

基于PCA-区间二型FLS的短期风电功率预测

李 军, 王星辉

(兰州交通大学自动化与电气工程学院, 兰州 730070)

摘 要: 针对短期风电功率预测, 提出一种基于主成分分析(PCA)和一型非单值区间二型模糊逻辑系统(FLS)相结合的方法。PCA方法可对预测模型的高维输入进行降维, 在此基础上考虑到风电功率数据的随机性特点, 建立一型非单值区间二型FLS预测模型, 应用反向传播(BP)算法设计预测模型前件和后件的参数, 进一步将SVD-QR算法应用到BP算法的结果中以确定约简后的模糊规则集合, 迭代至算法的执行结果满足预测精度的要求。将该文方法应用于不同地区的风电场风电功率预测实例中, 在同等条件下还分别与SVM(支持向量机)、一型非单值FLS、一型非单值区间二型FLS、PCA-单值区间二型FLS等其他预测方法进行比较。实验结果表明, 所提方法取得了较高的预测精度, 具有很好的预测效果, 同时, 模型的模糊规则数少, 较好地解决了模糊模型的规则“爆炸”问题, 这使得PCA-区间二型FLS方法在风电功率预测领域具有较好的应用潜力。

关键词: 风电功率; 预测; 主成分分析; 区间二型模糊逻辑系统; BP算法; SVD-QR算法

中图分类号: TM614

文献标识码: A

0 引 言

准确的风电功率预测是实现风能大规模开发利用的有效手段之一, 提高风电功率预测精度可保障风电场和电力系统安全稳定运行^[1]。精确并可靠的风电功率预测对于优化电网运行的成本和改进电力系统的可靠性极其重要, 其中, 超短期或短期风电功率预测^[2-6]能够规避由于风电机组装机容量的增大而带来的风电功率波动性的影响, 是能源领域非常重要的研究方向之一。

风电功率的预测方法通常可分为物理方法、统计方法、空间相关性预测方法、组合预测方法等。更先进的现代统计方法, 如神经网络^[4]、支持向量机(SVM)^[5]等, 能从过去的时间序列中描述出输入与输出的非线性联系, 已在风电功率超短期或短期预测中取得成功的应用。文献[6]给出一种将模糊逻辑与神经网络结合的方法, 成功应用于风电场短期风电功率区间预测中。

二型模糊逻辑系统(Type-2 fuzzy logic systems, 二型FLS)^[7]作为一种强有力的时间序列建模方法,

已被成功应用于混沌时间序列预测^[8]、风速预测^[9]、电力负荷预测^[10]、交通流预测^[11]中, 具有很好的应用潜力。考虑到风电功率数据的随机性与间歇性, 以及区间二型FLS方法^[12]在预测领域中的成功应用, 它理应是风电功率预测的有力工具之一。

将一型或二型FLS方法应用于时间序列预测中, 现有的文献通常设置较低的输入维数, 以避免规则“爆炸”问题, 这在一定程度上限制了应用范围。当输入的维数较高时, 常用的二型FLS会遇到规则“爆炸”问题。主成分分析(PCA)则是一种较好的特征提取预处理方法, 如文献[4]将PCA与人工神经网络方法结合, 成功应用于风电功率预测中。因此, 可考虑将PCA与一型非单值区间二型FLS相结合, 从而解决规则“爆炸”问题, 进一步再通过BP与SVD-QR组合算法调整模型的参数, 达到约简规则数目和提高运算效率的目的。

在现有的区间二型FLS方法成功应用于预测建模的基础上, 考虑风电功率数据的随机性及测量不确定性, 本文提出一种将PCA与一型非单值区间二型FLS相结合的预测方法, 在区间二型FLS方法

收稿日期: 2016-11-09

基金项目: 国家自然科学基金(51467008)

通信作者: 李 军 (1969—), 男, 博士、教授, 主要从事计算智能与系统预测、控制方面的研究。lijun691201@mail.lzjtu.cn

的设计过程中,基于BP算法进行参数的调整,并应用SVD-QR算法进行一定程度的规则约简,以进一步提高计算效率。将所提出方法应用于2个不同地区的风电功率预测实例中,在同等条件下,还与SVM、非单值一型FLS方法、一型非单值区间二型FLS方法、PCA-一型非单值FLS、PCA-单值区间二型FLS等其他方法进行比较,以验证本文方法的有效性。

1 PCA方法

PCA方法是一种较好的数据预处理方法,考虑对训练数据集进行K-L变换,提取特征向量,即主轴所形成的子集,将原始的训练数据或测试数据投影到由本特征向量子集所张成的空间上,完成降维过程。具体的PCA算法实现如下:

1)给定维输入的数据集:

$$\tilde{X} = \{\tilde{x}_1, \dots, \tilde{x}_N\} \in \mathbb{R}^{n \times N} \quad (1)$$

并计算给定数据集的均值,即:

$$m = \frac{1}{N} \sum_{i=1}^N \tilde{x}_i \quad (2)$$

2)计算数据集的协方差矩阵,即:

$$C = \frac{1}{N} \sum_{i=1}^N (\tilde{x}_i - m)(\tilde{x}_i - m)' \quad (3)$$

并计算协方差矩阵的特征值和特征向量:

$$[U, A] = \text{eig}(NC) \quad (4)$$

式中, $\text{eig}(\cdot)$ ——特征值分解函数。

3)将原始训练数据投影到由 p 个特征向量构成的子集所张成的空间中,即:

$$x_i = U' \tilde{x}_i, i = 1, \dots, N \quad (5)$$

PCA变换后:

$$X = \{x_1, \dots, x_N\} \in \mathbb{R}^{p \times N} \quad (6)$$

PCA是一种广泛采用的特征提取方法,它仅涉及在数据的原始空间上进行线性化处理的技术,可用于短期风电功率时间序列预测模型的输入预处理中。

2 一型非单值区间二型FLS

考虑输入测量的不确定性,一个输入被建模为一型模糊数的二型FLS称为一型非单值二型FLS。由于一般二型FLS对于每条点火规则而言,

使用乘积 t -范数时(t 为有界线性算子),计算交运算相当复杂,降型难度也很大,且目前对次隶属函数的选择没有合理的依据,故可采用区间二型FLS,交、并运算以及降型均较易执行,本节将针对一型非单值二型FLS进行分析。

2.1 区间二型模糊集合

记一个二型模糊集合为 \tilde{A} ,可定义二型模糊隶属函数为 $\mu_{\tilde{A}}(v, u)$,其中 $v \in V$, $u \in J_v \subseteq [0, 1]$, J_v 是 v 的主隶属,即有:

$$\tilde{A} = \int_{v \in V} \int_{u \in J_v} \mu_{\tilde{A}}(v, u)/(v, u), \quad J_v \subseteq [0, 1] \quad (7)$$

式中, $0 \leq \mu_{\tilde{A}}(v, u) \leq 1$, \int 表示取遍所有可能的 v 和 u ,对于取值离散的情形, \int 由 \sum 代替。

当所有的 $\mu_{\tilde{A}}(v, u)$ 取值均等于1时,那么 \tilde{A} 就是区间二型模糊集合,即:

$$\tilde{A} = \int_{v \in V} \int_{u \in J_v} 1/(v, u), \quad J_v \subseteq [0, 1] \quad (8)$$

次隶属函数是 $\mu_{\tilde{A}}(v, u)$ 的一个垂直切片,可用垂直切片的方式将 \tilde{A} 重新表示为:

$$\tilde{A} = \int_{v \in V} \mu_{\tilde{A}}(v)/v = \int_{v \in V} \left[\int_{u \in J_v} f_v(u)/u \right] / v, \quad J_v \subseteq [0, 1] \quad (9)$$

式中, $\mu_{\tilde{A}}(x)$ ——次隶属函数; $f_v(u)$ ——次隶属度,即次隶属函数的高度。

如果 J_v 和论域 V 的取值均为离散值, \tilde{A} 则表示为:

$$\begin{aligned} \tilde{A} &= \sum_{v \in V} \left[\sum_{u \in J_v} 1/u \right] / v = \sum_{i=1}^N \left[\sum_{u \in J_{v_i}} 1/u \right] / v_i \\ &= \left[\sum_{k=1}^{M_1} 1/u_{1k} \right] / v_1 + \dots + \left[\sum_{k=1}^{M_N} 1/u_{Nk} \right] / v_N \end{aligned} \quad (10)$$

区间二型模糊集合的主隶属 J_v 的不确定性,组成了一个有界区域,即为不确定性轨迹(footprint of uncertainty, FOU),即:

$$\text{FOU}(\tilde{A}) = \bigcup_{v \in V} J_v \quad (11)$$

FOU可通过上、下隶属函数来描述,即:

$$\bar{\mu}_{\tilde{A}}(v) = \text{FOU}(\tilde{A}), \quad \underline{\mu}_{\tilde{A}}(v) = \text{FOU}(\tilde{A}) \quad \forall v \in V \quad (12)$$

式中, FOU的上界是上隶属函数 $\bar{\mu}_{\tilde{A}}(v)$; FOU的下界是下隶属函数 $\underline{\mu}_{\tilde{A}}(v)$ 。

对于具有不确定均值的高斯型主隶属函数, $\bar{\mu}_i(v)$ 和 $\underline{\mu}_i(v)$ 分别为:

$$\bar{\mu}_i(v) = \begin{cases} N(m_i, \sigma; v), & v < m_i \\ 1, & m_i \leq v \leq m_2 \\ N(m_2, \sigma; v), & v > m_2 \end{cases} \quad (13)$$

$$\underline{\mu}_i(v) = \begin{cases} N(m_2, \sigma; v), & v \leq \frac{m_1 + m_2}{2} \\ N(m_1, \sigma; v), & v > \frac{m_1 + m_2}{2} \end{cases} \quad (14)$$

式中, $N(m_i, \sigma; v) \equiv \exp\left[-\frac{1}{2}\left(\frac{v - m_i}{\sigma}\right)^2\right], i = 1, 2$ 。

2.2 一型非单值区间二型 FLS

假设给定一系列 N 个输入-输出数据对, 即:

$$(x^{(i)}:y^{(i)}), \dots, (x^{(N)}:y^{(N)}) = \left\{x_1^{(i)}, \dots, x_p^{(i)}:y^{(i)}\right\}_{i=1}^N \quad (15)$$

式中, $x_1 \in X_1, \dots, x_p \in X_p$ 为输入, 输出 $y \in Y$ 。可设计具有 M 条规则的区间二型 FLS, 每条规则具有 p 个前件, 则第 l 条规则 R^l 有—— R^l : 如果 x_1 是 $\tilde{F}_1^l, \dots, x_p$ 是 \tilde{F}_p^l , 则 y 是 $\tilde{G}^l, l = 1, \dots, M$ 。其中 \tilde{F}_k^l 是与 $x^{(i)}$ 的元素相对应的二型模糊集。

\tilde{F}_k^l 由具有不确定均值的第 k 个先验高斯型主隶属函数所描述, 即:

$$\mu_{\tilde{F}_k^l}(x_k) = \exp\left[-\frac{1}{2}\left(\frac{x_k - m_{\tilde{F}_k^l}}{\sigma_{\tilde{F}_k^l}}\right)^2\right], m_{\tilde{F}_k^l} \in [m_{\tilde{F}_{k1}^l}, m_{\tilde{F}_{k2}^l}] \quad (16)$$

式中, $k = 1, \dots, p; l = 1, \dots, M$, 它的上、下隶属函数 $\bar{\mu}_{\tilde{F}_k^l}(x_k)$ 和 $\underline{\mu}_{\tilde{F}_k^l}(x_k)$ 分别由式(13)、式(14)计算。

另外, 对所有的点 $x_k \in X_k$ 被建模为一型高斯模糊数, 描述输入的隶属函数为:

$$\mu_{X_k}(x_k) = \exp\left[-\frac{1}{2}\left(\frac{x_k - x_k'}{\sigma_{X_k}}\right)^2\right] \quad (17)$$

式中, x_k' ——模糊集的中心; σ_{X_k} ——输入集的标准差。

一型非单值区间二型 FLS 的模糊推理结论由如下定理 1 给出。

定理 1^[12], 在以乘积 t -范数为交运算的区间一型非单值二型 FLS 中:

1) 输入 x' 和前件运算的结果 $F^l(x')$, 即点火集

$F^l(x')$, 是一个区间一型集, 即:

$$F^l(x') = [\underline{f}^l(x'), \bar{f}^l(x')] \equiv [\underline{f}^l, \bar{f}^l] \quad (18)$$

式中,

$$\underline{f}^l(x') = \sup_x \int_{x_1 \in X_1} \cdots \int_{x_p \in X_p} \left\{ \left[\mu_{X_1}(x_1) \times \underline{\mu}_{\tilde{F}_1^l}(x_1) \right] \times \cdots \times \left[\mu_{X_p}(x_p) \times \underline{\mu}_{\tilde{F}_p^l}(x_p) \right] \right\} / x \quad (19)$$

$$\bar{f}^l(x') = \sup_x \int_{x_1 \in X_1} \cdots \int_{x_p \in X_p} \left\{ \left[\mu_{X_1}(x_1) \times \bar{\mu}_{\tilde{F}_1^l}(x_1) \right] \times \cdots \times \left[\mu_{X_p}(x_p) \times \bar{\mu}_{\tilde{F}_p^l}(x_p) \right] \right\} / x \quad (20)$$

并且上确界在每个括号中的项都取得其上确界时取得。

2) 规则 R^l 的点火输出后件集, 是一个一型模糊集, 对于 $y \in Y$, 即有:

$$\mu_{R^l}(y) = \int_{b^l \in [\underline{f}^l \times \underline{\mu}_{\tilde{G}^l}(y)] \vee \cdots \vee [\bar{f}^l \times \bar{\mu}_{\tilde{G}^l}(y)]} 1/b^l \quad (21)$$

3) 假设 M 条规则中的 Q 条被点火, 则组合的一型输出集通过合并这些点火输出后件集得到, 即:

$$\mu_B(y) = \int_{b^l \in [\underline{f}^1 \times \underline{\mu}_{\tilde{G}^1}(y)] \vee \cdots \vee [\bar{f}^Q \times \bar{\mu}_{\tilde{G}^Q}(y)]} 1/b^l \quad (22)$$

式中, $\underline{\mu}_{\tilde{G}^l}(y)$ 、 $\bar{\mu}_{\tilde{G}^l}(y)$ —— $\mu_{\tilde{G}^l}(y)$ 的下、上隶属函数,

$\mu_B(y) = \bigcup_{l=1}^Q \mu_{R^l}(y), y \in Y$ 的计算结果可得出定理 1 中 3) 的结论。

由定理 1 可知, 输入为一型非单值时, 仅仅影响点火集, 无论采用哪种 t -范数, 输入与前件的运算结果都是一个点火区间。若记:

$$\mu_{Q_k^l}(x_k) \equiv \mu_{X_k}(x_k) \prod \mu_{\tilde{F}_k^l}(x_k) \quad (23)$$

则 $\mu_{Q_k^l}(x_k)$ 的下、上隶属函数为:

$$\underline{\mu}_{Q_k^l}(x_k) = \int_{x_k \in X_k} \left[\mu_{X_k}(x_k) \times \underline{\mu}_{\tilde{F}_k^l}(x_k) \right] \quad (24)$$

$$\bar{\mu}_{Q_k^l}(x_k) = \int_{x_k \in X_k} \left[\mu_{X_k}(x_k) \times \bar{\mu}_{\tilde{F}_k^l}(x_k) \right] \quad (25)$$

令 $\underline{x}_{k, \max}^l$ 和 $\bar{x}_{k, \max}^l$ 分别表示取到 x_k 的 $\sup \underline{\mu}_{Q_k^l}(x_k)$ 和 $\sup \bar{\mu}_{Q_k^l}(x_k)$ 值, 考虑式(24)、式(25), 则有:

$$\bar{f}_k^l(x_k') = \bar{\mu}_{Q_k^l}(\bar{x}_{k, \max}^l), \underline{f}_k^l(x_k') = \underline{\mu}_{Q_k^l}(\underline{x}_{k, \max}^l) \quad (26)$$

式中, $k=1, \dots, p$ 。因此, 式(19)、式(20)变形为:

$$\bar{f}^l(\mathbf{x}') = \mathbf{T}_{k=1}^p \bar{f}_k^l(\mathbf{x}_k') = \mathbf{T}_{k=1}^p \bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k, \max}^l) \quad (27)$$

$$\underline{f}^l(\mathbf{x}') = \mathbf{T}_{k=1}^p \underline{f}_k^l(\mathbf{x}_k') = \mathbf{T}_{k=1}^p \underline{\mu}_{\underline{Q}_k^l}(\underline{x}_{k, \max}^l) \quad (28)$$

式(27)、式(28)中, \mathbf{T} 是 t -范数的简写, 另外, 需要考虑的是, 应用乘积 t -范数, 在前件隶属函数为式(16), 且输入为式(17)的情形下, 式(27)、式(28)的具体计算结果有 5 种情形需要区分^[11], 由表 1 给出。

表 1 乘积 t -范数下的 $\underline{\mu}_{\underline{Q}_k^l}(\underline{x}_{k, \max}^l)$ 和 $\bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k, \max}^l)$

Table 1 $\underline{\mu}_{\underline{Q}_k^l}(\underline{x}_{k, \max}^l)$ and $\bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k, \max}^l)$ under product t -norm

状态	$\underline{\mu}_{\underline{Q}_k^l}(\underline{x}_{k, \max}^l)$	$\bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k, \max}^l)$
1	$\exp\left[-\frac{1}{2}(m_{k2}^l - x_k')^2 / (\sigma_{x_k}^2 - \sigma_k^2)\right]$	$\exp\left[-\frac{1}{2}(m_{k1}^l - x_k')^2 / (\sigma_{x_k}^2 + \sigma_k^2)\right]$
2	$\exp\left[-\frac{1}{2}(m_{k2}^l - x_k')^2 / (\sigma_{x_k}^2 - \sigma_k^2)\right]$	1
3	$\exp\left[-\frac{1}{2}(m_{k2}^l + m_{k1}^l - 2x_k')^2 / 4\sigma_{x_k}^2 - \frac{1}{2}(m_{k2}^l - m_{k1}^l)^2 / 4\sigma_{x_k}^2\right]$	1
4	$\exp\left[-\frac{1}{2}(m_{k1}^l - x_k')^2 / (\sigma_{x_k}^2 - \sigma_k^2)\right]$	1
5	$\exp\left[-\frac{1}{2}(m_{k1}^l - x_k')^2 / (\sigma_{x_k}^2 - \sigma_k^2)\right]$	$\exp\left[-\frac{1}{2}(m_{k2}^l - x_k')^2 / (\sigma_{x_k}^2 + \sigma_k^2)\right]$

注: 表 1 中 m_{k1}^l 、 m_{k2}^l 、 σ_{k1}^l 简记为 m_{k1}^l 、 m_{k2}^l 、 σ_k^l 。

经过模糊推理之后, 选择“集的中心法”降型, 即有:

$$Y_{\cos}(\mathbf{Y}^1, \dots, \mathbf{Y}^M, \mathbf{F}^1, \dots, \mathbf{F}^M) = [y_l, y_r] \\ = \int_{y_l} \dots \int_{y_r} \int_{f^1} \dots \int_{f^M} 1 / \frac{\sum_{i=1}^M f^i y^i}{\sum_{i=1}^M f^i} \quad (29)$$

式中, Y_{\cos} ——由 2 个端点 y_l 和 y_r 所决定的区间集; $f^i \in F^i = [\underline{f}^i, \bar{f}^i]$; $y^i \in Y^i = [y_l^i, y_r^i]$, $i=1, \dots, M$ 。注意, $[y_l^i, y_r^i]$ ($i=1, \dots, M$) 相当于二型区间后件集 $C_{\bar{Q}^i}$ 的重心, 必须在计算式(29)前先计算出来。

由式(29)知, y_l 、 y_r 可表示为模糊基函数 (FBF) 的扩张, 即:

$$y_l = \frac{\sum_{i=1}^M f_l^i y_l^i}{\sum_{i=1}^M f_l^i} = \sum_{i=1}^M y_l^i p_l^i \quad (30)$$

$$y_r = \frac{\sum_{i=1}^M \bar{f}_r^i y_r^i}{\sum_{i=1}^M \bar{f}_r^i} = \sum_{i=1}^M y_r^i p_r^i \quad (31)$$

式中, f_l^i 、 \bar{f}_r^i ——对 y_l 和 y_r 起贡献作用的点火强度隶属度; p_l^i 、 p_r^i ——不同的 FBF。

2.3 一型非单值区间二型 FLS 的设计

给定输入-输出数据 $(x_1^{(t)}, \dots, x_p^{(t)}; y^{(t)}), t=1, \dots, N$, 其中 $x_1^{(t)}, \dots, x_p^{(t)}$ 是经过 PCA 降维后的数据, 目标是: 设计一个一型非单值区间二型 FLS, 通过更新设计参数使得如式(18)误差函数在 E 个训练周期内达到最小。

$$e^{(t)} = \frac{1}{2} [f(x^{(t)}) - y^{(t)}]^2, t=1, \dots, N \quad (32)$$

误差反向传播 (BP) 训练算法具体实现步骤如下:

步骤 1: 初始化所有前件、后件以及输入隶属函数中的参数, 选取式(7)的高斯模糊数的均值以测量值为中心, 即对于 $t=1$, 令 $x_k' = x_k^{(t)}, k=1, \dots, M$, 并且初始化这些模糊数的标准差;

步骤 2: 置训练周期的计数 $count=1$;

步骤 3: 训练数据的计数 $t=1$;

步骤 4: 将 $p \times 1$ 维的输入 $\mathbf{x}^{(t)}$ 应用于一型非单值区间二型 FLS, 基于定理 1 的结果, 由式(27)、式(28)结合表 1 计算 \underline{f}^l 和 $\bar{f}^l (k=1, \dots, M)$;

步骤 5: 应用 K - M 迭代法^[13], 借助式(30)、式(31), 这会导致 M 条规被重新排序, 之后规则会重新标号 $1, \dots, M$, 这样可求取规则 L 和 R , y_l 和 y_r 可表示为:

$$y_l = \frac{\sum_{i=1}^M f_l^i y_l^i}{\sum_{i=1}^M f_l^i} = \frac{\sum_{i=1}^L \bar{f}_l^i y_l^i + \sum_{j=L+1}^M \underline{f}_l^j y_l^j}{\sum_{i=1}^L \bar{f}_l^i + \sum_{j=L+1}^M \underline{f}_l^j} \quad (33)$$

$$= y_l(\bar{f}_l^1, \dots, \bar{f}_l^L, \underline{f}_l^{L+1}, \dots, \underline{f}_l^M, y_l^1, \dots, y_l^M) \\ y_r = \frac{\sum_{i=1}^M \bar{f}_r^i y_r^i}{\sum_{i=1}^M \bar{f}_r^i} = \frac{\sum_{i=1}^R \underline{f}_r^i y_r^i + \sum_{j=R+1}^M \bar{f}_r^j y_r^j}{\sum_{i=1}^R \underline{f}_r^i + \sum_{j=R+1}^M \bar{f}_r^j} \quad (34)$$

$$= y_r(\underline{f}_r^1, \dots, \underline{f}_r^R, \bar{f}_r^{R+1}, \dots, \bar{f}_r^M, y_r^1, \dots, y_r^M)$$

步骤 6: 由式(33)、式(34), 一型非单值区间二型 FLS 的解模糊输出应为:

$$y(\mathbf{x}^{(i)}) = \frac{y_l(\mathbf{x}^{(i)}) + y_r(\mathbf{x}^{(i)})}{2} \quad (35)$$

步骤 7: 确定 y_l 和 y_r 对隶属函数的显式依赖, 可得:

$$\begin{aligned} y_l = & y_l \left[\bar{\mu}_{x_1}(x_1), \dots, \bar{\mu}_{x_p}(x_p), \underline{\mu}_{x_1}(x_1), \dots, \underline{\mu}_{x_p}(x_p), \right. \\ & \bar{\mu}_{\bar{F}_1^1}(x_1), \dots, \bar{\mu}_{\bar{F}_p^1}(x_p), \dots, \bar{\mu}_{\bar{F}_1^R}(x_1), \dots, \\ & \bar{\mu}_{\bar{F}_p^R}(x_p), \underline{\mu}_{\bar{F}_1^{R+1}}(x_1), \dots, \underline{\mu}_{\bar{F}_p^{R+1}}(x_p), \dots, \\ & \left. \underline{\mu}_{\bar{F}_1^M}(x_1), \dots, \underline{\mu}_{\bar{F}_p^M}(x_p), y_1^1, \dots, y_1^M \right] \end{aligned} \quad (36)$$

$$y_l = y_l \left[T_{k=1}^p \bar{\mu}_{\bar{Q}_k^1}(\bar{x}_{k,\max}^1), \dots, T_{k=1}^p \bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k,\max}^l), T_{k=1}^p \bar{\mu}_{\bar{Q}_k^{l+1}}(\bar{x}_{k,\max}^{l+1}), \dots, T_{k=1}^p \bar{\mu}_{\bar{Q}_k^M}(\bar{x}_{k,\max}^M), y_1^1, \dots, y_1^M \right] \quad (38)$$

$$y_r = y_r \left[T_{k=1}^p \underline{\mu}_{\bar{Q}_k^1}(\bar{x}_{k,\max}^1), \dots, T_{k=1}^p \underline{\mu}_{\bar{Q}_k^R}(\bar{x}_{k,\max}^R), T_{k=1}^p \underline{\mu}_{\bar{Q}_k^{R+1}}(\bar{x}_{k,\max}^{R+1}), \dots, T_{k=1}^p \underline{\mu}_{\bar{Q}_k^M}(\bar{x}_{k,\max}^M), y_r^1, \dots, y_r^M \right] \quad (39)$$

步骤 8: 测试 $\mathbf{x}^{(i)}$ 的各维分量来确定其 $\bar{\mu}_{\bar{F}_p^i}(x_i)$ 和 $\underline{\mu}_{\bar{F}_p^i}(x_i)$ 处于哪种状态, 结合表 1 的结果, 将 y_l 和 y_r 表示为显式函数;

步骤 9: 基于式 (32) 的误差函数, 结合表 1 的结果, 计算 $\bar{\mu}_{\bar{Q}_k^l}(\bar{x}_{k,\max}^l)$ 和 $\underline{\mu}_{\bar{Q}_k^l}(\bar{x}_{k,\max}^l)$ 关于特定设计参数的偏导数, 用最速下降算法调整步骤 8 中建立的活动状态的参数;

步骤 10: 设定 $t \equiv t+1$, 如果 $t = N+1$, 则转向步骤 11, 否则转向步骤 3;

步骤 11: 设定 $count = count + 1$, 如果 $count = E$, 训练结束, 否则转向步骤 2。

算法中需计算上、下隶属函数关于它们的参数的偏导数, 一旦确定前件隶属函数的活动状态, 通过计算偏导数和表 1 给出的运算结果, 在步骤 9 中使用最速下降算法调整参数。

例如:

$$\begin{aligned} m_{kl}^l(i+1) = & m_{kl}^l(i) - \alpha \frac{\partial e^{(i)}}{\partial m_{kl}^l} \bigg|_i = m_{kl}^l(i) - \\ & \alpha \left[\frac{\partial e^{(i)}}{\partial f(\mathbf{x}^{(i)})} \frac{\partial f(\mathbf{x}^{(i)})}{\partial y_l} \frac{\partial y_l}{\partial m_{kl}^l} + \frac{\partial e^{(i)}}{\partial f(\mathbf{x}^{(i)})} \frac{\partial f(\mathbf{x}^{(i)})}{\partial y_r} \frac{\partial y_r}{\partial m_{kl}^l} \right] \bigg|_i \end{aligned} \quad (40)$$

注意:

$$\begin{aligned} y_r = & y_r \left[\bar{\mu}_{x_1}(x_1), \dots, \bar{\mu}_{x_p}(x_p), \underline{\mu}_{x_1}(x_1), \dots, \underline{\mu}_{x_p}(x_p), \right. \\ & \underline{\mu}_{\bar{F}_1^1}(x_1), \dots, \underline{\mu}_{\bar{F}_p^1}(x_p), \dots, \underline{\mu}_{\bar{F}_1^R}(x_1), \dots, \\ & \underline{\mu}_{\bar{F}_p^R}(x_p), \bar{\mu}_{\bar{F}_1^{R+1}}(x_1), \dots, \bar{\mu}_{\bar{F}_p^{R+1}}(x_p), \dots, \\ & \left. \bar{\mu}_{\bar{F}_1^M}(x_1), \dots, \bar{\mu}_{\bar{F}_p^M}(x_p), y_r^1, \dots, y_r^M \right] \end{aligned} \quad (37)$$

由于输入是一型非单值, 有 $\bar{\mu}_{x_p}(x_p) = \underline{\mu}_{x_p}(x_p)$, 这样式 (36)、式 (37) 可被简化。结合式 (27)、式 (28), y_l 和 y_r 对隶属函数的显式依赖还可进一步表示为:

$$\frac{\partial y_l}{\partial m_{kl}^l} \bigg|_i = \left[\frac{\partial y_l}{\partial \bar{\mu}_{\bar{F}_k^l}(x_k^{(i)})} \frac{\partial \bar{\mu}_{\bar{F}_k^l}(x_k^{(i)})}{\partial m_{kl}^l} \right] \bigg|_i \quad (41)$$

$$\frac{\partial y_r}{\partial m_{kl}^l} \bigg|_i = \left[\frac{\partial y_r}{\partial \underline{\mu}_{\bar{F}_k^l}(x_k^{(i)})} \frac{\partial \underline{\mu}_{\bar{F}_k^l}(x_k^{(i)})}{\partial m_{kl}^l} \right] \bigg|_i \quad (42)$$

2.4 SVD-QR 算法

为减少区间二型 FLS 的规则数, 可通过 SVD-QR 算法对规则数目进行约简^[14]。由式 (30) 和式 (31) 可得:

$$\begin{aligned} y_l = & \sum_{i=1}^M y_l^i \left(\frac{\sum_{i=1}^L \bar{f}^i + \sum_{i=L+1}^M \underline{f}^i}{\sum_{i=1}^L \bar{f}^i + \sum_{i=L+1}^M \underline{f}^i} \right) \\ = & \sum_{i=1}^M y_l^i p_l^i(x) = y_l^T p_l(x) \end{aligned} \quad (43)$$

其中,

$$p_l^i(x) = \frac{h_l^i}{\sum_{i=1}^L \bar{f}^i + \sum_{j=L+1}^M \underline{f}^j}, h_l^i = \begin{cases} \bar{f}^i, & i=1, \dots, L(x) \\ \underline{f}^i, & i=L(x)+1, \dots, M \end{cases}$$

$L(x)$ 意味着 L 对于 x 的显式依赖以强调对于每个 x , L 可能改变。

同样, 式 (43) 可表示为:

$$y_r = \sum_{i=1}^M y_r^i \left(\frac{\sum_{i=1}^R \underline{f}^i + \sum_{i=R+1}^M \bar{f}^i}{\sum_{i=1}^L \underline{f}^i + \sum_{i=R+1}^M \bar{f}^i} \right) \quad (44)$$

$$= \sum_{i=1}^M y_r^i p_r^i(x) = y_r^T p_r(x)$$

式中, $p_i(x)$ 和 $p_r^i(x)$ 为 FBF, $p_r^i(x) =$

$$\frac{h_r^i}{\sum_{i=1}^R \bar{f}^i + \sum_{i=R+1}^M \underline{f}^i}, \quad h_r^i = \begin{cases} \bar{f}^i, & i=1, \dots, R(x) \\ \underline{f}^i, & i=R(x)+1, \dots, M \end{cases}$$

基于上述分析, SVD-QR 算法的实现如下:

步骤 1: 为 y_1 建立一个 FBF 矩阵, 记为:

$$\Phi_1 = \begin{bmatrix} p_1^1(x^{(1)}) & \cdots & p_1^M(x^{(1)}) \\ \vdots & \ddots & \vdots \\ p_1^1(x^{(N)}) & \cdots & p_1^M(x^{(N)}) \end{bmatrix} \quad (45)$$

对矩阵 Φ_1 进行 SVD 分解得:

$$A = LA_1M$$

式中, L 、 M ——正交矩阵; $A_1 = \text{diag}(\sigma_1, \dots, \sigma_l)$ ——

对角矩阵, 可令阈值为 χ_{eps} , 满足 $\frac{\sigma_{\min}(A)}{\sigma_{\max}(A)} \geq \chi_{\text{eps}}$ 即可。

步骤 2: 利用 QR 分解, 对 FBF 按秩排序, 形成新的 FBF 矩阵 Φ_1' , 其中:

$$\Phi_1' = \begin{bmatrix} p_1^1(x^{(1)}) & \cdots & p_1^{M'}(x^{(1)}) \\ \vdots & \ddots & \vdots \\ p_1^1(x^{(N)}) & \cdots & p_1^{M'}(x^{(N)}) \end{bmatrix} \quad (46)$$

式中, $M' < M$; \hat{r}_1 条规则的编号为 $J = \{j_1, \dots, j_{\hat{r}_1}\}$ 。

步骤 3: 为 y_r 也建立一个 FBF 矩阵, 记为 Φ_r' , 其中:

$$\Phi_r' = \begin{bmatrix} p_r^1(x^{(1)}) & \cdots & p_r^{M'}(x^{(1)}) \\ \vdots & \ddots & \vdots \\ p_r^1(x^{(N)}) & \cdots & p_r^{M'}(x^{(N)}) \end{bmatrix} \quad (47)$$

同步步骤 2, 约简得到 \hat{r}_r 条规则, 记为 $K = \{k_1, \dots, k_{\hat{r}_r}\}$ 。

步骤 4: 将步骤 2 和步骤 3 的结果合并, 即保留 $J \cup K$ 中的规则。因此, 约简后的规则总数满足:

$$\max(\hat{r}_1, \hat{r}_r) \leq \hat{r} \leq (\hat{r}_1 + \hat{r}_r) \quad (48)$$

最后, \hat{r} 条规则将重新编号。

具体应用时, 将 SVD-QR 算法组合 BP 算法, 进

行迭代设计, 以实现规则数的减少。即基于 BP 算法设计所有的前件和后件参数, 再进一步将 SVD-QR 算法应用到 BP 算法的结果中, 以确定减少后的 \hat{r} 条规则的集合。如果误差函数满足预测精度, 则停止。否则, 重复迭代直至满足精度为止。阈值选择影响约简规则的数目, 在算法的复杂性与模型的精度之间起到折衷。

3 短期风电功率预测实例

按照时间序列建模的方式, 仅考虑历史的风电功率值, 将 PCA 与一型非单值区间二型 FLS 方法结合, 应用于短期风电功率预测实例中。本节的实例中, 首先均需对数据进行零均值, 方差为 1 的归一化处理。一型非单值区间二型 FLS 模型的前件、输入隶属函数的选取分别按式(16)、式(17)所示。实验采用平均绝对百分比误差 (MAPE)、均方根误差 (RMSE) 作为评价指标^[4]。

为描述方便, 基于 BP 算法的 FLS 记为 FLS-1, BP 与 SVD-QR 组合迭代算法的 FLS 记为 FLS-2。一型非单值二型 FLS 方法简记为二型 NSFLS, 单值区间二型 FLS 方法简记为二型 SFLS, 非单值一型 FLS 方法简记为一型 NSFLS。

3.1 加拿大亚伯达省风电场的风电功率预测实例

采用加拿大亚伯达省的某风电场在 2010 年 12 月 1~28 日之间的风电功率数据^[15], 采样间隔为 10 min。将原始数据的连续 3 个样本进行平均, 作为一个数据点(时间间隔为 30 min), 可构建提前半小时的风电功率预测模型, 模型的输入为 5 维, 前 1000 组数据作为训练, 余下的 300 组数据作为测试。

使用单一的 FLS 方法时, 每个前件选取两个模糊集, 使用 32 条规则, 基于 PCA 结合二型 FLS 方法时, 选取主元 $p=3$, 每个前件取 3 个模糊集, 使用 27 条规则。应用 SVD-QR 算法, 进行适当的规则约简, 经过 6 个周期的训练, 规则减少的变化范围是 $\hat{r}=[18, 20]$ 。表 2 给出了基于 BP 算法实现时, 不同区间二型 FLS 方法和其他 FLS 方法的参数、参数的数目情况, 若基于 BP 与 SVD-QR 组合迭代算法实现, 则表 2 中的 M 变为 M' 。

表 2 基于 BP 算法的不同 FLS 的参数及参数的数量

Table 2 Parameters and numbers of parameters in different FLSs based on BP algorithm

FLS	输入集参数	前件参数	后件参数	参数数目
一型 NSFLS	σ_{x_i}	m_k^l, σ_k^l	\bar{y}^i	$2nM + M + n$
二型 SFLS	—	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_l^i, y_r^i	$3nM + M$
二型 NSFLS	σ_{x_i}	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_l^i, y_r^i	$3nM + M + n$
PCA-一型 NSFLS	σ_{x_i}	m_k^l, σ_k^l	\bar{y}^i	$2pM + M + p$
PCA-二型 SFLS	—	$m_{k1}^l, m_{k2}^l, m_{k3}^l, \sigma_k^l$	y_l^i, y_r^i	$4pM + M$
PCA-二型 NSFLS	σ_{x_i}	$m_{k1}^l, m_{k2}^l, m_{k3}^l, \sigma_k^l$	y_l^i, y_r^i	$4pM + M + p$

表 3 概括给出了所有设计参数的初值选择情况。注意到,前件隶属函数的初始值 m_x 和 σ_x 分别是前 1000 个训练样本数据的均值和标准差,且输入集的参数 σ_i 使用从一型 NSFLS 设计中获得的输入标准差 σ_{x_k} 的最终调整结果, y_l^i 和 y_r^i 为 $\bar{y}^i - \sigma_i$ 和 $\bar{y}^i + \sigma_i$

其中, \bar{y}^i 可从一型 NSFLS 方法的设计中获得。每个 FLS 均通过最速下降算法调参,学习参数 α 选取为 0.02,进行 6 个周期的训练和测试,每个周期之后基于测试集,计算 $RMSE$ 及 $MAPE$, SVM 方法的取值按照交叉验证选取参数 $c = 1024$ 和 $g = 0.0313$ 。

表 3 不同 FLS 中的参数初始值

Table 3 Initial values of parameters in different FLSs

FLS	输入	前件(均值、标准差)	后件
一型 NSFLS	$\sigma_{x_i} = \sigma_i$	$m_x - 1.5\sigma_x, m_x + 1.5\sigma_x, \sigma_k^l = 1.5\sigma_x$	$\bar{y}^i \in [-2, 2]$
二型 SFLS	—	$[m_x - 1.5\sigma_x - 0.25\sigma_i, m_x - 1.5\sigma_x + 0.25\sigma_i]$ $[m_x + 1.5\sigma_x - 0.25\sigma_i, m_x + 1.5\sigma_x + 0.25\sigma_i] \sigma_k^l = 1.5\sigma_x$	$\bar{y}^i - \sigma_i$ $\bar{y}^i + \sigma_i$
二型 NSFLS	$\sigma_{x_i} = \sigma_i$	$[m_x - 1.5\sigma_x - 0.25\sigma_i, m_x - 1.5\sigma_x + 0.25\sigma_i]$ $[m_x + 1.5\sigma_x - 0.25\sigma_i, m_x + 1.5\sigma_x + 0.25\sigma_i] \sigma_k^l = 1.5\sigma_x$	$\bar{y}^i - \sigma_i$ $\bar{y}^i + \sigma_i$
PCA-一型 NSFLS	$\sigma_{x_i} = \sigma_i$	$m_x - 1.5\sigma_x, m_x, m_x + 1.5\sigma_x$ $\sigma_k^l = 1.5\sigma_x$	$\bar{y}^i \in [-2, 2]$
PCA-二型 SFLS	—	$[m_x - 1.5\sigma_x - 0.25\sigma_i, m_x - 1.5\sigma_x + 0.25\sigma_i]$ $[m_x - 0.25\sigma_i, m_x + 0.25\sigma_i]$ $[m_x + 1.5\sigma_x - 0.25\sigma_i, m_x + 1.5\sigma_x + 0.25\sigma_i] \sigma_k^l = 1.5\sigma_x$	$\bar{y}^i - \sigma_i$ $\bar{y}^i + \sigma_i$
PCA-二型 NSFLS	$\sigma_{x_i} = \sigma_i$	$[m_x - 1.5\sigma_x - 0.25\sigma_i, m_x - 1.5\sigma_x + 0.25\sigma_i]$ $[m_x - 0.25\sigma_i, m_x + 0.25\sigma_i]$ $[m_x + 1.5\sigma_x - 0.25\sigma_i, m_x + 1.5\sigma_x + 0.25\sigma_i] \sigma_k^l = 1.5\sigma_x$	$\bar{y}^i - \sigma_i$ $\bar{y}^i + \sigma_i$

图 1、图 2 分别给出了基于 BP 算法、BP 与 SVD-QR 组合迭代算法的不同 FLS 方法经过 6 个训练周期的 RMSE 变化曲线。从图 1、图 2 可看出,在

2 种算法的实现下,PCA 结合二型 NSFLS 的方法在每个训练周期均取得了最低的 $RMSE$ 值,二型 NSFLS 方法的表现效果略优于一型 NSFLS 方法。



图1 $RMSE$ 随训练代数变化的曲线(BP算法)Fig. 1 Curve of $RMSE$ changes with epoch during training process (BP algorithm)图2 $RMSE$ 随训练代数变化的曲线
(BP与SVD-QR组合算法)Fig. 2 Curve of $RMSE$ changes with epoch during training process (combining BP and SVD-QR algorithm)

表4给出了在测试集上,不同FLS方法与SVM方法预测结果的数值对比,从表4进一步看出,不同FLS方法的预测精度均优于SVM方法,在BP或组合BP和SVD-QR的迭代算法实现下,PCA与二型NSFLS结合的方法均具有最小的 $RMSE$ 、 $MAPE$ 值,应用BP和SVD-QR组合的迭代算法进行规则约简后,不同FLS方法的 $RMSE$ 、 $MAPE$ 值略有上升,但规则约简提升了计算效率。

图3给出了待预测时段在2010年12月22日20:00~2010年12月28日04:00之间的风电功率实际值与PCA-二型NSFLS方法的预测结果比较,由图3看出,未进行规则约简的PCA-二型NSFLS方法的预测效果略优于规则约简后的该方法,且预测误差波动较小,体现出较好的预测效果。

表4 测试集上不同FLS方法的预测结果比较

Table 4 Comparison of forecasting results of different FLSs in test set

预测方法	$MAPE$	$RMSE$
SVM	14.5011	60.5307
一型 NSFLS-1	10.7860	46.4967
二型 SFLS-1	13.7855	55.5567
二型 NSFLS-1	9.9723	43.8815
PCA-一型 NSFLS-1	11.1304	48.0552
PCA-二型 SFLS-1	11.3369	52.5006
PCA-二型 NSFLS-1	8.8377	42.7365
一型 NSFLS-2	12.3947	55.0153
二型 SFLS-2	13.9916	57.1761
二型 NSFLS-2	11.8605	55.4267
PCA-一型 NSFLS-2	12.6966	55.2100
PCA-二型 SFLS-2	11.9615	55.0990
PCA-二型 NSFLS-2	11.2266	50.5407




图3 基于PCA-二型NSFLS方法的提前半小时预测的风电功率实际值与预测值曲线

Fig. 3 Comparison of forecasting result using PCA-Type 2 NSFLS method and actual value of wind power for half-hour ahead forecasting

3.2 新疆某地区天风二场风电预测实例

实验选取新疆某地区天风二场提供的实测数据集,原始数据的采样间隔为15 min。取2015年1月1~14日之间的共1300组数据,前1000组数据用于训练,剩余的300组数据用于测试,按照时间序列建模的方式构建基于PCA-二型NSFLS的预测模型,进行提前15 min短期预测。

预测模型的输入设定为 9 维,若每个前件选取最少的两个模糊集,规则数为 $2^9=512$ 条,这使得单一的 FLS 方法无法应用。对输入进行 PCA 变换,主元 $p=5$,每个输入选取 2 个模糊集,则使规则数减少到 32 条,同 2.1 节,进一步可应用 SVD-QR 算法,进行适当的规则约简,经过 6 个周期的训练,规则减少的变化范围是 $\hat{r}=[18,20]$ 。表 5 给出了基于 BP 算法实现时,不同区间二型 FLS 方法和其他 FLS 方法的参数、参数的数目情况,基于 BP 与 SVD-QR 组合迭代算法实现时,表中的 M 变为 M' 即可。

表 6 概括给出了所有设计参数的初值选择情况。注意到,前件隶属函数的初始值 m_x 和 σ_x 的确定, y_i^l 和 y_i^r 的确定同 2.1 节。每个 FLS 都通过最速下降算法调参, α 选取为 0.04,进行 6 个周期的训练和测试,SVM 方法的取值按照交叉验证选取参数 $c=34$ 和 $g=0.09$ 。

表 6 不同 FLS 中的参数初始值

Table 6 Initial values of the parameters in different FLSs

FLS	输入	前件(均值、标准差)	后件
PCA-一型 NSFLS	$\sigma_{x_i} = \sigma_i$	$m_x - 1.5\sigma_x, m_x + 1.5\sigma_x, \sigma_k^l = 4\sigma_x$	$\bar{y}^i \in [-2, 2]$
PCA-二型 SFLS	—	$[m_x - 1.5\sigma_x - 0.5\sigma_i, m_x - 1.5\sigma_x + 0.5\sigma_i]$ $[m_x + 1.5\sigma_x - 0.5\sigma_i, m_x + 1.5\sigma_x + 0.5\sigma_i] \sigma_k^l = 4\sigma_x$	$\bar{y}^i - \sigma_i, \bar{y}^i + \sigma_i$
PCA-二型 NSFLS	$\sigma_{x_i} = \sigma_i$	$[m_x - 1.5\sigma_x - 0.5\sigma_i, m_x - 1.5\sigma_x + 0.5\sigma_i]$ $[m_x + 1.5\sigma_x - 0.5\sigma_i, m_x + 1.5\sigma_x + 0.5\sigma_i] \sigma_k^l = 4\sigma_x$	$\bar{y}^i - \sigma_i, \bar{y}^i + \sigma_i$

图 4、图 5 给出了基于不同算法实现下的不同方法经过 6 个训练周期的 RMSE 变化曲线。从图 4、图 5 可看出,PCA 结合二型 NSFLS 的方法在每个训练周期均取得了最低的 RMSE 值,单一的二型 NSFLS 方法的表现优于一型 NSFLS 方法。

表 7 进一步给出了不同 FLS 方法及 SVM 方法的预测效果数值对比,从 MAPE 值的比较来看,不同 PCA-FLS 方法的 MAPE 值均低于 SVM 方法。从 RMSE 值的对比来看,不同 PCA-FLS 方法与 SVM 方法的预测精度保持在一个量级上,且 PCA 与二型 NSFLS 结合的方法,其 RMSE、MAPE 值均最小。进行规则约简后,不同 FLS 方法的 RMSE、MAPE 值则略有上升。虽然规则的约简在一定程度上略微降

表 5 不同 FLS 的参数及参数的数量

Table 5 Parameters and numbers of parameters in different FLSs

FLS	输入集参数	前件参数	后件参数	总参数
一型 NSFLS	σ_{x_i}	m_k^l, σ_k^l	\bar{y}^i	$2nM + M + n$
二型 SFLS	—	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_i^l, y_i^r	$3nM + M$
二型 NSFLS	—	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_i^l, y_i^r	$3nM + M + n$
PCA-一型 NSFLS	σ_{x_i}	m_k^l, σ_k^l	\bar{y}^i	$2pM + M + p$
PCA-二型 SFLS	—	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_i^l, y_i^r	$2pM + M$
PCA-二型 NSFLS	σ_{x_i}	$m_{k1}^l, m_{k2}^l, \sigma_k^l$	y_i^l, y_i^r	$3pM + M + p$

注:具有 M 条规则,每条规则有 p 个前件,即 $i=1, \dots, M, k=1, \dots, p$ 。

低了预测精度,但总体上可提升计算效率。




图 4 RMSE 随训练代数变化的曲线(BP 算法)

Fig. 4 Curve of RMSE changes with epoch during training process (BP algorithm)




图5 RMSE随训练代数变化的曲线(BP与SVD-QR组合算法)

Fig. 5 Curve of RMSE changes with epoch during training process(Combining BP and SVD-QR algorithm)

表7 PCA-二型NSFLS-2与其他方法的预测结果对比
Table 7 Comparison of forecasting results of PCA-Type 2 NSFLS-2 and other methods

预测方法	MAPE	RMSE
SVM	96.2931	8.1819
PCA-一型NSFLS-1	66.2176	8.2030
PCA-二型SFLS-1	73.3269	8.1689
PCA-二型NSFLS-1	61.7940	7.7316
PCA-一型NSFLS-2	72.7763	8.4459
PCA-二型SFLS-2	80.1683	9.2798
PCA-二型NSFLS-2	62.0101	8.1221

注:表中加粗的4个数值代表本文方法的预测精度较好。

图6给出了待预测时段在2015年1月11日12:00~2015年1月14日15:00之间的实际风电功




图6 基于PCA-二型NSFLS方法的提前15 min预测的风电功率实际值与预测值曲线

Fig. 6 Comparison of forecasting result using PCA-Type 2 NSFLS method and actual value of wind power for 15-minute ahead forecasting

率值与PCA结合二型NSFLS方法的预测结果比较,由图6看出,本文方法的预测误差波动较小,预测效果好,对于未进行规则约简的方法而言,其预测效果略优。

4 结 论

针对风电功率短期预测,提出一种基于PCA-二型NSFLS结合的预测方法。为检验所提出方法的预测效果,将其应用于不同地区的风电功率数据预测实例中。实验结果表明:

1) SVD-QR算法可在一定程度上约简规则,但无法根本上解决二型NSFLS方法所面临的规则“爆炸”问题。PCA算法可有效地对历史风电功率数据进行特征提取预处理,使得PCA-FLS方法能解决规则“爆炸”问题,拓宽预测的应用范围。

2)考虑到风电功率数据的随机性和间歇性,对输入测量的非单值模糊化处理所形成的一型非单值区间二型FLS更具优势。一型非单值二型FLS方法是将目前出现的所有不确定性因素考虑在内的FLS方法,这种不确定性包括了由于使用含噪声的数据进行训练而导致的规则的不确定性,以及在实际预测中用到的由于含噪声的测量而导致的输入测量的不确定性。通过BP与SVD-QR的组合迭代算法的实现进一步约简了规则数目,提高了计算效率。

3)以MAPE、RMSE等指标作为评价,PCA结合一型非单值区间二型FLS的方法在BP或BP与SVD-QR组合迭代算法的不同实现下,均取得了较好的预测效果,这显示了本文方法在风电功率预测方面的应用潜力。

[参考文献]

- [1] Jung Jaesung, Broadwater R P. Current status and future advances for wind speed and power forecasting[J]. Renewable and Sustainable Energy Reviews, 2014, 31: 762—777.
- [2] 薛禹胜, 郁琛, 赵俊华. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141—150.
- [2] Xue Yusheng, Yu Chen, Zhao Junhua, et al. A review on short-term and ultra-short-term wind power prediction [J]. Automation of Electric Power Systems, 2015, 39(6): 141—150.

- [3] 李 军, 李大超. 基于优化核极限学习机的风电功率时间序列预测[J]. 物理学报, 2016, 65(13): 130501-1—130501-10.
- [3] Li Jun, Li Dachao. Wind power time series prediction using optimized kernel extreme learning machine method [J]. Acta Physica Sinica, 2016, 65(13): 130501-1—130501-10.
- [4] 周松林, 茆美琴, 苏建徽. 基于主成分分析与人工神经网络的风电功率预测[J]. 电网技术, 2011, 35(9): 128—132.
- [4] Zhou Songlin, Mao Meiqin, Su Jianhui. Prediction of wind power based on principal component analysis and artificial neural network [J]. Power System Technology, 2011, 35(9): 128—132.
- [5] Hu Qinghua, Zhang Shiguang, Yu Mam, et al. Short-term wind speed or power forecasting with heteroscedastic support vector regression [J]. IEEE Transactions on Sustainable Energy, 2016, 7(1): 241—249.
- [6] Kavousi-Fard A, Khosravi A, Nahavandi S. A new fuzzy-based combined prediction interval for wind power forecasting [J]. IEEE Transactions on Power Systems, 2016, 31(1): 18—26.
- [7] Mendel J M. Type-2 fuzzy sets and systems: An overview [J]. IEEE Computational Intelligence Magazine, 2007, 2(2): 20—29.
- [8] Karnik N N, Mendel J M. Applications of type-2 fuzzy logic systems to forecasting of time-series [J]. Information Sciences, 1999, 120(1): 89—111.
- [9] 郑 高, 肖 建, 王 婧, 等. 基于区间二型模糊逻辑的短期风速预测研究[J]. 太阳能学报, 2011, 32(12): 1792—1797.
- [9] Zheng Gao, Xiao Jian, Wang Jing. Forecasting study of short-term wind speed based on interval type-2 fuzzy logic method [J]. Acta Energaie Solaris Sinica, 2011, 32(12): 1792—1797.
- [10] Khosravi A, Nahavandi S. Load forecasting using interval type-2 fuzzy logic systems: Optimal type reduction [J]. IEEE Transactions on Industrial Informatics, 2014, 10(2): 1055—1063.
- [11] Li L, Lin W H, Liu H. Type-2 fuzzy logic approach for short-term traffic forecasting [J]. IEE Proceedings Intelligent Transport Systems, 2006, 153(1): 33—40.
- [12] Mendel J M, John R I, Liu Feilong. Interval type-2 fuzzy logic systems made simple [J]. IEEE Transactions on Fuzzy Systems, 2006, 14(6): 808—821.
- [13] Chen Yang, Wang Dazhi, Tong Shaocheng. Forecasting studies by designing Mamdani interval type-2 fuzzy logic systems: With the combination of BP algorithms and KM algorithms [J]. Neurocomputing, 2016, 174(PB): 1133—1146.
- [14] Liang Q, Mendel J M. Designing interval type-2 fuzzy logic systems using an SVD-QR method: Rule reduction [J]. International Journal of Intelligent Systems, 2000, 15(10): 939—957.
- [15] Alberta electric system operator (AESO) wind power integration [EB/OL]. <http://www.aeso.ca/gridoperations/13902.html>, 2016-10-24.

SHORT-TERM WIND POWER FORECASTING BASED ON PCA-INTERVAL TYPE-2 FUZZY LOGIC SYSTEMS METHOD

Li Jun, Wang Xinghui

(School of Automation & Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Aiming at short-term wind power forecasting, a method composed of principal component analysis (PCA) and interval type-2 fuzzy logic systems (FLS) with non-singleton type-1 fuzzification is proposed. PCA method is used to reduce input's dimensions of the model. On the basis of this, taking into account the stochastic nature of wind power, a forecasting model using an interval type-2 FLS with non-singleton type-1 fuzzification is built. The back-propagation (BP) algorithm is used to update the parameters including input membership function, antecedent and consequent membership function respectively. Further more, SVD-QR algorithm is applied to the results of the BP algorithm to determine the reduced set of fuzzy rules, the process iterates until the forecast accuracy can meet design requirement. The employed method is then applied to real-world wind power forecasting instances in different areas. Under the same conditions, compared to the existing forecasting methods including type-1 FLS, interval type-2 FLS with singleton fuzzification, interval type-2 FLS with non-singleton type-1 fuzzification, PCA-interval type-2 FLS with singleton fuzzification, etc., experiment results confirm that the employed method can achieve better forecasting accuracy. Meanwhile, fuzzy rule explosion problems are solved effectively owing to the reduced fuzzy set by PCA transform, hence, it shows good application potential in the wind power forecasting field.

Keywords: wind power; forecasting; principal component analysis; interval type-2 fuzzy logic systems; back-propagation algorithm; SVD-QR algorithm