

文章编号: 2095-2163(2023)08-0114-07

中图分类号: TP202+.1

文献标志码: A

# 基于 SSA-SVM 的刀具寿命预测

毛佳伟<sup>1</sup>, 周敏<sup>2,3</sup>, 张豪<sup>2,3</sup>, 饶琪<sup>2,3</sup>

(1 武汉科技大学 精密制造研究所, 武汉 430081; 2 武汉科技大学 冶金装备与控制技术教育部重点实验室, 武汉 430081;

3 武汉科技大学 机械传动与制造工程湖北省重点实验室, 武汉 430081)

**摘要:** 数控机床(CNC)自动刀库中刀具的管理工作以及机床运行参数制定,都与刀具的使用寿命息息相关,而刀具寿命预测值与其影响因素呈现出一种高维度的复杂非线性关系。针对这一问题,提出将刀具寿命影响因子作为变量输入到支持向量机(SVM)模型,再利用麻雀搜索算法(SSA)对SVM的核函数 $g$ 和惩罚参数 $C$ 进行优化,以均方根误差(RMSE)作为适应度函数,通过迭代选择最优的回归参数训练模型。结果表明:SSA-SVM模型预测精度较BP神经网络、SVM、LSTM分别提升了9.1%、5.6%、0.12%,且耗时仅为4.724 7 s,方法具有可行性。

**关键词:** 刀具寿命预测; 支持向量机(SVM); 麻雀搜索算法(SSA); BP神经网络

## Tool life prediction based on SSA-SVM

MAO Jiawei<sup>1</sup>, ZHOU Min<sup>2,3</sup>, ZHANG Hao<sup>2,3</sup>, RAO Qi<sup>2,3</sup>

(1 Precision Manufacturing Institute, Wuhan University of Science and Technology, Wuhan 430081, China; 2 Key Laboratory of Metallurgical Equipment and Control Technology, Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China; 3 Hubei Key Laboratory of Mechanical Transmission and Manufacturing Engineering, Wuhan University of Science and Technology, Wuhan 430081, China)

**[Abstract]** The management of the tool in the automatic tool library of CNC machine tools and the formulation of the operation parameters of the machine tools are closely related to the service life of the tool. The relationship between tool life prediction and its influencing factors is complicated and nonlinear. In order to solve this problem, the knives' service life impact factors are selected as variable input to the support vector machine (SVM) model, the sparrow search algorithm (SSA) is used to optimize kernel function  $g$  and penalty parameter  $C$  of support vector machine SVM, with root mean square error (RMSE) as a fitness function, and through the iterative selection of the optimal regression parameters, the model is trained. The results show that the prediction accuracy of SSA-SVM model is improved by 9.1%, 5.6% and 0.12% compared with BP neural network, SVM and LSTM, respectively, and the time is only 4.724 7 s. The method is feasible.

**[Key words]** tool life prediction; support vector machine; sparrow search algorithm; BP neural network

## 0 引言

中国在2015年提出“中国制造2025”规划,预示中国将朝着“工业4.0迈出重要一步”<sup>[1]</sup>。面对机遇与挑战,传统制造企业积极发展,智能制造成为产业革命改革的一个重要良策。

随着数控车间的“智能化”升级,很多制造企业的数控机床(CNC)都配备了自动刀库,取消了由原来人工配送刀具和更换刀具,实现了机床一体化作业,大大降低了企业生产成本。自动刀库中刀具的

管理工作,数控编程对于走刀工艺路径以及参数的规划,都与刀具的使用寿命息息相关,所以准确预测数控刀具的使用寿命成为当前工业问题的研讨热点。

刀具的使用寿命是指将一把新刀从开始使用到报废标准总的切削时长<sup>[2]</sup>。目前,刀具使用寿命大概有2种方法,分别是:基于物理模型和数据驱动<sup>[3]</sup>。其中,基于物理模型的方法是通过建立刀具寿命与切削速度、刀具齿数以及背吃刀数等加工参数之间的显式数学模型。基于数据驱动的方法,通

**基金项目:** 国家自然科学基金面上项目(51975431)。

**作者简介:** 毛佳伟(1995-),男,硕士研究生,主要研究方向:智能制造;周敏(1967-),女,教授,博士生导师,主要研究方向:智能制造、制造业信息化研究。

**通讯作者:** 周敏 Email: zhomin@wust.edu.cn

**收稿日期:** 2022-09-23

过将刀具直径、切削宽度、进给量等刀具寿命影响因素输入到已建立的机器学习模型,以总切削时长  $T$  为标签,利用机器学习的方法如人工神经网络<sup>[4]</sup>、支持向量机<sup>[5]</sup>和贝叶斯网络<sup>[6]</sup>等进行模型构建,避免建立复杂的物理模型。基于数据驱动的方法更多地依赖数据,降低了对刀具加工过程中的磨损机理的探究,可以更容易地构建出刀具使用寿命模型<sup>[7]</sup>。

丁怡等学者<sup>[8]</sup>分析了影响刀具寿命的主要因素,结合人工神经网络模型,建立了刀具寿命预测的 BP 神经网络模型。并进行了验证运算,得到了可靠有效的结果。Hosseinkhani 等学者<sup>[9]</sup>提出了一种使用混合有限元方法结合经验磨损率方程估算刀具寿命的方法。Kovac 等学者<sup>[10]</sup>利用工具工作温度的测量值确定了扩展的泰勒函数关系,该方法可以将获取的刀具表面的温度作为输入信号,进行刀具寿命的预测。薛嫣等学者<sup>[11]</sup>提出了对滚动轴承数据进行时域、频域、时频域的故障特征提取,将提取特征作为 LSTM 预测模型输入,得到了很好的预测结果。但是上述方法都不同程度地存在一些不足,例如 BP 神经网络是一种局部寻优方法,易陷于局部极小化,且收敛速度较慢,预测结果好坏很大程度依赖初始参数的设置,通用性差。而基于泰勒公式的物理模型,在实际生产加工中,刀具寿命受多种因素影响,更无法表征出这种高维度的非线性关系。时间序列模型(LSTM)需要大量数据才能对其进行正确训练,对参数设置有严格要求,模型鲁棒性较差。

针对以上所述问题,本文提出一种 SSA-SVM<sup>[12-14]</sup>刀具寿命预测模型,利用具有强非线性拟合能力的支持向量机回归(SVM)算法<sup>[15]</sup>,只对样本数据学习,不需要调节网络连接权值<sup>[16]</sup>、神经元个数等参数,再将 SSA 优化算法对 SVM 参数进行调优。最终得到的模型泛化能力强,耗时短、适用性高、预测准确率较 BP 神经网络、SVM、LSTM 三个模型均有提高,满足在线预测要求。

## 1 机床便携式刀具库自动换刀系统框架设计

目前,大多数的数控机床的换刀工作依旧由人工完成<sup>[17]</sup>。操作流程一般如下:机床开始加工前,由操机人员根据工艺部门下发的数控工艺卡进行车床刀具安装,待某一工序结束时,停机,从数控机床便携式刀具库取出下一个工序需要的刀具(或由刀具计划人员配送)安装到机床的刀具夹头上,开始运行下一个工序<sup>[18]</sup>。当前工作流程有 2 个亟待解

决的问题。一是换刀流程极为繁琐,人工参与度高,极易出现加工失误。二是由于数控工艺人员不了解刀具寿命等相关知识,只考虑加工路线和切削量,造成精密刀具这种昂贵资源白白浪费,无形增加企业生产成本。本文设计出一种刀具库自动换刀系统,设计思路如下:

- (1) 机床数控系统读取工艺卡上刀具信息。
- (2) 机床便携式传感器读取加工参数,例如背吃刀量,切削速度等作为数据补充。
- (3) 将数据组合在一起输入到自创立的 SSA-SVM 刀具寿命预测系统,计算出预测值  $T$ 。
- (4) 如加工时间  $t < 1/2T$ , 则机床继续工作,若  $t > 1/2T$ , 则触发数控系统报警指令  $S$ 。
- (5) 将报警指令  $S$  传输到 PLC, 由 PLC 控制转盘式刀具库转动。
- (6) 刀具库中的 RFID 读写器读取刀柄上的编码,若符合要求,则由机械手将刀具取出并安装到机床夹头上,若不符合,则 PLC 继续控制转盘转动,直到挑选出符合要求的刀具。具体系统流程如图 1 所示。

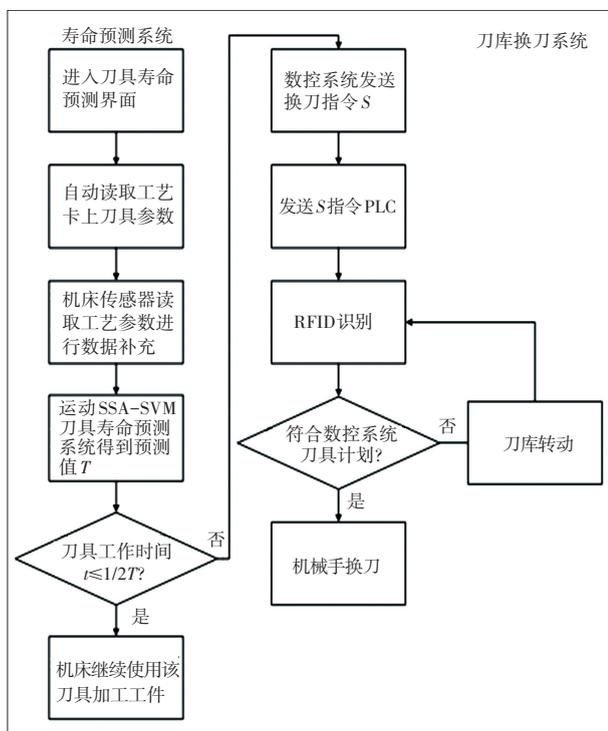


图 1 刀具库自动换刀系统框架

Fig. 1 Tool library automatic tool change system framework

要保证该系统的流畅性和稳定性,刀具寿命预测子系统需保证预测的准确性,且要满足在线预测要求,即设计的寿命预测模型相对误差要在合理范围,且耗时要短。

## 2 刀具寿命预测模型建立

### 2.1 刀具寿命影响因素

要准确的预测刀具寿命,需要研究刀具寿命影响因素,通过查阅文献[19],可知刀具的寿命公式具体如下:

$$T = \frac{C_r \cdot D_o^q}{v_c \cdot a_p^x \cdot f^y \cdot a_w^u \cdot Z^p} \quad (1)$$

其中,  $C_r$  为刀具寿命系数;  $D_o$  为刀具直径;  $v_c$  为切削速度;  $a_p$  为背吃刀量;  $a_w$  为切削宽度;  $f$  为进给量;  $z$  为刀具齿数。  $x, y, u, p, q$  为各相应参数的指数值,其大小表明各相应参数对刀具寿命的影响程度。一般情况下,刀具寿命还与刀具的刃磨质量、冷却条件、润滑程度相关,可见刀具的寿命受多种因素影响,基于传统物理模型很难阐释刀具寿命与其影响因子之间的非线性关系。

### 2.2 支持向量机回归算法

SVM 回归以统计学为基础,是一种监督学习方法,广泛应用于寿命预测、故障诊断等领域。本文采用 SVM 回归进行刀具剩余寿命预测。

研究中,对于给定的训练样本  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ ,  $y_i \in \mathbb{R}$ , 希望得到一个形如式(2)的模型,使得  $f(x)$  和  $y$  尽可能接近,  $w$  和  $b$  为模型待定参数,超平面所对应的模型方法见如下:

$$f(x) = w^T x + b \quad (2)$$

对于样本  $D$ , 传统回归模型一般通过  $f(x)$  和  $y$  之间的差别来计算损失,两者完全相同时,损失即为零。与此不同,支持向量机能容忍  $f(x)$  和  $y$  产生最多  $\varepsilon$  的偏差,即  $f(x)$  和  $y$  偏差的绝对值大于  $\varepsilon$  时就会计算损失。于是回归问题可转化为:

$$\max_{w, b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \ell_\varepsilon(f(x_i) - y_i) \quad (3)$$

其中,  $C$  表示正则化常数,  $\ell_\varepsilon$  为  $\varepsilon$ -不敏感损失 ( $\varepsilon$ -insensitive loss) 函数,可由如下公式进行计算:

$$\ell_\varepsilon(z) = \begin{cases} 0, & \text{if } |z| \leq \varepsilon \\ |z| - \varepsilon & \text{otherwise} \end{cases} \quad (4)$$

引入松弛变量  $\xi_i$  和  $\hat{\xi}_i$ , 可将式(3)重写为:

$$\begin{aligned} \min_{w, b, \xi, \hat{\xi}} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \\ \text{s.t.} & f(x_i) - y_i \leq \varepsilon + \xi_i \\ & y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i \end{aligned}$$

$$\xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m \quad (5)$$

引入拉格朗日乘子  $\mu_i \geq 0, \hat{\mu}_i \geq 0, \alpha_i \geq 0, \hat{\alpha}_i \geq 0$ , 由拉格朗日乘子法可得到式(5)的拉格朗日函数:

$$\begin{aligned} L(w, b, \alpha, \hat{\alpha}, \xi, \hat{\xi}, \mu, \hat{\mu}) &= \frac{1}{2} \|w\|^2 + \\ & C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) - \sum_{i=1}^m \mu_i \xi_i - \sum_{i=1}^m \hat{\mu}_i \hat{\xi}_i + \\ & \sum_{i=1}^m \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \\ & \sum_{i=1}^m \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i). \end{aligned} \quad (6)$$

将式(2)代入,再令  $L(w, b, \alpha, \hat{\alpha}, \xi, \hat{\xi}, \mu, \hat{\mu})$  对  $w, b, \xi$  和  $\hat{\xi}$  的偏导为0可得:

$$w = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) x_i \quad (7)$$

$$0 = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \quad (8)$$

$$C = \alpha_i + \mu_i \quad (9)$$

$$C = \hat{\alpha}_i + \hat{\mu}_i \quad (10)$$

将式(7)~式(10)代入式(6),即可得到 SVM 回归的对偶问题:

$$\begin{aligned} \max_{\alpha, \hat{\alpha}} & \sum_{i=1}^m y_i (\hat{\alpha}_i - \alpha_i) - \varepsilon (\hat{\alpha}_i + \alpha_i) - \\ & \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_j - \alpha_j) x_i^T x_j \\ \text{s.t.} & \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) = 0 \\ & 0 \leq \alpha_i, \hat{\alpha}_i \leq C \end{aligned} \quad (11)$$

上述过程需要满足 KKT (Karush - Kuhn - Tucker) 条件,即要求:

$$\begin{cases} \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) = 0 \\ \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i) = 0 \\ \alpha_i \hat{\alpha}_i = 0, \xi_i \hat{\xi}_i = 0 \\ (C - \alpha_i) \xi_i = 0, (C - \hat{\alpha}_i) \hat{\xi}_i = 0 \end{cases} \quad (12)$$

由式(12)可知,当且仅当  $f(x_i) - y_i - \varepsilon - \xi_i = 0$  时,  $\alpha_i$  可以取非零值,同样当且仅当  $y_i - f(x_i) - \varepsilon - \hat{\xi}_i = 0$  时,  $\hat{\alpha}_i$  可以取非零值。换句话说,当样本  $D$  没有落入  $\varepsilon$ -间隔带中,  $\alpha_i$  和  $\hat{\alpha}_i$  才能取非零值,  $f(x_i) - y_i - \varepsilon - \xi_i = 0$  和  $y_i - f(x_i) - \varepsilon - \hat{\xi}_i = 0$  不能同时成立,因此  $\alpha_i$  和  $\hat{\alpha}_i$  至少有一个为零。

将式(7)代入式(2), 则 SVM 回归的解形如式(13)所示:

$$f(\mathbf{x}) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i^T \mathbf{x} + b \quad (13)$$

其中, 使得  $\hat{\alpha}_i - \alpha_i \neq 0$  的样本即为支持向量, 都落在隔离带外, 其解仍具有稀疏性。

由式(12)可看出, 对于每个样本都有  $(C - \alpha_i) \xi_i = 0$  且  $\alpha_i(f(x_i) - y_i - \varepsilon - \xi_i)$ 。因此在得到  $\alpha_i$  后, 若  $0 < \alpha_i < C$ , 则必有  $\xi_i = 0$ , 进而有:

$$b = y_i + \varepsilon - \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i^T \mathbf{x} \quad (14)$$

因此求解式(11)得到  $\alpha_i$ , 理论上来说, 可任意选取满足  $0 < \alpha_i < C$  的样本通过式(14)求得  $b$ 。采用更鲁棒的方法, 求得多个满足条件的  $b$  后取平均值。

考虑映射特征, 在特征空间中划分超平面所对应的模型可表示为:

$$f(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (15)$$

则相应的式(7)将形如:

$$\mathbf{w} = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \phi(\mathbf{x}_i) \quad (16)$$

将式(16)代入式(15), 则 SVM 回归可表示为:

$$f(\mathbf{x}) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \kappa(\mathbf{x}_i, \mathbf{x}_j) + b \quad (17)$$

其中,  $\kappa(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$  为核函数。

### 2.3 基于 SVM 的刀具寿命预测模型

通过上述对刀具寿命影响因素和支持向量机(SVM)理论综合分析, 本文构建了基于 SVM 的刀具寿命预测模型, 具体步骤如下:

**Step 1** 根据本文所做的刀具寿命分析, 选择刀具直径 ( $D_o$ )、切削速度 ( $v_c$ )、背吃刀量 ( $\alpha_p$ )、切削宽度 ( $a_w$ )、进给量 ( $f$ )、刀具齿数 ( $Z$ ) 用作预测模型输入参数, 模型的输出参数为刀具寿命  $T$ ;

**Step 2** 从样本数据分析, 输入模型的参数, 例如切削宽度 ( $a_w$ )、进给量 ( $f$ ) 等参数的量纲不一致会对模型精度造成影响, 所以对数据样本进行归一化处理, 原理如下:

$$x_{scale} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (18)$$

其中,  $x_{scale}$  为归一化后的值;  $x$  为样本数据真实值;  $x_{max}$  为该列样本数据最大值;  $x_{min}$  为该列样本数据最小值;

**Step 3** 选择合适的 SVM 核函数。通过对比分析, 选择在多领域预测效果不错的径向基核函数;

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (19)$$

**Step 4** SVM 的有效性取决于惩罚系数  $C$ 、径向基核函数的宽度参数  $g$ 。使用刀具寿命训练集样本并交叉验证  $w$  参数选择的每一个组合, 在此基础上选择具有最佳交叉验证精度的参数;

**Step 5** 通过校验样本检验预测模型的泛化能力。使用所选择的参数在整个测试集上验证 SVM 模型<sup>[13-14]</sup> 预测精度。

### 2.4 基于 SSA 优化 SVM 的刀具寿命预测模型建立

麻雀搜索算法 (sparrow search algorithm, SSA) 由 Xue 等学者于 2020 年提出, 该算法是根据麻雀觅食并逃避捕食者的行为而提出的群智能优化算法。SSA 主要是受麻雀的觅食行为和反捕食行为的启发而提出的。该算法比较新颖, 具有寻优能力强、收敛速度快的优点。麻雀群觅食过程也是发现者-跟随者模型的一种, 同时还叠加了侦查预警机制。麻雀中找到食物较好的个体作为发现者, 其他个体作为跟随者, 同时种群中选取一定比例的个体进行侦查预警, 如果发现危险则放弃食物, 安全第一。麻雀搜索算法基于上述原理对 SVM 模型进行优化。其主要思路为用 SVM 的惩罚系数  $C$  和径向基核函数的宽度参数  $g$  作为麻雀的位置, 通过对全局的适应度值排序, 求最优值和最优位置, 得到最优参数。SSA 优化 SVM 参数流程如图 2 所示。基于 SSA-SVM 的刀具寿命模型建立可详述如下:

**Step 1** 参数初始化。初始化 SSA 种群参数, 最大迭代参数  $iter_{max}$  以及捕食者和加入者的比例, 确定 SVM 惩罚参数  $C$  和径向基核函数宽度  $g$  的取值范围;

**Step 2** 计算适应度值、并排序。利用式(20)计算出全局的适应度大小、并排序, 最优值即为麻雀的最佳捕食位置。适应度函数设置为 SVM 训练后的  $MSE$  误差;

$$fitness = \operatorname{argmin}(MSE_{\text{pridict}}) \quad (20)$$

**Step 3** 捕食者位置更新公式为:

$$X'_{i,j} = \begin{cases} X'_{i,j} \cdot \exp\left(\frac{-i}{\alpha \cdot iter_{max}}\right) & \text{if } R_2 < ST \\ X'_{i,j} + Q \cdot L & \text{if } R_2 \geq ST \end{cases} \quad (21)$$

其中,  $t$  为当前迭代次数;  $iter_{max}$  是一个常数, 表示最大迭代次数;  $X'_{i,j}$  表示第  $t$  次迭代时第  $i$  个麻雀在第  $j$  维中的位置信息;  $\alpha \in (0, 1]$  是一个随机数;  $Q$  表示一个服从正态分布的随机数;  $R_2$  ( $R_2 \in [0, 1]$ ) 和  $ST$  ( $ST \in [0.5, 1]$ ) 分别为预警值和安全值;

$L$  表示  $1 \times d$  的全1矩阵。当  $R_2 < ST$  时,意味着觅食者周围没有捕食者,发现者可以进入广泛的搜索操作,否则,发现者带领种群转移到安全区。

**Step 4** 加入者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right) & \text{if } i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L & \end{cases} \quad (22)$$

其中,  $X_p$  是目前发现者所占据的最优位置;  $X_{worst}$  表示当前全局最差位置;  $A$  表示一个  $1 \times d$  矩阵,其中每个元素随机赋值为 1 或 -1,并且  $A^+ = A^T(AA^T)^{-1}$ 。当  $i > n/2$  时,这表明适应度值较低的第  $i$  个加入者没有获得食物,处于十分饥饿的状态,此时需要飞往其它地方觅食,以获得更多的能量。

**Step 5** 警戒者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t| & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \varepsilon}\right) & f_i = f_g \end{cases} \quad (23)$$

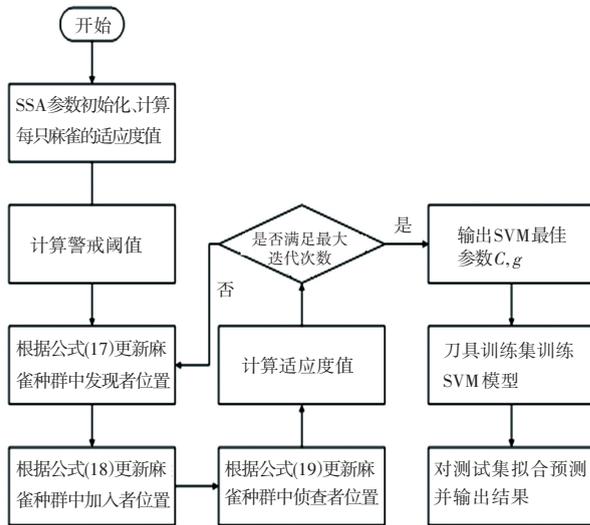


图2 SSA优化SVM参数流程图

Fig. 2 SVM parameter optimization flow chart based on SSA

### 3 仿真实验与分析

#### 3.1 实验数据

本文选取柔性系统中最具代表性的铣刀作为实验样本<sup>[20]</sup>。在数控车间,粗铣是必不可少的加工工序,将其作为研究工况,刀具材料为YT15硬质合金,工件的材料为45钢。由文献[21]可知,其材料相对加工性系数取1.0~1.6。实验的训练集取22组样本数据,验证集取17组样本数据,表1为刀具寿命预测部分验证集数据。

表1 刀具寿命预测部分样本数据

Tab. 1 Partial sample data of tool life prediction

序号	$D_0/\text{mm}$	$Z$	$a_p/\text{mm}$	$a_w/\text{mm}$	$f/(\text{mm} \cdot \text{tooth}^{-1})$	$v_c/(\text{m} \cdot \text{min}^{-1})$	$K_v$	$T/\text{min}$
1	80	4	2	40	0.12	183	1.1	72
2	80	4	3	50	0.10	175	1.2	85
3	100	5	4	60	0.13	150	1.1	98
4	100	5	5	75	0.15	130	1.2	107
5	100	5	7	60	0.07	173	1.2	125
6	125	6	5	75	0.10	144	1.1	180
7	125	6	7	80	0.11	140	1.3	136
8	125	6	6	90	0.13	135	1.0	113
9	160	8	3	96	0.10	150	1.1	190
10	160	8	5	100	0.13	130	1.1	171

#### 3.2 实验结果评价准则

采用3种评价准则,分别为均方根误差(Root Mean Square Error,  $RMSE$ )、决定系数(R-squared,  $R^2$ )和平均绝对误差(Mean Absolute Error,  $MAE$ ),3个评价准则定义如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (T(i) - \bar{T}(i))^2} \quad (24)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (T(i) - \hat{T}(i))^2}{\sum_{i=1}^n (T(i) - \bar{T}(i))^2} \quad (25)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |T(i) - \bar{T}(i)| \quad (26)$$

其中,  $n$  表示循环预测刀具寿命的次数;  $T(i)$  表示第  $i$  个工况对应的刀具寿命的实际值;  $\bar{T}(i)$  表示其预测值。

#### 3.3 模型预测与算法仿真比较

对于SVM模型来说,找到最优的惩罚系数  $C$  和核函数  $g$  至为重要,也是本文采用SSA优化算法的目的所在,经多次仿真实验后,将SSA算法的麻雀个数设置为20,最大迭代次数为150次,最终得到SVM模型的最优惩罚系数  $C$  为250,最优核函数  $g$  为0.1069,而未经优化的SVM模型的最优参数  $C = 256$ ,  $g = 0.0625$ 。为维持SVM模型在过拟合和欠拟合之间的平衡,往往最佳的参数范围是  $C$  比较大,  $gamma$  比较小,或者  $C$  比较小,  $gamma$  比较大。  $gamma$  越大,理论上SVM可以拟合任何非线性数据,综上所述,经过SSA算法优化后的SVM模型具有很好的泛化性,图3为优化后的SVM参数选择结果3D视图。

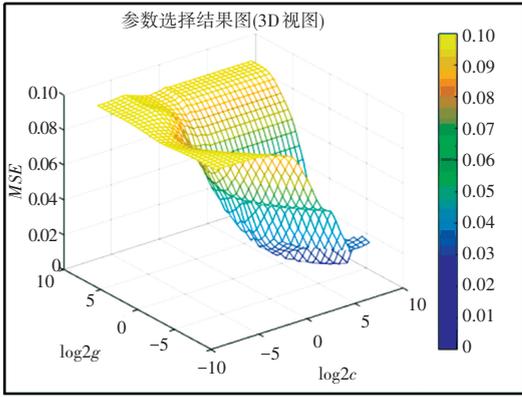


图 3 参数选择结果图

Fig. 3 Parameters selection result diagram

为了验证 SSA-SVM 模型的刀具寿命预测效果,在实验数据相同的条件下,将测试样本以矩阵的形式输入到训练好的 SVM、SSA-SVM、BP 神经网络和 LSTM 模型中,经 Matlab 仿真,得到的实验结果见表 2,绘制后的曲线如图 4 所示。可知 SSA-SVM 模型的准确度(以相关系数  $R^2$  作为评判标准)较 SVM、BP、LSTM 分别提高了 3.6%,9.1%,0.12%。虽然运用 LSTM 模型也取得了不错的预测效果,但其耗时过长,不能满足刀具寿命在线预测的要求。

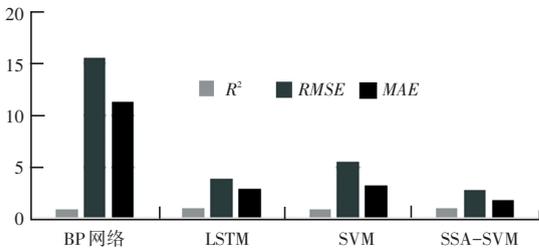


图 4 各模型精度对比

Fig. 4 Accuracy comparison of each model

表 2 预测结果统计

Tab. 2 Statistics of prediction results

	$R^2$	RMSE	MAE	Time/ s
BP 网络	0.915 1	15.611 9	11.282 2	5.516 7
LSTM	0.997 2	3.819 6	2.836 1	1 171.621 3
SVM	0.943 5	5.524 5	3.227 3	3.867 2
SSA-SVM	0.998 4	2.783 5	1.734 8	4.274 2

利用 Matlab 自带的绘图工具,用颜色不同的点分别代表样本真实值与另外 4 个模型预测值,然后用折线连起来。刀具寿命预测结果对比如图 5 所示。适应度曲线如图 6 所示。从图 5 可以更直观地比较各个模型的预测效果,得知 SSA-SVM 模型的预测精度最好,相对误差最小,与真实值最为接近。同时由图 6 可看到,SSA-SVM 模型的适应度值在迭

代至 40 后就趋于稳定,说明该模型的稳定性高,且耗时短。

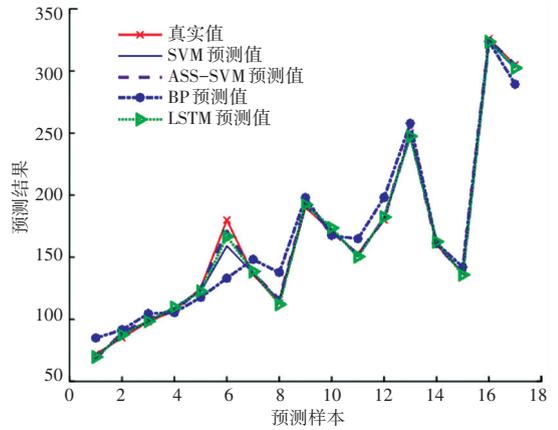


图 5 刀具寿命预测结果对比

Fig. 5 Comparison of tool life prediction results

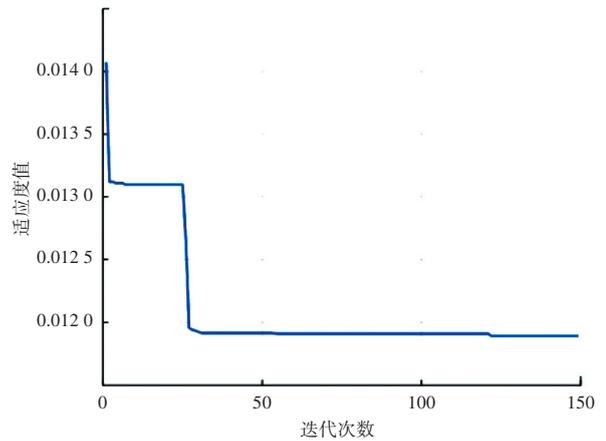


图 6 适应度曲线

Fig. 6 Fitness curve

### 4 结束语

本文构建的 SSA-SVM 刀具寿命预测模型,通过麻雀搜索算法(SSA)优化 SVM 模型参数,在正则化系数  $C$  基本不变的情况下,将核函数  $g$  由 0.062 5 提高到了 0.106 9,提升了模型对于非线性问题的泛化能力。且通过仿真实验表明:SSA-SVM 在惩罚系数  $C = 250$ ,核函数  $g = 0.106 9$  时,将刀具寿命影响因素作为变量输入,验证集的  $RMSE = 2.783 5$ ,比 BP 神经网络、SVM、LSTM 的模型准确率分别提升了 9.1%,5.6%,0.12%,且耗时仅为 4.724 7 s,满足企业智能制造系统在线预测刀具寿命的要求。

### 参考文献

[1] 郭铁成. 中国制造 2025: 智能时代的国家战略[J]. 学术前沿, 2015 (19): 54-67.