



(12) 发明专利

(10) 授权公告号 CN 112101190 B

(45) 授权公告日 2023. 11. 03

(21) 申请号 202010955163.0

G06V 10/52 (2022.01)

(22) 申请日 2020.09.11

G06V 10/80 (2022.01)

(65) 同一申请的已公布的文献号

G06V 10/82 (2022.01)

申请公布号 CN 112101190 A

G06N 3/0464 (2023.01)

(43) 申请公布日 2020.12.18

G06N 3/045 (2023.01)

(73) 专利权人 西安电子科技大学

G06N 3/047 (2023.01)

地址 710071 陕西省西安市碑林区太白南路2号

G06N 3/048 (2023.01)

G06N 3/084 (2023.01)

(72) 发明人 李玲玲 梁普江 孙宸 马晶晶

焦李成 刘芳 郭晓惠 刘旭

张丹

(56) 对比文件

CN 110334765 A, 2019.10.15

CN 110728224 A, 2020.01.24

CN 111523521 A, 2020.08.11

WO 2020169043 A1, 2020.08.27

马永杰;程时升;马芸婷;陈敏.多尺度特征融合与极限学习机结合的交通标志识别.液晶与显示.2020,(第06期),全文.

(74) 专利代理机构 西安通大专利代理有限责任公司 61200

专利代理师 高博

审查员 张媛媛

(51) Int. Cl.

G06V 10/764 (2022.01)

G06V 20/10 (2022.01)

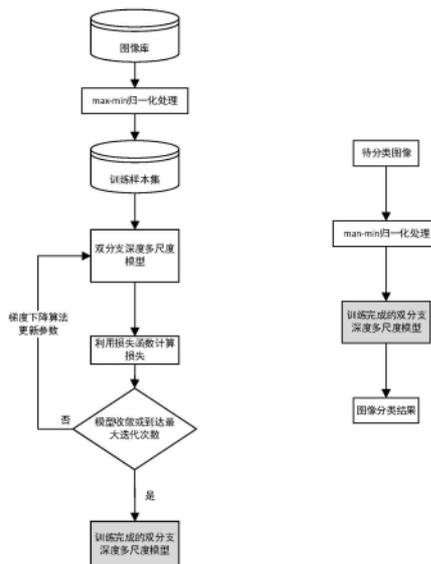
权利要求书3页 说明书9页 附图2页

(54) 发明名称

一种遥感图像分类方法、存储介质及计算设备

(57) 摘要

本发明公开了一种遥感图像分类方法、存储介质及计算设备,创建遥感图像集,对遥感图像集进行标准化处理,得到训练样本集和测试样本集;设置多尺度特征提取模块,通过在两个并行的卷积模块中设置不同的空洞卷积,生成两个尺度的特征图;设置自适应特征融合模块,自适应特征融合模块能够自适应的选择生成的两个不同尺度的特征中的有用信息并进行融合;搭建整个神经网络模型;使用训练样本集对整个神经网络模型进行迭代训练;在测试样本中随机选择样本作为位置类别样本,利用训练好的神经网络对需要预测的未知样本进行分类。本发明减少冗余信息,更灵活的选择多尺度特征,提升网络的稳定性,进而提升网络模型的分类能力。



1. 一种遥感图像分类方法,其特征在于,包括以下步骤:

S1、创建遥感图像集,对遥感图像集进行标准化处理,得到训练样本集和测试样本集;

S2、设置多尺度特征提取模块,包括两个并行的卷积模块,通过在两个并行的卷积模块中设置不同的空洞卷积,提取出不同尺度的信息,生成两个尺度的特征图;

S3、设置自适应特征融合模块,包括全局池化构成的压缩操作,两个全连接层以及softmax函数构成的激活操作,自适应特征融合模块能够自适应的选择步骤S2中生成的两个不同尺度的特征中的有用信息并进行融合,具体为:

S301、将两个尺寸为 $W \times H \times C$ 的特征图 $O_a$ 和 $O_b$ 相加得到总的特征图 $O$ ,特征图 $O$ 的尺寸为 $W \times H \times C$ ,对 $O$ 使用全局平均池化操作,得到包含全局信息的卷积特征图 $z$ ,卷积特征图 $z$ 的尺寸为 $1 \times 1 \times C$ ;

S302、将卷积特征图 $z$ 通过两个全连接层和softmax激活层生成两组不同的权重 $p$ 和 $q$ , $p$ 和 $q$ 的尺寸为 $1 \times 1 \times C$ ,对于第一个全连接层,参数个数为 $C \times \frac{C}{r}$ ,输出尺寸为 $1 \times 1 \times C/r$ , $r$ 为超参数;对于第二个全连接层,参数个数为 $\frac{C}{r} \times 2C$ ,输出尺寸为 $1 \times 2 \times C$ ,分为两个不同的特征 $p'$ 和 $q'$ ,尺寸均为 $1 \times 1 \times C$ ;

S303、对于两个全连接层输出的特征 $p'$ 和 $q'$ 用softmax函数激活,并分离为两组不同的权重 $p$ 和 $q$ ,将两个权重 $p$ 和 $q$ 按通道分别乘以两个输入特征 $O_a$ 和 $O_b$ ,再将其相加得到融合后的特征图 $O$ ;

S4、搭建整个神经网络模型,以步骤S3中融合得到的包含多尺度信息的卷积特征作为输入,具体为:

S401、搭建一个有八个卷积模块的深度特征提取部分,将融合后的多尺度特征图送入,输入特征图尺寸为 $112 \times 112 \times 64$ ;

S402、使用全局池化层将提取到的深度语义特征压缩为一维特征,输入为卷积模块的输出特征图,输出为一维的全局特征,尺寸为 $1 \times 1 \times 512$ ;

S403、使用卷积核大小为 $512 \times T$ 的全连接层进行最终结果的分类, $T$ 等于样本集合中所包含类别的个数;

S5、使用步骤S1中所得到的训练样本集对步骤S4整个神经网络模型进行迭代训练;

S6、在测试样本中随机选择样本作为位置类别样本,利用步骤S5训练好的神经网络对需要预测的未知样本进行分类。

2. 根据权利要求1所述的遥感图像分类方法存储介质及计算设备,其特征在于,步骤S1具体为:

S101、获取UC\_Merced图像,建立遥感图像样本集 $I = \{I_1, I_2, \dots, I_i, \dots, I_N\}$ ,并根据每个样本对应的标签建立对应的样本标签集 $L = \{L_1, L_2, \dots, L_i, \dots, L_N\}$ ,标签集中的标签 $L_i$ 对应样本集中样本 $I_i$ 的类别, $I_i$ 表示样本集中的第 $i$ 个样本, $i \in [0, N]$ , $N$ 表示样本集中总的样本个数;

S102、对样本集中的样本进行min-max归一化处理;

S103、将归一化之后的数据集分为训练数据集Train和测试数据集Test,对于每一类样本,将80%作为训练样本集,剩余20%作为测试样本集,得到训练样本集 $\{Train_1, Train_2, \dots, Train_m, \dots, Train_M\}$ 和测试样本集 $\{Test_1, Test_2, \dots, Test_j, \dots, Test_J\}$ ,其中, $Train_m$ 为训练数据

集中的第 $m$ 个样本,  $m \in [0, M]$ ,  $M$ 为训练集中样本的总个数,  $M < N$ ;  $\text{Test}_j$ 为测试数据集中的第 $j$ 个样本,  $j \in [0, J]$ ,  $J$ 为训练集中样本的总个数,  $J < N$ 。

3. 根据权利要求1所述的遥感图像分类方法存储介质及计算设备, 其特征在于, 步骤S2中, 两个卷积模块的输入为经过min-max处理后的样本, 裁减至 $224 \times 224 \times 3$ ; 输出为两个拥有相同尺寸的特征图, 尺寸为 $112 \times 112 \times 64$ ; 卷积模块中有两个串联的卷积层, 两个卷积模块参数共享, 输出两个包含不同尺度信息的特征图 $O_a$ 和 $O_b$ 。

4. 根据权利要求3所述的遥感图像分类方法存储介质及计算设备, 其特征在于, 第一个卷积块conv<sub>a</sub>, layer<sub>a.1</sub>使用 $3 \times 3$ 的卷积核, 步长为1, layer<sub>a.2</sub>也使用 $3 \times 3$ 的卷积核, 步长为2, 其空洞率设置为1, 输出特征图 $O_a$ 的尺寸为 $112 \times 112 \times 64$ ;

第一个卷积块conv<sub>b</sub>, layer<sub>b.1</sub>使用 $3 \times 3$ 的卷积核, 步长为1, layer<sub>b.2</sub>也使用 $3 \times 3$ 的卷积核, 步长为2, 其空洞率设置为2, 输出特征图 $O_b$ 的尺寸为 $112 \times 112 \times 64$ 。

5. 根据权利要求1所述的遥感图像分类方法存储介质及计算设备, 其特征在于, 步骤S5具体为:

S501、设置迭代训练时的超参数, 包括总的迭代次数 $E$ , 学习率 $\eta$ , 训练时每一批次的批量大小 $B$ , 即每一次训练时, 训练样本集 $\{\text{Train}_1, \text{Train}_2, \dots, \text{Train}_m, \dots, \text{Train}_M\}$ 每次输入 $B$ 个样本, 整个样本集每一轮训练所需要的输入次数为 $Q$ ;

S502、选择交叉熵函数 $loss = \sum_{m=1}^M y_m * \log(o_m)$ 作为损失函数;

S503、通过梯度下降算法降低步骤S502损失函数, 迭代训练网络, 每次迭代时对网络中的参数进行更新, 第 $t$ 次迭代更新后的卷积核参数 $W_{t+1}$ 如下:

$$W_{t+1} = W_t - \eta * \frac{\partial loss_t}{\partial W_t}$$

其中,  $W_t$ 表示第 $t$ 次迭代的卷积核参数,  $loss_t$ 表示第 $t$ 次迭代时权重参数所带来的损失,  $\frac{\partial loss_t}{\partial W_t}$ 即是本次更新的梯度值;

S504、当迭代次数未达到所设置的最小迭代次数 $E$ 时, 若损失函数 $loss$ 不再下降, 则停止训练; 当迭代次数达到所设置的最小迭代次数 $E$ 时, 则停止训练, 得到训练好的卷积神经网络模型; 否则, 继续进行迭代优化。

6. 根据权利要求1所述的遥感图像分类方法存储介质及计算设备, 其特征在于, 步骤S6中, 对于未知类别的遥感图像 $I_{\text{unkown}}$ 进行min-max标准化处理, 使图像内的像素点的值在 $[0, 1]$ 之间, 得到归一化处理之后的待分类样本 $I'_{\text{unkown}}$ ; 将归一化之后的样本输入到已经训练好的网络中, 网络输出的分类结果即样本的预测结果。

7. 一种存储一个或多个程序的计算机可读存储介质, 其特征在于, 所述一个或多个程序包括指令, 所述指令当由计算设备执行时, 使得所述计算设备执行根据权利要求1至6所述的方法中的任一方法。

8. 一种计算设备, 其特征在于, 包括:

一个或多个处理器、存储器及一个或多个程序, 其中一个或多个程序存储在所述存储器中并被配置为所述一个或多个处理器执行, 所述一个或多个程序包括用于执行根据权利要求

要求1至6所述的方法中的任一方法的指令。

## 一种遥感图像分类方法、存储介质及计算设备

### 技术领域

[0001] 本发明属于图像处理技术领域,具体涉及一种基于双支路深度多尺度网络的遥感图像分类方法、存储介质及计算设备。

### 背景技术

[0002] 遥感图像场景分类是一项基本的遥感图像处理任务,在军事和民用领域都有广泛的应用。近几年遥感技术发展迅速,所捕获到的遥感图像拥有高分辨率,结构复杂的特点。传统的遥感图像处理方法难以捕捉到复杂图像中的语义信息,所以在当前高质量图像的分类任务上表现不佳。

[0003] 近几年,深度学习发展迅速,并且已经在图像处理领域取得了很好地效果。得益于卷积操作和层级结构,深度学习方法不仅可以提取诸如颜色,纹理这种图像的浅层特征,还可以有效地提取图像中的深层语义特征,比如图像中的目标。然而当前的卷积神经网络模型有一定的局限性,由于一般的模型都只有固定的感受野,难以提取多尺度特征,在面对图像中目标大小变化时,模型往往难以充分捕捉到目标的信息。通过使用不同感受野的卷积核可以使模型能够提取多尺度特征,进而捕捉到不同大小的目标,更灵活的发挥卷积神经网络的优势。因此,如何在卷积神经网络中引入多尺度特征,并且灵活运用多尺度特征成为了提高模型性能的关键。

### 发明内容

[0004] 本发明所要解决的技术问题在于针对上述现有技术中的不足,提供一种基于双支路深度多尺度网络的遥感图像分类方法、存储介质及计算设备,通过结合空洞卷积的特性,可以在卷积神经网络中引入多尺度特性,增强网络对不同尺度目标的感知能力,同时利用通道注意力机制自适应的融合多尺度特征,可以使网络更灵活的应对多尺度问题,从而提升对遥感图像的分类能力。

[0005] 本发明采用以下技术方案:

[0006] 一种遥感图像分类方法,包括以下步骤:

[0007] S1、创建遥感图像集,对遥感图像集进行标准化处理,得到训练样本集和测试样本集;

[0008] S2、设置多尺度特征提取模块,包括两个并行的卷积模块,通过在两个并行的卷积模块中设置不同的空洞卷积,提取出不同尺度的信息,生成两个尺度的特征图;

[0009] S3、设置自适应特征融合模块,包括全局池化构成的压缩操作,两个全连接层以及softmax函数构成的激活操作,自适应特征融合模块能够自适应的选择步骤S2中生成的两个不同尺度的特征中的有用信息并进行融合;

[0010] S4、搭建整个神经网络模型,以步骤S3中融合得到的包含多尺度信息的卷积特征作为输入;

[0011] S5、使用步骤S1中所得到的训练样本集对步骤S4整个神经网络模型进行迭代训

练;

[0012] S6、在测试样本中随机选择样本作为位置类别样本,利用步骤S5训练好的神经网络对需要预测的未知样本进行分类。

[0013] 具体的,步骤S1具体为:

[0014] S101、获取UC\_Merced图像,建立遥感图像样本集 $I = \{I_1, I_2, \dots, I_i, \dots, I_N\}$ ,并根据每个样本对应的标签建立对应的样本标签集 $L = \{L_1, L_2, \dots, L_i, \dots, L_N\}$ ,标签集中的标签 $L_i$ 对应样本集中样本 $I_i$ 的类别, $I_i$ 表示样本集中的第 $i$ 个样本, $i \in [0, N]$ , $N$ 表示样本集中总的样本个数;

[0015] S102、对样本集中的样本进行min-max归一化处理;

[0016] S103、将归一化之后的数据集分为训练数据集Train和测试数据集Test,对于每一类样本,将80%作为训练样本集,剩余20%作为测试样本集,得到训练样本集 $\{Train_1, Train_2, \dots, Train_m, \dots, Train_M\}$ 和测试样本集 $\{Test_1, Test_2, \dots, Test_j, \dots, Test_J\}$ ,其中, $Train_m$ 为训练数据集中的第 $m$ 个样本, $m \in [0, M]$ , $M$ 为训练集中样本的总个数, $M < N$ ;  $Test_j$ 为测试数据集中的第 $j$ 个样本, $j \in [0, J]$ , $J$ 为训练集中样本的总个数, $J < N$ 。

[0017] 具体的,步骤S2中,两个卷积模块的输入为经过min-max处理后的样本,裁减至 $224 \times 224 \times 3$ ;输出为两个拥有相同尺寸的特征图,尺寸为 $112 \times 112 \times 64$ ;卷积模块中有两个串联的卷积层,两个卷积模块参数共享,输出两个包含不同尺度信息的特征图 $O_a$ 和 $O_b$ 。

[0018] 进一步的,第一个卷积块conva, layera.1使用 $3 \times 3$ 的卷积核,步长为1, layera.2也使用 $3 \times 3$ 的卷积核,步长为2,其空洞率设置为1,输出特征图 $O_a$ 的尺寸为 $112 \times 112 \times 64$ ;

[0019] 第一个卷积块convb, layerb.1使用 $3 \times 3$ 的卷积核,步长为1, layerb.2也使用 $3 \times 3$ 的卷积核,步长为2,其空洞率设置为2,输出特征图 $O_b$ 的尺寸为 $112 \times 112 \times 64$ 。

[0020] 具体的,步骤S3具体为:

[0021] S301、将两个尺寸为 $W \times H \times C$ 的特征图 $O_a$ 和 $O_b$ 相加得到总的特征图 $O$ ,特征图 $O$ 的尺寸为 $W \times H \times C$ ,对 $O$ 使用全局平均池化操作,得到包含全局信息的卷积特征图 $z$ ,卷积特征图 $z$ 的尺寸为 $1 \times 1 \times C$ ;

[0022] S302、将卷积特征图 $z$ 通过两个全连接层和softmax激活层生成两组不同的权重 $p$ 和 $q$ , $p$ 和 $q$ 的尺寸为 $1 \times 1 \times C$ ,对于第一个全连接层,参数个数为 $C \times \frac{C}{r}$ ,输出尺寸为 $1 \times 1 \times C/r$ ,

$r$ , $r$ 为超参数;对于第二个全连接层,参数个数为 $\frac{C}{r} \times 2C$ ,输出尺寸为 $1 \times 2 \times C$ ,分为两个不同的特征 $p'$ 和 $q'$ ,尺寸均为 $1 \times 1 \times C$ ;

[0023] S303、对于两个全连接层输出的特征 $p'$ 和 $q'$ 用softmax函数激活,并分离为两组不同的权重 $p$ 和 $q$ ,将两个权重 $p$ 和 $q$ 按通道分别乘以两个输入特征 $O_a$ 和 $O_b$ ,再将其相加得到融合后的特征图 $O$ 。

[0024] 具体的,步骤S4具体为:

[0025] S401、搭建一个有八个卷积模块的深度特征提取部分,将融合后的多尺度特征图送入,输入特征图尺寸为 $112 \times 112 \times 64$ ;

[0026] S402、使用全局池化层将提取到的深度语义特征压缩为一维特征,输入为卷积模块的输出特征图,输出为一维的全局特征,尺寸为 $1 \times 1 \times 512$ ;

[0027] S403、使用卷积核大小为 $512 \times T$ 的全连接层进行最终结果的分类， $T$ 等于样本集合中所包含类别的个数。

[0028] 具体的，步骤S5具体为：

[0029] S501、设置迭代训练时的超参数，包括总的迭代次数 $E$ ，学习率 $\eta$ ，训练时每一批次的批量大小 $B$ ，即每一次训练时，训练样本集 $\{\text{Train}_1, \text{Train}_2, \dots, \text{Train}_m \dots, \text{Train}_M\}$ 每次输入 $B$ 个样本，整个样本集每一轮训练所需要的输入次数为 $Q$ ；

[0030] S502、选择交叉熵函数  $loss = \sum_{m=1}^M y_m * \log(o_m)$  作为损失函数；

[0031] S503、通过梯度下降算法降低步骤S502损失函数，迭代训练网络，每次迭代时对网络中的参数进行更新，第 $t$ 次迭代更新后的卷积核参数 $W_{t+1}$ 如下：

$$[0032] \quad W_{t+1} = W_t - \eta * \frac{\partial loss_t}{\partial W_t}$$

[0033] 其中， $W_t$ 表示第 $t$ 次迭代的卷积核参数， $loss_t$ 表示第 $t$ 次迭代时权重参数所带来的损失， $\frac{\partial loss_t}{\partial W_t}$ 即是本次更新的梯度值；

[0034] S504、当迭代次数未达到所设置的最小迭代次数 $E$ 时，若损失函数 $loss$ 不再下降，则停止训练；当迭代次数达到所设置的最小迭代次数 $E$ 时，则停止训练，得到训练好的卷积神经网络模型；否则，继续进行迭代优化。

[0035] 具体的，步骤S6中，对于未知类别的遥感图像 $I_{\text{unknown}}$ 进行min-max标准化处理，使图像内的像素点的值在 $[0, 1]$ 之间，得到归一化处理之后的待分类样本 $I'_{\text{unknown}}$ ；将归一化之后的样本输入到已经训练好的网络中，网络输出的分类结果即样本的预测结果。

[0036] 更进一步的，本发明的特点还在于：

[0037] 本发明的另一技术方案是，一种存储一个或多个程序的计算机可读存储介质，所述一个或多个程序包括指令，所述指令当由计算设备执行时，使得所述计算设备执行根据所述的方法中的任一方法。

[0038] 本发明的另一技术方案是，一种计算设备，包括：

[0039] 一个或多个处理器、存储器及一个或多个程序，其中一个或多个程序存储在所述存储器中并被配置为所述一个或多个处理器执行，所述一个或多个程序包括用于执行所述的方法中的任一方法的指令。

[0040] 与现有技术相比，本发明至少具有以下有益效果：

[0041] 本发明是一种基于双支路深度多尺度网络的遥感图像分类方法，结合了空洞卷积和自适应融合方法，由于空洞卷积可以在不增加额外参数的情况下扩大卷积核的感受野，这可以使得卷积核更灵活的捕捉不同尺度大小的目标，增加网络的多尺度特性；通过注意力机制的自适应融合方法可以自适应的融合不同尺度的特征，让网络有选择不同尺度特征的能力。本发明可以使深度神经网络模型能够捕捉多尺度特征并灵活运用多尺度特征。

[0042] 进一步的，使用80%的样本作为训练数据集，可以使网络更充分的捕捉样本集的特征，使用20%作为验证数据集，以保证网络的有效性；通过对数据进行max-min归一化处理，可以增强网络的稳定性，进一步加快网络的收敛速度。

[0043] 进一步的,通过使用在浅层设置两个并行的不同大小感受野的卷积层,可以提取到两个不同尺度的特征,从而在卷积神经网络中引入丰富的多尺度信息,使得网络能够提取多尺度特征。空洞卷积可以在不增加网络参数的情况下,扩大卷积核的感受野,使得网络拥有捕捉不同大小的目标的能力。

[0044] 进一步的,通过对特征进行池化压缩操作和全连接层操作,可以给两个分支包含不同尺度信息的特征图以不同的权重,进而自适应的选择出更关键的信息进行融合,最终更灵活的利用多尺度特征,减少特征图中的冗余信息。

[0045] 进一步的,通过设置多层的串联卷积层结构,可以更有效的提取出稳定且具有鉴别性的特征。浅层的低级特征可以经过多层卷积层转变为深层的高级语义特征,更有益于最终的分类结果。

[0046] 进一步的,交叉熵函数在面对多分类问题时,可以有效地定位网络的损失,结合梯度下降算法,可以是网络在庞大搜索空间中收敛。同时,通过设置合适的超参数,可以有效地减少过拟合现象。

[0047] 综上所述,本发明通过设置拥有不同感受野的并行特征提取模块,并结合注意力机制自适应融合多尺度特征,构建了一种基于双支路深度多尺度网络的遥感图像分类方法,利用空洞卷积在卷积神经网络中引入了丰富的多尺度特性,并结合注意力机制,自适应地选择合适的特征进行融合,减少冗余信息,更灵活的选择多尺度特征可以让网络更灵活的解决目标大小不一致的问题,提升网络的稳定性,进而提升网络模型的分类能力。

[0048] 下面通过附图和实施例,对本发明的技术方案做进一步的详细描述。

## 附图说明

[0049] 图1为本发明基本流程图;

[0050] 图2为本发明深度多尺度网络模型图;

[0051] 图3为基于通道注意力的自适应融合模块结构图。

## 具体实施方式

[0052] 本发明提供了一种基于双支路深度多尺度网络的遥感图像分类方法、存储介质及计算设备,利用空洞卷积获取图像的多尺度特征,然后利用通道注意力机制自适应地融合多尺度特征,再将融合后的多尺度特征通过多层残差模块提取出高级语义信息,最后通过全连接层和softmax函数实现图像分类。

[0053] 请参阅图1,本发明一种基于双支路深度多尺度网络的遥感图像分类方法,包括以下步骤:

[0054] S1、创建遥感图像集,对样本进行标准化处理,得到训练样本集和测试样本集;

[0055] S101、获取UC\_Merced图像,建立遥感图像样本集 $I = \{I_1, I_2, \dots, I_i, \dots, I_N\}$ ,并根据每个样本对应的标签建立对应的样本标签集 $L = \{L_1, L_2, \dots, L_i, \dots, L_N\}$ ,标签集中的标签 $L_i$ 对应样本集中样本 $I_i$ 的类别, $I_i$ 表示样本集中的第 $i$ 个样本, $i \in [0, N]$ , $N$ 表示样本集中总的样本个数;

[0056] S102、对样本集中的样本进行min-max标准化处理:

$$[0057] \quad \{I'_1, I'_2, \dots, I'_i, \dots, I'_N\} = \frac{\{I_1, I_2, \dots, I_i, \dots, I_N\} - I_{\min}}{I_{\max}}$$

[0058] 其中,  $I_{\min}$  表示所有样本中的所有像素点处像素值的最小值,  $I_{\max}$  表示所有样本中的所有像素点处像素值的最大值,  $\{I'_1, I'_2, \dots, I'_i, \dots, I'_N\}$  表示标准化处理之后的样本集, 其中每个样本的每一个像素点处的像素值都在  $[0, 1]$  之间。

[0059] S103、将归一化之后的数据集分为训练数据集Train和测试数据集Test, 对于每一类样本, 将其中的80%作为训练样本集, 其余的20%作为测试样本集, 最终得到训练样本集  $\{\text{Train}_1, \text{Train}_2, \dots, \text{Train}_m, \dots, \text{Train}_M\}$  和测试样本集  $\{\text{Test}_1, \text{Test}_2, \dots, \text{Test}_j, \dots, \text{Test}_J\}$ ;

[0060] 其中,  $\text{Train}_m$  为训练数据集中的第m个样本,  $m \in [0, M]$ , M为训练集中样本的总个数,  $M < N$ ;  $\text{Test}_j$  为测试数据集中的第j个样本,  $j \in [0, J]$ , J为训练集中样本的总个数,  $J < N$ 。

[0061] S2、设置多尺度特征提取模块;

[0062] S201、设置两个并行的卷积模块, 其中两个卷积模块参数共享, 但是空洞率不同。输入为经过min-max处理后的样本, 将其裁减至  $224 \times 224 \times 3$ ; 输出为两个拥有相同尺寸的特征图, 其尺寸为  $112 \times 112 \times 64$ ;

[0063] S202、两个卷积模块均使用  $3 \times 3$  的卷积核, 卷积模块中有两个串联的卷积层, 第一个卷积层步长为1, 第二个卷积层步长为2, 是的输出特征图的尺寸减小为原来的  $1/2$ , 两个卷积模块参数共享, 输出两个包含不同尺度信息的特征图  $O_a$  和  $O_b$ ;

[0064] 第一个卷积块conva, layera.1使用  $3 \times 3$  的卷积核, 步长为1, layera.2也使用  $3 \times 3$  的卷积核, 步长为2, 其空洞率设置为1, 输出特征图  $O_a$ , 其尺寸为  $112 \times 112 \times 64$ ;

[0065] 第一个卷积块convb, layerb.1使用  $3 \times 3$  的卷积核, 步长为1, layerb.2也使用  $3 \times 3$  的卷积核, 步长为2, 其空洞率设置为2, 输出特征图  $O_b$ , 其尺寸为  $112 \times 112 \times 64$ ;

[0066] S3、设置自适应特征融合模块, 包括有全局池化构成的压缩操作, 2个全连接层, 还有softmax函数构成的激活操作, 如图2所示, 具体描述如下:

[0067] S301、输入的两个特征图  $O_a$  和  $O_b$  尺寸为  $W \times H \times C$ , 将其相加得到总的特征图  $O$ , 其尺寸为  $W \times H \times C$ , 对  $O$  使用全局平均池化操作, 得到包含全局信息的卷积特征图  $z$ , 其尺寸为  $1 \times 1 \times C$ ;

$$[0068] \quad z_c = F_{gp}(O_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W O_c(i, j)$$

[0069] S302、将全局特征  $z$  通过两个全连接层和softmax激活层, 生成两组不同的权重  $p$  和  $q$ , 其中,  $p$  和  $q$  的尺寸为  $1 \times 1 \times C$ , 对于第一个全连接层, 其参数个数为  $C \times \frac{C}{r}$ , 其输出尺寸为  $1 \times 1 \times C/r$ , 其中  $r$  为超参数, 本实验中设置为16;

[0070] 对于第二个全连接层, 其参数个数为  $\frac{C}{r} \times 2C$ , 其输出尺寸为  $1 \times 2 \times C$ , 将其分为两个不同的特征  $p'$  和  $q'$ , 其尺寸都为  $1 \times 1 \times C$ ;

[0071] S303、对于两个全连接层输出的特征  $p'$  和  $q'$  用softmax函数激活, 并分离为两组不同的权重  $p$  和  $q$ ;

[0072] Softmax函数为:

$$[0073] \quad S_i = \frac{e^i}{\sum_j e^j}$$

[0074] 其中,  $S_i$  表示输出第  $i$  个位置上的值,  $e^i$  表示输入第  $i$  个位置上的值;

[0075] 将两个权重  $p$  和  $q$  按通道分别乘以两个输入特征  $O_a$  和  $O_b$  中, 再将其相加, 得到融合后的特征图  $O$ :

$$[0076] \quad K = p \cdot O_1 + q \cdot O_2$$

[0077] 其中,  $K$  为自适应融合后的特征, 其中包含不同尺度的信息;

[0078] S4、搭建整个神经网络模型;

[0079] S401、搭建一个有八个卷积模块的深度特征提取部分, 将融合后的多尺度特征图送入, 输入特征图尺寸为  $112 \times 112 \times 64$ ;

[0080] 第一个卷积块 conv1: 输入为多尺度特征图, layer1.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer1.2 使用  $3 \times 3$  的卷积核, 步长为 2, 使得输出特征图尺寸为  $56 \times 56 \times 64$ ;

[0081] 第二个卷积块 conv2: 输入为第一个卷积块的输出。Layer2.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer2.2 使用  $3 \times 3$  的卷积核, 步长为 1, 使得输出特征图尺寸为  $56 \times 56 \times 64$ ;

[0082] 第三个卷积块 conv3: 输入为第二个卷积块的输出。Layer3.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer3.2 使用  $3 \times 3$  的卷积核, 步长为 2, 使得输出特征图尺寸为  $28 \times 28 \times 128$ ;

[0083] 第四个卷积块 conv4: 输入为第三个卷积块的输出。Layer4.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer4.2 使用  $3 \times 3$  的卷积核, 步长为 1, 使得输出特征图尺寸为  $28 \times 28 \times 128$ ;

[0084] 第五个卷积块 conv5: 输入为第四个卷积块的输出。Layer5.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer5.2 使用  $3 \times 3$  的卷积核, 步长为 2, 使得输出特征图尺寸为  $14 \times 14 \times 256$ ;

[0085] 第六个卷积块 conv6: 输入为第五个卷积块的输出。Layer6.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer6.2 使用  $3 \times 3$  的卷积核, 步长为 1, 使得输出特征图尺寸为  $14 \times 14 \times 256$ ;

[0086] 第七个卷积块 conv7: 输入为第六个卷积块的输出。Layer7.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer7.2 使用  $3 \times 3$  的卷积核, 步长为 2, 使得输出特征图尺寸为  $7 \times 7 \times 512$ ;

[0087] 第八个卷积块 conv8: 输入为第七个卷积块的输出。Layer8.1 使用  $3 \times 3$  的卷积核, 步长为 1, layer8.2 使用  $3 \times 3$  的卷积核, 步长为 1, 使得输出特征图尺寸为  $7 \times 7 \times 512$ ;

[0088] S402、使用全局池化层将提取到的深度语义特征压缩为一维特征, 输入为卷积模块的输出特征图, 输出为一维的全局特征;

[0089] 卷积模块的输出特征图尺寸为  $7 \times 7 \times 512$ , 通过全局平均池化得到一维的全局特征, 其尺寸为  $1 \times 1 \times 512$ ;

[0090] S403、使用全连接层进行最终结果的分类;

[0091] 全连接层卷积核大小为  $512 \times T$ , 其输出为一维向量, 长度为  $T$ , 其中  $T$  等于样本集合中所包含类别的个数。使用 softmax 回归函数预测各类别的概率, 公式如下:

$$[0092] \quad p_j = \frac{\exp(Out_j)}{\sum_{i=1}^T \exp(Out_i)}$$

[0093] 其中,  $Out$  表示全连接层的输出, 作为 softmax 函数的输入,  $j$  表示当前类别,  $j \in [0, T]$ ,  $p_j$  表示输入图像被判别为第  $j$  类的概率。

[0094] S5、对整个卷积神经网络模型进行迭代训练；

[0095] S501、设置迭代训练时的超参数：总的迭代次数E，学习率 $\eta$ ，训练时每一批次的批量大小B，即每一次训练时，训练样本集 $\{\text{Train}_1, \text{Train}_2, \dots, \text{Train}_m \dots, \text{Train}_M\}$ 每次输入B个样本，则整个样本集每一轮训练所需要的输入次数Q为：

$$[0096] \quad Q = \frac{M}{B}$$

[0097] 其中，M为训练数据集中的样本总数。

[0098] S502、设置损失函数：由于是多分类问题，故选择交叉熵函数作为损失函数：

$$[0099] \quad \text{loss} = \sum_{m=1}^M y_m * \log(o_m)$$

[0100] 上式表示所有样本的交叉熵损失函数总和，对于样本 $\text{Train}_m$ 而言， $y_m$ 表示样本的实际类别， $o_m$ 表示模型所预测出的类别。

[0101] S503、通过梯度下降算法降低损失函数从而迭代训练网络，每次迭代时通过下式对网络中的参数进行更新：

$$[0102] \quad W_{t+1} = W_t - \eta * \frac{\partial \text{loss}_t}{\partial W_t}$$

[0103] 其中， $W_t$ 表示第t次迭代的卷积核参数， $\text{loss}_t$ 表示第t次迭代时权重参数所带来的损失， $\frac{\partial \text{loss}_t}{\partial W_t}$ 即是本次更新的梯度值， $W_{t+1}$ 表示第t次迭代更新后的卷积核参数。如此反复迭

代更新卷积核参数，便可使网络的损失函数越来越小，分类结果越来越趋近于实际类别。

[0104] S504、当迭代次数未达到所设置的最小迭代次数E时，若损失函数loss不再下降，则停止训练；当迭代次数达到所设置的最小迭代次数E时，则停止训练，得到训练好的卷积神经网络模型；否则，继续进行迭代优化。

[0105] S6、对需要预测的未知样本进行分类。

[0106] S601、对于未知类别的遥感图像 $I_{\text{unkown}}$ 进行min-max标准化处理，使图像内的像素点的值在 $[0, 1]$ 之间，得到归一化处理之后的待分类样本 $I'_{\text{unkown}}$ ；

[0107] S602、将归一化之后的样本输入到已经训练好的网络中，网络输出的分类结果即是对该样本的预测结果。

[0108] 为使本发明实施例的目的、技术方案和优点更加清楚，下面将结合本发明实施例中的附图，对本发明实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例是本发明一部分实施例，而不是全部的实施例。通常在此处附图中的描述和所示的本发明实施例的组件可以通过各种不同的配置来布置和设计。因此，以下对在附图中提供的本发明的实施例的详细描述并非旨在限制要求保护的本发明的范围，而是仅仅表示本发明的选定实施例。基于本发明中的实施例，本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例，都属于本发明保护的范围。

[0109] 仿真条件：

[0110] 本实例在HP-Z840-Workstation with Xeon(R) CPU E5-2630, GeForce 1080ti, 64G RAM, Windows系统下, Pytorch运行平台上, 完成本发明以及现有遥感图像场景分类仿

真。

[0111] 参数设置：

[0112] 学习率固定为0.001,  $\eta=0.001$ , 每次输入图片数B为16次, 衰减率 $\beta$ 为0.9, 两个支路中的空洞率分别设置为1和2。

[0113] 实验结果：

[0114] 以上述仿真条件下, 对于UCMerced\_LandUse使用80%作为训练样本集, 20%作为测试样本集。在测试样本集上, 本方法分别和现有代表性的三种深度学习模型进行对比, 结果如表1所示：

[0115] 表1: 测试分类准确率比较

|                | GSoP-Net | ECA-Net | 本发明方法  |
|----------------|----------|---------|--------|
| [0116] 平均分类准确率 | 0.9262   | 0.9405  | 0.9526 |

[0117] 表1中的GSoP-Net为现有的基于二阶特征深度模型的遥感图像分类方法, ECA-Net为现有的基于通道注意力机制的遥感图像分类方法, 如图3所示。从表一中可以看出, 在相同实验条件下, 本发明的准确率要高于现有代表性的遥感图像分类模型。

[0118] 综上所述, 本发明一种基于双支路深度多尺度网络的遥感图像分类方法、存储介质及计算设备, 首先对样本集进行合理的预处理并分为训练集和测试集, 通过使用并行的具有不同空洞率的卷积层, 可以捕捉到不同尺度的信息, 从而在整个模型中引入多尺度信息, 进一步通过自适应模块选择出不同尺度特征图中的有用信息进行融合, 充分利用了多尺度特征中的信息, 最后通过多层的卷及操作生成鲁棒性且具有强鉴别性的特征用于最后的分类, 通过训练集对整个神经网络进行迭代训练使得网络具有正确分类能力。最后, 便可以对未知类别的图片进行分类。

[0119] 本领域内的技术人员应明白, 本申请的实施例可提供为方法、系统、或计算机程序产品。因此, 本申请可采用完全硬件实施例、完全软件实施例、或结合软件和硬件方面的实施例的形式。而且, 本申请可采用在一个或多个其中包含有计算机可用程序代码的计算机可用存储介质(包括但不限于磁盘存储器、CD-ROM、光学存储器等)上实施的计算机程序产品的形式。

[0120] 本申请是参照根据本申请实施例的方法、设备(系统)、和计算机程序产品的流程图和/或方框图来描述的。应理解可由计算机程序指令实现流程图和/或方框图中的每一流程和/或方框、以及流程图和/或方框图中的流程和/或方框的结合。可提供这些计算机程序指令到通用计算机、专用计算机、嵌入式处理机或其他可编程数据处理设备的处理器以产生一个机器, 使得通过计算机或其他可编程数据处理设备的处理器执行的指令产生用于实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能的装置。

[0121] 这些计算机程序指令也可存储在能引导计算机或其他可编程数据处理设备以特定方式工作的计算机可读存储器中, 使得存储在该计算机可读存储器中的指令产生包括指令装置的制品, 该指令装置实现在流程图一个流程或多个流程和/或方框图一个方框或

多个方框中指定的功能。

[0122] 这些计算机程序指令也可装载到计算机或其他可编程数据处理设备上,使得在计算机或其他可编程设备上执行一系列操作步骤以产生计算机实现的处理,从而在计算机或其他可编程设备上执行的指令提供用于实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能的步骤。

[0123] 以上内容仅为说明本发明的技术思想,不能以此限定本发明的保护范围,凡是按照本发明提出的技术思想,在技术方案基础上所做的任何改动,均落入本发明权利要求书的保护范围之内。

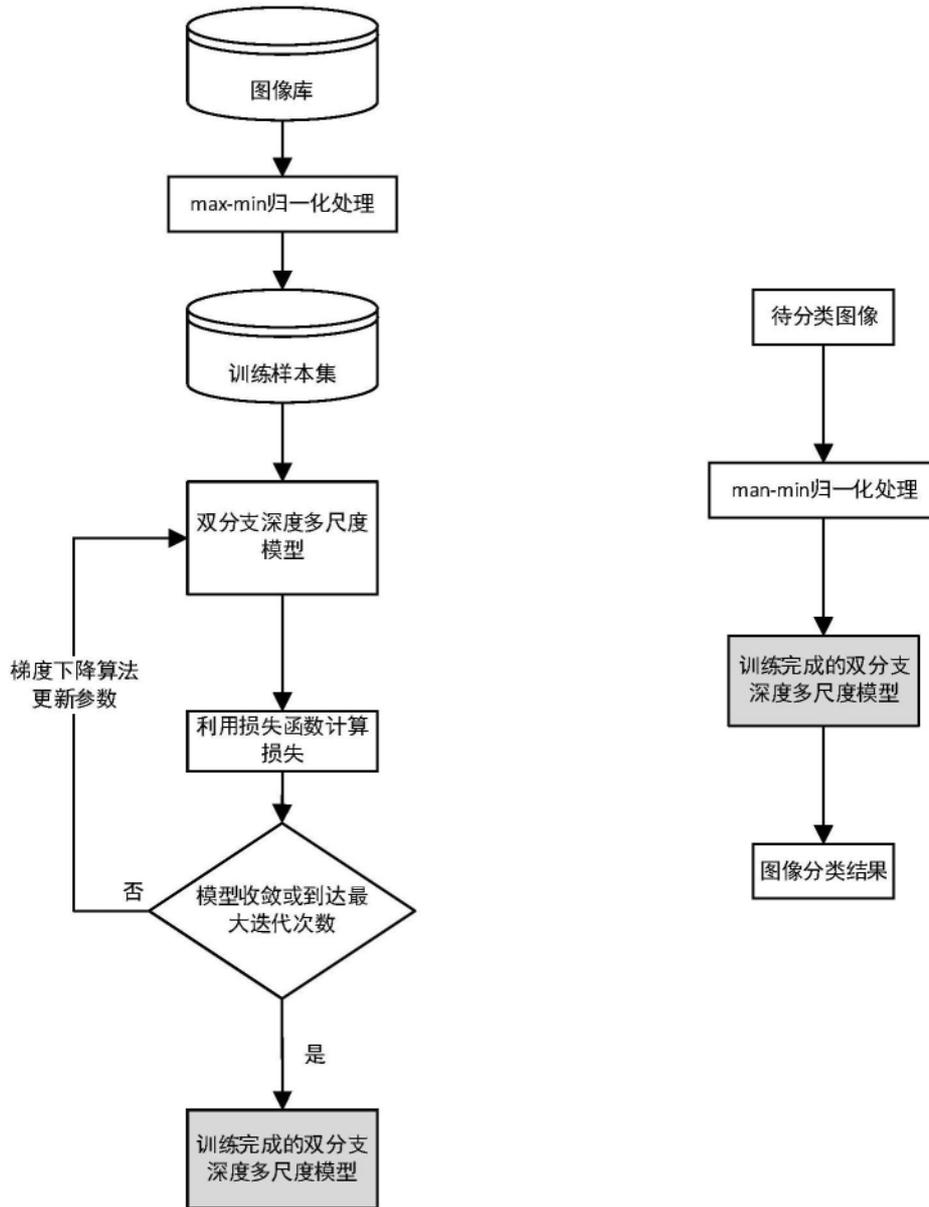


图1

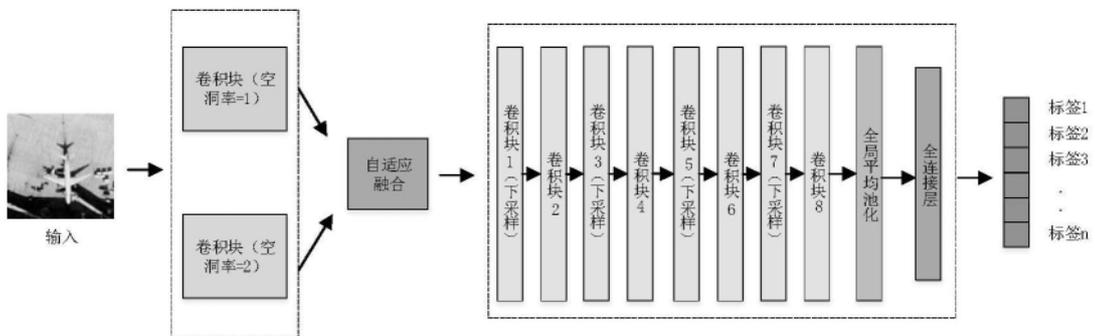


图2

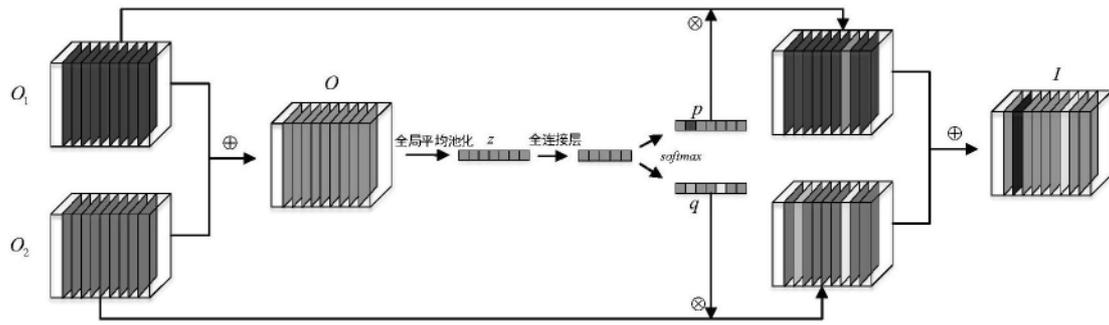


图3