

引用格式: Xue Huazhu, Wang Changjing, Zhou Hongmin, *et al.* BP Neural Network based on Simulated Annealing Algorithm for High Resolution LAI Retrieval[J]. Remote Sensing Technology and Application, 2020, 35(5): 1057-1069. [薛华柱, 王昶景, 周红敏, 等. 基于模拟退火算法的BP神经网络模型估算高分辨率叶面积指数[J]. 遥感技术与应用, 2020, 35(5): 1057-1069.]
doi: 10.11873/j.issn.1004-0323.2020.5.1057

基于模拟退火算法的BP神经网络模型估算 高分辨率叶面积指数

薛华柱¹, 王昶景^{1,2}, 周红敏², 王锦地², 万华伟³

(1. 河南理工大学测绘与国土信息工程学院, 河南 焦作 454000;

2. 北京师范大学地理科学学部, 遥感科学国家重点实验室, 北京市陆表遥感数据产品工程技术研究中心, 北京 100875;

3. 环境保护部卫星环境应用中心, 北京 100094)

摘要: 卫星遥感技术的快速发展使得获取全球大范围叶面积指数成为可能, 但基于现有的算法和数据估算高分辨率LAI的精度还需要提高。针对农作物、草地和林地等3种典型地表类型, 选取地面观测数据较多的4个研究区, 包括3个各地类用于建模验证的研究区与一个用于适用性验证的独立研究区, 针对4个研究区, 分别获取地面测量数据以及对应的30 m空间分辨率地表反射率数据。在3个主要研究区建立并比较了NDVI植被指数经验模型、BP神经网络模型和基于模拟退火算法的BP神经网络模型, 利用地面实测数据对模型进行验证。结果表明: 在研究所选的3个主要研究区, 基于模拟退火算法的BP神经网络模型的估算精度比BP神经网络模型和NDVI经验模型的估算精度高, 农田、草地和林地站点估算结果的决定系数分别为0.899、0.858和0.863, BP神经网络模型的估算结果决定系数分别为: 0.763、0.710和0.742, NDVI经验模型的精度最差, 其估算结果的决定系数分别为0.622、0.536和0.637。为了验证SA-BP神经网络的适用性, 选取独立研究区进行验证, 结果显示验证精度较高, R^2 为0.842, RMSE为0.689 5, 说明该模型外推能力较好。研究证明了基于模拟退火算法的BP神经网络模型提高了模型泛化能力, 有效防止了BP神经网络模型滑入局部最小值, 是提高高空间分辨率LAI估算精度的有效手段。

关键词: 叶面积指数; 反演; 模拟退火算法; 神经网络

中图分类号: TP79 **文献标志码:** A **文章编号:** 1004-0323(2020)05-1057-13

1 引言

叶面积指数(Leaf Area Index, LAI)是指单位水平地表面上所有绿色叶子表面积的一半, 是重要的植被结构参数和生物物理变化的关键参数^[1], 能够提供植被生长的动态信息, 是作物生长模型和决

策支持系统的一项重要输入参数^[2,3]。精确估算LAI对农业、生态、环境和气候变化研究具有十分重要的意义^[4-5]。

利用遥感技术进行叶面积指数的估算具有覆盖范围广、人力物力花费少、时间和空间分辨率高

收稿日期: 2019-03-21; 修订日期: 2020-07-12

基金项目: 国家重点研发计划课题“全球多时空尺度遥感动态监测与模拟预测”(2016YFB0501502), 国家自然科学基金青年基金项目(41801242), 国家重点基础研究发展计划项目“遥感信息动态特征分析与时间尺度扩展”(2013CB733403), 国家自然科学基金项目“小麦长势无人机遥感监测关键指标参数反演机理及长势诊断模型研究”(41871333)。

作者简介: 薛华柱(1977—), 男, 安徽肥东人, 博士, 副教授, 主要从事地表参数定量反演研究。E-mail: xhz@hpu.edu.cn

通讯作者: 周红敏(1980—), 女, 浙江衢州人, 博士, 高级实验师, 主要从事地表参数定量反演研究。E-mail: zhouhm@bnu.edu.cn

等一系列的优点,是获取区域或全球尺度植被 LAI 的有效手段^[3,6-7]。利用遥感数据反演 LAI 的方法主要包括统计模型法和物理模型反演法^[8-9]。统计模型法中应用最广泛的是植被指数法,是指将由遥感影像得出的各种植被指数与实测叶面积指数建立回归模型后进行反演的 LAI 计算方法,这种方法计算简便快捷,应用方式灵活,是最为常用的遥感估算叶面积指数的方法^[10-12]。但由于植被的生理生化参数与光谱反射率之间的关系较为复杂,受叶冠结构、植被密度、土壤背景、大气状况和观测角度等因素影响显著,对于不同的区域或植被类型,植被指数和 LAI 的函数关系会发生变化,因而这种方法的普适性较差。此外植被指数虽然对大气散射、土壤反射的干扰有一定的抵抗作用,但对大气散射和背景反射等因素的抗干扰能力较差^[13]。物理模型法以植被冠层反射率和物理参数为基础,将 LAI 和叶片的光学特性等一系列的基本参数与冠层反射率建立联系,从而实现 LAI 的反演。物理模型法通常可以分为 4 类:参数化模型、几何光学模型、辐射传输模型和计算机模拟模型等^[14-15]。受限于目前的技术发展,如传感器的技术、覆盖范围与影像获取频率等限制了物理参数的获取,会导致 LAI 产品在时空连续性上表现欠佳^[16]。目前广泛使用的 LAI 遥感产品如:MODIS LAI^[17]、CYCLOPES LAI^[18]、AVHRR LAI^[19]、POLDER LAI^[20]、GEOV1 LAI^[21]等都是公里级分辨率的产品,它们的核心算法都为物理模型,由于受天气、传感器技术和反演算法等影响,大多数产品具有较为严重的数据缺失;再者物理模型的算法较为复杂,输入数据多,计算速度较慢,反演过程繁琐,目前还不能很好地用于高分辨率叶面积指数的估算^[22]。全球陆表特征参量 GLASS LAI 产品基于广义神经网络的方法估算得到,产品的时间和空间连续性比上述 LAI 产品都好,估算精度较高,其分辨率同样为公里级^[23]。由于全球植被覆盖类型错综复杂,尤其是农业估产、生态学等研究领域在实际应用中,需要高分辨率 LAI 提供更有价值的信息^[24]。高空间分辨率 LAI 是指空间分辨率在几米~几十米之间的 LAI 数据,其数据量庞大且过于繁杂,智能优化算法中的神经网络方法具有自组织自适应能力和强大的容错性,使得在信息不完备的情况下反演 LAI 能获得较好的结果^[25-26]。

基于误差反向传播算法的 BP 神经网络(Back-

Propagation neural network)模型,是人工神经网络当中应用最为广泛的神经网络^[27-28]。与传统的人工神经网络模型相比,拥有非线性映射,容错性好,自适应性强等一系列的优点^[29-30]。该方法已被一些学者用于 LAI 反演,其中,林杰等^[31]采用 Landsat 反射率数据,利用 BP 神经网络模型进行 LAI 反演,估算长时间跨度的南京市 LAI,并分析了其植被变化趋势;陆坤等^[32]基于 GF-2 号卫星数据,使用 PRO-SAIL 模型结合 BP 神经网络模型进行 LAI 反演。但 BP 神经网络模型的缺点也很明显,如训练速度较慢,容易陷入局部最小值等。模拟退火算法(Simulated Annealing, SA)最早的思想是由 Metropolis 等于 1953 年提出。1983 年 Kirkpatrick 等^[33]成功地将退火思想引入到组合优化领域。该算法基于概率方法,可以很好地跳出局部最小值,逐步得到全局最小值^[34]。

采用基于模拟退火算法的 BP 神经网络模型,算法优势即在 BP 神经网络模型求解最优解时利用模拟退火算法扩大网络的权值更新空间,使其不容易陷入局部最小值,将其用于高分辨率的 LAI 反演。选取农田、草地和林地 3 种不同地表类型的研究区,以地面实测和 30 m 分辨率遥感观测数据为基础,分别建立了 NDVI 经验模型、BP 神经网络模型和基于模拟退火算法的 BP 神经网络模型,以地面实测数据为验证数据,评价了 3 种模型的精度,比较分析了 3 种建模方法的优劣。最后利用基于模拟退火算法的 BP 神经网络模型估算得到研究区 30 m 空间分辨率 LAI 分布图。最后,在独立研究区进一步验证了 SA-BP 神经网络的适用性。

2 实验区和数据

2.1 研究区域概况

本文选取了地表类型为农田、林地和草地为主的 3 个主要研究区,分别是乌克兰的 Pshenichne、中国的张北和法国的 Nezer 研究区。这 3 个研究区地形地貌和地表类型特征明显,且具有丰富的地面测量数据,可满足研究建模和验证需求。另外,为证明研究方法的普适性,在 3 个主要研究区的基础上增加了 Southwest 研究区进行模型的进一步验证。

Pshenichne 研究区位于乌克兰的 Pshenichne 站点,属于 FP7(7th Framework Programme)站点,中心点经纬度(WGS84)为 50°04'48" N, 30°13'48" E。主要为平原,属温带大陆性气候,一月份平均气温-

5.8℃,7月份平均气温19.5℃,平均年降水量622 mm。区域作物主要包括冬小麦,春季大麦,玉米,大豆等一系列农作物,由于农作物种类较多,该地区没有典型的作物轮种方式,地表分布较为复杂。

张北研究区位于中国河北省张家口市张北县地处河北省西北部,属于VALERI(VALidation of European Remote sensing Instruments)站点,站点中心经纬度(WGS84)坐标为41°16′44″N,114°41′16″E。该地区处于半干旱地带,气候特殊,春季干旱多风,夏季短暂且多雨凉爽,秋季寒霜来临较早,冬季漫长,严寒少雪,属中温带大陆性季风气候,年平均气温3.2℃,年降水量300 mm左右,日照时数年平均2 897.8 h。地形地貌复杂,主要为丘陵和波状平原,植被主要以牧草为主。

Nezer研究区位于法国西南部吉伦特省的兰德斯日加斯科涅地区自然公园处,属于VALERI站点,站点占地面积50 km²,站点中心经纬度(WGS84)为44°35′47″N,1°02′30″W。该地区属温带海洋性气候,最冷月平均气温在0℃以上,最暖月低于22℃,一年四季降水比较均匀,年降雨量500~700 mm,主要植被为以松树为主的针叶林。

Southwest研究区位于法国西南部,邻近图卢兹,属于FP7站点,站点中心经纬度为43°30′14″N,1°10′15″E。其主要植被为农作物,包括小麦、玉米和向日葵等多种农作物。该研究区轮种作物与Pshenichne研究区相似,因此Southwest站点数据用以进行模型的普适性验证。

为了保证数据质量,本文选用已被广泛验证的地面观测数据集用于建模和模型检验。张北研究区和Nezer研究区使用欧洲VALERI项目收集整理的LAI地面测量数据,VALERI项目从2000年开始由欧洲航空局启动,对MODIS、AVHRR、MERIS等传感器在内的LAI等全球陆地遥感数据进行真实性检验,站点数据集中包含了地面叶面积指数、植被冠层反射率(TOC)和植被覆盖度(fCover)等数据资料,可用于相应的遥感数据产品的验证。张北研究区共有40个LAI地面测量数据,获取时间为2002年7月至8月,获取方式为半球数字图像法(DHP);Nezer研究区共计91个LAI地面测量数据,获取时间从2000年7月至2002年4月,获取方式为LAI-2000冠层分析仪和半球数字图像法(DHP)。

Pshenichne研究区和Southwest研究区使用

FP7项目收集的LAI地面测量数据,FP7为中长期重大科技研发计划,是欧盟投资最多的全球性科技开发计划,站点数据集包括30 m分辨率的叶面积指数、植被覆盖度(fCover)、光合有效辐射(FAPAR)、大气层顶反射率(TOA)等数据资料,同样可用于相关遥感产品的真实性检验。Pshenichne研究区共计141个LAI地面测量点,数据获取时间从2013年7月至2015年,获取方式为半球数字图像法(DHP)。Southwest研究区共计28个LAI地面测量点,数据获取时间为2013年,获取方式为半球数字图像法(DHP)。

地面测量样点的分辨率为30 m,单个像元有多个地面测量样点时,取LAI平均值作为该像元LAI值。若单个像元内只有一个地面测量样点,即认为该LAI为该像元LAI值。对研究区建模点数量与验证点数量进行反复调整和实验,进行大量总结后,决定按LAI梯度随机选取总地面测量点数量的15%作为验证点,其他作为建模点,3个主要研究区建模点与验证点数量如表1所示。

表1 建模数据量一览表

Table1 List of modeling data volume		
研究区域	建模数据对	验证数据对
张北	40	7
Pshenichne	141	25
Nezer	91	16

1.2 遥感影像数据

为研究高空间分辨率LAI估算方法,主要采用30 m分辨率的Landsat 7和8数据作为模型训练和估算的输入数据;地面实测LAI数据,作为模型训练和估算的验证数据。

Landsat7 ETM+与Landsat8 OLI多光谱遥感影像数据下载自美国的USGS网站(<https://earth-explorer.usgs.gov/>)。根据地面数据获取的时间,不同研究区下载的数据类型不完全相同,其中张北研究区域和Nezer研究区的数据类型为L7 ETM+ Collection 1 Level-2 30 m分辨率影像数据,共计6个波段的地表反射率,张北研究区的PATH/ROW为125/031,影像获取时间为2002年。Nezer研究区的PATH/ROW为200/029,影像获取时间为2000~2002年。Pshenichne研究区和Southwest研究区的数据类型为L8 OLI C1 Level-2 30 m分辨率影像数据,共计7个波段的地表反射率,Pshenichne研究区的PATH/ROW为181/025,影像获取时间

为2013~2015年。Southwest研究区的PATH/ROW为199/030,影像获取时间为2013年。

在数据网站获取了Landsat Level-2地表反射率,该数据已经过辐射校正、几何校正和大气校正,选取无云情况下的高质量地表反射率数据后,可直接将地面测量数据与遥感数据进行匹配,得到遥感反射率-地面实测LAI观测数据对,用于模型训练和检验。

3个主要研究区中,张北研究区植被覆盖类型均为草地,Nezer植被覆盖类型均为林地,可直接进行整个研究区的LAI估算,Pshenichne研究区地表类型比较多样,如图1所示,为了保证模型精度,根据地表分类数据对研究区域进行掩膜,只选取农田区域用于建模和估算。独立研究区Southwest的样方点类型均为农作物。

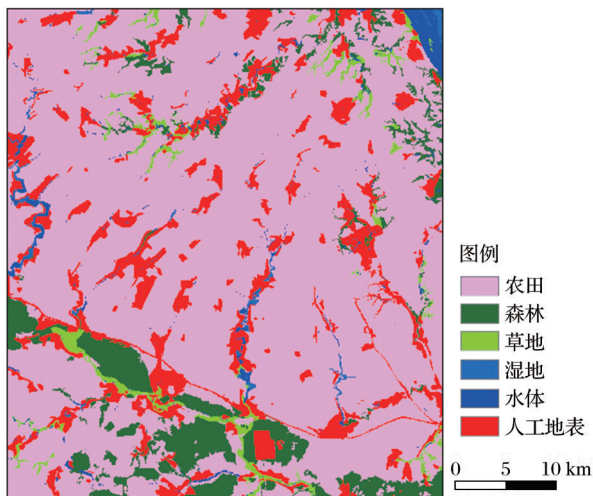


图1 乌克兰研究区土地覆盖分布图(2010年)

Fig.1 Land cover map of Ukraine research area(2010)

2 实验方法

2.1 方法概述

与粗分辨率的叶面积指数估算相比,高分辨率的叶面积指数估算的难点在于输入参数规律复杂和数据量庞大。BP神经网络模型不需研究目标结构的先验知识,且原理和结构都易于理解,功能稳定,精度较高,容错率强,在处理非线性问题方面性能很强,故其在地表参数的估算方面应用广泛,很适合用于高分辨率叶面积指数的估算。但BP神经网络模型和其众多的改进方式都是建立在梯度下降法的基础上,其存在着收敛速度较慢,易陷入局部最小值等缺点,在进行复杂运算时会大大降低效率与精度。借助模拟退火算法的有效搜寻全局寻

优的特性,可以对BP神经网络模型的权值的跳跃范围进行限定,减少无用搜索过程,从而更快速有效地寻找全局最优权值。基于模拟退火算法的BP神经网络模型,能有效规避局部最小值,可提高模型训练的成功率与精度。

2.2 BP神经网络模型

基于误差反向传播算法的BP神经网络模型是人工神经网络当中应用最为广泛的神经网络,它无需事先确定输入与输出之间的映射关系,能够通过自身的训练,学习某种规则,在输出给定格式的输入值时得到接近期望值的输出值(图2)。与传统的模型相比,BP神经网络模型拥有非线性映射,容错性好,自适应性强等一系列的优势^[30, 35]。

在BP神经网络模型正向传播的过程中,对于除输入层节点外的每个神经元节点,其信号输入与输出的关系:

$$\text{net}(i) = \sum_{j=1}^n W_{ij} X_j - \mu \quad (1)$$

$$Y_i = f(\text{net}(i)) \quad (2)$$

其中: X 为信号输入, W 为该神经元节点权值, μ 为偏置, f 为激励函数, Y 为信号输出。

其反向误差传播过程,权值修改采用梯度下降法,其误差函数为:

$$E(W) = \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n (I_j^i - O_j^i)^2 \quad (3)$$

$$W_{ij} = W_{ij} - \delta \nabla E(W_{ij}) \quad (4)$$

其中: E 为误差公式, $\nabla E(W_{ij})$ 为权值误差偏导,权值不断进行调整,直到得到权值的最优解。




图2 BP神经网络模型结构示意图

Fig.2 Schematic diagram of BP neural network

BP神经网络模型的工作原理是将输入值向输出端正向传递,而每层输出值与目标值之间的误差沿网络结构进行逆向传递,传递过程中逐一改变节点之间的权值,直到返回输入层,此后继续进行数值的正向传递,周而复始,反复学习,直到最终网络输出端的误差被稳定控制在一个设定的范围内或

者学习训练次数达到了预先设定的阈值,则停止学习,将网络结构的所有权值保存,即保存了训练好的BP神经网络模型结构,此时的BP神经网络模型才可以用来进行实际遥感数据的反演工作^[35-37]。

2.3 模拟退火算法

模拟退火算法是一种通用的随机搜索算法,是对局部搜索算法的扩展,用以在一个大的解空间内寻找最优解。模拟退火算法模仿自然界的退火过程,利用了物理中固体物质的退火过程与一般优化问题的相似性:从某一初始温度开始,伴随着温度不断下降,结合概率突跳特性在解空间内随机寻找全局最优解^[38]。

模拟退火算法的基本思想为:在一定温度下,从一个温度状态随机变换到另一个状态,随着温度不断降低,搜索过程以概率1停留在最优解。根据Metropolis准则^[39],粒子在温度 T 时趋于平衡的概率为 $\exp(-\Delta E/kT)$,其中 E 为温度 T 时的内能, ΔE 为其改变量, k 为Boltzmann常数。

将内能 E 模拟为目标函数值 f ,温度 T 演化为控制参数 t ,由初始解 S 开始,对当前解重复进行“随机产生新解 S 、计算目标函数误差 ΔE 、以概率 $\exp(-\Delta E/kT)$ 接受或舍弃当前解”的过程,并逐步衰减 t 值,直至温度降为最低值,算法的当前解即为最优解。当温度很高时,所有能量状态的概率都相同,随着温度的下降,直到最低温度,搜索过程以概率1收敛于全局最优解。

2.4 基于模拟退火算法的BP神经网络模型

基于模拟退火算法的BP神经网络模型(SA-BP)算法基本流程包括以下6个步骤:

(1)SA-BP神经网络模型关键参数设定:设定初始退火温度 T_{\max} ,最终退火温度 T_{\min} ,随机生成初始解 S ,温度衰减参数 d ,每个温度的迭代次数 L ;神经网络层数,输入层节点,隐含层节点的设定。

(2)构建神经网络,并行输入学习样本,随机初始化权值,对 $k=1, \dots, L$ 循环进行(3)至(5)循环。

(3)产生权值新解 S' ,计算增量 $\Delta t=E(S')-E(S)$,其中 $E(S)$ 为评价函数。

(4)若 $\Delta t < 0$,则接受 S' 作为新的当前解,否则以概率 $\exp(-\Delta t/T)$ 接受 S' 作为新的当前解。

(5)设终止条件为连续若干个新解都没有被接受,满足条件时输出当前解作为最优解,结束当前循环。

(6) $T'=T*d$,若 $T' > T_{\min}$,转第(3)步,否则结

束算法,输出最优解。

在迭代过程当中,BP神经网络模型与模拟退火交替进行,直至完全降温,输出最优权重。算法流程图如图3所示。

2.5 精度评价方法

各个模型的精度评价的指标主要为决定系数 R^2 与均方根误差RMSE,拟合 R^2 表示由预测值和实测值拟合模型的決定系数,拟合模型的 R^2 越接近1,模型的拟合精度越高。RMSE即均方根误差,表示模型预测值同实际值之间的离散程度,其计算公式为 $\sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}}$,其中 x 为预测值, y 为实测值, i 为数据编号, n 表示数据数目。RMSE的值越小,说明模型的预测值同实际值之间的离散程度越小,即模型越可靠。

本文使用 R^2 和RMSE评价结果的精度分为两部分:对建模数据建立的模型进行初步评价;利用模型对验证数据进行估算,进行精度评定。

2.6 模型的构建

2.6.1 BP神经网络模型的建立

以Landsat7 ETM+6个波段反射率或Landsat8 OLI 7个波段反射率作为输入变量,地面测量LAI值作为输出变量,根据大量实验和总结,采用Sigmoid函数作为传递函数,输出层采用线性传递函数。训练算法选用动量梯度下降法,网络目标误差为0.001,训练迭代次数3 000次,学习速率为0.001。神经网络为3层,输入层、输出层以及一层的隐含层。以地表反射率波段作为输入变量,LAI实测值为输出变量,Zhangbei研究区和Nezer输入层节点数为6,输出层节点数为1。Pshenichne研究区输入层节点数为7,输出层节点数为1。

由于模拟退火的迭代次数一般为150次左右,因此对利用训练样本对神经网络进行反复训练150次,分别得到3个主要研究区各自精度较高、较稳定的神经网络模型。

2.6.2 SA-BP神经网络模型的建立

SA-BP神经网络模型相关参数与BP神经网络模型参数一致,设置初始温度为100,终止温度为0.01,降温衰减参数为0.95,根据BP神经网络模型的权值范围,设定权值区间为 $[-3, 3]$ 。

在建模过程中,模拟退火算法的初始温度和终止温度设定可以适应大部分模型和算法,衰减温度根据计算机硬件及模型复杂程度进行设定,权值区

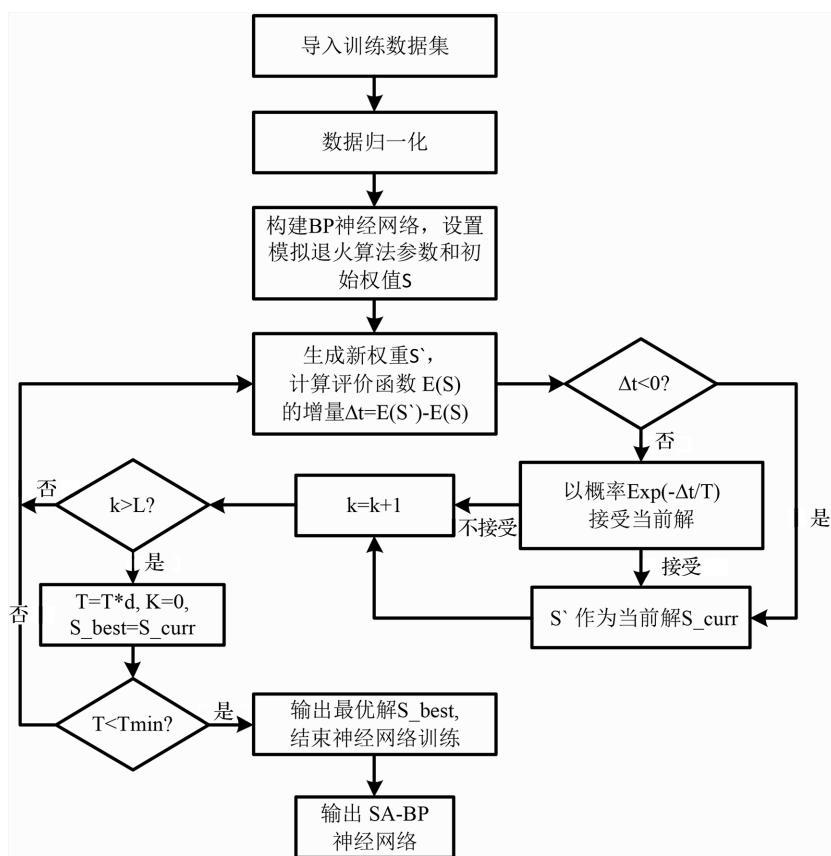


图 3 SA-BP 算法流程图

Fig.3 Flow chart of SA-BP algorithm

间根据模型参数最佳范围进行设定;神经网络的输入层节点设置为输入维度,输出层节点设置为输出维度,迭代次数设为默认值,目标误差根据研究对象进行确定。

通过合理的参数设定,利用3个主要站点各自的训练样本分别进行训练,最终得到3个主要研究区精度较高、较稳定的神经网络模型。

3 结果与分析

3.1 仿真分析

在参数一致的情况下,使用BP神经网络模型和SA-BP神经网络模型对Pshenichne研究区数据集进行训练和测试,其训练误差如图4~5所示。可以看出,BP神经网络模型的迭代次数较多且最终精度没有达到预设值,而SA-BP神经网络模型的网络迭代速度较快,有更高的训练精度。说明SA-BP神经网络可以跳出局部最小值,得到更高精度的BP神经网络。

3.2 建模精度

对3个主要站点的遥感数据—地面数据对进行分别训练,使用NDVI经验模型、BP神经网络模型




图 4 BP 神经网络迭代曲线

Fig.4 BP Neural Network Iterative Curve

和SA-BP神经网络模型,在每个站点利用各自研究区相应的数据集进行建模分析,分别比较了3种建模方法的建模精度。其中:NDVI经验模型选用文献中的列出的对数模型^[40],其具体公式为(A为系数):

$$LAI = -1/2 A \ln(1 - NDVI)$$

使用Landsat近红外与红外波段计算得到的




图5 SA-BP神经网络迭代曲线

Fig.5 SA-BP Neural Network Iterative Curve

NDVI作为输入变量,与之相对应的地面实测 LAI 作为输出变量。经拟合得出回归方程的系数。研究区 Pshenichne、张北、Nezer 的系数 A 分别是 2.906、5.163 和 1.791。

比较结果如表 2 所示。由表 2 可见,在森林、农田和草地 3 个主要站点,SA-BP 神经网络模型的建模精度高于 BP 神经网络模型和 NDVI 经验模型的精度,NDVI 经验模型在 3 种地类的建模精度均不太理想,在张北草地站点建模精度最好,该现象是由于 Pshenichne 农田站点与 Nezer 森林站点的植被分布情况较为复杂,张北草地站点植被类型较为简单。BP 神经网络模型和 SA-BP 神经网络模型的在 Pshenichne 农田站点,建模精度最接近, R^2 分别是 0.78 和 0.86,而在张北草地站和 Nezer 森林站,SA-BP 神经网络模型的精度提升比农田站点更显著,张北站点的 R^2 从 0.70 提高至 0.89,Nezer 站点的 R^2 从 0.75 提高至 0.87,两个站点的 RMSE 的改善效果也

表 2 模型精度一览表

Table2 List of modeling results			
研究区域	模型类型	R^2	RMSE
Pshenichne	NDVI 经验模型	0.5862	0.9981
	BP 神经网络	0.7836	0.7331
	SA-BP 神经网络	0.8625	0.5822
Zhangbei	NDVI 经验模型	0.5363	0.5848
	BP 神经网络	0.7053	0.5171
	SA-BP 神经网络	0.8962	0.3484
Nezer	NDVI 经验模型	0.5317	0.9141
	BP 神经网络	0.7538	0.7923
	SA-BP 神经网络	0.8769	0.6530

比 Pshenichne 站点显著。产生这一差别的原因可能在于:张北站点与 Nezer 站点的数据量偏少,使用 SA-BP 神经网络模型能够在数据量较少的情况下提供更高精度的结果;张北站点与 Nezer 站点的植被类型较为单一,而 Pshenichne 站点的农作物轮种模式不规律,存在大量不同类型的农作物,致使模型精度提升不明显。

3.3 站点估算结果

利用建成的各自研究区的不同模型分别在 3 个主要站点进行了 LAI 估算,并用地面测量数据对估算结果进行了验证。结果如图 6~8 所示。

在 Pshenichne 农田站点,实测 LAI 范围为 0~6,如图 6 所示,SA-BP 神经网络模型的验证精度较高, R^2 为 0.899 2, RMSE 为 0.482 9,当 LAI 值较低(0~2)和中值(3~4)时,估算结果与地面实测值拟合效果较好;LAI 值在(2~3)时,模型估算结果较地面测量值有轻微的低估现象。BP 神经网络模型的总体验证精度比 SA-BP 神经网络模型差, R^2 为 0.762 9, RMSE 为 0.717 9,散点图 LAI 中值区较为离散,且有个别点有较严重的错误估计现象。ND-




图6 Pshenichne研究区验证结果

Fig.6 Pshenichne verification result




图7 Zhangbei研究区验证结果

Fig.7 Zhangbei verification result




图8 Nezer研究区验证结果

Fig.8 Nezer verification results

VI经验模型的精度最差, R^2 为 0.622 1, RMSE 为 0.919 2, LAI 在中低值(0~4)分布离散, 在 LAI 高值区(4~6)有显著低估现象。

张北草地研究区的建模数据较少, 只有 40 对, LAI 范围区间为 0~3, 验证点数量也只有 7 对。如图 7 所示, 从验证结果来看, SA-BP 神经网络模型的精度仍然比 BP 神经网络模型和 NDVI 经验模型高, R^2 为 0.858 1, RMSE 为 0.382 6, BP 神经网络模型的 R^2 为 0.709 5, RMSE 为 0.476 6, NDVI 经验模型的表现更差, R^2 为 0.536 1, RMSE 为 0.560 7。从散点分布图看, SA-BP 神经网络模型有轻微的离散趋势, 但整体优于 BP 神经网络模型和 NDVI 经验模型。

在 Nezer 森林站点, LAI 范围区间为 0~5, 如图 8 所示, SA-BP 神经网络模型具有较明显的低估现象, 且有个别验证点低估严重, 但总体估算精度比 BP 神经网络模型和 NDVI 经验模型高, R^2 为 0.863 0, RMSE 为 0.577 2, BP 神经网络模型的估算精度为 R^2 为 0.741 5, RMSE 为 0.756 1, 由于该站点为林地

站点, LAI 值大多都分布于高值区, NDVI 经验模型的表现很差, 估算精度为 R^2 为 0.637 5, RMSE 为 1.021 7。

从以上 3 个主要站点的验证结果来看, SA-BP 神经网络模型精度均优于 BP 神经网络模型与 NDVI 经验模型, 且 SA-BP 神经网络模型建模精度与验证精度之间的差距较小。由 Pshenichne 站点和 Nezer 站点的结果分析可知, 由于 NDVI 的饱和性质, NDVI 模型在 LAI 值处于(3~6)区间时, 有较为明显的低估现象, 而 SA-BP 神经网络在高值区(3~6)没有饱和性缺陷的体现。在模型的训练当中, SA-BP 神经网络模型通过设置合理的降温条件, 能够大大提高算法运行速度, 建模的精度也普遍优于 BP 神经网络模型和 NDVI 经验模型, 说明该算法具有更好的模拟能力。

本研究的 SA-BP 神经网络模型与杨敏等^[37,41]所建立的 LAI 反演模型相比, 建模精度与实测数据验证结果的 R^2 和 RMSE 均优于二者。其中, 杨敏

等^[37]针对南京市周边绿色植被,建立植被指数与部分反射率波段作为输入的隐含层为2层的BP神经网络模型,在数据复杂且建模数据较少的情况下容易出现轻微的过拟合现象,造成建模精度较高,而验证精度差的现象;朱绪超等^[41]针对塔里木河周边林地,建立基于植被指数的经验统计模型,在针对单一林地类型时有较好的结果,对复杂林地的反应能力较低,难以进行推广和普及。本研究的SA-BP

神经网络模型在防止模型过拟合和对复杂地表的适应能力上均表现较好,可靠性较高。

3.4 区域 LAI 估算结果

利用训练得到的SA-BP神经网络模型,基于Landsat 高分辨率反射率影像对3个主要研究区的LAI值进行估算,分别生成不同时间节点的三年Pshenichne LAI分布图(图9)、一年张北研究区LAI分布图(图10)、三年Nezer分布图(图11)。

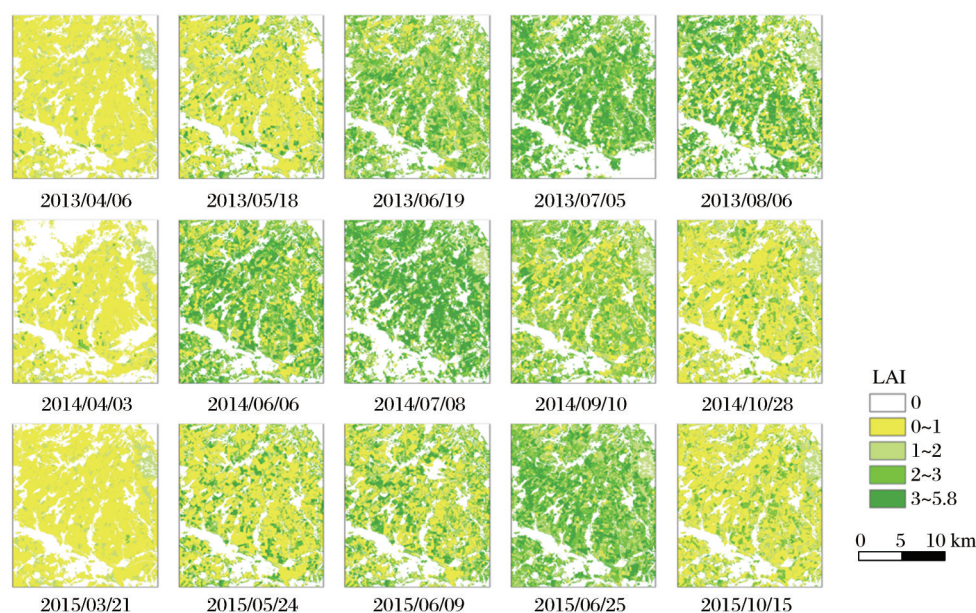


图9 Pshenichne SA-BP 神经网络模型估算结果

Fig.9 Pshenichne Estimation results of SA-BP neural network model




图10 Zhangbei SA-BP 神经网络模型估算结果

Fig.10 Zhangbei Estimation results of SA-BP neural network model

Pshenichne 研究区的 LAI 估算结果图较好地反映了该地区的农作物的正常生长趋势,且3年中相近时间点的 LAI 值较为接近,经查阅乌克兰国家统计局(State Statistics Service of Ukraine)官网相关资料(<http://www.ukrstat.gov.ua/>),因旱育连续严重的干旱天气,2015年Pshenichne的各类农作物与往年相比都有不同程度减产,从图9可见2015年的 LAI 值较2013和2014年相近时间点 LAI 值普遍偏低, LAI 估算结果符合实际情况。

张北研究区的 LAI 分布图反映了牧草的生长

趋势,4月份牧草生长较快,故2002年4月2日与4月18日之间 LAI 差距较为明显,9月份牧草开始枯萎, LAI 开始迅速下降,符合实际情况。

Nezer 研究区主要物种为海岸松,属于常绿针叶林,混杂了一些灌木与落叶林品种, LAI 分布图较好地反映了植被的空间分布特征和时间变化趋势, GLASS 产品的关于该站点的 LAI 全年趋势分析图^[14],该研究区在3月份时 LAI 达到全年最小值,7月份时,森林植被最为茂盛,符合该研究区的森林 LAI 的变化情况。




图 11 Nezer SA-BP 神经网络模型估算结果

Fig.11 Nezer Estimation results of SA-BP neural network model

3.5 区域 LAI 统计分析

为进一步探究模型精度对于高分辨率 LAI 估算的影响,基于 Pshenichne 研究区 2014 年 6 月 6 日的 Landsat 30 m 分辨率反射率影像为例,利用 NDVI 经验模型、BP 神经网络模型、SA-BP 神经网络模型分别进行 LAI 估算,得到由 NDVI 经验模型估算得到的 NDVI LAI、BP 神经网络模型估算得到的 BP LAI 与 SA-BP 神经网络模型估算得到的 SA-BP LAI,统计 3 种 LAI 分布。

其分布图状况如下所示:如图 12 所示。NDVI LAI 与站点验证结果一致,在高值区有显著的低估现象,BP LAI 的中值区表现较为离散,LAI 在值 (5.5~6) 区间有较明显的高估,根据站点实测验证结果分析,虽然 BP LAI 的分布变化均匀,但其离散性较为严重,因此整体误差较大。SA-BP 神经网络的估算结果分布情况也与站点验证结果分布一致,在低值区有轻微低估,中值区有轻微高估现象,整体结果符合当前生长季分布。因此,可以得出,由于高分辨率 LAI 的数据量较大,模型的可靠性对高分辨率 LAI 的估算结果影响非常大。

3.6 SA-BP 神经网络普适性验证

为证明 SA-BP 神经网络的普适性,用以 Pshenichne 研究区数据训练的 SA-BP 神经网络模型估算 Southwest 研究区的 LAI,与该站点地面实测结果进行对比,结果如图 13 所示。




图 12 Pshenichne 2014 年 6 月 6 日区域 LAI 估算结果对比统计图

Fig.12 Pshenichne comparative statistical histogram of regional LAI estimation results

由散点图可见,SA-BP 模型估算结果与地面实测结果一致性高, R^2 为 0.842 0。RMSE 为 0.689 5,与 Pshenichne 研究区的 RMSE 相比有所升高,从 0.482 9 升高至 0.689 5。经过分析发现,由于 Southwest 站点存在新的轮种作物,且该作物类型数据未参与建模,因此验证结果分布较为离散,RMSE 值较高。说明在地面测量数据可获取的情况下,基于更加细致的地表分类进行建模可以有效提高反演精度。




图13 Southwest研究区验证结果

Fig.13 Southwest verification results

4 结 语

本研究以 Pshenichne, 张北和 Nezer 3 个区域为主要研究区, 收集整理了 3 个研究区域的 LAI 地面测量数据, 并获取了相应地区同时段的遥感 Landsat8 OLI 和 Landsat7 ETM+ 反射率影像数据, 建立并比较了 NDVI 经验模型、BP 神经网络模型与 SA-BP 神经网络模型的反演精度, 并用站点地面实测数据进行了验证。结果显示, SA-BP 神经网络模型比 NDVI 经验模型和 BP 神经网络模型模拟精度更高, 在高分辨率 LAI 估算上更有优势。最后基于 Landsat 30 m 分辨率反射率数据, 用 SA-BP 神经网络模型估算了 3 个研究区的 LAI, 通过相关资料与文献证明该方法的精度可靠。最后, 以 Southwest 研究区为例, 证明了 SA-BP 神经网络具有较好的普适性, 在地面数据可获取的情况下, 基于细化的地表分类建模将可以有效提高反演精度。

SA-BP 神经网络模型提高了模型的泛化能力和迭代速度, 有效避免了 BP 神经网络模型陷入局部最小值的缺陷, 具有更高的估算精度, 是高分辨率叶面积指数估算的有效手段。

参考文献 (References):

- [1] Chen J M, Black T A. Defining Leaf Area Index for Non-Flat Leaves [J]. *Plant Cell & Environment*, 1992, 15 (4): 421-429.
- [2] Chen J M, Cihlar J. Retrieving Leaf Area Index of Boreal Conifer Forests Using Landsat TM Images [J]. *Remote Sensing of Environment*, 1996, 55(2):153-162.
- [3] Gu Chengyan, Du Huaqiang, Zhou Guomo, *et al.* Retrieval of Leaf Area Index of Moso Bamboo Forest with Landsat Thematic Mapper Image based on PROSAIL Canopy Radiative Transfer Model [J]. *Chinese Journal of Applied Ecology*,

- 2013, 24(8):2248-2256.[谷成燕, 杜华强, 周国模, 等. 基于 PROSAIL 辐射传输模型的毛竹林叶面积指数遥感反演 [J]. *应用生态学报*, 2013, 24(8):2248-2256.]
- [4] Cleugh H A, Leuning R, Mu Q, *et al.* Regional Evaporation Estimates from Flux Tower and MODIS Satellite Data [J]. *Remote Sensing of Environment*, 2007, 106(3):285-304.
- [5] Hu Lei, Zhang Qingxia, Zhang Chonghua, *et al.* Changes in Leaf Area Index of Early-Season Cropping Rice and Its Relationship with Yield under Climate Warming in Nanchang County [J]. *Ecology and Environmental Sciences*, 2019, 28 (9): 1785-1792.[胡磊, 张清霞, 张崇华, 等. 气候变暖下南昌县早稻叶面积指数变化及其与产量的关系 [J]. *生态环境学报*, 2019, 28(9): 1785-1792.]
- [6] Turner D P, Cohen W B, Kennedy R E, *et al.* Relationships between Leaf Area Index and Landsat TM Spectral Vegetation Indices across Three Temperate Zone Sites [J]. *Remote Sensing of Environment*, 1999, 70(1):52-68.
- [7] Liu Jun, Pang Xin, Li Yanrong, *et al.* Inversion Study on Leaf Area Index of Summer Maize Using Remote Sensing [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2016, 47(9):309-317.[刘珺, 庞鑫, 李彦荣, 等. 夏玉米叶面积指数遥感反演研究 [J]. *农业机械学报*, 2016, 47 (9):309-317.]
- [8] Li Xiaotong, Qin Xianlin, Liu Shuchao, *et al.* Estimation of Forest Leaf Area Index based on GF-1 WFV Data [J]. *Remote Sensing for Land & Resources*, 2019, 31(3):80-86.[李晓彤, 覃先林, 刘树超, 等. 基于 GF-1 WFV 数据森林叶面积指数估算 [J]. *国土资源遥感*, 2019, 31(3):80-86.]
- [9] Xu Weixing, Xue Huazhu, Jin Huaan, *et al.* Retrieval of Leaf Area Index by Fusing Prior Information from Remote Sensing Data [J]. *Remote Sensing Technology and Application*, 2019, 34(6):1235-1244.[徐卫星, 薛华柱, 靳华安, 等. 融合遥感先验信息的叶面积指数反演 [J]. *遥感技术与应用*, 2019, 34(6):1235-1244.]
- [10] Tian Qingjiu, Min Xiangjun. Advances in Study on Vegetation Indices [J]. *Advance in Earthences*, 1998, 13(4):327-333.[田庆久, 闵祥军. 植被指数研究进展 [J]. *地球科学进展*, 1998, 13(4):327-333.]
- [11] Liang L, Di L, Zhang L, *et al.* Estimation of Crop LAI Using Hyperspectral Vegetation Indices and A Hybrid Inversion Method [J]. *Remote Sensing of Environment*, 2015, 165: 123-134.
- [12] Jiang Hong, Zhang Zhaoming, Wang Xiaoqin, *et al.* Bamboo Forest LAI Retrieval and Analysis in Mountainous Area based on TAVI [J]. *Journal of Geo-Information Science*, 2015, 17 (4):500-504.[江洪, 张兆明, 汪小钦, 等. 基于 TAVI 的山区毛竹林 LAI 反演分析 [J]. *地球信息科学学报*, 2015, 17 (4):500-504.]
- [13] Xiang Hongbo, Guo Zhihua, Zhao Zhanqing, *et al.* Estimating Method of Forest Leaf Area Index on Different Space Scales [J]. *Scientia Silvae Sinicae*, 2009, 45(6):139-144.[向洪波, 郭志华, 赵占轻, 等. 不同空间尺度森林叶面积指数的估算方法 [J]. *林业科学*, 2009, 45(6):139-144.]
- [14] Wang Dongwei, Meng Xianzhi, Wang Jingdi, *et al.* The Development of Leaf Area Index Inversion from Remote Sensing [J]. *Journal of Wuyi University*, 2009, 23(4):47-52.[王东

- 伟, 孟宪智, 王锦地, 等. 叶面积指数遥感反演方法进展[J]. 五邑大学学报(自然科学版), 2009, 23(4):47-52.]
- [15] Ren Zhe, Chen Huailiang, Wang Lianxi, *et al.* Research on Inversion Model of Wheat LAI Using Cross-Validation[J]. Remote Sensing for Land and Resources, 2015, 27(4): 34-40.[任哲, 陈怀亮, 王连喜, 等. 利用交叉验证的小麦 LAI 反演模型研究[J]. 国土资源遥感, 2015, 27(4):34-40.]
- [16] Liang S, Zhang X, Xiao Z, *et al.* Global LAnd Surface Satellite (GLASS) Products [M]. Berlin: Springer International Publishing, 2014.
- [17] Knyazikhin Y, Martonchik J V, Myneni R B, *et al.* Estimating Vegetation Canopy Leaf Area Index and Fraction of Absorbed Photosynthetically Active Radiation from MODIS and MISR Data[J]. Journal of Geophysical Research, 1998, 103 (D24): 32239-32256.
- [18] Baret F, Hagolle O, Geiger B, *et al.* LAI, FAPAR and FCOVER CYCLOPES Global Products Derived from VEGETATION: Part 1: Principles of the Algorithm [J]. Remote Sensing of Environment, 2007, 110(3):275-286.
- [19] Martin C, Jessica M, Eric V, *et al.* A 30+ Year AVHRR LAI and FAPAR Climate Data Record: Algorithm Description and Validation [J]. Remote Sensing, 2016, 8(3): 263. doi: 10.3390/rs8030263.
- [20] Zhang Y, Tian Y, Knyazikhin Y, *et al.* Prototyping of MISR LAI and FPAR Algorithm with POLDER Data over Africa [J]. IEEE Transactions on Geoscience and Remote Sensing, 2000, 38(5): 2402-2418.
- [21] Baret F, Weiss M, Lacaze R, *et al.* GEOV1: LAI and FAPAR Essential Climate Variables and FCOVER Global Time Series Capitalizing Over Existing Products. Part1: Principles of Development and Production[J]. Remote Sensing of Environment, 2013, 137(10):299-309.
- [22] Zhao Jing, Li Jing, Liu Qinhua, *et al.* Leaf Area Index Inversion Combining with HJ-1/CCD and Landsat 8/OLI Data in the Middle Reach of the Heihe River Basin[J]. Journal of Remote Sensing, 2015, 19(5):733-749.[赵静, 李静, 柳钦火, 等. 联合 HJ-1/CCD 和 Landsat 8/OLI 数据反演黑河中游叶面积指数[J]. 遥感学报, 2015, 19(5):733-749.]
- [23] Xiao Z, Liang S, Wang J, *et al.* Use of General Regression Neural Networks for Generating the GLASS Leaf Area Index Product from Time-Series MODIS Surface Reflectance [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1):209-223.
- [24] Shi Y, Wang J, Wang J, *et al.* A Prior Knowledge-based Method to Derivate High-resolution Leaf Area Index Maps with Limited Field Measurements [J]. Remote Sensing, 2016, 9(1):13. doi: 10.3390/rs9010013.
- [25] Li Shuangcheng, Zheng Du. Applications of Artificial Neural Networks to Geosciences: Review and Prospect[J]. Advances in Earth Science, 2003, 18(1):68-76.[李双成, 郑度. 人工神经网络模型在地质研究中的应用进展[J]. 地球科学进展, 2003, 18(1):68-76.]
- [26] Bacour C, Baret F, Béal D, *et al.* Neural Network Estimation of LAI, fAPAR, fCover and LAI×Cab, from Top of Canopy MERIS Reflectance Data: Principles and Validation [J]. Remote Sensing of Environment, 2006, 105(4):313-325.
- [27] Xiang Hongbo. Estimating Forest LeafArea Index based on BP-Neural Networks: A Case Study from Northern Slope of Changbai Mountain [D]. Chongqing: Southwest University, 2009.[向洪波. 基于 BP 神经网络森林叶面积指数估算研究——以长白山北坡为例[D]. 重庆: 西南大学, 2009.]
- [28] Liu Jun, Meng Qingyan, Ge Xiaosan, *et al.* Leaf Area Index Inversion of Summer Maize at Multiple Growth Stages based on BP Neural Network [J]. Remote Sensing Technology and Application, 2020, 35(1):174-184.[刘俊, 孟庆岩, 葛小三, 等. 基于 BP 神经网络的夏玉米多生育期叶面积指数反演研究[J]. 遥感技术与应用, 2020, 35(1):174-184.]
- [29] Ma Yinchu, Yan Guangjian, Ding Wen, *et al.* Leaf Area Index Retrieval of Winter Wheat Using Artificial Neural Network [J]. Transactions of the CSAE, 2009, 25(12):187-192.[马茵驰, 阎广建, 丁文, 等. 基于人工神经网络方法的冬小麦叶面积指数反演[J]. 农业工程学报, 2009, 25(12): 187-192.]
- [30] Ding S, Su C, Yu J. An Optimizing BP Neural Network Algorithm based on Genetic Algorithm [J]. Artificial Intelligence Review, 2011, 36(2):153-162.
- [31] Lin Jie, Pan Ying, Yang Min, *et al.* Quantitative Inversion of Long Sequential Leaf Area Index Using Remote Sensing based on BP Neural Network from 1988 to 2013. Acta Ecologica Sinica, 2018, 38(10):3534-3542.[林杰, 潘颖, 杨敏, 等. 1988-2013 年基于 BP 神经网络的植被叶面积指数遥感定量反演[J]. 生态学报, 2018, 38(10):3534-3542.]
- [32] Lu Kun, Meng Qingyan, Sun Yunxiao, *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.[陆坤, 孟庆岩, 孙云晓, 等. 基于 GF-2 卫星数据的孕穗期小麦叶面积指数反演——以河北省廊坊市为例[J]. 国土资源遥感, 2018, 30(1):196-202.]
- [33] Kirkpatrick S, Gelatt C D, Vecchi M P. Optimization by Simulated Annealing [J]. Science, 1983, 220(4598):671-680.
- [34] Cui Yongli, Wei Jun. Application of SA Algorithm to Solving Problem of Non-linear Constraint Optimization [J]. Journal of Dalian University, 2003, 24(6):5-8.[崔永利, 魏君. SA 法在求解非线性约束优化问题中的应用[J]. 大连大学学报, 2003, 24(6):5-8.]
- [35] Lu Yanshan, Zhao Zhengqi. Optimization and Application Research of BP Neural Network [J]. Journal of Beijing University of Chemical Technology (Natural Science Edition), 2001, (1):67-69.[吕砚山, 赵正琦. BP 神经网络的优化及应用研究[J]. 北京化工大学学报(自然科学版), 2001, 28(1): 67-69.]
- [36] Liu Songqing. Research and Application on MATLAB BP Neural Network [J]. Computer Engineering and Design, 2003, 24(11):81-83, 88.[柳松青. MATLAB 神经网络 BP 网络研究与应用[J]. 计算机工程与设计, 2003, 24(11):81-83, 88.]
- [37] Yang Min, Lin Jie, Gu Zheyang, *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, 2015, 13(4):86-93.[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[J]. 中国水土保持科学, 2015, 13(4):86-93.]
- [38] Zhao X, Huang S, Xiang J, *et al.* Remote Sensing of Atmospheric Duct Parameters Using Simulated Annealing[J]. Chinese Physics B, 2011, 20(9):468-475.
- [39] Goffe W L, Ferrier G D, Rogers J. Global Optimization of Statistical Functions with Simulated Annealing[J]. Journal of Econometrics, 1994, 60(1-2):65-99.
- [40] Qi J, Chehbouni A, Huete A R, *et al.* A Modified Soil Adjusted Vegetation Index[J]. Remote Sensing of Environment, 1994, 48(2):119-126.
- [41] Zhu Xuchao, Yuan Guofu, Yi Xiaobo, *et al.* Leaf Area Index Inversion of Riparian Forest in the Lower basin of Tarim River based on Landsat 8 OLI Images[J]. Arid Land Geography, 2014, 37(6):1248-1256.[朱绪超, 袁国富, 易小波, 等. 基于Landsat 8 OLI影像的塔里木河下游河岸林叶面积指数反演[J]. 干旱区地理, 2014, 37(6):1248-1256.]

BP Neural Network based on Simulated Annealing Algorithm for High Resolution LAI Retrieval

Xue Huazhu¹, Wang Changjing^{1,2}, Zhou Hongmin², Wang Jingdi², Wan Huawei³

(1.School of Surveying & Land Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China;

2.State Key Laboratory of Remote Sensing Science, Beijing Engineering Research Center for Global Land Remote Sensing Products, Faculty of Geographical Science, BNU, Beijing 100875, China;

3.Satellite Environmental Center, Ministry of Environmental Protection, Beijing 100785, China)

Abstract: The rapid development of satellite remote sensing technology makes it possible to obtain global large-scale Leaf Area Index (LAI). However, it is difficult to estimate high-resolution LAI based on existing algorithms and data. In this paper, four typical research areas consist of three research areas for modeling validation and an independent research area for applicability validation including grassland, farmland and woodland were selected. Field data and correspondent satellite of the areas were then collected. The empirical model of NDVI vegetation index, the BP neural network model and the BP neural network based on simulated annealing algorithm were established and 30 m resolution LAI data were estimated with all models. Estimated results were validated with the Field data in three main research areas. The results indicated that NDVI empirical model has the worst accuracy in the three main research areas selected in this paper. The estimation accuracy of BP neural network model based on simulated annealing algorithm is higher than that of BP neural network model. The determinant coefficients of estimation results of farmland, grassland and woodland sites are 0.899, 0.858 and 0.863 respectively. The determinant coefficients of BP neural network model were 0.763, 0.710 and 0.742 respectively, while the determinant coefficients of NDVI empirical model were 0.622, 0.536 and 0.637 respectively. In order to verify the applicability of SA-BP neural network, an independent research area was selected for further verification. The results show that the validation accuracy is high, R^2 is 0.842 0, and RMSE is 0.689 5, which shows that the model has good extrapolation ability. This study proves that the BP neural network model based on simulated annealing algorithm improves the generalization ability of the model, effectively prevents the BP neural network model from sliding into the local minimum, and it is an effective method for LAI estimation in high spatial resolution.

Key words: Leaf Area Index(LAI); Inversion; Simulated annealing algorithm; BP neural network