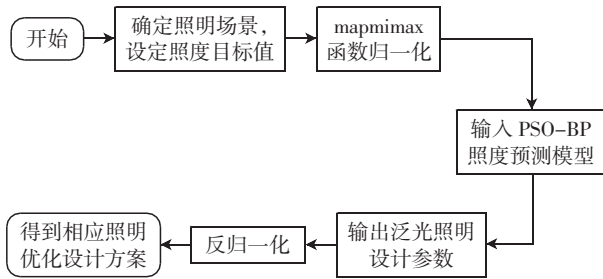


图 8 照明设计流程

Fig.8 Lighting design process

### 4 模型应用

某中部地区机场存在泛光照明节能改造需要,拟将原 1 000 W 的高压钠灯更换为 400 W 的 LED 灯具,需在满足照度要求的基础上改善节能水平。该机场泛光照明基础设施现状为:全场共 13 基高杆灯,每基高杆灯盘上有 9 盏高压钠灯。

改造要求 1:1 更换 LED 灯具,且满足机位工作区范围内水平目标照度  $E_h$  为 30 lx,垂直目标照度  $E_v$  不小于 20 lx,GR 目标值设为 40,分区评价指标目标值大于 15 lx。考虑航空器停放对实际照明分布的影响,故而对均匀度  $U$  不作要求,设为 0.04。将上述照度设计目标要求按前述照明设计流程得到照度设计方案,方案建议 GSE 安装点位为 HM4,安装高度为 21.2 m,灯具数量为 3 盏,垂直俯仰角  $\theta_l$  为 45.8°,按照照度设计方案在 DIALux evo 中进行照度仿真,所得仿真结果均满足或优于照度设计目标。DIALux evo 中局部机位仿真结果如图 9 所示,某机场 PSO-BP 模型与 DIALux evo 仿真结果如表 1 所示。




图 9 照明设计方案局部仿真结果

Fig.9 Partial simulation results of lighting design scheme

表 1 某机场 PSO-BP 模型与 DIALux evo 仿真结果

Tab.1 Simulation results of an airport by PSO-BP model and DIALux evo

项目	参数	PSO-BP	DIALux evo
输入	$E_h/lx$	30	30.1
	$E_v/lx$	20	18.7/21.8
	$U$	0.04	0.03
	GR	40	43
	$E_{free}/lx$	>15	31.3
	$E_{wing}/lx$	>15	41.7
	$E_{middle}/lx$	>15	24.6
	$E_{tail}/lx$	>15	15.9
输出	GSE 点位		HM4
	安装高度/m		21.2
	灯具数量/盏		3.0
	$\theta_l/(^\circ)$		45.8

### 5 结语

本文结合机坪泛光照明方案设计的研究现状和神经网络算法思想,提出一种基于 PSO-BP 神经网络的泛光照明优化预测模型,基于不同照明场景实例验证了模型的有效性,并与单纯 BP 神经网络方法所建立的预测模型进行了对比,得出如下结论。

(1)本文以 PSO 算法优化 BP 神经网络的初始权值和阈值,从而构建 PSO-BP 泛光照明优化预测模型,与 BP 神经网络预测模型对比,在 RMSE、MAE 等指标上均有改善,预测精度更高。

(2)PSO-BP 预测模型经实际运行场景验证,可以有效且准确地预见照明方案合规性,能够很好地应用于不同照明场景下的照明方案设计中。

(3)改进的 PSO-BP 算法通过识别其模型参数,可以根据照度参数要求快速获取相匹配的安装方案,实现了由照度参数到安装方案的逆向过程;一定程度上降低了照度方案设计过程中的主观性和随机性,避免设计者在机坪泛光照明精细化仿真时盲目试算;优化了泛光照明方案设计流程,推动该领域向去经验化设计方向发展。未来可进一步完善并在实际工程中应用。

**参考文献:**

[1] DAVIS R G, WILKERSON A M. Philadelphia international airport apron lighting: led system performance in a trial installation[R]. Richland: Pacific Northwest National Lab, 2015.

[2] 陈 强. 机坪泛光照明高杆灯 LED 改造及智能化控制建设探讨[J]. 光源与照明, 2020(11): 22-24.

[3] MUBARAK R R, LAMTIAR S, CALLISTA A B. Prototipe kontrol dan monitoring remote apron floodlight berbasis mikrokontroler dengan modul dimmer[J]. Journal of Airport Engineering Technology (JAET), 2022, 3(1): 37-47.

[4] WAYAN S Y I. Analisis konsumsi energi untuk efisiensi kelistrikan pada penggunaan sistem tata cahaya apron flood light Bandar udara [J]. Jurnal Kajian Teknik Elektro, 2022, 6(2): 54-61.

[5] 沈俊超. 基于粒子群算法的配电系统照明设备节能控制方法研究[J]. 光源与照明, 2023(10): 151-153.

[6] 朱菊香, 谷 卫, 罗丹悦, 等. 基于 PSO 优化 BP 神经网络的多传感器数据融合[J]. 中国测试, 2022, 48(8): 94-100.

[7] BARTSEV A A. Apron lighting design including aircraft shadows[J]. Light & Engineering, 2002, 10(2): 47-52.

[8] ICAO. Annex 14 to the convention on international civil aviation— aerodromes: volume i— aerodrome design and operations: 8th ed [S]. Montreal: ICAO, 2018.

[9] 中国民用航空局. 民用机场机坪泛光照明技术要求: MH/T 6108— 2014[S]. 北京: 中国民航出版社, 2014.

[10] 范 勇, 裴 勇, 杨广栋, 等. 基于改进 PSO-BP 神经网络的爆破振动速度峰值预测[J]. 振动与冲击, 2022, 41(16): 194-203.

[11] 石宸睿, 田 露, 徐 湛, 等. 基于 PSO-BP 的应急通信感知装备效能评价方法[J]. 系统工程与电子技术, 2022, 44(11): 3455-3462.

[12] 周 中, 张俊杰, 丁昊晖, 等. 基于 PSO-BP 神经网络的隧道绿色建造污水处理预测模型[J]. 铁道科学与工程学报, 2022, 19(5): 1450-1458.

[13] YANG J Y, YANG H, YANG X, et al. Optimal design of digital FIR filters based on back propagation neural network[J]. IEICE Electronics Express, 2023, 20(1): 20220491.

[14] 刘伟吉, 冯嘉豪, 祝效华, 等. 基于动量自适应学习率 PSO-BP 神经网络的钻速预测模型研究[J]. 科学技术与工程, 2023, 23(24): 10264-10272.

[15] 杨春宇. 建筑物照明亮度设计引入神经网络算法研究[J]. 建筑科学, 2008, 24(12): 81-84.

[16] PIOTROWSKI A P, NAPIORKOWSKI J J. A comparison of methods to avoid overfitting in neural networks training in the case of catchment runoff modelling[J]. Journal of Hydrology, 2013, 476: 97-111.

(责任编辑:刘雅婷)

(上接第 30 页)

[10] 涂 钰. 基于贝叶斯优化集成学习算法的航班延误预测融合模型研究[D]. 成都: 西南交通大学, 2021.

[11] 王 辉, 张文杰, 刘 杰, 等. 基于分类回归决策树算法的航班延误预测模型[J]. 中国民航大学学报, 2022, 40(3): 35-40.

[12] 刘 博, 叶博嘉, 田 勇, 等. 航班延误预测方法研究综述[J]. 航空计算技术, 2019, 49(6): 124-128.

[13] STEFANOVIČ P, ŠTRIMAITIS R, KURASOVA O. Prediction of flight time deviation for Lithuanian Airports using supervised machine learning model[J]. Computational Intelligence and Neuroscience, 2020, 2020 (1): 8878681.

[14] RODRÍGUEZ-SANZ Á, COMENDADOR F G, VALDÉS R A, et al. Assessment of airport arrival congestion and delay: prediction and reliabil-

ity[J]. Transportation Research Part C: Emerging Technologies, 2019, 98: 255-283.

[15] KHANMOHAMMADI S, TUTUN S, KUCUK Y. A new multilevel input layer artificial neural network for predicting flight delays at JFK airport[J]. Procedia Computer Science, 2016, 95: 237-244.

[16] 刘中祥, 王 欣. 基于随机森林回归的航班延误预测[J]. 现代计算机, 2019, 25(15): 20-24.

[17] 曹卫东, 张金迪, 刘晨宇. 基于 ST-LightGBM 的机场离港航班延误预测[J]. 陕西科技大学学报, 2023, 41(4): 166-172.

[18] 徐海文, 汪 腾. 考虑航路网络结构的离场航班延误预测模型[J]. 科学技术与工程, 2023, 23(11): 4734-4744.

(责任编辑:明 月)