

卡尔曼滤波修正的风电场短期功率预测模型

赵攀¹, 戴义平¹, 夏俊荣¹, 盛迎新²

(1. 西安交通大学叶轮机研究所, 710049, 西安; 2. 中能电力科技开发有限公司, 100043, 北京)

摘要: 针对数值天气预报模型输出的气象参数存在系统误差而导致风电场功率预测精度受到制约的问题,提出了一种基于卡尔曼滤波修正的风电场短期功率预测模型. 使用卡尔曼滤波算法对数值天气预报输出的风速数据进行动态修正,并结合其他气象数据形成新的用于风电功率预测的修正气象数据集;根据原始气象数据和修正气象数据这2个训练集分别建立了风电场功率输出的原始神经网络、修正神经网络的预测模型. 经同一时间区间内的实测数据与模型分析数据的对比分析表明:通过卡尔曼滤波修正的风速数据能够很好地跟踪实际风速数据的变化趋势,平均误差与绝对平均误差比较小;所提模型能够显著降低预测结果的均方根误差,使其从未修正前的17.73%降低至11.32%,证明预测精度得到了明显提高.

关键词: 卡尔曼滤波;神经网络;功率预测;风力发电

中图分类号: TK89 **文献标志码:** A **文章编号:** 0253-987X(2011)05-0047-05

A Kalman Filter Based Correction Model for Short-Term Wind Power Prediction

ZHAO Pan¹, DAI Yiping¹, XIA Junrong¹, SHENG Yingxin²

(1. Institute of Turbomachinery, Xi'an Jiaotong University, Xi'an 710049, China; 2. Zhong Neng Power-Tech Development Co. Ltd., Beijing 100043, China)

Abstract: A Kalman filter based correction model for short-term wind power prediction was proposed to solve the problem of wind energy prediction accuracy constraint induced by the systematic errors in meteorological parameters from the numerical weather prediction (NWP) model. The wind speed data from NWP were corrected dynamically by using the Kalman filter algorithm and the improved NWP set used for wind power prediction was formed by combining the corrected wind speed data with other meteorological data. The original neural network prediction model and the corrected neural network prediction model were trained by using the raw NWP set and the improved NWP set, respectively. The analysis on the comparison between the simulation data and the measured data in a same time interval shows that, the corrected wind speed series by the Kalman filter are very close to observed wind speed; the mean error and the mean absolute error are smaller; the root mean square error decreases from 17.73% to 11.32%. It seems that the wind power prediction model proposed has a clearly higher accuracy.

Keywords: Kalman filter; neural network; power prediction; wind power generation

由于常规能源的日益枯竭及人们对改善生存环境的迫切需求,清洁、可再生的风能资源受到了世界各国的广泛关注. 然而,由于风电场功率输出受到自

然界风的制约,所以具有波动性和间歇性,当大规模的风电接入电力系统时,电能质量和电网的安全、稳定运行将受到严重的影响. 风电场功率的准确预测,

对于电力部门优化电力系统调度、减少旋转备用容量、降低电力系统运行成本具有重要的现实意义^[1]。

风电功率预测方法分为物理方法和统计方法。物理方法是根据数值天气预报(numerical weather prediction, NWP)结果获得风电场所在区域的气象数据,再根据风场周围的等高线、障碍物、粗糙度等物理信息计算得到各个风力机组轮毂高度处的风速、风向等信息,最后依据风力机的功率曲线来预测功率输出。统计方法则是在不考虑风速变化的情况下,利用历史数据建立气象数据与输出功率之间的非线性映射关系,然后利用 NWP 输出的气象数据来预测风电场功率输出^[2]。

在统计方法中,NWP 为预测模型提供了气象预报数据。事实上,NWP 模型在预测近地气象参数时会产生系统误差,这是由于 NWP 模型处理次网格现象的能力不足及物理参数初始化存在缺点所致^[3]。系统误差的存在对最终的风电功率预测精度将产生较大的影响,一般可采用统计方法来消除系统误差,此类方法主要由模式输出统计(model output statistics, MOS)法^[4]发展而来,但存在着一定的缺陷。卡尔曼滤波算法能够克服 MOS 方法的缺点,有效提高气象模式输出的精度。

本文以统计方法中常用的逆向传播(BP)神经网络为基础来建立预测模型,通过卡尔曼滤波技术消除 NWP 预报数据中存在的误差,即用风速中存在的系统误差来修正预测模型,从而达到提高风电功率预测精度的目的。

1 风电场短期功率预测模型

1.1 风力机功率

风力机组的风轮从风中吸收的能量^[5]

$$E = \frac{1}{2} C_P A \rho v^3 \quad (1)$$

式中: C_P 为风力机的功率系数; A 为风轮扫掠面积; ρ 为空气密度; v 为风速。由式(1)可知,风电功率输出主要取决于风速及空气密度。现有的风力发电机组均具有偏航系统,它能够根据风向的变化来动态调整风轮的方向,最大限度地捕捉风能,因此在建模时应主要考虑风速对输出功率的影响。

1.2 BP 神经网络预测模型

BP 神经网络是一种按误差逆向传播算法训练的多层前馈网络,能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,但需要大量的历史数据,其拓扑结构由输入层、隐含层和输出层组成。

本文用风速、风向正弦、风向余弦及空气密度等变量作为输入的训练向量,以实际功率输出作为目标向量,来建立一个 3 层的 BP 神经网络,其结构如图 1 所示,由此得到的气象数据与功率输出之间的非线性映射关系将作为未来的风电场实际功率预测的数学模型。




图1 BP神经网络风电功率预测模型

NWP 能够提供风场内测风塔位置的风速、风向、温度、压力、湿度等多个参数的预测数值,其中风速与风向可以直接作为模型的变量,空气密度则需要通过温度、压力及湿度等参数来求取。

1.3 空气密度的计算

空气中水蒸气占有一定比例时,可称之为湿空气。水蒸气的加入将使得空气密度有所降低^[6-7],该密度可由理想气体状态方程及道尔顿分压定律来计算,即

$$\rho_{h,air} = \frac{p_d}{R_d T} + \frac{p_v}{R_v T} \quad (2)$$

式中: $\rho_{h,air}$ 为湿空气密度; p_d 为干空气分压; R_d 为干空气气体常数; p_v 为水蒸气分压; R_v 为水蒸气气体常数; T 为热力学温度,是 NWP 提供的温度数据。水蒸气分压为

$$p_v = \phi p_{sat} \quad (3)$$

式中: ϕ 为相对湿度,由 NWP 模型提供; p_{sat} 为饱和水蒸气压力,计算式为

$$p_{sat} = 610.781 \times 10^{(7.5T-2048.625)/(T-35.85)} \quad (4)$$

干空气分压为

$$p_d = p - p_v \quad (5)$$

式中: p 为 NWP 提供的压力数据。

2 卡尔曼滤波算法

卡尔曼于 1960 年发表了关于递归解决线性离散数据滤波器的论著,自此卡尔曼滤波器得到了广泛的研究与应用。卡尔曼滤波算法是一种有效的以

最小均方误差来估计系统状态的计算方法,即通过将前一时刻预报误差反馈到原来的预报方程中,及时修正预报方程系数,以提高下一时刻的预报精度。

在卡尔曼滤波算法中,描述系统的数学模型^[8]是状态方程和量测方程,分别为

$$\mathbf{x}_t = \mathbf{F}_t \mathbf{x}_{t-1} + \mathbf{w}_t \quad (6)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{v}_t \quad (7)$$

式中: $\mathbf{x}_t$ 为未知过程在 t 时刻的状态向量; $\mathbf{y}_t$ 为 t 时刻的观测向量; $\mathbf{F}_t$ 和 $\mathbf{H}_t$ 分别为系统矩阵及观测矩阵,且必须在滤波器应用之前确定; $\mathbf{w}_t$ 和 $\mathbf{v}_t$ 分别为系统噪声和量测噪声,均假定为高斯白噪声且相互独立,与其相对应的协方差矩阵分别为 $\mathbf{W}_t$ 和 $\mathbf{V}_t$ 。

卡尔曼滤波算法提供了一种在观测向量更新为 $\mathbf{y}_t$ 基础上的递归来估计未知状态的算法。

假定现有系统状态为 $\mathbf{x}_t$,则在上一状态 $\mathbf{x}_{t-1}$ 及其协方差矩阵 $\mathbf{P}_{t-1}$ 的基础上,可以得到 t 时刻的预测状态及其协方差矩阵的预测方程,即

$$\mathbf{x}_{t/(t-1)} = \mathbf{F}_t \mathbf{x}_{t-1} \quad (8)$$

$$\mathbf{P}_{t/(t-1)} = \mathbf{F}_t \mathbf{P}_{t-1} \mathbf{F}_t^T + \mathbf{W}_t \quad (9)$$

当新的观测向量 $\mathbf{y}_t$ 更新后,就可以得到 t 时刻的状态向量 $\mathbf{x}_t$ 的最优估计值,即

$$\mathbf{x}_t = \mathbf{x}_{t/(t-1)} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t \mathbf{x}_{t/(t-1)}) \quad (10)$$

式中: $\mathbf{K}_t$ 称为卡尔曼增益,为卡尔曼滤波算法的重要参数,计算式为

$$\mathbf{K}_t = \mathbf{P}_{t/(t-1)} \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_{t/(t-1)} \mathbf{H}_t^T + \mathbf{V}_t)^{-1} \quad (11)$$

至此,可以更新未知状态 $\mathbf{x}_t$ 在 t 时刻的协方差矩阵,并作为算法递归运行的条件,即

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_{t/(t-1)} \quad (12)$$

式(10)~式(12)称为卡尔曼滤波器的更新方程。

3 卡尔曼滤波修正的预测模型

3.1 卡尔曼滤波修正的预测模型结构

在应用统计方法进行风电场功率预测时,NWP是进行预报的数据基础,因此NWP提供的数据精度将直接决定着最终功率预测结果的可靠性。一般情况下,NWP处理次网格现象的能力不足及物理参数初始化存在缺陷,从而导致了气象模式输出存在着一定程度的系统误差,此误差引入风电功率的统计模型之中必然影响最终的预测精度。

从MOS中演化而来的多种统计方法可以用来消除此类系统误差。然而,MOS方程的建立需要大量的历史资料,而积累历史资料是很困难的,动态更新方程的参数也是MOS所不能及的。卡尔曼滤波算法则不同,它不需要大量的历史资料,仅通过误差

反馈便可动态修正预测方程系数,这对于提高气象模式输出的精度具有重要的现实意义。

图2为采用卡尔曼滤波算法修正后的风电场功率预测模型。NWP提供的历史气象数据经卡尔曼滤波算法修正后形成BP神经网络的训练集合,从风力机组和监视控制系统(SCADA)采集得到的各个风机的功率序列将作为BP神经网络的目标集合,经充分训练之后得到气象数据与功率输出之间的非线性映射关系即为BP网络预测模型。同理,经卡尔曼滤波算法修正后的未来气象数据经过神经网络训练后得到最终的预测功率输出。




图2 卡尔曼滤波修正的风电功率预测模型

3.2 用于风电功率预测模型修正的

卡尔曼滤波算法

风力机功率输出主要取决于风速,因此本文采用一种非线性卡尔曼滤波器对NWP输出的风速时间序列进行了修正。将风速的预测误差作为NWP风速输出数据的函数,并对此误差进行估计。假定 $\mathbf{v}_t$ 是NWP模型在 t 时刻的风速输出, $\mathbf{y}_t$ 是 t 时刻的预测误差,根据Galanis等人的研究成果^[3,9], $\mathbf{y}_t$ 可用一个关于 $\mathbf{v}_t$ 的三阶多项式来描述,即

$$\mathbf{y}_t = \mathbf{x}_{0,t} + \mathbf{x}_{1,t} \mathbf{v}_t + \mathbf{x}_{2,t} \mathbf{v}_t^2 + \mathbf{x}_{3,t} \mathbf{v}_t^3 + \mathbf{q}_t \quad (13)$$

式中: $\mathbf{x}_{i,t}$ ($i=0,1,2,3$)是采用卡尔曼滤波器进行估计的系数; $\mathbf{q}_t$ 为上一步生成的高斯非线性系统误差。采用待估计的系数矩阵作为状态向量,即 $\mathbf{x}_t = [\mathbf{x}_{0,t} \quad \mathbf{x}_{1,t} \quad \mathbf{x}_{2,t} \quad \mathbf{x}_{3,t}]^T$,用 $\mathbf{y}_t$ 作为观测向量,观测矩阵 $\mathbf{H}_t = [1 \quad \mathbf{v}_t \quad \mathbf{v}_t^2 \quad \mathbf{v}_t^3]$,系统矩阵取单位矩阵,基于此,本文所研究的系统方程及量测方程为

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{w}_t \quad (14)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{q}_t \quad (15)$$

4 应用研究

以江苏某沿海风电场作为试验风场,对本文所述方法进行了验证。由于此风场所处地区没有限电规定,且多年统计数据显示出不存在大风切机等因素的影响,所以该风场作为测试风场较为理想。试验

风场内装有 33 台额定功率为 1.5 MW 的风力发电机组,均为变桨距型机组,其轮毂高度为 80 m. 风场建有测风塔,用来观测实际的风速、风向、温度、压力、湿度等气象数据.

4.1 训练用风速数据的卡尔曼滤波修正

对 2009 年风场测风塔位置的风速数据进行了卡尔曼滤波修正(该风速数据是通过 NWP 反推获得的),消除其中的系统误差,并以此作为 BP 网络的输入向量之一. 输出向量采用各单机 SCADA 提供的功率值. 基于此,建立了风场内各风机的 BP 网络预测模型,并进行了功率预测.

评价卡尔曼滤波对 NWP 输出风速修正结果的指标可用平均误差 e_M 和绝对平均误差 e_{MA} 来描述,即

$$e_M = \frac{1}{k} \sum_{i=1}^k (f(i) - o(i)) \tag{16}$$

$$e_{MA} = \frac{1}{k} \sum_{i=1}^k |f(i) - o(i)| \tag{17}$$

式中: $f(i)$ 为 NWP 模型输出的风速预测数据或者卡尔曼滤波修正后的风速数据; $o(i)$ 为测风塔观测的实际风速数据; k 为样本数量.


表 1 给出了试验风场 2009 年每个月 NWP 模式输出风速数据和相应的经卡尔曼滤波修正的数据与实测风速数据之间的 e_M 和 e_{MA} . 从表 1 可看出,卡尔曼滤波算法能够有效消除 NWP 模式输出风速中所存在的系统误差.

表 1 2009 年全年 NWP 预测及卡尔曼滤波修正结果


月份	NWP 预测结果		卡尔曼滤波修正结果	
	e_M	e_{MA}	$e_M/10^{-5}$	e_{MA}
1	0.895	1.787	-85.40	0.419
2	1.117	2.081	-41.21	0.534
3	0.890	1.832	5.64	0.513
4	1.140	2.134	0.54	0.498
5	0.550	1.522	-79.82	0.466
6	1.301	2.256	-0.88	0.641
7	1.343	2.184	40.72	0.585
8	1.582	2.166	-9.50	0.513
9	0.918	1.759	-78.42	0.445
10	0.966	1.664	26.33	0.398
11	0.493	1.831	6.38	0.489
12	1.134	1.782	-141.88	0.430
全年平均	1.027	1.913	-29.00	0.494

图 3 为 2009 年试验风场 2 个时段的风速在修正前后的对比曲线. 从图 3 中可以看出,NWP 模式

输出的原始预测风速变化较为平缓,不能实时跟踪实际风速的变化趋势,这是由于误差,特别是系统误差的存在而引起的. 然而,通过卡尔曼滤波算法修正后的风速数据能够跟踪实测风速的变化且误差较小,表明卡尔曼滤波算法能够有效地消除风速数据中的系统误差. 风速数据中的随机误差是无法消除的,这是滤波数据与实测数据间存在差异的缘故.



(a)6月某天中12:00~24:00的风速曲线



(b)10月某天中12:00~24:00的风速曲线

图 3 试验风场滤波修正前后风速曲线比较(2009 年)

4.2 修正模型的风电场短期功率预测

评价风电场短期功率预测准确度的指标主要是均方根误差,即

$$e_{RMS} = \left(\frac{1}{k} \sum_{i=1}^k \left(\frac{P_f(i) - P_o(i)}{P_{rated}} \right)^2 \right)^{1/2} \tag{18}$$

式中: $P_f(i)$ 为预测的风电场在 i 时刻的功率输出; $P_o(i)$ 为 i 时刻关口表功率数据,即实际风电场功率输出; P_{rated} 是风电场的总装机容量; k 为样本数量.

采用 4.1 节的 2009 年全年 NWP 反推数据及其相应的修正数据,分别建立了风电场短期功率预测的原始、修正 BP 网络预测模型. 本文将 2010 年 5 月作为测试时间段,分别将原始 NWP 数据及经卡尔曼滤波器修正的 NWP 数据作为已训练的对应 BP 神经网络预测模型的输入数据,对风电场短期功率输出进行了预测,以此评估卡尔曼滤波算法修正


后的风电场功率预测模型。

表 2 为分别采用原始 NWP 数据和经卡尔曼滤波修正后的 NWP 数据作为各自 BP 神经网络模型输入而得到的风电场功率预测输出的均方根误差。从表 2 可以看出,对于同一测试时间段,使用卡尔曼滤波修正的风电场短期功率预测模型的均方根误差比较小, e_{RMS} 从原始模型的 17.73%降至为修正模型的 11.32%,修正效果较为明显。


表 2 试验风电场 2010 年 5 月功率输出误差

数据	原始 NWP	修正 NWP
$e_{RMS}/\%$	17.73	11.32

从图 4 可以看出,经卡尔曼滤波修正后的风电功率预测模型不仅能够有效预测实际功率的变化趋势,而且其 e_{RMS} 比原始预测模型要小得多,表明卡尔曼滤波对预测模型的修正在提高风电功率预测精度上是有效的。



(a)5 月 10 日的功率曲线



(b)5 月 12 日的功率曲线

图 4 风电功率的 BP 神经网络预测结果

5 结 论

本文提出了一种利用卡尔曼滤波修正的风电场短期功率预测模型。通过采用卡尔曼滤波算法对 NWP 输出的风速数据进行动态修正,能够有效消除 NWP 预测风速数据中含有的系统误差。利用原始 NWP 数据及修正后的 NWP 数据分别建立了 BP

神经网络预测模型,并在同一测试时间段评估了卡尔曼滤波修正后的风电场功率预测模型的均方根误差,结果表明,经修正的预测模型能够有效预测实际功率的变化趋势,这对于准确预测风电场功率输出、优化电力系统调度、减小旋转备用容量、最大限度地让电网吸纳风电等,具有重要的现实意义。

NWP 输出的每个气象参数均存在系统误差,而本文仅对风场输出功率影响较大的风速数据进行了动态修正,对于影响风场功率输出的其他气象参数做全面的动态修正,将是今后进一步研究的内容。

参考文献:

[1] BERNHARD E, BRETT O, MARK L A, et al. Predicting the wind [J]. IEEE Power & Energy Magazine, 2007, 5(6):78-89.

[2] 谷兴凯, 范高峰, 王晓蓉, 等. 风电功率预测技术综述 [J]. 电网技术, 2007, 31(S2): 335-338.

GU Xingkai, FAN Gaofeng, WANG Xiaorong, et al. Summarization of wind power prediction technology [J]. Power System Technology, 2007, 31 (S2): 335-338.

[3] GALANIS G, LOUKA P, KATSAFADOS P, et al. Application of Kalman filter based on non-linear functions to numerical weather predictions [J]. Annales Geophysicae, 2006, 24(10):2451-2460.

[4] HARRY R G, DALE A L. The use of model output statistics (MOS) in objective weather forecasting [J]. Journal of Applied Meteorology, 1972, 11(8):1203-1211.

[5] BURTION T, SHARPE D, JENKINS N, et al. Wind energy handbook [M]. Chichester, England: John Wiley and Sons, 2001.

[6] 万新民. 图解法确定湿空气的密度[J]. 暖通空调, 1981(4):42.

WAN Xinmin. Graphical method to determine the density of wet air [J]. Heating Ventilating & Air Conditioning, 1981(4):42.

[7] Density of air [EB/OL]. [2010-10-11]. http://en.wikipedia.org/wiki/Air_density.

[8] MAYBECK P S. Stochastic models, estimation, and control [M]. New York, USA: Academic Press, 1979.

[9] LOUKA P, GALANIS G, SIEBERT N, et al. Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2008, 96(12): 2348-2362.

(编辑 苗凌)