

基于 D-S 证据理论的短期风速预测模型

刘亚南¹, 卫志农¹, 朱 艳², 孙国强¹, 孙永辉¹, 杨友情³, 钱 璞³, 周 军³

(1. 河海大学 可再生能源发电技术教育部工程研究中心, 江苏 南京 210098;

2. 国电南瑞科技股份有限公司, 江苏 南京 210061; 3. 安徽省电力公司池州供电公司, 安徽 池州 247000)

摘要: 提出一种基于 D-S 证据理论的短期风速组合预测模型。分别采用时间序列、BP 神经网络和支持向量机预测模型对风速进行预测, 通过对预测误差的分析, 借助 D-S 证据理论对 3 种模型进行融合。选取待测日前几日的风速数据作为融合样本, 计算出相应的基本信任分配函数, 同时将函数进行融合, 并将融合结果作为风速预测模型的权重, 得到待预测日的风速预测结果。仿真结果表明, 所提组合预测模型的预测误差更小, 效果更好。

关键词: 风电; 时间序列; BP 神经网络; 支持向量机; D-S 证据理论; 预测; 模型

中图分类号: TM 715; TM 614

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2013.08.022

0 引言

风力发电在我国发展迅速并逐步走向产业化和规模化, 对风速预测的研究也越来越深入。由于风速具有较强的随机性, 所以风电机组出力波动性较大。对风电场风速进行准确的预测, 对电力部门及时调整调度计划, 衡量风电场的容量可信度, 进而确定合适的风电上网价格, 具有重要的现实意义^[1]。

众所周知, 风速预测的精度不仅与预测方法的选择有很大关系, 还与预测周期及预测地点的风速特性有关。一般而言, 预测周期越短, 预测地点风速振荡性越小, 预测精度越高, 反之越低。目前, 风速预测已经有比较深入的研究, 较为成熟的有时间序列分析法、神经网络法等^[2]。文献[3]采用时间序列分析方法对风电场风速进行预测, 在有限的样本序列下建立了精度较高的预测模型, 但是该方法的低阶模型往往不能反映所有样本的性能, 高阶模型的估计较为复杂, 在计算中消耗时间, 同时不易寻找到合适的阶数。卡尔曼滤波^[4]能动态地修改预测权值, 并依靠预测递推方程获得较高的精度, 但是如何建立卡尔曼滤波状态方程和量测方程存在困难。文献[5]提出了一种基于时间序列和卡尔曼滤波的混合型算法。首先利用风速的时间序列数据建立了一个低阶模型, 通过该模型的预测方程直接推导出卡尔曼滤波的状态和量测方程, 然后利用迭代方程进行预测, 从而有效地避免了 2 种模型的缺陷。文献[6]分别借助于 BP 神经网络和广义回归神经网络 GRNN (Generalized Regression Neural Network) 进行风速预测, 实验结果表明后者的效果优于前者。同时, 也验证了时间序列与 GRNN 结合起来的预测效果比单一模型效果更有效。文献[7]采用改进的空间相关法和径向基神经网络相结合的风速预测模型, 该方法通过分析风电场与空间相关点风速时间序列之间的关联度, 分别选择关联度高的相关点的风速数据作为径向基函数 RBF (Radical Basis Function) 的输入数据, 该方法提高了预测精度, 减少了径向基神经网络的训练时间。

事实上, 单个预测模型往往很难达到理想的精度, 同时预测结果还具有不确定性和片面性, 因此, 如何融合单一方法的优点来进行风速预测成为近年来的一个研究热点。文献[8]利用改进的模糊层次分析法进行风速预测, 该方法融合了多种预测方法, 取得了一定的效果, 但是引入的专家经验具有不确定性, 而专家经验的选取与预测结果有密切的关系。基于以上分析, 本文提出一种基于证据理论的短期风速预测模型, 分别采用时间序列、BP 神经网络和支持向量机 (SVM) 对风速进行预测。根据每个模型的相对误差确定该模型在组合中的权重, 从而确立基本信任分配函数, 并运用证据理论对函数进行融合, 最终得到未来的风速。该模型融合多种预测模型的优点, 预期的结果将比单个模型有明显的提高。

1 证据理论基本概念

1.1 基本定义

证据理论是目前信息融合领域中最常用的一种方法, 它建立在集合论的基础上, 主要用来解决不确定性问题^[9]。

定义 1: 对于一个集合 A , 称集合 $Q = \{C | C \subseteq A\}$ 是集合 A 的幂集, 表示为 2^A 。对于一个判决问题, 用集合 Θ 表示能够认识到的所有可能结果, Θ 称为识别框架。

定义 2: 设 Θ 为识别框架, 基本信任分配函数

收稿日期: 2012-03-12; 修回日期: 2013-05-17

基金项目: 国家自然科学基金资助项目 (50877024, 51107032, 61104045)

Project supported by the National Natural Science Foundation of China (50877024, 51107032, 61104045)

$m(\cdot)$ 是一个从集合 2^Θ 到 $[0, 1]$ 的映射, A 表示识别框架 Θ 的任一子集, 记作 $A \subseteq \Theta$, 且满足 $m(\emptyset)=0$, $\sum_{A \subseteq \Theta} m(A)=1$ 。其中 $m(A)$ 称为事件 A 的基本信任分配函数, 它表示证据对 A 的信任程度。

1.2 证据理论 Dempster 合成法则

D-S 合成法则是一个反映证据联合作用的法则。给定几个同一识别框架上基于不同证据的信任函数, 若证据不是完全冲突的, 则可以利用 D-S 合成法则计算出一个新的信任函数。

设 B_{e1}, B_{e2} 是同一个识别框架上 2 个信任函数, m_1 和 m_2 分别是其对应的基本可信度分配, 对应焦点分别为 A_i 和 B_j , 设 $K = \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) < 1$, 则 D-S 合成法则为:

$$m(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} m_1(A_i)m_2(B_j)}{1-K} & A \neq \emptyset \\ 0 & A = \emptyset \end{cases} \quad (1)$$

若待合成的函数多于 2 个, 则可以采用上述方法将前一步合成结果与下一个函数进行合成, 直至所有函数合成完毕。

2 证据理论权重融合模型

2.1 权重提取模型

运用 Dempster 合成法则之前, 需要提取融合样本的权重。利用训练数据对单一风速预测模型进行训练后, 每个模型产生的训练误差为 $e_i = (\hat{y}_i - y_i) / y_i$ ($i=1, 2, 3$), $\hat{y}_i$ 为风速的预测值, y_i 为风速的真实值。权重赋值跟预测精度有密切的关系, 预测精度高, 说明该算法在组合中所占的权重比较大, 精度低, 相应的权重就比较小, 因此权重 w_i 可表示为下面关于 e_i 的函数^[10-12]:

$$w_i = \frac{1 / (|e_i| + \varepsilon)}{\sum_{i=1}^3 1 / (|e_i| + \varepsilon)} \quad (2)$$

这里 ε 的引入避免了相对误差为 0, 进而可得到组合预测结果:

$$Y = \sum_{i=1}^3 w_i y_i \quad \sum_{i=1}^3 w_i = 1 \quad (3)$$

2.2 权重融合模型

在风速预测融合模型中, 模型权重被视为证据理论的基本信度值。对于 3 种风速模型预测值 $\hat{y}_1, \hat{y}_2$ 和 $\hat{y}_3$, 对应权重分别为 w_1, w_2 和 w_3 , 在识别框架 $\Theta = \{\hat{y}_1, \hat{y}_2, \hat{y}_3\}$ 上建立基本信任分配函数 $m(\cdot)$, 其对应的信度值为 $m(\hat{y}_i) = w_i$ ($i=1, 2, 3$)。假设 3 天的风速预测值所对应的信度值为 $m_j(\hat{y}_i)$ ($i=1, 2, 3; j=1, 2, 3, 4$)。首先将第 1 天和第 2 天对应的信任函数进行融合,

然后将合成后的信任函数与第 3 天的信任函数进行 2 重融合, 最终得到的信度值为 $m_4(\hat{y}_1), m_4(\hat{y}_2)$ 和 $m_4(\hat{y}_3)$ 。假设第 4 天的风速预测值为 $\hat{y}_1^4, \hat{y}_2^4$ 和 $\hat{y}_3^4$, 则最终合成结果表示为:

$$\hat{y}^4 = m_4(\hat{y}_1)\hat{y}_1^4 + m_4(\hat{y}_2)\hat{y}_2^4 + m_4(\hat{y}_3)\hat{y}_3^4 \quad (4)$$

3 3 种预测模型

3.1 时间序列法预测模型

时序模型主要包括稳定模型和非稳定模型。常用的稳定模型有自回归 AR(Auto Regressive)模型、滑动平均 MA(Moving Average)模型、自回归滑动平均 ARMA(Auto Regressive Moving Average)模型。非稳定模型有差分自回归平均 ARIMA(Auto Regressive Integrated Moving Average)模型等, 为方便起见, 本文也采用此方法, 其模型表达式为:

$$\phi(B)k^d \tilde{X}_t = \theta(B)a_t \quad (5)$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (6)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (7)$$

$$k = 1 - B \quad (8)$$

其中, $\{\tilde{X}_t\}$ ($t=1, 2, \dots$) 为时间序列, $\{a_t\}$ 为均值为 0、方差为 σ_a^2 的正态白噪声过程, ϕ_i ($i=1, 2, \dots, p$) 和 θ_j ($j=1, 2, \dots, q$) 为模型的待估系数, B 为后移差分算子, p 为自回归项, d 为差分次数, q 为移动平均项。

本文采用 Box-Jenkins 法进行时间序列分析建模。首先进行差分处理, 直到获得平稳序列, 再对该平稳序列进行模型识别和参数估计。定阶采用赤池信息准则 AIC(Akaike's Information Criterion), 参数估计采用非线性最小二乘法。

3.2 BP 神经网络原理

BP 神经网络^[13]是一种多层前馈神经网络, 由输入层、隐含层和输出层组成。BP 网络的权值调整采用反向传播的学习算法, 它利用均方误差和梯度下降法来实现对网络连接权值的修正, 使得网络实际输出与目标输出之间的均方误差达到期望误差范围之内。神经元采用 Sigmoid 传递函数, 各层神经元的权值修正如下:

$$w_{lk}^r(s+1) = w_{lk}^r(s) + \alpha \delta_l^r(s) y_l^{r-1}(s) \quad (9)$$

其中, r 为层数, l, t, k 为神经元, w_{lk} 为连接权, α 为学习率, δ_l^r 为误差修正值。

3.3 SVM 原理

SVM^[14-16]的基本思想是通过一个非线性映射, 将输入空间的数据映射到一个高维空间, 然后在此空间中作线性回归。对于回归预测问题, 设训练样本 (x_i, y_i) , $x_i \in \mathbf{R}^m$, $y_i \in \mathbf{R}$, $i=1, 2, \dots, m$, m 为训练样本个数。采用如下的回归函数:

$$f(\mathbf{x}_i, \mathbf{w}) = \mathbf{w}\phi(\mathbf{x}_i) + \mathbf{b} \quad (10)$$

其中, $\mathbf{w}$ 为权值向量; $\mathbf{b}$ 为偏差, 是 2 个待训练的参数; 对于非线性映射函数 $\phi(\mathbf{x})$ 的选取一般都是选择试算得到的。

对 $\mathbf{w}$ 和 $\mathbf{b}$ 的训练实际是极小化下面的泛函:

$$R(c, \varepsilon) = \frac{1}{m} c \sum_{i=1}^m L(y_i - f(\mathbf{x}_i, \mathbf{w}), \mathbf{x}_i) + \frac{1}{2} \mathbf{w}^T \mathbf{w} \quad (11)$$

式(11)等号右边第 1 项为经验误差项, 第 2 项为正规化项, 正规化常数 c 用来平衡 2 项误差之间的关系。

$$L(y_i - f(\mathbf{x}_i, \mathbf{w}), \mathbf{x}_i) = |y_i - f(\mathbf{x}_i, \mathbf{w})|_{\varepsilon} = \begin{cases} 0 & |y_i - f(\mathbf{x}_i, \mathbf{w})| \leq \varepsilon \\ |y_i - f(\mathbf{x}_i, \mathbf{w})| - \varepsilon & \text{其他} \end{cases} \quad (12)$$

即为 ε 的不敏感损失函数。

具体求解过程中, 引入核函数 $k(\mathbf{x}_i, \mathbf{x}_j)$, 可以直接将上述极小值问题转化为下面的对偶问题, 并采用二次规划进行求解:

$$\begin{aligned} \max \{a_i\} \{a_i^*\} = & -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (a_i - a_i^*)(a_j - a_j^*) k(\mathbf{x}_i, \mathbf{x}_j) - \\ & \varepsilon \sum_{i=1}^m (a_i + a_i^*) + \sum_{i=1}^m y_i (a_j - a_j^*) \\ \text{s.t.} \quad & \sum_{i=1}^m (a_i - a_i^*) = 0 \\ & a_i, a_i^* \in [0, c] \end{aligned} \quad (13)$$

其中, a_i 和 a_i^* 为非零的拉格朗日乘子。

由于上述问题转化为一个二次规划问题, 因此, 原来待定的回归函数表达式可表示为:

$$f(\mathbf{x}_i, a_i, a_i^*) = \sum_{i=1}^m (a_i - a_i^*) k(\mathbf{x}_i, \mathbf{x}_j) + \mathbf{b} \quad (14)$$

核函数的选择决定了特征空间的结构, 常用有 RBF 等。由于对偶问题被描述成为一个凸规划问题, 因此所求得的任意解均为全局最优解, 克服了神经网络的局部极值问题。

4 基于证据理论的短期风速预测模型

4.1 模型输入、输出变量的选择

风速数据是一组随时间变化的一维时间序列。对于时间序列模型, 其因变量是待预测的风速, 自变量为风速自身的历史值。对于 BP 神经网络和 SVM 网络, 在选择输入、输出变量前需要把一维数据序列转化成矩阵形式, 以获得数据间的关联信息, 这里采用相空间重构的方法。相空间重构中嵌入维数 m 和延迟时间 τ 的大小选取很重要, 嵌入维数可以使用 C-C 方法和嵌入窗法^[17]来确定, 延迟时间可以用 C-C 方法来确定。将原数据序列进行空间重构, 构造样本对 $(\mathbf{x}_i, y_i)$, 其中 $\mathbf{x}_i$ 为 m 维向量^[18]。

4.2 样本输入的预处理

原始样本数据进行相应的预处理有利于加快模

型的样本训练速度和收敛速度, 提高预测精度。本文主要采用归一化方法对数据进行处理:

$$\tilde{x}(i) = \frac{x(i) - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

其中, $\tilde{x}(i)$ 为归一化后的数据序列值; $x_{\max}, x_{\min}$ 分别为样本的最大值和最小值。

4.3 预测模型的评价标准

预测模型的预测效果可以采用平均绝对百分比误差 (MAPE) 和均方根误差 (RMSE) 来评价, 其表达式为:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100\% \quad (16)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2} \times 100\% \quad (17)$$

其中, $y_i, \hat{y}_i$ 分别为第 i 个实际风速值与预测风速值。

5 算例分析

本文采用某地区风速数据进行实验, 每 15 min 记录一次, 每天 96 个点, 得到一组风速序列, 共有 1 056 个点 (2008 年 6 月 1 日至 11 日), 分别用上述 3 种方法对 11 日的风速值进行提前一个点 (即 15 min) 的预测。BP 神经网络和 SVM 的输入输出数据采用相空间重构方法获得, 因此需要嵌入维数和延迟时间, 本文嵌入维数取 5, 延迟时间取 1。

首先分别采用 3 种预测模型获得 8 日至 10 日的风速预测结果, 如表 1 所示 (相对误差为真实值与预测值之差的绝对值与真实值的比值, 由于数据较多, 篇幅有限, 只列取 24 个点数据)。通过对上述预测数据分析, 利用融合模型对 11 日风速进行预测。分别提取 8 日至 10 日模型权重, 从而得到基本信任分配函数, 通过合成法则对基本信任分配函数进行多重融合, 将最终融合结果作为 11 日预测模型的权重, 该程序的流程图如图 1 所示。本文 ε 选择 0.001。

通过权重提取模型, 分别可以得到 8 日至 10 日每天 3 种预测模型对应的权重, 如表 2 所示。

将表 2 中的权重当作相应的基本信任分配函数, 通过 Dempster 合成法则进行 2 重融合, 得到最终的权重为 0.238 9、0.169 9、0.591 2。最后对 11 日风速进行预测, 预测结果如表 3 所示。

3 种单一预测模型和 2 种组合预测模型的误差对比如表 4 所示, 同时预测风速值的分布如图 2 所示。

需要特别指出的是, 单一模型中, 大部分情况下 BP 模型和 SVM 模型都优于时间序列模型, BP 模型的 RMSE、MAPE 和最大误差分别比时间序列模型低 1.19%、1.03% 和 4.04%, SVM 模型则分别比时间序列模型低 2.13%、2.39% 和 5.42%。同时, 利用单一模型进行预测, SVM 模型的预测精度比 BP 模型高,

表 1 2008-06-08 至 2008-06-10 预测相对误差
Tab.1 Relative forecast errors from 2008-06-08 to 2008-06-10

采样点	相对误差								
	8 日时间序列	8 日 BP	8 日 SVM	9 日时间序列	9 日 BP	9 日 SVM	10 日时间序列	10 日 BP	10 日 SVM
1	0.054 9	0.019 6	0.011 5	0.012 5	0.015 4	0.000 8	0.004 8	0.009 7	0.002 0
2	0.041 0	0.019 4	0.008 0	0.016 7	0.008 9	0.007 2	0.000 8	0.005 3	0.006 6
3	0.024 3	0.013 8	0.003 6	0.021 3	0.005 8	0.014 6	0.005 5	0.000 3	0.009 4
4	0.024 2	0.015 4	0.006 8	0.016 9	0.004 4	0.004 9	0.002 9	0.001 8	0.006 8
5	0.028 5	0.018 2	0.007 2	0.020 0	0.002 8	0.008 6	0.001 0	0.000 1	0.006 3
6	0.015 2	0.017 2	0.000 7	0.011 6	0.009 2	0.005 2	0.004 9	0.000 1	0.008 5
7	0.004 7	0.012 4	0.000 9	0.003 6	0.011 4	0.000 9	0.015 7	0.006 0	0.012 3
8	0.003 1	0.006 9	0.001 1	0.002 8	0.013 6	0.003 0	0.013 4	0.005 0	0.007 0
9	0.019 7	0.005 8	0.015 4	0.136 1	0.140 1	0.125 9	0.457 2	0.038 7	0.107 3
10	0.038 7	0.006 8	0.003 8	0.022 9	0.029 3	0.064 7	0.010 9	0.009 2	0.096 4
11	0.027 5	0.003 2	0.003 1	0.021 9	0.039 7	0.013 8	0.010 6	0.056 4	0.035 4
12	0.024 3	0.021 5	0.000 7	0.023 5	0.102 6	0.005 0	0.022 2	0.053 7	0.017 4
85	0.016 1	0.008 6	0.004 3	0.011 9	0.003 4	0.006 7	0.009 8	0.020 0	0.019 1
86	0.016 2	0.015 5	0.016 4	0.025 1	0.007 7	0.002 2	0.015 0	0.029 2	0.016 2
87	0.013 9	0.020 8	0.017 2	0.034 2	0.000 3	0.003 1	0.019 6	0.029 9	0.014 6
88	0.014 5	0.023 5	0.014 2	0.028 0	0.002 3	0.001 9	0.021 1	0.032 2	0.018 4
89	0.010 4	0.021 7	0.013 9	0.023 7	0.007 3	0.002 9	0.018 5	0.032 4	0.015 4
90	0.007 1	0.012 1	0.004 3	0.013 8	0.009 7	0.001 4	0.020 4	0.033 2	0.013 7
91	0.019 1	0.004 6	0.000 8	0.004 9	0.008 4	0.001 4	0.018 3	0.025 5	0.010 1
92	0.013 2	0.007 7	0.006 5	0.009 4	0.005 6	0.002 4	0.022 2	0.024 7	0.012 3
93	0.013 3	0.011 9	0.004 0	0.004 0	0.010 4	0.001 1	0.018 3	0.021 4	0.008 9
94	0.018 1	0.015 1	0.000 6	0.004 6	0.007 6	0.004 3	0.018 8	0.020 7	0.004 9
95	0.015 6	0.011 9	0.000 7	0.003 1	0.009 2	0.002 4	0.015 9	0.012 4	0.001 7
96	0.013 8	0.014 4	0.003 9	0.009 6	0.007 1	0.002 0	0.015 1	0.005 9	0.000 1




图 1 证据理论权重融合的风速预测流程
Fig.1 Flowchart of wind speed forecast with fused weights based on evidence theory

表 2 2008-06-08 至 2008-06-10 3 种预测模型对应的权重

Tab.2 Weights for three forecasting models from 2008-06-08 to 2008-06-10

日期	时间序列权重	BP 权重	SVM 权重
2008-06-08	0.229 8	0.294 5	0.475 7
2008-06-09	0.380 9	0.246 4	0.372 8
2008-06-10	0.324 7	0.278 6	0.396 6

表 3 D-S 模型预测结果

Tab.3 Forecasting results of D-S model

采样点	风速/(m·s ⁻¹)		采样点	风速/(m·s ⁻¹)	
	实际值	D-S 预测值		实际值	D-S 预测值
1	6.13	6.092 1	85	3.48	3.533 2
2	6.18	6.186 6	86	3.44	3.456 2
3	6.17	6.224 7	87	3.42	3.412 6
4	6.16	6.199 9	88	3.39	3.405 6
5	6.15	6.181 5	89	3.37	3.377 6
6	6.16	6.165 1	90	3.38	3.361 2
7	6.17	6.171 7	91	3.43	3.378 1
8	6.19	6.185 9	92	3.48	3.448 4
9	6.63	6.041 0	93	3.53	3.508 1
10	6.56	6.709 9	94	3.58	3.561 5
11	6.46	6.639 6	95	3.64	3.610 7
12	6.37	6.483 0	96	3.70	3.672 1




图 2 真实值与预测值曲线

Fig.2 Actual wind speed curve and forecast curve

而且预测时间更短。文献[8]也认为对于一般的风速预测模型,BP 模型和 SVM 模型优于时间序列模型,但当风速变化较大时,预测结果将有所不同。

改进模糊层次分析法[8]结合了 3 种预测方法的优点,预测精度高于时间序列、BP 网络和 SVM 网络,但是引入的模糊判断矩阵是根据专家经验选取

的,因此不同的判断矩阵得到的结果不同,预测效果很难掌握。本文采用证据理论的组合预测模型进行预测,从算例结果可看出,证据理论组合模型的预测精度优于其他单一预测模型,与改进的模糊层次分析法相比,RMSE、MAPE 和最大误差分别低 1.55%、

表 4 5 种方法误差比较

Tab.4 Comparisons of forecasting error among five methods

预测方法	RMSE/%	MAPE/%	最大误差/%
时间序列法	7.72	5.21	18.58
BP 网络	6.53	4.18	14.54
SVM 网络	5.59	2.82	13.16
改进模糊层次分析法	5.48	2.62	12.37
D-S 证据理论	3.93	2.25	10.22

0.37%和 2.15%,同时避免了专家经验带来的影响,有效地降低了预测方法的不确定性,保证了模型的精度。

6 结论

本文借助于证据理论的思想,通过 Dempster 合成法则对历史预测数据进行模型权重的融合,从而对待预测日的风速进行预测。首先采用 3 种方法对待测日前 3 日的风速进行预测,提取融合样本,根据误差计算这 3 日的模型权重,然后将权重看作基本信任分配函数,并对函数进行融合,最后将融合结果作为待测日的模型权重,对待测日风速进行预测。实例分析结果表明,证据理论预测模型的预测结果比单一预测模型的精度更高,同时与现有的改进模糊层次分析法组合预测模型相比,其不仅预测精度更高,同时还能有效地避免层次分析法中专家经验的不确定性对预测精度的影响,为短期风速预测提供了一种新的有效方法。

参考文献:

[1] 雷亚洲,王伟胜,印永华,等. 风电对电力系统运行的价值分析[J]. 电网技术,2002,26(5):10-14.
LEI Yazhou,WANG Weisheng,YIN Yonghua,et al. Analysis of wind power value to power system operation[J]. Power System Technology,2002,26(5):10-14.

[2] 杨秀媛,肖洋,陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报,2005,25(11):1-5.
YANG Xiuyuan,XIAO Yang,CHEN Shuyong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE,2005,25(11):1-5.

[3] 丁明,张立军,吴义纯. 基于时间序列分析的风电场风速预测模型[J]. 电力自动化设备,2005,25(8):32-34.
DING Ming,ZHANG Lijun,WU Yichun. Wind speed forecast model for wind farms based on time series analysis[J]. Electric Power Automation Equipment,2005,25(8):32-34.

[4] 马静波,杨洪耕. 自适应卡尔曼滤波在电力系统短期负荷预测中的应用[J]. 电网技术,2005,29(1):75-79.
MA Jingbo,YANG Honggeng. Application of adaptive Kalman filter in power system short-time load forecasting[J]. Power System Technology,2005,29(1):75-79.

[5] 潘迪夫,刘辉,李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术,2008,32(7):82-86.
PAN Difuf,LIU Hui,LI Yanfei. A wind speed forecasting optimization model for wind farms based on time series analysis

and Kalman filter algorithm[J]. Power System Technology,2008,32(7):82-86.

[6] 蔡凯,谭伦农,李春林,等. 时间序列与神经网络法相结合的短期风速预测[J]. 电网技术,2008,32(8):82-86.
CAI Kai,TAN Lunnong,LI Chunlin,et al. Short-term wind speed forecasting combing time series and neural network method[J]. Power System Technology,2008,32(8):82-86.

[7] 李文良,卫志农,孙国强,等. 基于改进空间相关性法和径向基神经网络的风电场短期风速分时预测模型[J]. 电力自动化设备,2009,29(6):89-92.
LI Wenliang,WEI Zhinong,SUN Guoqiang,et al. Multi-interval wind speed forecast model based on improved spatial correlation and RBF neural network[J]. Electric Power Automation Equipment,2009,29(6):89-92.

[8] 黄文杰,傅砾,肖盛. 采用改进模糊层次分析法的风速预测模型[J]. 电网技术,2010,34(7):164-167.
HUANG Wenjie,FU Li,XIAO Sheng. A predictive model of wind speed based on improved fuzzy analytical hierarchy process[J]. Power System Technology,2010,34(7):164-167.

[9] 杨风暴,王肖霞. D-S 证据理论的冲突证据合成方法[M]. 北京:国防工业出版社,2010.

[10] 李鹏,颜艳,郑武军,等. 证据理论融合量子神经网络的短期负荷预测[J]. 电力系统保护与控制,2010,38(16):49-53.
LI Peng,YAN Yan,ZHENG Wujun,et al. Short-term forecasting based on quantum neural network by evidence theory[J]. Power System Protection and Control,2010,38(16):49-53.

[11] LI Hongdong,ZHANG Jing,XIAO Lin,et al. Application of DS evidence theory in combined price forecasting [C] //Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies,2008. DRPT 2008. Nanjing,China:[s.n.],2008:1025-1029.

[12] 吴京秋,孙奇,杨伟,等. 基于 D-S 证据理论的短期负荷预测模型融合[J]. 电力自动化设备,2009,29(4):66-70.
WU Jingqiu,SUN Qi,YANG Wei,et al. Short-term load forecast model fusion based on D-S evidence theory[J]. Electric Power Automation Equipment,2009,29(4):66-70.

[13] 彭信淞,贺辉,姚建刚,等. 用 PSO 优化 BP 神经网络的母线负荷预测方法[J]. 电力系统及其自动化学报,2010,22(5):146-151.
PENG Xinsong,HE Hui,YAO Jiangang,et al. Method of bus-load forecasting using BP neural network optimized by PSO[J]. Proceedings of the CSU-EPSCA,2010,22(5):146-151.

[14] 梁建武,陈祖权,谭海龙,等. 短期负荷预测的聚类组合和支持向量机方法[J]. 电力系统及其自动化学报,2011,23(1):34-38.
LIANG Jianwu,CHEN Zuquan,TAN Hailong,et al. Application of clustering combination and support vector machine in short-term load forecasting[J]. Proceeding of the CSU-EPSCA,2011,23(1):34-38.

[15] WANG Y,WU D L,GUO C X,et al. Short-term wind speed prediction using support vector regression[C]//2010 IEEE Power and Energy Society General Meeting. Minneapolis,MN,USA:[s.n.],2010:1-6.

[16] 龚灯才,李训铭,李林峰. 基于模糊支持向量机方法的短期负荷预测[J]. 电力自动化设备,2005,25(7):41-43.
GONG Dengcai,LI Xunming,LI Linfeng. Short-term load forecast based on fuzzy support vector machine method[J]. Electric Power Automation Equipment,2005,25(7):41-43.

[17] 罗欣,周渝慧,郭宏榆. 基于混沌因子及相空间重构后的神经网络

络短期电价预测的研究[J]. 继电器,2008,36(1):48-52.

LUO Xin,ZHOU Yuhui,GUO Hongyu. Short-term price forecasting based on chaotic property and phase space reconstructed neural networks[J]. Relay,2008,36(1):48-52.

[18] 曾杰,张华. 基于最小二乘支持向量机的风速预测模型[J]. 电网技术,2009,33(18):66-70.

ZENG Jie,ZHANG Hua. A wind speed forecasting model based on least squares support vector machine[J]. Power System Technology,2009,33(18):66-70.

作者简介:

刘亚南(1988-),男,江苏徐州人,硕士研究生,研究方向为电力系统负荷预测(E-mail:lynwyx@163.com);

卫志农(1962-),男,江苏江阴人,教授,博士研究生导师,研究方向为电力系统运行分析与控制、输配电系统自动化等(E-mail:wzn_nj@263.net);

朱 艳(1981-),女,江苏建湖人,研究方向为电力系统自动化(E-mail:jiangxie1225@163.com)。

Short-term wind speed forecasting model based on D-S evidence theory

LIU Yanan¹,WEI Zhinong¹,ZHU Yan²,SUN Guoqiang¹,SUN Yonghui¹,
YANG Youqing³,QIAN Ying³,ZHOU Jun³

(1. Research Center for Renewable Energy Generation Engineering of Ministry of Education,Hohai University, Nanjing 210098,China;2. NARI Technology Development Co.,Ltd.,Nanjing 210061,China;
3. Chizhou Power Supply Company of Anhui Electric Power Company,Chizhou 247000,China)

Abstract: A combined short-term wind speed forecasting model based on D-S evidence theory is proposed. The forecasting models of time series,BP neural network and support vector machine are adopted to respectively forecast the wind speed. Based on the analysis of forecast errors,D-S evidence theory is applied to fuse these three models. The wind speed data for several days before are taken as the fusion samples to calculate the corresponding basic trust distribution functions,which are then fused. The results of fusion are taken as the weights of the wind speed forecasting model and the wind speed of the day to be forecasted is calculated. Simulative results show that,the proposed combined forecasting model has smaller forecasting error and better effect.

Key words: wind power; time series; BP neural network; support vector machines; D-S evidence theory; forecasting; models

(上接第 130 页 continued from page 130)

Sensorless vector control technology for brushless doubly-fed
wind power generator

ZHU Yunguo^{1,2},ZHANG Xing¹,LIU Chun¹,CHEN Hongbing¹

(1. College of Electrical and Automatic Engineering,Hefei University of Technology,Hefei 230009,China;
2. Department of Electrical Engineering,Tongling College,Tongling 244000,China)

Abstract: A control strategy applying the model-reference adaptive speed identification is proposed to remove the bad influence of speed sensor on the control stability and accuracy of the vector control system for the BDFG(Brushless Doubly-Fed Generator),which observes the stator flux at BDFG power side to obtain the reference model and design the adjustable model,and then estimates the rotor speed by regulating the error between two models. A simulation model of control system is established with MATLAB/Simulink and the simulative results show the proposed adaptive speed observer realizes the precise speed identification in both static and dynamic conditions and the decoupled control of active and reactive powers. Experiment is carried out on a small-power BDFG platform and the experimental result verifies the feasibility and effectiveness of the proposed control strategy.

Key words: wind power; brushless doubly-fed generator; rotor speed; vector control; model reference adaptive system; stator-flux-oriented