

基于改进 LSTM 的数码雷管模组印刷质量预测

许可^{1a,2}, 高宏宇^{1b,2}, 官华^{1a,2}, 孙文娟^{1a,2}

(1. 沈阳理工大学 a. 理学院, b. 自动化与电气工程学院, 沈阳 110159; 2. 辽宁省兵器工业智能优化与控制重点实验室, 沈阳 110159)

摘要: 由于数码雷管模组印刷过程中生产工艺复杂、强时序性等特点, 其质量的精准预测已成为提高产品质量管理水平的关键。基于此提出一种改进长短期记忆(long short-term memory, LSTM)网络的数码雷管模组印刷质量预测模型。首先根据数码雷管模组印刷过程提炼机器运行参数、环境参数与检测参数作为印刷产品质量的原始特征, 并对关键检测参数进行时序特征重构以增强特征表达能力; 其次基于改进的 LSTM 网络建立数码雷管模组印刷特征提取框架, 采用卷积神经网络提取空间特征避免 LSTM 挖掘高维印刷特征时隐含关系的不足, 通过全局注意力机制自适应学习不同时刻印刷特征对印刷产品质量的贡献度, 为 LSTM 提取的深层时序特征分配不同权值; 最后以深层特征作为输入, 通过全连接网络实现数码雷管模组印刷产品的质量预测。实验结果表明, 相较于 BP 神经网络、门控循环单元网络、LSTM 等预测方法, 改进的 LSTM 网络有效提高了数码雷管模组印刷产品质量的预测精度。

关键词: 模组印刷; 质量预测; 长短期记忆网络; 特征重构

中图分类号: TP183

文献标志码: A DOI:10.3969/j.issn.1003-1251.2025.01.002

Quality Prediction for Digital Detonator Module Printing Based on Improved LSTM

XU Ke^{1,2}, GAO Hongyu^{1,2}, GONG Hua^{1,2}, SUN Wenjuan^{1,2}

(1. Shenyang Ligong University, Shenyang 110159, China;

2. Liaoning Key Laboratory of Intelligent Optimization and Control for Ordnance Industry, Shenyang 110159, China)

Abstract: Due to the complex production process and strong timing characteristics of the digital detonator module printing process, accurate prediction for its quality has become a key to improving product quality management. For this reason, a quality prediction model for digital detonator module printing that improves the long short-term memory network is proposed. First, based on the digital detonator module printing process, the parameters of machine operating, environment and detection are extracted as the original features of the printed product quality, and the key detection parameters are reconstructed in time series to enhance the feature expression ability. Secondly, a digital detonator module printing feature extraction framework is established based on the improved long short-term memory network. The convolutional neural network is designed to extract spatial features to avoid the shortcomings of implicit relationships when LSTM mines high-dimensional printing features. The global attention mechanism is used to adaptively learn the contribution of printing features at different moments to the quality of printed products, and assign different weights to the deep temporal features extracted by LSTM. Finally, deep features are used as input to achieve quality pre-

收稿日期: 2024-03-12

基金项目: 辽宁省教育厅高等学校基本科研项目(LJKQZ2021057, LJKZ0260); 辽宁省“百千万人才工程”资助项目(2021921089); 辽宁省“兴辽英才计划”项目(XLYC2006017)

作者简介: 许可(1982—), 女, 副教授, 博士。

diction for the digital detonator module printing through a fully connected network. Experimental results show that compared with prediction methods such as BP neural network, gated recurrent unit network, and LSTM, the improved long short-term memory network effectively improves the accuracy of quality prediction for digital detonator module printing.

Key words: module printing; quality prediction; long short-term memory network; feature reconstruction

数码电子雷管是在传统雷管的基础上加入电子控制模块,从而实现了对爆破的精准控制,在矿山、建筑、交通等领域已得到了广泛应用。其中数码电子雷管电子控制模块(以下简称为数码雷管模组)印刷过程不仅工艺复杂且受设备等因素的影响较大,从而影响数码雷管的使用效果和安全性,若能对印刷环节进行质量预测可以有效提高产品的生产质量。

近年来,随着生产信息化系统的普及,产品质量预测方法转化为基于数据驱动的机器学习算法。高玉明等^[1]针对小批量产品在生产过程中的不确定因素等问题,提出了梯度优化和最小二乘支持向量机(least squares support vector machine, LSSVM)相结合的多品种、小批量产品质量预测模型。董海等^[2]针对机械产品的质量特性,建立了基于蜻蜓算法的极端梯度提升模型,解决了机械产品质量损失问题。董海等^[3]针对批量交货产品的质量预测问题,采用加权 LSSVM 的方法对交货产品的质量数据进行训练和预测。刘淑伟等^[4]为提高建材装备制造过程中产品质量,提出一种基于遗传算法的支持向量机质量预测模型。Su 等^[5]针对生产过程中零件的质量预测问题,建立了基于粗糙集的粒子群最小二乘支持向量机综合算法。Liu 等^[6]针对转炉炼钢过程中的实时预测问题,提出了一种基于混合核的 LSSVM 动态分析方法。上述方法在解决简单加工过程的产品质量预测问题时具有一定的优势,但当产品的生产工艺复杂、生产数据时序性较强时,往往无法挖掘到产品质量与生产过程工艺参数间的深层关系。

随着生产工艺变得越来越复杂,传统的机器学习对于复杂的非线性建模能力有限,而深度学习方法能够有效地挖掘大量生产数据间的非线性关系,被广泛应用于产品质量预测。丁鹏程等^[7]针对工艺数据存在的高维性、复杂的相关性等问题,提出了一种基于改进多隐层极限学习机的产品质量预测模型。Wang 等^[8]应用粒子群算法优化 BP 的权值和阈值,对复杂机械产品的装配质量

进行预测。林刚等^[9]利用卷积神经网络(CNN),建立带钢产品质量预测模型,从而准确地在线评估带钢质量。段暎^[10]以铣削加工为研究对象,针对刀具磨损预测问题提出一种改进深度残差卷积神经网络(ResNet)的刀具磨损预测算法。戴稳等^[11]针对铣刀磨损状态问题,提出了基于堆叠稀疏编码与 CNN 相结合的预测方法。李欣铜等^[12]针对氟化工等复杂生产过程,提出了一种具有输入注意力(Attention)机制的 CNN 用于化工产品质量预测。何彦等^[13]针对汽车组合仪表组装质量预测问题,提出基于 CNN 与支持向量回归相结合的质量预测方法。Liu 等^[14]为捕捉制造和装配过程中各工序之间的时间相互作用,提出了一种端到端的统一产品质量预测框架。赵圆方等^[15]针对汽车发动机缸体压铸过程,提出了基于长短期记忆(long short-term memory, LSTM)网络的产品质量预测方法。张天瑞等^[16]针对多工序产品制造过程的复杂性,提出了一种改进的双向长短期记忆(bidirectional long short-term memory, BLSTM)网络产品质量预测模型。房鑫洋等^[17]针对复杂产品制造过程中工艺数据的高维性及复杂关联性,提出了一种基于 Attention 与 BLSTM 的复杂产品质量预测方法。Wang 等^[18]针对批处理过程质量预测问题,设计了一种基于堆叠自动编码器的 LSTM 序列模型。Huang 等^[19]针对航空涡扇发动机剩余使用寿命,通过 BLSTM 高效挖掘多个原始传感器中的有效特征,对剩余使用寿命实现精准预测。Ren 等^[20]针对工业智能化生产过程,提出了一种基于广深序列的数据驱动方法,为具有不同类型数据的工业过程提供可靠的产品质量预测。

由于数码雷管模组印刷生产工艺复杂,生产数据间同时存在时序特征及空间特征。因此,单一的网络模型容易忽略高维输入变量的相关特征,而 LSTM 则更适合提取生产工艺间的时序特征。本文结合 CNN、LSTM、Attention,提出一种基于注意力机制的卷积长短期记忆(AT-CNN-LSTM)网络的数码雷管模组印刷产品质量预测

模型。该模型以 LSTM 为基础,采用 CNN 提取印刷产品信息的空间特征,加强 LSTM 的空间表达。并通过引入 Attention 机制增强 LSTM 隐藏层中不同时序信息的重要性差异,以此提高数码雷管模组印刷质量预测精度。

1 问题描述

数码雷管模组主要由控制芯片、存储器、电源

管理电路和模组外壳等组成。其主要生产工艺包括表面贴装 (surface mounted technology, SMT)、模组外壳注塑成型、桥丝点焊等,生产流程如图 1 所示。SMT 工序主要包含锡膏印刷、元器件贴装以及回流焊接,其中锡膏印刷的结果对后续产品的质量有直接影响。在印刷后需经过锡膏检测机 (solder paste inspection, SPI) 进行检查,验证数码雷管模组电路板质量的优劣。

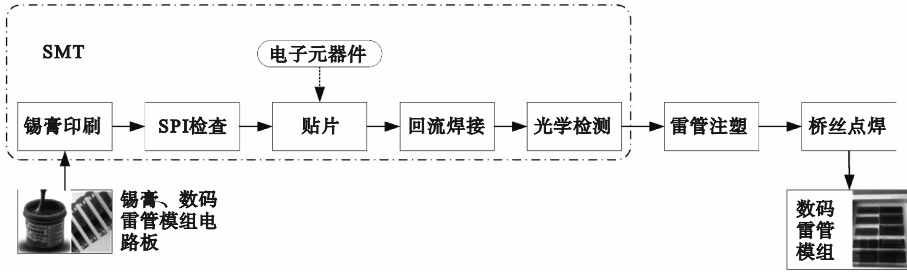


图 1 数码雷管模组生产流程

Fig. 1 Production flow of digital detonator module

进行锡膏印刷时需将数码雷管模组电路板放至钢网下方,在钢网一端添加锡膏,锡膏通过钢网开孔可进入焊盘。刮刀以一定的速度和角度从钢网一端移到另一端,移除钢网和刮刀后,焊盘上会保留一薄层锡膏以便后续回流焊接。锡膏印刷过

程如图 2 所示。钢网、刮刀等参数的设置直接影响锡膏的分布、流动性,环境温度和湿度影响锡膏的凝固速度,此外 SPI 检测可以看出锡膏进入焊盘的尺寸轮廓等。




图 2 数码雷管模组锡膏印刷过程

Fig. 2 Printing process of solder paste

综上,在印刷环节中,影响印刷产品质量的主要特征包括印刷机运行参数、环境参数、SPI 检测参数三类。机器运行参数包括钢网厚度、钢网张力、刮刀长度等;环境参数包括温度和湿度;SPI 检测参数包括焊盘体积、面积、高度。具体印刷特征如表 1 所示。

表 1 数码雷管模组印刷特征

Table 1 Printing characteristics of digital detonator module

特征类型	特征名称
机器运行参数	钢网厚度、钢网张力、刮刀长度、刮刀压力、刮刀行进速度、刮刀角度、刮刀厚度、锡膏粘度、数码雷管模组电路板对角尺寸
SPI 检测参数	焊盘体积、面积、高度
环境参数	环境温度、湿度

由于机器的运行状况、外界环境都与时间息息相关,因此需将上述特征数据构造为时间窗口的形式。印刷特征 $X_t = \{x_t, x_{t+1}, \dots, x_{t+T-1}\}$, 其中 T 为时间窗口长度, $x_t = \{x_t^1, x_t^2, \dots, x_t^D\}$ 是 t 时刻影响数码雷管模组印刷质量的特征集合, D 为特征个数。 y_t 为 t 时刻数码雷管模组印刷产品质量, 即

$$y_t = \begin{cases} 0, & \text{表示 } t \text{ 时刻数码雷管模组印刷质量合格} \\ 1, & \text{表示 } t \text{ 时刻数码雷管模组印刷质量不合格} \end{cases}$$

将时间窗口数据 X_t 作为输入变量, y_t 作为输出变量, 学习 X_t 与 y_t 之间的非线性映射关系, 从而预测 t 时刻数码雷管模组印刷产品质量。

2 基于 AT-CNN-LSTM 印刷质量预测

针对数码雷管模组印刷过程中数据的高频性、多维性、时序性等特点, 设计了基于注意力机

制卷积长短期记忆网络(AT-CNN-LSTM)的数码雷管模组印刷质量预测模型, 其模型结构如图3所示(图中 Cell 为记忆单元)。数据预处理包括对 SPI 检测数据进行时序(time series, TS)特征重构、数据归一化以及将归一化后的数据构造为时间窗口序列形式。AT-CNN-LSTM 预测模型主要由 CNN 层、LSTM 层、Attention 层及输出层构成。首先将时间窗口数据输入到 CNN 层, 用以提取印刷设备参数、环境因素与 SPI 检测数据的空间特征, 以获得数码雷管模组的高维印刷特征表达。然后将 CNN 层的输出送入 LSTM 层, 获取印刷变量间的时间依赖关系, 提取不同时刻印刷变量的时间特性。再将 LSTM 层的隐层状态作为 Attention 层的输入, Attention 层能够学习这些隐层状态的重要性, 赋予不同时刻状态为不同的权值, 通过加权求和得到融合各个时刻的最终特征。最后接入输出层将最终特征转化为不合格产品的概率值 \bar{y}_t , 以实现数码雷管模组印刷质量的精准预测。

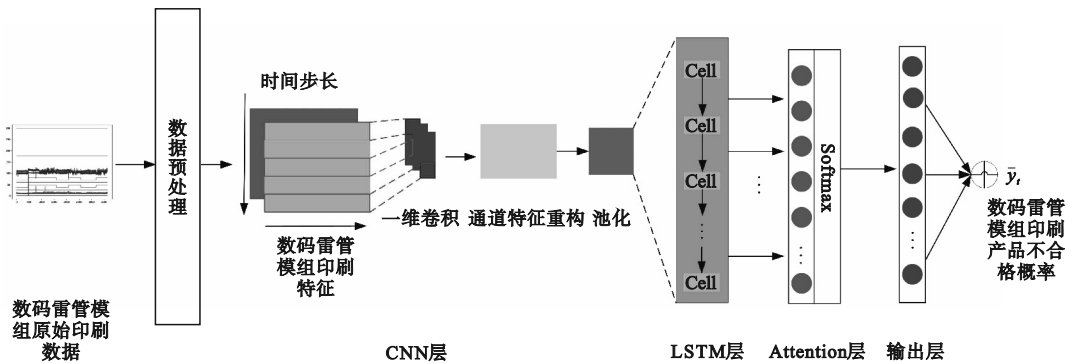


图3 基于 AT-CNN-LSTM 的数码雷管模组印刷质量预测模型

Fig. 3 Printing quality prediction of digital detonator module based on AT-CNN-LSTM

2.1 数据预处理

2.1.1 TS 特征重构

由于原始数据集的获取是以焊盘为单位, 而实际的数码雷管模组印刷过程是以拼板为单位, 即每个拼板包含多个数码雷管模组电路板, 每个数码雷管模组电路板包含多种类型的焊盘, 每种类型的焊盘包含数量不一的焊盘个数。在经过 SPI 检测时可以获得每个焊盘的体积、面积、高度等数据。因此不能直接将原始数据作为模型的输入。为满足生产要求、增强特征的表达能力, 对每个拼板中焊盘的体积、面积和高度进行 TS 特征重构, 每一个 SPI 检测特征将由 5 个 TS 特征 (ts_1 、 ts_2 、 ts_3 、 ts_4 、 ts_5) 进行表示, 如表 2 所示。

表 2 TS 特征构建

Table 2 TS feature construction

TS 特征	描述
ts_1	\bar{z}_k
ts_2	$\sqrt{\frac{1}{n} \sum_{r=1}^n (z_k^r - \bar{z}_k)^2}$
ts_3	$\max(z_k) - \min(z_k)$
ts_4	$\frac{1}{n} \sum_{r=1}^n (z_k^r - \bar{z}_k)^3 \left/ \left(\sqrt{\frac{1}{n} \sum_{r=1}^n (z_k^r - \bar{z}_k)^2} \right)^3 \right.$
ts_5	$\frac{1}{n} \sum_{r=1}^n (z_k^r - \bar{z}_k)^4 \left/ \left(\sqrt{\frac{1}{n} \sum_{r=1}^n (z_k^r - \bar{z}_k)^2} \right)^4 \right.$

表 2 中 n 为 1 次 SPI 检测的产品焊盘个数, z_k^r 为第 k 检测项第 r 个焊盘的检测值, \bar{z}_k 为第 k 检测

项的平均值。

2.1.2 数据归一化

由于数码雷管模组印刷过程数据的度量单位不同,为消除不同量纲的影响,需对数据进行最大-最小归一化处理,计算过程如式(1)所示。

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x_i 为印刷工艺数据($i=1,2,\dots,D$), i 为印刷特征索引; x_{\max} 、 x_{\min} 为 x_i 最大、最小值; x_i^* 为 x_i 归一化后数据。

2.1.3 时间窗口构建

给定长度为 3 的时间窗口,窗口在归一化后的数据集上每次截取连续长度为 3 的子数据集,将窗口依次向下滑动,直至整个时序数据集构建完成,其过程如图 4 所示。

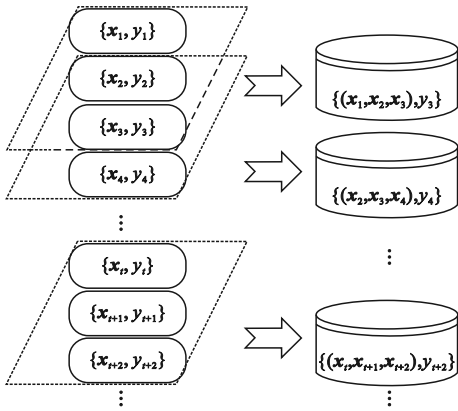


图 4 时间窗口构建

Fig. 4 Time window construction

2.2 基于 CNN 的印刷特征提取

CNN 变体繁多,其 1DCNN 是以一维卷积的方式提取序列数据特征,通过堆叠一维卷积层和池化层实现数码雷管模组印刷特征的深度挖掘,捕捉印刷工艺间的特征信息,弥补了 LSTM 网络空间特征提取能力不足。基于 CNN 的印刷特征提取结构如图 5 所示。




图 5 CNN 印刷特征提取结构

Fig. 5 CNN printing feature extraction structure

将时间窗口数据 X_i 作为输入,通过一维卷积进行特征提取,再经过池化层对数据进行下采样得到 CNN 层输出特征 $M = \{m_1, m_2, \dots, m_T\}$,其中

m_1, \dots, m_T 为经 CNN 提取后数码雷管模组印刷特征。在每次卷积操作后需将得到的多通道特征重构为单通道特征,避免一维卷积后造成多通道数据离散问题。

一维卷积是特征提取的关键,通过训练数码雷管模组印刷数据得到一组使损失函数最小的卷积核,利用卷积核提取数码雷管模组印刷过程中的关键特征。数码雷管模组印刷数据由 T 个采样时间的 D 个特征组成,即在不同采样时间采集相同特征的不同变量值,行变量和列变量之间的相关性完全不同,为避免混淆印刷特征和时间特征之间的关系,本文选用了时间方向维度为 1 的卷积核,即卷积核尺寸为 $1 \times D$,卷积步长为 1。通过卷积核对输入数据 X_i 进行卷积操作,实现数码雷管模组印刷特征提取,其计算表达式为

$$m_j^l = F(w_j^l \otimes v^l + q_j) \quad (2)$$

式中: m_j^l 为经第 l 层第 j 个卷积核卷积后输出; F 为激活函数; \otimes 表示卷积操作; w_j^l 为第 l 层第 j 个卷积核; v^l 为第 l 层输入; q_j 为偏置值。

在卷积过程中通常选取 ReLU 作为激活函数,但当 ReLU 函数的输入值为负数时,其输出为 0,导致部分神经元死亡,相应的权重无法更新。因此本文采用 Leaky_ReLU 激活函数,引入斜率 K ,即当输入为负时,Leaky_ReLU 的输出仍为非 0 值,为减轻梯度消失问题,令 $K = 0.01$,其计算表达式为

$$\text{Leaky_ReLU} = \begin{cases} -Kx, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3)$$

2.3 基于 LSTM 的时序特征提取

利用 CNN 层对数码雷管模组印刷数据进行空间特征提取,并将提取后的印刷特征数据用于训练 LSTM,印刷特征数据通过遗忘门 f_t 、输入门 i_t 、输出门 o_t 在隐藏层的不同单元之间传递,从而控制对以往时刻和当前时刻印刷特征的记忆和遗忘程度,实现对数码雷管模组印刷数据时间特征的提取。基于 LSTM 的时序特征提取结构如图 6 所示。

图 6 中 δ 为 Sigmoid 激活函数, \tanh 为双曲正切激活函数, LSTM 网络结构的输入和输出表达式为

$$f_t = \delta(\omega_f [h_{t-1}, m_t] + b_f) \quad (4)$$

$$i_t = \delta(\omega_i [h_{t-1}, m_t] + b_i) \quad (5)$$

$$\tilde{c}_t = \tanh(\omega_c [h_{t-1}, m_t] + b_c) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (7)$$

$$o_t = \delta(\omega_o [h_{t-1}, m_t] + b_o) \quad (8)$$

$$h_t = o_t \odot \tanh(c_t) \quad (9)$$

式中: $\omega_f, \omega_i, \omega_c, \omega_o$ 为遗忘门、输入门、候选单元和输出门的输入权值; b_f, b_i, b_c, b_o 为遗忘门、输入门、候选单元和输出门的偏置权值; m_t 表示 t 时刻输入; h_t 表示 t 时刻输出; \tilde{c}_t 和 c_t 分别为候选单元状态以及记忆单元状态。式(4)是遗忘门函数, 决定遗忘多少上一时刻的数码雷管模组印刷数据信息; 式(5)是输入门函数, 选择性保留当前时刻的印刷信息; 式(6)定义了要添加到 c_t 的候选值 \tilde{c}_t ; 式(7)为 c_t 的状态更新, 表示当前时刻印刷信息与上一时刻印刷信息的融合; \odot 代表两个向量对应元素相乘; 式(8)决定输出 c_t 中信息的比例; 式(9)表示 LSTM 的时序特征输出。

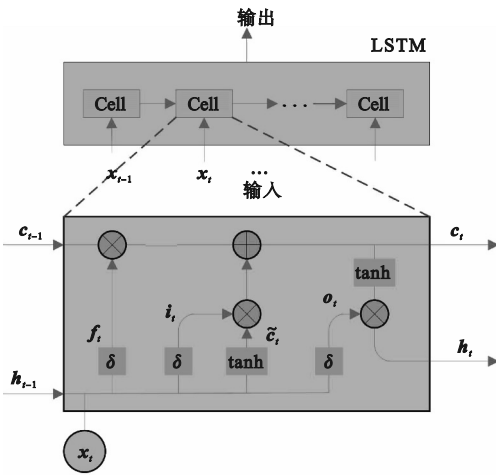


图6 LSTM 时序特征提取结构

Fig. 6 LSTM time series feature extraction structure

2.4 基于注意力机制的时序特征权值分配

全局注意力机制是一种在序列模型中常用的注意力机制, 使模型在整体的时序特征中关注重要时刻的印刷信息, 弥补了 LSTM 因固定的滑动窗口或固定位置的门控机制来获取数码雷管模组印刷数据而导致模型无法区分时间特征的重要程度。全局注意力机制网络结构如图7所示。




图7 全局注意力机制结构

Fig. 7 Global attention mechanism structure

数码雷管模组印刷数据经 LSTM 层提取出长期依赖关系的时序特征后, 将其输出 $H = \{h_t\}$,

h_2, \dots, h_r 作为注意力层的输入, 注意力层将自动学习 LSTM 层中隐藏状态下各时刻的重要性, 根据不同时刻的重要性赋予不同的权重并进行加权求和。经加权后得到的印刷特征综合了 LSTM 层中每个时刻的时序特征, 更有利于提高产品的预测精度、增强模型的代表能力。全局注意力机制的实现步骤如下。

步骤1 初始化权值并计算输入特征的注意力得分, 计算式为

$$e_t = \tanh(\omega_t h_t + g_t) \quad (10)$$

步骤2 应用 Softmax 函数增强注意力得分的差异性, 并确保所有得分之和为 1, 表达式为

$$a_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)} \quad (11)$$

式中: e_t 为神经元提取后的时间序列信息; a_t 为对应印刷信息的时间序列权重。

步骤3 计算印刷特征, 计算式为

$$S = \sum_{i=1}^T a_i h_i \quad (12)$$

式中 S 为对 h_t 加权求和得到的最终印刷特征。

2.5 输出层

经过 CNN 层、LSTM 层和 Attention 层的特征提取, 实现了数码雷管模组印刷特征的深度挖掘, 输出层则主要负责全连接网络的搭建以实现数码雷管模组印刷环节质量的最终预测。由于在数码雷管模组印刷环节中合格产品的数量远大于不合格产品的数量, 数据量失衡易使模型的预测结果更加倾向多数样本, 造成少数样本预测难度增大, 从而使模型的预测结果偏离实际情况。因此本文引入 FocalLoss 损失函数来解决合格产品与不合格产品的数量失衡问题。FocalLoss 通过引入参数 α 和 γ 对二分类交叉熵损失函数进行更改。损失函数 $FL(p_t)$ 计算表达式为

$$FL(p_t) = -\alpha(1-p_t)^\gamma \log(p_t) \quad (13)$$

式中: p_t 为 t 时刻经印刷环节后数码雷管模组属于合格或不合格类型概率值; α 用于调节合格、不合格产品损失之间的比例, α 越大不合格产品所占的权重越大; γ 用于调节易分类产品与难分类产品的损失贡献度, γ 越大错误分类产品的权重越大。本文中参数 α 与 γ 的组合采用文献[21]中的建议值: $\alpha = 0.25, \gamma = 2$ 。

为避免模型过拟合或陷入局部最优, 向损失函数 FocalLoss 中添加 L2 正则化项, 得到如式(14)所示的带有权重惩罚因子的损失函数 $FL'(p_t)$ 。

$$FL'(p_i) = -\alpha(1 - p_i)^\gamma \log(p_i) + \beta \sum_{i=0}^m \omega_i^2 \quad (14)$$

式中: β 为正则化系数; ω_i 为训练权重。

3 实验分析

3.1 实验环境及实验数据

为验证数码雷管模组印刷质量预测模型的实用性,在不同的网络结构和参数下进行多次实验。所有实验均在一台具有 16 G 内存、Intel(R) Core

(TM) i5 - 8265U CPU@ 1.60 GHz 和 Nvidia GeForce MX 250 GPU 的计算机上进行。软件框架结构使用 Python3.6,以开源的深度学习库 PyTorch 作为引擎,实现本文算法模型的应用。

将 TS 特征加入原始数据集中构成新的特征数据集,并按公式(1)处理,再将数据以 8:2 的比例划分为训练集和测试集。实验数据如表 3 所示,其中 $V-ts_1$ 表示模组焊盘体积的 ts_1 特征, $A-ts_1$ 表示模组焊盘面积的 ts_1 特征, $H-ts_1$ 表示模组焊盘高度的 ts_1 特征。

表 3 数码雷管模组印刷数据集

Table 3 Printing data set of digital detonator module

产品编码	钢网厚度/ mm	钢网张力/ N	刮刀速度/ (mm·s ⁻¹)	刮刀压力/ N	环境温度/ ℃	...	$V-ts_1$ / μm ³	$A-ts_1$ / μm ²	$H-ts_1$ / μm	检测结果
1	0.15	37.5	70	9	25.4	...	99.36	111.01	95.26	1
2	0.15	37.5	70	9	25.4	...	95.69	106.10	95.98	1
3	0.15	37.5	70	9	25.4	...	102.78	110.51	99.05	0
4	0.15	37.5	70	9	25.4	...	98.03	107.29	97.30	1
5	0.15	37.5	70	9	25.4	...	103.28	110.32	99.68	0
6	0.15	37.5	70	9	25.4	...	99.86	108.01	98.43	0
7	0.15	37.5	70	9	25.4	...	102.58	110.34	99.03	0
8	0.15	37.5	70	9	25.4	...	98.69	106.89	98.28	0
9	0.15	37.5	70	9	25.4	...	100.10	108.55	98.23	0
10	0.15	37.5	70	9	25.4	...	98.82	106.66	98.64	0
11	0.15	37.5	70	9	25.4	...	95.76	108.31	98.13	0
...
3630	0.12	47.5	80	9	25	...	112.61	108.38	106.67	0
3631	0.12	47.5	80	9	25	...	114.59	110.46	106.56	1

3.2 实验参数

本文模型的参数主要涉及 CNN 层和 LSTM 层。Attention 层和输出层参数由上游输入和目标输出决定,无需单独设置。本文对 CNN 层、LSTM 层及基本参数进行多次实验以寻找最优参数组合。

为平衡模型的复杂性和训练效率,需对 AT-CNN-LSTM 模型的网络结构、时间步长、学习率、L2 正则化系数进行预测。其结果如表 4 所示(其中,以网络结构 $C_{32}^1 - B_8^2$ 为例,表示网络第一层为 CNN 层,卷积核数为 32,网络第二层为 LSTM 层,神经元数为 8)。

由表 4 可知,当 AT-CNN-LSTM 的结构为 $C_{22}^1 - C_{16}^2 - B_{32}^3$ 时, FL' 相对较小,表明此时数码雷管模组的印刷特征被充分挖掘。

表 4 不同参数下 AT-CNN-LSTM 预测性能

Table 4 AT-CNN-LSTM prediction performance under different parameters


编号	网络结构	窗口长度	学习率	L2 正则化系数	FL'
1	$C_{22}^1 - B_{32}^2$	3	0.001	0.000 1	0.005 2
2	$C_{32}^1 - B_{36}^2$	6	0.005	0.000 5	0.004 8
3	$C_{42}^1 - B_{60}^2$	12	0.010	0.001 0	0.004 6
4	$C_{22}^1 - C_{16}^2 - B_{32}^3$	3	0.001	0.000 1	0.003 7
5	$C_{32}^1 - C_{16}^2 - B_{36}^3$	6	0.005	0.000 5	0.004 2
6	$C_{42}^1 - C_{21}^2 - B_{60}^3$	12	0.010	0.001 0	0.004 3
7	$C_{22}^1 - C_{16}^2 - B_{32}^3 - B_{16}^4$	3	0.001	0.000 1	0.004 1
8	$C_{32}^1 - C_{16}^2 - B_{36}^3 - B_{23}^4$	6	0.005	0.000 5	0.004 3
9	$C_{42}^1 - C_{21}^2 - B_{60}^3 - B_{30}^4$	12	0.010	0.001 0	0.004 6

为讨论池化策略及尺寸对模型的影响,在 $C_{22}^1 - C_{16}^2 - B_{32}^3$ 结构中采用不同的池化策略和尺寸。其模型的预测性能对比结果如表5所示。

表5 不同池化策略和尺寸下 AT-CNN-LSTM 预测性能

Table 5 AT-CNN-LSTM prediction performance under different pooling strategies & sizes

池化策略	池化尺寸	池化步长	FL'
无池化层			0.003 7
平均池化	2	1	0.003 6
	3	2	0.004 0
	4	1	0.004 1
	2	2	0.004 5
最大池化	3	1	0.003 1
	4	2	0.004 3



(a) 迭代收敛

由表5可知,过大的池化尺寸与池化步长可能导致印刷特征丢失,模型性能下降,较小的池化尺寸与步长易造成信息的冗余。当池化尺寸为3、池化步长为1时 FL' 损失较低。


模型迭代次数为100,样本数量为16。

3.3 实验结果

本文使用准确率、精确率、召回率和 $F1$ 值评估模型的性能。

AT-CNN-LSTM模型迭代收敛情况与预测结果混淆矩阵如图8所示。

从图8(a)可知,AT-CNN-LSTM模型经100次迭代 FL' 损失值达到0.0031。从图8(b)可知,有32个产品实际合格而预测为不合格,有36个产品实际不合格而预测为合格。其准确率、精确率、召回率和 $F1$ 值如表6所示。



(b) 混淆矩阵

图8 AT-CNN-LSTM 迭代收敛与预测结果混淆矩阵

Fig. 8 AT-CNN-LSTM iterative convergence and prediction results confusion matrix

表6 AT-CNN-LSTM 预测精度

Table 6 AT-CNN-LSTM prediction accuracy %

模型	准确率	精确率	召回率	$F1$ 值
AT-CNN-LSTM	90.62	82.69	84.31	83.50

由表6可知,AT-CNN-LSTM模型的预测准确率达到90.62%, $F1$ 值达到83.50%,其预测结果较优。在数码雷管模组印刷过程中,加工人员可根据此预测结果并结合SPI检测结果综合判断数码雷管模组印刷的质量,减少未被发现的不合格模组进入下一个工艺流程的数量。

3.4 实验对比

将本文所提模型与BPNN^[22]、XGBOOST^[23]及LSTM^[15]、GRU^[24]、CNN-LSTM^[25]、Informer^[26]

模进行实验对比,以此来验证AT-CNN-LSTM模型的有效性。

上述模型的相关超参数设置如下:BPNN中网络层数设为3,隐藏层神经元个数为(256,64,32),学习率设为0.0010,迭代次数为1000,采用Sigmoid激活函数并添加惩罚系数为0.0001的L2正则化项;SVM惩罚因子为50,采用多项式核函数,其中多项式核函数中的阶数设为3;XGBOOST中学习率为0.001,树的最大深度为8,子级中实例重量的最小总和为1.2,提升阶段树最大迭代次数为1000,正则化系数为0.0001;LSTM、GRU、CNN-LSTM、Informer中所涉及到的参数与本文模型中所涉及的参数保持一致。上述模型的精确率-召回率曲线对比结果如图9所示。

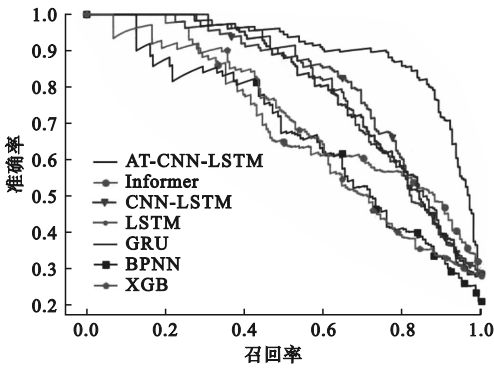


图 9 数码雷管模组印刷质量预测对比图

Fig. 9 Comparison diagram of digital detonator module printing quality prediction

由图 9 可知,AT-CNN-LSTM 算法优于上述其他对比算法。为进一步体现模型在测试样本中的预测精度,计算上述模型的准确率、精确率、召回率和 $F1$ 值,结果如表 7 所示。

表 7 数码雷管模组印刷质量预测对比

Table 7 Comparison of printing quality prediction of digital detonator modules %

模型	准确率	精确率	召回率	$F1$ 值
XGBOOST	79.92	67.06	55.88	60.96
BPNN	86.52	71.57	51.41	59.84
GRU	82.48	68.78	69.12	68.95
LSTM	84.55	77.71	63.24	69.73
CNN-LSTM	83.72	70.28	73.04	71.63
Informer	85.52	70.89	82.35	76.19
AT-CNN-LSTM	90.62	82.69	84.31	83.50

由表 7 可知,本文所提 AT-CNN-LSTM 方法在准确率、精确率、召回率和 $F1$ 值上均优于其他算法。且与 BPNN、XGBOOST 等非时序算法相比,其准确率、精确率、召回率、 $F1$ 值平均提升了 7.40%、13.38%、30.67%、23.10%,与 GRU、LSTM 等时序算法相比其准确率、精确率、召回率、 $F1$ 值平均提升了 6.55%、10.77%、13.12%、11.88%,表明 AT-CNN-LSTM 算法不仅挖掘数码雷管模组印刷数据的时间特征与空间特征,还在在此基础上引入 Attention 机制,增强了模型对不同时刻特征的敏感程度,从而提升了模型的预测精度。

为了有足够的时间应对可能出现的不合格产品,需要提前一步来预测数码雷管模组印刷质量,考虑根据当前时刻 t 的前 3 个时刻特征值预测 t 时刻的产品合格与否。不同时刻产品的预测精度

不同,其对比结果如表 8 所示。

表 8 不同时刻数码雷管模组印刷质量预测对比

Table 8 Comparison of printing quality prediction of digital detonator modules at different times %

时间	准确率	精确率	召回率	$F1$ 值
t 时刻	90.62	82.69	84.31	83.50
$t+1$ 时刻	71.27	73.67	73.67	73.67
$t+2$ 时刻	71.37	70.40	70.20	70.30
$t+3$ 时刻	66.62	69.21	66.49	67.82

表 8 显示了预测未来时刻数码雷管模组印刷质量的分类准确率、精确率、召回率、 $F1$ 值与 t 时刻(即当前时刻)的比较结果,可以看出,随着时间的拉长,预测精度下降,但精度下降速度在可接受范围内,一定程度上仍可以判断出未生产的数码雷管模组印刷质量,因此可将事后处理转化为事前预防,为数码雷管模组的生提供一定的指导。

4 结论

本文针对数码雷管模组印刷数据具有时序性、印刷质量类别具有不平衡性等特点,提出了一种基于 AT-CNN-LSTM 的数码雷管模组印刷过程质量预测方法。经实验表明,与现有的其他机器学习算法相比,本文所提方法在准确率、 $F1$ 值性能指标上平均高出 6.84% 和 15.62%,验证了算法的有效性。本文的主要贡献如下。

1) 在原始印刷数据集的基础上对 SPI 检测数据进行 TS 特征重构,既解决了数据采集的高频性问题,又增强了原始数据集中特征表达。

2) 将 CNN 和 Attention 融入预测框架中,通过 CNN 提取数码雷管印刷产品的空间特征。通过 Attention 分析 LSTM 隐藏层与目标输出的相关性,加强重要时序特征的注意力权重,提高了印刷质量的预测精度。

3) 引入 FocalLoss 损失函数解决类别不平衡问题,增强模型的精确度。

4) 对数码雷管模组印刷质量的未来趋势进行预测,实现了数码雷管模组印刷质量的事前控制。

在未来的研究中可以进一步考虑数码雷管模组印刷缺陷的类型,将相同缺陷类型的产品划分为一类,以便后续的质量追溯。

参考文献 (References):

[1] 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.
- GAO Y M, ZHANG T R, ZHANG S. Multi-variety and small-batch product quality prediction method based on GBO-LSSVM[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2022(6): 175-179. (in Chinese)
- [2] 董海, 田赛. 基于 DA-XGboost 算法的复杂机械产品质量预测[J]. 组合机床与自动化加工技术, 2021(3): 53-56.
- DONG H, TIAN S. Quality prediction of complex mechanical products based on DA-XGboost algorithm[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2021(3): 53-56. (in Chinese)
- [3] 董海, 徐德珉. 基于加权 LS-SVM 的批量产品标准差预测与质量控制[J]. 统计与决策, 2020, 36(16): 172-175.
- DONG H, XU D M. Standard deviation prediction and quality control of batch products based on weighted LS-SVM[J]. *Statistics & Decision*, 2020, 36(16): 172-175. (in Chinese)
- [4] 刘淑伟, 郭顺生. 基于遗传算法-支持向量机的建材产品质量预测方法研究[J]. 机械制造, 2016, 54(11): 93-95, 99.
- LIU S W, GUO S S. Research on quality prediction method of building materials products based on genetic algorithm-support vector machine[J]. *Machinery*, 2016, 54(11): 93-95, 99. (in Chinese)
- [5] SU Y Y, HAN L J, WANG J N, et al. Quantum-behaved RS-PSO-LSSVM method for quality prediction in parts production processes[J]. *Concurrency and Computation: Practice and Experience*, 2022, 34(7): e5522.
- [6] LIU C, TANG L X, LIU J Y, et al. A dynamic analytics method based on multistage modeling for a BOF steelmaking process[J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(3): 1097-1109.
- [7] 丁鹏程, 战洪飞, 林颖俊, 等. 基于多隐层极限学习机的产品质量预测方法[J/OL]. 计算机集成制造系统, 2023: 1-21[2024-03-01]. <https://kns.cnki.net/kcms/detail/11.5946.TP.20231101.1348.006.html>.
- DING P C, ZHAN H F, LIN Y J, et al. Product quality prediction method based on multiple hidden layer extreme learning machine[J/OL]. *Computer Integrated Manufacturing Systems*, 1-21[2024-03-01]. <https://kns.cnki.net/kcms/detail/11.5946.TP.20231101.1348.006.html>. (in Chinese)
- [8] WANG X, LIU M, GE M, et al. Research on assembly quality adaptive control system for complex mechanical products assembly process under uncertainty[J]. *Computers in Industry*, 2015, 74: 43-57.
- [9] 林刚, 王庆强, 宋泽平, 等. 基于卷积神经网络的带钢质量预测[J]. 仪表技术, 2020(5): 5-7, 40.
- LIN G, WANG Q Q, SONG Z P, et al. Strip quality prediction based on convolutional neural network[J]. *Instrumentation Technology*, 2020(5): 5-7, 40. (in Chinese)
- [10] 段喆. 基于深度学习的刀具磨损识别与预测关键技术研究[D]. 武汉: 华中科技大学, 2021.
- [11] 戴稳, 张超勇, 孟磊磊, 等. 采用深度学习的铣刀磨损状态预测模型[J]. 中国机械工程, 2020, 31(17): 2071-2078.
- DAI W, ZHANG C Y, MENG L L, et al. Prediction model of milling cutter wear status based on deep learning[J]. *China Mechanical Engineering*, 2020, 31(17): 2071-2078. (in Chinese)
- [12] 李欣铜, 陈志冰, 魏志强, 等. 具有输入数据注意力机制的卷积神经网络用于氟化工产品质量预测[J]. 化工进展, 2022, 41(2): 593-600.
- LI X T, CHEN Z B, WEI Z Q, et al. Convolution neural network with attention mechanism of input data for quality prediction of fluorine chemical products[J]. *Chemical Industry and Engineering Progress*, 2022, 41(2): 593-600. (in Chinese)
- [13] 何彦, 肖圳, 李育锋, 等. 使用 CNN-SVR 的汽车组合仪表组装质量预测方法[J]. 中国机械工程, 2022, 33(7): 825-833.
- HE Y, XIAO Z, LI Y F, et al. An assembly quality prediction method for automotive instrument clusters using CNN-SVR[J]. *China Mechanical Engineering*, 2022, 33(7): 825-833. (in Chinese)
- [14] LIU Z Y, ZHANG D H, JIA W Q, et al. An adversarial bidirectional serial-parallel LSTM-based QTD framework for product quality prediction[J]. *Journal of Intelligent Manufacturing*, 2020, 31(6): 1511-1529.
- [15] 赵圆方, 高媛, 钱峰, 等. 应用 LSTM 网络的缸体压铸质量预测[J]. 机械设计与制造, 2021(7): 229-232.
- ZHAO Y F, GAO Y, QIAN F, et al. Quality prediction of cylinder die castings based on LSTM network[J]. *Machinery Design & Manufacture*, 2021(7): 229-232. (in Chinese)
- [16] 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.
- ZHANG T R, LIU Y T, WANG Y K. Research on multi-process product quality prediction based on improved BiLSTM[J]. *Journal of System Simulation*, 2023, 35(11): 2321-2332. (in Chinese)
- [17] 房鑫洋, 张洁, 吕佑龙, 等. 基于 Attention-BLSTM 的复杂产品制造质量预测方法[J]. 计算机集成制造系统, 2023, 29(12): 3974-3984.
- FANG X Y, ZHANG J, LYU Y L, et al. Attention-BLSTM-based quality prediction for complex products[J]. *Computer Integrated Manufacturing Systems*, 2023, 29(12): 3974-3984. (in Chinese)
- [18] WANG K, GOPALUNI R B, CHEN J, et al. Deep learning of complex batch process data and its application on quality prediction[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(12): 7233-7242.
- [19] HUANG C G, HUANG H Z, LI Y F. A bidirectional LSTM prognostics method under multiple operational conditions[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(11): 8792-8802.
- [20] REN L, MENG Z H, WANG X K, et al. A wide-deep-sequence model-based quality prediction method in industrial process analysis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(9): 3721-3731.
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2999-3007.
- [22] 张蕾. 基于 BP 网络的产品质量预测-控制模型的研究[J]. 机械设计与制造工程, 2018, 47(8): 97-101.
- ZHANG L. Research on the product quality prediction-control model based on BP network[J]. *Machine Design and Manufacturing Engineering*, 2018, 47(8): 97-101. (in Chinese)
- [23] 杨正森. 基于 FTRL 和 XGBoost 算法的产品故障预测模型[J]. 计算机系统应用, 2019, 28(3): 179-184.
- YANG Z S. Product fault prediction model based on FTRL and XGBoost algorithm[J]. *Computer Systems & Applications*, 2019, 28(3): 179-184. (in Chinese)