

基于泄露积分型 ESN 的电力负荷预测系统

李秋迪¹ 陈家豪¹ 侯玉双¹ 岳殿佐¹

LI Qiudi CHEN Jiahao HOU Yushuang YUE Dianzuo

摘要

电力负荷预测在能源领域扮演着十分重要的角色，良好的电力负荷预测系统可以帮助电力系统运营商提前做好供电策略，从而在保障电力系统运行稳定性的同时降低能耗。研究了基于泄露积分型回声状态网络的电力负荷预测系统的性能，构建了单点预测和短时连续自动预测两种预测模式，并评估了泄露率及权重矩阵谱半径对系统预测误差的影响。在单点预测模式下，系统基于历史数据进行下一时刻（15 min 之后）负荷值的预测，预测的归一化均方差最低 0.015 8；在短时连续自动预测模式下，系统能够根据历史数据连续预测之后一段时间的负荷值，预测值在 6.5 h 之内保持与真实值的偏差百分比低于 10%。

关键词

泄露积分型回声状态网络；电力负荷预测；单点预测；短时连续自动预测；参数优化

doi: 10.3969/j.issn.1672-9528.2024.09.036

0 引言

电力负荷预测作为电力行业的重要技术之一，对于保障电力供应的稳定性、提高能源利用效率以及推动能源可持续发展起着至关重要的作用。随着电力需求的不断增长和能源形势的日益严峻，准确预测电力负荷成为电力行业管理和运营的关键环节。传统的电力负荷预测方法主要基于机器学习的算法或者统计学方法，这些方法在一定程度上存在着精度不高、波动性大等问题。

近年来，越来越多的学者将人工神经网络（artificial neural network, ANN）引入电力负荷预测中，以提高预测结果的准确性。范国松等人^[1]在 2022 年建立了一种基于 PSO-BP 神经网络的电力负荷预测方法。叶国达等人^[2]利用反向传播神经网络对电力负荷进行预测。2024 年，常智慧等人^[3]提出了一种基于 CEEMDAN 与 INGO 优化 BiLSTM 的短期电力负荷预测系统。尽管目前存在的一些基于 ANN 的电力负荷预测系统在一定程度上提高了负荷预测的准确性和精度，但这些方法通常需要较高的计算成本，并对计算机性能有较高要求。

相比于结构复杂、训练困难的人工神经网络，泄露积分型回声状态网络（echo state network, ESN）只需要对输出权值进行更新，从而大大减少了计算量。同时，该算法避免了梯度消失、梯度爆炸等问题，对时序数据预测有很好的应用前景^[4]。基于上述分析，本文研究了基于泄露积分型 ESN 的

电力负荷预测系统，并在传统单点预测的基础上研究短时连续自动预测模式，分析系统关键参数对预测性能的影响。

1 基于泄露积分型 ESN 的电力负荷预测系统设计

ESN 的网络结构如图 1 所示，主要包括输入层、储备池层和输出层三部分，其中储备池层是一个由大量神经元组成的稀疏连接网络。ESN 中的输入权重与储备池层内部权重是随机生成的，输入数据在 ESN 中的递归连接作用下使网络具有一定的记忆能力。ESN 的训练过程涉及优化隐藏层到输出层的连接权重，通过不断调整连接权重，ESN 可以逐渐学习并适应输入数据的模式，从而提高其预测准确度和稳定性。




图 1 回声状态网络结构示意图

图 1 中 n 时刻，假设：输入层有 K 个节点，输入为 $u(n)$ ；储备池层有 N 个神经元，储备池状态为 $x(n)$ ；输出层有 L 个节点，输出为 $y(n)$ ^[5]。

那么 n 时刻的状态为：

$$u(n) = [u_1(n), u_2(n), \dots, u_K(n)]^T \quad (1)$$

$$x(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T \quad (2)$$

$$y(n) = [y_1(n), y_2(n), \dots, y_L(n)]^T \quad (3)$$

1. 河北科技师范学院数学与信息科技学院 河北秦皇岛 066004
[基金项目] 河北省自然科学基金项目“基于半导体激光器实时全光信息处理的储备池计算研究”（F2022407007）

图1中, 储备池相当于传统神经网络的隐藏层, 用 W_{in} 表示与储备池相连的输入权重, 用 W 表示储备池内部神经元的连接权重, W_{out} 表示储备池到输出层的输出权重。此外, W_{back} 表示从输出层到反馈回储备池层的连接权重。

每一时刻储备池的输入 $u(n)$ 都会对储备池层的状态 $x(n)$ 进行更新, 其状态更新公式为:

$$x(n+1)=f(W_{in}u(n+1)+Wx(n)+W_{back}y(n)) \quad (4)$$

式中: W_{in} 、 W 以及 W_{back} 三个权重均是在第一次构建 ESN 时随机产生的, 并且不会改变。其中, $u(n+1)$ 表示此刻输入层的输入, f 是储备池中神经元的激活函数, $x(n)$ 是上一时刻的储备池状态, $x(n+1)$ 是当前时刻的储备池状态^[5]。

目前诸多学者已经从不同的角度对 ESN 开展研究, 泄露积分型是一种比较常用的储备池优化方法。泄露积分型 ESN 为了控制储备池层内部神经元的状态持续程度引入了泄露率^[6]的概念。泄露积分型 ESN 的储备池层状态更新公式如式(5)所示:

$$x(n+1)=(1-\alpha)x(n)+f(W_{in}u(n+1)+Wx(n)+W_{back}y(n)) \quad (5)$$

式中: α 表示泄露率, 可视为离散后的储备池层状态更新速度。当 $\alpha=1$ 时, 系统就是传统 ESN, 由此可知泄露积分型 ESN 是 ESN 的改进模型。

经过训练后得到储备池输出权重 W_{out} , 进而基于当前储备池的状态 $x(n+1)$ 及上一时刻储备池的输出 $y(n)$ 可得到储备池的输出:

$$y(n+1)=f_{out}(W_{out} \times (u(n+1), x(n+1), y(n))) \quad (6)$$

式中: f_{out} 表示输出层神经元激活函数。

基于泄露积分型 ESN 的工作流程主要包括网络初始化、训练、测试三部分, 如图2所示。




图2 回声状态网络构建工作流程图

首先, 对泄露积分型 ESN 进行初始化。在储备池中, 本系统选择 $\tanh$ 函数作为神经元的激活函数, 其表达式为:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

式中: e 是自然对数的底, x 是输入值。 $\tanh$ 函数具有 S 形曲线特点, 函数的取值范围为 $[-1,1]$ 。相较于 Sigmoid 函数的取值范围为 $[0,1]$, $\tanh$ 函数的输出范围更广, 具有更好的对称性。同时, $\tanh$ 函数的导数形式简单, 且在 0 点处的导数最大,

有利于梯度下降算法的收敛。

其次, 初始化连接权重。由于泄露积分型 ESN 仅通过调整输出权重 (W_{out}) 来线性拟合输出结果, 输入层与储备池层的权重 (W_{in} 与 W) 采用均匀分布的随机数生成。虽然 W 是随机生成的, 但储备池层作为 ESN 的重要组成部分, 它的参数选择在一定程度上决定了 ESN 的性能。谱半径 θ 作为储备池层权重矩阵 W 的最大特征值的绝对值, 是影响储备池记忆能力的一个关键因素^[7]。通常可设定 $\theta < 1$, 以确保 ESN 具有回声状态性质。

在构建完泄露积分型 ESN 网络结构之后, 基于选择的数据集对输出权重进行训练。在泄露积分型 ESN 中, 只需训练输出层权重 W_{out} 即可, 这里使用岭回归, 对 W_{out} 进行训练方法公式为:

$$W_{out} = Y_d X^T (X X^T + \beta I)^{-1} \quad (8)$$

$$Y = W_{out} X \quad (9)$$

式中: W_{out} 表示输出权重, X 表示储备池状态, β 表示正则化项, Y_d 表示期望输出, Y 表示储备池实际输出^[8]。

基于泄露积分型 ESN 的电力负荷预测系统通过结合人工神经网络的强大非线性建模能力和 ESN 的高效计算特性, 实现对电力负荷需求的准确预测。使用了 2018 年 9 月无锡市电力负荷数据集对系统进行训练和测试, 该数据集每隔 15 min 采集一次电力负荷值。系统选取了其中 2000 个数据点进行训练, 另外选取 1000 个数据点用于测试。负荷值在输入系统前进行了归一化处理, 其公式为:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (10)$$

式中: X_{norm} 是归一化后的数据, X_{min} 是原始数据中的最小值, X 是原始数据, X_{max} 是原始数据中的最大值。

在系统中, 设计了两种预测模式: 单点预测模式和短时连续自动预测模式。两种模式的训练过程是一致的, 即设定训练集 $u(1) \sim u(n)$, 实际输出为 $y(1) \sim y(n)$, 期望输出为 $u(2) \sim u(n+1)$, 按岭回归方法得到训练后的输出权重为 W_{out} 。在训练之后的运行过程中, 单点预测模式中输入为当前实际负荷值 $u(n+1)$, 输出 $y(n+1)$ 尽可能地拟合下一时刻的负荷值 $u(n+2)$, 如此反复。在短时连续自动预测模式下, 训练后的最后一个输出值 $y(n)$ 将作为下一时刻系统的输入值再次注入储备池, 即替代了单点预测中的 $u(n+1)$, 它将产生新的输出值 $y(n+1)$ 以拟合期望值 $u(n+2)$ 。进而, $y(n+1)$ 将再次输入到储备池产生新的输出, 如此反复。可见, 在单点预测模式下系统不断接受真实的电力负荷值而产生下一时刻的预测值。而在短时连续自动预测模式下, 训练后的系统不再接受真实电力负荷值, 而是凭借训练的结果和自身的演化连续运行输出后续一系列预测值。

2 系统优化


系统优化可以有效地提高系统的运行效率、系统预测性

能和稳定性。在基于泄露积分型 ESN 的电力负荷预测系统优化过程中,本文着重考虑了谱半径 θ 和泄露率 a 对系统性能的影响。ESN 中一般设定谱半径 $\theta < 1$, 以确保储备池具有回声状态性质,但是当谱半径 θ 过于小时,会导致网络的动态范围减小,从而影响系统的预测性能^[9];泄露率 a 较小时,上一时刻内部神经元的状态变化较慢,从而网络的短期记忆能力较强。但是当 a 过于小时,会出现过度记忆或过度拟合的情况^[10]。这意味着网络可能会过度依赖先前的输入,从而忽略了新的输入,导致网络在处理新数据时出现问题。为了确定 θ 和 a 的最佳取值,评估系统预测的准确性,系统通过遍历不同的参数组合,并利用归一化均方差(normalized mean square error, NMSE)来评估系统预测性能。

$$NMSE = \frac{1}{L} \sum_{n=1}^L [y(n) - y_d(n)]^2 / \text{var}(y_d) \quad (11)$$

式中: L 为测试数据的长度, $y(n)$ 为实际输出, y_d 为期望输出, var 为方差。

图 3 首先分析了提前 1 步预测时泄露率 a 和谱半径 θ 对预测误差 NMSE 的影响。图 3 (a) 为谱半径 $\theta=0.5$ 时 NMSE 随 a 的变化。从图 3 (a) 中可以观察到随着 a 由 0.2 增加到 1, NMSE 先减小而后振荡增加, a 在 0.28 左右 NMSE 达到最小值 0.016。可见, a 过小或者过大均不利于系统的准确预测。图 3 (b) 为 $a=0.28$ 时, NMSE 随 θ 的变化。 θ 在由 0 增加的过程中 NMSE 显示缓慢变小,而后突然急剧增加。 $\theta=0.42$ 时, NMSE 取得相对较小的值。



(a) NMSE 随泄露率 a 的变化 (b) NMSE 随谱半径 θ 的变化

图 3 提前 1 步预测时 NMSE 的变化





图 4 NMSE 随泄露率 a 和谱半径 θ 的变化的二维图

从上面的测试中可以发现, a 和 θ 的变化都会导致 NMSE 的变化, 因此有必要将 a 和 θ 联合起来分析。图 4 为 NMSE 随 a 和 θ 的变化的二维图, 其中不同颜色表示不同

NMSE 的值。为了突出预测性能好的区域颜色的变化情况, $NMSE > 0.02$ 的区域均由白色表示, 图中白色虚线圈出了 $NMSE \leq 0.016$ 的参数区域。可以看到, NMSE 值较低的蓝色区域集中在适中的 θ 和相对小的 a 处, 当 θ 在 0.48 附近且泄露率 a 在 0.28 附近时 NMSE 较小, 系统具有较好的预测性能。

分析出谱半径和泄露率对单点预测模式下提前一步预测的影响后, 进一步检验系统在单点预测中提前 n 预测的性能。当参数为 $a = 0.28$ 和 $\theta = 0.5$ 时, 图 5 呈现了在不同预测步数下的系统预测误差。数据集是每隔 15 min 采集一点数据的, 因此提前 n 步预测也可视为提前 $n \times 15$ min 预测。图 5 (a) 至图 5 (d) 分别为提前 1 步至 4 步预测。从图中可以观察到, 随着预测步数的增加, 系统预测误差逐渐增大。在提前 1 步预测时, $NMSE=0.0158$ 。提前两步预测时, $NMSE=0.0294$ 。提前 3 步预测和提前 4 步预测时, 红色曲线(预测值)与蓝色曲线(实际值)有了明显的偏差, 其 NMSE 值分别为 0.0448 和 0.0616。由此可见, 在单点预测模式下, 提前 2 步之内预测(30 min 内预测), 系统展现出了较高的预测准确性。




(a 为提前 1 步预测; b 为提前 2 步预测; c 为提前 3 步预测; d 为提前 4 步预测)

图 5 $a = 0.28$, $\theta = 0.5$ 时单点预测模式下的预测结果

接下来研究短时连续自动预测模式下系统的预测性能。如前面所述, 在此模式下, 系统训练后不再接受实际负荷值作为输入, 而是以预测值作为输入继续预测下一个负荷值, 如此反复。当系统较好地实现短时连续自动预测时, 系统实际上模拟了一个电力负荷值演化的过程。图 6 (a) 展示了短时连续自动预测模式下当参数为 $a=0.28$ 和 $\theta=0.5$ 时, 负荷真实值与预测值随迭代时间增长的变化情况。如图 6 (a) 所示, 在 6.5 h 内, 预测值在真实值上下浮动, 呈现出相同的变化趋势。但当时间超过 6.5 h, 预测值的变化趋势与真实值的变化趋势明显不同。这是由于在短时连续预测模式下, 系统误差积累到一定程度导致的。图 6 (b) 显示了预测值偏差百分比随时间的变化, 这里偏差百分比表示 $(| \text{真实值} - \text{预测值} | / \text{真实值}) \times 100\%$ 。

值 y / 真实值 $\times 100\%$ 。由图可知, 在 6.5 h 之内偏差百分比低于 10%。然而, 超过 6.5 h 后, 偏差百分比急剧增加至超过 40%。这表明, 在短时连续自动预测模式下, 系统在 6.5 h 内的预测准确性较高。



(a) 实际值和预测值
随时间的变化
(b) 预测偏差百分比
随时间的变化

图 6 短时连续自动预测模式的运行结果

最后, 为了便于用户的使用, 基于 Matlab GUI 开发了电力负荷预测系统界面, 如图 7 所示。界面主要包含真实历史数据查看、预测模式选择、模型参数微调、预测结果展示几部分。界面上方为真实历史数据查看区域, 左上角的波动线图显示了历史上某月电力负荷波动情况, 其中红线为峰值, 黑线为均值, 绿线为谷值, 可以帮助用户更加直观地观察真实历史数据的变化趋势。中上部的线图展示了当月每天最高气温与最低气温的一个变化折线图, 让用户可以比较不同气温下电力负荷的一个情况。右上部分为 ESN 的网络结构模型。在预测模式选择区域中设置了单点预测和短时连续自动预测功能选择按钮, 用户可以通过这些按钮执行相应的操作。在

模型参数调整区域内, 用户可以根据自己的需求修改泄露积分型 ESN 模型的参数如训练样本数量、测试样本数量、神经元个数、泄露率、谱半径。右下角区域为预测结果展示部分, 展示了在已选择的预测模式下系统预测值与真实值的变化情况以及测试误差 NMSE 的值。

3 结论

本文基于泄露积分型 ESN 模型构建了电力负荷预测系统, 详细分析了泄露率和谱半径对预测性能的影响, 找到了优化的参数, 设计了单点预测和短时连续自动预测两种运行模式。系统选取 2018 年无锡市真实负荷数据进行了测试, 在单点预测模式下提前 1 步预测的 NMSE 最低值为 0.015 8, 预测性能较好。在短时连续自动预测模式下, 系统在 6.5 h 内连续预测的结果与实际值相比, 预测值偏差低于 10%。此外, 为便于系统的应用, 设计了软件界面, 能够直观显示数据的变化趋势, 便于系统的模式选择和参数调节。

参考文献:

- [1] 范国松, 齐正. PSO-BP 神经网络的电力负荷预测研究 [J]. 微型电脑应用, 2022, 38(10): 130-133.
- [2] 叶国达. 基于 BP 神经网络的电力系统负荷预测算法研究及实现 [J]. 重庆电力高等专科学校学报, 2023, 28(5): 1-4.
- [3] 常智慧, 徐耀松. 基于 CEEMDAN 与 INGO 优化 BiLSTM 的短期电力负荷预测 [J/OL]. 控制工程, 1-9 [2024-05-08]. <https://doi.org/10.14107/j.cnki.kzgc.20230089>.




图 7 系统界面

基于频谱分析与支持向量机的绕组检测分析方式比较研究

秦培浩¹

QIN Peihao

摘要

电力系统中绕组工频交流耐压试验能够有效检验绕组的绝缘强度和耐压水平,通过检测数据以及相关技术分析手段发现绕组内部是否存在缺陷,确保绕组在运行过程中能够承受规定的工频交流电压。对电力行业常用的电力设备检测方式与频谱分析、支持向量机分析手段进行了比较分析,并在算法框架搭建方面给出了进一步的优化方向。

关键词

电气;绕组检测;频谱分析;支持向量机;人工智能

doi: 10.3969/j.issn.1672-9528.2024.09.037

0 引言

电气检测试验作为各行业电力系统的重点工作内容,流程严谨性和成果准确性至关重要。目前行业中的一般检测试验工作多以人工检测配合兆欧表、耐压器以及工频谐振试验装置等设备完成测试与分析工作,方法简便易行,培训和操作周期较短,但设备投入成本较高,运维等工作较为频繁,这也是一般检测试验的缺点。文章以红石电站4号发电机定子绕组交流耐压试验为样本参考,综合现有的较为先进的检测手段,与一般检测试验方式进行对比分析。

1. 国网新源松花江水力发电有限公司吉林白山发电厂
吉林吉林 132000

1 一般检测试验方式

1.1 试验背景及目的

2022年红石电站4号发电机依据规程要求,需要进行定子绕组交流耐压试验,对绕组的绝缘强度、耐压水平等参数进行异常判定,对表面缺陷进行全方面检查,针对闪络、放电、绝缘击穿等异常情况进行收集整理。

1.2 仪器选用及接线图设计

FLUKE1550C兆欧表、ZGSIII-60/5型直流耐压器以及GXZ-1200kVA工频谐振试验装置。红石4号发电机铭牌参数如表1所示,试验接线如图1所示。

- [4] Muhammad M, FRANCESCO G, SONIA L, et al. Comparison of echo state network and feed-forward neural networks in electrical load forecasting for demand response programs[J]. Mathematics and computers in simulation, 2021, 184: 282-293.
- [5] 向传娇. 进化算法优化回声状态网络的时间序列预测研究[D]. 赣州: 江西理工大学, 2023.
- [6] 樊江川, 于昊正, 王冬生, 等. 基于PLESN和LESQRN概率预测模型的短期电力负荷预测[J]. 燕山大学学报, 2024, 48(1): 54-61.
- [7] 刘鑫. 基于改进回声状态网络的时间序列预测[D]. 吉林: 吉林化工学院, 2023.
- [8] GARDNER S D, HAIDER M R, MORADI L, et al. A modified echo state network for time independent image classification[C]//2021 IEEE International Midwest Symposium on Circuits and Systems (MWSCAS). Piscataway: IEEE, 2021: 255-258.

- [9] 张琪. 基于演化回声状态网络的时间序列预测研究[D]. 南京: 南京信息工程大学, 2022.
- [10] 王苑卉. 面向深度回声状态网络的参数优化方法研究[D]. 南京: 南京邮电大学, 2023.

【作者简介】

李秋迪(2000—), 女, 河北沧州人, 硕士研究生, 研究方向: 全光型储备池计算时间尺度优化。

陈家豪(2001—), 男, 河北邯郸人, 硕士研究生, 研究方向: 全光型储备池计算。

侯玉双(1979—), 女, 河北唐山人, 博士, 教授, 研究方向: 储备池计算。

岳殿佐(1982—), 通信作者(email: yuedianzuo@163.com), 男, 河北唐山人, 博士, 高级工程师, 硕士生导师, 研究方向: 储备池计算。

(收稿日期: 2024-06-19)