



基于神经网络模型的船舶电网短期电力负荷预测

张宇涵, 高海波, 商蕾, 林治国, 陈亚杰

引用本文:

张宇涵, 高海波, 商蕾, 等. 基于神经网络模型的船舶电网短期电力负荷预测[J]. 应用科技, 2021, 48(5): 12–15,22.

ZHANG Yuhuan, GAO Haibo, SHANG Lei, et al. Short-term load forecasting for marine electric network based on neural network models[J]. *Applied science and technology*, 2021, 48(5): 12–15,22.

在线阅读 View online: <https://dx.doi.org/10.11991/yykj.202101010>

您可能感兴趣的其他文章

Articles you may be interested in

基于LSTM神经网络的汽轮发电机状态监测系统

State monitoring system of turbine generator based on LSTM neural network

应用科技. 2020, 47(6): 96–100 <https://dx.doi.org/10.11991/yykj.202007003>

基于经验模态分解改进神经网络光伏出力预测

Improved neural network for output prediction of photovoltaic generation based on empirical modal decomposition

应用科技. 2020, 47(3): 41–45 <https://dx.doi.org/10.11991/yykj.201911018>

基于神经网络的燃气日负荷智能预测方法

Research on combination forecasting method of gas daily load based on neural network

应用科技. 2020, 47(2): 23–28 <https://dx.doi.org/10.11991/yykj.201904019>

船用高强度T型接头焊接角变形预测仿真

Simulation of T-joint based welding angular deformation in marine high-strength steel

应用科技. 2017, 44(4): 12–15 <https://dx.doi.org/10.11991/yykj.201607020>

遗传算法优化BP神经网络在中医按摩机器人中的应用

Application of BP neural network based on genetic algorithm optimization in Chinese medicine massage robot

应用科技. 2017, 44(2): 73–77 <https://dx.doi.org/10.11991/yykj.201603018>

考虑地形影响的短期风电功率预测

Short-term wind power prediction methods considering the influence of terrain

应用科技. 2015, 42(6): 6–9 <https://dx.doi.org/10.11991/yykj.201503032>



微信公众平台



期刊网址

DOI: 10.11991/ykj.202101010

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1191.U.20210825.1410.004.html>

基于神经网络模型的船舶电网短期电力负荷预测

张宇涵¹, 高海波¹, 商蕾¹, 林治国¹, 陈亚杰²

1. 武汉理工大学 能源与动力工程学院, 湖北 武汉 430063

2. 中国船舶重工集团公司 第七一一研究所, 上海 201101

摘 要:恶劣海况时电力推进船舶的电网负荷波动较大, 发电机组会频繁投入或退出电网, 准确的电力负荷预测将有助于优化能量管理策略, 保障电力系统的安全性, 并提升用电效率。人工神经网络拥有很强的学习能力和泛化能力, 能够有效的进行短期电力负荷预测。通过对反向传播 (BP)、径向基神经网络 (RBF)、Elman 共 3 种不同的网络模型进行原理阐述、数据处理、模型建立及参数调整后, 再对其在短期电力负荷预测的表现进行比较, RBF 神经网络的预测效果及各项评价指标最优, 且其模型建立最简便, 因此相较于另外两种网络更适合进行短期电力负荷预测。

关键词:短期电力负荷预测; BP 神经网络; RBF 神经网络; Elman 神经网络; 船舶电网; 计算机应用; 人工智能; 机器学习

中图分类号: TM715

文献标志码: A

文章编号: 1009-671X(2021)05-0012-05

Short-term load forecasting for marine electric network based on neural network models

ZHANG Yuhan¹, GAO Haibo¹, SHANG Lei¹, LIN Zhiguo¹, CHEN Yajie²

1. School of Energy and Power Engineering, Wuhan University of Technology, Wuhan 430063, China

2. No. 711 Research Institute, China Shipbuilding Industry Corporation, Shanghai 201101, China

Abstract: The electric power load of an electric propulsion ship fluctuates greatly under rough sea, and the generator sets will be frequently put into or out of the power grid. Accurate power load forecasting will be conducive to optimizing power management system, so as to ensure the security of power system and improve power efficiency. Artificial neural network has strong learning ability and generalization ability, and can effectively carry out short-term power load forecasting. After principle elaboration, data processing, modelling and parameter adjustment of three different network models—back propagation (BP), radial basis function (RBF) and Elman, their performance in short-term power load forecasting is compared. It is shown that RBF neural network has the best forecasting effect and the highest score of various evaluation indexes, and that its model is the easiest to build, for which it is more suitable for short-term power load forecasting than the other two networks.

Keywords: short-term load forecasting; BP neural network; RBF neural network; Elman neural network; marine electric network; computer application; artificial intelligence; machine learning

电力推进船舶发展迅速, 其电力推进负荷占比有时达到总装机容量的 70% 以上, 对于电站能量管理系统的要求也在不断提升。发生恶劣海况时, 机动航行或动力定位时整个电力系统负荷会产生较大的波动, 准确的电力负荷预测能够帮助调控发电机组合理供电, 应对负荷大幅波动对电

网造成的冲击, 根据预测结果还能够优化能量管理的策略, 对船舶电网整体稳定、高效运转起关键作用^[1-2]。船舶电力负荷预测可按照周期分为短、中、长 3 种^[3], 其中短期电力负荷预测注重时效性, 但由于时间很短, 所以对预测模型的精度和速度要求很高。较于传统的预测方法, 人工神经网络能够很好地处理电力负荷这类非线性的数据, 依靠其自身强大的学习能力和泛化能力成为了负荷预测的热点^[4], 每种智能方法都有其特殊的优势、局限性和应用合理性^[5]。本文分别使用 BP、RBF、Elman 共 3 种不同的网络对恶劣海况进行短期电力负荷预测, 探究不同神经网络各自的

收稿日期: 2021-01-23. 网络出版日期: 2021-08-26.

基金项目: 国家自然科学基金重点项目 (U1709215); 国家自然科学基金项目 (51579200); 中央高校基本科研业务费项目 (2018III053GX).

作者简介: 张宇涵, 男, 硕士研究生.

高海波, 男, 副教授, 博士.

通信作者: 高海波, E-mail: hbgao_whut@126.com.

优劣^[6-7],找到适合完成电力负荷预测的方法。

1 神经网络的基本原理

1.1 BP神经网络

BP神经网络是20世纪80年代由Rumelhart和McClelland提出的误差反向传播的多层前馈神经网络,是当前应用最广泛的神经网络^[8]。其网络结构如图1所示,一般情况下由输入层、隐含层、输出层3层组成。输入与输出之间均有连接。




图1 BP神经网络结构

BP神经网络的处理主体分为正向的信息传递和反向的误差传播2个部分。将数据输入,通过隐含层计算后传至输出层,该过程为正向信息传递,当输出和初设期望值不相符时,将其误差进行反向传播,根据梯度下降法的原理来降低误差,网络各层连接权值不断更新,最终使误差的均方值最小,该过程为误差反向传播。

1.2 RBF神经网络

RBF神经网络是在20世纪80年代由J.Moody和C.Darken提出的单隐层前馈神经网络^[9]。整个网络如图2所示,也是由3层组成,将数据输入,在隐含层中发生空间层到隐含层的转换,同时在隐含层中还可以实现非线性的转换,最终信息会以线性的形式传递到输出层。




图2 RBF神经网络结构

RBF神经网络可以在隐含层将输入的低维数据转换成高维,使原本线性不可分的数据在高维空间内变成线性可分数据,网络的整体结构简单,收敛速度理想,理论上能够逼近任何非线性

函数,也是广泛应用于回归预测的算法之一^[10]。

1.3 Elman神经网络

Elman神经网络是20世纪90年代由J.L.Elmman提出的一种动态递归神经网络^[11],其结构如图3所示。和传统的神经网络结构相比,该网络有一个特殊的层叫做承接层,它的功能是存储隐含层单元在前一时刻的输出值,并将其返回到网络的输入端,可以看作是一个延迟算子。通过隐含层与承接层这种连接方式能够增强网络处理动态信息的能力,进而能够达到动态建模的目的^[12]。




图3 Elman神经网络结构

2 数据处理与模型建立

2.1 数据处理

在进行负荷预测之前,数据的采集工作非常重要,若历史数据量不足,会导致无法准确预测,若过量则会导致网络训练时间过长,最终无法收敛。采集某船在恶劣海况下进行动力定位时的电网负荷数据,累计时长为25 min。图4所示为采集到的船舶电网负荷曲线图。在MATLAB中进行预测仿真,数据采集的周期设置为10 s,25 min内共采集150个数据,将前120个数据作为输入,通过神经网络进行预测,输出后30个数据与采集的后30个数据进行对比。




图4 实际负荷曲线

若获取的负荷数据前后差别过大超出可接受范围,则视为数据异常,需要对初始数据进行异

常处理工作,在此采用水平处理法。

若

$$\begin{cases} |Y(k) - Y(k-1)| > \alpha(k) \\ |Y(k) - Y(k+1)| > \beta(k) \end{cases}$$

则

$$Y(k) = \frac{Y(k-1) + Y(k+1)}{2}$$

式中: $\alpha(k)$ 、 $\beta(k)$ 为设置的阈值, k 为采样点,每隔 10 s 进行一次采样,一共采集 150 个点,取值范围为 1~150; $Y(k)$ 为第 k 个点的负荷值, $Y(k+1)$ 为第 $k+1$ 个点的负荷值,若 $k=150$ 则 $Y(k+1)$ 为第 1 个点的负荷值, $Y(k-1)$ 是第 $k-1$ 个点的负荷值,若 $k=1$ 则 $Y(k-1)$ 表示第 150 个点的电力负荷值。

对短期电力负荷进行预测,输入采用一段连续时间的电力负荷历史数据值作为单输入,为避免神经元饱和,需要对数据进行归一化处理^[13],在训练完成后再反归一化输出真实值。

归一化:

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

反归一化:

$$x_i = (x_{\max} - x_{\min})y_i + x_{\min}$$

式中: x_{\max} 、 x_{\min} 为输入负荷的最大值和最小值; x_i 、 y_i 是进行归一化前后的负荷值。

2.2 模型建立

2.2.1 BP 神经网络模型构建

完成了前期数据处理后,需要对神经网络的模型进行构建,网络创建采用 newff 命令,考虑到进行短期电力负荷需要网络能够快速收敛,故隐含层只取 1 层, BP 神经网络整体由 3 层组成,在此输入和输出均只有负荷值,故两层神经元个数均为 1, 隐含层神经元个数 N 通过经验公式和试凑法进行确定。经验公式为

$$N = \sqrt{m+l} + q \quad (1)$$

式中: N 为隐含层神经元个数, m 为输入层神经元个数, l 为输出层神经元个数, q 为 1~10 中的任意一个常数。

通过经验公式以及试凑法确立 BP 神经网络隐含层神经元的个数为 5, 误差设定为 1×10^{-3} , 其他数值均采用默认值。

2.2.2 RBF 神经网络模型构建

RBF 神经网络整体结构由 3 层组成, 隐含层中使用的径向基函数是高斯函数, 故激活函数表达式为

$$R(x_p - c_i) = \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right)$$

式中: $\|x_p - c_i\|$ 为欧式范数, c_i 为高斯函数的中心,

σ 为高斯函数的方差, x_p 为第 p 个输入样本。

输入和输出层依旧为 1 个神经元, 在 MATLAB 中创建神经网络有 2 种方式, 分别为 newrb 和 newrbe。newrbe 创建神经网络时, 隐含层神经元个数自动等于输入样本数量, 网络整体创建速度极快, 能够一次性得到零误差的径向基网络, 只需通过调整分布常数 spread 值来调整预测精度, 分布常数太小能提高网络训练速度, 但同时易出现过拟合状态。最终确定的 spread 值为 1.4。

2.2.3 Elman 神经网络模型构建

图 3 中 Elman 网络结构图的数学表达式^[14]为

$$\begin{cases} y(k) = g(w^2 h(k)) \\ h(k) = f(w^1 u(k-1) + w^3 x_c(k)) \\ x_c(k) = h(k-1) \end{cases}$$

式中: $f(x)$ 为隐含层神经元的传递函数, $g(x)$ 为输出层神经元的传递函数, $u(k-1)$ 为输入值, $h(k)$ 为隐含层输出值, $y(k)$ 为输出值, k 代表不同时刻, w^1 、 w^2 、 w^3 分别为输入层到隐含层、隐含层到输出层、承接层到隐含层的权值^[15]。

网络创建采用 elman 命令, 隐含层神经元个数依旧根据式 (1) 和试凑法确定, 最终个数确定为 5, 输入层和输出层神经元个数均为 1, Elman 的其他参数设置与 BP 保持一致即可。

3 仿真结果分析

仿真训练在网络建立后开始。图 5 给出了 BP、RBF 和 Elman 共 3 种不同神经网络各自的预测效果, 从效果图上看整体预测趋势都是符合要求的, BP 预测效果略差, Elman 次之, RBF 效果最好, 预测值几乎能和真实值完全拟合。




图5 3种网络预测效果

图 6 为预测相对误差图, 图中可见, BP 网络和 Elman 网络可以明显看出有多个预测误差较大的点, 其相对误差均存在一定的波动, RBF 网络误差波动很小。




图6 3种网络预测相对误差

对于网络预测的效果评价指标还有平均相对误差 (mean absolute percentage error, MAPE) 值、均方根误差 (root mean squared error, RMSE) 值和决定系数 (R^2)。

平均相对误差:

$$e_{\text{MAP}} = \left(\frac{1}{n} \right) \times \sum_{i=1}^n \left(\frac{|p_i - q_i|}{q_i} \right) \times 100\%$$

式中: n 为预测样本数; p_i 为预测值; q_i 为真实值。

均方根误差:

$$e_{\text{RMS}} = \sqrt{\left(\frac{1}{n} \right) \times \sum_{i=1}^n [p_i - q_i]^2}$$

决定系数:

$$R^2 = \frac{\left(n \sum_{i=1}^n p_i q_i - \left(\sum_{i=1}^n p_i \right) \cdot \left(\sum_{i=1}^n q_i \right) \right)^2}{\left(n \left(\sum_{i=1}^n p_i \right)^2 - \left(\sum_{i=1}^n p_i \right)^2 \right) \cdot \left(n \left(\sum_{i=1}^n q_i \right)^2 - \left(\sum_{i=1}^n q_i \right)^2 \right)}$$

表1为3种网络评价指标数据汇总,误差指标数值越小代表预测的结果越精确,决定系数越接近1,表明预测的结果越接近真实值,预测的准确度越高,船舶电网才能够越有效地进行能量分配。从表1中可明显看出RBF网络的各项指标相较另外2种网络更好,且RBF网络的结构简单,相较于另外2种网络,RBF网络模型只需要确定spread值就能完成模型构建,且RBF网络具有全局逼近能力,解决了BP网络可能陷入的局部最优问题,训练速度快,能够满足短期电力负荷预测的时效性。因此RBF神经网络更适合解决短期电力负荷预测问题。为增强结论的可靠性,我们将输入和输出的比例进行略微调整。表2为输入调整为130组、输出调整为20组数据的各网络评价指标,表3为输入调整为110组、输出调整为40组的各网络评价指标,从结果来看,RBF网络各项指标依然处于最优的状态。

表1 各网络的评价指标

评价指标	BP	RBF	Elman
e_{MAP}	0.0945	0.0069	0.0441
e_{RMS}	7.7499	0.6090	2.6088
R^2	0.9234	0.9995	0.9979

表2 输入为130组各网络的评价指标

评价指标	BP	RBF	Elman
e_{MAP}	0.5612	0.0123	0.0532
e_{RMS}	6.7812	1.1136	2.4558
R^2	0.9520	0.9977	0.9664

表3 输入为110组各网络的评价指标

评价指标	BP	RBF	Elman
e_{MAP}	0.2500	0.0075	0.0890
e_{RMS}	7.5582	0.8381	7.4349
R^2	0.9420	0.9993	0.9664

4 结论

1) 恶劣海况下,电力推进船舶进行动力定位或机动航行时,船舶电网的负荷具有很强的随机性,很难找到精确的数学模型去进行描述。但人工神经网络拥有强大的自学习能力,通过对历史数据的学习能够很好地找到其中内含的规律,因此借助人工神经网络能够很好地解决短期电力负荷预测问题。

2) 相较于BP神经网络,Elman独特的承接层具有短期记忆的功能,能够内部反馈并存储一部分过去时刻的信息,也十分适合船舶的实时电力负荷预测。

3) RBF神经网络的各项评价指标都要优于另外两种网络,网络模型建立简便、学习收敛速度快、误差小,能够有效地进行电力负荷预测,为能量管理策略进行合理的能量调度提供依据,提高船舶电网的工作效率。

参考文献:

- [1] 赵亮. 电力推进船舶的能量管理与负荷预测研究 [D]. 武汉: 武汉理工大学, 2016.
- [2] 朱常荣. 基于机器学习的智能电网短期电力负荷预测研究 [D]. 昆明: 昆明理工大学, 2020.
- [3] LAI C S, YANG Yuxiang, PAN Keda, et al. Multi-view neural network ensemble for Short and mid-term load forecasting[J]. *IEEE transactions on power systems*, 2021, 36(4): 2992-3003.
- [4] 唐德栋. 基于人工智能的短期电力负荷预测方法研究 [D]. 北京: 中国地质大学 (北京), 2020.

- Computer Vision and Pattern Recognition (CVPR). Las Vegas, USA, 2016: 2818–2826.
- [14] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, USA, 2016: 770–778.
- [15] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA, 2017: 936–944.
- [16] LIU Ying, CUI Hongyuan, KUANG Zheng, et al. Ship detection and classification on optical remote sensing images using deep learning[C]//The 4th Annual International Conference on Information Technology and Applications (ITA 2017). Guangzhou, China, 2017, 12: 05012.
- [17] SOMMER L W, SCHUCHERT T, BEYERER J. Fast deep vehicle detection in aerial images[C]//2017 IEEE Winter Conference on Applications of Computer Vision (WACV). Santa Rosa, USA, 2017: 311–319.
- [18] GUO Wei, YAND Wen, ZHANG Haijian, et al. Geospatial object detection in high resolution satellite images based on multi-scale convolutional neural network[J]. *Remote sensing*, 2018, 10(1): 131.
- [19] WANG E K, LI Yueping, NIE Zhe, et al. Deep fusion feature based object detection method for high resolution optical remote sensing images[J]. *Applied sciences*, 2019, 9(6): 1130.
- [20] CHENG Gong, ZHOU Peicheng, HAN Junwei. Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images[J]. *IEEE transactions on geoscience and remote sensing*, 2016, 54(12): 7405–7415.

本文引用格式:

杨志钢, 黎明, 李泳江. 基于 multi-FPN 的遥感目标检测方法 [J]. 应用科技, 2021, 48(5): 16–22.

YANG Zhigang, LI Ming, LI Yongjiang. An object detection method of remote sensing image based on multi-FPN[J]. *Applied science and technology*, 2021, 48(5): 16–22.

(上接第 15 页)

- [5] GE Quanbo, JIANG Haoyu, HE Meiguang, et al. Power load forecast based on fuzzy BP neural networks with dynamical estimation of weights[J]. *International journal of fuzzy systems*, 2020, 22(3): 956–969.
- [6] 李昌海. 基于机器学习算法的短期电力负荷预测研究 [D]. 成都: 电子科技大学, 2020.
- [7] 张彦. 基于不同神经网络模型的水环境承载力评价 [J]. 水科学与工程, 2019(3): 5–9.
- [8] HUA Xia, ZHANG Gang, YANG Jiawei, et al. Theory study and application of the BP-ANN method for power grid short-term load forecasting[J]. *ZTE communications*, 2015, 13(3): 2–5.
- [9] 周旭, 来庭煜, 饶佳黎. 基于 RBF 神经网络模型的电力系统短期负荷预测 [J]. 通信电源技术, 2018, 35(11): 152–154.
- [10] LIU Yuecan, ZHANG Kun, ZHEN Shuai, et al. WRL: a combined model for short-term load forecasting[M]//SHAO Jie, YIU M L, TOYODA M, et al. *Web and Big Data*. Cham: Springer, 2019: 35–42.
- [11] XIE Kun, YI Hong, HU Gangyi, et al. Short-term power load forecasting based on Elman neural network with particle swarm optimization[J]. *Neurocomputing*, 2020, 416: 136–142.
- [12] ZHENG Xiaoqiang, RAN Xinyu, CAI Mingxin. Short-term load forecasting of power system based on neural network intelligent algorithm[J]. *IEEE Access*, 2020, PP(99): 1–1.
- [13] 赵东雷, 李丹华, 库巍, 等. 基于神经网络的电力系统短期负荷预测 [J]. 华北电力技术, 2017(9): 22–27.
- [14] 李佳殷, 周勃, 乔清锋. 基于 Elman 神经网络的新风负荷预测研究 [J]. 建筑节能, 2020, 48(3): 19–21, 39.
- [15] 宋明达. 基于改进遗传算法优化 Elman 神经网络的短期负荷预测 [D]. 衡阳: 南华大学, 2020.

本文引用格式:

张宇涵, 高海波, 商蕾, 等. 基于神经网络模型的船舶电网短期电力负荷预测 [J]. 应用科技, 2021, 48(5): 12–15, 22.

ZHANG Yuhan, GAO Haibo, SHANG Lei, et al. Short-term load forecasting for marine electric network based on neural network models[J]. *Applied science and technology*, 2021, 48(5): 12–15, 22.