



计算机科学

COMPUTER SCIENCE

基于多模态特征融合的时间序列异常检测

张国华, 燕雪峰, 关东海

引用本文

张国华, 燕雪峰, 关东海. 基于多模态特征融合的时间序列异常检测[J]. 计算机科学, 2023, 50(6A): 220700094-7.

ZHANG Guohua, YAN Xuefeng, GUAN Donghai. [Anomaly Detection of Time-series Based on Multi-modal Feature Fusion](#) [J]. Computer Science, 2023, 50(6A): 220700094-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于动态时空神经网络的城市交通流量预测方法](#)

City Traffic Flow Prediction Method Based on Dynamic Spatio-Temporal Neural Network
计算机科学, 2023, 50(6A): 220600266-7. <https://doi.org/10.11896/jsjcx.220600266>

[面向交通流量预测的时空Graph-CoordAttention网络](#)

Spatial-Temporal Graph-CoordAttention Network for Traffic Forecasting
计算机科学, 2023, 50(6A): 220200042-7. <https://doi.org/10.11896/jsjcx.220200042>

[联合人体姿态估计和多目标跟踪的跨数据集学习](#)

Cross-dataset Learning Combining Multi-object Tracking and Human Pose Estimation
计算机科学, 2023, 50(6A): 220400199-7. <https://doi.org/10.11896/jsjcx.220400199>

[基于改进Yolov4-tiny的轻量级目标检测算法](#)

Lightweight Target Detection Algorithm Based on Improved Yolov4-tiny
计算机科学, 2023, 50(6A): 220700006-7. <https://doi.org/10.11896/jsjcx.220700006>

[注意力特征融合的孪生网络目标跟踪方法](#)

Attentional Feature Fusion Approach for Siamese Network Based Object Tracking
计算机科学, 2023, 50(6A): 220300237-9. <https://doi.org/10.11896/jsjcx.220300237>

基于多模态特征融合的时间序列异常检测

张国华 燕雪峰 关东海

南京航空航天大学计算机科学与技术学院软件新技术与产业化协同创新中心 南京 211106

(zgh2020@nuaa.edu.cn)

摘要 多元时间序列的有效异常检测对于数据的分析挖掘具有重要意义。然而,已有的检测方法大多基于单模态,不能有效利用时间序列在多模态空间中的分布信息,对于多模态特征缺乏自适应融合方式且难以提取其时空依赖关系。为此,提出了一种多模态特征融合的时间序列异常检测方法,建立了一个多模态特征自适应融合模块,通过一维卷积网络和软选择方式对多元时间序列的多模态特征进行自适应融合。对于融合后的多模态特征,构建由时间注意力和空间注意力组成的时空注意力模块,同时提取其时间和空间依赖关系得到时空注意力向量,由时空注意力向量得到模型预测结果。通过学习正常样本分布,根据预测值与真实值的误差度量实现异常检测。在4个公开数据集上进行测试,结果表明,所提方法优于其他模型,证明了所提方法的有效性。

关键词: 时间序列;异常检测;长短期记忆网络;一维卷积神经网络;注意力机制

中图法分类号 TP391

Anomaly Detection of Time-series Based on Multi-modal Feature Fusion

ZHANG Guohua, YAN Xuefeng and GUAN Donghai

College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Software New Technology and Industrialization Collaborative Innovation Center, Nanjing 211106, China

Abstract Effective anomaly detection of multivariate time series is important for data mining analysis. However, most of the existing detection methods are based on single modality, they cannot effectively utilize the distribution information of time series in multi-modal space. For multi-modal features, there is no effective adaptive fusion method and extraction method of spatial-temporal dependence. In this paper, a time series anomaly detection method based on multi-modal feature fusion is proposed. The multi-modal feature adaptive fusion module is established, it can adaptively fuse the multi-modal features through convolution network and soft selection mode. The spatial-temporal attention module is proposed, it is composed of temporal attention and spatial attention. It extracts spatial-temporal dependence of the multi-modal features and outputs the spatial-temporal attention vector. Then the model prediction results are obtained based on the spatial-temporal attention vector. By learning the distribution of normal samples, anomaly detection result is obtained according to the error measure between the predicted values and the real values. The proposed method is compared with other state-of-the-art models on four public datasets, and results demonstrate its effectiveness.

Keywords Time series, Anomaly detection, LSTM, 1D-CNN, Attention mechanism

1 引言

时间序列是一种重要的数据类型,由一组随机变量按照时间顺序排列组成,其通常具有海量、高维的复杂特性。这些大量的时序数据中包含着不同的信息特征,数据中的异常数据所蕴含的信息通常比正常数据更为重要。时间序列异常检测能够识别时序数据中偏离正常模式的异常数据,对于进一步提取数据的隐含特征并对其进行分析具有重要意义,被广泛应用于医疗^[1-2]、传感器网络^[3]等领域。

现有的异常检测算法主要分为有监督和无监督两种方式,有监督方法在样本数据和标签充足的情况下能达到很好的效果,然而现实情况下由于异常样本稀疏及标注困难,很难进行以分类为基础的有监督异常检测。无监督方法由于在训练时不需要标签数据,更适合于类不平衡情况下的异常检测任务。已有的无监督方法主要采用以长短期记忆网络(Long

Short-Term Memory, LSTM)为基础的预测模型^[4-5]及以编解码器和生成对抗网络(Generative Adversarial Networks, GAN)为基础的重构模型^[6-8],在实验中取得了一定的效果。但是现有模型很少考虑时间序列在时域和频域多模态空间中的分布信息,且已有的多模态模型采用相加或拼接方式对多模态特征进行融合,不能充分利用特征的上下文关系信息。此外,多元时间序列相比单变量的时间序列具有更高的复杂性,其需要同时关注数据的时间依赖关系和空间依赖关系,在考虑数据的多模态特征情况下这种依赖关系会变得更加复杂,需要一种有效方式来学习数据在多模态特征空间中的复杂依赖关系,使得模型着重关注于与当前特征关联程度较高的特征信息,忽略与之相关性较低的特征信息。

针对上述问题,本文提出了一种基于卷积神经网络(Convolutional Neural Networks, CNN)和 LSTM 的多模态异常检测模型,旨在有效利用时间序列在时域和频域空间上的

分布信息。本文提出了一种多模态特征融合模块,在提取多模态特征上下文关系的基础上使用软选择的方式对多模态特征进行自适应融合;解决了传统融合方式不能利用特征的上下文关系的问题,软选择方式能够自适应地为不同模态特征分配不同权重。此外,构建一种由时间注意力和空间注意力组成的时空注意力模块,并行提取时间序列多模态特征的时空依赖关系。结合多模态特征融合和注意力机制提高模型对数据分布的学习能力,提高异常检测的准确率。本文使用公开的数据集对所提出的方法进行实验和验证,结果证明了本文方法对多元时间序列异常检测的有效性。

2 相关工作

2.1 时间序列异常检测

时间序列异常检测领域已有学者做了大量工作,现有的机器学习方法可以分为基于重构的方法和基于预测的方法。基于重构的方法通过数据的低维表示对数据进行重构,将重构误差作为异常评分进行异常检测。主成分分析(Principal Components Analysis, PCA)是一种线性重构模型, Li 等^[9]采用 PCA 和小波变换相结合的方法,通过 PCA 来监测子空间中传感器测量值之间的相关性,采用小波变换方法作为数据预处理器,过滤出代表季节波动和内部负载变化的低频特征。对于复杂的数据可使用编解码器和生成对抗网络等深度学习模型。有学者将 GAN 用于异常检测^[8-10]且取得不错效果, Audibert 等^[7]提出了一种基于对抗训练的模型 USAD,在编解码器架构的基础上使用对抗训练方式来快速识别异常数据。但是 GAN 比较难训练,没有一种很好的达到纳什均衡的方法。Malhotra 等^[6]提出了一种基于 LSTM 的编解码器框架。Garg 等^[11]提出了 UAE 模型,为每个独立的通道数据设计了一个由全连接层组成的自动编码器。Lin 等^[12]提出了一种基于 LSTM 的变分自编码器模型,使用基于 LSTM 的编码器对时序数据进行编码,将每个时间步长的时间依赖特性映射到潜在空间中,解码器从潜在空间中估计数据的期望分布。基于编解码器结构的方法由于缺乏有效的正则化方法,因此可能造成模型的过拟合,导致无法准确地进行异常检测。

基于预测的方法根据模型的预测值与真实值之间的预测误差进行异常检测。Ding 等^[13]提出了一种基于分层时间存储器(HTM)和贝叶斯网络的实时异常检测算法。Gugulothu 等^[14]提出了一种非时间降维和循环网络自编码器相结合的端到端的时间序列建模框架。Zhang 等^[5]提出了一种将预测和重构相结合的方法,从多个角度学习数据分布。Hundman 等^[4]提出了一种基于 LSTM 无监督和非参数动态阈值的异常检测方法 LSTM-AE,通过对多元时间序列的各序列分别进行预测,根据各序列的预测误差进行异常检测,用于监测航天器发回的遥测数据。当数据具有很高的维度特性时,采取对每一个时间序列分别预测的方式是不现实的。对于多元时间序列的预测问题,有学者使用 CNN 和循环神经网络(Recurrent Neural Network, RNN)相结合的模型^[15-16],能够捕捉多元时间序列的短期局部依赖和长时特征。

通过融合不同层次或分支的特征能够有效提升的模型性能,在图像处理领域^[17-18]被广泛应用。在异常检测领域, Kong 等^[19]提出了一种基于时频融合的齿轮箱故障诊断

方法,通过对不同频率的频带信号先后进行频带特征融合和时序特征融合来提高检测性能。针对时间序列数据, Huang 等^[20]提出了一个多模态生成对抗网络模型 MMGAN,用于实现时序信息关于时域特征分布和频域特征分布的联合学习,但是其采用拼接方式对多模态特征进行融合,不能自适应地聚焦于不同模态特征。

2.2 时间序列时频分析

通过时频分析工具可以将时间序列的时域信息映射到频域空间,得到时间序列的频域信号。通过对时间序列的时域和频域信息的联合分析可以弥补单一的时域或频域分析的不足,为异常检测任务提供更多有效的信息。Gothwal 等^[1]提出了一种基于傅里叶变换(Fourier Transform, FT)的心率失常异常检测方法,通过对心电信号进行快速傅里叶变换来识别心电信号中的峰值,使用神经网络进行识别。傅里叶变换处理非平稳信号有其固有的缺陷,其虽然能够获取信号中总体上包含的频率成分,但是不能获取各频率的时间信息。Cocconcelli 等^[21]提出了一种基于短时傅里叶变换(Short-Term Fourier Transform, STFT)的电机轴承故障检测方法。STFT 通过窗函数方式在一定程度上解决了 FT 处理非平稳信号的缺陷。但是 STFT 的窗口大小是固定的,无法满足非稳态信号变化的频率的需求。小波变换(Wavelet Transform, WT)通过将傅里叶变换中的三角基函数替换为小波基函数,通过基函数的伸缩平移不仅能够得到不同尺度下的频率成分,也可以获取频率成分在时域上的具体位置,相比 STFT 能够更加有效地对非平稳信号进行分析。

3 多元时间序列异常检测模型

定义 $X = \{x_1, x_2, \dots, x_T\}$ 表示时间序列,其中 T 表示时间序列长度, x_i 表示时间序列中的一个时间点 $x_i \in R^m$,当 X 为单变量时间序列时 x_i 为标量,当其多元时间序列时 x_i 为一个 m 维向量。异常检测就是为每一个时间点分配一个标签 $y \in \{0, 1\}$ (0 表示正常, 1 表示异常)。

数据通常具有很大规模,若直接将数据放入模型进行训练需要巨大的计算开支,造成训练时间和参数更新缓慢。因此需要对数据按滑动窗口方式进行划分,划分后的数据表示为 $W = \{\omega_1, \omega_2, \dots, \omega_n\}$, $\omega_l = \{x_1, x_2, \dots, x_l\}$, l 为窗口长度。每次输入一个窗口大小的数据到模型中,根据历史 l 个数据预测未来某一时刻数据 $x_{l+\Delta}$ 的值,其中 Δ 可针对不同任务设置不同的值。

本文所提出的网络模型整体框架如图 1 所示,主要包括时间序列模态转换、多模态特征自适应融合、融合时空特性的注意力机制。时间序列模态转换模块将时间序列从时域空间映射到频域空间,表示为 x^T 映射为 x^F 。多模态特征自适应融合模块首先提取数据不同模态空间中的特征表示为 z^T 和 z^F ,接着对多模态特征 z^T 和 z^F 进行融合得到最终多模态特征 z 。对融合后的多模态特征 z 由融合时空特性的注意力机制分别提取得到时间注意力向量和空间注意力向量,将两个注意力向量经由 Dense 层得到模型预测输出。根据模型预测输出值与数据真实得到预测误差,对预测误差进行指数加权移动平均得到异常评分,由 POT(Peak Over Threshold)算法^[27]自动确定阈值,根据所确定阈值为每个数据点分配一个标签,用于

表示该数据点是否异常。




图1 模型框架图

Fig. 1 Model framework diagram

3.1 时间序列模态转换

通过对时间序列进行模态转换可以得到时间序列的频域状态表示,时间序列的时域和频域状态表示共同组成数据的多模态信号表示。考虑到小波变换相比傅里叶变换更适合于非平稳数据的分析,因此模态转换采用小波变换方法。离散小波变换能够在一定程度上消除连续小波变换的冗余性,可以将时间序列看成离散的时间点,采用离散小波变换对时间序列进行分解得到时间序列的时域和频域信号。小波基可以由基本的尺度函数 $\varphi(t)$ 和小波函数 $\psi(t)$ 推导得出,离散实数空间内的离散信号可由离散化的小波基表示为:

$$X[t] = \frac{1}{\sqrt{N}} \sum_k W_\psi[j_0, k] \phi_{j_0, k}[t] + \frac{1}{\sqrt{N}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \Psi_{j, k}[t] \quad (1)$$

其中:

$$W_\psi[j_0, k] = \frac{1}{\sqrt{N}} \sum_t X[t] \phi_{j_0, k}[t] \quad (2)$$

$$W_\psi[j, k] = \frac{1}{\sqrt{N}} \sum_t X[t] \Psi_{j, k}[t] \quad (3)$$

其中, W_ψ 和 W_ϕ 分别是近似系数和细节系数。通过构造正交函数将时间序列进行多分辨率分解,得到原始数据的低频和高频信号。近似系数得到的低频信号能够反映原始数据的趋势,细节系数得到的高频信号能够反映原始数据中的随机波动。经过离散小波变换得到的频域信号长度缩短为原始信号长度的一半,采用二插值重构方法将频域信号扩充至与原始信号相同的长度。

3.2 多模态特征自适应融合

多模态特征自适应融合包括特征提取和特征融合两部分。特征提取模块采用一维卷积分别对时域和频域特征进行提取,一维卷积操作能够提取各模态数据在时间维度上的短期模式以及空间维度上的局部依赖关系。卷积层由 C 个卷积核组成,第 k 个卷积核的卷积操作如下:

$$z_k = \sigma(W_k * X + b_k) \quad (4)$$

其中, X 表示卷积层输入, W_k 和 b_k 分别为卷积核的权重和偏置项参数。 $*$ 表示卷积操作, σ 为激活函数,这里使用 LeakyReLU 激活函数, LeakyReLU 能够解决 ReLU 激活函数在负区域无法进行反向传播的问题。将提取得到的时域特征 z^T 和频域特征 z^F 使用特征融合模块进行融合,融合过程如图 2 所示,其表达式如下:

$$M(z^T, z^F) = \sigma(\text{Conv}(\text{GAP}(z^T + z^F))) \quad (5)$$

$$z = M(z^T, z^F) \otimes z^T + (1 - M(z^T, z^F)) \otimes z^F \quad (6)$$

其中, GAP 为全局平均池化操作, Conv 为卷积操作, \otimes 为张量点乘运算, σ 表示激活函数,采用 sigmoid 激活函数将数值映射到 $[0, 1]$ 范围内作为各模态特征的权重。首先将时域

特征和频域特征相加,经过全局平均池化层对全局信息进行整合,使用卷积核大小为 k 的一维卷积网络学习通道特征的上下文关系,经过激活函数得到每个通道的权重。最后对 z^T 和 z^F 做加权平均,各自权重分别为 $M(z^T, z^F)$ 和 $1 - M(z^T, z^F)$ 。时频域各自通道的权重信息由网络训练得到,通过这种方式可以得到每个通道特征对于最终结果的重要程度,根据重要程度为提取得到的时域特征和频域特征赋予不同的权重值,使得模型对于不同的时频域特征有不同的关注程度。通过加权融合方式实现时频域特征的自适应融合,提升对最终结果影响较大的特征关注度,并抑制对最终结果影响较小的特征。相比常用的相加和拼接融合操作,提出的融合模块有以下优势:1)通过全局平均池化操作可以整合单个特征的跨时间步信息;2)通过一维卷积网络可以学习到特征的上下文依赖关系;3)对 z^T 和 z^F 的加权平均采用软选择方式,可以通过网络迭代调整不同模态特征的权重来自适应地融合不同模态特征。




图2 多模态特征自适应融合模块

Fig. 2 Multi-modal feature adaptive fusion module

3.3 融合时空特性的注意力机制

为了学习时间序列的时序依赖关系,使用循环神经网络学习融合后的多模态特征时序依赖关系。常见的循环神经网络有 RNN、LSTM 和门控循环单元(Gated Recurrent Unit, GRU),原始的 RNN 存在梯度消失和梯度爆炸问题。本文采用 BiLSTM 提取数据时序依赖关系,相比单向 LSTM,不仅能够学习序列的前向信息,其还可以学习序列的后向信息,捕捉数据的双向依赖关系。BiLSTM 可以看作由前向 LSTM 和后向 LSTM 堆叠而成,每个 LSTM 单元的计算过程如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$\bar{c} = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (10)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \bar{c} \quad (11)$$

$$h_t = o_t \otimes \tanh(c_t) \quad (12)$$

其中, h_t 为隐藏层状态; f_t, i_t, o_t 分别表示遗忘门、输入门和输出门; W_i, W_f, W_o 为对应 f_t, i_t, o_t 的权重矩阵; b_i, b_f, b_o 为对应偏置; σ 为激活函数; c_t 为细胞状态。BiLSTM 的结构如图 3 所示,其每一时刻的隐藏层状态可表示为 $\bar{h}_t = [h_t^1, h_t^2]$, h_t^1 表示前向层的隐藏层状态, h_t^2 表示后向层的隐藏状态。最后需要对两层的隐藏状态进行融合,为了保障网络参数轻量化,使用相加的方式对隐藏层状态进行融合得到 $\bar{h} = \{\bar{h}_1, \bar{h}_2, \dots, \bar{h}_n\}$ 。




图3 BiLSTM 结构图

Fig. 3 BiLSTM structure diagram

为了解决 LSTM 对于时间序列的长时依赖关系和各时间序列间的空间依赖关系,使用两种注意力机制分别提取数据的时间依赖关系和空间依赖关系。

考虑到历史数据的每一时刻对于最终预测结果所起的作用不同,使用时间注意力机制捕获历史每一刻的关键性作用程度。根据 BiLSTM 输出 $\bar{h} = \{\bar{h}_1, \bar{h}_2, \dots, \bar{h}_n\}$, 采用缩放点积评分函数计算每一时刻的权重。

$$F_T(Q, K) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (13)$$

根据评分函数计算历史时刻的隐状态与 \bar{h}_n 的相关程度,接着根据各自的权重分值进行加权平均,得到上下文向量 c_t , 将 \bar{h}_n 与 c_t 进行拼接得到最终的时间注意力向量 v^T 。

为了进一步捕获各时间序列间的空间依赖关系,使用 TPA 注意力机制^[16]提取空间注意力向量。如图 4 所示,首先对 BiLSTM 输出隐状态 $\bar{h} = \{\bar{h}_1, \bar{h}_2, \dots, \bar{h}_n\}$ 使用 k 个卷积核的一维卷积操作,卷积操作在整合各变量跨时间步长信息的同时能够提取不同变量之间的复杂依赖关系。通过卷积操作得到输出特征 $H^C \in R^{n \times k}$ 。评分函数的计算过程如下:

$$F_C(H_i^C, \bar{h}_n) = \text{sigmoid}((H_i^C)^T W_a \bar{h}_n) \quad (14)$$

$$v^C = \sum_{i=1}^n F_C(H_i^C, \bar{h}_n) H_i^C \quad (15)$$

其中, H_i^C 表示 H^C 的行向量, W_a 为 $n \times k$ 的权重矩阵,通过评分函数 F_C 得到注意力权重,根据注意力权重与 H^C 进行加权平均得到空间注意力向量 v^C 。




图4 TPA 注意力机制

Fig. 4 TPA attention mechanism

最后将得到的时间注意力向量 v^T 和空间注意力向量 v^C 进行拼接,经过 Dense 层得到预测结果。损失函数采用均方根误差(RMSE):

$$\text{Loss} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \tilde{x}_i)^2} \quad (16)$$

3.4 异常评分优化

模型使用单步预测,模型预测 t 时刻的输出为 \tilde{x}_t , 预测误差表示为 $e = \{e_1, e_2, \dots, e_T\}$, 其中 $e_t = \sum_i^m |\tilde{x}_i^t - x_i^t|$ 。对于时序数据中的突变导致的峰值,模型不能完美地进行预测,导致在突变峰值处通常会有很大的预测误差。这种情况在异常检测中会增加虚警率,为了优化这种情况,采用指数加权移动的

平均对预测误差进行平滑得到异常评分,根据异常评分进行最终的异常判断。在 t 时刻的移动平均公式为:

$$V_t = V_{t-1} * \alpha + e_t * (1 - \alpha) \quad (17)$$

其中, V_t 是 t 时刻移动的平均结果, e_t 是 t 时刻的原始值, α 为权重,通过设置 α 可以控制结果的平稳性,减少突变峰值对最终检测效果的影响。

为了自动确定阈值,本文使用极值理论的原理对异常评分分布进行拟合并设置阈值。极值理论在不基于数据符合任何分布的情况下,对可能会发生的极端事件分布进行推断,相比其他方法具有更好的适用性。在极值理论中 POT 方法被广泛应用,其使用广义帕累托分布对数据分布进行拟合,通过最大似然估计对分布参数进行估计进而确定阈值。根据阈值为每一个时间点分配一个标签,表示该点是否异常。

4 实验

本节包括实验设置和实验分析,实验分析部分包括对比实验、消融实验、阈值分析以及异常分布可视化分析,从不同的角度对所提模型进行验证。

4.1 实验设置

4.1.1 评价指标

考虑到不平衡问题,本文采用精确率(Precision)、召回率(Recall)和 F1 分数作为评价指标。F1 指标常用于评价统计学中的二分类模型的效果,其可以看作模型精确率和召回率的调和平均,计算式如下:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$F1 = 2 * \frac{P * R}{P + R} \quad (20)$$

其中, TP 表示检测为异常且实际为异常样本数量, FP 表示检测为异常而实际为正常的样本数量, FN 表示检测为正常但实际为异常的样本数量。

4.1.2 数据集

1) ECG, 心电图数据集,共包含 8 个患者的心电图数据,每个数据由两个通道组成;2) Gesture, 一个演员的动作表示的时间序列,包含两个通道的数据,分别表示为演员右手的 X 和 Y 坐标;3) Space Shuttle, 包含航天飞机的阀门状态时间序列,由 NASA 工程师标记,共有 3 个子数据集,其中每个数据包含一个通道;4) SMD, 包含对一个计算机集群中的 28 台机器为期五周的资源使用情况,每个机器的数据由 38 个通道组成。根据文献[22]选取 machint-1-1, 2-1, 3-2 和 3-7 这 4 个非平稳时间序列子集进行分析。

上述 4 个数据集中, ECG, Gesture 和 Space Shuttle^[23], SMD^[3] 使用 min-max 方式对数据进行归一化,根据官方提供的信息将其划分为训练集和测试集,训练集中只包含正常样本,将训练集中的 20% 作为验证集。使用滑动窗口对数据进行划分,设置窗口大小为 100, 移动步长为 1。

在 SMD 数据集的测试过程中采取点调整(point-adjust)方法,在连续为异常的子序列中,若其中一个数据点被检测为异常,则该子序列其他点也被认为检测到异常。其余 3 个数据集中每个子数据集包含异常子序列较少,不采用点调整方法。

设置训练轮数为 100, batch 大小为 64, 学习率为 0.001, 采用 Adam 优化器更新参数。

4.2 实验分析

4.2.1 对比实验

为了验证所提方法的有效性, 本节将在各数据集上进行对比实验。实验所用对比方法分别如下。

(1) PCA, 使用 Sklearn 提供的 PCA 工具完成, 通过分析只保留一个可以解释 90% 方差的主成分子集, 对数据进行重构还原, 根据重构误差识别异常。

(2) LSTM-AE, 是由文献[6]提出的一种基于长短期记忆网络的编码器-解码器异常检测方法, 编码器和解码器均使用 LSTM 完成, 该方案学习重构正常时间序列, 然后利用重构误差来检测异常。模型参数与原论文中保持一致。

(3) USAD, 是由文献[7]提出的一种快速、稳定的多元时间序列无监督异常检测方法, 使用两个自编码器进行对抗训练, 两个自编码器共享一个编码器。通过重构误差能够快速准确识别出时间序列中的异常。为了使模型在 4 个数据集上达到较好效果, 对模型进行优化, 在模型的编码器和解码器中的全连接层后加入 ReLU 激活函数。

(4) UAE, 根据文献[11]实现单变量全连接自编码器, 通过为每个通道训练一个单独的自编码器, 将每个通道的重构误差进行汇总以实现多元时间序列的异常检测。编码器和解码器中的全连接层数根据输入数据长度确定, 模型参数与原论文中保持一致。

(5) MMGAN, 根据文献[23]实现基于自适应卷积网络的

生成对抗网络模型, 由于原论文中代码未开源, 根据论文中描述的模型结构和参数进行复现。

所选取的对比方法在原文章中所使用的阈值设置方法不完全相同, 为了保证实验的公平性, 使用穷举法搜索异常评分值区间中所有可能的阈值, 然后选择其中最好的 F1 分数作为模型的性能。

各模型在不同的数据集上的实验结果如表 1 所列, 单看精确率或召回率不能准确评价模型性能, 极端情况下会出现精确率很高但召回率很低或召回率很高但精确率很低的情况, F1 分数综合考虑精确率和召回率, 做到对于两者的调和, 能够避免极端情况下对模型性能评价的偏差。从表中的数据可以看出, 本文方法在 ECG 数据集上取得了最好的精确率和召回率, 其余 3 个数据集相比 ECG 数据集的异常数据占比较高, 所提方法在保持最优的精确率的同时能够保持较好的召回率。在 4 个数据集上均取得最优的 F1 值, 在 ECG 数据集上提升了 8%, 在 Gesture 数据集上提升了 5.7%, 在 Space Shuttle 数据集上提升了 7.5%, 在 SMD 数据集上提升了 6.6%。PCA 是一种线性重构方法, 对于非线性数据分析能力较差, USAD 和 UAE 是由全连接层组成的编解码器结构, 其不能很好地学习到数据的时序依赖关系。LSTM-AE 可以学习到数据的时序依赖关系, 其并不能明确地学习到数据的空间依赖关系。ECG 和 Gesture 为准周期数据, Space Shuttle 为周期数据, SMD 为非周期数据, 说明所提模型能够对周期性和非周期性的数据分布进行高质量学习。

表 1 对比实验结果

Table 1 Results of contrast experiment

方法	数据集											
	ECG			GESTURE			SPACE SHUTTLE			SMD		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
PCA	0.235	0.770	0.301	0.260	0.909	0.405	0.230	0.583	0.326	0.539	0.881	0.574
LSTM-AE	0.425	0.687	0.458	0.276	0.921	0.424	0.369	0.988	0.508	0.576	0.745	0.650
USAD	0.339	0.674	0.402	0.666	0.990	0.799	0.282	0.982	0.434	0.775	0.800	0.710
UAE	0.467	0.714	0.530	0.552	0.805	0.655	0.369	0.950	0.518	0.858	0.878	0.849
MMGAN	0.478	0.694	0.513	0.702	0.896	0.766	0.303	0.913	0.420	0.823	0.854	0.826
Ours	0.608	0.814	0.610	0.846	0.867	0.856	0.446	0.918	0.593	0.951	0.879	0.915

4.2.2 消融实验

为了验证所提方法各模块的有效性, 本节将在各数据集上进行消融实验。实验所用的 4 种模型结构如下。

(1) CNN-LSTM: 基础的 CNN-LSTM 单模态模型, 使用一维卷积和单层单向的 LSTM 网络结构。

(2) 添加多模态融合模块: 在 CNN-LSTM 基础上使用多模态模型, 使用两个一维卷积网络分别提取时域和频域特征, 加入所提出的多模态特征融合模块, LSTM 为单层单向的网络结构。

(3) 添加注意力模块: 在 CNN-LSTM 基础上添加注意力模块, 不考虑数据的多模态特征, 使用一维卷积和单层双向的 LSTM 网络结构。

(4) 最终模型: 本文提出的最终模型, 在 CNN-LSTM 基础上考虑数据的多模态特征, 同时加入注意力模块。

以上 4 种模型的实验结果如表 2 所列。从表中可见, 加入多模态融合模块后的模型相比基础的模型, 在实验的 4 个数据集中 F1 指标均有提升, 说明多模态融合模块能够有效

地对时间序列的多模态数据进行提取融合, 相比单模态能够为异常检测任务提供更多有效信息。加入注意力模块后的模型, 除了在 ECG 数据集中没有较好的提升效果, 在其余 3 个数据集上均有明显的提升效果, 说明加入的时间注意力模块和空间注意力模块能够有效地提取时间序列的时空依赖关系。最终的模型相比单独使用多模态融合模块和单独使用注意力模块, 在 F1 指标上有明显的提升效果, 证明在考虑数据的多模态特征基础上加入注意力模块能够更好地学习数据的分布特征, 提升异常检测效果。

表 2 消融实验结果

Table 2 Results of ablation experiment

方法	数据集			
	ECG	GESTURE	SPACE-SHUTTLE	SMD
CNN-LSTM	0.530	0.497	0.436	0.825
添加多模态	0.570	0.736	0.461	0.861
添加注意力	0.557	0.822	0.533	0.857
最终模型	0.610	0.856	0.593	0.915

4.2.3 阈值分析

为了验证所提方法中 POT 所选择的阈值的有效性,本节将在各数据集上进行阈值选择分析。使用 POT 自动选择阈值与通过搜索得到最好的 F1 分数确定的阈值进行对比。

阈值分析的实验结果如表 3 所列,在 4 个数据集上通过 POT 算法自动确定的阈值的检测效果与通过搜索得到的最好的 F1 分值确定的阈值的检测效果相差很小。在现实情况下自动确定阈值的方法更具有普适性,实验结果证明本文采取 POT 算法进行阈值选择是有效且实用的。


表 3 阈值选择分析

Table 3 Threshold selection analysis


方法	数据集			
	ECG	GESTURE	SPACE-SHUTTLE	SMD
POT	0.590	0.823	0.551	0.899
F1 _{best}	0.610	0.856	0.593	0.915

4.2.4 异常分布可视化


本节实验通过对异常评分的分布进行可视化以验证模型对于数据的检测效果。选取 LSTM-AE 和 UAE 两种模型在 ECG 数据集上进行测试,计算模型对于样本数据的异常评分,将异常评分由柱状图进行展示,结果如图 5 所示。



(a) LSTM-AE



(b) UAE



(c) 本文方法

图 5 异常评分分布

Fig. 5 Abnormal score distribution

从图中可以看出,本文方法的异常评分分布有比较明显的分布边界,正常样本和异常样本的重合分布较少,这证明所提方法能够有效地区分正常样本和异常样本,学习数据的特征分布。而其他两种模型的分分布边界不是很明显,正常样本和异常样本有较多的重合,有较多的异常点没有被检测到且

部分正常样本被视为异常。

综合以上几种实验结果,对比实验证明所提方法较已有的模型方法有明显的检测效果提升;消融实验证明所提模型各个模块对于检测效果提升有很大帮助;异常分布可视化能够直观地看出正常样本和异常样本的异常评分分布,证明所提方法能够较好地正负样本进行分离。可以得出结论:本文方法较已有方法在多元时间序列异常检测任务中表现出了更优的检测效果。

结束语 目前已有的深度学习异常检测模型主要关注于时间序列在时域空间中的分布特征,很少有模型关注于数据在多模态空间中的分布特征,且已有的多模态异常检测模型不能充分利用多模态特征上下文关系进行有效的融合。据此,本文提出了一种多模态特征融合时间序列异常检测模型,设计了一种新颖的多模态特征融合模块,能够在捕捉数据的空间依赖特性的同时对数据的多模态数据进行自适应融合。另外,通过对两种注意力机制进行融合,使得模型能够同时动态捕捉多元时间序列的复杂时空依赖关系。在公开的 4 个数据集上进行充分实验,结果证明了所提模型的有效性。下一步考虑将更多模态数据的自适应高效融合,为异常检测任务提供更多的有效信息。

参考文献

- [1] GOTHWAL H, KEDAWAT S, KUMAR R. Cardiac arrhythmias detection in an ECG beat signal using fast fourier transform and artificial neural network[J]. Journal of Biomedical Science and Engineering, 2011, 4(4): 289-296.
- [2] KIRANYAZ S, INCE T, GABBOUJ M. Real-time patient-specific ECG classification by 1-D convolutional neural networks [J]. IEEE Transactions on Biomedical Engineering, 2015, 63(3): 664-675.
- [3] SU Y, ZHAO Y, NIU C, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network[C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019: 2828-2837.
- [4] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018: 387-395.
- [5] ZHANG Y, CHEN Y, WANG J, et al. Unsupervised deep anomaly detection for multi-sensor time-series signals [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(2): 2118-2132.
- [6] MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection[J]. arXiv:1607.00148, 2016.
- [7] AUDIBERT J, MICHIARDI P, GUYARD F, et al. USAD: unsupervised anomaly detection on multivariate time series[C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020: 3395-3404.
- [8] DU B, SUN X, YE J, et al. GAN-Based Anomaly Detection for Multivariate Time Series Using Polluted Training Set[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 30(3): 1028-1037.

- [9] LI S, WEN J. A model-based fault detection and diagnostic methodology based on PCA method and wavelet transform[J]. *Energy and Buildings*, 2014, 68: 63-71.
- [10] LIU S, ZHOU B, DING Q, et al. Time Series Anomaly Detection with Adversarial Reconstruction Networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 4293-4306.
- [11] GARG A, ZHANG W, SAMARAN J, et al. An Evaluation of Anomaly Detection and Diagnosis in Multivariate Time Series [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(6): 2508-2517.
- [12] LIN S, CLARK R, BIRKE R, et al. Anomaly detection for time series using vae-lstm hybrid model[C]// 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020). IEEE, 2020: 4322-4326.
- [13] DING N, GAO H, BU H, et al. Multivariate-time-series-driven real-time anomaly detection based on bayesian network[J]. *Sensors*, 2018, 18(10): 3367.
- [14] GUGULOTHU N, MALHOTRA P, VIG L, et al. Sparse neural networks for anomaly detection in high-dimensional time series [C]// AI4IOT workshop in Conjunction with ICML, IJCAI and ECAI. 2018: 1551-3203.
- [15] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks [C]// The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. 2018: 95-104.
- [16] SHIH S Y, SUN F K, LEE H. Temporal pattern attention for multivariate time series forecasting [J]. *Machine Learning*, 2019, 108(8): 1421-1441.
- [17] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2021: 3560-3569.
- [18] LI X, WANG W, HU X, et al. Selective kernel networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 510-519.
- [19] KONG Z Q, DENG L, TANG B P, et al. Fault diagnosis of planetary gearbox based on deep learning with time-frequency fusion and attention mechanism [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(6): 221-227.
- [20] HUANG X, ZHANG F, FAN H, et al. Multimodal Adversarial Learning Based Unsupervised Time Series Anomaly Detection [J]. *Journal of Computer Research and Development*, 2021, 58(8): 1655.
- [21] COCCONCELLI M, ZIMROZ R, RUBINI R, et al. STFT based approach for ball bearing fault detection in a varying speed motor[M]// *Condition Monitoring of Machinery in Non-stationary Operations*. Berlin: Springer, 2012: 41-50.
- [22] WU R, KEOGH E. Current time series anomaly detection benchmarks are flawed and are creating the illusion of progress [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022: 1479-1480.
- [23] KEOGH E, LIN J, FU A. Hot sax: Efficiently finding the most unusual time series subsequence[C]// Fifth IEEE International Conference on Data Mining, 2005: 226-233.
- [24] RAJPURKAR P, HANNUN A Y, HAGHPANAHI M, et al. Cardiologist-level arrhythmia detection with convolutional neural networks[J]. arXiv:1707. 01836, 2017.
- [25] SAEEDI EMADI H, MAZINANI S M. A novel anomaly detection algorithm using DBSCAN and SVM in wireless sensor networks[J]. *Wireless Personal Communications*, 2018, 98(2): 2025-2035.
- [26] HARISH B S, KUMAR S V A. Anomaly based intrusion detection using modified fuzzy clustering[J]. *Int. J. Interact. Multimed. Artif. Intell.*, 2017, 4(6): 54-59.
- [27] SIFFER A, FOUQUE P A, TERMIER A, et al. Anomaly detection in streams with extreme value theory[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2017: 1067-1075.



ZHANG Guohua, born in 1995, post-graduate. His main research interests include machine learning and anomaly detection.



YAN Xuefeng, born in 1975, Ph.D, professor, is a member of China Computer Federation. His main research interests include intelligent computing, model-based systems engineering, simulation, and evaluation.