

基于改进GRNN的电网雷击跳闸预测

韩志彦, 常虹, 范泽敏, 陈静

华东理工大学信息科学与工程学院, 上海

Email: Xhc2016@gmail.com, hchang@ecust.edu.cn, 15753633628@163.com, claudia@163.com

收稿日期: 2020年11月12日; 录用日期: 2020年12月9日; 发布日期: 2020年12月16日

摘要

电力系统的安全可靠稳定有着重大意义, 而雷击输电线路导致跳闸是一种常见的危害形式, 因此有效预防预测雷击跳闸事故有着重要的意义。本文针对广义回归神经网络的超参数优化选择问题, 提出基于和声搜索算法的优化超参数方法, 将改进后广义回归神经网络用于建立雷击跳闸预测模型, 并采用故障检测率、误报率、总预测精度以及平均绝对误差等性能指标评价该预测模型的预测性能。实验结果表明本文建立的模型能够准确预测雷击跳闸, 预测模型性能优异。

关键词

雷击跳闸, 广义回归神经网络, 神经网络, 和声搜索算法

Predicting Lightning Outages of Transmission Lines Using Modified Generalized Regression Neural Network

Zhiyan Han, Hong Chang, Zemin Fan, Jing Chen

School of Information Science and Engineering, East China University of Science and Technology, Shanghai

Email: Xhc2016@gmail.com, hchang@ecust.edu.cn, 15753633628@163.com, claudia@163.com

Received: Nov. 12th, 2020; accepted: Dec. 9th, 2020; published: Dec. 16th, 2020

Abstract

The security, reliability and stability of power system are of great significance. Tripping caused by lightning strikes on transmission lines is a common form of hazard. Therefore, it is of great significance to effectively prevent and predict lightning strikes. Aiming at the problem of optimal selec-

tion of hyperparameters in generalized regression neural networks (GRNN), this paper proposes an optimal hyperparametric method based on harmony search (HS) algorithm. Then, the improved method is applied to establish the prediction model of lightning strikes. Fault detection rate (FDR), false alarm rate (FAR), total prediction accuracy (PA) and mean absolute error (MAE) are adopted to evaluate the prediction performance. The test results indicate that the prediction model of lightning strikes based on improved GRNN can accurately predict lightning outages with an outstanding performance.

Keywords

Lightning Outage, General Regression Neural Networks, Neural Networks, Harmony Search Algorithm

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

电力系统是将其他能源转化为电能并将其传输给用户的系统，其中，输电网络与配电网络是电力系统重要的组成部分，是电能传输的动脉。除了的自然物理的因素和人为因素之外，雷击是造成电力系统供配电网络可靠性降低的一个重要的因素。220 kV 及以上电压等级的输电线路是省级电网的骨干网络，其架空输电线路往往需要穿越各种野外自然环境恶劣的地区[1]。据统计全国高压输电线路跳闸事故中，雷击引起的高压输电线路跳闸事故占到了跳闸事故的 40%~70%。特别是在雷电多发、土壤电阻率低、地形多变复杂的地区，雷击导致输电线路跳闸的概率更高[2]。在国外的实际运行中，雷击跳闸仍然严重危害这是输电线路安全运作。欧美发达国家因雷击引起的事故都占 50%以上，而在美加等国雷击引起的输电线路事故占到了 60% [3]。输电线路的等级越高受到雷击的概率也越高。

雷电现象和雷击的复杂随机特性导致了雷击跳闸故障的复杂随机性，给电力系统的安全可靠稳定地运行带来了巨大的隐患。因此对输电线路雷电事故风险进行评估具有重要意义。准确预测雷击故障能够为输电线路的运行维护提供预警信息，对于提高电网的可靠性，提高用户用电的可靠性[4]，具有重要的工程应用意义。

为了提高电网的可靠性，避免因雷击造成灾难性后果，许多学者进行了相关研究[5] [6]。文献[5]首次提出了采用神经网络的方法预测输电线路雷击跳闸，对雷击跳闸故障进行提前预测、提前干预，避免故障的发生。Hunt [7]等人针对雷电定位系统可能出现误报的现象，采用二元 t 分布对该类误报进行了建模分析，通过对南美及澳大利亚电网的测试分析，证明了二元 t 分布在雷电定位系统误差建模方面表现出良好的性能。文献[8]采用数据挖掘的方法对输电线路两端的初始电压行波进行分析，检测沿 220 kV 输电线路不同段的雷击情况，进而对输电线路进行继电保护处理。相比传统继电保护方法，该方法提高了故障检测速度，但仍属于故障发生后的保护，没有做到预报警。

本文针对电网特别是输电线路的雷击跳闸问题，分析雷击跳闸过程的数据提取参数，在文献[5]的基础之上采用改进的广义回归网络 GRNN 进行预测模型的建立与训练，解决了 GRNN 平滑参数选择盲目性的问题，提高了模型预测精度。将人工神经网络应用到高压输电线路的安全维护，也是人工智能方法与传统电气技术相结合的一种尝试。契合了我国 2020 年 3 月初提出的新基建计划中的人工智能与特高压、智

能电网方向,具有重要的理论意义。

2. 基于改进 GRNN 的雷击跳闸预测模型

输电线路跳闸的一个原因是由于雷电直接击中导体或输电塔而导致输电线路过压。世界各地的电力公司目前都配备了雷电定位系统(LLS)来监控雷电活动。LLS 可以对雷电发生的时刻、位置坐标、雷电电流幅值、雷电的极性以及回闪的次数等进行实时测量。

2.1. 雷击跳闸过程分析

雷击输电线路时,可能击中绝缘导体或杆塔。当雷击电流大于雷击电阻水平时,绝缘体可能会被击穿。因此,雷击跳闸的概率可以表示为式(1) [5]:

$$P = \eta(gP_1 + P_a P_2) \quad (1)$$

其中: η 是产生电弧的概率, g 是雷击杆塔的概率, P_a 是绕过架空地线的概率, P_1 是闪电电流概率, P_2 是绝缘屏蔽失效概率。

上述雷击跳闸模型可以定量评估当雷击输电线路时传输输电线路跳闸的概率。从上述雷击中断模型可以总结出:雷击跳闸的主要影响因素是雷电电流峰值和雷击传输线路的概率。

2.2. 基于改进 GRNN 的雷击跳闸预测步骤

由上述分析可知雷击跳闸概率主要由雷电电流峰值及雷击传输线路率概率两个因素决定。雷电电流峰值可以直接从 LLS 收集的雷电信息中获得,但雷击传输线路的概率无法直接收集。因此,本文提出采用预测的方法获得雷击输电线路概率。

根据经验可知,输电线路周围的闪电越多、闪电离传输线路越近,雷击传输线路的概率就越大。根据雷电和传输塔的位置信息,很容易计算雷电与传输线路之间的距离。进而,可以计算出输电线路一段距离范围内的雷击次数。本文将这个距离范围定义为雷电走廊。

根据上述分析可知:通过雷电走廊中的雷击次数、传输线与雷电之间的最近距离、雷电走廊的平均雷电电流强度以及最近雷击电流的峰流即可预测出输电线路受雷击跳闸的概率。

本文采用广义回归神经网络(GRNN)神经网络建立预测模型。GRNN 具有良好的非线性映射能力,建立模型不需要大量的样本,需要人为确定的参数较少。由于具体预测过程如下:

步骤 1) 构造样本集。根据前面的分析,预测模型的输入参数是雷电走廊中的雷击次数、传输线与雷电之间的最近距离、雷电走廊的平均雷电电流强度以及最近雷击的峰流。

步骤 2) 选择训练样本和测试样本。

步骤 3) 优化平滑参数。由于平滑参数的选取对预测精度有着决定性的作用,因此,为了避免盲目人为选择带来的缺点,本文采用和声搜索算法来选择最佳平滑参数。对 HS-GRNN 进行训练。

步骤 4) 采用训练后的 HS-GRNN [9]预测模型进行雷击跳闸预测。

步骤 5) 验证及评价模型的有效性。

2.3. 预测性能的评价指标

根据输电线路雷击跳闸问题的特点,本文选择故障检测率(FDR)、故障误报率(FAR)、总预测精度(PA)及平均绝对误差(Mean Absolute Error,简称 MAE)作为预测结果的评价指标。各评价指标的数学表达式如下所示:

$$\text{FDR} = \frac{FN}{FP + FN} \times 100\% \quad (2)$$

$$FAR = \frac{TN}{TP + TN} \times 100\% \tag{3}$$

$$PA = \frac{FN + TP}{FP + FN + TP + TN} \times 100\% \tag{4}$$

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \tag{5}$$

其中， FP 和 FN 分别为正常和跳闸的跳闸样本数； TP 和 TN 是分别分类为正常和跳闸的正常样本数； y 为实际值， \hat{y} 为预测值。

3. 仿真实验

3.1. 模型建立

本文实验数据就来自于某省级电网的 LLS 运行数据，共 240 组数据，本文选择其中 168 个样本作为训练集，剩余的 72 个样本作为测试集。训练集中有 83 个雷击跳闸样本(即 $y = 1$)和 85 个正常样本(即 $y = 0$)；在测试集中有 37 个雷击跳闸样本和 35 个正常样本。本文选择的雷电走廊为 1.5 km，HS-GRNN 输入信号：雷电走廊内的雷击次数 x_1 、输电线与雷电之间的最近距离 x_2 、雷电走廊内的雷击电流平均强度 x_3 及最近的雷击峰值电流 x_4 。雷击跳闸样本中的部分数据[5]如表 1 所示。

Table 1. Statistic of lightning trip information (Part)

表 1. 雷电信息统计(部分)

输电线	x_1 (次)	x_2 (km)	x_3 (KA)	x_4 (KA)
JJ	18	0.1017	75.42	80.0
SJ	1	0.6254	40.20	40.2
DB	25	0.0588	46.96	44.5
BJ	17	0.1301	51.22	52.0
WH	65	0.0549	44.04	40.8
YH	25	0.1244	49.90	50.4
YM	3	0.4929	145.26	76.9
FY	6	0.0436	53.30	30.2
GL	18	0.091	30.13	28.1
WY	45	0.0064	39.53	37.3

基于上述信息建立基于 HS-GRNN 的雷击跳闸预测模型：模型输入层神经元数目为 4；模式层的神经元数目与输入样本的数目相关，此处模式层的神经元数目为训练集的样本数，即为 168；求和层有两类神经元，一类是 SD 神经元(共 1 个)，另一类是 SN 神经元，其数目与神经网络的输出维度有关，此处为 1，因此求和层的神经元数目为 1；输出层的神经元数目也与神经网络的输出维度相关，也为 1。最后得到的 GRNN 结构如图 1 所示。

3.2. 基于 HS-GRNN 的雷击跳闸预测模型训练

为了避免 GRNN 平滑参数选择的盲目性, 本文采用 HS 算法对于 GRNN 平滑参数 $spread$ 寻优, 经过训练得到本问题最优平滑参数 $spread = 0.38589$ 。利用优化后的 GRNN 模型、采用预测样本对模型进行训练, 训练结果如图 2 所示。计算可得故障检测率 $FDR = 100.00\%$ 、误报率 $FAR = 0.00\%$ 、总预测精度 $PA = 100.00\%$ 以及平均绝对误差 $MAE = 3.0828E-5$ 。




Figure 1. GRNN structure applied to predicting lightning outages
图 1. 雷击跳闸预测中的 GRNN 神经网络结构

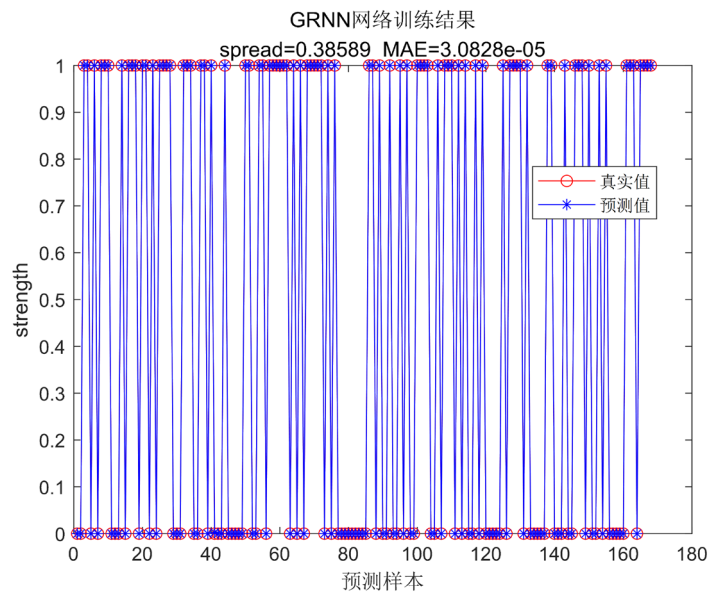


Figure 2. HS-GRNN predicting model training results
图 2. HS-GRNN 预测模型的训练结果

3.3. 基于 HS-GRNN 的雷击跳闸预测模型测试

采用上述模型、通过测试样本对模型的预测能力进行测试, 测试结果如图 3 所示。统计图 3 所得的测试结果如表 2 所示, 计算可得故障检测率 $FDR = 100.00\%$ 、误报率 $FAR = 0.00\%$ 、总预测精度 $PA = 100.00\%$ 以及平均绝对误差 $MAE = 8.4746E-6$ 。

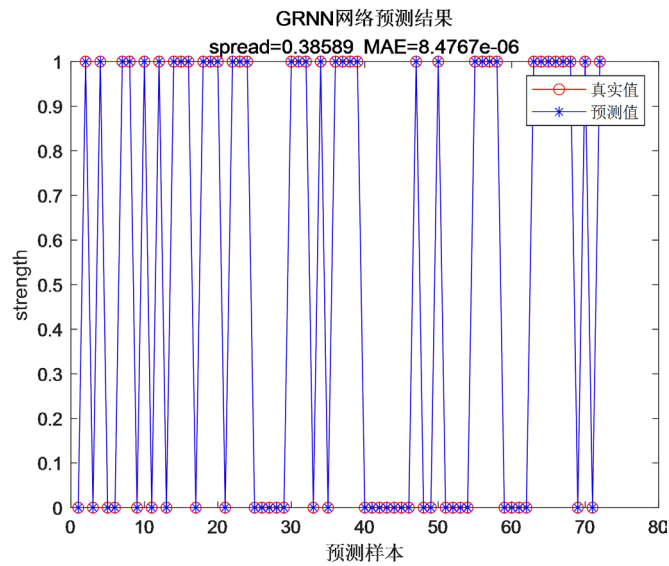


Figure 3. HS-GRNN predicting model testing results
图 3. HS-GRNN 预测模型的测试结果

Table 2. The statistics of predicting results by HS-GRNN
表 2. HS-GRNN 预测结果统计

Spread = 0.38589	分类为跳闸	分类为正常
跳闸样本	37	0
正常样本	0	35

3.4. 基于 HS-GRNN 的雷击跳闸预测结果与其他模型预测结果的对比

为了进一步评价本文提出了 HS-GRNN 雷击跳闸预测模型的预测精度及性能, 本文将该模型的预测结果与 BP、RBF、GRNN 预测模型的预测结果进行了对比, 结果如表 3 所示。从表 3 可见, 本文提出的 HS-GRNN 在平均绝对误差 MAE、故障检测率 FDR、故障误报率 FAR、总预测精度 PA 等各项指标上均占优, 尤其是 MAE 指标, 远小于 GRNN、BP 和 RBF 的预测平均绝对误差; 尽管 GRNN 和 HS-GRNN 在 FDR、FAR 及 PA 三项指标的表现相同, 但表 3 中 GRNN 的预测结果是在采用不同 spread 值进行训练后选择的最佳结果, 而 HS-GRNN 可以很好的避免该问题, 又能保证预测效果。

Table 3. Predicting results of different NN
表 3. 不同神经网络预测效果

神经网络	MAE	FDR	FAR	PA
GRNN	0.0028799	100.00%	0.00%	100.00%
BP	0.9947	91.89%	0.00%	95.83%
RBF	0.48751	5.41%	0.00%	51.39%
HS-GRNN	8.4746E-6	100.00%	0.00%	100.00%

4. 结束语

电力系统是国民经济运行的大动脉, 而深度学习、神经网络是近些年开始广泛应用的技术。把人工

智能等领域的相关技术成果应用在电气工程领域是一种探索之旅。本文就研究了基于改进的神经网络的雷击跳闸预测, 利于广义回归神经网络在类似于雷击跳闸这样的小样本问题上的拟合能力, 建立相应的预测模型进行雷击跳闸预测。同时, 采用智能算法对 GRNN 的平滑参数进行选取, 避免了选取过程的盲目性。经与其他预测模型预测结果对比, 本文提出的基于 HS-GRNN 的雷击跳闸预测模型在 MAE、FDR、FAR 及 PA 等各项指标上均表现优异, 为输电线路雷击跳闸的预防提供了新思路。

基金项目

本文受国家自然科学基金青年基金项目(61603139)资助。

参考文献

- [1] Hu, Y., *et al.* (2014) Analysis of Influential Factors on Operation Safety of Transmission Line and Countermeasures. *High Voltage Engineering*, **40**, 3491-3499.
- [2] 陈继东, 吴伯华. 线路型 500 kV 避雷器保护范围的研究[J]. 电磁避雷器, 2002(5): 33-38.
- [3] IEEE Working Group on Estimating Lightning Performance of Transmission Lines (1985) A Simplified Method for Estimating Lightning Performance of Transmission Lines. *IEEE Transactions on Power Apparatus and Systems*, **PAS-104**, 918-932. <https://doi.org/10.1109/TPAS.1985.319093>
- [4] 杨清, 熊小伏, 王建, 翁世杰. 一种输电线路雷击概率预测新方法及其在书店系统短期可靠性评估中的应用[J]. 智能电网, 2014, 4(2): 37-46.
- [5] Xie, Y.Y., Li, C.J., Lv, Y.J. and Yu, C. (2019) Predicting Lightning Outages of Transmission Lines Using Generalized Regression Neural Network. *Applied Soft Computing Journal*, **78**, 438-446. <https://doi.org/10.1016/j.asoc.2018.09.042>
- [6] Yao, C., *et al.* (2014) Study of Magnetic Fields from Different Types of Lightning Faults on a Multi-Tower System. *IEEE Transactions on Dielectrics and Electrical Insulation*, **21**, 1866-1874. <https://doi.org/10.1109/TDEI.2014.004324>
- [7] Hunt, H.G.P., *et al.* (2020) Can We Model the Statistical Distribution of Lightning Location System Errors Better? *Electric Power Systems Research*, **178**, 1-10. <https://doi.org/10.1016/j.epsr.2019.106042>
- [8] Morales, J.A., Anane, Z. and Cabral, R.J. (2018) Automatic Lightning Stroke Location on Transmission Lines Using Data Mining and Synchronized Initial Travelling. *Electric Power Systems Research*, **163**, 547-558. <https://doi.org/10.1016/j.epsr.2018.01.025>
- [9] Geem, Z.W., *et al.* (2001) A New Heuristic Optimization Algorithm: Harmony Search. *Simulation*, **76**, 60-68. <https://doi.org/10.1177/003754970107600201>