

LI Hongyu, SUN Junsong, WANG Li, YANG Jie, ZHAO Yuxin. Geomagnetic Storm Image Recognition Based on Spectrogram and Convolutional Neural Network (in Chinese). *Chinese Journal of Space Science*, 2025, 45(4): 943–949. CSTR:32142.14.cjss.2024-0066. DOI:10.11728/cjss2025.04.2024-0066

基于声谱图和卷积神经网络的磁暴图像识别*

李鸿宇 孙君嵩 王 丽

杨 杰 赵雨馨

(江苏省地震局 南京 210014)

摘 要 磁暴是一种重要的地磁场扰动类型,影响着通信、电力和航空航天等领域,因此对磁暴识别技术进行研究与创新有助于磁暴信息的应用. 基于 2010—2023 年 12 个定点地磁观测水平分量分钟值数据,采用声谱图成像技术,运用 VGG19 卷积神经网络模型开展磁暴日和磁静日人工智能图像分类研究. 实验结果显示,模型的准确率为 97.41%,精确率为 98.00%,召回率为 96.80%,模型的预测能力较好,这表明声谱图成像技术在图像识别分类问题中具有较高的实用性,且 VGG19 卷积神经网络模型用于磁暴日和磁静日地磁分类的可行性较高,研究结果为磁暴预警与监测提供了新的思路.

关键词 地磁, 磁暴, 声谱图, 卷积神经网络, 图像分类

中图分类号 P315

Geomagnetic Storm Image Recognition Based on Spectrogram and Convolutional Neural Network

LI Hongyu SUN Junsong WANG Li

YANG Jie ZHAO Yuxin

(Jiangsu Earthquake Agency, Nanjing 210014)

Abstract Geomagnetic storms represent an important type of geomagnetic field disturbance that can cause interference and damage to fields such as communication, power supply, and aerospace technology. Therefore, the advancement and innovation of geomagnetic storm recognition technology have good development prospects for strengthening the application of geomagnetic storm data in related fields. In this study, we leveraged an extensive dataset comprising minute value recordings of horizontal components sourced from 12 permanent geomagnetic observation stations from 2010 to 2023. Employing spectral imaging technology, we conducted a comprehensive artificial intelligence-based image classification analysis to differentiate between geomagnetic storm days and geomagnetic quiet days, utilizing the VGG19

* 中国地震局地震科技星火计划项目 (XH23016YB), 江苏省地震局青年科学基金项目 (202408) 和江苏省地震局局长科研基金项目 (202201) 共同资助

2024-05-07 收到原稿, 2025-02-05 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/>)

convolutional neural network model. We have obtained good experimental results. This experiment uses accuracy, precision, and recall as evaluation metrics. The experimental model demonstrated the accuracy rate of 97.41%, with a precision value of 98.00% and a recall rate standing at 96.80%. These indicators collectively emphasize the reliable predictive ability of our model. Furthermore, the application of spectrograms within the context of image recognition and classification has demonstrated significant feasibility. Notably, the VGG19 convolutional neural network model exhibited remarkable feasibility when tasked with categorizing geomagnetic storm days and geomagnetic quiet days. The recognition accuracy of this model for geomagnetic storm days is relatively high and the model itself is relatively stable. However, there is some fluctuation in the recognition of geomagnetic quiet days, which also means that the model still has room for further improvement, especially by increasing the number of training sets and improving the learning accuracy of the model for map information. In summary, our research findings contribute to the improvement of geomagnetic storm identification methods, providing a promising approach to enhance geomagnetic storm prediction and monitoring capabilities, and ultimately promoting the wider application of geomagnetic storm information in related fields.

Key words Geomagnetism, Geomagnetic storm, Spectrograms, Convolutional neural networks, Image classification

0 引言

地磁场变化在地磁学中可分为磁静日变化和磁扰日变化两类. 磁扰日变化的主要特点是出现的时间不规律, 变化形态多样, 缺乏长时间连续性, 在不同的磁扰类型中, 磁暴是最重要的一种扰动类型. 此外, 由于磁暴对通信系统、供电系统、航空飞行、导航服务等有不同程度的影响, 因此, 磁暴研究具有较高的应用价值^[1]. 为明确磁暴强度的大小, 1939年 Bartels 等^[2]提出了描述地磁活动性的 K 指数概念, 后被 IAGA (国际地磁学和高空大气学协会) 观测规范采用, 是目前较为通用的地磁活动性指数. K 指数用 0~9 共 10 个等级来表示磁暴强度的大小, 其中 $K \geq 5$ 时即认为产生了磁暴. 2007 年中国地震局地球物理研究所国家地磁台网中心引入福尔克斯-马洛斯指数 (Fowlkes-Mallows Index, FMI) 方法计算地磁指数 K , 各观测台站每日观测结束后均需计算 K 指数^[3]. 依据 FMI 计算方法原理, 如果要判断这一天是否存在磁暴, 除经验判断之外, 还需要等待地磁观测一天后计算 K 指数, 依据 K 指数结果进行判断, 其时效性存在滞后的现象.

随着深度学习技术的不断发展, 在地震学研究中, 地震震相分类、识别及定位等方面的应用研究迅速发展起来^[4,5]. 地磁数据与地震波形数据具有一定的相似性, 但是由于地磁观测采样率仍处于秒级和分钟

级的事实, 其时序曲线特征信息较少. 如果能够将地磁观测数据转换为具体的图像供深度学习使用, 实现磁暴信息实时自动识别或可成为可能. 声谱图是一个很好的数据可视化方案, 其是采用时间、幅度和频率 3 个维度信息描述声音信号的三维感知图, 不同时间 (X 轴) 和频率 (Y 轴) 上信号振幅值或功率值在图像中一般采用不同的灰度或颜色来标识^[6]. 如果将地磁信号视为声音信号, 在同一时刻不同频率分量的功率大小应该是不同的, 其可以展现磁暴时刻的功率大小特征.

2014 年 Simonyan 等^[7]提出的 VGG 卷积神经网络在 ImageNet 大规模视觉识别挑战赛上取得优异成绩. VGG 网络对卷积神经网络进行了改良, 分析了网络深度与性能的关系, 采用较小的卷积核和更深的网络结构, 并取得较好的学习效果, 成为卷积神经网络中一种重要的网络结构. VGG 中使用大小为 3×3 的卷积核和池化层搭建深层卷积神经网络, 因其结构简单、应用性极强而得到广泛应用.

本文将选用地磁水平分量 H 分钟值数据绘制声谱图, 建立深度学习数据集, 选用 VGG19 卷积神经网络, 利用卷积神经网络的特征提取和自学能力, 学习磁暴日和磁静日 (本研究中磁静日特指 $K < 2$ 的日期) 的声谱图像特征, 建立能够识别磁暴日和磁静日的神经网络模型, 应用到地磁暴识别及公共服务领域, 可进一步提高磁暴信息的识别效率.

1 数据与声谱图样本建立

1.1 数据来源

选用河北红山、山西大同、山东莒县陵阳、江苏新沂、福建泉州、湖北钟祥、重庆仙女山、四川西昌、宁夏固原、甘肃嘉峪关、青海大武和新疆红浅 12 个台站 2010—2023 年地磁水平分量 H 的分钟值数据。

1.2 声谱图样本建立

声谱图是对短时傅里叶变换的可视化表达, 其定义为^[8]

$$T_{\text{STFT}_x}^{(h)}(t, \omega) = \int_{-\infty}^{\infty} x(\tau) h(\tau - t) e^{-j\omega\tau} d\tau. \quad (1)$$

其中, $x(\tau)$ 为输入信号, $h(\tau - t)$ 为窗函数, $e^{-j\omega\tau}$ 为傅里叶变换的复指数核函数, t 为时间变量, ω 为频率变量, 且 $\|h\|^2 = 1$ 。

将地磁水平分量 H 逐日绘制声谱图, 部分台站存在一定的缺数, 共获得基础图件 57154 张, 同时参考各台站每日 K 指数, 将 $K \geq 5$ 的日期声谱图分为一

类, 标签命名为磁暴日, 将全天 $K < 2$ 的日期声谱图分为一类, 标签命名为磁静日。2010—2022 年的地磁水平分量 H 逐日声谱图中磁暴日声谱图 3170 张, 磁静日声谱图 3170 张, 用作建立训练集和验证集 (比例为 8:2), 选取 2023 年磁暴日的声谱图 406 张、磁静日声谱图 406 张建立测试集。磁暴日与磁静日声谱图的随机样本如图 1 和图 2 所示。

从图 1 和图 2 可以看出, 地磁扰动时其声谱图出现明显变化, 主要集中在 0.01 Hz 频率以上, 该两类数据集的区别明显可见, 深度学习分类识别可行性更高。

在深度学习实际操作中, 数据集图片不包括图名、横轴数值标注、横纵坐标轴标签和色卡, 减少不必要的图片信息。

2 深度学习模型

2.1 VGG19 模型

VGG 卷积神经网络是由卷积层、激活层、池化




图 1 磁暴日声谱图

Fig. 1 Spectrogram of geomagnetic storm day




图2 磁静日声谱图

Fig. 2 Spectrogram of geomagnetic quiet days

层和全连接层组成的, 其中卷积层的作用最为重要, 通过实现局部感知和参数共享两种方式, 同时达到降维处理和提取样本特征的目的^[9]. 卷积核是卷积层的核心, 在卷积核的作用下可以提取图像中不同位置的特征, 在起到降维作用的同时也减少了需要训练的参数.

选用的 VGG19 模型如图 3 所示, 其结构由 19 层网络组成, 共包含 16 个卷积层和 3 个全连接层. 所有卷积层均使用 3×3 大小的卷积核, 采用步长 1 和边界填充 1 进行卷积运算. 在卷积层之后, 通过 2×2 的最大池化层对特征图进行下采样. VGG19 模型的最后 3 个全连接层用于输出图像的分类概率. 在此结构基础上, 本文的 VGG19 模型分类器部分由 3 个全连接层改为 2 个全连接层, 1 个 ReLU 激活函数和 1 个 Dropout 层, 同时设定输出单元为 2(二分类), 该修改引入非线性且防止过拟合, 其实际训练效果优于传统 VGG19 模型.

2.2 数据集划分

(1) 训练集, 磁暴日声谱图 2536 张, 磁静日声谱

图 2536 张.

(2) 验证集, 磁暴日声谱图 634 张, 磁静日声谱图 634 张.

(3) 测试集, 磁暴日声谱图 406 张, 磁静日声谱图 406 张.

2.3 模型训练环境与参数

这里采用 Python 3.10 编程语言, 使用 pytorch2.0 进行网络搭建、训练和测试. 模型训练次数为 50, 训练批次大小为 16, 进程数为 8, 学习率为 0.001.

2.4 评价指标

实验采用准确率 (Accuracy)、精确率 (Precision) 和召回率 (Recall) 作为评价指标.

3 结果与分析

VGG19 模型训练后, 测试集测试结果混淆矩阵如表 1 所示. 其中, TP (True Positives, 定义符号 N_{TP}), 表示正样本被正确识别为正样本; TN (True

ConvNet configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
Input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
Maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
Maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
Maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
Maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
Maxpool					
FC-4096					
FC-4096					
FC-1000					
Soft-max					

图 3 VGG19 模型结构
Fig. 3 Structure of VGG19 model

表 1 测试集实验结果的混淆矩阵
Table 1 Confusion matrix of test set experimental results

真实情况	预测情况	
	正例(磁暴日)	反例(磁静日)
	正例(磁暴日)	反例(磁静日)
正例(磁暴日)	393 (TP)	13 (FN)
反例(磁静日)	8 (FP)	398 (TN)

Negatives, 定义数学符号 N_{TN}), 表示负样本被正确识别为负样本; FP (False Positives, 定义符号 N_{FP}), 表示假的正样本, 即负样本被错误识别为正样本; FN (False Negatives, 定义符号 N_{FN}) 表示假的负样本,

即正样本被错误识别为负样本.

VGG19 模型评价结果如下.

准确率 (Accuracy, 定义符号 A) 表示分类正确的样本数占总样本数的比例. $A = (N_{TP} + N_{TN}) / (N_{TP} + N_{TN} + N_{FP} + N_{FN}) = (393 + 398) / (393 + 398 + 13 + 8) = 97.41\%$.

精确率 (Precision, 定义符号 P) 是指分类为正类别的样本中真正为正类别的比例. $P = N_{TP} / (N_{TP} + N_{FP}) = 393 / (393 + 8) = 98.00\%$.

召回率 (Recall, 定义符号 R) 是指所有正类别样本中被正确识别为正类别的比例. $R = N_{TP} / (N_{TP} + N_{FN}) = 393 / (393 + 13) = 96.80\%$.

从评价指标来看, 此次实验模型的准确率高达 97.41%, 精确率为 98.00%, 召回率为 96.80%, 模型的预测能力较好。

本文关注的核心问题是磁暴图像的识别情况, 也就是召回率的评价情况, 其数值为 96.80%, 也是较高的结果。因此, 使用 VGG19 神经网络结果进行地磁磁暴识别是存在应用前景的。

在数据准备过程中研究发现, 将地磁数据转为声谱图时, 磁暴日和磁静日可以人工观察出图像区别, 其主要的图像差异为 0.002~0.004 Hz 的频段, 而计算机存在识别错误的情况。图 4 给出了错误分类的样图, 图 4(a)~(d) 4 天 K 指数分别对应红山台 2023 年 9 月 24 日、大武台 2023 年 7 月 25 日、新沂台 2023 年 6 月 1 日、红浅台 2023 年 7 月 11 日。其中图 4(a)(b) 两幅图像可人工分辨地磁强扰动现象, 判断为磁暴日; 图 4(c)(d) 两幅图未有较强的地磁扰动现象, 可判断为磁静日。

从准确率 (97.41%)、精确率 (98.00%) 和召回率

(96.80%) 三个模型评价指标来看, VGG19 模型用于磁暴日和磁静日分类有优异的表现, 但是也存在一定数量的错误识别情况。错误识别的可能原因是图像信息中的异常信息比重较小, 或是异常信息不明确, 同时也可能是训练样本量较少。为进一步验证模型的稳定性和结论的可信度, 采用随机抽取图件建立训练集 (2536×2) 和验证集 (634×2), 进行 10 组模型训练, 模型训练相关参数一致, 每组训练 20 轮次, 对固定测试集进行预测 (406×2), 其预测结果见表 2。

从表 2 中可以看出, 10 个模型磁暴日的预测结果基本一致, 并且图 4(a)(b) 两幅图中 10 个模型的预测结果一致为错误; 磁静日的预测结果存在一定波动, 第 6 组和第 8 组结果偏离较大, 图 4(c) 中有 6 组预测错误, 图 4(d) 中有 3 组预测错误, 可见模型训练存在一定的不确定性, 尤其是在信息相对模糊的情况下。

本文训练结果显示, 模型对于磁暴日的识别准确率较高且模型本身较为稳定, 而对于磁静日的识别存在一定波动, 这意味着模型仍有进一步完善的空间,




图 4 分类错误样例

Fig. 4 Sample diagram of classification errors

表 2 10 组测试集实验结果
Table 2 Experimental results of 10 test sets

		1组	2组	3组	4组	5组	6组	7组	8组	9组	10组
磁暴日	正 (TP)	393	392	393	393	394	395	393	392	392	393
	反 (FN)	13	14	13	13	12	11	13	14	14	13
磁静日	正 (TN)	399	388	398	394	377	354	378	405	374	387
	反 (FP)	7	18	8	12	29	52	28	1	32	19

可以增大训练集数量, 提升模型对图件信息的学习准确率.

4 结论

基于地磁水平分量 H 分钟值数据, 采用声谱图展现地磁观测数据的频谱特征, 运用 VGG19 模型开展地磁磁暴日和磁静日图像分类深度学习, 主要研究结论如下. 声谱图用于地磁磁暴日和磁静日信息展示具有较高的实用性, 其能够将二维时序曲线转换为三维时间、频率和幅度的图像, 展示的数据信息更加丰富; VGG19 网络模型用于地磁磁暴日和磁静日分类具有可行性, 在本次实验中存在训练样本量偏小的现象, 但训练的模型分类识别能力较好, 该模型有较好的应用前景; 深度学习过程中人工可识别的图像仍然存在机器错误识别的情况, 其产生原因复杂, 在训练样本建立和模型选择方面有进一步完善的空间.

致谢 文中使用的地磁数据来自中国地震局地球物理研究所国家地磁台网中心.

参考文献

[1] XU Wenyao. Geomagnetism[M]. Beijing: Seismological Press, 2003 (徐文耀. 地磁学 [M]. 北京: 地震出版社, 2003)

[2] BARTELS J, HECK N H, JOHNSTON H F. The three-hour-range index measuring geomagnetic activity[J]. *Terrestrial Magnetism and Atmospheric Electricity*, 1939, **44**(4): 411-454

[3] WANG Jianjun, LI Qi, YANG Dongmei, et al. An improved FMI method of deriving K indices[J]. *Chinese Journal of Geophysics*, 2017, **60**(7): 2534-2544 (王建军, 李琪, 杨冬梅, 等. 地磁活动 K 指数自动计算 FMI 方法的改进 [J]. *地球物理学报*, 2017, **60**(7): 2534-2544)

[4] GAO Yongguo, YIN Xinxin, LI Shaohua. Automatic recognition of earthquake and blasting events based on deep learning[J]. *Journal of Geodesy and Geodynamics*, 2022, **42**(4): 426-430 (高永国, 尹欣欣, 李少华. 基于深度学习的地

震与爆破事件自动识别研究 [J]. *大地测量与地球动力学*, 2022, **42**(4): 426-430)

[5] ZHAO Ming, CHEN Shi, YUEN D. Waveform classification and seismic recognition by convolution neural network[J]. *Chinese Journal of Geophysics*, 2019, **62**(1): 374-382 (赵明, 陈石, YUEN D. 基于深度学习卷积神经网络的地震波形自动分类与识别 [J]. *地球物理学报*, 2019, **62**(1): 374-382)

[6] DU Xiaodong, TENG Guanghui, TOMAS N, et al. Classification and recognition of laying hens' vocalization based on texture features of spectrogram[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, **50**(9): 215-220 (杜晓冬, 滕光辉, TOMAS N, 等. 基于声谱图纹理特征的蛋鸡发声分类识别 [J]. *农业机械学报*, 2019, **50**(9): 215-220)

[7] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]//Proceedings of the International Conference on Learning Representations (ICLR). Banff, Morocco: the Core Research Group Led by Yoshua Bengio and Yann LeCun, 2014

[8] ZHU Mingzhe, JI Hongbing, JIN Yan. Parameter estimation of hybrid DS/FH spread spectrum signals based on adaptive decimating STFT[J]. *Systems Engineering and Electronics*, 2010, **32**(3): 454-457, 462 (朱明哲, 姬红兵, 金艳. 基于自适应抽取 STFT 的混合 DS/FH 扩频信号参数估计 [J]. *系统工程与电子技术*, 2010, **32**(3): 454-457, 462)

[9] LIU Jianbo. Research and Application of Image Classification Method Based on Convolutional Neural Network[D]. Daqing: Northeast Petroleum University, 2018 (刘建伯. 基于卷积神经网络图像分类方法研究及应用 [D]. 大庆: 东北石油大学, 2018)

作者简介



李鸿宇 男, 1982 年 4 月出生于吉林省梅河口市, 现为江苏省地震局电磁研究中心预测研究室主任, 高级工程师, 主要研究方向为地震电磁分析预报方法和电磁大数据分析.
E-mail: 27587295@qq.com