

# 多输出直觉模糊最小二乘支持向量回归算法

王定成<sup>1</sup> 陆一祎<sup>1</sup> 邹勇杰<sup>2</sup>

(南京信息工程大学计算机与软件学院 南京 210044)<sup>1</sup> (北京大学信息与工程科学部 北京 100871)<sup>2</sup>

**摘 要** 支持向量机回归是一种重要的机器学习算法,虽然已成功应用于多个领域,但针对复杂系统,单输出支持向量回归算法的训练时间过长并且缺乏实用性。多输出直觉模糊最小二乘支持向量回归(Intuitionistic Fuzzy Least Squares Support Vector Regression,IFLS-SVR)在多输出支持向量机的基础上引入了直觉模糊,解决了不确定多输出复杂系统问题,减少了训练时间。生活中复杂的多输出模型更为常见,文中在传统支持向量回归的基础上对其进行改进,提出多输出 IFLS-SVR 模型。多输出 IFLS-SVR 采用直觉模糊算法将实际数据转化为模糊数据,将二次规划优化问题转化为求解一系列线性方程组。与现有的模糊支持向量回归相比,多输出 IFLS-SVR 采用直觉模糊方法来计算隶属度函数,采用最小二乘法提高了算法的训练效率,减少了训练时间,获得了更精确的解。仿真结果表明,与其他方法相比,多输出 IFLS-SVR 取得了较好的效果。最后将多输出 IFLS-SVR 模型应用于复杂的风速风向预测,也取得了较好的效果。

**关键词** 最小二乘支持向量回归,直觉模糊,多输出,风气象预测,风速和风向的预测

**中图分类号** TP301 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.05.025

## Multi-output Intuitionistic Fuzzy Least Squares Support Vector Regression Algorithm

WANG Ding-cheng<sup>1</sup> LU Yi-yi<sup>1</sup> ZOU Yong-jie<sup>2</sup>

(School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China)<sup>1</sup>

(Division of Information & Engineering, Peking University, Beijing 100871, China)<sup>2</sup>

**Abstract** Support vector machine regression is an important machine learning algorithm, and it has been applied to some areas successfully. However, single-output support vector regression (SVR) has long training time and lacks practicality in some complex systems. The multi-output intuitionistic fuzzy least squares support vector regression (IFLS-SVR) introduces intuitionistic fuzzy on the basis of multi-output SVR to solve the problem of uncertain multi-output complex system and reduce the training time. Most applications in life are complex. Based on traditional support vector regression, this paper proposed a multi-output intuitionistic fuzzy least squares support vector regression model (IFLS-SVR). The multi-output IFLS-SVR transforms the actual data into fuzzy data by intuitionistic fuzzy algorithm, and transforms the quadratic programming optimization problem into the process of solving a series of linear equations. Compared with the existing fuzzy support vector regression, the multi-output IFLS-SVR uses the intuitionistic fuzzy method to calculate the membership function, and exploits least square method to improve the training efficiency, thus reducing the training time, obtaining more accurate solution. Compared with other methods, the multi-output IFLS-SVR achieves good results by simulation model. Finally, the multi-output IFLS-SVR model also performs excellently when it is applied to predict the wind speed and wind direction.

**Keywords** Least squares support vector regression, Intuitionistic fuzzy, Multi-output, Wind speed and wind direction prediction

## 1 前言

支持向量机作为基于统计学理论的一种机器学习算法,研究的是小样本数据,其原理是 VC 维理论和结构风险最小化准则,已经成功应用于模式识别领域<sup>[1]</sup>。支持向量机回归是支持向量机在连续函数域的形式,已经有许多成功的应用研究<sup>[2-3]</sup>。与传统回归方法相比,支持向量机回归将非线性问

题转化为线性问题,成功地解决了高维运算等问题<sup>[4-5]</sup>。然而,采用二次规划优化方法存在训练时间过长以及样本数据噪声干扰的问题。模糊支持向量机(Fuzzy Support Vector Mechine,FSVM)<sup>[6-8]</sup>将模糊集理论和支持向量机模型相结合,改进了传统的支持向量机,有效地解决了噪声与野点的问题。在 FSVM 中,如何选取有效的模糊隶属度函数是一个关键的问题。文献[9-12]对模糊支持向量机的隶属度值函数进

到稿日期:2018-04-28 返修日期:2018-07-10 本文受国家自然科学基金重点项目(61103141)资助。

王定成(1967-),男,博士,教授,硕士生导师,主要研究领域为人工智能等,E-mail:dcwang2005@126.com(通信作者);陆一祎(1993-),女,硕士生,主要研究领域为智能计算;邹勇杰(1993-),男,硕士生,主要研究领域为机器学习。

行了研究,给不同的样本赋予不同的权重。为了消除噪声和离群点对结果的影响,在构建目标函数时,对噪声点赋予较小的权重。文献[13]研究的隶属函数不仅考虑了样本与类中心之间的距离,还考虑了样本大小对模糊支持向量机的影响,提高了分类性能。通常情况下,将远离类中心的点称为离群点或噪声点,赋予小的隶属度,减少噪声点的影响。在计算隶属度时,通常都会尽量避免这些离群点对分类的影响,这是研究隶属度计算方法时所遵循的原理。

直觉模糊对模糊集理论进行了拓展,直觉模糊集能够更加客观地反映实际生活中的模糊现象,因而在很多领域都得到了广泛应用。与传统的模糊集相比,直觉模糊集多了非模糊隶属度,能更加精确地反映实际事物<sup>[14]</sup>。文献[13]将直觉模糊应用于支持向量机进行 C-means 聚类研究,与 K-means 和模糊 C-means 等算法相比,其具有更高的效率。文献[15-16]采用直觉模糊、最小二乘支持向量回归和 Sammon 映射改进了传统的模糊 C-回归算法,以解决聚类问题,取得了较好的效果。

本文研究直觉模糊最小二乘支持向量回归,将直觉模糊应用于支持向量回归模型以解决连续函数域的问题。最小二乘支持向量回归(Least Squares Support Vector Regression, LS-SVR)算法把不等式约束变为等式约束,从而大大方便了求解过程,因此本文采用直觉模糊最小二乘支持向量回归。同时,由于实际系统不仅存在噪声和不确定性,而且常常是多输出的系统,各输出之间存在耦合性,因此本文对多输出最小二乘支持向量回归进行研究。

## 2 最小二乘支持向量回归

$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}, x_i \in R^n, y_i \in R, x_i$  和  $y_i$  分别是输入向量和输出向量。SVR 将样本映射到高维特征空间,采用最小二乘法解决以下规划问题:

$$\min \frac{1}{2} \|w\|^2 + \frac{c}{2} \sum_{i=1}^n e_i^2 \quad (1)$$

s. t.  $y_i = W \cdot \varphi(x_i) + b + e_i$

其中,  $e_i$  是一个误差变量,  $w$  是权重,  $\varphi(x_i)$  是一个非线性映射函数,  $b$  为偏差量。引入拉格朗日乘子  $\alpha_i$ , 得到方程(2):

$$L(W, b, e, \alpha) = \frac{1}{2} \|W\|^2 + \frac{c}{2} \sum_{i=1}^n e_i^2 - \sum_{i=1}^n \alpha_i [W \cdot \varphi(x_i) + b + e_i - y_i] \quad (2)$$

根据 KKT 条件求解约束优化问题可得方程(3):

$$\begin{cases} \frac{\partial L}{\partial W} = 0 \rightarrow W = \sum_{i=1}^n \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow 0 = \sum_{i=1}^n \alpha_i \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = C e_i \\ \frac{\partial L}{\partial \alpha} = 0 \rightarrow 0 = W \cdot \varphi(x_i) + b + e_i - y_i \end{cases} \quad (3)$$

通过求解二次规划得出 LS-SVR 解。

## 3 直觉模糊多输出最小二乘支持向量回归算法

### 3.1 模糊支持向量机

在传统的支持向量机中,每一个训练样本点都是有效的

且能够对产生分类超平面起作用;但在实际的数据集中,训练样本有可能存在孤立点或噪声点,会对构造分类面产生一定的副作用,从而使得在分类器训练数据的过程中出现过学习现象,导致分类器泛化性能降低。在这种情况下,Wang 等人在支持向量机的基础上结合隶属度函数,提出了模糊支持向量机。为了减少这些离群值或噪声的影响,对训练集的每个样本点分配隶属度,并对每个样本的隶属度进行加权。如果某个数据点是噪声点,那么该点将会被分配一个较低的隶属度,因此这些离群点的总误差将会减小。

在文献[6]中,模糊支持向量机对每一个样本数据进行了隶属度划分,并将隶属度函数与原始支持向量机进行合理改造。采用模糊支持向量机进行分类时,首先对数据进行模糊化处理,用  $s_i$  表示样本的隶属度。原来的数据集变为模糊数据集训练集  $T = \{(x_1, y_1, s_1), (x_2, y_2, s_2), \dots, (x_i, y_i, s_i)\}$ , 其中  $x_i \in R^n, y_i \in \{-1, 1\}, 0 \leq s_i \leq 1$ , 则寻求最优分类超平面的优化问题即为:

$$\min \frac{1}{2} \|w\|^2 + \frac{c}{2} \sum_{i=1}^n s_i e_i^2 \quad (4)$$

s. t.  $y_i = W \cdot \varphi(x_i) + b + e_i$

其中,  $C$  为惩罚系数,  $e_i$  为松弛变量。采用拉格朗日乘子法对上述优化问题进行转化,即:

$$L(W, b, e, \alpha) = \frac{1}{2} \|W\|^2 + \frac{c}{2} \sum_{i=1}^n s_i e_i^2 - \sum_{i=1}^n \alpha_i [W \cdot \varphi(x_i) + b + e_i - y_i] \quad (5)$$

其中,  $\alpha_i \geq 0$  是拉格朗日法中对应的拉格朗日乘子。

根据 KKT 条件求解约束优化问题可得到方程:

$$\begin{cases} \frac{\partial L}{\partial W} = 0 \rightarrow W = \sum_{i=1}^n \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow 0 = \sum_{i=1}^n \alpha_i \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = C s_i e_i \\ \frac{\partial L}{\partial \alpha} = 0 \rightarrow 0 = W \cdot \varphi(x_i) + b + e_i - y_i \end{cases} \quad (6)$$

从而求得最优超平面分类函数为:

$$f(x) = \text{sgn}(W \cdot x + b) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i (x_i \cdot x) + b\right) \quad (7)$$

由模糊支持向量机的构造过程可知:若  $\alpha_i = 0$ , 则  $e_i = 0$ , 那么对应的  $x_i$  被正确分类;若  $\alpha_i > 0$ , 那么对应的  $x_i$  为支持向量。而式  $C s_i$  的值越小, 则样本点  $x$  被错分的代价和概率就会越小。因此,在构造模糊支持向量机的过程中,尽量使噪声或孤立点的值  $C s_i$  降到最小,即可减小噪声对分类面的影响。

### 3.2 隶属度

隶属度可直观地反映出样本点对分类面贡献的重要程度。然而,若要保证模糊支持向量机能有较好的分类效果和泛化能力,则要求隶属度值是准确的。但目前尚未有一个通用的解决方法来确定隶属度,因此在涉及到隶属度概念时通常需要根据实际情况来确定合适的隶属度函数。下面列出几种隶属度量方法。

#### 3.2.1 连续学习的隶属度

此类问题隶属度的构造是将时间作为自变量的函数,这

样隶属度函数表示为:

$$s_i = f(t_i), i = 1, 2, \dots, l \quad (8)$$

且满足:

$$s_1 = f(t_1) = \epsilon \quad (9)$$

$$s_2 = f(t_2) = 1 \quad (10)$$

其中,  $t_1 \leq t_2 \leq \dots \leq t_i \leq t_{i+1} \leq \dots \leq t_l$  为每个样本出现的时间,  $\epsilon$  为隶属度下界阈值。若隶属度与时间满足线性关系, 则:

$$s_i = f(t_i) = \frac{1-\epsilon}{t_i-t_1} t_i + \frac{t_1 \epsilon - t_1}{t_i-t_1} \quad (11)$$

若隶属度与时间满足二次函数关系, 则:

$$s_i = f(t_i) = (1-\epsilon) \left( \frac{t_i-t_1}{t_l-t_1} \right)^2 + \epsilon \quad (12)$$

支持向量机虽然能够有效解决分类问题, 但针对连续学习问题的应用还很少, 因此连续的隶属度函数缺乏实际应用。

### 3.2.2 基于 S 型的隶属度

在实际情况中, 采用基于距离的隶属度的线性函数所达到的效果可能并不理想, 因此又提出了一种由标准 S 型函数改造成的隶属度函数, 其表达式为:

$$\mu(d_i, a, b, c) = \begin{cases} 1, & d_i \leq a \\ 1 - 2 \left[ \frac{d_i - a}{c - a} \right]^2, & a < d_i \leq b \\ 2 \left[ \frac{d_i - a}{c - a} \right]^2, & b < d_i \leq c \\ 0, & d_i > c \end{cases} \quad (13)$$

其中,  $d_i$  是样本点到其所属类中心的距离,  $a, b$  是预先设定的参数,  $b = (a+c)/2$ , 当  $d_i = b$  时,  $\mu(d_i, a, b, c) = 0.5$ 。

### 3.2.3 基于 KNN 的隶属度

基于 KNN 的隶属度既考虑了样本点与类中心的关系, 又考虑了其于样本空间的参照关系。此方法具有较强的鲁棒性, 因此被广泛地应用于各个领域。

模糊算法通过隶属度函数将实际的精确数据变成模糊集, 计算过程如下。

1) 计算两类样本的类中心:

$$(\bar{x}_1, \bar{y}_1) = \frac{1}{n_1} \sum_{i=1}^{n_1} (x_{1i}, y_{1i}) \quad (14)$$

$$(\bar{x}_2, \bar{y}_2) = \frac{1}{n_2} \sum_{i=1}^{n_2} (x_{2i}, y_{2i}) \quad (15)$$

2) 计算两类样品的半径:

$$r_1 = \sqrt{(\max x_{1i} - \bar{x}_1)^2 + (\max y_{1i} - \bar{y}_1)^2}, i = 1, 2, \dots, n_1 \quad (16)$$

$$r_2 = \sqrt{(\max x_{2i} - \bar{x}_2)^2 + (\max y_{2i} - \bar{y}_2)^2}, i = 1, 2, \dots, n_2 \quad (17)$$

3) 计算每个样本的隶属度:

$$\mu_{1i} = 1 - \frac{\sqrt{(x_{1i} - \bar{x}_1)^2 + (y_{1i} - \bar{y}_1)^2}}{r_1} + \epsilon, i = 1, 2, \dots, n_1 \quad (18)$$

$$\mu_{2i} = 1 - \frac{\sqrt{(x_{2i} - \bar{x}_2)^2 + (y_{2i} - \bar{y}_2)^2}}{r_2} + \epsilon, i = 1, 2, \dots, n_2 \quad (19)$$

式(14)~式(19)中,  $x_{1i}$  和  $x_{2i}$  分别是两类样本的输入向

量,  $n_1$  和  $n_2$  分别为两类样本数,  $\bar{x}_1$  和  $\bar{x}_2$  分别是两类样本的中心,  $r_1$  和  $r_2$  分别是两类样本的半径,  $\mu_{1i}$  和  $\mu_{2i}$  分别是两类样本的隶属度,  $\epsilon$  则为一个非常小的正数, 用于避免出现隶属度为零的情况。

但是, 实际系统并不是完全的模糊集, Atanassov<sup>[14]</sup> 提出了直觉模糊集, 对传统模糊算法增加了非隶属度, 是更符合实际的算法。

假定  $\lambda$  是一个给定的域, 在  $\lambda$  上的直觉模糊集定义为:

$$A = \{ \langle x, \mu_A(x), \nu_A(x) \rangle | x \in \lambda \} \quad (20)$$

其中,  $\mu_A(x)$  和  $\nu_A(x)$  分别为  $x$  上的隶属函数和非隶属函数, 且:

$$\mu_A(x): \lambda \rightarrow [0, 1], x \in \lambda \rightarrow \mu_A(x) \in [0, 1] \quad (21)$$

$$\nu_A(x): \lambda \rightarrow [0, 1], x \in \lambda \rightarrow \nu_A(x) \in [0, 1] \quad (22)$$

$\mu_A(x)$  和  $\nu_A(x)$  满足所有  $x \in A$  和  $0 \leq \mu_A(x) + \nu_A(x) \leq 1$ 。

$\pi_A = 1 - (\mu_A(x) + \nu_A(x))$  是犹豫或不确定性作用的程度, 即直觉指数。

### 3.3 直觉模糊多输出支持向量机

根据直觉模糊的定义对训练样本进行模糊化, 然后对训练样本进行修改。直觉指数反映了样本的不确定性。

$$\begin{aligned} \min & \frac{1}{2} \sum_{j=1}^k \|W_j\|^2 + \frac{c}{2} \sum_{i=1}^l \sum_{j=1}^k (\mu_{i,j} - t \cdot \pi_{i,j}) e_{i,j}^2 + C_0 \sum_{i=1}^l \eta_i \\ \text{s. t. } & y_{i,j} = W_j \cdot \varphi(x_i) + b_j + e_{i,j} \end{aligned} \quad (23)$$

其中,  $\eta_i = \sum_{j=1}^k |e_{i,j}|, i = 1, 2, \dots, l$ 。参数  $t$  需要满足  $0 \leq \mu_{i,j} - t \cdot \pi_{i,j} \leq 1$ 。

引入拉格朗日乘子, 得到式(24):

$$\begin{aligned} L(W, b, e, \alpha) = \min & \frac{1}{2} \sum_{j=1}^k \|W_j\|^2 + \frac{c}{2} \sum_{i=1}^l \sum_{j=1}^k (\mu_{i,j} - t \cdot \pi_{i,j}) e_{i,j}^2 + C_0 \sum_{i=1}^l \eta_i + \sum_{i=1}^l \sum_{j=1}^k \alpha_{i,j} [W_j \cdot \varphi(x_i) + b_j + e_{i,j} - y_{i,j}] \end{aligned} \quad (24)$$

根据 KKT 条件

$$\begin{cases} \frac{\partial L}{\partial W_j} = 0 \rightarrow W_j = \alpha_{i,j} y_{i,j} \varphi(x_i) \\ \frac{\partial L}{\partial b_j} = 0 \rightarrow 0 = \sum_{i=1}^l \alpha_{i,j} y_{i,j} \\ \frac{\partial L}{\partial e_{i,j}} = 0 \rightarrow 0 = C(\mu_{i,j} - t \cdot \pi_{i,j}) e_{i,j} - \alpha_{i,j} \\ \frac{\partial L}{\partial \alpha_{i,j}} = 0 \rightarrow 0 = y_{i,j} [W_j^T \varphi(x_i) + b_j] - 1 + e_{i,j} \end{cases} \quad (25)$$

经同解变换消除了变量  $W$ 。

$$\begin{bmatrix} 0 & & & 1^T \\ 1 & K(x_i, x_j) + (\mu_{i,j} - t \cdot \pi_{i,j}) C^{-1} I \end{bmatrix} \begin{bmatrix} b_j \\ \alpha_j \end{bmatrix} = \begin{bmatrix} 0 \\ Y_j^* \end{bmatrix} \quad (26)$$

由式(26)可以得出对应多个输出 IFLS-SVR 的结果:

$$f^{(j)}(X) = \sum_{i=1}^l \alpha_{i,j} K(X, X_i) + b_j, j = 1, 2, \dots, k \quad (27)$$

## 4 实验结果与分析

### 4.1 核函数

在支持向量机方法中, 核函数及其参数的选择对于支持向量机的性能有着重要的影响。在处理线性可分的情况时,

计算比较简单;而在处理非线性的情况时,数据被映射到高维空间,且计算被表示为数据点的内积形式,以此将非线性问题转化为线性问题进行求解,此时就需要选取合适的核函数。核函数的原理是计算两个向量在隐式映射过后的空间中的内积函数:给定一个核函数  $K$ ,对于所有的  $x, z \in \lambda$ ,满足  $K(x, z) = \langle \phi(x), \phi(z) \rangle$ ,其中  $\phi(\cdot)$ 是从原始输入空间  $\lambda$  到内积空间的映射,  $K$  是半正定函数且满足 Mercer 条件:

$$\iint K(x, z)g(x)g(z)dx dz > 0, g \in L_2 \quad (28)$$

常用的核函数有多项式核、高斯核、线性核、Sigmoid 核,可以根据实际情况混合这些基本核得到新的核函数,如针对 MSVR 问题提出的基于信息几何方法的数据依赖核等。以下给出几种常用的核函数。

1) 线性核函数:

$$k(x, x_j) = x \cdot x_j \quad (29)$$

2) 多项式核函数:

$$k(x, x_j) = ((x \cdot x_j) + 1)^d \quad (30)$$

3) 高斯(RBF)核函数:

$$k(x, x_j) = \exp\left(-\frac{\|x - x_j\|^2}{\delta^2}\right) \quad (31)$$

高斯核函数的局部性较强,原理是将样本数据从一个低维空间映射到高维空间。高斯核函数相对于多项式核函数而言具有良好的局部性,全局性较差。而且,无论样本数量大小,高斯核函数都具有很好的性能,参数较少也是高斯核函数的一个优点。因此高斯核函数是应用最广泛的一种核函数。

4) Sigmoid 核函数:

$$k(x, x_j) = \tanh(\gamma \langle x, x_j \rangle + \theta) \quad (32)$$

Sigmoid 函数比较接近生物神经元, Sigmoid 核函数在训练的过程中,就相当于多层感知器神经网络,自动确定了隐含层节点的数目以及输入节点的权值。由于支持向量机具有较强的数学理论基础,保证了 Sigmoid 函数所得为全局最优值,提高了泛化性,也避免了过学习现象的出现。

因此,在选用核函数时,若了解空间内数据的具体分布,就可以选择符合数据分布的核函数;若对空间内数据的具体分布不了解,则使用交叉验证的方法,尝试不同的核函数,根据结果选取误差最小的核函数,也可以将多个核函数结合起来,形成混合核函数。

本文选择径向基函数作为核函数。参数和对模型的精度非常关键。本文采取控制变量法,使训练样本的数量与测试样本的数量相同,改变参数值,对比不同方法的结果得出结论。

#### 4.2 实验

为了验证 IFLS-SVR 的有效性,进行仿真实验。数据从 -3 到 3 以 0.01 为采样间隔,共取 300 个输入样本。前 200 个样本数据是训练样本,后 100 个数据是测试样本。

采用多输出 IFLS-SVR 算法(IFMLS)与多输出 LS-SVR 算法(MLS-SVR)以及多个单输出 SVR 算法(Single SVR)进行比较。通过计算迭代时间和比较根均方误差(Root Mean Square Error, RMSE)来分析各算法的性能。多输出 IFLS-SVM 的均方根误差(RMSE)如表 1 所列。根据表 1 的均方根误差可以看出,算法的泛化性能较好。由实验结果可知,多

输出 IFLS-SVM 算法与多输出 LS-SVR 算法相比具有较好的效果。

表 1 不同方法的实验结果

参数设置	算法	训练样本	测试样本	RMSE
$\gamma=0.5$ $\epsilon=0.1$	IFMLS-SVR	200	100	0.185
	MLS-SVR	200	100	0.193
	Single SVR	200	100	1.486
$\gamma=0.5$ $\epsilon=1$	IFMLS-SVR	200	100	1.132
	MLS-SVR	200	100	1.226
	Single SVR	200	100	3.550
$\gamma=0.1$ $\epsilon=1$	IFMLS-SVR	200	100	0.531
	MLS-SVR	200	100	0.647
	Single SVR	200	100	1.924
$\gamma=0.1$ $\epsilon=3$	IFMLS-SVR	200	100	3.225
	MLS-SVR	200	100	3.501
	Single SVR	200	100	7.287

图 1 显示了 3 种算法的迭代时间比较,可以看出多输出 IFLS-SVR 算法的迭代时间最短。表 2 列出了 3 种方法迭代时间与迭代速度的比较。




图 1 3 种方法的迭代时间比较

Fig. 1 Comparison of iteration time of three methods

表 2 3 种方法迭代时间与迭代速度的比较

Table 2 Comparison of iteration time and iteration speed of three methods

	Iteration time/s	Iteration speed/s <sup>-1</sup>
IFMLS-SVR	78.57	2.55
MLS-SVR	99.07	2.02
Single SVR	197.31	1.01

从表 2 中可以看出,多输出 IFLS-SVR 算法的迭代时间为 78.57 s,迭代时间最短;而单输出 SVR 的迭代时间接近 200 s,迭代速度最慢。因此,本文提出的多输出 IFLS-SVR 算法更为合理。

## 5 多输出 IFLS-SVR 风速风向预测模型

风速和风向是重要的气象因素,它们在风力发电和设施农业等领域有重要的影响,合理地预测风速有利于风能的利用。但由于大气动力学的复杂性,传统方法预测的精度受到限制。影响风速与风向的因素有很多,每个因素对风的影响程度都不同。有些因素对风变化的影响大,这就表明该因素的变化对风速以及风向的预测会产生较大的影响。因此,在预测风速以及风向时,需要计算这些因子与风速和风向的关联度。关联度较大的因子将对风速与风向的预测起到推动作用,而关联度较小的因子可能也会干扰到其他关联性强的因子,从而对结果产生影响。因此,我们需要对与风变化相关的因素进行分析,计算这些因子与风速、风向的关联程度,将

关联度高的因子加入到样本中,而关联度小的因子则可以忽略不计,以提高预测的准确性。

将 IFLS-SVR 应用于风力风向的预测可以解决系统的不确定性和噪声的影响。实验数据是于 2001 年 4 月从 NCEP/NCAR 新疆风电场实际风速序列中提取。选择数据点的间隔为 1h。将前 300 个值作为模型的训练样本,将后 50 个值作为预测样本。图 2 给出实验样本的风速和风向分布。




图 2 实验样本风的速度和方向

Fig. 2 Wind speed distribution and wind direction distribution of samples

在图 2 中,风速在 [4, 14] 的范围内变化,白天风速在 [5, 7] 左右基本稳定,夜晚风速值波动较大。四月新疆的昼夜温差比较大,但一般来说风速的波动值大于月底风速。以正北方向为 0°,顺时针方向为正。虽然风向的波动很大,但是基本上是以 200°为基准上下浮动。

基于多输出 IFLS-SVR 的风速及风向的预测结果如图 3 所示,从中可以看出预测值与实际值相差较小。




图 3 多输出 IFLS-SVR 的预测结果

Fig. 3 Prediction results of multi-output IFLS-SVR

图 4 采用多输出 IFLS-SVR、多输出 LS-SVR 以及单输出 SVR 3 种不同的方法来预测风速和风向的结果。

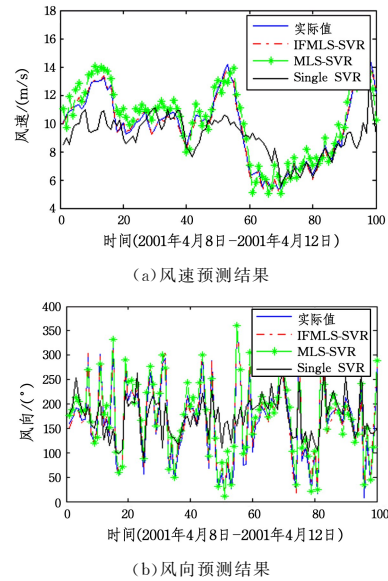


图 4 3 种方法的风速及风向预测结果

Fig. 4 Wind speed and wind direction prediction results of three methods

由图 4 可知,多输出 IFLS-SVR 的预测结果与实际值最接近;与多输出 IFLS-SVR 相比,MLS-SVR 的结果有一定的偏差;单输出 SVR 的预测误差最大。实验结果证明了多输出 IFLS-SVR 算法的优越性。

本文选择均方根误差 (RMSE) 和平均绝对百分比误差 (Mean Absolute Percent, Error, MAPE) 来评价实验结果:

$$MAPE = \frac{1}{M} \left[ \sum_{i=1}^M \frac{|y_i - f(x_i)|}{y_i} \right] \times 100\% \quad (33)$$

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M [y_i - f(x_i)]^2} \quad (34)$$

表 3 列出了 3 种方法的预测误差。

表 3 3 种方法的 MAPE 值和 RMSE 值  
Table 3 MAPE and RMSE of three methods

	MAPE		RMSE/	
	速度/(m/s)	方向/(°)	速度/(m/s)	方向/(°)
IFMLS-SVR	15.09	17.51	0.3393	9.712
MLS-SVR	21.93	25.67	0.7375	17.2493
Single SVR	35.39	31.13	1.6799	39.7379

从表 3 可以看出,多输出直觉模糊最小二乘支持向量回归的误差最小,风速的平均绝对百分比误差接近 15%,风向的平均绝对百分比误差接近 17%,其风速以及风向的平均绝对百分比误差均超过了 20%,而 LS-SVR 的风速以及风向平均绝对百分比误差均超过了 30%。因此,误差为 15.09% 和 17.51% 的 IFMLS-SVR 算法的表现更好。与 LS-SVR 相比,IFMLS-SVR 有助于克服传统 SVR 对噪声和孤立点的影响,且具有更强的泛化性。实验结果证实了直觉模糊多输出回归模型的可行性。

**结束语** IFLS-SVR 采用多输出回归来解决复杂系统问题,与现有模糊支持向量回归相比,该算法更接近实际系统,因此,既能解决复杂系统的不确定问题,又能提高拟合的精

度。误差分析表明,根据平均绝对误差百分比和均方根误差,多输出 IFLS-SVR 模型的预测效果相对较好。

### 参考文献

- [1] SUYKENS J A K, GESTEL T V, BRABANTER J D, et al. Least Squares Support Vector Machines[J]. *International Journal of Circuit Theory & Applications*, 2015, 27(6): 605-615.
- [2] ZHOU G H, CHAO H Q, SHEN Y P. Secure migration support vector machine[J]. *Computer Science*, 2017, 44(S2): 381-384. (in Chinese)  
周国华,巢海鲸,申燕萍.安全迁移支持向量机[J].*计算机科学*, 2017, 44(S2): 381-384.
- [3] WANG D C, CAO Z L, CHEN B J, et al. Prediction of daily temperature multi time series based on local support vector regression[J]. *Journal of System Simulation*, 2016, 28(3): 654-660. (in Chinese)  
王定成,曹智丽,陈北京,等.气温多元时间序列局部支持向量回归预测[J].*系统仿真学报*, 2016, 28(3): 654-660.
- [4] PENG J, ZHOU Y, CHEN C L P. Region-Kernel-Based Support Vector Machines for Hyperspectral Image Classification[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015, 53(9): 4810-4824.
- [5] LIANG J J, WU D. Clustering piecewise double support vector domain classifier[J]. *Control and Decision*, 2015, 30(7): 1298-1302. (in Chinese)  
梁锦锦,吴德.聚类分片双支持向量域分类器[J].*控制与决策*, 2015, 30(7): 1298-1302.
- [6] LIN C F, WANG S D. Fuzzy support vector machines[J]. *IEEE Transaction on Neural Networks*, 2002, 13(2): 464-471.
- [7] LIU S Y, WU D. Fuzzy clustering smooth support vector machine[J]. *Control and Decision*, 2017, 32(3): 547-551. (in Chinese)  
刘三阳,吴德.模糊聚类光滑支持向量机[J].*控制与决策*, 2017, 32(3): 547-551.
- [8] SHANG Z G, YAN H S. Product design time prediction based on fuzzy support vector machine. *Control and Decision*, 2012, 27(4): 531-524. (in Chinese)  
商志根,严洪森.基于模糊支持向量机的产品设计时间预测[J].*控制与决策*, 2012, 27(4): 531-524.
- [9] DING S F, SUN J G. Research on Fuzzy dual support vector machine based on mixed fuzzy membership degree[J]. *Application Research of Computers*, 2013, 30(2): 432-435. (in Chinese)  
丁胜峰,孙劲光.基于混合模糊隶属度的模糊双支持向量机研究[J].*计算机应用研究*, 2013, 30(2): 432-435.
- [10] HA M, WANG C, CHEN J. The support vector machine based on intuitionistic fuzzy number and kernel function[J]. *Soft Computing*, 2013, 17(4): 635-641.
- [11] ZHAO K L, LI L, DENG N. A new method of constructing fuzzy membership degree [J]. *Computer Technology and Development*, 2012, 22(8): 75-77. (in Chinese)  
赵克楠,李雷,邓楠.一种构造模糊隶属度的新方法[J].*计算机技术与发展*, 2012, 22(8): 75-77.
- [12] ELIZABETH S, SUJATHA L. Project Scheduling Method Using Triangular Intuitionistic Fuzzy Numbers and Triangular Fuzzy Numbers[J]. *Applied Mathematical Sciences*, 2015, 9(4): 185-198.
- [13] LEI H U, NIU Q, CHEN Y. Enhanced clustering algorithm based on fuzzy C-means and support vector machine[J]. *Journal of Computer Applications*, 2013, 33(4): 991-993.
- [14] ATANASSOV K T. Intuitionistic Fuzzy Sets[J]. *Fuzzy Sets and Systems*, 1986, 35(1): 1-137.
- [15] LIN K P, CHANG H F, CHEN T L. Intuitionistic fuzzy C-regression by using least squares support vector regression[J]. *Expert Systems with Applications an International Journal*, 2016, 64(C): 296-304.
- [16] WAN Z, LIANG W D, LU Z J. Study on the Membership Interval Distribution Function for Fuzzy Sets [J]. *Journal of Chongqing University of Technology (Natural Science)*, 2011, 25(1): 107-112. (in Chinses)  
万中,梁文冬,卢宗娟.模糊数的隶属度区间分布函数研究[J].*重庆理工大学学报(自然科学版)*, 2011, 25(1): 107-112.