

基于深度学习的刀具磨损检测研究综述

陈 希, 宋育斌, 孔维宾*, 陈登钱, 杨晓芳

盐城工学院信息工程学院, 江苏 盐城

收稿日期: 2023年3月15日; 录用日期: 2023年4月20日; 发布日期: 2023年4月27日

摘 要

在现代化智能制造加工过程中, 刀具的磨损状态直接决定工件产品的质量。传统的刀具磨损检测方法存在检测精度低、鲁棒性差等问题。近年来, 深度学习的发展为刀具磨损检测提供了更加智能的解决方案。从刀具磨损检测流程开始梳理, 对刀具磨损信号的检测方法进行阐述, 将采集刀具磨损信号的常用处理方法进行归纳, 并对常用的刀具磨损深度学习模型进行分类, 说明不同模型的原理, 特点以及研究现状, 最后分析了不同方法的特点和应用场景。

关键词

刀具磨损, 信号处理, 特征提取, 深度学习, 智能制造

Overview of Tool Wear Detection Based on Deep Learning

Xi Chen, Yubin Song, Weibin Kong*, Dengqian Chen, Xiaofang Yang

College of Information Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

Received: Mar. 15th, 2023; accepted: Apr. 20th, 2023; published: Apr. 27th, 2023

Abstract

In the modern intelligent manufacturing process, the wear status of the tool directly determines the quality of the workpiece product. Traditional tool wear detection methods have problems such as low detection accuracy and poor robustness. In recent years, the development of deep learning has provided a more intelligent solution for tool wear detection. Starting from the process of tool wear detection, the detection methods of tool wear signals are explained, the common processing methods for collecting tool wear signals are summarized, and the common deep learning models for tool wear are classified, the principles, characteristics and research status of different models

*通讯作者。

are explained, and finally the characteristics and application scenarios of different methods are analyzed.

Keywords

Tool Wear, Signal Processing, Feature Extraction, Deep Learning, Smart Manufacturing

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着中国制造 2025 的提出,在新一轮的产业变革环境下,工业自动化、智能化制造已经成为一种必然趋势。智能化制造是跨领域、跨学科融合的先进制造技术,在自动化、智能化加工制造中,都需要用到切削加工技术,其占比达到 90%以上,而在切削加工中都离不开刀具的使用[1]。刀具在切削过程中长时间的使用会出现损耗,严重时可能会出现崩刀、断刀等情况,研究表明,通过刀具磨损检测并根据情况进行实时换刀可降低生产成本 10%~40%,提高生产速度 10%~50% [2],刀具的磨损状态直接影响到加工生产效率,由此可见刀具磨损检测的必要性。

目前,常用的刀具磨损状态检测方法主要包括直接检测法和间接检测法。直接检测法[3]是通过测量刀具表面的几何形状参数来获取刀具磨损状态,如图像处理法,易受外在环境条件的影响且需要停机检测,无法实现实时在线测量。间接检测法[4]是通过采集分析加工过程中与刀具磨损相关的信号来评估刀具磨损状态,可以实现实时在线测量,不需要停机检测,实际应用更为广泛。

在深度学习模型未完全成熟之前,学者们主要通过数学模型对刀具磨损信号进行分析,近些年学者们开始使用机器学习和深度学习模型对刀具磨损进行预测。刀具磨损检测通常有三个过程,首先采集刀具磨损的相关信号,然后对采集到的信号进行处理,最后构建学习模型对刀具的磨损进行预测。使用传统机器学习算法对刀具磨损进行检测,依赖于人工经验知识的辅助,模型的泛化性能,预测精度,对复杂问题下刀具磨损的预测效果较差。孙巍伟[5]等人通过经验模态分解刀具振动信号,再利用隐马尔可夫模型进行预测,由于特征提取不够充分,在不同程度磨损下的识别准确度不够高。赵帅[6]等人通过小波包分解时频信号,通过随机森林算法划分刀具磨损,与 AdaBoost 方法相比稳定性、鲁棒性更好。王爽[7]等人通过建立高斯回归方程,并在其中引入平滑度理论选择核函数优化模型,相比传统检测方法有显著提升,但是对复杂问题导致的刀具磨损,还需要对模型进行一定的改进和优化。

近年来,深度学习模型凭借其强大的学习能力,在计算机视觉、语音处理等领域获得了广泛的应用,也逐渐被用于刀具磨损检测领域[8],并取得了不错的效果。

2. 刀具磨损信号检测方法

随着近年来的设备智能化发展,刀具磨损的检测已经从传统的停机检测转变为实时在线检测。在工业生产过程中,刀具磨损信号的检测方法[9]主要分为直接检测法和间接检测法两种。

2.1. 直接检测法

直接检测法是直接对刀具的表面外观进行识别检测的方法,主要是采用图像处理法。通过电荷耦合器

件(CCD 相机)等方法直接采集刀具的图片并转化成灰度图, 然后通过计算机对其进行处理, 从而得到磨损值, 其缺点是通常需要进行停机检测。

2.2. 间接检测法

间接检测法是通过监测刀具使用过程中刀具磨损产生的各种信号, 对其进行分析, 反映其磨损状态的方法。缺点是采集的信号可能会有大量的噪声, 需要对其进行进一步的处理, 优点是可以在刀具的使用过程中进行检测, 也可以进行多种信号融合检测, 是刀具磨损的深度学习模型使用较多的方法。以下是常见的间接检测方法:

1) 切削力信号检测法

刀具在使用过程中, 不同的磨损状况会导致切削力信号随之变化。切削力信号检测法通过安装力传感器可以对刀具使用过程中的力信号进行实时监测, 具有抗干扰性好的特点。

2) 声发射信号检测法

声发射信号源发射弹性波到刀具的表面, 声发射信号检测法通过声发射信号传感器检测接受到的振动信号来检测刀具的磨损情况, 刀具的材料、破损都会引起不同程度上变化, 具有精度高, 灵敏性好等特点。

3) 功率信号检测法

功率信号检测法是刀具在使用过程中, 刀具不同的磨损状态都会使电动机的功率发生变化, 通过监测电动机的功率从而分析刀具的磨损情况。在检测过程中一般通过传感器采集电动机的主轴功率, 或者是整个电动机产生的功率。功率信号检测的优点是信号采集比较简便, 很少有其它信号产生干扰。

4) 振动信号检测法

振动信号检测法是用振动信号传感器对刀具在使用过程中的振动信号进行采集。通常振动信号与刀具多种信号相关, 振动信号的灵敏度相对较高, 而且采集便捷, 信号相对容易处理, 但是需要克服外界因素对其的影响。

3. 刀具磨损信号处理

在采集完刀具使用过程中的信号后, 需要对采集的信号进行特征提取, 比较常用的特征提取方法为时频分析法[10]。时频分析法主要是对采集的信号构建时域和频域的联合函数, 用来描述信号在不同时间不同频率下的表现状态[11]。以下是常见的时频分析法:

1) 小波分析

小波分析[12]可以处理非平稳信号, 其原理是对一段信号, 用不同的小波基函数去拟合原信号。根据需求的不同, 可以对不同的信号频段进行不同的处理。虽然理论上小波分析可以处理非线性非平稳信号, 但是在实际使用过程中, 对非线性的信号分析效果欠佳。

2) 经验模态分解(EMD)

经验模态分解[13]是将信号进行平稳化的方法。将一段信号的上下包络求解平均值, 再由原信号减去平均值, 将这个过程重复数次到其满足固有模态函数(IMF)的条件为止, 得到 IMF1, 在原有信号上减去 IMF1, 得到新信号。接着在新信号的基础上重复以上过程, 直到其达到筛选条件, 最终得到若干信号分量和一条残余信号。经验模态分解理论上可以应用于任何信号, 对非平稳信号有着显著的分析效果。经验模态分解不同于傅里叶变换和小波变换, 不需要用基函数去不断拟合原信号, 所以对非线性非平稳信号也有极佳分析效果。

3) 希尔伯特黄变换(HHT)

希尔伯特黄变换[14]由经验模态分解作为基础,因此可以处理非线性非平稳信号。其原理是在经验模态分解的基础上对每个 IMF 分信号加上希尔伯特(Hilbert)变换,将解析信号变为指数形式,这样可以更精确的得到信号的瞬时频率。

4) 变分模态分解(VMD)

变分模态分解[15]将磨损信号分解为 n 个 IMF 分量,每个分量由一个中心频率和一个基准带宽组成,IMF 分量之和等于原信号,目的是使 IMF 分量的带宽和最小,最终得到最优解。变分模态分解可以使复杂的原信号分解为简单的信号,有较好的抗噪声干扰、精确度高等特点。

4. 刀具磨损的深度学习模型

常用的刀具磨损的深度学习检测模型[16]基本上可以分为四大类,如图 1 所示,根据数据是否有标签被分为:有监督学习模型、无监督学习模型、半监督学习模型以及深度迁移学习模型[17],通常根据不同数据选择建立合适的模型对刀具的磨损进行预测。刀具的深度学习检测流程如图 2 所示,在刀具磨损的信号采集完成后,通过时频分析方法对刀具磨损信号进行处理,选择合适的深度学习模型对刀具磨损进行预测。

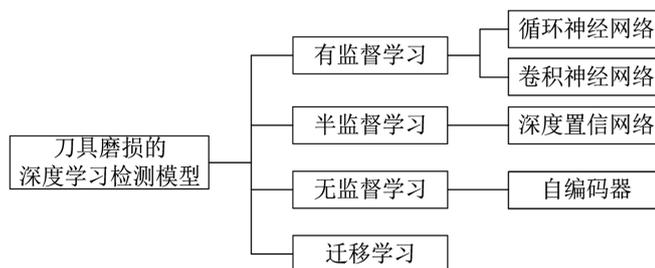


Figure 1. Classification diagram of the deep learning model of the tool
图 1. 刀具的深度学习模型分类图

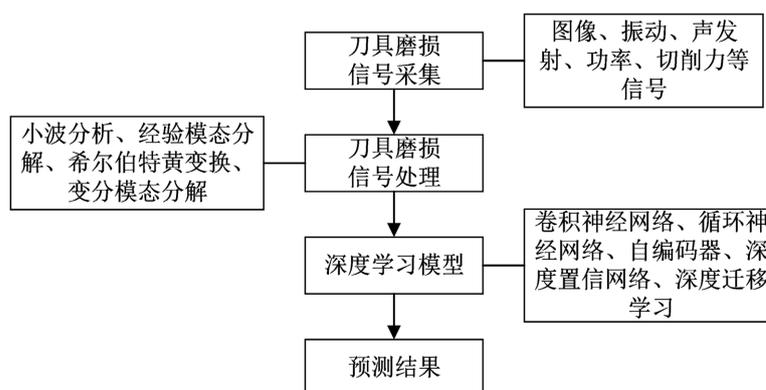


Figure 2. Deep learning tool detection flow chart
图 2. 深度学习的刀具检测流程图

4.1. 神经网络

神经网络[18]是在模拟人体脑神经神经元的基础上发展而来。将输入 x 输入到输入层中,通过隐含层中间的两层权重 w ,在将得出的值和预测值的误差最小化,通过梯度下降的方法得到最优权重值,这是应用最广泛的浅层网络学习方法。

4.2. 循环神经网络(RNN)

由于普通神经网络只对每个输入单独进行处理,不保留任何输入输出之间的状态和信息,对于一些时序数据,由于这种数据的数据量庞大,计算量过多通常会导致特征丢失等问题,循环神经网络的提出很好的解决了这些问题[19]。循环神经网络接受上一时间步隐藏状态的信息,并输出当前时间步的信息和被保留的上一时间步的信息,这样可以很好的保留隐藏状态下的有用信息。

4.2.1. 长短期记忆神经网络(LSTM)

长短期记忆神经网络[20]是一种特殊的循环神经网络,针对长时序数据中会出现的梯度消失和梯度爆炸问题,长短期记忆神经网络选择性的将信息进行去除保留。如图 3 所示为一个长短期记忆神经网络单元[21]示意图,一个单元主要有三个门组成:遗忘门、输入门、输出门。遗忘门 f_t 决定上一时间步哪些状态需要保留和舍弃,输入门 i_t 决定哪些新信息需要放在细胞状态中,输出门 O_t 决定多少信息需要输出值,候选细胞状态 \tilde{C}_t 为需要保留的新信息。

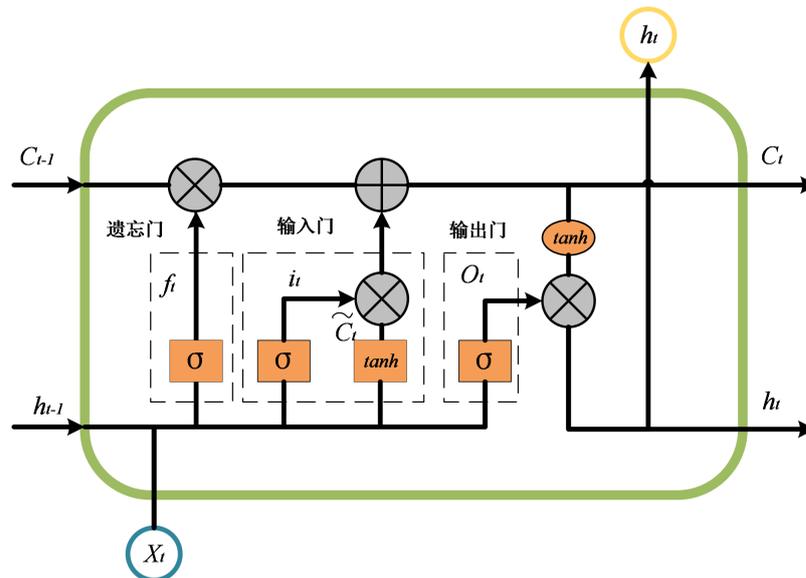


Figure 3. Schematic of the long and short-term memory unit
图 3. 长短期记忆单元示意图

吴飞[22]等人通过在小波分解过程中使用阈值函数,对高频信号修正进行去噪重构,并构建长短期记忆神经网络模型,通过粒子群算法优化模型中的隐藏层单元数和学习率得出最优参数。相比于未使用算法优化参数的 LSTM 模型,总体预测精度提高了 3.9%,改进后的模型在小样本预测中取得较好的效果。姜超[23]等人通过改进变分模态分解对主轴电机电流信号进行去噪。用最大包络峰度法确定 VMD 最佳分解模态数,并计算信噪比筛选出主要噪声信号进行软硬值去噪重构,通过长短期记忆神经网络进行预测,平均准确率达到 93.78%,相较于粒子群算法的支持向量机(PSO-SVM)模型,LSTM 模型在使用较少的时间,提升了 3%的预测精度,与 BP 神经网络模型相比,LSTM 模型虽然使用了一倍的时间但是提升了将近 5%的预测精度,经过改进的 VMD 克服了数据的模态混叠,软硬值去噪可以提取不同频段的有效特征,并且 LSTM 模型有着良好的预测精度。Zhou [24]等人将扭矩信号作为刀具磨损的检测对象,将扭矩信号进行希尔伯特黄变换和经验模态分解,将 EMD 分解后 IMF 信号振幅平均值和 HHT 边际谱作为特征输入变量并设置一个时间窗口选择多工况条件下的信号作为输出,将处理后的信号输入到 LSTM 模型得到刀具的

磨损, 由于数据质量不佳, 最终预测准确率只达到 78.06%。Sayyad [25]等人使用 IEEE NUA A ideahouse 数据集对刀具磨损进行预测。通过引入 PCC (皮尔逊系数)、RF (随机森林)、PCA (主成分分析)三种方法混合对信号进行特征提取选择, 将其输入到 LSTM 模型及其变种中进行对比。实验表明, PCC、RF、PCA 的混合特征选择方法大大降低了分析数据的复杂性, 和解码 - 编码器 LSTM 相结合预测效果最佳, 预测精度达到 97%。

4.2.2. 门控循环网络(GRU)

门控循环网络[26]可以看作是长短期记忆网络的简化版。如图 4 所示为一个门控循环单元示意图, 其中将长短期记忆网络中的遗忘门和输出门结合提出了更新门, 将细胞状态和隐藏状态也进行结合为隐藏状态[27]。其中更新门 z_t 用来决定哪些信息需要被保留下来, 重置门 r_t 的作用是将新的信息与之前保留下来的信息相融合。门控循环网络相较于于长短期记忆网络在更新状态过程中使用了较少的参数, 但是能够实现相似的效果, 计算速度明显提高。

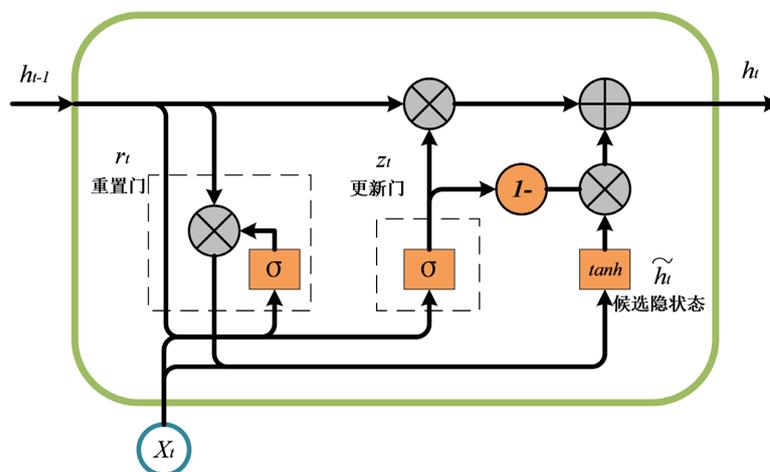


Figure 4. Schematic of the gating recurrent unit
图 4. 门控循环单元示意图

郝俊虎[28]等人通过小波分解对刀具磨损信号进行处理, 使用一种软硬阈值改良折衷法调整阈值进行降噪, 在阈值附近使用硬阈值法, 在远离阈值的过程中使用接近软阈值法并通过信噪比衡量选择最佳方案。在时频域通过计算皮尔逊系数对特征进行筛选, 然后将降噪后的信号输入到双层 GRU-BP 模型中得到刀具的预期磨损, 使用 RMSE 和 RUL Score 作为评分标准, 相比 XGBoost 和 BP 神经网络方法预测效果更好。胡德凤[29]等人提出了一种深度信号处理和堆叠残差 GRU 的刀具磨损预测模型。通过小波阈值分解过滤高频噪声信号重构, 并进行时频分析提取多个特征, 创新性的提出一种 BGSA 模块(由双向门控循环单元和内部注意力层实现)深度提取时序上的特征, 在此基础上提出了堆叠残差 GRU, 将 GRU 引入残差网络堆叠起来得到刀具磨损, 并用多种指标进行实验对比。实验表明, 引入残差模型的整体模型的整体提升性能较大, 一定程度上解决了网络退化问题, 提高了模型的收敛速度, 准确率能够达到 95%以上。Xu [30]等人提出了一种多尺度卷积的门控循环单元网络(MCGRU), 先通过多尺度卷积内核提取刀具磨损信号的局部特征, 然后通过深层门控循环网络捕捉信号中长时间尺度上长依赖特征, 最终得到刀具磨损, 使用 MAE 和 RMSE 作为评判标准, 对比其他模型能够取得更好的效果并且在没有足够的标签数据的情况下 MCGRU 能够更好的对原始数据进行有效预测。Xu [31]等人直接对火炮钻井数据的原始力信号进行评估, 在特征筛选过程中引入递归消除交叉验证(RFECV)对特征功能进行评分, 递归剔除不重要

的特征, 确定平均评分最好的维数, 使用 SVR 估计模型选择合适的特征后输入到 GRU 模型中。实验表明, 此方法相对支持向量回归(SVR)和多层感知机(MLP), 准确率能够达到 93.7%左右, 相对于 SVR 和 MLP 对数据特征的离散提取, GRU 模型对时序数据能够有效提取过去状态的特征。

4.2.3. 双向循环神经网络(BiRNN)

神经网络还有一种变形, 为双向循环神经网络, 常见的有双向长短期记忆网络(BiLSTM) [32]和双向门控循环网络(BiGRU) [33]。普通的循环神经网络只和上一时刻的数据特征相关, 而双向循环神经网络考虑到未来时刻的特征数据, 获取的特征信息更多。但是双向循环神经网络通常需要完整的序列数据才能预测任意时刻的数据, 并且双向计算的参数大大增加, 导致计算效率下降。

陈启鹏[34]等人提出一种 CNN 和 BiGRU 结合的深度门控循环单元网络模型(CABGRUS), 通过小波阈值去噪处理加速度信号中的高斯白噪声, 使用一维卷积从时序信号进行局部特征提取, 减少了模型的训练时间, 通过双层 BiGRU 网络并在其引入注意力机制(Attention), 提高了网络模型的识别精度和泛化能力, 最终预测准确率达到 97.58%, 相较于其他机器学习和深度学习模型有显著提升。Wu [35]等人将刀具的切削力信号用 Hankle 矩阵进行重构, 通过奇异值分解(SVD)对信号进行特征提取, 能够有效提取弱信号中的特征, 和使用时域特征进行对比, SVD 方法明显取得较好的结果。将 SVD 特征输入到 BiLSTM 中得到刀具磨损, 和其他循环神经网络模型进行对比实验, 可以发现 SVD-BiLSTM 刀具磨损预测模型的预测误差最小, 其预测性能优于其他循环神经网络。Mahmood [36]等人通过 SSA (奇异谱分析)将刀具磨损信号分解重构进行降噪, 通过主成分分析(PCA)将得到的特征进行降维, 最大限度减少信息损失, 减少网络的训练时间, 减低过拟合风险。使用独热编码(one-hot)将文本标签转变成二进制输入到 BiLSTM 中, 并且应用早停法和 dropout 修正网络, 有效解决过拟合问题, 最终得出预期磨损, 准确率达到 97.94%。Zhao [37]等人提出了一种局部特征的门控循环网络(LFGRU), 将手工提取特征和自动提取特征相结合。设计一个窗口从信号中提取局部特征, 为了解决信号序列中间部分信息丢失的问题, 在双向门控循环神经网络中间引入一个加权平均值来突出中间局部特征的影响。在刀具磨损检测的问题上, 相较于其他方法, LFGRU 的回归误差明显最小, 效果最好, 并且不需要太多相关知识经验就可以得到刀具局部特征, 完成刀具磨损预测。

4.3. 卷积神经网络(CNN)

2012 年, Krizhevsky 与 Hinton [38]推出 AlexNet 模型, 卷积神经网络因其对高维度数据强大的特征提取能力, 其广泛应用于图像处理领域。卷积神经网络一般由输入层、卷积层、池化层、全连接层、输出层组成。如图 5 所示为卷积神经网络的一个步骤示意图, 通过卷积核以一定的步长在所需要提取的数据上滑动对输入数据进行特征提取, 池化层对特征数据值进行压缩, 减少数据的维度。

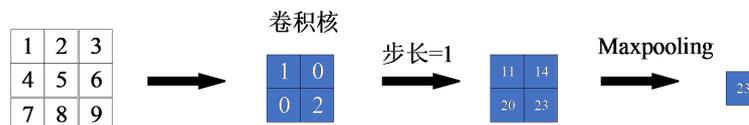


Figure 5. Schematic of convolutional neural network

图 5. 卷积神经网络示意图

此外卷积神经网络还有一些特殊的结构, 以下是常见的一些卷积神经网络模型:

1) Vggnet 卷积网络

Vggnet [39]卷积网络由多层的块状卷积滤波器堆栈组成, 和传统的卷积网络不同, Vgg 卷积网络通过

使用多个小尺寸卷积核来代替传统的大尺寸卷积核。如图 6 所示为 Vgg13 的模型示意图, 通过两层的卷积核代替一个大卷积核, 通过更深层次的模型结构提高模型的性能。Vggnet 的更深层次的网络结构虽然能够提高模型的性能, 但是由于其使用了三个全连接导致其参数使用较多, 浪费了较多的计算资源。

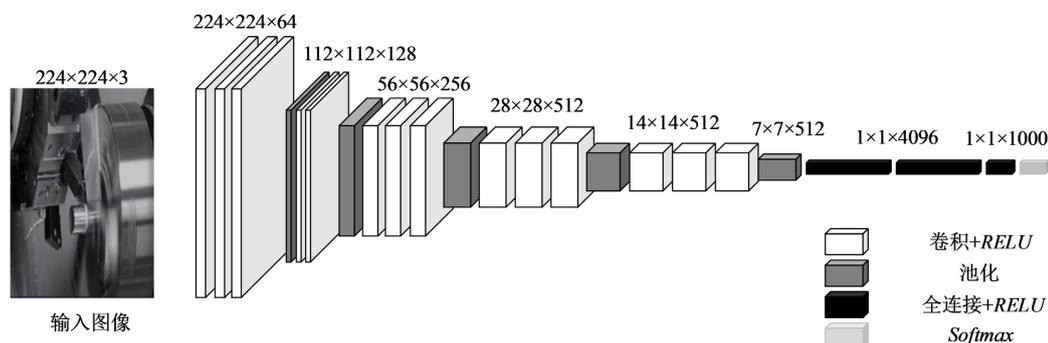


Figure 6. Schematic of Vgg13 network
图 6. Vgg13 网络示意图

周谦[40]等人对刀具振动和力信号进行处理, 通过短时傅里叶变换将一维非平稳数据近似分成多段平稳数据, 再将其转换成二维图谱输入到 Vgg13 卷积网络进行预测, 相比 Vgg16、Vgg19 网络模型, Vgg13 的损失函数值更小, 稳定性更好, 准确度达到 98%。Yang [41]等人提出了高效通道注意力破坏重构学习 (ECADCL) 的方法从刀具磨损图像中评估刀具状态, ECADCL 包括特征提取模块、破坏与重构模块、决策模块。特征提取模块由 resnet18 进行特征提取, 并引入 ECA 注意力模块自适应提取关键特征。破坏与重构模块为了区别刀具图像的局部细节, 通过区域混淆机制(RCM)破坏结构, 引入对抗学习减少噪声, 最后对局部信息进行重组。决策模块由全连接构成, 输出最终结果。实验表明, 引入 ECA 的 Vgg16 网络的准确率最高达到 94.09%, ECA 使网络能够集中在输入图像中最有代表性的部分, 同时抑制不太关键的信息, 破坏与重构模块能够局部对特征进行有效提取。

2) GoogLeNet 卷积网络

GoogLeNet [42]卷积网络和 Vggnet 网络是同时提出的, 相较于 Vggnet, GoogLeNet 在结构方面提出 Inception 结构, 使网络模型获得更宽的网络宽度和更深的网络深度。如图 7 所示为一个 Inception 示意图, 通过不同的卷积核获得不同尺度下的特征最后融合在一起, 并在 Inception 内使用三个 1×1 的卷积核进行数据压缩降维。GoogLeNet 网络由多个 Inception 堆叠而成, 并在网络不同深度添加两个 Softmax (辅助分类器)向前传递梯度, 用来解决模型参数增加导致的梯度消失问题。

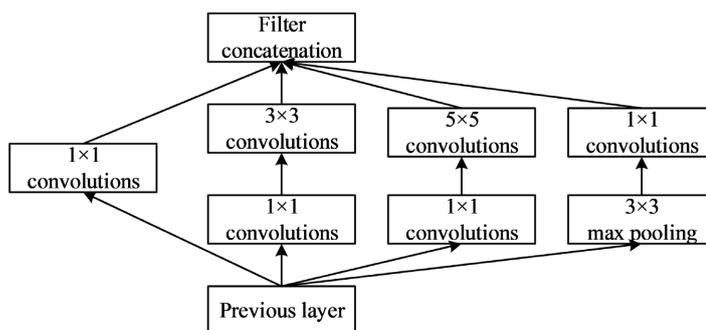


Figure 7. Schematic of Inception
图 7. Inception 示意图

Liao [43]等人对比论证车床铣削加工制造过程中的声发射信号的时频处理方式,发现小波变换(CWT)和短时傅里叶变换(STFT)能够有效捕获时频特征,而希尔伯特黄变换(HHT)和 Wigner Ville 分布(WVD)容易出现模态混叠和交叉问题。通过卷积神经网络经典结构对铣削加工中的声发射信号转变成图谱进行分类。实验表明,使用 GoogLenet 的准确率为 89.67%,计算速度最快只用时 2.65 毫秒,能够有效实时的对刀具磨损进行预测。童诗佳[44]提出了一种基于 GoogLenet 的断刀检测,通过拍摄换刀时刀具的照片,将其转换成灰度图,通过中值滤波过滤噪声,并将 Inception 模块和 Residual 模块相结合并降维,进一步增加网络深度,减少了模型参数,一定程度上减少了过拟合风险,提高了模型的泛化能力,准确率达到 95%。

3) Resnet 卷积网络

Resnet [45]也称为残差卷积网络,它由多个残差块堆叠组成。如图 8 所示为残差块的示意图,在原有的输入 x 求得映射 $H(x)$ 的基础上引入残差的概念,将其等价映射为 $F(x)+x$,当 $H(x)$ 极为接近于 $F(x)+x$ 时使得网络能够捕捉到映射中细微的变化,一定程度能够缓解梯度消失的问题,并且模型能够快速收敛。

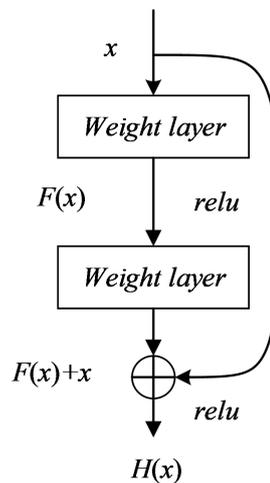


Figure 8. Schematic of the residual block

图 8. 残差块示意图

Dong [46]等人提出了一种基于多传感信号的 CaAt-ResNet-1d 模型,使用 Resnet18 作为基础网络进行一维卷积提取特征,在剩余网络块中加入 CaAt5 通道注意力机制,自动对不同通道的特征进行提取,更加适合对多通道时序信号进行提取。最终该方法的准确率达到 89.27%,相对其他 GRU、LSTM、基础 Resnet18 模型效果更好。Li [47]等人提出了一种残差和密集连接块相融合的残差密集网络(RDN),首先对刀具的振动信号进行预处理,通过小波阈值去噪重构,将不同卷积层之间的残差的密集连接,使得特征能够重复使用,减少了参数的数量,增强了特征传播。通过对比实验证明,一定深度的 RDN 方法,可以更加有效的提取特征,准确率达到 93.5%。

4) Densenet 卷积网络

Densenet 网络结构[48]和 Resnet 网络结构较为相似,如图 9 所示是 Densenet 稠密连接示意图,不同的是 Resnet 网络是前面残差块映射的简单相加,而 Densenet 网络是前面所有层输出的连接,因此保留了不同层数之间的特征,并且在训练数据较少的情况下也能够做到有效的模型拟合,提高了模型的计算效率。

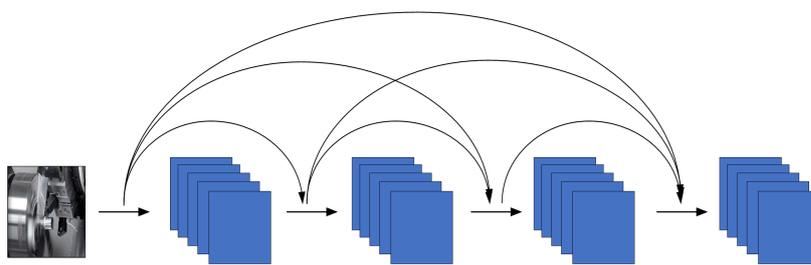


Figure 9. Schematic of the Dense block
图 9. Dense block 示意图

曹大理[49]等人通过一维卷积网络提取刀具原始时域信号中的高维特征，避免在信号处理中的损失，并引入皮尔逊系数和互信息和最大信息系数选出强相关的特征，构建 Densenet 网络得出预测准确率达到 97.1%，相比传统 SVR、隐马尔可夫模型(HMM)、BP 神经网络(BPNN)、FNN 模型有更好的稳定性和拟合效果。Guo [50]等人提出了一种监测 - 预测方法。在监测过程中使用 Densenet 的改进模型，将密集块和过渡块相结合，提取刀具磨损的相关特征。在预测过程中使用一种编码 - 解码结构，引入注意力机制选择性的将长期和短期信息向量相连接，获取不同时间段特征，编码 - 解码结构使用 GRU 模型来预测刀具磨损。实验表明，使用改进 Densenet 的监测模块比使用 Resnet、GRU 模型的拟合效果更好，融合了注意力机制能够对刀具磨损进行实现多步预测，并且短期信息比长期信息对刀具磨损预测影响更大。

4.4. 深度置信网络(DBN)

1) 受限玻尔兹曼机

受限玻尔兹曼机[51]是一个概率图模型，和一般玻尔兹曼机不同，受限玻尔兹曼机只有两层之间有连接权值，同一层内部是没有连接权值的。其原理是通过求解可见单元和隐层单元的联合概率分布函数和能量函数，寻找最大概率下的最优权重。

2) 深度置信网络

深度置信网络[52]是一个由多层受限玻尔兹曼机堆栈而成的网络模型，结构类似于神经网络。如图 10 所示为深度置信网络模型图，通过受限玻尔兹曼机隐层之间连接，在最底层构建一层 BP 神经网络，通过反向传播优化权重。不同于前馈神经网络通过反向传播微调权重，深度置信网络从底层逐层求解来微调权重，解决神经网络容易陷入局部最优的问题。

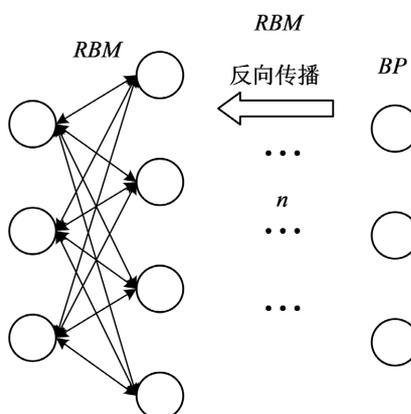


Figure 10. Deep belief network model diagram
图 10. 深度置信网络模型图

Wang [53]等人提出了多任务训练的改进深度置信网络, 首先对每一层进行无监督预训练得到权重, 采用迭代损失阈值的自适应停止方法确定无监督训练次数。在此基础上, 采用基于孪生网络的训练方法对预训练后的 DBN 进行权重调整, 将 DBN 网络最后几个隐藏层的传输改进为多任务并行数据传输, 使改进后的 DBN 可以实现多任务学习。多任务深度学习方法可以实现信息共享, 抑制过拟合, 提高预测精度, 减少计算时间, 最终预测精度达到 99%。刘子安[54]等人构建深度置信网络模型, 在其中引入 Dropout 正则化, 引入随机概率向量判断节点的工作状态, 工作静默的节点会在训练过程中停止使用, 预测准确率达到 96%, 相较于改进前模型的提升了 3.4%。Chen [55]等人使用深度置信网络模型对刀具磨损进行预测, 并且通过设置不同神经元和 SVR、ANN 进行对比, 并隐藏一部分神经元进行对比实验, 最终发现 DBN 的速度相对较快、并且稳定性更好, 最终预测精度达到 98.89%, 能够有效实现刀具磨损预测。David [56]等人提出了一种改进蜻蜓优化算法的深度置信网络(IDOA-DBN)模型, 利用局部二值模式(IBP)、加速鲁棒特征(SURF)、哈里斯角检测(HCD)、定向梯度直方图(HOG)、灰度共生矩阵(GLCM)特征描述对刀具分割图像进行特征提取, 降低纹理特征向量。通过改进的蜻蜓优化算法降低特征提取的维数, 使用深度置信网络得到刀具的预期磨损。实验表明, 对比 Alexnet、Resnet14、Resnet18、Autoencoder 等模型和其他算法, IDOA-DBN 模型有更好的性能预测精度达到 98.83%。

4.5. 自编码器(AE)

自编码器[57]结构类似于神经网络, 如图 11 所示通过构建解码器和编码器来实现, 解码器将高维的数据变换成低维数据, 编码器再将低维的数据变换为高维的数据, 这样可以将数据中的高维度特征用低维度表现出来。在刀具磨损检测问题上常用的是一种堆栈稀疏自编码器(SSAE), 在自编码器的基础上引入一个稀疏限制项, 通过设置在损失函数中的限制项来减少自编码器中神经元的个数, 提高网络运算效率[58], 再将稀疏自编码器堆叠连接, 更大程度的提取特征。

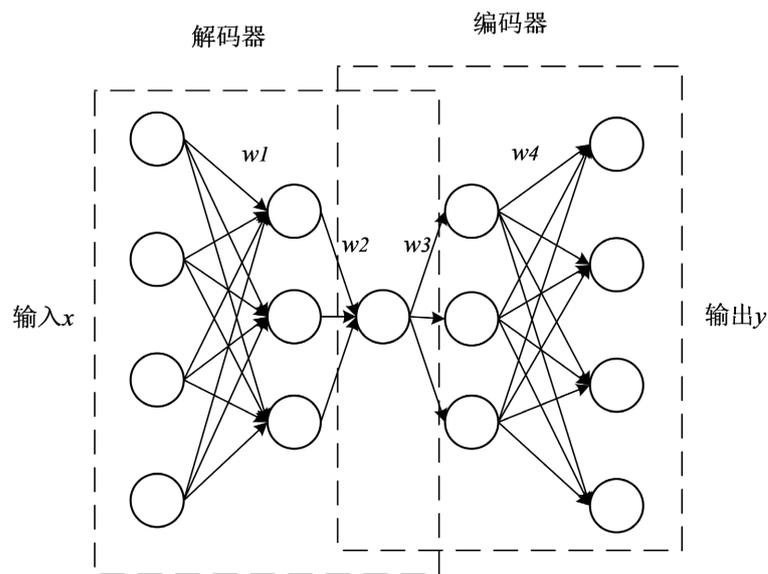


Figure 11. Auto-Encoder model diagram
图 11. 自编码器模型图

李宏坤[59]等人通过刀具主轴电流信号对刀具磨损进行预测, 对数据信号进行压缩感知, 为了增强网络的鲁棒性, 在训练数据中高斯白噪声, 并对堆栈稀疏自编码进行有监督微调。与人工提取特征和其他

数据处理方式相比用了更少的时间,避免了先验知识才能对刀具磨损进行预测的弊端,准确率达到 98.5%。安华[60]等人通过稀疏自编码器对刀具切削力信号进行特征提取,在样本中加入高斯白噪声增加样本数目,提高预测精度,利用 Dropout 方法解决网络中的过拟合问题,引入皮尔逊系数自动选择相关度较高的特征,利用 BP 算法建立模型,最后通过指数平滑法微调预测值,使预测监测过程更加贴近工程实际。Ochoa [61]等人提出了一种使用多种传感信号的 MFCC-SSAE 模型来预测刀具磨损,将刀具磨损信号的 5 种切削条件和几何参数以及 7 个梅尔频率倒频谱系数(MFCC)输入到 SSAE 模型中并对自定稀疏性、正则化和稀疏正则化器的参数进行调整,防止训练出现过拟合和欠拟合的问题,相对其他 CNN, FFNN, WT-SVM 方法,此方法每 16 ms 即可评估刀具磨损情况,展现出极强的实时预测能力,最终预测准确率达到 99.63%。Ou [62]等人提出了一种阶次分析和堆栈稀疏自编码器(OA-SSAE)的方法,通过阶次分析刀具磨损中的电流信号,变速信号转化为角度域平稳信号提取信号中的阶数特征,然后将阶次特征输入到 SSAE 当中并通过 L-BFGS 算法优化模型中的关键参数,结果表明该方法的性能优于其他方法,在实际工业制造中具有较好的适用性,最终得到刀具的预期磨损,平均准确率达到 96.41%,高于 ELM、BPNN、SVM、RF、KNN 模型,但在计算时间上会略微高出。

4.6. 深度迁移学习模型

迁移学习指将类似问题的网络模型通过微调应用在目标问题的学习方法[63],构建参数共享的模型以及对源域、目标域特征进行变换,主要包括基于样本的迁移、基于特征的迁移、基于模型的迁移和基于关系的迁移[64]。如图 12 所示在迁移学习任务执行过程中需要确定源域和目标域,将源域模型中学习到的知识参数应用到目标域中,通过调整参数的方法,完成对目标域模型的训练。迁移学习可以通过对相似问题源域中数据样本的提取,解决新的目标问题中数据标签样本不足导致模型欠拟合的问题,在刀具磨损预测方面也获得广泛关注。

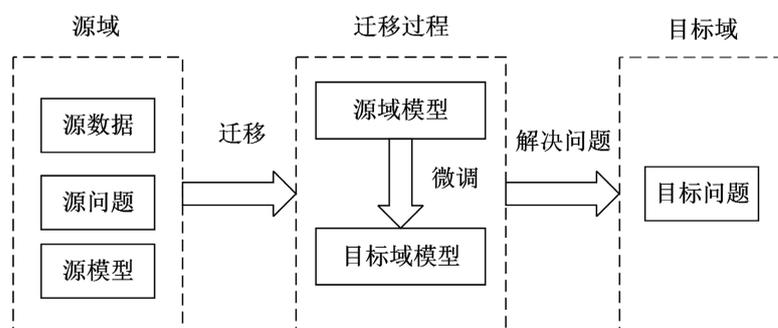


Figure 12. Schematic of transfer learning
图 12. 迁移学习示意图

戴稳[65]等人提出一种基于 Alexnet 的迁移学习模型方法预测刀具磨损。先通过传感器采集刀具的振动信号并使用皮尔逊系数提取出相关程度较高特征,然后通过复 morlet 将刀具磨损信号转变成小波尺度图,利用 Alexnet 模型进行训练,对参数进行微调,最终得到一个全连接的网络。实验表明,迁移学习模型在小样本的刀具磨损预测效果表现非常好,准确率达到 100%,而仅使用 Alexnet 的预测率只有 66.7%。蔡伟立[66]等人提出了一种动态对抗域适应迁移学习方法,通过 LSTM 预训练历史刀具数据样本,然后通过对抗域适应训练,用少量的目标域样本去微调模型参数,最后使用微调后的模型预测出刀具磨损。实验表明,使用动态对抗域适应的预测效果明显强于未使用的模型,平均准确率在 90%以上,而未使用的模型平均准确率在 60%左右,说明该方法在训练样本较少的情况下能够有效构建模型对刀具磨损进行预

测。Sun [67]等人提出了一种基于稀疏自编码器(SAE)的深度迁移学习模型,通过权值转移将源域模型的权值转移到目标域中,为了学习目标域特征和源域特征的联合特征和相似性,通过SAE层之间的梯度更新使特征之间的差异最小化,最后构建SAE模型得到刀具磨损。实验表明,通过特征迁移学习模型的平均相对误差要明显低于未进行特征迁移学习的模型,并且该方法也能准确的预测出刀具的磨损。Wang [68]等人提出了一种对抗域的迁移学习模型,通过优化器最小化源域的训练损失,同时使源域和目标域的域分类器损失最大化生成公共特征,然后构建一维CNN网络对刀具磨损进行预测。实验表明,使用对抗域的迁移学习模型可以使没有标签数据的目标域样本的预测精度从43%提高到69%,并且在使用10%的有标签数据之后,预测精度达到88%。

表1对刀具磨损检测常用的深度学习模型进行了对比,通过对比不同模型特点,给出不同模型的适用场景。表2对本文中提及的一些方法进行对比汇总,由于使用的数据并不相同,因此只对其特点创新性进行归纳总结。

Table 1. Comparison of the advantages and disadvantages of different models

表 1. 不同模型的优缺点对比

深度学习方法	常用模型	特点	适用场景
循环神经网络	(双向)长短期记忆网络 (双向)门控循环网络	能够提取时间序列数据的特征	多用于时序数据的预测
卷积神经网络	Vggnet GoogLenet Resnet Densenet	能够处理多维数据,并且模型的预测精度较好,应用场景多	多用于二维图像并且数据量较大的数据
深度置信网络		不需要大量的含标签数据样本,模型的收敛速度较快,不容易陷入局部最优	多用于小样本预测
自编码器	堆栈稀疏自编码器	泛化能力强,无监督不需要有标签的数据样本	没有标签的数据
深度迁移学习		从源域学习样本,不需要目标域过多的样本数据	对于模型、数据分布相似的数据,能够快速得到结果,也可用于小样本预测

Table 2. Summary of different literature methods

表 2. 不同文献方法汇总

模型方法	文献来源	类型	准确率	特点及其创新性
小波阈值去噪改进 PSO-LSTM	文献[22]	分类	96%	可以实现小规模样本的预测和分类,并且识别精度高
改进 VMD-LSTM	文献[23]	分类	92.44%	改进的 VMD 克服了模态混叠问题,并且模型识别精度高,泛化能力强
HHT-LSTM	文献[24]	回归	78.06%	使用扭矩信号,实现在多工况下得到刀具的磨损
PCC、RF、PCA 混合的编码-解码 LSTM	文献[25]	回归	97%	采用 PCC、RF、PCA 混合方法提取特征,降低数据的复杂度,发现切削力信号的强相关性

Continued

小波阈值去噪的融合 Attention 堆叠残差 GRU	文献[29]	回归	>95%	提出堆叠残差 GRU 模型, 解决深度网络的退化问题, 并一定程度上加快了模型的收敛速度
交叉验证递归特征消除的 GRU	文献[31]	回归	93.7%	特征选择降低了特征维数并且能够有效消除噪声
小波阈值去噪的融合 Attention 的 CNN + BiGRU	文献[34]	分类	97.58%	一维 CNN 提取了信号局部特征, BiGRU 能够兼顾全局信号特征, 融合 Attention 机制提高模型的精度和泛化能力
SSA-BiLSTM	文献[36]	分类	97.94%	使用 PCA 降低了特征维度, 减少了信息损失, 训练提前终止防止过拟合
短时傅里叶的 Vgg13	文献[40]	分类	>98%	短时傅里叶将非平稳信号分解成多段近似平稳信号, 并且模型预测准确率高, 损失值更小, 整体稳定性好
ECADCL 的 Vgg	文献[41]	分类	94.09%	ECA 使网络能够提取关键特征, 破坏与重构模块提高模型的鲁棒性
CaAt-ResNet-1d	文献[46]	分类	89.27%	使用 CaAt 通道注意力机制, 能够对多通道时序信号进行提取
小波阈值去噪 RDN	文献[47]	分类	93.5%	提出残差块的密集连接概念, 缓解了梯度分散的问题
Densenet	文献[49]	回归	97.1%	使用原始时域信号避免损失, 自适应的提取特征, 泛化性能强
多任务训练的 DBN	文献[53]	分类	99%	使用孪生网络的训练方法, 多任务深度学习方法可以实现信息共享, 加快计算速度
改进 DBN	文献[54]	分类	96%	改进后的 DBN 模型泛化能力得到增强
DBN	文献[55]	回归	98.89%	增加模型深度并隐藏部分神经元, 稳定性好, 计算速度快
IDOA-DBN	文献[56]	分类	98.83%	IDOA 降低特征维度, 显著的减少模型的计算时间
压缩感知加噪处理数据的 SSAE	文献[59]	分类	98.5%	更好的对表征信号的隐藏特征进行提取, 自适应的提取特征, 识别出不同信号的差异
SSAE	文献[61]	分类	99.63%	通过对模型正则化、系数正则化的参数进行微调, 避免过拟合, 并且计算速度快, 实时性强
OA-SSAE	文献[62]	分类	96.41%	使用阶次分析提取特征, 减少了模型的计算量, 提高了模型的效率, L-BFGS 算法寻找最优参数, 提升预测效果, 贴近工程实际
动态对抗域的 LSTM 迁移学习	文献[66]	回归	>90%	通过对抗域训练微调模型参数, 用较少的样本实现高效预测
对抗域的 CNN 迁移学习	文献[68]	回归	88%	对抗域训练生成共同特征, 对于标签较少的数据有较好的效果

5. 未来展望

目前在刀具磨损预测领域中, 虽然深度学习在提高预测精度和加快模型运算速度方面提供了理论支持, 但是结合各类学习模型, 还存在一些问题:

1) 对于刀具检测信号。对于单一信号的处理已经难以满足刀具的深度学习模型, 多种信号, 以及多种信号融合的刀具检测模型更多的被使用, 多种状态下刀具的磨损状态也是目前重点的研究方向。目前

信号数据主要使用的是有标签数据，在数据标注方面用到大量的时间精力，但是使用无样本标签的数据的无监督学习预测效果会比较差，这是以后需要改进和研究的方向。

2) 对于网络模型架构。由于采集到刀具信号形式多种多样，对于不同形式信号选择不同的模型是有必要的。目前学者们使用较多的是混合网络模型，将两种及以上的学习模型相结合，这样虽然可以解决这个问题并提高模型的特征提取能力，但是随着网络层数加深，拟合速度进一步下降，因此有效提高模型的运算效率是目前主要需要解决的问题。

3) 对于深度学习模型的超参数。在模型超参数的设置上主要根据个人经验和文献，随着智能优化算法的发展，目前使用广泛的模型都会在原有基础上加上智能优化算法来找到最佳的超参数以达到更好的效果，但是智能优化算法有时会陷入局部最优或全局搜索能力变差等问题，这方面还有待加强，有着比较广泛的研究前景。

6. 结束语

本文对刀具使用过程中信号的采集以及后续对信号特征的提取方法进行总结归纳，总结深度学习的预测模型，对刀具磨损的实时检测进行论述，基于深度学习的刀具磨损检测方法已经成为发展趋势。关于在线实时刀具磨损检测技术，无论是在信号处理还是深度学习模型都存在着一些问题和挑战。随着深度学习和其他相关领域的发展，如何通过深度学习和其他跨学科相结合的方法是解决刀具磨损问题的关键，未来将建立起更加完善的刀具磨损检测系统来满足制造业生产的需要。

基金项目

江苏省研究生实践创新计划资助项目(SJCX22-XZ033); 大学生创新创业训练计划资助项目(2022464)。

参考文献

- [1] 刘战强, 黄传真, 万熠, 等. 切削温度测量方法综述[J]. 工具技术, 2002, 36(3): 3-6.
- [2] 李鹏, 黄亦翔, 夏鹏程, 等. 基于一维卷积长短时记忆网络的多信号融合刀具磨损评估[J]. 机械与电子, 2021, 39(5): 8-14.
- [3] 关山, 康晓峰. 在线金属切削刀具磨损状态监测研究的回顾与展望 I: 监测信号的选择[J]. 机床与液压, 2010, 38(11): 127-132.
- [4] 陈雷明, 杨润泽, 张治. 刀具检测方法综述[J]. 机械制造与自动化, 2011, 40(1): 49-50+144.
- [5] 孙巍伟, 黄民, 高延. 基于 EMD-HMM 的机床刀具磨损故障诊断[J]. 机床与液压, 2017, 45(13): 178-181.
- [6] 赵帅, 黄亦翔, 王浩任, 等. 基于随机森林与主成分分析的刀具磨损评估[J]. 机械工程学报, 2017, 53(21): 181-189.
- [7] 王爽. 基于高斯回归分析的高温合金刀具磨损在线预测方法[J]. 工具技术, 2022, 56(2): 83-87.
- [8] Martínez-Arellano, G., Terrazas, G. and Ratchev, S. (2019) Tool Wear Classification Using Time Series Imaging and Deep Learning. *The International Journal of Advanced Manufacturing Technology*, **104**, 3647-3662. <https://doi.org/10.1007/s00170-019-04090-6>
- [9] 贾娜, 马雪亭. 对刀具磨损获取信号处理方法的探讨[J]. 机械制造, 2015, 53(3): 55-57.
- [10] 王友仁, 王俊, 黄海安. 基于非线性短时傅里叶变换阶次跟踪的变速行星齿轮箱故障诊断[J]. 中国机械工程, 2018, 29(14): 1688-1695.
- [11] Chen, J.G., Jiang, J., Guo, X.N., et al. (2021) An Efficient CNN with Tunable Input-Size for Bearing Fault Diagnosis. *International Journal of Computational Intelligence Systems*, **14**, 625-634. <https://doi.org/10.2991/ijcis.d.210113.001>
- [12] Torrence, C. and Compo, G.P. (1998) A Practical Guide to Wavelet Analysis. *Bulletin of the American Meteorological Society*, **79**, 61-78. [https://doi.org/10.1175/1520-0477\(1998\)079<0061:APGTWA>2.0.CO;2](https://doi.org/10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2)
- [13] Yu, D., Cheng, J. and Yang, Y. (2005) Application of EMD Method and Hilbert Spectrum to the Fault Diagnosis of Roller Bearings. *Mechanical Systems and Signal Processing*, **19**, 259-270.

- [https://doi.org/10.1016/S0888-3270\(03\)00099-2](https://doi.org/10.1016/S0888-3270(03)00099-2)
- [14] Huang, N.E., Shen, Z. and Long, S.R. (1998) The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis. *Proceedings of the Royal Society of London*, **454**, 903-995. <https://doi.org/10.1098/rspa.1998.0193>
- [15] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- [16] Goodfellow, I., Le, Q., Saxe, A., *et al.* (2009) Measuring Invariances in Deep Networks. In: *Advances in Neural Information Processing Systems*, MIT Press, Cambridge, 646-654.
- [17] Erhan, D., Bengio, Y., Courville, A., *et al.* (2010) Why Does Unsupervised Pre-Training Help Deep Learning. *Journal of Machine Learning Research*, **11**, 625-660.
- [18] Sick, B. (2002) On-Line and Indirect Tool Wear Monitoring in Turning with Artificial Neural Networks: A Review of More than a Decade of Research. *Mechanical Systems and Signal Processing*, **16**, 487-546. <https://doi.org/10.1006/mssp.2001.1460>
- [19] Bengio, Y., Simard, P. and Frasconi, P. (1994) Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*, **5**, 157-166. <https://doi.org/10.1109/72.279181>
- [20] 何彦, 凌俊杰, 王禹林, 等. 基于长短期记忆卷积神经网络的刀具磨损在线监测模型[J]. 中国机械工程, 2020, 31(16): 1959-1967.
- [21] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [22] 吴飞, 农皓业, 马晨浩. 基于 PSO-LSTM 模型的刀具磨损预测方法[J/OL]. 吉林大学学报(工学版): 1-9. <https://doi.org/10.13229/j.cnki.jdxbgxb20210778>, 2023-3-14.
- [23] 姜超, 李国富. 改进 VMD-LSTM 法在刀具磨损状态识别中的应用[J]. 机械科学与技术, 2022, 41(2): 246-252.
- [24] Zhou, J.T., Zhao, X. and Gao, J. (2019) Tool Remaining Useful Life Prediction Method Based on LSTM under Variable Working Conditions. *The International Journal of Advanced Manufacturing Technology*, **104**, 4715-4726. <https://doi.org/10.1007/s00170-019-04349-y>
- [25] Sayyad, S., Kumar, S., Bongale, A., *et al.* (2022) Tool Wear Prediction Using Long Short-Term Memory Variants and Hybrid Feature Selection Techniques. *The International Journal of Advanced Manufacturing Technology*, **121**, 6611-6633. <https://doi.org/10.1007/s00170-022-09784-y>
- [26] Prihatno, A.T., Nurcahyanto, H., Ahmed, M.F., *et al.* (2021) Forecasting PM_{2.5} Concentration Using a Single-Dense Layer Bi-LSTM Method. *Electronics*, **10**, 1808. <https://doi.org/10.3390/electronics10151808>
- [27] Lopez, E., Valle, C., Allende, H., *et al.* (2018) Wind Power Forecasting Based on Echo State Networks and Long Short-Term Memory. *Energies*, **11**, 526-536. <https://doi.org/10.3390/en11030526>
- [28] 郝俊虎, 胡毅, 崔宁宁, 等. GRU-BP 在数字化车间关键部件寿命预测中的研究[J]. 小型微型计算机系统, 2020, 41(3): 637-642.
- [29] 胡德凤, 张晨曦, 汪世涛, 等. 基于深度信号处理和堆叠残差 GRU 的刀具磨损智能预测模型[J]. 计算机科学, 2021, 48(6): 175-183.
- [30] Xu, W.X., Miao, H.H., Zhao, Z.B., *et al.* (2021) Multi-Scale Convolutional Gated Recurrent Unit Networks for Tool Wear Prediction in Smart Manufacturing. *Chinese Journal of Mechanical Engineering*, **34**, 1-16. <https://doi.org/10.1186/s10033-021-00565-4>
- [31] Xu, H., Zhang, C., Hong, G.S., *et al.* (2018) Gated Recurrent Units Based Neural Network for Tool Condition Monitoring. 2018 *IEEE International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, 8-13 July 2018, 1-7. <https://doi.org/10.1109/IJCNN.2018.8489354>
- [32] 曾安, 聂文俊. 基于深度双向 LSTM 的股票推荐系统[J]. 计算机科学, 2019, 46(10): 84-89.
- [33] Liu, F.G., Zheng, J.Z., Zheng, L.L., *et al.* (2020) Combining Attention-Based Bidirectional Gated Recurrent Neural Network and Two-Dimensional Convolutional Neural Network for Document-Level Sentiment Classification. *Neuro-computing*, **371**, 39-50. <https://doi.org/10.1016/j.neucom.2019.09.012>
- [34] 陈启鹏, 谢庆生, 袁庆霓, 等. 基于深度门控循环单元神经网络的刀具磨损状态实时监测方法[J]. 计算机集成制造系统, 2020, 26(7): 1782-1793.
- [35] Wu, X.Q., Li, J., Jin, Y.Q., *et al.* (2020) Modeling and Analysis of Tool Wear Prediction Based on SVD and BiLSTM. *The International Journal of Advanced Manufacturing Technology*, **106**, 4391-4399. <https://doi.org/10.1007/s00170-019-04916-3>
- [36] Mahmood, J., Luo, M. and Rehman, M. (2022) An Accurate Detection of Tool Wear Type in Drilling Process by Ap-

- plying PCA and One-Hot Encoding to SSA-BLSTM Model. *The International Journal of Advanced Manufacturing Technology*, **118**, 3897-3916. <https://doi.org/10.1007/s00170-021-08200-1>
- [37] Zhao, R., Wang, D.Z., Yan, R.Q., *et al.* (2017) Machine Health Monitoring Using Local Feature-Based Gated Recurrent Unit Networks. *IEEE Transactions on Industrial Electronics*, **65**, 1539-1548. <https://doi.org/10.1109/TIE.2017.2733438>
- [38] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, **60**, 2-12.
- [39] Li, Z.B., Li, F., Zhu, L., *et al.* (2020) Vegetable Recognition and Classification Based on Improved VGG Deep Learning Network Model. *International Journal of Computational Intelligence Systems*, **13**, 559-564. <https://doi.org/10.2991/ijcis.d.200425.001>
- [40] 周谦, 国凯, 孙杰. VGG13 卷积神经网络在刀具磨损监测中的应用[J]. 工具技术, 2022, 56(6): 112-116.
- [41] Yang, J., Duan, J., Li, T.X., *et al.* (2022) Tool Wear Monitoring in Milling Based on Fine-Grained Image Classification of Machined Surface Images. *Sensors*, **22**, 8416. <https://doi.org/10.3390/s22218416>
- [42] Szegedy, C., Liu, W., Jia, Y.Q., *et al.* (2015) Going Deeper with Convolutions. *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 7-12 June 2015, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- [43] Liao, Y.B., Ragai, I., Huang, Z.Y., *et al.* (2021) Manufacturing Process Monitoring Using Time-Frequency Representation and Transfer Learning of Deep Neural Networks. *Journal of Manufacturing Processes*, **68**, 231-248. <https://doi.org/10.1016/j.jmapro.2021.05.046>
- [44] 童诗佳. 基于 GoogleNet 的断刀检测系统[D]: [硕士学位论文]. 武汉: 华中科技大学, 2019.
- [45] He, K.M., Zhang, X.Y., Ren, S.Q., *et al.* (2016) Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Washington DC, 27-30 June 2016, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- [46] Dong, L., Wang, C.S., Yang, G., *et al.* (2023) An Improved ResNet-1d with Channel Attention for Tool Wear Monitor in Smart Manufacturing. *Sensors*, **23**, 1240. <https://doi.org/10.3390/s23031240>
- [47] Li, Y.T., Xie, Q.S., Huang, H.S., *et al.* (2019) Research on a Tool Wear Monitoring Algorithm Based on Residual Dense Network. *Symmetry*, **11**, 809. <https://doi.org/10.3390/sym111060809>
- [48] Huang, G. and Liu, Z. (2017) Densely Connected Convolutional Networks. *IEEE Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 1-28. <https://doi.org/10.1109/CVPR.2017.243>
- [49] 曹大理, 孙惠斌, 张纪铎, 等. 基于卷积神经网络的刀具磨损在线监测[J]. 计算机集成制造系统, 2020, 26(1): 74-80.
- [50] Guo, B.S., Zhang, Q., Peng, Q.J., *et al.* (2022) Tool Health Monitoring and Prediction via Attention-Based Encoder-Decoder with a Multi-Step Mechanism. *The International Journal of Advanced Manufacturing Technology*, **122**, 685-695. <https://doi.org/10.1007/s00170-022-09894-7>
- [51] Hinton, G.E. (2010) A Practical Guide to Training Restricted Boltzmann Machines. *Momentum*, **9**, 926-947.
- [52] Hinton, G.E., Osindero, S. and The, Y.W. (2006) A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, **18**, 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- [53] Wang, Y.Q., Qin, B., Liu, K., *et al.* (2020) A New Multitask Learning Method for Tool Wear Condition and Part Surface Quality Prediction. *IEEE Transactions on Industrial Informatics*, **17**, 6023-6033. <https://doi.org/10.1109/TII.2020.3040285>
- [54] 刘子安, 刘建春, 苏进发, 等. 刀具磨损感知数据驱动下的 DBN 预测模型研究[J]. 机械科学与技术, 2021, 40(7): 1043-1050.
- [55] Chen, Y.X., Jin, Y. and Jiri, G. (2018) Predicting Tool Wear with Multi-Sensor Data Using Deep Belief Networks. *The International Journal of Advanced Manufacturing Technology*, **99**, 1917-1926. <https://doi.org/10.1007/s00170-018-2571-z>
- [56] David, L.G., Patra, R.K., Falkowski-Gilski, P., *et al.* (2022) Tool Wear Monitoring Using Improved Dragonfly Optimization Algorithm and Deep Belief Network. *Applied Sciences*, **12**, 8130. <https://doi.org/10.3390/app12168130>
- [57] Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986) Learning Representations by Back-Propagating Errors. *Nature*, **323**, 533-536. <https://doi.org/10.1038/323533a0>
- [58] Xu, L., Cao, M.Y., Song, B.Y., *et al.* (2018) Open-Circuit Fault Diagnosis of Power Rectifier Using Sparse Autoencoder Based Deep Neural Network. *Neurocomputing*, **311**, 1-10. <https://doi.org/10.1016/j.neucom.2018.05.040>
- [59] 李宏坤, 郝佰田, 代月帮, 等. 基于压缩感知和加噪堆栈稀疏自编码器的铣刀磨损程度识别方法研究[J]. 机械工程学报, 2019, 55(14): 1-10.

-
- [60] 安华, 王国锋, 王喆, 等. 基于深度学习理论的刀具状态监测及剩余寿命预测方法[J]. 电子测量与仪器学报, 2019, 33(9): 64-70.
- [61] Ochoa, L.E.E., Quinde, I.B.R., Sumba, J.P.C., *et al.* (2019) New Approach Based on Autoencoders to Monitor the Tool Wear Condition in HSM. *IFAC-PapersOnLine*, **52**, 206-211. <https://doi.org/10.1016/j.ifacol.2019.09.142>
- [62] Ou, J.Y., Li, H.K., Huang, G.J., *et al.* (2020) A Novel Order Analysis and Stacked Sparse Auto-Encoder Feature Learning Method for Milling Tool Wear Condition Monitoring. *Sensors*, **20**, 2878. <https://doi.org/10.3390/s20102878>
- [63] 雷亚国, 杨彬, 杜兆钧, 吕娜. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.
- [64] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- [65] 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.
- [66] 蔡伟立, 胡小锋, 刘梦湘. 基于迁移学习的刀具剩余寿命预测方法[J]. 计算机集成制造系统, 2021, 27(6): 1541-1549.
- [67] Sun, C., Ma, M., Zhao, Z.B., *et al.* (2018) Deep Transfer Learning Based on Sparse Autoencoder for Remaining Useful Life Prediction of Tool in Manufacturing. *IEEE Transactions on Industrial Informatics*, **15**, 2416-2425. <https://doi.org/10.1109/TII.2018.2881543>
- [68] Wang, P. and Russell, M. (2020) Domain Adversarial Transfer Learning for Generalized Tool Wear Prediction. *Proceedings of the Annual Conference of the PHM Society*, **12**, 8. <https://doi.org/10.36001/phmconf.2020.v12i1.1137>