文章编号:1674-2974(2024)08-0198-13 DOI:10.16339/j.cnki.hdxbzkb.2024190

基于改进SVR算法的模具棱线磨损预测方法研究

谢晖[1,3†],蒋磊[2],刘守河[3],王龙[2],李乐平[4],孔繁涛[4]
[1. 汽车车身先进设计制造国家重点实验室(湖南大学),湖南 长沙 410082;
2. 东风本田汽车有限公司 新车型中心,湖北 武汉 430056;
3. 季华实验室,广东 佛山 528200;
4. 湖南天汽模汽车科技有限公司,湖南 长沙 410082]

摘 要:为研究汽车覆盖件模具棱线几何特征参数及成形工艺参数对棱线磨损的影响,实现对模具棱线磨损的精准预测,提出了一种基于改进SVR算法的模具棱线磨损预测模型.通过利用改进的拉丁超立方抽样(ILHS)方法获取模具棱线磨损有限元计算的实验样本,进而构建预测模型的输入参数集.通过耦合混沌理论、动态权重方法对蝗虫优化算法(GOA)进行改进,利用改进后的蝗虫优化算法(IGOA)对SVR算法关键参数进行寻优.构建了基于IGOA-SVR算法的模具棱线磨损预测模型,结合粒子群寻优算法(PSO)建立多目标优化模型,实现对模具棱线磨损的高精度预测以及几何特征参数和成形工艺参数优化.对比5种常规预测模型,基于IGOA-SVR算法的预测模型在采样点处的预测误差分别为8.546%、8.497%、8.473%,较GOA-SVR预测模型分别提高25.9%、26.2%、26.4%,预测精度相比于其他预测模型也有不同程度的提高.结果表明改进后的IGOA-SVR算法具有更高的精度.

关键词:模具磨损;蝗虫优化算法;支持向量回归;模具锐棱;粒子群寻优算法
中图分类号:TG76 **文献标志码**:A

Study on Prediction Method of Die Sharp-edged Wear Based on an Improved SVR Algorithm

XIE Hui[1,3†], JIANG Lei[2], LIU Shouhe[3], WANG Long[2], LI Leping[4], KONG Fantao[4]
[1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body(Hunnan University), Changsha 410082, China;
2. Dongfeng Honda Automobile Co. ,Ltd. , New Model Center, Wuhan 430056, China;
3. Jihua Laboratory, Foshan 528200, China;
4. TQM (Hunan) Automotive Technology Co. ,Ltd. , Changsha 410082, China]

Abstract: To study the influence of geometric characteristic parameters and forming process parameters of automobile stamping die on the sharp-edged wear and realize the accurate prediction of the die sharp-edged wear, a prediction method of the die sharp-edged wear based on improved SVR algorithm was proposed in this paper. By using the improved Latin hypercube sampling (ILHS) method, the experimental samples of finite element

* **收稿日期**:2023-05-31
基金项目:湖南省2023十大科技攻关项目(2023GK1070);广东省科技重点研发项目(X210181TB210);铝合金车身外覆盖件锐棱成形工艺及其装备产业化研发项目(202N2YCNME001)
作者简介:谢晖(1971—),男,湖南衡南人,湖南大学教授,博士
† 通信联系人,E-mail:danielxie@163.com

calculation of die sharp-edged wear were obtained, and the input parameter set of the prediction model was then constructed. The chaos theory and dynamic weights were introduced into the grasshopper optimization algorithm (GOA), and the improved grasshopper optimization algorithm (IGOA) was used to improve key parameters of the SVR algorithm. Based on the IGOA-SVR algorithm, the prediction model of die sharp-edged wear was constructed, which was combined with the particle swarm optimization (PSO) algorithm to establish a multi-objective optimization model so as to realize the high-precision prediction as well as the optimization of geometric characteristic parameters and forming process parameters. Compared with five existing conventional prediction models, the prediction errors of the prediction model based on IGOA-SVR at the sampling point were 8.546%, 8.497%, and 8.473%, respectively, which were 25.9%, 26.2%, and 26.4% higher than the GOA-SVR prediction model, respectively, and the prediction accuracy was also improved to varying degrees compared with other prediction models. The results show that the improved IGOA-SVR has higher accuracy.

Key words: die wear; grasshopper optimization algorithm; support vector regression; die sharp-edged; particle swarm optimization algorithm

汽车覆盖件模具作为高感知模具对磨损具有更高的敏感度[1],磨损不仅会对模具棱线造成破坏,还会影响生产零件棱线的清晰度,严重影响整车的外观质量.同时模具磨损是影响模具寿命的主要因素,因此实现对模具磨损的计算与预测分析是必要的.结合学者对模具磨损的研究发现,磨损是一个动态的非线性过程[2],与模具表面几何形状、表面质量、材料性能、成形工艺参数等因素有关,进而导致对模具磨损的计算成为一个复杂的问题.

针对汽车覆盖件模具磨损计算以及模具寿命预测问题,目前国内外学者大多采用有限元法(Finite Element Method,FEM)对汽车覆盖件成形过程进行模拟,采用 Archard 理论对模具磨损进行数值计算[3],进而实现对模具的寿命预测.1953 年,英国 Archard 提出磨损计算理论,此后国外学者以该理论为基础开展大量的模具磨损研究;Burwell[4]研究磨损产生的机理,并将磨损分为粘着磨损、磨粒磨损、腐蚀磨损、冲蚀磨损、疲劳磨损和微动磨损等类型,构建磨损研究的基础;Lee 等人[5]采用有限元法研究普通钢材模具的摩擦系数、模具温度对磨损量的影响;Altan 等人[6]基于模具成形中磨损、应力、应变的关系,得出磨损易发生在应力集中处的结论;Kim 等人[7]结合仿真和实验研究温度和成形速度对模具磨损的影响;陈晓航[8]通过有限元分析研究了工艺参数对模具磨损的影响,并采用 Pro-M 法和磨损累积法预测模具的疲劳寿命.谢晖等人[9]基于有限元法建立了超高强钢板冲压模具磨损预测模型,并研究了成形工艺参数对模具磨损程度的影响规律.上述学者采用有限元数值模拟的方法对模具磨损进行计算,研究了成形工艺参数对模具磨损的影响.

由于结构复杂、成形困难等原因,对覆盖件成形仿真进行建模、前处理、求解、后处理以及模具磨损数值分析等过程非常耗时.几何参数和工艺参数的变化也会导致此过程重复数次.因此,需要引入高效的寻优代理模型,预测汽车覆盖件模具磨损量,并搜寻合理的几何特征参数和成形工艺参数来指导覆盖件模具的生产与制造.

机器学习具有运算速度快、非线性拟合能力强、模型设置简单等优点[10-11].近年来,随着智能技术的快速发展,部分学者借助于机器学习算法研究冲压件缺陷预测、汽车零件回弹计算、冲压成形工艺参数优化等问题.聂昕等人[12]提出一种截面曲线图像化方法,并基于卷积神经网络模型研究工艺参数和材料参数对汽车梁类零件回弹的影响;Hambli 等人[13]基于神经网络模型研究模具间隙与材料延伸率之间的非线性关系;吴飞等人[14]基于长短时记忆网络模型,建立了刀具磨损预测模型,利用粒子群寻优算法预测模型,实现对刀具磨损的预测;刘淼等人[15]采用汽车结构件参数化方法,建立汽车结构件深度学习应力预测模型,并验证了预测模型的可行性.黄瑶等人[16]基于修正的 Archard 磨损模型,利用 BP 神经网络方法,实现对挤压模具的磨损预测.上述研究更关注于机器学习算法应用于零部件缺陷预测、零件回弹预测、零件成形参数优化等领域,应用于覆盖件模

具磨损预测领域的相关研究较少,因此将机器学习算法应用于汽车覆盖件模具的磨损预测具有一定的研究意义.针对覆盖件模具,尤其是具有锐棱特征的模具,其锐棱几何特征参数以及成形工艺参数对模具的磨损和使用寿命至关重要.由于锐棱的形状取值空间大、难控制、无规律、离散变量多、需求样本多,为了更准确地研究锐棱几何特征参数、成形工艺参数对覆盖件模具棱线处磨损的综合影响,本文以简化锐棱模具为研究对象,利用改进的拉丁超立方抽样方法,获取实验样本集,将混沌理论、动态权重方法引入蝗虫优化算法(Grasshopper Optimization Algorithm,GOA),利用改进后的蝗虫优化算法(Improved Grasshopper Optimization Algorithm,IGOA)对支持向量回归(Support Vector Regression,SVR)算法进行改进优化,实现对简化锐棱模具棱线磨损量的预测,并结合粒子群寻优(Particle Swarm Optimization,PSO)算法建立多目标优化模型,实现对几何特征参数和成形工艺参数的优化.

1 模具磨损有限元仿真计算

1.1 Archard修正计算模型

金属成形过程的磨损预测所用的常规模型是Archard[17]模型,表达式为:

$$h = K\frac{pv}{H} \tag{1}$$

式中:h为磨损量;K为常量磨损系数;p为接触表面正压力;v为接触面相对滑动速度;H为表面材料硬度.

在板料成形过程中,模具与板料之间的磨损系数会随着模具表面受到的压力以及板料接触面相对滑动速度的变化而发生改变.

以压力p和相对滑动速度v为设计变量进行磨损实验,获取不同设计变量组合下的磨损系数K,利用曲线拟合得到拟合关系式:

$$K = Q_1 p^a v^q \tag{2}$$

式中:K为磨损系数;Q_1为常数项;p为接触面正压力;v为接触面相对滑动速度;a为压力拟合指数;q为速度拟合指数.

将磨损系数和Archard磨损计算模型进行耦合,得到修正后的磨损计算公式:

$$h_i(r) = \frac{Q_1}{H}\int_{x_{i-1}}^{x_i} p_i^{a+1}(r,x)v_i^{q+1}(r,x)\mathrm{d}x \tag{3}$$

式中:r与x分别表示位移与时间的参数;i表示冲压次数;$h_i(r)$表示模具表面任意一点在i次冲压时的磨损量;x_i表示i次冲压的时间.则j次冲压后累积磨损量可以表示为:

$$h(r) = \sum_{i=1}^{j} h_i(r) \tag{4}$$

1.2 有限元仿真计算

本节主要以简化锐棱模具作为研究对象,构建简化锐棱模具冲压成形仿真计算模型.

根据前者研究[7-9,18]发现影响模具棱线磨损的主要因素包括棱线几何特征参数和成形工艺参数.其中棱线几何特征参数可以描述为棱线圆角半径R和棱线两侧夹角θ.图1所示为特征棱线断面示意图,其中d表示板料厚度;L表示棱线弧长;θ表示棱线两侧夹角;R表示棱线圆角半径,即为凸模棱线圆角半径.

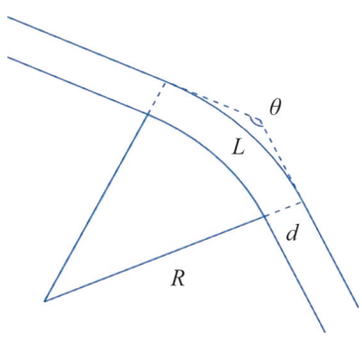


图1 特征棱线断面示意图

Fig.1 Feature prism section diagram

1.2.1 有限元仿真模型

本节以简化锐棱模具作为仿真计算对象,有限元模型如图2所示,其中包括凹模、凸模、压边圈和板料,拉延筋位置如图3所示.板料材料参数如表1所示.

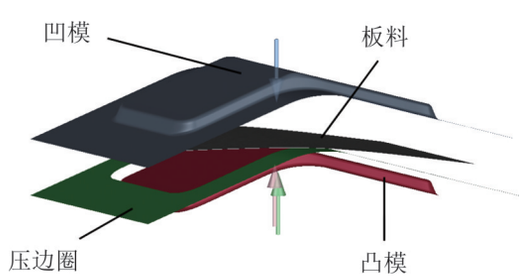


图2 有限元模型

Fig.2 Finite element model

图4所示为简化锐棱模具的特征棱线断面示意图,其中R为模具锐棱特征,A–A为特征棱线断面示意图.

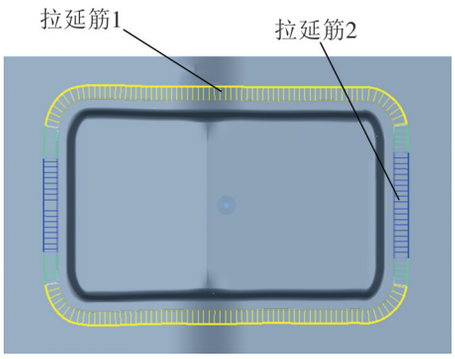


图3　等效拉延筋示意图

Fig.3　Equivalent draw-bead diagram

表1　AL6014铝合金的材料参数

Tab.1　Material parameters of AL6014

材料	数值
板料厚度/cm	0.9
弹性模量E/GPa	70
屈服强度σ_s/MPa	103.5
泊松比ν	0.3
抗拉强度σ_b/MPa	214.1
硬化指数N	0.259
材料密度ρ/(g·cm^{-3})	2.7e-05

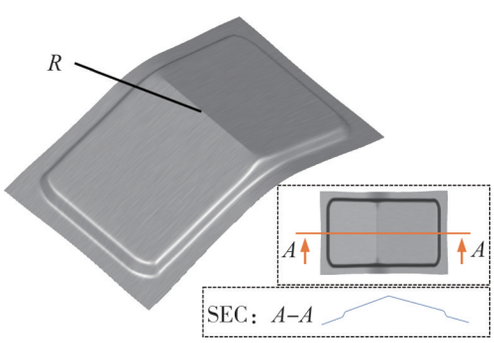


图4　简化锐棱模具断面示意图

Fig.4　Section diagram of simplified die sharp-edged

1.2.2　基于ILHS方法抽样

目前通常采用Monte Carlo、LHS(Latin Hypercube Sampling)等方法进行样本随机抽样.其中LHS方法作为一种分层抽样方法,将参数区间均分后,固定分层区间的抽样个数,导致样本参数的实际分布情况与抽样结果不符.本文结合样本参数的实际分布情况对拉丁超立方抽样方法进行改进,其抽样流程如下.

对于某一冲压成形工艺参数$X(X_{min}<X<X_{max})$,其在抽样区间的分布函数为$Y=F(X)$,根据分布函数可以求得工艺参数边界的累计分布值为$Y_{min}=F(X_{min})$和$Y_{max}=F(X_{max})$;将累计分布值区间$[Y_{min},Y_{max}]$划分为n个等距不重叠子区间$\Lambda_i=[Y_{i-1},Y_i]$,子区间集合为$\bigcup_i^n\Lambda_i=[Y_{min},Y_{max}]$($Y_0=Y_{min},Y_n=Y_{max}$),其中$Y_i$为区间$\Lambda_i$分界点,在子区间$\Lambda_i$中进行均匀抽样获取采样值$Y_z$,进而通过$Y=F(X)$求出对应参数$X_z$.

ILHS方法根据样本参数实际分布情况确定子区间Λ_i的抽样个数为U,计算公式为:

$$U=G\frac{m}{N} \tag{5}$$

式中:G为采样组工艺参数随机模拟数量;m为分布函数位于子区间Λ_i内对应的参数X的数量;N为采集到的实际工艺参数数量.

选取锐棱几何特征参数:棱线圆角半径R、棱线两侧夹角θ;成形工艺参数:冲压速度V、压边力F、等效拉延筋系数f_1、等效拉延筋系数f_2、摩擦系数μ、模具间隙λ作为设计变量.其中根据《乘用车外部凸出物》(GB11566—2009)标准和设计经验确定棱线圆角半径及夹角θ的设计范围,根据简化模具的尺寸特征和材料参数属性,结合成形分析结果和设计经验确定成形工艺参数的取值范围,选取上述设计变量的取值范围如表2所示.

表2　ILHS采样参数表

Tab.2　ILHS sampling parameters

参数	取值范围
冲压速度V/(mm·s^{-1})	300~600
压边力F/kN	45~65
等效拉延筋系数f_1	0.4~0.6
等效拉延筋系数f_2	0.4~0.6
摩擦系数μ	0.1~0.15
模具间隙λ/mm	0.8~1.2
棱线圆角半径R/mm	2~4
棱线两侧夹角θ/(°)	130~145

设定ILHS方法采样样本为360个,获取360组样本组合数据,如表3所示.

1.2.3　磨损仿真计算结果

将上述样本集进行仿真计算,设定冲压次数为80万次,获取简化锐棱模具的累积磨损量.图5所示为实验样本46的磨损量云图,模具在棱线处的磨损量如图6所示,其中棱线沿Y轴方向的坐标取值范围为Y=(0,300).

提取锐棱线上3个采样点的磨损量作为计算结果,如图7所示.棱线中点Y坐标为$Y_0=150$,采样点Y坐标为$Y_i=\{Y_1=0,Y_2=15,Y_3=30\}$,采样点$Y$坐标与棱线中点$Y$坐标比值为$W_i$,用以描述采样点在棱线上的位置.

表3 锐棱几何特征参数及成形工艺参数样本集

Tab.3 Sample of geometric characteristic parameters and forming process parameters

编号	训练样本参数值							
	θ/(°)	R/mm	V/(mm·s^{-1})	F/kN	f_1	f_2	μ	λ/mm
1	130	2	356	60.5	0.587	0.482	0.120	1.125
2	135	3	337	57.9	0.525	0.462	0.115	0.979
3	140	4	447	60.9	0.425	0.576	0.144	1.042
4	145	2	501	58.9	0.581	0.581	0.145	0.880
5	130	3	554	64.2	0.459	0.579	0.145	0.900
6	135	4	336	57.6	0.586	0.464	0.116	1.013
7	140	2	404	53.9	0.576	0.503	0.126	1.169
8	145	3	516	46.0	0.452	0.459	0.115	0.839
9	130	4	479	48.5	0.589	0.558	0.140	0.906
10	135	2	367	49.2	0.472	0.467	0.117	0.978
11	140	3	416	59.8	0.527	0.574	0.144	0.856
12	145	4	499	58.3	0.493	0.423	0.106	0.953
…	…	…	…	…	…	…	…	…
357	130	2	563	51.0	0.502	0.530	0.132	1.037
358	135	3	484	57.5	0.426	0.529	0.132	0.830
359	140	4	444	60.6	0.469	0.559	0.140	0.941
360	145	2	471	53.1	0.481	0.427	0.107	1.073

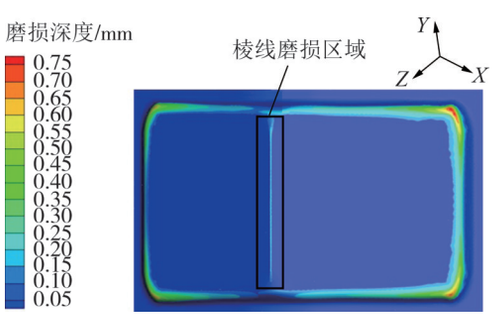


图5 磨损计算云图(样本46)

Fig.5 Wear calculation cloud(46#)

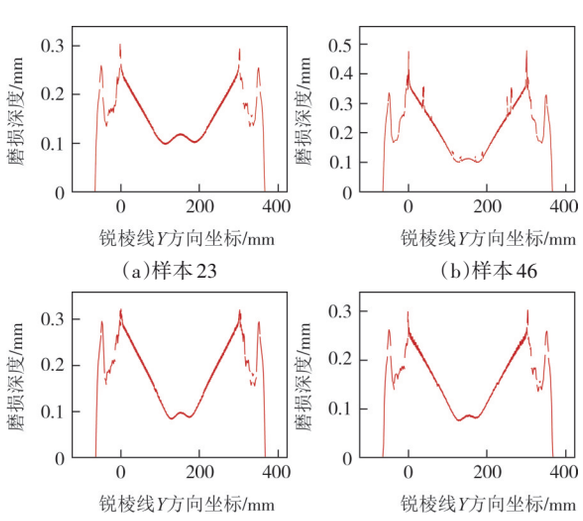


图6 锐棱模具棱线处磨损量(样本23、46、95、263)

Fig.6 Wear of the die sharp-edged(23#、46#、95#、263#)

$$W_i = \frac{Y_i}{Y_0} \tag{6}$$

取样点磨损计算量如表4所示.

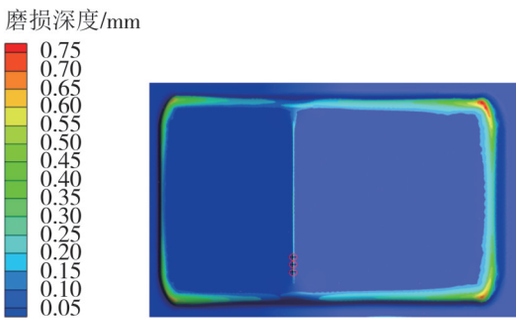


图7 棱线采集点

Fig.7 Sample points of the die sharp-edged

表4 采样点磨损量

Tab.4 Wear of the sample points

编号	采样点磨损量		
	1	2	3
1	0.582 17	0.418 01	0.366 70
2	0.409 08	0.306 01	0.289 50
3	0.660 92	0.547 03	0.520 16
4	0.658 31	0.468 93	0.484 01
5	0.653 77	0.547 69	0.475 40
6	0.309 90	0.252 53	0.228 43
7	0.324 35	0.275 94	0.258 75
8	0.207 36	0.169 41	0.151 29
9	0.431 09	0.276 82	0.243 80
10	0.279 95	0.194 30	0.177 68
11	0.335 77	0.296 95	0.270 82
12	0.158 04	0.145 36	0.129 92
…	…	…	…
357	0.484 07	0.316 57	0.290 45
358	0.425 88	0.247 77	0.224 09
359	0.346 07	0.302 08	0.274 17
360	0.154 45	0.133 07	0.118 14

2 模具棱线磨损预测模型与方法

2.1 SVR算法

SVR是基于SVM引入不敏感损失函数ε所构造的一种用于解决非线性回归问题的算法,由Drucker等人[19]提出.SVR算法的本质是通过一种映射关系将非线性回归问题投射到高维特征空间,寻找一个距离所有训练样本误差最小的回归平面,实现最大非线性回归拟合精度.根据所给输入输出训练样本建立最优决策函数表达式如下:

$$f(x)=\omega\varphi(x)+b \tag{7}$$

式中:ω为惯性因子;$\varphi(x)$为非线性的映射函数;$f(x)$为预测值.

通过引入不敏感损失函数ε和松弛变量ξ_i、ξ_i^*,最优决策函数的求解方程可以表示为:

$$\begin{cases}\min\dfrac{1}{2}\|\omega\|^2+C\sum\limits_{i=1}^{n}\left(\xi_i+\xi_i^*\right)\\ \text{s.t.}\begin{cases}y_i-\omega\phi(x_i)-b\leqslant\varepsilon+\xi_i\\-y_i+\omega\phi(x_i)+b\leqslant\varepsilon+\xi_i^*\\\xi_i\geqslant0,\xi_i^*\geqslant0\end{cases}\end{cases} \tag{8}$$

式中:C为惩罚因子;x_i为包含多个特征的输入特征向量;y_i为第i个参数的真实值.

引入拉格朗日函数,结合对偶原理,将式(8)转化为目标函数$T\left(\alpha_i^*,\alpha_i\right)$的最大值问题:

$$\begin{cases}\max T(\alpha_i^*,\alpha_i)=M_1-M_2\\M_1=-\dfrac{1}{2}\sum\limits_{i=1}^{n}(\alpha_i^*-\alpha_i)(\alpha_j^*-\alpha_j)\phi(x_i)\phi(x_j)\\M_2=\sum\limits_{i=1}^{n}\alpha_i(y_i+\varepsilon)+\sum\limits_{i=1}^{n}\alpha_i(y_i-\varepsilon)\end{cases} \tag{9}$$

$$\text{s.t.}\begin{cases}\sum\limits_{i=1}^{n}(\alpha_i-\alpha_i^*)=0\\0\leqslant\alpha_i,\alpha_i^*\leqslant C\end{cases} \tag{10}$$

式中:α_i、α_j、α_i^*、α_j^*为拉格朗日算子.

本文用于解决非线性回归问题,选择径向基核函数(RBF),其表达式为:

$$\begin{cases}K\left(x,x_i\right)=\exp\left(\dfrac{1}{2\gamma^2}\|x-x_i\|^2\right)\\g=\dfrac{1}{2\gamma^2}\end{cases} \tag{11}$$

式中:$K\left(x,x_i\right)$为核函数;g为核参数;γ为核半径.

最终SVR非线性回归方程表示为:

$$f(x)=\sum_{i=1}^{n}(\alpha_i-\alpha_i^*)K(x,x_i)+b \tag{12}$$

2.2　IGOA-SVR算法

采用IGOA算法对SVR算法中的关键参数进行优化,其中主要包括影响SVR算法回归精度的惩罚因子C、不敏感损失函数ε和核参数g.

GOA算法由于具有较强的全局和局部搜索能力,常用于解决优化配置[20]、参数优化[21]等问题.在搜寻过程中,种群之间的相互作用不断向目标靠近,与此同时算法会由于种群多样性降低,进而陷入局部最优搜寻.为避免该问题,本文基于GOA算法,通过耦合混沌理论和动态权重方法,构建了改进蝗虫优化算法,具体流程如下.

1)利用混沌映射的随机性、遍历性及初值敏感性的特点,将其用于初始化GOA种群,进而提高种群的多样性.本文采用Tent映射方法初始化GOA种群.

首先,映射搜索空间:

$$x_k^l=\frac{x_k^l-x_{\min}^l}{x_{\max}^l-x_{\min}^l} \tag{13}$$

式中:k为种群的序列号;$x_{\min}^l$为第l维的最小值;$x_{\max}^l$为第l维的最大值.

其次,生成Tent混沌映射序列:

$$x_{k+1}^l=\begin{cases}2x_k^l,0\leqslant x_k^l<0.5\\2(1-x_k^l),0.5\leqslant x_k^l\leqslant1\end{cases} \tag{14}$$

最后,将Tent混沌映射序列映射到搜索空间:

$$x_{k+1}^l=x_{\min}^l+x_{k+1}^l(x_{\max}^l-x_{\min}^l) \tag{15}$$

利用Tent映射方法初始化GOA种群,使其遍历搜索空间,提高算法的最优搜寻概率.

2)随着种群不断向搜寻目标靠近,GOA算法收敛速度变慢,为提高GOA的收敛速度,在保证全局寻优的同时,引入动态权重方法.其中GOA算法的标准公式为:

$$x_i^l=c\left(\sum_{j=1,j\neq i}^{N_u}c\frac{\mathrm{ub}_l-\mathrm{lb}_l}{2}s\left(\left|x_j^l-x_i^l\right|\right)\frac{x_j-x_i}{d_{ij}}\right)+\hat{T}_l \tag{16}$$

式中:c为动态衰减系数;N_u为种群数目;ub_l和lb_l分别为蝗虫位置在第l维的阈值上下限;s为相互作用力函数;d_{ij}为第i只蝗虫和第j只蝗虫之间的距离;$\hat{T}_l$为最优解对应的第l维的位置.

将动态权重引入标准GOA中得到:

$$x_i^l=c\left(\sum_{j=1,j\neq i}^{N_u}c\frac{\mathrm{ub}_l-\mathrm{lb}_l}{2}s\left(\left|x_j^l-x_i^l\right|\right)\frac{x_j-x_i}{d_{ij}}\right)+\eta\hat{T}_l \tag{17}$$

$$\eta=\eta_{\max}-(\eta_{\max}-\eta_{\min})(t/\mathrm{Max_iter})^2 \tag{18}$$

式中:t为迭代次数;Max_iter为最大迭代次数;η为权重系数;$\eta_{\max}$、$\eta_{\min}$分别为权重系数最大值、最小值.

通过引入混沌理论提高了蝗虫优化算法初始化种群的多样性,增强了全局寻优能力;通过引入动态

权重方法进一步提高了算法收敛速度.为了验证IGOA相比于GOA算法的收敛精度,分别利用单峰测试函数(F_1,F_2)和多峰测试函数(F_3,F_4)对IGOA进行测试,测试函数表达式如表5所示.在Matlab平台中独立运行20次后,测试结果如表6所示.

表5 测试函数表达式

Tab.5 Test function expression

测试函数	真实值
$F_1(x)=\sum_{i=1}^{D}\lvert x_i\rvert+\prod_{i=1}^{D}\lvert x_i\rvert$	0
$F_2(x)=\sum_{i=1}^{D}\left(\sum_{j=i}^{i}x_j\right)^2$	0
$F_3(x)=-20\exp\left(-0.2\sqrt{\frac{1}{D}\sum_{i=1}^{D}x_i^2}\right)-\exp\left[\frac{1}{D}\sum_{i=1}^{D}\cos(2\pi x_i)\right]+20+e$	0
$F_4(x)=\frac{1}{4\,000}\sum_{i=1}^{D}x_i^2-\prod_{i=1}^{D}\cos\left(\frac{x_i}{\sqrt{i}}\right)+1$	0

对比分析表6可以发现,从最优值、平均值和方差三个维度分析,在有限迭代次数下IGOA收敛精度均高于GOA,故耦合混沌理论和动态权重的IGOA具有更强的参数寻优能力,可以用于对SVR模型关键参数的优化.本文所提出的IGOA-SVR预测方法流程如图8所示.

表6 测试结果

Tab.6 Test results

测试函数	算法	最优值	平均值	方差
F_1	GOA	$1.025\,9\times10^{-7}$	$5.750\,6\times10^{-4}$	0.001 8
	IGOA	$8.819\,7\times10^{-31}$	$8.267\,5\times10^{-23}$	$4.182\,3\times10^{-22}$
F_2	GOA	$2.761\,4\times10^{-5}$	0.002 8	0.003 3
	IGOA	$2.043\,6\times10^{-17}$	$7.216\,9\times10^{-16}$	$5.081\,2\times10^{-16}$
F_3	GOA	$5.822\,4\times10^{-5}$	0.055 1	0.300 5
	IGOA	$8.349\,5\times10^{-11}$	$8.834\,2\times10^{-10}$	$6.154\,3\times10^{-10}$
F_4	GOA	0.014 6	0.224 7	0.150 0
	IGOA	$4.340\,8\times10^{-16}$	$9.074\,1\times10^{-14}$	$2.043\,1\times10^{-13}$

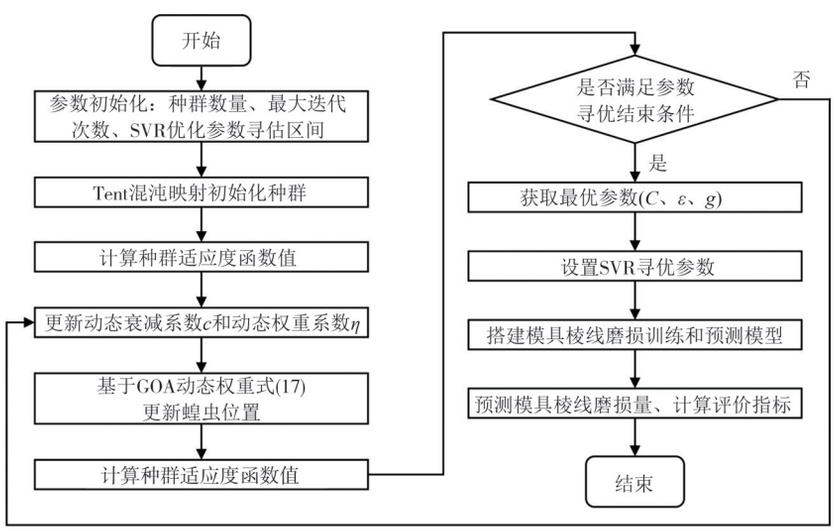


图8 IGOA-SVR预测方法流程图

Fig.8 Flow chart of IGOA-SVR

2.3 模具棱线磨损预测模型

模具棱线磨损预测模型如图9所示,预测模型主要包括:预测目标函数、预测模型输入参数集和预测模型算法.在预测目标函数中,$f(U)$表示模具棱线磨损量$P(P_1,P_2,P_3)$与预测模型输入参数集U之间的非线性关系.在预测模型输入参数集U中,主要包括棱线几何特征参数和成形工艺参数,即棱线圆角半径$U_1(R/\text{mm})$、棱线两侧夹角$U_2[\theta/(°)]$、冲压速度$U_3[V/(\text{mm}\cdot\text{s}^{-1})]$、压边力$U_4(F/\text{kN})$、等效拉延筋系数$U_5(f_1)$、等效拉延筋系数$U_6(f_2)$、摩擦系数$U_7(\mu)$、模具间隙$U_8(\lambda/\text{mm})$.在预测模型算法中,定义了求解预测目标函数的方法集IGOA-SVR,其中包括耦合混沌理论、动态权重和GOA的IGOA算法以及SVR算法.

3 模具棱线磨损预测结果分析

本节主要从训练样本、预测磨损、预测指标评价、不同预测模型对比分析等方面来阐述基于IGOA-SVR算法的模具棱线磨损预测模型的实际效果.

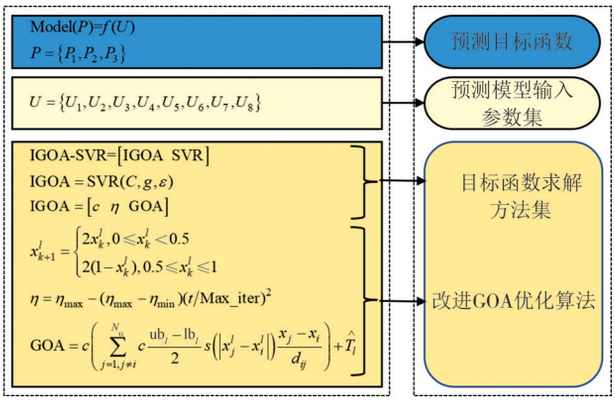


图 9　模具棱线磨损预测模型

Fig.9　Prediction model of die sharp-edged

3.1　预测模型评价指标

为了评价预测模型效果,本文采用以下指标对预测模型的精度进行评价.

1)平均绝对误差(Mean Absolute Error, MAE):

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{19}$$

2)平均绝对百分比误差(Mean Absolute Percentage Error, MAPE):

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i-\hat{y}_i}{y_i}\right| \tag{20}$$

3)均方误差(Mean Square Error, MSE):

$$\mathrm{MSE}=\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2 \tag{21}$$

4)均方根误差(Root Mean Square Error, RMSE):

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{22}$$

5)对称平均绝对百分比误差(Symmetric Mean Absolute Percentage Error, SMAPE):

$$\mathrm{SMAPE}=\frac{1}{n}\sum_{i=1}^{n}\frac{\left|y_i-\hat{y}_i\right|}{\sqrt{\left|y_i\right|+\left|\hat{y}_i\right|}} \tag{23}$$

式中:y_i为真实值;$\hat{y}_i$为预测值.

3.2　预测结果

利用第 1 节中通过ILHS获取的采样样本作为输入参数集,以有限元磨损计算获取的模具棱线磨损量作为训练样本集,其中有效样本集为360组,将其划分为训练集(324组数据)和测试集(36组数据).

模型训练步骤如下:

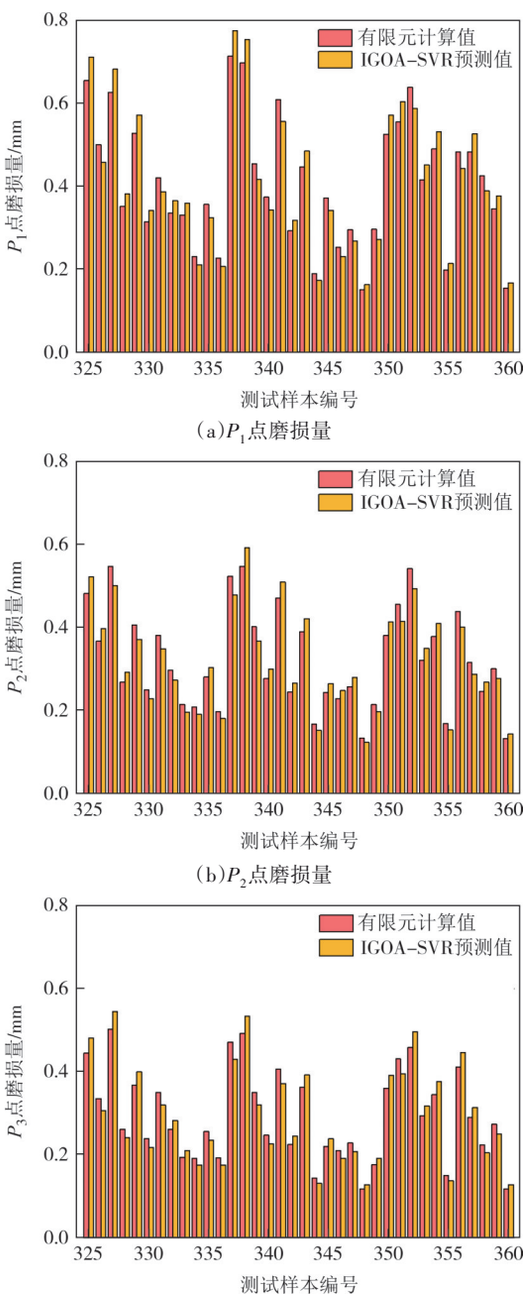
1)初始化种群数量初步设定为30,Max_iter初步设定为200;

2)设置SVR算法关键参数的寻估区间,其中惩罚因子C寻估区间为[1, 1 000]、不敏感损失函数ε寻估区间为[0, 0.3]、核参数g寻估区间为[0, 10];

3)完成对训练样本集的归一化处理;

4)利用IGOA算法对SVR模型关键参数寻优;

5)基于优化的SVR模型对模具棱线磨损量进行预测,预测结果如图10所示.



(a)P_1点磨损量

(b)P_2点磨损量

(c)P_3点磨损量

图 10　基于IGOA-SVR算法的模具棱线磨损预测结果

Fig.10　Prediction results of die sharp-edged wear based on IGOA-SVR algorithm

从图10可以看出,通过有限元计算得出的采样点处的磨损量与预测值误差较小,说明本文建立的IGOA-SVR可以较好地预测模具棱线磨损量.计算预测模型精度评价指标值,包括MAE、MAPE、MSE、RMSE、SMAPE,计算结果如表7所示.预测模型在三个采样点处的各项评价指标均处于较低水平,其中平均绝对百分比误差分别为:8.546%、8.497%、8.473%,表明预测模型具有一定的稳定性,可以用于对简化模具棱线磨损量的预测.

表7 预测模型各项评价指标值

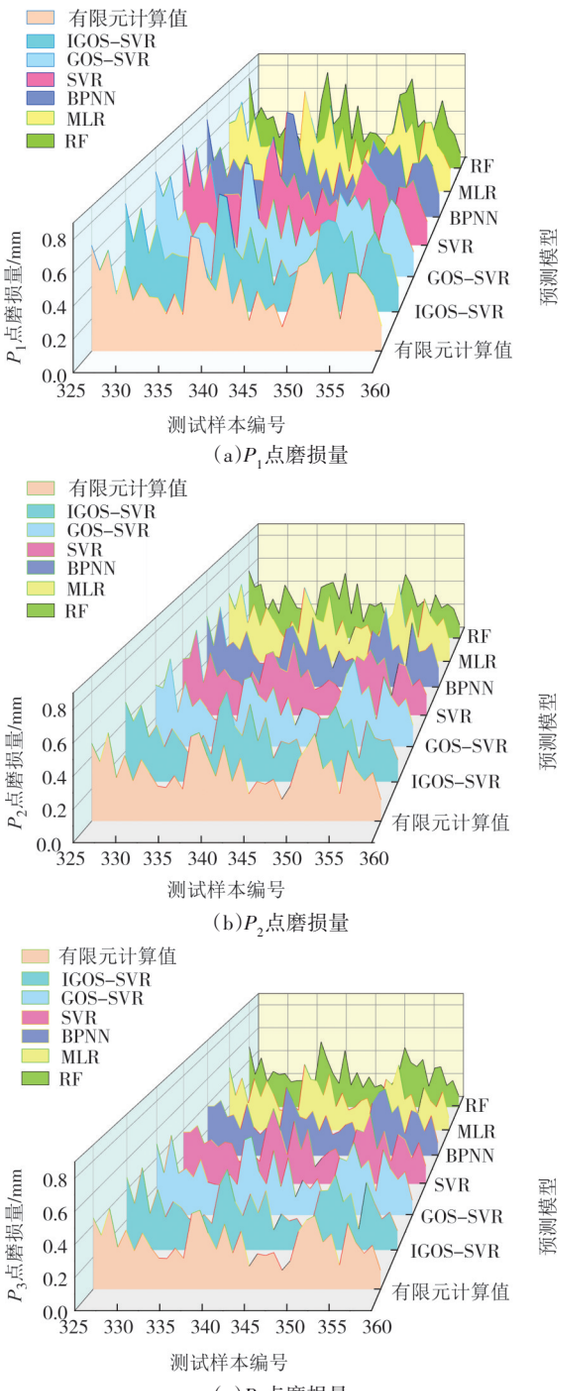
Tab.7 Evaluation index values of the prediction model

采样点	MAE/mm	MAPE/%	MSE	RMSE/mm	SMAPE
P_1	0.0349 6	8.545 51	0.001 39	0.037 27	0.037 83
P_2	0.0276 1	8.497 23	0.000 86	0.029 38	0.033 72
P_3	0.0250 0	8.473 30	0.000 71	0.026 62	0.031 99

3.3 常用预测模型对比分析

为了验证本文提出的基于IGOA-SVR方法的模具棱线磨损预测模型的优越性,将IGOA-SVR预测模型与基于GOA-SVR、SVR、反向传播神经网络(Back Propagation Neural Network, BPNN)、多元线性回归(Multiple Linear Regression, MLR)、随机森林(Random forest, RF)方法搭建的常规预测模型进行对比.常规预测模型的预测结果如图11所示,从图中可以看出常规预测模型和基于IGOA-SVR方法的预测模型都可以用于预测模具棱线磨损量,几种预测模型均具有较高的预测精度.

利用MAE、MAPE、MSE、RMSE、SMAPE等误差指标对预测模型进行对比分析,对比结果如表8~表10以及图12所示.从列表和图示中可以看出,相比于常规预测模型,基于IGOA-SVR方法的预测模型误差评价指标更小,在模具棱线P_1点处,基于IGOA-SVR方法的MAE、MAPE、MSE、RMSE、SMAPE分别为0.034 96 mm、8.546%、0.001 39、0.037 27 mm和0.037 83;在模具棱线P_2点处,基于IGOA-SVR方法的MAE、MAPE、MSE、RMSE、SMAPE分别为0.027 61 mm、8.497%、0.000 86、0.029 38 mm和0.033 72;在模具棱线P_3点处,基于IGOA-SVR方法的MAE、MAPE、MSE、RMSE、SMAPE分别为0.025 00 mm、8.473%、0.000 71、0.026 62 mm和0.031 99,相较于GOA-SVR和SVR方法有明显降低.表11为IGOA-SVR和GOA-SVR方法在采样点处平均绝对百分比误差指标的对比结果,二者对比



(a)P_1点磨损量

(b)P_2点磨损量

(c)P_3点磨损量

图11 常规预测模型预测结果对比

Fig.11 Comparisons of prediction results obtained by general predication methods

分析表明通过将混沌理论、动态权重方法与GOA耦合,可以解决GOA方法容易陷入局部最优的问题,提高全局寻优能力,进而实现了对SVR关键参数的寻优功能,提高了模具棱线磨损预测模型的预测精度.与SVR、BP、MLR、RF方法相比,IGOA-SVR方法的误差评价指标同样为最小,进一步说明基于

IGOA-SVR方法搭建的预测模型在预测模具棱线磨损问题上优于常规预测算法.

表8　采样点P_1预测模型对比分析结果

Tab.8　Comparison and analysis results of prediction models for P_1

预测模型	MAE/mm	MAPE/%	MSE	RMSE/mm	SMAPE
IGOA-SVR	0.034 96	8.545 51	0.001 39	0.037 27	0.037 83
MLR	0.061 44	14.973 51	0.004 32	0.065 71	0.066 19
BPNN	0.057 38	14.014 56	0.003 75	0.061 27	0.062 46
SVR	0.053 06	13.001 64	0.003 23	0.056 84	0.057 15
GOA-SVR	0.047 26	11.532 13	0.002 55	0.050 46	0.051 10
RF	0.071 91	17.548 15	0.005 91	0.076 88	0.078 51

表9　采样点P_2预测模型对比分析结果

Tab.9　Comparison and analysis results of prediction models for P_2

预测模型	MAE/mm	MAPE/%	MSE	RMSE/mm	SMAPE
IGOA-SVR	0.027 61	8.497 23	0.000 86	0.029 38	0.033 72
MLR	0.049 05	15.101 67	0.002 72	0.052 15	0.058 85
BPNN	0.045 19	13.898 91	0.002 31	0.048 09	0.055 47
SVR	0.043 32	13.220 77	0.002 17	0.046 60	0.052 64
GOA-SVR	0.037 53	11.516 89	0.001 60	0.040 01	0.045 68
RF	0.057 65	17.706 91	0.003 77	0.061 43	0.070 57

表10　采样点P_3预测模型对比分析结果

Tab.10　Comparison and analysis results of prediction models for P_3

预测模型	MAE/mm	MAPE/%	MSE	RMSE/mm	SMAPE
IGOA-SVR	0.025 00	8.473 30	0.000 71	0.026 62	0.031 99
MLR	0.044 32	14.925 20	0.002 25	0.047 39	0.056 81
BPNN	0.041 54	14.173 70	0.001 93	0.043 97	0.053 30
SVR	0.038 45	13.034 68	0.001 69	0.041 08	0.049 11
GOA-SVR	0.034 01	11.508 82	0.001 31	0.036 25	0.042 99
RF	0.051 89	17.572 30	0.003 06	0.055 29	0.066 98

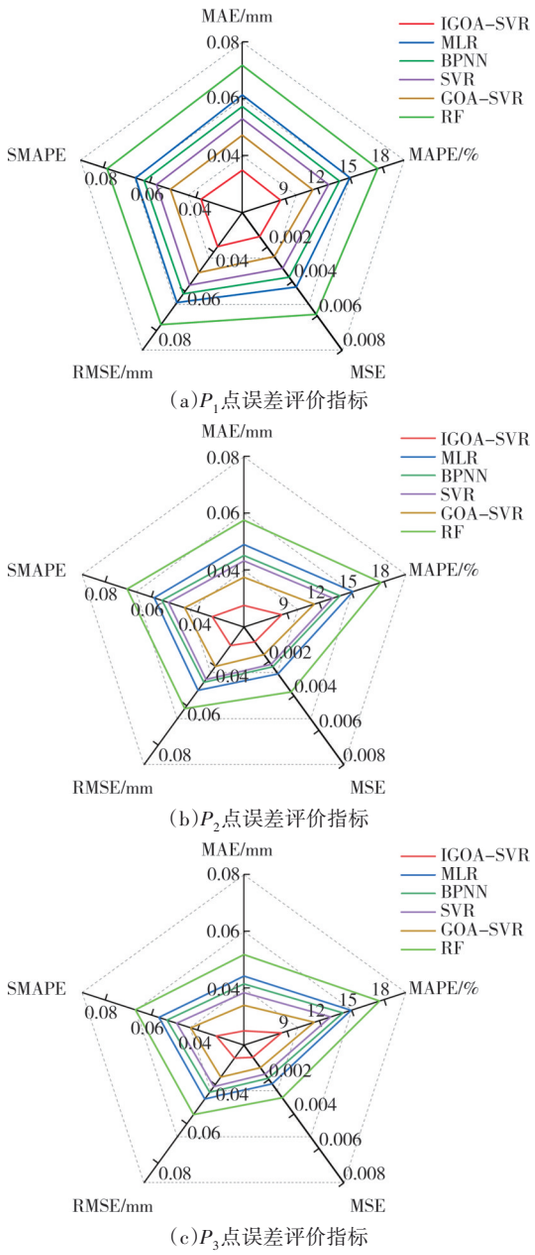
表 11　平均绝对百分比误差指标对比分析

Tab.11　Comparative and analysis of mean absolute percentage error

预测模型	平均绝对百分比误差/%		精度提高百分比/%
	IGOA-SVR	GOA-SVR	
P_1	8.545 51	11.532 13	25.9
P_2	8.497 23	11.516 89	26.2
P_3	8.473 30	11.508 82	26.4

图 13 所示为预测模型的收敛曲线,相较于GOS-SVR方法,改进后的蝗虫优化算法IGOS-SVR收敛速度更快,收敛精度更高.

综上,本文构建的基于IGOA-SVR模具棱线磨损预测模型具有预测精度较高、设置参数少、预测精度高、寻优速度快等特点,可以用于模具设计阶段,实现对模具棱线磨损量的快速预测,为模具棱线的几何特征参数设置和成形工艺参数设置提供一定的指导意义.



(a)P_1点误差评价指标

(b)P_2点误差评价指标

(c)P_3点误差评价指标

图 12　预测模型评价指标对比分析

Fig.12　Comparative analysis of evaluation indicators for prediction models

3.4　粒子群多目标优化

粒子群优化(PSO)算法是由 Kennedy 等人所提出的一种模拟自然界群体觅食行为的智能优化方法,在全局范围内具有较强的寻优能力.其主要通过在迭代过程中更新粒子的速度和位置,进而寻求空间的最优解.

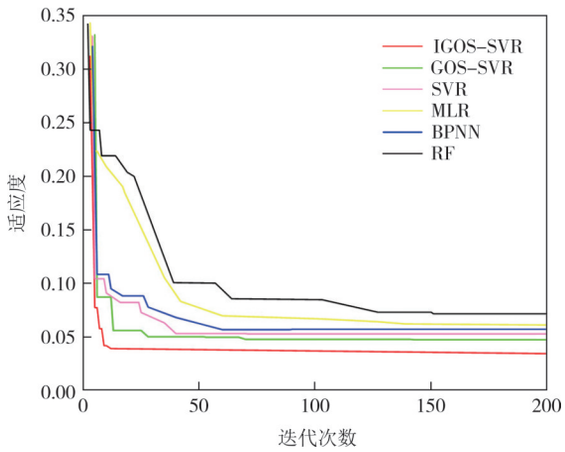


图 13 预测模型收敛曲线图

Fig.13 Convergence curve of prediction models

本节采用IGOA-SVR-PSO方法,实现对模具棱线磨损预测模型中几何特征参数与成形工艺参数的最优解,其主要流程如下.

1)建立目标函数.根据模具棱线磨损预测模型的数学模型,将模具棱线磨损量$P(P_1,P_2,P_3)$作为优化目标.

$$\min \psi_1 f_1(U) + \psi_2 f_2(U) + \psi_3 f_3(U) \tag{24}$$

式中:$f_1(U)$、$f_2(U)$、$f_3(U)$表示采样点磨损量关于优化变量的目标函数;ψ_1、ψ_2、ψ_2为目标函数的权重因子.

2)选取优化变量.根据模具棱线磨损预测模型的数学模型,主要包括棱线几何特征参数和成形工艺参数.

3)建立约束条件.设置优化变量的寻优范围:

$$\text{s.t.}\begin{cases} 2 \leqslant U_1 \leqslant 4 \\ 130 \leqslant U_2 \leqslant 145 \\ 300 \leqslant U_3 \leqslant 600 \\ 45 \leqslant U_4 \leqslant 65 \\ 0.4 \leqslant U_5, U_6 \leqslant 0.6 \\ 0.1 \leqslant U_7 \leqslant 0.15 \\ 0.8 \leqslant U_8 \leqslant 1.2 \end{cases} \tag{25}$$

4)设定参数.PSO参数分别设为:惯性因子$\hat{\omega}$ = 0.8;速度因子分别为$\lambda_1 = 2$、$\lambda_2 = 1$;迭代次数设置为200;种群数量设置为100.

基于IGOA-SVR-PSO的参数优化方法流程图如图14所示,模型收敛曲线如图15所示.经过多次迭代,结果收敛于4、145、313、50.7、0.468、0.463、0.116、0.972附近,故通过粒子群寻优算法得到的最优参数如表12所示.

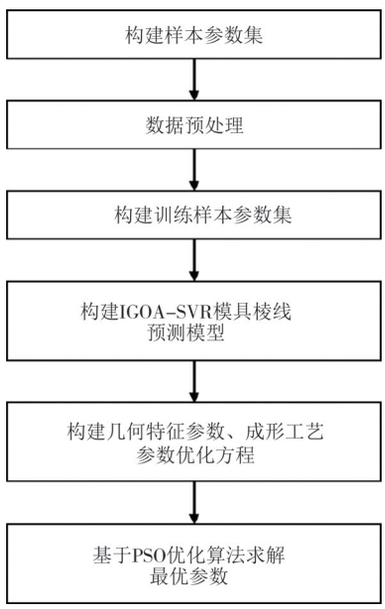


图 14 基于IGOA-SVR-PSO的参数优化方法流程图

Fig.14 Flow chart of parameter optimization method based on IGOA-SVR-PSO

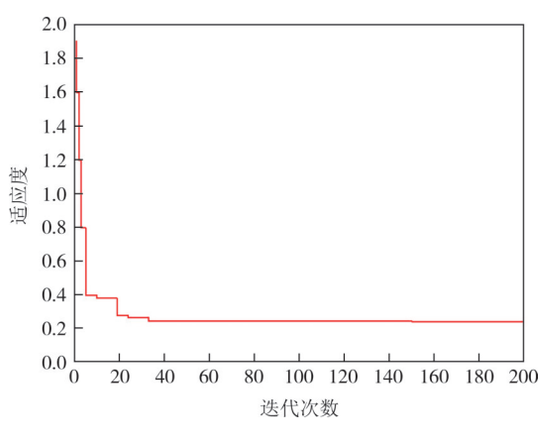


图 15 PSO收敛曲线图

Fig.15 PSO convergence curve

表 12 优化后参数及对应预测结果

Tab.12 Optimized parameters and the corresponding prediction results

优化后的参数								磨损量预测结果/mm		
R/mm	θ/(°)	V/(mm·s^{-1})	F/kN	f_1	f_2	μ	λ/mm	P_1	P_2	P_3
4	145	313	50.7	0.468	0.463	0.116	0.972	0.092 65	0.081 12	0.067 63

将粒子寻优算法得到的最优参数进行有限元仿真计算,计算磨损量.通过计算得到采样点处的磨损量分别为:P_1点0.085 41 mm、P_2点0.088 52 mm、P_3点0.062 10 mm,与预测值相比误差分别为:P_1点

8.477%、P_2点-8.360%、P_3点8.905%.通过对参数寻优得到最优解,对应的预测磨损量和计算值均明显减小,说明粒子群寻优算法的有效性.

4 结论

本文采用IGOA-SVR方法,以具有锐棱特征的简化模具替代模型为研究对象,对覆盖件模具锐棱特征线处磨损进行预测研究,主要内容和成果如下.

1)将混沌理论、动态权重方法与GOA耦合,提出了改进蝗虫优化算法(IGOA),提高了对SVR模型关键参数的寻优能力.

2)建立了具有锐棱特征的简化模具,基于IGOA-SVR算法,搭建了模具棱线磨损预测模型,在采样点处的预测误差分别为8.546%、8.497%、8.473%,实现了对模具棱线处磨损量的精确预测.

3)将IGOA-SVR方法与常规预测方法进行对比分析,分别对模具棱线磨损量进行预测.结果表明,基于IGOA-SVR方法的预测模型的预测精度更高、收敛速度更快.

4)基于IGOA-SVR-PSO方法对影响模具棱线磨损的几何特征参数和成形工艺参数进行优化,获取最优参数为棱线圆角半径4 mm、棱线两侧夹角145°、冲压速度313 mm/s、压边力50.7 kN、等效拉延筋系数f_1=0.468、等效拉延筋系数f_2=0.463、摩擦系数0.116、模具间隙0.972 mm,对应的采样点处的磨损量分别为:P_1点0.085 41 mm、P_2点0.088 52 mm、P_3点0.062 10 mm.

参考文献

[1] 乔晓勇.车身覆盖件模具磨损机理及寿命预测研究[D].长沙:湖南大学,2019.
QIAO X Y. The research on automobile body covering parts die wear mechanism and the life prediction [D]. Changsha: Hunan University,2019.(in Chinese)

[2] 聂昕,宁敏清,乔晓勇. 基于动态模型的冲压模具磨损寿命研究[J]. 中国公路学报,2018,31(3):133-141.
NIE X,NING M Q,QIAO X Y. Research on stamping die wear life based on dynamic model[J]. China Journal of Highway and Transport,2018,31(3):133-141.(in Chinese)

[3] DYCK T,OBER-WÖRDER P,BUND A. Calculation of the wear surface and the coefficient of friction for various coated contact geometries[J]. Wear,2016,368/369:390-399.

[4] BURWELL J T Jr. Survey of possible wear mechanisms [J]. Wear,1957, 1(2): 119-141.

[5] LEE R S, JOU J L. Application of numerical simulation for wear analysis of warm forging die[J]. Journal of Materials Processing Technology,2003,140(1/3):43-48.

[6] ALTAN T, KNOERR M. Application of the 2D finite element method to simulation of cold-forging processes [J]. Journal of Materials Processing Technology,1992,35(3/4):275-302.

[7] KIM D H,LEE H C,KIM B M,et al. Estimation of die service life against plastic deformation and wear during hot forging processes[J]. Journal of Materials Processing Technology, 2005, 166(3): 372-380.

[8] 陈晓航.基于数值模拟的厚板小孔类模具寿命预测与失效分析研究[D].重庆:重庆理工大学,2013.
CHEN X H. Life prediction and failure analysis of the punching die for small holes on thick plate based on numerical simulation [D]. Chongqing: Chongqing University of Technology, 2013. (in Chinese)

[9] 谢晖,李江曼,王诗恩,等. 超高强钢板冲压模具磨损CAE分析研究与应用[J]. 湖南大学学报(自然科学版), 2015, 42(8):15-21.
XIE H,LI J M,WANG S E,et al. Research and application of die wear CAE analysis of ultra high strength steel stamping[J]. Journal of Hunan University (Natural Sciences), 2015, 42(8): 15-21.(in Chinese)

[10] 陈仁朋,戴田,张品,等. 基于机器学习算法的盾构掘进地表沉降预测方法[J]. 湖南大学学报(自然科学版), 2021, 48(7): 111-118.
CHEN R P, DAI T, ZHANG P, et al. Prediction method of tunneling-induced ground settlement using machine learning algorithms[J]. Journal of Hunan University (Natural Sciences), 2021, 48(7): 111-118.(in Chinese)

[11] 段亮,宋春元,刘超,等. 基于机器学习的高速列车轴承温度状态识别[J]. 吉林大学学报(工学版), 2022, 52(1): 53-62.
DUAN L,SONG C Y,LIU C,et al. State recognition in bearing temperature of high-speed train based on machine learning algorithms [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(1): 53-62.(in Chinese)

[12] 聂昕,谭天,申丹凤. 基于深度学习的汽车梁类件冲压回弹研究[J]. 中国机械工程, 2023, 34(7): 838-846.
NIE X,TAN T,SHEN D F. Research on stamping springback of automobile beam parts based on deep learning [J]. China

Mechanical Engineering,2023,34(7):838-846.(in Chinese)

[13] HAMBLI R, GUERIN F. Application of a neural network for optimum clearance prediction in sheet metal blanking processes [J]. Finite Elements in Analysis and Design, 2003, 39(11): 1039-1052.

[14] 吴飞,农皓业,马晨浩. 基于粒子群优化算法-长短时记忆模型的刀具磨损预测方法[J]. 吉林大学学报(工学版),2023,53(4):989-997.
WU F,NONG H Y,MA C H. Tool wear prediction method based on particle swarm optimization long and short time memory model [J]. Journal of Jilin University (Engineering and Technology Edition),2023,53(4):989-997.(in Chinese)

[15] 刘淼,孙成智,王潇嵩. 基于深度学习的汽车结构件应力预测方法[C]//2021 中国汽车工程学会年会论文集 4. 北京: 机械工业出版社, 2021.
LIU M, SUN C Z, WANG X S. Stress prediction method of automobile structural part based on deep learning [C]//China Society of Automotive Engineers. Beijing: China Machine Press, 2021.

[16] 黄瑶, 孙宪萍, 王雷刚, 等. 基于 BP 神经网络的挤压模具磨损预测[J]. 塑性工程学报,2006, 13(2):64-66.
HUANG Y, SUN X P, WANG L G, et al. Wear prediction of extrusion die based on BP neutral networks [J]. Journal of Plasticity Engineering,2006,13(2):64-66.(in Chinese)

[17] ERIKSEN M. The influence of die geometry on tool wear in deep drawing[J]. Wear,1997,207(1/2):10-15.

[18] 蒋磊,贾倩茹,谢晖,等. 基于 SVR 模型的双锐棱铝合金翼子板成形工艺优化[J]. 制造技术与机床,2022(12): 113-120.
JIANG L, JIA Q R, XIE H, et al. Forming process optimization of double-sharp-edged aluminum alloy fender based on SVR model [J]. Manufacturing Technology & Machine Tool, 2022(12): 113-120.(in Chinese)

[19] DRUCKER H, BURGES C J C, KAUFMAN L, et al. Support vector regression machines [C]//Proceedings of the 9th International Conference on Neural Information Processing Systems. Denver, Colorado: ACM, 1996: 155-161.

[20] GAMPA S R, JASTHI K, GOLI P, et al. Grasshopper optimization algorithm based two stage fuzzy multiobjective approach for optimum sizing and placement of distributed generations, shunt capacitors and electric vehicle charging stations [J]. Journal of Energy Storage, 2020, 27: 101117.

[21] HESHMATI M, NOROOZIAN R, JALILZADEH S, et al. Optimal design of CDM controller to frequency control of a realistic power system equipped with storage devices using grasshopper optimization algorithm [J]. ISA Transactions, 2020, 97: 202-215.