

风电场输出功率的组合预测模型

刘纯, 范高锋, 王伟胜, 戴慧珠

(中国电力科学研究院, 北京市 海淀区 100192)

A Combination Forecasting Model for Wind Farm Output Power

LIU Chun, FAN Gao-feng, WANG Wei-sheng, DAI Hui-zhu

(China Electric Power Research Institute, Haidian District, Beijing 100192, China)

ABSTRACT: It is of significance to forecast output power of wind farm for the operation of power grid to which large amount of wind power is connected. By use of BP neural network, radial basis function neural network and support vector machine, a combination forecasting model for output power of wind farm is built. The weights are calculated by three methods, i.e., equal weight average method, covariance optimization combination forecast and time-varying weight combination forecast. Research results show that the forecast accuracy from different methods is diverse one another; even though a method can offer high forecast accuracy in total, at individual point the forecast error of this method may be larger, however combination forecasting model can avoid larger forecast error in each point, so it is favorable to improve forecast accuracy.

KEY WORDS: wind farm; power forecast; BP neural network; radial basis function (RBF) neural network; support vector machine (SVM)

摘要: 风电场输出功率预测对于接入大量风电的电力系统运行具有重要意义。作者利用BP神经网络、径向基函数神经网络和支持向量机进行风电功率预测,提出了风电场输出功率的组合预测模型。采用3种方法确定权重,即等权重平均法、协方差优选组合预测法和时变权系数组合预测法。研究结果表明,不同方法的预测精度不同,整体预测精度高的方法在个别预测点也可能误差较大,组合预测模型能有效减少各预测点较大误差的出现,有利于提高预测精度。

关键词: 风电场; 功率预测; BP神经网络; 径向基函数神经网络; 支持向量机

0 引言

大规模风电接入电网给电力系统的运行带来一些新问题,其中很重要的一方面是对电力系统运行调度的影响。风电功率预测对电力系统的功率平衡和经济调度具有非常重要的意义。国外风电装机

容量较大的国家都进行了风电功率预测系统的开发。功率预测方法没有统一的分类标准,按照不同的标准有不同的分类。根据预测物理量的不同可分为2类:第1类是对风速进行预测,然后根据风电机组或风电场的功率曲线得到风电场的输出功率;第2类是直接预测风电场的输出功率。根据所采用数学模型的不同可分为持续预测法、自回归滑动平均(auto-regressive and moving average, ARMA)模型法、卡尔曼滤波法和智能方法等。持续预测方法^[1]是最简单的预测方法,认为风速预测值等于最近几个风速值的滑动平均值,通常认为最近一点的风速值为下一点的风速预测值^[2],该方法的预测误差较大,且预测结果不稳定。改进的方法有ARMA模型^[3-4]、卡尔曼滤波算法^[5-6]或将时间序列法与卡尔曼滤波算法相结合^[7],另外还有一些智能方法,如人工神经网络方法^[2,8-9]等。此外,预测的时间尺度非常重要,不同时间尺度的预测结果用途不同,如数min内的风速预测主要用于风力发电控制、电能质量评估及风轮机机械部件的设计等^[10]。15 min~72 h的预测主要用于电力系统的暂态稳定评估、功率平衡和调度、电力市场交易等。从建模的观点来看,不同时间尺度是有本质区别的:对于0~3 h的预测,由于其变化主要由大气条件的持续性决定,因此采用统计方法可以得到较好的预测结果^[11];而对于长达数天的预测,不考虑数值天气预报数据无法反映大气运动的本质,也难以得到较好的预测结果,因此,目前研究的风电场输出功率预测都将数值天气预报数据作为一组重要的输入数据,本文的研究也基于数值天气预报数据。

欧洲风电发达国家目前均建立了风电功率预测系统,其中德国太阳能研究所的WPMS系统采用神经网络模型,应用于德国四大电网公司,取得

了较好的效果。笔者在研究和项目实践中发现，采用一种预测模型在有些预测点可能出现较大的误差，因此在建立用于风电功率预测的 BP (back propagation)神经网络模型、径向基函数(radial basis function, RBF)神经网络模型和支持向量机(support vector machine, SVM)模型的基础上，采用 3 种模型组合预测的方法。研究表明，组合模型有效减少了较大误差的出现，提高了预测精度。

1 输入数据的选择

风力机捕获的风功率可用下式表示^[12]：

$$P = \frac{1}{2} C_p A \rho v^3 \tag{1}$$

式中： C_p 为风轮的功率系数； ρ 为空气密度； A 为风轮扫掠面积； v 为风速。由式(1)可以看出，风电机组的输出功率取决于风速及空气密度。由于湍流及阵风的影响，导致风电机组的输出功率较杂散。

一般风电场由很多风电机组组成，风能被风电机组叶轮吸收，使风轮后面的风速降低，形成尾流。由于上风向的风电机组尾流的影响，使下风向风电机组捕获的风能减少，相应风电机组的出力也降低。

为进一步定量分析风向对风电场输出功率的影响，定义风电场的效率系数 η ：

$$\eta = P_m / P_f \tag{2}$$

式中： P_m 为风电场在一定风速和风向下的实测功率； P_f 为风电场在一定风速和风向不受尾流影响的输出功率。某风电场的效率如图 1 所示。可以看出，风速较低时，由于尾流和粗糙度的影响，在某些风向下风电场效率较低，在风速为 4 m/s 时，效率最低，降到 45%。同时可以看出，风速越大，风电场效率系数越高，当风速超过额定风速一定量时，受尾流影响的机组的风速也超过额定风速，此时尾流效应不影响输出功率，风电场在任何风向下

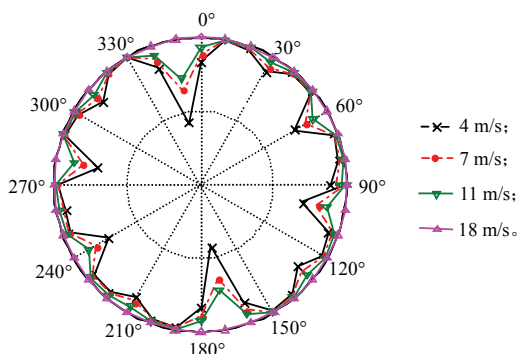


图 1 风电场在不同风速、风向下的效率
Fig. 1 Wind farm efficiency under different wind speed and wind direction

效率系数都为 100%。

图 2 是根据实测数据绘制的某风电场的风速-风向-功率三维图，可以看出，风电场输出功率并不是平滑的曲面。




图 2 风速-风向-功率三维图
Fig. 2 3-dimension diagram of wind speed-wind direction-wind power

空气密度 ρ 也是影响输出功率的重要因素之一。空气密度与湿度、温度、压强密切相关，因此在风电功率预测中要考虑温度、湿度和压强。

根据以上分析，风电功率预测模型的输入数据应包括风速、风向、温度、湿度和压强。

2 预测模型

2.1 预测模型的选择

风电场输出功率与风速、风向、气温、气压、湿度等多种因素有关，很难用一定的数学表达式描述。人工智能方法如 BP 神经网络、RBF 神经网络、SVM 等具有较强的非线性学习能力，能通过统计数据学习得到其内在关系。本文选择以上 3 种方法进行预测。

2.2 BP 神经网络模型

BP 神经网络是基于误差反向传播算法的多层前向神经网络，采用有导师的训练方式^[13-16]。它可以任意精度逼近任何非线性映射；可以学习和自适应未知信息；具有分布式信息存储与处理结构，具有一定的容错性，因此构造出来的系统具有较好的鲁棒性，适合处理复杂问题。BP 神经网络的基本结构如图 3 所示。




图 3 BP 神经网络结构
Fig. 3 The structure of BP neural network

2.3 RBF 神经网络模型

1989 年文献[17]提出用 RBF 作神经元的功能函数来进行神经网络的学习, Jackon 论证了 RBF 神经网络对非线性连续函数的一致逼近性能^[18]。RBF 神经网络是一种单隐层前馈型网络,它以 RBF 作为隐节点激活函数,具有收敛速度快、逼近精度高、网络规模小等特点。RBF 神经网络的基本结构如图 4 所示。




图 4 RBF 神经网络结构

Fig. 4 The structure of RBF neural network

构建 RBF 网络的基本思想是:用 RBF 作为隐单元的“基”构成隐含层空间,这样就将输入矢量直接映射到隐层空间,当 RBF 的中心点确定后,这种映射关系也就确定了。而隐层空间到输出层的映射是线性的,即网络的输出是隐单元输出的线性加权和。

RBF 网络的映射关系由 2 部分组成:第 1 部分是从输入空间到隐含层空间的非线性变换。第 j 个隐单元输出为

$$h_j(\mathbf{x}) = \phi(\|\mathbf{x} - \mathbf{c}_j\|, \sigma_j) = \exp\left[-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{2\sigma_j^2}\right] \quad (3)$$

式中: $\phi(\cdot)$ 为隐单元的变换函数,它是一种对中心点径向对称衰减的非负线性函数,本文取高斯函数; $\|\cdot\|$ 表示范数,本文取 2 范数; \mathbf{x} 为 n 维输入向量,即 $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$; σ_j 为第 j 个非线性变换单元的宽度; \mathbf{c}_j 为第 j 个非线性变换单元的“中心”向量,即

$$\mathbf{c}_j = [c_j^1, c_j^2, \dots, c_j^n]^T \quad (4)$$

式中 c_j^k 表示第 j 个中心对应第 k 个输入的分量。

第 2 部分是从隐含层空间到输出层空间的线性合并层,输出为

$$f(\mathbf{x}) = \sum_{j=1}^m h_j(\mathbf{x})w_j \quad (5)$$

式中: w_j 为第 j 个隐单元与输出之间的连接权; m 为隐单元数。

采用自组织选取中心法进行网络训练。数据归一化与 BP 网络所采用的方法相同。

2.4 SVM 模型

SVM 是由 Vapnik 提出的一种统计学习方法^[19-28],是在统计学习理论的 VC 维理论和结构风险最小原理的基础上发展起来的一种新的机器学习方法。具有理论完善、适应性强、全局优化、训练时间短和泛化能力强的特点。最小二乘向量机将二次优化问题转化为一个线性方程组的求解问题,克服了 SVM 的缺陷^[29]。

假设存在如下样本集合:

$$z = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_t, y_t)\}$$

$$\mathbf{x}_i \in \mathbf{R}^n, y_i \in \mathbf{R}, i = 1, \dots, t$$

对该样本的最小二乘向量机回归的表述为

$$\min J = \frac{1}{2} \mathbf{w} \mathbf{w}^T + C \sum_{i=1}^t e_i^2 \quad (6)$$

$$\text{s.t. } y_i = \mathbf{w} \boldsymbol{\varphi}(\mathbf{x}_i) + b + e_i \quad (7)$$

式中: \mathbf{w} 为超平面的法线向量; C 为惩罚系数; e_i 为误差; b 为偏置。

式(6)的拉格朗日函数为

$$L = \frac{1}{2} \mathbf{w} \mathbf{w}^T + C \sum_{i=1}^t e_i^2 - \sum_{i=1}^t \alpha_i [\mathbf{w} \boldsymbol{\varphi}(\mathbf{x}_i) + b + e_i - y_i] \quad (8)$$

对该拉格朗日函数求极值,问题转化为对以下线性方程组的求解:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & k(\mathbf{x}_1, \mathbf{x}_1) + 1/C & \dots & k(\mathbf{x}_1, \mathbf{x}_t) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & k(\mathbf{x}_t, \mathbf{x}_1) & \dots & k(\mathbf{x}_t, \mathbf{x}_t) \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_t \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_t \end{bmatrix} \quad (9)$$

式中 $k(\mathbf{x}_i, \mathbf{x}_j) = \langle \boldsymbol{\varphi}(\mathbf{x}_i), \boldsymbol{\varphi}(\mathbf{x}_j) \rangle$ 为核函数,它是非线性映射函数 $\boldsymbol{\varphi}(\cdot)$ 的内积。解该方程组,可得到 t 个样本的回归系数向量 $\boldsymbol{\alpha}$ 和偏置 b ,故对 k 时刻的预测值为

$$P(\mathbf{x}_k) = \sum_{i=1}^t \alpha_i k(\mathbf{x}_k, \mathbf{x}_i) + b \quad (10)$$

3 风电功率预测的组合模型

3.1 组合预测的概念

组合预测^[30]是对几种预测方法得到的预测结果,选取适当的权重进行加权平均的一种预测方法。其主要目的在于消除单一预测方法可能存在的较大偏差,提高预测的准确性。图 5 是 BP 神经网络




图 5 组合预测模型

Fig. 5 Combination forecasting model

络、RBF神经网络和支持向量机3种预测方法组合预测的示意图。

3.2 等权重平均法(组合模型1)

等权重平均法的计算公式为

$$P_{\Sigma} = \frac{P_{BP} + P_{RBF} + P_{SVM}}{3} \quad (11)$$

式中： P_{Σ} 为总的预测输出功率； P_{BP} 、 P_{RBF} 、 P_{SVM} 分别为BP神经网络、RBF神经网络、SVM预测的输出功率。

3.3 协方差优选组合预测法(组合模型2)

组合预测值可表示为

$$P_{\Sigma} = \lambda_1 P_{BP} + \lambda_2 P_{RBF} + \lambda_3 P_{SVM} \quad (12)$$

式中： λ_1 、 λ_2 、 λ_3 分别为BP神经网络、RBF网络和SVM的权重，有 $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 。

3种预测方法及组合预测的误差分别为 e_1 、 e_2 、 e_3 、 e_c ，3种预测误差的方差为 σ_{11} 、 σ_{22} 、 σ_{33} ，组合预测误差的方差为 $\text{var}(e_c) = \sum_{i=1}^3 \lambda_i^2 \sigma_{ii}$ 。

在约束 $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 的条件下，引入拉格朗日乘子对 $\text{var}(e_c)$ 求极小值，可以得到

$$\lambda_i = \frac{1}{\sigma_{ii}(1/\sigma_{11} + 1/\sigma_{22} + 1/\sigma_{33})}, \quad i=1,2,3 \quad (13)$$

$$\text{var}(e_c) = \frac{1}{1/\sigma_{11} + 1/\sigma_{22} + 1/\sigma_{33}} \quad (14)$$

当3种预测方法的预测误差分别服从零均值正态分布时，可用下式估计 σ_{ii} ($i=1,2,3$):

$$\hat{\sigma}_{ii} = \frac{1}{n} \sum_{t=1}^n e_{it}^2 \quad (15)$$

式中： n 为历史数据个数； e_{it} 为第 i 种组合模型在 t 点的误差。由此可得出 λ_i ($i=1,2,3$)的估计值为

$$\hat{\lambda}_i = \left(\sum_{t=1}^n e_{it}^2 \right)^{-1} \left[\sum_{j=1}^3 \left(\sum_{t=1}^n e_{jt}^2 \right)^{-1} \right]^{-1} \quad (16)$$

可以证明： $\text{var}(e_c)_{\min} \leq \min(\sigma_{11}, \sigma_{22}, \sigma_{33})$ ，表明组合预测方法优于单一预测方法。

3.4 时变权系数组合预测法(组合模型3)

协方差优选组合预测法计算得到的权系数是固定不变的。实际上，在不同情况下各预测方法的预测精度可能不同，采用变系数的方法有可能进一步提高预测精度。权系数的确定可采用移动样本，取最近的 s 个样本历史值来计算权系数：

$$\hat{\lambda}_i = \left(\sum_{t=n-s+1}^n e_{it}^2 \right)^{-1} \left[\sum_{j=1}^3 \left(\sum_{t=n-s+1}^n e_{jt}^2 \right)^{-1} \right]^{-1} \quad (17)$$

计算中采用移动样本，每次都使用 s 个样本计算。对于提前1d的预测，能得到的最近的测量值是前1d的，因此用前1d的样本计算权系数，权系数每天更新一次。

4 算例分析

4.1 风电场基本情况及数据处理

算例风电场包含58台G58-850kW型机组，总装机容量为49.3MW。风电场共有6行风机，行间距为480m，行内每2台风机间距为360m。G58-850kW型风电机组是一种变速双馈风电机组，风轮直径为58m，轮毂高度为55m。

适当的数据处理可提高神经网络的泛化能力，提高预测精度。下面介绍采用的数据归一化方法。

1) 风速归一化。

一般风电机组运行的风速范围为3~25m/s，陆地上极限风速一般不超过30m/s。当然，不同地区的极限风速是不同的。可采用如下方法对风速进行归一化：

$$v_g = v_t / v_{\max} \quad (18)$$

式中： v_g 为归一化后的风速值； v_t 为数值天气预报系统预测的风速值； v_{\max} 为气象观测的历史最大风速。

2) 风向归一化。

风向对风电场出力有重要影响，一年中风向可能在 $0^\circ \sim 360^\circ$ 之间变化，取风向的正弦值或余弦值可实现0~1的映射，但单一的正弦值或余弦值不能完全区分 $0^\circ \sim 360^\circ$ 内的所有风向，风向的正弦值和余弦值结合在一起可以区分所有的风向，因此输入神经网络的风向为2个值：风向的正弦值和余弦值。

3) 气温、气压、湿度的归一化采用与风速归一化类似的方法，取气象观测的最大值进行归一化。

训练数据为3个月数值天气预报数据和风电场出力数据，包含不同风速段、不同风向的数据。取另一时间段的数据(3个月)用于预测模型的测试。

4.2 单一模型的预测

对于BP神经网络，3层网络理论上就可以逼近任何非线性函数，因此选择包含一个隐含层的3层网络。网络隐层神经元传递函数采用S型正切函数，输出层神经元传递函数采用S型对数函数。隐层节点数会影响预测精度。经逐一筛选分析，当网络隐层节点数为19时，训练样本误差最小，均方根误差(root mean squared error, RMSE)为10.9%；隐层节点数继续增加，出现过学习现象，网络外推能力变差，预测误差反而增大。对于RBF神经网络，选择高斯

函数作为径向基函数，采用自组织选取中心法进行神经网络的学习。本文中最小二乘 SVM 的核函数选择高斯函数，训练算法选择最小二乘回归算法。

通过对测试数据的分析，BP 神经网络、RBF 网络、SVM 的均方根预测误差分别为 15.3%、13.2%、12.8%。从测试数据的预测结果来看，RBF 网络比 BP 网络预测精度高，SVM 比 RBF 网络预测精度高。图 6 是采用不同预测方法得到的一段 24h 的预测结果。图 7 是各预测方法的绝对误差曲线。可以看出，尽管 SVM 预测结果的均方根误差较小，但在某些预测点会出现较大的误差。




图 6 不同模型的预测结果

Fig. 6 Forecasting results of different models




图 7 各模型预测的绝对误差

Fig. 7 Absolute forecasting errors of different models

4.3 组合模型的预测

根据训练数据的预测结果，计算协方差优选组合预测法的权系数；根据前 1 d 的预测结果计算时变权系数法的权系数，权系数见表 1。组合模型的预测结果见图 8，绝对误差见图 9。

表 1 组合模型的权系数

Tab. 1 Weights of combination models

模型	λ_1	λ_2	λ_3
组合模型 2	0.149 1	0.153 6	0.697 3
组合模型 3	0.338 5	0.329 5	0.332 0




图 8 组合模型的预测结果

Fig. 8 Forecasting results of combination models




图 9 组合模型预测的绝对误差

Fig. 9 Absolute forecasting errors of combination models

各预测点的最大绝对误差见表 2。由表 2 可以看出，BP 模型预测结果的最大绝对误差为 17.0%，SVM 预测结果的最大绝对误差为 22.4%。这说明，虽然 BP 模型预测结果的均方根误差较大，但在这 24 h 内的预测却比 SVM 模型好。3 种组合模型的最大绝对误差中最大的为 17.6%，最小的为 16.1%。可以说，组合模型能有效减少较大误差的出现，提高预测精度。

表 2 预测结果的最大绝对误差

Tab. 2 The maximum absolute errors of the forecasting results

预测模型	BP 网络	RBF 网络	SVM
最大绝对误差/%	17.0	16.7	22.4
预测模型	组合模型 1	组合模型 2	组合模型 3
最大绝对误差/%	17.6	16.3	16.1

5 结论

1) BP 神经网络、RBF 神经网络及 SVM 都可用来进行风电场输出功率预测，且预测误差接近。

2) 在本文算例中，RBF 网络的预测结果好于 BP 神经网络，SVM 的预测结果好于 RBF 网络。但需要注意的是，并不是每个预测点都如此。

3) 本文提出了组合预测模型，即对 3 种预测结果求加权平均值作为最终预测结果，采用了 3 种处理方法，即等权重平均、协方差优选组合预测和时变权系数组合预测。组合预测可以有效减少较大误差的出现，从而提高预测精度。组合预测方法推荐采用时变权系数法，该方法具有一定的自适应能力，预测效果较好。

参考文献

- [1] Brown B G, Katz R W, Murphy A H. Time series models to simulate and forecast wind speed and wind power[J]. Journal of Climate and Applied Meteorology, 1984, 23(8): 1184-1195.
- [2] Lexiadis M A, Dokopoulo s P, Samanoglou S H, et al. Short term forecasting of wind speed and related electrical power[J]. Solar Energy, 1998, 63(1): 61-68.
- [3] Boone A. Simulation of short-term wind speed forecast errors using a

- multi-variate ARMA(1,1) time-series model[D]. Stockholm, Sweden: Royal Institute of Technology, 2005.
- [4] 吴国阳, 肖洋, 翁莎莎. 风电场短期风速预测探讨[J]. 吉林电力, 2005(6): 21-24.
Wu Guoshang, Xiao Yang, Weng Shasha. Discussion about short-term forecast of wind speed on wind farm[J]. Jilin Electric Power, 2005(6): 21-24(in Chinese).
- [5] Bossanyi E A. Short-term wind prediction using Kalman filters [J]. Wind Engineering, 1985, 9(1): 1-8.
- [6] 王耀南, 孙春顺, 李欣然. 用实测风速校正的短期风速仿真研究[J]. 中国电机工程学报, 2008, 28(11): 94-100.
Wang Yaonan, Sun Chunshun, Li Xinran. Short-term wind speed simulation corrected with field measured wind speed[J]. Proceedings of the CSEE, 2008, 28(11): 94-100(in Chinese).
- [7] 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 Difu, 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(in Chinese).
- [8] 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(in Chinese).
- [9] Kariniotakis G N, Stavrakakis G S, Nogaret E F. Wind power forecasting using advanced neural networks models[J]. IEEE Trans on Energy Conversion, 1996, 11(4): 762-767.
- [10] Potter C W, Negnevitsky M. Very short-term wind forecasting for Tasmanian power generation[J]. IEEE Trans on Power Systems, 2006, 21(2): 965-972.
- [11] Lange M, Focke U. Physical approach to short-term wind power prediction[M]. Germany: Springer, 2006: 7-8.
- [12] 王承煦, 张源. 风力发电[M]. 北京: 中国电力出版社, 2003: 56.
- [13] Simon Haykin. 神经网络原理[M]. 叶世伟, 史忠植, 译. 北京: 机械工业出版社, 2004: 109-121.
- [14] Martin Hagan T, Howard Demuth B, Mark Beale H, et al. 神经网络设计[M]. 北京: 机械工业出版社, 2002: 197-221.
- [15] 蒋宗礼. 人工神经网络导论[M]. 北京: 高等教育出版社, 2001: 97-106.
- [16] Hecht Nielsen R. Kolmogorov's mapping neural network existence theorem[C]. First IEEE International Conference of Neural Networks, San Diego, 1987.
- [17] Moody J, Darken C. Fast learning in networks of locally-tuned processing units[J]. Neural Computation, 1989, 1(2): 289-303.
- [18] Jackson I R H. Convergence properties of radial basis functions [J]. Constructive Approximation, 1988, 4(1): 243-264.
- [19] Vapnik V N. Statistical learning theory[M]. New York: Wiley, 1998: 375-400.
- [20] Vapnik V N. 统计学习理论的本质[M]. 张学工, 译. 北京: 清华大学出版社, 2000: 5-6.
- [21] 耿艳, 韩学山, 韩力. 基于最小二乘支持向量机的短期负荷预测[J]. 电网技术, 2008, 32(18): 72-76.
Geng Yan, Han Xueshan, Han Li. Short-term load forecasting based on least squares support vector machines[J]. Power System Technology, 2008, 32(18): 72-76(in Chinese).
- [22] 杜颖, 卢继平, 李青, 等. 基于最小二乘支持向量机的风电场短期风速预测[J]. 电网技术, 2008, 32(15): 62-66.
Du Ying, Lu Jiping, Li Qing, et al. Short-term wind speed forecasting of wind farm based on least square-support vector machine[J]. Power System Technology, 2008, 32(15): 62-66(in Chinese).
- [23] 罗玮, 严正. 基于广义学习矢量量化和支持向量机的混合短期负荷预测方法[J]. 电网技术, 2008, 32(13): 62-68.
Luo Wei, Yan Zheng. A hybrid approach of short-term load forecasting based on generalized learning vector quantity and support machine[J]. Power System Technology, 2008, 32(13): 62-68(in Chinese).
- [24] 赵庆明, 李永丽, 贺家李. 基于支持向量机的电流互感器饱和和补偿算法[J]. 电网技术, 2008, 32(4): 86-90.
Zhao Qingming, Li Yongli, He Jiali. Compensation algorithm for current transducer saturation based on support vector machine [J]. Power System Technology, 2008, 32(4): 86-90(in Chinese).
- [25] 牛东晓, 刘达, 邢棉, 等. 基于自组织映射支持向量机的日前电价预测[J]. 电网技术, 2007, 31(18): 15-18,22.
Niu Dongxiao, Liu Da, Xing Mian, et al. Day-ahead electricity price forecasting using support vector machines based on self-organizing map[J]. Power System Technology, 2007, 31(18): 15-18,22(in Chinese).
- [26] 谢宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化方法[J]. 中国电机工程学报, 2006, 26(22): 17-22.
Xie Hong, Wei Jiangping, Liu Heli. Parameter selection and optimization method of SVM model for short-term load forecasting [J]. Proceedings of the CSEE, 2006, 26(22): 17-22(in Chinese).
- [27] 牛东晓, 谷志红, 邢棉, 等. 基于数据挖掘的SVM短期负荷预测方法研究[J]. 中国电机工程学报, 2006, 26(18): 6-12.
Niu Dongxiao, Gu Zhihong, Xing Mian, et al. Study on forecasting approach to short-term load of SVM based on data mining [J]. Proceedings of the CSEE, 2006, 26(18): 6-12(in Chinese).
- [28] 赵登福, 庞文晨, 张讲社, 等. 基于贝叶斯理论和在线学习支持向量机的短期负荷预测[J]. 中国电机工程学报, 2005, 25(13): 8-13.
Zhao Dengfu, Pang Wenchen, Zhang Jiangshe, et al. Based on Bayesian theory and online learning SVM for short term load forecasting [J]. Proceedings of the CSEE, 2005, 25(13): 8-13(in Chinese).
- [29] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [30] 牛东晓, 曹淑华. 电力系统负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998: 188-194.



刘纯

收稿日期: 2009-02-16.

作者简介:

刘纯(1968—), 男, 高级工程师, 研究方向为电力系统分析与风力发电;

范高锋(1977—), 男, 博士, 研究方向为风力发电对电力系统的影响, E-mail: fangaofeng@epri.ac.cn;

王伟胜(1968—), 男, 博士, 教授级高级工程师, 主要从事电力系统分析与风力发电领域的科研与教学工作;

戴慧珠(1939—), 女, 教授, 博士生导师, 长期从事电力系统分析与风力发电等领域的科研与教学工作。

(责任编辑 沈杰)