

基于改进萤火虫算法优化的电力光纤 线路状态预测模型研究

孔历波, 毛一凡, 欧阳李亮, 康 恺, 何 超

(浙江大有实业有限公司 杭州科技发展分公司, 杭州 310052)

摘要: 为了提升电力通信系统光纤线路状态预测的准确率, 提出一种基于改进萤火虫 (FA) 算法优化的电力光纤线路状态预测模型 (FA-ARIMA-GRU); 首先, 针对 FA 寻优过早收敛和寻优精度低等问题, 对整体距离进行指数加权平均, 设计了迭代衰减步长因子, 并且对偏差修正进行考虑, 从而改善上述 FA 所存在的问题; 其次, 将改进的 FA 用于 ARIMA-GRU 光功率预测模型输入参数的优化, 从而在一定程度上提升 ARIMA-GRU 预测模型输入参数的准确性; 最终, 通过仿真试验对 FA-ARIMA-GRU 预测模型的效果进行验证, 结果表明 FA-ARIMA-GRU 预测模型具有较优的预测效果, 精准预测光功率值, 提前掌握电力光纤的线路状态, 预知光纤线路故障、有效规避故障和保障电力通信传输畅通不间断。

关键词: 电力光纤; 光功率; 萤火虫算法; 电力光纤线路状态预测模型

Research on State Prediction Model of Power Optical Fiber Line Based on Firefly Algorithm Optimization

KONG Libo, MAO Yifan, OUYANG Liliang, KANG Kai, HE Chao

(Hangzhou Science and Technology Development Branch, Zhejiang Dayou Industrial Co., Ltd.,
Hangzhou 310052, China)

Abstract: In order to improve the accuracy of state prediction of optical fiber lines in power communication system, a state prediction model for power optical fiber lines (FA-ARIMA-GRU, firefly algorithm auto represent integrated moving average mode gated recurrent unit) based on improved firefly algorithm is proposed. Firstly, aiming at the problems of premature convergence and low accuracy of the FA optimization, the overall distance is on the exponentially weighted average, the iterative attenuation step factor is designed, and the deviation correction is considered to improve the problems of the FA; Secondly, the improved FA is used to optimize the input parameters of the ARIMA-GRU optical power prediction model, so as to improve the accuracy of the input parameters of the ARIMA-GRU prediction model to a certain extent; Finally, the effect of the FA-ARIMA-GRU prediction model is verified through the simulation test. The results show that the FA-ARIMA-GRU prediction model has better prediction effect, can accurately predict the optical power value, master the line state of power optical fiber in advance, predict the optical fiber line fault, effectively avoid the fault and ensure the smooth and uninterrupted power communication transmission.

Keywords: power optical fiber; optical power; firefly algorithm; state prediction model of power optical fiber line

0 引言

近年来, 光纤通信由于损耗小、速度快、容量大合抗干扰等特性, 在电力领域得到广泛的应用^[1]。当光纤线路发生故障时, 将导致电力通信中断, 进而给用户及企业造成不可逆的损失。因光功率数据能够在全面表征电力光纤通信线路受各种参数的影响程度, 故通过预测电力光纤光功率的发展趋势, 能够达到预测通信线路未来状态的目的^[2-4]。目前光纤维护主要通过在线实时获取光功率数据来进行, 当光功率数据超越前期设定的阈值时, 系统将开启光时域反射仪 (OTDR, optical time domain reflectometer) 进行测试, 通过分析测试得到的曲线进行光纤故障诊断与

定位, 之后由现场工作人员进行维修, 从而恢复电力通信。但上述方法仅能实时掌握电力通信线路的实时状态, 处理已经发生的故障, 不能预测和提前分析线路状态未来的发展趋势, 对未来故障进行有效的规避, 因此基于电力光纤的光功率数据的特性, 构建精准的光功率预测模型, 提前掌握电力光纤线路状态成为下一阶段研究的重点^[5-9]。

光功率是一种具备复杂性、时变性及非线性等特性的时间序列数据。近些年, 国内外学者针对时间数据序列预测进行了大量的研究, 并得到多种时间序列预测方法^[10-16], 例如支持向量机 (SVM, support vector machine) 模型、神经网络预测模型、自回归滑动平均 (ARMA, auto-regres-

收稿日期: 2022-04-11; 修回日期: 2022-05-09。

作者简介: 孔历波 (1976-), 女, 浙江杭州人, 大学本科, 高级工程师, 主要从事电力通信工程方向的研究。

引用格式: 孔历波, 毛一凡, 欧阳李亮, 等. 基于改进萤火虫算法优化的电力光纤线路状态预测模型研究[J]. 计算机测量与控制, 2022, 30(8): 50-55, 61.

sive and moving-average) 模型、灰色预测模型等方法。SVM 预测模型中核函数的类型及参数对其泛化性能和学习能力起到决定性作用, 故选用单一核函数的 SVM 预测模型, 呈现出较低的预测精度; 神经网络预测模型处理非线性数据时, 存在局部极小值和学习速度慢等问题; ARMA 预测模型在对非线性时间序列数据进行处理时, 首先需要进行平稳化处理, 并且整体的预测精度相对较低。

针对上述的不足, 学者们对预测算法进行改进和融合。文献 [17] 提出一种差分自回归移动平均模型与支持向量回归模型融合的功率预测模型 (ARIMA-SVR, autoregressive integrated moving average model-support vector regression) 光伏短期功率预测模型, 实现短期光伏功率预测, 提升电力系统光伏消纳和能源协调的整体能力; 文献 [18] 提出一种自适应粒子群优化 ARIMA-SVM 光功率预测模型, 对 SVM 的核参数进行优化, 实现光功率数据未来趋势的预测; 文献 [19] 提出一种 ARIMA-RVM 光功率预测模型, 对光纤光功率数据进行预测; 文献 [20] 提出一种长短记忆网络 (LSTM, long short term memory network) 光纤参数预测方法, 实现光纤数据的短期预测; 文献 [21] 提出自用自适应粒子群优化的 ARIMA-GRU 组合光功率趋势预测模型, 实现了光功率预测, 为电力光纤故障预警监测提供理论依据。

综上所述, 在各行各业均有时间序列预测方法的成功案例, 但在光纤光功率预测方面的研究和应用还处于探索阶段, 预测的精度有待进一步的提升。本文基于光纤光功率预测的实际需求和前人研究成果, 提出一种基于改进萤火虫算法优化的光功率预测模型 (FA-ARIMA-GRU, firefly algorithm-autoregressive integrated moving average mode-gated recurrent unit), 实现光功率趋势的准确预测, 进而提前掌握电力光纤的线路状态, 实现预知光纤线路故障、有效规避故障和保障电力通信传输通畅不间断。

1 ARIMA-GRU 模型原理

光功率是一种具备复杂性、时变性及非线性等特性额定时间序列数据, 故选用 ARIMA 模型对高频光功率数据进行预测; 选用 GRU 模型对低频光功率数据进行预测, 形成 ARIMA-GRU 组合光功率趋势预测模型, 选用改进萤火虫算法对组合预测模型的参数进行优化, 在一定程度上提升光功率预测的精度, 减小预测误差。光功率预测模型的过程如图 1 所示。

1.1 数据预处理

1.1.1 数据分解

本文选用采用小波变换 Mallat 算法来对原始光功率数据进行分解, 从而得到高频数据和低频数据, 分解得到的数据长度为原来数据长度的一半。分解表达式为:

$$X_{j+1} = GX_j, Z_{j+1} = HZ_j, j = 0, 1, \dots, J \quad (1)$$

式中, H 表示低通滤波器; G 表示高通滤波器; j 表示小波分解的层数; Z_{j+1} 表示在分辨率 $2^{-(j+1)}$ 下原始数据分解得到的

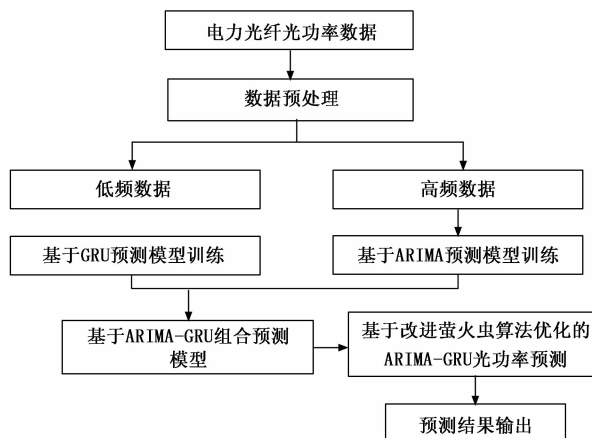


图 1 电力光纤光功率预测流程图

高频分量数据; X_{j+1} 表示在分辨率 $2^{-(j+1)}$ 下原始数据分解得到的低频分量数据。

1.1.2 数据重构

数据分解得到的高、低频数据利用 Mallat 算法进行重构, 最终得到重构数据, 重构数据的长度与原始数据一致。重构表达式为:

$$x_j = H^* x_{j+1} + G^* z_{j+1}, j = 0, 1, \dots, J \quad (2)$$

式中, H^* 表示 H 的对偶算子; G^* 表示 G 的对偶算子。

1.2 ARIMA 模型

ARIMA 模型主要由自回归移动平均模块 (ARMA, autoregressive moving average)、自回归模块 (AR, autoregressive) 和移动平均模块 (MA, moving average) 3 个模块组成。

自回归模块主要采用变量的历史数据预测当前数据, 其表达式为:

$$y_t = \mu + \sum_{i=1}^p \gamma_i y_{t-i} + \epsilon_t \quad (3)$$

式中, γ_i 表示自相关系数; y_t 表示当前的信息; ϵ_t 表示误差; μ 表示常数项; p 表示阶数。

移动平均模块主要对预测过程当中所出现的随机波动情况进行解决, 其表达式为:

$$y_t = \mu + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t \quad (4)$$

式中, θ_i 表示相关系数。

由自回归移动平均模块是上述两模块的结合, 其表达式为:

$$y_t = \mu + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t + \sum_{i=1}^p \gamma_i y_{t-i} \quad (5)$$

将上述 3 个模型与差分法结合在一起便构成差分整合移动平均自回归模型, 其通过模型解析和定阶 (确定 p 、 d 和 q 的值, 其中 d 取 1 或 2)、参数估计和确定、模型验证 3 个阶段来进行构建。

1.3 GRU 模型

GRU 神经网络和 LSTM 神经网络具十分相似的网络结构, 具体网络结构如图 2 所示。由图 2 可知, GRU 神经网络主要包含重置门与更新门, 其中更新门表示当前时间步

长上接收上一步长状态信息的程度；重置门表示忽略上一步长信息的程度，两者均需要对当前时刻和前一步长时刻状态信息进行线性转换。

GRU 模型构建步骤为：

1) 更新信息确认。首先，当前输入状态 x_t 和神经元上一时刻的输出 h_{t-1} 相加；其次，将相加结果与更新门权重 W_z 相乘；最后运用 sigmoid 函数对乘积结果进行运算，具体的计算表达式为：

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (6)$$

式中， σ 表示 sigmoid 函数； W_z 表示更新门权重； x_t 表示当前神经元的输入； z_t 表示更新门；

$[\]$ 表示两向量相连接，即相加； h_t 表示本次神经元的输出，更新门输出值越大，则代表当前状态代入的上一神经元信息越多。




图 2 GRU 神经网络模型

2) 重置信息确定及跟新。首先，当前输入状态 x_t 和神经元上一时刻的输出 h_{t-1} 相加；其次，将相加结果与重置门权重 W_r 相乘；最后经过 sigmoid 层，与此同时，tanh 层会构建新的向量 \tilde{h}_t 来作为新的候选向量，具体表达式为：

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (7)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t]) \quad (8)$$

式中， W_r 表示更新门权重； W 表示表示各自向量的权重； \tilde{h}_t 表示本次神经元当中输出待定值。重置门输出值越小则表示写入上一神经元的的信息越少。

3) 信息输出。首选，选取更新门 z_t 当做权重向量；其次，通过对 h_{t-1} 和 \tilde{h}_t 进行加权平均，获得本次神经元的输出 h_t ；最终，将输出门权重 W_o 和神经元输出 h_t 相加，相加的结果经过 sigmoid 层得到整体 GRU 神经元总输出，具体表达式为：

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (9)$$

$$y_t = \sigma(W_o \cdot h_t) \quad (10)$$

式中， y_t 表示 GRU 神经元整体总输出； W_o 表示输出门权重。

光纤光功率的高频数据选用 ARIMA 模型来进行预测，低频数据选用 GRU 模型进行预测，将高、低频预测结果相加得到 ARIMA-GRU 组合预测模型。

2 基于改进 FA 的 ARIMA-GRU 模型优化

由上节可知，ARIMA 模型在构建过程中 p, q 的值仅是基于偏相关和自相关分析得到，GRU 模型输入长度设定也是通过经验得到，故上述各个参数均有一定程度的优化空间，本节选用改进萤火虫算法对 ARIMA-GRU 预测模型进

行优化，从而提升电力光纤光率预测的准确性，更加精准的掌握电力光纤线路状态。

2.1 改进萤火虫优化算法 (FA)

2.1.1 标准萤火虫优化算法

随着计算机技术的不断创新，智能技术的不断发展，更多新型的智能算法应运而生，为了对模型优化及参数选择等问题进行解决，Yang^[22] 于 2008 年提出一种针对模型优化及参数选择^[25] 的算法，即萤火虫算法，其 (FA, firefly algorithm) 是众多智能算法中的一种。该算法通过对自然界当中萤火虫群体行为进行模拟，进而达到对模型的优化求解的目的，具有操作简便、参数设置少及计算效率高等优点。在光线功率预测问题当中，预测模型的求解及优化过程就是萤火虫之间移动位置、彼此吸引及优胜劣汰的过程。在整个算法优化进程中，萤火虫彼此之间的吸引是由吸引度和亮度决定。亮度较高的萤火虫代表模型可行解处于优越的位置，并且此时的萤火虫具备较强的吸引力。最亮的萤火虫就是模型优化及参数选择的最优解。随着传播介质的吸收与空间距离的增加，萤火虫的亮度逐渐变暗，并且其位置在每次迭代计算过程中不断地更新，进而问题的解也得到进一步的优化。

对于 FA 基本原理的数学表达式为：

1) 相对荧光亮度：

$$I(r) = I_0 e^{-\gamma r} \quad (11)$$

式中， γ 表示传播介质的光吸收系数； I_0 表示初始萤火虫亮度； r 表示两萤火虫的笛卡尔距离，其表达式为：

$$r_{ij} = \|x_i - x_j\| = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (12)$$

式中， $(x_i - x_j), (y_i - y_j)$ 分别表示第 i, j 只萤火虫在空间当中的位置。

2) 吸引度：

$$\beta(r) = (\beta_0 - \beta_{\min}) e^{-\gamma r} \quad (12)$$

式中， β_0 表示 $r = 0$ 处，即光源处的吸引度大小； β_{\min} 表示最小吸引力度。

3) 萤火虫位置移动：

$$[w, b]'_i = [w, b]_i + (\beta_0 e^{-\gamma r} ([w, b]_i - [w, b]_j) + \text{rand}()) \quad (13)$$

式中， α 表示扰动步长因子，通常其取值范围为 $[0, 1]$ ； $\text{rand}()$ 表示某个随机扰动，通常其为取值范围 $[-0.5, 0.5]$ 内均匀分布或 $U(0, 1)$ 标准正态分布； r 表示第 i 个和第 j 个萤火虫的笛卡尔距离； $[w, b]_i$ 表示亮度较第 i 萤火虫更亮的萤火虫的位置。

萤火虫算法整体流程如图 3 所示。

2.1.2 改进萤火虫优化算法

虽然标准萤火虫算法具备操作简便、参数设置少、计算效率高及寻优能力强等优点，但是其在解决非线性和高维度问题时，存在局部最优收敛与收敛速度慢等智能算法的通病。传统萤火虫算法步长因子选用固定值，设置过小会造成萤火虫移动缓慢，从而需要较长时间才能达到收敛，甚至无法达到收敛；设置过大会造成萤火虫反复振荡于最

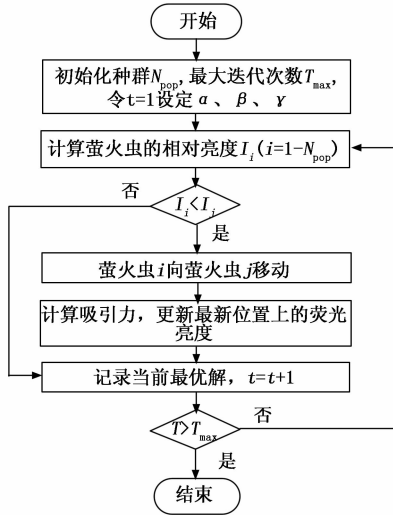


图 3 萤火虫算法整体流程图




图 4 基于改进萤火虫算法的 ARIMA-GRU 模型优化流程

优解附近。

本文参考梯度优化算法当中的 Adam 算法^[24]和 RM-Sprop 算法^[25], 对萤火虫算法进行改进, 对整体距离进行指数加权平均, 并设计了迭代衰减步长因子。改进萤火虫算法还对偏差修正进行考虑, 在一定程度上改善初始误差大和过拟合等问题。

2.2 基于改进 FA 的 ARIMA-GRU 模型优化

本文采用的改进萤火虫算法当中, 各个萤火虫的位置表示 ARIMA-GRU 组合模型参数的一个可行解; 萤火虫位置的适应度用萤火虫的亮度表示。各个萤火虫均会朝着比自己亮度高的个体进行飞行, 从而搜寻到更优的位置。各萤火虫吸引其它萤火虫的程度与两者距离成反比, 与亮度成正比。改进萤火虫算法优化 ARIMA-GRU 模型的整体流程如图 4 所示。由图 4 可以看出, 改进萤火虫算反对自然界中的萤火虫行为进行模拟, 通过多次迭代搜索到群中最亮萤火虫的位置, 输出训练 ARIMA-GRU 模型的最优参数, 形成 FA-ARIMA-GRU 复合模型。

基于改进萤火虫算法的 ARIMA-GRU 模型优化流程为:

1) 初始化。萤火虫的数量假设为 N , 并对各个萤火虫的位置进行随机初始化。设置介质对光的初始吸引度 $\beta_0 = 1.0$; 初始步长 $\alpha = 0.3$; 吸收系数 $\gamma = 1$, 吸引度的表达式为:

$$\beta(r) = (\beta_{\max} - \beta_{\min})e^{-\gamma r} + \beta_{\min} \quad (14)$$

式中, $\beta_{\max} = 1, \beta_{\min} = 0.2$, 式 (14) 保证任意两萤火虫之间的吸引度保持在 $[0.2, 1]$ 区间内。

2) 计算各个萤火虫适应度值。适应度选用 R^2 指标, 其表达式为:

$$R^2 = 1 - \frac{\sum_i (\hat{y}^{(i)} - y^{(i)})^2}{\sum_i (\bar{y} - y^{(i)})^2} \quad (15)$$

式中, $y^{(i)}$ 表示真实值; $\hat{y}^{(i)}$ 表示预测值; 当 R^2 距离 1 越近, 表示此位置萤火虫的亮度越亮。

3) 移动。各个萤火虫飞向比其亮度更大的萤火虫, 飞行过程中萤火虫的位置变化可以通过以下表达式进行表示:

$$[\omega, b]_i = s_2 [\omega, b]_i + (1 - s_2) * (\beta_0 e^{-\gamma r} ([\omega, b]_j + arand())^2) \quad (16)$$

$$[\omega, b]_i = \frac{[\omega, b]_i}{s_2} \quad (17)$$

式中, α 表示扰动步长因子, 通常其取值范围为 $[0, 1]$; $rand()$ 表示某个随机扰动, 通常其为取值范围 $[-0.5, 0.5]$ 内均匀分布或 $U(0, 1)$ 标准正态分布; r 表示第 i 个和第 j 个萤火虫的笛卡尔距离; $[\omega, b]_j$ 表示亮度较第 i 萤火虫更亮的萤火虫的位置。为了进一步提升算法的收敛性, 令步长呈现迭代衰减态势, 那么第 t 步长的表达式为:

$$\alpha = s_1 \alpha + (1 - s_1) * (0.97)^t \quad (18)$$

其中: s_1 表示一阶矩估计的指数衰减率, $s_1 = 0.9$; s_2 表示二阶矩估计的指数衰减率, $s_2 = 0.999$ 。

群体中亮度最大的萤火虫不会向另外萤火虫的位置进行移动, 其位置更新基于以下表达式:

$$[\omega, b]_i = [\omega, b]_i + \alpha * rand(-0.5, 0.5) \quad (19)$$

4) 对移动至新位置的萤火虫的适应度值进行计算, 如移动后的位置比原有位置优越, 此时位置移动生效, 反之萤火虫不发生移动, 停留在原地。

5) 为了防止优化后模型出现过拟合现象, 该算法设定一个适应度阈值。当每次迭代完成后, 对当前最优适应度值进行记录, 如果最优适应值大于等于设定的适应度阈值或者该算法已经达到最大迭代次数, 此时算法输出搜寻到的最优参数, 反之跳转至步骤 2) 继续进行迭代。

6) 采用改进萤火虫算法输出的最优参数来构建 ARIMA-GRU 模型。

3 仿真实验分析

3.1 数据集描述

本文采集杭州某供电公司某一路光纤复合架空地线

(OPGW, optical power grounded waveguide) 连续 350 天光功率数据来作为仿真实验数据, 取前 250 天数据进行模型训练和优化; 后 100 天数据用于测试模型预测效果。原始光功率数据如图 5 所示。




图 5 光功率原始数据图

3.2 模型评价指标

本文预测模型效果的评价指标选用均方根误差 (RMSE, root mean square error) 其数学表达式为:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\tau_i - \hat{\tau}_i)^2}{n}} \quad (20)$$

式中, n 表示数据的长度; $\hat{\tau}_i$ 表示光功率预测数据; τ_i 表示光功率原始数据。

3.3 实验配置

本文全部的试实验全部在表 1 所给出的配置下进行。

表 1 实验设置表

类别	配置
操作系统	Windows10 64 位
内存	8.00 G
显卡	gtx1080
处理器	AMD 瑞龙 3
实验环境	Python3.6
开发工具	Spyder
后端	tensorflowgpu1.14

3.4 FA-ARIMA-GRU 模型验证

3.4.1 数据预处理

数据预处理第一步需要对原始光功率数据进行分解与重构操作, 而小波变换中不同的小波分解层数与小波基所得到的分解结果是不同的, 故确定小波分解层数和选取恰当的小波基在小波变换应用中起到决定性作用。Coiflet、Daubechies、Haar、Symlets 等是常用的几种小波基, 其在不同的应用场景得到广泛的应用。

在对小波基选取的过程中, 重点对相似性、消失矩、对称性、支撑长度和正则性这几点进行重点考虑。dbN 小波在大量实际应用过程中呈现出高消失矩和较好正则性等优点, 于此同时也暴露出其不具备对称性的缺陷, 该缺陷可能致使信号在分析与重构过程当中出现相位失真的现象。symN 小波在实际应用过程中较 dbN 小波具有较好的对称性, 能够在一定程度减少相位失真现象的发生。对于小波

分解的层数, 信噪比不同的信号均有一个接近最优的分解层数, 过多分级层数会导致信号严重失真; 而分解层数过少会导致信号去噪效果较差, 对后续信号的进一步分析造成一定程度的影响。


综上所述, 本文选取 sym1、sym2、sym3、sym4、db1、db2、db3、db4 八种不同的小波基, 对各小波基进行 1~4 层小波分解, 并对分解后的小波进行重构, 将最终数据代入至本文所构建的预测模型当中, 将预测数据与原始数据进行对比, 并对预测 RMSE 值进行计算, 得到如表 2 所示数据。

表 2 不同小波基函数与分解层数预测 RMSE 值


层数 \ 类型	1	2	3	4
sym1	0.027	0.030	0.079	0.111
sym2	0.025	0.035	0.065	0.094
sym3	0.025	0.043	0.058	0.101
sym4	0.024	0.029	0.068	0.090
db1	0.025	0.037	0.066	0.105
db2	0.028	0.029	0.055	0.097
db3	0.025	0.034	0.060	0.093
db4	0.031	0.041	0.063	0.105

由表 1 可知, 原始光功率随着小波分解层数的不断提升, 损失逐渐增多, 致使预测误差不断增大, 通过上述数据的对比, 得出在一层小波分解当中运用 sym4 小波基函数计算所得的结果 RMSE 最小, 故本文选用 sym4 小波基函数对原始数据进行一层小波分解。

通过 sym4 小波基函数对上述采集获得的原始光功率数据进行一层分解和重构, 经过分解与重构得到的光功率数据如图 6 所示。



(a) 预处理后低频数据图



(b) 预处理后高频数据图

图 6 sym4 小波处理后的数据图

3.4.2 实验结果分析

本节采用 ARIMA-GRU 预测模型和本文构建的 FA-ARIMA-GRU 预测模型在前期预留的 100 天电力光纤光功

率测试数据集上进行预测结果和实际数据的对比, 并以拟合曲线的方式来呈现不同预测模型所预测的效果, 如图 7 所示。由图 7 可以看出, 本文所构建的 FA-ARIMA-GRU 预测模型较 ARIMA-GRU 与原始更为接近, 更能准确预测未来电力光纤光功率的发展趋势, 从而提前掌握电力光纤的线路状态, 为电力光纤故障定位提供可靠的参数依据, 起到辅助作用。




图 7 光功率预测结果对比图

为进一步对本文构建的 FA-ARIMA-GRU 预测模型的效果进行说明, 本文分别列举 ARIMA-GRU、ARIMA-SVM、PSO-ARIMA-GRU、APSO-ARIMA-SVM、FA-ARIMA-GRU 光功率趋势预测模型的预测误差, 具体误差数据如表 3 所示。

表 3 不同光功率趋势预测模型的预测误差

预测模型	RMSE
ARIMA-GRU	0.033 1
PSO-ARIMA-GRU	0.024 5
FA-ARIMA-GRU	0.018 6
ARIMA-SVM	0.084 5
ARIMA-PSOSVM	0.064 2
ARIMA-APSOSVM	0.042 9

由表 3 可以看出, 上述所提及的 6 中预测模型中, 本文所构建的 FA-ARIMA-GRU 预测模型 RMSE 值最小, 表明该模型较其他预测模型具有较小的预测误差和较好的拟合效果, 整体的预测精度较高, 是一种高效的电力光纤光功率趋势预测模型。

3.4.3 模型性能分析

为了对 FA-ARIMA-GRU 预测模型的性能进行验证, 本文从算法运行时间的角度对模型的性能进行分析, 以各算法运行 10 次的时间的平均值为基准进行运行时间的比较, 具体如表 4 所示。

表 4 不同模型性能分析结果

预测模型	运行时间/h
ARIMA-GRU	0.90
PSO-ARIMA-GRU	0.68
FA-ARIMA-GRU	0.51

由表 4 数据可以看出本文所构建的模型具有较高的时间效率, 能够快速得到预测结果。

4 结束语

基于电力光纤光功率预测的实际需求和电力光纤光功率数据的特性, 本文提出一种基于萤火虫算法优化的电力光纤线路状态预测模型, 通过研究主要得到以下结论:

- 1) 提出改进 FA 算法, 改善算法寻优过早收敛和寻优精度低的现状;
- 2) 基于改进 FA 对 ARIMA-GRU 光功率组合预测模型进行改善, 进而形成 FA-ARIMA-GRU 电力光纤光功率预测模型, 进而提前掌握电力光纤的运行状态, 为故障定位提供帮助;
- 3) 模型试验验证表明: 本文构建预测模型较其他模型具有较高的预测精度和运行效率。

由于本文数据集中数据量有限, 在大数据高速发展的背景下, 凸显出数据不足的缺陷, 后续应该采集更多的数据进行模型训练, 引入适当的修正因子, 再次提升模型预测的精准度。

参考文献:

- [1] 姜文, 王禄海, 吴清玉, 等. 电力系统通信网络状态估计模型与智能告警 [J]. 电力系统及其自动化学报, 2019, 31 (2): 101-105, 118.
- [2] 王山岭. 基于 VR-GIS 的光缆故障精确定位方法研究 [D]. 长春: 长春理工大学, 2020.
- [3] YE Z. The application analysis of ice-melting technical measures for OPGW [C] //2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2), Beijing, 2018.
- [4] 陈晓娟, 王山岭, 窦增. 双模式电力光纤线路状态监测系统的设计 [J]. 光通信技术, 2019, 43 (1): 24-27.
- [5] 陈晓娟, 付浩, 赵亮, 等. 电力光缆接头盒在线检测系统设计 [J]. 电力信息与通信技术, 2018, 16 (11): 64-68.
- [6] 付浩. 双模式城区电力光纤线路在线检测系统 [D]. 长春: 长春理工大学, 2019.
- [7] 刁梦雯. 基于宽度学习的多变量时间序列预测研究及应用 [D]. 南京: 南京邮电大学, 2020.
- [8] TANG B, ZHOU Z. The design of communication network optical fiber cable condition monitoring system based on distributed optical fiber sensor [C] //2018 International Conference on Electronics Technology (ICET), Chengdu, 2018.
- [9] 张凯, 药炜, 原军, 等. 相位敏感 OTDR 和布里渊 OTDR 结合的双参量分布式光纤传感的研究 [J]. 激光与红外, 2021, 51 (1): 74-79.
- [10] 张娜. 基于 GIS 和 OTDR 的光纤智能监控系统研究 [J]. 计算机测量与控制, 2016, 24 (2): 99-102.
- [11] 王小娟, 刘俊霞, 胡兵, 等. 基于 CS-SVR 模型的短期风电功率预测 [J]. 计算机测量与控制, 2020, 28 (1): 152-155.

(下转第 61 页)