

基于一维残差卷积神经网络的 Pi2 脉动识别模型*

张怡悦^{1,2} 邹自明^{1,3} 方少峰^{1,3}

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

3(国家空间科学数据中心 北京 100190)

摘要 Pi2 脉动是一种不规则的超低频波 (Ultra-Low Frequency, ULF), 是磁层与电离层耦合的重要瞬态响应, 其发生与亚暴爆发有密切的关系. Pi2 脉动作为地球磁层中的一种扰动现象, 其发生信号隐藏在地磁场分量观测数据中. 面对持续增长的观测数据量, 如何有效地判断某段地磁场分量观测数据中是否有 Pi2 脉动发生, 是构建 Pi2 脉动识别模型的关键. 利用子午工程磁通门磁力仪观测的地磁场分量数据, 基于一维残差卷积神经网络 (One-Dimensional Residual Convolutional Neural Network, 1D-ResCNN), 构建了一个端到端的 Pi2 脉动识别模型, 用于判别某段地磁场分量观测数据中是否有 Pi2 脉动发生. 实验结果表明, 该模型与现有公开发表的 Pi2 脉动机器学习识别模型相比, 具有更高的识别准确率和更低的虚报率、漏报率.

关键词 Pi2 脉动, Pi2 脉动识别模型, 一维残差卷积神经网络

中图分类号 P353

Identification Model of Pi2 Pulsation Based on One-dimensional Residual Convolutional Neural Network

ZHANG Yiyue^{1,2} ZOU Ziming^{1,3} FANG Shaofeng^{1,3}

1(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2(University of Chinese Academy of Sciences, Beijing 100049)

3(National Space Science Data Center, Beijing 100190)

Abstract Pi2 pulsations are irregular ultra-low frequency waves, representing a significant transient response to the coupling between the magnetosphere and ionosphere. Their occurrence is associated with

* 国家重点研发计划项目 (2022YFF0711400) 和中国科学院网信专项 (CAS-WX2022SF-0103) 共同资助

2024-01-30 收到原稿, 2024-04-28 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

onset of substorms. As a disturbance phenomenon in the Earth's magnetosphere, the occurrence signal of Pi2 pulsations is hidden within the observation data of geomagnetic field components. Addressing the increasing amount of observation data, how to efficiently determine whether Pi2 pulsation has occurred in a segment of geomagnetic field component observational data is the key to build a Pi2 pulsation identification model. Based on the time series observation data of the FGM from the Chinese Meridian Project and One-Dimensional Residual Convolutional Neural Network (1D-ResCNN), this paper establishes an end-to-end Pi2 pulsation identification model. This model can distinguish whether Pi2 pulsation occurs in the observation data of a certain geomagnetic field component. Experimental results show that this model has higher recognition accuracy and lower false positive rate and false negative rate than the existing Pi2 pulsation machine learning identification model.

Key words Pi2 pulsations, Pi2 pulsation identification model, One-dimensional residual convolutional neural network

0 引言

地球磁层中存在不同类型的等离子体波, 超低频波 (Ultra-Low Frequency, ULF) 是地球磁层中频率最低的一种等离子体波. 根据波动形态与周期的不同, 超低频波被分类为规则脉动 (Pc1~Pc5) 和不规则脉动 (Pi1~Pi2)^[1]. 其中 Pi2 脉动是一种周期范围在 40~150 s, 频率范围在 6.7~25 mHz, 波形为衰减振荡列的不规则脉动^[1], 其持续时间通常为 5~10 min^[2]. Pi2 脉动可以出现在夜侧的所有纬度, 是一种全球性现象. 作为地球磁层中的一个复杂现象, 其产生和传播与许多太阳活动及地磁活动密切相关. Pi2 脉动最重要的特性之一是与磁层亚暴爆发的起始具有明确的相关性^[3-5]. 早期, Pi2 脉动被认为是磁层亚暴的伴随现象^[3], 常被作为亚暴发生的指示器. 但随着在非亚暴期间观察到 Pi2 脉动的发生, 与亚暴无关的 Pi2 脉动产生机制被提出^[6]. 目前对 Pi2 脉动产生机制及与磁层扰动的相互作用尚未达成共识.

Pi2 脉动发生信号无法直接获取, 需要从地磁场分量观测数据中提取. 为了实现对 Pi2 脉动的识别, 通常使用傅里叶变换^[5,7] 和小波变换^[8,9] 两种时频分析方法. 傅里叶变换能够有效揭示信号的周期性特征, 但在处理 Pi2 脉动这类非平稳信号时受到一定限制. 相比之下, 小波变换提供了一种多尺度分析框架, 能够灵活地捕捉信号在不同时间和频率尺度上的细节^[10]. Nosé等^[8] 提出了一种基于离散小波变换分析的 Pi2 脉动检测算法, 该算法夜侧的成功探测率为 83.4%, 日侧仅为 26.5%. 小波变换的识别效果与小波基函数的选取以及人为设定的阈值标准有关, 这些因

素的选择依赖于专业知识和经验. 自 20 世纪 90 年代以来, 机器学习被广泛应用到空间物理领域的研究上. 机器学习旨在创建一种通用方法, 自动学习数据的特征和分布, 从数据中提取有价值的模式, 对专家经验知识依赖较少. 1997 年 Sutcliffe^[11] 结合傅里叶变换 (Fourier Transform, FT) 和多层感知机 (Multi-Layer Perceptron, MLP) 识别地面磁强计中的 Pi2 脉动. 2021 年 Rabie 等^[12] 结合离散小波变换 (Discrete Wavelet Transform, DWT) 和卷积神经网络 (Convolutional Neural Network, CNN), 实现了背景噪声和微脉动 (Pi2, Pc3, Pc4) 的分类. 另外, 机器学习方法也被应用至 Pc3 和 Pc5 的识别^[13-16]. 由此可见, 机器学习方法可以适用于包括 Pi2 脉动在内的超低频波的识别, 并取得了初步的成果. 然而, Sutcliffe^[11] 在构建 Pi2 脉动识别模型仅用了 100 个样本数据. Rabie 等^[12] 通过人工挑选, 以 1:1 的比例构建了正负样本数据集, 改变了脉动事件的数据分布. 这两种数据集构造方式可能会影响模型的泛化性和在符合真实分布的数据上的表现能力. 此外, 两种模型在数据预处理时, 依赖于传统时频分析进行时序特征提取.

为了实现对不同地磁活动条件下 Pi2 脉动的识别, 本文利用子午工程磁通门磁力仪记录的 2011—2021 年时间序列观测数据, 构建了一个基于一维残差卷积神经网络的 Pi2 脉动机器识别模型. 将一定时间范围内的原始磁力仪观测数据作为模型输入, 输出对该段时间范围内有无 Pi2 脉动发生的识别结果. 该模型实现了 Pi2 脉动的端到端识别, 无须预先对数据进行时序特征提取, 且具有更高的识别准确率.

1 数据集

1.1 数据来源

使用子午工程漠河站 2011—2021 年磁通门磁力仪记录的秒采样地磁场 H 分量^[17,18] 观测数据. 漠河站的台站编码为 MHT, 地磁坐标为 ($48^{\circ}50'$, $195^{\circ}28'$). 磁通门磁力仪观测数据中存在着缺省值和异常值, 针对单点缺省或异常情况, 采用线性插值的方法进行补全, 针对连续缺省或异常情况, 进行舍弃处理.

1.2 Pi2 脉动事件筛选

采用监督学习方法构建 Pi2 脉动识别模型. 为了构造用于模型训练的标注样本集, 需要从磁力仪观测数据中筛选出 Pi2 脉动事件, 并由领域专家进行验证. 在筛选 Pi2 脉动事件过程中, 对每日 H 分量进行高通

滤波 (截止频率为 6 mHz)^[19], 并利用连续小波变换计算滤波后 H 分量的小波功率谱. 小波基函数选取非正交 Morlet 小波. 同时, 为尽量避免小波功率谱边缘效应的影响, 在进行连续小波变换前, 将该天的磁力仪观测数据向前后各扩展一天^[19]. 沿时间维度扫描 Pi2 脉动频率范围内 (6.7~25 mHz) 的小波功率谱, 筛选出小波功率超过预定义阈值的时刻, 将其标记为候选事件. 阈值选取为 50 倍的背景噪声, 背景噪声由地磁活动平静时期的小波功率谱计算所得, 倍数的选取由 Pi2 脉动发生时期的小波功率与平静时期的小波功率之比确定. 事件的起始时间定义为功率超过阈值的第一个时刻^[9], 结束时间定义为功率恢复到阈值以下的最后一刻. 磁场时间序列中的阶跃变化和尖峰也将导致功率的突然增强, 但并没有表现出 Pi2 脉动现象的典型特征. 图 1 给出了 2019 年 9 月 24 日




图 1 候选事件中的非 Pi2 脉动事件举例 (2019 年 9 月 24 日 00:00 UT—01:00 UT 漠河站磁力仪观测数据)

Fig. 1 Example of non-Pi2 pulsation event in candidate events (MHT magnetometer data during 00:00 UT—01:00 UT on 24 September 2019)

00:00 UT—01:00 UT 漠河站磁力仪观测数据, 观察图 1(a)(b) 可以发现, 该段磁力仪观测数据不满足 Pi2 脉动的波形, 持续时间仅为 1~2 min; 图 1(c) 中出现了功率的突然增强, 被小波分析方法筛选为候选事件, 图 1(d)~(f) 中的空间环境参数均变化平缓. 因此, 认为尖峰的出现可能是由于仪器误差导致的. 小波分析筛选得到的候选事件中存在着非 Pi2 脉动事件, 因此需要对候选事件进行进一步的筛查. 确定是否为 Pi2 脉动事件的标准为: ①持续时间 ≥ 5 min^[2], ②磁力仪观测数据的波形呈不规则的衰减振荡列^[1], ③相邻时间点的振幅变化平缓 (< 1 nT)^[14]. 依据以上标准, 对候选事件进行人工筛查, 得到最终的 Pi2 脉动事件筛选结果. 一个典型的 Pi2 脉动事件如图 2 所示. 图 2 给出了 2011 年 6 月 1 日在漠河站观测到的一个 Pi2 脉动事件, Pi2 脉动的开始时间大约为

16:37 UT, 结束时间大约为 16:45 UT. 根据上述方法对漠河站 2011—2021 年的 Pi2 脉动事件进行筛选^[20], 根据筛选结果进行数据标注及样本构造.

1.3 数据标注及样本构造

Pi2 脉动识别模型的输入为一段磁力仪观测数据, 因此, 需要将连续的磁力仪观测数据切分为等长的时间窗口, 每个窗口代表一个时间序列样本. 根据筛选出的 Pi2 脉动事件, 对每个窗口进行标注, 得到带有标签的样本. 若当前窗口内的磁力仪观测数据中有 Pi2 脉动发生, 则标注为正样本, 标签为 1; 否则标注为负样本, 标签为 0.

为了确保时间窗口的长度能够有效覆盖 Pi2 脉动事件的持续时间, 对 1.2 节筛选出的 Pi2 脉动事件持续时间进行了统计分析, 如图 3 所示. 其中 66% 的 Pi2 脉动事件持续时间小于等于 10 min, 90% 的




图 2 候选事件中的 Pi2 脉动事件举例 (2011 年 6 月 1 日 16:00 UT—17:00 UT 漠河站磁力仪观测数据)

Fig. 2 Example of Pi2 pulsation event in candidate events (MHT magnetometer data during 16:00 UT—17:00 UT on 1 June 2011)

Pi2 脉动事件持续时间在 20 min 以内, 97% 的 Pi2 脉动事件持续时间不超过 40 min. Pi2 脉动的持续时间为 5~10 min^[2], 但由于本文在进行事件筛选时, 并未进一步区分孤立事件和多个连续事件, 将多个连续事件视为一个 Pi2 脉动事件, 因此存在许多持续时间大于 10 min 的 Pi2 脉动事件.

分别选取大小为 10, 20, 40 min 的窗口对磁力仪观测数据进行切分, 得到对应长度为 600, 1200, 2400 的磁力仪观测数据样本. 根据当前时间范围内有无 Pi2 脉动发生, 将磁力仪观测数据样本人工标注为正样本和负样本.

Pi2 脉动作为一种短周期磁场扰动变化, 与太阳活动密切相关. 太阳活动的强弱程度可根据太阳表面黑子数的数量进行评估. 中国气象局发布的太阳活动水平分级标准按太阳黑子相对数的取值范围, 将太阳




图 3 Pi2 脉动事件持续时间的统计结果
Fig. 3 Statistical results of Pi2 pulsation events duration

活动水平分为很低、低、中、高和很高^[21]. 本章依据该标准, 将太阳活动水平划分为低、中、高三个等级. 太阳黑子相对数小于 50 时, 认为太阳活动水平低; 太阳黑子相对数在 50~100 时, 认为太阳活动水平中等; 太阳黑子相对数大于等于 100 时, 认为太阳活动水平高. 根据 SILSO 提供的每日太阳黑子数^{*}, 对 2011—2021 年每日的太阳活动水平等级进行统计, 如图 4(a) 所示. 横坐标表示年份, 纵坐标表示太阳活动处于当前水平的总天数. 将 11 年的磁力仪观测数据随机划分为训练集、验证集和测试集, 训练集包括 2012, 2014, 2016, 2018 和 2020 年的数据; 验证集包括 2013 年和 2017 年的数据; 测试集包括 2011, 2015, 2019 和 2021 年的数据. 对训练集、验证集和测试集中, 处于不同太阳活动水平的天数进行统计. 由图 4(b) 可知, 三种数据集中均包含了处于不同太阳活动水平的磁力仪观测数据. 使用不同长度窗口进行切分, 得到的训练集、验证集和测试集的正负样本分布情况如表 1 所示, 通过这种方式划分的数据集记为 Dataset1.

同时, 考虑一种完全随机划分方法. 将 2011—2021 年的数据打乱, 从中随机抽取 30% 的数据作为测试集, 用于评估最终模型的识别能力; 对其余数据按 7:3 的比例, 随机划分出训练集和验证集, 分别用于模型的训练和超参数调整. 完全随机划分方法得到的数据集记为 Dataset2, 其正负样本分布情况如表 2 所示.




图 4 太阳活动水平统计情况
Fig. 4 Statistics of solar activity levels

* Source: WDC-SILSO, Royal Observatory of Belgium, Brussels. <http://www.sidc.be/SILSO/>

表 1 漠河站 Dataset1 的正负样本分布情况

Table 1 Positive and negative sample distribution of Dataset1 at MHT

窗口长度/min	训练集		验证集		测试集	
	正样本	负样本	正样本	负样本	正样本	负样本
10	13320	216936	6524	89668	10061	146323
20	10855	104273	5223	42873	8071	70121
40	8477	49087	3977	20071	6195	32901

表 2 漠河站 Dataset2 的正负样本分布情况

Table 2 Positive and negative sample distribution of Dataset2 at MHT

窗口长度/min	训练集		验证集		测试集	
	正样本	负样本	正样本	负样本	正样本	负样本
10	14662	221925	6232	95163	9011	135839
20	11737	106556	5170	45528	7242	65183
40	9188	49958	3844	21505	5617	30596

2 Pi2 脉动识别的建模

地面台站磁通门磁力仪观测数据是随时间变化的随机变量, 即时间序列. 对一定时间范围内的磁力仪观测数据中是否有 Pi2 脉动发生的识别, 构成了一个时间序列分类 (Time Series Classification, TSC) 任务. 本文使用一个端到端的判别式分类模型, 实现对 Pi2 脉动的机器识别.

2.1 网络结构

自卷积神经网络 (Convolutional Neural Network, CNN) 在计算机视觉领域的图像分类任务中取得巨大成功以来, CNN 模型被尝试应用到时间序列分类任务中, 并获得了不错的成果. 本文构建了一个一维 CNN 模型用于将原始磁力仪观测数据映射到类别概率分布, 并在该 CNN 模型的卷积块中引入了残差模块 (Residual Block, ResBlock)^[22]. 残差模块的应用使得模型可以学习数据中更通用的特征, 提高了模型的泛化能力, 其结构如图 5 所示. 残差模块 ResBlock 中包含两个卷积核长度为 3 的一维卷积层 (Conv1d), 每个卷积层后面都有一个批归一化层 (Batch Normalization, BN) 和一个 ReLU 激活层. 残差操作是一种恒等映射的跳跃连接 (skip connection), 将跳过两个卷积层, 在最终的 ReLU 激活函数前添加输入. 跳跃连接要求两个卷积层的输出与输入具有相同的形状, 以便直接相加. 直接相加的残差模

块 ResBlock1 如图 5(a) 所示; 若形状不同, 则需额外引入一个卷积核长度为 1 的一维卷积层, 用于将输入转换为加法运算所需的形状, 具有线性变换的残差模块 ResBlock2 如图 5(b) 所示. 含残差模块 ResBlock 的一维 CNN 模型记为 1D-ResCNN, 其网络结构如图 6 所示. 输入的时间序列首先经过一个一维卷积层 (卷积核长度为 5, 个数为 64) 以及批归一化层和 ReLU 层, 再通过最大池化层 (Max Pooling) 对特征进行压缩和降维. 然后通过 8 个残差模块 ResBlock (对应的卷积核长度及个数见图 6), 在每一个 ResBlock 后均有一个丢弃率设置为 0.2 的 Dropout 层, 用于避免模型过拟合. 最后一个残差卷积块的输出经过全局平均池化层 (Global Average Pooling, GAP) 和 Dropout 层后, 传递给由全连接层 (Full Connection, FC) 和 Softmax 层构成的分类器. 模型输出被分类器分为 2 类, 分别对应当前输入的磁力仪观测数据被分类为类别 0 (没有 Pi2 脉动发生) 的概率 P_0 和被分类为类别 1 (有 Pi2 脉动发生) 的概率 P_1 , P_0 和 P_1 的取值范围在 $[0, 1]$, 且 $P_0 + P_1 = 1$.

2.2 模型训练

模型训练及推理流程如图 7 所示, X_i 为直接切分后的磁力仪观测数据样本 (单变量时间序列), Y_i 为样本对应标签. 为避免数值不稳定带来的影响, 加速模型收敛效果, 还需对窗口内的磁力仪观测数据进行最大最小值特征缩放, 将数据归一化到 $[0, 1]$. 特征缩放




图 5 直接相加的残差模块 ResBlock1 (a) 和具有线性变换的残差模块 ResBlock2 (b)

Fig. 5 ResBlock1 with direct addition (a) and ResBlock2 with linearly transformation to match the dimension (b)




图 6 1D-ResCNN 网络结构

Fig. 6 Network architecture of 1D-ResCNN




图 7 模型训练及推理流程

Fig. 7 Diagram of model training and inference process

后的磁力仪观测数据为 1D-ResCNN 模型的输入, 长度为 N (切分窗口大小). 使用训练集和验证集对 1D-ResCNN 模型进行训练和调参, 得到最终的识别模型. 将训练好的识别模型应用到测试集上, 依据真实

标签评估模型识别效果.

使用中国科学院国家空间科学中心公共技术服务中心空间科学数据融合计算平台提供的计算服务 (GPU: Tesla K80), 将交叉熵损失函数作为模型的损

失函数, 参数更新选取 Adam 优化器, 初始学习率设置为 0.001, 并动态调整学习率. 当模型性能在 3 个周期内没有改善时, 学习率会按照 0.1 的比例降低. 每次迭代中用于计算梯度的样本数量 (Batch Size) 选取为 256. 在模型训练过程中, 通过监测模型在训练集和验证集上的损失函数值变化, 判断模型的拟合情况. 1D-ResCNN 模型的训练损失和验证损失变化情况如图 8 所示, 随着训练轮次的增加, 模型在 Dataset1 和 Dataset2 上的平均损失值趋于平缓. 当模型的验证损失连续 20 次没有显著下降时, 停止训练, 防止过拟合. 选取所有训练轮次中验证损失最小的轮次对应的参数, 作为模型的最优参数, 用于在测试集上评估模型性能.

2.3 模型决策策略

完成训练的 1D-ResCNN 模型将输出两个概率值, 分别对应属于类别 0 (没有 Pi2 脉动发生) 的概率 P_0 和属于类别 1 (有 Pi2 脉动发生) 的概率 P_1 . 定义两种针对模型输出的决策策略, 用于判定模型将当前时间范围内判别为有 Pi2 脉动发生, 还是没有 Pi2 脉动发生.

策略 1 若 $P_1 \geq P_0$, 则模型认为在当前时间范围内的磁力仪观测数据中有 Pi2 脉动发生; 若 $P_1 < P_0$, 则模型认为在当前时间范围内的磁力仪观测数据中没有 Pi2 脉动发生.

策略 2 设定一个超参数概率阈值 p , 若 $P_1 \geq p$, 则模型认为在当前时间范围内的磁力仪观测数据中有 Pi2 脉动发生, 否则认为没有 Pi2 脉动发生. 阈值 p 的设置依赖于验证集的结果, 检查阈值 p 取值为 $[0, 1]$ 时验证集的 F_1 值, 确定 F_1 值最高时对应的阈值,

将该值作为模型应用到测试集上的概率阈值 p .

3 实验结果分析

3.1 评价指标

对一定时间范围内是否有 Pi2 脉动发生的识别可视为一个二分类任务, 若当前时间范围内有 Pi2 脉动发生, 则该段磁力仪观测数据样本为正例; 若没有 Pi2 脉动发生, 则该段磁力仪观测数据样本为负例. 二分类的混淆矩阵如表 3 所示.

本文选取准确率 (A), 虚报率 (False Positive Rate, FPR, R_{FP})、漏报率 (False Negative Rate, FNR, R_{FN}) 以及 F_1 值作为模型评价指标, 表达式如下:

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}}, \quad (1)$$

$$R_{FP} = \frac{N_{FP}}{N_{FP} + N_{TN}}, \quad (2)$$

$$R_{FN} = \frac{N_{FN}}{N_{FN} + N_{TP}}, \quad (3)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (4)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (5)$$

$$F_1 = \frac{2PR}{P + R} = \frac{2N_{TP}}{2N_{TP} + N_{FN} + N_{FP}}. \quad (6)$$

其中, N_{TP} 表示将正例正确预测为正例的数量, N_{FP} 表示将负例错误预测为正例的数量, N_{FN} 表示将正例错误预测为负例的数量, N_{TN} 表示将负例正确预测为负例的数量.




图 8 1D-ResCNN 模型训练过程中的损失函数值变化

Fig. 8 Variation of loss function value during the training process of 1D-ResCNN model

由表 1 可知, 负样本数量远多于正样本数量, 存在样本分布不均衡问题, 准确率无法全面反映模型的识别性能, 需要进一步考虑虚报率、漏报率和 F_1 值. 虚报表示模型将没有 Pi2 脉动发生的磁力仪观测数据误判为有 Pi2 脉动发生. 漏报表示模型将有 Pi2 脉动发生的磁力仪观测数据误判为没有 Pi2 脉动发生. F_1 值适用于样本分布不均衡的情况, 是精确率 P 和召回率 R 的调和平均值, 取值为 $[0, 1]$. 准确率 A 和 F_1 值越高, 虚报率 R_{FP} 和漏报率 R_{FN} 越低, 表示模型识别效果越好.

3.2 实验结果分析

将本文提出的模型与现有公开发表的 Pi2 脉动机器学习识别模型进行对比. 现有两种模型: 一是 Sutcliffe^[11] 提出的结合傅里叶变换的多层感知机模型; 二是 Rabie 等^[12] 提出的结合离散小波变换的卷积神经网络模型. 使用 3.1 节所述指标评估不同模型的优劣, 并分析使用不同长度的窗口切分数据以及不同决策策略对三种模型识别效果的影响.

将策略 1 作为模型决策策略, 本文模型与现有两种 Pi2 脉动机器学习识别模型在 Dataset1 和 Dataset2 测试集上的实验结果对比如表 4 所示, 表格

内每个单元格以 Dataset1 结果和 Dataset2 结果的形式记录了两个不同数据集上的模型性能. 实验结果显示, 模型在两种数据集上的性能表现无显著差异. 在使用不同长度窗口切分数据的情况下, 本文提出的 1D-ResCNN 模型在测试集上的准确率 A 和 F_1 值均最高, 漏报率 R_{FN} 最低. 三种模型的准确率 A 和虚报率接近, 但漏报率和 F_1 值差距明显. 1D-ResCNN 模型的准确率相较于 Sutcliffe^[11] 的方法 (FT+MLP) 和 Rabie 等^[12] 的方法 (DWT+CNN) 分别平均上升了 4% 和 3%, 漏报率分别平均下降了 33%~35% 和 36%~40%, F_1 值分别平均提升了 0.26 和 0.24. Sutcliffe^[11] 和 Rabie 等^[12] 的模型识别结果与窗口长度选择有较大的关系. 当窗口长度为 10 min 和 20 min 时, FT+MLP 模型的 F_1 值逐步提升, 漏报率 R_{FN} 下降. 但当窗口长度增大到 40 min 时, F_1 值出现明显下降, 漏报率上升. FT+MLP 模型将大量真实有 Pi2 脉动发生的磁力仪观测数据预测为没有 Pi2 脉动发生. 随着窗口长度的增加, DWT+CNN 模型的漏报率 R_{FN} 大幅下降, F_1 值提升. 相较而言, 1D-ResCNN 模型在不同窗口长度下的 4 种评价指标结果接近, F_1 值均在 0.82 及以上, 可认为该模型在对窗口长度的选择上具有更好的鲁棒性.

将策略 2 作为模型决策策略, 选取不同的超参数概率阈值 p 和不同的窗口长度 cut 时, 三种模型在 Dataset1 验证集上的 F_1 值如图 9 所示, 横轴为概率阈值 $p \in [0, 1]$, 纵轴为 F_1 值. 随着阈值 p 的增大, F_1 值的整体趋势为先增大再减小, 策略 2 取 F_1 值最大时对应的阈值 p 作为测试集的决策阈值. 使用策略 2 的三

表 3 混淆矩阵

Table 3 Confusion matrix

预测类别	真实标签	
	正例	正例
正例	TP	FP
负例	FN	TN

表 4 使用策略 1 的不同模型在 Dataset1 和 Dataset2 测试集上的实验结果

Table 4 Experimental results on testing Dataset1 and Dataset2 of different models with Decision 1

模型	窗口长度/min	准确率/(%)	虚报率/(%)	漏报率/(%)	F_1 值
FT+MLP ^[11]	10	95.63, 95.76	1.05, 0.98	52.68, 53.39	0.58, 0.58
	20	93.75, 94.04	1.73, 1.69	45.58, 44.35	0.64, 0.65
	40	88.41, 88.45	2.77, 2.27	58.39, 62.08	0.5, 0.50
DWT+CNN ^[12]	10	95.90, 95.89	0.06, 0.05	62.83, 65.28	0.54, 0.51
	20	93.89, 94.33	0.11, 0.18	58.26, 55.12	0.58, 0.61
	40	92.43, 91.59	0.69, 0.21	44.10, 53.07	0.70, 0.63
1D-ResCNN(本文方法)	10	97.84, 97.86	0.83, 0.96	21.64, 19.80	0.82, 0.82
	20	96.89, 97.13	1.41, 1.23	17.85, 17.70	0.85, 0.85
	40	95.71, 95.82	1.85, 1.82	17.21, 16.98	0.86, 0.86




图9 不同窗口长度和概率阈值 p 的情况下三种模型在验证集上的 F_1 值

Fig. 9 F_1 -score of different models on validation datasets with different window cut and threshold p

种模型在 Dataset1 和 Dataset2 测试集上的实验结果如表5所示, 表5的格式与表4相同. 与使用策略1相比, FT+MLP模型的虚报率平均上升了约3%, 漏报率平均下降了约15%, F_1 值平均提升了约0.05; DWT+CNN模型的虚报率平均上升了约2%, 漏报

率显著下降, 平均下降了约35%, F_1 值平均提升了约0.19. 由此可见, 超参数概率阈值 p 的选择在一定程度上影响了这两种模型的识别效果, 需要为其选择合适的概率阈值 p , 以提升模型对磁力仪观测数据中是否有Pi2脉动发生的综合识别能力. 而本文提出的1D-ResCNN模型在使用两种不同的决策策略时, 可得到接近的结果. 观察图9(c)可知, 1D-ResCNN模型在验证集上的 F_1 值随阈值 p 的变化较为平缓, 可认为在较宽范围的阈值 p 上均可得到水平相当的识别结果, 即模型在不同阈值的选择上具有良好的鲁棒性. 在使用策略2的情况下, 1D-ResCNN模型的虚报率和漏报率均小于另外两种模型, 准确率和 F_1 值均大于另外两种模型, 因此综合认为本文提出的1D-ResCNN模型对Pi2脉动的识别能力要优于现有Pi2脉动机器学习模型.

为验证1D-ResCNN模型在不同台站上的有效性, 将该模型应用至不同纬度台站的磁通门磁力仪观测数据上. 选取的台站为琼中站(QZT)、邵阳站(SYT)、马陵山站(MLS)和农安站(NAT), 4个台站的纬度依次增高. 按1.2节所述方法从4个台站磁力仪观测数据中筛选出Pi2脉动事件, 依据1.3节所述方法构造样本. 训练集选取2013年和2017年的数据; 测试集与漠河站Dataset1测试集选取的年份相同, 为2011, 2015, 2019, 2021年. 从训练集中随机选取30%的数据, 作为验证集, 用于模型的交叉验证. 使用长度为40 min的窗口对数据进行切分, 构造正负样本. 4个台站的基本信息及正负样本分布情况如表6所示.

分别使用4个台站的数据集对漠河站训练得到的模型进行微调, 采用策略1作为模型决策策略, 测试集上的实验结果如表7所示. 除琼中站的准确率 A 和 F_1 值较低、虚报率 R_{FP} 较高外, 其他台站评价指标的结果接近, F_1 值大于等于0.8. 认为本文提出的1D-ResCNN模型可应用在不同纬度台站的磁力仪观测数据上. 琼中站的实验结果相较其他台站存在虚报率较高的情况, 其原因可能在于Pi2脉动在低纬度地区的振幅较小, 模型对振幅较小的Pi2脉动与背景噪声的区分能力较差.

3.3 模型能力评价

为了进一步对模型进行评估, 分别选取模型正确识别出来的样本、虚报样本和漏报样本进行分析.

表 5 使用策略 2 的不同模型在 Dataset1 和 Dataset2 测试集上的实验结果

Table 5 Experimental results on testing Dataset1 and Dataset2 of different models with Decision2

模型	窗口长度/min	决策阈值	准确率/(%)	虚报率/(%)	漏报率/(%)	F_1 值
FT+MLP ^[11]	10	0.29, 0.25	95.24, 95.25	2.43, 2.67	38.72, 36.10	0.62, 0.63
	20	0.33, 0.31	93.52, 93.55	3.25, 3.65	34.48, 31.63	0.68, 0.68
	40	0.29, 0.27	86.80, 87.19	8.38, 7.91	38.81, 39.51	0.60, 0.59
DWT+CNN ^[12]	10	0.27, 0.27	96.98, 97.13	1.89, 1.53	19.39, 23.02	0.77, 0.77
	20	0.27, 0.28	96.09, 94.33	2.00, 2.20	20.53, 21.55	0.81, 0.79
	40	0.29, 0.27	93.55, 94.10	3.78, 3.22	20.61, 20.53	0.80, 0.81
1D-ResCNN (本文方法)	10	0.38, 0.43	97.77, 97.84	1.25, 1.17	16.41, 17.17	0.83, 0.83
	20	0.40, 0.38	96.81, 97.06	1.87, 1.76	14.65, 13.62	0.85, 0.85
	40	0.42, 0.35	95.73, 95.76	2.26, 2.74	14.98, 12.43	0.86, 0.86

表 6 不同台站的基本信息及样本分布情况

Table 6 Basic information and samples distribution of different stations

台站名称 (编码)	地磁坐标	训练集		验证集		测试集	
		正样本	负样本	正样本	负样本	正样本	负样本
琼中站 (QZT)	(16°48', 182°0')	1845	9772	748	4231	5944	31784
邵阳站 (SYT)	(23°54', 183°55')	1611	12929	675	5557	5190	41070
马陵山站 (MLS)	(29°25', 191°21')	1522	12388	680	5282	3710	30634
农安站 (NAT)	(39°0', 198°5')	1923	14381	859	6129	5252	38020

表 7 不同台站的测试集的实验结果

Table 7 Experimental results on testing datasets of stations at different latitudes

台站名称 (编码)	准确率/(%)	虚报率/(%)	漏报率/(%)	F_1 值
琼中站 (QZT)	90.73	8.64	12.63	0.75
邵阳站 (SYT)	95.81	1.77	23.35	0.80
马陵山站 (MLS)	95.86	1.96	22.16	0.80
农安站 (NAT)	95.76	1.88	21.27	0.82

本文提出的模型对持续时间较长的孤立 Pi2 脉动和连续 Pi2 脉动的识别能力较强. 图 10 为 2011 年 3 月 6 日 12:40 UT—13:20 UT 漠河站磁力仪观测数据 H 分量, 带通滤波后的 H 分量 (截止频率为 6 mHz 和 25 mHz) 及小波功率谱. 模型将这段磁力仪观测数据正确地判别为有 Pi2 脉动发生, 观察可知, 此次 Pi2 脉动是一个孤立事件, 且持续时间为 7~10 min. 同时, 模型也正确识别出了同一时间范围内、位于其他纬度台站的 Pi2 脉动, 如图 11 所示, 图 11(a) 为 5 个台站的原始 H 分量, 图 11 (b) 为带通滤波后的 H 分量. Pi2 脉动在 5 个台站的发生时刻和

持续时间接近, 且波形相似. 由图 11(a) 可知, 原始 H 分量的峰间振幅随纬度的降低而减小. 模型对如图 12 所示的连续 Pi2 脉动, 同样具有较好的识别能力. 图 12 与图 10 格式相同, 给出了 2011 年 1 月 21 日 14:27 UT 左右发生的一个连续 Pi2 脉动. 模型同样识别出了其他纬度台站中此次 Pi2 脉动的发生, 如图 13 所示. 分析模型正确识别出的磁力仪观测数据样本, 认为模型对持续时间较长、振幅变化较大的 Pi2 脉动, 具有良好的识别能力.

由表 4 和表 5 可知, 模型存在较高的漏报率, 平均为 15%~20%. 由于本文在样本构造时采取直接切




图 10 1D-ResCNN 模型正确识别出的孤立 Pi2 脉动

Fig. 10 Isolated Pi2 pulsation correctly identified by 1D-ResCNN




图 11 2011 年 3 月 6 日 12:40 UT–13:20 UT 期间 5 个台站的磁力仪观测数据

Fig. 11 Magnetometer data of five stations during 12:40 UT–13:20 UT on 6 March 2011

分磁力仪观测数据的方法, 导致一个 Pi2 脉动可能被切分在两段磁力仪观测数据中. 如图 14 所示的磁力仪观测数据中包含一个刚开始出现振幅增强的 Pi2 脉动, 图 15 所示的磁力仪观测数据中包含一个

振幅逐渐减弱、即将结束的 Pi2 脉动. 模型无法正确识别出此类时间累积不够的 Pi2 脉动, 漏报率较高.

在模型虚报的磁力仪观测数据中存在频率大于




图 12 1D-ResCNN 模型正确识别出的连续 Pi2 脉动

Fig. 12 Cyclic Pi2 pulsation correctly identified by 1D-ResCNN




图 13 2011 年 1 月 21 日 14:00 UT–14:40 UT 期间五个台站的磁力仪观测数据

Fig. 13 Magnetometer data of five stations during 14:00 UT–14:40 UT on 21 January 2011

25 mHz 的规则脉动, 如图 16 所示. 观察图 16(b) (c) 可知, 在 6.7~25 mHz 的频率范围内, 没有出现明显的振幅变化和功率增强, 但图 16(a) 磁力仪观测数据 H 分量显示出了规则的波动. 模型错误地将这段磁

力仪观测数据判断为有 Pi2 脉动发生, 模型对信号多尺度特征的捕捉能力还有待提升.

综上所述, 本文提出的模型在识别持续时间较长、振幅变化明显的孤立 Pi2 脉动和连续 Pi2 脉动方




图 14 1D-ResCNN 模型漏报的处在初期的 Pi2 脉动

Fig. 14 Incipient Pi2 pulsation missed by 1D-ResCNN




图 15 1D-ResCNN 模型漏报的处在衰减阶段的 Pi2 脉动

Fig. 15 Pi2 pulsation in the decay phase missed by 1D-ResCNN

面表现出色,但仍存在漏报和虚报的问题.未来的工作将集中在优化模型架构、改进样本构造策略上,通过这些改进,期望能够进一步提升模型性能,降低漏报率和虚报率.

4 结论与讨论

利用子午工程磁力仪观测数据,构建了一个基于一维残差卷积神经网络 (1D-ResCNN) 的 Pi2 脉动识别模型.该模型可对一段磁力仪观测数据中是否有 Pi2 脉动发生进行判别,实现了 Pi2 脉动与背景噪声

的区分.识别效果优于现有的两种 Pi2 脉动机器学习识别模型,具有更高的识别准确率和更低的漏报率、虚报率,且在窗口长度和模型决策策略的选择问题上具有更好的鲁棒性.同时,该模型可用于识别不同纬度台站磁力仪观测数据中的 Pi2 脉动.

提出的模型可对一定时间范围内是否存在 Pi2 脉动进行初筛.需要说明的是,本文在样本构造时采用了直接切分方法,可能会使一个连续 Pi2 脉动事件被切分在两段磁力仪数据中,影响模型对时间积累不足的 Pi2 脉动的识别能力,导致漏报率提升.除此之外,模型只能判断出一段时间范围内有没有




图 16 1D-ResCNN 模型虚报的 Pi2 脉动

Fig. 16 False positive Pi2 pulsations identified by 1D-ResCNN

Pi2 脉动发生, 无法指出 Pi2 脉动事件具体的起始和结束时间. 还需在后续的工作中对上述不足进行改进, 数据处理方面可以考虑使用滑动窗口方法处理磁力仪观测数据, 以保持事件的连续性. 模型结构调整方面可以考虑将 1D-ResCNN 网络与其他具有时间序列处理能力的网络结构相融合, 例如 LSTM 及其变体等, 以实现变长时间序列的分类, 并通过增加注意力机制来确定 Pi2 脉动的开始和结束时间.

综上所述, 提出了一种端到端的 Pi2 脉动识别模型, 该模型在数据预处理时无须进行时序特征提取, 适用于各种地磁活动条件. 在不同纬度台站的测试结果表明, 模型具有良好的泛化性. 未来将进一步结合卫星星座的观测数据, 开展 Pi2 脉动事件传播分析, 促进太阳风—磁层—电离层相互作用的研究.

致谢 本项成果使用了国家重大科技基础设施子午工程科学数据. 中国科学院网信专项“空间科学大数据智能管理与分析挖掘关键技术及应用”提供了数据分析挖掘工具. 北京大学任杰老师对 Pi2 脉动研究及事件筛选进行了指导.

参考文献

- [1] JACOBS J A, KATO Y, MATSUSHITA S, *et al.* Classification of geomagnetic micropulsations[J]. *Journal of Geophysical Research*, 1964, **69**(1): 180-181
- [2] TAKAHASHI K, LEE D H, NOSÉ M, *et al.* CRRES electric field study of the radial mode structure of Pi2 pulsations[J]. *Journal of Geophysical Research: Space Physics*, 2003, **108**(A5): 1210
- [3] SAITO T, YUMOTO K, KOYAMA Y. Magnetic pulsation Pi2 as a sensitive indicator of magnetospheric substorm[J]. *Planetary and Space Science*, 1976, **24**(11): 1025-1029
- [4] CHEN L, SHIOKAWA K, MIYOSHI Y, *et al.* Correspondence of Pi2 pulsations, aurora luminosity, and plasma flux fluctuation near a substorm brightening aurora: Arase observations[J]. *Journal of Geophysical Research: Space Physics*, 2023, **128**(10): e2023JA031648
- [5] SIMHA C P, KATLAMUDI M R, BULUSU J. Low latitude Pi2 pulsations at Desalpar, Gujarat, India: A statistical analysis of the influences of magnetic storms/substorms, seasons, and solar cycles[J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2023, **252**: 106145
- [6] KEILING A, TAKAHASHI K. Review of Pi2 models[J]. *Space Science Reviews*, 2011, **161**(1): 63-148
- [7] KWON H J, KIM K H, JUN C W, *et al.* Low-latitude Pi2 pulsations during intervals of quiet geomagnetic conditions ($K_p \leq 1$)[J]. *Journal of Geophysical Research: Space Physics*, 2013, **118**(10): 6145-6153
- [8] NOSÉ M, IYEMORI T, TAKEDA M, *et al.* Automated detection of Pi 2 pulsations using wavelet analysis: 1. Method and an application for substorm monitoring[J]. *Earth, Planets and Space*, 1998, **50**(9): 773-783
- [9] MURPHY K R, JONATHAN RAE I, MANN I R, *et al.* Wavelet-based ULF wave diagnosis of substorm expansion phase onset[J]. *Journal of Geophysical Research: Space Physics*, 2009, **114**(A1): A00C16
- [10] KATSAVRIAS C, PAPADIMITRIOU C, HILLARIS A, *et al.* Application of wavelet methods in the investigation of geospace disturbances: a review and an evaluation of the approach for quantifying wavelet power[J]. *Atmosphere*,

- 2022, **13**(3): 499
- [11] SUTCLIFFE P R. Substorm onset identification using neural networks and Pi2 pulsations[J]. *Annales Geophysicae*, 1997, **15**(10): 1257-1264
- [12] RABIE E, HAFEZ A G, SAAD O M, *et al.* Geomagnetic micro-pulsation automatic detection via deep leaning approach guided with discrete wavelet transform[J]. *Journal of King Saud University-Science*, 2021, **33**(1): 101263
- [13] BALASIS G, AMINALRAGIA-GIAMINI S, PAPADIMITRIOU C, *et al.* A machine learning approach for automated ULF wave recognition[J]. *Journal of Space Weather and Space Climate*, 2019, **9**: A13
- [14] ANTONOPOULOU A, BALASIS G, PAPADIMITRIOU C, *et al.* Convolutional neural networks for automated ULF wave classification in swarm time series[J]. *Atmosphere*, 2022, **13**(9): 1488
- [15] OMONDI S, YOSHIKAWA A, ZAHRA W K, *et al.* Automatic detection of auroral Pc5 geomagnetic pulsation using machine learning approach guided with discrete wavelet transform[J]. *Advances in Space Research*, 2023, **72**(3): 866-883
- [16] PAPPOE J A, YOSHIKAWA A, KANDIL A, *et al.* A machine learning approach combined with wavelet analysis for automatic detection of Pc5 geomagnetic pulsations observed at geostationary orbits[J/OL]. *Advances in Space Research*, 2023. (2023-11-03). [2024-01-30]. <https://www.sciencedirect.com/science/article/abs/pii/S0273117723008736>
- [17] TERAMOTO M, MIYOSHI Y, MATSUOKA A, *et al.* Off-Equatorial Pi2 pulsations inside and outside the plasma-pause observed by the Arase satellite[J]. *Journal of Geophysical Research: Space Physics*, 2022, **127**(1): e2021JA029677
- [18] TAKAHASHI K, LYSAK R, VELLANTE M. Statistical analysis of Pi2 pulsations observed by Van Allen Probes[J]. *Journal of Geophysical Research: Space Physics*, 2022, **127**(9): e2022JA030674
- [19] ZENG Zhengjun, ZHANG Ying, DU Aimin, *et al.* Characteristics of Pc3 compressional waves in the topside ionosphere[J]. *Progress in Geophysics*, 2020, **35**(3): 918-924 (曾正君, 张莹, 杜爱民, 等. 顶部电离层 Pc3 压缩波的波动特征[J]. *地球物理学进展*, 2020, **35**(3): 918-924)
- [20] ZHANG Yiyue, ZOU Ziming, FANG Shaofeng. Pi2 pulsation event annotation time-series dataset[DB/OL]. V3. Science Data Bank, 2024. [2024-04-26]. <https://cstr.cn/14804.11.sciencedb.space.01648>
- [21] China Meteorological Administration. QX/T 135-2011 Classification for solar activity level[S]. Beijing: China Meteorological Press, 2011 (中国气象局. QX/T 135-2011 太阳活动水平分级[S]. 北京: 中国气象出版社, 2011)
- [22] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778

作者简介



张怡悦 女, 1999 年 6 月出生, 现为中国科学院大学、中国科学院国家空间科学中心在读硕士生, 主要研究方向为机器学习在超低频波识别中的应用。
E-mail: zhangyiyue21@mails.ucas.ac.cn



邹自明 (通信作者) 男, 1971 年 5 月出生, 现为中国科学院国家空间科学中心研究员, 博士生导师, 主要研究方向为日地空间信息系统技术、机器学习在空间物理中的应用等。
E-mail: mzou@nssc.ac.cn