

基于卷积神经网络和 AMSR2 微波遥感的土壤水分反演研究^①

谭建灿^{②*} 毛克彪^{③*} 左志远^{*} 赵天杰^{**} 谭雪兰^{***} 李建军^{****}

(^{*} 中国农业科学院农业资源与农业区划研究所 北京 100081)

(^{**} 中国科学院遥感与数字地球研究所遥感科学国家重点实验室 北京 100101)

(^{***} 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)

摘 要 土壤水分是水文、气象、农业等研究中的重要参数,尤其在农作物估产模型和农业干旱监测研究中有特别重要的意义。前人在土壤水分反演算法研究上已经做了大量研究工作,但由于影响地表土壤水分的因素较多,各种算法依然存在一些不足。本研究在分析以往反演算法的基础上,总结不同算法的优势和局限性,提出利用具有深度学习特点的卷积神经网络方法(CNN)进行土壤水分反演,从而克服传统土壤水分反演方法的缺陷并提高土壤水分反演的精度。以被动微波 AMSR2 数据为例,在对土壤水分产品算法进行剖析的基础上,构建了基于卷积神经网络反演土壤水分的模型框架,从而提高反演算法的通用性和反演精度。深度学习卷积神经网络的精度主要取决于训练和测试样本数据库,然而被动微波像元分辨率比较低,以及很难获得与卫星同步的地面实测数据。本文选择不同地区地表均一的土壤水分观测站点,以 AMSR2 土壤水分产品作为参照来获取地面同步数据,从而克服地面同步观测数据的难题。将 AMSR2 亮温数据和对应地面同步观测土壤水分数据为样本随机分成训练和测试数据库,通过反复训练,当卷积神经网络选择两个卷积层两池化层的组合,迭代次数 3000 次时,网络反演的总体精度最高。经过测试样本验证表明,CNN 反演土壤水分值与地面同步观测土壤水分的均方根误差 RMSE 为 1.1178%,两者保持了较高相关性($r=0.8685$)。以地面站点实测数据对 CNN 反演结果进行验证,相对误差为 39.25%。相比于 JAXA 产品与实测值的验证结果,CNN 反演结果的平均相对误差小 10.24%,说明 CNN 明显提高被动微波遥感土壤水分反演的精度。

关键词 深度学习,卷积神经网络(CNN),被动微波,AMSR2,土壤水分

0 引 言

土壤水分是控制地表水量和能量平衡的重要因子,是地表生态系统水循环的重要组成部分之一,对区域水资源、农作物估产、农业旱情监测等实际领域具有重要意义^[1,2]。传统测量土壤水分的方法是利

用探针或重量测量法测定不同深度的土壤水分,其优点是在局部精度较高,但地面测量法只适合采集小区域样点的土壤水分信息,且需要大量人力进行取样和实验室测量,很难实现大区域土壤含水量的监测^[3,4]。与传统地面点位测量方法不同,遥感技术是大区域尺度上研究土壤水分时空分布较为常见的手段。应用于土壤水分反演的遥感技术有 3 种:

① 国家自然科学基金(41571427)和中国农业科学院创新群体(Y2017JC33)资助项目。
② 男,1994 年生,硕士生;研究方向:农业遥感研究;E-mail: satellitetjc@163.com
③ 通信作者,E-mail: maokebiao@caas.cn
(收稿日期:2017-12-20)

可见光、红外遥感和微波遥感。微波遥感具有全天时、全天候的监测能力以及对云、雨、大气较强的穿透能力,相比于易受大气影响的可见光和红外遥感更具有优势^[5-7]。为了实现全球和区域的地表土壤水分监测,近 20 年来国内外陆续研制发射了多个星载微波遥感传感器。其中,AMSR-E 传感器由 AU-QA 卫星搭载,其微波土壤水分产品被广泛应用于诸多研究领域。作为后续传感器,日本于 2012 年 5 月发射的地球水环境变动监测卫星 GCOM-W1 搭载了 AMSR2(advance microwave scanning radiometer 2, AMSR2)仪器。为避免地面无线电频率干扰,AMSR2 增设了 7.3GHz 的垂直和水平极化两个通道,从而可能得到更为可靠的微波辐射计数据^[8]。同时,相比于 AMSR-E 传感器,AMSR-2 的天线反射器扩大成 2.0m,其微波亮温采样的空间分辨率精度由 25km 提高到 10km。

微波遥感反演土壤水分的原理是基于土壤介电常数主要受土壤水分变化的影响,而介电常数是影响微波辐射变化的主要因素^[9]。一般的被动微波土壤反演方法是建立辐射传输模型,主要有针对裸土地表辐射的 AIEM 模型^[10]、 Q_p 模型^[11]和针对植被覆盖地表辐射的 τ - ω 模型^[12],这些反演模型只是针对地表类型单一的地表。在土壤水分反演过程中,微波观测辐射信号除了取决于地表土壤水分,同时受地表粗糙度、植被层的衰减与消光特性,以及地表与植被温度等因素影响,因此很难从微波辐射传输的物理机制上解释卫星星上亮温的变化是受一个或多个因素组合的影响所致^[5,13]。被动微波土壤水分反演的另一种方法是机器学习方法,不同的机器学习方法在遥感技术反演土壤水分中得到了广泛的应用,包括随机森林^[14,15]、BP 神经网络^[16]、广义回归神经网络^[17]等。这些传统的神经网络方法均属于浅层的机器学习方法,其缺陷在于难以解决局部最优、过拟合及梯度扩散等问题^[18,19]。近年来,深度学习技术作为通过多层非线性变换对高复杂度数据建模算法的合集,凭借其深层次非线性结构的特点,相比于过去的浅层机器学习方法更有优势,其中最典型的算法之一是卷积神经网络(convolutional neural network, CNN)。在传统的计算机视角、语音

识别、目标识别探测、自然语言处理、棋类博弈和人工智能等应用领域都取得了很大的成功^[20]。

卷积神经网络早在 1998 年由 Lecun^[21]初次实现,并在手写字符识别领域成功应用,然而当时的 CNN 只适合做小图片的识别,对于大规模数据,应用效果不佳。直至 2012 年, Krizhevsky^[22]等对 CNN 进一步向深层学习方面优化,并在大型图像数据库 ImageNet 的图像分类竞赛中以巨大优势夺冠,使得卷积神经网络成为学术界的研究热点,此后 CNN 在多个领域得到应用,助推了深度学习的研究热潮。CNN 是第一个真正成功地训练多层网络结构的深度学习算法,在人工智能图像识别领域尤为广泛应用。在遥感领域,卷积神经网络多用于影像分类和地物识别方面。CNN 提供了一种端到端的学习模型,模型中的参数可以通过梯度下降方法进行训练,经过卷积和池化的多层训练能够自动学习并提取复杂数据中的特征^[23]。卷积神经网络算法的原理非常适合模拟高度复杂的微波辐射传输方程,可用于构建被动微波土壤水分反演模型。因此本文针对被动微波辐射计 AMSR2 数据,结合深度学习卷积神经网络方法,对土壤水分进行反演研究,提高了反演精度,从而弥补了辐射传输模型和传统机器学习方法的缺陷。

1 数据与方法

1.1 数据来源

(1) AMSR2 微波辐射计亮温数据: AMSR-2 是第二代先进微波辐射成像仪,搭载于“第一轮卫星计划-全球水圈变化观测卫星(GCOM-W1)”,由日本宇航局(Japan Aerospace Exploration Agency, JAXA)于 2012 年 5 月 18 日成功发射,同年 7 月 JAXA 开始实时发布全球地表微波亮温观测数据。AMSR2 是一种圆锥式扫描微波辐射成像仪,包括主反射镜、微波辐射接收机,在轨运行期间与地表观测站点的垂直入射角为 55°。AMSR2 的轨道离地面 700km,其扫描宽度为 1450km,共 14 个水平/垂直极化观测通道,分别是 6.9、7.3、10.65、18.7、23.8、36.5 和 89.0GHz,主要用于监测全球水分分布及能量循

环^[24,25]。

(2)AMSR2 土壤水分产品:AMSR2 的土壤水分产品主要有日本宇航局(JAXA)官方的查找表算法 L3 级土壤水分产品。JAXA 提供每日的升、降轨全球土壤水分数据,为等经纬度投影,空间分辨率为 0.1°。对于 AMSR2 L3 级土壤水分产品,JAXA 官方给出的精度在植被含水量小于等于 1.5kg/m² 的区域内均方根误差 RMSE 小于 6.3%。JAXA 土壤水分算法的核心思想在于通过极化差指数 PI(polarization index)和土壤水分指数 ISW(index of soil wetness)与土壤水分和植被含水量的关系建立查找表。该查找表是基于辐射传输模型模拟卫星上亮温而设计的,整个算法过程有如下 3 个重要步骤:前向模型参数优化、建立查找表和基于查找表反演地表参数^[26]。该算法 PI 指数和 ISW 指数均采用了亮温比值的表现形式,理论上可认为在一定程度上消除了植被冠层温度和土壤温度对地表水分反演的影响。因此,JAXA 在建立查找表时,土壤与植被温度被全部假定在 293K,这有可能是导致 JAXA 土壤水分产品值的整体动态范围较少。针对 JAXA 土壤水分产品,研究者在全球和局部地区^[27-30]进行大量的精度验证工作,结果显示受地形、气候、温度、植被等因素影响,土壤水分产品在不同地区的精度差异较大,实际上难以达到 JAXA 官方标称的精度。

(3)地面土壤水分监测站点数据:全国气象站点土壤水分监测站(如图 2)提供了每日每小时不同深度土壤水分监测数据,其中包括土壤体积含水量(%)。AMSR2 卫星每日过境中国的时间为 13:30 和 1:30,

因此地面监测站点土壤水分数据选取当日 13:00 和 1:00 的值。站点数据观测的最浅土壤深度是 10cm,所以选取地下 10cm 探头的数据,以更好接近地面表层的土壤水分。




图 1 全国土壤水分监测站点分布

1.2 卷积神经网络方法

卷积神经网络(CNN)结合了深度学习和人工神经网络算法,使用一种基于随机梯度下降的改进学习率反向传播算法来训练网络中的权重,并实现了深度学习中多层过滤器网络结构的全局训练算法,降低了网络模型的复杂度^[31]。与以往的机器学习模型不同,卷积神经网络具有局部链接和权值共享两大特点,即使用局部连接的方式,有效提取数据信息,并通过共享权值减少参数量。典型的卷积神经网络如图 2 所示,主要由输入层、卷积层、池化层、全连接层、输出层构成,其中卷积层和池化层交替设置若干个,从而构成一个多层的神经网络。




图 2 卷积神经网络结构

训练数据直接决定了卷积神经网络反演的精度,然而被动微波数据的空间分辨较低,通常是几十

千米,难以获得与卫星同步的地面实测数据作为网络输入的样本。因此,本研究分区域选择多个土壤

水分观测站点,且站点附近的地表尽量均一,以 AMSR2 土壤水分产品作为参照来获取地面同步数据,从而克服地面同步观测数据的难题。本文首先选择所在位置附近地势平坦、地物类型均一的土壤水分地面实测站点,然后参照 MODIS 数据选择天气较为晴朗云量较少的日期(2014 年 8 月~2016 年 8 月内),匹配 AMSR2 卫星过境中国的时间,当站点的土壤水分值与经纬度位置邻近的 AMSR2 土壤水分产品像元的值接近时,将该像元的土壤水分产品数据作为 AMSR2 卫星对应的地面同步观测数据,克服了同步实测数据带来的困难。本文采集的 AMSR2 亮温和对应土壤水分地面同步观测数据样本共有 31076 组,其中随机抽取验证样本和不用用于训练的测试样本各 3000 组,剩下作为输入的训练样本共 25076 组。

卷积神经网络的输入层保证样本像元大小统一为 14×1 ,即每个样本的大小为 14×1 ,并对数据进行规则化处理。卷积层用于提取数据样本特征,是一个卷积神经网络中最为核心的部分。卷积层中每一个神经元节点的输入只是上一层输出的一部分,即跟上一层输出进行局部链接^[32]。为了更深入提取数据特征,卷积层通过对应的连接权值与局部输入进行加权求和再加上偏置值,得到该神经元输入值。卷积操作的计算式如下:

$$x_j^l = f(\sum_{i \in M_j} x_i^{l-1} \cdot k_{ij}^l + b_j^l) \quad (1)$$

式中, l 是卷积层所在的层数, k 是卷积核, b 是偏置项, f 是激活函数, M_j 是上一层的一个输入特征数据。卷积核是一个权值矩阵,其尺寸和个数由人工指定,本研究设置的卷积核尺寸为 4×1 ,共 30 个。卷积核移动的步长为 1。卷积层每一个神经元的输出通过激活函数实现去线性化。常用的激活函数包括 sigmoid 函数、tanh 函数和 ReLU 函数等。sigmoid 函数和 tanh 函数都存在饱和问题,容易使梯度消失,而 ReLU 函数为不饱和非线性函数,能够解决传统机器学习神经网络普遍存在的梯度爆炸、梯度消失等问题,同时可以加快网络训练的收敛速度^[33]。因此采用 ReLU 函数作为激活函数,其计算公式如下:

$$f(x) = \max(x, 0) \quad (2)$$

对于 ReLU 而言,如果输入大于 0,则输出与输入相等,否则输出 0。使用 ReLU 函数,输出不会随着输入的逐渐增加而趋于饱和。卷积神经网络在每一层卷积操作之后加上一个池化层,对卷积层的输出进行下采样。池化层可以非常有效地缩小矩阵的尺寸,从而减少最后全连接层中的参数,加快计算速度,也有防止过拟合问题的作用^[34]。池化层的前向传播过程也是通过移动一个核函数来完成,常用的核函数有最大值运算或平均值运算。本文采用最大池化方法,其计算公式为

$$x_j^l = f(\beta_j^l \max(x_j^{l-1}) + b_j^l) \quad (3)$$

式中, l 表示所在层数, β 表示最大池化系数, b 是偏置项, f 是激活函数。池化层同样采用 ReLU 作为激活函数。设定池化核的矩阵尺寸为 2。在卷积神经网络结构中,经过多个卷积层和池化层后,连接着 1 到 2 个全连接层。上述卷积神经网络采用两组卷积层和池化层,最后连接一个全连接层。全连接层的每一个神经节点与上一层的所有神经节点进行全连接。全连接层的作用在于整合卷积层和池化层中具有不同特征的局部信息^[35]。为了保持 CNN 网络性能稳定,全连接层的神经节点激活函数同样采用 ReLU 函数。全连接层以经过卷积和池化后获取的数据高阶不变性的特征为依据,进行信息变换和计算处理,完成了一次学习的正向向前传播处理过程。CNN 输出层的以均方误差(mean squared error, MSE)作为损失函数,其函数式如下:

$$MSE(y, y') = \frac{\sum_{i=1}^n (y_i - y_i')^2}{n} \quad (4)$$

式中, y_i 为一个训练批次(batch)中第 i 个数据的目标答案,而 y_i' 为神经网络给出的反演值。卷积神经网络的优化过程包含两个阶段,即前向传播阶段和后向传播阶段。前向传播阶段是从训练样本输入,经过卷积核池化逐层变换传送到输出层,计算得到预测值,并将预测值和目标值做对比得出两者之间的误差。后向传播阶段是计算损失函数对每一个参数的梯度,再根据梯度和学习率使用梯度下降算法更新每一个参数,从而使 CNN 在训练数据上的损失函数尽可能小。在海量训练数据下,要计算所有训练数据的损失函数需要消耗大量时间。为了加速

训练过程,需使用随机梯度下降算法(stochastic gradient descent, SGD)。传统的随机梯度下降算法保持单一的参数学习率以更新所有权重,其学习率在训练过程中并不会改变。本文采用 Adam (adaptive moment estimation) 算法作为 CNN 后向传播阶段的梯度下降算法,该方法由 OpenAI 的 Kingma 和多伦多大学的 Ba^[36] 于 2014 年提出。Adam 算法是随机梯度下降算法的扩展式,和传统的随机梯度下降算法不同,Adam 通过计算梯度的一阶矩估计和二阶矩估计从而为不同的参数设计独立的自适应性参数学习率,因此具有很高的计算效率和较低的内存需求。为了搭建卷积神经网络,采用了 Python 语言环境下的 Keras 接口和 Tensorflow 深度学习库提供的算法框架。通过多次训练后,当卷积层和隐含层各两个,网络训练迭代 3000 次时,卷积神经网络的表现最好(图 3),总体精度相关系数 R 有 0.8715。

2 结果与分析

2.1 CNN 土壤水分反演测试样本精度评估

CNN 反演土壤水分的测试样本数据结果显示(表 1),相关系数 $R = 0.8685$, 决定系数 $R^2 = 0.7544$,均方根误差 RMSE = 1.1178%, 平均绝对误




图 3 不同迭代次数下网络训练的总精度

差 MAE = 0.8375%, 说明 CNN 土壤水分反演模型测试精度较高。从散点图(图 4)可知,在 4% ~ 8% 的土壤水分范围内,CNN 反演的误差较少,而在 0 ~ 4% 和 8% ~ 20% 的范围内误差相对较大。尽管这样,CNN 反演数据和测试样本的地面同步土壤水分观测数据的拟合线总体上接近于 1:1,表明 CNN 反演的土壤水分能够保持与实际值的整体空间变化,说明 CNN 完全可以应用于土壤水分反演。

地面验证是土壤水分反演模型投入实际应用的关键。目前对土壤水分反演模型的实际精度验证是反演方法研究中的一个难点,其主要原因在于地面点实测数据与大尺度的遥感反演结果在表达的空间尺度上无法准确对接。地面验证对方法的实际应用和推广至关重要,因此需利用实测站点的土壤水分

表 1 CNN 反演测试样本精度分析

测试样本量	相关系数 R	决定系数 R^2	均方根误差(%)	绝对误差(%)
3000	0.8685	0.7544	1.1178	0.8375




图 4 CNN 反演与测试样本实际土壤体积含水率散点图

数据与 CNN 反演结果和 JAXA 土壤水分产品值进行对比验证分析。考虑到地面实测站点数据有较多空值和明显偏差的值,本文选取 2015 年 6 月到 2016 年 8 月所在位置地势平坦、地物类型均一、无明显偏差和空值的土壤水分实测站点 18 个,共提取数据 492 个。向训练完毕的 CNN 输入时间相对应的 AMSR2 亮温影像反演土壤水分,并按站点的经纬度位置提取反演结果像元的土壤体积含水率值,将 CNN 反演的数据与地面实测数据进行对比验证,同时也将时间相对应的 JAXA 土壤水分产品与地面实测数据进行对比。

结果显示,CNN 模型反演值与实测数据的平均相对误差为39.25%,而 JAXA 产品值与实测数据的平均相对误差为49.67%,说明采用实测数据验证时,CNN 反演的平均相对误差比 JAXA 产品的小10.24%,表明 CNN 反演的精度更高。从散点图(图5)可知,CNN 反演土壤体积含水率的范围集中在5%~15%,JAXA 产品也有同样情况,而地面实测的土壤体积含水率的范围集中在3%~25%,而且点集中分布在1:1线的左上方,说明与站点实测数据相比,CNN 反演和 JAXA 产品都比地面实测低估土壤含水率。尽管采集样本时尽量保证数据的代




图5 CNN 反演值、JAXA 产品值与实测土壤体积含水率散点图

表性,但 CNN 反演结果和站点数据相比偏低,主要原因在于被动微波的分辨率较低,相对于大尺度的真实地表,地面更加复杂,因此低估现象反映了地表土壤水分在大尺度反演下的误差。其次,本研究中地面站点实测数据的测量深度在10cm以上,因此可能与小于5cm土壤深度的微波地表反演的值存在明显差异。需要说明的是,本研究在选取CNN训练样本数据时,尽量克服被动微波星上亮温和地面观测数据的同步性问题,所以相比于JAXA产品数据,CNN反演的土壤水分值的平均相对误差更小,说明CNN反演土壤水分的精度与JAXA产品相比有提高。

2.2 CNN 土壤水分反演结果分析

为了进一步分析反演结果,向CNN土壤水分反演模型输入2016年9月13日AMSR2亮温升轨数据,反演中国主要陆地地区当天升轨的土壤体积含水率,并生成空间分布图(图6)。从图6可知,中国土壤水分的分布趋势比较合理,反演结果和中国干湿分布状况基本一致。在沿海、长江流域、黄河流域以及一些大湖泊水体周围的土壤水分较高,这和实际情况相符合。对比JAXA土壤水分产品(图7)可知,CNN反演的土壤水分在空间分布上和JAXA的AMSR2土壤水分产品总体上保持一致,尤其是华北、华南和西南地区。和JAXA产品一样,CNN反演的土壤水分在东北大小兴安岭和青藏高原地区相对偏高,但土壤水分超过30%的分布范围较JAXA产品的要小,只有小部分地区超过30%,说明CNN反演的对局部地区土壤水分反演偏高的程度比JAXA产品低。

进一步探讨CNN反演的土壤水分和JAXA的AMSR2产品土壤水分之间的误差来源及空间分布(图8),从图8可知,CNN反演土壤水分和JAXA产品之间的绝对误差在中国大部分地区处于2.5%以下,较大的误差出现在青藏高原和东北大小兴安岭地区。需要说明的是,被动微波遥感观测到的亮温除了受地表土壤含水量影响外,地表高植被覆盖度、地表粗糙度、冰雪冻土、湿地水域同样影响微波亮温的观测精度。因此JAXA产品在北大兴安岭和青藏高原地区的土壤水分与实际情况相比有较大偏差,而CNN土壤反演算法较好地弥补了这一缺陷。对于被动微波的大尺度像元来说,几乎每个像元都是混合像元。为了充分利用卷积神经网络深度提取数据特征的优势,需根据每一地区的实际情况分区域选取高精度地面同步观测样本数据库,与被动微波数据共同构成训练样本,从而进一步提高土壤水分反演的精度。

3 结 论

本文将深度学习卷积神经网络方法应用于被动微波土壤水分反演问题。深度学习卷积神经网络的




图 6 CNN 反演 2016 年 9 月 13 日升轨的中国土壤水分空间分布图




图 7 JAXA 产品 2016 年 9 月 13 日升轨的中国土壤水分空间分布图




图 8 CNN 反演和 JAXA 产品土壤体积含水率绝对差值空间分布图

反演精度主要取决于训练和测试样本数据库,然而被动微波数据的空间分辨率比较低,以及很难获得与卫星同步的地面实测数据。因此我们选择不同地区的土壤水分观测站点,这些站点附近地表尽量均一,以 AMSR2 土壤水分产品作为参照来获取地面同步数据,从而克服地面同步观测数据的难题。将 AMSR2 亮温数据和地面同步观测数据随机分成训练和测试数据库,构建卷积神经网络模拟被动微波的辐射传输过程,对地表土壤水分进行反演,结果如下:

(1)训练得到的卷积神经网络,经随机抽取的测试样本验证表明,反演出了具有较好精度的 10km 的地表土壤水分 ($R = 0.8685$ 和 $RMSE = 1.1178\%$),说明 CNN 适用于微波遥感地表土壤水分反演。实测站点数据对 CNN 反演结果进行验证结果表明,CNN 反演与实测值的平均相对误差为 39.25%,而 JAXA 产品值与实测数据的平均相对误差为 49.67%,相对于实测站点数据二者都有低估,但相比于 JAXA 产品与实测值验证的结果,CNN 反演结果的误差更小(小 10.24%),表明 CNN 反演土壤水分的精度更高。地面实测数据是点数据,而 AMSR2 被动微波遥感的分辨率达 10km,获取的是整个面的信息,因此点-面两者直接对比会产生一定的误差。其次,本研究采用地点实测数据的最小测量深度为 10cm,与小于 5cm 土壤深度的地表反演值进行对比,存在明显差异。

(2)CNN 输出 2016 年 9 月 13 日的中国土壤水分反演结果表明符合实际情况,与同一天的 JAXA 土壤水分产品较为一致。与 JAXA 产品相比,CNN 反演土壤水分在东北大小兴安岭和青藏高原地区的偏高现象相对不明显。随着将来地面实测网络的增加,卷积神经网络的优势在通过补充足够的地面同步高精度训练数据,以适应复杂程度更高的地表类型,进一步提高模型的反演精度,从而克服以往传统土壤水分反演模型的缺陷。

致谢:感谢中国气象局慷慨提供的全国土壤水分监测站点数据,感谢日本宇宙航空开发机构提供的 AMSR2 数据。

参考文献

- [1] Houser AC. Soil moisture: A central and unifying theme in physical geography[J]. *Progress in Physical Geography*, 2011, 35(1): 65-86
- [2] 程宇, 陈良富, 柳钦火, 等. 基于 MODIS 数据对不同植被覆盖下土壤水分监测的可行性研究[J]. *遥感学报*, 2006, 10(5): 783-788
- [3] Seneviratne I Sonia, Corti T, Davin L E, et al. Investigating soil moisture-climate interactions in a changing climate: a review[J]. *Earth-Science Reviews*, 2010, 99(3-4): 125-161
- [4] Gao J Q, Ouyang H, Lei G C, et al. Effects of temperature, soil moisture, soil type and their interactions on soil carbon mineralization in Zoigê alpine wetland, Qinghai-Tibet Plateau[J]. *Chinese Geographical Science*, 2011, 21(1): 27-35
- [5] 施建成, 杜阳, 杜今阳, 等. 微波遥感地表参数反演进展[J]. *中国科学:地球科学*, 2012(6): 814-842
- [6] 陈修治, 苏泳娴, 李勇, 等. 基于被动微波遥感的中国干旱动态监测[J]. *农业工程学报*, 2013, 29(16): 151-158
- [7] 郑兴明, 赵凯, 李晓峰, 等. 利用微波遥感土壤水分产品监测东北地区春涝范围和程度[J]. *地理科学*, 2015, 35(3): 334-339
- [8] 张桂欣, 郝振纯, 祝善友, 等. AMSR2 缺失数据重建及其土壤湿度反演精度评价[J]. *农业工程学报*, 2016, 32(20): 137-143
- [9] 毛克彪, 胡德勇, 黄健熙, 等. 针对被动微波 AMSR-E 数据的土壤水分反演算法[J]. *高技术通讯*, 2010, 20(6): 651-659
- [10] Chen K S, Wu T D, Leung T et al. Emission of rough surfaces calculated by the integral equation method with comparison to three dimensional moment method simulations[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(1): 90-101
- [11] 施建成, 蒋玲梅, 张立新. 多频率多极化地表辐射参数化模型[J]. *遥感学报*, 2006, 10(4): 502-514
- [12] Zeng J Y, Li Z, Chen Q, et al. Method for soil moisture and surface temperature estimation in the Tibetan Plateau using spaceborne radiometer observations[J]. *IEEE Geoscience & Remote Sensing Letters*, 2015, 12(1): 97-101
- [13] Mao K B, Tang H J, Ma Y, et al. The monitoring analysis for the drought in China by using an improved MPI

- method[J]. *Journal of Integrative Agriculture*, 2012, 11 (6): 1048-1058
- [14] 沈润平, 郭佳, 张婧娴, 等. 基于随机森林的遥感干旱监测模型的构建[J]. *地球信息科学学报*, 2017, 19 (1): 125-133
- [15] Whitcomb J, Clewley D, Akbar R, et al. Method for up-scaling in-situ soil moisture measurements for calibration and validation of smap soil moisture products[C]. In: *Proceedings of the 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, China, 2016. 1641-1644
- [16] Zai S M, Guo D D, Han Q B, et al. Soil moisture prediction based on artificial neural network model[J]. *Chinese Agricultural Science Bulletin*, 2011, 27 (8): 280-283
- [17] 贾艳昌, 谢谟文, 姜红涛. 全球 36km 格网土壤水分逐日估算[J]. *地球信息科学学报*, 2017, 19 (6): 854-860
- [18] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40 (6): 1229-1251
- [19] Hinton E G, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313 (5786): 504
- [20] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. *计算机研究与发展*, 2013, 50 (9): 1799-1804
- [21] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86 (11): 2278-2324
- [22] Krizhevsky A, Sutskever I, Hinton E G. ImageNet classification with deep convolutional neural networks[C]. In: *Proceedings of the International Conference on Neural Information Processing Systems*, Lake Tahoe, USA, 2012. 1097-1105
- [23] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. *计算机应用*, 2016, 36 (9): 2508-2515
- [24] Zabolotskikh E, Mitnik L, Reul N, et al. New possibilities for geophysical parameter retrievals opened by GCOM-W1 AMSR2[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2015, 8 (9): 4248-4261
- [25] Imaoka K, Kachi M, Fujii H, et al. Global Change Observation Mission (GCOM) for monitoring carbon, water cycles, and climate change[J]. *Proceedings of the IEEE*, 2010, 98 (5): 717-734
- [26] 陆峥, 柴琳娜, 张涛, 等. AMSR2 土壤水分产品在黑河流域中上游的验证[J]. *遥感技术与应用*, 2017, 32 (2): 324-337
- [27] Kim S, Liu Y Y, Johnson F M, et al. A global comparison of alternate AMSR2 soil moisture products: Why do they differ? [J]. *Remote Sensing of Environment*, 2015, 161: 43-62
- [28] Parinussa R M, Holmes T R H, Wanders N, et al. A preliminary study toward consistent soil moisture from AMSR2 [J]. *Journal of Hydrometeorology*, 2013, 16 (2): 932-947
- [29] Wu Q, Liu H, Wang L, et al. Evaluation of AMSR2 soil moisture products over the contiguous United States using in situ, data from the International Soil Moisture Network [J]. *International Journal of Applied Earth Observation & Geoinformation*, 2016, 45 (Part B): 187-199
- [30] Cho E, Moon H, Choi M. First assessment of the Advanced Microwave Scanning Radiometer 2 (AMSR2) soil moisture contents in Northeast Asia [J]. *Journal of the Meteorological Society of Japan*, 2015, 93 (1): 117-129
- [31] Deng L, Yu D. Deep learning: methods and applications [J]. *Foundations & Trends in Signal Processing*, 2014, 7 (3): 197-387
- [32] Chen Y S, Lin Z H, Zhao X, et al. Deep learning-based classification of hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2017, 7 (6): 2094-2107
- [33] Nair V, Hinton E G. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th International Conference on International Conference on Machine Learning*, Haifa, Israel, 2010. 807-814
- [34] Boureau Y L, Ponce J, Lecun Y. A theoretical analysis of feature pooling in visual recognition[C]. In: *Proceedings of the 27th International Conference on Machine Learning*, Haifa, Israel, 2010. 111-118
- [35] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. *自动化学报*, 2016, 42 (9): 1300-1312
- [36] Kingma D, Ba J. Adam: A method for stochastic optimization[EB/OL]. <https://arxiv.org/abs/1412.6980v8>; arXiv, 2014

Soil moisture retrieval based on convolutional neural network and AMSR2 microwave remote sensing

Tan Jiancan^{*}, Mao Kebiao^{*}, Zuo Zhiyuan^{*}, Zhao Tianjie^{**}, Tan Xuelan^{***}, Li Jianjun^{****}

(^{*} Institute of Agricultural Resources and Regional Planning, Chinese
Academy of Agricultural Science, Beijing 100081)

(^{**} State Key Laboratory of Remote Sensing Science, Institute of Remote Sensing
and Digital Earth Research, Chinese Academy of Sciences, Beijing 100101)

(^{***} College of Resources and Environment, Hunan Agricultural University, Changsha 410128)

(^{****} College of Computer Science and Information Technology, Central South University
of Forestry and Technology, Changsha 410004)

Abstract

Soil moisture is an important parameter in the research of hydrology, meteorology and agriculture, especially in crop yield estimation model and agricultural drought monitoring research. A great deal of research work has been done on the research of soil moisture retrieval algorithm. However, due to many factors affecting the soil moisture on the surface, part of algorithms still have some shortcomings. Based on the analysis of previous inversion algorithms, this paper summarizes the advantages and limitations of different methods, and proposes to use the convolutional neural network (CNN) to perform soil moisture retrieval to overcome the limitation of traditional soil moisture retrieval methods and improve the accuracy. Taking the passive microwave AMSR2 data as an example, the model framework of soil moisture retrieval based on CNN and the analysis of AMSR2 soil moisture product algorithm is constructed to improve the versatility and accuracy of soil moisture retrieval method. The accuracy of deep learning CNN depends primarily on the training and testing sample databases. However, passive microwave pixels have low resolution and it is difficult to obtain ground-based measured data synchronized with the satellite. We selected a number of surface soil moisture observation stations in different regions and AMSR2 soil moisture products as a reference to obtain the ground synchronization data, thus overcoming the problem of ground synchronous observation data. The AMSR2 brightness temperature data and corresponding soil moisture data at ground-based observations are randomly divided into training and testing databases. When the CNN chooses a combination of two layers of two convolution layers with 3000 iterations in iterative training, the overall accuracy of network inversion is the highest. The test sample show that the root mean square error (RMSE) of CNN retrieval soil moisture and ground observation data is 1.1178%, which show a high correlation ($R=0.8685$). The CNN retrieving results are verified by the in-suit data from the ground stations, which show that the average relative error is 39.25%. The average relative error of CNN is 10.24% lower than JAXA and ground-based value, which shows that the accuracy of passive microwave soil moisture retrieval based on CNN is obviously improved.

Key words: deep learning, convolution neural network (CNN), passive microwave, AMSR2, soil moisture