

一种基于CNN的地磁异常信息地震预测算法

李少栋, 黄 鹰

中国地质大学(武汉)地理与信息工程学院, 湖北 武汉

收稿日期: 2023年4月19日; 录用日期: 2023年7月5日; 发布日期: 2023年7月12日

摘 要

地震是一种难以预测的自然灾害。震前磁异常曾被很多学者观察到过, 但是还不能用它进行预测。本文尝试采用多点布设的磁强监测网络, 将站点地磁异常以等值线图的形式绘制出来, 并基于卷积神经网络模型VGGNet构建了一种地震预测模型VGG-12, 该模型可以对地磁异常等值线图进行分析, 挖掘其中的地震信息, 进而实现地震发生方位和等级预测的目的。将该模型在具有类别的地磁异常等值线图像构成的数据集上训练和预测, 结果显示, 该模型的预测准确率可以达到75%以上。

关键词

卷积神经网络, 深度学习, 地震预测, 地磁异常

A Seismic Prediction Algorithm for Geomagnetic Anomaly Information Based on CNN

Shaodong Li, Ying Huang

School of Geography and Information Engineering, China University of Geosciences (Wuhan), Wuhan Hubei

Received: Apr. 19th, 2023; accepted: Jul. 5th, 2023; published: Jul. 12th, 2023

Abstract

Earthquake is an unpredictable natural disaster. Magnetic anomalies before earthquakes have been observed by many scholars, but they cannot be used for prediction. This article attempts to use a multi-point magnetic monitoring network to plot the geomagnetic anomalies at the site in the form of contour maps, and constructs an earthquake prediction model VGG-12 based on the convolutional neural network model VGGNet. This model can analyze the contour maps of geomagnetic anomalies, mine the seismic information, and achieve the purpose of earthquake predic-

tion. The model was trained and predicted on a dataset composed of geomagnetic anomaly contour images with categories, and the results showed that the prediction accuracy of the model could reach over 75%.

Keywords

Convolutional Neural Network, Deep Learning, Earthquake Prediction, Geomagnetic Anomaly

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

地震是板块碰撞引起的地壳形变和振动,同时是一种破坏力极强的自然灾害,通常会给地震区域的人带来巨大的生命财产安全损失。我们国家的云南四川地区,由于位于亚欧板块和印度洋板块边界,板块活动强烈,因而地震频发。2008年8.0级汶川地震造成了10万人左右的死亡[1],近期的地震如2022年5月的四川雅安芦山6.1级地震和2022年9月的四川甘孜泸定6.8级地震,给当地的房屋、道路以及公共设施造成了不小的损失。

大量研究表明,地震之前会有显著的地磁异常:1989年发生在美国加州的7.1级地震当天,出现了增强了20倍的地磁异常信号,地震发生前3小时,信号增强了60倍[2]。2000年7月1~15日发生在日本伊豆岛的火山和地震群震前40分钟出现了地磁特大异常[3]。2008年汶川地震前5小时,地震重灾区北川县就有指南针指向紊乱的现象,在地震发生前13分钟,北川中学有一个班的同学集体观察到指南针不规则转圈的现象[4]。这些现象表明突发地磁异常很可能预示着一场地震的发生。

本文采用在研究区域布设的地磁仪器采集到的地磁数据,综合利用深度学习的相关知识,建设起一个可以同时预测地震方位、震级的地震预测系统。在出现地磁异常时,可以利用该系统进行地震预判和预防,不仅为地震预测提供一个可行的研究方向与研究思路,同时也能实际应用于研究区域附近的防震减灾,具有很高的经济价值。

2. 卷积神经网络

2.1. 卷积神经网络结构

机器学习算法可以分为无监督学习和监督学习。其中无监督学习需要从样本中学习并获得规律;监督学习是在训练样本过程中,要对应确定的结果,然后对未知样本进行结果预测。监督学习可分为分类问题和回归问题,分类问题的标注结果为离散值,回归问题的标注结果为连续值。本文所研究的地震预测就是典型的监督回归问题。常用的有监督回归算法主要包括线性回归、支持向量机、梯度提升算法等。神经网络算法是一种常用的机器学习算法。

卷积神经网络(Convolutional Neural Network, CNN)是一种前馈神经网络,与其他神经网络模型相比, CNN 通过自主学习来学习优化过滤器进行特征筛选,而在传统算法中这些过滤器是人为设计的,因此在 CNN 中对于输入样本不需要有太多的先验知识或人为干预,这样卷积神经网络可以由浅入深进行全面的特征筛选,从而可以有效消除人工特征筛选的局限性,这是 CNN 的一个主要优势。近年来已经在图像和视频识别、图像分类、图像分割、自然语言处理[5]、脑机接口[6]等诸多领域中都有应用。

一个 CNN 由输入层, 卷积层, 池化层, 全连接层和输出层构成(图 1 展示了一个经典 CNN 结构图), 除了输入和输出层外的其他层也叫隐含层。其中卷积层用来进行样本特征提取, 不同的卷积核可以提取不同的特征; 池化层用于降低卷积后特征图像的数据维数, 全连接层利用卷积层和池化层提取到的全部特征进行预测。以 CNN 模型为基础, 将多层卷积和多层池化结合产生新的网络模型, 可提高网络结构的准确度, 经典的卷积神经网络模型有 GoogLeNet、AlexNet、VGGNet 等[7]。

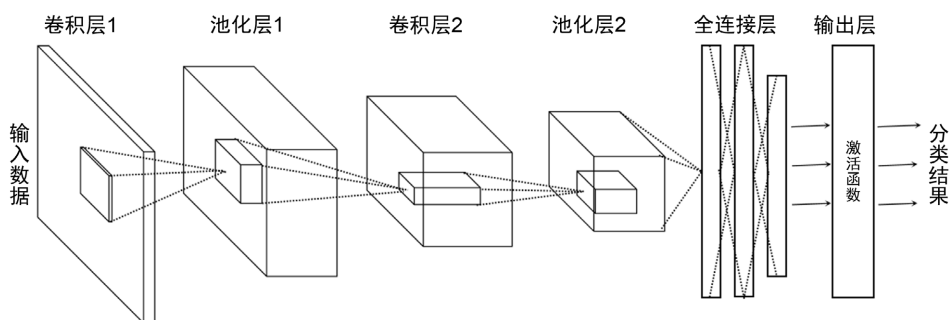


Figure 1. CNN structure

图 1. CNN 结构图

与循环神经网络、BP 神经网络相比, CNN 在图像识别领域具有以下三点优势:

- 1) 能够自动学习图像中的特征, 使得它们能够很好地捕捉和描述图像的细节;
- 2) 可以处理大型图像数据集, 并且能够从中快速学习;
- 3) 有很多开源的 CNN 模型可以供使用, 比如 VGG、ResNet 和 Inception 等。

目前 CNN 已经在图像处理领域取得了广泛成果[8] [9], 本研究最终选择采用 CNN 开展后续异常图像的识别工作。

2.2. 评价指标

对神经网络模型的评价依赖于混淆矩阵的构建。

在分类模型的常用指标中, 混淆矩阵是能够比较全面的反映模型的性能, 并能够衍生出很多其他的指标。以表 1 的二分类结果混淆矩阵为例, 其中: TP: 真正例, 实际为正预测为正; FP: 假正例, 实际为负但预测为正; FN: 假反例, 实际为正但预测为负; TN: 真反例, 实际为负预测为负。

Table 1. Confusion matrix

表 1. 混淆矩阵

	预测结果		
	正	负	
真实标签	正	TP	FN
	负	FP	TN

根据混淆矩阵可以得到召回率和准确率的计算公式:

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (2)$$

以上为二分类问题中的混淆矩阵、准确率、召回率的相关概念, 在多分类评价问题中, 只需要把每个类别单独视为“正”, 所有其它类型视为“负”, 就可以计算出预测结果中 TP、FN、FP、TN 值, 再代入到公式(1)、(2)中就能计算出多分类的召回率和准确率。

3. 地磁异常数据的采集与分析方法

3.1. 地磁异常等值线图

本研究采用在四川凉山自治州地区某区域密集布设的一组地磁传感器网络的磁强数据, 总共由 25 个磁强传感器节点, 分布在一个 14,000 多平方公里的范围内。数据通过物联网实时采集传输到我们的数据中心。通过对磁强数据进行磁异常分析, 可以得到整个监测区域的地磁异常等值线图。

图 2 展示了两幅地磁异常等值线图, 其中图 2(a)是正常情况下的等值线图, 图 2(b)是震前出现超阈值地磁异常时的等值线图, 图像尺寸均为 480×480 。

可以看到, 相较于图 2(a)展示出来的正常状态下等值线图, 异常发生时的等值线图差异很明显, 最主要的差别在于异常出现后, 等值线图中会出现若干个极值区域, 由于等值线图是基于站点异常绘制的, 因此可以推断位于极值区域内及附近的站点出现了较大的地磁异常, 因此, 对地磁异常等值线图进行特征识别, 是可以同时将站点位置、异常强度的影响考虑进来的。




Figure 2. Contour map of geomagnetic anomalies

图 2. 地磁异常等值线图

3.2. 地磁异常等值线图特征识别

在得到了地磁异常等值线图后, 需要通过观察找到等值线图中与地震相关的地磁异常特征。在绘制和观察了 2022 年 2 月 1 日至 2022 年 12 月 31 日共计 334 天的等值线图之后, 可以总结出四条可能与地震发生有关的特征:

- 1) 极值区域的面积;
- 2) 极值区域的异常值大小;
- 3) 极值区域的持续时间;
- 4) 极值区域的方位。

基于传统数字图像处理的方法可以分别处理和分析这四个特征, 特征与对应变量间的关系见表 2。

Table 2. Contour map feature
表 2. 等值线图特征

特征	说明	变量
面积	极值区域的面积	图像中色彩超过某个阈值的像素个数
异常值大小	极值区域中最大异常的数值	图像中最强像素值
持续时间	极值区域持续多少天出现在图像中的同一个位置上	前后两天图像求差值, 差值图像中之前的极值所在区域内的像素如果有大部分小于某个阈值, 持续时间就加 1 天
方位	极值区域相对于研究区域中心的方位	计算正常情况下的像素均值: 如果北半区像素均值 > 均值, 记方向为北; 如果南半区像素均值 > 均值, 记方向为南; 如果南北均大于均值, 则按照南北的大小比较并记录

这四个特征分开统计很简单, 但是要综合起来分析却很难, 因为如果要像第三章构建模型的方式那样通过为四个特征设定阈值的方式构建本章的模型, 那么一方面会割裂这四个特征的内在关联, 另一方面需要设置四个阈值, 受人为影响因素较大, 使得模型移植到别的区域的困难增加。

考虑到以上研究过程中存在的困难以及卷积神经网络在图像特征识别方面的良好表现, 本文选择采用卷积神经网络对地磁异常等值线图进行处理、识别和分类。将地震预测转化为一个分类问题, 将对(震级, 方位)的预测转化为具体的类别。

3.3. 网络模型设计

本研究需要同时输出方向和震级 2 个标签, 根据这两个标签可以划分出 5 个类别, 这是一个多分类问题。

VGGNet 是在 ImageNet 竞赛上针对 ImageNet 数据集而提出的分类网络, 图像大小为 224×224 , 而本研究的所用到的等值线图数据集大小为 480×480 , 要比 ImageNet 数据集大, 但是类别数要远远少于 ImageNet 数据集中的类别, 本研究对其采取了一些改进措施以适配本研究的数据集, 具体表现在:

- 1) 大大减少了所有卷积层和全连接层中的滤波器数量;
- 2) 将 VGGNet 原本的五个卷积块缩减为四个卷积块, 去除最后一个全连接层, 并添加了 Dropout 优化策略;
- 3) 输出层神经元个数为 5, 对应 5 个地震类别。

改进后的 VGGNet 网络仅有 12 层, 我们将改进后的网络命名为 VGG-12。VGG-12 的网络结构具体结构见图 3。




Figure 3. VGG-12
图 3. VGG-12

VGG-12 由四个卷积块组成, 每个卷积块中的卷积层的滤波器大小都为 3×3 的, 每个卷积块中的卷积层中的滤波器数量皆相同, 四个卷积块的滤波器数量分别为 32, 64, 128, 256。最后, 通过两个全连接层至输出层, 每个全连接层都添加了 Dropout 层, 防止模型过拟合。输出层是一个完全连通的层, 有 5 个神经元对应 5 种地震类别。

4. 实验结果

4.1. 实验环境

开展本研究的计算机的硬件环境为: CPU 型号为 Intel(R) Core(TM) i5-9300H, 显卡型号为 NVIDIA 1660 GeForce GTX Ti。软件环境为: 操作系统为 Windows 11 操作系统, 编程语言为 Python, 集成开发环境为 PyCharm, 主要三方库有 tensorflow、numpy、pandas、PIL、scipy、scikit-learn。

4.2. 实验数据

地震数据来源于中国地震台网(<https://news.ceic.ac.cn/>), 按照纬度范围 $26^{\circ}\text{N} \sim 31^{\circ}\text{N}$, 经度范围 $100^{\circ}\text{E} \sim 104^{\circ}\text{E}$, 时间范围从 2022 年 2 月 1 日~2023 年 1 月 1 日, 有感地震震级 $M_s > 3.0$ 为限定条件[10]查询地震记录, 可以发现在监测区域周围 400 公里以内发生 18 次地震, 监测区域的地磁数据都有反应。具体可见表 3。

Table 3. Earthquake list

表 3. 地震列表

发震时刻	震级(M)	纬度($^{\circ}$)	经度($^{\circ}$)	距离(千米)	参考位置
2022-03-29 05:25:09	4.3	30.03	103.41	357.59	四川眉山市丹棱县
2022-03-30 11:52:28	3.7	27	103.26	239.80	云南昭通市巧家县
2022-04-06 21:07:55	3.4	27.77	100.63	251.84	云南丽江市宁蒗县
2022-04-16 08:32:13	4.6	27.78	100.62	253.06	云南丽江市宁蒗县
2022-04-22 12:36:52	3.2	29.94	102	290.54	四川甘孜州康定市
2022-04-30 01:23:47	4.2	27.77	100.63	251.84	云南丽江市宁蒗县
2022-05-20 08:36:36	4.8	29.67	102.48	250.34	四川雅安市汉源县
2022-06-01 17:00:08	6.1	30.37	102.94	374.80	四川雅安市芦山县
2022-06-20 06:40:52	4.4	27.21	103.75	280.57	贵州毕节市威宁县
2022-09-05 12:52:18	6.8	29.59	102.08	234.65	四川甘孜州泸定县
2022-10-04 07:19:34	3.4	26.97	103.11	227.75	云南昭通市巧家县
2022-10-04 20:44:27	3.6	28.91	102.14	127.50	四川凉山州冕宁县
2022-10-05 03:17:26	3.7	29.39	102.21	202.51	四川雅安市石棉县
2022-10-22 13:17:01	5	29.61	102.03	238.53	四川甘孜州泸定县
2022-11-12 07:13:39	4.2	26.93	102.92	215.65	云南昭通市巧家县
2022-11-16 10:46:59	4.3	26.46	102.04	258.67	四川凉山州会理市
2022-11-18 21:23:56	4.3	29.62	102.01	240.46	四川甘孜州泸定县
2022-12-25 02:15:57	3.1	26.85	100.8	294.62	云南丽江市宁蒗县

4.3. 地震数据集构建

由于期间一共发生了 18 次地震, 次数较少, 因此地震类别不宜太多, 否则会导致落入每个类别中的地震次数过少, 训练后的模型只在训练集上表现效果优秀, 却难以推广到测试集中, 即出现过拟合现象。

地震震级转化为类别比较简单, 只要选取一个震级, 保证大于这个震级的地震和小于这个震级的地震数量接近 5:5 即可, 根据表 3 中的震级分布情况, 将用于分类的震级设置为 4 级, 18 次地震中, 有 7 次地震小于等于 4 级, 11 次地震大于 4 级。

地震方位转化为类别就要用到聚类算法, 本研究所用的选择 K 均值聚类算法, 距离采用的是欧式距离。将方位类别确定为 2, 利用 SPSS 软件确定这两个类别中心的经纬度为(29.68°N, 102.37°E)和(27.19°N, 101.97°E), 而研究区域中心的经纬度为(28.10°N, 102.16°E), 从两个类别中心相对于研究区域中心的位置来看, 可以将方位类别分为南北两个类别。

根据以上震级和方位的分类规则, 可以得到 4 个地震类别, 再加上一个未发生地震的类别, 共 5 个类别, 具体可见表 4。

Table 4. Classification of contour map

表 4. 等值线图像类别

是否地震	方向	震级	类别	地震次数	等值线图数量
否			0		169
是	北	>4	1	6	83
是	北	<4	2	3	21
是	南	>4	3	5	36
是	南	<4	4	4	25

按照这种方式进行分类之后, 从数量上看, 标记为未发生地震的日期为 169, 有地震发生的日期为 165, 二者比例接近 5:5。

4.4. 数据增强

观察该数据集可以发现存在一个问题: 样本量太少。一共 334 张图片还分成了 5 个类别, 导致真正要识别的地震类别中的图像数量太少, 这样训练出来的神经网络泛化能力一般不会太好。为此, 本研究采用了诸如亮度增强、对比度增强、水平翻转等数据增强方法提高样本数量。考虑到地震方位是在南北方向, 因此在纵向上旋转图像势必会对图像的南北特征产生影响, 因此在图像增强时只是做了水平翻转而没有做任何纵向翻转和图像旋转操作。

这样进行了数据增强操作之后, 样本总量从 334 增加至 1649, 扩大至原来的 4.93 倍, 各个类别的样本数量也有所增加。

5. 分析与总结

5.1. 实验结果分析

本节将利用 VGG-12 模型开展训练和测试, 并将其与基于传统数字图像处理的预测模型进行对比分析。

在深度学习中, 数据集的选取对神经网络模型的训练有着直接影响, 本研究所用数据集中共有 1649 张图片, 类别共 5 类, 分为 0, 1, 2, 3, 4, 各有 833, 437, 96, 169, 114 张图片, 在 1649 张图像中,

选取 1319 张用于训练, 330 张用于测试。

使用 VGG-12 模型进行训练和测试, 并利用混淆矩阵、准确率、召回率来对网络性能进行评价, 得到混淆矩阵见表 5。

Table 5. Result of classification

表 5. 分类结果

真实类别	预测类别					总计
	0	1	2	3	4	
0	115	3	4	1	3	125
1	8	81	8	4	1	103
2	7	2	14	1	4	28
3	6	8	3	26	1	45
4	3	0	5	1	21	30
总计	139	94	34	33	30	330

各个类别的准确率与召回率为:

Table 6. Evaluation of classification

表 6. 分类评价

指标 \ 类别	0	1	2	3	4
准确率	89.64%	89.33%	75.55%	80.34%	84.38%
召回率	92.00%	78.64%	50.45%	58.30%	70.71%

5.2. 总结

由表 6 可知, VGG-12 对于除了类别 2 以外的类别识别准确度都达到了 80%以上, 模型在等值线图分类上表现良好, 其中类别 0 的识别度最高, 其次是类别 1, 最低的是类别 2, 推测可能原因有 2 个:

分类为 0 和 1 的样本数量最多, 分类为 2 的样本数量最少, 因此模型对于类别 0 和 1 的特征识别度更全面和精确, 对类别为 2 的特征识别度受限于样本数要模糊一些;

类别 0 代表无地震发生时的等值线图, 这种等值线图一般不具备在 4.1.3.节所总结的 4 个特征, 因此整个图像的像素值变化比较平缓, 因此特征数量更少, 也更好识别; 而类别 1 代表等级大于 4 级的地震, 因此图像表现刚好与类别 0 的图像相反, 其像素值变化剧烈, 图像中的细节更多, 因此在充分训练之后, 突出特征被网络识别, 因此也能更好识别; 而类别 2 代表震级小于 4 级的地震, 其图像中像素的变化居于无地震和强震之间, 因此可能同时具有这两种类别图像的特征, 如果其中代表强震或者无震的特征稍微多一些, 就会被误分到无震和强震的类别中, 从而导致该类的识别效果不好。

对单张图像的识别可以将该图像分类, 由于震前地磁异常会连续多天出现, 因此该次地震对应的震前地磁异常等值线图也会多天表现出相同的特征并被神经网络分到同一个类别中。因此在地磁异常出现后, 可以用异常前后连续几天的分类结果来对这次地震的震级和方位的性质进行分析, 进而也就实现了对地震的方位和震级实现预测。

6. 结论

本研究提出了一种以 VGGNet 为原型的改进后的 VGG-12 模型, 该模型相较于原始 VGGNet 而言有更少的隐含层和参数, 可以有效减少训练过程中的计算量。利用该模型对由分类后的地磁异常等值线图构成的数据集进行训练和预测。实验结果表明, 该模型可以很好地提取图像中与地震有关的特征信息, 以较高的准确率将图像归入它所对应的地震类别中, 从而实现对地震方位和震级的预测。

但是受时间与技术的限制, 研究过程还仍然存在一些不足之处:

1) 深度学习时样本数量太少, 即使经过数据增强后, 也只是勉强达到了神经网络模型训练所需的最低样本数量, 而且样本数量太少使得要素类别也只能做简单划分;

2) 研究地震时只研究了研究区域附近约 350 km 及以内的地震, 只考虑了距离因素对于研究区域的影响, 实际上如果震级够大, 地震影响的范围还能进一步提高。

基金项目

国家自然科学基金项目 42074074。

参考文献

- [1] 袁一凡. 四川汶川 8.0 级地震损失评估[J]. 地震工程与工程振动, 2008(5): 10-19.
<https://doi.org/10.13197/j.eeev.2008.05.003>
- [2] Fraser-Smith, A.C., Bernardi, A., McGill, P.R., *et al.* (1990) Low-Frequency Magnetic Field Measurements near the Epicenter of the Ms 7.1 Loma Prieta Earthquake. *Geophysical Research Letters*, **17**, 1465-1468.
<https://doi.org/10.1029/GL017i009p01465>
- [3] Uyeda, S., Hayakawa, M., Nagao, T., *et al.* (2002) Electric and Magnetic Phenomena Observed before the Volcano-Seismic Activity in 2000 in the Izu Island Region, Japan. *Proceedings of the National Academy of Sciences*, **99**, 7352-7355. <https://doi.org/10.1073/pnas.072208499>
- [4] 曾小苹, 郑吉盎, 王翊焱, 等. 震前特大地磁异常及其短临预警意义[J]. 中国工程科学, 2011, 13(4): 48-53.
- [5] Collobert, R. and Weston, J. (2008) A Unified Architecture for Natural Language Processing: Deep Neural Networks with Multitask Learning. *Proceedings of the 25th International Conference on Machine Learning*, New York, NY, 5-9 July 2008, 160-167. <https://doi.org/10.1145/1390156.1390177>
- [6] Avilov, O., Rimbert, S., Popov, A., *et al.* (2020) Deep Learning Techniques to Improve Intraoperative Awareness Detection from Electroencephalographic Signals. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, 20-24 July 2020, 142-145.
<https://doi.org/10.1109/EMBC44109.2020.9176228>
- [7] Li, Y. (2022) Research and Application of Deep Learning in Image Recognition. 2022 IEEE 2nd International Conference on Power, Electronics and Computer Applications (ICPECA), Shenyang, 21-23 January 2022, 994-999.
<https://doi.org/10.1109/ICPECA53709.2022.9718847>
- [8] Dong, Z., Wu, Y., Pei, M., *et al.* (2015) Vehicle Type Classification Using a Semisupervised Convolutional Neural Network. *IEEE Transactions on Intelligent Transportation Systems*, **16**, 2247-2256.
<https://doi.org/10.1109/TITS.2015.2402438>
- [9] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2017) Imagenet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, **60**, 84-90. <https://doi.org/10.1145/3065386>
- [10] 中国地震局地球物理研究所, 中国地震台网中心, 国家海洋环境预报中心, 起草. GB 17740-2017, 地震震级的规定[S]. 2017.