

文章编号: 1006-4710(2014)01-0102-06

# 基于自适应 Elman 神经网络的短期风电功率预测

肖蕾, 李郁侠

(西安理工大学 水利水电学院, 陕西 西安 710048)

**摘要:** 针对 BP 神经网络动态性能的不足、适应性较差的问题, 提出了基于自适应 Elman 神经网络的短期风电功率预测模型。通过对比不同隐含层数的 Elman 预测模型的预测误差, 选取最小误差的隐含层数作为自适应 Elman 预测模型的隐含层数; 根据不同的训练集和预测集的输入, 自动调节 Elman 隐含层节点数, 实现隐含层节点数的自适应, 寻求具有最佳隐含层节点数的预测模型, 提高了风电功率预测精度。

**关键词:** 短期风电功率预测; 不同隐含层数; 隐含层节点数的自适应; 自适应 Elman 神经网络模型  
**中图分类号:** TB551      **文献标志码:** A

## Short-term wind power prediction based on adaptive Elman neural network

XIAO Lei, LI Yuxia

(Faculty of Water Resources and Hydroelectric Engineering, Xi'an University of Technology, Xi'an 710048, China)

**Abstract:** With an aim at the problems of shortage of the BP neural network dynamic performance and low-adaptability, a short-term wind power prediction model based on the adaptive Elman neural network is proposed in this paper. Through the comparison of prediction errors in the number of different hidden layers of Elman prediction model, the number of the minimum error hidden layers is selected as the number of hidden layers in the adaptive Elman prediction model. In accordance with the inputs of different training set and prediction set, the number of Elman hidden layer nodes can be automatically regulated so as to realize the adaptation of number of hidden layer nodes and to seek for the prediction model with the best number of hidden layer nodes, whereby improving the prediction accuracy of wind power.

**Key words:** short-term wind power forecast; different hidden layer; the adaptability of the number of hidden layer node; adaptive Elman neural network model

短期风电功率预测可为电网调度部门进行经济调度和风电竞价上网提供依据, 预测精度的提高一直是研究的重点<sup>[1]</sup>。

早期的预测技术主要有趋势外推法、回归分析法、时间序列法等, 这些方法预测精度不高, 并且不具备自适应和自学习能力。近年来专家系统、人工神经网络<sup>[2-3]</sup>、小波分析<sup>[4-5]</sup>及支持向量机<sup>[6]</sup>等人工智能方法得到了广泛研究和应用, 其中人工神经网络法应用于风电功率预测, 取得了较好效果。目前大量应用的 BP 神经网络, 是一种静态神经网络, 用于预测动态的风电功率容易陷入局部最小值, 预测

精度很难提高<sup>[7-8]</sup>。

风电功率预测模型的输入变量包括温度、风速等, 这些因素是随时间变化的。为根据风电场所在区域的实际情况进行预测模型的自动调整, 本文建立了自适应 Elman 神经网络对短期风电功率进行预测。

## 1 Elman 神经网络

Elman 神经网络是一种反馈神经网络, 其神经网络一共有 4 层, 分别是输入层、隐含层、承接层, 输

收稿日期: 2013-10-20

作者简介: 肖蕾, 女, 硕士生, 研究方向为电力系统分析与优化运行。E-mail: 603334282@qq.com。

李郁侠, 男, 教授, 研究方向为电力市场理论与技术。E-mail: li-yuxia@163.com。

出层,输入层神经元起传输信号的作用,输出层神经元起线性加权的作用。承接层从隐含层接受反馈信号,用来记忆隐含层神经元前一刻的输出值,并用到本次计算中;反馈状态不同,则输出结果不同。承接层神经元的输出经延迟与存储,再输到隐含层,其对历史数据有敏感性,增加了网络自身处理动态信息的能力,可用于动态建模<sup>[9-11]</sup>。

设神经网络的输入向量为  $u$ , 隐含层输出向量为  $x$ , 承接层输出向量为  $x_c$ , 输出向量为  $y$ 。 $w^1$ 、 $w^2$  和  $w^3$  分别为隐含层到输出层、输入层到隐含层、承接层到隐含层的连接权值。 $g(\cdot)$  为输出神经元的激活函数,是隐含层输出的线性组合,一般采用 purelin 函数。 $f(\cdot)$  为隐含层神经元的激活函数,一般采用 tansig 函数。则各层之间的关系为:

$$x(k) = f(w^1 x_c(k) + w^2 (u(k-1))) \quad (1)$$

$$x_c(k) = x(k-1) \quad (2)$$

$$y(k) = g(w^3 x(k)) \quad (3)$$

Elman 神经网络算法可采用 BP 网络中附加动量的梯度下降反向传播算法对网络进行训练,其网络权值  $w^1$  和  $w^2$  的修正方法和 BP 网络中权值的修正方法一样,对  $w^3$  采用链式导数规则来修正,衡量算法是否结束的误差函数  $E$  为:

$$E = \sum_{k=1}^N [y(k) - d(k)] \quad (4)$$

式中,  $d(k)$  是期望输出向量。

## 2 Elman 神经网络的设计与改进

### 2.1 输入量的选取

风电场的输出功率随风的波动而波动,风力机捕获的风电功率可以用下式表示:

$$P = \frac{1}{2} C_p A \rho V^3 \quad (5)$$

式中,  $P$  为风轮输出功率(kW),  $C_p$  为风轮的功率系数,  $A$  为风轮扫掠面积( $m^2$ ),  $\rho$  为空气密度( $kg/m^3$ ),  $v$  为风速( $m/s$ )。

风速是影响风电功率输出的最重要因素,空气密度的大小直接关系到捕获的风能的多少。本文以西北某风电场 2011 年的气象数据为依据,得出了不同月份空气密度的日变化曲线(见图 1),月空气密度曲线图(见图 2)。从图 1 和图 2 可以看出同一月内不同天的空气密度变化不大,同一年中不同月的空气密度变化较大。

为了研究密度对风电功率的影响,本文取该风电场 1 月、7 月、8 月的各个典型日的历史风速和功率数据做出功率散点,如图 3。




图 1 不同月份空气密度的日变化曲线

Fig. 1 The daily changing curve of different months air density




图 2 空气密度的月变化曲线

Fig. 2 The month changing curve of the air density




图 3 1 月、7 月及 8 月的功率散点图

Fig. 3 The power scatter plot of January, July and August

从图 2 可以看出 7 月和 8 月的空气密度相近,从图 3 可以看出 7 月和 8 月功率变化趋势基本一样;从图 2 可以看出 1 月和 7 月份的空气密度相差较大,从图 3 可以看出 1 月和 7 月的功率变化趋势相差较大,通过分析可以得出结论:空气密度对风电功率输出的影响较大。

空气密度  $\rho$  为气压、气温和水气压的函数,其计算公式为:

$$\rho = \frac{1.276}{1+0.00366t} \cdot \frac{(P-0.378P_w)}{1000} \quad (6)$$

式中,  $P$  为气压(hPa),  $t$  为气温( $^{\circ}\text{C}$ ),  $P_w$  为水气压(hPa)。

几小时或是几天内的气压,水气压基本不变,但温度变化幅度较大,故密度也是变化的。温度变化幅度与气压、水气压的变化幅度相比较,对于式(6)来说,影响空气密度的最主要因素是温度,故短期风电功率预测(0~72 h)时选取风速和温度作为预测模型的输入。

## 2.2 数据预处理

为了提高训练速度和灵敏度以及避免隐含层函数的饱和区,对输入数据采用式(7)进行归一化处理,对输出数据采用式(8)进行反归一化处理。

$$y_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (7)$$

$$x_i = (x_{\max} - x_{\min}) \times y_i + x_{\min} \quad (8)$$

式中,  $x_{\max}$  和  $x_{\min}$  表示输入数据的最大值和最小值;  $y_i$  为输入数据归一化后的值。对历史风速、温度和功率进行归一化处理,对预测后输出的功率进行反归一化处理。

## 2.3 隐含层数的选取

一般情况下,Elman神经网络模型采用单隐含层的网络结构<sup>[12-13]</sup>;当输入因子较多时,为了满足学习速率、提高收敛速度,采用多隐含层的结构。但隐含层数不能过多,过多会使网络规模变大,增加网络的复杂性,有可能出现“过拟合”现象,使得网络的预测能力降低,还会使网络的训练时间过长。

本文采用 matlab 编写程序,选取误差最小的隐含层数建立自适应 Elman 神经网络模型。

## 2.4 隐含层节点数的自适应调节

隐含层神经元数目的选择必须综合多方面的因素,确定最佳的隐含层节点数。在满足预测精度的前提下,尽可能减少隐含层节点数<sup>[14-15]</sup>。

本文通过隐含层节点数的自适应调节来解决隐含层节点数的选取问题。通过比较不同隐含层节点数情况下的误差,选取误差最小的隐含层节点数为最优节点数,使隐层节点数能够随着训练集和预测集的更新不断的自我调节,自动以最优的隐层节点数进行预测。其核心问题是循环比较,通过比较每种隐含层节点数情况下的 MAPE,逐个比较,最后选取最优的隐含层节点数  $i$ ,使得 MAPE( $i$ ) 的值最小。在循环时 MAPE( $k+1$ ) 会自动覆盖掉前一次的误差 MAPE( $k$ ),所以论文采用行列式存储的方式,应用语句 MAPE(:,  $k$ ) 存储在第  $k$  列中,解决了覆盖问题,再按照循环对比,最后根据不同的输入输出

数据,自动选择合适的隐层节点数进行预测。

## 2.5 预测结果的评价

本文选取均方误差(MSE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE),作为预测结果的评价指标。

$$\text{MSE} = \sum_{i=1}^n (y_i^* - y_i)^2 / n$$

$$\text{RMSE} = \sqrt{\sum_{i=1}^n (y_i^* - y_i)^2 / n}$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i^* - y_i}{y_i} \right|$$

其中,  $y_i^*$  为预测值,  $y_i$  为期望值,  $n$  为预测样本数。

## 3 算例分析

### 3.1 不同隐含层 Elman 神经网络模型的验证

选取某风电场 2011 年 8 月 1~2 日风速、温度和功率的 189 个数据点作为样本(每 10 min 一个数据点),分别建立隐含层为一层、二层、三层和四层的 Elman 神经网络模型,用第 1~144 个数据作为训练集来训练网络,用第 145~189 个数据对模型进行检验。表 1 为不同隐含层 Elman 神经网络模型的预测误差。

表 1 不同隐含层 Elman 神经网络模型的预测误差  
Tab. 1 The prediction error of different hidden layer Elman neural network model

不同层数模型 Elman	MSE	RMSE	MAPE
一层	2805	52.9620	0.0713
二层	2678.4	51.7530	0.0714
三层	2208.6	46.9956	0.0636
四层	2352.7	48.5210	0.0665

从表 1 中可知,在多隐含层 Elman 神经网络中,三隐含层 Elman 神经网络预测误差最小,故确定动态自适应 Elman 神经网络模型的隐含层数为 3 层。

### 3.2 自适应 Elman 神经网络模型的验证

对于自适应 Elman 神经网络模型,由于训练集和预测集数据的不同,最优神经网络的隐含层节点数可能是不相同的。

为了验证 Elman 神经网络模型的自适应性,本文选取某风电场 2011 年 8 月 1~2 日风速、温度和功率的 189 个数据点作为样本(每 10 min 一个数据点),并把该样本分为三个样本数据。第一样本数据采用第 1~144 个数据作为训练集,第 145~159 个数据作为预测集;第二样本数据采用第 16~159 个数据作为训练集,第 160~174 个数据作为预测集;

第三样本数据采用第 31~174 个数据作为训练集,第 175~189 个数据作为预测集。

表 2 为采用不同样本数据时的隐含层节点数自动调节运行结果表。

表 2 不同样本数据的预测误差  
Tab. 2 The prediction error of different sample data

隐含层节点数	各样本下的误差 MAPE		
	第一样本	第二样本	第三样本
5	0.074 4	0.075 1	0.075 0
6	0.075 5	0.090 6	0.071 9
7	0.075 1	0.087 4	0.070 9
8	0.075 3	0.075 5	0.072 8
9	0.070 4	0.084 2	0.071 7
10	0.074 4	0.084 5	0.072 3
11	0.073 8	0.085 5	0.072 2
12	0.073 7	0.084 8	0.072 4
13	0.072 4	0.072 7	0.073 0
14	0.073 6	0.085 9	0.072 1
15	0.073 8	0.084 9	0.072 0

用第 1~144 个数据作为训练集,第 145~159 个数据作为预测集时,隐含层节点数为 9 时,预测误差 MAPE 最小,故模型的最佳隐含层节点数为 9;

表 3 自适应 Elman 神经网络模型的预测误差  
Tab. 3 The prediction error of adaptive Elman neural network model

隐含层节点数	5	6	7	8	9	10	11	12	13	14	15
误差 MAPE	0.068 4	0.070 1	0.066 4	0.070 7	0.073 4	0.064 7	0.069 2	0.064 6	0.067 2	0.072 4	0.074 7

表 4 为自适应性 Elman、Elman、BP 预测误差的对比表,图 4 为自适应 Elman、Elman、BP 的预测结果对比图,图 5 为自适应性 Elman、Elman、BP 预测误差对比图。

从表 4 可以得出:在三种不同的误差评价指标下,自适应 Elman 神经网络的误差小于 Elman 神经网络和 BP 神经网络的误差。

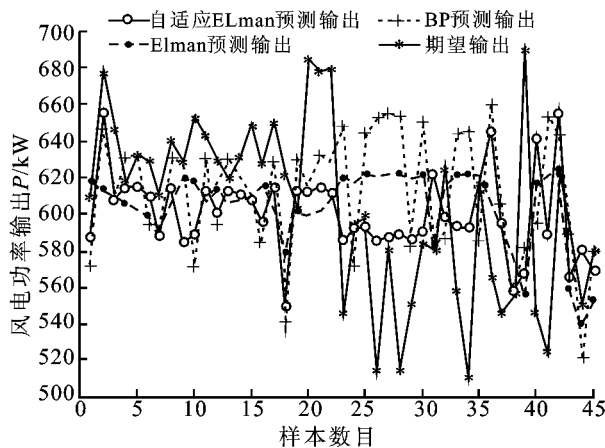


图 4 各种预测模型的预测结果  
Fig. 4 Predicted results of all kinds of forecasting model

用第 16~159 个数据作为训练集,第 160~174 个数据作为预测集时,隐含层节点数为 13 时,预测误差 MAPE 最小,故模型的最佳隐含层节点数为 13;用第 31~174 个数据作为训练集,第 175~189 个数据作为预测集时,隐含层节点数为 7 时,预测误差 MAPE 最小,故模型的最佳隐含层节点数为 7。

通过表 2 可以看出:随着样本的更新,自适应 Elman 神经网络模型都可以自动建立最优模型,达到了自适应调节的目的,可以提高预测精度。

本文最终采用 1~144 个数据作为训练集,第 145~189 个数据作为预测集,隐含层数为 3,建立自适应 Elman 神经网络模型,进行风电场短期风电功率预测,并与 Elman 神经网络模型和 BP 网络模型的预测结果进行对比。

建模时,BP 网络模型的隐含层节点数和自适应 Elman 神经网络模型的最佳隐含层节点数相同;Elman 神经网络模型的隐含层节点数和自适应 Elman 神经网络模型的预测误差最大时的隐含层节点数相同。隐含层自动调节(自适应)运行结果表如表 3,从表中可以看出,模型的最佳隐含层节点数是 12。

表 4 不同预测模型的预测误差  
Tab. 4 The prediction error of different prediction Models

预测模型	MSE/kW	RMSE/kW	MAPE
自适应 Elman	2 282.7	47.777 5	0.064 6
Elman	3 059.2	55.310 2	0.074 7
BP	5 337.6	73.059 2	0.094 3




图 5 不同预测模型的预测误差对比  
Fig. 5 The prediction error of different prediction model

由图4看出,自适应Elman神经网络的预测曲线的趋势与期望输出曲线的趋势最接近;由图5可以看出,用三种不同预测模型进行短期风电功率预测时,自适应Elman神经网络进行短期风电功率预测时预测误差曲线低于其他两个,误差总体较小。可见在预测时间相同的条件下,自适应Elman网络模型的预测效果明显要比Elman网络模型和BP网络模型的预测效果好。

#### 4 结 论

本文针对BP网络动态性能差、易陷入局部最小值的特点,提出了自适应Elman神经网络预测模型。对隐含层节点数自适应,使隐层节点数能够随着训练集和预测集的更新不断的自我调节,可以自动选取最优的隐层节点数,网络能根据最新训练结果自动调整,从而让整个神经网络的性能更加优越。最后将自适应性Elman神经网络、Elman神经网络、BP神经网络预测结果进行对比,验证了自适应性Elman神经网络模型的可行性和有效性。

#### 参考文献:

- [1] 符金伟,马进,周榆晓,等.风电功率预测研究方法综述[J].华东电力,2012,40(5):888-892.  
FuJinWei, Ma Jing, Zhou Yuxiao, et al. Wind power prediction research method ensemble[J]. Journal of East China Power, 2012, 40(5): 888-892.
- [2] 范高锋,王伟胜,刘纯.基于人工神经网络的风电功率短期预测系统[J].电网技术,2008,32(22):72-76.  
Fan Gaofen, Wang Weisheng, Liu Chun. Wind power short-term prediction system based on artificial neural network[J]. Power Grid Technology, 2008, 32(22): 72-76.
- [3] 孟洋洋,卢继平,孙华利,等.基于相似日和人工神经网络的风电功率短期预测[J].电网技术,2010,34(12):163-167.  
Meng Yangyang, Lu Jiping, Sun Huali, et al. Based on the Similar day and the artificial neural network the short-term wind power prediction[J]. Power Grid Technology, 2010, 34(12): 163-167.
- [4] 师洪涛,杨静玲,丁茂生,等.基于小波-BP神经网络的短期风电功率预测方法[J].电力系统自动化,2011,35(16):44-48.  
Shi Hongtao, Yang Jingling, Ding Maosheng, et al. Based on the wavelet-BP neural network short-term wind power prediction[J]. Automation of Electric Power Systems, 2011, 35(16): 44-48.
- [5] 厉卫娜,苏小林.基于小波-神经网络的短期风电功率预测研究[J].电力学报,2011,26(6):59-62.  
Li Weina, Su Xiaolin. Based on wavelet- neural network short-term wind power prediction research[J]. Journal of Electric Power, 2011, 26(6): 59-62.
- [6] 余健明,马小津,倪峰,等.基于改进 PSO-LSSVM 的风电场短期功率预测[J].西安理工大学学报,2013,29(2):176-181.  
Yu Jianming, Ma Xiaojin, Ni feng, et al. Based on improved PSO-LSSVM short-term wind power prediction [J]. Journal of Xi'an University of Technology, 2013, 29(2): 176-181.
- [7] 周斌,文亮,杨力,等. BP神经网络在风电功率预测中的应用[J].宜宾学院学报,2012,12(6):30-32.  
Zhou Bin, Wen Liang, Yang Li, et al. BP neural network in the application of wind power prediction[J]. Journal of Yibin College, 2012, 12(6): 30-32.
- [8] 郭琦,鲍金春,宋继光.基于BP神经网络的风电功率预测[J].电源技术应用,2011,1(6):14-18.  
Guo Qi, BaoJinChun, Song Jiguang. Wind power prediction based on BP neural network[J]. Power technology application, 2011, 1(6): 14-18.
- [9] 张良均,曹晶,蒋世忠.神经网络实用教程[M].北京:机械工业出版社,2008.
- [10] 石黄霞,何颖,董晓红.基于Elman神经网络的电力负荷预测模型研究[J].工业仪表与自动化装置,2013,(1):85-87.  
Shi Huangxia, He Ying, Dong Xiaogong. Based on the Elman neural network power load prediction model[J]. Industrial Instrumentation and Automation Devices, 2013, (1): 85-87.
- [11] 刘荣,方鸽飞.改进Elman神经网络的综合气象短期负荷预测[J].电力系统保护与控制,2012,4(22):113-117.  
Liu rong, Fang Gefei. The Improved comprehensive meteorological Elman neural network short-term load forecasting[J]. Power System Protection and Control, 2012, 40(22): 113-117.
- [12] 张靠社,杨剑.基于Elman神经网络的短期风电功率预测[J].电网与清洁能源,2012,28(12):87-91.  
Zhang Kaoshe, Yang Jian. Short-term wind power prediction based on Elman neural network[J]. Power Grid and Clean Energy, 2012, 28(12): 87-91.
- [13] 石春源.基于Elman神经网络锂电池劣化程度的预测研究[D].哈尔滨:哈尔滨理工大学,2011.  
Shi Chunyuan. Based on the Elman neural network Lithium battery degradation prediction research[D]. Harbin: Harbin

University of Science and Technology, 2011.

- [14] 赵智勇,黄伟,尉扬. 一种基于小波分析和 Elman 动态神经网络的中长期电力负荷预测方法[J]. 山西电力, 2013, (1):1-5.

Zhao Zhiyong, Wang Wei, Weiyang. Based on the wavelet analysis and dynamic Elman neural network the medium and long term power load forecasting method[J]. Journal of Shanxi Electric Power, 2013, (1):1-5.

- [15] 祝燕萍,方鸽飞. 基于动态自适应神经网络和人体舒适度的短期负荷预测[J]. 电力系统保护与控制, 2012, 40(1):56-61.

Zhu Yanping, Fang Gefei. Based on dynamic adaptive neural network and comfort of human body short-term load forecasting[J]. Journal of Power System Protection and Control, 2012, 40(1):56-61.

(责任编辑 杨小丽)

(上接第 101 页)

- [19] 谈军利,康跃虎,焦艳平,等. 不同种植年限覆膜滴灌盐碱地土壤盐分离子分布特征[J]. 农业工程学报, 2008, 24(6):59-63.

Tan Junli, Kang Yuehu, Jiao Yanping, et al. Characteristics of soil salinity and salt ions distribution in salt-affected field under mulch-drip irrigation in different planting years[J]. Transactions of the CSAE, 2008, 24(6):59-63.

- [20] 王伟,傅臣家,李光永,等. 土壤盐分与灌溉水质对滴灌棉花出苗率的影响[J]. 灌溉排水学报, 2011, 30(1):20-23.

Wan Wei, Fu Chenjia, Li Guangyong, et al. Impacts of water quality and initial soil salt content on seedling emergence of cotton under drip irrigation[J]. Journal of Irrigation and Drainage, 2011, 30(1):20-23.

- [21] 王春霞,王全九,刘建军,等. 灌水矿化度及土壤含盐量对南疆棉花出苗率的影响[J]. 农业工程学报, 2010, 26(9):28-33.

Wang Chunxia, Wang Quanjiu, Liu Jianjun, et al. Effects of mineralization of irrigation water and soil salinity on cotton emergence rate in Southern Xinjiang Uygur Autonomous Region of China[J]. Transactions of the CSAE, 2010, 26(9):28-33.

- [22] 郝志刚,胡自志,朱兴运. 碱茅耐盐性的研究[J]. 草业科学, 1994, 3(3):27-36.

Hao Zhigang, Hu Zizhi, Zhu Xingyun. The studies on salt tolerance in puccinellia spp[J]. Acta Pratacultural Science, 1994, 3(3):27-36.

(责任编辑 李虹燕)