

# 基于密集连接空洞卷积神经网络的青藏地区云雪图像分类

曹 辉, 翁理国, 张德正

(南京信息工程大学 自动化学院, 江苏 南京 210044)

**摘要:** 为了提高高纬度地区云雪卫星图像的识别准确率, 提出了密集连接空洞卷积神经网络与空洞卷积相结合的方法进行云雪卫星图像识别研究; 该方法首先采用常规卷积层对图像进行处理得到特征图, 然后采用多个密集块和过渡层对特征图进行处理; 其中, 密集块中采用跨层连接的方式实现了网络中所用层的特征传递, 使得大量云雪特征得到重用, 同时减轻了训练过程中的梯度消失问题; 密集块中的卷积核采用空洞卷积, 在减少参数量的同时扩大局部感受野, 对云雪的光谱信息进行特征提取; 最后, 该方法采用平均全局池化层与全连接层得到云雪图像的预测结果; 实验结果表明, 与其他机器学习方法相比, 该方法能够提高卫星云雪图像的识别准确率, 具有良好的泛化能力。

**关键词:** 云雪图像识别; 特征提取; 跨层连接; 空洞卷积

## Cloud and Snow Image Detection in Qinghai—Tibet Area based on Dense Dilated Convolution Neural Network

Cao Hui, Weng Ligu, Zhang Dezheng

(College of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract:** In order to improve the recognition accuracy of cloud—snow satellite imagery in Qinghai—Tibet region, this paper proposes a method combining dense dilated convolutional neural network and dilated convolution to carry out cloud snow satellite image recognition research. The method firstly processes the image by using a conventional convolution layer to obtain a feature map, and then uses a plurality of dense blocks and a transition layer to process the feature map. Among them, the feature transfer of the layers used in the network is realized by using the cross—layer connection in the dense block, so that a large number of cloud snow features are reused, and the gradient disappearance problem during the training process is alleviated. The convolution kernel in the dense block adopts the dilated convolution to expand the local receptive field while reducing the parameter quantity, and extract the feature information of the cloud snow. Finally, the method uses the average global pooling layer and the fully connected layer to obtain the prediction results of the cloud snow image. The experimental results show that compared with other machine learning methods, this method can improve the recognition accuracy of satellite cloud image and has good generalization ability.

**Keywords:** cloud snow image recognition; feature extraction; cross—layer connection; dilated convolution

## 0 引言

随着我国的人造卫星技术的不断发展, 卫星遥感影像技术的应用也越来越广泛<sup>[1]</sup>。在气象领域, 卫星图像的重要性不言而喻, 已经成为天气预报、灾害天气预测的最直接、可靠的信息来源<sup>[2]</sup>。随着卫星遥感技术及图像处理技术的飞速发展, 深度学习开始与卫星图像相结合, 使得卫星云图的应用有了极大的进步<sup>[3]</sup>。而我国的青藏高原地区, 每年都会会有大雪给畜牧业生产与牧民的生活造成危害, 所以相关部门做好大雪预测、及时发现积雪覆盖范围,

帮助牧民采取有效措施, 较少人畜损失是一项重要工作。而在冬季, 青藏地区降雪明显增多, 降雪检测就显得更加困难, 所以我们利用深度学习技术进行青藏高原地区的雪灾识别就尤为重要。因为云雪的全色波段的光谱特性具有相似性, 所以卫星云雪图像识别存在一定的技术难题<sup>[4]</sup>。李腾腾<sup>[5]</sup>等提出一种基于灰度共生矩阵与平均梯度的方法提取云雪纹理信息从而实现云雪分离方法。该方法主要是利用灰度均值与灰度共生矩阵计算的能量作为特征参数提取云的特征, 再利用改进的平均梯度和分形维数的方法实现云雪分离。陈婷<sup>[6]</sup>等针对全色图像的冰雪识别问题, 以过渡区理论为基础, 提出基于过渡区特征的冰雪识别方法。该方法首先利用聚类方法分离冰雪识别方法。该方法首先利用聚类方法分离雪、云与其物体再通过边缘检测提取过渡区图像, 并且与过渡区的均值和方差特征量组合成特征向量, 用以分析过渡区特征, 识别具有冰雪过渡区的点构成冰雪边界, 实现冰雪识别。

上述方法没有充分利用云雪的光谱特性, 因而存在局

**收稿日期:** 2018-11-05; **修回日期:** 2019-03-29。

**基金项目:** 国家自然科学基金项目(61503192); 江苏省自然科学基金(BK20161533); 江苏省青蓝工程。

**作者简介:** 曹 辉(1993-), 男, 江苏淮安人, 硕士研究生, 主要从事机器学习、大数据分析方向的研究。

翁理国(1981-), 男, 江苏南京人, 教授, 博士, 主要从事机器学习、大数据分析方向的研究。

限性。综上所述，以上的识别方法在分析云雪样本时，由于云雪特征复杂、全色光谱信息相似，存在提取云雪图像特征单一、多光谱信息没有充分利用等问题，检测方法存在一定的局限性，不具备较好的泛化能力<sup>[7]</sup>。随着深度学习技术的快速发展，尤其是在图像处理领域取得巨大的成功<sup>[8]</sup>。深度卷积神经网络具备了较强图像特征提取能力，实现了很多以前难以实现的功能<sup>[9]</sup>。这些经典的卷积神经网络也存在不足。本文将密集连接网络 (Densenet) 与空洞卷积相结合应用于多光谱卫星云雪图像识别分类，可以有效地利用云雪的光谱特征信息解决卫星云雪图像识别的问题。本文的方法相比于常见的机器学习方法，准确率高，泛化能力强。

## 1 密集连接卷积神经网络

### 1.1 密集连接卷积神经网络

卷积神经网络在解决图像识别领域得到了广泛应用<sup>[10]</sup>。本文将深度卷积神经网络应用于卫星云雪图像识别，也取得很好的识别效果。密集连接卷积神经网络模型是在深度残差卷积神经网络的基础上采用了一种全新的连接方式的改进<sup>[11]</sup>。密集连接卷积神经网络的密集连接是通过密集连接块实现的<sup>[11]</sup>。本文在密集连接块中采用了空洞卷积。密集块采用空洞卷积可以减少参数，扩大局部感受野，充分地提取卫星云雪图像的光谱信息特征。

### 1.2 密集连接空洞卷积神经网络结构

密集连接卷积神经网络在深度残差网络的基础上进行改进，将网络中的卷积层进行两两连接，从而网络中每一个卷积层都可以接收前面所有层的特征与信号。密集连接卷积神经网络在深度残差网络的基础上改变连接方式，在达到相同的精度时，其参数量与计算量均为深度残差网络的一半<sup>[12]</sup>。

#### 1.2.1 改进的密集连接卷积神经网络

密集连接卷积神经网络中密集连接是通过密集块实现的。在密集块中，第  $l$  层的输出等于将前面所有层的输出特征进行级联操作，再进行非线性变换  $H(\cdot)$ ，非线性变换公式：

$$X_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (1)$$

密集块中的密集连接方式如图 1 所示。




图 1 密集连接块结构图

其中， $H_1, H_2, H_3, H_4$  表示非线性变换， $x_0, x_1, x_2, x_3$  表示特征图。非线性变换  $H(\cdot)$  是一种由 3 种操作函数组成的复合函数。3 种操作函数分别是批归一化函数 (Batch Normalization, BN), Relu 激活函数，卷积操作

(conv)。

从密集连接块中，可以看出每一层都两两连接，网络使用较少的参数就可以使得大量特征得到复用。在密集块中，每层的特征图都要进行非线性变换。在密集块中采用卷积操作采用了  $1 \times 1$  的卷积核与  $3 \times 3$  的空洞卷积核相结合的卷积操作。其中，采用  $1 \times 1$  的卷积核的卷积层作为密集块的瓶颈层。瓶颈层主要是用来减少下一层输入的特征图数量，因此提高了卷积操作效率。在密集连块中，如果每层产生  $k$  个特征图，则它会在第  $l$  层输入特征图的个数是  $k_0 + k(l-1)$ ，其中  $k_0$  是输入层的通道数，则超参数  $k$  为网络的增长率。其中，超参数  $k$  是卷积核的个数。 $k$  值越大则卷积核提取特征的能力越强，网络中流通的信息量也会越大，但也会相应地提高模型的复杂度。所以  $k$  值不能太大，本文采用的  $k$  值设为 32。空洞卷积是在原卷积核的基础之上设置一个参数，扩张率为  $r$ 。将原卷积核进行扩张在膨胀系数所限制的范围内。这样得到的空洞卷积核的高度为  $h + (h-1)(r-1)$ ，宽度为  $w + (w-1)(r-1)$ 。其中， $h$  为原卷积核的高， $w$  为原卷积核的宽。密集块通过使用空洞卷积核，可以增大卷积核的局部感受野而不增加参数量。本文设置的膨胀参数  $r$  为 2，这样  $2 \times 2$  的卷积核就与  $3 \times 3$  卷积核具有相同的感受野，同时减少了卷积核的参数量。原始卷积核与空洞卷积核如图 2 所示。图 2 (a) 为  $2 \times 2$  的原始卷积核，假设在原始卷积核中的参数分别为  $a, b, c, d$ 。原始卷积核在进行扩张后如图 2 (b) 所示。原卷积核未被占用的区域用 0 进行填充。本文采用的密集块就可以扩大卷积核的局部感受野，从特征图中充分提取云雪的光谱特征信息。




图 2 原始卷积核与空洞卷积核

#### 1.2.2 密集连接卷积神经网络过渡层

由于网络的密集块中的每一层都会接受前面所有层的特征作为输入，这样的采用级联方式使得网络层数不断加深，因此为了在网络结构中进行下采样处理，就需要在密集块之后采用过渡层进行数据降维操作。过渡层中主要是包含  $1 \times 1$  的卷积层和  $2 \times 2$  的平均池化层两部分。

过度层主要目的是减少特征图的数量和大小，实现数据降维的目的。如果密集块包含  $m$  个特征映射，为了在过渡层中减少特征图，可以使过渡层生成  $\theta m$  输出特征图，其中  $0 < \theta \leq 1$  被称为压缩因子。本文的密集连接网络采用的压缩因子  $\theta = 0.5$ 。

#### 1.2.3 密集连接卷积神经网络整体结构

本文采用的密集连接神经网络的结构包含一个常规的卷积层、3 个密集块、2 个过渡层、全局平均池化层、一个全连接层、一个输出层。

其中，常规卷积层包含卷积操作、relu 函数激活以及最

大池化降维操作。密集块与过渡层交替出现。3 个密集块的层数分别是 6 层、12 层、24 层。3 个过渡层包含  $1 \times 1$  卷积核操作与  $1 \times 1$  池化操作。最后 3 层是全局平均池化层、全连接层、输出层。密集连接卷积神经网络采用跨层连接的方式, 使得网络结构中大量特征的重用, 可以充分利用卫星云雪图像的光谱特征信息。同时, 反向误差信号传播过程中, 不会出现随着层数加深而变得越来越小, 缓解了梯度消失的问题。密集连接神经网络的结构如图 3 所示。




图 3 密集深度卷积神经网络结构

随着网络层数的不断加深, 神经网络模型的深度与复杂度也逐渐加深。如果卷积神经网络层数太少就不能充分提取云雪样本的光谱信息特征。如果网络层数的加深, 网络的参数就增加, 训练时间较慢<sup>[12]</sup>, 同时网络在训练数据时, 梯度信号会逐渐消失, 从而导致网络模型难以优化<sup>[12]</sup>。本文将改进的密集连接卷积神经网络与空洞卷积核相结合, 应用与多光谱卫星云雪图像检测较好地解决了这些问题。

## 2 密集连接空洞卷积神经网络的云雪识别模型

本文的多光谱卫星云雪图像采集主要来自于中国 HJ1A/1B 卫星, 该卫星是我国用来进行环境与自然灾害的监测预报。本文基于 HJ1A/1B 的四个可见光通道的数据实现云雪数据识别。本文采用的数据集中云、雪、云雪混合、无云无雪样本数量都是 9 600 个。每类取 7 680 个样本作为训练集, 每类取 1 920 个样本作为测试集。利用密集连接卷积神经网络对多光谱卫星云雪图像进行检测, 实现 4 分类任务。4 分类分别是只有云的区域, 只有雪的区域, 无云无雪区域, 云雪混合区域。在密集连接卷积神经网络中, 首先将每个多光谱卫星云雪图像输入到网络模型中。在常规的卷积层中, 网络模型利用  $7 \times 7 \times 64$ 、步长为 2 的卷积核对图像数据进行特征提取, 然后利用  $2 \times 2$  的最大池化进行降维, 生成  $7 \times 7 \times 64$  的特征图。特征图进入到密集块 1 中。密集连接块 1 包含 6 层神经网络, 使得每层网络输出 32 个特征图, 即增长率为 32。每层再和前面所有层的特征图进行级联, 然后进行非线性函数变换。特征图送入到过渡层 1, 进行  $1 \times 1$  的卷积与  $2 \times 2$  池化操作。因为在过渡层设置了压缩因子为 0.5, 使得过渡层 1 输出的特征图变为密集连接块 1 输出的一半。过渡层 1 输出的特征图经过后面的多个密集块与过渡层, 再经过全局平均池化层、全连接层。当特征图经过全连接层是, 每张特征图大小已经变为  $1 \times 1$ , 所以全连接层输出的特征图维度是  $1 \times 1 \times 1 024$ , 最后的输出层输出包含 4 个类别的类别概率向量, 最终实现 4 分类任务。利用密集连接卷积神经网络实现云雪图像分类过程如图 4 所示。




图 4 卫星云雪图像分类过程

## 3 实验结果分析

图 5 为不同算法的卫星云雪识别效果图, 图 6 为另一组卫星云雪检测效果图。在实验效果图中, 只有云的区域由深灰色表示, 只有雪的区域由浅灰色表示, 无云无雪区域由黑色表示, 云雪混合区域由白色表示。本文分别使用了支持向量机 (SVM)、随机森林 (RandomForest)、卷积神经网络 (CNN)、卷积密集连接神经网络 (Densenet)。

本文采用灰度共生矩阵经云雪图像的纹理特征转化为 SVM 模型的分类特征。由于多光谱云雪卫星云雪图像样本的纹理特征是通过在空间位置重复出现灰度分布而形成的, 所以在图像空间已一定的距离隔开两个像素之间存在一定的灰度关系, 即图像的灰度空间相关性。灰度共生矩阵是图像的的像素距离和角度的矩阵函数, 通过计算图像中两点灰度之间的相关性, 从而反映云雪图像的的纹理特征的综合信息<sup>[7]</sup>。

我们就可以用灰度共生矩阵描述多光谱云雪卫星云雪图像的纹理特征, 灰度共生矩阵的统计量有: ASM 能量、对比度、相似性、熵等。本文将灰度共生矩阵的 ASM 能量、对比度、相似性、熵等作为 SVM 模型的分类特征。其中, 对于 SVM, 本文采用的非线性分类 SVM 可以用于 4 分类任务。非线性分类 SVM 采用 RBF 作为核函数, 选取合适惩罚系数是 20。这样在训练样本数据时, 就可以使用核技巧以及软间隔最大化, 学得一个非线性 SVM 模型, 实现云雪图像识别。

RandomForest 是以决策树为基学习器的集成学习方法<sup>[13]</sup>。该算法简单、容易实现。决策树在对样本训练划分属性时, 是从当前属性集合中选择一个最优属性进行划分。随机森林模型在决策树训练过程中, 引入随机性选择训练集属性, 对属性进行分割, 直至叶节点。本文在使用随机森林模型时, 采用的分裂选择度量为 gini 指数。选择 100 棵决策树组成 RandomForest, 提取样本的纹理特征, 进行云雪识别<sup>[14]</sup>。

本文的 CNN 模型总共有 7 层, 分别是卷积层、池化层、卷积层、池化层、全连接层、全连接层、输出层<sup>[15-16]</sup>。图 5 是本文采用的支持向量机 (SVM)、随机森林 (RandomForest, RF)、卷积神经网络 (CNN)、密集连接卷积神经网络 (Densenet) 的云雪图像预测实验结果对比图。图 5 (a) 是卫星云图原始图像, 图 5 (b) 是 SVM 分类的效果图, 图 5 (c) 是 RandomForest 分类的效果图, 图 5 (d) 是 CNN 检测的效果图, 图 5 (e) 是 Densenet 检测的效果图。

通过对图 5 中各个检测效果进行分析, 可以得到如下

结论：图 5 (b) 中深灰色区域部分较多，浅灰色区域较少，使得云的过多检测，SVM 的检测效果比较差。图 5 (c) 中深灰色区域比 (b) 中减少，浅灰色区域增多，RandomForest 的识别效果有所提升，依然有云的误检，图 5 (d) 中浅灰色区域较多，深灰色区域较少，存在雪的误检。但是检测效果比 SVM 与 RandomForest 有所提升。图 5 (e) 的检测效果比较好，Densenet 根据训练样本的光谱特征与纹理信息来进行检测，能比较好地区分出云与雪的区域，以及在云雪混合和无云无雪区域的上检测效果较好。




图 5 不同算法的云雪预测图

图 6 为另一组不同算法的云雪检测预测图。我们从实验结果对比图中，仍然会发现 SVM 的结果图 6 (b) 中，存在云的误检，深灰色区域较多，SVM 的检测效果依然较差。在 RandomForest 的结果图中 6 (c) 浅灰色区域较少，存在雪的误检，RandomForest 的识别效果不理想。CNN 的实验结果图识别结果比 SVM 与 RandomForest 的效果较好，能提取云雪的大致轮廓，较好的区分样本的特征，泛化效果较好。在 6 (e) 图中，Densenet 的效果比 CNN 更好，该模型能有效提取云雪的光谱特征与纹理信息，有效区分样本特征。




图 6 不同算法的云雪预测图

为了进一步对实验结果进行有效分析，采用 100 张不同区域的卫星云图测试结果作为统计的平均值进行对比。表 1 是 RandomForest、SVM、CNN、Densenet 等方法的预测结果。从表中，可以看出，SVM 的效果最差，RandomForest 的效果优于 SVM，CNN 的结果优于 RandomForest。本文使用的 Densenet 识别的准确率高于其他几类方法。CNN、Densenet 在多光谱卫星云雪图像的训练集准确率和验证集准确率变化趋势如图 7~8。图 7 是 CNN 的准确率变化图。图 8 是 Densenet 的准确率变化图。

图 7 是 CNN 在训练集与测试集的准确率变化图。图 7 是 Densenet 在训练集与测试集的准确率变化图。我们可以看出 Densenet 的收敛速度快于 CNN。Densenet 并且无论是在训练集还是测试集的准确率也高于 CNN。所以，从实验

表 1 卫星云雪图检测平均准确率

检测方法	准确率
SVM	59.90%
RandomForest	60.16%
CNN	90.45%
Densenet	94.16%




图 7 CNN 的准确率变化图




图 8 Densenet 的准确率变化图

结果图上可以看出 Densenet 的测试结果要优于 CNN。CNN、Densenet 在多光谱卫星云雪图像的训练集损失和验证集损失变化趋势如图 9~10 所示。图 9 是 CNN 的损失变化图。图 10 是 Densenet 的损失变化图。我们可以看出 Densenet 的损失减少速度快于 CNN。所以，从图 9~10 我们可以看出 Densenet 的在损失减少的方面要优于 CNN。所以 Densenet 在多光谱卫星云雪图像上的预测效果要优于 CNN 的预测效果。




图 9 CNN 的损失变化图

#### 4 总结

由于云雪表面特征复杂与光谱特征的相似性，传统机




图10 Densenet的损失变化图

器学习方法不能很好地提取样本特征,使得云雪检测效果不理想。本文将密集连接卷积神经网络应用于多光谱卫星云雪图像检测方面,提升卫星云雪图像的检测效果。因为密集连接卷积神经网络具有能解决梯度消失问题<sup>[17]</sup>、强化特征传播、支持特征的重用、减少了参数量等优点<sup>[18]</sup>,所以在图像领域应用广泛<sup>[19]</sup>。密集连接卷积神经网络每一层提取的特征都相当于对输入数据进行一个非线性变换,而随着深度的增加,变换的复杂度也逐渐增加相当于更多非线性函数的复合<sup>[20]</sup>。相比于一般神经网络的分类器直接依赖于网络最后一层(复杂度最高)的特征,密集连接卷积神经网络可以综合利用浅层复杂度低的特征,因而泛化能力较好。本文的采用密集连接卷积神经网络对HJ1A/1B卫星拍摄的我国青藏高原地区的多光谱卫星云雪图像进行识别<sup>[21]</sup>。最后通过实验结果对比,说明密集连接卷网络在识别多光谱卫星云雪图像时具有较好的泛化能力,但是对于雪的误检还有待降低。虽然本文采用密集连接卷积神经网络进行多光谱卫星云雪图像,识别效果比传统的机器学习方法进一步提升,但是相关研究中还处于初始阶段,存在一些不足,需要进一步优化与改进模型。本文的网络模型主要在以下方面进行改进:1)保证识别模型检测精度的前提下,提高模型的检测的速度,因此应该进一步优化模型网络结构。2)着重提高模型的抗干扰的能力,在卫星图像中存在云雾、降水等干扰因素对数据样本产生影响。所以,我们要提升模型的抗干扰能力<sup>[22]</sup>。3)随着计算机硬件技术的快速发展,模型可以与计算机硬件水平相适应设,向着检测方法快速化、精准化的方向发展<sup>[23]</sup>。

#### 参考文献:

[1] 金磊,赵鑫,全广宇. 气象卫星资料在森林环境监测中的应用[J]. 科学技术创新, 2018(18): 147-148.

[2] 曹永旺. 中国西部低温雪灾统计规律及对称性结构[D]. 西安: 陕西师范大学, 2016.

[3] 申茂阳,王舰锋,王阳光. 基于卷积神经网络的卫星云图云量计算[J]. 系统仿真学报, 2018, 30(5): 1623-1630.

[4] 孔维斌,夏旻,仇学飞. 基于深度极限学习机的卫星云图云量计算[J]. 计算机科学, 2018, 45(4): 227-232.

[5] 李腾腾,唐新明,高小明. 资源三号影像朵云识别中云雪分离研究[J]. 测绘通报, 2016(2): 46-49.

[6] 孙磊,曹晓光. 基于多种纹理特征的全色图像云雪区特征提取[J]. 电子设计工程, 2014, 22(2): 174-176.

[6] 陈婷,汪爱华,王智勇. 基于过渡区特征的全色遥感图像冰雪识别[J]. 国土资源遥感, 2013, 25(2): 27-32.

[7] 刘万安,施必成,夏旻. 基于多维多粒度级联森林的云雪分类[J]. 2018, 计算机应用: 1-7.

[8] 葛轶众,杨马英. 基于ReLU神经网络的移动目标视觉伺服研究[J]. 计算机测量与控制, 2018, 26(8): 78-82.

[9] Lo S B, Lou S A, Lin J S, et al. Artificial convolution neural network techniques and applications for lung nodule detection. [J]. IEEE Transactions on Medical Imaging.

[10] Lo S C B, Chan H P, Lin J S, et al. Artificial convolution neural network for medical image pattern recognition [J]. Neural networks, 1995, 8(7): 1201-1214.

[11] 夏旻,施必成,刘佳,等. 多维加权密集连接卷积网络的卫星云图云检测[J]. 计算机工程与应用, 2018, 54(20): 184-189.

[12] 夏旻,宋稳柱,施必成,等. 基于加权密集连接卷积网络的深度强化学习方法[J]. 计算机应用, 2018, 38(8): 2141-2147.

[13] Zhuo Z H, Feng, J. Deep Forest: Towards an alternative to deep neural networks [J]. 2017. arXiv preprint arXiv: 1702.08835, 2017.

[14] 薄瑜,刘瑞杰,何丹丹. 基于改进决策树分类算法的遥感影像分类研究[J]. 计算机测量与控制, 2018, 26(7): 207-211.

[15] 张富为,杨秋翔,宋超峰. 基于卷积神经网络的构件分类策略的研究[J]. 2018, 计算机工程与应用: 1-8.

[16] 黄一天,陈芝彤. Pytorch框架下基于卷积神经网络实现手写数字识别[J]. 电子技术与软件工程, 2018(19): 147.

[17] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition [J]. Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.

[18] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition [J]. Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.

[19] Huang G, Liu Z, Maaten L V D, et al. Densely Connected Convolutional Networks [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. 2017: 2261-2269.

[20] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.

[21] 李海亮,汪秀华,罗红霞,等. 基于HJ-1A/1BCCD数据的海南岛水体提取研究[J]. 中山大学学报(自然科学版), 2016(1): 149-154.

[22] 丛爽,向微. BP网络结构、参数及训练方法的设计与选择[J]. 计算机工程, 2001, 27(10): 36-38.

[23] Dakos V, Nes E H V, Donangelo R, et al. Spatial correlation as leading indicator of catastrophic shifts [J]. Theoretical Ecology, 2010, 3(3): 163-174.