

doi:10.3969/j.issn.2097-0013.2023.03.001

基于EfficientNet的滑坡遥感图像识别方法——以贵州省毕节市为例

李长冬^{1,2}, 龙晶晶¹, 刘勇^{3*}, 易书帆¹, 冯鹏飞³

LI Chang-Dong^{1,2}, LONG Jing-Jing¹, LIU Yong^{3*}, YI Shu-Fan¹, FENG Peng-Fei³

1. 中国地质大学(武汉)工程学院, 湖北 武汉 430074; 2. 中国地质大学(武汉)湖北巴东地质灾害国家野外科学观测研究站, 湖北 武汉 430074; 3. 中国地质大学(武汉)机械与电子信息学院, 湖北 武汉 430074

1. Faculty of Engineering, China University of Geosciences, Wuhan 430074, Hubei, China; 2. Badong National Observation and Research Station of Geohazards, China University of Geosciences, Wuhan 430074, Hubei, China;

3. School of Mechanical Engineering and Electronic Information, China University of Geosciences, Wuhan 430074, Hubei, China

摘要:近年来,随着工程建设的快速发展,工程活动改变了边坡原始地质条件,导致滑坡灾害频繁发生,严重威胁人民的生命财产安全。因此,深入研究滑坡的快速、精确识别方法对于防灾减灾具有重要意义。本文提出一种基于EfficientNet高效网络提取滑坡深度特征的潜在滑坡识别方法,该方法通过寻找一组最优的复合系数从深度、宽度、分辨率三个维度对神经网络进行扩展,自适应地优化网络结构,并引入带动量的梯度下降算法(Stochastic Gradient Descent Momentum, SGDM)作为网络学习的优化器,充分考虑历史梯度的影响,在参数更新过程中不断调整当前梯度值,从而相应地调整参数的更新幅度,改善神经网络的学习效果,提取滑坡体的深层次特征。实验结果表明,EfficientNet模型在测试集上的平均准确度达到92.78%,可以高效准确地实时提取滑坡信息,对灾后的快速反应有指导意义。

关键词:滑坡识别;深度特征;EfficientNet;带动量的梯度下降算法(SGDM)

中图分类号:P642.22

文献标识码:A

文章编号:2097-0013(2023)03-0403-10

Li C D, Long J J, Liu Y, Yi S F and Feng P F. 2023. Landslide Remote Sensing Image Recognition Based on EfficientNet: Taking Bijie City, Guizhou Province as an Example. *South China Geology*, 39(3): 403–412.

Abstract: In recent years, with the rapid development of engineering construction, engineering activities have changed the original geological conditions of slopes, resulting in frequent landslide disasters, which seriously threaten people's life and property safety. Therefore, it is of great significance to study the rapid and accurate identification method of landslides for disaster prevention and reduction. In this paper, a potential landslide recognition method is proposed based on EfficientNet to realize the extraction of landslide depth features. The method extends the neural network from three dimensions of depth, width, and resolution by searching for a set of optimal composite coefficients, and adaptively optimizes the network structure. The Stochastic Gradient Descent Momentum (SGDM) is introduced as the optimizer of network learning, which fully considers the influence of historical gradient. And the current gradient value is constantly adjusted during the param-

收稿日期:2023-6-1;修回日期:2023-7-17

基金项目:国家自然科学基金重大项目(42090054)、湖北省创新群体项目(2022CFA002)

第一作者:李长冬(1981—),男,教授,博士生导师,从事地质灾害演化机理与防治研究,E-mail:lichangdong@cug.edu.cn

通讯作者:刘勇(1979—),男,副教授,博士生导师,主要从事滑坡数据智能化处理研究,E-mail:yongliu@cug.edu.cn

eter updating process, so as to adjust the parameter updating amplitude accordingly, improve the learning effect of neural networks and extract the deep features of the slope. The experimental results show that the average accuracy of the EfficientNet model on the test set reaches 92.78%, which can efficiently and accurately extract landslide information in real-time and provides guiding information for the rapid response after the disaster.

Key words: landslide identification; deep feature; EfficientNet; Stochastic Gradient Descent Momentum (SGDM)

滑坡是一种全球性的地质灾害,常常给工农业生产及人民生命财产造成巨大损失(Su A J et al., 2022;唐辉明等,2022)。我国地质条件复杂,地形地貌多样,是世界上地质灾害最严重,受威胁人口最多的国家之一(李长冬等,2020;李长冬和谭钦文,2022;唐辉明,2022;邱芹军等,2023)。滑坡灾害具有突发性、多发性和群发性的特点,其诱发因素复杂多样,主要包含河流冲刷、强降雨(李长冬等,2022;陈慧娟等,2023)、地震和人工切坡等(张勤等,2017)。近年来,由于我国社会经济的快速发展以及地震和大气降水等因素的影响,滑坡灾害的发生越来越频繁,其影响也越来越大(李益敏等,2021)。滑坡灾害严重制约着区域的经济的发展,对人类的生命财产造成巨大损失,环境资源也遭受了巨大的破坏,因而探索更加快速、精确的滑坡识别方法具有十分重要的意义(张勤等,2022)。

传统的潜在滑坡识别主要是根据经验判别技术(Schuster and Krizek, 1979),综合运用概率评估、统计分析等方法,从地貌、地层、水文地质以及裂缝类型等方面开展滑坡识别工作。然而这些方法由于主观性过强,所提取的特征信息大都停留于表层,极大的限制了滑坡的分类精度。随着遥感技术的出现与发展,基于遥感影像的滑坡识别逐渐成为主流。其中遥感影像应用研究是较为新颖的技术手段(陈冠宇等,2016a)。Stephens et al.(1988)利用TM、Spot卫星数据进行滑坡识别和滑坡灾害预测工作;Mantovani et al.(1996)系统总结了遥感技术在欧洲国家滑坡研究中的应用;Baatz(1999)提出了面向对象的遥感影像分析方法;周乐群和杨岚(2000)提出遥感技术正朝高分辨率(地面和光源)、多时相和多角度方向发展;Blesius and Leonardo(2002)提出了一种基于遥感数据和岩土边坡稳定性参数的滑坡易感性制图方法;刘沛等(2004)、李

剑萍(2004)综合运用RS、GPS和GIS等技术建立了滑坡体的三维定量解析模式图,以此来获取滑坡的空间分布规律;Roessner et al.(2005)将卫星遥感和GIS技术综合运用在吉尔吉斯斯坦南部滑坡的危险性评估中,实现了基于交互式和自动式的滑坡信息提取;Schulz(2007)利用Ladar数据提取DEM开展滑坡敏感性制图研究;Noferini et al.(2007)利用SAR数据来监测缓慢移动的滑坡;Zhong C et al.(2012)详细讨论了不同的遥感技术数据处理和整合方法以及最新的成果;Behling et al.(2014)提出了一种基于RapidEye时间序列数据的面向对象的自动山体滑坡测绘方法;Mezaal and Pradhan(2018)提出利用CFS特征选择技术对热带森林浅层和深层滑坡进行识别,并采用随机森林对算法性能进行评估;Criss et al.(2020)提出一个易用监测数据校准的模型,可以根据水库水位变化预测滑坡运动;马玉林等(2022)从滑坡的基本定义、分类以及遥感解译标志出发,总结当前主流的滑坡识别方法和精度评价方式,并分析了各个方法的基本原理及优缺点;张占忠等(2022)采用“多期次影像遥感解译监测+InSAR形变分析+现场调查”的综合研究评价方法,对江巴变形体坡面进行了详细的解译分析;殷宗敏等(2022)利用时序InSAR技术对三峡库首区的地表形变进行监测,并利用获取的形变数据圈定了潜在的滑坡区;Long Y J et al.(2023)为了解强震后滑坡活动的演变,利用最大似然法和随机森林算法对地震灾害区十年的卫星图像进行处理。尽管目前国内外学者已经在滑坡识别上做了大量的研究,取得了丰硕的成果,但在一些紧急的滑坡灾害识别问题上,已有的方法暂时无法满足滑坡防治的需求,同时特征提取不够充分,因而滑坡识别的精度和速度仍然有待提高。

鉴于此,本文以贵州省毕节市为研究区域,利

用TripleSat卫星图像裁剪得到的滑坡样本数据集开展研究。为了提高滑坡灾害识别的效率和精度,本文引入EfficientNet高效网络来提取滑坡的深度特征。该网络通过使用一组最优的复合系数从深度、宽度、分辨率三个维度对神经网络进行统一缩放,自适应地优化网络结构。同时引入带动量的梯度下降算法(Stochastic Gradient Descent Momentum, SGDM)进行网络优化,该算法充分考虑历史梯度的影响,在参数更新过程中不断调整当前梯度,以改善神经网络的学习效果,从而提高滑坡识别的效率和准确率。

1 滑坡识别方法的实现

本文首先通过插值的方法对图像数据进行预处理从而形成数据集,接着以EfficientNet神经网络为主要结构对数据集进行特征的提取和分类工作。同时,本文引入SGDM算法对神经网络进行优化。该算法可以实时调整梯度,改变当前网络参数的变化范围。SGDM算法可以加快网络的收敛速度,避免神经网络陷入局部优化或鞍点。具体流程如图1所示。

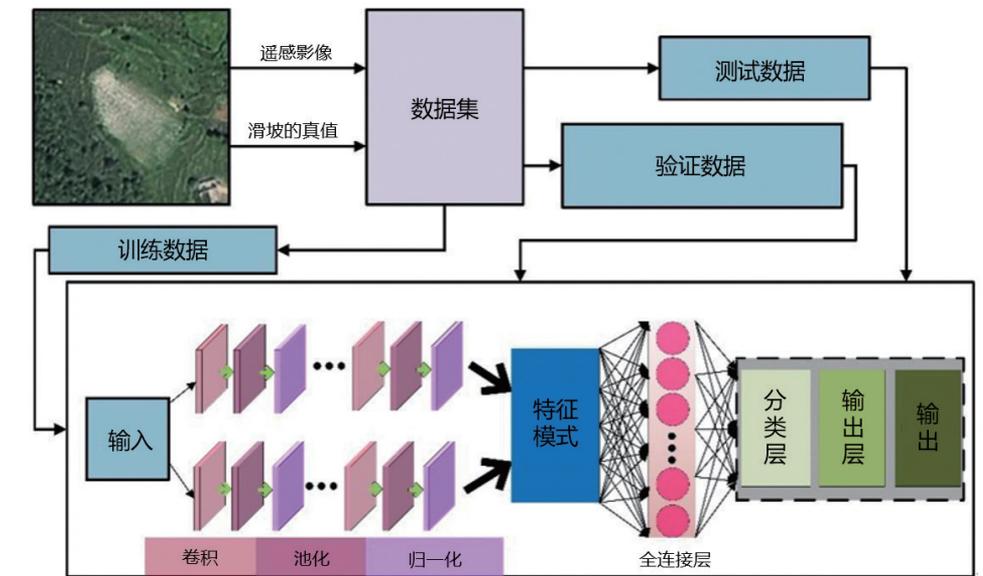


图1 基于卷积神经网络的滑坡识别流程图

Fig. 1 Flowchart of landslide identification based on Convolutional Neural Network (CNN)

据姜英等(2017)修改

1.1 数据预处理

遥感图像在使用过程中,首先需要经过预处理措施(卢薇艳等,2019)。目前常用的插值方法大致分为最近邻插值、双线性插值法和样条插值法(康牧和凌凤彩,2013)。其中最近邻插值法是最简单的插值方法,它按照最小距离原则决定原始图像映射到输出图像中某点的像素值(张芳等,2022),这种方法操作简单,处理速度快,但容易出现马赛克和锯齿现象,使得结果图像模糊化和块状化,并且容易出现像素不连续的情况;样条插值法的运算精度高,结果图像非常清晰,但其处理过程复杂,时间消

耗较多(杨春雨和张鑫,2022)。双线性插值法效果要好于最近邻插值法,但是计算量稍大,算法更复杂,程序运行时间也更长,但缩放后图像质量高,基本克服了最近邻插值灰度值不连续的特点。因此,综合考虑对输出图像的质量和算法效率的要求,本文采用双线性插值法完成图像的预处理工作。

双线性插值法的思想是利用原始图像像素点周围四个近邻像素点之间的相关性,运用双线性算法处理得到结果图像(周前祥等,2004)。该方法使用插值点周围4个近邻点的像素值加权内插作为该点的像素值,其过程可分解为两个一维线性插

值,即 x 方向和 y 方向线性插值。由于从原始图像映射到结果图像的过程中,新的坐标不一定是整数,而数字图像处理领域要求像素值只在整数坐标处有定义,因此只能借助于映射点周围的一些整数坐标点的像素值来估计待求点的像素值。具体计算方法如下:

设 $P(x,y)$ 点(x,y 不一定为整数)周围 2×2 区域的四个近邻点A、B、C、D坐标分别为 (u,v) 、 $(u+1,v)$ 、 $(u,v+1)$ 、 $(u+1,v+1)$,这四点的像素已知,分别为 $f(A)$ 、 $f(B)$ 、 $f(C)$ 、 $f(D)$ 。

第一步,在 x 方向做线性内插。设 $M(x,v)$ 、 $N(x,v+1)$,计算 M 、 N 两点的像素值公式如下:

$$\begin{aligned} f(M) &= (x-u)[f(B)-f(A)]+f(A) \\ &= (u-x+1)f(A)+(x-u)f(B) \end{aligned} \quad (1)$$

$$\begin{aligned} f(N) &= (x-u)[f(D)-f(C)]+f(C) \\ &= (u-x+1)f(C)+(x-u)f(D) \end{aligned} \quad (2)$$

第二步,在 y 方向做线性内插。设点 $P(x,y)$ 的像素值为 $f(P)$,则:

$$\begin{aligned} f(P) &= (y-v)[f(N)-f(M)]+f(M) \\ &= (v-y+1)f(M)+(y-v)f(N) \end{aligned} \quad (3)$$

1.2 神经网络模型

1.2.1 EfficientNet模型

目前,深度学习算法中的卷积神经网络(Convolutional Neural Networks, CNN)在滑坡识别中应用最为广泛。CNN通过不同的卷积核提取图像局部特征,完成图像识别分类(陈冠宇等, 2016b)。一般的CNN结构包括卷积层、池化层、非线性变换和全连接层(Li S et al., 2021),其结构如图2所示。CNN可以处理具有清晰的网络结构拓扑的数据,特别是在二维图形拓扑上获得了巨大的成功。因此,CNN是当前图像识别领域的核心算法之一。

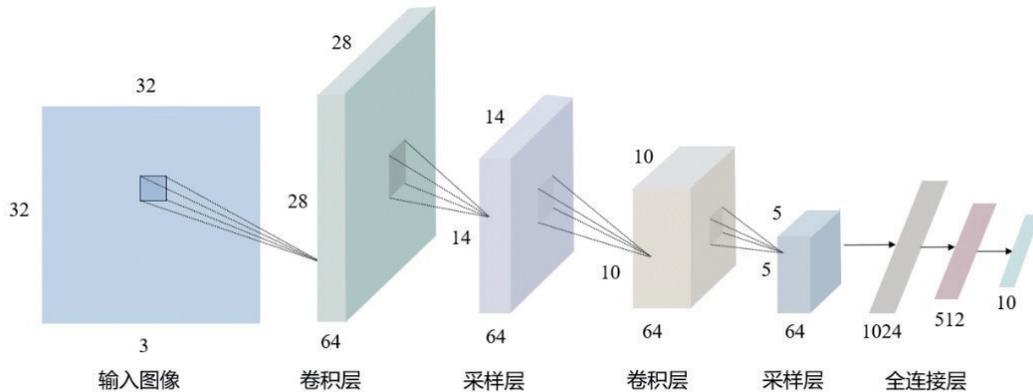


图2 卷积神经网络结构图

Fig. 2 Convolution neural network (CNN) structure diagram

据 Krizhevsky et al. (2017)修改

为了提高神经网络的精度,一般会对图片分辨率、网络的深度和宽度(卷积通道数)三个维度中的某个维度进行调整,实现卷积神经网络的扩展(徐宏根等, 2019)。但这种方式得到的网络在精度上具有很大的局限性,即精度增益在达到80%后会迅速饱和,因而无法实现精度的进一步提升(Chen L et al., 2021)。此外,单一维度调整网络结构往往容易导致特征丢失,出现过拟合情况。并且随着网络的宽度和深度达到一定程度,网络的识别率反而会下降,网络的参数也会更多,对硬件要求也越高。为解

决上述问题,考虑网络深度、网络宽度、图像分辨率三个维度之间的关系并探索出最合适的组合,提出EfficientNet算法,以设计一个标准化的卷积网络扩展方法,可以同时兼顾速度与精度的模型缩放,既可以实现较高的准确率,又可以充分节省算力资源(Tan M X and Le Q V, 2019)。

EfficientNet通过使用一组最优的复合系数来从深度、宽度、分辨率三个维度进行统一缩放,自适应地优化网络结构,同时避开了传统单一维度调整网络时的任意性。大量实验表明,该模型无论是在

识别效率还是识别准确率上都具有很大的优势。EfficientNet 的基础网络架构 (Tan M X and Le Q V, 2019) 是通过神经网络架构搜索技术得到的 (图 3), 将整个卷积网络称为 N , 它的第 i 个卷积层可表示为如式 (4) 所示的函数映射:

$$Y_i = F_i(X_i) \tag{4}$$

其中, X_i 为输入张量, Y_i 为输出张量。若卷积神经网络由 k 个卷积层组成, 则卷积神经网络 N 可表示为:

$$\begin{aligned} N &= F_k \circ \dots \circ F_2 \circ F_1(X_1) \\ &= e_{j=1 \dots k} F_j(X_1) \end{aligned} \tag{5}$$

实际上, 多个结构相同的卷积层可表示为一个 stage, 以 stage 为单位, 卷积网络 N 可表示为:

$$N = e_{i=1 \dots s} F_i^{L_i}(X_{\langle H_i, W_i, C_i \rangle}) \tag{6}$$

其中, $F_i^{L_i}$ 表示第 i 个 stage 的卷积运算, 它由某一卷积层重复 L_i 次构成, L_i 即为网络的深度; $\langle H_i, W_i, C_i \rangle$ 表示第 i 层输入张量的维度, 其中, C_i 是通道的数目, 即网络的宽度; H_i 和 W_i 为图片的分辨率。为了减小搜索空间, EfficientNet 只在三个维度上进行缩放。尽管如此, 搜索空间仍然很大, 因此增加一个限制, 即一个卷积网络的所有卷积层必须通过相同的比例常数进行统一扩展, 网络的放大只在 EfficientNet-B0 的基础上进行, 最终模型可抽

象为如下优化问题:

$$\begin{aligned} \max_{d, w, r} & \text{Accuracy}[N(d, w, r)] \\ \text{s.t.} & N(d, w, r) = e_{i=1 \dots s} \hat{F}_i^{d \times L_i}(X_{r \times \bar{H}_i, r \times \bar{W}_i, w \times \bar{C}_i}) \tag{7} \\ & \text{Memory}(N) \leq \text{target_memory} \\ & \text{Flops}(N) \leq \text{target_flops} \end{aligned}$$

其中, “s.t.” 全称 subject to, 代表限制条件, w 、 d 和 r 分别表示网络宽度 (C_i)、深度 (L_i) 以及分辨率 (H_i 和 W_i) 的倍率。 target_memory 指给定的计算内存; target_flop 指每秒浮点运算数。式 (7) 旨在通过优化参数, 在给定的计算内存和效率的约束下, 构建最高效的模型。

对神经网络单一维度进行缩放具有局限性, EfficientNet 网络提出混合缩放方法 (compound scaling method), 即通过使用组合缩放系数 ϕ , 同时缩放宽度 w 、深度 d 和图片分辨率 r 。其缩放基数分别为 α 、 β 、 γ 。 (α, β, γ) 为一组待求解的参数, 则约束优化问题可用式 (8) 表示:

$$\begin{aligned} \text{depth: } & d = \alpha^\phi \\ \text{width: } & w = \beta^\phi \\ \text{resolution: } & r = \gamma^\phi \\ \text{s.t. } & \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ & \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{aligned} \tag{8}$$

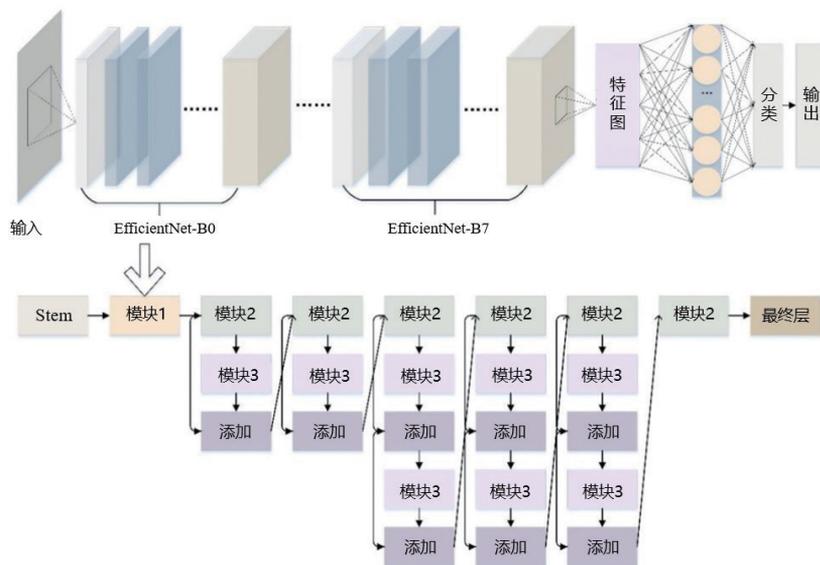


图 3 EfficientNet 基础网络架构

Fig. 3 The basic structure diagram of EfficientNet

据 Tan M X and Le Q V (2019) 修改

其中, β 和 γ 在约束上会有平方, 因为如果增加宽度或分辨率为其原来的两倍, 那么其计算量将会增加到原来的四倍, 而如果增加深度为其原来的两倍, 其计算量只会增加到原来的两倍。

该优化问题具体求解方式如下:

1. 固定公式中的 $\phi=1$, 然后基于公式(7)和(8)进行搜索, 得出最优的 α 、 β 、 γ , 进而得到最基本的模型 EfficientNet-B0。在约束条件下, 大量实验发现, 在 Efficient-B0 上最优的参数是 $\alpha=1.2$ 、 $\beta=1.1$ 、 $\gamma=1.15$ 。

2. 固定 α 、 β 、 γ 的值, 在 Efficient-B0 的基础上, 使用不同的 ϕ , 从而得到 EfficientNet-B1 至 EfficientNet-B7。

需要注意的是, 公式中 ϕ 的大小对应着消耗资源的大小, 即当 $\phi=1$ 时, 得出了一个最小的最优基础模型, ϕ 增大时, 相当于对最小基础模型的三个维度同时进行扩展, 模型变大, 性能会得到提升, 但资源消耗也会变大。

根据算力不同, EfficientNet 网络架构按照缩放尺度不同分为 B1-B7 七种网络, 这七种网络利用 16 个 Block 块, 交叉使用 3×3 和 5×5 的卷积核进行特征提取。本文重点介绍基础网络模型 EfficientNet-B0(表 1)。B1-B7 七种网络即为在 B0 的基础上

修改分辨率、通道数级层数而得到的。EfficientNet-B0 网络分为 9 个阶段(Stage), 第一个阶段为一个卷积核大小为 3×3 , 步距为 2 的普通卷积层, 第二个阶段到第八个阶段都是在重复移动翻转瓶颈卷积(mobile inverted bottleneck convolution, MBConv)模块, 层数(Layers)表示该层重复 MBConv 结构的次数, 第九层由一个 1×1 的卷积层、一个全局平均池化层(Global Average Pooling)和全连接层(Full Connected layer, FC)分类层所组成。在表格中, 每个 MBConv 后的数字 1 或 6 表示倍率因子, $k3 \times 3$ 表示 MBConv 中 Depthwise 卷积所采用的卷积核大小。在 MBConv 模块中, 使用 Depthwise 卷积以减少计算量; 采用 Inverted Residual 结构来加强特征的传递; 引入了压缩与激发网络结构(Squeeze-and-Excitation Network, SENet)的注意力思想, 来增强特征的表达能力。

1.2.2 带动量的梯度下降法(SGDM)算法

神经网络的参数空间十分复杂, 无法轻易找到最优解, 因而在神经网络的学习过程中需要使用优化算法, 从而沿着梯度的方向不断更新参数, 并逐渐靠近网络的最优参数。不同的优化算法会带来参数调整速度和网络学习效果上的差异, 进而影响最后的识别精度及效率。因此, 根据数据集的特点和解决问题的侧重来选择不同的优化算法具有重要意义。

表 1 EfficientNet-B0 基础网络
Table 1 EfficientNet-B0 Basic Network

阶段 (Stage) i	操作算子 (Operator) \hat{F}_i	分辨率 (Resolution) $\hat{H}_i \times \hat{W}_i$	#通道数 (Channel numbers) \hat{C}_i	#层数 (Layers) \hat{L}_i
1	Conv 3×3	224×224	32	1
2	MBConv1, $k3 \times 3$	112×112	16	1
3	MBConv6, $k3 \times 3$	112×112	24	2
4	MBConv6, $k5 \times 5$	56×56	40	2
5	MBConv6, $k3 \times 3$	28×28	80	3
6	MBConv6, $k5 \times 5$	14×14	112	3
7	MBConv6, $k5 \times 5$	14×14	192	4
8	MBConv6, $k3 \times 3$	7×7	320	1
9	Conv 1×1 & Pooling & FC	7×7	1280	1

注: 据 Tan M X and Le Q V(2019)修改。

本文选用 SGDM 来进行参数调整和网络学习工作。算法流程见表 2。该方法考虑到历史梯度的加权平均值作为速率进行优化, 即如果当前时刻的

梯度与历史时刻梯度方向相似, 则历史梯度所带来的惯性会在当前时刻的梯度上产生加强的效果, 参数调整的幅度也更大; 如果当前时刻的梯度与历史

表2 带动量的梯度下降法(SGDM)算法流程
Table 2 Stochastic Gradient Descent Momentum (SGDM) Algorithm Process

Require: 初始参数 $\theta=0$
初始化速度 $v=0$
While 未达到停止准则 do
从训练集中随机选取 m 个样本 $\{x^{(1)}, \dots, x^{(m)}\}$,
对应的目标为 $\{y^{(1)}, \dots, y^{(m)}\}$
计算梯度: $g = \frac{1}{m} \nabla_{\theta} \sum_i L[f(x^{(i)}; \theta), y^{(i)}]$
计算速度更新: $v = av - \varepsilon g$
应用更新: $\theta = \theta + v$
end while

时刻梯度方向有明显差异,则会造成当前时刻的梯度方向减弱。也就是说,SGDM算法会根据历史梯度的影响来实时地调整当前梯度,从而避免了SGDM优化算法中在某时刻梯度接近零而无法再次进行参数更新的情况出现(陈聪等,2021)。同时,参数的更新幅度也会相应做出改变,故该优化算法拥有比随机梯度下降法(Stochastic Gradient Descent, SGD)更快的收敛速度。此外,相比于Adam等学习率自适应调整的优化算法,SGDM的收敛精度往往更高,学习效果也更好。因此,考虑一阶动量因子的SGDM优化算法能够使得网络的训练更加高效,因而在神经网络中得到广泛的应用。

设待更新的权重参数和偏置分别为 w 和 b ,动

量梯度下降法对求得的梯度 dw, db 使用指数加权求平均得到对应的一阶动量因子 v_{dw}, v_{db} ,学习率为 a ,指数衰减率为 η ,则使用SGDM算法进行网络更新的公式如下:

$$v_{dw^{[k]}} = \eta v_{dw^{[k-1]}} + (1 - \eta) dw^{[k]} \quad (9)$$

$$w^{[k]} = w^{[k-1]} - av_{dw^{[k]}} \quad (10)$$

$$v_{db^{[k]}} = \eta v_{db^{[k-1]}} + (1 - \eta) db^{[k]} \quad (11)$$

$$b^{[k]} = b^{[k-1]} - av_{db^{[k]}} \quad (12)$$

2 实例分析

2.1 研究区域及数据

本文研究区域位于贵州省毕节市(图4a),该区域地处青藏高原向东部丘陵过渡的斜坡带,海拔457~2900 m,海拔相对高差大,多陡峭山坡,雨量充沛(年平均降雨量为849~1399 mm),生态环境脆弱。同时,毕节市位于云贵高原,地势上属于二三级阶梯交汇处,区域范围内海拔相对高差大。毕节市的地形和降水条件,为滑坡的发育奠定了基础。本文以Ji S P et al.(2020)根据历史滑坡编录数据、现场调查以及结合TripleSat卫星遥感影像资料获得的770个滑坡样本和2003个非滑坡样本组成的开源数据集为研究对象(图4b),开展潜在的滑坡识别研究。

2.2 实验结果

本文实验环境硬件以及软件环境如下:处理器 Intel(R)Core(TM)17-10750H,运行内存16GB,显卡

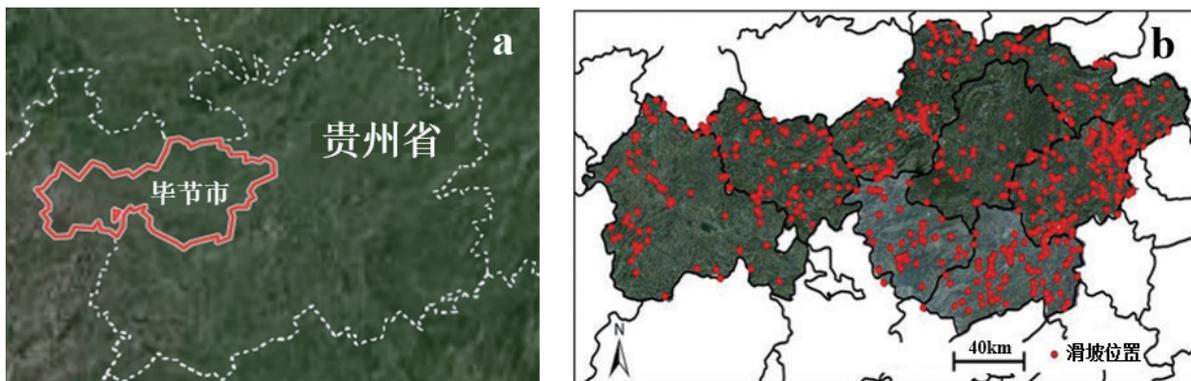


图4 研究区位置图(a)和毕节市滑坡分布图(b)

Fig. 4 (a) Location map of the study area, and (b) landslide distribution map of Bijie City

据 Ji S P et al.(2020)修改.

型号为NVIDIA GeForce GTX 1650 Ti;所有代码均在软件Matlab2021a中运行。实验时,将所有滑坡遥感图像使用双线性插值统一大小为 224×224 。实验数据集选择样本数据中90%的数据作为训练数据,剩下10%的数据作为测试数据。具体数据集划分(据Ji S P et al., 2020)见表3。

表3 本次实验的数据集分类

Table 3 Classification of the dataset for this experiment

	训练集	测试集
滑坡	693	77
非滑坡	1803	200

2.2.1 评价指标

对于实验结果数据,本次采用精确度(Precision, P)、召回率(Recall, R)和准确度(Accuracy, A)作为评价指标对模型进行进一步评价。其中,精确度也叫查准率,是指正确预测为正的样本数占全部预测为正的样本数的比例,它表示对正样本数据的预测准确程度。召回率是指正确预测为正的样本数占全部实际为正的样本数的比例。准确度是指所有被预测正确样本数的比例,该指标能够得出总的正确率。根据预测结果和实际结果的不同匹配形式,可以把结果数据分为四类,即 True Positive (TP)、False Positive (FP)、True Negative (TN) 和 False Negative (FN),其中,TP表示将正类预测为正类的样本数目,FP表示将负类预测为正类的样本数目,TN表示将负类预测为负类的样本数目,

FN表示将正类预测为负类的样本数目。将四类数据结果表示在混淆矩阵(表4)中,可以直观地得出各个评价指标。

$$P = \frac{TP}{TP + FP} \quad (13)$$

$$R = \frac{TP}{TP + FN} \quad (14)$$

$$A = \frac{TP + TN}{TP + FP + TN + FN} \quad (15)$$

表4 混淆矩阵

Table 4 Confusion Matrix

		实际值	
		0 (Negative)	1 (Positive)
预测值	0 (Negative)	TN (True Negative)	FN (False Negative)
	1 (Positive)	FP (False Positive)	TP (True Positive)

2.2.2 结果分析

在与本文的EfficientNet模型进行性能比较时,我们测试了以下较为流行的网络结构:ResNet-18、Inceptionresnet-v3和AlexNet。经过计算,我们得到了在学习率设置为0.0001、批量大小设置为20、训练周期为6轮、每轮的迭代次数为85次、最大迭代次数为510次的情况下EfficientNet模型和其它神经网络模型的测试结果(表5)。从表5中可以看出,EfficientNet准确度达到了92.78%,而其他模型的准确率均在90%以下。

表5 EfficientNet模型和其它神经网络模型的测试结果比较

Table 5 The comparison of the test results of EfficientNet model and the other neural network models

网络模型	TP	FN	FP	TN	P(%)	R(%)	A(%)
ResNet-18	48	29	8	192	85.71	62.34	86.64
AlexNet	27	50	0	200	100	54.00	81.95
InceptionresNet-v3	33	44	1	199	97.06	42.86	83.75
EfficientNet	54	23	13	187	80.60	70.13	92.78

3 讨论

本文使用EfficientNet模型自动识别滑坡,在

本研究区域中得到了较好的效果。该模型的识别准确率达到92.78%,但是也存在一些问题。一方面是模型的识别效率较低,该模型识别一张遥感图像耗时较长,因此可以进一步简化模型,同时还要提

高模型的识别准确度。另一方面则存在模型识别单一的问题,本文主要使用深度学习对潜在滑坡进行识别,为二分类任务,即区分滑坡与非滑坡,如何使用该模型进行滑坡识别多分类任务仍需要进一步研究。由于不同区域滑坡的形成条件及滑坡运动类型不同,与之对应的影像形态特征也不同,下一步可从运动类型,如蠕变、加速等角度对滑坡进行多分类识别研究。

4 结论

(1)基于遥感影像的滑坡识别一直处于一种低效率与低准确度的状态。鉴于此,本文使用EfficientNet特征提取识别模型,通过寻找一组最优的复合系数来从深度,宽度,分辨率三个维度对神经网络进行扩展,自适应地优化网络结构。并运用SGDM算法作为网络学习的优化器,充分考虑历史梯度的影响,在参数更新过程中不断调整当前梯度值,从而相应地调整参数的更新幅度,改善神经网络的学习效果,提取滑坡体的深层次特征。

(2)本文采用基于毕节市的770个滑坡样本和2003个非滑坡样本数据集进行模型训练和测试。同时选择了ResNet-18、Inceptionresnet-v3、AlexNet等多种结构差异较大的卷积神经网络模型与本文所创建的神经网络(EfficientNet)进行对比。在所研究的滑坡遥感图像中,EfficientNet网络的准确度和召回率都达到了很好的效果,其中准确度高达92.78%,其它网络均低于90%。

(3)EfficientNet深度学习可以很好地对研究区内大部分滑坡进行自动识别。本研究为EfficientNet深度学习在滑坡识别领域的推广提供了理论参考。

参考文献:

陈聪,候磊,李乐乐,杨鑫涛.2021.基于GRU改进RNN神经网络的飞机燃油流量预测[J].科学技术与工程,21(27):11663-11673.

陈冠宇,李向,王岭玲.2016a.基于大数据的遥感图像植被识别方法[J].地质科技情报,35(3):204-209.

陈冠宇,安凯,李向.2016b.基于卷积神经网络的不良地质体识别与分类[J].地质科技情报,35(1):205-211.

陈慧娟,邹浩,阎遥,王超.2023.持续强降雨影响下黄梅县袁山村三组滑坡破坏特征与成因分析[J].华南地质,39(3):482-491.

姜英,王延江,林青,刘伟锋.2017.基于卷积神经网络与Bayesian决策的图像识别与分类记忆建模[J].中国科学:技术科学,47(9):977-984.

康牧,凌凤彩.2013.一种基于新插值方法的图像旋转算法[J].计算机科学,40(5):303-306.

刘沛,况顺达,姚智.2004.RS、GIS在贵州省环境地质综合调查中的应用——以崩塌、滑坡、泥石流调查为例[J].贵州地质,21(3):161-164+160.

李剑萍.2004.3S技术在灾害监测预测中的应用及展望[J].灾害学,19(S1):85-89.

卢薇艳,罗鹏,龚淑云.2019.基于遥感技术的海岸线提取及应用研究综述[J].华南地质与矿产,35(3):393-397.

李长冬,龙晶晶,姜茜慧,付智勇.2020.水库滑坡成因机制研究进展与展望[J].地质科技通报,39(1):67-77.

李长冬,谭钦文.2022.动水驱动型滑坡物理启滑能够预测吗?[J].地球科学,47(10):3908-3910.

李长冬,孟杰,项林语,黄德崑,崔宇寒.2022.白鹤滩库首区砂岩结构多尺度演变机制研究[J/OL].地球科学:1-10.

李益敏,袁静,蒋德明,王东驰,刘心知.2021.基于GIS的高山峡谷区滑坡灾害危险性评价——以泸水市为例[J].水土保持研究,28(3):355-363.

马玉林,吴华,张文海.2022.遥感技术在滑坡识别中的应用探讨[J].科技创新与应用,12(3):142-145.

邱芹军,吴亮,马凯,谢忠,陶留锋.2023.面向灾害应急响应的地质灾害链知识图谱构建方法[J].地球科学,48(5):1875-1891.

唐辉明,李长冬,龚文平,邹宗兴,张永权,张抒,张俊荣.2022.滑坡演化的基本属性与研究途径[J].地球科学,47(12):4596-4608.

唐辉明.2022.重大滑坡预测预报研究进展与展望[J].地质科技通报,41(6):1-13.

徐宏根,李春来,杨森,董小环.2019.光谱保真归一化卷积高光谱超分辨率重建方法[J].华南地质与矿产,35(4):504-513.

杨春雨,张鑫.2022.煤矿机器人环境感知与路径规划关键技术[J].煤炭学报,47(7):2844-2872.

殷宗敏,赵宝强,叶润青.2022.时序InSAR技术在三峡库首区潜在滑坡识别中的应用研究[J].华南地质,38(2):273-280.

周乐群,杨岚.2000.基于“3S”技术的国土资源与生态环境动态监测[J].华南地质与矿产,16(4):40-46.

- 周前祥,敬忠良,姜世忠.2004.遥感影像双线性插值小波融合方法[J].上海交通大学学报,38(4):547-550.
- 张勤,黄观文,杨成生.2017.地质灾害监测预警中的精密空间对地观测技术[J].测绘学报,46(10):1300-1307.
- 张勤,赵超英,陈雪蓉.2022.多源遥感地质灾害早期识别技术进展与发展趋势[J].测绘学报,51(6):885-896.
- 张芳,赵东旭,肖志涛,耿磊,吴骏,刘彦北.2022.单幅图像超分辨率重建技术研究进展[J].自动化学报,48(11):2634-2654.
- 张占忠,陈富强,刘亚林,李丹,杜世回,张晓宇.2023.基于遥感技术的嘉黎江巴变形体稳定性评价与分析[J].地质科技通报,42(3):28-37.
- Baatz M. 1999. Object-oriented and multi-scale image analysis in semantic networks[C].Proc the International Symposium on Operationalization of Remote Sensing.
- Behling R, Roessner S, Kaufmann H, Kleinschmit B. 2014. Automated Spatiotemporal Landslide Mapping over Large Areas Using RapidEye Time Series Data[J]. Remote Sensing, 6(9): 8026-8055.
- Blesius L J. 2002. A satellite based methodology for landslide susceptibility map-ping incorporating geotechnical slope stability parameters. [D]. The University of Iowa.
- Chen L, Lin W B, Chen P, Jiang S, Liu L, Hu H Y. 2021. Porosity Prediction from Well Logs Using Back Propagation Neural Network Optimized by Genetic Algorithm in One Heterogeneous Oil Reservoirs of Ordos Basin[J]. Journal of Earth Science, 32(4): 828-838.
- Criss R E, Yao W M, Li C D, Tang H M. 2020. A Predictive, Two-Parameter Model for the Movement of Reservoir Landslides[J]. Journal of Earth Science, 31(6): 1051-1057.
- Ji S P, Yu D W, Shen C Y, Li W L, Xu Q. 2020. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks[J]. Landslides, 17: 1337-1352.
- Krizhevsky A, Sutskever I, Hinton G E. 2017. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 60(6), 84-90.
- Li S, Chen J P, Liu C, Wang Y. 2021. Mineral Prospectivity Prediction via Convolutional Neural Networks Based on Geological Big Data[J]. Journal of Earth Science, 32(2): 327-347.
- Long Y J, Li W L, Huang R Q, Xu Q, Yu B, Liu G. 2023. A Comparative Study of Supervised Classification Methods for Investigating Landslide Evolution in the Mianyu-an River Basin, China[J]. Journal of Earth Science, 34 (2): 316-329.
- Mantovani F, Soeters R, Westen C. 1996. Remote sensing techniques for landslide studies and hazard zonation in Europe[J]. Geomorphology, 15(3): 213-225.
- Mezaal M R, Pradhan B. 2018. An improved algorithm for identifying shallow and deep-seated landslides in dense tropical forest from airborne laser scanning data[J]. Cate-na, 167: 147-159.
- Noferini L, Pieraccini M, Mecatti D, Macaluso G, Atzeni C, Mantovani M, Marcato G, Pasuto A, Silvano S, Tagliavini F. 2007. Using GB-SAR technique to monitor slow moving landslide[J]. Engineering Geology, 95(3): 88-98.
- Roessner S, Wetzel H U, Kaufmann H, Sarnagoev A. 2005. Potential of Satellite Remote Sensing and GIS for Landslide Hazard Assessment in Southern Kyrgyzstan (Central Asia) [J]. Natural Hazards, 35(3): 395-416.
- Schulz W H.2007.Landslide susceptibility revealed by LI-DAR imagery and historical records, Seattle, Washington[J]. Engineering Geology, 89(1-2): 67-87.
- Schuster R L, Krizek R. 1979. Landslides: Analysis and control[J]. Transportation Research Board Special Report.
- Stephens P R, Trotter C M, De Rose R C, Newsome P F, Carr K S. 1988. Use of satellite data to map landslides[C]. 9th Asian Conference on Remote Sensing, Bangkok, Thailand, J11.1-J11.7.
- Su A J, Feng M Q, Dong S, Zou Z X, Wang J G. 2022. Improved Statically Solvable Slice Method for Slope Stability Analysis[J]. Journal of Earth Science, 33(5): 1190-1203.
- Tan M X, Le Q V. 2019. EfficientNet: Re-thinking Model Scaling for Convolutional Neural Networks[C]. 36th International Conference on Machine Learning (ICML).
- Zhong C, Li H, Xiang W, Su A J, Huang X F. 2012. Comprehensive Study of Landslides through the Integration of Multi Remote Sensing Techniques: Framework and Latest Advances[J]. Journal of Earth Science, 23(2): 243-252.