

doi: 10.7690/bgzdh.2025.04.006

# 基于 LSTM 和贝叶斯网络的枪械交验合格率预测

王宪升<sup>1</sup>, 胡 瑶<sup>1</sup>, 姜黎明<sup>1</sup>, 郝 佳<sup>2</sup>, 孙嘉伟<sup>2</sup>, 张晓宁<sup>2</sup>, 陈东阳<sup>1</sup>

(1. 重庆建设工业(集团)有限责任公司工艺技术研究所, 重庆 400054;

2. 北京理工大学机械与车辆学院, 北京 100081)

**摘要:** 为准确定位影响成枪一次交验合格率的关键加工环节, 选取贝叶斯网络构建加工参数与合格率之间的因果模型。通过选取长短期记忆(long short-term memory, LSTM)神经网络模型作为成枪一次交验合格率的时间序列预测模型, 能较准确地预测下一批次的成枪一次交验合格率, 进一步定位到关键加工环节。结果表明, 该预测可为下一步有针对性地改进生产工艺提供理论参考。

**关键词:** 交验合格率; 预测; LSTM 模型; 贝叶斯网络**中图分类号:** TJ2   **文献标志码:** A

## Prediction of Firearms Acceptance Rate Based on LSTM and Bayesian Network

Wang Xiansheng<sup>1</sup>, Hu Yao<sup>1</sup>, Jiang Liming<sup>1</sup>, Hao Jia<sup>2</sup>, Sun Jiawei<sup>2</sup>, Zhang Xiaoning<sup>2</sup>, Chen Dongyang<sup>1</sup>

(1. Institute of Process Technology, Chongqing Jianshe Industry (Group) Co., Ltd., Chongqing 400054, China;

2. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China)

**Abstract:** In order to accurately locate the key processing links affecting the pass rate of the first delivery of the finished gun, the Bayesian network is selected to construct a causal model between the processing parameters and the pass rate. By selecting the long short-term memory (LSTM) neural network model as the time series prediction model for the pass rate of the first delivery of guns, the pass rate of the first delivery of guns in the next batch can be predicted more accurately, and the key processing links can be further located. The results show that the prediction can provide a theoretical reference for the next targeted improvement of the production process.

**Keywords:** acceptance rate; prediction; LSTM model; Bayesian network

## 0 引言

笔者通过选取某新型装备加工过程中成枪一次交验合格率数据, 利用历史的成枪一次交验合格率预测下一批次的成枪一次交验合格率, 选用基于长短期记忆(LSTM)神经网络的方法来进行一次交验合格率的预测。

## 1 交验合格率预测模型构建

### 1.1 LSTM 模型

近年来, 随着深度学习技术的不断发展, 一些深度学习模型逐渐被应用到时序数据的研究中。深度学习模型是一种拥有多个非线性映射层级的深度神经网络模型, 能够对输入信号逐层抽象并提取特征, 挖掘出更深层次的潜在规律<sup>[1]</sup>。

循环神经网络(recurrent neural network, RNN)由于其网络结构与普通神经网络不同, 非常适合对时间序列进行处理和预测。目前, 循环神经网络已经在时序分析、语音识别等问题上取得了长足的发展<sup>[2]</sup>。与传统的BP神经网络有所不同, 循环神经

网络能够记忆并利用之前的数据信息, 对后面输出结果产生影响, 更适合用于时间序列数据的预测。

普通的RNN模型中, 其重复神经网络模块的链式模型如图1所示。这个重复的模块只有一个非常简单的结构, 一个单一的神经网络层(例如tanh层), 这样就会导致信息的处理能力比较低。

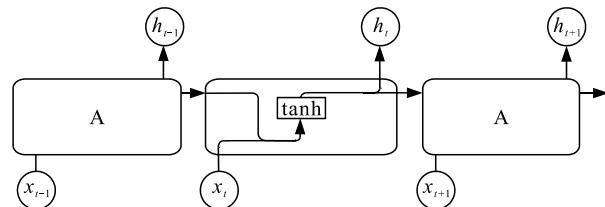


图1 循环神经网络结构

LSTM<sup>[3]</sup>是循环神经网络的一种, 具有的特殊结构使得它具有长时记忆功能。当所学知识与预测位置相差较远时, 循环神经网络的学习能力会下降。LSTM神经网络能够解决循环神经网络长期依赖的问题。与普通的循环神经网络的不同之处在于, LSTM是一种具有3个特殊的“门”结构的神经网络模型。“门”通过“开”和“关”, 控制信息选

收稿日期: 2024-08-09; 修回日期: 2024-09-18

第一作者: 王宪升(1990—), 男, 山东人。

择性地通过。通过使用激活函数, 控制通过这个结构的信息量。当“门”值为 1 时, 所有信息通过; 当“门”值为 0 时, 无信息通过。遗忘门(forget gate)的作用是让神经网络忘记上一单元没有用的信息; 输入门(input gate)的作用是补充最新的记忆给神经网络, 使网络不断接受新的信息; 输出门(output gate)的作用是决定当前时刻的输出。其中遗忘门和输入门至关重要, 是 LSTM 神经网络的核心。通过遗忘门和输入门, LSTM 神经网络可以更加有效地决定哪些信息应该被遗忘, 哪些信息应该被保留。LSTM 的细胞结构如图 2 所示。

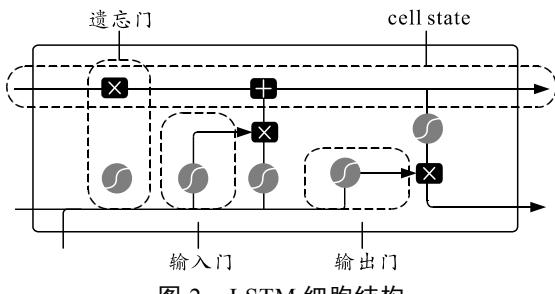


图 2 LSTM 细胞结构

## 1.2 基于 LSTM 的一次交验合格率预测模型构建

Pytorch 是 Python 的一个机器学习包, 与 Tensorflow 类似, Pytorch 非常适合用来构建神经网络模型, 并且已经提供了一些常用的神经网络模型包, 用户可以直接调用。笔者使用 Pytorch 来构建基于 LSTM 的一次交验合格率预测模型。

根据事先人为指定的规则对加工数据进行统计分析, 计算每个批次成枪的一次交验合格率, 对数据进行归一化操作, 这些合格率数据即为算法的训练数据。

算法的一个关键参数是滑动时间窗的大小, 即多少个输入数据对应一个预测的输出数据。如图 3 所示, 指定滑动时间窗长度  $N$ , 则每  $N$  个一次检验合格率对应 1 个成枪一次检验合格率预测值  $q$ , 同时 LSTM 神经网络输入层特征个数也对应为  $N$ 。通过指定滑动时间窗, 可以实现对训练数据的分割和整理, 如果滑动时间窗大小为 days\_for\_train, 给定序列的长度为  $d$ , 将输出长度为  $(d-days\_for\_train+1)$  个输入/输出对<sup>[4]</sup>。

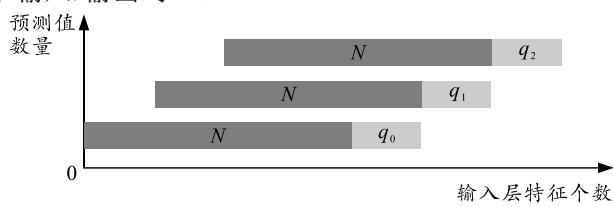


图 3 滑动时间窗

算法的参数设置如表 1 所示。

表 1 LSTM 模型参数设置

模型输入	一次交验合格率历史数据
input_size:	输入层特征个数: 为滑动时间窗大小
num_layers:	堆叠 LSTM 的层数, 默认值为 1
hidden_size:	隐藏层单位数
损失函数:	均方损失函数
output_size:	输出层特征个数, 为 1
模型输出	一次交验合格率预测值序列

## 1.3 成枪一次交验合格率预测实例

选取 11 个批次的成枪数据, 分别计算每个批次的成枪合格率如表 2 所示。

表 2 成枪一次交验合格率预测样本

批次	合格率	批次	合格率	批次	合格率
1	0.90	5	0.90	9	0.89
2	0.90	6	0.90	10	0.89
3	0.92	7	0.89	11	0.89
4	0.90	8	0.92		

取滑动窗口大小为 3, 隐藏层节点数为 6, 输出层特征个数为 1。每组滑动时间窗口内的合格率为一组训练样本, 训练长短期记忆网络模型。并以上一个滑动窗口样本作为神经网络输入值, 来计算下一批次合格率的预测值。

目前, 成枪一次交验合格率预测模块已部署在质量问题分析系统中, 用户上传历史批次的检测数据后, 系统会调用合格率预测模块, 绘制一次交验合格率变化折线图, 预测下一批次的合格率值, 并显示给用户。图 4 中界面预测的下一批次的成枪一次交验合格率为 0.88。

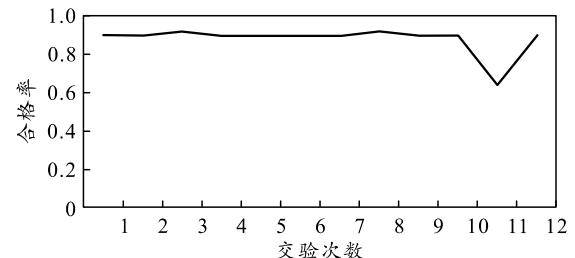


图 4 一次交验合格率预测情况

## 2 交验合格率波动溯源分析模型

前面引入 LSTM 进行一次交验合格率的预测。对于交验合格率有波动的情况, 需要分析导致该波动出现的异常加工环节。笔者采用贝叶斯网络和决策树技术实现异常环节的定位和分析。

### 2.1 加工参数-合格率因果模型构建

贝叶斯网络是一个基于概率推理的有向无环图, 用符号  $B(G, P)$  表示  $G$  表示随机变量节点的结构, 即贝叶斯网络拓扑结构;  $P$  表示有向边的概率,

即用条件概率来描述<sup>[5]</sup>。

贝叶斯网络可以用来表示一些特征之间的因果关系，以及这些特征的联合概率分布。利用贝叶斯网络的推理功能，可通过已知特征来预测最有可能的未知特征的值。

一次交验合格率是指在一个批次内成枪的合格率，而成枪的合格率受很多关键尺寸的影响，对于成枪一次交验合格率有波动或者较低的批次，如果能够构建关键尺寸与成枪合格率的因果关系，就能够找到导致合格率出现波动的异常尺寸和异常环节。

如图 5 所示，总体技术方案为：利用关键检测参数数据以及一次交验合格率数据，构建关键参数与批次合格与否的贝叶斯网络，利用贝叶斯网络的推理能力，生成异常环节决策树训练数据，进而构建异常环节决策树，从而定位到可能影响合格率的异常环节和异常原因。

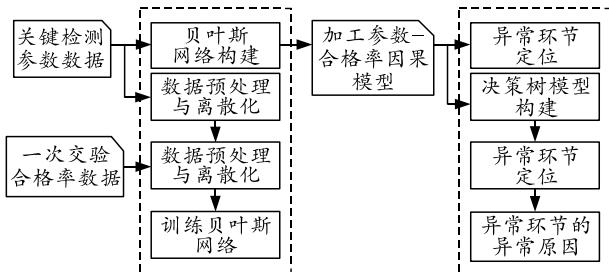


图 5 交验合格率波动溯源分析技术方案

进行数据处理和离散化操作。

对于所有尺寸数据，每个相同的尺寸对应的数据大致呈现正态分布，引入规则：将尺寸平均值周围 1 个标准差范围内的数据视为正常数据，离散化后值为 0；将尺寸平均值周围 1 个标准差范围之外的数据视为异常数据，离散化后值为 1。对于批次合格与否，如果一个批次内有一个尺寸数据不合格，则该批次为不合格，值为 1，如果一个批次内所有尺寸数据均合格，则该批次合格，值为 0。数据离散化如图 6 所示。

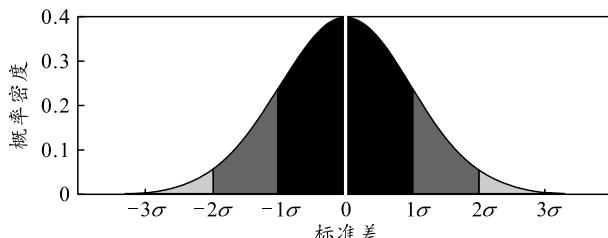


图 6 数据离散化

尺寸数据离散化后，获得加工数据表的结构如表 3 所示。

表 3 数据离散化后的加工数据

批次	参数 1	参数 2	...	参数 n	批次合格与否
1	0	1	...	0	0
2	1	0	...	1	1
3	1	1	...	0	1
4	0	1	...	1	1
⋮	⋮	⋮	⋮	⋮	⋮
m	0	1	...	0	0

利用得到的加工数据表作为贝叶斯网络的训练数据，进行贝叶斯网络的结构学习和参数学习，完成加工参数-合格率因果模型的构建。

贝叶斯网络的结构学习：爬山算法+K2 评分进行贝叶斯网络结构学习，学习流程如图 7 所示。爬山算法的目标是找出 K2 评分最高的贝叶斯网络结构。

K2 评分的原理：在给定先验知识和样本数据的条件下，选择后验概率值最大的网络结构；

K2 评分的核心公式如下：

$$F_{K2}(G|D) = \log P(G) + \sum_{i=1}^n \sum_{j=1}^{q_i} \left[ \log \left( (r_i - 1)! / (m_{ijk} + r_i - 1)! \right) + \sum_{k=1}^{r_i} \log (m_{ijk}!) \right]. \quad (1)$$

式中：数据集  $D$  为关于样本变量  $\{x_1, x_2, \dots, x_n\}$  的完整独立同分布数据； $G$  为关于变量集  $\{x_1, x_2, \dots, x_n\}$  的 BN 结构，并且  $P(\theta_G|G)$  服从均匀分布。

贝叶斯网络参数学习采用最大似然估计，其学习步骤如图 7 所示。

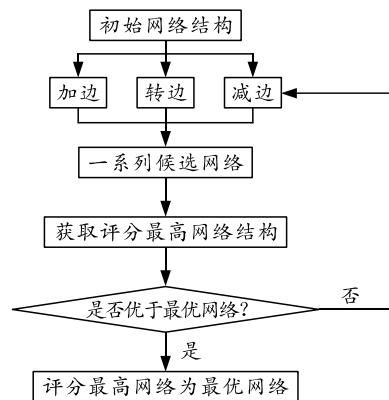


图 7 贝叶斯网络结构学习步骤

算法核心原理： $\theta^* = \operatorname{argmax}_{\theta} L(\theta|D)$ ，其中  $L(\theta|D) = P(D|\theta)$  为  $\theta$  的似然函数。一个由  $n$  个变量  $X = \{x_1, x_2, \dots, x_n\}$  组成的贝叶斯网络。设变量  $x_i$  有  $r_i$  个取值，其父节点  $\text{pa}(x_i)$  的取值组合共有  $q_i$  个，若  $x_i$  无父节点，则  $q_i=1$ ，那么，需求的网络参数有：

$$\theta = \{\theta_{ijk} \mid i = 1, \dots, n; j = 1, \dots, q_i; k = 1, \dots, r_i\}. \quad (2)$$

式中  $\theta_{ijk} = P(x_i = k \mid \text{pa}(x_i) = j)$ ，对  $L(\theta|D)$  取对数

可得：

$$l(\theta|D) = \log(L(\theta|D)) = \log \prod_{i=1}^m P(d_i|\theta) = \sum_{i=1}^m \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} m_{ijk} \log \theta_{ijk}. \quad (3)$$

式中  $m_{ijk}$  为数据  $D$  中满足  $x_i=k$  和  $\text{pa}(x_i)=j$  的样本数量。

经过贝叶斯网络的结构及参数学习即可获得加工参数-合格率贝叶斯网络，如图 8 所示，其中的数字节点即为加工参数对应的序号。

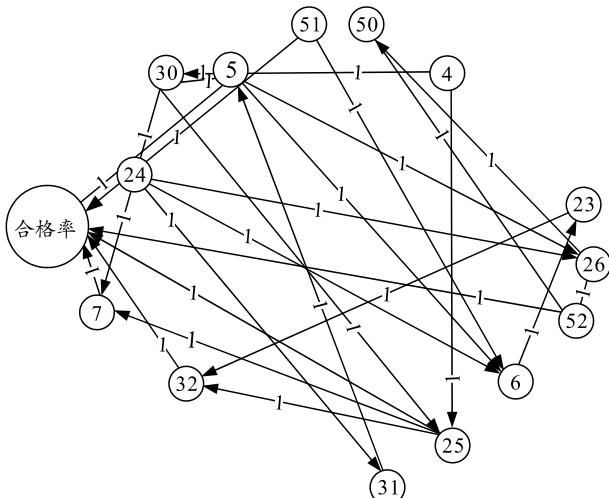


图 8 加工参数-合格率因果模型

## 2.2 异常加工参数决策树构建

这一步的总体思路是：利用加工参数-合格率贝叶斯网络的条件概率推理能力，获取可能为异常参数的状态组合对应批次不合格的概率，并基于此得到异常加工参数决策树训练数据，生成决策树模型，认定出现在决策树中的加工参数即为异常参数。

### 1) 条件概率推断。

条件概率推断指的是计算  $P(x|e)$ ，其中  $e$  指的是贝叶斯网络中部分变量的取值为  $e$ ， $x$  指的是其余变量的取值为  $x$ 。 $P(x|e)$  指的是已知部分变量取值为  $e$  的情况下，另一部分变量取值为  $x$  的概率大小。

### 2) 决策树。

决策树是一种机器学习算法，即通过训练数据来构建模型的决策规则，可以对未知的数据进行决策分类。决策树是一种树形结构，其中每个内部节点表示一个属性上的判断，每个分支代表一个判断结果的输出，最后每个叶节点代表一种分类结果。

决策树需要监督学习的方法进行训练，即给出一堆样本，每个样本都有一组属性和一个分类结果，也就是分类结果已知，那么通过学习这些样本得到一个决策树，这个决策树能够对新的数据给出

正确的分类。

决策树由节点和有向边组成，其节点有内节点和叶节点 2 种类型，内节点表示一个对象或者特征，叶节点表示分类结果，有向边上的值则表示对象每个属性或特征中可能取的值。

本文中，决策树中的内节点即为加工参数，而叶节点表示加工参数组合对应的分类结果，即正常或者异常，有向边上的值则为加工参数状态可能的取值，即 0 或者 1。通过训练异常加工参数决策树，就可以得到各个加工参数取值对加工参数组合的分类规则，进而找出所有可能导致加工参数组合异常的关键加工参数集合。

为找到导致批次不合格的关键加工参数，首先找到不合格的批次，这个批次内所有加工参数和批次合格与否的组合如下：

$$N = [S_1, S_2, S_3, S_4, S_5, S_6, \dots, S_n, Q]. \quad (4)$$

式中  $Q=1$ ，在这个时间窗内所有异常的加工参数，都有可能是导致批次不合格的加工参数。

设所有异常加工参数的数量为  $s$ ，在这些参数中，每个参数的状态可是 0 或者 1，即正常或者异常，那么这些参数的组合可以有很多种，可能组合集合为：

$$T = \{T_0, T_1, T_2, \dots, T_m\}. \quad (5)$$

式中  $m=2^n-1$ 。

利用加工参数-合格率贝叶斯网络的条件概率推断功能，可分别获得  $s$  个参数的  $m$  种组合导致批次不合格的概率，由此可以获得概率分布矩阵如表 4 所示。

表 4 参数组合概率分布矩阵

组合集	参数 1	参数 2	...	参数 $n$	批次不合格概率
$T_0$	0	0	...	0	$P_0$
$T_1$	0	1	...	0	$P_1$
$T_2$	0	0	...	0	$P_2$
$T_3$	0	1	...	1	$P_3$
$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$
$T_s$	1	1	...	1	$P_s$

设定概率阈值  $T_h = \sum_{i=1}^m P_i / m$ ，即概率阈值为所有批次不合格概率的平均值。以上概率分布矩阵中，使批次不合格的概率大于概率阈值的加工参数组合，标记为“异常”组合，而使批次不合格的概率小于概率阈值的加工参数组合，则标记为“正常”组合，通过这样的标记方式，可以得到异常加工参数决策树的训练数据如表 5 所示。

表 5 决策树训练数据

组合集	参数 1	参数 2	...	参数 n	标签
$T_1$	1	0	...	1	正常
$T_2$	1	1	...	0	异常
$T_3$	0	1	...	1	正常
$\vdots$	$\vdots$	$\vdots$	...	$\vdots$	$\vdots$
$T_S$	1	1	...	0	异常

在基于加工参数-合格率贝叶斯网络的条件概率推断功能, 获取异常加工参数决策树训练数据后, 进行异常加工参数决策树的构建。

决策树构建的基本步骤如下:

- 1) 开始, 所有样本都看作一个节点;
- 2) 遍历每种分割方式, 找到最好的分割点;
- 3) 将样本分割成若干节点;
- 4) 对每个节点继续执行 2)-3)步, 直到每个节点足够“纯”为止。

一个分割点可以将当前的所有节点分为若干类, 如果使得分类后的样本集合只有一种分类结果, 则该集合“纯”, 如果分类后的样本集合还有许多分类结果, 则该集合“不纯”。分类后的集合越“纯”, 则说明分类效果越好。一个样本集合的纯度的度量指标就是信息熵:

$$ED = -\sum_{k=1}^n p_k \log_2 p_k. \quad (6)$$

式中:  $D$  为样本集合;  $k$  为样本的标签类别;  $p_k$  为样本集合  $D$  中  $k$  类别出现的概率;  $ED$  数值越小, 则说明样本集合  $D$  的纯度越高。

如果在根节点上选择特征  $a$  作为分类依据, 则一个样本集合将会被分为若干个样本集合, 整个体系的信息熵可由如下公式计算:

$$ED_a = -\sum_{i=1}^n n_{D_i} ED_i. \quad (7)$$

式中:  $D_i$  为被分出的第  $i$  个样本集合;  $n_{D_i}$  为此样本集合中样本的个数。

希望在分类以后能够降低熵的大小, 使之变“纯”, 这种分类后熵变小的判定标准可以用信息增益来衡量, 它表示 2 个信息熵的差值, 信息增益越大越佳, 区分样本的能力更强, 选择信息增益最大的特征属性进行分类最佳。

信息增益公式为:

$$g(D, a) = E(D) - E(D|A). \quad (8)$$

式中:  $g(D, a)$  为样本  $D$  基于特征  $a$  分类后的信息增益;  $E(D)$  为样本  $D$  原本的信息熵;  $E(D|A)$  为样本  $D$  基于特征  $A$  分类后的信息熵。

通过信息增益最大原则的方法构建异常坐席决

策树, 得到的一个决策树结构如图 9 所示。

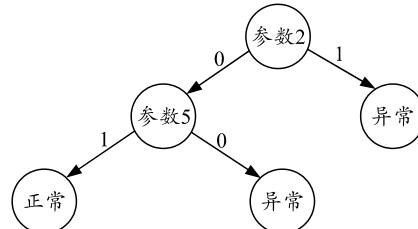


图 9 异常加工参数决策树

在得到图 9 的决策树结构信息之后, 找到在决策树中所有可能导致叶节点为异常的加工参数, 这些参数即为可能导致合格率下降的关键加工参数。

### 2.3 异常工艺参数定位实例

选取成  $Q$  的 62 个尺寸作为关键尺寸, 进行异常尺寸定位与溯源。

给每个尺寸名称进行编号, 如表 6 所示。由于尺寸数量较多, 这里只展示部分尺寸数据。

表 6 尺寸编号

编号	名称
1	J10304-3OP1014.1(0, -0.17)
2	J10304-3OP102.5(-0.02, -0.14)
3	J10304-3OP1020.4(+0.33, 0)
$\vdots$	$\vdots$
62	J10304-3OP30φ8.2(+0.036, 0)

将每个批次的这 62 个尺寸的平均值分别进行处理和离散化, 得到如表 7 所示数据, 由于尺寸数量较多, 这里只展示部分尺寸数据。

表 7 贝叶斯网络训练数据

批次	尺寸 编号 1	尺寸 编号 2	...	尺寸 编号 62	批次 合格与否
1	0	1	...	0	0
2	1	0	...	1	1
3	1	1	...	0	1
4	0	1	...	1	1
$\vdots$	$\vdots$	$\vdots$	...	$\vdots$	$\vdots$
11	0	1	...	0	0

利用上表数据作为训练数据, 训练得到如下加工参数-合格率贝叶斯网络。图 10 中节点上的数字代表上表 6 中的尺寸编号。

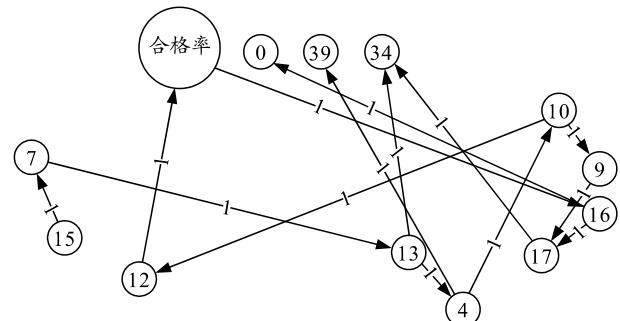


图 10 加工参数-合格率贝叶斯网络

在完成贝叶斯网络的训练之后，利用贝叶斯网络的推理能力，得到加工参数-合格率联合概率分布，即每个批次内加工参数的状态组合对应该批次不合格的概率。联合概率分布如表8所示。

表8 联合概率分布

批次	尺寸 编号1	尺寸 编号2	…	尺寸 编号62	批次不合格 概率
1	0	0	…	0	0.12
2	0	1	…	0	0.23
3	0	0	…	0	0.53
4	0	1	…	1	0.42
⋮	⋮	⋮		⋮	⋮
4	1	1	…	1	0.35

设定概率阈值为所有批次不合格概率的平均值。以上概率分布矩阵中，使批次不合格的概率大于概率阈值的加工参数组合，标记为“异常”组合，而使批次不合格的概率小于概率阈值的加工参数组合，则标记为“正常”组合。通过这样的标记方式，可以得到异常加工参数决策树的训练数据如表9所示。

表9 异常加工参数决策树训练数据

尺寸 编号1	尺寸 编号2	…	尺寸 编号62	标签
1	0	…	1	正常
1	1	…	0	异常
0	1	…	1	正常
⋮	⋮		⋮	⋮
0	1	…	0	异常

在得到上表所示的决策树训练数据后，训练异常工艺参数决策树，得到异常加工参数决策树结构如图11所示。

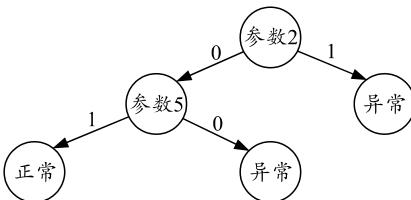


图11 异常加工参数决策树

在得到图11的决策树结构信息之后，找到在决策树中所有可能导致叶节点为异常的加工参数，即在决策树中和“异常”叶节点相连的参数，即参数2和参数5，对应在表6中即可找到对应的具体参数信息，这2个参数即为可能导致合格率下降的关键加工参数。

### 3 结论

笔者提出基于LSTM的成枪一次交验合格率时间序列预测模型，通过实验证明其能够较为准确地预测下一批次的成枪一次交验合格率，预警可能出现的较低合格率批次。同时，为能准确定位影响成枪一次交验合格率的关键加工环节，提出了基于贝叶斯网络的关键加工参数与成枪一次交验合格率之间的因果模型。通过生成联合概率分布和进一步训练异常加工参数决策树的方式，定位可能影响到一次交验合格率的关键尺寸，进一步定位到关键加工环节，为下一步有针对性地改进生产工艺提供理论参考。

### 参考文献：

- [1] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [2] SRIVASTAVA N, MANSIMOV E, SALAKHUTDINOV R. Unsupervised learning of video representations using LSTMs[C]//Proceedings of the 32nd International Conference on Machine Learning. Lille: JMLR W & CP, 2015: 843–852.
- [3] GRAVES A. Long short-term memory[M]. Berlin: Springer, 2012: 1735–1780.
- [4] LUO X M. Time series prediction model based on PYTORCH[J]. Jinxiuzhongxun journal, 2021, 10: 1016–1020.
- [5] JUN H B, KIM D. A Bayesian network—based approach for analysis[J]. Expert Systems with Applications, 2017, 81: 332–348.