

# 基于短距空间光谱并行双向 RNN 的高光谱农业图像分类

王茂发<sup>1</sup>, 冯十辰<sup>1</sup>, 黄鸿亮<sup>2</sup>, 龚启舟<sup>3</sup>, 万 泉<sup>1</sup>, 徐 智<sup>1</sup>

(1. 桂林电子科技大学广西可信软件重点实验室, 广西 桂林 541004)

(2. 澳门大学科技学院数学系, 中国 澳门 999078)

(3. 北京信息科技大学理学院, 北京 100192)

**[摘要]** 提出一种新的短距空间并行双向 RNN 算法(shorten spatial-spectral parallel bidirectional RNN, St-SS-pBRNN)用于高光谱农业图像分类,通过组合多个卷积层实现了频谱和空间特征的同时利用,提升了图像的分类效果. 采用并行门控循环单元(gate recurrent unit, GRU)和双向 RNN 的组合架构,缩短了 RNN 的序列长度,大幅减少了模型的计算量. 在农业高光谱图像分类对比实验中,算法性能稳定,准确率比经典的短距空间并行 GRU 算法(shorten spatial-spectral parallel GRU, St-SS-pGRU)最优效果提升大于 2%,相关模型有望在国内大范围的农业用地分类中得以推广应用.

**[关键词]** 深度学习, 门控循环单元, 长短时记忆网络, 循环神经网络, 高光谱图像分类

**[中图分类号]** TP391.4 **[文献标志码]** A **[文章编号]** 1672-1292(2022)04-0001-08

## Shorten Special-spectral Parallel Bidirectional RNN for Hyperspectral Agricultural Image Classification

Wang Maofa<sup>1</sup>, Feng Shichen<sup>1</sup>, Huang Hongliang<sup>2</sup>, Gong Qizhou<sup>3</sup>, Wan Quan<sup>1</sup>, Xu Zhi<sup>1</sup>

(1. Guangxi Key Laboratory of Trusted Software, Guilin University of Electronic Technology, Guilin 541004, China)

(2. Department of Mathematics, School of Science and Technology, University of Macau, Macau 999078, China)

(3. School of Applied Science, Beijing Information Science and Technology University, Beijing 100192, China)

**Abstract:** A method is proposed for HSI classification using shorten spatial-spectral parallel bidirectional RNN (St-SS-pBRNN). By combining multi-convolutional layers, it not only uses the frequency information of spectrum but also considers the spatial characteristics in the images, thereby obtaining better performance and effects. Meanwhile, a combined architecture of parallel gate recurrent unit (GRU) and bidirectional RNN is adopted, which shortens the sequence length of RNN and greatly reduces the amount of calculation of the model. In the comparative experiments of agricultural hyperspectral image classification, the performance of the algorithm is stable and accurate, and its accuracy is more than 2% higher than the optimal effect of the classical shorten spatial-spectral parallel GRU (St-SS-pGRU). It is expected to be popularized and applied in a wide range of agricultural land classification in China.

**Key words:** deep learning, gate recurrent unit (GRU), long short term memory network (LSTM), recurrent neural networks (RNN), hyperspectral image classification

高光谱图像(hyperspectral image, HSI)相对于多光谱图像,携带了更为丰富的地物信息,其被广泛应用于包括农业、工业、军事在内的各个领域<sup>[1-2]</sup>. 利用 HSI 中丰富的光谱信息,可以准确地区分不同的农业土壤覆盖类别<sup>[3]</sup>.

近年来,深度学习已广泛应用于包括 HSI 分类在内的各个领域<sup>[4-5]</sup>,其中卷积神经网络(convolutional neural networks, CNN)和残差网络(residual network, ResNets)由于能够提取图像的空间上下文信息,已经在 HSI 分类上获得了一些较为成功的结果<sup>[6-7]</sup>. 但是 CNN 和 ResNet 将光谱视为多维特征空间中的无序向

收稿日期:2022-03-16.

基金项目:国家自然科学基金资助项目(42164002,41504037)、广西科技计划项目(桂科 AD20325004、桂科 AD19110022).

通讯作者:王茂发,博士,副教授,研究方向:数据挖掘. E-mail:wangmaofa2008@126.com

量,忽略了光谱波段间的连续性<sup>[8]</sup>. RNN 是一种可解决时序问题的神经网络<sup>[8]</sup>,考虑到高光谱的谱序也是一个时序序列,循环神经网络可充分利用 HSI 的高光谱分辨率特性,继而实现 HSI 分类<sup>[9-10]</sup>. 但是对于长时序分类,RNN 的效果不如预期,长距离依赖性、梯度消失和过度拟合经常发生<sup>[11]</sup>. RNN 的变体长短时记忆网络(long short-term memory, LSTM)<sup>[12]</sup>虽然一定程度上解决了长距离依赖性问题,但高光谱间的记忆功能仍然很难被训练,容易发生过拟合现象.

有研究提出了 3D-CNN<sup>[13-15]</sup>和卷积 LSTM(convolutional LSTM, CLSTM)<sup>[16]</sup>组合框架来进行 HSI 分类<sup>[17]</sup>,其可同时考虑图像空间上下文信息和频谱的序列连续性,具有很高的准确性,但是同时训练这两种模型时间复杂度非常大. 门控循环单元(gate recurrent unit, GRU)是一种 LSTM 的变体<sup>[18-19]</sup>,在文献[8]中 GRU 被用于对 HSI 分类,相对于 LSTM 具有更好的性能. 为了解决 RNN 容易过拟合且难以训练的问题, Xu 等<sup>[20]</sup>提出了频带组 LSTM 算法,其通过减少 LSTM 中的时间步长有效地简化了训练过程. 双向 RNN(bidirectional RNN, BRNN)<sup>[21]</sup>的提出解决了 RNN 在序列中仅有后项信息依赖前项信息的问题,并证明了序列中后项信息可对前项信息产生影响,从而保障了序列的前后项同时依赖能力.

短距空间光谱并行 GRU(shorten spatial spectral parallel GRU, St-SS-pGRU)<sup>[22]</sup>算法有效地结合了 3D-CNN 和 RNN 的优势,其通过并行 GRU 结构简化了训练过程,并在 HSI 分类中取得较好的成绩. 但 St-SS-pGRU 处理序列问题时,后向信息对前向信息的影响被削弱,在 HSI 分类中有时很难达到预期效果. 本研究提出了一种基于并行 GRU 的短距双向 RNN 算法(shorten spatial spectral parallel bidirectional RNN, St-SS-pBRNN),其充分考虑了 HSI 序列化后的前后项信息相互依赖关系. 在农业 HSI 分类对比实验中,该算法性能稳定、效果显著,其准确率比经典的 St-SS-pGRU 算法的最优效果提升了 2%以上.

## 1 算法

### 1.1 递归神经网络

与人工神经网络(artificial neural network, ANN)不同,RNN 是具有递归单元的神经网络,在解决涉及顺序数据分析的问题时,具有更好的表现. 循环单元中各个数据的状态不仅与当前单元有关而且还与前一单元的状态有关,即前一单元的状态可以有效地影响下一单元. 给定一个样本序列  $\mathbf{x} = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(m)]^T$ ,其中  $\mathbf{x}(t)$  是第  $t$  个时间的数据,对于第  $t$  个循环单元,其隐藏状态可以描述为:

$$\begin{cases} \mathbf{h}^{(0)}, & t=0, \\ \mathbf{h}^{(t)} = \mathbf{h}(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}), & t>0. \end{cases} \quad (1)$$

式中,  $\mathbf{h}^{(0)}$  是循环单元的初始状态,  $\mathbf{h}$  是非线性函数. 通常  $\mathbf{h}^{(0)}$  设置为零向量. 在第  $t$  个时间中,循环的单元输出为  $\mathbf{y}(t)$ ,对于非分类任务,RNN 模型输出向量为  $\mathbf{y} = [\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(m)]^T$ ,而对于分类任务,仅需要一个输出,通常采用最后一个输出,

$$\mathbf{y}^{(t)} = \mathbf{y}(\mathbf{h}^{(t)}). \quad (2)$$

在传统的 RNN 模型中,循环隐藏状态的更新规则和等式中的输出分别为式(1)和式(2),在隐含层中通常表现为如下等式:

$$\mathbf{h}(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}) = \phi(\mathbf{W}_h \mathbf{x}^{(t)} + \mathbf{U}_h \mathbf{h}^{(t-1)} + \mathbf{b}_h), \quad (3)$$

$$\mathbf{y}(\mathbf{h}^{(t)}) = \mathbf{W}_y \mathbf{h}^{(t)} + \mathbf{b}_y. \quad (4)$$

在式(3)和式(4)中  $\mathbf{W}_h$ 、 $\mathbf{U}_h$  和  $\mathbf{W}_y$  为权重矩阵,  $\mathbf{b}_h$  和  $\mathbf{b}_y$  为偏置向量;  $\phi$  是激活函数,如 sigmoid 函数或双曲正切函数. 激活函数是在人工神经网络的神经元上运行的函数,负责将神经元的输入映射到输出端,激活函数可以将线性输出结果映射成非线性结果,从而使人工神经网络可以应用到非线性模型中.

### 1.2 双向 RNN

双向 RNN 在  $t$  时刻的输出不仅取决于  $t$  之前的信息,还取决于  $t$  之后时刻的信息. 例如预测一句话中间丢失的一个词语,同时使用上下文来预测通常比只使用上文准确. 双向 RNN 结构为两个互相叠加的 RNN.

$$\mathbf{S}^{(t)} = f(\mathbf{U} \mathbf{x}^{(t)} + \mathbf{W} \mathbf{S}^{(t-1)} + \mathbf{b}), \quad (5)$$

$$\mathbf{S}' = f(\mathbf{U}' \mathbf{x}^{(t)} + \mathbf{W}' \mathbf{S}'^{(t-1)} + \mathbf{b}'), \quad (6)$$

$$\mathbf{y}^{(t)} = g(\mathbf{V} \mathbf{S}^{(t)} + \mathbf{V}' \mathbf{S}'^{(t-1)} + \mathbf{c}). \quad (7)$$

式中,  $\mathbf{S}, \mathbf{y}$  为不同时间段隐藏层的值,而  $f, g$  都为激活函数.

如图 1 所示,每个时刻有一个输入,隐藏层有两个节点(向量),式(5)进行正向计算,式(6)进行反向计算,输出层为式(7). 从等式中可以看出,式(5)、式(6)的权重不共享,即一个单层的向 RNN 一共有 6 个权重矩阵:正向: $U, V, W$ . 反向: $U', V', W'$ . 权重向量: $b, b', c$ .

### 1.3 长期短时记忆

传统的 RNN 存在的一个缺陷是远距离依赖的问题<sup>[11]</sup>. RNN 具有计算连接序列数据相关信息的能力,但是当序列过长,通过循环单元传播时,信息会丢失. 在 LSTM 中可有效解决上述问题. 如图 2 所示,LSTM 包含一个遗忘门  $f$ ,一个输入门  $i$  和一个输出门  $o$ . 门结构实际上是一个逻辑回归模型,部分信息可以被门结构有选择性地过滤. LSTM 可以模拟遗忘和记忆的过程,通过计算遗忘和记忆的概率来实现在长距离传播中需要保留的信息流.




图 1 双向 RNN 示意图

Fig. 1 Graphic of Bidirectional RNN




图 2 LSTM 模型示意图

Fig. 2 Graphic model of LSTM

$$f^{(t)} = \sigma(W_f x^{(t)} + U_f h^{(t-1)} + b_f), \quad (8)$$

$$i^{(t)} = \sigma(W_i x^{(t)} + U_i h^{(t-1)} + b_i), \quad (9)$$

$$o^{(t)} = \sigma(W_o x^{(t)} + U_o h^{(t-1)} + b_o), \quad (10)$$

$$\tilde{c}^{(t)} = \tanh(W_c x^{(t)} + U_c h^{(t-1)} + b_c), \quad (11)$$

$$c^{(t)} = i^{(t)} x \tilde{c}^{(t)} + f^{(t)} x c^{(t-1)}, \quad (12)$$

$$h^{(t)} = o^{(t)} x \tanh(c^{(t)}). \quad (13)$$

式(8)、式(9)、式(10)分别表示遗忘门、输入门和输出门. 在式(11)和式(12)中  $W_f, W_i, W_o, W_c, U_f, U_i, U_o, U_c$  为权重矩阵.  $b_f, b_i, b_o, b_c$  为偏差向量. 式(13)和式(14)分别为 LSTM 的两个输出,通常情况下,式(13)作为下一个单元的输入而式(14)作为整个 LSTM 链路的输出结果.  $\sigma$  表示 sigmoid 函数,  $\tanh$  表示双曲正切函数. 等式(14)和式(15)分别描述了 sigmoid 函数和 tanh 函数.

$$\sigma(x) = \frac{1}{1 + e^{(-x)}}, \quad (14)$$

$$\tanh(x) = \frac{e^x - e^{(-x)}}{e^x + e^{(-x)}}. \quad (15)$$

### 1.4 门控循环单元

LSTM 有许多变体,各种变体在特定问题上都有特定的优势. GRU 作为 LSTM 的一个变体,其使用了比 LSTM 更少的参数,使得训练过程比 LSTM 更简化,在某些特定问题中通常可以达到与 LSTM 相同甚至更好的效果. 有研究表明在 HSI 分类问题中使用 GRU 比使用 LSTM 更合适<sup>[9]</sup>.

LSTM 和 GRU 之间的主要区别是 GRU 中采用了更新门  $z$  和复位门  $r$ ,而不是使用忘记门,输入门和输出门. GRU 的结构如图 3 所示,GRU 的结构可描述为:

$$z^{(t)} = \sigma(W_z x^{(t)} + U_z h^{(t-1)} + b_z), \quad (16)$$

$$r^{(t)} = \sigma(W_r x^{(t)} + U_r h^{(t-1)} + b_r), \quad (17)$$

$$\tilde{h}^{(t)} = \tanh(W_h x^{(t)} + U_h (r^{(t)} * h^{(t-1)}) + b_h). \quad (18)$$

$$h^{(t)} = (1 - z^{(t)}) h^{(t-1)} + z^{(t)} \tilde{h}^{(t)}. \quad (19)$$




图 3 GRU 模型示意图

Fig. 3 Graphic model of GRU

式(16)和式(17)代表更新门和复位门.  $W_z, W_r, W_h, U_z, U_r, U_h$  为权重矩阵.  $b_z, b_r, b_h$  为偏置向量. 式(17)为当前权重和偏置向量与复位门结果通过计算得到的中间结果. 式(18)为当前节点的输出结果,该结果可继续作为下一个节点输入,也可以在链路最后一个节点将其作为链路输出结果.

### 1.5 St-SS-GRU 模型

带有 GRU(shorten spatial spectral GRU, St-SS-GRU)的短距空间光谱 RNN. St-SS-GRU 的前半部分实际上是 3D 卷积层,内核的深度和跨度均为 1. 使用了 3 个不同的卷积内核( $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$ )对不同的频带进行卷积,该部分的输出是一个序列,其长度与原始输入的长度相同. 输出序列是一个带有前后项特征的向量,序列上的每个单元数据都是一个特征向量. 后半部分使用了 GRU 短距 RNN (shorten GRU, St-GRU). St-GRU 的结构如图 4 所示. 进入 GRU 之前的序列数被大幅减小,从而使网络更易于训练. input 是原始图像,依次连接的是 3D-Conv(3D 卷积层)和短距 GRU 层(St-GRU),和全连接层(fully connected, FC). 每一层的输入和输出按照向量维度进行连接.  $N$  是 3D 卷积层中的滤波器数量,  $D$  是输入图像中的波段数量,  $T$  是 GRU 时间步长,  $H$  是 GRU 中隐藏层中的神经元数量.

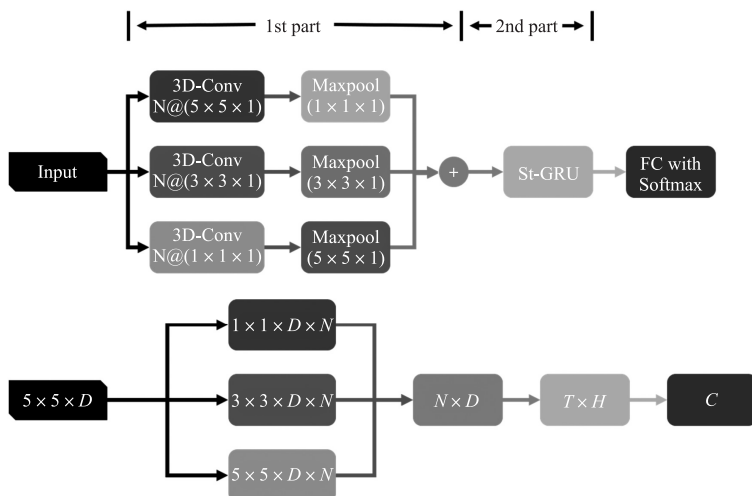


图 4 带有 GRU 的短距空间光谱的网络架构图

Fig. 4 Graphic of shorten spatial-spectral GRU

短距并行 GRU(shorten parallel GRU, St-pGRU)的结构如图 5 所示. 并行 GRU 短距空间光谱 RNN(St-SS-pGRU)与短距空间光谱 GRU(St-SS-GRU)相似,不同之处在于,GRU 被替换为了并行 GRU. 该结构实际上是由多个 GRU 单元组成,其输出变为了每个单元的总和. St-GRU 和 St-pGRU 的结构中,Conv 表示卷积层,图 5 最下端表示了每一层的输入和输出的向量的形状.  $D$  是输入图像中的波段数,  $N$  是输入的这个波段中向量的维度数,  $M$  是一维卷积层中的滤波数,  $T$  是 GRU 的时序长度,  $H$  是 GRU 隐藏层中神经元的数量.

### 1.6 St-SS-pBRNN 模型

在 St-pGRU 模型基础上,将原有的单向 GRU 单元替换为了双向 RNN 结构(bidirectional RNN),从而使 3D 卷积层输出的序列对其前后项的数据依赖. 采用该模型,在后续实验输出结果上取得了更好的效果. St-SS-pBRNN 的前半部分实际上是 3D 卷积层,内核的深度和跨度均为 1,使用了 3 个不同的卷积内核( $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$ )对不同的频带进行卷积,该部分的输出是一个序列,如图 7 中的 3D-Conv 节点所输出的节点,序列上的每个单元数据都是一个特征向量,其长度与原始输入的长度相同. 最大池化层(Maxpool)的作用是将图片降维,去掉不必要的冗余信息,由各个 3D-Conv 输出经过最大池化函数后相加取均值所得到的带有前后项特征的向量将作为图 6 的输入. 短距双向并行 RNN(shorten parallel bidirectional RNN, St-pBRNN)的结构如图 6 所示. 进入 BRNN 之前的序列数被大幅减小,从而使网络更易于训练. 如图 7 所示, input 是原始图像,依次连接的是 3D-Conv(3D 卷积层)和短距双向并行 RNN 层(St-pBRNN)和全连接层(fully connected, FC),其中全连接层是神经网络中每层神经元与下一层神经元全部连接的结构,是人工神经网络最基础的结够. 每一

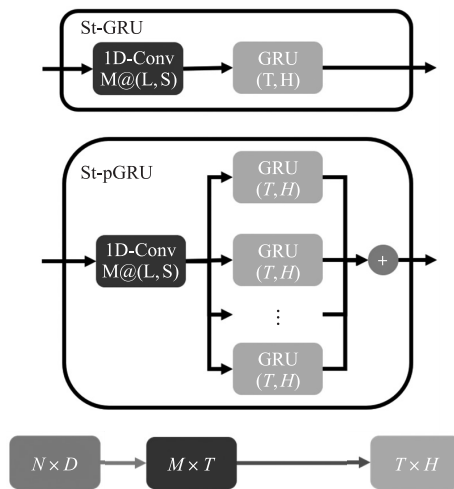


图 5 短距并行 GRU 和并行 GRU 短距空间光谱

Fig. 5 Shorten GRU and shorten parallel GRU

层的输入和输出按照向量维度进行连接.  $N$  是 3D 卷积层中的滤波器数量,  $D$  是输入图像中的波段数量,  $T$  是 BRNN 时间步长,  $H$  是 BRNN 中隐藏层中的神经元数量. 如图 7 所示, 若 Input 输入一张  $145 \times 145 \times 200$  的高光谱图像其频带数为 200, St-pBRNN 节点将会得到一张 200 维经过 3D 卷积并池化的图像, 200 维图像的每一个维度将作为 BRNN 的单个节点, 所有节点按照频带顺序构成一个 BRNN 链路, 该结构包含了每个维度前后向的相关信息.




图 6 短距双向并行 RNN 示意图层

Fig. 6 Graphic of shorten parallel bidirectional RNN

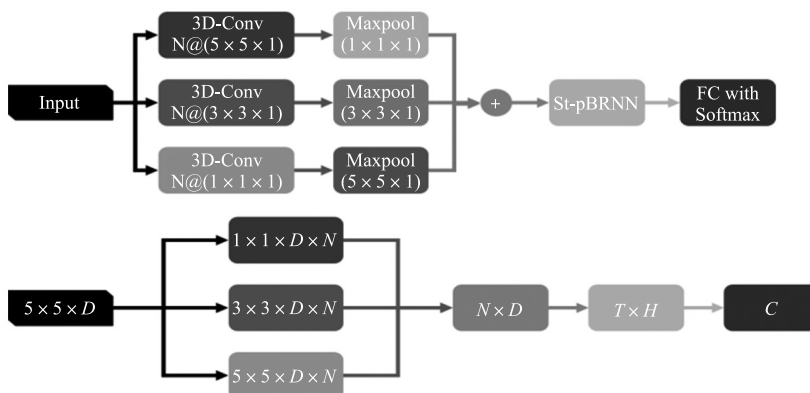


图 7 短距双向并行空间频谱 RNN 结构示意图

Fig. 7 Graphic of shorten spatial-spectral parallel bidirectional RNN

## 2 实验

### 2.1 实验数据

在实验中, 使用了两个 HSI 数据集, 分别来自帕维亚大学和印第安松农场来评估所提出模型的表现.

帕维亚大学的数据集是由反射光学系统成像光谱仪于 2001 年在意大利北部的帕维亚获得的. 校正后的数据的空间分辨率为每个像素 1.3 m, 包含 103 个光谱带, 大小为  $0.43 \sim 0.86 \mu\text{m}$ . 其具有  $610 \times 340$  像素的图像可分为 9 种地面用途类别. 表 1 提供了有关数据集所有类别的信息以及它们相应的训练和测试样本. 在帕维亚大学数据集中,  $D = 103$ , 在实验中, 超参数设置为:  $N = 16$ ,  $T = 5$ ,  $H = 128$ .

印第安松农场数据集由 Tairborne 可见红外成像光谱仪传感器于 1992 年在印第安纳州西北部的印第安松测试地点获得. 经过校正的数据具有 20 m 的中等空间分辨率, 包含 200 个光谱带, 大小为  $0.4 \sim 2.5 \mu\text{m}$ , 图像由  $145 \times 145$  像素组成, 分为 16 个地面用途类别. 表 2 提供了有关数据集所有类别的信息及

表 1 帕维亚大学数据集中使用的训练和测试样本数

Table 1 Samples of training and samples used in the Pavia University dataset

序号	类别名称	训练集	测试集	序号	类别名称	训练集	测试集
1	Asphalt	548	6 083	6	Bare Soil	532	4 497
2	Meadows	540	18 109	7	Bitumen	375	955
3	Gravel	392	1 707	8	Bricks	514	3 168
4	Trees	542	2 522	9	Shadows	231	716
5	Metal sheet	256	1 089		Total	3 921	38 846



其相应的训练和测试样本. 在印第安松数据集中, $D=200$ ,在实验中,超参数设置为: $N=16,T=5,H=128$ .

表 2 印第安松数据集中使用训练和测试样本数

Table 2 Samples of training test sample used in the Indian Pines dataset

序号	类别名称	训练集	测试集	序号	类别名称	训练集	测试集
1	Alfalfa	30	16	9	Oats	15	5
2	Corn-notill	150	1 278	10	Soybean-notill	150	822
3	Corn-min	150	680	11	Soybean-mintill	150	2 305
4	Corn	100	137	12	Soybean-clean	150	443
5	Grass-pasture	150	333	13	Wheat	150	55
6	Grass-trees	150	580	14	Woods	150	1 115
7	Grass-pasture-mowed	20	8	15	Building-grass-trees	50	336
8	Hay-windrowed	150	328	16	Stone-stell-towers	50	43
Total						1 765	8 484

2.2 实验结果

实验是将每种算法独立的运行 10 次,得出的结果为每种算法 10 个独立结果的平均数. 实验是在具有 GPU 为 NVIDIA GTX1050Ti 和 CPU 为 i7-7700K 4.20GHz 上的计算机实现.

表 3 和表 4 分别列出来不同算法在两个数据集上的实验结果,其表现了精度和训练时间. 在两个数据集上 GRU 作为架构核心的算法均优于由 LSTM 作为核心的算法;LSTM 在实验中也很难收敛. 因此有理由表明 GRU 在 HSI 分类任务的表现更好.

图 8 和图 9 分别显示了帕维亚大学数据集和印第安松数据集的分类效果图. 在两种数据集结果中,St-SS-pBRNN 的准确率最高且偏差比其他模型小,这表明 St-SS-pBRNN 更加健壮. 比较不同算法的处理时间发现 St-GRU 的训练明显快于其他结构算法. St-SS-pBRNN 的训练速度与 LSTM 和 GRU 接近,但其准确率最高.

表 3 帕维亚大学高光谱数据集分类效果

Table 3 Classification accuracies and training time for the Pavia Uuniversity dataset

模型	总准确率/%	训练时间/s
LSTM	84.68±1.40	434.22
GRU	86.92±1.29	232.15
St-GRU	92.25±0.78	7.31 *
St-SS-GRU	96.80±0.37	104.56
St-SS-pGRU	98.44±0.26	128.91
St-SS-pBRNN	99.70±0.24 *	279.67

注: \* 为最佳效果情况.

表 4 印第安松高光谱数据集分类效果

Table 4 Classification accuracies and traning time for the Indian Pines dataset

模型	总准确率/%	训练时间/s
LSTM	71.65±1.05	838.85
GRU	77.01±1.82	442.67
St-GRU	80.53±0.90	7.63 *
St-SS-GRU	87.16±1.06	287.54
St-SS-pGRU	90.35±0.86	300.90
St-SS-pBRNN	93.21±0.85 *	489.12

注: \* 为最佳效果情况.

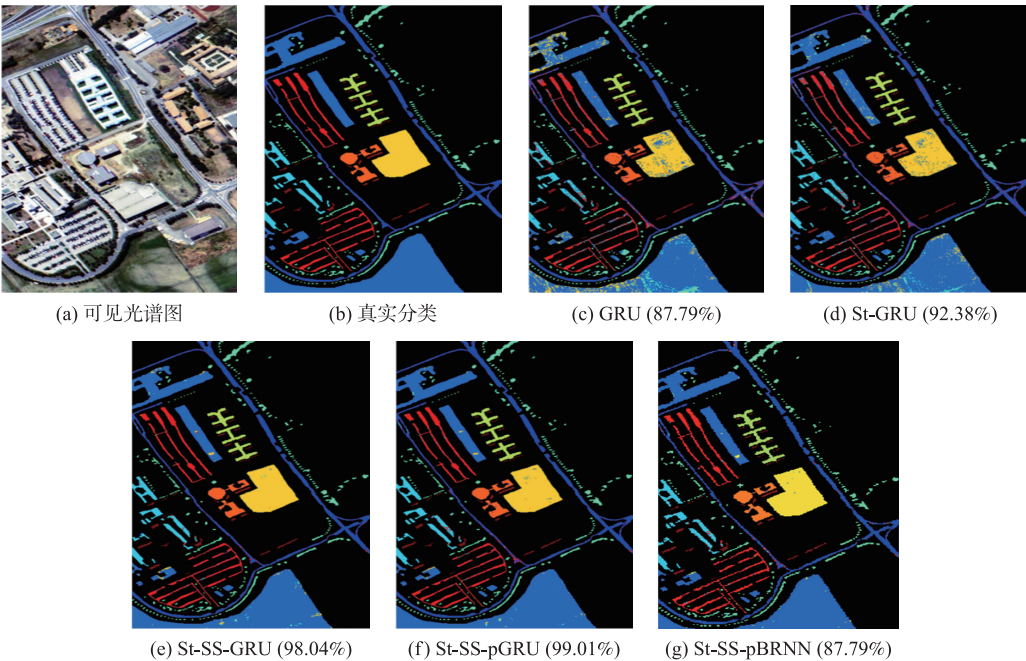


图 8 帕维亚大学数据集实验效果图  
Fig. 8 The classification maps of the Pavia University dataset




图9 印第安松农场数据集实验效果图

Fig. 9 The classification maps of the Indian Pines dataset

### 3 结论

在本研究中,我们提出了一个新的基于高光谱影像分类的 St-SS-pBRNN 模型. 该模型是一种新的并行 GRU 短程空间谱双向 RNN 算法. 其优点是既考虑了光谱特性,又考虑了空间特性. 同时,并行 GRU 和双向 RNN 的组合结构缩短了 RNN 的序列长度,大大降低了模型的计算复杂度. 为了验证模型的合理性,将 St-SS-pBRNN 模型与其他模型进行了比较. 实验结果表明,St-SS-pBRNN 的性能优于 LSTM 和 GRU. 总体精度比 St-SS-pGRU 算法提高 2%,算法有稳定性. St-SS-pBRNN 模型有望集成与农业高光谱数据自动分类系统中,为大规模农业用区分、普查、规划服务.

### [参考文献] (References)

- [1] BIOUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral remote sensing data analysis and future challenges[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6-36.
- [2] 舒速, 杨明, 赵振凯. 基于分水岭的高光谱图像分类方法[J]. 南京师大学报(自然科学版), 2015, 38(1): 91-97.
- [3] 朱志宾, 丁世飞. 基于 TWSVM 的图像分类[J]. 南京师大学报(自然科学版), 2014, 37(3): 8-14.
- [4] 王崇, 吴见. 农作物各类高光谱遥感识别研究[J]. 地理与地理信息科学, 2015, 31(2): 29-33.
- [5] ZHU X X, TUIA D, MOU L, et al. Deep learning in remote sensing: a comprehensive review and list of resources[J]. IEEE Geoscience and Remote Sensing Magazine, 2018, 5(4): 8-36.
- [6] 陈跃. 改进可拓理论的带钢表面缺陷图像分类方法[J]. 南京师范大学学报(工程技术版), 2016, 16(3): 54-62.
- [7] LEE H, KWON H. Going deeper with contextual CNN for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2016, 26(10): 4843-4855.
- [8] ZHONG Z L, LI J, MA L F, et al. Deep residual networks for hyperspectral image classification[C]//2017 IEEE International Geoscience and Remote Sensing Symposium. Fort Worth, TX, USA, 2017.
- [9] MOU L, GHAMISI P, ZHU X X. Deep recurrent neural networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3639-3655.
- [10] SUNDERMEYER M, OPARIN I, GAUVAIN J L, et al. Comparison of feedforward and recurrent neural network language models[C]//2013 IEEE International Conference on Acoustics, Speech, and Signal Processing. Vancouver, BC, Canada, 2013.

- [11] FELIX A G, DOUGLAS E, JÜRGEN S. Applying LSTM to time series predictable through time-window approaches [C]// Proceedings of the 12th Italian Workshop on Neural Nets. Salerno, Italy; Springer, 2002: 193–200.
- [12] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157–166.
- [13] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks [J]. Neural Computation, 2014, 1(2): 270–280.
- [14] LI L, ZHANG H, SHEN Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network [J]. Remote Sensing, 2017, 9(1): 67.
- [15] ZHONG Z L, LI J, LUO Z M. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(2): 847–858.
- [16] 李冠东, 张春菊, 高飞, 等. 双卷积池化结构的 3D-CNN 高光谱遥感影像分类方法 [J]. 中国图象图形学报, 2019, 24(4): 639–654.
- [17] 魏健, 赵红涛, 刘敦楠, 等. 基于注意力机制的 CNN-LSTM 短期电力负荷预测方法 [J]. 华北电力大学学报(自然科学版), 2021, 48(1): 42–47.
- [18] LIU Q S, ZHOU F, HANG R L, et al. Bidirectional-convolutional LSTM based spectral-spatial feature learning for hyperspectral image classification [J]. Remote Sensing, 2017, 9(12): 1330.
- [19] 王文广, 赵文杰. 基于 GRU 神经网络的燃煤电站 NO<sub>x</sub> 排放预测模型 [J]. 华北电力大学学报(自然科学版), 2020, 47(1): 96–103.
- [20] XU Y H, DU B, ZHANG L P, et al. A band grouping based LSTM algorithm for hyperspectral image classification [C]//CCF Chinese Conference on Computer Vision. Singapore; Springer, 2017: 421–432.
- [21] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks. [J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673–2681.
- [22] LUO H W. Shorten spatial-spectral RNN with parallel-GRU for hyperspectral image classification [J]. arXiv Preprint arXiv: 1810.12563, 2018.

[责任编辑: 陈 庆]