

DOI: 10.19344/j.cnki.issn1671-5276.2025.02.033

基于 GWO-LSTM 的航空零件质量预测方法

尹佳¹, 张思超², 贾保国¹, 段晓蕊¹, 张茜³

(1. 中航西安飞机工业集团股份有限公司, 陕西 西安 710089;

2. 西安电子科技大学 机电工程学院, 陕西 西安 710071;

3. 中国电子科技集团公司第十研究所, 四川 成都 610036)

摘要: 为了提高航空零件的加工质量, 使用深度学习算法对原始加工误差数据集进行增强, 构建长短记忆神经网络预测未来零件的误差, 并使用灰狼算法对预测模型关键参数进行优化。实验结果表明: 与传统的深度学习质量预测方法对比, 质量预测精度有明显提升。因此, GWO-LSTM 可以有效提高航空零件质量预测精度, 提高产品生产质量, 具有一定的工程实践价值。

关键词: 航空零件; 质量预测; 参数优化; 样本增强; 长短记忆神经网络; 灰狼算法

中图分类号: V262.3 **文献标志码:** B **文章编号:** 1671-5276(2025)02-0170-07

Quality Prediction Method of Aerospace Parts Based on GWO-LSTM

YIN Jia¹, ZHANG Sichao², JIA Baoguo¹, DUAN Xiaorui¹, ZHANG Qian³

(1. AVIC Xi'an Aircraft Industry Group Company Ltd., Xi'an 710089, China;

2. School of Electro Mechanical Engineering, Xidian University, Xi'an 710071, China;

3. The 10th Research Institute of China Electronics Technology Group Corporation, Chengdu 610036, China)

Abstract: In order to improve the machining quality of aerospace parts, the deep learning algorithm was used to enhance the original machining-errors data set, the long short-term memory was constructed to predict the errors of future parts, and the grey wolf algorithm was applied to optimize the key hyperparameters of the prediction model. The experimental result shows that the accuracy of the improved deep learning method for quality prediction is significantly raised compared with the traditional one. Thus, GWO-LSTM can effectively improve the accuracy of quality prediction of aerospace parts as well as the production quality, which has a certain engineering practice value.

Keywords: aerospace parts; quality prediction; parameter optimization; sample enhancement; long short-term memory; grey wolf algorithm

0 引言

航空零件具有多品种、小批量、加工难度大、精度要求高等特点。构建质量预测模型可以把握航空零件未来的加工生产情况, 对于将失控的产品提前修改相应的工艺参数, 减少或消除影响产品加工质量的不良因素, 以达到提高产品精度和质量的要求。

国内外学者对产品加工质量预测进行了诸多研究。苏欣等^[1]利用热力图分析和特征重要度分析提取影响质量的强相关特征参数, 并采用 Xgboost 机器学习算法分别进行质量预测分析; 蒋金瑜^[2]采用蜻蜓算法对选取复杂机械产品质量预测特征, 建立 DA-Xgboost 模型对产品质量进行有

效预测; 秦永涛等^[3]基于小波去噪和递推偏最小二乘方法对加工过程的质量实现成功预测; 高玉明等^[4]采用 LSSVM 对产品加工过程进行量化分析, 并使用 GBO 算法对 LSSVM 模型中的惩罚函数与核函数寻优, 实现了多品种、小批量产品质量预测。

针对产品加工质量预测算法的优化方法也是近年来的研究热门。杨建新等^[5]采用郊狼算法对 LSSVM 模型进行优化, 实现了复杂零件的多工序质量预测; 侯红玲等^[6]利用遗传算法对 BP 神经网络权值和阈值进行优化, 有效提高内螺纹挤压质量, 降低实际加工成本; ZHAO 等^[7]提出了一种基于人工蜂群算法优化的人工神经网络模型 (ABC-ANN) 对冷轧带钢的平面度进行预测, 相

基金项目: 陕西省科技重大专项项目 (2019zdx01-01-02)

第一作者简介: 尹佳 (1981—), 男, 辽宁黑山人, 研究员级高工, 研究方向为航空制造技术, 695468617@qq.com。

较于传统预测模型,精度得到了有效提升。

现有研究中深度学习算法和优化方法较为传统,其神经网络架构较为简单,参数优化较为简便,预测精度及优化效果具有一定的提升空间。本文使用CTGAN算法对原始数据进行增强,构建基于GWO(grey wolf algorithm)算法改进的LSTM(long short-term memory)预测模型,有效提高了对未来航空零件加工质量的预测精度。

1 航空零件质量预测方法研究

1.1 数据处理方法

1) CTGAN 数据增强

部分航空零件批量较小,数据量难以支撑深度学习模型拟合出加工数据的特征,因此需要对原始数据进行增强,扩大原始数据样本容量。

CTGAN (condition tabular generative adversarial networks) 是一种使用生成对抗网络(generative adversarial networks, GAN)^[8]数据增强的方法由XU等^[9]提出。该算法在GAN的基础上,使用一种特定的归一化技术 mode-specific normalization 用于处理包含非高斯和多模态分布的数据,同时使用条件生成器和抽样训练方法来解决类不平衡问题^[10],对表格类型的数据增强效果显著。

2) 标准化、归一化处理

航空零件误差数据中量纲、数量级不同等问题会降低深度学习预测模型的精度,因此需要对原始数据进行标准化、归一化处理。

1.2 航空零件预测方法

航空零件加工质量随着时间推移不断变化,因此,可以将航空零件误差数据看作一个时序数据集。航空零件质量和误差之间存在极大的关联性,使用合适的深度学习模型可以挖掘出两者间非线性的关联影响,进而实现未来航空零件的质量预测。

长短记忆神经网络LSTM是一种具有记忆性的神经网络,由于其独特的“门”结构,该网络可处理时间序列中间隔时间较长的数据,其网络参数会随着输入序列而更新,同时会选择记住和遗忘输入序列里的相关信息^[11],有效避免了梯度消失和梯度爆炸的问题,能实现航空零件质量的预测任务。

LSTM的神经元结构如图1所示。LSTM神经元包括记忆细胞和输入门、遗忘门、输出门3个

门结构,其计算公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

式中: x_t 表示当前输入; h_{t-1} 表示上一个神经元的输出; i_t 、 f_t 、 o_t 分别表示输入门、遗忘门、输出门的计算结果; W_f 、 W_i 、 W_c 、 W_o 分别表示遗忘门、输入门、记忆细胞、输出门的权重; b_f 、 b_i 、 b_c 、 b_o 分别表示遗忘门、输入门、记忆细胞、输出门的偏置项; h_t 为当前神经元的输出。

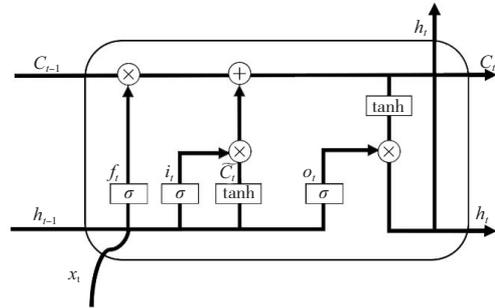


图1 LSTM结构示意图

LSTM神经网络采用链式结构,上一个神经元的输出会作为下一个神经元输入的一部分,结合神经元内部的“门”结构,实现了对时序数据特征的有效提取。

1.3 预测模型优化方法

LSTM航空零件质量模型中含有诸多参数,参数的取值也会对预测结果产生明显的影响,因此需要使用优化算法对预测模型中的关键参数进行寻优。

灰狼优化算法(grey wolf optimization, GWO)由MIRJALILI等^[12]提出,该算法通过模拟灰狼群体中的等级制度和捕食行为,最终获得参数的最优解。

GWO算法中将灰狼群体划分为4个等级:第1等级为 α 狼,是整个狼群的领导者,即算法的最优解;第2等级为 β 狼,负责辅助 α 狼管理狼群,即算法的优解;第3等级为 δ 狼,需要听从 α 狼和 β 狼的指令进行侦察、捕食等行为,即算法的次优解;第4等级为 ω 狼,是等级最低的狼,听从前3个等级狼的领导。

狼群的捕食过程用式(7)、式(8)两个公式定义:

$$D = CX_p(t) - X(t) \quad (7)$$

$$X(t+1) = X_p(t) - AD \quad (8)$$

式中: D 表示灰狼和猎物间的距离; t 表示迭代次数; X_p 表示猎物位置; X 表示灰狼位置; A 、 C 均为系数,如式(9)、式(10)所示。

$$A = 2ar_1 - a \quad (9)$$

$$C = 2r_2 \quad (10)$$

式中: r_1 、 r_2 均为 $[0, 1]$ 间的随机数; a 为收敛因子,随着 t 的增大线性减小到0,如式(11)所示。

$$a = 2 - \frac{t}{t_{\max}} \quad (11)$$

式中 t_{\max} 为最大迭代次数。

狼群在捕食过程中识别猎物的位置并包围他们,在识别到猎物位置之后, ω 狼在 α 、 β 、 δ 狼的指挥下向猎物存在的方向搜寻,进而更新狼群的位置。该过程的数学模型如式(12)、式(13)、式(14)所示。

$$\begin{cases} D_\alpha = C_1 X_\alpha - X \\ D_\beta = C_2 X_\beta - X \\ D_\delta = C_3 X_\delta - X \end{cases} \quad (12)$$

$$\begin{cases} X_1 = X_\alpha - A_1 D \\ X_2 = X_\beta - A_2 D \\ X_3 = X_\delta - A_3 D \end{cases} \quad (13)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (14)$$

式中: D_α 、 D_β 、 D_δ 分别表示 α 、 β 、 δ 狼与其他个体间的距离; X_α 、 X_β 、 X_δ 分别为 α 、 β 、 δ 狼的当前位置; C_1 、 C_2 、 C_3 为随机向量; X 表示灰狼的当前位置。

2 建模思路

航空零件加工过程受到多方面因素影响,加工质量难以监测。因此,本文提出了一种基于GWO-LSTM的航空零件质量预测方法,利用航空零件加工误差数据,挖掘零件质量和误差数据之间的关联规律,并使用长短记忆网络LSTM对未来零件质量进行预测,使用灰狼算法GWO对预测模型参数进行优化,步骤如图2所示。

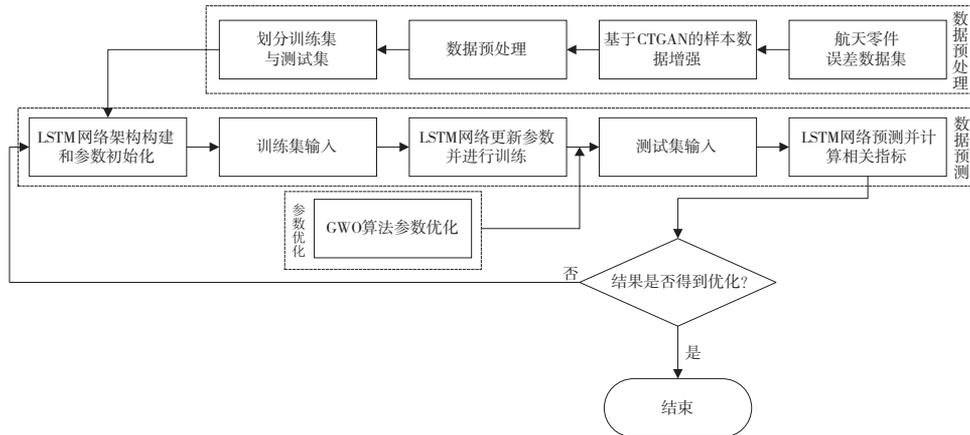


图2 模型预测流程图

2.1 数据预处理

本文使用CTGAN算法对原始样本进行增强。将航空零件误差数据作为输入,设置训练批次和训练次数,最后将扩充后的数据与原始数据进行对比,观察数据的分布情况是否相似。

对增强后的误差数据依次采用Min-Max方法和Z-score方法进行标准化,将误差数据全部映射到 $[0, 1]$ 区间内且服从标准正态分布,如式(15)、式(16)所示。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

$$x' = \frac{x - \mu}{\sigma} \quad (16)$$

式中: x_{\max} 为样本数据中的最大值; x_{\min} 为样本数据中的最小值; μ 为样本数据的均值; σ 为样本数据的标准差。

2.2 数据预测

将预处理后的误差数据输入到LSTM网络中进行预测,挖掘数据间的关联性,得到预测值,并计算预测值与真实值的方均根误差RMSE。

2.3 参数优化

根据预测模型的RMSE,使用GWO算法对预测模型参数集 $X = (x_1, x_2, \dots, x_k)$ 向RMSE减小的方向进行迭代优化,当迭代次数达到设置的最大值时得到预测模型参数优化的最终结果 $X_{op} =$

$(x_{1op}, x_{2op}, \dots, x_{kop})$, 并将 X_{op} 作为预测模型的参数对误差数据进行预测。

3 实验分析

3.1 实验数据说明

实验数据为某飞机制造厂航空零件的加工数

据。该零件先后对正反面进行加工,之后使用Creo软件进行三维建模,读取8组表面特征(正反一一对应的16个点)的空间坐标,经过点云配准后计算出8个表面特征的同轴度误差数据,构成航空零件误差数据集。其中,每个特征共有数据158条,部分数据如表1所示。

表1 某航空产品加工误差数据集

特征 1	特征 2	特征 3	特征 4	特征 5	特征 6	特征 7	特征 8
0.038 41	0.018 11	0.045 54	0.030 15	0.047 53	0.049 09	0.044 10	0.037 73
0.021 93	0.033 24	0.031 40	0.026 42	0.014 31	0.018 02	0.049 49	0.045 10
0.042 29	0.047 09	0.030 80	0.029 06	0.009 43	0.027 73	0.046 09	0.044 38
...

3.2 实验环境

实验处理器使用 Intel (R) Core (TM) i5-6500 CPU @ 3.20 GHz 3.19 GHz, RAM 为金士顿 DDR4 2 666 MHz 16 GB, 硬盘为希捷 ST1000DM003-1SB102 1 TB; 基于 Python 3.8.5、Tensorflow-cpu 2.3.0 深度学习框架编译程序。

3.3 模型验证

1) 数据预处理

使用 CTGAN 算法将航空零件误差数据集每个特征的数据增强到 1 000 条。GAN 网络的输入为 8 个特征的全部数据, 训练迭代次数设置为 500 次, 训练批次设置为 4, 增强后的 8 个特征数据分布和原始数据分布对比如图 3 所示。

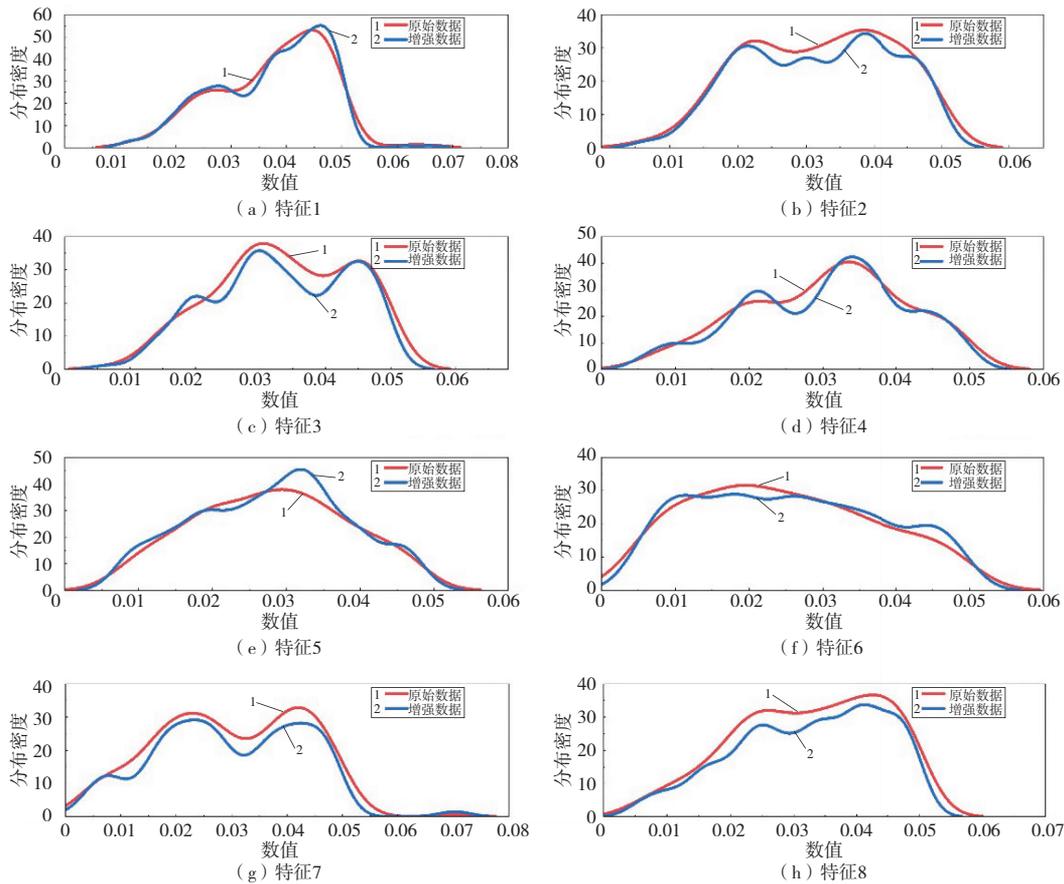


图3 原始数据与增强数据分布密度图

从图3中可以看出增强数据的数值分布与原始数据基本一致;使用Min-Max方法和Z-score

方法对增强后的误差数据集进行标准化,标准化后误差数据集如表2所示。

表2 某航空产品加工误差归一化、标准化数据集

特征 1	特征 2	特征 3	特征 4	特征 5	特征 6	特征 7	特征 8
0.018 13	0.519 78	0.380 15	0.691 16	0.544 80	0.409 52	0.339 04	0.095 97
0.667 72	0.950 10	0.331 35	0.352 12	0.319 80	0.857 78	0.232 16	0.597 63
0.492 48	0.712 70	0.303 07	0.611 10	0.643 58	0.666 06	0.283 80	0.668 22
...

2) 质量预测

本文构建了LSTM网络模型,实现航空零件误差数据特征到质量的映射关系。LSTM初始模型采用三层网络结构,分别为LSTM层、LSTM层、Dense层,神经元个数分别为 m_1 、 m_2 、1,训练批次batch_size为 k ,每层神经网络神经元随机失活比例dropout为 n 、激活函数为ReLU,时间窗口大小为50,训练迭代次数为1500,优化器选用Adam,学习率为0.001,训练集和测试集比例为4:1。模型结构如图4所示。

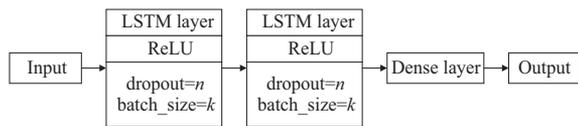


图4 LSTM神经网络结构图

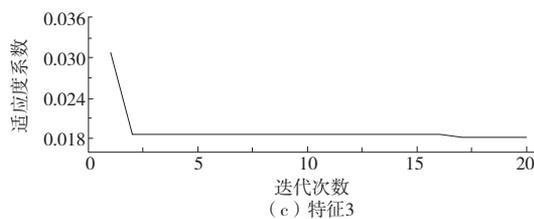
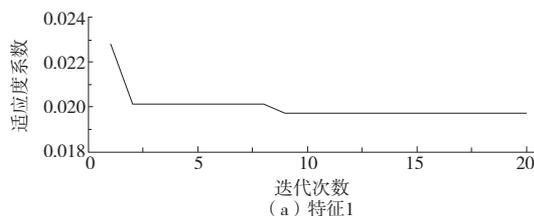
本文的预测模型使用3种评价准则对预测结果进行评估,如式(17)、式(18)、式(19)所示。

a) 平均绝对误差 MAE

$$M_{AE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (h(x_i) - y_i)^2} \quad (17)$$

b) 方均根误差 RMSE

$$R_{MSE} = \frac{1}{m} \sum_{i=1}^m |h(x_i) - y_i| \quad (18)$$



c) 决定性系数 R^2

$$R^2 = \frac{\sum_{i=1}^m (h(x_i) - \bar{y})^2}{\sum_{i=1}^m (h(x_i) - y_i)^2} \quad (19)$$

式中: m 为样本总数; $h(x_i)$ 为误差预测值; y_i 为误差实际值; \bar{y} 为误差实际值的平均值。

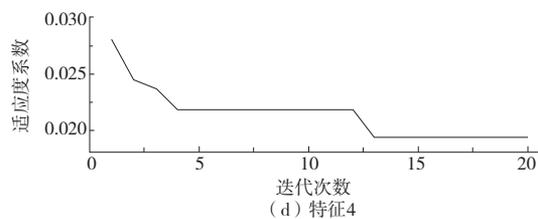
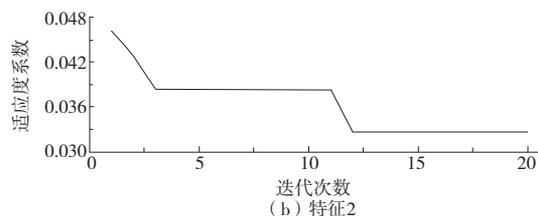
3) 参数优化

本文采用灰狼算法(GWO)对LSTM初始模型中神经网络隐藏层的神经元个数、训练批次batch_size、神经元随机失活比例dropout进行优化;GWO算法的迭代次数为20,寻值的狼数量为4,并根据经验值确定模型参数默认值和寻优参数范围。参数默认值和寻优范围如表3所示。

表3 参数寻优范围表

参数名称	m_1	m_2	k	n
默认值	40	20	16	0.25
寻优上限	60	36	20	0.50
寻优下限	20	16	10	0.20

使用GWO算法对8个特征的LSTM预测模型的参数分别进行优化,其适应度收敛曲线如图5所示。



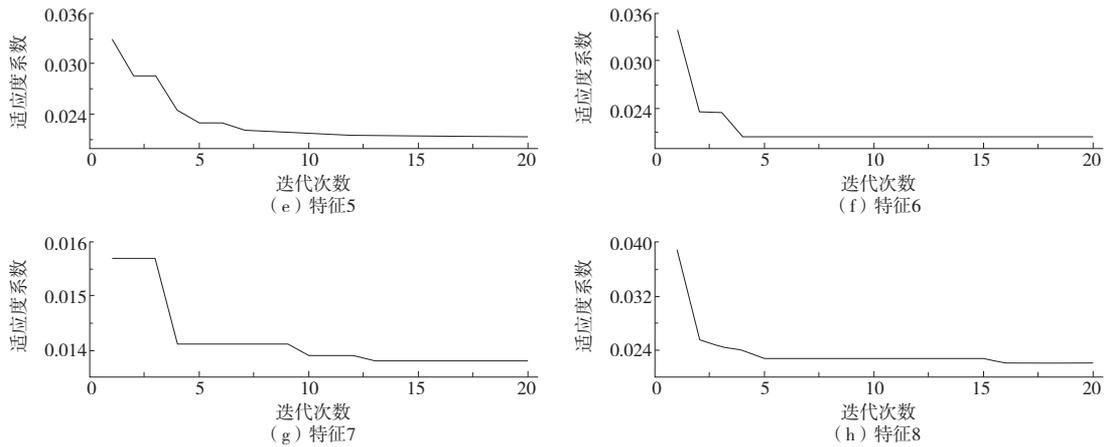


图5 GWO算法适应度收敛曲线

经过20次迭代后适应度系数都达到收敛状态。各模型经GWO算法优化后的参数如表4所示;得到优化参数后,对加工误差进行预测,同时使用初始LSTM、门控单元神经网络GRU、循环神经网络RNN进行对比,各对比模型参数与前文中LSTM初始模型参数保持一致。预测模型最终评价指标如表5所示。

从表5中可以看出,本文提出的GWO-LSTM模型预测效果最好,LSTM、GRU模型次之,RNN模型最差。RNN模型由于网络结构简单无法解决长期依赖的问题,在预测时序较长的数据时效果较差;GRU相较于LSTM,前者结构更为简单,在对较为复杂的数据进行预测时效果不如LSTM模型;本文提出的方法在LSTM模型的基础上使

用GWO算法对模型进行优化,获得了更好的预测效果。

表4 GWO算法参数优化结果

特征名称	参数名称			
	第一层神经元个数	第二层神经元个数	dropout	batch_size
特征1	35	17	0.226 262 495	18
特征2	42	21	0.207 396 186	16
特征3	46	22	0.216 435 322	16
特征4	42	18	0.201 805 967	12
特征5	36	30	0.275 894 433	10
特征6	37	20	0.290 695 338	11
特征7	48	36	0.201 332 152	10
特征8	57	18	0.333 700 395	11

表5 预测模型评价指标对比

特征名称	评价指标	模型名称			
		GWO-LSTM	LSTM	GRU	RNN
特征1	方均根误差	0.005 038 92	0.005 253 741	0.005 691 060	0.008 324 567
	平均绝对误差	0.003 989 69	0.003 992 944	0.004 496 569	0.006 696 504
	决定性系数	0.754 966 93	0.604 087 830	0.455 444 342	0.185 323 234
特征2	方均根误差	0.004 591 06	0.005 795 793	0.005 952 263	0.008 296 415
	平均绝对误差	0.003 681 03	0.004 562 423	0.004 648 688	0.006 921 185
	决定性系数	0.737 347 55	0.538 861 241	0.492 473 559	0.238 651 543
特征3	方均根误差	0.004 579 96	0.005 732 618	0.005 963 880	0.008 905 446
	平均绝对误差	0.003 592 49	0.004 493 236	0.004 724 270	0.007 351 806
	决定性系数	0.751 693 72	0.521 753 769	0.473 414 427	0.267 853 219

续表5

特征名称	评价指标	模型名称			
		GWO-LSTM	LSTM	GRU	RNN
特征 4	方均根误差	0.004 891 67	0.005 743 872	0.005 871 252	0.008 975 794
	平均绝对误差	0.003 831 69	0.004 491 166	0.004 530 433	0.007 066 053
	决定性系数	0.702 128 24	0.590 647 839	0.540 369 040	0.230 856 432
特征 5	方均根误差	0.004 588 35	0.004 769 279	0.005 688 272	0.008 634 302
	平均绝对误差	0.003 617 81	0.003 654 757	0.004 433 596	0.006 999 992
	决定性系数	0.747 055 53	0.704 779 014	0.542 118 681	0.206 532 432
特征 6	方均根误差	0.004 555 94	0.005 846 230	0.006 575 003	0.010 201 892
	平均绝对误差	0.003 528 05	0.004 511 969	0.005 167 959	0.058 254 369
	决定性系数	0.757 089 09	0.712 695 750	0.625 332 393	0.187 312 305
特征 7	方均根误差	0.004 489 91	0.006 773 203	0.007 261 366	0.011 022 165
	平均绝对误差	0.003 483 44	0.005 280 069	0.005 595 210	0.009 061 531
	决定性系数	0.764 520 07	0.636 296 025	0.555 400 357	0.017 321 690
特征 8	方均根误差	0.004 944 83	0.005 285 803	0.005 999 194	0.009 475 534
	平均绝对误差	0.003 928 04	0.004 113 494	0.004 677 664	0.007 633 543
	决定性系数	0.728 117 30	0.704 038 089	0.631 147 724	0.209 472 912

4 结语

针对传统 LSTM 预测模型误差较大和难以优化的问题,本文提出了一种基于 GWO 算法改进的 LSTM 预测模型。利用深度学习算法对原始数据进行增强,并在 LSTM 预测模型的基础上使用 GWO 算法对预测模型的关键参数进行优化,可有效地提高产品误差预测的精度和实际生产的加工质量。

参考文献:

- [1] 苏欣,高晓旭,赖贤尧,等. 基于机器学习的零件加工质量预测及优化[J]. 机械制造与自动化,2022,51(5):136-139.
- [2] 蒋金瑜. 基于 PCA_NearMiss 和 XGBoost 的产品质量预测[J]. 内燃机与配件,2021(1):122-123.
- [3] 秦永涛,赵丽萍,要义勇. 基于小波变阈值去噪递推偏最小二乘的加工质量预测方法[J]. 计算机集成制造系统,2008,14(1):172-176,182.
- [4] 高玉明,张天瑞,张赛. 基于 GBO-LSSVM 的多品种小批量产品质量预测[J]. 组合机床与自动化加工技术,2022(6):175-179.
- [5] 杨建新,兰小平,姚志强,等. 基于郊狼算法优化的 LSSVM 多工序质量预测方法[J]. 制造业自动化,2021,43(12):105-109.
- [6] 侯红玲,陈鑫,常向龙,等. 基于遗传算法优化 BP 神经网络的内螺纹冷挤压质量预测[J]. 塑性工程学报,2022,29(1):102-109.
- [7] ZHAO J W, LI J D, YANG Q, et al. A novel paradigm of flatness prediction and optimization for strip tandem cold rolling by cloud-edge collaboration[J]. Journal of Materials Processing Technology, 2023, 316: 117947.
- [8] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[EB/OL]. (2014-06-10) [2023-05-16]. <http://arxiv.org/abs/1406.2661>.
- [9] XU L, SKOULARIDOU M, CUESTA-INFANTE A, et al. Modeling tabular data using conditional GAN[EB/OL]. (2019-07-01) [2023-05-16]. <http://arxiv.org/abs/1907.00503>.
- [10] 江春雨,程琳,黎晓明亮. 生成对抗网络在计算机视觉领域的应用[J]. 计算机科学与应用,2018,8(11):1726-1733.
- [11] GU J X, WANG Z H, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354-377.
- [12] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

收稿日期:2023-08-14