

基于格拉姆角场与并行KConvNeXt的采样系统异常压力检测

张祺¹, 肖伸平², 聂立波¹, 彭远刚³, 宋永波³

1. 湖南工业大学生命科学与化学学院, 湖南 株洲 412007; 2. 湖南工业大学电气与信息工程学院, 湖南 株洲 412007; 3. 深圳市亚辉龙生物科技股份有限公司, 广东 深圳 518116

【摘要】为提高全自动生化分析仪的测试精度与检测效率,提出一种基于格拉姆角场(GAF)与并行KConvNeXt网络的检测模型,以准确判定采样系统在采样过程中由样本针堵塞所产生的异常情况。首先运用GAF方法,将一维采样压力信号的时间序列转化为二维图像。随后,采用改进的注意力机制结合并行双通道KConvNeXt网络对压力信号进行分类,最终实现94.58%的分类准确率。实验结果表明,提出的方法能有效捕捉采样压力信号的关键特征,为生化分析仪采样系统异常压力检测提供一种高效的解决方案,具有重要的实际应用价值。

【关键词】采样系统;异常检测;格拉姆角场;ConvNeXt网络

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2025)09-1184-07

Anomalous pressure detection in sampling systems based on Gramian angular field and parallel KConvNeXt

ZHANG Qi¹, XIAO Shenping², NIE Libo¹, PENG Yuangang³, SONG Yongbo³

1. School of Life Science and Chemistry, Hunan University of Technology, Zhuzhou 412007, China; 2. School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China; 3. Shenzhen YHLO Biotech Co., Ltd., Shenzhen 518116, China

Abstract: A detection model based on Gramian angular field (GAF) and parallel KConvNeXt network is proposed for accurately detecting the abnormal conditions caused by sample needle blockage in the sampling system during the sampling, thus improving the testing accuracy and detection efficiency of automated biochemical analyzers. GAF-based method is employed to transform the time series of one-dimensional pressure signals into two-dimensional image representations. Subsequently, an improved attention mechanism integrated with a parallel dual-channel KConvNeXt network is used to classify the pressure signals, and achieves a final classification accuracy of 94.58%. The experimental results show that the proposed method can effectively capture the key characteristics of the pressure signals, offering an efficient solution for the anomalous pressure detection in biochemical analyzer sampling system and exhibiting important practical significance.

Keywords: sampling system; anomaly detection; Gramian angular field; ConvNeXt network

前言

全自动生化分析仪能够快速、准确地为医生和生化检验人员提供检验数据,在临床诊断和生物化学检验的高效运行中发挥重要作用^[1]。然而,未经适当处理的正常血液样本以及来自血液系统疾病患者的样本中可能存在纤维蛋白或血凝块,会导致采样

系统中取样针的堵塞,进而延长检测周期,并直接影响检测结果的准确性^[2-3]。因此,利用采样系统中吸样压力信号快速、准确识别血液样本中的血凝块和纤维蛋白,及时发出警报并采取相应的干预措施,对于提升全自动生化分析仪的智能化水平具有重要意义。长期以来,日立等国际品牌使用马田系统对全自动生化分析仪的采样系统进行吸样压力信号的异常识别与检测^[4]。该系统是一种基于阈值距离的分类方法,可以根据样本阈值之间的相似性进行分类。但是,该方法对阈值的设定非常敏感,并且处理非线性数据能力有限,这些特性使得算法的泛化能力受到限制^[5-6]。随着深度学习技术在计算机视觉领域的

【收稿日期】2025-02-19

【基金项目】国家重点研发计划(2019YFE0122600)

【作者简介】张祺,硕士研究生,研究方向:医学信号人工智能,E-mail: 337100797@qq.com

快速发展,其强大的特征提取能力逐步渗透至医疗与工业领域,产生许多面向时间序列异常检测与分类任务的新方法^[7-8]。在工业领域方面,Pota等^[9]构建了基于LSTM的变分自编码器框架,有效解决工业炉时间序列的实时异常检测;Tran等^[10]则利用一维卷积神经网络分类器,提升工业物联网系统的异常识别能力;Carletti等^[11]采用基于贝叶斯神经网络对冰箱制造中的时间序列数据异常进行检测。在医疗领域,袁成成等^[12]利用残差网络结合自注意力机制,实现心律失常信号的精准分类;张乙鹏等^[13]则使用CNN-LSTM混合模型,开发出了对正常和5种类型的不定音进行分类的肺音分类算法。尽管这些方法在各自领域取得显著成效,但都是利用一维时序信号的输入进行模型的建立,导致模型难以充分提取信号的时频特征,使其在面对复杂环境或噪声干扰时容易出现特征提取不充分等问题,进而模型在复杂场景下会出现性能瓶颈问题。

针对上述瓶颈,格拉姆角场(GAF)可以通过极坐标映射与三角运算,将一维时序信号无损编码为二维图像矩阵[格拉姆角和场(GASF)/格拉姆角差场(GADF)],这对于一维时序信号的时频特征增强带来了理论层面的突破性成果。研究结果表明,在生物医学和工业检测等领域中,GAF的时频联合特征表征能力普遍优于传统的时频变换方法^[14-18]。此外,GAF生成的类图像结构与卷积神经网络的局部感知特性高度契合。ConvNeXt网络通过层级感受野的扩展和通道注意力机制的引入,为GAF图像的特征挖掘提供一个理想的架构。Lin等^[19]通过将一维的恒流充电曲线转换成GADF图像,再结合ConvNeXt网络来对退役电池进行筛选,提高分类准确性。Wang等^[20]采用GASF把分布式光纤传感系统的一维时间信号转化为二维图像,再利用卷积神经网络模型ConvNeXt,对多种不同的扰动事件进行快速分类识别。Li等^[21]将5种土豆品种的一维光谱数据转化为二维图像,并利用ConvNeXt模型实现高效的分类。ConvNeXt网络依靠深度可分离卷积与分层结构,得以精准捕捉多尺度特征,特别适合处理GAF这类需兼顾效率与精度的图像分析任务。

本研究提出一种基于GAF与并行ConvNeXt结合的模型,模型首先将一维压力信号通过GAF转换为二维图像,之后利用并行的ConvNeXt网络分别从GASF和GADF两种图像中提取信号特征,并结合改进的卷积块注意力模块(Convolutional Block Attention Module, CBAM)对特征进行深度挖掘与学习。最后将以上两种图像的特征进行融合,从而提升对压力信号的分类能力。该方法有效提高全自动

生化分析仪压力信号的分类准确率,为检测结果的可靠性提供有力保障。

1 资料与方法

1.1 实验数据集

根据文献^[22]的研究数据,在37℃时测量得到的在1s剪切率时的标准化全血黏度的平均黏度为(5.46±0.84) mPa·s,血清黏度平均值为(1.27±0.06) mPa·s。本实验采用不同黏度的聚乙烯醇溶液,以模拟血细胞和纤维蛋白在实际样本中对吸样针堵塞的影响。实验设置4种黏度值(3、4、5、6 mPa·s),其中6 mPa·s作为异常情况的对照组。实验通过10台全自动生化分析仪YHLO IBC900,在1~25 μL的9个不同吸样量条件下进行测量。每个吸样量下,每台机器测量1次,每个吸样量重复测量10次,从而在每个黏度条件下共获得900次测量数据,总共采集3 600组数据。

1.2 转换方法

随着深度学习在计算机视觉、自然语言处理等领域取得的成功,相关研究提出两种将时间序列编码成图像的处理算法:GASF和GADF^[23]。这些算法可以将一维时间序列转换为二维图像,从而实现时间序列数据的可视化。具体实施步骤概述如下:

时间序列 $X = \{x_1, x_2, \dots, x_n\}$ 包含的测量值被标准化为0和1之间的值:

$$\tilde{x}_i = \frac{x_i - \min(X)}{\max(X) - \min(X)}, \quad i = 1, 2, \dots, n \quad (1)$$

然后,使用反余弦函数将一维时间序列转换到极坐标系中,并将时间戳作为半径,如式(2)所示:

$$\begin{cases} \phi = \arccos(\tilde{x}_i), & 0 \leq \tilde{x}_i \leq 1, \quad \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, & t_i \in N \end{cases} \quad (2)$$

其中, t_i 表示时间戳, N 是用于调整极坐标范围的常数因子, ϕ 是时间序列中每个值的角余弦。由式(2)可知, ϕ 的取值范围为 $[0, \pi/2]$,该范围内的角余弦值随着 x_i 的增大而单调减小,不同的 ϕ 值在极圆上不同角度点之间产生相应的畸变。最后,将缩放后的时间序列转换为极坐标系下的表示,利用角度透视视图,通过考虑各点之间的三角函数差异,进而分析不同时间间隔下时间序列的相关性。GAF具有两种不同的编码方法,即GASF和GADF,如式(3)和式(4)所示:

$$\text{GASF} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

$$GADF = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (4)$$

利用GAF法可以保持信号的时间序列特征,因为极坐标变换后的时间序列是伴随着时间的增加从

左上角输入到右下角,使得转换后的图像可以最大限度地保留原信号所具有的特征,这可以有效地利用卷积神经网络识别故障类型。图1描述了使用两种不同的GAF编码技术将生化分析仪吸样压力信号转换成图像的结果。

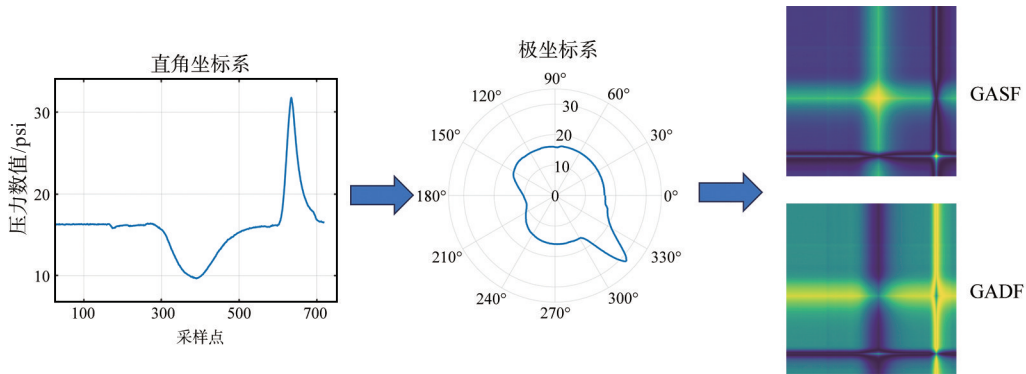


图1 采样压力信号的GAF变换
Figure 1 GAF transformation of pressure signals

2 压力检测网络结构方案

2.1 改进的注意力机制模块

在计算机视觉领域,注意力机制起着至关重要的作用,它能够引导模型聚焦于输入数据中的关键区域,从而提高特征的表达力并增强模型的性能^[24]。

CBAM是一种特殊的注意力机制,它不仅在空间维度上,还在通道维度上评估特征的重要性,其结构如图2所示。通过这种方式,CBAM能够为重要的特征分配更高的权重,进而强化模型识别关键信息的能力,并最终提升模型的整体性能。

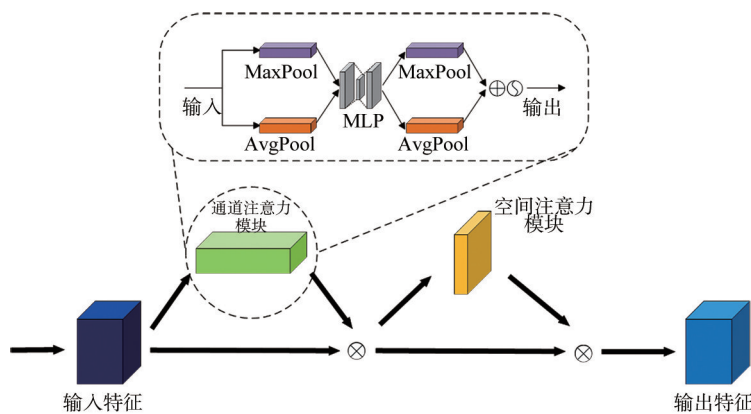


图2 CBAM结构图
Figure 2 CBAM structure

在深度学习领域,传统的多层感知器(MLP)在特征处理能力方面存在一些局限性。首先,MLP的非线性激活函数被固定在每个节点上,导致其在应对多样化任务需求时缺乏灵活性。其次,连接节点的边权重仅为简单的标量值,这种设计限制了网络捕捉特征间复杂关系的能力。为了解决这些问题,

基于Kolmogorov-Arnold表示定理提出的科尔莫戈罗夫-阿诺德(Kolmogorov - Arnold Networks, KAN)网络为传统MLP提供一种创新的替代方案^[25]。与MLP中固定激活函数的使用不同,KAN在边上引入可学习的激活函数,并采用参数化为样条的单变量函数替代传统线性权重参数。这种设计显著增强了

模型的灵活性与适应性,使其能够更有效地捕捉特征间的复杂交互。

受到KAN网络启发,本文对CBAM进行改进,提出一种增强特征聚合能力的注意力机制,即KCBAM。具体而言,在原CBAM的通道注意模块中引入残差连接,连接模块的输入与输出。这一设计不仅缩短了有效的梯度传播路径,提升训练效率,还在一定程度上缓解深度网络中的梯度消失问题。此外,KCBAM使用3

层KAN网络替代原有的MLP运算,突破了MLP的同质化限制,从而使网络能够学习到更丰富的特征表示,改进的通道注意力结构图如图3所示。这些创新性的改进极大地提升CBAM模型在复杂视觉任务中的表现能力,使其在特征聚合和表达方面更具优势,增强网络对视觉信息的理解和处理能力。因此,KCBAM不仅在理论上拓展了现有模型的应用潜力,也为实际应用中的视觉任务提供更为强大的支持。




图3 改进的通道注意力结构图

Figure 3 Improved channel attention structure

2.2 压力分类模型的总体框架

ConvNeXt模型是对Swin Transformer架构的深度卷积神经网络改进,该模型提供4种不同规模的版本(T/S/B/L)^[26]。鉴于高效检测的需求,本文选取ConvNeXt-T作为基准模型,因其在特征提取方面具有优异表现,且具备较少的参数量和较低的硬件需求。为进一步提升模型的感知能力和检测精度,本文在现有模型基础上引入通过GAF转换后的信号图像,并结合改进的KCBAM注意力机制与并行ConvNeXt网络,最终构建一个针对全自动生化分析仪吸样压力信号故障检测的高效分类模型。

首先,采用GAF方法将一维吸样压力信号转化为二维图像数据。GAF转换后的图像与原始时序数据之间建立一一映射关系,从而有效保留数据的时间

相关性。此转换过程使得可以利用深度学习在图像视觉分析中的优势,实现深层次特征提取。接着,将GAF生成的不同图像数据输入结合改进注意力机制KCBAM的并行KConvNext模型,经过ConvNeXtBlock模块及下采样步骤,提取图像特征。该模型具备有效捕捉吸样压力信号时序特征和局部特征的能力,从而提高分类和识别的准确性。最终,将捕捉到的时序特征与局部特征融合,并输入全连接层进行吸样压力信号的分类。通过融合不同图像模态的特征,弥补各自的局限性,增强算法的鲁棒性和泛化能力。多支路并行网络不仅拓宽网络宽度,提升不同尺度特征的提取能力,还显著提高模型的计算速度和分类性能。双通道并行KCBAM-ConvNeXt网络结构图如图4所示。

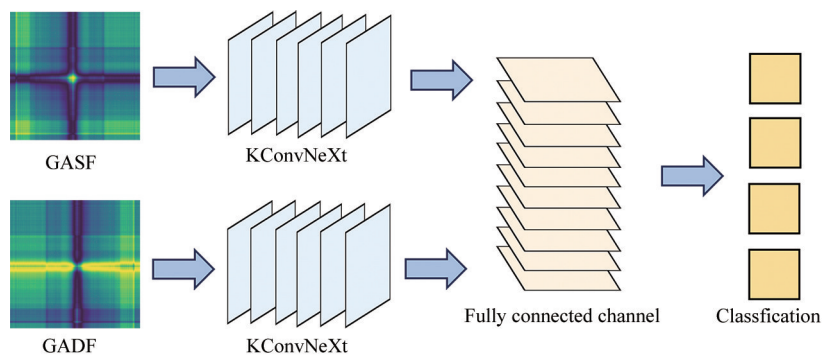


图4 双通道并行KCBAM-ConvNeXt网络结构图

Figure 4 Dual-channel parallel KCBAM-ConvNeXt network structure

3 结果与分析

3.1 模型参数设置

本文所有的实验都是在 Nvidia RTX 3080 的 GPU 上进行的,提出的网络模型的代码是基于 PyTorch 框架实现的。将 3 600 组样本,随机按照 4:1 的比例划分为训练集、测试集,两者之间不存在交集。采用 Adam 优化器进行优化,初始学习速率设定为 0.001。损失函数采用交叉熵函数,经过 200 次迭代完成模型训练。

3.2 消融实验

评估指标是判断诊断算法性能的标准,在数据分析中具有重要意义。本实验采用准确率 (Accuracy)、精确度 (Precision)、召回率 (Recall)、F1 分数 (F1 score)、混淆矩阵以及受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线作为分类效果评价手段。TP、TN、FP、FN 分别表示真阳性、真阴性、假阳性、假阴性的数量,表达式如式(5)~式(8)所示:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1 \text{ score} = \frac{2 \times Precision + Recall}{Precision + Recall} \quad (8)$$

为验证 ConvNeXt 与 KCBAM 结合的有效性,以及获得对模型提升帮助的并行网络,本文进行消融实验,以此验证混合模型的有效性。消融实验结果

如表 1 所示,其中单独使用 KConvNeXt 的准确率为 91.39%。在 KConvNeXt 中采用并行多通道输入后,网络可以综合利用不同格拉姆角场图中更有区别性的特征,使得模型准确率提高 3.19%,F1 分数提高 3.27%。通过将 KCBAM 模块集成到并行 ConvNeXt 结构中,该网络利用空间注意力机制聚焦于特定区域的特征,从而确保重要的空间信息得到充分利用。实验结果表明,与并行 ConvNeXt 模型相比,该网络的准确率提高 3.47%,F1 分数提高 3.48%。综上所述,通过消融实验可以看出,注意力机制和并行网络可以加强网络的特征提取能力,能够提取更加完整的信号的时间、空间、频率信息,有效提高异常情况的分类能力。

表 1 各模型消融实验(%)

Table 1 Ablation experiments of each model (%)

模型	准确率	精确度	召回率	F1 分数
并行 KConvNeXt	94.58	94.53	94.60	94.56
并行 ConvNeXt	91.11	91.03	91.05	91.08
KConvNeXt	91.39	91.38	91.33	91.29

在分类问题中,混淆矩阵是一种评价模型性能的工具。为验证 3 类任务测试实验的精确度,引入混淆矩阵分别对 3 次测试结果进行可视化,3 类任务模型的混淆矩阵如图 5 所示。由图 5 可知,每种模型对于分类都达到优秀的效果,特别是最后的异常项黏度达到 6 mPa·s 的效果最佳。




图 5 各网络混淆矩阵

Figure 5 Confusion matrix of each network

ROC 曲线可用于评估不同阈值下分类模型的性能。从 ROC 曲线看,曲线下的面积越大表示分类性能越好。如图 6 所示,黏度为 6 mPa·s 的 ROC 曲线位于顶部,因此各类网络对于 6 mPa·s 的分类性能最

好,可以作为异常类别的区分。

3.3 模型对比实验

为了验证模型对压力信号格拉姆角场图片分类的有效性,选取 4 种经典深度学习网络模型进行对比




图6 各网络 ROC-AUC 曲线

Figure 6 ROC-AUC curve of each network

实验分析,其中包括 ConvNeXt 网络、ResNet18 网络、MobileNet_V2 网络、ShuffleNet 网络,并获得准确率和损失的比较曲线,如图 7 所示。各模型的评价指标如表 2 所示。与其他 4 个模型相比,由图 7a 可知,本文方法在训练集中分类准确率表现优越,收敛后平稳至 94.58%。由图 7b 可知,本文方法在完成 200 次迭代后,loss 值达到最小,收敛速度以及最终收敛值都优于其他对比算法,表示本文方法对于数据的拟合能力最强。而 ShuffleNet 由于网络结构的设计侧重于计算效率,可能会在一定程度上限制模型对特征的表达能

力,因此分类准确率最低,平均达到 89.17%。ResNet18、MobileNet_V2 都是轻量化模型,均可将不同的相关性特征信息进行保留,使得分类准确率有所提高,但其中 ResNet18 训练数据集规模较小时,ResNet18 可能无法充分学习到数据的特征表示,从而导致泛化能力下降。MobileNet_V2 在小数据集上或者数据分布与训练数据有显著差异时的泛化能力不足,且只对特定硬件有优化,会较难实现最优结果。因此,上述两种方法平均分类准确率只可达到 90% 左右,且训练过程中验证集的表现不稳定。

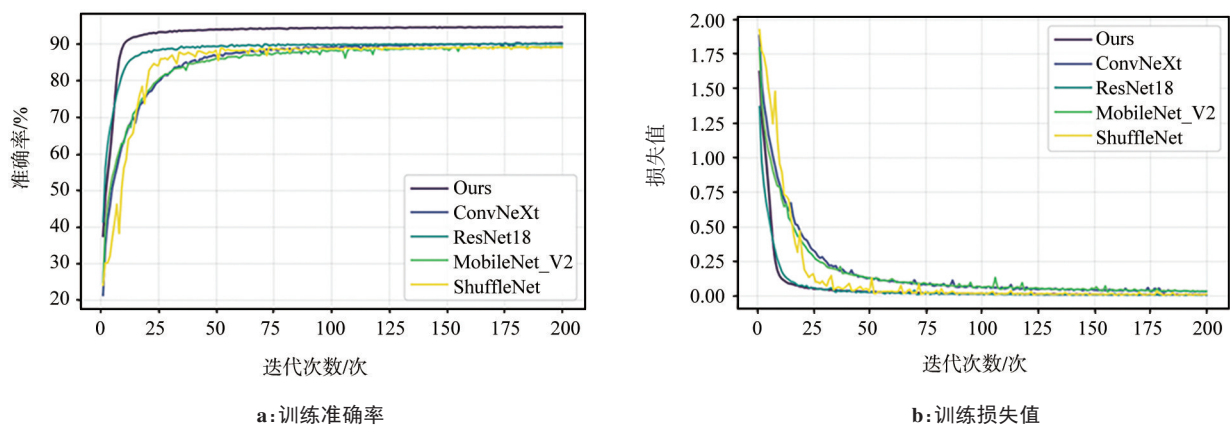


图7 模型训练性能对比图

Figure 7 Comparison of model training performance

表2 各模型对比实验(%)

Table 2 Comparative experiments among different models (%)

模型	准确率	精确度	召回率	F1 分数
并行 KConvNeXt	94.58	94.53	94.60	94.56
ConvNeXt	90.27	90.21	90.30	90.31
ResNet18	90.06	90.03	90.01	90.09
MobileNet_V2	89.34	89.33	89.29	89.38
ShuffleNet	89.17	89.15	89.12	89.20

3.4 应用前景与挑战分析

实验表明,本研究方法在全自动生化分析仪采样系统的异常压力检测中优势显著,通过对吸样压力信号的快速识别,能够有效减少因样本针堵塞、气泡空吸等异常情况造成的样本污染或检测结果偏差,从而提升高效运行下检测的稳定性。此外,随着基层医疗机构的普及和家庭健康管理需求增长,小型化、便携式的全自动生化分析仪逐渐兴起。异常

压力检测技术的发展将会促进全自动生化分析仪的进步,推动行业向更高精度、更高效率、更智能化的方向发展。同时,该技术在实际应用中面临着诸多挑战。一方面,高精度的传感器和先进的检测技术可能会增加仪器的成本,这在一定程度上会影响其市场推广和应用范围,需要在保证检测性能的前提下,合理控制成本;另一方面,全自动生化分析仪在运行过程中,可能会受到各种干扰因素的影响,如电磁干扰、温度变化等,这些因素可能会影响压力检测的准确性,因此还需要提高检测系统的抗干扰能力和环境适应性。此外,整个采样系统涉及多个组件的协同工作,不同部件的协同性及任一部件的性能不稳定都可能导致检测异常,影响整个系统的检测效果,因此需确保各部件同步稳定与高效运行。这些关键问题的解决,将有力推动该技术从实验室研究顺利实现产业化落地。

4 结论

本文针对全自动生化分析仪在采样过程中出现的异常情况,提出一种结合GAF和ConvNeXt网络的异常检测方法。该方法首先采用GAF法将压力信号转化为两种不同尺度的图像,从而有效地保留信号的时序特征与空间信息。在此基础上,通过将图像特征输入改进的注意力机制与CovNeXt模型的融合网络,模型能够自适应地聚焦于具有较高代表性的时间权重特征,进而提升整体的检测性能。最后,采用并行架构对不同尺度的特征进行有效融合,使模型能够更加精确地捕捉信号的时频特性,从而显著提高检测的准确性。实验结果显示,该模型的分​​类准确率高达94.58%,在分类精度上均优于其他模型,证实其在异常压力分类中的优越性及研究方法的可行性,能够提升生化分析仪的准确性和稳定性。

【参考文献】

- [1] Wang L, Xu WC, Wang B, et al. Methods and advances in the design, testing and development of *in vitro* diagnostic instruments [J]. Processes, 2023, 11(2): 403.
- [2] Hou JP, Ren WH, Zhao WL, et al. Blood clot and fibrin recognition method for serum images based on deep learning [J]. Clin Chim Acta, 2024, 553: 117732.
- [3] Zhu YZ, Meng XR, Chen YQ, et al. Self-served and fully automated biochemical detection of finger-prick blood at home using a portable microfluidic analyzer [J]. Sens Actuators B Chem, 2020, 303: 127235.
- [4] Ramlie F, Muhamad WZ, Harudin N, et al. Classification performance of thresholding methods in the Mahalanobis-Taguchi system [J]. Appl Sci, 2021, 11(9): 3906.
- [5] Arathi M, Govardhan A. Performance of mahalanobis distance in time series classification using shapelets [J]. Int J Mach Learn Comput, 2014, 4(4): 339-345.
- [6] Mei JY, Liu MZ, Wang YF, et al. Learning a mahalanobis distance-based dynamic time warping measure for multivariate time series classification [J]. IEEE Trans Cybern, 2016, 46(6): 1363-1374.
- [7] Choi K, Yi JH, Park C, et al. Deep learning for anomaly detection in time-series data: review, analysis, and guidelines [J]. IEEE Access, 2021, 9: 120043-120065.
- [8] Sun JC, Yang Y, Liu YQ, et al. Univariate time series classification using information geometry [J]. Pattern Recognit, 2019, 95: 24-35.
- [9] Pota M, De Pietro G, Esposito M. Real-time anomaly detection on time series of industrial furnaces: a comparison of autoencoder architectures [J]. Eng Appl Artif Intell, 2023, 124: 106597.
- [10] Tran DH, Nguyen VL, Nguyen H, et al. Self-supervised learning for time-series anomaly detection in industrial internet of things [J]. Electronics, 2022, 11(14): 2146.
- [11] Carletti M, Masiero C, Beghi A, et al. A deep learning approach for anomaly detection with industrial time series data: a refrigerators manufacturing case study [J]. Procedia Manuf, 2019, 38: 233-240.
- [12] 袁成成, 刘自结, 王常青, 等. 融合残差网络与自注意力机制的心律失常分类 [J]. 生物医学工程学杂志, 2023, 40(3): 474-481.
- [13] Yuan CC, Liu ZJ, Wang CQ, et al. et al electrocardiogram signal classification based on fusion method of residual network and self-attention mechanism [J]. Journal of Biomedical Engineering, 2023, 40(3): 474-481.
- [14] 张乙鹏, 孙文慧, 陈扶明. 基于小波变换和CNN-LSTM的肺音分类算法 [J]. 中国医学物理学杂志, 2024, 41(3): 356-364.
- [15] Zhang YP, Sun WH, Chen FM. Lung sound classification algorithm based on wavelet transform and CNN-LSTM [J]. Chinese Journal of Medical Physics, 2024, 41(3): 356-364.
- [16] Ma JD, Wang HR. Anomaly detection in sensor data via encoding time series into images [J]. J King Saud Univ Comput Inf Sci, 2024, 36(10): 102232.
- [17] Yang CL, Chen ZX, Yang CY. Sensor classification using convolutional neural network by encoding multivariate time series as two-dimensional colored images [J]. Sensors (Basel), 2019, 20(1): 168.
- [18] Qin Z, Zhang YB, Meng SY, et al. Imaging and fusing time series for wearable sensor-based human activity recognition [J]. Inf Fusion, 2020, 53: 80-87.
- [19] Ko DW, Yang JJ. EEG-based schizophrenia diagnosis through time series image conversion and deep learning [J]. Electronics, 2022, 11(14): 2265.
- [20] Barra S, Carta SM, Corrigan A, et al. Deep learning and time series-to-image encoding for financial forecasting [J]. IEEE/CAA J Autom Sin, 2020, 7(3): 683-692.
- [21] Lin MQ, Wu J, Meng JH, et al. Screening of retired batteries with gramian angular difference fields and ConvNeXt [J]. Eng Appl Artif Intell, 2023, 123(Part B): 106397.
- [22] Wang YJ, Zhuo W, Liu B, et al. GASF-ConvNeXt-TF algorithm for perimeter security disturbance identification based on distributed optical fiber sensing system [J]. IEEE Internet Things J, 2024, 11(10): 17712-17726.
- [23] Li Y, Chen ZQ, Zhang FY, et al. Research on detection of potato varieties based on spectral imaging analytical algorithm [J]. Spectrochim Acta A Mol Biomol Spectrosc, 2024, 311: 123966.
- [24] Rosenson RS, McCormick A, Uretz EF. Distribution of blood viscosity values and biochemical correlates in healthy adults [J]. Clin Chem, 1996, 42(8 Pt 1): 1189-1195.
- [25] Wang ZG, Oates T. Imaging time-series to improve classification and imputation [C]//Proceedings of the 24th International Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2015: 3939-3945.
- [26] Guo MH, Xu TX, Liu JJ, et al. Attention mechanisms in computer vision: a survey [J]. Comput Vis Media, 2022, 8(3): 331-368.
- [27] Koenig BC, Kim S, Deng SL. KAN-ODEs: Kolmogorov-Arnold network ordinary differential equations for learning dynamical systems and hidden physics [J]. Comput Methods Appl Mech Eng, 2024, 432 (Part A): 117397.
- [28] Liu Z, Mao HZ, Wu CY, et al. A ConvNet for the 2020s [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 11966-11976.

(编辑:陈丽霞)