

DOI:10.19651/j.cnki.emt.2416309

基于改进 TCN 的上扣扭矩序列数据分类^{*}

邓智¹ 王正勇¹ 何小海¹ 滕奇志¹ 何海波²

(1. 四川大学电子信息学院 成都 610065; 2. 成都西图科技有限公司 成都 610024)

摘要: 在油气开发领域,油套管安装后的密封性能检测尤为重要。其中,上扣过程中产生的扭矩序列数据可以作为油套管密封性的评判依据,用来判断上扣是否合格。为了利用上扣扭矩序列数据信息进行油套管密封性的识别分类,首先基于 TCN 网络模型结构,再融入位置编码机制和自注意力机制,搭建了一种新的网络模型,即 PSE-TCN 网络。通过比较不同策略下的结果准确率,展示了模型学习的过程,通过与其他网络模型进行对比,验证了本方法的有效性。实验结果表明,PSE-TCN 相较于其他经典网络模型和一些改进后的 TCN 网络模型,扭矩序列识别精度有较大提升,在自制 UCR_whorl 数据集上,模型识别准确率达到 93.41%。

关键词: 上扣扭矩;时间序列分类;位置编码;时间卷积网络;自注意力机制;下采样

中图分类号: TN911; TE938 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Classification of make-up torque sequence data based on improved TCN

Deng Zhi¹ Wang Zhengyong¹ He Xiaohai¹ Teng Qizhi¹ He Haibo²

(1. College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China;

2. Chengdu Xitu Technology Co., Ltd., Chengdu 610024, China)

Abstract: In the field of oil and gas development, the sealing performance test of oil casing after installation is particularly important. Torque sequence data is an important basis for judging the sealing performance of the oil casing, which can be used to judge whether the buckle is qualified. In order to identify and classify the sealing performance of the oil casing by using the information of the buckled torque sequence data, a new network model was built which named PSE-TCN network based on the TCN model integrated with position encoding and self-attention mechanisms. By comparing the accuracy of results under different strategies, the learning process of the model was demonstrated. The effectiveness of this method was validated by comparing it with other network models. Experimental results show that torque sequence recognition accuracy was significantly improved by the PSE-TCN network compared with other classical network models and several improved TCN models. The recognition accuracy of this model achieved 93.41% on the self-made UCR_whorl dataset.

Keywords: make-up torque; time series classification; positional encoding; temporal convolutional network; self-attention mechanism; downsampling

0 引言

随着工业水平的发展,近年来国家对能源的需求逐渐增加,而油气作为一种关键能源在各行各业发挥着重要作用。油气开采过程中,当钻井达到预定深度之后,螺纹油套管会被逐段下入到井中进行安装。每段油套管通过螺纹接头与上一段紧密连接,进而形成一个完整的管道系统,为后续的固井工作做准备。在油套管的安装过程中,需要保证每次上扣质量合格才能够满足整体管柱的密封性能要求。

若是在油套管的安装过程中发生上扣不合格情况,则会导致井整体达不到密封性要求,进而引起油气的泄露^[1]。因此,在安装油套管的过程中对上扣质量进行检测有着十分重要的意义。

现场进行上扣作业的时候,工人会根据扭矩仪采集到的上扣扭矩曲线图形来进行上扣质量的判断。一般情况下,操作人员会根据曲线整体图形的波动情况和拐点信息来判断本次上扣是否合格^[2]。

目前针对油套管密封性能的检测,主要依赖于人工评

收稿日期:2024-06-26

^{*} 基金项目:国家自然科学基金(62071315)项目资助

判相关数据,例如上述提到的采用人工监测油套管上扣产生的曲线图来判断上扣是否合格,进而判断是否发生泄露。然而,现场实际应用经验表明,这类人工检测方法效率低下,需要 24 h 现场值守,而且容易受到主观因素影响,无法有效保障油气开采的安全性。为了解决这一问题,本文从上扣过程中扭矩序列的数据特征出发,利用计算机识别扭矩序列并作出判断来替代传统的人工检测方法,从而提高油气开采的效率和可靠性。

随着大数据和人工智能的飞速发展,各个产业都在发生深刻的变革。在工程应用领域,已有学者基于深度学习和机器学习,在实际工程应用中进行故障检测和识别判断。古洪亮等^[3]利用卷积神经网络对螺栓连接曲线的异常数据进行判别,田润芝^[4]通过 BP 神经网络预测了油套管的整体腐蚀速率,卢浩龙等^[5]利用傅里叶变换和卷积神经网络,进行工业过程故障检测,解决了检测灵敏度低的问题,并提高了检测效率。Walas 等^[6]基于机器人脚踝上的扭矩信息,使用 SVM 算法来识别机器人所处的地形类型,Popov 等^[7]利用前馈神经网络,将外关节扭矩值分类,用以进行碰撞定位及分类,Moder 等^[8]基于采集的扭矩数据信息,利用机器学习模型,分析预测流体动压径向轴承的润滑状态。因此,基于机器学习和深度学习理论,建立起一套上扣扭矩数据的识别分类方法有着潜在的应用价值与意义。

现阶段,油套管上扣扭矩序列数据的智能化分类技术研究较少。目前,已有学者针对气密封螺纹上扣扭矩曲线图像的智能识别分类开展了研究,例如李文哲等^[9]基于扭矩曲线的图像信息,利用深度神经网络,对现场采集到的扭矩曲线进行识别分类,且准确率已经达到了 92.87%。该方法是从图像分类的角度出发,利用现场采集的上扣扭矩曲线图像数据进行模型的训练和测试。然而,基于上扣扭矩序列数据的识别分类工作还需要进一步探究验证。因此,针对上扣扭矩序列数据特征的识别分类问题,本文搭建了名为 PSE-TCN 的上扣扭矩序列分类网络模型,该模型能够对现场产生的扭矩序列特征进行识别分类,进而判断是否发生泄漏,有望提高现场工作效率,并进行高效指导和优化二次上扣。

1 整体网络结构

在处理序列数据分析中,循环神经网络(recurrent neural network, RNN)^[10]有着比较好的表现,但是由于 RNN 在处理序列数据中存在一个严重的缺陷:网络一次只能处理一个步长,后一步的运算需要等到前一步处理完成才可以继续进行相应运算,因此训练时间偏长,且内存消耗也比较大。以 RNN 的改进网络长短期记忆网络(long short-term memory, LSTM)^[11]为例,虽然这个网络中加入了遗忘门、输入门和输出门等结构,能够更好地捕捉前后元素之间的依赖关系,但是这种结构会导致计算复杂度变高。针对这种情况,使用卷积神经网络并行处理任务,可以提高整体

的网络性能。时间卷积网络(temporal convolutional network, TCN)^[12]模型是基于全卷积神经网络(fully convolutional network, FCN)^[13]基础卷积模型进行设计的。本文选择 TCN 作为基础网络进行改进和调整,主要是因为从现场采集的上扣扭矩数据是时间序列数据,具有强烈的时间相关性和顺序依赖性。TCN 能够有效捕捉长时间依赖关系,适合处理长时间跨度的扭矩序列数据。而且,与 RNN 相比,TCN 不仅支持并行计算,极大提高了计算效率,同时还避免了梯度消失与爆炸的问题,确保了训练过程的稳定性和可靠性。

TCN 作为一个常用的序列分类网络,常被研究人员进行不同程度的改进后应用于各类领域中。李响^[14]提出了一种 TCN-BiGRU 网络模型,通过输入的扭矩等信息来预测涨圈型密封环的寿命,该模型主要是在 TCN 网络的基础上,加入双向门控循环单元提升模型的特征提取能力。这个改进方法虽然在处理多模态输入时能提升网络整体性能,但也因此会增加系统的复杂度,需要更多的计算资源。曹渝昆等^[15]提出了一种轻量级的时间卷积神经网络 L-TCN,采用深度可分离卷积来替代 TCN 中的普通卷积,从而在保证预测精度的同时减少网络模型的参数量和计算量。这种改进方法虽然减少了参数量和计算复杂度,但是在处理较复杂的序列信息时模型性能会有所下降。

所以,为了迅速处理时间相关性较强的上扣扭矩序列数据,就需要在参数量增加较少的情况下,同时能够保证模型快速捕捉到前后数据特征的顺序性和关联性。因此,本文围绕 TCN 基础网络结构做出改进和调整,构建了名为 PSE-TCN 的网络模型,整体结构如图 1 所示。在这个网络结构中,序列数据首先通过位置编码层帮助模型理解序列中的元素顺序,然后通过改进后的 TCN 结构层进行序列数据的特征提取,之后通过自注意力层使模型能够根据元素间的关系,动态地分配重要性权重,最终将提取信息输入到全连接层中进一步完成分类任务。

1.1 TCN 模型结构

1) 扩张因果卷积

TCN 模型的基本结构和 FCN 类似,输入层与隐藏层的长度相同,并且在处理的过程中会采用零填充的方法,让后继层的长度与先前层保持一致;模型中的每层卷积结构都包含了一个因果卷积^[16],该结构保证了前一时刻的输出不受后一时刻输入的影响,使得整体网络是一个从前往后的链接,这样就能让模型处理时间序列任务时满足前后依赖的逻辑顺序。同时,为了让因果卷积覆盖更多的历史信息,在保证整体网络模型深度不变的情况下仍然有较大感受野,就需要对输出前的每一层引入扩张卷积^[17]。类似于在卷积核的计算过程中加入步长间隔,为了让每个卷积层包含更广范围的信息,通过在卷积过程中加入序列间隔,从而覆盖更长的时间序列范围,进而增强整体网络模型的特征提取能力。扩张因果卷积的结构如图 2 所示,该结构包

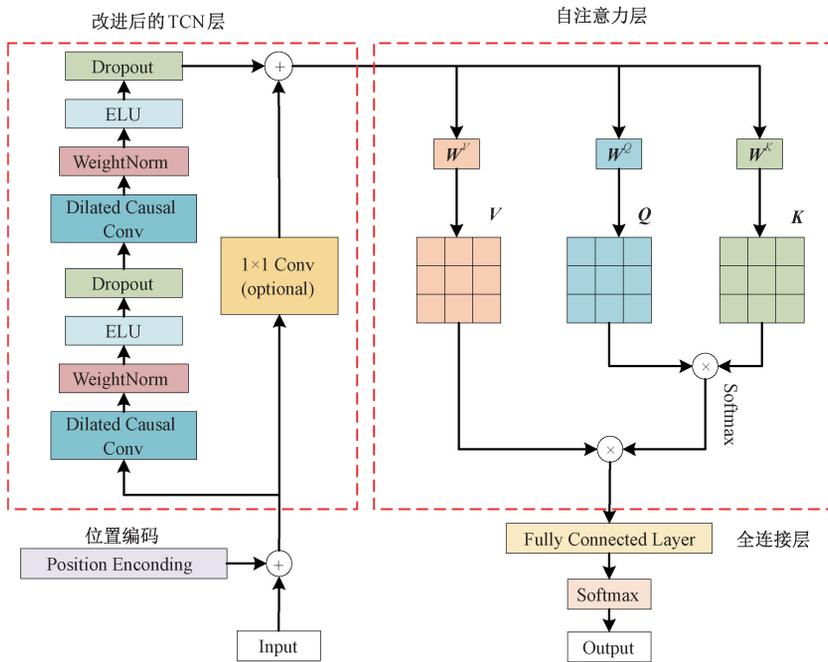


图 1 PSE-TCN 网络结构
Fig. 1 PSE-TCN network structure

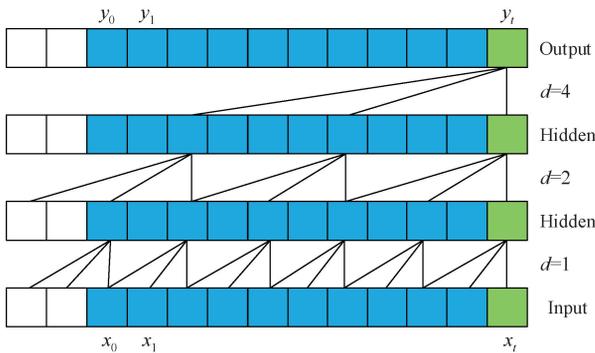


图 2 扩张因果卷积结构
Fig. 2 Dilated causal convolutional structure

含了一个输入层,一个输出层和两个隐藏层, x_0 到 x_t 代表了序列元素的输入, y_0 到 y_t 代表了最终的输出,其中参数 d 代表了膨胀因子。

2) 残差连接

一般而言,网络的深度越高,最终训练完成后的模型精度也会越高。但如果不加限制地持续增加网络深度,则会在训练时出现梯度消失或者梯度爆炸的状况,最终导致模型性能退化。为了解决梯度消失和爆炸的问题,Hayou 等^[18]在 ResNet 网络中提出了残差连接^[19]这一策略。

因此,相较于普通的神经网络,TCN 网络中引用了残差连接,进一步提升整体网络模型性,改进后的 TCN 残差连接结构如图 3 所示。为了获得更好的分类结果,在一个残差连接中堆叠两层扩张因果卷积层,同时将原始的 ReLU 激活函数进行了修改,采用效果更好的 ELU 函数。

在图 3 中,Dilated Causal Conv 表示扩张因果卷积层,Weight Norm 表示权值维度上的归一化,ELU 表示代表激活函数,Dropout 表示神经网络的正则化; 1×1 Conv 表示 1×1 的卷积核,通过这步处理,直接将输入跳跃连接至后续层的输出,通过加法操作直接将输入信息传递至后续层。

1.2 位置编码

在时间序列任务的处理过程中,TCN 网络模型拥有局部连接的特性,即卷积操作的过程中每一层只关注到输入的一个局部区域。虽然这种特性能够有效地捕捉到局部时间序列数据中的模式和变化,如短期的趋势或者周期性波动,但是整体网络对于全局信息的捕捉能力依然有待加强。对于上扣扭矩序列数据,除了关键的节点能反映重要信息,整体的序列数据也包含了一定的关联性和逻辑性。在上扣扭矩序列数据中,某些异常信息只能在全局视角下才能够有效识别出来。例如,一个孤立的异常扭矩值可能不符合当前段的变化趋势,如果不考虑整个序列的前后情况,则很有可能判断成为异常波动。但是全局视角下可以帮助识别这些异常信息,并提高整体的检测准确率。因此,分析全局序列信息,理解每个节点的前后关系,能更加准确地识别异常和趋势变化,进而构建更加可靠的网络模型。

为了能够将序列的整体顺序信息利用起来,需要在输入中添加位置编码来让整体网络结构注意到序列的位置信息。利用位置编码,模型能够区分不同位置的输入,并将这些位置信息融入到模型的表示中,从而更好地捕捉到

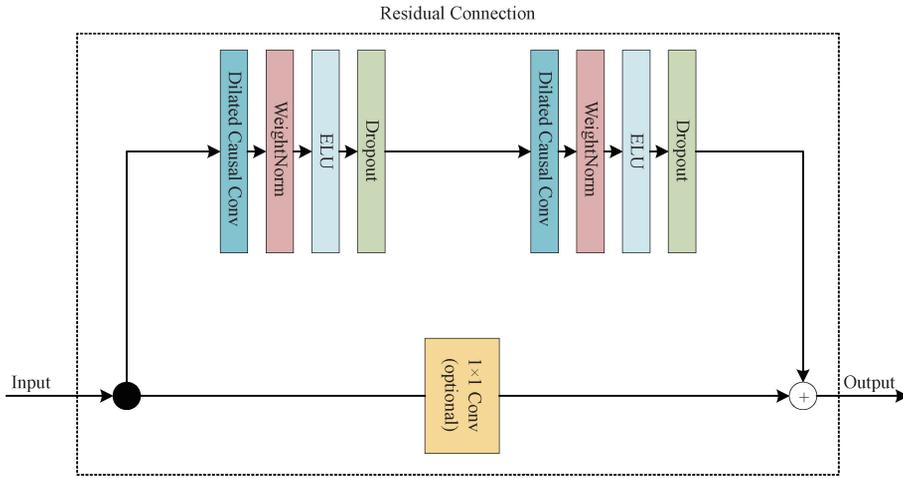


图 3 改进后的 TCN 残差连接结构

Fig. 3 The improved residual connection structure of TCN

序列数据中的结构和模式^[20]。

位置编码的形式通常是一个正弦函数和一个余弦函数组成,具体公式如下:

$$PE(pos, 2i) = \sin(pos/10\ 000^{2i/d_{model}}) \quad (1)$$

$$PE(pos, 2i+1) = \cos(pos/10\ 000^{2i/d_{model}}) \quad (2)$$

其中, $PE_{(pos, 2i+1)}$ 表示的是位置编码矩阵中第 pos 个位置,第 $2i$ 个维度的值, d_{model} 是整个模型的维度。从上式可以看出,位置编码由不同维度的正弦波组成。利用上面的公式,序列中每个行向量均可生成 d_{model} 维的位置向量。

根据三角函数的公式:

$$\sin(\alpha + \beta) = \sin\alpha \cos\beta + \cos\alpha \sin\beta \quad (3)$$

$$\cos(\alpha + \beta) = \cos\alpha \cos\beta - \sin\alpha \sin\beta \quad (4)$$

可以将 $PE_{(pos+k, 2i)}$ 与 $PE_{(pos+k, 2i+1)}$ 由 $PE_{(pos, 2i)}$, $PE_{(pos, 2i+1)}$, $PE_{(k, 2i)}$ 以及 $PE_{(k, 2i+1)}$ 表示出来:

$$PE(pos+k, 2i) = PE(pos, 2i) \times PE(k, 2i+1) + PE(pos, 2i+1) \times PE(k, 2i) \quad (5)$$

$$PE(pos+k, 2i+1) = PE(pos, 2i+1) \times PE(k, 2i+1) - PE(pos, 2i) \times PE(k, 2i) \quad (6)$$

由上式可知,第 $pos+k$ 个位置序列的位置编码可以通过第 pos 个位置的编码和第 k 个位置的编码表示,因此位置编码可以反映序列整体相对位置之间的信息^[21]。扭矩序列的实际生成过程中,前后之间的扭矩数据存在一定的关联,因此在训练过程中加入这些位置信息能够让模型更好地注意到前后序列之间的相关性。在特征提取的过程中,采用正弦函数与余弦函数相结合的位置编码组合,为每个序列位置生成一个独特的向量,并将其添加到输入数据的嵌入向量中,从而为模型提供位置信息。

1.3 自注意力机制

本文所采用的自注意力机制^[22],是在处理序列任务时常用到的一种机制,它能够让模型注意到每个元素和其他元素之间的关系性,充分计算序列数据中的每个元素和其

他元素之间的关联程度,从而提高整体网络的学习能力。就本文提取到的扭矩数据而言,由于每次上扣时扭矩值会按照一定的规律变化,所以采集到的每个扭矩数据前后之间存在一定的关联性。因此,通过引入自注意力机制将扭矩序列中不同位置的元素信息联系起来,发现扭矩序列数据中的内部特性及相关性,能够增强整体网络模型对扭矩序列信息中的关键点特征信息的捕获能力。

假设输入的序列 x_i 中包含了多个元素,每个元素的维度为 d ,则对于每个输入 x_i ,可以利用线性变换获得其对应的查询向量 Q_i 、键向量 K_i 和值向量 V_i :

$$Q_i = X_i W^Q \quad (7)$$

$$K_i = X_i W^K \quad (8)$$

$$V_i = X_i W^V \quad (9)$$

其中, W^Q 、 W^K 、 W^V 是针对查询向量、键向量以及值向量的权重矩阵,用来将输入的向量映射至 Query、Key 和 Value 空间中。而计算查询向量和键向量之间的相似度关系,最常用的方法就是点积注意力:

$$Attention(Q_i, K_j) = \frac{Q_i K_j^T}{\sqrt{d_k}} \quad (10)$$

式中: d_k 表示的是键向量的维度(通常情况下与查询向量维度相同),点积之后除以 $\sqrt{d_k}$ 是为了缩放点积运算的结果,使模型的训练更加稳定。点积得到的结果后续需要通过 $softmax$ 函数得到注意力权重 A_{ij} :

$$A_{ij} = softmax(Attention(Q_i, K_j)) \quad (11)$$

式中: A_{ij} 表示的是第 i 个位置对第 j 个位置的注意力权重,这些权重需要用来和对应的值向量相乘进行加权求和,转变为输出表示 O_i :

$$O_i = \sum_{j=1}^N A_{ij} V_j \quad (12)$$

式中: O_i 是第 i 个位置的输出表示。在整个过程中, W^Q 、 W^K 、 W^V 作为参数,用来将对应的输入向量变换到对应的

Query 空间、Key 空间和 Value 空间。处理数据时,通过计算查询向量和所有键向量的点积来获得相似性得分,表示当前元素与其他元素的相关性,然后用 *softmax* 函数进行注意力的权重计算,最后用这些权重对所有值向量进行加权平均,生成当前元素的新的表示,这种表示方法包含了输入序列中的所有元素的位置信息,不同位置的贡献由注意力权重决定。

2 数据集及预处理

2.1 数据预处理

为了进一步简化训练过程,本文实验过程中将采集得到的数据集进行了数据预处理工作,即对采集到的扭矩序列数据通过最大三角形三桶(largest triangle three buckets, LTTB)算法^[23]进行下采样处理。

LTTB 算法通常用于数据的降采样。在数据的可视化领域,有时候需要将收集到的大量数据点进行下采样操作,以便在有限的空间内展示出数据的整体特征状况。这种算法在保留整体数据特征的同时还能够减少数据数量,实现高效的数据降采样。

其算法原理是先将整体的数据按照 x 轴分成若干个子集,每个子集中包含了一些数据点。然后对于每个划分好的子集,需要计算数据点的 y 轴最大值和最小值从而确定出整体的主要趋势。为了保留数据的重要特征,需要从这些划分好的子集中提取重要的数据点,其选择的依据是:将每个子集中的 y 轴数据点添加到结果集中,同时为了保证数据的完整性,需要保留原始数据的第一个数据点和最后一个数据点,最后根据结果集中的数据点进行 x 轴坐标的重新排序,并进行绘制相应的趋势图。

整体算法原理如图 4 所示,首先需要将所有数据点划分为大致相同的子集,其中,第一个和最后一个子集只包含原始数据的第一个和最后一个数据点。该算法的原理是一次处理 3 个子集,按照从左到右的顺序。构成三角形的左侧点(在第 1 子集内,如图 4 的点 A 所示)始终固定为先前选中的点,构成三角形的右侧点(在第 3 个子集内,如图 4 的点 C 所示)为该子集内所有点的平均值。关于中间点,可以通过计算筛选出第 2 个子集中,与之前的两个固定点形成最大三角形的点,该点便是第 2 个子集中的代表点(在第 2 个子集内,如图 4 的点 B 所示),并且之后会被作为下一个三角形的左侧点纳入后续计算中。

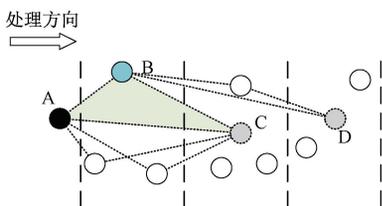


图 4 LTTB 算法示意图

Fig. 4 Illustration of the LTTB algorithm

2.2 预处理结果

为了减少整体模型的计算量,需要将整体的数据进行一次下采样操作。在下采样之前,每组序列数据有 2 000~2 500 个元素,本次处理将每条序列数据的元素个数都降低到 200 个。LTTB 算法下采样之后的效果如图 5 所示,从图中可以看出数据经过下采样之后的曲线图和原图几乎保持一致,没有造成拐点等重要信息的缺失。因此,将所有的输入数据进行下采样后构建成数据集,有助于模型减少训练时间,提高训练效率。

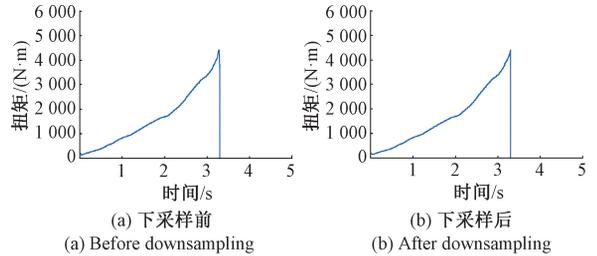


图 5 LTTB 算法效果展示

Fig. 5 Demonstration of the effect of the LTTB algorithm

2.3 数据集的制作

本文数据由相关油气田研究院提供,在上扣过程中,扭矩仪会实时采集并且保存相关扭矩数值,这些数据为本次实验的原始数据。将这些数据经过下采样处理之后,就构成了实验用的数据集数据。

为了将这些序列数据分类,需要将数据集中的扭矩数据绘制成图像进行分析。扭矩时间序列数据转化为曲线图像后的 3 类图像如图 6 所示,其中横坐标代表上扣时间,纵坐标的值代表螺纹扭矩序列中的扭矩值。

基于图 6 展示的扭矩序列图像,可以将数据集中的扭矩序列数据划分为 3 类:合格序列、波动序列和无拐点序列。根据现场实际上扣情况分析,合格序列反映了上扣到位合格;波动序列和无拐点序列则表示上扣不合格,需要重新上扣。部分上扣扭矩序列数据及标注如表 1 所示,经过下采样,每组数据均由 200 个数据组成。由于每次上扣完成之后,扭矩值会骤降到 0,因此每组数据的最后一个元素均为“0”;表中最后一列是每组数据的类别标注,在这一列中,“0”代表序列数据合格,“1”代表序列数据无拐点,“2”代表序列数据波动。

为了进一步依据这些数据特征对数据集进行保存和管理,本文基于 UCR 时间序列档案数据模式^[24],通过对下采样后的数据集进行标注工作,制作了包含上扣扭矩序列的 UCR_whorl 时间序列数据集。

当前数据集中共有 5 675 组上扣扭矩序列数据,并分为训练集、验证集和测试集。其中,训练集有 4 125 组数据,用于网络模型的训练;验证集有 675 组数据,用于监测训练过程并评估训练效果;测试集有 875 组数据,用于测试训练完成后的模型性能。

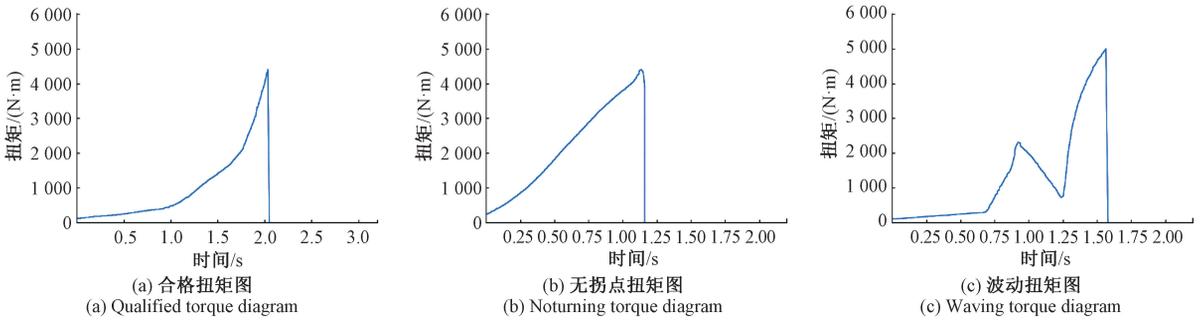


图 6 扭矩序列数据绘制的图像

Fig. 6 Graph plotted from torque sequence data

表 1 数据集表格及标注
Table 1 Dataset tables and labels

组别	1	2	3	...	199	200	标注类别
第 1 组	164.66	164.66	182.35	...	1 432.88	0	0
第 2 组	147.33	164.66	199.34	...	5 384.88	0	1
第 3 组	186.46	251.69	268.66	...	1 588.89	0	0
⋮				⋮			⋮
第 n 组	159.36	159.36	251.33	...	4 778.22	0	2

3 实验结果与分析

3.1 实验配置条件

本文网络训练工作是在装有 Linux 系统的服务器上完成的,CPU 采用的是 12th Gen Intel(R) Core(TM) i5-12400,GPU 采用的是 NVIDIA GeForce RTX 2080 Ti,整体网络模型利用 PyTorch 深度学习框架实现的。

3.2 训练细节

本文网络模型在训练时使用的损失函数是交叉熵损失函数^[25],优化器为 Adam,初始的学习率为 0.001,批次大小设置为 64,所有模型都训练 100 轮,并且每 10 轮进行依次验证并保存模型权重。

损失函数的设置是为了优化 PSE-TCN 网络的训练过程,以最小化训练损失,交叉熵损失函数是一种用于回归分类问题的损失函数,从本质上讲,是用于平衡概率分布之间的相似程度。一般来说,交叉熵损失函数的结果越小,表明模型预测的概率分布与真实标签的概率分布越接近。对于图像分类任务,假设有 n 个样本和 m 个类别,则单个样本的损失计算如下:

$$L_i = - \sum_{j=1}^m y_{ij} \log(p_{ij}) \quad (13)$$

式中: y_{ij} 是第 i 个样本的真实标签,而 p_{ij} 则是模型预测的第 i 个样本属于第 j 类的概率。对所有样本的损失求平均得到总损失:

$$L = - \frac{1}{n} \sum_{i=1}^n L_i \quad (14)$$

交叉熵损失函数本身是一种连续可导的函数,这种性

质让它非常适合在梯度下降的优化算法中使用,用于参数的更新。

3.3 实验数据分析

为了检测本文搭建的网络模型性能,在自制的 UCR_whorl 数据集上进行了多次重复对比试验。结果如表 2 所示,随着不同改进策略的引进,整体模型的准确率在逐步提升。本文主要策略为将原始的激活函数进行更改,然后在编码机制上引入了位置编码,并且采用了自注意力机制。表 2 中,参数量代表网络模型的可学习参数总数,准确率(Accuracy)用来评判网络模型分类的准确性,具体公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

式中: TP 表示预测结果为正样本且实际结果为正样本的个数; TN 表示预测结果为负样本且实际结果为负样本的个数; FP 表示预测结果为正样本而实际结果为负样本的个数; FN 表示预测结果为负样本而实际结果为正样本的个数。

表 2 改进策略对比

网络模型	准确率/%	参数量/K
TCN	86.04	297
TCN+ELU	88.83	297
TCN+ELU+位置编码	91.02	312
TCN+ELU+位置编码+自注意力机制(本文模型)	93.41	363

根据表 2 的结果可以看出,整体网络模型的预测准确率随着优化策略的改进不断提升,最终的测试准确率达到 93.41%,相比于原始的 TCN 网络模型,整体提升了 7.37%,模型性能得到较大的提升。

另外本文将实验结果与其他经典的网络模型进行对比,如 NVAE^[26]和 GRU^[27],同时还与近年来改进的 TCN 网络模型 TCN-LSTM^[28]和 SENet-TCN^[29]模型对比。依旧采用参数数量和准确率作为比较标准,最终的实验结果整理后如表 3 所示。从表 3 可以看出,本文提出的 PSE-TCN 网络的实验结果准确率比其他网络模型更高,拥有更好的分类性能。

表 3 与其他网络模型的精度、参数量对比

Table 3 Comparison of accuracy and parameter count with other network models

网络模型	准确率/%	参数量/K
TCN-BiGRU	87.53	594
L-TCN	84.27	172
NVAE	85.98	80
GRU	87.24	150
TCN	86.04	297
TCN-LSTM	88.22	495
SENet-TCN	90.67	308
PSE-TCN(本文模型)	93.41	363

4 结 论

本文详细介绍了一种用于自动识别和分类螺纹上扣扭矩序列的方法。该方法采用了一种基于 TCN 神经网络模型改进的时间序列分类模型,命名为 PSE-TCN。这个模型的设计使其能够有效应对复杂的背景干扰以及多样的上扣扭矩时间序列数据,实现自动识别分类任务的高效处理。

通过一系列对比实验,将结果数据进行分析,可以看出本文提出的 PSE-TCN 方法在扭矩序列的分类任务中表现出更高的准确性,超过了一些经典的分类模型和其他基于 TCN 改进的网络模型。与基于图像信息的 NAFENet 分类网络相比,PSE-TCN 模型不仅具备更高的识别分类性能,还展现出更广泛的应用潜力。

参考文献

- [1] 付雅谥,周建英.油气储运设施安全的重要性探讨[J]. 化工管理,2020(7):129-130.
FU Y M, ZHOU J Y. Discussion on the importance of safety in oil and gas storage and transportation facilities [J]. Chemical Industry Management, 2020(7): 129-130.
- [2] 罗蒙,郭红军.台肩式金属密封特殊扣油套管上扣曲线分析与判定[J]. 宝钢技术,2023(3):12-17.

- LUO M, GUO H J. Analysis and determination of makeup torque curves for shoulder-type metal sealed premium threaded oil casings [J]. Baosteel Technology, 2023(3): 12-17.
- [3] 古洪亮,丁建明.基于卷积神经网络的拧紧曲线异形识别方法研究[J]. 机械,2023,50(7):19-24,80.
GU H L, DING J M. Research on anomaly detection in tightening curves based on convolutional neural networks[J]. Machinery, 2023, 50(7): 19-24,80.
- [4] 田润芝.基于人工智能的油套管腐蚀预测研究与失效分析[D]. 西安:西安石油大学,2022.
TIAN R ZH. Research on corrosion prediction and failure analysis of oil casings based on artificial intelligence[D]. Xi'an: Xi'an Shiyou University, 2022.
- [5] 卢浩龙,朱彦敏.基于多尺度图 Transformer 的滚动轴承故障诊断[J]. 国外电子测量技术,2023,42(12): 186-194.
LU H L, ZHU Y M. Rolling bearing fault diagnosis based on multi-scale graph transformer[J]. Foreign Electronic Measurement Technology, 2023, 42(12): 186-194.
- [6] WALAS K, KANOULAS D, KRYCZKA P. Terrain classification and locomotion parameters adaptation for humanoid robots using force/torque sensing[C]. 2016 IEEE-RAS 16th International Conference on Humanoid Robots (Humanoids). IEEE, 2016: 133-140.
- [7] POPOV D, KLIMCHIK A, MAVRIDIS N. Collision detection, localization & classification for industrial robots with joint torque sensors[C]. 2017 26th IEEE International Symposium on Robot and Human Interactive Communication(RO-MAN). IEEE, 2017: 838-843.
- [8] MODER J, BERGMANN P, GRÜN F. Lubrication regime classification of hydrodynamic journal bearings by machine learning using torque data[J]. Lubricants, 2018, 6(4): 108.
- [9] 李文哲,马梓瀚,罗伟,等. NAFENet: 基于全局注意力特征融合的螺纹扭矩曲线分类网络[J]. 计算机系统应用,2023,32(12):136-142.
LI W ZH, MA Z H, LUO W, et al. NAFENet: A thread torque curve classification network based on global attention feature fusion[J]. Computer Systems Applications, 2023, 32(12): 136-142.
- [10] SHAN D J, LUO Y, ZHANG X W, et al. DRRNets: Dynamic recurrent routing via low-rank regularization in recurrent neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 34(4): 2057-2067.
- [11] 马振东,范锦彪,王燕,等.基于 LSTM 的勘察器外壁温度反演方法研究[J]. 电子测量技术,2024,47(4): 181-187.

- MA ZH D, FAN J B, WANG Y, et al. Research on inversion method for surveyor outer wall temperature based on LSTM [J]. *Electronic Measurement Technology*, 2024, 47(4): 181-187.
- [12] FAN J, ZHANG K, HUANG Y P, et al. Parallel spatio-temporal attention-based TCN for multivariate time series prediction [J]. *Neural Computing and Applications*, 2023, 35(18): 1-10.
- [13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [14] 李响. 车辆传动系统密封环寿命预测与分析[D]. 镇江: 江苏大学, 2022.
LI X. Life prediction and analysis of sealing rings in vehicle transmission systems[D]. Zhenjiang: Jiangsu University, 2022.
- [15] 曹淦昆, 桂丽媛. 基于深度可分离卷积的轻量级时间卷积网络设计 [J]. *计算机工程*, 2020, 46(9): 95-100, 109.
CAO Y K, GUI L Y. Design of a lightweight temporal convolutional network based on depthwise separable convolutions [J]. *Computer Engineering*, 2020, 46(9): 95-100, 109.
- [16] HAMAD A R, KIMURA M, YANG L ZH, et al. Dilated causal convolution with multi-head self attention for sensor human activity recognition [J]. *Neural Computing and Applications*, 2021, 33(20): 1-18.
- [17] 叶乡凤, 董张玉, 杨学志. 基于扩张图卷积网络的 SAR 图像分类 [J]. *智能计算机与应用*, 2022, 12(7): 69-73, 79.
YE X F, DONG ZH Y, YANG X ZH. SAR image classification based on dilated graph convolutional networks [J]. *Intelligent Computers and Applications*, 2022, 12(7): 69-73, 79.
- [18] HAYOU S, CLERICO E, HE B, et al. Stable resnet[C]. *International Conference on Artificial Intelligence and Statistics*. PMLR, 2021: 1324-1332.
- [19] MUBASHAR M, ALI H, GRÖNLUND C, et al. R2U ++: A multiscale recurrent residual U-Net with dense skip connections for medical image segmentation [J]. *Neural Computing and Applications*, 2022, 34(20): 17723-17739.
- [20] LIUTKUS A, CIFKA O, WU S L, et al. Relative positional encoding for transformers with linear complexity[C]. *International Conference on Machine Learning*. PMLR, 2021: 7067-7079.
- [21] LEI D, HONGDONG W, JIANKUN L. An attention mechanism model based on positional encoding for the prediction of ship maneuvering motion in real sea state [J]. *Journal of Marine Science and Technology*, 2024, 29(1): 136-152.
- [22] GUO M H, LIU ZH N, MU T J, et al. Beyond self-attention: External attention using two linear layers for visual tasks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(5): 5436-5447.
- [23] STEINARSSON S. Downsampling time series for visual representation [D]. Reykjavik: University of Iceland, 2013.
- [24] DAU A H, BAGNALL A, KAMGAR K, et al. The UCR time series archive [J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 6(6): 1293-1305.
- [25] 金玉, 袁和金. 基于改进 FCN 双路径特征融合的局部放电图谱识别 [J]. *电子测量技术*, 2022, 45(24): 132-136.
JIN Y, YUAN H J. Partial discharge spectrum recognition based on improved fcnn with dual-path feature fusion [J]. *Electronic Measurement Technology*, 2022, 45(24): 132-136.
- [26] CUI J N, XIE Y T, JOSHI A A, et al. PET denoising and uncertainty estimation based on NVAE model using quantile regression loss [C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer Nature Switzerland, 2022: 173-183.
- [27] LIU Y W, SONG Z L, XU X L, et al. Bidirectional GRU networks-based next POI category prediction for healthcare [J]. *International Journal of Intelligent Systems*, 2022, 37(7): 4020-4040.
- [28] HUO F C, CHEN Y, REN W J, et al. Prediction of reservoir key parameters in 'sweet spot' on the basis of particle swarm optimization to TCN-LSTM network [J]. *Journal of Petroleum Science and Engineering*, 2022, 214: 110544.
- [29] WANG Y, DING H, SUN X CH. Residual life prediction of bearings based on SENet-TCN and transfer learning [J]. *IEEE Access*, 2022, 10: 123007-123019.

作者简介

邓智, 硕士研究生, 主要方向为模式识别与计算机视觉。

E-mail: dz18867151833@163.com

王正勇, 副教授, 硕士生导师, 主要研究方向为图像处理与模式识别、计算机视觉、智能系统。

E-mail: 690728634@sina.com

何小海(通信作者), 教授, 博士生导师, 主要研究方向为图像处理, 模式识别, 计算机视觉, 图像通信和软件工程等。

E-mail: hxx@scu.edu.cn

滕奇志, 教授, 博士生导师, 主要研究方向为图像处理, 图像传输, 模式识别和软件工程。

E-mail: qzteng@scu.edu.cn

何海波, 高级工程师, 主要研究方向为图像处理、计算机应用。

E-mail: 351813868@qq.com