

# 改进的卷积神经网络及在地层识别中的应用

肖红<sup>1</sup>, 张瑶瑶<sup>1\*</sup>, 张福禄<sup>2</sup>

(1. 东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318;

2. 东北石油大学 电气信息工程学院, 黑龙江 大庆 163318)

**摘要:**针对地层识别效率低、准确率不高的问题,提出一种基于改进卷积神经网络的地层识别新方法。该方法基于Ghost模块及扩张卷积,搭建双向级联GhostNet,可有效减少网络参数,从而降低计算量;同时,该模型具有多尺度特征提取能力,并采用双向损失函数对学习过程进行监督,从浅层聚焦于图像局部信息到深层提取语义信息,对所有层输出进行融合,可有效提高地层识别的准确度。首先根据地区特性对测井曲线进行组合优选,对数据进行分层、沃尔什滤波以及线性插值等预处理操作,然后将测井曲线形态映射为二值图像,构造样本数据集,应用改进后的网络即可进行地层识别。实验结果表明,与同类算法比较,提出算法的准确率约有六个百分点的提高,且参数量显著减少。从而表明该方法在复杂地层识别方面具有较大潜力。

**关键词:**卷积神经网络;地层识别;GhostNet;双向级联网络;测井曲线;扩张卷积

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2021)09-0167-06

doi:10.3969/j.issn.1673-629X.2021.09.028

## Improved Convolution Neural Network and Its Application of Stratigraphic Identification

XIAO Hong<sup>1</sup>, ZHANG Yao-yao<sup>1\*</sup>, ZHANG Fu-lu<sup>2</sup>

(1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China;

2. School of Electrical Engineering and Information, Northeast Petroleum University, Daqing 163318, China)

**Abstract:** Aiming at the problem of low efficiency and low accuracy of formation recognition, a new method of stratigraphic identification based on improved convolutional neural network is proposed. This method is based on the Ghost module and dilated convolution to build a bi-directional cascade GhostNet, which can effectively reduce network parameters and the amount of calculation. At the same time, the model has multi-scale feature extraction capabilities and uses a two-way loss function to supervise the learning process. The shallow layer focuses on the image local information to the deep layer to extract semantic information, and the output of all layers is fused, which can effectively improve the accuracy of stratigraphic identification. Firstly, the log curves are combined and optimized according to the regional characteristics, and the preprocessing operations such as stratification, Walsh filtering and linear interpolation are performed on them. Then the log curve shape is mapped into a binary image, the sample data set is constructed, and the improved network can be used for stratigraphic identification. The experiment shows that compared with similar algorithms, the accuracy of the proposed algorithm is improved by about six percentage points, and the amount of parameters is significantly reduced. It shows that the proposed method has great potential in the identification of complex stratigraphic.

**Key words:** convolution neural network; stratigraphic identification; GhostNet; bidirectional cascade network; logging curve; dilated convolution

## 0 引言

深度学习能够有效地从原始输入数据中提取抽象且具有良好泛化能力的特征表示<sup>[1]</sup>,卷积神经网络就是其代表算法之一,在计算机视觉中的图像分类<sup>[2]</sup>、图像语义分割<sup>[3]</sup>、目标检测<sup>[4]</sup>等方面取得了突破性的

成功。

地层识别是在一个油区范围内对全井段地层信息进行处理<sup>[5]</sup>,结果直接影响后续测井解释和储层评价的准确性<sup>[6]</sup>。众多学者利用测井曲线形态进行地层识别研究<sup>[7]</sup>。近年来,聚类分析<sup>[8]</sup>、BP神经网络<sup>[9]</sup>、贝叶

收稿日期:2020-09-13

修回日期:2021-01-14

基金项目:国家自然科学基金(61702093);黑龙江省自然科学基金(LH2019F004);国家科技重大专项(2017ZX05019005-006)

作者简介:肖红(1979-),女,博士,副教授,研究方向为智能优化算法;张瑶瑶(1993-),女,硕士研究生,研究方向为计算机视觉。

斯判别<sup>[10]</sup>等人工智能算法也逐渐应用于油气勘探工作中。

卷积神经网络的原理<sup>[11]</sup>与人工地层识别中对测井曲线的特征提取与分析有相通之处,利用卷积神经网络开展自动化地层识别具有广阔的应用前景。因此,文中基于深度卷积 Ghost 模块,利用扩张卷积构造双向级联网络,对不同尺度特征信息进行交换,有效提高地层识别的准确率。

## 1 预备知识

### 1.1 Ghost 模块

卷积操作提取的特征图冗余严重且计算成本大。Ghost 模块<sup>[12]</sup>通过卷积得到部分特征图,基于已存在的特征映射,运用低成本变换得到其他可以充分揭露内在特征信息的相似特征图,既可以减少模型参数量,也可以减少模型运算量,提高网络性能。Ghost 模块结构如图 1 所示。




图 1 Ghost 模块

在搭建网络时,文中将 Ghost 模块组成 Ghost 瓶颈结构。步长为 2 时增添深度可分离卷积结构。与使用  $1 \times 1$  大小点卷积的 MobileNets<sup>[13]</sup>、ShuffleNet<sup>[14]</sup> 等模型相比,Ghost 瓶颈结构中自定义卷积核大小。以前模型架构<sup>[15-16]</sup>处理特征图的操作仅限于深度卷积或移位操作,而 Ghost 瓶颈结构恒等映射与线性变换并行进行,从而保留固有特征图。

### 1.2 扩张卷积

文中欲搭建的网络需要具有聚合多尺度信息能力,而扩张卷积<sup>[17]</sup>(dilated convolution, Dconv)可以在不丢失分辨率或者重新缩放图像的前提下,聚合多尺度上下文信息。其原理如下:

设  $F:Z^2 \rightarrow R$  为离散函数。令  $\Omega_r = [-r, r]^2 \cap Z^2$  并令  $k: \Omega_r \rightarrow R$  是  $(2r+1)^2$  的离散滤波器。离散卷积运算  $*$  可以定义为:

$$(F * k)(p) = \sum_{s+l=p} F(s)k(t) \quad (1)$$

设  $l$  是扩张因子并定义:

$$(F * _l k)(p) = \sum_{s+lt=p} F(s)k(t) \quad (2)$$

\*  $l$  为扩张卷积或者扩张  $l$  倍的卷积,常见的卷积操作是扩张 1 倍的卷积。

设  $F_0, F_1, \dots, F_{n-1}: Z^2 \rightarrow R$  为离散函数,令  $k_0, k_1,$

$\dots, k_{n-2}: \Omega_1 \rightarrow R$  为离散的  $3 \times 3$  滤波器,使用扩张因子滤波器:  $F_{i+1} = F_{i \otimes 2} k_i$  ( $i=0, 1, \dots, n-2$ ),定义  $F_{i+1}$  中元素  $p$  的感受野作为  $F_0$  的一组修改为  $F_{i+1}(p)$  的元素,设  $F_{i+1}$  中  $p$  的感受野的大小为这些元素的数目。显而易见,  $F_{i+1}$  中每个元素的感受野的大小是  $(2^{i+2} - 1) \times (2^{i+2} - 1)$ ,有效增加了感受野范围。

### 1.3 双向级联网络结构

双向级联网络 (bi-directional cascade network, BDCN)<sup>[18]</sup> 的双向损失函数监督学习模式在每一层中负责监督训练,使每一层都集中在一个特定的尺寸上,并对所有层输出进行融合。

在 BDCN 中,假设  $Y$  是边缘标签,标签可以分为小部位边缘和大部为边缘,即边缘标签中存在很大的尺度变化,那么  $Y$  可以分解成多种尺度的叠加:

$$Y = \sum_{s=1}^S Y_s \quad (3)$$

其中,  $Y_s$  是某一个特征的尺度的标签。

为使 BDCN 可以自动学习特定层的特定尺度,将  $Y_s$  分解为  $Y_s^{s2d}$  和  $Y_s^{d2s}$  两个互补的监督。 $Y_s^{s2d}$  忽略比  $s$  尺度更小的监督,  $Y_s^{d2s}$  则忽略尺度比  $s$  大的监督。这里的监督其实是每个中间层预测的结果,之所以称其为监督,因为是面向每个  $D_s$  的输出对  $D$  本身参数而言,  $P_s$  是  $D$  的监督。而  $P_s$  的尺度,由后面的部分自行决定。 $Y_s^{s2d}$  和  $Y_s^{d2s}$  表示如下:

$$\begin{aligned} Y_s^{s2d} &= Y - \sum_{i < s} P_i^{s2d} \\ Y_s^{d2s} &= Y - \sum_{i < s} P_i^{d2s} \end{aligned} \quad (4)$$

其中上标  $s2d$  表示从浅层到深层的传播,  $d2s$  表示从深层到浅层的传播。

## 2 双向级联 GhostNet 模型

### 2.1 网络模型结构

多尺度表示对于地层识别至关重要,文中设计了利用扩张卷积生成多尺度特征,并利用 BDCN 自动学习不同图层中的尺度的网络模型—双向级联 GhostNet。双向级联 GhostNet 网络的多个 ID block 通过双向级联结构推断出不同的监督来学习。具体而言,该网络基于 GhostNet,在其第二层添加一个卷积层,然后将 GhostNet 中的 13 个卷积层分成 6 个区块,每个区块遵循一个汇集层,逐步扩大下一个区块中的感受域。其具体结构如图 2 所示。

### 2.2 运算关系

双向级联 GhostNet 由六个 ID Block 组成,每个 ID Block 将多个 G-bneck 的输出融合并输入两个  $1 \times 1$  卷积层,分别生成  $P^{d2s}$  和  $P^{s2d}$  的预测。ID Block 内步长为 1, ID Block 间的步长为 2。级联结构将预测由浅层向

深层传播。对于第  $s$  个 ID Block,  $P_s^{2d}$  通过公式(4)计算的监督  $Y_s^{2d}$  进行训练,  $P_s^{2s}$  的训练方式类似,最终的预测使用  $1 \times 1$  卷积融合中间预测来计算。双向级联 GhostNet 网络对中间层的监督是混杂了其他层的信息的,为了避免某一层的监督影响其他层,断开梯度向其他层传播。

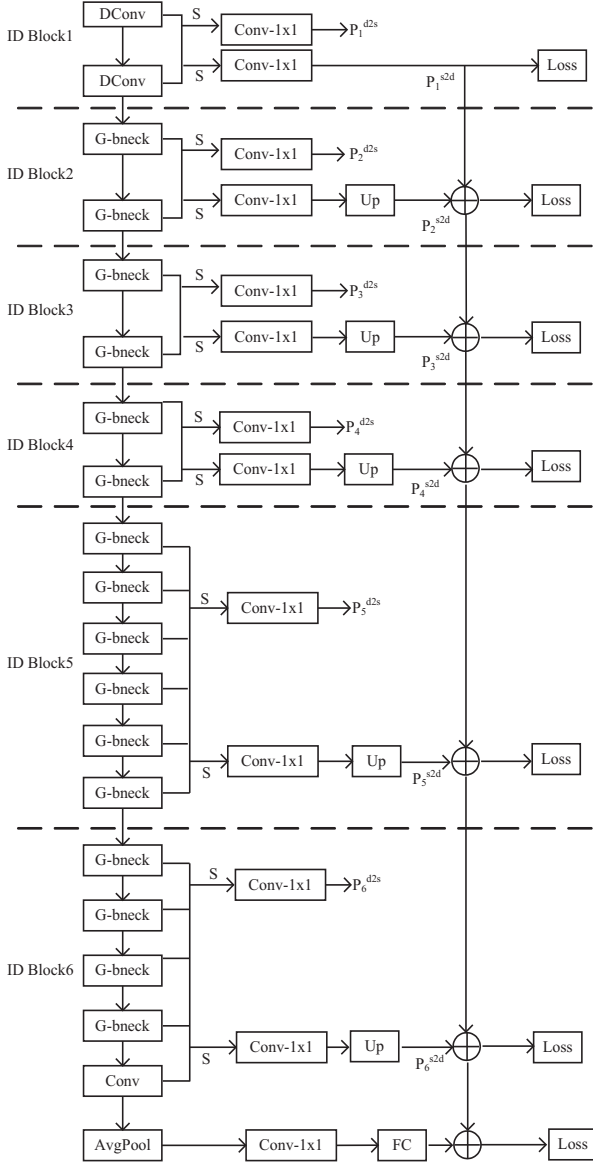


图2 双向级联 GhostNet 结构

### 2.3 计算效率

对于给定数据  $X \in R^{c \times h \times w}$  ( $c$ 、 $h$  和  $w$  分别表示输入数据的通道数、高和宽),任意卷积层生成  $n$  个特征图的运算可表示为:

$$Y = X * f + b \quad (5)$$

其中,  $*$  表示卷积操作,  $b$  表示偏量,  $Y \in R^{n \times h' \times w'}$  表示  $n$  通道的输出特征图( $h'$  和  $w'$  表示输出数据的高和宽),  $f \in R^{c \times k \times k \times n}$  表示在此卷积层的卷积滤波器( $k \times k$  表示卷积滤波器的内核大小)。

卷积操作过程的浮点运算数为  $nh'w'ck^2$ ,通常多

达数十万。根据等式(5)可知,  $f$  和  $b$  中需要优化的是输入和输出特征图的尺寸。假设输出特征图是通过廉价操作得到的固有特征映射的相似图,固有特征图由普通的卷积滤波器生成。  $M$  个固有特征映射  $Y' \in R^{m \times h' \times w'}$  通过使用一次卷积:

$$Y' = X * f \quad (6)$$

为简单起见,省略了偏置项。根据  $Y'$  上的固有特征生成相似特征图:

$$y_{ij} = \Phi_{ij}(y'_i), \forall i = 1, 2, \dots, m, j = 1, 2, \dots, s \quad (7)$$

其中,  $y'_i$  为  $Y'$  的第  $i$  个固有特征,  $\Phi_{ij}$  除最后一个外生成的第  $j$  个相似特征  $y_{ij}$  线性映射。最后一个  $\Phi_{is}$  是用于保留固有特征图的直接映射。

例如,有一个直接映射和  $m(s-1) = \frac{n}{s}(s-1)$  个线性操作,平均每个线性操作的卷积核大小为  $d \times d$ 。理论上, Ghost 模块与普通卷积的加速比为:

$$r_s = \frac{nh'w'ck^2}{\frac{n}{s}h'w'ck^2 + (s-1)\frac{n}{s}h'w'd^2} = \frac{ck^2}{\frac{1}{s}ck^2 + \frac{s-1}{s}d^2} \approx \frac{sc}{s+c-1} \approx s \quad (8)$$

其中,  $d \times d$  的大小与  $k \times k$  的大小相似,而  $s < c$ ,因此压缩比可以计算为:

$$r_c = \frac{nckk}{\frac{n}{s}ckk + (s-1)\frac{n}{s}dd} \approx \frac{sc}{s+c-1} \approx s \quad (9)$$

由此可见,使用 Ghost 模型,能够减少卷积计算中的冗余,有效提高计算速度。

### 3 基于双向级联 GhostNet 的地层识别方法

测井曲线是地质勘探人员对复杂矿场情况进行观测和分析的有效措施。文中结合专家经验、油藏描述等专业相关知识,进行测井曲线组合优选,并通过数据分层、沃尔什滤波以及分段线性插值等方法对数据进行预处理,将测井曲线形态转换为二值图像,构建样本数据集,并运用卷积神经网络进行识别。操作流程如图3所示。

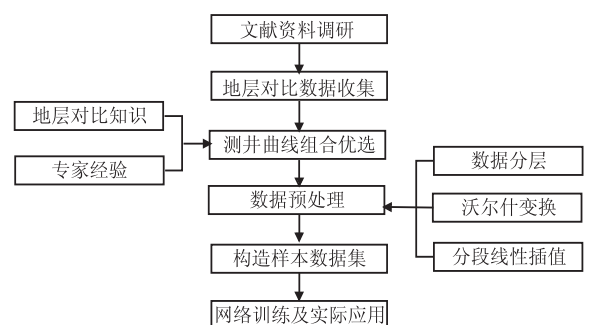


图3 地层识别方法流程

### 3.1 曲线组合优选

在实际地层对比工作中,收集选定的油田区域每口井的测井曲线作为原始数据,但不同的测井曲线对地层对比的贡献程度不尽相同。例如,筇竹寺组具有极高自然伽马和低电阻率的特性,而灯四段伽马低值,曲线近乎平直,偶夹小齿状,电阻率高值。此外,不同油田区域具有不同的地质环境,因此在进行地层识别研究时,需要根据地区特性来进行测井曲线组合优选,有利于构造高质量的训练样本,从而提升网络的训练效率和泛化能力。

### 3.2 数据预处理

实际测井曲线存在尖锐点、每层的数据点个数不同等问题,为解决这些问题,在构建训练集前,选用沃尔什滤波对数据进行异常点清洗,并采用分段线性插值法将每层数据点个数统一化。

#### 3.2.1 沃尔什滤波

为避免数据在测井过程中因设备或信号等原因产生异常点,对最后分类准确率产生影响,文中采用沃尔什滤波对所有测井曲线片段进行处理,剔除异常点。

沃尔什滤波变换核为:

$$g(x, u) = \frac{1}{N} \prod_{i=1}^{n-1} (-1)^{b_i(x) b_{i+1-u}(u)} \quad (10)$$

其中,  $b_k(z)$  为  $z$  的二进制第  $k$  位值。

设  $f(x)$  为离散序列,沃尔什滤波变换表示为:

$$W(u) = \frac{1}{N} \sum_{x=0}^{N-1} f(x) \prod_{i=0}^{n-1} (-1)^{b_i(x) b_{i+1-u}(u)} \quad (11)$$

其中,  $u = 0, 1, \dots, N-1; N = 2^n$ 。

沃尔什滤波反变换核为:

$$h(x, u) = \prod_{i=0}^{n-1} (-1)^{b_i(x) b_{i+1-u}(u)} \quad (12)$$

沃尔什滤波反变换公式为:

$$f(x) = \sum_{u=0}^{n-1} W(u) \prod_{i=0}^{n-1} (-1)^{b_i(x) b_{i+1-u}(u)} \quad (13)$$

#### 3.2.2 分段线性插值

为解决小层厚度不相等问题,统计各小层数据点个数,根据统计结果统一数据点个数为  $L$ ,对少于或多于此长度的测井曲线片段分别进行插值和抽稀操作。为避免高次插值在插值区间边界产生剧烈动荡,文中采用分段线性插值法进行插值与抽稀。

原理如下:

设已知节点  $a = x_0 < x_1 < \dots < x_n = b$  上的函数值为  $y_0, y_1, \dots, y_n$ , 插值函数为:

$$\varphi(x) = \frac{x - x_{i+1}}{x_i - x_{i+1}} y_i + \frac{x - x_i}{x_{i+1} - x_i} y_{i+1} (x_i \leq x \leq x_{i+1}) \quad (14)$$

满足  $\varphi(x_i) = y_i$ , 其中  $i = 0, 1, \dots, n$ , 且在每个小区间  $[x_i, x_{i+1}]$  ( $i = 0, 1, \dots, n$ ) 上  $\varphi(x)$  是线性函数。

### 3.3 基于双向 GhostNet 模型的网络训练

#### 3.3.1 样本图像构造方法

设选取了  $n$  种测井曲线,每种曲线最大值和最小值分别为  $\text{Max}_i$  和  $\text{Min}_i$ , 其中  $i = 1, 2, \dots, n$ 。小层数据点个数设为  $L$ , 对于划分后的所有小层,首先构造大小为  $L \times (\sum_{i=1}^n (\text{Max}_i - \text{Min}_i + 1) + 1)$  的 0 值图像。然后在二值图上,将第  $i$  条曲线上的第  $j$  个数据点  $d_{ij}$  按四舍五入取整,即  $[d_{ij}]$ , 然后将二值图像中的像素点  $(j, \sum_{i=1}^n (\text{Max}_i - \text{Min}_i + 1) + [d_{ij}] + \text{Min}_i + 1)$  设置为 255, 从左到右依次将第  $i$  条测井曲线形态映射到图像的第  $i$  个区域。

#### 3.3.2 实施网络训练

采用样本图像构造方法,将测井曲线形态转换为二值图像,对不同地层的图片进行类别标注,分别记为 1-7,并将样本图像随机划分为训练数据集和测试数据集。网络参数包括:训练迭代次数、每次输入网络的样本数量、初始学习率、动量因子、权重衰减因子等。采用 Adam 优化方法对网络进行多次重复训练,直到对测试集样本达到满意的识别率,训练结束。经过训练后的网络可以直接用于未知类型的地层识别,具体方法为:将未知类型地层的特征数据预处理为与训练样本相同的图像,直接提交训练后的网络,根据网络输出即可判定类别。

## 4 实验及结果分析

### 4.1 资料数据

实验数据来自西南盆地,文中主要研究层段为:龙王庙、沧浪铺、筇竹寺、灯四 2、灯四 1、灯三段以及灯二段,共计 7 个地层。

根据已有地质结构资料来评估测井曲线组合特征和已知地层划分之间的对应关系,通过分析对比,文中选择对地层识别影响较大的五种测井曲线:声波时差(AC)、补偿中子(CAL)、自然伽马(GR)、梯度电阻率(RT)以及自然电位测井曲线(SP)。本次数据共包含 739 口井,每口井优选 5 条测井曲线,每条曲线分为 7 层,根据小层起始深度和终止深度对测井曲线进行分层,分层后获得 25 865 个曲线片段。

### 4.2 数据处理

为解决测井曲线异常点波动过大问题对矿场数据的 25 865 个曲线片段进行沃尔什滤波,沃尔什滤波变换系数设置为 1。对小层数据点个数进行统计,取平均值 1 000 为统一数据点个数。对于少于此数值的小层曲线进行插值,多于此数值的小层曲线进行抽稀。部分数据处理前后如图 4 所示,original 离散点表示原



始数据,数据点个数大于统一值,对数据采用分段线性插值原理进行数据抽稀;interpolation 离散点表示对数据进行抽稀后得到的结果,数据量虽减少但仍可保持曲线形态;Walsh filtering 离散点表示进行沃尔什滤波后的曲线形态,曲线尖锐部分变得平滑。

#### 4.3 构造样本图像

根据曲线统计结果可得,五种曲线的最大值和最

小值分别为  $\text{Max}_i \in \{585, 44, 115, 1\ 106, 100\}$ 、 $\text{Min}_i \in \{0, 0, 0, 0, -116\}$ ,构造大小为  $1\ 000 \times 3\ 325$  像素的 0 值图像,为保证图片大小适中,对曲线等比例缩放,最终图像大小为  $1\ 000 \times 1\ 000$  像素,依次将 5 条测井曲线片段映射到对应位置,共获得 5 173 张映射图,七层地层曲线形态图如图 5 所示。随机选择 80% 测井曲线数据作为训练集,20% 作为测试集。




图4 数据处理前后对比





图5 测井曲线映射图

#### 4.4 比较分析

网络采用 pytorch 框架, Linux 操作系统下应用 Nvidia RTX 2070 GPU 进行编译、训练及测试。

GhostNet、扩张卷积 GhostNet 和双向级联 GhostNet 初始学习率分别为 0.4、0.1 和 0.1,学习率每迭代 30 次减少 10 倍,权重衰减因子为 0.000 1, Nesterov 动量因子为 0.9。GhostNet 使用随机梯度下

降优化算法,扩张卷积 GhostNet 和双向级联 GhostNet 使用 Adam 优化算法。训练迭代次数为 250,批量大小为 64。GhostNet 损失函数结果如图 6(a)所示,扩张卷积 GhostNet 损失函数结果如图 6(b)所示,双向级联 GhostNet 网络的损失函数结果如图 6(c)所示,网络参数量及测试集上的准确率如表 1 所示。



(a) GhostNet 损失函数下降曲线

(b) 扩张卷积 GhostNet 损失函数下降曲线

(c) 双向级联 GhostNet 损失函数下降曲线

图6 损失函数下降曲线

表 1 地层识别准确率

网络名称	参数量/M	识别准确率/%
GhostNet	5.18	90.36
扩张卷积 GhostNet	6.82	94.59
双向级联 GhostNet	7.12	96.67

为了验证文中方法相比现有方法的优势,与 MobileNetV3、ResNet34 进行对比实验。ResNet34 优化器为均方根传播优化算法,初始学习率为 0.045,每迭代 2 次后以 0.94 的指数速率衰减。MobileNetV3 使用相同优化算法,动量为 0.9,初始的学习率为 0.1,每 3 个迭代学习率因子衰减 0.01。

实验结果如表 2 所示,改进后的网络在地层识别上的准确率分别高达 96.67%,比同类算法平均提升 6.18%,且参数量较少。

表 2 同类方法地层识别准确率

方法	参数量/M	识别准确率/%
MobileNetV3-Large	5.4	93.27
MobileNetV3-Small	2.9	85.41
ResNet34	21.8	93.93
VGG-16	34.0	89.36
文中网络	7.12	96.67

对于文中模型在地层识别问题中所展示出的优势,给出如下理论分析。首先,由损失函数下降曲线图可知,GhostNet 损失函数值下降,但曲线震荡,网络在学习过程中可能遇到瓶颈。随后,将普通卷积替换为扩张卷积,有效提高了网络的学习与泛化能力,损失函数下降曲线收敛速度较快。最后,双向级联 GhostNet 每一层的双向监督机制,解决了训练策略的问题,网络收敛效果较好,网络特征提取能力增强,得到稳定的性能提升。

## 5 结束语

文中提出了一种双向级联 GhostNet 的新方法,并将其应用于实际地层识别中。首先,更改 GhostNet 模块中的普通卷积为扩张卷积,从而获得多尺度表示;其次,构建双向级联网络,使用双向损失函数对学习过程进行监督,增强识别准确性;最后,将测井数据进行预处理,将测井曲线形态转化为二值图片,构造样本数据集,使用样本图像进行网络训练及测试。实验结果表明,该方法不仅具有较高的地层识别准确率而且网络参数量较少,优于同类的对比方法,从而表明提出的改进措施是有效的、可行的。

### 参考文献:

[1] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6):1229-1251.

[2] 李亚飞,董红斌.基于卷积神经网络的遥感图像分类研究[J].智能系统学报,2018,13(4):550-556.

[3] 陈鸿翔.基于卷积神经网络的图像语义分割[D].杭州:浙江大学,2016.

[4] TIAN Z, SHEN C, CHEN H, et al. Fcos: fully convolutional one-stage object detection[C]//Proceedings of the IEEE international conference on computer vision. Seoul, Korea (South); IEEE, 2019: 9627-9636.

[5] 刘 蕾.曲线符号推演层序地层分析方法研究[D].北京:中国石油大学(北京),2017.

[6] 范佳佳,安志渊,朱 键,等.测井资料在层序地层识别中的应用探讨[J].能源与节能,2012(9):113-114.

[7] 余 瑜,林良彪,蓝彬恒,等.基于小波分析的层序地层划分及识别——以川东地区上二叠统龙潭组为例[J].西北地质,2018,51(4):43-52.

[8] DUAN T, GRIFFITHS C M, JOHNSEN S O. High-frequency sequence stratigraphy using syntactic methods and clustering applied to the upper Limestone Coal Group (Pendleian, E1) of the Kincardine Basin, United Kingdom[J]. Mathematical Geology, 2001, 33(7): 825-844.

[9] 朱北斗,龚国芳,周如林,等.基于盾构掘进参数的 BP 神经网络地层识别[J].浙江大学学报:工学版,2011,45(5): 851-857.

[10] 石玉江,张海涛,周金昱,等.应用常规测井属性分析进行地层结构划分[J].测井技术,2016,40(4):493-497.

[11] 徐朝晖,刘钰铭,周新茂,等.基于卷积神经网络算法的自动地层对比实验[J].石油科学通报,2019,4(1):1-10.

[12] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle, WA, USA; IEEE, 2020: 1580-1589.

[13] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[J]. arXiv:1704.04861, 2017.

[14] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. [s. l.]: IEEE, 2018: 6848-6856.

[15] WU B, WAN A, YUE X, et al. Shift: a zero flop, zero parameter alternative to spatial convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, UT, USA; IEEE, 2018: 9127-9135.

[16] JADERBERG M, VEDALDI A, ZISSERMAN A. Speeding up convolutional neural networks with low rank expansions [J]. arXiv:1405.3866, 2014.

[17] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. arXiv:1511.07122, 2015.

[18] HE J, ZHANG S, YANG M, et al. Bi-directional cascade network for perceptual edge detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. [s. l.]: IEEE, 2019: 3828-3837.