

唐 俊, 赵成萍, 周新志, 等. 基于 *EVI*-RBF 的玉米长势监测及产量预测[J]. 江苏农业学报, 2020, 36( 3 ): 577-583.  
doi: 10.3969/j.issn.1000-4440.2020.03.007

## 基于 *EVI*-RBF 的玉米长势监测及产量预测

唐 俊<sup>1</sup>, 赵成萍<sup>1</sup>, 周新志<sup>1</sup>, 李 博<sup>2</sup>

(1. 四川大学电子信息学院, 四川 成都 610065; 2. 四川大学水利信息化联合实验室, 四川 成都 610065)

**摘要:** 近年来, 农作物长势监测和产量预测研究大多是通过建立复杂的生长模型来实现的, 而这往往不具有较强的推广性。本研究建立了一种基于植被指数和产量统计数据的玉米长势监测及产量预测方法。以玉米为研究对象, 利用 MODIS09A1 数据建立其 2000–2018 年的增强型植被指数 (*EVI*) 时间序列, 并将该序列作为径向基 (RBF) 神经网络的输入参数, 下一阶段的 *EVI* 值或玉米产量作为网络的输出参数, 完成玉米的长势监测及产量预测。该方法被成功应用到黑龙江省哈尔滨市宾县的玉米研究中, 对玉米 *EVI* 值的预测精度达到了 90.0% 以上, 产量预测相较于传统的线性回归模型也有明显提高, 预测精度达到了 98.6%。依赖植被指数和产量统计数据的长势监测及产量预测方法有较大的应用推广前景。

**关键词:** MODIS09A1; *EVI*-RBF; 玉米; 长势; 产量

**中图分类号:** S127; S513      **文献标识码:** A      **文章编号:** 1000-4440(2020)03-0577-07

## Maize growth monitoring and yield prediction based on *EVI*-RBF

TANG Jun<sup>1</sup>, ZHAO Cheng-ping<sup>1</sup>, ZHOU Xin-zhi<sup>1</sup>, LI Bo<sup>2</sup>

(1. Electronic Information School, Sichuan University, Chengdu 610065, China; 2. Joint Laboratory of Water Conservancy Informatization, Sichuan University, Chengdu 610065, China)

**Abstract:** In recent years, the research of maize growth monitoring and yield prediction is mostly achieved by building complex growth models, but these methods are not easy to be popularized. To overcome the problem, a method of maize growth monitoring and yield prediction was established based on vegetation index and statistical yield data. Taking maize as the research object, the enhanced vegetation index (*EVI*) time sequence from 2000 to 2018 of the maize was established by using MODIS09A1 data. Moreover, this time sequence was taken as the input parameter of radial basis function (RBF) neural network, and the values of *EVI* or maize yield in the next stage were taken as the output parameters. This method has been successfully applied to the research on maize in Binxian County, Harbin City, Heilongjiang province, with the prediction accuracy of over 90% for the value of *EVI*. Compared with the results based on conventional linear regression forecasting method, the prediction accuracy of yield based on the proposed method in this study was significantly improved. In conclusion, the method of growth monitoring and yield prediction based on vegetation index and statistical yield data has a great application prospect.

**Key words:** MODIS09A1; *EVI*-RBF; maize; growth; yield

收稿日期: 2020-01-03

基金项目: 国家自然科学基金项目 (U1933123)

作者简介: 唐 俊 (1996-), 男, 四川德阳人, 硕士研究生, 主要从事模式识别与智能系统研究。 (E-mail) 815095332@qq.com

通讯作者: 赵成萍, (E-mail) sc\_zcp@scu.edu.cn

监测作物生长状况, 预测作物产量对国家粮食安全和农业可持续发展至关重要<sup>[1]</sup>。遥感技术已被广泛用于作物生长状况监测以及产量预测研究<sup>[2]</sup>, 特别是植被指数, 如归一化差异植被指数 (*NDVI*) 已被广泛用于产量预测<sup>[3-4]</sup>。此外, 叶面积

指数( $LAI$ )<sup>[5]</sup>、增强型植被指数( $EVI$ )<sup>[6-7]</sup>、标准化差异水指数( $NDWI$ )<sup>[2]</sup>等也用于预测作物产量。长期以来,作物生长状况的信息是通过实地调查获得的,虽然这种方法调查的信息准确,但耗费了大量的时间、人力、物力,调查效率较低,而且其调查领域受到限制。随着地理空间科学技术的发展,遥感技术越来越多地应用于作物生长状况监测<sup>[8-10]</sup>。基于遥感技术的长势监测方法发展迅速,主要包括影像分类法、同期对比法、作物生长过程监测法、作物生长过程模型法等。同期对比法通过建立与作物生长密切相关的植被指数序列,结合辅助统计数据,比较历年间的差异,以达到监测长势的目的,该法简单易行,在一定时间内得到了较为广泛的应用。近年来,更多研究考虑将植被指数以外的辅助环境变量(如太阳辐射、温度、土壤湿度等)融入作物生长过程模型。Seo等<sup>[11]</sup>通过 $NDVI$ 及作物生长过程模型模拟生物量,监测作物长势。

作物产量可采用多种模型进行估算,如基于半物理遥感的作物产量模型,基于卫星指数的作物产量模型,基于相关加权的农业气象模型以及作物模拟模型。很多研究使用作物生长模型在不同尺度上进行作物长势监测和产量预测<sup>[12-16]</sup>。Parida等<sup>[17]</sup>通过建立种植面积与产量的线性回归模型,完成了产量预测。Guo等<sup>[18]</sup>通过提高样本集的精度,更准确地预测小麦生长指标和产量。Pede等<sup>[19]</sup>利用卫星衍生的地表温度推导生长度日,进而预测玉米的平均产量。Jha等<sup>[20]</sup>使用气象数据完成了水稻产量的预测。Nevavuori等<sup>[21]</sup>利用无人机获取的多光谱

数据,开发了一个基于卷积神经网络(CNN)的深度神经网络,完成了玉米产量的预测。Niedbala等<sup>[22]</sup>基于气象数据和化肥效应完成了冬小麦产量的预测。Li等<sup>[23]</sup>结合积温、 $EVI$ 及气象统计数据建立模型,完成了玉米产量的预测。Skakun等<sup>[24]</sup>利用Landsat 8和Sentinel-2数据建立冬小麦产量评估经验模型,研究反射率和各植被指数与产量的关系。农作物产量预测研究方法大致可分为改进模型、改进数据质量以及应用神经网络或机器学习等。

在每个区域建立作物生长模型是不切实际的,因为该模型需要除遥感数据以外的大量辅助数据,而这些辅助数据一般获取困难,使得该法的推广性不强。本研究拟基于 $EVI$ 时间序列和产量统计数据建立 $EVI$ -RBF模型及产量-RBF模型,其中 $EVI$ -RBF模型用于预测 $EVI$ 值,进而预测长势,而产量-RBF模型则用于预测产量,以期完成作物长势及产量的高精度预测,协助有关部门提前调控农业生产活动,实现增产增收。

## 1 材料与方法

### 1.1 研究区域概况

图1显示,研究区域位于黑龙江省中部的宾县。宾县地处松花江南岸,地跨东经 $126^{\circ}55'41''\sim 128^{\circ}19'17''$ ,北纬 $45^{\circ}30'37''\sim 46^{\circ}01'20''$ ,总面积 $3\,844.6\text{ km}^2$ ,主要作物有水稻、大豆、玉米等,其中玉米是典型的一年一熟制,4月底至5月初为玉米的播种期,9月底至10月初为玉米的收割期。

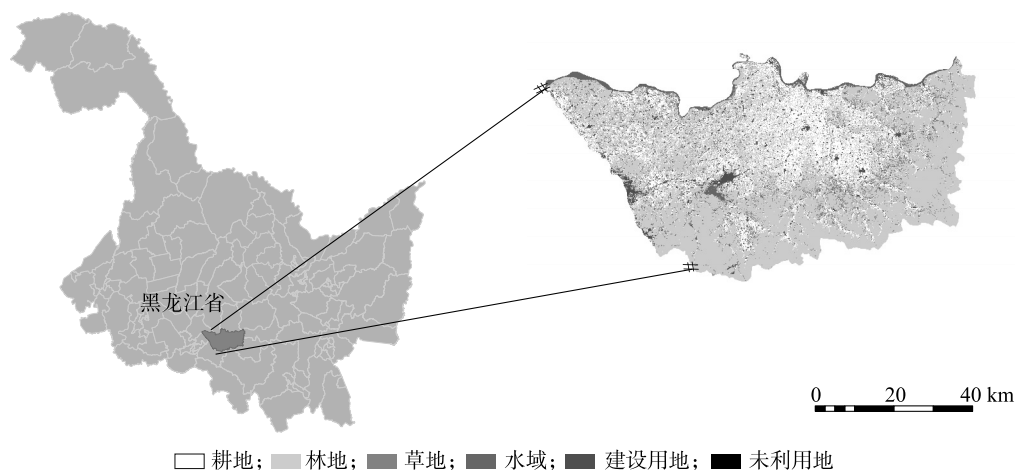


图1 研究区示意图

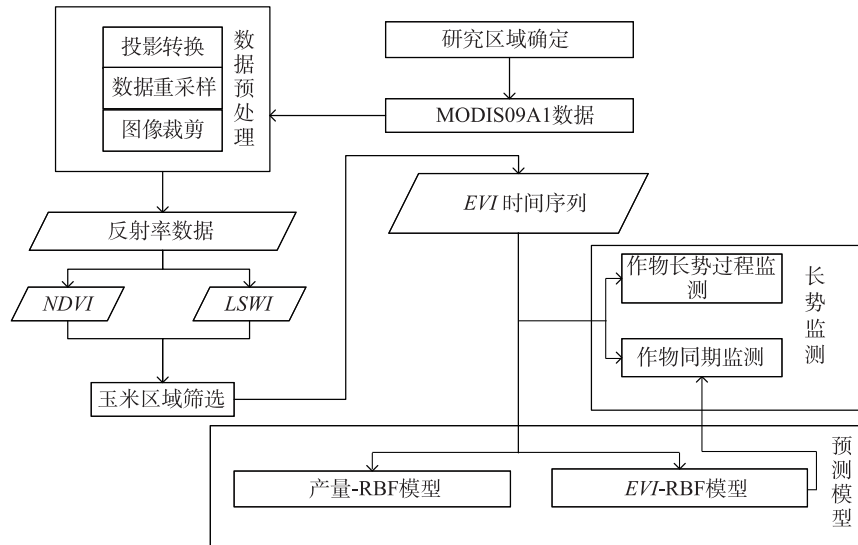
Fig.1 Map of study area

## 1.2 数据源

本研究以 Terra/Aqua 上的 MODIS 陆地三级标准数据产品-地表反射率产品 (MODIS09A1) 为主要数据源。此数据源的特点是空间分辨率适中,可免费获取,时间间隔为 8 d,包含 7 个反射率波段,其中波段1~2的空间分辨率为 250 m,波段3~7空间分辨率为 500 m。整个宾县的研究区域需要 h26v04 和 h27v04 共 2 景 MODIS 影像实现全覆盖。从美国 USGS EROS 数据中心下载了黑龙江省哈尔滨市宾县2000-2018年玉米所有生长阶段(4月23日到10月16日)的图像,并基于 Google Earth Engine 平台对 MODIS 数据进行批量拼接和裁剪工作。

## 1.3 技术路线

图2显示,本研究采用 MODIS09A1 数据,经投影转换、数据重采样和图像裁剪后,获取可用的反射率数据,再利用多时相阈值法筛选出仅包含玉米的区域,进而提取玉米的 EVI 值,并建立玉米2000-2018年的 EVI 时间序列,该序列不仅能够用于监测作物长势,还可以应用到预测模型中。在 EVI-RBF 模型中完成 EVI 值的预测,将预测的 EVI 值与同期 EVI 值进行差异比较并完成长势划分,进而实现长势的预测。同时,也可以将 EVI 时间序列输入到产量-RBF 模型中,完成玉米产量的预测。



NDVI:归一化差异植被指数;LSWI:地表水分指数;EVI:增强型植被指数;RBF:径向基。

图2 预测模型的框架

Fig.2 Framework of prediction model

1.3.1 数据预处理 MODIS09A1 数据已经经过了云筛选、大气校正及几何校正<sup>[25]</sup>,但还需要对遥感图像做如下处理:

(1)利用 ENVI 软件将下载的图像投影转换至 WGS84 坐标系。

(2)数据重采样。采用重采样精度最高的三次卷积法将 500 m 分辨率波段重采样至 250 m。

(3)图像裁剪。以宾县的行政边界为基础,利用 ArcGIS 软件导出宾县的 SHP 文件,利用此 SHP 文件对重采样后的图像进行裁剪。

(4)玉米区域筛选。利用裁剪的宾县遥感图像,结合宾县当地的种植模式,基于公式(1)、公式(2)提取的地表水分指数(LSWI)和 NDVI,采用多时

相阈值法进一步去除干扰区域。

(5)计算 EVI 值。通过公式(3)计算筛选出图像的 EVI 值,以供后续研究使用。

$$LSWI = \frac{\rho_{NIR} - \rho_{SWIR1}}{\rho_{NIR} + \rho_{SWIR1}} \quad (1)$$

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (2)$$

$$EVI = 2.5 \times \frac{\rho_{NIR} - \rho_{RED}}{1.0 + \rho_{NIR} + 6.0 \times \rho_{RED} - 7.5 \times \rho_{BLUE}} \quad (3)$$

其中, $\rho_{NIR}$ 、 $\rho_{RED}$ 、 $\rho_{BLUE}$ 、 $\rho_{SWIR1}$  分别表示近红外波段、红光波段、蓝光波段及短波红外 1 波段的反射率。

使用 MODIS09A1 数据简化了预处理过程,对每副图像数据的处理仅需要 180 s,缩短了对县级尺度

农作物长势监测的预处理时间。

**1.3.2 长势监测** 长势监测包含作物长势过程监测和作物实时监测。作物长势过程监测通过建立植被指数时间序列,形成作物生长过程的动态曲线,对比曲线的差异,分析作物的整体长势,同时结合产量的统计数据验证。作物实时监测则是通过比较历史同时段植被指数,对差异值进行分级、统计,反映作物的实时生长状况<sup>[26-27]</sup>。

本研究利用建立的 *EVI* 时间序列,通过对比研究当年、前一年、丰产年的数据,完成作物长势过程监测。在作物实时监测的基础上,不再对实时的同期图像进行差异等级划分,而是根据历史数据库同时段图像的 *EVI* 均值对作物长势进行划分,可以更直观地了解作物长势的历史差异,同时可增强后续研究工作中对 *EVI* 值预测的实际意义。

**1.3.3 预测模型** 径向基(RBF)神经网络的设计简单,并且具有良好的局部逼近性能,所以常常用于解决非线性问题<sup>[28]</sup>。图3显示,*EVI* 时间序列与作物长势、产量均存在较大联系,而这种联系往往不是线性的,故可将 *EVI* 时间序列作为径向基神经网络输入参数,产量或者 *EVI* 值作为网络输出参数,得到产量-RBF 模型和 *EVI*-RBF 模型。

## 2 结果与分析

### 2.1 作物监测

**2.1.1 作物长势过程监测** 本研究选取的主要研究时间段包含了玉米从出土到成熟的全部生长阶段<sup>[25]</sup>。将2016年的 *EVI* 曲线与2015年(丰产年)的 *EVI* 曲线及2000–2016年平均的 *EVI* 曲线分别进行对比,结果(图4)表明,2016年玉米成长初期(5月底至6月下旬)的 *EVI* 走势与2015年的 *EVI* 走势极为接近,但在玉米成熟前关键阶段(7月上旬至8月上旬)的 *EVI* 走势则略微低于2015年。2016年的 *EVI* 走势在玉米整个成熟的关键阶段(5月初至8月上旬)均优于2000–2016年平均的 *EVI* 走势。因此,预测2016年的玉米产量将略微低于2015年,但高于2000–2016年平均玉米产量。

**2.1.2 历史同期长势等级划分** 本研究在作物实时监测的基础上,不再对实时的同期图像进行差异等级划分,而是通过历史数据库同时段图像的 *EVI* 均值对作物长势进行划分。这种方式可以更直观地了解作物生长曲线走势以及历史作物长势的优劣等




图3 径向基神经网络示意图  
x:输入层神经元;c:隐含层神经元;y:输出层神经元;w:连接权值。

图3 径向基神经网络示意图

Fig.3 Schematic diagram of radial basis function neural network




图4 宾县玉米长势对比曲线图  
a:4月23日;b:5月1日;c:5月9日;d:5月17日;e:5月25日;f:6月2日;g:6月10日;h:6月18日;i:6月26日;j:7月4日;k:7月12日;l:7月20日;m:7月28日;n:8月5日;o:8月13日;p:8月21日;q:8月29日;r:9月6日;s:9月14日;t:9月22日;u:9月30日;v:10月8日;w:10月16日。

图4 宾县玉米长势对比曲线图

Fig.4 Comparison curve of maize growth in Binxian County

级,同时也可增强后续预测 *EVI* 值的实际应用价值。长势等级划分的分级标准不同<sup>[26-27]</sup>,本研究在遵循正态分布原则的基础上,将历史数据库同日期的作物长势划分为长势极差、长势差、长势正常、长势好、长势特别好共5个等级,等级1至5分别对应于 $[0, \frac{u}{4}]$ 、 $(\frac{u}{4}, \frac{u}{2}]$ 、 $(\frac{u}{2}, u]$ 、 $(u, \frac{3u}{2}]$ 、 $(\frac{3u}{2}, 1]$ ,  $u$  为历年同日期的 *EVI* 值。

表1显示,2011–2018年的玉米长势优于2000–2010年。通过历史同期比较进行长势划分,可提前初步了解当前整个研究区域的风势情况,并在此基础上结合当地苗情及作物的生长状况,实现精准监控。



2.2 预测模型

2.2.1 EVI-RBF 模型 选取 5 月 17 日至待预测日期的玉米 EVI 时间序列作为 RBF 神经网络的输入参数,基于曲线相似度判断对训练样本进行优化。

具体步骤为:计算各曲线的斜率及其标准差,选取与当前曲线斜率的标准差最接近的 5 条曲线作为 RBF 神经网络的训练样本<sup>[29]</sup>。

表 1 2000 年至 2018 年玉米长势划分  
Table 1 Division of maize growth vigor from 2000 to 2018

年份	玉米 EVI 值及长势等级									
	06-18	06-26	07-04	07-12	07-20	07-28	08-05	08-13	08-21	08-29
2000 年	0.207(1)	0.275(2)	0.386(3)	0.433(1)	0.497(1)	0.576(1)	0.569(1)	0.532(1)	0.510(1)	0.465(1)
2001 年	0.201(1)	0.246(1)	0.317(1)	0.417(1)	0.496(1)	0.632(3)	0.554(1)	0.552(2)	0.520(1)	0.506(3)
2002 年	0.264(3)	0.331(3)	0.434(3)	0.530(3)	0.629(4)	0.649(4)	0.609(3)	0.599(4)	0.545(3)	0.504(3)
2003 年	0.215(1)	0.380(4)	0.432(3)	0.475(2)	0.538(2)	0.616(3)	0.640(4)	0.575(3)	0.558(3)	0.573(5)
2004 年	0.251(3)	0.291(3)	0.372(2)	0.540(3)	0.583(3)	0.679(5)	0.616(3)	0.560(3)	0.527(2)	0.488(3)
2005 年	0.277(4)	0.346(3)	0.459(3)	0.626(5)	0.617(4)	0.615(3)	0.691(5)	0.609(4)	0.559(3)	0.515(3)
2006 年	0.207(1)	0.248(1)	0.305(1)	0.475(2)	0.530(2)	0.571(1)	0.683(5)	0.566(3)	0.551(3)	0.523(4)
2007 年	0.249(3)	0.341(3)	0.471(4)	0.586(4)	0.601(3)	0.615(3)	0.634(4)	0.564(3)	0.568(4)	0.534(4)
2008 年	0.247(3)	0.288(3)	0.530(4)	0.569(4)	0.698(5)	0.628(3)	0.698(5)	0.555(2)	0.562(4)	0.447(1)
2009 年	0.203(1)	0.217(1)	0.378(2)	0.519(3)	0.592(3)	0.630(3)	0.595(3)	0.600(4)	0.549(3)	0.524(4)
2010 年	0.287(4)	0.282(2)	0.491(4)	0.551(3)	0.673(5)	0.611(3)	0.577(2)	0.586(3)	0.600(5)	0.534(4)
2011 年	0.260(3)	0.342(3)	0.424(3)	0.591(4)	0.655(4)	0.699(5)	0.648(5)	0.615(5)	0.567(4)	0.529(4)
2012 年	0.302(5)	0.393(4)	0.568(5)	0.620(4)	0.588(3)	0.712(5)	0.592(3)	0.623(5)	0.584(5)	0.511(3)
2013 年	0.338(5)	0.444(5)	0.527(4)	0.671(5)	0.665(4)	0.671(5)	0.676(5)	0.636(5)	0.593(5)	0.533(4)
2014 年	0.349(5)	0.463(5)	0.538(4)	0.612(4)	0.679(5)	0.631(3)	0.581(2)	0.567(3)	0.520(1)	0.495(3)
2015 年	0.297(4)	0.441(5)	0.527(4)	0.558(4)	0.696(5)	0.629(3)	0.628(4)	0.584(3)	0.540(3)	0.491(3)
2016 年	0.292(4)	0.417(4)	0.529(4)	0.618(4)	0.635(4)	0.655(4)	0.626(4)	0.590(4)	0.546(3)	0.592(5)
2017 年	0.329(5)	0.493(5)	0.568(5)	0.609(4)	0.628(4)	0.627(3)	0.620(3)	0.624(5)	0.653(5)	0.552(4)
2018 年	0.305(5)	0.499(5)	0.531(4)	0.561(4)	0.627(4)	0.619(3)	0.633(4)	0.611(4)	0.576(4)	0.582(5)

括号内数值为长势等级。

将优化后训练样本输入时间段的 EVI 值乘以一定倍数(本试验中采用的倍数是 10),以此增强输入参数的差异性。RBF 神经网络模型输出参数为输入参数经过隐含层的线性求和,所以为增强模型的合理性,本试验将待预测时间段的 EVI 值乘以 100 后作为网络的输出参数,训练得到 EVI-RBF 模型。利用训练后的模型完成 EVI 预测。本研究对 2018 年 6 月 18 日至 8 月 29 日(该时间段包含玉米主要生长阶段,并且可以保证网络的输入样本维度充足)的 EVI 值进行预测。

预测误差=(预测值-实测值)/实测值

表 2 显示,EVI 值预测的整体精度在 90.0% 以上,足以指导实际的农业活动,这充分表明了利用 RBF 神经网络进行 EVI 值预测的可行性。同时,可以考虑将预测值放入历史数据库,与同期 EVI 值进行对

比,并进行长势划分,以此来预测作物长势。

表 2 2018 年玉米增强型植被指数 (EVI) 值预测结果  
Table 2 Prediction results of maize enhanced vegetation index (EVI) in 2018

日期(月-日)	EVI 实测值	EVI 预测值	预测误差
06-18	30.525	33.164	0.086
06-26	49.861	48.482	-0.028
07-04	53.074	54.945	0.035
07-12	56.082	60.965	0.087
07-20	62.730	64.088	0.022
07-28	61.891	59.514	-0.038
08-05	63.264	61.080	-0.035
08-13	61.117	58.086	-0.050
08-21	57.565	54.128	-0.060
08-29	58.150	61.601	0.059

2.2.2 产量-RBF 模型  $EVI$  平均值与对应年份的粮食产量具有较高的相关性,这表明作物长势在一定程度上反映了粮食产量<sup>[27]</sup>,故分别选取玉米主要生长期(5月17日至9月22日)的  $EVI$  均值、最大值、累计值与2000–2015 年的玉米年均产量建立线性回归模型。

利用建立的模型预测 2016 年玉米产量,结果(表 3)显示,各模型的玉米产量预测结果均存在较大误差, $EVI$  均值模型和  $EVI$  累计值模型的预测误差为 13.1%, $EVI$  最大值模型的预测误差为 24.3%。

表 3 基于线性回归模型的玉米产量预测结果

Table 3 Prediction results of maize yield by linear regression model

模型	产量实测值 (kg/hm <sup>2</sup> )	产量预测值 (kg/hm <sup>2</sup> )	预测误差
$EVI$ 均值模型	10 763.000	9 351.921	-0.131
$EVI$ 最大值模型	10 763.000	8 147.245	-0.243
$EVI$ 累计值模型	10 763.000	9 351.933	-0.131

图 5 显示,在玉米产量预测中,单个植被指数值与产量的相关度不高, $EVI$  均值和  $EVI$  累计值模型的  $R^2$  仅为 0.31, $EVI$  最大值模型的  $R^2$  为 0.29。

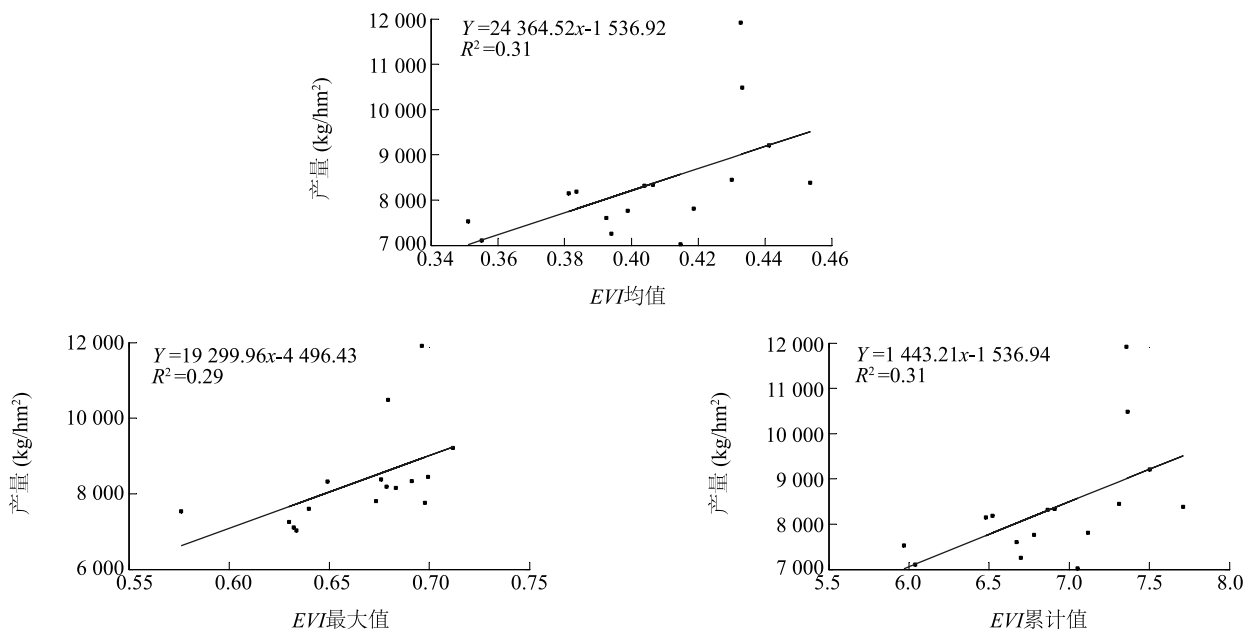


图 5 植被指数与玉米产量的回归模型

Fig.5 Regression model of vegetation index and maize yield

上述研究结果表明,单一植被指数-产量的线性回归模型的预测精度较低,故本研究引入了径向基神经网络,选取2000–2015 年的 5 月 17 日到 8 月 13 日各阶段  $EVI$  值作为 RBF 神经网络的输入参数(将  $EVI$  值乘以 10,增强输入样本差异性),市辖区的年均玉米产量作为输出参数,训练得到产量-RBF 模型,预测 2016 年的玉米产量为 10 616.173 kg/hm<sup>2</sup>,预测精度为 98.6%,优于线性回归模型。

相较于玉米  $EVI$  的均值、最大值、累计值, $EVI$  时间序列更为直观地反映了玉米的生长过程,增强了  $EVI$  与产量之间的相关性。通过分析历史数据库发现预测精度的提高主要是由于 2016 年玉米的  $EVI$  时间序列与 2015 年玉米的  $EVI$  时间序列特别相似所致。表明只要数据库的历史数据足够丰富,预测的精度就能够得到保障。

### 3 结论

本研究在玉米  $EVI$  时间序列和产量统计数据的基础上,实现了长势的过程监测、长势预测及产量预测。长势预测可结合农作物所属的生长期及苗情,准确把握作物下一阶段的长势,提前指导农业生产活动。产量预测则可提前了解当年的农业情况,并协助相关部门做出合理调控。

在本研究中,模型的建立仅仅使用了  $EVI$  时间序列,并未使用其他与玉米相关的植被指数或气象、积温等辅助数据。因此,后续研究工作可以探索如何将  $EVI$  与其他辅助数据相结合,提高模型的预测精度和稳定性。同时,遥感图像易受云层等干扰因素的影响,所以后续研究需开发有效的去云算法或高效的多元遥感数据融合算法,进而提高遥感图像的精度。

本研究模型的建立仅依赖于遥感图像和产量统计数据,简单易行,高精度的预测也可为相关农业管理部门提供可靠的农情信息,保障农业工作高效、有序地展开。

## 参考文献:

- [1] KHANAL S, FULTON J, SHEARER S. An overview of current and potential applications of thermal remote sensing in precision agriculture[J]. *Computers and Electronics in Agriculture*, 2017, 139: 22-32.
- [2] BOLTON, DOUGLAS K F, MARK A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics[J]. *Agricultural and Forest Meteorology*, 2013, 173: 74-84.
- [3] DE L, OVANDO G, BRESSANINI L, et al. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 146: 531-547.
- [4] YU B, SHANG S. Multi-year mapping of major crop yields in an irrigation district from high spatial and temporal resolution vegetation index[J]. *Sensors*, 2018, 18(11): 3787.
- [5] DUCHEMIN B, MAISONGRANDE P, BOULET G, et al. A simple algorithm for yield estimates: evaluation for semi-arid irrigated winter wheat monitored with green leaf area index[J]. *Environmental Modelling & Software*, 2008, 23(7): 876-892.
- [6] SON N T, CHEN C F, CHEN C R, et al. A comparative analysis of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation[J]. *Agricultural and Forest Meteorology*, 2014, 197: 52-64.
- [7] KOUADIO L, NEWLANDS N K, DAVIDSON A, et al. Assessing the performance of MODIS NDVI and EVI for seasonal crop yield forecasting at the ecodistrict scale[J]. *Remote Sensing*, 2014, 6(10): 10193-10214.
- [8] CHENG T, YANG Z, LNOUE Y, et al. Preface: recent advances in remote sensing for crop growth monitoring[J]. *Remote Sensing*, 2016, 8: 116.
- [9] MENG J H. Research to crop growth monitoring indicators with remote sensing[D]. Beijing: Graduate School of Chinese Academy of Sciences, 2006.
- [10] HANK T B, BACH H, MAUSER W. Using a remote sensing-supported hydro-agroecological model for field-scale simulation of heterogeneous crop growth and yield: application for wheat in central Europe[J]. *Remote Sensing*, 2015, 7(4): 3934-3965.
- [11] SEO B, LEE J, LEE K D, et al. Improving remotely-sensed crop monitoring by NDVI-based crop phenology estimators for corn and soybeans in Iowa and Illinois, USA[J]. *Field Crops Research*, 2019, 238: 113-128.
- [12] AKULA B, SHEKH A M. Field calibration and evaluation of crop simulation model, InfoCrop to estimate wheat yields[J]. *Journal of Agrometeorology*, 2005, 7(2): 199-207.
- [13] SUNEJA P, DAS D K, KALRA N. Spectral differentiation of wheat, mustard and chickpea crops grown under variable water supply situations[J]. *Climate Change and Environmental Sustainability*, 2014, 2(1): 62-66.
- [14] KRISHNAN P, SHARMA R K, DASS A, et al. Web-based crop model: Web InfoCrop-Wheat to simulate the growth and yield of wheat[J]. *Computers and Electronics in Agriculture*, 2016, 127: 324-335.
- [15] SAXANA R, BHARADWAJ V, KALRA N. Simulation of wheat yield using WTGROWS in northern India[J]. *Journal Agrometeorology*, 2006, 8(1): 87-90.
- [16] SINGH P K, SINGH K K, BAXLA A K, et al. Impact of climatic variability on wheat yield predication using DSSAT v 4.5 (CERES-wheat) model for the different agroclimatic zones in India[J]. *Climate Change Modelling, Planning and Policy for Agriculture*, 2015, 6: 45-55.
- [17] PARIDA B R, RANJAN A K. Wheat acreage mapping and yield prediction using Landsat-8 OLI satellite data: a case study in Sahibganj province, Jharkhand (India) [J]. *Remote Sensing in Earth Systems Sciences*, 2019, 2: 96-107.
- [18] GUO C, TANG Y, LU J, et al. Predicting wheat productivity: integrating time series of vegetation indices into crop modeling via sequential assimilation[J]. *Agricultural and Forest Meteorology*, 2019, 272: 69-80.
- [19] PEDE T, MOUNTRAKIS G, SHAW S B. Improving corn yield prediction across the US corn belt by replacing air temperature with daily MODIS land surface temperature[J]. *Agricultural and Forest Meteorology*, 2019, 276: 107615.
- [20] JHA P K, ATHANASIADIS P, GUALDI S, et al. Using daily data from seasonal forecasts in dynamic crop models for yield prediction: a case study for rice in Nepal's Terai[J]. *Agricultural and Forest Meteorology*, 2019, 265: 349-358.
- [21] NEVAVUORI P, NARRA N, LIPPING T. Crop yield prediction with deep convolutional neural networks[J]. *Computers and Electronics in Agriculture*, 2019, 163: 104859.
- [22] NIEDBALA G. Application of artificial neural networks for multi-criteria yield prediction of winter rapeseed [J]. *Sustainability*, 2019, 11(2): 533.
- [23] LI Y, GUAN K, YU A, et al. Toward building a transparent statistical model for improving crop yield prediction: modeling rainfed corn in the US[J]. *Field Crops Research*, 2019, 234: 55-65.
- [24] SKAKUN S, VERMOTE E, FRANCH B, et al. Winter wheat yield assessment from Landsat 8 and Sentinel-2 data: incorporating surface reflectance, through phenological fitting, into regression yield models[J]. *Remote Sensing*, 2019, 11(15): 1768.
- [25] 胡 琼. 基于时序 MODIS 影像的农作物遥感识别方法研究[D]. 北京: 中国农业科学院, 2018.
- [26] 吴炳方, 张 峰, 刘成林, 等. 农作物长势综合遥感监测方法[J]. *遥感学报*, 2004, 8(6): 498-514.
- [27] 于 堃, 王志明, 孙 玲, 等. MODIS 时序数据在县级尺度作物长势监测分析中的应用[J]. *江苏农业学报*, 2013, 29(6): 1278-1290.
- [28] 王 珏, 周健勇. 基于 RBF 神经网络对宁波地铁粉丝量的预测及广告运营模式研究[J]. *交通运输*, 2019, 5(1): 27-32.
- [29] 朱 洁. 一种新的曲线相似性判别方法研究[D]. 武汉: 武汉理工大学, 2008.

(责任编辑: 王 妮)