光电技术及应用

DOI: 10.16818/j.issn1001－5868.20250122001

基于SA-LSTM的电力光缆光功率预测方法

陈锦山[1]，吴诗雨[2]，林国栋[2]，王新澜[2*]，林　树[3]，李兆祥[2]，赵丽娟[4]

（1. 国网福建省电力有限公司，福州 350001；2. 国网福建省电力有限公司电力科学研究院，福州 350007；
3. 国网福建省电力有限公司厦门供电公司，福建 厦门 361004；4. 华北电力大学 电子与通信工程系，河北 保定 071003）

摘　要： 为提高基于光功率预知光缆异常的准确性，提出一种基于模拟退火长短期记忆（Simulated Annealing-Long Short-Term Memory，SA-LSTM）算法的光功率波动预测方法。首先，对原始光功率数据进行归一化处理；随后，利用模拟退火算法对长短期记忆模型的关键超参数（包括迭代次数、隐藏层单元数和学习率）在大范围内进行全局寻优，以获得最优参数组合；最后，基于优化后的参数建立LSTM模型，用于预测光功率的未来趋势。实验结果表明，采用最优参数时，所提方法的光功率预测均方根误差为2.83×10^{-3} dB，该误差仅为光功率均值的0.14%。相较于自回归移动平均径向基函数算法、差分自回归移动平均支持向量机算法、自回归移动平均长短期记忆算法和差分自回归移动平均长短期记忆算法，预测精度分别提升了91.7%、91.0%、96.4%和96.3%。因此，所提方法能够更加准确地预测电力光缆的光功率变化趋势，具有重要的工程应用价值。

关键词： 电力光缆；光功率；长短期记忆算法；模拟退火算法

中图分类号： TN913　**文章编号：** 1001－5868(2025)03－0536－07

Simulated Annealing-Long Short-Term Memory Based Light-Power Prediction Method for Power Cables

CHEN Jinshan[1], WU Shiyu[2], LIN Guodong[2], WANG Xinlan[2], LIN Shu[3], LI Zhaoxiang[2], ZHAO Lijuan[4]

(1. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350001, CHN; 2. State Grid Fujian Electric Power Co., Ltd. Electric Power Research Institute, Fuzhou 350007, CHN; 3. State Grid Fujian Electric Power Co., Ltd. Xiamen Power Supply Company, Xiamen 361004, CHN; 4. Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, CHN)

Abstract: To improve the accuracy of predicting anomalies in optical cable systems based on optical power data, in this study, we employ the simulated annealing-long short-term memory (SA-LSTM) algorithm and predict optical power fluctuations. First, the raw optical power data are normalized. Subsequently, the SA algorithm is used to perform global optimization of the LSTM algorithm's key parameters, including the number of iterations, hidden layer units, and learning rate, across a wide range. These optimized parameters are used to construct an LSTM model that can predict future trends in optical power. Experimental results demonstrate that the optical power, predicted using the proposed method with optimal parameters, exhibits a root-mean-square error of 2.83×10^{-3} dB, which is only 0.14% of the mean value. The prediction accuracy of the proposed method is 91.7%, 91.0%, 96.4%, and 96.3% higher than those of the autoregressive moving-average radial-basis-function, autoregressive integrated moving-average support-vector-machine,

收稿日期：2025－01－22.

基金项目：国网福建省电力有限公司科技项目“非侵入式电力光纤状态感知监测与资源管理技术研究”（521304240015）.

* 通信作者：王新澜

autoregressive moving-average LSTM, and autoregressive integrated moving-average LSTM algorithms, respectively. Thus, the proposed method can predict optical power trends in power cable systems with high accuracy, showing significant potential for engineering applications.

Key words: power optical cable; optical power; long short-term memory; simulated annealing

0 引言

随着现代电力系统的快速发展，光纤通信技术在电力传输网络中的应用范围持续拓展。光纤通信在保障数据传输高效性与稳定性方面发挥了关键作用，而其中的光功率作为评估光纤通信质量的重要指标，直接反映了光缆线路的健康状态[1]。光功率的变化受到光纤物理特性、线路环境条件等多种因素的影响。由于这些影响的复杂性，光功率数据呈现出非线性、时变性等典型的时间序列特征。因此，有效分析光功率时间序列，准确预测光功率变化趋势十分重要[2-3]。

近年来，随着时间序列预测方法的不断发展，出现了多种应用于光功率预测的技术。2013年，姜万昌等[4]提出自回归移动平均（Autoregressive Moving Average，ARMA）与径向基函数（Radial Basis Function，RBF）相结合的ARMA-RBF算法用于光功率变化趋势预测。该方法通过引入RBF神经网络，部分缓解了ARMA模型的线性局限性，但仍然不足以捕捉复杂的时间序列模式。2015年，王林等[2]采用差分自回归移动平均（Autoregressive Integrated Moving Average，ARIMA）与支持向量机（Support Vector Machine，SVM）相结合的ARIMA-SVM算法进行光功率预测。尽管ARIMA-SVM算法结合了时间序列建模与机器学习方法，其性能依然受到SVM在处理非线性问题上的能力限制及ARIMA模型对数据线性特性的依赖。2019年，付浩等[5]通过自回归移动平均长短期记忆网络（Autoregressive Moving Average Long Short-Term Memory，ARMA-LSTM）算法对光功率进行趋势预测。2022年，高云鹏[6]进一步提出差分自回归移动平均长短期记忆网络（Autoregressive Integrated Moving Average Long Short-Term Memory，ARIMA-LSTM）算法用于相同领域的预测。然而，这两种方法在训练过程中未对长短期记忆（Long Short-Term Memory，LSTM）算法的参数进行有效优化，导致其易于陷入局部最优解，限制了预测精度的提升。2024年，杨菁等[7]提出基于双池化多层感知机模型的光功率预测方法，解决了光功率时常突变的问题，但其预测精度仍有待提高。因此，如何提升电力光缆线路劣化预测模型的精度，成为当前研究的重要方向。

为进一步提高光功率预测的精度，本文提出一种基于模拟退火（Simulated Annealing，SA）和LSTM相结合的SA-LSTM算法，并对电力光缆的光功率波动进行预测。首先对原始光功率数据进行归一化处理；随后利用SA算法对LSTM中的迭代次数、隐藏层单元数和学习率进行全局寻优，获得最优参数；最后利用最优参数建立LSTM模型，得到更加准确和鲁棒的预测结果。该方法有效提升了光功率预测的准确性，具有重要的工程应用价值。

1 数据处理与方法原理

1.1 数据处理

基于历史实测光功率数据，对未来光功率的变化情况进行预测。为尽可能降低预测结果中的噪声，并减小数据样本之间的差异，对输入数据进行归一化处理，将其规范到[0，1]区间，计算公式如下[1]：

$$\overline{X}_i=\frac{x_i-x_{\min}}{x_{\max}-x_{\min}} \tag{1}$$

式中，i为实验数据中第i个光功率数据，$\overline{X_i}$为归一化后的数据，x_i为原始数据，$x_{\min}$为原始数据中的最小值，$x_{\max}$为原始数据中的最大值。归一化处理不仅可以保留数据之间的关系，还能消除因不同量纲和数值范围所引起的干扰，从而提高模型对数据的理解和解释能力，并加快模型的收敛速度[8]。

1.2 LSTM算法原理

LSTM是循环神经网络（Recurrent Neural Network，RNN）的一种改进结构，通过在隐藏层中引入记忆单元，能够更好地处理时间序列数据中的长短期依赖[9]。LSTM通过若干可控的门（遗忘门、输入门、输出门）来调节信息在不同记忆单元之间的传递，从而灵活控制过去和当前信息的记忆与遗忘程度。与传统RNN相比，LSTM具有处理长期依赖的能力，有效缓解了梯度消失问题。在LSTM

的设计中，遗忘门负责决定上一时刻的“记忆”在当前时刻应保留多少；输入门则控制当前时刻的输入信息能够被存储到记忆单元的比例，进而调节“历史”信息与“当前”输入的融合程度；输出门决定从单元状态输出多少信息[10]。图1展示了LSTM的网络结构，清晰呈现了其如何通过门控机制实现更精确的时序数据建模。

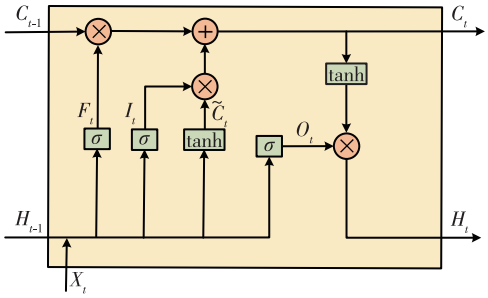


图1 LSTM的网络结构

在图1中，F_t为前一个LSTM神经元通过遗忘门后的剩余数据信息量，I_t为当前LSTM神经元的输入数据信息量，O_t为输出门在当前时刻t的状态。计算公式如下[9]：

$$F_t=\sigma\left(\boldsymbol{W}_{\mathrm{f}}\cdot\left[\boldsymbol{H}_{t-1},\boldsymbol{X}_t\right]+\boldsymbol{b}_{\mathrm{f}}\right) \tag{2}$$

$$I_t=\sigma\left(\boldsymbol{W}_{\mathrm{i}}\cdot\left[\boldsymbol{H}_{t-1},\boldsymbol{X}_t\right]+\boldsymbol{b}_{\mathrm{i}}\right) \tag{3}$$

$$O_t=\sigma\left(\boldsymbol{W}_{\mathrm{o}}\cdot\left[\boldsymbol{H}_{t-1},\boldsymbol{X}_t\right]+\boldsymbol{b}_{\mathrm{o}}\right) \tag{4}$$

$$\tilde{\boldsymbol{C}}_t=\tanh\left(\boldsymbol{W}_{\mathrm{c}}\cdot\left[\boldsymbol{H}_{t-1},\boldsymbol{X}_t\right]+\boldsymbol{b}_{\mathrm{c}}\right) \tag{5}$$

$$\boldsymbol{C}_t=\boldsymbol{f}_t\odot\boldsymbol{C}_{t-1}+\boldsymbol{I}_t\odot\tilde{\boldsymbol{C}}_t \tag{6}$$

$$\boldsymbol{H}_t=\boldsymbol{O}_t\odot\tanh\left(\boldsymbol{C}_t\right) \tag{7}$$

式中，σ为sigmoid函数，其输出值介于0和1之间；$\boldsymbol{W}_{\mathrm{f}}$，$\boldsymbol{W}_{\mathrm{i}}$和$\boldsymbol{W}_{\mathrm{o}}$为遗忘门、输入门和输出门的权重矩阵；$\boldsymbol{b}_{\mathrm{f}}$，$\boldsymbol{b}_{\mathrm{i}}$和$\boldsymbol{b}_{\mathrm{o}}$为对应的偏置项；$t$为当前时间；$t-1$为前一时间；$\tilde{\boldsymbol{C}}_t$为当前时刻$t$的单元状态；$\boldsymbol{W}_{\mathrm{c}}$为单元状态权重矩阵；$\boldsymbol{b}_{\mathrm{c}}$为单元状态偏置项；$\boldsymbol{X}_t$为输入序列；$\boldsymbol{H}_t$为最终输出；$\odot$为Hadamard乘积运算。

1.3 SA算法原理

SA是一种全局优化算法，最早由Metropolis等提出[11]。受物理退火过程的启发，SA算法首先需要确定一个初始温度，并在问题的解空间中生成一个初始状态作为起始解。随后对当前解施加扰动，模拟固体内部粒子在一定温度下的状态变化过程，生成一个新的解。新解生成后，通过评估其优劣进行更新。如果新解优于当前解，则替换当前解作为新的最优解；若新解未优于当前解，则根据Metropolis准则，以一定的接受概率p决定是否接受该解。接受概率p的表达式为[12]：

$$p=\exp\left(-\frac{C_{a+1}-C_a}{T}\right) \tag{8}$$

式中，C_a和C_{a+1}分别为目标函数在第a次和$a+1$次的迭代值，T为当前温度。在LSTM参数优化过程中，模拟退火算法能够有效避免陷入局部最优解，用于寻找算法的最佳参数组合。

2 算法优化

2.1 SA最佳参数的确定

所使用的实验数据来源于参考文献[1]，选取了保定-石家庄三天的历史光功率数据作为训练样本。共提取300个样本，其中前240个光功率数据用于训练LSTM模型，后60个则作为测试集用于验证预测结果。LSTM算法为每次预测1个时间点，通过逐步预测得到测试集光功率的变化趋势。本研究在操作系统为Windows 11，硬件配置为12th Gen Intel(R) Core(TM) i5-12500H CPU(2.50 GHz)、16 GB内存的平台上开展。算法实现和运行均基于Matlab R2022b环境。预测结果通过均方根误差(Root Mean Square Error，RMSE)作为评价指标，具体计算公式为[13]：

$$RMSE=\sqrt{\frac{\sum_{i=1}^{n}\left(\omega_i-\hat{\omega}_i\right)^2}{n}} \tag{9}$$

式中，ω_i为原始光功率数据，$\hat{\omega}_i$为预测光功率数据，n为数据长度。$RMSE$值越小，说明模型预测精度越高[14]。

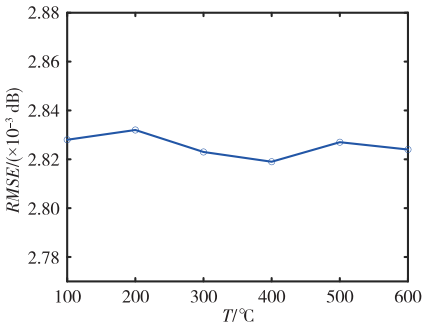
传统的超参数优化方法，如网格搜索法和随机搜索法，存在训练过程复杂、时间长、效率低等问题[15]。利用SA算法对LSTM的迭代次数、隐藏层单元数和学习率进行同时优化。首先设定LSTM网络参数初始值，依据该参数建立和训练LSTM，再利用Metropolis准则[14]评估训练好的LSTM是否满足收敛条件。若收敛，则输出优化完成的LSTM网络参数；若未收敛，则用SA算法继续优化本次迭代输出的LSTM网络参数直至收敛。SA算法能够有效避免陷入局部最优，并在较大范围内同时优化多个参数。同时SA算法的参数对以上寻优过程也有影响，本节研究这些参数对LSTM计算准确性和实时性的影响，以获得最佳的SA参数。

SA算法通过控制退火过程的温度变化完成参

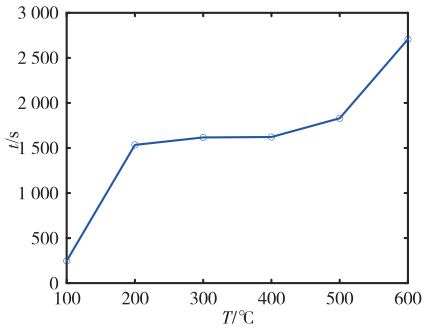
数调整。选择初始温度范围为100～600℃，迭代次数范围为1～20次，主要原因有两点：其一，随着初始温度和迭代次数的提高，算法运行时间显著增加，考虑到实际计算资源和效率的限制，选择这一范围有助于在精度与效率之间取得平衡；其二，实验结果表明，当迭代次数达到20次时，*RMSE*已趋于稳定，进一步增加迭代次数对预测性能的提升不再显著，且波动幅度较小，从而验证了20次迭代是一个合理的选择。此外，所有实验数据均经过多次执行求平均值后得出，以确保结果的可靠性和一致性。图2(a)和(b)展示了SA算法中初始温度对*RMSE*和计算时间的影响趋势，表明温度设置对模型优化性能至关重要；图2(c)和(d)则反映了迭代次数增加对*RMSE*和计算时间的影响趋势，进一步验证了优化结果对迭代次数的依赖性。

由图2可知，初始温度对模型的优化性能有一定影响。分析图2(a)可知，在本实验条件下，随着初始温度从100℃增加至600℃，*RMSE*在2.82×10^{-3}～2.84×10^{-3} dB范围内波动，变化范围较小。由图2(b)可知，随初始温度的增加，计算时间从246.08 s增加至2 706.46 s，为原来的11倍。较高的初始温度在提升全局搜索能力的同时显著增加了计算成本，另外，较高的温度使得算法进行了更广泛的解空间搜索，从而使计算时间显著增加。相比之下，在较低初始温度下，*RMSE*已经接近最优值，且计算时间较短。综合考虑*RMSE*和计算时间，后续实验中选取初始温度为100℃。

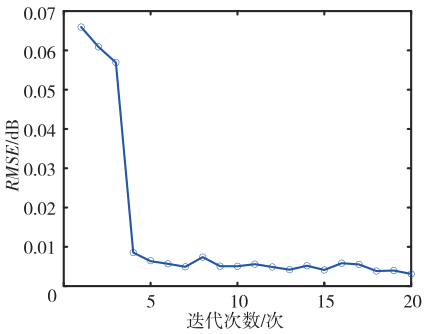
由图2可知，随着迭代次数的增加，*RMSE*逐渐减小，表明模型在优化过程中不断趋向更优的参数配置，从而提高了预测的准确性。由图2(c)可知，在迭代初期，*RMSE*的下降幅度较大，说明在该阶段模型对参数的调整更加灵活，能迅速找到适合的参数组合。随着迭代的继续，*RMSE*的下降幅度趋于平稳，这可能是由于模型已经接近最优解，进一步的参数调整对性能提升的影响减弱。由图2(d)可以看出，计算时间也随着迭代次数的增加逐渐升高。虽然SA算法的迭代次数通常会影响计算时间，但这种影响并不总是严格成正比。实际计算时间还受到其他因素的影响，如每次迭代的计算量、解的收敛情况和温度变化的控制等。综合考虑*RMSE*和计算时间，后续实验中选取迭代次数为10。



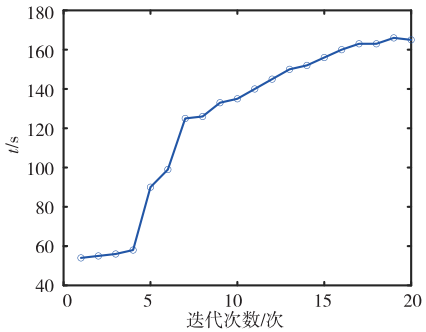
(a) 初始温度对*RMSE*的影响



(b) 初始温度对计算时间的影响



(c) 迭代次数对*RMSE*的影响



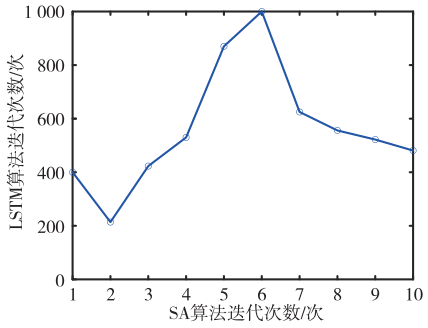
(d) 迭代次数对计算时间的影响

图2　SA最佳参数的确定

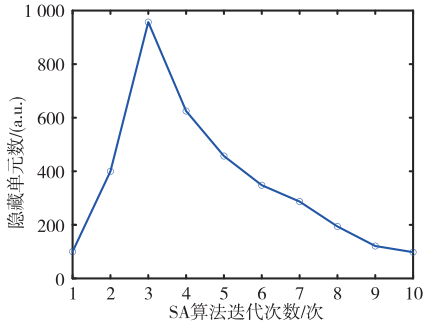
2.2　SA-LSTM算法的验证

由2.1节可知，SA算法中初始温度和迭代次数分别选取100℃和10次。LSTM模型的初始迭代次数、隐藏层单元数和学习率分别设置为400，100和0.01。针对参数优化，依据参考文献[5-6]，迭代次数的寻优范围设定为(50，1 000)，隐藏层单元数的

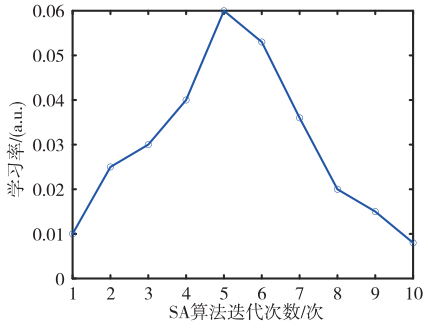
范围为(50,1 000),学习率的范围为(0.001, 0.1)。在SA算法的优化过程中,LSTM模型各参数取值的变化如图3所示。



(a) LSTM算法迭代次数



(b) LSTM算法隐藏层单元数



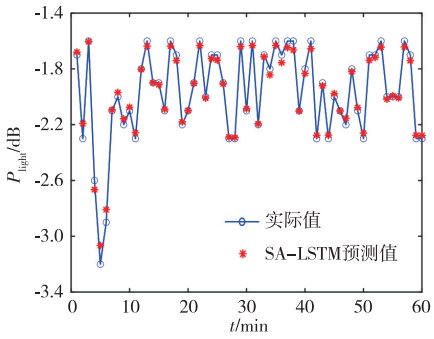
(c) LSTM算法学习率

图3 SA算法优化过程中LSTM参数的变化

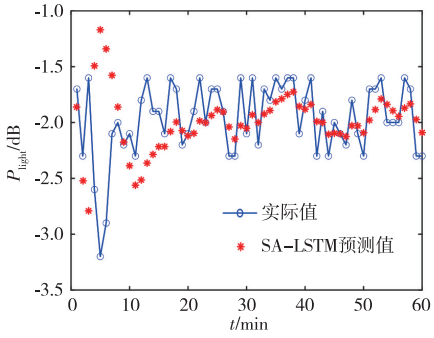
最终,通过SA算法优化后的LSTM模型参数最优值见表1。得到最终光功率预测曲线如图4(a)所示。为了突出参数优化的重要性,图4(b)展示了未进行参数优化的预测曲线。由图3和表1可知,LSTM算法的迭代次数、隐藏层单元数和学习率在优化过程中表现出先上升后下降的趋势,最终分别收敛于481,98和0.008。

表1 SA算法寻优后LSTM的最优参数

参数	寻优范围	最优参数
迭代次数	(50, 1 000)	481
隐藏层单元数	(50, 1 000)	98
学习率	(0.001, 0.1)	0.008



(a) SA-LSTM



(b) LSTM

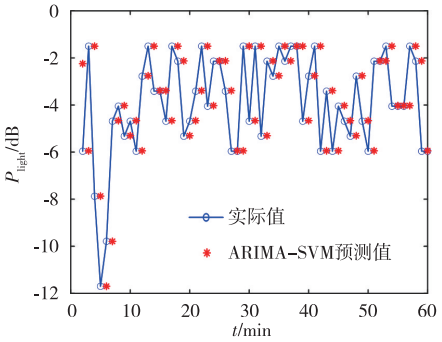
图4 光功率预测曲线

由图4(a)和(b)的对比可知,通过模拟退火算法优化后的参数组合能有效提升LSTM算法在光功率预测任务中的性能,显著降低预测误差。在图4(a)的光功率预测曲线中,出现一次较大的波动,这可能是光纤传输过程中受到环境噪声影响,造成光功率数据短暂突变所致。然而,这种干扰通常是瞬时的,随着干扰消失,信号会恢复正常。因此,这种现象不会对模型的整体预测性能产生显著影响。

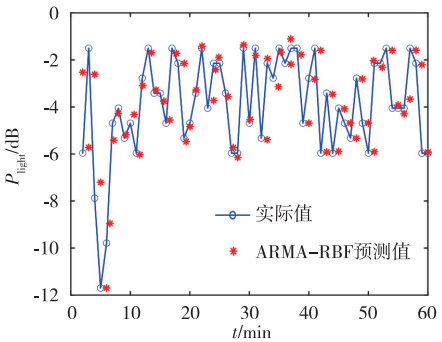
3 与经典算法预测结果的比较

为对比算法的预测效果,将SA-LSTM算法与ARMA-RBF算法[4]、ARIMA-SVM算法[2]、ARMA-LSTM算法[5]和ARIMA-LSTM算法[6]进行对比分析。实验数据和数据集分割方法均与第2.1节保持一致。根据参考文献[2,4-6],各算法的参数设定如下:对于ARMA-RBF算法,RBF的隐藏层神经元数量为10,ARMA的自回归阶数、差分阶数和移动平均阶数分别取11,0和8;对于ARIMA-SVM算法,SVM采用高斯核函数,ARIMA的自回归阶数、差分阶数和移动平均阶数分别取1,1和1;对于ARMA-LSTM算法,LSTM的迭代次数、隐藏层单元数和学习率分别选取400,100和0.01,ARMA的自回归阶数、差分阶数和移

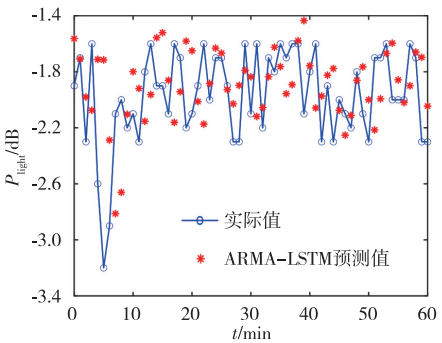
动平均阶数分别取24，0和14；对于ARIMA-LSTM算法，LSTM的迭代次数、隐藏层单元数和学习率分别选取400，100和0.01，ARIMA的自回归阶数、差分阶数和移动平均阶数分别都取1。四种算法的预测曲线对比结果如图5所示。



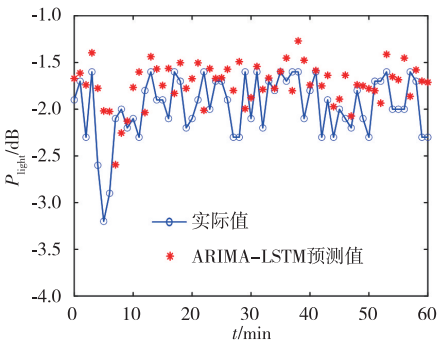
（a）ARIMA-SVM



（b）ARMA-RBF



（c）ARMA-LSTM



（d）ARIMA-LSTM

图5　不同算法的光功率预测曲线

为量化各算法的性能，实验分别记录了不同算法的计算时间和*RMSE*，并且为进一步提升研究结果的可靠性，本研究以10次独立运行的结果计算*RMSE*的标准差，具体结果如表2所示。

表2　不同算法的计算时间、*RMSE*及其标准差

预测算法	计算时间/s	*RMSE*/dB	标准差/dB
ARMA-RBF	9.27	3.39×10^{-2}	3.72×10^{-3}
ARIMA-SVM	8.93	3.11×10^{-2}	3.10×10^{-3}
ARMA-LSTM	77.89	7.84×10^{-2}	3.99×10^{-3}
ARIMA-LSTM	65.17	7.71×10^{-2}	3.69×10^{-3}
SA-LSTM	108.32	2.83×10^{-3}	4.21×10^{-4}

由图4(a)、图5及表2可知，SA-LSTM算法在预测精度上具有显著优势，其*RMSE*最低，而ARMA-RBF，ARIMA-SVM，ARMA-LSTM和ARIMA-LSTM算法的预测误差相对较高。计算显示，SA-LSTM算法在预测精度上相较于ARMA-RBF，ARIMA-SVM，ARMA-LSTM和ARIMA-LSTM算法分别提升了91.7%，91.0%，96.4%和96.3%。这一结果表明，SA-LSTM算法通过SA优化LSTM模型的参数配置，有效提升了模型在光功率预测中的表现。

尽管SA-LSTM算法的计算时间较其他算法有所增加，但其计算时间的增长主要来源于SA算法在参数优化过程中对参数的全局搜索能力的提升。SA算法通过动态调整参数配置，避免了模型陷入局部最优解，同时更精准地逼近全局最优解，从而显著提高了预测精度。这种优化过程尽管增加了计算时间，但为预测性能的提升提供了有力支撑，使得计算时间的增加合理且可接受。在本研究中，利用SA-LSTM算法可以根据历史数据提前预测60 min后的数据，时间只需108.32 s。因此，算法计算时间的增加与实际所需的时间相比，几乎可以忽略不计。此外，多次实验统计分析结果表明，SA-LSTM算法的*RMSE*标准差仅为4.21×10^{-4} dB，显著低于其他算法。进一步表明SA-LSTM算法在光功率预测中具有更高的稳定性和鲁棒性。结合预测结果与阈值法[16]，可以有效预测电力光缆线路的劣化情况，具有较高的工程应用价值。

4　结论

本文利用SA-LSTM算法实现了光功率的预测，提升了基于光功率预知光缆异常的准确性。首先对原始光功率数据进行归一化处理。随后利用

SA算法对LSTM算法中的迭代次数、隐藏层单元数和学习率在大范围内进行全局寻优，获得最优参数。最后，基于优化得到的参数构建LSTM模型，用于预测光功率的未来趋势。根据预测结果结合阈值法可以判断电力光缆线路的劣化情况。实验结果表明，所提方法在最优参数时光功率预测的均方根误差为2.83×10^{-3} dB，仅为均值的0.14%。相较于ARMA-RBF，ARIMA-SVM，ARMA-LSTM和ARIMA-LSTM算法，预测精度分别分别提升了91.7%，91.0%，96.4%和96.3%。因此，所提方法能够更加准确地预测电力光缆的光功率趋势，具有重要的工程应用价值。

参考文献：

[1] 赵 芬. 数据挖掘在光纤故障诊断中的应用研究[D]. 北京：华北电力大学，2011.
Zhao Fen. Application and research of data mining in fiber optic fault diagnosis [D]. Beijing: North China Electric Power University, 2011.

[2] 王 林，郭 健，刘 静，等. 基于ARIMA-SVM组合模型的光功率趋势预测新方法[J]. 电力信息与通信技术，2015，13(12)：94-99.
Wang Lin, Guo Jian, Liu Jing, et al. A new method of optical power trend forecasting using ARIMA-SVM combination model [J]. Electric Power Information and Communication Technology, 2015, 13(12): 94-99.

[3] 曾繁祎，陈太艺，周 川. 基于光纤传感技术的输电线路在线监测技术[J]. 电力与能源，2022，43(4)：322-325，347.
Zeng Fanyi, Chen Taiyi, Zhou Chuan. Online monitoring technology of transmission line based on optical fiber sensing technology[J]. Power & Energy, 2022, 43(4): 322-325, 347.

[4] 姜万昌，杨 旸，隋吉生. 基于小波变换的ARMA-RBF光功率组合预测[J]. 光通信技术，2013，37(12)：29-31.
Jiang Wanchang, Yang Yang, Sui Jisheng. Optical power combination forecasting model based on wavelet transform and ARMA-RBF [J]. Optical Communication Technology, 2013, 37(12): 29-31.

[5] 付 浩，王圣达，姜 山，等. 基于ARMA-LSTM的光功率预测方法[J]. 光通信技术，2019，43(1)：20-23.
Fu Hao, Wang Shengda, Jiang Shan, et al. Optical power forecasting method based on ARMA-LSTM [J]. Optical Communication Technology, 2019, 43(1): 20-23.

[6] 高云鹏. 基于机器学习的光通信保护系统中光功率预测研究[D]. 北京：华北电力大学，2021.
Gao Yunpeng. Research on optical power prediction in optical communication protection system based on machine learning [D]. Beijing: North China Electric Power University, 2021.

[7] 杨 菁，张 欢，张烨宇，等. 基于双池化的多层感知机光功率预测方法[J]. 城市轨道交通研究，2024，27(4)：247-251，261.
Yang Jing, Zhang Huan, Zhang Yeyu, et al. Optical power prediction method based on double pooling multilayer perception [J]. Urban Mass Transit, 2024, 27(4): 247-251, 261.

[8] 杨潞霞，王梦冉，林兴亮，等. 基于CNN-LSTM的工业出水水质预测模型[J]. 净水技术，2024，43(5)：143-149.
Yang Luxia, Wang Mengran, Lin Xingliang, et al. Prediction model of industrial effluent quality based on CNN-LSTM [J]. Water Purification Technology, 2024, 43(5): 143-149.

[9] Li T, Hua M, Wu X. A hybrid CNN-LSTM model for forecasting particulate matter ($PM_{2.5}$) [J]. IEEE Access, 2020, 8: 26933-26940.

[10] Sang S, Li L. A novel variant of LSTM stock prediction method incorporating attention mechanism [J]. Mathematics, 2024, 12(7): 945.

[11] 李淑香. 基于模拟退火的粒子群算法在函数优化中的应用[J]. 沈阳工业大学学报，2019，41(6)：664-668.
Li Shuxiang. Application of particle swarm optimization algorithm based on simulated annealing in function optimization [J]. Journal of Shenyang University of Technology, 2019, 41(6): 664-668.

[12] He D, Qu Y, Sheng G, et al. Oil production rate forecasting by SA-LSTM model in tight reservoirs [J]. Lithosphere, 2024, 2024(1): 1-15.

[13] Tang J, Xu L, Wu X, et al. A short-term forecasting method for ionospheric TEC combining local attention mechanism and LSTM model [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 1001305.

[14] 韩 颖，张 旭，于明鑫，等. 基于改进LSTM的FBG传感网络光谱基线校正方法[J]. 光通信研究，2024(4)：42-49.
Han Ying, Zhang Xu, Yu Mingxin, et al. Baseline correction method of FBG sensor network spectrum based on the improved LSTM model [J]. Study on Optical Communications, 2024(4): 42-49.

[15] 熊兴隆，冯 磊，刘 佳，等. 基于改进变分模态分解的Φ-OTDR信号去噪方法[J]. 半导体光电，2020，41(3)：400-405.
Xiong Xinglong, Feng Lei, Liu Jia, et al. De-noising method of Φ-OTDR signal based on improved variational mode decomposition [J]. Semiconductor Optoelectronics, 2020, 41(3): 400-405.

[16] 龚 伟. 电力通信光纤线路状态自动化监测系统设计[J]. 激光杂志，2021，42(10)：152-156.
Gong Wei. Design of automatic monitoring system for power communication optical fiber line status [J]. Laser Journal, 2021, 42(10): 152-156.

作者简介：

陈锦山(1986—)，男，福建省漳平市人，高级工程师，主要研究方向为电力通信及自动化；

王新澜(1997—)，女，河北省张家口市人，助理工程师，主要研究方向为电力系统自动化及通信。