

## 无缝钢管斜轧穿孔管形多目标预测

加世滢<sup>1</sup>, 王清华<sup>1</sup>, 王贞艳<sup>1</sup>, 胡建华<sup>2</sup>, 双远华<sup>2</sup>, 周新亮<sup>3</sup>

(1. 太原科技大学 电子信息工程学院, 山西 太原 030024; 2. 太原科技大学 材料科学与工程学院, 山西 太原 030024;  
3. 太原重工股份有限公司 技术中心, 山西 太原 030024)

**摘要:** 针对无缝钢管斜轧穿孔生产中工艺参数对毛管尺寸精度的影响问题, 考虑生产工艺以及生产需求优化等因素, 建立了基于最小二乘支持向量回归的多目标预测模型。通过灰色关联分析法对影响因素进行分析筛选, 以前伸量、轧辊间距、导板间距、顶头直径、坯料直径 5 个工艺参数作为预测模型的输入, 以毛管壁厚和外径 2 个管形参数作为预测模型的输出; 考虑到数据样本小且输入和输出参数之间的交叉相关性问题, 构建了多输入多输出最小二乘支持向量回归模型对毛管管形进行预测。将实际采集的数据作为训练样本, 通过仿真实验证明了模型的有效性, 研究结果可为无缝钢管斜轧穿孔生产过程中所需的工艺参数调整与优化提供参考。

**关键词:** 无缝钢管; 斜轧穿孔; 最小二乘支持向量回归; 管形预测; 工艺参数

**DOI:** 10.13330/j.issn.1000-3940.2022.10.023

**中图分类号:** TP183

**文献标志码:** A

**文章编号:** 1000-3940 (2022) 10-0169-07

## Multi-objective prediction on cross-rolling and perforated pipe shape for seamless steel pipe

Jia Shiyong<sup>1</sup>, Wang Qinghua<sup>1</sup>, Wang Zhenyan<sup>1</sup>, Hu Jianhua<sup>2</sup>, Shuang Yuanhua<sup>2</sup>, Zhou Xinliang<sup>3</sup>

(1. School of Electronic and Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;  
2. School of Materials Science and Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;  
3. Technical Center of Taiyuan Heavy Industry Co., Ltd., Taiyuan 030024, China)

**Abstract:** In view of the influence of process parameters on the dimensional accuracy of capillarity in the cross-rolling and preforming production of seamless steel pipe, a multi-objective prediction model based on least squares support vector machine was established considering the factors of production process and production demand optimization, and the influencing factors were analyzed and screened by the grey correlation analysis method. Then, taking five process parameters of forward extension amount, roll spacing, guide plate spacing, plug diameter and blank diameter as inputs of the prediction model and the two pipe shape parameters of capillary wall thickness and outer diameter as outputs of the prediction model, considering the small data sample and the cross correlation between input and output parameters, a multi-input and multi-output least squares support vector regression model was constructed to predict the capillary shape. Furthermore, taking the actual data as training samples, the effectiveness of the model was proved by simulation experiments. And the research results provide reference for the adjustment and optimization of the process parameters required in the cross-rolling and preforming production process of seamless steel pipe.

**Key words:** seamless steel pipe; cross-rolling and preforming; least squares support vector regression; pipe shape prediction; process parameters

无缝钢管是一种重要的经济钢材, 是国防和国民经济建设的重要原材料之一, 被广泛应用于化工、核能、航空、航天、地质、石油、船舶、汽车、机械等

领域。无缝钢管的种类繁多, 生产过程中工艺复杂、批量小, 且需要根据规格多样的产品设置不同的设备<sup>[1]</sup>, 因此, 生产过程中需要设置合理的工艺参数。

钢管生产主要由穿孔、连轧、张减 3 个变形工序组成, 穿孔作为热轧无缝钢管的第 1 道工序, 其过程分为: (1) 管坯被轧辊咬入未接触顶头前; (2) 管坯接触顶头, 开始穿孔, 最终脱离轧辊形成毛管<sup>[2]</sup>。穿孔过程中涉及到的工艺参数较多, 对钢管的成品质量有很大影响, 不合理的参数设置在穿

收稿日期: 2021-10-22; 修订日期: 2022-01-20

基金项目: 山西省科技重大专项 (20191102009)

作者简介: 加世滢 (1996-), 女, 硕士研究生

E-mail: 13103421357@163.com

通信作者: 王清华 (1980-), 女, 博士, 讲师

E-mail: 2002043@tyust.edu.cn

孔过程中会导致出现偏心和失圆的情况,这一缺陷会造成市场竞争力下降和资源浪费等问题。

无缝钢管生产过程中的工艺参数较多、生产过程复杂且各工艺参数之间相互关联,工艺参数与成品质量之间的非线性关系较强,因而很难通过经典的建模方法得到精确的数学模型,以控制生产过程中的工艺参数<sup>[3]</sup>。而传统的工艺参数设置通常依赖传统经验、类比或基于实验的枚举法,导致参数设定的效率低、周期长、盲目性高<sup>[4]</sup>。因此,利用实际生产数据进行建模成为必然途径。近年来,神经网络凭借其优势在轧制力和板带厚度预测方面获得了较大的发展。文献[5]提出应用长时间学习和短时学习的神经网络在线学习功能建立模型,并对热轧过程的轧制力进行预测。文献[6]采用 Bayesian 神经网络预测板带厚度。文献[7]采用径向基神经网络对轧制厚度进行预测。但是,人工神经网络需要大量数据,采用经验风险最小化的训练方法,会使网络泛化能力受到限制<sup>[8]</sup>。

与神经网络相比,支持向量机对数据的依赖性更小,具有很强的泛化能力和非线性映射能力<sup>[9]</sup>。最小二乘支持向量机通过二次规划方法将不等式约束转化为等式约束,采用损失函数的误差平方和作为训练样本集的经验损失,将二次规划问题转化为线性方程组,是一种改进的支持向量机算法<sup>[10-11]</sup>。现实工程领域中广泛存在多输出回归问题,可以将其转化为多个独立的单输出回归问题来解决,但忽略了多个输出之间的耦合性,会影响预测精度<sup>[12]</sup>。针对上述问题,文献[13]通过从多元输入空间到多元输出空间的学习,提出了多输出最小二乘回归算法,并验证了该方法的有效性。多输入多输出支持向量回归(Multi-input Multi-output Support Vector Regression, MSVR)方法在考虑输出变量之间误差的前提下对支持向量回归的损失函数进行修改,并同时考虑输出变量之间的相关性<sup>[14]</sup>。

学者们在热轧工艺方面做了大量研究,但多集中于板带材轧制力和板型的预测研究,针对管材的质量参数建模的研究较少。所以,本文采用多输入多输出最小二乘支持向量回归(Multi-input Multi-output Least-Squares Support Vector Regression, MLSSVR)方法对无缝钢管斜轧穿孔管形进行预测,它包含两个输出目标,在对管形进行预测时考虑输出变量之间的关系,这是算法设计时重点考虑的因素,以实现建模结果的高效率、高精度、高泛化能力。

## 1 无缝钢管穿孔生产影响因素分析

在无缝钢管生产过程中,坯料直径、坯料长度是坯料本身的指标,轧辊间距、顶头直径主要影响毛管的壁厚,而导板间距在较大程度上决定着毛管的外径,送进角、出钢温度、轧辊转速、穿孔速度与毛管质量也有关系。坯料穿孔后的壁厚和外径决定了毛管的几何尺寸,穿孔过程中轧件的变形量较大,利用数学模型进行分析时,需考虑穿孔机自身刚度和弹跳值对毛管尺寸精度的影响。此外,在生产过程中影响产品质量的因素是多方面的,主要包括材料、设备、人员等,这些影响因素之间有内在相关性,其耦合关系示意图如图1所示。只有保证工艺参数设置合理、设备运行可靠、工艺经济可行、生产环境良好,才能促进生产的合理高效运行。

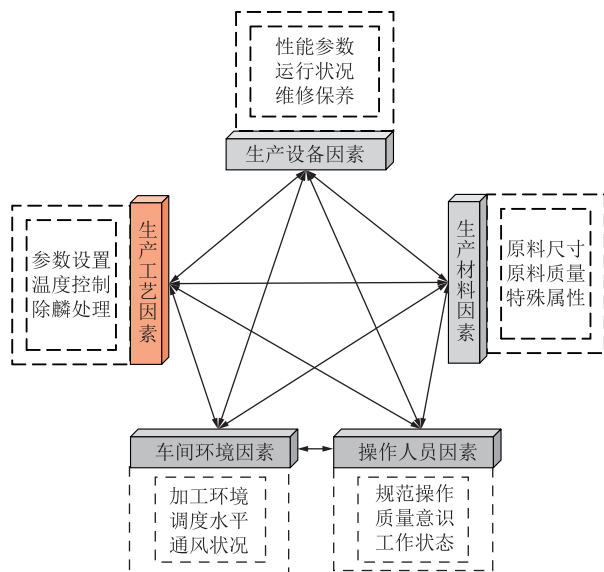


图1 产品影响因素关系示意图

Fig. 1 Schematic diagram of relationship among product influencing factors

生产过程中可检测和设置的参数众多,为了避免模型结构复杂的问题,将采集到的数据通过灰色关联法进行分析。其中,灰色关联分析通过对事物的发展趋势进行分析,在更高层次上实现对事物之间和因素之间的理解,关联度越高,表现越优异<sup>[15]</sup>。本节将实际采集数据与灰色关联法相结合,得到影响成品管形的关键因素如表1所示。由表1可知:与毛管壁厚和外径均有较大关联度的是坯料直径、顶头直径、轧辊间距、导板间距、前伸量这5个工艺参数,将其作为管形预测模型的输入变量,将毛管壁厚和外径作为输出变量。

表 1 管形影响因子关联度

Table 1 Correlation degrees of influencing factors on pipe shape

| 序号 | 因子   | 壁厚关联度  | 排序 | 外径关联度  | 排序 |
|----|------|--------|----|--------|----|
| 1  | 坯料直径 | 0.8453 | 1  | 0.9758 | 2  |
| 2  | 顶头直径 | 0.8165 | 4  | 0.9318 | 4  |
| 3  | 坯料长度 | 0.5980 | 8  | 0.6017 | 6  |
| 4  | 出钢温度 | 0.6070 | 7  | 0.5584 | 8  |
| 5  | 入口锥角 | 0.5966 | 9  | 0.5487 | 9  |
| 6  | 出口锥角 | 0.5966 | 10 | 0.5487 | 10 |
| 7  | 送进角  | 0.6118 | 6  | 0.5640 | 7  |
| 8  | 轧辊间距 | 0.8446 | 3  | 0.9761 | 1  |
| 9  | 导板间距 | 0.8451 | 2  | 0.9644 | 3  |
| 10 | 前伸量  | 0.6359 | 5  | 0.6981 | 5  |
| 11 | 轧辊转速 | 0.5666 | 11 | 0.5238 | 11 |

## 2 多输入多输出最小二乘支持向量机

### 2.1 MIMO 系统模型

MIMO (Multiple-input Multiple-output) 是多输入多输出系统, 包含多个输入、输出变量, 单个输入变量影响多个输出变量, 单个输出变量也会受到多个输入变量的影响, MIMO 系统结构框图如图 2 所示。其中,  $x_1, x_2, \dots, x_m$  为  $m$  个输入变量,  $y_1, y_2, \dots, y_n$  为  $n$  个输出变量,  $a_{11}, \dots, a_{nm}$  为输入变量与输出变量之间的交互影响。若采用多个单输入单输出 (Single-input Single-output, SISO) 系统控制 MIMO 系统, 忽略了变量之间的交互影响。然而, 大量的实际系统属于多输入多输出非线性系统, 而这些多输入多输出非线性系统在建模时会产生不确定性和约束。




图 2 MIMO 系统结构图

Fig. 2 Structure diagram of MIMO system

基于上述理论知识, 同时一些多任务学习方法也提供了借鉴, 例如: 基于任务相关性概念提出的层次贝叶斯方法; 根据层次贝叶斯提出一种正则化的多任务学习方法。针对无缝钢管斜轧穿孔管形预测模型, 本文采取 MLSSVR 预测模型。

### 2.2 多输入多输出最小二乘支持向量回归原理

MLSSVR 预测模型的设计思想为: 寻找多输入多输出空间之间的映射函数, 从而考虑不同输出变量之间的相关信息。给定训练样本集  $(X, Y) = \{(x_i, y_i) \mid i = 1, \dots, l\}$ , 其中:  $x_i \in \mathbf{R}^m$ , 为第  $i$  个样本的  $m$  维输入向量;  $y_i \in \mathbf{R}^n$ , 为对应的  $n$  维输出向量;  $X, Y$  是由  $x_i$  和  $y_i$  组成的输入向量和输出向量的块矩阵,  $X = (x_1, \dots, x_l)^T \in \mathbf{R}^{l \times m}$ ,  $Y = (y_1, \dots, y_l)^T \in \mathbf{R}^{l \times n}$ ;  $l$  为样本总数;  $\mathbf{R}$  为实数集合。MLSSVR 预测模型的目的是构建一个从  $m$  维至  $n$  维的非线性映射。

类似于单输出情况, 回归函数  $f(x)$  定义为:

$$f(x) = \omega^T \varphi(x) + b \quad (1)$$

式中:  $\omega = (\omega_1, \dots, \omega_m) \in \mathbf{R}^{m \times n}$ , 是由权重向量  $\omega_j$  组成的矩阵,  $j = 1, \dots, m$ ;  $b = (b_1, \dots, b_m) \in \mathbf{R}^n$ , 是由偏差  $b_j$  组成的矩阵;  $\varphi(x)$  为特征空间函数。

多输入多输出最小二乘支持向量回归机通过解决以下优化问题得到  $\omega$  和  $b$ :

$$\min_{\omega, b} J(\omega, b, \Xi) = \frac{1}{2} \sum_{j=1}^m \omega_j^T \omega_j + \frac{\gamma}{2} \sum_{i=1}^l e_i^T e_i \quad (2)$$

$$\text{s. t. } Y = Z^T \omega + b + \Xi \quad (3)$$

式中:  $\Xi = (e_1, \dots, e_l)^T \in \mathbf{R}^{l \times m}$ , 为训练误差矩阵;  $e_i$  为第  $i$  个样本的训练误差向量;  $\gamma$  为惩罚系数;  $Z = (\varphi(x_1), \dots, \varphi(x_l)) \in \mathbf{R}^{m \times l}$ , 为特征空间函数  $\varphi(x)$  的集合。

若直接求解多输出问题, 将转化为  $m$  个独立的单输出回归问题。为解决这个问题, 假设  $\omega_j = \omega_0 + v_j$ , 其中,  $\omega_0$  携带输出变量之间的相关信息,  $v_j$  携带每个输出变量的特殊信息, 当不同输出变量彼此相似时, 向量  $v_j$  小, 否则  $\omega_0$  小。

可以通过解决以下优化问题来获得多输出回归:

$$\begin{cases} \min_{\omega_0, v, b, \Xi} J(\omega_0, v, b, \Xi) = \frac{1}{2} \omega_0^T \omega_0 + \frac{1}{2} \times \frac{\lambda}{m} \times \\ \sum_{j=1}^m v_j^T v_j + \frac{\gamma}{2} \sum_{i=1}^l e_i^T e_i \\ \text{s. t. } Y = Z^T \omega + b + \Xi \end{cases} \quad (4)$$

式中:  $v = (v_1, \dots, v_m) \in \mathbf{R}^{m \times n}$ ;  $\lambda$  为正则化参数。

引入拉格朗日乘子, 可得到:

$$L(\omega_0, v, b, \Xi, A) = J(\omega_0, v, b, \Xi) - \text{trace}[A^T (Z^T \omega + b + \Xi - Y)] \quad (5)$$

式中:  $A = (\alpha_1, \dots, \alpha_m) \in \mathbf{R}^{l \times m}$ , 是由拉格朗日乘子  $\alpha_j$  组成的矩阵;  $\text{trace}(\cdot)$  函数用于计算矩阵 “ $\cdot$ ” 的对角线元素之和。

根据 KKT 条件 (Karush-Kuhn-Tucker Conditions), 可得到以下方程组:

$$\begin{cases} \frac{\partial L}{\partial \omega_0} = 0 \Rightarrow \omega_0 = \sum_{j=1}^m Z \alpha_j \\ \frac{\partial L}{\partial \nu} = 0 \Rightarrow \nu = \frac{m}{\lambda} Z A \\ \frac{\partial L}{\partial b} = 0 \Rightarrow A^T \mathbf{1}_l = 0 \\ \frac{\partial L}{\partial \Xi} = 0 \Rightarrow A = \gamma \Xi \\ \frac{\partial L}{\partial A} = 0 \Rightarrow Z^T \omega + b + \Xi - Y = 0 \end{cases} \quad (6)$$

式中:  $\mathbf{1}_l$  为单位矩阵。

由式 (6) 可知:  $\omega_0 = \frac{\lambda}{m} \sum_{j=1}^m \nu_j$ , 显然  $\omega_0$  是  $\nu_j$  的线性组合。

式 (6) 中消除  $\omega$  和  $\Xi$ , 可得到以下线性矩阵方程:

$$\begin{bmatrix} \mathbf{0}_{n \times n} & \mathbf{P}^T \\ \mathbf{P} & \mathbf{H} \end{bmatrix} \begin{bmatrix} \mathbf{b} \\ \alpha \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ \mathbf{y} \end{bmatrix} \quad (7)$$

其中:

$$\begin{cases} \mathbf{P} = \text{blockdiag}(\mathbf{1}_l, \dots, \mathbf{1}_l) \in \mathbf{R}^{nl \times n} \\ \mathbf{H} = \Omega + \frac{1}{\gamma} \mathbf{I}_{nl} + \frac{m}{\lambda} \mathbf{Q} \in \mathbf{R}^{nl \times nl} \\ \Omega = \text{repmat}(\mathbf{K}, m, n) \in \mathbf{R}^{nl \times nl} \\ \mathbf{Q} = \text{blockdiag}(\mathbf{K}, \dots, \mathbf{K}) \in \mathbf{R}^{nl \times nl} \\ \mathbf{K} = \mathbf{Z}^T \mathbf{Z} \in \mathbf{R}^{l \times l} \\ \alpha = (\alpha_1^T, \dots, \alpha_m^T)^T \\ \mathbf{y} = (\mathbf{y}_1^T, \dots, \mathbf{y}_l^T)^T \end{cases} \quad (8)$$

式中:  $\mathbf{0}_{n \times n}$  为一个  $n \times n$  的零矩阵;  $\mathbf{I}_{nl}$  为一个  $nl \times nl$  的单位矩阵, 其中  $nl$  为输出变量数  $n$  和训练样本数  $l$  的乘积;  $\text{blockdiag}$  为块对角矩阵;  $\text{repmat}(\mathbf{K}, m, n)$  为创建一个由  $\mathbf{K}$  堆叠的  $m \times n$  的矩阵;  $\mathbf{K}$  为核函数矩阵, 且满足 Mercer 定理。

因为式 (7) 不是正定矩阵, 很难直接求解, 可通过以下变换将其转换为正定矩阵:

$$\begin{pmatrix} \mathbf{S} & \mathbf{0}_{n \times nl} \\ \mathbf{0}_{n \times n} & \mathbf{H} \end{pmatrix} \begin{pmatrix} \mathbf{b} \\ \mathbf{H}^{-1} \mathbf{P} \mathbf{b} \end{pmatrix} = \begin{pmatrix} \mathbf{P}^T \mathbf{H}^{-1} \mathbf{y} \\ \mathbf{y} \end{pmatrix} \quad (9)$$

式中:  $\mathbf{S} = \mathbf{P}^T \mathbf{H}^{-1} \mathbf{P} \in \mathbf{R}^{n \times n}$ , 为正定矩阵;  $\mathbf{H} \in \mathbf{R}^{nl \times nl}$ , 也为正定矩阵。

可求得  $\alpha$  和  $b$  的解为:

$$\begin{cases} \mathbf{b} = \mathbf{S}^{-1} \boldsymbol{\eta}^T \mathbf{y} \\ \alpha = \nu - \boldsymbol{\eta} \mathbf{b} \end{cases} \quad (10)$$

式中:  $\boldsymbol{\eta} = \mathbf{H}^{-1} \mathbf{P}$ ;  $\nu = \mathbf{H}^{-1} \mathbf{y}$ 。

则 MLSSVR 预测模型可写为:

$$f(x) = \left( \sum_{j=1}^m \alpha_j + \sum_{i=1}^l \frac{m}{\lambda} \alpha_i \right) \mathbf{K} + b_j \quad (11)$$

### 2.3 模型建立

将 5 个输入变量与毛管外径和壁厚之间的关系进行全面量化, 通过 MLSSVR 对无缝钢管管形预测进行建模。图 3 为建立的多输入多输出最小二乘支持向量回归预测模型图。其中,  $k(x_i, x)$  为核函数,  $b_1$ 、 $b_2$  为毛管外径和壁厚的偏差。

## 3 实验结果与分析

为了获得具有良好泛化能力的最佳模型参数, 实验由某钢厂实地采集数据, 在装有 MATLAB 软件的计算机上完成, 建立 MLSSVR 预测模型。

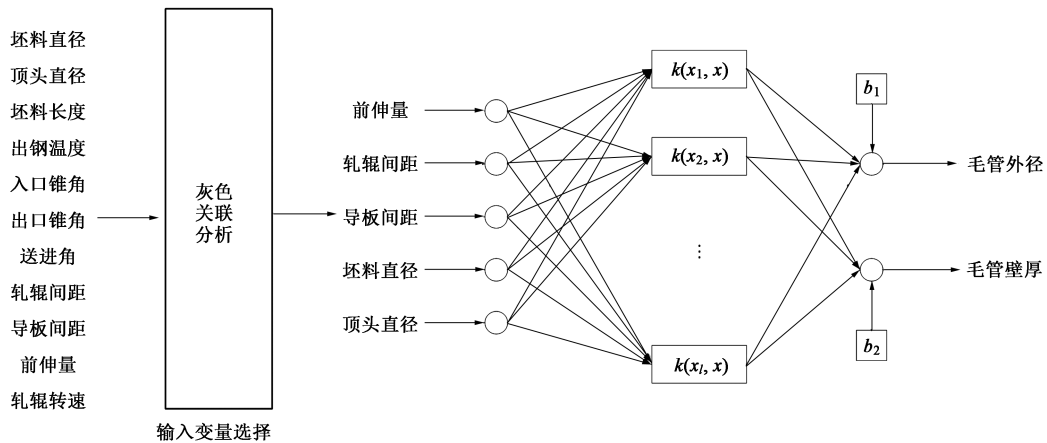


图 3 基于 MLSSVR 的无缝钢管管形预测模型结构图

Fig. 3 Structure diagram of pipe shape prediction model for seamless steel pipe based on MLSSVR



### 3.1 实验数据获取

本文以某钢厂钢管生产线为研究背景，采集实验数据，建立无缝钢管斜轧穿孔管形预测模型。坯料从环形加热炉中通过 1280 ℃ 的温度加热后进行穿孔，得到温度仍较高的毛管，此时不易测得毛管的外径和壁厚，所以，测试实验数据针对冷却后的毛

管几何尺寸进行测量。根据该成品管的规格，首先采用卡尺找到毛管的一条直径，选取直径的任一端作为起始点，从 0° 开始到 360° 每间隔 15° 做一个标记，共测得 12 个毛管外径、24 个毛管壁厚，测量过程如图 4 所示。图 5 为穿孔后毛管外径沿圆周方向分布的极形图。



图 4 实验数据测量过程

(a) 卡尺测量外径 (b) 测厚仪测量壁厚

Fig. 4 Measurement process of experiment data

(a) Outer diameter measured by callipers (b) Wall thickness measured by thickness gauge

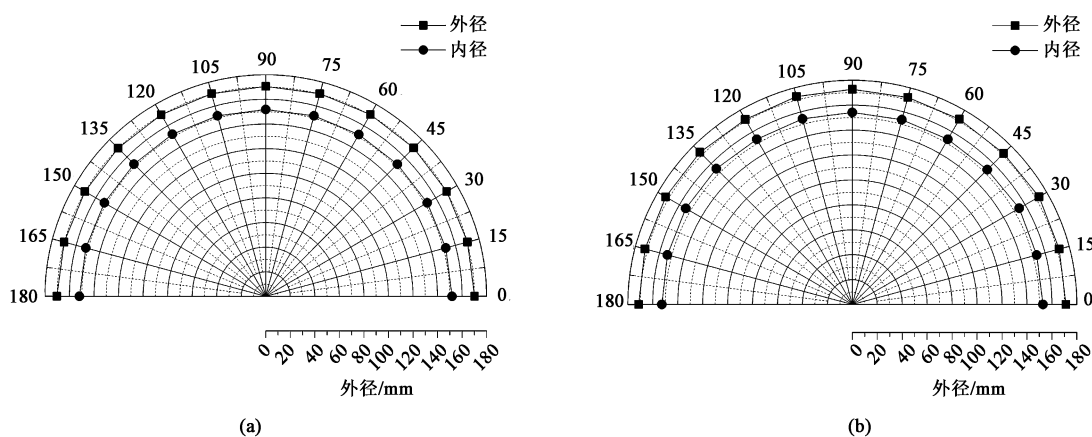


图 5 无缝钢管毛管实测结果

(a) 头部 (b) 尾部

Fig. 5 Measured results of capillary for seamless steel pipe

(a) Head of pipe (b) End of pipe

### 3.2 模型预测精度验证

为了验证所建立的 MLSSVR 模型的预测精度，选取 190 组训练样本、50 组测试样本。图 6 为测试集预测值与实际值的比较，可以看出，建模过程中使用的数据集基于本方法达到了很高的预测能力，因此，该模型具有很高的泛化能力。

### 3.3 不同预测模型的比较

性能度量可以反映模型预测值与实际值之间的拟合程度。为了评估预测精度，采用以下指标：

(1) 平均相对误差  $MRE$ ：

$$MRE = \frac{1}{l} \sum_{i=1}^l \frac{|y' - y'_i|}{y'} \quad (12)$$

(2) 相关系数  $R$ ：

$$R = \frac{\sum_{i=1}^l (y' - \bar{y}') (y'_i - \bar{y}'_i)}{\sqrt{\sum_{i=1}^l (y' - \bar{y}')^2 \sum_{i=1}^l (y'_i - \bar{y}'_i)^2}} \quad (13)$$

式中： $l$  为测试集样本总数； $y'$  和  $y'_i$  分别为输出的实际

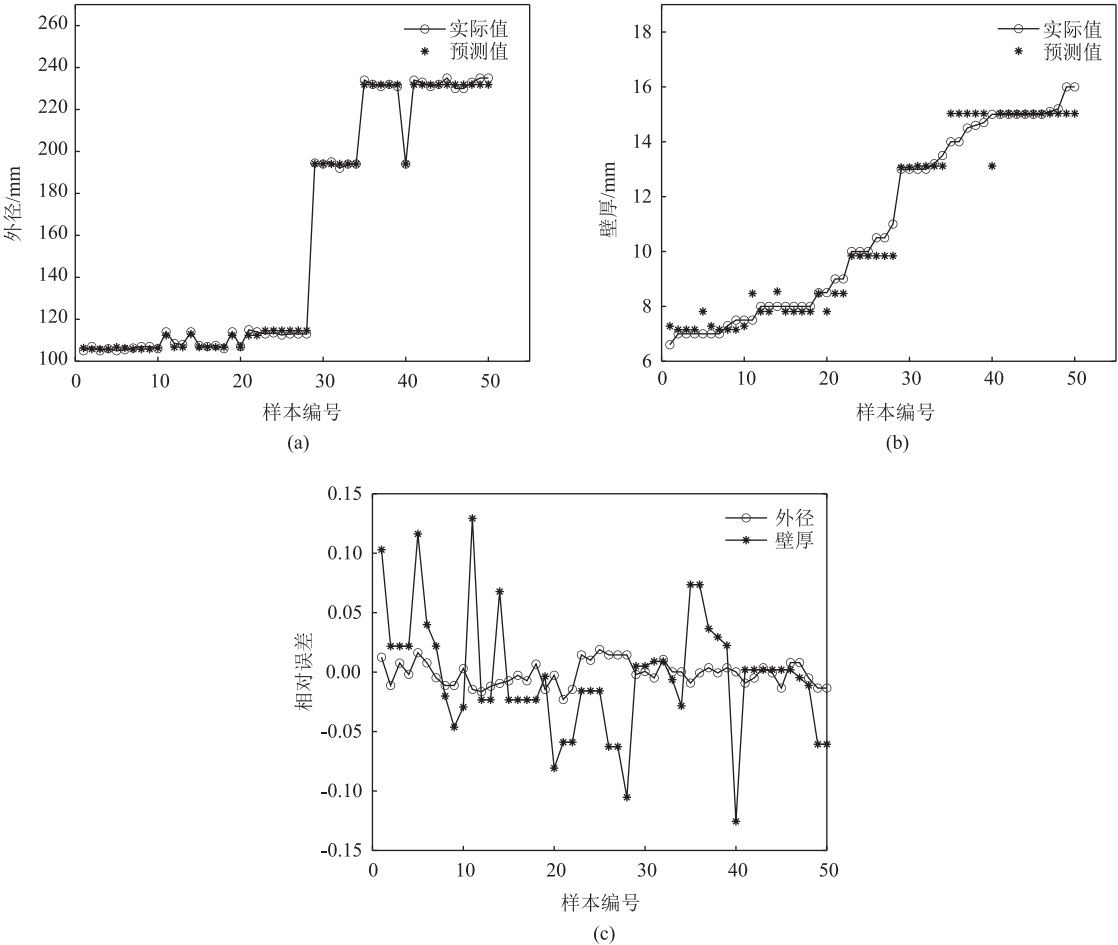


图 6 实际值与 MLSSVR 预测值比较

(a) 外径 (b) 壁厚 (c) 平均相对误差

Fig. 6 Comparison of actual values and MLSSVR predicted values

(a) Outer diameter (b) Wall thickness (c) Average relative error

值和预测值;  $\bar{y}$  和  $\bar{y}_i$  分别为实际值和预测值的平均值。

平均相对误差  $MRE$  反映了模型实际值和预测值之间的误差; 相关系数  $R$  反映了输入变量对输出变量的综合影响, 模型的预测值越接近于实际值,  $R$  值越接近于 1。

由于径向基函数具有极高的泛化能力, 能排除样本数据中的噪声, 避免过拟合问题。与其他核函数相比, 优势在于: (1) 线性核函数是径向基函数的特例; (2) Sigmoid 核函数不是正定的, 对于某些参数, Sigmoid 核函数的行为类似于径向基函数; (3) 相对而言, 多项式核函数中的参数较多, 模型选择难度较大。因此, 本文采用径向基核函数。

不同优化算法的模型性能不同, 为进一步验证 MLSSVR 方法的有效性, 实验中对训练集和测试集采用其他算法进行仿真。支持向量回归 (Support Vector Regression, SVR) 和最小二乘支持向量回归 (Least Squares Support Vector Regression, LSSVR) 算

法将多输出模型改为 2 个单输出模型, MSVR 算法是在 SVR 算法的基础上进行多输出仿真实验, 上述方法同样适用于管形分析。不同优化算法预测得到的毛管外径和壁厚的平均相对误差和相关系数如表 2 所示。可以看出, 相比其他方法, MLSSVR 具有更高的精度, 说明考虑不同输出变量之间的交叉信息有助于提高单输出回归方法的性能。

表 2 不同优化算法的管形预测结果比较

Table 2 Comparison of pipe shape prediction results for different optimization algorithms

| 优化算法   | 平均相对误差/% |        | 相关系数 $R$ |        |
|--------|----------|--------|----------|--------|
|        | 外径       | 壁厚     | 外径       | 壁厚     |
| 数学模型   | 0.1453   | 0.2127 | 0.9972   | 0.9640 |
| SVR    | 0.0984   | 0.1732 | 0.9977   | 0.9662 |
| LSSVR  | 0.0527   | 0.1293 | 0.9982   | 0.9714 |
| MSVR   | 0.0069   | 0.0455 | 0.9997   | 0.9738 |
| MLSSVR | 0.0068   | 0.0325 | 0.9997   | 0.9864 |

结果表明, 提出的 MLSSVR 方法能使每个测试样本的预测值和实际值之间的一致性最高, 其主要的原因: (1) 该模型是基于非线性映射能力强、泛化能力强的支持向量机进行拟合的; (2) 多任务学习与 LSSVR 的结合, 考虑了不同输出变量之间潜在的交叉相关性。针对不同的输出变量建立不同模型的单输出 LSSVR 和 SVR 方法, 过程较为耗时; 虽然 SVR 也是多任务学习, 相比 SVR 和 LSSVR, 其与 MLSSVR 的相对误差和相关系数的值最接近; 与 MLSSVR 相比, MSVR 的鲁棒性和泛化性能稍差, MLSSVR 模型的预测精度更高。

## 4 结论

(1) 本文研究了多输出回归问题, 同时对管形的影响因素进行分析, 根据少量输入输出数据, 建立了基于 MLSSVR 方法的 5 输入 2 输出管形预测模型, 仿真表明该模型的泛化能力较高。

(2) 对数据中关键变量的提取可以提高模型的可靠性, 前伸量、轧辊间距、导板间距、坯料直径、顶头直径作为影响管形最重要的因素, 为模型的设计提供有价值的参考。

(3) 将 MLSSVR 模型与其他优化算法建立的结果进行比较, 仿真结果表明, MLSSVR 模型比其他模型的精度高, 其原因是 SVR 和 LSSVR 模型将多输出问题转化为两组单输出回归算法来解决, 而 MLSSVR 模型考虑了不同输出变量之间的潜在相关性。

(4) 该模型能考虑前伸量、轧辊间距、导板间距、坯料直径、顶头直径等重要参数对毛管外径和壁厚影响, 根据实验结果和数值分析, MLSSVR 方法可以成功地用于无缝钢管斜轧穿孔管形的预测。

### 参考文献:

- [1] 栾治伟, 张文新, 王柏琳, 等. 无缝钢管热轧生产过程中的轧辊孔型匹配问题 [J]. 计算机集成制造系统, 2017, 23 (12): 2676-2682.  
Luan Z W, Zhang W X, Wang B L, et al. Roller pass matching problem for hot-rolled seamless steel tube [J]. Computer Integrated Manufacturing Systems, 2017, 23 (12): 2676-2682.
- [2] 双远华, 王付杰, 王清华. 无缝钢管连续斜轧工艺与设备的探索 [J]. 机械工程学报, 2017, 53 (10): 18-24.  
Shuang Y H, Wang F J, Wang Q H. Explorative study of tandem skew rolling process and equipment for producing seamless steel tubes [J]. Journal of Mechanical Engineering, 2017, 53 (10): 18-24.
- [3] Zhang W Y, Ju D Y, Zhao H Y, et al. Fuzzy controller optimized by genetic algorithm for the molten metal level in the twin roll strip casting process [J]. Materials Science Forum, 2015, 833: 197-200.
- [4] 周华民, 高煌, 张云, 等. 注塑成型工艺参数自动设置与优化技术 [J]. 精密成形工程, 2016, 8 (1): 7-13.  
Zhou H M, Gao H, Zhang Y, et al. Automatic setting and optimization of injection molding process parameters [J]. Journal of Net-shape Forming Engineering, 2016, 8 (1): 7-13.
- [5] Son J, Lee D, Kim I, et al. A study on on-line learning neural network for prediction for rolling force in hot-rolling mill [J]. Journal of Materials Processing Technology, 2005, 164-165: 1612-1617.
- [6] 陈鑫, 朱明杰, 吴敏, 等. 结合机理计算与神经网络预测的无缝钢管轧制力建模 [J]. 冶金自动化, 2015, 39 (4): 32-37.  
Chen X, Zhu M J, Wu M, et al. Rolling force modeling for seamless steel pipe combining mechanism model and neural network prediction [J]. Metallurgical Industry Automation, 2015, 39 (4): 32-37.
- [7] 高山凤, 刘鸿飞, 郝安民, 等. 热轧板带横向厚度分布的预测与控制 [J]. 哈尔滨工业大学学报, 2016, 48 (1): 180-183.  
Gao S F, Liu H F, Xi A M, et al. Prediction and control of thickness transverse distribution in hot rolling strip [J]. Journal of Harbin Institute of Technology, 2016, 48 (1): 180-183.
- [8] Wang Z H, Liu Y M, Gong D Y, et al. A new predictive model for strip crown in hot rolling by using the hybrid AMPPO-SVR-based approach [J]. Steel Research International, 2018, 89 (7): 1800003.
- [9] Zhu X, Zhu Z. The generalized predictive control of bacteria concentration in marine lysozyme fermentation process [J]. Food Science & Nutrition, 2018, 6 (8): 2459-2465.
- [10] Yusof Y, Kamaruddin S S, Husni H, et al. Forecasting model based on LSSVM and ABC for natural resource commodity [J]. International Journal of Computer Theory and Engineering, 2013, 5 (6): 906-909.
- [11] Suykens J A K, Van Gestel T, De Brabanter J, et al. Least Square Support Vector Machine [M]. Singapore: World Scientific Publishing, 2002.
- [12] Liu X, Zhu Q, Lu H. Modeling multiresponse surfaces for airfoil design with multiple-output-gaussian-process regression [J]. Journal of Aircraft, 2014, 51 (3): 740-747.
- [13] Xu S, An X, Qiao X, et al. Multi-output least-squares support vector regression machines [J]. Pattern Recognition Letters, 2013, 34 (9): 1078-1084.
- [14] 杨勇, 黄文波, 金裕成, 等. 基于 MSVR 和 Arousal-Valence 情感模型的表情识别研究 [J]. 重庆邮电大学学报: 自然科学版, 2016, 28 (6): 836-843.  
Yang Y, Huang W B, Jin Y C, et al. A study of expression recognition based on MSVR and Arousal-Valence emotion model [J]. Journal of Chongqing University of Posts and Telecommunications: Natural Science Edition, 2016, 28 (6): 836-843.
- [15] 魏子茹, 卢延辉, 王鹏宇, 等. 基于 CRITIC 法的灰色关联理论在无人驾驶车辆测试评价中的应用 [J]. 机械工程学报, 2021, 57 (12): 99-108.  
Wei Z R, Lu Y H, Wang P Y, et al. Application of grey correlation theory based on CRITIC method in autonomous vehicles test and evaluation [J]. Journal of Mechanical Engineering, 2021, 57 (12): 99-108.