

基于 ARMA-LSTM 的光功率预测方法

付浩¹,王圣达²,姜山²,康爱民³

(1.长春理工大学 电子与信息工程学院,长春 130022;

2.国网吉林省电力有限公司 信息通信公司,长春 130021;3.国网辽宁省电力有限公司 阜新供电公司,辽宁 阜新 123000)

摘要:光功率是衡量电力光纤通信质量的一种重要的指标。针对光功率的这一特性,提出了一种自回归移动平均-长短期记忆网络(ARMA-LSTM)光功率预测方法,该方法通过 db5 小波对原始光功率数据进行一层分解获得光功率数据趋势项部分和细节项部分。采用 LSTM 对趋势项进行建模预测,采用 ARMA 对细节项进行建模预测并将两种预测结果相加得到最终的预测结果。实验结果表明:该预测模型比传统预测模型的预测精度更高。

关键词:电力光纤;小波分解;ARMA-LSTM;光功率预测

中图分类号:TP393.01 文献标识码:A 文章编号:1002-5561(2019)01-0020-04

DOI:10.13921/j.cnki.issn1002-5561.2019.01.005

开放科学(资源服务)标识码(OSID):



Optical power forecasting method based on ARMA-LSTM

FU Hao¹, WANG Shengda², JIANG Shan², KANG Aimin³

(1. Changchun University of Science and Technology, Electronic and Information Engineering, Changchun 130022, China;

2. Information and Communication Company, State Grid Jilin Electric Power Co., Ltd., Changchun 130021, China;

3. Fuxin Power Supply Company, State Grid Liaoning Electric Power Co., Ltd., Fuxin Liaoning 123000, China)

Abstract: Optical power is an important index to measure the quality of power optical fiber communication. For this characteristic of optical power, an auto-regressive moving average and long-term memory network (ARMA-LSTM) optical power prediction method is proposed, this method decomposes the original optical power data layer by db5 wavelet to obtain the trend term and detail term of the optical power data. LSTM is used to model and predict trend items and ARMA is used to model and predict detailed items, and the predicted results are added together to obtain the final predicted results. The experimental results show that the prediction accuracy of the model is higher than that of the traditional prediction model.

Key words: power fiber; wavelet decomposition; ARMA-LSTM; optical power forecast

0 引言

电力光纤具有通信容量大、传输损耗小和抗电磁干扰性好等优点,在电力通信中占有主要位置,承担了电力企业 95% 以上的电力通信业务^[1]。随着电力企业的信息化建设飞速发展,中国铺设电力光缆总长度已超过 150×10^4 km, 中国北方某省城区已经建成了 100% 覆盖所有 66 kV 变电站的电力光纤支撑网络,电

力光缆总长度已达 2549 km, 并且随着城郊光缆通信网的建设,光纤支撑网预期将达到 3349 km。当电力光纤线路出现老化、腐蚀、雷击、冰雪覆压、湿气渗透以及线路受潮等故障类型时,光纤线路不会立即产生传输信号中断,其光功率值也不会立即大幅度衰减,但会导致光纤线路的缓慢劣变,此时线路的光功率数据则会呈现一定的变化趋势。对于这类故障,传统监测光纤光功率的方式并不能有效地及时发现故障并进行处理,这将会给企业造成巨大的经济损失^[2]。目前,国内外对电力光纤线路趋势分析的研究主要集中在利用径向基函数(RBF)神经网络、支持向量机和支持向量回归等智能优化算法对光功率趋势进行预测分析^[3]。这些方法的信息传递不具有持久性。针对该问题,本文提出一种自回归移动平均-长短期记忆网络(ARMA-LSTM)光功率预测方法。

收稿日期:2018-08-07。

基金项目:长春市科技局项目(17DY030)资助。

作者简介:付浩(1994-),男,河南周口人,硕士研究生,主要从事智能信号检测方向的研究。参与了光纤在线检测与智能预警方法的研究和双模式城区电力光纤支撑网在线检测研究两个项目;在校期间,获得了“基于温度和电阻的光缆故障预测方法”和“一种光缆接头盒密闭性在线监测系统”两项专利。



1 ARMA-LSTM 预测原理

因为光功率会受到浮冰、大风、光纤物理参数、光纤线路环境和收发端衰减等条件的影响而发生变化,具备随机性和不确定性,所以电力光纤光功率是一种兼具非线性、时变性和复杂性等特点的时间序列数据。针对电力光纤光功率的这些特性,本文首先用小波分解将原始光功率数据分为高频部分和低频部分,高频部分代表光功率数据的细节项,低频部分代表光功率数据的趋势项;用 ARMA 预测光功率数据的细节项和 LSTM 预测光功率数据的趋势项,最终将 ARMA 预测数据和 LSTM 预测数据叠加。

1.1 ARMA 原理

ARMA 模型作为一种时间序列模型是研究时间序列的重要方法,该模型为 AR 模型与 MA 模型的线性结合^[4,5]。设 AR 模型的阶数为 p ,MA 模型的阶数为 q ,则 ARMA 模型($ARMA(p,q)$)可表示为:

$$\varphi(B)Y_t = \theta(B)\varepsilon_t \quad (1)$$

$\varphi(B)$ 和 $\theta(B)$ 分别为:

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (2)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (3)$$

其中, $\varphi_i (i=1,2,\dots,p)$ 是 AR 模型参数, $\theta_i (i=1,2,\dots,q)$ 是 MA 模型参数, Y_t 是平稳时间数据序列, B 是先后推移算子, ε_t 是均值为 0 的白噪声序列。

1.2 LSTM 原理

LSTM 是一种环神经网络(RNN),相对于传统的 RNN 网络,它有更强大的学习能力。可以保持 RNN 网络的持久性,使模型能够长时间依赖^[6,7]。一个完整的 LSTM 神经网络包含输入门、输出门和遗忘门^[8],其结构如图 1 所示。在 t 时刻,其遗忘门、输入门和输出门分别为:

$$f_t = \sigma(W_f \cdot [x'_{t-1}, x_t] + b_f) \quad (4)$$




图 1 LSTM 的结构图

$$i_t = \sigma(W_i \cdot [x'_{t-1}, x_t] + b_i) \quad (5)$$

$$o_t = \sigma(W_o \cdot [x'_{t-1}, x_t] + b_o) \quad (6)$$

其中, x_t 和 x'_t 分别是 t 时刻的输入和输出。 f_t 、 i_t 和 o_t 分别是遗忘门、输入门和输出门在 t 时刻的输出结果。 W_f 、 W_i 和 W_o 分别是遗忘门、输入门和输出门的权重矩阵。 b_f 、 b_i 和 b_o 分别是遗忘门、输入门和输出门的偏置项。

从式(4)、式(5)和式(6)可以得出 LSTM 神经网络的最终输出 x'_t 是由输出门 o_t 和单元状态 C'_t 共同确定的^[9]。

$$C'_t = \tanh(W_c \cdot [x'_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = C_{t-1} \times f_t + i_t \times C'_t \quad (8)$$

$$x'_t = o_t \times \tanh(C_t) \quad (9)$$

其中, W_c 是记忆单元的权重矩阵, b_c 是记忆单元的偏置项, C_t 是 t 时刻的记忆单元。

1.3 ARMA-LSTM 模型训练步骤

首先,用 db 小波函数对原始光功率数据 Z 进行小波分解,之后用二插值重构算法进行重构得到光功率数据的趋势项部分 $X_1, X_2, \dots, X_N$ 和细节项部分 $Y_1, Y_2, \dots, Y_{N_0}$ 。

其次,构建趋势项预测模型,步骤如下:

①归一化。对光功率趋势项 $\{X_t, t=1,2,3,\dots,N\}$ 进行归一化,使归一化的数据位于 $(-1,1)$ 之间。

②划分数据。将前 200 个数据划分为训练数据,后 50 个数据划分为测试数据。

③构建网络。LSTM 的输入层选择 50 个神经元,隐层选择 30 个神经元,输出层选择 1 个神经元,模型迭代次数为 1000 次。

④趋势项预测。用步骤②获得的模型进行预测得到光功率趋势项数据预测结果。

⑤反归一化。还原 LSTM 模型预测出的结果。

再次,构建细节项预测模型,其步骤如下:

①模型识别。计算光功率细节项样本数据 $\{Y_t, t=1,2,3,\dots,N\}$ 的自相关函数(ACF)和偏自相关函数(PACF),并根据所得的 ACF 和 PACF,判定用于光功率细节项数据进行预测的模型为 $ARMA(p,q)$ 模型。

②模型定阶。根据得到的最小信息准则(AIC)值确定最优模型阶数 p 和 q 。

③模型检验。判断残差序列是否为白噪声序列。若模型残差序列不是白噪声序列,转向步骤②,重新修改模型,并确定模型阶次,直到得到最优模型为止。

④模型预测。利用构建的 ARMA 模型对后 50 天的光功率细节项数据测试样本集进行预测。

然后,将趋势项模型预测结果和细节项模型预测结果进行相加,得到最终的 ARMA-LSTM 组合预测模型结果。

最后,进行误差计算,根据不同 db 小波分解和不同分解层数下的 ARMA-LSTM 模型的预测结果计算均方根误差(RMSE),最小 RMSE 即为所需要的最优小波分解。

2 实验及结果分析

本文所采用的实验数据来自吉林省电力公司某变电站,每半小时从光端机提取一次电力光纤的光功率值,连续提取 250 天的数据,将每天提取的光功率值的平均值作为样本数据得到 250 天的光功率数据,如图 2 所示。将前 200 个光功率数据作为训练样本集,后 50 个光功率数据作为测试样本集来对预测结果进行检验。首先用不同的小波对原始光功率数据进行一层小波分解,然后采用二插值重构算法进行重构。最后对趋势项部分和细节项部分分别用 LSTM 模型和 ARMA 模型进行建模。




图 2 原始光功率信号

对于趋势项部分使用 LSTM 神经网络建模进行预测,对于细节项部分使用 ARMA 模型进行预测,最终将两种结果相加得到 ARMA-LSTM 的光功率预测结果。首先,用不同 db 小波对原始数据进行分解,分解后的数据用 ARMA-LSTM 预测,其结果如表 1 所示。得出用 db5 小波模型预测最高。然后,用 db5 小波对原始数据进行不同层数分解,并用模型进行预测。用 db5 小波一层分解、二层分解、三层分解和四层分解得到 RMSE 依次为 0.0654、0.06801、0.0741 和 0.0851。

表 1 不同小波的 ARMA-LSTM 模型光功率预测的 RMSE 值

小波函数	RMSE	小波函数	RMSE
db1	0.0823	db6	0.0678
db2	0.0781	db7	0.0714
db3	0.0740	db8	0.0759
db4	0.0693	db9	0.0792
db5	0.0654	db10	0.0834

从以上结果可以看出,用 db5 小波进行一层分解时,ARMA-LSTM 光功率预测精度最高,其 $RMSE=0.0654$,所以采用 db5 小波对原始光功率进行一层分解效果最好,其分解结果如图 3 所示。对于低频部分使用 LSTM 神经网络建模进行预测,LSTM 模型输入 50 个神经元,循环次数为 1000 次,预测结果如图 4 所示。高频部分为平稳时间序列,直接使用 AIC 进行模型定阶,当 $p=24,q=14$ 时取得 AIC 值为-7.3211,确定模型为 ARMA(24,14),结果如图 5 所示。

ARMA-LSTM 预测模型最终的预测结果如图 6 所示。为与之对比,本文用传统光功率预测模型进行光功率预测,即根据自回归积分滑动平均(ARIMA)模型对没有小波分解的原始光功率数据进行预测。首先对原始光功率数据进行差分处理得到平稳化的时间序




图 3 db5 小波分解的趋势项部分和细节项部分




图 4 LSTM 模型下光功率趋势项预测结果




图 5 ARMA 模型下光功率细节项预测结果




图 6 ARMA-LSTM 模型的光功率预测曲线




图 7 ARIMA 模型的光功率预测曲线




图 8 SVM 模型的光功率预测曲线




图 9 LSTM 模型的光功率预测曲线




图 10 ARMA-SVM 模型的光功率预测曲线

列并进行 AIC 判定,当 ARIMA 模型阶数取 $p=13, q=3$ 时,得到的 AIC 值最小,由此确定为 ARIMA(13,1,3) 模型的预测结果如图 7 所示。根据支持向量机(SVM)建模方法对没有小波分解的原始光功率数据进行预测,其预测结果如图 8 所示。根据 LSTM 神经网络的建模步骤对没有小波分解的原始光功率数据进行预测,其预测结果如图 9 所示。根据 ARMA-SVM 预测模型进行预测,ARMA 预测光功率的细节项部分,SVM 预测光功率的趋势项部分,其预测结果如图 10 所示。

为了更好地对比 ARIMA、SVM、LSTM、ARMA-SVM 和 ARMA-LSTM 的预测结果,本文列举出 5 种预测模型的预测误差,如表 2 所示。可以看出,ARMA-LSTM 的预测精度最高,其 $RMSE=0.0654$,该组合模型的预测精度较 ARMA 模型提高了 54.6%,较 SVM 模型提高了 40.8%,较 LSTM 模型提高了 39.2%,较 ARMA-SVM 模型提高了 22.6%。

表 2 5 种预测模型的 RMSE 值

预测方法	RMSE	预测方法	RMSE
ARIMA	0.1471	ARMA-SVM	0.0845
SVM	0.1156	ARMA-LSTM	0.0654
LSTM	0.1075	—	—

3 结束语

本文针对电力通信光纤光功率时间序列时变性

和非线性等特点,设计了一种基于 ARMA-LSTM 光功率预测模型。该预测模型的预测精度较传统的 ARIMA、SVM、LSTM 和 ARMA-SVM 预测模型有较大提升。本文研究光纤状态趋势发展状况并根据其趋势预知未来发生的故障,将电力光纤线路的事后维护变为事先进行维护,这对电力通信系统的稳定运行具有重大的意义。

参考文献:

- [1] 张锡市. 光缆监测系统在电力通信网络中的研究与应用 [J]. 信息通信, 2011, 21(6): 39-40.
- [2] 陈晓娟, 郑国男, 王圣达. 三种工作模式自由切换的电力光纤监测系统 [J]. 光通信技术, 2015, 39(12): 41-44.
- [3] 姜万昌, 杨畅, 隋吉生. 基于小波变化的 ARMA-RBF 光功率组合预测 [J]. 光通信技术, 2013, 37(12): 29-41.
- [4] 梁昌勇, 马银超, 陈荣, 等. 基于 SVR-ARMA 组合模型的日旅游需求预测 [J]. 管理工程学报, 2015, 26(1): 122-127.
- [5] 杨高飞, 徐睿, 秦鸣, 等. 基于 ARMA 和卡尔曼滤波的短时交通预测 [J]. 郑州大学学报, 2017, 38(2): 36-40.
- [6] 赵江波, 刘静伟. 光纤通信技术现状及研究热点分析 [J]. 无线互联科技, 2015, 26(10): 7-8.
- [7] 代杰杰, 宋辉, 盛戈峰, 等. 采用 LSTM 网络的电力变压器运行状态预测方法研究 [J]. 高电压技术, 2018, 44(4): 1099-1106.
- [8] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆网络的风电场发电功率超短期预测 [J]. 电网技术, 2017, 41(12): 3797-3802.
- [9] 徐尧强, 方乐恒, 赵冬华, 等. 基于 LSTM 神经网络的用电量预测 [J]. 电力大数据, 2017, 20(8): 25-28.