光电技术及应用

DOI：10.16818/j.issn1001－5868.20250709002

一种基于深度学习的荧光粉型LED色温预测新方法

郭兰辉[1,2]，何剑锋[1,2*]，徐　杰[1,2]，余　鑫[1,2]，崔　剑[3]，李卫东[3]，曾民晨[3]

（1. 东华理工大学 江西省核地学数据科学与系统工程技术研究中心，南昌 330013；2. 东华理工大学人工智能与信息工程学院，南昌 330013；3. 南昌科瑞普光电科技有限公司，南昌 330117）

摘　要： 针对传统荧光粉型发光二极管（LED）封装方式在实现目标色温调控过程中需频繁实验而导致效率低下、生产成本高的问题，提出一种基于多层感知机（MLP）的荧光粉型LED色温预测方法，旨在实现荧光粉配比的智能化和色温的精准预测。该方法利用Light Tools光学仿真软件建立LED封装模型，系统研究三色荧光粉配比、荧光粉粒子总数及粒径大小与色温的映射关系，构建了相应的训练数据集。在此基础上建立了MLP神经网络预测模型，通过独立数据集验证模型的性能。结果表明，模型预测值与真实值具有良好的一致性，平均决定系数R^2达到0.915 8，表明所构建的模型具有优异的泛化能力和预测精度，可为LED封装工艺优化提供技术支持。

关键词： LED封装；荧光粉；色温；神经网络；多层感知机

中图分类号： TN312.8　**文章编号：** 1001－5868(2025)05－0892－07

Study on Deep-Learning-Based Color Temperature Prediction Methods for LED Phosphors

GUO Lanhui[1,2], HE Jianfeng[1,2], XU Jie[1,2], YU Xin[1,2], CUI Jian[3], LI Weidong[3], ZENG Minchen[3]

(1. Jiangxi Engineering Technology Research Center of Nuclear Geoscience Data Science and System, East China University of Technology, Nanchang 330013, CHN; 2. College of Artificial Intelligence and Information Engineering, East China University of Technology, Nanchang 330013, CHN; 3. NanChang CREP Optoelectronics & Technology Co. Ltd., Nanchang 330117, CHN)

Abstract: Achieving target color temperatures in LED packaging using traditional red, green, and blue phosphors combined with ultraviolet LED chips is restricted by three factors—requirement of frequent experimentation, low efficiency, and high production costs. Therefore, in this study, a color temperature prediction method, based on a multilayer perceptron (MLP), is proposed for LED phosphors. This method enables intelligent optimization of phosphor ratios, supporting accurate prediction of color temperatures. An LED packaging model was established, using the Light Tools optical simulation software, to systematically investigate the relationship mapping among the ratios of three color phosphors, total number of phosphor particles, particle size, and color temperature. A corresponding training dataset was constructed, and an MLP neural network prediction model was developed, whose performance was then validated using an independent dataset. The values predicted by the proposed model are in good agreement with the actual values, with an average coefficient of determination (R^2) of 0.915 8. This result confirms the excellent generalization ability and prediction accuracy of the proposed model, which can thus provide technical support for optimizing LED packaging processes.

Key words: LED packaging; phosphor; color temperature; neural network; multilayer perceptron

收稿日期：2025－07－09.

基金项目：江西省赣江新区科技计划项目（H202400102）.

* **通信作者：**何剑锋

0　引言

发光二极管(LED)因其寿命长、成本低、发光率高等特点,已成为现代照明和显示技术的基础[1]。目前市场上主流的LED器件多采用YAG：Ce^{3+}商用黄色荧光粉与蓝光LED芯片结合方式和红、绿、蓝三色荧光粉与紫外LED芯片结合方式[2]。其中,红、绿、蓝三色荧光粉与紫外LED芯片结合方式具有较高的显色指数,光谱更接近自然光,色彩还原更准确,并且可以通过调整荧光粉组成来精确设计光谱。荧光粉是一种典型的光致发光材料,具有色彩丰富性好、色彩饱和度高、光学性能优越等优势[3]。2007年,刘霁等介绍了光转换法中白光LED用荧光粉的制备方法,并总结了白光LED荧光粉种类[4]。2017年,陈盛雄等利用“中间参数A”的方法生产的白光LED的色温与目标色温的误差在50 K以内,该方法在预测高色温时比“直接探索色温与荧光粉浓度的关系”的方法更精确,精度提高一个数量级[5]。作为LED组件的重要组成部分,荧光粉的性能配比会直接影响到LED的光谱特征,而传统的LED封装方式往往依赖频繁的实验试错,这样不仅浪费人力物力,而且无法系统性探索各荧光粉配比与色温之间的深层次关联。

近年来,人工智能的快速发展为此提供了解决思路。2019年,裴洪等综述了机器学习在设备剩余寿命预测中的应用,包括神经网络、支持向量机、深度学习等方法,通过多层感知机(MLP)人工神经网络对复合材料结构监测数据进行分析,展示了深度学习在预测分析中的优势和应用前景[6]。2021年,Yuan等提出具有两步学习算法的封闭式网络,以建立设计参数与热老化负载和LED产品的发光输出之间的经验关系。该方法的灵活性通过将其与不同的神经网络体系结构集成得到验证,结果表明在热老化2 160小时后,LED的光通量折旧(Lumen)、相关色温(CCT)和色坐标的差异分别为1.6%,1.9%和1.1%[7]。2024年,Novita等通过比较分析七种不同的回归模型,发现线性回归、鲁棒回归和Lasso回归在预测Mn^{4+}掺杂晶体的红色荧光粉材料性能方面表现最佳[8]。2025年,Shi等研究基于机器学习方法对发光材料的发射波长进行预测和探索,进一步验证机器学习方法在发光材料的波长预测方面具有巨大的应用潜力[9]。深度学习模型凭借其强大的非线性映射能力,能够从历史数据中挖掘材料组分与性能之间的内在联系,为荧光粉材料的性能预测和优化提供了新的可能性[10]。基于此,本文提出一种基于深度学习的荧光粉型LED色温预测方法,为工业LED封装和色温调控提供技术支持和新思路。

1　理论基础

1.1　多层感知机

MLP[11]是一种前馈式人工神经网络,由多层神经元组成,是深度学习领域经典的神经网络架构之一[12]。MLP主要包含三层结构,输入层、一个或多个隐藏层和输出层。每一层由多个神经元组成,相邻层之间的神经元通过权重连接,具有非线性映射能力、较高并行性及全局优化的特点。MLP网络能够将输入的数据$\{c_1, c_2, c_3 \cdots c_n\}$与目标的输出数据$O$进行拟合：

$$F_1 = RELU(\boldsymbol{W}_{f1}\{c_1, c_2, \cdots, c_n\} + \boldsymbol{b}_{f1}) \quad (1)$$

$$F_k = RELU(\boldsymbol{W}_{fk}F_{K-1} + \boldsymbol{b}_{fk}), k = 2, 3, \cdots, K \quad (2)$$

$$O = RELU(\boldsymbol{W}_O F_k + \boldsymbol{b}_O) \quad (3)$$

式中,K为隐藏层层数;RELU为激活函数;$\boldsymbol{W}_{fk}$,$\boldsymbol{b}_{fk}$分别为每个隐藏层的权重矩阵、偏置值;F_k为隐藏层的输出;$\boldsymbol{W}_O$,$\boldsymbol{b}_O$分别为网络输出O的权重矩阵、偏置。

1.2　正则化方法

在深度学习模型中,尤其是在数据量较为有限的情况下,过拟合问题往往较为严重。为解决该问题,本文在标准的MLP上引入了多种正则化技术,旨在通过限制模型参数的自由度提高其泛化能力。具体而言,主要使用了三种互补的正则化策略：Dropout, BatchNormalization和早停机制。其中Dropout技术会在训练过程中随机丢弃一部分神经元及其连接,模拟集成学习中的多模型平均效果,从而有效防止网络对特定神经元路径的过度依赖[13];BatchNormalization通过标准化每一层的输入分布,不仅加速了模型收敛过程,还提供了一定的正则化效果,使模型对输入数据分布变化更具鲁棒性[14-15];早停策略则通过监控验证集性能,在模型开始过拟合时及时终止训练,是一种简单而有效的正则化方法[16]。

2　基于深度学习的荧光粉型LED色温预测方法研究

所提出的基于深度学习的荧光粉型LED色温预测的模型建立主要包括数据集的获取,数据预处理,构建MLP模型,在隐藏层中添加Dropout层和

BatchNormalization，最后运用早停策略。整体流程见图1所示。

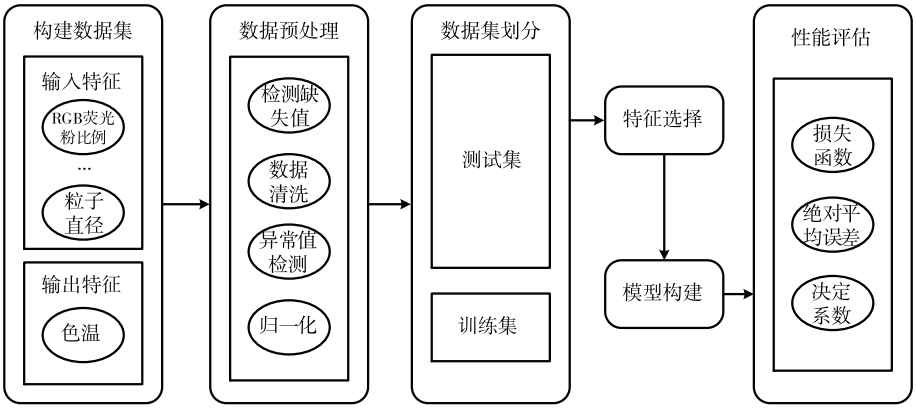


图1 整体流程图

2.1 数据集构建及数据预处理

由于传统的点胶法封装LED存在同批次空间一致性差的问题，且对RGB荧光粉的比例、总浓度和荧光粉粒子大小的数据采集困难、误差大。因此，本文使用专业光学仿真软件Light Tools进行数据集的构建。首先在Light Tools中构建好LED模型，包括光源、荧光层、接收器等，如图2所示。

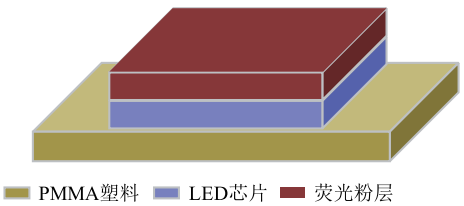


图2 荧光粉型LED模型结构示意图

其中，光源采用一个0.01 mm×0.5 mm×0.5 mm的表面光源，让其上表面发光。在发光面创建一个0.005 mm×0.5 mm×0.5mm的透镜，透镜的材料用RGB三色荧光粉填充。在光源的Z轴正方向3 mm处放置一个3 mm×3 mm的接收器，用于以接收光源发出的光信号。模拟开始后，相应的数据可以在Light Tools中导出，从而构建所需的数据集。

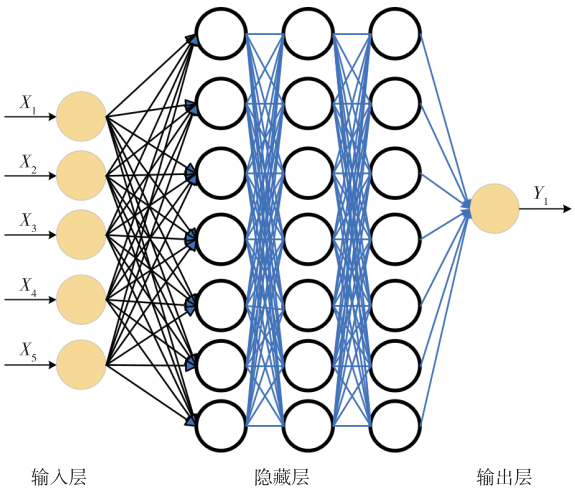
为确保LED荧光粉数据的质量和一致性，采用以下数据预处理方法。首先，通过数据加载和验证环节对数据集进行检查，验证必要特征列和目标列的完整性，并检测数据中的缺失值情况。随后对数据集进行数据清洗，如果数据集中存在缺失值则使用中位数法进行填充，对于超出范围的异常值则将其限定在合理范围内予以修正。下一步对数据集采用MinMaxScaler方法将特征值和目标值归一化到[0,1]区间，这不仅有助于加速模型收敛，还能有效防止某些特征因数值范围较大而导致的模型训练过程中某些特征主导现象。

$$x_{\text{norm}}=\frac{x-x_{\min}}{x_{\max}-x_{\min}}\times(b-a)+a \tag{4}$$

式中，x_{norm}为归一化结果，即最终的标准化数据值；x为原始数据值，待为归一化的单个数据点；$x_{\min}$为该特征在整个数据集中的最小值；$x_{\max}$为该特征在整个数据集中的最大值；a和b为目标跨度，即新的数据范围大小。最后对数据集进行分割，将数据集按8:2的比例划分为训练集和测试集。

2.2 基于深度学习的荧光粉型LED色温预测模型构建

在本研究所提基于深度学习的荧光粉型LED色温预测的核心算法中，MLP模型采用经典的层级结构，如图3所示。



X_1：红色荧光粉比例 X_2：绿色荧光粉比例 X_3：蓝色荧光粉比例
X_4：荧光粉浓度总数 X_5：荧光粉粒子大小 Y_1：色温

图3 模型结构图

其中，输入层的神经元数量与输入特征维度一致，输出层的神经元数量与输出特征维度一致。

将RGB三色荧光粉比例、荧光粉粒子总浓度和粒径作为输入特征，色温作为输出特征。模型采用三层全连接神经网络结构，隐藏层神经元数依次为128，64和32。训练过程中，逐层递减设计有助于模型逐步提取更高层次的特征表示，可控制参数数量，避免过拟合；同时，设置batch size为32，学习率为0.001。

2.2.1　模型正则化设计

为提高MLP模型在荧光粉型LED性能预测任务上的泛化能力和鲁棒性，本文系统性地引入了正则化技术。在每个隐藏层的激活函数后添加BatchNormalization，批量归一化能解决深度神经网络中的内部协变量偏移问题。而Dropout层被添加在每个批量归一化层之后，将其丢弃率设置为0.2。Dropout通过训练过程中随机关闭部分神经元，可以实现防止特征共适应，减少过拟合风险效果。具体如下：

$$M_{i,j}\sim Bernoulli(p),p\in[0,1)\,\boldsymbol{x}_{\text{out}}=\boldsymbol{x}\odot\boldsymbol{M}\times\frac{1}{1-p_{\text{drop}}} \tag{5}$$

$$E[\boldsymbol{x}_{\text{out}}]=E\left[\boldsymbol{x}\times\frac{\boldsymbol{M}}{1-p_{\text{drop}}}\right]=\boldsymbol{x}\times\frac{E[\boldsymbol{M}]}{1-p_{\text{drop}}}=\boldsymbol{x}\times\frac{1-p_{\text{drop}}}{1-p_{\text{drop}}}=\boldsymbol{x} \tag{6}$$

式中，$M_{i,j}$为掩码矩阵的第i行第j列元素；$\boldsymbol{M}$为与输入$\boldsymbol{x}$同维度的二值矩阵；$Bernoulli(p)$表示伯努利分布，参数为p；p为保留概率，取值范围为[0,1)；$\boldsymbol{x}$为进入Dropout层的原始激活值；⊙为逐元素乘法，即$\boldsymbol{x}$和$\boldsymbol{M}$对应位置元素相乘。

在隐藏层中镶嵌正则化层如图4所示。由图4可知，在每个隐藏层后依次应用BatchNormalization和Dropout技术，形成“BatchNormalization→ReLU→Dropout”的结构序列。BatchNormalization通过标准化每一层的输入数据分布，可加速模型的训练收敛过程并减少内部协变量偏移，而Dropout则通过随机丢弃神经元防止网络对特定特征过度依赖。这两种技术协同工作，结合输入特征的MinMaxScaler标准化预处理和训练过程中的早停策略，构建完整的正则化体系，有效控制了模型过拟合风险。输出层作为网络的最终层，负责产生预测结果，该层只有一个结点，对应色温的预测值。

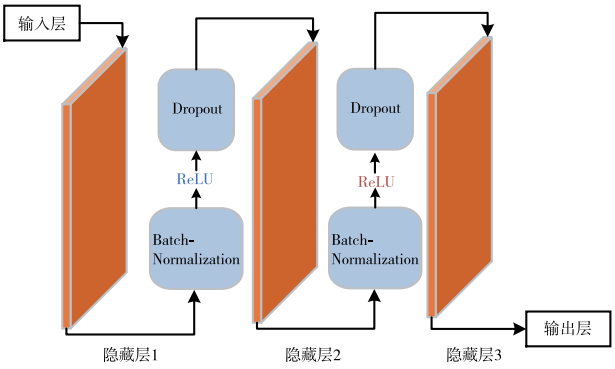


图4　隐藏层结构图

此外，在MLP中引入早停机制，当验证性能开始下降时在MLP中引入早停机制，避免了依赖于手动设置固定训练轮数的局限性。该策略保留了泛化能力最强的模型状态，从而确保了训练的合理性，可以有效防止过拟合现象。

3　实例验证

3.1　数据来源

为验证所提出的基于深度学习的荧光粉型LED色温预测模型的有效性，采用约束随机采样方法生成1 000种不同配比的RGB荧光粉数据并由Light Tools仿真。其中，数据生成遵循以下物理约束条件：RGB三色荧光粉比例之和为1，各色荧光粉比例在[0,1]区间内分布；荧光粉粒子总浓度在5 000～100 000颗/mm^{3}范围内分布，荧光粉粒子直径在200 nm～10 μm范围内随机生成。考虑到紫外LED芯片的发光机理，完全随机的RGB比例配置往往会导致色温过高，偏离实际应用需求。因此，采用分层采样策略：50%的样本采用红色荧光粉高比例配置（红色比例60%～100%，绿蓝比例在剩余范围内随机分配），以覆盖实用色温区间；另外50%的样本保持完全随机分配，以维持参数空间的全面覆盖。

3.2　相关度分析

将基于深度学习的荧光粉型LED色温预测模型的输入特征与输出特征之间的相关性进行分析，通过对数据集的样本数据进行统计分析，揭示不同荧光粉配比参数与LED光学性能指标之间的内在关联。表1为各参数展示情况。

LED荧光粉的许多物理特性与光学性能之间往往存在线性或近似线性的关系，RGB荧光粉的比例变化与最终光学性能之间的关系也通常表现为线性或分段线性，而皮尔逊相关系数能够精确量化

这种线性关系的强度和方向[17]。因此，使用皮尔逊相关系数计算数据之间的关系，如图5所示。

表1 各参数展示

序号	红色荧光粉比例	绿色荧光粉比例	蓝色荧光粉比例	粒子总数/(1•mm^{-3})	荧光粉粒子大小/nm	色温/K
1	0.042 4	0.792 3	0.165 2	929 612	10 442	10 442
2	0.169 9	0.774 2	0.055 8	896 987	602	7 961
…	…	…	…	…	…	…
1 000	0.783 6	0.105 2	0.111 0	869 478	2 157	5 815

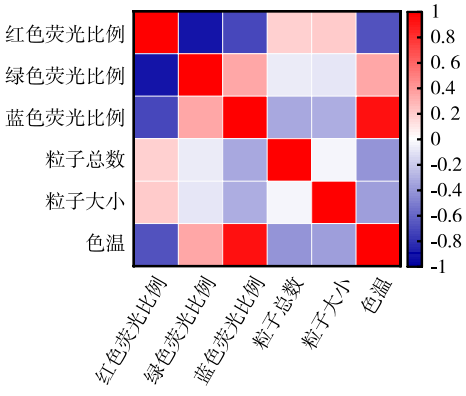


图5 相关参数数据相关度

由图可知，色温与RGB三基色比例呈现出显著的相关关系：与红色比例呈明显负相关(−0.76)，表明红色荧光粉比例增加会显著降低色温；与蓝色比例呈强烈正相关(0.86)，表明增加蓝色荧光粉比例可有效提高色温；与绿色比例呈弱正相关(0.12)，对色温影响相对较小。这一结果符合色彩理论预期，红色光谱成分增加会使光源偏暖使色温降低，而蓝色光谱成分增加则使光源偏冷使色温升高。

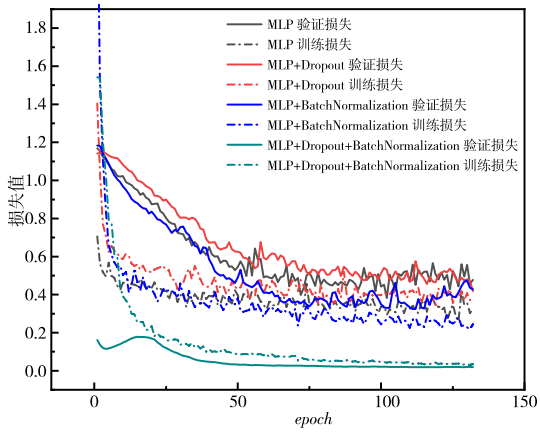
3.3 模型训练结果

为了进一步验证所提出的基于深度学习的荧光粉型LED色温预测模型的有效性，对创建的数据集按8:2的比例进行分割和数据预处理。为精确评估模型预测的准确性，使用损失函数、平均绝对误差(MAE)和决定系数(R^2)三种评价指标来评价模型性能。

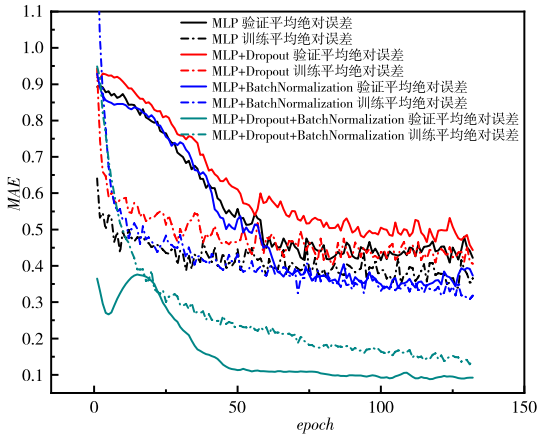
3.3.1 消融实验

为证实所提正则化方法的有效性，设计了4组消融实验，分别为基线MLP，MLP+Dropout，MLP+BatchNormalization，MLP+Dropout+BatchNormalization通过去除BatchNormalization组件和Dropout组件来分析其对模型的具体影响，结果如图6所示。

由图6(a)和(b)可知，基线MLP模型表现出典型的过拟合现象，训练损失持续下降至约0.3，而验证损失在50轮后稳定在0.5左右，训练MAE和验证



(a) 损失函数训练过程监控图



(b) 平均绝对误差训练过程监控图

图6 训练过程监控图

MAE之间存在显著差距，表明模型对训练数据过度拟合，泛化能力有限。添加Dropout正则化后，模型性能得到显著改善，验证损失从基线的0.5降低至约0.45，改善幅度达10%，训练和验证曲线更加接近，过拟合现象明显缓解，验证MAE稳定在0.4左右，相比基线模型提升约11%。BatchNormalization的引入则主要体现在训练稳定性的提升上，收敛速度明显加快，在约80轮内即达到稳定状态，损失函数下降更加平滑，减少了训练震荡，验证MAE降低至约0.35，相比基线模型改善约22%。而同时添加了Dropout和BatchNormalization之后，可以发现模型在训练初

期（约0～25轮）表现出快速学习特性，损失函数和MAE均呈现迅速下降趋势。这表明网络权重从随机初始化状态迅速调整至更优解空间，模型对数据分布的理解在初始阶段获得显著提升。训练损失从约1.7降至0.2以下，验证损失从约0.25降至0.1以下，说明模型训练良好。在中期阶段（约25～75轮），学习曲线逐渐平缓，但仍保持稳定下降趋势。此阶段模型进入精细调整过程，权重参数的更新幅度减小，但仍在持续优化性能。值得注意的是，训练集与验证集的损失曲线始终保持相近且同步下降的态势，未出现明显分离现象，这表明BatchNormalization和Dropout等正则化技术可有效防止过拟合问题。在训练后期（75～150轮），模型性能趋于稳定，损失函数和MAE曲线几乎趋于水平。模型在训练集和验证集上分别达到约0.02和0.01的损失值，MAE分别降至约0.15和0.1。由此可知，所提基于深度学习的荧光粉型LED色温预测模型不仅具有良好的收敛性能，而且可有效缓解过拟合问题，为LED荧光粉配方优化提供了稳定可靠的预测基础。

3.3.2　预测结果分析

模型预测结果如图7所示。其中，x轴和y轴分别为标准化后的真实值和预测值。对预测结果的定量分析可知，建立的学习模型具有良好的预测能力。预测值与真实值的相关性分析显示，数据点在归一化坐标系中呈现出良好的线性分布特征，大部分观测点沿着理想预测线（$y=x$）紧密分布。模型在全色温范围内均保持了较高的预测精度，特别是在低色温段（归一化值为0.0～0.3）和高色温段（归一化值为0.7～1.0）表现尤为突出。中间色温区域虽存在适度的预测偏差，但整体预测趋势与实际测量值高度吻合，表明模型成功捕获了色温变化的内在规律。

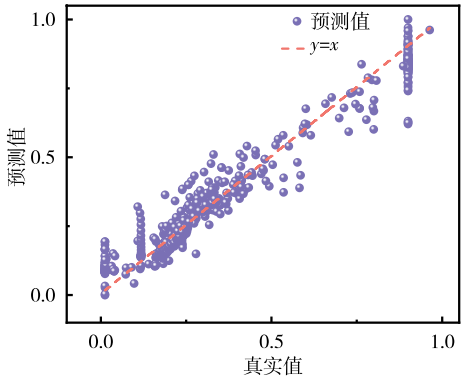


图7　预测结果散点图

对于色温预测，模型表现出较高的准确性，R^2达到0.915 8，接近理想值1.0。散点准确分布在理想预测线（红色虚线）上，表明模型能够精确捕捉LED荧光粉输入参数与色温之间的复杂关系。从2 000 K至7 000 K的宽广色温范围内，预测值与实际值吻合。

3.3.3　多模型对比实验

为了全面评估所提出模型的性能优势，选择Random Forest，XGBoost和长短记忆神经网络（LSTM）三种具有代表性的机器学习和深度学习模型进行对比实验。采用MAE、均方根误差（*RMSE*）和R^2作为评价指标，在相同的数据集划分和训练策略下进行比较，结果见表2。

表2　不同模型预测结果对比

模型	*MAE*	*RMSE*	R^2
Random Forest	0.098 8	0.140 5	0.867 3
XGBoost	0.099 9	0.129 2	0.879 6
LSTM	0.113 4	0.148 7	0.815 0
MLP＋Dropout＋BatchNormalization	0.098 6	0.137 7	0.915 8

综上可知，所提出的基于深度学习的荧光粉型LED色温预测模型，在对红、绿、蓝三色荧光粉与紫外LED芯片相结合的预测上有较好的效果，充分证明了所提模型在LED荧光粉配方设计中的实用价值，能够有效减少传统试错过程中的实验次数，加速高性能LED产品的研发进程。

4　结论

本文提出一种基于深度学习的荧光粉型LED色温预测模型。首先使用Light Tools对LED模型进行光线仿真，探究RGB三色荧光粉配比、颗粒大小、浓度与色温的关系并构建数据集。然后建立MLP预测模型，采用正则化技术提高泛化能力，经150轮迭代训练后，成功建立了以RGB荧光粉配比、总浓度、颗粒直径为输入，色温为输出的映射关系。实验结果表明，基于MLP的LED荧光粉色温预测模型的预测色温和真实色温之间的平均相关系数为0.915 8，可为LED封装工艺优化提供技术支持。通过科学的数据预处理和模型优化策略，实现了高精度的色温预测。研究结果验证了深度学习方法在LED荧光粉色温预测领域的有效性和实用性，为LED产业的智能化发展提供了重要的技术支撑，且有望在LED制造、质量控制和产品开发等领域发挥重要作用。

参考文献：

[1] 崔元日，潘苏予．第四代照明光源——白光LED[J]．灯与照明，2004，28(2)：31-34.
Cui Yuanri，Pan Suyu. The fourth generation lighting source - daylight LED[J]. Light & Lighting，2004，28(2)：31-34.

[2] 李迎光．全可见光谱LED照明用荧光粉的制备及发光性能研究[D]．杭州：浙江科技大学，2024.
Li Yingguang. Study on the preparation and luminescent properties of fluorescent[D]. Hangzhou：Zhejiang University of Science and Technology，2024.

[3] 蔡义昕，贾婧媛，王榕梓，等．基于深度学习的LED荧光粉层结构设计方法[J]．光电子技术，2024，44(4)：289-297，305.
Cai Yixin，Jia Jingyuan，Wang Rongzi，et al. Deep learning based design method for LED phosphor layer structure[J]. Optoelectronic Technology，2024，44(4)：289-297，305.

[4] 刘 霁，李万万，孙 康．白光LED及其涂敷用荧光粉的研究进展[J]．材料导报，2007，21(8)：116-120.
Liu Ji，Li Wanwan，Sun Kang. Progress in research on white light emitting diode and its phosphors[J]. Materials Review，2007，21(8)：116-120.

[5] 陈盛雄，朱大庆，廖欣怡．一种预测白光LED相关色温的新方法[J]．发光学报，2017，38(6)：820-827.
Chen Shengxiong，Zhu Daqing，Liao Xinyi. A new method for predicting correlated color temperature of white LEDs[J]. Chinese Journal of Luminescence，2017，38(6)：820-827.

[6] 裴 洪，胡昌华，司小胜，等．基于机器学习的设备剩余寿命预测方法综述[J]．机械工程学报，2019，55(8)：1-13.
Pei Hong，Hu Changhua，Si Xiaosheng，et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering，2019，55(8)：1-13.

[7] Yuan C C A，Fan J，Fan X. Deep machine learning of the spectral power distribution of the LED system with multiple degradation mechanisms[J]. Journal of Mechanics，2020，3710.1093：172-183.

[8] Novita M，Chauhan A S，Ujianti R M D，et al. Exploring deep learning and machine learning for novel red phosphor materials[J]. Journal of Luminescence，2024，269：120476.

[9] Shi X，Zhong X，Liu W，et al. Prediction and exploration of emission wavelength (or energy) of luminescent materials based on machine learning[J]. Journal of Luminescence，2025，279：121024.

[10] LeCun Y，Bengio Y，Hinton G. Deep learning[J]. Nature，2015，521(7553)：436-444.

[11] 张 驰，郭 媛，黎 明．人工神经网络模型发展及应用综述[J]．计算机工程与应用，2021，57(11)：57-69.
Zhang Chi，Guo Yuan，Li Ming. Review of development and application of artificial neural network models[J]. Computer Engineering and Applications，2021，57(11)：57-69.

[12] Taud H，Mas J F. Multilayer Perceptron (MLP)[M]// Geomatic Approaches for Modeling Land Change Scenarios. Cham：Springer International Publishing，2017：451-455.

[13] 买蕊蕊，刘 洋，陈 桂，等．基于Dropout卷积神经网络的叠前地震孔隙度预测方法[C]//第七届油气地球物理学术年会论文集，2025：307-310.

[14] Li Y，Wang N，Shi J，et al. Adaptive Batch Normalization for practical domain adaptation[J]. Pattern Recognition，2018，80：109-117.

[15] Yao Z，Cao Y，Zheng S，et al. Cross-iteration batch normalization [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)，2021：12326-12335.

[16] 李丽霞，王 彤，范逢曦．早停止策略在BP神经网络中的应用[J]．数理医药学杂志，2004，17(2)：165-167.
Li Lixia，Wang Tong，Fan Fengxi. The application of strategy of early-stopping in back-propagation neural network[J]. Journal of Mathematical Medicine，2004，17(2)：165-167.

[17] 肖 勇，赵 云，涂治东，等．基于改进的皮尔逊相关系数的低压配电网拓扑结构校验方法[J]．电力系统保护与控制，2019，47(11)：37-43.
Xiao Yong，Zhao Yun，Tu Zhidong，et al. Topology checking method for low voltage distribution network based on improved Pearson correlation coefficient[J]. Power System Protection and Control，2019，47(11)：37-43.

作者简介：

郭兰辉(2000—)，男，江西省赣州市人，硕士研究生，主要从事LED光谱特征的研究；

何剑锋(1977—)，男，江西省婺源市人，教授，博士，主要从事核数据采集与信号处理、嵌入式系统应用开发的研究。