

文章编号:2095-0411(2016)01-0088-05

几种短期风速时间序列预测技术的比较

杨小强,韩亚军,刘 静
(重庆科创职业学院 机电工程学院,重庆 402160)

摘要:对风速进行准确的预测可以减轻对电力系统的不利影响,提高风电场在电力市场中的竞争力。比较了几种不同的风速预测方法,它们都是采用时间序列分析短期风速数据。讨论传统的线性自回归滑动平均模型(ARMA),常用的前馈和循环神经网络,同时对自适应神经模糊推理系统(ANFIS)以及神经逻辑网络进行比较。通过建模对几种方法的预测性能进行估计,最终得出基于人工智能的模型比线性模型效果更好,能够准确快速地预测结果。

关键词:风速;时间序列;神经网络

中图分类号:TM 614

文献标志码:A

doi:10.3969/j.issn.2095-0411.2016.01.017

A Comparison of Various Forecasting Techniques Applied to Mean Hourly Wind Speed Time Series

YANG Xiaoqiang, HAN Yajun, LIU Jing

(School of Machine and Electrical Engineering, Chongqing Creation Vocational College, Chongqing 402160, China)

Abstract: Accurate prediction wind speed can reduce the iMPact on the power system and improve the competitiveness of the wind farm in the electric power market. This paper mainly compared several different wind speed forecasting methods, which use the time series to analyze the short-term wind speed data, discussed the traditional linear auto regressive moving average model(ARMA), the common feed forward and recurrent neural network, and also compared the adaptive neural fuzzy inference system(ANFIS) and the neural logic network. The model shows that the artificial intelligence model is better than the linear model, and it can predict the wind speed accurately and quickly.

Key words: wind speed; time series; neural networks

风是最难预测的气象参数之一,风是由于地球转动时,在不同的地表形成较大的压差和温差而产生的。最早的预测技术是根据可用的信息及分析得到的时间尺度对风能进行预测,只能预测几秒到几分钟的短期风速,预测对象就是 WECS 系统的控制对象。要预测几小时内的风能就要分析整个电力系

统的运行计划,而预测几天内的风能就需要分析电力系统的维护计划和资源计划。

本文提出的分析方法是基于文献中提到的以下方法建立的,包括:数值天气预报和中尺度模式,广义等效马尔可夫模型和时间序列分析方法。后者还采用了自回归滑动平均模型(ARMA)^[1]、卡尔曼滤

收稿日期:2015-04-24。

基金项目:重庆市第二批高等学校青年骨干教师资助计划(渝教人[2013]74号)。

作者简介:杨小强(1983—),男,甘肃天水人,助教,主要从事电气工程及自动化教学研究。

波器、双线性和光滑阈值自回归模型。近年来又提出人工智能技术,它们主要采用多层感知器,径向基函数(RBF),循环神经网络和模糊逻辑^[2],并结合了具有时空神经网络的模糊分类器。

随着预测水平的提高,各种预测方法的效果都有明显改善,但相比之下,当输入是过去每小时平均数据时,持久性的单步预测方法比本文的短期风速时间序列预测方法效果要好一些,数值预测模型^[3]比持久性的单步预测方法在前面第一个小时存在的 RMS 误差要高出 25%,卡尔曼滤波器算法比持久性预测方法 RMS 误差低 2%,而前馈神经网络^[4]比持久性预测方法 RMS 误差高 0.3%~2.1%。本文的研究目的是比较几种较难的人工智能风能预测方法,主要根据它们的预测效果和模型估计时间进行比较。后面所讨论的预测模型是在文献中已经提到的模型基础上建立起来的,如自回归滑动平均模型(ARMA)和神经网络,自适应神经模糊推理系统(ANFIS)和神经逻辑网络,后面两者有效的将神经网络和模糊逻辑以及人工智能系统相结合。

1 预测方法

1.1 Box-Jenkins 方法

Box 和 Jenkins 是基于平稳的时间序列提出的模型,该模型利用过去的预测误差和随机项。利用序列 p 和 q 建立 ARMA(p, d, q)模型,可用下式表示:

$$y_t = \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t \quad (1)$$

式中: ϕ_i 是自回归函数, θ_j 是移动平均参数, e_t 是随机项。如果时间序列不平稳,则可先差分 d 次直到平稳为止。

1.2 前馈神经网络

基于前馈神经网络的学习能力形成了一种应用广泛的预测方法。它的运算原理详见文献^[5-6]。输出层中的神经元响应为:

$$y_i = f_1 \left(\sum_{q=1}^l w_{iq} f_2 \left(\sum_{j=1}^m v_{qj} x_j + b_j \right) + b_q \right) \quad (2)$$

式中 f_1 和 f_2 为非线性 Sigmoid 函数。

研究时采用了 2 种不同的训练算法。第 1 种是梯度下降或反向传播(BP)算法^[6]。这种算法具有 2 个主要参数:自适应学习率和动量项,可加速训练过程。第 2 种训练方法就是 Levenberg Marquardt

(LM) 算法^[7]。线性网络(LN)是一种比前馈神经网络更简单的网络类型。这些网络没有隐藏层,并且输出层的激活函数都是线性的。这种网络的加权值和偏差是使用 Widrow-Hoff 准则训练的,它是最小二乘法的一种变化形式。这些网络可以产生线性逼近式。

1.3 径向基函数网络

径向基函数网络(RBF)与前馈神经网络^[5-6]具有相似的形式。隐藏的神经元包含和高斯密度函数类似的径向基函数,可用中心位置 \hat{x} 和宽度参数 σ_i 来描述。隐藏层第 q 个神经元的输出可用下式表示:

$$z_q = \exp \left(- \sum_{j=1}^m (x_j - \hat{x}_j)^2 / \sigma_j^2 \right) \quad (3)$$

第 3 层和第 2 层线性结合,因此,神经元 i 的输出为:

$$y_i = \sum_{q=1}^l (w_{iq} z_q + b_q) \quad (4)$$

径向基函数网络的参数可分 3 步确定。第 1 步,采用聚类算法建立单元中心;第 2 步,使用最近邻方法确定宽度;第 3 步,通过减小输出与实际数据间的和方差建立第 3 层的加权值。

1.4 Elman 递归神经网络

除了前馈神经网络,还可以在 ANN 的各层之间建立循环链接。这里采用的网络类型是 Elman (ELM)创建的,并且引入了称为 context^[8]的输入神经元。这些神经元只与隐藏层的神经元相互作用,该层神经元的数量和隐藏层相等。对于一个具有 P 个输入和 I 个隐藏神经元的网络,神经元 y_i 的输出为:

$$y_i = \sum_{l=1}^I w_{il} g(t) \quad (5)$$

式中: W_i 为隐藏层和输出层之间的加权值, $g(t)$ 是隐藏神经元的输出函数,可按式(6)计算:

$$g_i(t) = f \left(\sum_{j=1}^p w_{ij} x_{t-j} + \sum_{k=1}^q \sum_{l=1}^I w_{ikl} g_l(t-k) + b_i \right) \quad (6)$$

1.5 ANFIS 模型

基于模糊推理系统的自适应网络(如图 1 所示)采用模糊 if-then 规则建模,而且还可以根据期望的输入输出数据对隶属函数进行调整。它使用一阶 Sugeno 模糊模型通过模糊规则建模获得期望的

输出。




图1 ANFIS 结构

Fig.1 ANFIS architecture

if $X_1 = A_i$ and $X_n = B_j$ then

$$f_i = p_i X_1 + q_i X_n + r_i \quad (7)$$

第①层的每一个神经元都对应着一个语言标记,输出则和这个语言标记的隶属函数相等。

$$OL_{1i} = \mu_{A_i}(X_1) \quad (8)$$

第②层的每个节点都代表着一个模糊系统规则的发射强度,其可以通过输入信号的乘法运算得到。

$$OL_{2i} = \mu_{A_i}(X_1) * \mu_{B_j}(X_n) \quad (9)$$

第③层的每个节点代表着第 i 个规则的发射强度和所有规则的发射强度之比值 W_i 。

$$OL_{3i} = W_i = \frac{w_i}{\sum_{i=1}^j w_i} \quad (10)$$

第④层的输出是由前面第 i 个规则的相对发射强度和系统总规则共同产生的。

$$OL_{4i} = w_i f_i = w_i (p_i X_1 + q_i X_n + r_i) \quad (11)$$

最后一层将第 4 层所有的输入信号进行求和作为系统的总输出。

$$OL_{5i} = \sum_{i=1}^j w_i f_i \quad (12)$$

采用加权平均法对结果进行反模糊。通过反向传播训练方法可以确定隶属函数的最佳参数值,并且可以通过最小二乘法确定模糊规则上的线性参数,用这种方法来减小输入输出数据对之间的误差,和 ARMA 及 BP 网络相比,ANFIS 模型在预测混沌时间序列方面成功地体现出了它的优越性。

1.6 神经网络(NLN)

最早开发的 NLN 网络结合了人的信息加工的 2 种主要方式——逻辑和直觉。当逻辑和直觉用于研究研究人的逻辑和三值逻辑推论时是非常有用的。但是,NLN 和其他神经网络不同,它们具有一个与神经元以及连接相联系的有序偶。比如,可以把有序偶用三值逻辑表示为 true (1,0),false (0,1) 以及 don't know (0,0)。

有序对经过推广可以包含实数,用 (a, b) 表示。用于时间序列预测时,网络的输入输出可以分别描述为: $X_i \rightarrow (X_{1i}, 0)$, $Y_j \rightarrow (Y_{1j}, 0)$ 。这里对反向传播算法和 LM 训练算法做了适当的修改并用于 NLN 网络中,如图 2。




图2 神经网络

Fig.2 neural logic network

具有单个隐藏层的网络的输出为:

$$(y_{1j}, y_{2j}) = \begin{cases} \left[f\left(\sum_{i=1}^m w_{1j,i} x_{1i} - \sum_{i=1}^m w_{2j,i} x_{2i}\right), 0 \right] & \text{if } \sum_{i=1}^m w_{1j,i} x_{1i} - \sum_{i=1}^m w_{2j,i} x_{2i} > 0 \\ \left[0, f\left(\sum_{i=1}^m w_{2j,i} x_{2i} - \sum_{i=1}^m w_{1j,i} x_{1i}\right) \right] & \text{if } \sum_{i=1}^m w_{2j,i} x_{2i} - \sum_{i=1}^m w_{1j,i} x_{1i} > 0 \\ [0, 0] & \text{otherwise} \end{cases} \quad (13)$$

式中: f 代表 Sigmoid 激活函数。它可以使用具有适当加权值的相同网络结构开发逻辑规则(LR)。

1.7 训练方案

数据组中包含 744 个数据点,分别用来表示 1 个月的所有小时数。将其划分成 3 个小组:训练组(tr)、评估组(ev)和预测组(pr)。训练组用于评估 ARMA 参数和训练非线性模型。评估组在训练阶

段是未知的,用于检查网络的进程。用于预测组的模型参数可以减小评估组的 RMS 误差,而每个模型的特性都可以在预测组上测试。对于 RBF 网络,可以按照类似的过程进行训练,它是通过各种隐藏神经元的组合来评估网络参数,并且传播常数 σ 。

2 选择输入变量

要建立一个成功的时间序列预测模型,最重要

的一项任务就是选择输入变量,输入变量决定了模型的结构。尽管对于人工智能模型还没有系统的研究方法,但可以采用统计方法确定相对输入。例如:自相关(ACF)以及部分相关(PACF)。这些方法都是从线性模型得来的,但是,因为神经网络是非线性的,所以它们的计算只能提供一些指示,而不能作为一种标准的工具来确定有用的变量和时差。

选择变量时第一步就是使用 ACF。然后分两步确定灵敏度,先利用已经选择的每个变量训练网络,直到训练误差达到最小,再通过将每个变量置零消除其影响,除去影响最小的变量。

对于不具任何逻辑规则的 NLN 网络,也可以按前一段中描述的方法确定输入变量,然后将这些变量作为逻辑规则的输入,它们的输出则与目标数据相关。那些逻辑规则和初始变量一起就作为最终 NLN 模型的输入。

2.1 检测数据的应用

图 3 表示风速时间序列的自相关函数,表 1 为每一组风速数据的统计特征表。结合灵敏度分析可以看出,后面 2 组测量值对开发基于神经元的预测模型影响最大。当把最后 6 次的测量值作为输入时,NIN 网络性能最佳,这些输入可以用于评估 NLN 网络逻辑规则的输出。目标函数和逻辑规则之间的相关系数见表 2。NLN 的最终模型是以原始输入作为输入值,对应的输出为 and, majority, at least true(6) 以及 at least false 规则。




图 3 风速数据组的自相关系数
Fig.3 Autocorrelation of wind speed data sets

表 1 数据组及其统计特征

Table 1 Data sets and their statistics			
类别	系数	评估	预报
累积时间/s	1~500	501~550	551~744
点数	500	50	194
最小值/(m·s ⁻¹)	0.68	1.66	1.36
最大值/(m·s ⁻¹)	15.63	7.26	13.91
平均值/(m·s ⁻¹)	7.49	3.84	7.56
误差/(m·s ⁻¹)	3.47	1.38	3.01

表 2 LR 和输出目标函数之间的相关系数 Table 2 Correlation coecients of LR and output target			
逻辑规则	相关系数	逻辑规则	相关系数
或	0.196 2	优先	0.145 2
与	0.815 9	大多数	0.813 7
非	0.597 0	最小正确率	0.815 9
异或	0.251 6	最小错误率	0.811 3

3 数据结果及结论

已经建立的预测模型是利用过去的 n 次测量值建立的,它们的输出是时间序列 w_t 的当前值。这些模型可用下式表示:

$$w_t = f(w_{t-1}, \cdots, w_{t-n}) \tag{14}$$

式中 f 可代表任意一个基于人工智能的模型。

可以利用持久性算法比较线性和非线性模型的结果,即假设时间序列的预测结果和上次测量值相等,即

$$w_t = w_{t-1} \tag{15}$$

因为持久性算法使用简单,因此比较使用不同数据组的各种方案的结果时常用这种方法。

图 3 表明这种风速时间序列不平稳,采用简单的差分过程可消除平稳度。通过建立 ARIMA(0, 1,0)模型可减小 Akaike 信息量准则,它可以测试模型的效果和复杂性。若不包括复杂性评价,采用类似的过程训练 ANN 网络,可建立 ARIMA (2,1,2) 模型减小评估组的 RMS 误差。

为了避免所用的 Logistic 激活函数进入饱和区,将神经网络的数据标定于 0.1~0.9 之间。对于 ANFIS 算法,输入未标定,通过分析可得到,每个输入变量采用 3 个高斯隶属函数就可以得到这种算法的优化结构。如果输入变量采用的隶属函数数目更多,训练组的模型会更优化,但评估组和预测组的实现将更困难。利用 Logistic 函数将 NLN 网络的神经元激活,和其他网络一样这些数据是有界的。然后将这些变量作为逻辑规则的输入,逻辑规则和激活函数都具有一个双曲线切线,最后就得到了第③节末尾所介绍的模型。

表 3 中列出的数据是从预测组得到的,对于在训练和评估阶段的网络来说这些数据是未知的。对这些数据进行 RMS 误差分析,并且采用 benchmark 持久性算法对它们的结果按百分率基准(% impr.)进行比较。表里还列出了每一种预测技术的其他一些信息,包括隐藏神经元的数量(HN),达到评估组最小 RMS 误差的收敛时间(CT)。

表 3 预测结果
Table 3 Forecasting results

模型	均方根/ ($\text{m} \cdot \text{s}^{-1}$)	基准百 分率/%	体系 架构	静态试 验/s
固定值	1.258 7	—	—	—
算法(2)	1.238 3	1.62	—	—
自回归移动平均模型 1	1.230 3	2.25	(2,1,2)	—
自回归移动平均模型 2	1.260 7	-0.15	(0,1,0)	—
线性神经网络	1.216 2	3.37	NO	79
反向传播算法(BP)	1.211 1	3.78	6 HN	532
LM 神经网络	1.199 9	4.67	4 HN	5
径向基函数神经网络	1.212 1	3.70	35 HN	39
Elman 神经网络	1.225 0	2.67	3 HN	331
适应模糊神经推理系统	1.206 2	4.17	9 rules	7
神经逻辑网络	1.204 8	4.28	NO HN	22
逻辑规则神经网络	1.197 1	4.89	3 HN	141

分析表明,相比于线性自回归以及 ARMA 模型,非线性人工智能模型更容易理解这种特殊时间序列的特点。它们的 RMS 误差介于 $0.01 \sim 0.07 \text{ m} \cdot \text{s}^{-1}$ 。而且,非线性模型不需要将时间序列转换为平稳过程。

将前馈网络和 2 种不同的训练算法进行比较,可以看出 LM、ANN 比 BP 算法的 RMS 误差低 1% 左右,而且, BP 算法的收敛时间超出 LM 算法 100s,它们之间的主要区别在于 BP-NN 算法推广性较差。对于这种时间序列,由于评估数据组和预测组具有不同的特点,因此可能会产生无效的网络,见表 1 和表 3。

根据模型误差和收敛时间调查,Elman 循环神经网络模型比人工智能网络模型效果差一些。径向基函数网络在所有的前馈网络中误差最大,为 $1.216 2 \text{ m} \cdot \text{s}^{-1}$,但速度非常快(39s)。线性网络比 ARMA 模型效果更好,由于参数少,因此和 BP 算法相比,它的收敛时间更快。

ANFIS 算法的训练时间比持久性算法晚 7s,因此前者的 RMS 误差比后者小 4.2%。ANFIS 算法还能提供控制时间序列的相关信息,所以这种算法更有用些。一个没有隐藏神经元的普通 NLN 网络 RMS 误差只有 $1.204 8 \text{ m} \cdot \text{s}^{-1}$ 。将输入列表中的逻辑规则具体化可将网络的预测准确度提高 0.63%。由于参数数量的增加,第 2 个网络的训练时间会更快。NLN 模型都是使用修改后的 LM 算法训练的。只有逻辑规则神经网络模型在所有算法中 RMS 误差是最低的,只有 $1.197 1 \text{ m} \cdot \text{s}^{-1}$ 。采用这种模型预测的时间序列如图 4 所示。




图 4 预测组的实际数据和 NLN+LR 预测结果

Fig.4 Actual data and NLN+LR forecast for the prediction set

4 结 论

通过对几种短期风速时间序列预测技术进行比较,得出以下结论:基于人工智能的模型比线性模型效果更好,并且所有非线性模型都具有相对 RMS 误差,而其中误差最小的模型是采用逻辑规则创建的神经逻辑网络(NLN),它的 RMS 误差比持久性算法低 4.9%。

参考文献:

- [1]曾勇红,王锡凡,冯宗建.基于混合自回归滑动平均潜周期模型的短期电价预测[J].西安交通大学学报,2008,42(2):34-38.
- [2]李士勇.模糊控制.神经控制和智能控制论[M].哈尔滨:哈尔滨工业大学,1996:250-387.
- [3]WATSON S, HALLIDAY J A, LANDBERG L. Wind speed forecasting and its application to wind power integration[J].Proceedings of the Fifteenth British Wind Energy Association Conference,1993,35(12):61-70.
- [4]王凤琴,高颖,赵军.基于遗传算法的神经网络优化[J].燕山大学学报,2001,18(3):21-26
- [5]邵红梅,安凤仙.一类训练前馈神经网络的梯度算法及收敛性[J].中国石油大学学报(自然科学版),2010,34(4):89-93.
- [6]贾立山,谈至明.基于随机参数调整的改进反向传播学习算法[J].同济大学学报(自然科学版),2011,39(5):57-62.
- [7]郝欢,陈亮,张翼鹏.采用归一化最小均方误差准则的 LM-BP 算法[J].信号处理,2013,29(8):193-197.
- [8]CONNOR J, MARTIN R, ATLAS L. Recurrent neural Networks and robust time series prediction[J]. IEEE Trans Neural Networks,1994,5(2):240-253.

(责任编辑:李艳)