

文章编号: 2095-4980(2021)04-0581-08

基于注意力机制的电磁时间序列异常检测方法

王 翔, 邓 文*, 刘世雄, 黄知涛

(国防科技大学 电子科学学院, 湖南 长沙 410073)

摘 要: 实现电磁数据的异常检测和模式发现, 对电磁目标异常行为的判断与提前预警具有重要价值。不同类型的电磁数据通常以时间序列的形式存在, 且具有正常数据与异常数据不均衡等特点。为应对上述挑战, 提出一种基于时空联合注意力机制的时间序列异常检测方法。基于电磁数据的时间与空间特征, 结合通道与空间注意力机制, 增强对时序数据异常部分的特征表示。实验结果表明, 提出的检测算法能够有效应对数据不均衡的难点, 具有较强的鲁棒性。

关键词: 电磁时间序列; 异常检测; 注意力机制; 卷积神经网络; 长短期记忆网络

中图分类号: TP183

文献标志码: A

doi: 10.11805/TKYDA2021150

Anomaly detection method of electromagnetic time series based on attention mechanism

WANG Xiang, DENG Wen*, LIU Shixiong, HUANG Zhitao

(School of Electronic Science, National University of Defense Technology, Changsha Hunan 410073, China)

Abstract: The realization of abnormal detection and pattern discovery of electromagnetic data is of great value to the judgment and early warning of abnormal behaviors of electromagnetic targets. Different types of electromagnetic data usually exist in the form of time series, with the characteristic of imbalance between normal data and abnormal data. To address these issues, a time series anomaly detection method is proposed based on the spatial-temporal joint attention mechanism. The channel attention mechanism and spatial attention mechanism are combined to enhance the feature representation of the abnormal part of time series data. Experimental results show that the proposed detection algorithm can effectively deal with the difficulty of data imbalance and has strong robustness.

Keywords: electromagnetic time series; anomaly detection; attention mechanism; Convolutional Neural Network(CNN); Long Short-Term Memory(LSTM) network

随着通信、导航、WiFi 等军民频设备的大规模使用, 电磁数据日益向海量、高维的形式发展。基于电磁信息数据, 依托人工智能处理技术, 提取更多高价值信息, 已成为电磁频谱感知、利用与管理等领域的热点研究^[1]。特别是实现电磁数据中异常波形与模式的检测, 对电磁辐射源所在平台与目标异常行为判断与提前预警具有重要价值。

1 时间序列异常检测研究现状

时间序列异常检测是指发现数据中的异常值, 该异常数据为通常与整体数据集中绝大多数数据表现不一致或不符合预期的数据。在信号处理领域中, 原始电磁采样数据即为典型的时间序列数据。

针对时间序列的异常检测, 近年来, 深度学习方法在时间序列异常检测领域取得了不俗的成绩。卷积神经网络(CNN)和递归神经网络(Recursive Neural Network, RNN)是实现这些突破的两种主要网络架构类型。文献[2]中采用堆叠长短期记忆(LSTM)网络对时间序列中的异常进行检测, 证明了堆叠 LSTM 网络能够学习到数据的高

收稿日期: 2021-04-15; 修回日期: 2021-05-10

基金项目: 湖南省自然科学基金创新群体资助项目(2019JJ10004)

*通信作者: 邓 文 email:657673554@qq.com

级时间特征模式。文献[3]将 LSTM 架构应用到 RNN 结构, 组成深度 LSTM-RNN 网络, 并在网络入侵检测中验证了方法的可行性。文献[4]提出一种利用 RNN 进行入侵检测的深度学习的方法, 该模型能有效提高入侵检测的准确性和识别入侵类型的能力。文献[5]针对多元时间序列, 提出了一种深度学习框架——多通道深度卷积神经网络(Multi-Channels Deep Convolution Neural Networks, MC-DCNN), 该框架自动从每个通道的单个变量时间序列中学习特征, 并在最后一层结合所有通道的信息作为特征表示, 有助于提高分类性能。文献[6]针对人体姿态识别(Human Activity Recognition, HAR)问题提出了一种系统的特征学习方法, 该方法采用深度 CNN 自动从原始输入中系统地进行特征学习。通过深度架构, 学习到的特征被视为低层次原始时间序列信号的高层次抽象表示。文献[7]提出了多尺度 CNN, 利用新的多分支层和可学习的卷积层, 自动提取不同尺度和频率的特征, 从而获得更好的特征表示。文献[8]采用一个 34 层的 CNN 用于心电图分类, 实测数据集验证了网络的优异特征提取以及识别分类性能。文献[9]提出了一个基于层次时态记忆(Hierarchical Temporal Memory, HTM)和贝叶斯网络(Bayesian Network, BN)的实时异常检测算法——多变量时间序列驱动的实时异常检测(Multivariate-Time-Series-Driven Real-time Anomaly Detection, RADM), 在多变量敏感时间序列异常检测中, 取得了优异的检测性能。文献[10]通过带有周期性的门控循环单元捕捉多变量时间序列数据在时间维度上的深层信息, 并通过注意力机制找到度量各个特征的权重, 而后将两个角度的信息汇总作为多元时序预测结果, 提高了多变量时间序列异常检测性能。文献[11]提出了一种基于 CNN 的时间序列分割方法用于异常检测, 采用迁移学习框架, 在大规模合成单变量时间序列数据集上预训练模型, 然后在小规模、单变量或多变量数据集上用先前未见过的异常类别微调其权重, 在多变量时间序列异常上取得良好的检测性能。文献[12]结合振动信号自身的一维性特点, 提出一种基于一维卷积神经网络, 该算法模型在旋转机械故障检测上优于主流故障诊断方法。

在电磁数据异常检测方面, 由于数据具有不平衡特点, 即带标记的异常数据通常远少于正常数据。已有的工作对正常数据的分类识别性能优异, 但对不平衡数据的异常检测能力还有待增强。为应对上述挑战, 本文基于电磁信息领域数据的时空特征, 为充分利用电磁时间序列数据的时间关联特征和空间依赖特征进行异常检测, 提出了一种基于注意力机制的时间序列异常检测方法。为验证算法的有效性, 采用实测心电图(Electrocardiograph, ECG)开源时序数据对算法性能进行验证, 分别针对不同数据量、数据长度、异常种类以及异常数据率情况, 对算法性能进行深入实验分析。结果表明, 提出的检测算法能够有效应对数据不平衡的难点, 在数据集数据量、数据长度、异常种类、数据异常率等方面组合多样的情况下, 仍表现出较强的鲁棒性。

2 基于注意力机制的时间序列异常检测方法

2.1 算法模型设计

时间序列是电磁数据主要的存储形式, 基于电磁时序数据的时间与空间特征, 本文提出一种基于注意力机制的时间序列异常检测方法。其基本结构是融合 CNN 和 LSTM 两种网络完成数据时间特征和空间特征的提取。此外, 为在样本有限条件下, 提高对电磁时间序列中不同序列片段对序列异常检测贡献大小的捕获能力, 本文同时结合通道注意力机制与空间注意力机制, 增强对时序数据关键特征的表达。在此基础上, 实现对异常电磁时间序列的高效检测, 具体算法模型网络结构如图 1 所示。

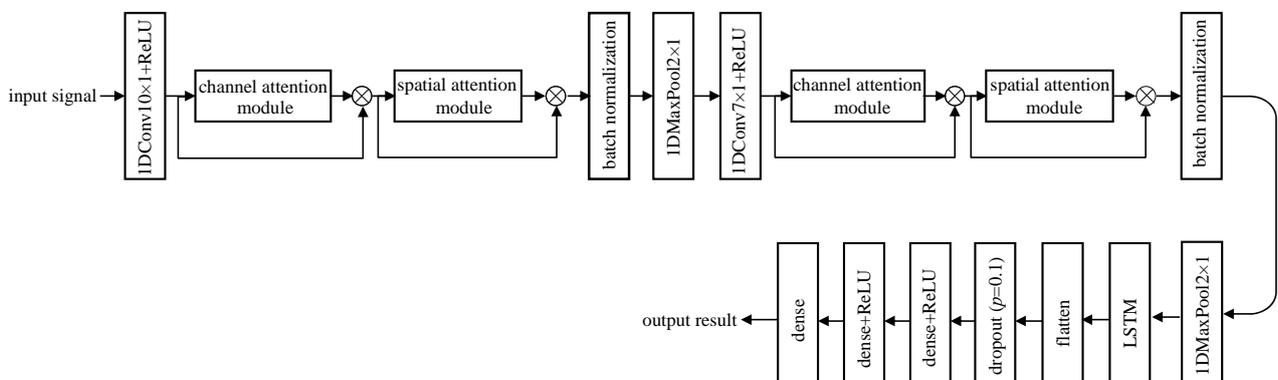


Fig.1 Architecture of the proposed algorithm

图 1 本文算法模型网络结构

模型构建了两层一维卷积层提取时序数据的空间特征, 10 个隐藏层单元的 LSTM 网络层提取时间特征, 最后经过 3 层全连接层输出异常检测结果。特别地, 本文在卷积层进行特征提取后分别加入注意力机制模块, 以

实现对卷积提取后的特征图进行加权操作，增强重要特征的表示。网络的详细参数如表 1 所示。

表 1 网络模型的详细参数
Table 1 Detail parameters of the proposed structure

layers	types	activation function	output shapes	kernel size	connected to
1	input_1(InputLayer)	-	3 600×1	-	-
2	conv1d(Conv1D)	ReLU	1 200×128	20×1	input_1[0][0]
3	global_average_pooling1d(GlobalAverage)	-	128	-	conv1d[0][0]
4	global_max_pooling1d(GlobalMax)	-	128	-	conv1d[0][0]
5	reshape(Reshape)	-	1×1×128	-	global_average_pooling1d[0][0]
6	reshape_1(Reshape)	-	1×1×128	-	global_max_pooling1d[0][0]
7	dense(Dense)	ReLU	1×1×8	-	reshape[0][0], reshape_1[0][0]
8	dense_1(Dense)	ReLU	1×1×128	-	dense[0][0], dense_1[1][0]
9	add(Add)	Sigmoid	1×1×128	-	dense_1[0][0], dense_1[1][0]
10	multiply(Multiply)	-	1×1 200×128	-	conv1d[0][0], add [0][0]
11	reshape_2(Reshape)	-	1 200×128	-	multiply[0][0]
12	lambda(Lambda)	-	1 200×1	-	reshape_2[0][0]
13	lambda_1(Lambda)	-	1 200×1	-	reshape_2[0][0]
14	concatenate(Concatenate)	-	1 200×2	-	lambda[0][0], lambda_1[0][0]
15	conv1d_1(Conv1D)	Sigmoid	1 200×1	7×1	concatenate[0][0]
16	multiply_1(Multiply)	-	1 200×128	-	reshape_2[0][0], conv1d_1[0][0]
17	reshape_3(Reshape)	-	1 200×128	-	multiply_1[0][0]
18	batch_normalization(BatchNormalization)	-	1 200×128	-	reshape_3[0][0]
19	max_pooling1d(MaxPooling1D)	-	400×128	2×1	batch_normalization[0][0]
20	conv1d_2(Conv1D)	ReLU	400×32	7×1	max_pooling1d[0][0]
21	global_average_pooling1d_1 (GlobalAverage)	-	32	-	conv1d_2[0][0]
22	global_max_pooling1d_1(GlobalMax)	-	32	-	conv1d_2[0][0]
23	reshape_4(Reshape)	-	1×1×32	-	global_average_pooling1d_1[0][0]
24	reshape_5(Reshape)	-	1×1×32	-	global_max_pooling1d_1[0][0]
25	dense_2(Dense)	ReLU	1×1×2	-	reshape_4[0][0], reshape_5[0][0]
26	dense_3(Dense)	ReLU	1×1×32	-	dense_2[0][0], dense_2[1][0]
27	-	-	-	-	-
28	add_1(Add)	Sigmoid	1×1×32	-	dense_3[0][0], dense_3[1][0]
29	multiply_2(Multiply)	-	1×400×32	-	conv1d_2[0][0], add_1[0][0]
30	reshape_6(Reshape)	-	400×32	-	multiply_2[0][0]
31	lambda_2(Lambda)	-	400×1	-	reshape_6[0][0]
32	lambda_3(Lambda)	-	400×1	-	reshape_6[0][0]
33	concatenate_1(Concatenate)	-	400×2	-	lambda_2[0][0], lambda_3[0][0]
34	conv1d_3(Conv1D)	Sigmoid	400×1	7×1	concatenate_1[0][0]
35	multiply_3(Multiply)	-	-	-	reshape_6[0][0], conv1d_3[0][0]
36	reshape_7(Reshape)	-	400×32	-	multiply_3[0][0]
37	batch_normalization_1(BatchNormalization)	-	400×32	-	reshape_7[0][0]
38	max_pooling1d_1(MaxPooling1D)	-	200×32	2×1	batch_normalization_1[0][0]
39	lstm(LSTM)	-	10	-	max_pooling1d_1[0][0]
40	flatten(Flatten)	-	10	-	lstm[0][0]
41	dropout(Dropout)	-	10	-	flatten[0][0]
42	dense_4(Dense)	-	20	-	dropout[0][0]
43	dense_5(Dense)	-	10	-	dense_4[0][0]
44	dense_6(Dense)	-	1	-	dense_5[0][0]

2.2 时间卷积网络结构

设定时间序列输入 $X = (x_1, x_2, \dots, x_T)$ 和输出 $Y = (y_1, y_2, \dots, y_T)$ ，采用时间卷积网络(Temporal Convolutional Network, TCN)^[13]实现对电磁时间序列的特征提取。TCN 网络是一种单向结构，其当前的输出只依据当前的数据和过去的数据计算得到，即 t 时刻的输出 y_t 仅与 x_t 和 x_{t-1} 有关，是一种严格按照时间顺序的模型，能够很好地提取时间序列特征。TCN 网络结构示意图如图 2 所示。

2.3 长短时记忆网络结构

设定时间序列输入 $X = (x_1, x_2, \dots, x_T)$ 、隐藏向量序列 $H = (h_1, h_2, \dots, h_T)$ ，其中 t 设置为 $1 \sim T$ 时刻。采用文献[14]

提出的 LSTM 结构实现对长电磁时间序列的时序特征提取。单个 LSTM 单元如图 3 所示。

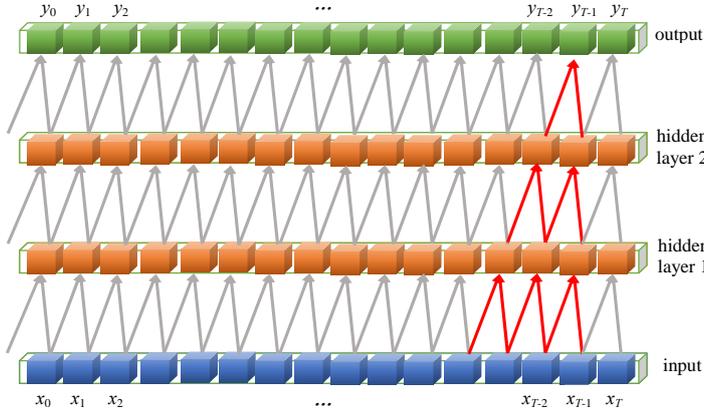


Fig.2 Architecture of a TCN
图 2 TCN 结构示意图

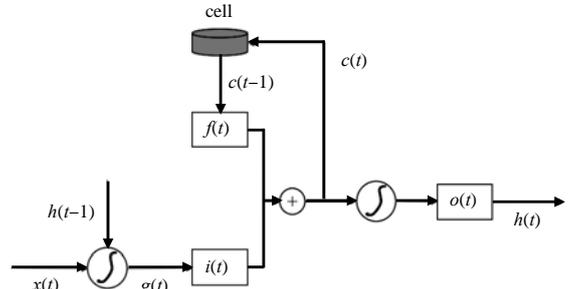


Fig.3 LSTM cell
图 3 长短期记忆单元

其状态值方程如下所示：

$$g(t) = \tanh[W_{ig}x(t) + W_{hc}h(t-1) + b_g] \quad (1)$$

$$i(t) = \sigma[W_{ii}x(t) + W_{hi}h(t-1) + b_i] \quad (2)$$

$$f(t) = \sigma[W_{if}x(t) + W_{hf}h(t-1) + b_f] \quad (3)$$

$$c(t) = f(t) * c(t-1) + i(t) * g(t) \quad (4)$$

$$o(t) = \sigma[W_{io}x(t) + W_{ho}h(t-1) + b_o] \quad (5)$$

$$h(t) = o(t) * \tanh(c(t)) \quad (6)$$

式中： σ 为 Sigmoid 函数； b 为偏置项； $x(t)$ 为同一时间步的前一层单元数据； $h(t-1)$ 为同一层单元前一个时间步的数据； $h(t)$ 为本单元的输出； $c(t)$ 为本单元当前时间步的隐藏状态； $i(t)$ 为控制 $x(t)$ 的输入门； $f(t)$ 为控制 $h(t-1)$ 的遗忘门； $o(t)$ 为控制 $h(t)$ 的输出门； W_{io} , W_{if} , W_{ii} , W_{ig} , W_{hc} , W_{hf} , W_{ho} 为权重矩阵。

状态转移过程为：

第一步：同一层单元前一个时间步的数据 $h(t-1)$ 与同一时间步的前一层单元数据 $x(t)$ 经过 \tanh 函数得到 $g(t)$ ，如式(1)所示；

第二步： $g(t)$ 经过输入门 $i(t)$ 得到 $g(t)i(t)$ ；

第三步：当前单元历史隐藏状态 $c(t-1)$ 经过遗忘门 $f(t)$ 得到 $f(t)c(t-1)$ ；

第四步： $g(t)i(t)$ 与 $f(t)c(t-1)$ 计算求和得到 $c(t)$ ，如式(4)所示；

第五步： $c(t)$ 经过 \tanh 函数，而后经过输出门 $o(t)$ 得到本单元当前时间步的输出 $h(t)$ ，如式(6)所示。

2.4 注意力机制模块

通道注意力模块将输入特征图分别进行最大池化和平均池化操作后，经过一个多层感知机得到 2 个输出特征并相加，再经过 Sigmoid 激活函数得到权重系数，与输入特征图相乘，得到各个特征通道的加权特征图，如式(7)所示。

$$M_c = \sigma\{MLP[AvgPool(X(t))] + MLP[MaxPool(X(t))]\} \quad (7)$$

通道注意力模块使用平均池化和最大池化 2 个池化操作来聚合特征映射的空间信息，其中，通过平均值池化获取全局每一个特征对权重系数的影响；通过最大池化获取对权重系数影响最大的特征。输入特征图通过通道注意力模块处理后，得到加权特征图，实现对重要特征的抽取。在本文考虑的电磁信息领域范畴，也可以通过通道注意力机制获取电磁数据中的关键特征，以增强特征表示。操作示意图如图 4 所示。

空间注意力模块将输入特征图分别进行最大池化和平均池化操作后，得到 2 个特征图并将其进行拼接操作，然后通过一个一维卷积操作进行空间降维，再经过 Sigmoid 激活函数得到权重系数，与输入特征图相乘，得到输出加权特征图，如式(8)所示。

$$M_s = \sigma\{Conv1D[AvgPoolX(t); MaxpoolX(t)]\} \quad (8)$$

类似的，空间注意力模块在通道维度上使用平均池化和最大池化 2 个池化操作来聚合特征映射的空间信

息，其中，通过平均值池化获取全局每一个通道对权重系数的影响；通过最大池化获取对权重系数影响最大的通道。输入特征图通过通道注意力模块处理后，获取加权特征图，实现对重要通道的抽取，即通过空间注意力机制获取电磁数据中关键特征的位置，以此增强特征表示。计算操作示意图如图 5 所示。

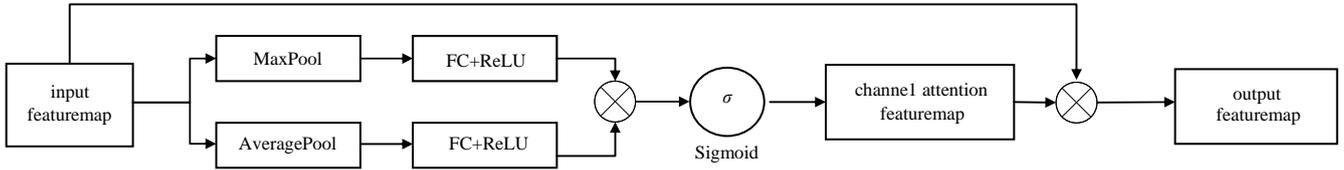


Fig.4 Working process of spatial attention
图 4 通道注意力模块计算操作示意图

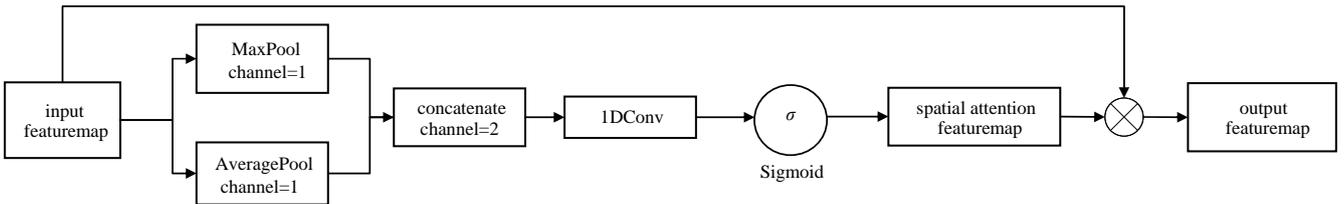


Fig.5 Working process of channel attention
图 5 空间注意力模块计算操作示意图

为充分利用通道注意力和空间注意力的优势，本文借鉴文献[15]的思路，将二者结合，加在模型的卷积网络，其结合顺序为先通道注意力后空间注意力。在前 2 个一维卷积层后使用组合注意力机制，通过 2 次组合注意力机制，将卷积层提取的特征图进行通道和空间 2 个维度的注意力图计算，得到加权特征图，然后再与输入特征图相乘，实现特征的自适应，增强数据关键特征表示。此外，为不影响 LSTM 提取时序特征依赖关系，在 LSTM 网络层后不再使用注意力机制对特征图进行加权操作。单个组合注意力机制模块结构如图 6 所示。

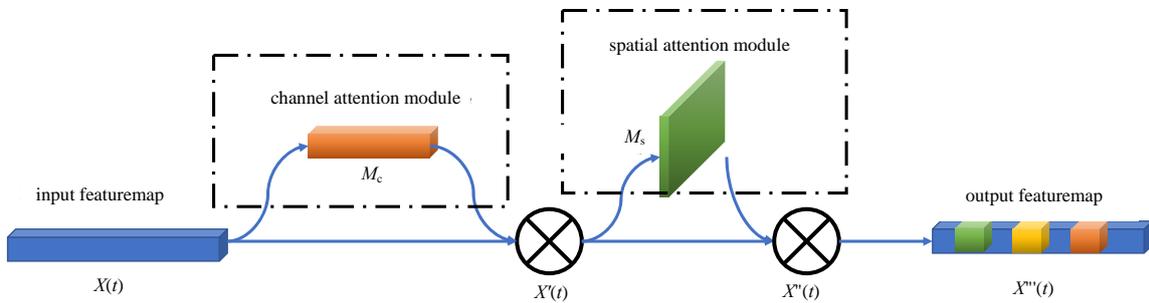


Fig.6 Diagram of the attention mechanism module
图 6 注意力机制模块结构示意图

由图 6 可以发现，添加注意力机制模块后，输入特征图 $X(t)$ 会先通过通道注意力模块 M_c 得到一个通道加权后的特征图 $X'(t)$ ，而后 $X'(t)$ 再经过空间注意力模块 M_s 得到一个空间加权后的特征图 $X''(t)$ ，具体计算为：

$$X'(t) = M_c[X(t)] \otimes X(t) \tag{9}$$

$$X''(t) = M_s[X'(t)] \otimes X'(t) \tag{10}$$

式中 M_c 与 M_s 中做了最大值池化与均值池化计算操作，减少了加权操作过程中特征信息的丢失。

3 实验验证

3.1 实验数据及处理

选取开源的心电图数据进行验证。由于心电图可视为一种低频的电磁信号，实验结果可以验证本文所提模型的有效性。具体包括 MIT-BIH 心电数据库中的 MIT-BIH Arrhythmia Database, MIT-BIH ST Change Database 以及欧盟 ST-T 心电数据库中的 European ST-T Database 实测数据集。

为全面评价算法性能，依据电磁时序数据特性，选择 3 个数据集集中的 MLIII, ECG, MLII 3 种导联方式数据分别进行异常检测实验，3 种导联方式数据示例如图 7~图 9 所示。

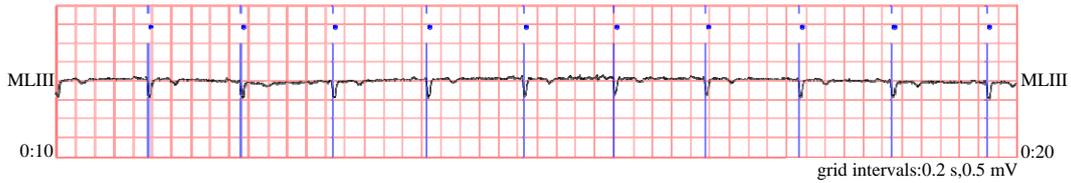


Fig.7 The MLIII signals data diagram of European ST-T database
图 7 European ST-T database 的 MLIII 导联方式数据示意图

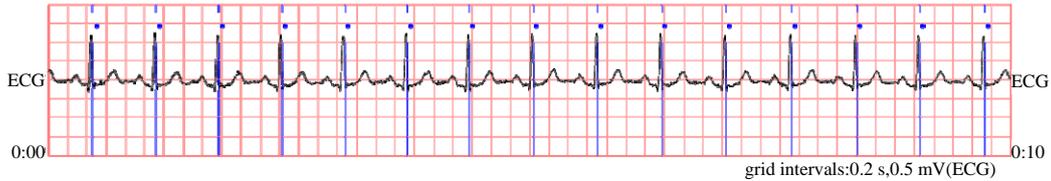


Fig.8 The ECG signals data diagram of MIT-BIH ST change database
图 8 MIT-BIH ST change database 的 ECG 导联方式数据示意图

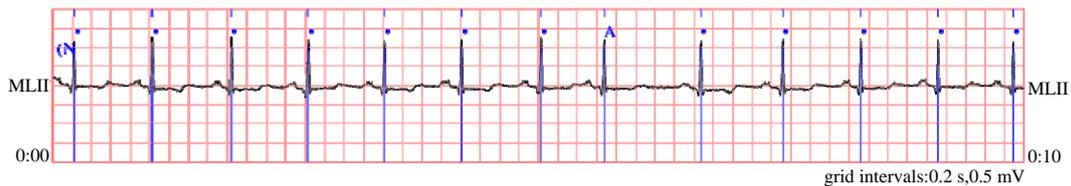


Fig.9 The MLII signals data diagram of MIT-BIH Arrhythmia database
图 9 MIT-BIH Arrhythmia database 的 MLII 导联方式数据示意图

选取数据中的 7 种异常情况，按照 80% 训练集和 20% 测试集划分数据集，经过处理后用于实验的数据集描述如表 2 所示。

表 2 实验数据集介绍
Table2 Data description

data set	European ST-T database	MIT-BIH ST change database	MIT-BIH Arrhythmia database
sample frequency	250 Hz	360 Hz	360 Hz
electrocardiogram lead	MLIII	ECG	MLII
data description	90 records of dynamic ECG with the same length, the duration of a single record is 2 h	28 records of ECG with different lengths	48 records of dynamic ECG with the same length for dual-channel, the duration for a single record is 0.5 h
data processing	10 s for each data fragment, each record containing 2 500 data points	10 s for each data fragment, each record containing 3 600 data points	
data label	"N" "F" "S" "T" "V" "s" "~"	"N" "Q" "S" "V"	"N" "L" "R" "A" " "
data size	33 758	6 925	8 443
training set	27 006	5 540	6 754
test set	6 751	1 385	1 689
the amount of data for abnormal data	5 477	606	2 522
abnormal rate/%	16.22	8.75	29.87

notes: the above "data label" types refer to different types of ECG records, specifying the "N" label as normal and the rest as abnormal

综上所述，选择的数据在数据量、数据长度、异常种类、数据异常率等方面组合多样，能够更加全面地评价算法模型的性能。

3.2 实验结果与分析

为更加直观地体现出本文算法的优异性能，选取 CNN, CNN-LSTM, CNN-LSTM-C(仅保留通道注意力模块)、CNN-LSTM-S(仅保留空间注意力模块) 4 个模型进行对比实验，各模型参数均与本文算法保持一致，在同等实验情况下进行性能比较。

上述所有模型均基于 keras 框架实现，使用 adam 优化器，学习率设置为 0.001。实验平台为 Ubuntu16.8 配置 NVIDIA 2020Ti 11 GB，基于 Python3.7 语言实现。

为对本文工作进行全面的评估，选取精确率(precision)、召回率(recall)、F1-score 和 ROC 曲线的线下面积(Receiver Operating Characteristic/Area Under the Curve, ROCAUC) 4 个指标评估本文算法。

F1 值：精确率和召回率的算术平均值，综合考虑了精确率与召回率，即：

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (11)$$

ROC 曲线是以假正类率(False Positive Rate, FPR)为横坐标、Recall 为纵坐标建立坐标系，依次连接每对(FPR, Recall)得到，如图 10 所示。精确率、召回率、F1-score 和 ROCAUC 4 个指标，其值越高，算法模型的性能越好。

实验结果如表 3~表 6 所示，对性能表现最佳的模型方法结果进行了加粗下划线表示，“Avg_P”表示在全部实验数据中模型方法所表现的平均性能，“Δ”表示 CNN-LSTM-CS 相比于对比模型方法的性能提升值。

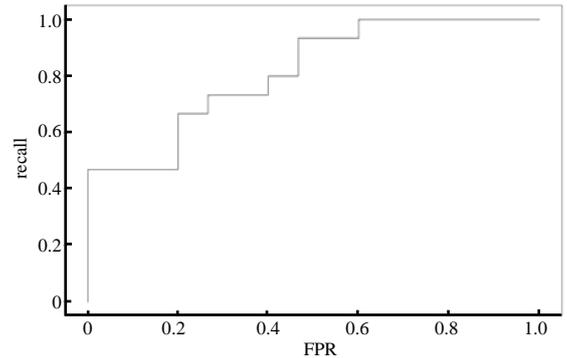


Fig.10 ROC curve
图 10 ROC 曲线

表 3 各模型方法精确率对比

Table3 Performance of precision of each model

data set	CNN	CNN-LSTM	CNN-LSTM-C	CNN-LSTM-S	CNN-LSTM-CS
European ST-T database	0.829	0.861	0.868	0.871	0.881
MIT-BIH ST change database	0.814	0.934	0.954	0.952	0.966
MIT-BIH Arrhythmia database	0.919	0.908	0.946	0.944	0.953
Avg_P	0.854	0.901	0.923	0.922	0.933
Δ/%	9.29	3.59	1.16	1.19	-

表 4 各模型方法召回率对比

Table4 Performance of recall of each model

data set	CNN	CNN-LSTM	CNN-LSTM-C	CNN-LSTM-S	CNN-LSTM-CS
European ST-T database	0.328	0.429	0.497	0.472	0.552
MIT-BIH ST change database	0.457	0.568	0.640	0.691	0.728
MIT-BIH Arrhythmia database	0.689	0.819	0.861	0.864	0.893
Avg_P	0.491	0.605	0.666	0.676	0.724
Δ/%	47.42	19.66	8.76	7.20	-

表 5 各模型方法 F1-score 对比

Table5 Performance of F1-score of each model

data set	CNN	CNN-LSTM	CNN-LSTM-C	CNN-LSTM-S	CNN-LSTM-CS
European ST-T database	0.381	0.508	0.502	0.428	0.532
MIT-BIH ST change database	0.547	0.757	0.779	0.711	0.915
MIT-BIH Arrhythmia database	0.564	0.855	0.911	0.907	0.926
Avg_P	0.497	0.707	0.731	0.682	0.791
Δ/%	59.05	11.93	8.26	15.98	-

表 6 各模型方法 ROCAUC 对比

Table6 Performance of ROCAUC of each model

data set	CNN	CNN-LSTM	CNN-LSTM-C	CNN-LSTM-S	CNN-LSTM-CS
European ST-T database	0.557	0.793	0.796	0.811	0.852
MIT-BIH ST change database	0.707	0.880	0.907	0.885	0.915
MIT-BIH Arrhythmia database	0.772	0.862	0.898	0.964	0.974
Avg_P	0.679	0.845	0.867	0.887	0.914
Δ/%	34.63	8.13	5.38	3.05	-

由实验结果可知，CNN-LSTM,CNN-LSTM-C,CNN-LSTM-S 以及 CNN-LSTM-CS 4 个模型方法相较于 CNN 模型方法，性能更优，说明 CNN 结合 LSTM 能够有效提取时序数据的时空特征，有利于原始时间序列的充分表达。CNN-LSTM-C,CNN-LSTM-S 和 CNN-LSTM-CS 3 个模型方法的性能均优于 CNN-LSTM 模型方法，说明在加入注意力机制模块后，实现了对时间序列数据的关键特征增强表示，有利于后续的检测识别。CNN-LSTM-CS 模型方法相较于 CNN-LSTM-C 以及 CNN-LSTM-S 2 个模型方法，在所有数据集上性能表现最优，且 CNN-LSTM-C 模型方法和 CNN-LSTM-S 模型方法在不同数据集表现出波动情况，说明不同数据集对通道和空间两个维度的注意力图需求不同。实际中，由于数据集在数据量、数据长度、异常种类、数据异常率等方面组合多样，单个的注意力机制不能有效适应不同种类的数据集，需根据不同的数据情况，综合考虑不同的特征权重对检测的重要程度。CNN-LSTM-CS 模型方法相较于 4 个对比算法，在所有数据集上性能表现最佳，其中，在各个数据的平均性能上，CNN-LSTM-CS 模型方法的平均精确率提升了 1.16%~9.29%，平均召回率提升了 7.20%~47.42%，平均 F1 值提升了 8.26%~59.05%，平均 ROCAUC 提升了 3.05%~34.63%，说明了 CNN-LSTM-CS 模型方法的有效性。

4 结论

时间序列异常检测对电磁数据挖掘分析具有重要价值, 本文充分考虑电磁数据的时空特征, 提出了一种基于注意力机制的时间序列异常检测方法。通过 CNN 和 LSTM 两种网络完成数据时间特征和空间特征的提取; 通过引入通道注意力机制与空间注意力机制实现对关键特征表示。此外, 本文使用原始数据, 模拟了实际电磁数据中掺杂着多种干扰数据的情景, 在多个组合实测数据集上验证了算法模型的优异性能。但心电图时序数据中的特征变量仅为一维, 真实电磁环境数据中同一目标在同一时刻具有多个维度的特征, 如何在复杂电磁环境条件下实现电磁时间序列的多元异常检测, 是未来研究工作的一个重要方向。

参考文献:

- [1] 李斌,李高云,陈亮. 电磁大数据挖掘应用研究[J]. 电子信息对抗技术, 2019,34(4):50-54,69. (LI Bin,LI Gaoyun,CHEN Liang. Research of electromagnetic space big data mining application[J]. Electronic Information Warfare Technology, 2019,34(4):50-54,69.)
- [2] MALHOTRA Pankaj,VIG Lovekesh,SHROFF Gautam,et al. Long Short Term Memory networks for anomaly detection in time series[C]// 23rd European Symposium on Artificial Neural Networks,Computational Intelligence and Machine Learning. Bruges,Belgium:[s.n.], 2015.
- [3] KIM J,KIM J,THITHU H L,et al. Long Short Term Memory recurrent neural network classifier for intrusion detection[C]// 2016 International Conference on Platform Technology and Service(PlatCon). Jeju,Korea(South):IEEE, 2016:1-5.
- [4] YIN Chuanlong,ZHU Yuefei,FEI Jinlong,et al. A deep learning approach for intrusion detection using recurrent neural networks[J]. IEEE Access, 2017(5):21954-21961.
- [5] ZHENG Yi,LIU Qi,CHEN Enhong,et al. Time series classification using multi-channels deep convolutional neural networks[C]// International Conference on Web-Age Information Management. [S.l.]:Springer, 2014:298-310.
- [6] YANG Jianbo,NGUYEN Minh Nhut,SAN Phyo Phyo,et al. Deep convolutional neural networks on multichannel time series for human activity recognition[C]// Proceeding of the IJCAI. Buenos Aires,Argentina:[s.n.], 2015:3995-4001.
- [7] CUI Zhicheng,CHEN Wenlin,CHEN Yixin. Multi-scale convolutional neural networks for time series classification[J/OL]. arXiv:1603.06995, 2016.
- [8] RAJPURKAR P,HANNUN A Y,HAGHPANAHI M,et al. Cardiologist-level arrhythmia detection with convolutional neural networks[J/OL]. arXiv:1707.01836, 2017.
- [9] DING N,GAO H B,BU H Y,et al. Multivariate time series driven real time anomaly detection based on Bayesian network[J]. Sensors, 2018,18(10):3367.
- [10] 郑育靖,何强,张长伦,等. 基于 GRU-Attention 的无监督多变量时间序列异常检测[J]. 山西大学学报(自然科学版), 2020,43(4):756-764. (ZHENG Yujing,HE Qiang,ZHANG Changlun,et al. GRU-Attention based unsupervised multivariate time series anomaly detection[J]. Journal of Shanxi University(Natural Science Edition), 2020,43(4):756-764.)
- [11] WEN Tailai,KEYES R. Time series anomaly detection using convolutional neural networks and transfer learning[J/OL]. arXiv:1905.13628, 2019.
- [12] 安晶,艾萍,徐森,等. 一种基于一维卷积神经网络的旋转机械智能故障诊断方法[J]. 南京大学学报(自然科学版), 2019, 55(1):133-142. (AN Jing,AI Ping,XU Sen,et al. An intelligent fault diagnosis method for rotating machinery based on one dimensional convolution neural network[J]. Journal of Nanjing University(Natural Science Edition), 2019,55(1):133-142.)
- [13] BAI S,KOLTER J Z,KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J/OL]. arXiv:1803.01271, 2018.
- [14] HOCHREITER S,SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997,9(8):1735-1780.
- [15] WOO S,PARK J,LEE J Y,et al. Cham:convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision(ECCV). [S.l.]:Springer, 2018:3-19.

作者简介:

王翔(1985-), 男, 副教授, 硕士生导师, 主要研究方向为信号处理、模式识别等.email:christoperwx@163.com.

邓文(1997-), 男, 在读硕士研究生, 主要研究方向为信号处理、模式识别等.

刘世雄(1994-), 男, 在读硕士研究生, 主要研究方向为时间序列分析、时空数据挖掘等.

黄知涛(1976-), 男, 教授, 博士生导师, 主要研究方向为信号处理、模式识别等.