

Journal of System Simulation

Volume 35 | Issue 11

Article 3

11-30-2023

Research on Multi-process Product Quality Prediction Based on Improved BiLSTM

Tianrui Zhang

School of Mechanical Engineering, Shenyang University, Shenyang 110044, China, trzhang@syu.edu.cn

Yuting Liu

School of Mechanical Engineering, Shenyang University, Shenyang 110044, China, lyt01232021@163.com

Yike Wang

School of Mechanical Engineering, Shenyang University, Shenyang 110044, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Research on Multi-process Product Quality Prediction Based on Improved BiLSTM

Abstract

Abstract: In response to the complex manufacturing process of multi-process products, a multi-process product quality prediction model based on the kernel principal component analysis (KPCA) - and improved sparrow search algorithm (ISSA) optimized bi-directional long short term memory (BiLSTM) was proposed to address the uncertain factors that affect product quality, while improving the capacity for each process and ensuring the stability, in multi-process production. Firstly, KPCA was used for data preprocessing, and a kernel function was established on the basis of principal component analysis together with kernel methods. As redundant features were removed through dimension reduction, an improved Gaussian mutation and the uniform mutation operator η were introduced to improve the sparrow search algorithm. Secondly, the ISSA was introduced into the BiLSTM, and the dimensionality reduced data were imported into the ISSA-BiLSTM model to achieve the quality prediction of multiprocess products. Finally, the TFT-LCD manufacturing process was analyzed as an example and compared with the existing methods. The experimental results show that the prediction model has a high prediction accuracy, with the root mean square error less than 10%, effectively improving the accuracy of multi-process product quality prediction.

Keywords

multi-process production, quality prediction, kernel principal component analysis (KPCA), improved sparrow search algorithm (ISSA), bi-directional long short-term memory (BiLSTM)

Recommended Citation

Zhang Tianrui, Liu Yuting, Wang Yike. Research on Multi-process Product Quality Prediction Based on Improved BiLSTM[J]. Journal of System Simulation, 2023, 35(11): 2321-2332.

基于改进 BiLSTM 的多工序产品质量预测研究

张天瑞, 刘玉亭*, 王译可

(沈阳大学 机械工程学院, 辽宁 沈阳 110044)

摘要: 针对多工序产品制造过程的复杂性, 为了解决多工序产品生产过程中影响产品质量问题的不确定因素, 同时提高生产工序的生产能力, 保证生产的稳定性, 提出了一种基于核主成分分析和改进麻雀搜索算法优化 BiLSTM 的多工序产品质量预测模型。利用 KPCA 对数据预处理, 主成分分析的基础上结合核方法建立核函数, 降维去除冗余特征, 引入改进的高斯变异和均匀变异算子 η 改进麻雀搜索算法; 将改进的麻雀搜索算法引入双向长短期记忆网络中, 将降维处理后的数据导入 ISSA-BiLSTM 模型中实现多工序产品的质量预测; 以 TFT-LCD 制造过程为例进行案例分析, 并与现有方法比较分析。实验结果表明: 该预测模型具有较好的预测精度, 且均方根误差值小于 10%, 有效地提高了多工序产品质量的预测精度。

关键词: 多工序产品; 质量预测; KPCA; ISSA; BiLSTM

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)11-2321-12

DOI: 10.16182/j.issn1004731x.joss.23-FZ0805

引用格式: 张天瑞, 刘玉亭, 王译可. 基于改进 BiLSTM 的多工序产品质量预测研究[J]. 系统仿真学报, 2023, 35(11): 2321-2332.

Reference format: Zhang Tianrui, Liu Yuting, Wang Yike. Research on Multi-process Product Quality Prediction Based on Improved BiLSTM[J]. Journal of System Simulation, 2023, 35(11): 2321-2332.

Research on Multi-process Product Quality Prediction Based on Improved BiLSTM

Zhang Tianrui, Liu Yuting*, Wang Yike

(School of Mechanical Engineering, Shenyang University, Shenyang 110044, China)

Abstract: In response to the complex manufacturing process of multi-process products, a multi-process product quality prediction model based on the kernel principal component analysis (KPCA) - and improved sparrow search algorithm (ISSA) optimized bi-directional long short-term memory (BiLSTM) was proposed to address the uncertain factors that affect product quality, while improving the capacity for each process and ensuring the stability, in multi-process production. Firstly, KPCA was used for data preprocessing, and a kernel function was established on the basis of principal component analysis together with kernel methods. As redundant features were removed through dimension reduction, an improved Gaussian mutation and the uniform mutation operator η were introduced to improve the sparrow search algorithm. Secondly, the ISSA was introduced into the BiLSTM, and the dimensionality reduced data were imported into the ISSA-BiLSTM model to achieve the quality prediction of multi-process products. Finally, the TFT-LCD manufacturing process was analyzed as an example and compared with the existing methods. The experimental results show that the prediction model has a high prediction accuracy, with the root mean square error less than 10%, effectively improving the accuracy of

收稿日期: 2023-07-02 修回日期: 2023-08-29

基金项目: 国家自然科学基金面上项目(52075088); 辽宁省研究生教育教学改革研究资助项目(LNYJG2022490)

第一作者: 张天瑞(1985-), 男, 副教授, 博士, 研究方向为质量管理与可靠性。E-mail: trzhang@syt.edu.cn

通讯作者: 刘玉亭(2000-), 女, 硕士生, 研究方向为质量管理与可靠性。E-mail: lyt01232021@163.com

multi-process product quality prediction.

Keywords: multi-process production; quality prediction; kernel principal component analysis (KPCA); improved sparrow search algorithm (ISSA); bi-directional long short-term memory (BiLSTM)

0 引言

高质量产品是我国制造业生存和发展的重中之重。在追求高质量产品的道路上，精准的质量预测显得尤为重要，精准的质量预测不仅仅是产品生产发展的需求，更是推动我国制造业朝着高质量产品迈进的重要动力^[1]。随着制造业的发展，大部分企业已从传统的生产模式转变为多品种小批量生产模式，多工序产品制造过程逐渐普遍。然而，与传统大规模生产相比，多工序制造过程呈现出明显的差异，传统的数学模型逐渐难以应对多工序产品生产的复杂性和多样性，因而，探索多工序产品质量预测方法是十分必要的。

众多文献对单工序产品的质量预测进行了研究。例如：文献[2]为了解决小批量产品制造过程中关键工序的识别，采用了NWA实现了移动极差控制图；文献[3]在复杂生产过程的质量预测中，利用计算机视觉提取特征，建立了动态的预测模型；文献[4]与变化的预测方法结合，提出了一种综合质量预测控制方法。以上针对单工序产品的质量预测研究无法适用于多工序之间的关联性和复杂性。为了解决这个问题，一些文献研究了在生产系统中进行质量分析的方法，例如：文献[5]为了提高产品生产自相关过程的平均检测漂移值，提出一种最小欧氏距离的监测方法；文献[6]通过预测控制生产中的最佳数据，实现了生产系统性能和质量的预测；文献[7]构建了一种基于马尔可夫链理论的多变量T2控制图，并说明了该方法的合理性。上述研究仅适用于稳定状态的研究，而多工序产品的生产具有动态不稳定的特点，因而无法得到适用。

目前较成熟的预测方法有：灰色预测模型(groy module, GM)、人工神经网络预测模型

(artificial nerual network, ANN)等。文献[8]以误差传递性角度出发，通过分析多工序产品的生产特性，构建了质量预测模型。文献[9]采用PSO算法调整支持向量机，解决了发动机装配质量预测问题。随着智能算法的应用，众多学者利用历史数据进行数学建模，以实现产品质量的预测。文献[10]通过分析SMT的工艺流程，提出基于时序特性的特征重构方式，设定时间窗口，提高了预测的准确率；文献[11]应用改进的ABC算法优化支持向量机的质量预测模型，以算法的稳定性和质量预测模型的准确性；文献[12]根据大数据环境下多工序的生产流程，构建了SC-PSO-RBF模型，该模型综合考虑了数据的多特征和全样本情况；文献[13]为提出了解决多工序制造过程中的损失预测问题的方法，其改进的GERT预测方法模型在实际中具有一定的实用价值；文献[14]以汽车零部件生产制造过程为例，通过分析其多工序生产过程的特征，基于密度聚类提出了MCDC-MF-SMOTE的采样方法，实现了汽车零部件生产中不平衡数据集的预测；文献[15]通过融合网络分析方法和灰色关联分析法，建立了灰色幂理论预测模型，实现了对多工序产品制造过程的提前精准预测；文献[16]针对特殊零件的相关质量问题，结合误差递增和分布的问题，提出了对其零件制造中的质量预测方法。

上述学者在理论和智能算法方面进行了大量的质量预测研究，但仍具有很大的局限性，且通常在研究中只使用一个数据集，从而模型只适用于某些特定的制造领域，无法满足制造业对实时质量预测的各种要求。因此，本文在上述研究的基础上，结合多工序生产的复杂性和关联性，通过特征提取，建立仿真模型，结合智能算法对多工序产品进行仿真质量预测。

1 方法与算法原理

针对多工序制造过程中存在的不确定因素导致的质量问题和质量数据不平衡引起的预测精度

不高的问题，本文件通过对生产过程的历史和实时数据分析，建立质量规则模型，利用网络质量异常规则对基于质量指标的制造过程进行预测。本文提出的多工序产品质量的预测方法如图1所示。

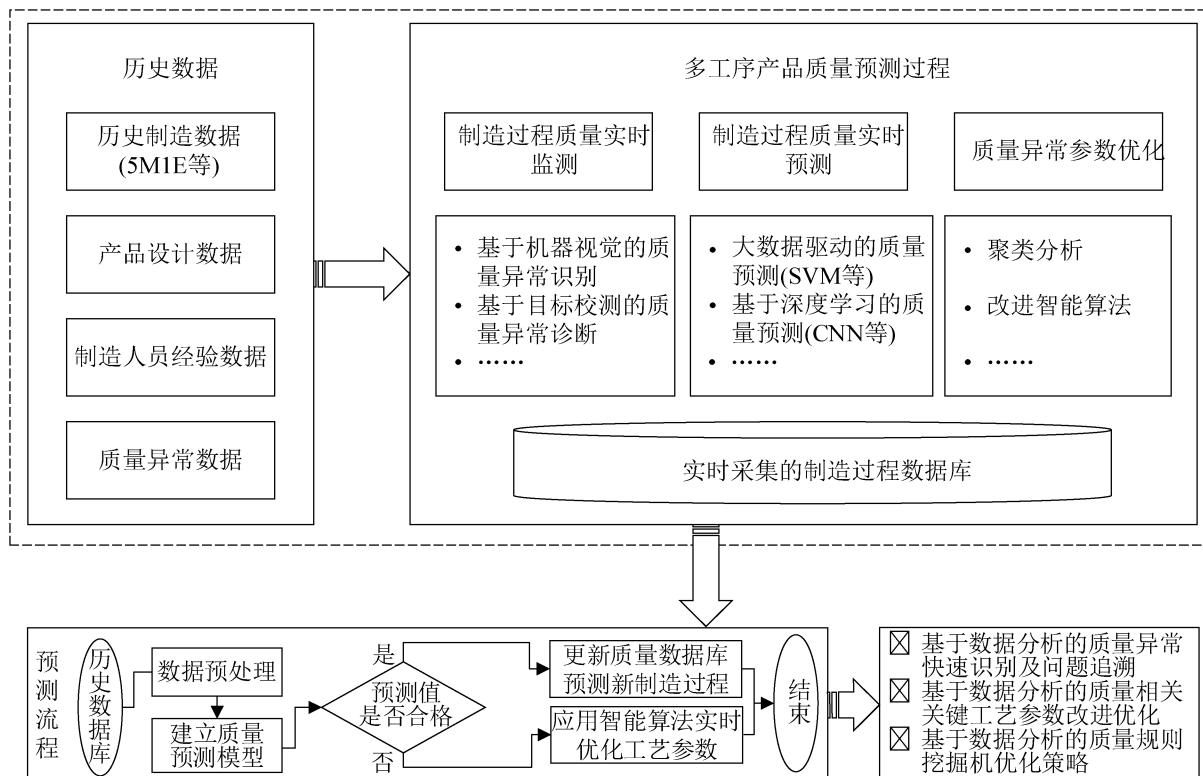


图1 多工序产品制造过程质量预测方法描述图

Fig. 1 Schematic description of quality prediction methods for multi-process product manufacturing

1.1 数据预处理

首先需要对数据降维处理，根据多工序产品质量数据的多个特征维度的特性，去除冗余和无关特征，从而提高仿真模型的精度和计算效率。本文利用对复杂高维非线性数据信息具有较强处理能力的核主成分分析(Kernel principle component analysis, KPCA)^[17]方法进行数据降维，以解决数据的非线性、动态性、非高斯性等复杂特性。

KPCA的处理过程是将任意两个不同的原始数据点 x_i, x_j 通过映射函数 $\varphi(X)$ 映射到高维特征空间范围内，可表示为

$$(x_i, x_j) \rightarrow K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (1)$$

式中： $x=(x_1, x_2, \dots, x_n)$ 为假设样本集合，即输入n

个数据样本，每个样本有 m 个属性，建立初始矩阵 $\mathbf{x}'_{n \times m}$ ，经规范化，得到 $\mathbf{x}_{n \times m}$ 矩阵。

对应得到的映射值为 $\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)$ ，数据经过中心化处理后，即

$$\sum_{i=1}^m \varphi(x_i) = 0, \varphi(x_i) \in R^N, x_i \in R^m \quad (2)$$

式中： N 为向量空间维度。

利用主成分分析求得的协方差矩阵：

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n \varphi(x_i) \varphi(x_i)^T \quad (3)$$

其特征方程为

$$\mathbf{Cv} = \lambda \mathbf{v} \quad (4)$$

式中： λ 为协方差矩阵的特征值； v 为特征向量，根据式(3)和(4)可得：

$$\mathbf{v} = \sum_{i=1}^n \varphi(x_i) \frac{\varphi(x_i)^T v}{\lambda n} = \sum_{i=1}^n \varphi(x_i) \alpha_i \quad (5)$$

$$\alpha_i = \frac{\varphi(x_i)^T v}{\lambda n} \quad (6)$$

式(4)通过引入核函数使 v 的计算更为简便。
引入核函数为

$$k(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (7)$$

对于式(2), 任意的 $i=1, 2, \dots, n$ 有

$$\varphi(x_k) C v = \lambda \varphi(x_k) v \quad (8)$$

通过将式(2), (4), (7)带入式(8)可得

$$K \alpha = \lambda n \alpha \quad (9)$$

式中: k 为KPCA的核函数, K 为核矩阵。

图2所示为KPCA算法实现流程, KPCA数据降维具体步骤如下:

- (1) 将采样的数据进行归一化处理, 使样本特征归一化到[0,1]区间;
- (2) 将低维数据进行非线性转换, 构造协方差矩阵。引入核函数, 获得核矩阵, 并进行中心化处理;
- (3) 采用自定的累计方差贡献值, 由小到大顺序进行分类, 获得特征向量。

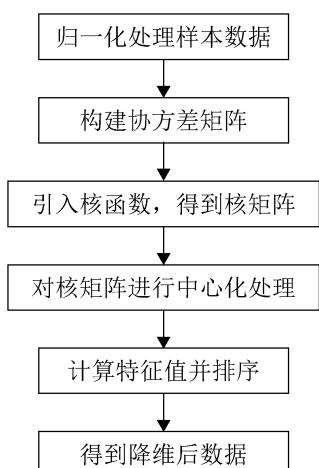


图2 KPCA算法实现流程
Fig. 2 KPCA algorithm implementation process

1.2 麻雀搜索算法

1.2.1 标准麻雀搜索算法

麻雀搜索算法(sparrow search algorithm, SSA)

是受麻雀的觅食和反捕行为启发得到的一种群体智能优化算法^[18], 通过迭代, 不断更新群体位置直至获得最优解。该算法将麻雀的捕猎行为视为一种“发现者-加入者”的模型, 种群中的麻雀主要分为发现者、加入者和侦察者。

发现者的位置公式更新为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot iter_{max}}\right), & R_2 < ST \\ X_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (10)$$

式中: t 为当前的迭代数; $iter_{max}$ 为常数, 是迭代的最大次数; $X_{i,j}^t$ 为第 t 次迭代中第 i 只麻雀第 j 维的位置信息; α 为(0, 1]中的均匀的随机数字; 预警值 $R_2 \in (0, 1]$; 安全值 $ST \in (0.5, 1]$; Q , L 分别为服从标准正态分布的随机数、元素均为1的单行矩阵。

加入者位置更新为

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right), & i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L, & \text{otherwise} \end{cases} \quad (11)$$

式中: n 为种群数量, 即种群规模; X_{worst}^t 为第 t 次迭代全局最差的位置; X_p^{t+1} 为发现者在 $t+1$ 次迭代中的最佳位置; A 为单行矩阵, 矩阵中的元素为随机分配的值1或-1, 且 $A^+ = A^T (AA^T)^{-1}$ 。

侦察者的位置更新为

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (12)$$

式中: β 和 K 均为步长控制的参数; β 为服从[0,1]正态分布的随机数; K 同时为麻雀位置的改变方向, 为[-1,1]内的随机数; ϵ 为极小的常数, 用以避免分母为0; f_i 为当前麻雀的适应度值; f_w , f_g 为代表全局中最差与最优的适应度值。

1.2.2 改进的麻雀搜索算法

SSA虽然具有寻优能力强、鲁棒性高、收敛

快等优点，但仍有一定的局限性，例如：种群的适应度不高，易陷入局部最优、由于SSA算法初始群体产生的随机性，易导致群体在空间中分布不均匀。针对以上两点，提出以下策略改进麻雀搜索算法：

(1) 为避免陷入局部最优，提高种群的适应度值，因而引入改进的高斯变异(Gaussian mutation, GM)，提高发现者的位置更新。具体改进为

$$X_{ij}^t = \begin{cases} \omega \cdot \exp\left(\frac{-i}{\alpha \cdot iter_{max}}\right), & R_2 < ST \\ \omega + QL, & R_2 \geq ST \end{cases} \quad (13)$$

式中： ω 为变化后的值。

$$\omega = X_{ij}^t \cdot (1 + \tau \cdot N) \quad (14)$$

式中： τ 为 $[0,1]$ 上的递减变量； X_{ij}^t 为当前搜索算法中第 i 行和第 j 列的个体在第 t 代的某个属性或参数的值； N 为随机数。

(2) 为了使种群均匀，加入一种均匀变异算子 η 。当危险发生时，两个位置的麻雀会更新不同的位置。具体实现公式为

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot \eta(t), & f_i \neq f_g \\ X_{ij}^t + K \left(\frac{\eta(t)}{(f_i - f_w) + \varepsilon} \right), & f_i = f_g \end{cases} \quad (15)$$

式中： $\eta(t)$ 为本文提出的统一变异算子。

$$\eta(t) = X_{ij}^t + r(v_{max} - v_{min}) \quad (16)$$

式中： v_{max} ， v_{min} 为麻雀数上界和下界； r 为 v_{max} 和 v_{min} 之间均匀分布的随机数值。图 3 为改进流程图。

1.3 双向长短期记忆网络

双向长短期记忆网络(bi-directional long short-term memory, Bi-LSTM)是一种基于LSTM的正反两种输入顺序的连续输入信息的方法，是循环神经网络的一种特殊变体，同时保留了LSTM处理具有长期相关性序列的优点，弥补了LSTM不能使用上下文信息进行预测的缺点。该网络结构如

图4所示。

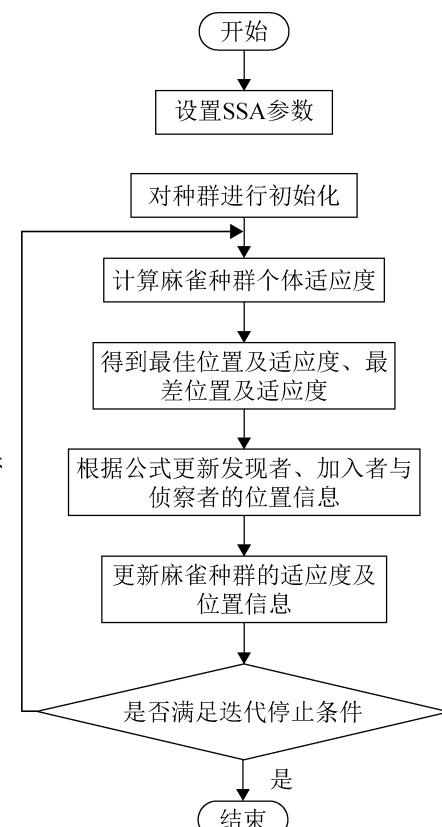


图3 改进的麻雀搜索算法的流程图

Fig. 3 Flow chart of improved sparrow search algorithm

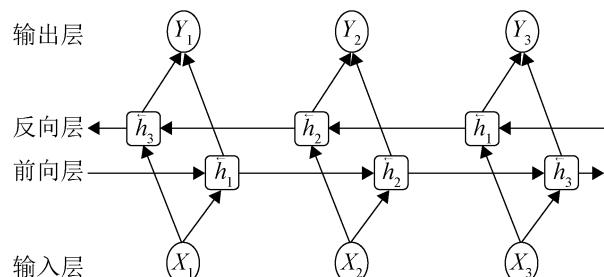


图4 Bi-LSTM结构图

Fig. 4 Bi-LSTM structure diagram

BILSTM的基本构建是LSTM单元，LSTM包括遗忘门、细胞状态、输入门，输出门。遗忘门为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (17)$$

细胞状态的更新为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (18)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (19)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (20)$$

式中： W_c 和 b_c 分别为细胞状态更新时的权值以及偏置向量； C_t 为在时间步 t 的长期状态； \tilde{C}_t 为在时间步 t 的候选长期状态。记忆细胞的最终状态通过遗忘门及输入门共同作用最终通过输出门 O_t 输出。输出门为

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (21)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (22)$$

式中： h_t 为输出状态值； W_o 和 b_o 分别为输出层的权值和偏置向量。

首先，从正向序列开始，将第一时刻到第 t 时刻的信息传入前向层，在前向层保存每个时间点的输出。将反向序列一次输入后向层，同时保存每个时间点的输出。最后结合前向层和后向层对

应的输出值，得到最终输出结果。

正向序列的隐藏向量为

$$\vec{h}_t = \sigma \vec{W} [\vec{h}_{t-1}, x_t] \quad (23)$$

反向序列的隐藏向量为

$$\hat{h}_t = \sigma \hat{W} [\hat{h}_{t-1}, x_t] \quad (24)$$

$$Y_t = f(\vec{W}[\vec{h}_t, \hat{h}_t]) \quad (25)$$

式中： \vec{h}_{t-1} 和 \hat{h}_{t-1} 分别为时间步 $t-1$ 的隐藏状态和时间步 $t-1$ 的反向隐藏状态； σ 与 f 均为本文选用的激活函数； X_t 为 t 时刻的输入； U_t 为 t 时刻的最终输出值； \vec{W} 为正向传递的权重矩阵； \hat{W} 为反向传递的权重矩阵。

2 基于 KPCA-ISSA-BiLSTM 的多工序产品质量预测仿真模型

本文提出的 KPCA-ISSA-BiLSTM 多工序质量预测模型结构如图 5 所示。

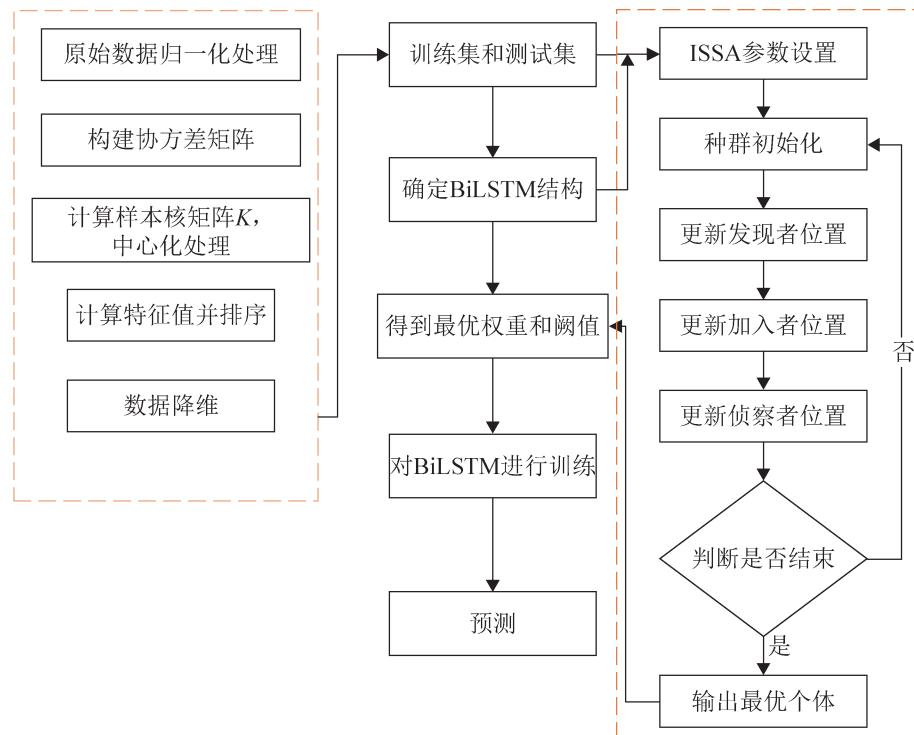


图 5 ISSA-BiLSTM 的结构图
Fig. 5 Structure diagram of ISSA-BiLSTM

2.1 模型建立

建模详细步骤如下

step 1：质量过程数据采集。对生产过程中所搜集的产品质量状况数据进行分析。得到一组具

有一定规律的连续生产数据, 分析数据产生的工艺设备的细微偏差以及对产品的质量特征的影响。将上一阶段的质量指数视为下一阶段的质量值, 以反映工艺装备在不同时期所产生的质量改变。

step 2: 数据预处理。首先输入数据集, 对其进行 KPCA 数据降维处理。特征降维后的特征可表示为 $X_j = (X_1, X_2, \dots, X_n)$, 质量值为 Y 。

step 3: 对降维后的数据进行特征处理。将其分为训练集和测试集并将数据进行归一化处理。

step 4: 建立双向长短期记忆神经网络模型。使用改进的 SSA 优化输入层与隐含层、隐含层与输出层之间的初始连接权值和初始阈值, 避免其陷入局部最优。

step 5: 处理后的数据作为输入代入到 BiLSTM 模型学习训练, 将每只麻雀的适应度值作为解来代替 BiLSTM 的初始权重和阈值。

step 6: 每次训练后根据预测结果的平方误差 (mean square error, MSE)、均方根误差 (root mean square error, rmse RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 来进行评估, 获取模型最优参数, 误差满足阙值时得到预测模型。

2.2 评价指标

本文采用的评价指标计算分别为

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (26)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (27)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (28)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (29)$$

2.3 参数设置

在一定程度上, 预测模型的性能还取决于算法和模型中参数的选择。因此, 为了尽量减少预测误差, 本文结合经验公式, 进行多次实验, 确定了一系列参数, 如表 1 所示。

表 1 参数设置

Table 1 Parameter setting

参数名称	参数数值
$iter_{max}$ 迭代最大次数	200
种群数量	30
搜索维度	$[-5, 5]$
发现者比例	0.2
安全阙值	0.8
BiLSTM 输入层节点数	5
BiLSTM 隐含层节点数	11
BiLSTM 输出层节点数	1

3 案例分析

在半导体制造过程的复杂且精细的流程中, 存在诸多质量数据和影响变量, 同时预测模型的应用需要考虑诸多的过程变量。因此, 本文选用半导体制造过程为例, 利用天池工业 AI 大赛-智能制造质量预测中提出的 TFT-LCD 的生产数据来验证本文所提出的多工序产品质量预测模型。该数据体现了设备和环境中的诸多影响因子, 例如: 温度、功率、制成时间、气体、液体流量等, 部分实验数据如表 2 所示。

表 2 部分实验数据
Table 2 Partial test data

ID 编号	TOOL-ID	210T1	210T2	210T3	...	750T1451	750T1452	Y
1	N	102.05	0.465	0.27	...	0.000 72	2.40E+12	2.945 08
2	M	100.95	0.805	0.22	...	0.000 72	2.40E+12	2.955 09
3	L	98.56	0.555	0.24	...	0.000 64	2.40E+12	2.741 26
4	M	100.35	0.901	0.22	...	0.000 72	2.40E+12	2.799 34
5	M	100.25	0.854	0.23	...	0.000 72	2.40E+12	2.692 09

本数据共 8 029 列字段，第一列为数据 ID 编号，Tool-ID 为每道工序使用的机台，中间的每一列数据均为预测 Y 的特征变量 T ，最后一列为最终需要预测的产品质量值 Y 。 Y 值代表综合质量指标，并非具体某一个特性值，若某一道工序的质量特性出现异常，则 Y 值也会出现质量问题。变量在多道工序制造中产生，使用不同的字段名字来表示不同的工序。

3.1 实验数据预处理

对于上述数据进行预处理，消除缺值样本并归一化特征值至 $[0, 1]$ 区间，针对 KPCA 中核参数 σ^2 的选取没有明确的数值选择方法等问题，本文通过设置参数选取区间，采用遍历法讨论不同核参数对第一主成分贡献率的影响。其中，设置搜索区间为 $[0.1, 3.5]$ ，搜索步长为 0.1，以成分总贡献率 90% 为阈值保留特征，得到的具体结果如图 6 所示。

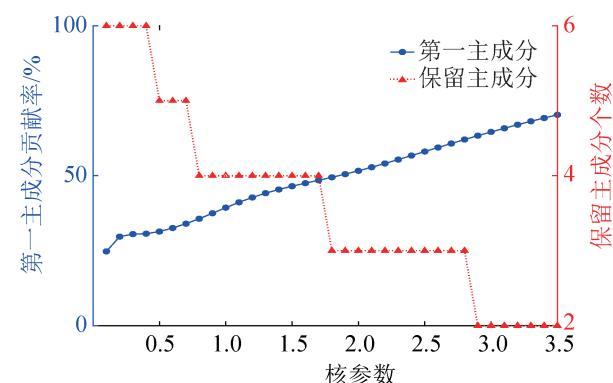


图 6 核参数的选取
Fig. 6 Selection of nuclear parameters

根据图 6 可知，随着核参数的递增，第一主成分贡献率和被保留主成分个数呈负相关。为方便对降维结果可视化，本文以保留主成分数为 3 作为目标进行特征降维，其中核参数取 2.5，降维后的结果如图 7~8 所示。

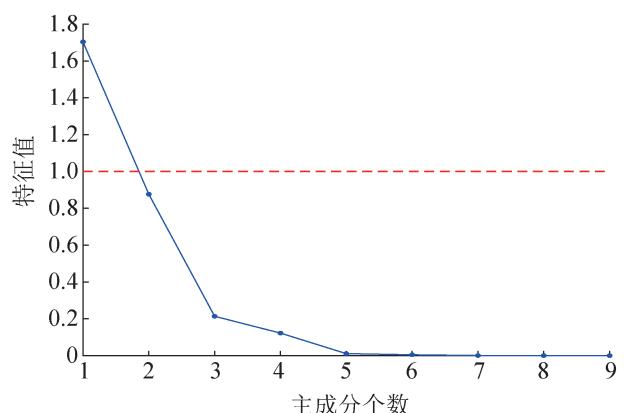


图 7 降维后的贡献率
Fig. 7 Contribution rate after dimension reduction

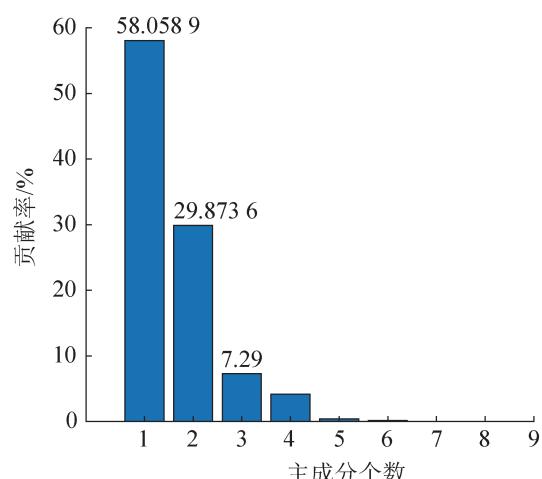


图 8 降维后的贡献率
Fig. 8 Contribution rate after dimension reduction

3.2 质量预测模型验证

在多工序产品质量预测阶段，为验证 ISSA-BiLSTM 的先进性，将其与 SSA-BiLSTM 和 BiLSTM 的结果做对比。

首先以 ISSA-BiLSTM 为例，ISSA 优化的 BiLSTM 主要超参数包括：第一层、第二层的隐含层节点数 L_1 、 L_2 、最大迭代次数 K 与学习率 L_r 。参数设置：麻雀数量 30，搜索迭代次数为 20，搜索上下界分别设置为 $[100, 500, 50, 0.1]$ 与 $[1, 1, 1, 0.001]$ 。将数据划分训练集与测试集，比重为 7: 3，并将

训练集的MSE误差作为适应度函数。训练得到的结果如图9~10所示；参数寻优进度如图11所示。

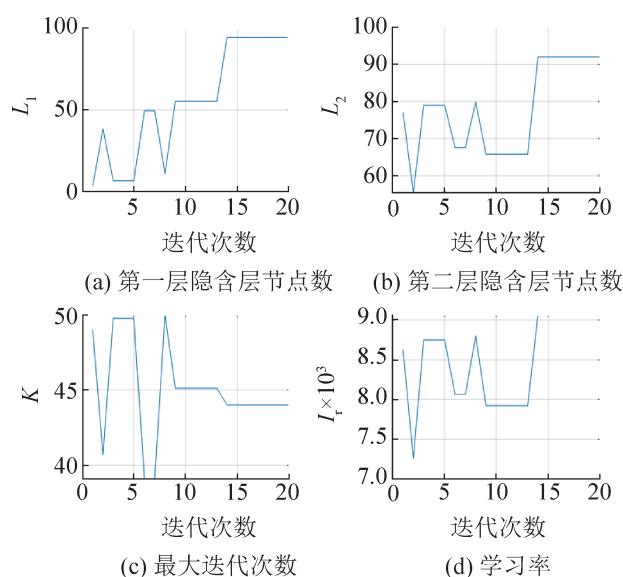


图9 参数寻优曲线
Fig. 9 Parameter optimization curve

由图10可知，经过20轮参数寻优，寻优曲线

逐渐收敛，超参数获得稳定取值。因此，将搜索到的最优参数导入BiLSTM模型进行重新训练，并对测试集进行预测。预测后结果如图12所示。通过SSA-BiLSTM/BiLSTM预测得到的结果如图13、14所示。

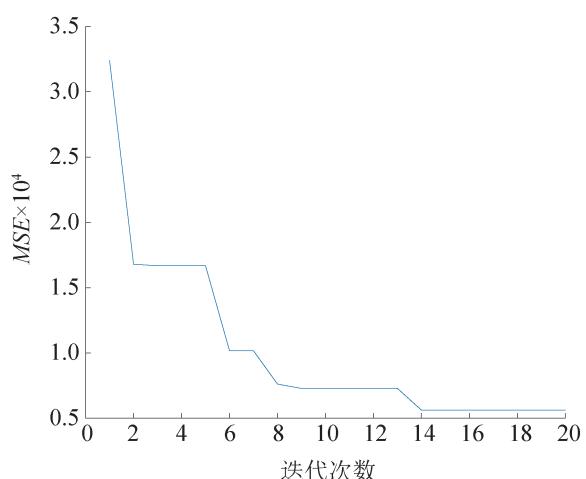


图10 ISSA的适应度曲线
Fig. 10 Fitness curve of ISSA

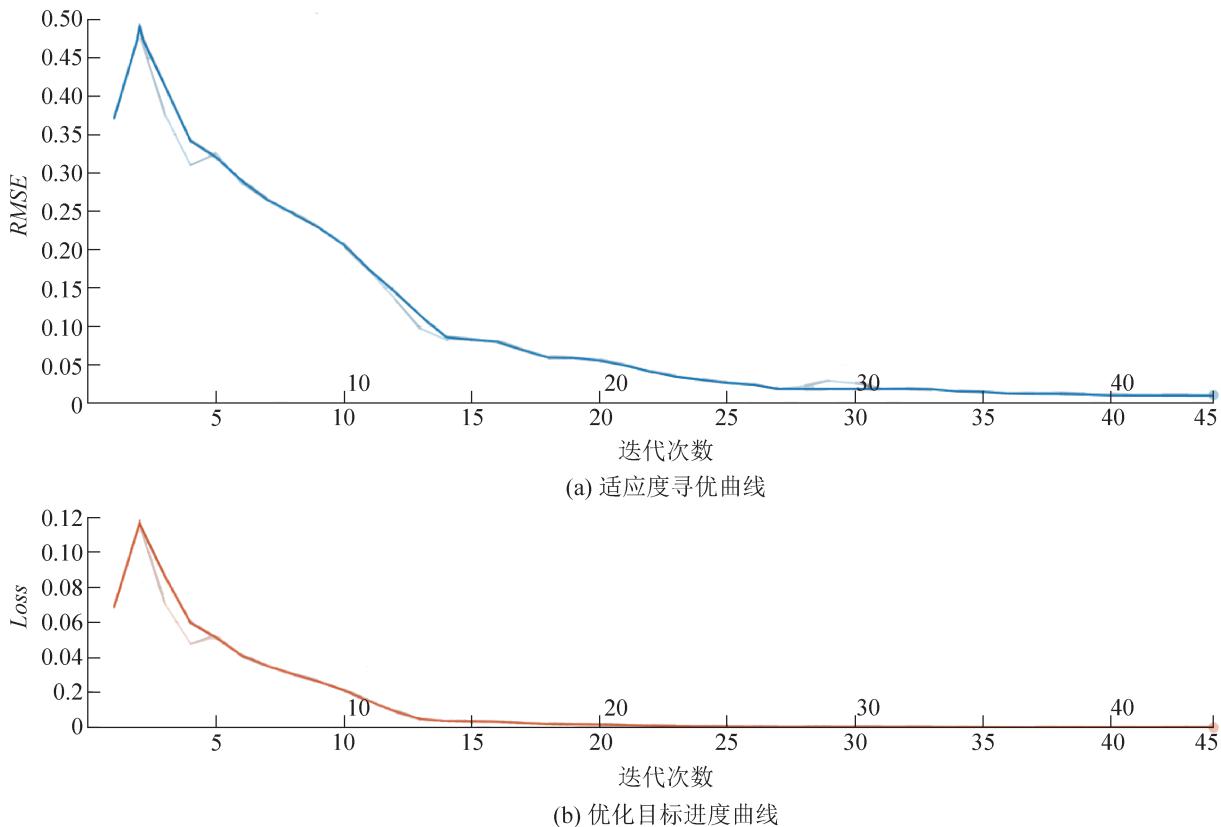


图11 参数寻优进度
Fig. 11 Parameter optimization progress

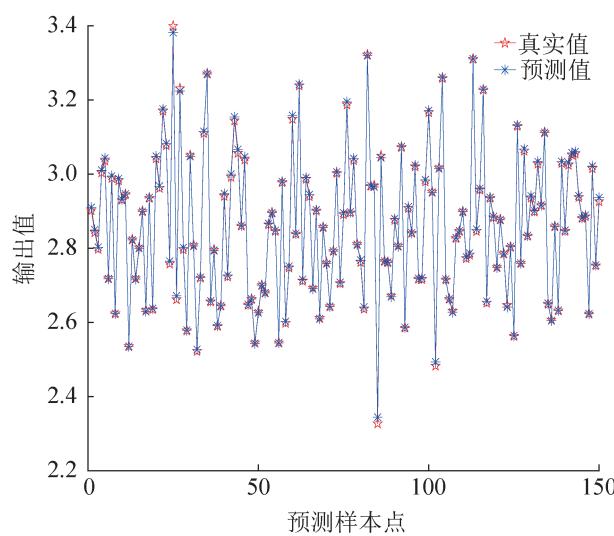


图 12 ISSA-BiLSTM 预测结果图
Fig. 12 ISSA-BiLSTM forecast chart

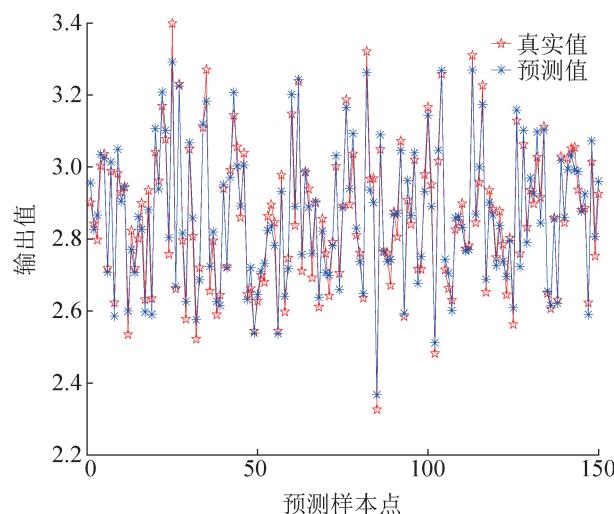


图 13 SSA-BiLSTM 预测结果图
Fig. 13 SSA-BiLSTM forecast chart

对比图12~14,由图12可知,ISSA-BiLSTM模型稳定性高于SSA-BiLSTM和BiLSTM模型,同时ISSA-BiLSTM模型预测值与真实值之间误差最小,预测结果验证了ISSA的有效性;由图13可知,SSA提高了BiLSTM的稳定性;由图14发现BiLSTM的预测精度较低,与真实值之间的误差较大。

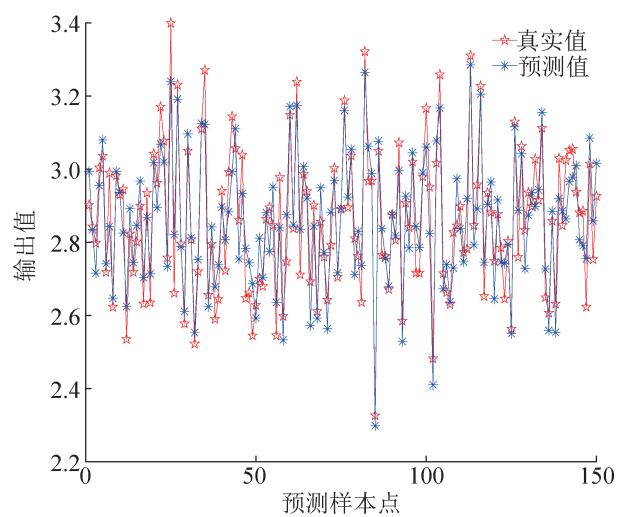


图 14 BiLSTM 预测结果图
Fig. 14 BiLSTM forecast chart

为对上述3种模型进行比较,本文采用RMSE、MAE、MAPE、决定系数(R^2)、纳什系数(Nash Sutcliffe-efficiency coefficient, NSE)以及运行时间对结果进行量化评估,结果如表3所示。

根据表3可知ISSA-BiLSTM预测精度最高,其RMSE、MAE、MAPE值均最小,较SSA-BiLSTM分别降低了80.25%,81.42%,98.13%,较BiLSTM分别下降了89.89%,89.98%,89.94%,其误差值相对较小,由此表明ISSA-BiLSTM模型的预测值较为精确。同时,通过对SSA-BiLSTM和BiLSTM的对比分析,发现SSA对预测的准确率有了较大的提高,但距离理想值还有差异。因此本文在SSA的基础上将其进行改进,提出了ISSA-BiLSTM预测仿真模型,科学的提升了仿真模型的稳定性,有效的提高了多工序产品质量的预测精度。由表2可知,由于数据输入前的降维处理,本文提出的方法模型计算用时较SSA-BiLSTM用时减少了34.78 s,较BiLSTM用时减少了75.73 s,时间成本分别减少了27.92%、45.76%。

表3 实验误差对比
Table 3 Comparison of experimental errors

模型	RMSE	MAE	MAPE	R^2	NSE	t/s
ISSA-BiLSTM	0.008 031 7	0.006 451 1	0.002 276 4	0.998 39	0.998 28	89.76
SSA-BiLSTM	0.040 674	0.034 72	0.012 15	0.956 29	0.955 98	124.54
BiLSTM	0.076 886	0.064 401	0.022 63	0.842 74	0.842 7	165.49

3.3 不同预测模型的比较分析

为了进一步验证ISSA-BiLSTM模型预测的准确性，将目前广泛应用的SSA-BiLSTM, BiLSTM, LSTM, SVM, RBF, BP等模型与其对比，以模型的预测率和训练时间为判断标准，以上预测模型均采用上述实验数据。为了提高预测模型的准确性，将以上每个模型进行10次预测，预测实验的准确率如图15所示，预测性能如表4所示。

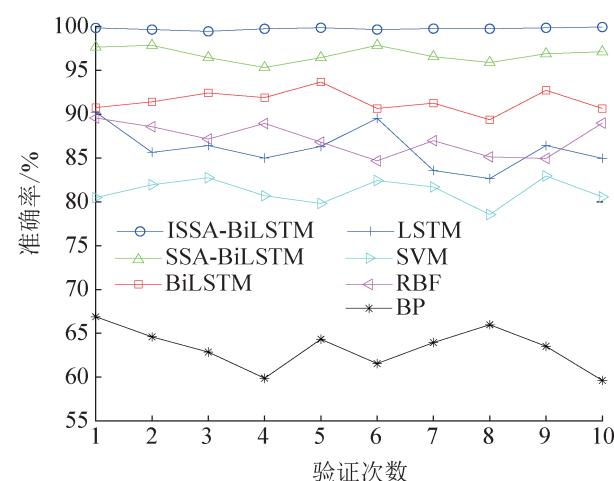


图15 预测结果准确率对比
Fig. 15 Comparison of prediction accuracies

表4 7种模型性能对比
Table 4 Performance comparison of seven models

模型	t/s	准确率/%
ISSA-BiLSTM	89.76	99.658
SSA-BiLSTM	124.54	96.841
BiLSTM	165.49	91.056
LSTM	174.32	87.459
SVM	210.81	81.734
RBF	185.19	86.791
BP	254.29	64.752

4 结论

本文针对多工序产品制造过程的相关性、不确定性、误差累积性以及动态复杂性的特点，以TFT-LCD多工序产品为研究对象展开了一系列相关研究，提出了一种利用智能优化算法构建基于改进BiLSTM的多工序产品质量预测模型，有效

地解决了质量异常的关键要素难以溯源，质量数据不均衡造成质量预测准确性差等质量问题。

(1) 首先通过KPCA对数据进行降维，提取特征向量，将其划分为训练集和测试集，进而通过融入高斯变异和均匀算子 η 的SSA算法优化BiLSTM的初始权重和阙值，从而提高预测模型的精度和稳定性。

(2) 为验证本文提出模型的有效性，选用TFT-LCD多工序产品研究对象，以天池工业AI大赛数据做依托，将预处理后的数据代入到ISSA-BiLSTM预测模型中进行训练与测试；其次，将数据代入到SSA-BiLSTM, BiLSTM两种预测模型中，与ISSA-BiLSTM预测模型进行对比实验；最后，通过决定系数、平均绝对误差等数值进行误差评估，ISSA-BiLSTM的RMSE, MAE, MAPE值均最小，验证了该模型的稳定性，有效的提升了多工序产品质量的预测精度。

参考文献：

- [1] 杨岚, 石宇强. 基于大数据的多工序产品质量预测[J]. 西南科技大学学报, 2020, 35(1): 81-89.
Yang Lan, Shi Yuqiang. Multi-Process Product Quality Prediction Based on Big Data[J]. Journal of Southwest University of Science and Technology, 2020, 35(1): 81-89.
- [2] 张曼. 面向小批量试制的关键工序质量控制技术研究 [D]. 杭州: 杭州电子科技大学, 2013.
Zhang Man. Research on Quality Control Technology of Key Procedure for Small Batch Trial Process[D]. Hangzhou: Hangzhou Dianzi University, 2013.
- [3] Zhou Shangming. Combining Dynamic Neural Networks and Image Sequences in a Dynamic Model for Complex Industrial Production Processes[J]. Expert Systems with Applications, 1999, 16(1): 13-19.
- [4] Li Jianming, Freiheit T, Jack Hu S, et al. A Quality Prediction Framework for Multistage Machining Processes Driven by an Engineering Model and Variation Propagation Model[J]. Journal of Manufacturing Science and Engineering, 2007, 129(6): 1088-1100.
- [5] Du Shichang, Xu Rui, Huang Delin, et al. Markov Modeling and Analysis of Multi-Stage Manufacturing Systems with Remote Quality Information Feedback[J]. Computers & Industrial Engineering, 2015, 88: 13-25.
- [6] Colledani M, Tolio T. Joint Design of Quality and

- Production Control in Manufacturing Systems[J]. CIRP Journal of Manufacturing Science and Technology, 2011, 4(3): 281-289.
- [7] 卢敏童. 基于SVM的制造过程多元质量诊断与控制图模式识别研究[D]. 合肥: 合肥工业大学, 2019.
Lu Mintong. Research on Multivariate Quality Diagnosis and Pattern Recognition of Control Chart Based on SVM for Manufacturing Process[D]. Hefei: Hefei University of Technology, 2019.
- [8] 刘立堃. 多工序制造过程误差综合预测模型研究[D]. 重庆: 重庆大学, 2010.
Liu Likun. Study on Error Synthesis Prediction Model in Multistage Manufacturing Process[D]. Chongqing: Chongqing University, 2010.
- [9] 吕旭泽. 基于PSO-Ls-SVM的发动机多工序装配质量预测模型研究[D]. 合肥: 合肥工业大学, 2016.
Lü Xuze. Research on the Engine Crankshaft Multistep Assembly Quality Prediction Model Based on LS-SVM of Particle Swarm Optimization[D]. Hefei: Hefei University of Technology, 2016.
- [10] 冯尔磊. 基于SMT大数据的产品质量预测方法研究与实现[D]. 西安: 西安电子科技大学, 2018.
Feng Erlei. Research on Analysis Method of SMT Product Quality Prediction Based on Big Data[D]. Xi'an: Xidian University, 2018.
- [11] 李先飞, 高琦, 高菲. 基于IGBCA与SVM的质量预测[J]. 制造技术与机床, 2019(12): 128-132.
Li Xianfei, Gao Qi, Gao Fei. Quality Prediction Model Based on IGBCA and SVM[J]. Manufacturing Technology & Machine Tool, 2019(12): 128-132.
- [12] 杨岚. 基于大数据的多工序制造过程产品质量控制研究[D]. 绵阳: 西南科技大学, 2020.
Yang Lan. Research on Product Quality Control of Multistage Manufacturing Process Based on Big Data [D]. Mianyang: Southwest University of Science and Technology, 2020.
- [13] 李亚平, 陶良彦. 基于改进型GERT网络的多工序制造过程质量损失预测研究[J]. 工业工程与管理, 2021, 26 (5): 150-160.
Li Yaping, Tao Liangyan. Prediction on Quality Loss for a Multi-Stage Manufacturing Process Based on an Improved GERT Network[J]. Industrial Engineering and Management, 2021, 26(5): 150-160.
- [14] 李敏波, 董伟伟. 面向不平衡数据集的汽车零部件质量预测[J]. 中国机械工程, 2022, 33(1): 88-96.
Li Minbo, Dong Weiwei. Quality Prediction of Automotive Parts for Imbalanced Datasets[J]. China Mechanical Engineering, 2022, 33(1): 88-96.
- [15] 杨俊峰. 基于改进灰色幂理论的过程质量控制研究[D]. 兰州: 兰州理工大学, 2019.
Yang Junfeng. Research on Process Quality Control Based on Improved Grey Power Theory[D]. Lanzhou: Lanzhou University of Technology, 2019.
- [16] 江平宇, 王岩, 王焕发, 等. 基于赋值型误差传递网络的多工序加工质量预测[J]. 机械工程学报, 2013, 49(6): 160-170.
Jiang Pingyu, Wang Yan, Wang Huanfa, et al. Quality Prediction of Multistage Machining Processes Based on Assigned Error Propagation Network[J]. Journal of Mechanical Engineering, 2013, 49(6): 160-170.
- [17] Bernhard Schölkopf, Smola A, Klaus-Robert Müller. Nonlinear Component Analysis as a Kernel Eigenvalue Problem[J]. Neural Computation, 1998, 10(5): 1299-1319.
- [18] Xue Jiankai, Shen Bo. A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.