

# 基于自适应深度学习的数控机床运行状态预测方法

杜柳青 李祥 余永维

(重庆理工大学机械工程学院, 重庆 400054)

**摘要:** 针对机床状态动态标签及差异化分布数据下的预测适应性差与准确度低问题, 结合时序特征关系和模型融合方法, 建立自适应混合深度学习模型进行机床状态预测。首先, 通过融合最小近邻分类器, 设计一种基于权值累积的自适应更新法则, 建立具有数据自适应性的状态预测模型。在此基础上, 提出一种基于中心损失函数的特征距离度量优化策略, 构建综合决策损失函数, 确保模型有效融合。在提出的一种组合收敛准则基础上, 采用 BBPT 方法训练优化模型, 对测试数据进行了验证。实验结果表明, 该模型能够自适应动态标签及差异化分布数据, 准确预测数控机床状态类别, 抗干扰强, 响应快。在 GPU 模式下预测时间最短仅需 100 ms, 较 BP 和 LSTM 分类网络, 预测准确率和实时性均显著提高。

**关键词:** 数控机床; 状态预测; 深度学习; 自适应混合时序模型; 最小近邻算法

中图分类号: TH115 文献标识码: A 文章编号: 1000-1298(2022)01-0451-08

OSID:



## Motion State Prediction Method of CNC Machine Tools Based on Adaptive Deep Learning

DU Liuqing LI Xiang YU Yongwei

(School of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China)

**Abstract:** The feature relationship of the motion state of CNC machine tools is very complex. Realizing the prediction of the future operation state of CNC machine tools can tap the potential abnormal emergencies of machine tools and enhance the stability of machine tool processing. In view of the problem of poor adaptability and low accuracy of prediction under dynamic label of machine tool state and differential distribution data, an adaptive hybrid deep learning model was established to predict machine tool state by combining time series feature relationship and model fusion method. Firstly, by combining the nearest neighbor classifier, an adaptive updating rule based on weight accumulation was designed, and a state prediction model with data adaptability was established. On this basis, an optimization strategy of feature distance metric based on center loss function was proposed, and a comprehensive decision loss function was constructed to ensure model fusion effectively. Based on a combination convergence criterion, the BBPT method was used to train the model, and the test data was verified. The experimental results showed that the model can adapt dynamic label and differential distribution data. The prediction of the state category of CNC machine tools had strong anti-interference, fast response and high accuracy, and can better meet the requirements of machine tool state classification and prediction. The prediction accuracy and real-time performance were significantly compared with BP and LSTM classification networks, and the shortest prediction time was only 100 ms in GPU mode.

**Key words:** CNC machine tools; state prediction; deep learning; adaptive hybrid timing model; K-nearest neighbors algorithm

## 0 引言

实现数控机床未来运行状态的预测, 能够挖掘

机床潜在的异常突发状况, 避免生产过程失效带来的损失, 增强机床加工的稳定性, 并且对设备的维修和维护具有指导性作用<sup>[1]</sup>。国内外学者对数控机

收稿日期: 2021-01-11 修回日期: 2021-02-26

基金项目: 国家自然科学基金面上项目(51775074)、重庆市自然科学基金项目(cstc2021jcyj-msxmX0372)、重庆市技术创新与应用示范专项(cstc2018jszx-cyzdX0172)、重庆市基础研究与前沿探索项目(cstc2018jcyjAX0352)和重庆市专业学位研究生教学案例库项目(2019-79)

作者简介: 杜柳青(1975—), 女, 教授, 博士, 主要从事机床精度设计和智能制造研究, E-mail: lqdu@cqut.edu.cn

床局部状态辨识、精度演化、故障识别等方面取得了较多研究成果<sup>[2-11]</sup>,而针对状态预测模型的研究较少。李海等<sup>[12]</sup>基于多维时间序列结合 min - max 标准化和自回归模型,实现了对数控机床的回转误差、主轴负载、主轴电流、电机温度等状态信息的预测。余永维等<sup>[13]</sup>基于时序深度学习模型,利用相空间重构原理挖掘精度时间序列关联信息,提出了数控机床精度预测方法。张存吉等<sup>[14]</sup>通过深度学习方法,构建深度神经网络,最终实现了微型铣削刀具磨损状态的分类。张鹏等<sup>[15]</sup>基于长短时记忆网络,引入注意力机制和多任务学习方法完成了对伺服系统状态的识别。

现有研究大多都是对数控机床局部状态的分析与预测,局部分析中伺服系统状态、运动精度、零件磨损等研究较为成熟,但典型性太强,适用范围窄;现有对机床整体状态的分析模型,也主要利用单一或局部数据对部分状态参数进行了回归预测,虽然实际回归效果好,但无法从回归参数中继续挖掘机床将来状态的具体所属类别,对机床未来运行状态的分类预测能力还比较欠缺。

深度学习网络具有强大的特征提取能力<sup>[16-23]</sup>。

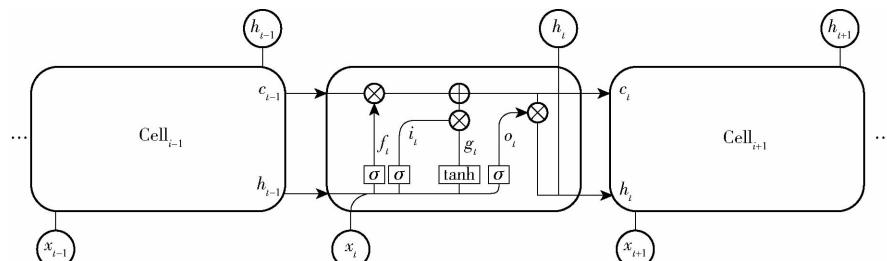


图 1 基于 LSTM 的深度学习模型

Fig. 1 Deep learning model based on LSTM

$t$  时刻遗忘门、输入门、记忆单元、输出门的计算公式分别为

$$f_t = \sigma(W_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + b_i) \quad (2)$$

$$\begin{cases} \tilde{c}_t = \tanh(W_c[\mathbf{h}_{t-1}, \mathbf{x}_t] + b_c) \\ c_t = f_t c_{t-1} + i_t \tilde{c}_t \end{cases} \quad (3)$$

$$\begin{cases} o_t = \sigma(W_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + b_o) \\ \mathbf{h}_t = o_t \tanh(c_t) \end{cases} \quad (4)$$

式中  $W_f$ —遗忘门  $W_i$ —输入门

$W_c$ —记忆单元

$W_o$ —输出门权值矩阵

$\tilde{c}_t$ —储存状态  $c_t$ —单元状态

$b_f$ —遗忘门偏置参数

$b_i$ —输入门偏置参数

$b_c$ —记忆单元偏置参数

机床状态特征具有清晰的局部关系,而整体关系复杂度高<sup>[24]</sup>,适合通过深度学习方法来建模。机床的全局和局部运行状态与机床特征数据具有较强的时间序列关联性,可以通过机床时序数据挖掘未来状态变化。

为解决机床状态动态标签及差异化分布数据下的预测适应性差与准确度低问题,本文针对数控机床多源大数据流,提出一种基于时序深度学习网络的自适应混合时序模型,并融合时序深度学习网络和 KNN(K-nearest neighbors)分类器,设计权值累积自适应更新规则控制特征数据库的方法控制模型,并提出一种组合收敛准则模型训练方法。

## 1 基于 LSTM 的时序深度学习模型

图 1 为基于 LSTM 的时序深度学习模型,LSTM 单个神经元由遗忘门、输出门、记忆门组成(图 1 中 Cell)。神经元通过这 3 个结构的计算,完成信息的舍弃和保留。神经元之间存在信息前馈传递性,即后续时间状态特征可以选择性地持久化之前状态信息,同时结合新输入特征信息得到最后的输出特征。

$b_o$ —输出门偏置参数

$\tanh, \sigma$ —激活函数

$\mathbf{x}_t$ — $t$  时刻输入特征

$\mathbf{h}_t$ — $t$  时刻隐状态特征

输入信号  $\mathbf{X}_t = (x_1, x_2, \dots, x_{t-1}, x_t, x_{t+1}, \dots)$  为数控机床多源参数序列。将 LSTM 的反馈结构在时间方向上展开,每一时刻的 LSTM 即为一个学习网络中的一层,沿时间方向展开,即形成基于 LSTM 单元的时序深度学习网络。

## 2 自适应深度学习机床状态预测模型

### 2.1 机床状态预测模型设计

针对传统 LSTM 模型不能处理动态标签任务的缺陷,引入 KNN 层,通过更改模型层的方式,来间接实现标签的任意增删,从而解决动态标签问题。融合 LSTM 特征提取器和 KNN 分类器的自适应混合

时序深度学习模型如图 2 所示。

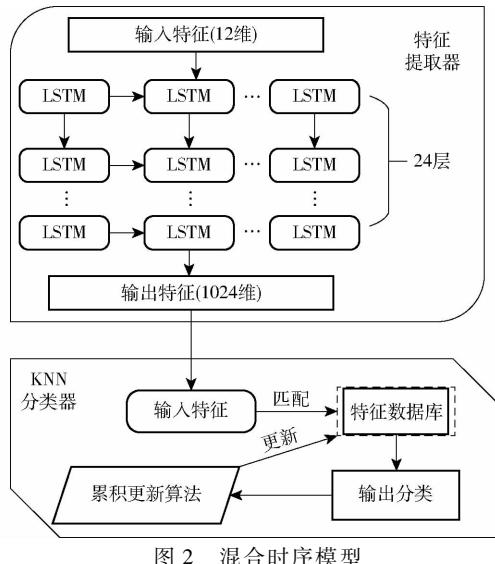


Fig. 2 Mixed time series model

模型输入为 12 维状态参量, 通过 LSTM 筛选重构后输出高维特征向量。设计约束使输出特征向量在重构空间下映射到对应类别特征向量附近, 最后通过度量特征距离的 KNN 层完成分类任务, 输出分类结果。

模型隐藏层由经验判断设定, 考虑到 CPU 推断的响应时间, 隐藏层设计为 22 层, 隐藏层具体参数如表 1 所示(层 2~23)。

表 1 网络结构参数

Tab. 1 Network structure parameters

层序号	输入 × 输出	层序号	输入 × 输出
1(输入层)	12 × 16	11~13	128 × 128
2~3	16 × 16	14	128 × 256
4	16 × 32	15~18	256 × 256
5~6	32 × 32	19	256 × 512
7	32 × 64	20~22	512 × 512
8~9	64 × 64	23	512 × 1024
10	64 × 128	24(输出层)	1 024 × 1 024

KNN 是一个典型距离度量分类算法, 其原理是找寻一个样本在特征空间中  $k$  个最邻近样本中最邻近的类, 其优点是计算速度快, 并在细粒度样本空间的预测准确率非常高。KNN 算法可视为一个特征向量库, 通过更新、增删、保存输出特征就可以完成类别更新的任务, 以此解决动态标签问题。

KNN 算法中特征向量之间的闵科夫斯基距离判断类别公式为

$$d = \left( \sum_{i=0}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (5)$$

式中  $d$ —特征向量  $x$  和  $y$  的距离

$p$ —距离系数

当  $p=2$  时为欧氏距离, 欧氏距离是最常见的度量指标。

KNN 算法数学模型为

$$I(x, y) = \begin{cases} 1 & (x = y) \\ 0 & (x \neq y) \end{cases} \quad (6)$$

其中

$$y = \operatorname{argmax}_{x_i \in N_k(x)} I(y_i, c_j)$$

$$(i = 1, 2, \dots, N; j = 1, 2, \dots, k) \quad (7)$$

式中  $I$ —指示函数, 当  $x$  与  $y$  的状态类别相同时其值为 1, 不同则为 0

$N_{k(x)}$ —训练集中包含  $k$  个最小邻点的领域

$c_j$ —样本类别

$k$ —最小近邻数

$N$ —总的类别数

求得所有类别指示函数统计量最大的标签, 即为最终分类结果。

引入 KNN 分类层后, LSTM 作为特征提取层, 将原有的 softmax 分类层替换为 KNN。KNN 算法处理的是高维特征搜索问题, KNN 算法直接保存的实际是 LSTM 的输出特征, 不同的特征集合, KNN 算法会生成不同的  $k-d$  树, 当删除类别时, 只需将该类别从特征集合中删除并重新构造  $k-d$  树即可。新增类别则需要用新样本集合微调 LSTM 参数, 得到新的特征输出集合, 并构造新的  $k-d$  树来实现。

## 2.2 模型自适应更新法则设计

由于样本数据存在分布差异, 采用 KNN 分类时, 数据偏差会明显扩大算法误差(图 3), 由于类别 1 存在数据偏差, 导致真实类别 1 与类别 2 局部不可分, 从而导致误判。为此, 在 KNN 算法基础上设计一种针对分布差异的自更新法则。

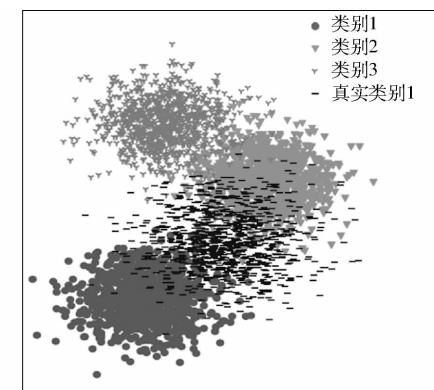


图 3 假设预测分布

Fig. 3 Distribution of hypothetical predict

通过带权值样本的迭代更新达到适应数据的效果, 权值更新模型为

$$w_{x_i} = \begin{cases} 0 & (G < C_{x_i}) \\ 1 & (G \geq C_{x_i}) \end{cases} \quad (8)$$

设定阈值  $G$ , 在每轮预测过程中不断迭代该预

测样本累积值  $C_{x_i}$ , 当低于阈值后该样本将会被删除。计算规则为

$$C_{x_i}^j = \begin{cases} C_{x_i}^{j-1} + 1 & (x_i = x_j \text{ 且 } \text{dist}(x_i, x_i) \leq R_{\max}) \\ C_{x_i}^{j-1} - 1 & (x_i = x_j \text{ 且 } \text{dist}(x_i, x_i) > R_{\max} \text{ 或 } x_i \neq x_j \text{ 且 } \text{dist}(x_i, x_i) < R_{\min}) \\ C_{x_i}^{j-1} & (x_i \neq x_j \text{ 且 } \text{dist}(x_i, x_i) \geq R_{\min}) \end{cases} \quad (9)$$

式中  $x$ —特征点  $j$ —训练轮次

$R_{\max}$ —预测样本点与 KNN 预测结果的最大距离

$R_{\min}$ —预测样本点与 KNN 预测结果的最小距离

$\text{dist}$ —距离函数

KNN 在预测时存在一个作用域半径, 即以预测样本点为中心, 参与预测的  $k$  个样本点能够围成最小圆半径。只有和预测样本点同类别的数据才进行累积计算。如图 4 所示, 中心最大的圆点为预测样本点, 设置的最小近邻为 6 个样本,  $R_{\max}$  作为作用域半径, 作用域范围内的同类别样本会自增、范围外的会自减, 而不同类别样本只会在距离

小于  $R_{\min}$  时自减。所以当预测特征重复出现在某个空间位置时, 该空间的样本点就会引导 KNN 逐渐趋向正确的分类。

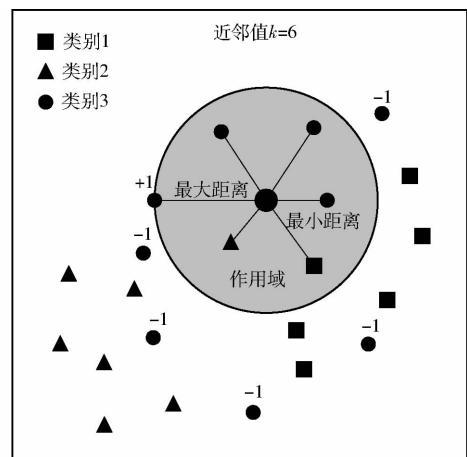


图 4 算法原理

Fig. 4 Algorithm description

该更新法则的自适应性测试结果如图 5 所示。由图 5 可知, 偏离真实预测结果的部分数据会因高频率递减而被删除, 从而消除了偏差数据的干扰, 减少了在预测过程中因环境不同而导致的预测偏差, 使模型具有较强的抗干扰性。

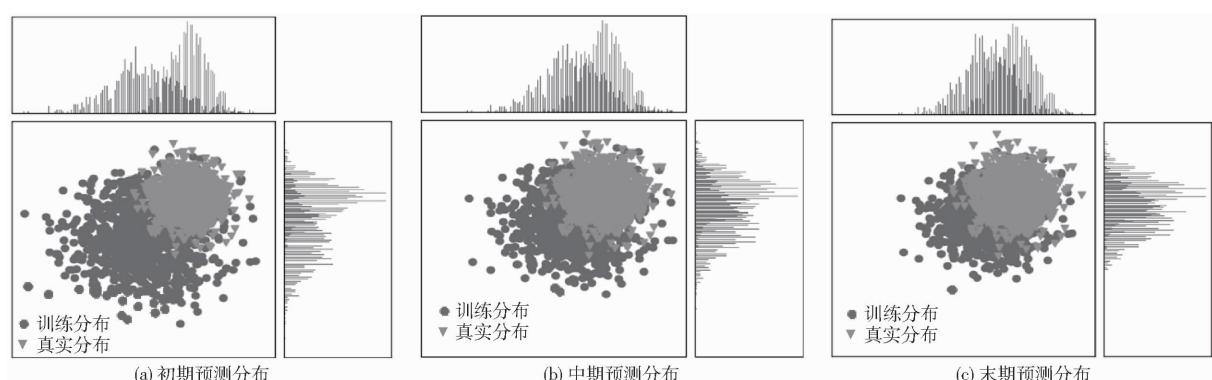


图 5 自适应预测分布演化

Fig. 5 Adaptive prediction distribution's evolution

## 2.3 自适应模型调参及训练

### 2.3.1 损失函数优化

为使自适应深度学习分类器效果最佳, 提出基于中心损失函数的特征距离度量优化策略, 构建综合决策损失函数, 确保模型有效融合, 综合损失函数通过加权构造, 即

$$L = L_s + \lambda L_c \quad (10)$$

其中

$$L_c = \frac{1}{2} \sum_{i=1}^m \| \mathbf{x}_i - \mathbf{c}_{y_i} \|_2^2 \quad (11)$$

$$L_s = - \sum_{i=1}^m \lg \frac{e^{\mathbf{W}_i^T \mathbf{x}_i + b_{y_i}}}{\sum_{j=1}^n e^{\mathbf{W}_j^T \mathbf{x}_i + b_j}} \quad (12)$$

式中  $\lambda$ —影响因子

$L_c$ —中心损失函数<sup>[25]</sup>

$\mathbf{c}_y$ —该类别的度量中心

$L_s$ —CrossEntropy 交叉熵损失函数

$\mathbf{W}$ —分类层权值向量

$b$ —偏置参数  $n$ —类别数量

$m$ —一次输入数据量

在最小化损失函数过程中, 交叉熵损失函数只有在输出与标签不同时才产生较大梯度, 使输出特征的类间间距变大, 中心损失函数则是缩小类内距离。

### 2.3.2 模型参数训练方法

采用 BPTT(Back propagation through time) 算法训练数控机床深度学习预测模型参数, 因数控机床状态预测模型实际应用时对准确率和查准率要求较

高,训练时收敛准则的相应阈值应越高越好,提出组合收敛准则为

$$\begin{cases} a_t - a_{t-1} \leq 0.1\% \\ a_t > 95\% \\ g > 90\% \end{cases} \quad (13)$$

其中

$$a = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

$$g = \frac{TP}{TP + FP} \times 100\%$$

式中  $TP$ —正确分类的正样本数量

$TN$ —正确分类的负样本数量

$FP$ —错误分类的正样本数量

$FN$ —错误分类的负样本数量

$a$ —准确率  $g$ —查准率

步骤如下:

(1)前向传播。根据式(1)~(4)可以分别得到对应门的输出和最后输出  $h_t$ 。

(2)计算误差并反向传播。根据正向传播计算的结果可以计算损失函数,在  $t$  时刻纵向和横向传播误差的定义为

$$\begin{cases} \delta_t = \frac{\partial E}{\partial h_t} \\ \delta_t^l = \frac{\partial E}{\partial net_t^l} \end{cases} \quad (14)$$

式中  $\delta$ —误差

$E$ —损失函数的输出值

$net_t^l$ — $t$  时刻  $l$  层的加权输入

(3)根据每层反向传播的误差项计算每个权值的梯度,然后更新每个权值。更新公式为

$$\omega_{\text{new}} = \omega_{\text{old}} + \eta \nabla_{\omega} \quad (15)$$

式中  $\nabla_{\omega}$ —网络性能函数在权值空间内的梯度

$\eta$ —每次更新步长

$\omega$ —泛指模型参数,为每个神经元权重

重复步骤(1)~(3),直到模型满足在训练数据集上的组合收敛准则为止。

### 3 实验与分析

数控机床的电流、电压、功率、转矩、速度以及运行温度等多源参数信息全面反映了机床的运行状态,采用机床运行过程参数训练自适应深度学习模型,预测数控机床进给系统和主轴系统的典型运行状态,包括正常状态、主轴转速异常、进给轴振动异常、主轴伺服故障、进给轴伺服故障,以验证基于自适应深度学习状态预测模型的效果,其输入多源数据和输出预测状态如图 6 所示。

以 G460L 型数控机床为数据采集对象,定期在

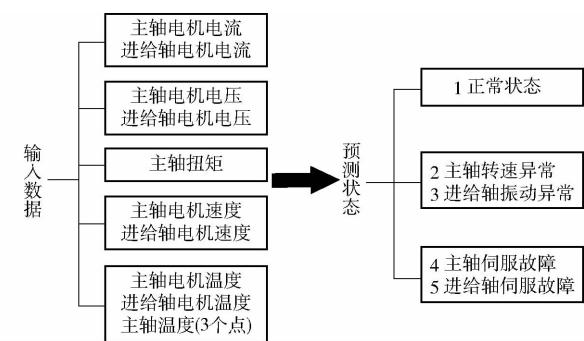


图 6 输入输出特征

Fig. 6 Input and output features

机床上进行空转、负载、加工等实验,采用 PT100 型温度传感器采集机床温度信息,通过 SBWZ-2460 型温度变送器、前置器输出至采集软件,其余数据通过以太网接口连接机床同步采集,图 7 为数据采集现场。

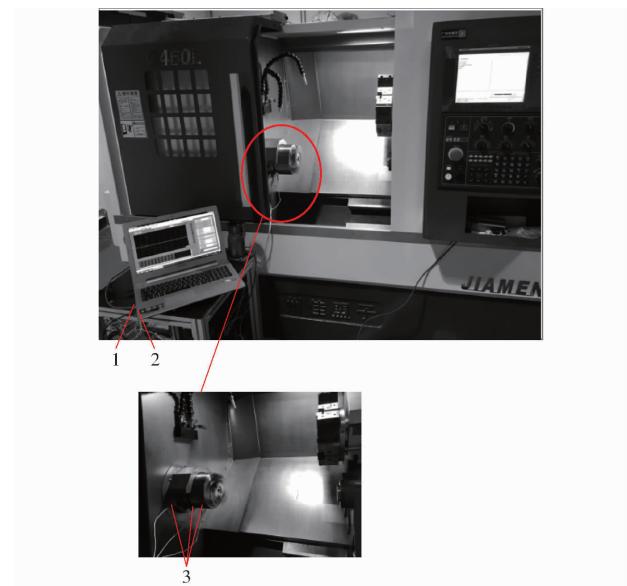


图 7 数据采集现场

Fig. 7 Data acquisition site

1. 网络接口 2. 温度数据接口 3. 温度传感器

机床运行状态变化频率较快,预测时域步长不易过长,设置预测步长为 30 s,数据采集间隔也应当同为 30 s。不同特征间会因为量纲不同而导致数据呈指数级差异,为了保证训练模型时梯度迭代稳定,应当对数据进行无量纲归一化。因样本数据中正常和异常数据属于易采集数据,故障数据为稀有数据,样本均衡比为 12:7:1,需要对故障数据做样本均衡。通过 SMOTE(样本生成算法)对其进行过采样训练,样本生成公式为

$$\mathbf{x}_t = \mathbf{x}_{t-1} + r \left( \sum_{i=0}^n \frac{\mathbf{x}_i}{n} - \mathbf{x}_{t-1} \right) \quad (16)$$

式中  $r$ —0~1 的随机数函数

设置输入为 10 个时序步长,对应输出为下一时

刻的标签，并根据分类平衡性原则，以类子集 7:3 划分训练集和验证集，基于 Pytorch1.1.0、Cuda9.0、Win10、GPU:1080ti 环境、设置学习率为 0.025、热启动学习率激活、余弦退火算法更改学习率，每 25 轮验证一次精确度。采用 BPTT 方法结合 center-loss 策略和收敛判别准则，迭代 256 轮后模型预测损失值达到最小，得到最优模型迭代结果如图 8 所示。

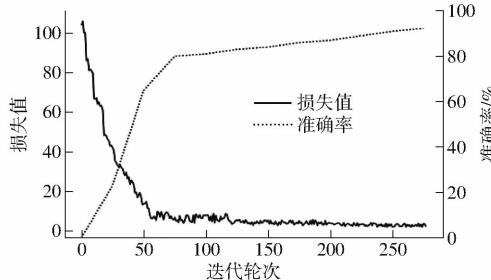


图 8 模型训练损失值-准确率变化曲线

Fig. 8 Change of model training loss - accuracy curve

以相同参数和数据集训练得到最优 LSTM 模型，同时对测试集进行预测。未替换分类层的混合模型准确率达到 94.6%。提取 3 000 个输出特征，采用 TSNE 降维可视化工具得到图 9 所示的样本点云图。图中数字对应图 6 预测状态编号，不同图形表示不同标签的特征点，不同标签间区分界限越明显分类典型性越好，结果表明混合模型的结果更优。图 9 表明了混合模型的输出特征具有良好的可分解性，也从另一角度证明了中心损失函数和 KNN 的有效性。

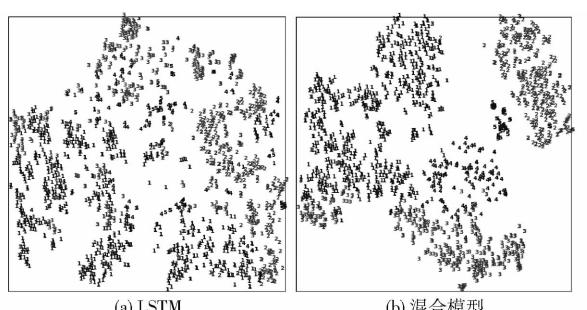


图 9 输出特征可视化结果

Fig. 9 Output feature's visualization results

分别对 LSTM 和混合模型进行 KNN 替换，设置近邻数  $k$  为 3~10，在相同测试集下遍历所有  $k$  值得到结果如表 2 所示。实验结果表明，在替换后  $k$  为 5 时模型准确率得到一定程度的提高，但提升不明显。而混合模型随着  $k$  的不断提升，预测准确率会越来越高，且相较 LSTM 准确率最高提升 3.7 个百分点。结果表明预测结果能够很好地反映机床的真实运行状态。

将归一化后的测试集加入指定分布的高斯噪声 ( $\mu = 0.1, \sigma = 0.05$ )，在测试集上进行重复

表 2 最小近邻遍历结果

Tab. 2 KNN traversal results

最小近邻数 $k$	准确率/%	
	LSTM	混合模型
3	91.5	95.0
4	93.0	95.2
5	94.6	95.7
6	94.2	95.7
7	94.3	96.0
8	94.1	96.3
9	93.2	96.5
10	93.1	96.8

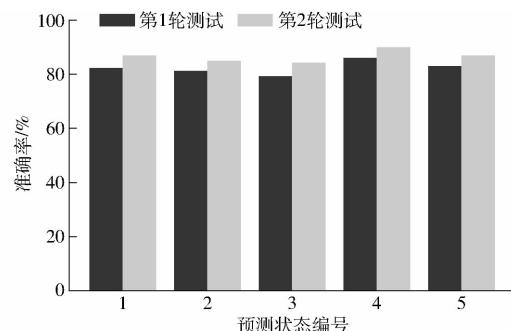


图 10 两次预测准确率变化结果

Fig. 10 Change results of twice prediction accuracy

预测(图 10)。由图 10 可知，第 1 轮测试时，在负增益数据增强后准确率下降，第 2 轮测试精度都相应回升，实验结果表明混合模型具有较好的抗干扰能力。

利用相同模型层参数的 LSTM 和 BP 神经网络与本文方法进行对比实验，实验结果如表 3 所示。LSTM 方法预测准确率为 94.6%，BP 方法为 91.7%，同时都没有抗干扰能力。在 CPU 端做推断时 BP 和 LSTM 模型运行速度较慢、实时性较差，可见无论从预测准确率方面，还是实际嵌入运用方面，本文提出的自适应混合时序网络的预测方法都优于其他两种方法，说明了本文方法的有效性。

表 3 结果对比

Tab. 3 Comparative results

参数	LSTM	BP	本文方法
预测准确率/%	94.6	91.7	96.8
推断时间(GPU)/ms	300~500	700~900	100~230
推断时间(CPU)/ms	8 000~10 000	>20 000	2 000~4 000
采样间隔/s	>10	>20	>4
抗干扰性	无	无	有

#### 4 结束语

根据数控机床状态分类预测的实际需求，分析了时序深度学习网络和 KNN 算法特性，提出了一种

自适应混合深度学习建模方法来构建机床状态分类预测模型,并设计了改进的BP模型训练方法。该模型具有预测准确率高、推断速度快、抗干扰恢复能力强的特点。实验结果表明,混合时序模型较BP

和LSTM准确率分别提升5.1、2.2个百分点,数据采集间隔和抗干扰能力也明显优于其他网络,能够很好地嵌入实际应用中,较好地满足机床状态分类预测要求。

## 参 考 文 献

- [1] 高宏力,刘庆杰,黄柏权,等.数控机床故障预测与健康管理关键技术[J].计算机集成制造系统,2010,16(10):2217-2226.  
GAO Hongli, LIU Qingjie, HUANG Boquan, et al. Key techniques of fault prediction and health management system in NC machine tool[J]. Computer Integrated Manufacturing Systems, 2010, 16 (10) :2217 - 2226. (in Chinese)
- [2] 余永维,杜柳青.深度学习框架下数控机床运动误差溯因方法[J].仪器仪表学报,2019,40(1):28-34.  
YU Yongwei, DU Liuqing. Motion error tracing of NC machine tools based on deep learning framework[J]. Chinese Journal of Scientific Instrument, 2019, 40 (1) :28 - 34. (in Chinese)
- [3] 喻曦,赵欢,李祥飞,等.基于双深度神经网络的轮廓误差补偿策略研究[J].机械工程学报,2019,55(3):130-137.  
YU Xi, ZHAO Huan, LI Xiangfei, et al. Research on contouring error compensation method using dual deep neural networks [J]. Journal of Mechanical Engineering, 2019, 55 (3) :130 - 137. (in Chinese)
- [4] 郝芳,王宏超,李宏伟.基于连续隐马尔可夫的滚动轴承故障诊断[J].中国工程机械学报,2019,17(2):184-188.  
HAO Fang, WANG Hongchao, LI Hongwei. Fault diagnosis of rolling bearing based on continuous hidden Markov model[J]. Chinese Journal of Construction Machinery, 2019, 17 (2) :184 - 188. (in Chinese)
- [5] 李海侠.遗传神经网络滑模控制在交流伺服控制中的应用研究[J].机械设计与制造,2012(7):142-144.  
LI Haixia. Application research of GA optimized RBF network-sliding model controller for AC servo system [J]. Machinery Design and Manufacture, 2012(7) :142 - 144. (in Chinese)
- [6] 曹莉,唐玲,吴浩,等.基于免疫神经网络的数控机床故障诊断研究[J].机床与液压,2016,44(13):184-190.  
CAO Li, TANG Ling, WU Hao, et al. Research on CNC machine tool fault diagnosis based on immune neural network [J]. Machine Tool and Hydraulics, 2016, 44 (13) :184 - 190. (in Chinese)
- [7] 熊青春,王家序,周青华.融合机床精度与工艺参数的铣削误差预测模型[J].航空学报,2018,39(8):272-280.  
XIONG Qingchun, WANG Jiaxu, ZHOU Qinghua. Prediction model of machining errors based on precision and process parameters of machine tools[J]. Acta Aeronautica et Astronautica Sinica, 2018, 39 (8) :272 - 280. (in Chinese)
- [8] 杜柳青,曾翠兰,余永维.基于多元混沌时间序列的数控机床运动精度预测[J].农业机械学报,2017,48(3):390-395.  
DU Liuqing, ZENG Cuilan, YU Yongwei. Prediction of numerical control machine's motion precision based on multivariate chaotic time series[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48 (3) :390 - 395. (in Chinese)
- [9] IBONE O, CARLOS P, JUAN J Z, et al. A machine-learning based solution for chatter prediction in heavy-duty milling machines[J]. Measurement, 2018, 128:34-44.
- [10] 邓聪颖,苗建国,殷国富,等.面向数控机床运行状态的切削稳定性预测研究[J].工程科学与技术,2019,51(3):184-191.  
DENG Congying, MIAO Jianguo, YIN Guofu, et al. Study on prediction of machining stability for machine tool under operational state[J]. Advanced Engineering Sciences, 2019, 51 (3) :184 - 191. (in Chinese)
- [11] 邓聪颖,刘蕴,殷国富,等.基于响应面方法的数控机床空间动态特性研究[J].工程科学与技术,2017,49(4):211-218.  
DENG Congying, LIU Yun, YIN Guofu, et al. Research on machine tool spatial dynamic characteristics based on response surface method[J]. Advanced Engineering Sciences, 2017, 49 (4) :211 - 218. (in Chinese)
- [12] 李海,王伟,黄璞,等.基于多维时间序列的数控机床状态预测方法研究[J].工程科学与技术,2018,50(1):187-195.  
LI Hai, WANG Wei, HUANG Pu, et al. State prediction method research in NC machine tool based on multidimensional time series[J]. Advanced Engineering Sciences, 2018, 50 (1) :187 - 195. (in Chinese)
- [13] 余永维,杜柳青,易小波,等.基于时序深度学习的数控机床运动精度预测方法[J].农业机械学报,2019,50(1):421-426.  
YU Yongwei, DU Liuqing, YI Xiaobo, et al. Prediction method of NC machine tools' motion precision based on sequential deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50 (1) :421 - 426. (in Chinese)
- [14] 张存吉,姚锡凡,张剑铭,等.基于深度学习的刀具磨损监测方法[J].计算机集成制造系统,2017,23(10):2146-2155.  
ZHANG Cunji, YAO Xifan, ZHANG Jianming, et al. Tool wear monitoring based on deep learning[J]. Computer Integrated Manufacturing Systems, 2017, 23 (10) :2146 - 2155. (in Chinese)
- [15] 张鹏,杨涛,刘亚楠.基于深度学习的伺服系统状态预测算法[J].计算机应用与软件,2019,36(3):236-242.  
ZHANG Peng, YANG Tao, LIU Ya'nan. Servo system state prediction algorithm based on deep learning [J]. Computer Applications and Software, 2019, 36 (3) :236 - 242. (in Chinese)
- [16] 陈学振,宋智勇,李颖,等.复杂特征下数控机床状态整体监控应用研究[J].机床与液压,2019,47(11):188-193.  
CHEN Xuezhen, SONG Zhiyong, LI Ying, et al. Research on application of NC machine tool state monitoring under complex characteristics[J]. Machine Tool and Hydraulics, 2019, 47 (11) :188 - 193. (in Chinese)
- [17] 杜柳青,余永维.基于并联深度信念网络的数控机床热误差预测方法[J].农业机械学报,2020,51(8):414-419.  
DU Liuqing, YU Yongwei. Thermal error prediction method of CNC machine tools based on parallel depth belief network [J].

- Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 414–419. (in Chinese)
- [18] 杜柳青,余永维.基于序列深度学习的数控机床热误差建模与预测方法[J].机床与液压,2020,48(23):88–92.  
DU Liuqing, YU Yongwei. Thermal error modeling and prediction for NC machine tools based on sequence deep learning[J]. Machine Tool and Hydraulics, 2020, 48(23): 88–92. (in Chinese)
- [19] ZUO Yunbo, WANG Hongjun, WU Guoxin, et al. Research on remote state monitoring and intelligent maintenance system of CNC machine tools[J]. The Journal of Engineering, 2019(23): 8671–8675.
- [20] YI Z, YANG J, HUI J. Machine tool thermal error modeling and prediction by grey neural network[J]. The International Journal of Advanced Manufacturing Technology, 2012, 59(9): 1065–1072.
- [21] POERNOMO A, KANG D K. Biased Dropout and Crossmap Dropout: learning towards effective dropout regularization in convolutional neural network[J]. Neural Network, 2018, 104: 60–67.
- [22] LI J, LUONG M T, JURAFSKY D. A hierarchical neural autoencoder for paragraphs and documents[J]. Computer Science, 2015(1): 1106–1115.
- [23] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning[J]. Computer Science, 2015(1): 104–112.
- [24] RUBEN Z, ALICIA L D, JAVIER G D, et al. Language identification in short utterances using long short-term memory (LSTM) recurrent neural networks[J]. Plos One, 2016, 11(1): 1–17.
- [25] WEN Y, ZHANG K, LI Z, et al. A discriminative feature learning approach for deep face recognition [C] // European Conference on Computer Vision, 2016: 499–515.
- 

(上接第204页)

- [21] 林滢,邵怀勇.基于随机森林算法的河南省冬小麦产量预测最佳时间窗和影响因子研究[J].麦类作物学报,2020,40(7):874–880.  
LIN Ying, SHAO Huaiyong. Study on optimal time and influencing factors for winter wheat yield prediction in Henan based on random forest algorithm[J]. Journal of Triticeae Crops, 2020, 40(7): 874–880. (in Chinese)
- [22] CAO J, ZHANG Z, TAO F L, et al. Identifying the contributions of multi-source data for winter wheat yield prediction in China[J]. Remote Sensing, 2020, 12(5): 750.
- [23] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [24] NICODEMUS K K. Letter to the editor: on the stability and ranking of predictors from random forest variable importance measures[J]. Briefings in Bioinformatics, 2011(4): 369–373.
- [25] 檀艳静. 1981—2016年河南省冬小麦产量对气象因素变化的响应[J]. 气象与环境科学, 2018, 41(4): 108–116.  
TAN Yanjing. Response of winter wheat yield to the changes of meteorological factors in Henan Province during 1981–2016 [J]. Meteorological and Environmental Sciences, 2018, 41(4): 108–116. (in Chinese)
- [26] LIU L, GUAN L, LIU X. Directly estimating diurnal changes in GPP for C3 and C4 crops using far-red sun-induced chlorophyll fluorescence[J]. Agricultural and Forest Meteorology, 2017, 232: 1–9.
- [27] CHEN X, MO X, ZHANG Y, et al. Drought detection and assessment with solar-induced chlorophyll fluorescence in summer maize growth period over North China Plain[J]. Ecological Indicators, 2019, 104(7): 347–356.
- [28] 周亮,慕号伟,马海姣,等. 基于卷积神经网络的中国北方冬小麦遥感估产[J]. 农业工程学报, 2019, 35(15): 119–128.  
ZHOU Liang, MU Haowei, MA Haijiao, et al. Remote sensing estimation on yield of winter wheat in North China based on convolutional neural network[J]. Transactions of the CSAE, 2019, 35(15): 119–128. (in Chinese)
- [29] SUN J, DI L, SUN Z, et al. County-level soybean yield prediction using deep CNN–LSTM model[J]. Sensors, 2019, 19(20): 4363.
- [30] GUAN K, WU J, KIMBALL J S, et al. The shared and unique values of optical, fluorescence, thermal and microwave satellite data for estimating large-scale crop yields[J]. Remote Sensing of Environment, 2017, 199: 333–349.
- [31] 程琳琳,李玉虎,孙海元,等. 京津冀MODIS长时序增强型植被指数拟合重建方法适用性研究[J]. 农业工程学报, 2019, 35(11): 148–158.  
CHENG Linlin, LI Yuhu, SUN Haiyuan, et al. Applicability of fitting and reconstruction method of MODIS long-time enhanced vegetation index in Beijing–Tianjin–Hebei [J]. Transactions of the CSAE, 2019, 35(11): 148–158. (in Chinese)
- [32] DRUSCH M, MORENO J, BELLO U D, et al. The fluorescence explorer mission concept—ESA's Earth Explorer 8[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(3): 1273–1284.