

基于卷积神经网络模型的遥感图像分类^①

付秀丽^{②*} 黎玲萍^{***} 毛克彪^{③***} 谭雪兰^{****} 李建军^{*****} 孙 旭^{*****} 左志远^{***}

(* 北京石油化工学院信息工程学院 北京 102617)

(** 中国农业科学院农业资源与农业区划研究所呼伦贝尔草原生态系统国家野外科学观测研究站 北京 100081)

(*** 北京化工大学信息科学与技术学院 北京 100029)

(**** 湖南农业大学资源环境学院 长沙 410128)

(***** 中南林业科技大学计算机与信息工程学院 长沙 410004)

(***** 东北农业大学文法学院 哈尔滨 150030)

摘 要 研究了遥感图像的分类,针对遥感图像的支持向量机(SVM)等浅层结构分类模型特征提取困难、分类精度不理想等问题,设计了一种卷积神经网络(CNN)模型,该模型包含输入层、卷积层、全连接层以及输出层,采用 SoftMax 分类器进行分类。选取 2010 年 6 月 6 日 LandsatTM5 富锦市遥感图像为数据源进行了分类实验,实验表明该模型采用多层卷积池化层能够有效地提取非线性、不变的地物特征,有利于图像分类和目标检测。针对所选取的影像,该模型分类精度达到 94.57%,比支持向量机分类精度提高了 5%,在遥感图像分类中具有更大的优势。

关键词 卷积神经网络(CNN),模型,支持向量机(SVM),特征提取,遥感图像分类

0 引 言

遥感图像是通过探测地物电磁辐射强度获得的反映地表各种地物的综合影像,其包含着从可见光到近红外的几百个窄波段内获取的地物图像,人们根据典型影像特征,可判断感兴趣的特定遥感目标。随着遥感技术的提高,遥感图像中目标地物轮廓会更加清晰,纹理特征更加复杂,空间信息更加丰富。遥感图像是监测地球表面的一种有效工具。遥感图像分类是对研究区地物类型在遥感图像上的各种统计信息进行特征提取,充分利用获取的特征向量按照规则对图像上像元进行划分归类,获取地物类型信息^[1]。遥感图像分类已被广泛用于对地探测^[2]

及物理学^[3]、农业^[4]、环境科学^[5,6]研究等。遥感图像包含着复杂的非线性特征,光谱信息之间既具有互补性,又存在极大的冗余性,这使得遥感数据的处理存在较大的复杂性,使得特征提取困难,对目标分类等领域精度的提高有所限制^[7]。遥感图像传统的分类方法有监督分类、非监督分类、半监督分类等,常用的分类方法有神经网络分类、支持向量机分类、随机森林分类、决策树分类等。分析得出,支持向量机等属于浅层结构模型^[8],这些浅层结构模型的共同点是对于原始的输入信号只经过较少层次的线性或者非线性处理来达到信号与信息处理的目的。但是对于一些复杂的信号,采用浅层的结构模型其表达能力具有一定的局限性,浅层模型输入和输出中间是有限的线性或者非线性的变换组合,所

① 国家自然科学基金(41571427),国家重点研发计划重点专项(2016YFC0500203),北京市属高校拔尖人才(CIT&TCD201504047)和北京市教委科研计划(KM201410017008)资助项目。
② 女,1978 生,博士,副教授;研究方向:地表发射率反演。
③ 通讯作者,E-mail: maokebiao@126.com
(收稿日期:2016-12-29)

以并不能充分的学习到信号中复杂的结构信息^[9], 分类结果不理想, 并且, 在不做任何的人工特征提取的条件下将所有的光谱波段作为分类器的输入, 将会出现由于数据高维度而产生的 Hughes 现象, 分类精度也会下降。

高光谱遥感图像数据结构复杂, 采用浅层结构模型对其进行分类具有局限性, 从而采用深层结构对高光谱遥感图像进行分类更为合理。深度学习是深度网络结构, 是机器学习的一个分支, 是通过建立类似于人脑的分层模型结构, 对输入数据逐级提取底层到高层的特征, 从而很好地建立底层信号到高层语义的映射关系^[10]。深度学习是深层次的神经网络, 能在有限的训练样本下获得较高的分类精度^[11], 因而在遥感图像分类中比传统神经网络更具优势, 分类效果更好。目前, 一些深度学习模型已经被应用于遥感图像处理。2014 年, Chen 针对高光谱遥感图像非线性特性的特征提取, 将栈式自编码网络应用到高光谱遥感图像分类中^[12]。2015 年, Zhao 等根据高光谱数据在光谱和空间变化下的数据特性, 将深度置信网络应用到高光谱数据的特征学习和数据分类, 有效地解决了由于数据结构复杂和样本数目有限而引起的问题^[13]。Romero 等提出了一种无监督的卷积神经网络算法, 通过采用贪婪分层无监督训练方式构建一个深度卷积神经网络模型, 并将其运用到遥感图像分析中^[14]。

卷积神经网络是深度学习在图像识别中比较常用的模型, 采用局部连接的方式实现特征提取和权值共享, 从而减少了参数的数量, 降低运算的复杂度, 主要运用在图像处理领域。在物体检测和识别领域, 卷积神经网络具有较高的识别率和广泛的实用性^[15], 对于图像平移、局部变形和旋转具有不变性^[16], 并且具有良好的容错性、并行处理能力以及自学能力。本文基于 Matlab 设计了一种卷积神经网络, 将其用于遥感图像进行特征提取和分类, 并通过实验验证了其可行性。

1 分类方法

1.1 支持向量机算法分类

支持向量机(SVM)于 1995 年由 Vapnik 首次提

出^[17], 是一种基于统计学习理论和结构最小风险原理的针对小样本训练和分类的机器学习理论^[18]。SVM 具有小样本学习、学习效率高、抗噪声性能、推广性好等优点, 在很大程度上解决了其他算法存在的过学习、局部最小值等问题, 同时能够用于解决空间信息处理分析领域的遥感图像处理, 在遥感图像分析与处理的主要应用如土地利用分类^[19]、混合像元分解^[20]、遥感影响融合^[21]、多光谱/高光谱遥感分类等^[22]。SVM 最大的优点在于不会引起 Hughes 现象, 即对于有限的训练样本, 特征维数的增加不会降低分类精度, 而且在各类别光谱值比较相近的情况下, SVM 依然可以根据有限的样本区分开各类。

SVM 主要是根据统计原理, 在特征空间中找到一个最优分类超平面, 将各类最大限度的区分开。根据待分类样本在特征空间的分布情况, 一般地, SVM 对线性可分和线性不可分这两种情况进行分析。设有样本集 (x_i, y_i) , $\mathbf{x} \in \mathbf{R}^d$, $y_i \in \{-1, +1\}$, $i = 1, 2, \dots, n$, 其中 n 为样本个数; d 为样本向量的维数; y_i 为分类类别。首先, 在线性可分的情况下, 根据在原空间寻找两类样本的最优分类超平面, 分类面的方程为

$$(\mathbf{w} \cdot \mathbf{x}) + b = 0 \tag{1}$$

其中, 向量 $\mathbf{w}$ 和标量 b 决定了分类超平面的位置, $(\mathbf{w} \cdot \mathbf{x})$ 表示两个向量的内积。并且要满足如下条件:

$$y_i[(\mathbf{w} \cdot \mathbf{x}) + b] - 1 \geq 0 \tag{2}$$

满足上述条件且使 $\|\mathbf{w}\|^2$ 最小的分类面就是最优分类面。根据统计原理, 求的最优分类函数为

$$\begin{aligned} f(x) &= \operatorname{sgn}\{(\mathbf{w}^* \cdot \mathbf{x}) + b\} \\ &= \operatorname{sgn}\left(\sum_{i=1}^n \partial_i^* y_i (x_i \cdot \mathbf{x}) + b^*\right) \end{aligned} \tag{3}$$

式中, $\operatorname{sgn}(\cdot)$ 为符号函数, $\partial_i^* > 0$ 为 Lagrange 系数, $\mathbf{w}^*$ 是法向量, b^* 为分类的阈值, 可以由任意一个支持向量求得。

在线性不可分的情况下, 加入了松弛变量进行分析, 将输入向量 $\mathbf{x}$ 从原始模式空间经过核函数的非线性变换, 映射到高维特征空间 H , 将非线性问题转化为某个高维空间中的线性问题, 在高维空间中寻找最优分类超平面, 设核函数为 $k(x_i \times x_j) = \varphi(x_i$

$\times x_j$), 建立的超平面为

$$\mathbf{w}\varphi(x) + b = 0 \quad (4)$$

要求它满足

$$y_i(\mathbf{w}\varphi(x) + b) - 1 \geq 0 \quad (5)$$

最后求得最优分类函数为

$$f(x) = \text{sgn}\left(\sum_{i=1}^n \partial_i^* y_i k(x_i \cdot \mathbf{x}) + b^*\right) \quad (6)$$

其中, $\text{sgn}(\cdot)$ 为符号函数, $\partial_i^* > 0$ 的样本定义为支持向量。

支持向量机属于浅层模型^[23], 对于原始的输入信号只经过较少层次的线性或者非线性处理, 可根据少量的训练样本得到学习精度和学习能力间的最优折中点。但是, 在大数据环境下, 由于支持向量机的表达能力具有一定的局限性, 不能充分学习到信号中复杂的结构信息^[24], 已不再适用, 而深层次的结构模型因其复杂的多层非线性变换而具有更强的表达能力和建模能力, 从而更适合处理复杂类型的

信号。

1.2 卷积神经网络算法

目前, 大部分遥感图像分类方法都是基于浅层结构, 例如支持向量机和逻辑回归分类器(LR)都是单层结构^[25]。基于深度学习的分类方法包含着两层或两层以上结构来提取有用的特征, 这种设计类似于模拟从视网膜到皮质的过程, 这种深层的架构在图像分类和目标识别领域中具有广阔的应用前景^[26,27]。卷积神经网络的结构与其他深度学习模型不同, 卷积神经网络具有局部连接和权值共享的特点。卷积神经网络使用局部连接的方式, 能够有效地提取空间信息, 通过共享权值的方式减少参数的数量。卷积神经网络是一个多层的神经网络, 基本的网络结构可以分为四个部分: 输入层, 卷积层, 全连接层和输出层, 本文采用的卷积神经网络结构如图1所示。




图1 卷积神经网络结构

输入层可以直接输入原始数据, 本研究的输入数据是经过辐射定标和大气校正的光谱图像, 选取训练样本并进行规则化, 保证样本的尺寸统一为 $3@32 \times 32$, 即每个样本的大小为 32×32 , 包含3个波段。

卷积层是提取样本特征的过程, 也叫做特征提取层, 包括卷积和池化两个过程。卷积的主要作用是提取输入数据特征, 每一个不同的卷积核提取的特征都不同, 卷积核数量越多, 提取到的特征越多。假设有二维离散函数 $f(x, y)$, $g(x, y)$, 那么它们的卷积定义为

$$f(m, n) * g(m, n) = \sum_u \sum_v f(u, v) g(m - u, n - v) \quad (7)$$

实际上等价于图像和卷积核的卷积操作, 即输入图像与可训练的卷积核进行卷积, 然后加一个偏置, 输入到神经元的激活函数, 得到卷积输出层。为了在保留有用信息的基础上减少运算数量, 加快网络的训练速度, 卷积神经网络在卷积过程后面连接一个池化过程的方式来减少数据量。池化是根据图像相对不变的属性, 对图像相邻区域的特征信息进行聚合统计。池化过程不仅能减小卷积提取的数据

特征维度,同时还能降低网络的拟合过程,改善网络性能。每一个池化操作对应的都是前一次的卷积操作,池化操作中的每个神经元对应卷积中的每一个 $N \times 1$ 位置。本研究使用的是最大池化方法,基本原理是选图像区域的最大值作为该区域池化后的值,其公式为

$$a_j = \max_{N \times 1} (a_i^{n \times 1} u(n, 1)) \quad (8)$$

其中, $u(n, 1)$ 是卷积操作的一个窗函数, a_j 是对应图像区域的最大值。

一般地,卷积层数越多,能够提取到更加抽象的特征。如图 1 所示,在第层第特征提取层 (x, y, z) 位置的神经元 v_{ij}^{xyz} 的值为

$$v_{ij}^{xyz} = g \left(\sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)} + b_{ij} \right) \quad (9)$$

其中, m 代表第 $(i-1)$ 特征提取层与当前第 j 特征提取层之间连接, P_i 和 Q_i 分别是卷积核的大小。 R_i 代表光谱的维度。 w_{ijm}^{pqr} 是神经元 (p, q, r) 连接到第特征提取层的权重, b_{ij} 是第 i 层第 j 个特征提取层的偏置^[11]。本文在第一次卷积采用 $5 \times 5 \times 32$ 的卷积核,第二次卷积采用 $5 \times 5 \times 64$ 的卷积核,池化过程都采用 2×2 矩阵。

全连接层是多层感知机的隐含层部分。通常情况下,后面层的神经元节点都和前一层的每个神经元节点连接,同一层的神经元节点之间是没有连接的。每一层的神经元节点分别通过连接线上的权值进行前向传播,加权组合得到下一层神经元节点的输入^[28]。

卷积神经网络的输出层通常是一个分类器,输出层神经元节点的数目根据具体分类任务来确定的。本研究采用的分类器是 SoftMax 分类器,SoftMax 分类器是以多项式分布为模型建模,输出结果的同时可以根据输出结果转换为分类概率值,适合对多种互斥的类别进行分类。SoftMax 对 k 类分类问题的系统方程为

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}; \theta) \\ p(y^{(i)} = 2 | x^{(i)}; \theta) \\ \vdots \\ p(y^{(i)} = k | x^{(i)}; \theta) \end{bmatrix} \quad (10)$$

其中, $1/(\sum_{j=1}^k e^{\theta_j^T x^{(i)}})$ 项对概率分布进行归一化操作,保证所有概率之和为 1。SoftMax 损失函数的数学表达式为

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T x^{(i)}}} \right] \quad (11)$$

其中, $1\{\cdot\}$ 表示指示性函数,当括号里的值为真时,函数的结果为 1,为假时,函数的结果为 0。

2 分类结果比较

基于光谱特征的遥感影像分类是一种将像素矢量作为输入的被广泛使用的传统方法,本文主要是设计一个卷积神经网络模型,将卷积神经网络分类和支持向量机分类算法进行对比实验,以验证其在遥感图像分类领域的有效性。

本文选取的数据为中空间分辨率 Landsat TM5 影像,轨道号为 114-027,数据接收时间是 2010 年 6 月 6 日,选取我国水稻生产第一大县富锦县为研究区域,遥感影像覆盖富锦县 90% 以上的地区。遥感数据的最佳波段选取是增强遥感图像处理的关键部分,直接影响到遥感图像解译和信息特征提取。通常最佳波段组合是指波段信息量丰富、波段相关性小、地物光谱差异大、可分性好的波段组合^[29]。根据单波段特点和地物特点选定 4、5、1 波段,样本大小为 32×32 ,对 TM 影像进行裁剪,完成数据的前期准备。

2.1 卷积神经网络特征提取

光谱传感器提供了详细的光谱信息,提高了区分各类地物的准确率和分类精度。此外,随着光谱技术的进步,光谱传感器提供更为精细的空间分辨率,为分析图像中的小空间结构提供依据^[30]。为研究这些空间结构,特征提取是关键的一部分。2009 年,Plaza 提出基于光谱信息的特征提取系统^[31],随着成像技术的发展,光谱传感器可以提供更加丰富的空间信息,促进了遥感图像分类的发展^[32]。Tarabalk 发现基于光谱—空间的特征提取方法极大地改善了分类算法的性能^[33]。由于卷积神经网络结构对图像的各种形式的变形具有高度不变性,因

而将卷积神经网络用于遥感图像光谱—空间的特征提取,不仅能降低因图像变形而引起的误差,同时还减少了特征提取的时间。

卷积神经网络模型通过不断地反馈调节以调到最优状态,模型中可以调节的参数有学习率、迭代次数、卷积层数等。模型利用 SoftMax 分类器进行分类,在数据处理过程中,确定学习率为 0.005,卷积层数为 3 层。为减少模型的处理时间,在模型训练之前,将数据归一化到 $[-1,1]$ 之间。

图 2 用折线图直观地显示了在不同的迭代次数下图像分类精度的变化情况,最终选取迭代次数为 70 次,作为最佳迭代次数。由此我们可以得知,迭代次数的增加在一定的范围内可以提高分类精度,但超过一定的范围则会导致分类精度的下降。




图 2 不同迭代次数下的分类结果

特征提取在卷积神经网络中是关键的一部分,按照不同的权重将特征提取出来,通过灰度图可视化的方式显示。每一个卷积核可以提取输入信号的特征,本研究采用的数据大小为 32×32 ,采用 5×5 的卷积核,下面以水田特征提取为例,经过数据预处理后输入卷积网络的水田样本图如图 3 所示。

经过 32 个 5×5 卷积核,即提取 32 个特征,得到第一层卷积后得到的特征提取图如图 4 所示,由于卷积神经网络模型自身的特点,经过卷积层特征提取之后,样本图像边缘有虚化现象。




图 3 数据预处理后输入的水田样本图



图 4 第一层卷积后得到的特征提取图

经过第一层卷积之后,对卷积结果进行池化,将池化的结果作为第二层卷积的输入,第二层卷积采用 64 个 5×5 卷积核,经过卷积后得到的特征提取图如图 5 所示。

最后再经过一层池化层得到卷积层的结果,并将其连接起来作为分类器的输入。从图 4 和图 5 对比可以看出,特征提取图的变化很明显,初始时是杂乱无章的,经过学习之后出现相关性和连续性。结果表明网络所学到的特征是通过输入与卷积内核的卷积得到。这些不同的卷积核能提取到不同的特征,经过一层一层的卷积之后提取到的特征更加的抽象,更有利于分类器进行分类。




图 5 第二层卷积后得到的特征提取图

2.2 分类结果与精度评价

本文选取富锦市影像中的一部分区域进行验证,选取的验证区域如图6所示。该研究区属于农

村,地物类型有限,主要以建设用地、耕地和林地为主,由于河流的宽度较窄,极大影响样本的纯净度,因此本文不对水进行分类。本文分类的类别主要有建设用地、水田、旱地和林地 4 类,其图像特征如表 1 所示。

利用支持向量机和卷积神经网络方法进行对验证区域分类,分为建设用地、林地、旱地和水田四类,分类后的结果如图 7 所示,其中图 7(a)为支持向量机的分类结果,图 7(b)为卷积神经网络的分类结果。

本文选取混淆矩阵来进行精度评价,混淆矩阵是一个表示分为某一类别的像元个数与地面检验为该类别数的 $n \times n$ 比较矩阵, n 代表分类的类别个数,评价精度的因子有用户精度、错分误差、生产精度、漏分误差、总体精度和 Kappa 系数等。这几项精度评价因子的计算公式和意义如表 2 所示。




图 6 验证区域

表 1 研究区土地覆盖地物类型及解译标志

地物类型	图像		地物特征
建设用地			建设用地包含道路及草地，有明显的道路穿过，颜色呈灰紫色
林地			没有明显的纹理特征，颜色呈橙色、棕色、棕黑色
旱地			纹理均匀，栅格状，颜色呈绿色
水田			纹理均匀，形状大多呈矩形，颜色呈深紫色




图 7 分类结果图

表 2 精度评价因子参数介绍

评价因子	计算公式	意义
用户精度	$UA = x_{ii}/x_{i+}$	表示第 i 类所具有的类型与地面实际类型相同的概率
错分误差	$FR = (x_{i+} - x_{ii})/x_{i+}$, $FR = 100\% - UA$	表示第 i 类所具有的类型与地面实际类型不相同的概率
生产精度	$PA = x_{jj}/x_{+j}$	表示相对于第 i 类,分类图上同一地点的分类结果与其相一致的的概率
漏分误差	$MR = (x_{+j} - x_{jj})/x_{+j}$, $MR = 100\% - PA$	表示相对于第 i 类,分类图上同一地点的分类结果与其不一致的概率
总体精度	$OA = \sum_{k=1}^n \frac{x_{kk}}{N}$	表示对每一个随机样本,所分类的结果与参考数据所对应区域的实际类型相一致的的概率
Kappa 系数	$K = \frac{N \sum_{i=1}^n x_{ii} - \sum_{i=1}^n (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^n (x_{i+} x_{+i})}$	表示分类与完全随机的分类产生错误减少的比例

注:其中, x_{ii} 指正正确分到第 i 类的像元总数; x_{ij} 是分类数据中第 i 类和参考数据类型第 j 类的分类像元数; $x_{i+} = \sum_{j=1}^n x_{ij}$ 为分类所得到的第 i 类的总和; $x_{+j} = \sum_{i=1}^n x_{ij}$ 为参考数据的第 i 类的总和; N 为总像元数

针对所选取的影像和样本,结果如表 3、表 4 所示。

表 3 支持向量机精度评价

种类	用户精度 (%)	错分误差 (%)	生产精度 (%)	漏分误差 (%)
建设用地	93.28	6.72	85.26	14.74
林地	100	0	66.71	33.29
旱地	95.46	4.54	97.82	2.18
水田	66.42	30.58	100	0
总体精度:89.3753%				
Kappa 系数:0.8572				

表 4 卷积神经网络精度评价

种类	用户精度 (%)	错分误差 (%)	生产精度 (%)	漏分误差 (%)
建设用地	98.43	1.57	94.32	5.68
林地	100	0	95.41	4.59
旱地	95.43	4.57	96.16	3.84
水田	97.35	2.65	93.18	6.82
总体精度:94.5732%				
Kappa 系数:0.9215				

实验结果表明,卷积神经网络方法能够提取地物特征,有效地提高分类精度,优于支持向量机的分类精度,在遥感图像分类中具有可行性。

3 结 论

本研究探讨了目前遥感影像分类的研究现状,指出深度学习是遥感图像分类的主流趋势。设计了一种卷积神经网络模型,并将该模型应用到遥感影像中,以水田样本为例,对该模型提取地物特征进行分析,结果表明不同的卷积核能提取到不同的特征。对 Landsat TM5 富锦市遥感影像进行了分类实验及精度评价,总体精度明显高于支持向量机分类算法,卷积神经网络在遥感影像分类中的可行性,但是由于卷积神经网络的网络性质以及参数的选择,导致线条特征提取不明显,分类边界不够细腻,影响图像分类效果,为遥感图像处理领域等相关工作提供参考价值。

参考文献

[1] 韦玉春,汤国安,杨昕. 遥感图像数字处理教程. 北京:科学出版社,2013. 13-16

[2] Yuen P W, Richardson M. An introduction to hyperspectral imaging and its application for security, surveillance and target acquisition. *Imaging SCI*, 2010, 58(5): 241-253

[3] Egerton R F. Electron Energy-Loss Spectroscopy in the Electron Microscope. New York: Plenum, 1996. 204-212

[4] Lacar F M, Lewis M M, Grierson I T. Use of hyperspectral imagery for mapping grape varieties in the Barossa Valley, South Australia. In: Proceedings of the 2001 IEEE International Geoscience Remote Sensing Symposium (IGARSS), Sydney, Australia, 2001. 6:2875-2877

[5] Malthus T J, Mumby P J. Remote sensing of the coastal zone: an overview and priorities for future research. *International Journal of Remote Sensing*, 2003, 24 (13): 2805-2815

[6] Bioucas-Dias J, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6-36

[7] Mitchell T M. Machine Learning. 北京:机械工业出版社,2003. 25-34

[8] 刘敏,李海涛,顾海燕等. World View-2 高分辨率卫星影像面向对象分类. 见:第十八届中国遥感大会, 2012. 123-129

[9] Krizhevsky A, Sutskever I, Hinton G E. Image net classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012. 1097-1105

[10] Erhan D, Courville A, Bengio Y. Understanding representations learned in deep architecture. http://www.dumitru.ca/files/publicatios/invarianes_techre-port.pdf: Dumitru, 2015

[11] Chen Y S, Jiang H L, Li C Y, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54 (10): 6232-6251

- [12] Chen Y, Lin Z, Zhao X, et al. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2094-2107
- [13] Chen Y, Zhao X, Jia X. Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2381-2392
- [14] Romero A, Gatta C, Camps-Valls G. Unsupervised deep feature extraction for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(3): 1349-1362
- [15] Himes G S, Inigo R M. Automatic target recognition using a neocognitron. *IEEE Transactions on Knowledge and Data Engineering*, 1992, 4(2): 167-172
- [16] Dahl G E, Yu D, Deng L, et al. Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition. *IEEE Transactions on Audio, Speech, and Language Processing*, 2012, 20(1): 30-42
- [17] Vapnik V N. The Nature of Statistical Learning Theory. New York: Springer Verlag, 1995. 19-65
- [18] Vapnik V N. Statistical Learning Theory. New York: Wiley-Interscience, 1998. 65-87
- [19] 何晓群, 刘文卿. 应用回归分析. 北京: 中国人民大学出版社, 2001. 55-67
- [20] 刘勇, 廖士中. 基于支持向量机泛化误差界的多核学习方法. 武汉大学学报(理学版), 2012, 58(2): 149-156
- [21] Vapnik V N 著, 张学工译. 统计学习理论的本质. 北京: 清华大学出版社, 2000. 198-243
- [22] 谭琨, 杜培军. 基于支持向量机的高光谱遥感图像分类. 红外与毫米波学, 2008, 27(2): 123-129
- [23] 刘敏, 李海涛, 顾海燕等. World View-2 高分辨率卫星影像面向对象分类. 见: 第十八届中国遥感大会, 2012. 123-129
- [24] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012. 1097-1105
- [25] Kruger N. Deep hierarchies in primate visual cortex what can we learn for computer vision. *IEEE Transactions on Pattern Analysis and Machine Intell*, 2013, 35(8): 1847-1871
- [26] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks. In: Proceedings of the 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012. 1106-1114
- [27] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313(5786): 504-507
- [28] 吴正文. 卷积神经网络在图像分类中的应用研究: [硕士学位论文]. 成都: 电子科技大学计算机科学与工程学院, 2015. 26-34
- [29] 姜小光, 王长耀, 王成. 成像光谱数据的光谱信息特点及最佳波段选择以北京顺义区为例. 干旱区地理, 2000, 23(3): 215-220
- [30] Benediktsson J A, Ghamisi P. Spectral-Spatial Classification of Hyperspectral. Remote Sensing Images. Boston: Artech House, 2015. 45-56
- [31] Plaza A, Plaza J, Martin G. Incorporation of spatial constraints into spectral mixture analysis of remotely sensed hyperspectral data. In: Proceedings of the IEEE International Workshop Machine Learning Signal Processing, Grenoble, France, 2009. 1-6
- [32] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 2013, 101(3): 652-675
- [33] Tarabalka Y, Fauvel M, Chanussot J, et al. SVM- and MRF-based method for accurate classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 2010, 7(4): 736-740

Remote sensing image classification based on CNN model

Fu Xiuli^{*}, Li Lingping^{* **}, Mao Kebiao^{** ****}, Tan Xuelan^{****}, Li Jianjun^{*****}, Sun Xu^{*****}, Zuo Zhiyuan^{**}
(^{*} Information Engineering Institute, Beijing Institute of Petrochemical Technology, Beijing 102617)
(^{**} National Hulunber Grassland Ecosystem Observation and Research Station, Institute of
Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081)
(^{***} College of Information Science & Technology, Beijing University of Chemical Technology, Beijing 100029)
(^{****} College of Resources & Environment, Hunan Agricultural University, Changsha 410128)
(^{*****} College of Computer Science and Information Technology, Central South University
of Forestry and Technology, Changsha 410004)
(^{*****} College of Humanities and Law, Northeast Agricultural University, Harbin 150030)

Abstract

The remote sensing image classification was studied. In consideration of the problems of feature extraction difficulty and low classification accuracy of the shallow structure classification model of support vector machine, a convolutional neural network model was designed for remote sensing image classification. The model comprises the input layer, convolution layer, full connection layer and output layer, and uses the SoftMax classifier for classification. The LandsatTM5 remote sensing image of Fujin city in June 6, 2010 was used as the data source to perform the classification experiment. The experimental results show that the proposed model employs several convolutional and pooling layers to extract the nonlinear and invariant features from the remote sensing image. These features are useful for image classification and target detection. The classification accuracy of the model was 92.57% when it was used in this image. Compared to the support vector machine classifier, the classification accuracy of this model was improved by 5%. Therefore, this model has a greater advantage in remote sensing image classification.

Key words: convolutional neural network (CNN), model, support vector machine (SVM), feature extraction, remote sensing image classification