

基于 EnMAP 卫星和深度神经网络的 LAI 遥感反演方法

李雪玲¹, 董莹莹^{2,3*}, 朱溢佺¹, 黄文江^{2,3}

(1. 首都师范大学 数学科学学院, 北京 100048;

2. 中国科学院空天信息创新研究院, 数字地球重点实验室, 北京 100094;

3. 中国科学院空天信息创新研究院, 北京 100094)

摘要: 区域叶面积指数 (Leaf Area Index, LAI) 定量反演是开展大尺度农作物长势监测和产量估算的重要基础。针对当前区域 LAI 遥感定量反演存在的反演精度不理想和模型稳定性弱等问题, 提出了一种基于少量训练样本进行 LAI 高精度反演的深度神经网络 (Small Simple Learning LAI-Net, SSSLAI-Net)。该网络由 2 个卷积层、1 个池化层和 3 个全连接层构成, 将光谱反射率数据作为网络输入端、输出端得到 LAI 反演值, 且该网络模型可支持小样本数据量的训练。以德国阿尔卑斯山麓高光谱遥感卫星影像 Environmental Mapping and Analysis Program (EnMAP) 为数据源, 以该区域的谷物、玉米、油菜、其他作物为研究对象, 数值实验结果表明当各作物类别的训练样本量均为 50 时, 基于 SSSLAI-Net 的 LAI 反演精度分别为 0.95、0.99、0.98、0.90; 且在添加噪声的情况下, 各作物类别的 LAI 反演精度分别为 0.95、0.98、0.96、0.89。综上, 提出的基于深度神经网络的区域 LAI 遥感定量反演方法 SSSLAI-Net 是鲁棒可靠的, 且该模型能够支持稳定的小样本建模。

关键词: 叶面积指数; 高光谱遥感; EnMAP; 深度神经网络; SSSLAI-Net

中图分类号: P237 **文献标识码:** A

Leaf area index estimation with EnMAP hyperspectral data based on deep neural network

LI Xue-Ling¹, DONG Ying-Ying^{2,3*}, ZHU Yi-Ning¹, HUANG Wen-Jiang^{2,3}

(1. School of Mathematical Sciences, Capital Normal University, Beijing 100048, China;

2. Key laboratory of Digital Earth Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

3. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China)

Abstract: Regional leaf area index (LAI) mapping is important for crop growth monitoring and yield estimation. Due to the lower accuracy and instability of statistical models for regional LAI estimation, we proposed a new deep neural network model, i. e. Small Simple Learning LAI-Net (SSLLAI-Net), based on small sample training, to achieve stable relationship between hyperspectral reflectance and LAI. The new proposed SSSLAI-Net was constructed with two convolution layers, one pooling layer and three connect layers, for which the inputs and outputs were hyperspectral reflectance and LAI estimation. Moreover, SSSLAI-Net could support small training sets. We applied SSSLAI-Net to an Environmental Mapping and Analysis Program (EnMAP) hyperspectral imagery for regional LAI map-

收稿日期: 2019-03-23, 修回日期: 2019-12-18

Received date: 2019-03-23, Revised date: 2019-12-18

基金项目: 国家自然科学基金“结合形态和营养指标的小麦长势遥感监测方法”(41601466); 国家重点研发计划项目“粮食作物重大病虫害遥感监测预警与防控技术”(2017YFE0122400); 中国科学院青年创新促进会(2017085); 北京市教委科技计划一般项目(KM201710028002).

Foundation items: Supported by National Natural Science Foundation of China (41601466); National Key R&D Program of China (2017YFE0122400); Youth Innovation Promotion Association CAS (2017085); Beijing Municipal Commission of Education grant (KM201710028002)

作者简介 (Biography): 李雪玲 (1995-), 女, 河北保定人, 硕士研究生, 主要从事农业定量遥感植被理化参数定量反演研究. E-mail: xueling_li@cnu.edu.cn.

* **通讯作者 (Corresponding author):** E-mail: donggy@radi.ac.cn

ping, in which cereals, maize, rape seed and other crops are selected as our objects. The achieved R^2 values for estimated LAI of cereals, maize, rape seed and other crops were 0.95, 0.99, 0.98 and 0.90 based on small training sets with 50 samples, while for the inputs with noise, the R^2 values were 0.95, 0.98, 0.96 and 0.89, respectively. In all, our new proposed SSSLAI-Net has high precision of regional LAI mapping, stability and noise resistance with hyperspectral remote sensing observations.

Key words: leaf area index (LAI), hyperspectral remote sensing, EnMAP, deep neural network, SSSLAI-Net

PACS:42.68.Wt

引言

叶面积指数(Leaf Area Index, LAI)是描述陆地生态系统和植被结构特征的一个重要的植物学参数,定量获取区域时空连续的植被 LAI 对农作物长势监测、产量估算具有重要意义^[1-3]。空间遥感技术作为快速大面积获取对地观测的技术,在农情信息提取尤其是 LAI 定量反演方面得到了广泛应用。目前遥感反演 LAI 的模型与方法主要包括三类:统计类、机理类以及数据同化^[4-5]。其中,统计模型^[5-7]主要通过构建光谱反射率与 LAI 之间的映射关系定量反演 LAI,模型简单易用,但稳定性弱;机理类模型^[8]通过描述作物生长的生理过程来计算 LAI,机理性强,但输入参数较多且难以获取;数据同化^[9-10]用观测数据调整机理模型输入参数来提高 LAI 拟合精度,对模型定标要求较高。统计模型相对于机理类模型和数据同化方法而言,使用便捷且对先验知识要求较低,在大尺度开展 LAI 反演的计算效率较高,是众多研究者开展区域参数反演的首选。在统计类模型中应用最为广泛的是植被指数^[11-12],通过不同波段的数学组合构建光谱指数来定量反演 LAI,但大量研究表明,在区域尺度受土壤、大气等因素影响,绝大多数光谱植被指数反演 LAI 的精度不高。

植被的 LAI 与光谱反射率之间通常认为是非线性关系^[13-14],神经网络作为一种非线性问题的优化解决方案在参数反演方面具有很好的应用。杨敏等人选取 BP 神经网络方法基于 Landsat 8 OLI 卫星数据实现了 LAI 的定量反演,精度明显高于传统的植被指数模型,且 LAI 空间分布情况与植被实际分布相符,模型的空间可靠性较高^[15]。姜春雷等人采用季节自回归积分滑动平均(SARIMA)、BP 神经网络二者结合方法对 MODIS LAI 时间序列进行建模和预测,充分发挥 SARIMA 方法在预测 LAI 时间序列中线性部分的优势,以及 BP 神经网络在预测非线性残差部分的优势,实验表明 SARIMA-BP 神经网络组合方法对 MODIS LAI 时间序列具有更好的适

应性,其预测准确性高于 SARIMA 方法或 BP 神经网络方法^[16]。Ilker Ercanli 等人基于人工神经网络进行 LAI 反演建模,并与多元回归模型进行比较,结果表明人工神经网络反演的 LAI 在精度和稳定性方面均有显著提高^[17]。神经网络方法在 LAI 定量反演方面具有很大的应用潜力,本文提出了一种基于少量训练样本进行 LAI 高精度反演的深度神经网络(Small Simple Learning LAI-Net, SSSLAI-Net)。该网络通过引入卷积层提取光谱特征,池化降维,全连接层实现光谱特征到 LAI 的非线性映射的过程,且模型具有较好的抗噪性和稳定性,降低模型对于海量训练样本的依赖,实现小样本量训练下模型的高精度反演,扩展模型的应用范围。

1 材料与方法

1.1 研究区与数据

以欧空局公开发布的 EnMAP 高光谱反射率和 LAI 产品为数据源(<http://www.enmap.org/>),选取了位于德国阿尔卑斯山麓(48.0514 N, 111.0760 E)的一套科学数据集,数据获取时间为 2006 年 7 月 22 日,并以该区域内正处于中后期生长阶段的谷物、玉米、油菜和其他作物为研究对象。其中,EnMAP 反射率数据已经过大气校正^[18],其光谱范围为 420-2460 nm,波段数目为 244,空间分辨率为 30 m;LAI 产品是基于辐射传输模型 Soil-Leaf-Canopy (SLC) 的逆过程实现的^[19]。该区域内的主要作物分布情况及 LAI 产品如图 1 所示。

1.2 基于小样本深度学习网络 SSSLAI-Net 的叶面积指数反演方法

1.2.1 深度学习神经网络的基本结构

深度学习神经网络通常由卷积层、池化层、全连接层构成,其中,1)卷积层主要用于提取高光谱遥感图像中的光谱特征,其参数由多个可学习的卷积核集合构成;利用卷积核运算时,需设定其尺寸、步长、填充方式,如图 2(a)所示,虚线框部分表示填




图1 研究区 EnMAP 遥感数据及产品 (a) 主要作物分布图 (b) LAI 产品

Fig. 1 Study area and EnMAP dataset (a) spatial distribution of main crops (b) LAI product

充,填充的像素值为0。2)池化层主要用于对高光谱特征进行降维,使用时需设定其尺寸、步长和池化类型(本文选取类型为最大池化),如图2(b)所示。3)全连接层主要用于建立光谱特征与 LAI 之间的映射关系,全连接层中的每个神经元均与其上一层的所有神经元进行全连接,如图2(c)所示。此外,激活函数也是网络中必不可少的组成,其能够增加网络的非线性表达。本文选取了 ReLU 函数和 Sigmoid 函数,参见公式(1)和(2),其中, max 函数用来求取 0 与 r 之间的最大值。

$$\text{ReLU}(r) = \max(0, r) \quad (1)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$




图2 深度神经网络基本结构(a)卷积,(b)池化,(c)全连接
Fig.2 The basic structure of deep neural network(a)convolution, (b)pooling, (c)fully connected

1.2.2 小样本深度学习网络 SLLAI-Net 的结构及 LAI 反演流程

1) SLLAI-Net 结构

为实现区域 LAI 的高精度反演并降低网络模型对训练样本数据的依赖性,本文提出了一种小样本深度学习网络 SLLAI-Net 来进行 LAI 定量反演。SLLAI-Net 以 EnMAP 光谱反射率数据为输入,其大小为 1×244 ,以 LAI 为输出,其大小为 1×1 ,网络结构包括 2 个卷积层、1 个池化层和 3 个全连接层,如图 3 所示。

首先,利用两个卷积层提取光谱特征,设置两个卷积层的卷积核尺寸为 1×3 、步长为 3,能够保证从光谱反射率数据中提取特征信息的同时缩小特征信息维度与输出端 LAI 维度的差距。其中,第一个卷积层的通道数为 1,卷积核个数设为 4,则第一层卷积计算后能够得到 4 个 1×81 的光谱特征;第二个卷积层的通道数为 4,卷积核个数设为 16,则第二层卷积计算后能够得到 16 个 1×27 的光谱特征,之后经 ReLU 函数激活以提升网络的非线性表达能力。

其次,将卷积层的输出作为池化层的输入进行数据降维,池化尺寸为 1×3 、步长为 3,则池化后能够得到 16 个 1×9 的光谱特征。

最后,将池化层的输出作为全连接层的输入,全连接层神经元个数采用逐层递减的方式,第一、二、三全连接层的神经元个数分别设置为 32、8、1。每个全连接层的输出均经过激活函数进行激活,其中第一和第二全连接层经 ReLU 函数激活,第三全连接层经 Sigmoid 函数激活。此外,为防止过拟合现象发生,在全连接层的输入与第一全连接层之间引入 Dropout 正则化,即在每次迭代中以 $p=0.5$ 的概率随机让全连接层输入的一半神经元不参与网络训练。




图3 基于 SLLAI-Net 的 LAI 反演流程图

Fig. 3 The flowchart of LAI estimation with our new proposed network

2) SLLAI-Net 训练

首先从样本总体中随机选取一定数量的样本作为训练样本,包括光谱反射率数据和 LAI。然后,设定网络超参数,包括初始学习率 $\eta=0.01$ 、数据批尺寸 $batchsize=100$ 以及迭代次数 $epoch=10000$ 。此外,训练网络参数采用 Adam 算法,Adam 算法中的超参数为 Pytorch 框架默认值;学习率衰减呈阶梯型下降,其中前 1000 次迭代,每迭代 250 次 $\eta=0.6 \times \eta$,之后每迭代 1000 次 $\eta=0.6 \times \eta$ 。最后将训练样本代

入 SSSLAI-Net 网络,基于正向传播和反向传播过程更新网络参数,其中 SSSLAI-Net 网络参数包含卷积层的权重和偏置项、全连接层的权重和偏置项。在 SSSLAI-Net 网络中,训练样本以 *batchsize* 批量传入,通过前向传播计算得到 LAI 数据,并基于损失函数计算每个训练样本反演 LAI 与 EnMAP LAI 之间的差异,称为残差。这里选用均方误差损失函数 $L(W, b)$,详见公式(3)。

$$L(W, b) = \frac{1}{N} \sum_{i=1}^N (y - \hat{y})^2, \quad (3)$$

其中, W 表示卷积层权重、全连接层权重, b 表示卷积层偏置项、全连接层偏置项, y 为 EnMAP LAI 值, \hat{y} 为经过 SSSLAI-Net 得到的 LAI 反演值, N 代表 y 的维度,这里 $N = 1$ 。

网络参数更新依据代价函数最小化,代价函数 $J(W, b)$ 详见公式(4),其中 $m=batchsize$,参数更新方式见公式(5)-(6)。

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m L(W, b), \quad (4)$$

$$W = W - \eta \frac{\partial J(W, b)}{\partial W}, \quad (5)$$

$$b = b - \eta \frac{\partial J(W, b)}{\partial b}, \quad (6)$$

因此,每次训练样本以 *batchsize* 批量传入 SSSLAI-Net,其经过一次前向和一次反向传播过程,网络参数更新一次。所有训练样本均完成此过程,称为一次迭代。依据设定的迭代次数 *epoch*,进行反复训练,不断缩小 LAI 反演值与 EnMAP LAI 的差异,最终达到收敛状态,迭代终止,完成训练。

1.2.3 网络验证

将样本总体中除去训练样本的数据作为验证样本进行网络精度检验。首先将验证样本输入训练好的 SSSLAI-Net 网络模型得到 LAI 数据,然后选用决定系数 R^2 和均方根误差 RMSE 计算 LAI 反演值

与 EnMAP LAI 之间相关关系和差异,并绘制 LAI 数据差异分布图以直观表征。

2 数值实验结果与分析

2.1 基于 EnMAP 卫星高光谱数据的叶面积指数定量反演

以 EnMAP 高光谱数据为研究对象,其对应的 LAI 产品为 EnMAP LAI 值,开展基于 SSSLAI-Net 的植被叶面积指数遥感定量反演数值实验。首先,从谷物、玉米、油菜以及其他作物四类研究对象中随机选取一定数量的训练样本;然后,基于该样本训练 SSSLAI-Net 并更新网络参数,得到优化的网络;最后,将优化的 SSSLAI-Net 模型应用于该类别的验证样本数据,完成对该类作物 LAI 的定量反演,并依据 LAI 数据产品进行精度检验。

本文为测试网络模型对训练数据的依赖性,随机抽取了不同大小的训练样本,其数据量依次为:5000个、1000个、500个、300个、100个、50个,基于训练样本的每类农作物 LAI 反演结果见表1, LAI 拟合散点密度图见图4。

提出的 SSSLAI-Net 适用于 LAI 反演,用于建模的小样本数据量在 50 个时,每个类别 LAI 的反演精度均能够达到 0.90 以上。且训练样本数量越大, R^2 越高, LAI 的反演结果越接近 EnMAP LAI; RMSE 越小, LAI 的反演误差越小。综上,提出的 SSSLAI-Net 支持小样本建模,并能提高 LAI 反演精度。SSLAI-Net 与反演精度之间的关系如图 5 所示。图 6(a)、(b)分别展示了 SSSLAI-Net₅₀₀₀ 与 SSSLAI-Net₅₀ 模型的 LAI 反演结果,图 6(c)为(a)、(b)与 EnMAP LAI 图像的差值对比结果,图 6(d)、(f)与图 6(e)、(g)分别为图 6(a)、(b)图像局部放大图。

从图 6 中得知, SSSLAI-Net₅₀₀₀ 差值范围在 0~2 之间, SSSLAI-Net₅₀ 差值范围在 0~6 之间,但二者验

表 1 基于 SSSLAI-Net 的植被叶面积指数定量反演精度

Table 1 LAI estimation accuracy with our new proposed network

模型	谷物 总量 108187		玉米 总量 25334		油菜 总量 28870		其他作物 总量 27071	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
	SSLLAI-Net ₅₀₀₀	0.99	0.06	0.99	0.03	0.99	0.09	0.99
SSLLAI-Net ₁₀₀₀	0.99	0.11	0.99	0.05	0.99	0.10	0.98	0.10
SSLLAI-Net ₅₀₀	0.99	0.15	0.99	0.06	0.99	0.13	0.97	0.14
SSLLAI-Net ₃₀₀	0.99	0.15	0.99	0.07	0.98	0.16	0.97	0.15
SSLLAI-Net ₁₀₀	0.98	0.23	0.99	0.09	0.98	0.20	0.95	0.18
SSLLAI-Net ₅₀	0.95	0.34	0.99	0.12	0.98	0.21	0.90	0.28




图4 基于SSLLAI-Net的叶面积指数定量反演散点密度图(a)谷物 SSSLAI-Net5000 (b)玉米 SSSLAI-Net5000 (c)油菜 SSSLAI-Net5000 (d)其他作物 SSSLAI-Net5000(e)谷物 SSSLAI-Net300 (f)玉米 SSSLAI-Net300 (g)油菜 SSSLAI-Net300 (h)其他作物 SSSLAI-Net300(i)谷物 SSSLAI-Net50 (j)玉米 SSSLAI-Net50 (k)油菜 SSSLAI-Net50 (l)其他作物 SSSLAI-Net50

Fig.4 Scatterplot of LAI estimation with our new proposed network(a)SSLLAI-Net5000 of cereals (b) SSSLAI-Net5000 of maize (c) SSSLAI-Net5000 of rape (d) SSSLAI-Net5000 of other crops(e)SSLLAI-Net300 of cereals (f) SSSLAI-Net300 of maize (g) SSSLAI-Net300 of rape (h) SSSLAI-Net300 of other crops(i)SSLLAI-Net50 of cereals (j) SSSLAI-Net50 of maize (k) SSSLAI-Net50 of rape (l) SSSLAI-Net50 of other crops

证 LAI 差值主要集中在 0~1 范围内。从曲线走势可知, SSSLAI-Net₅₀₀₀ 比 SSSLAI-Net₅₀ 验证 LAI 差值小。

2.2 结果分析与对比

选取了两种常用的统计类植被叶面积指数遥感定量反演模型进行对比分析,分别是对数模型^[20]和指数模型^[21],具体如下:

(1)对数模型

$$LAI = \frac{1}{K_{ndvi}} \ln \frac{NDVI_{bs} - NDVI_{\infty}}{NDVI - NDVI_{\infty}}, \quad (7)$$

式(7)中, $NDVI_{bs}$ 为裸土的归一化植被指数值(Normalized Difference Vegetation Index, NDVI), $NDVI_{\infty}$ 为

LAI 达到无穷大时的 NDVI 值, K_{ndvi} 为消光系数,与植被群体结构参数(特别是叶倾角分布)和叶片光学属性有关。

(2)指数模型

$$LAI = a \times e^{b \times NDVI}, \quad (8)$$

其中, a 、 b 为模型待定系数, e 为自然常数。

基于对数模型、指数模型和本文提出的 SSSLAI-Net 模型的 LAI 遥感定量反演结果见表 2。分析可知,SSLLAI-Net 对 LAI 的反演精度高于统计模型的反演精度。SSLLAI-Net 在 50 个训练样本建模条件下,实现谷物、玉米、油菜和其他作物的 LAI 定量反演的 R^2 分别为 0.95、0.99、0.98、0.90, RMSE 为

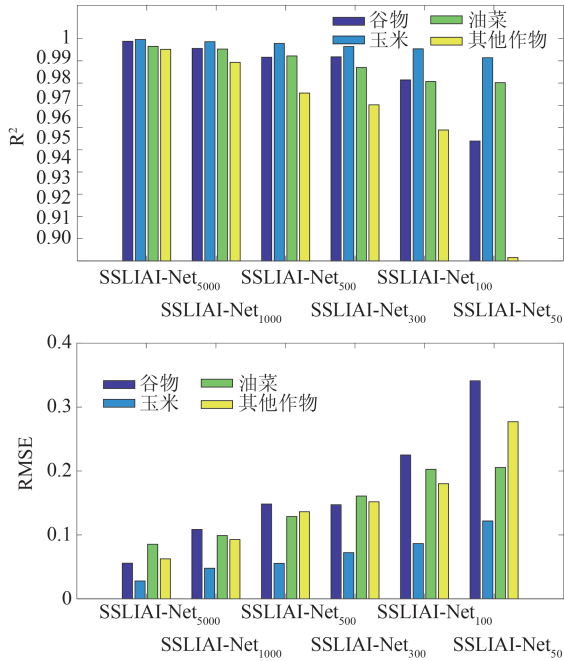


图5 SSSLAI-Net LAI反演精度

Fig.5 The LAI estimation accuracy with our new proposed network

0.34、0.12、0.21、0.28;对数模型优于指数模型反

演结果,对数模型对四类农作物LAI定量反演的R²分别为0.61、0.99、0.53、0.76;RMSE为1.02、0.12、1.00、0.44;指数模型对LAI定量反演的R²分别为0.61、0.89、0.47、0.71;RMSE为1.03、0.43、1.08、0.48。综上,本文提出的SSLLAI-Net模型相比统计模型而言,在LAI定量反演精度方面有很好的效果。

提出的SSLLAI-Net能够实现LAI定量反演的高精度,归因于网络模型结构以及参数更新方式。SSLLAI-Net优势在于采用卷积层、池化层、全连接层相结合的模式,依次实现提取光谱特征、降维、非线性回归。SSLLAI-Net模型参数包括卷积层参数和全连接层参数,卷积层参数用于特征提取,全连接层参数用于光谱特征非线性映射到LAI,由于模型参数多,以及每个网络层的参数都有各自的功能,因此可以充分逼近光谱反射率与LAI的非线性关系,而统计模型难以实现如上效果。并且小样本数据中的光谱反射率通过SSLLAI-Net正向传播输出LAI反演值,通过反向传播过程实现网络参数更新,如此反复训练,使残差不断减小最终达到收敛状态。因此,提出的SSLLAI-Net兼具支持小样本建




图6 基于SSLLAI-Net的研究区LAI反演结果(a) SSSLAI-Net5000 (b) SSSLAI-Net 50 (c) LAI差值对比(d) SSSLAI-Net5000局部 (e) SSSLAI-Net 50局部 (f) SSSLAI-Net5000局部 (g) SSSLAI-Net 50局部

Fig.6 Regional LAI mapping result(a) SSSLAI-Net5000 (b) SSSLAI-Net 50 (c) comparison of the residual error of estimated LAI based on SSSLAI-Net5000 and SSSLAI-Net50(d)subplot of estimated LAI with SSSLAI-Net5000 (e)subplot of estimated LAI with SSSLAI-Net50 (f)subplot of estimated LAI with SSSLAI-Net5000 (g)subplot of estimated LAI with SSSLAI-Net50

模和反演精度高的优点。

2.3 深度神经网络的抗噪性分析

光子采集数据通常是带有泊松噪声,为检验 SSSLAI-Net 在植被叶面积指数定量反演中的抗噪性,以 EnMAP 原始反射率数据作为均值获得了服从泊松分布的反射率数据,以模拟带有噪声数据,并对该数据进行 LAI 定量反演。LAI 定量反演的数值实验结果如表 3 所示。

用 50 个样本进行建模,实现谷物、玉米、油菜和其他作物的 LAI 定量反演的 R^2 分别为 0.95、0.98、0.96、0.89, RMSE 为 0.33、0.18、0.27、0.29。在极小训练样本建模且含噪声的情况下,对 LAI 定量反

演的 R^2 能够达到 0.90 以上或是非常接近 0.90。因此,本文提出的 SSSLAI-Net 具有良好的稳定性和抗噪性,可保证基于少量训练样本的高精度 LAI 反演结果。

图 7(a)、7(b) 分别展示了在含噪声的情况下, SSSLAI-Net₅₀₀₀ 与 SSSLAI-Net₅₀ 模型的 LAI 反演结果,图 7(c) 为 (a)、(b) 与 EnMAP LAI 图像的差值对比结果,图 7(d)、(f) 与图 7(e)、(g) 分别为图 7(a)、(b) 图像局部放大图。不难发现, SSSLAI-Net₅₀₀₀ 比 SSSLAI-Net₅₀ 的预测精度高。

表 2 基于 SSSLAI-Net 模型和统计类模型的 LAI 定量反演精度对比

Table 2 Comparison of estimated LAI with statistical models and new proposed network

模型	谷物		玉米		油菜		其他作物	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
Model1 ₅₀₀₀	0.63	1.00	0.99	0.11	0.54	0.98	0.77	0.42
Model1 ₁₀₀₀	0.62	1.01	0.99	0.11	0.53	0.98	0.76	0.43
Model1 ₅₀₀	0.62	1.01	0.99	0.11	0.53	0.98	0.76	0.43
Model1 ₃₀₀	0.63	1.00	0.99	0.11	0.53	0.99	0.76	0.43
Model1 ₁₀₀	0.62	1.01	0.99	0.12	0.54	1.00	0.76	0.44
Model1 ₅₀	0.61	1.02	0.99	0.12	0.53	1.00	0.76	0.44
Model2 ₅₀₀₀	0.62	1.01	0.89	0.42	0.48	1.04	0.72	0.46
Model2 ₁₀₀₀	0.62	1.01	0.89	0.42	0.48	1.04	0.71	0.47
Model2 ₅₀₀	0.62	1.02	0.89	0.42	0.48	1.04	0.71	0.47
Model2 ₃₀₀	0.62	1.02	0.89	0.42	0.48	1.05	0.71	0.47
Model2 ₁₀₀	0.61	1.05	0.89	0.42	0.48	1.08	0.71	0.48
Model2 ₅₀	0.61	1.03	0.89	0.43	0.47	1.08	0.71	0.48
SSLLAI-Net ₅₀₀₀	0.99	0.06	0.99	0.03	0.99	0.09	0.99	0.06
SSLLAI-Net ₁₀₀₀	0.99	0.11	0.99	0.05	0.99	0.10	0.98	0.10
SSLLAI-Net ₅₀₀	0.99	0.15	0.99	0.06	0.99	0.13	0.97	0.14
SSLLAI-Net ₃₀₀	0.99	0.15	0.99	0.07	0.98	0.16	0.97	0.15
SSLLAI-Net ₁₀₀	0.98	0.23	0.99	0.09	0.98	0.20	0.95	0.18
SSLLAI-Net ₅₀	0.95	0.34	0.99	0.12	0.98	0.21	0.90	0.28

model1 为对数模型, model2 为指数模型

表 3 基于 SSSLAI-Net 的植被叶面积指数定量反演精度(带噪声)

Table 3 LAI estimation accuracy with our new proposed network (with noise)

模型	谷物		玉米		油菜		其他作物	
	总量 108187		总量 25334		总量 28870		总量 27071	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
SSLLAI-Net ₅₀₀₀	0.99	0.11	0.99	0.05	0.99	0.17	0.99	0.07
SSLLAI-Net ₁₀₀₀	0.99	0.12	0.99	0.05	0.99	0.17	0.98	0.09
SSLLAI-Net ₅₀₀	0.99	0.16	0.99	0.09	0.98	0.17	0.97	0.15
SSLLAI-Net ₃₀₀	0.98	0.17	0.99	0.09	0.98	0.18	0.97	0.15
SSLLAI-Net ₁₀₀	0.97	0.25	0.99	0.13	0.97	0.22	0.93	0.23
SSLLAI-Net ₅₀	0.95	0.33	0.98	0.18	0.96	0.27	0.89	0.29




图7 基于SSLLAI-Net LAI的研究区LAI反演结果(带噪声)(a) SSSLAI-Net5000 (b) SSSLAI-Net 50 (c) LAI差值对比(d) SSSLAI-Net5000局部 (e) SSSLAI-Net 50局部 (f) SSSLAI-Net5000局部 (g) SSSLAI-Net 50局部

Fig.7 LAI inversion results based on proposed network containing noise(a) SSSLAI-Net5000 (b) SSSLAI-Net 50 (c)comparison of the residual error of estimated LAI based on SSSLAI-Net5000 and SSSLAI-Net50(d)subplot of estimated LAI with SSSLAI-Net5000 (e)subplot of estimated LAI with SSSLAI-Net50 (f)subplot of estimated LAI with SSSLAI-Net5000 (g)subplot of estimated LAI with SSSLAI-Net50

3 总结

为提高叶面积指数遥感定量反演精度和稳定性,本文提出了一种基于EnMAP高光谱遥感影像数据和深度神经网络模型的LAI定量反演方法。该方法在SSLLAI-Net模型构建过程中,将卷积层、池化层与全连接层相结合,完成提取光谱特征、降维、非线性回归分析过程。由于网络的前向传播和反向传播过程,使得网络可以更好地学习数据特征,完成数据预测。此外,本文还验证了网络模型的抗噪性能,结果表明在含噪声时仍能够对LAI实现高精度反演。综上,深度神经网络模型具有很好的稳定性与抗噪性,支持小样本建模,并保证LAI反演的高精度。

提出的SSLLAI-Net在LAI反演中的效果较好,具有极大的应用潜力在后续的研究中,将继续优化该方法,以期实现基于多光谱遥感数据的参数反演,以及对作物整个生育期的时序植被理化参数的定量反演应用研究。

References

- [1] Mananze S, Pôças I, Cunha M. Retrieval of Maize Leaf Area Index Using Hyperspectral and Multispectral Data [J]. *Remote Sens*, 2018, **10**(12), 1942.
- [2] LU Kun, MENG Qing-Yan, SUN Yun-Xiao, *et al.* Estimating leaf area index of wheat at the booting stage using GF-2 data: A case study of Langfang City, Hebei Province [J]. *Remote Sensing for Land & Resources*, 2018, **30**(1): 196-202.
- [3] Siegmann B, Jarmer T. Comparison of different regression models and validation techniques for the assessment of wheat leaf area index from hyperspectral data [J]. *International Journal of Remote Sensing*, 2015, **36**(18): 4519-4534.
- [4] ZHENG Guang, LIU Rong-Gao, LIU Yang, *et al.* Research progress and prospect of leaf area index retrieval by remote sensing [J]. *JOURNAL OF GEO-INFORMATION SCIENCE*, (郑光,刘荣高,刘洋,等.叶面积指数遥感反演研究进展与展望.地球信息科学学报), 2013, **15**(5).
- [5] HU Gu-Yue, LI Shao-Da, YANG Rong-Hao. Comparison of three regression models for remote sensing estimation of leaf area index [J]. *Science of Surveying and Mapping*, 2018.
- [6] LI Jian-Jian, ZHU Xiao-Hua, MA Liang-Liang, *et al.* Leaf Area Index Retrieval and Scale Effect Analysis of Multiple Crops from UAV-based Hyperspectral Data [J]. *Re-*

- Remote Sensing Technology & Application*, 2017.
- [7] DONG Ying-Ying, WANG Ji-Hua, LI Cun-Jun, *et al.* Estimating leaf area index from remote sensing data: based on data segmentation and principal component analysis [J]. *J. Infrared Millim. Waves*, (董莹莹, 王纪华, 李存军, 等. 基于数据分割与主成分分析的LAI遥感估算. *红外与毫米波学报*), 2011, **30**(02):124-130.
- [8] Berger K, Atzberger C, Danner M, *et al.* Evaluation of the PROSAIL model capabilities for future hyperspectral model environments: a review study. *Remote Sensing*, 2018, **10**(1), 85.
- [9] LI He, CHEN Zhong-Xin, LIU Guo-Huan, *et al.* Improving Winter Wheat Yield Estimation from the CERES-Wheat Model to Assimilate Leaf Area Index with Different Assimilation Methods and Spatio-Temporal Scales [J]. *Remote Sens*, 2017, **9**(3), 190.
- [10] DONG Ying-Ying, WANG Ji-Hua, LI Cun-Jun, *et al.* Comparison and analysis of data assimilation algorithms for predicting the leaf area index of crop canopies [J]. *Selected Topics in Applied Earth Observations and Remote Sensing*, *IEEE Journal of*, 2013, **6**(1):188-201.
- [11] FENG Wei, WU Ya-Peng, HE Li, *et al.* An optimized non-linear vegetation index for estimating leaf area index in winter wheat. *Precision Agric*, 2019.
- [12] SUN Yuan-Heng, REN Hua-Zhong, ZHANG Tian-Yuan, *et al.* Crop Leaf Area Index Retrieval Based on Inverted Difference Vegetation Index and NDVI [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, **15**(11):1662-1666.
- [13] Sivasankar T, Kumar D, Srivastava H S, *et al.* Wheat leaf area index retrieval using RISAT-1 hybrid polarized SAR data [J], *Geocarto International*, 2019.
- [14] Garrigues S, Allard D, Baret F, *et al.* Influence of landscape spatial heterogeneity on the non-linear estimation of leaf area index from moderate spatial resolution remote sensing data [J]. *Remote Sensing of Environment*, 2006, **105**(4):286-298.
- [15] YANG Min, LIN Jie, GU Zhe-yan, *et al.* Leaf area index retrieval based on Landsat 8 OLI multi-spectral image data and BP neural network [J], *Science of Soil and Water Conservation*. (杨敏, 林杰, 顾哲衍, 等. 基于Landsat 8 OLI多光谱影像数据和BP神经网络的叶面积指数反演. *中国水土保持科学*), 2015, **13**(04):86-93.
- [16] JIANG Chun-Lei, ZHANG Shu-Qing, ZHANG Ce, *et al.* Modelling and predicting of MODIS leaf area index time series based on a hybrid SARIMA and BP neural network method [J]. *Spectroscopy & Spectral Analysis*, 2017.
- [17] Ercanli I, Gnl A, Senyurt M, *et al.* Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey [J]. *Forest Ecosystems*, 2018, **5**(04):58-69.
- [18] Migdall S, Bach H, Kaufmann H. Simulation of enmap-like hyperspectral images based on textural information and a radiative transfer approach [C]. In *Hyperspectral 2010 Workshop* (p. 6) (Frascati, Italy, 2010).
- [19] Verhoef W, Heike Bach. Coupled soil - leaf-canopy and atmosphere radiative transfer modeling to simulate hyperspectral multi-angular surface reflectance and TOA radiance data [J]. *Remote Sensing of Environment*, 2007, **109**(2):166-182.
- [20] TAN Chang-Wei, WANG Ji-Hua, HUANG Yi-De, *et al.* Quantitative Improvement of Beer-Lambert Law with Spectral Remote Sensing Technology and Its Application [J], *Scientia Agricultura Sinica*. (谭昌伟, 王纪华, 黄义德, 等. 运用光谱技术改进Beer-Lambert定律的量化及其应用研究. *中国农业科学*), 2005, **38**(3):498-503.
- [21] XIA Tian, WU Wen-Bin, ZHOU Qing-Bo, *et al.* Comparison of two inversion methods for winter wheat leaf area index based on hyperspectral remote sensing [J], *Transactions of the Chinese Society of Agricultural Engineering*. (夏天, 吴文斌, 周清波, 等. 冬小麦叶面积指数高光谱遥感反演方法对比. *农业工程学报*), 2013, **29**(3):139-147.