

## GEP 优化的多输出 RBF 网络作物生理参数建模

闵文芳, 江朝晖\*, 李婷婷, 祁 钊, 饶 元

(安徽农业大学信息与计算机学院, 合肥 230036)

**摘 要:** 针对常用的回归和神经网络作物建模方法存在的输出单一、参数优化困难和预测精度不足等问题, 利用基因表达式编程优异的全局搜索能力和 RBF 神经网络多输出任意非线性函数逼近特点, 设计了 1 种 GEP 优化的 RBF 多输出模型算法 GEP-RBF。以水稻和番茄的 5 个关键环境因子为输入、以叶片 CO<sub>2</sub> 交换率和蒸腾速率为输出, 进行建模验证。结果显示, 在预测的均方根误差指标上, GEP-RBF 模型与 GA-RBF 和 RBF 相比, 水稻的 CO<sub>2</sub> 交换率和蒸腾速率分别降低了约 28.4%、38.0% 和 89.9%、62.8%, 番茄的 CO<sub>2</sub> 交换率和蒸腾速率则分别降低了约 56.9%、48.4% 和 75.3%、67.1%; 在多输出结果的平衡性指标上, 相比 GA-RBF 和 RBF, GEP-RBF 模型提高了约 16.4%~77.4%。结果表明, GEP-RBF 模型具有良好的预测精度和多输出平衡性, 是一种有效的作物生长建模方法。

**关键词:** 作物模型; 基因表达式编程; 优化; RBF 神经网络

中图分类号: S24; TP391

文献标识码: A

文章编号: 1672-352X (2017)01-0165-06

### Multi output RBF network based on GEP optimization of modeling for crop physiological parameters

MIN Wenfang, JIANG Zhaohui, LI Tingting, QI Zhao, RAO Yuan

(School of Information and Computer, Anhui Agricultural University, Hefei 230036)

**Abstract:** In order to address such problems as single output, parameter optimization difficulties, and lack of prediction accuracy etc. in modeling and predicting for the conventional plants based on regression and neural network, A multi output RBF network based on GEP optimization was designed with the help of strong global search ability of GEP and multi output arbitrary nonlinear function approximation of RBF network. Five key environmental factors of rice and tomato served as input, leaf CO<sub>2</sub> exchange rate and transpiration rate as output, the proposed method was adopted in modeling and verifying. Experimental results showed: in view of the root mean square error, compared with GA-RBF and RBF, CO<sub>2</sub> exchange rate and transpiration rate in rice using the GEP-RBF model were reduced by ~28.4%, 38.0% and 89.9%, 62.8%, respectively, while those in tomato were reduced by ~56.9%, 48.4% and 75.3%, 67.1%, respectively; on the balance of multiple output result, compared with GA-RBF and RBF, using the GEP-RBF model could improve it by ~16.4% - 77.4%. The study indicated that the GEP-RBF model has good prediction accuracy and multi output balance, and it is an effective method for crop growth modeling.

**Key words:** crop model; gene expression programming; optimization; RBF neural network

作物与环境构成一个非常复杂的生物系统, 生长模型是精确描述作物生理参数、生态指标与环境因子之间关系的重要工具, 对于现代农作物生产管理及相关科学研究具有重要意义<sup>[1]</sup>。目前一些经典的作物模型如 TOMGRO、DSSAT 等已较为成熟, 但由于地域气候、作物生长环境品种以及研究目标

的差异, 作物模型皆具有一定针对性与适应性, 在时空上外推时存在困难, 导致应用中准确性不足、操作复杂、且难以兼容和集成等问题<sup>[2]</sup>。因此人们一方面对经典模型进行验证、修正和完善, 发展本地化版本, 提高模型的实用性<sup>[3]</sup>, 另一方面针对特定的环境、作物和研究目标, 还在不断开发经验与

收稿日期: 2016-04-29

基金项目: 农业部国际科技合作项目 (948 计划, 2015-Z44 和 2016-X34), 安徽省自然科学基金 (1508085MF110) 和安徽省科技攻关项目 (1501031102) 共同资助。

作者简介: 闵文芳, 硕士研究生。E-mail: 1192090271@qq.com

\* 通信作者: 江朝晖, 博士, 教授。E-mail: jiangzh@ahau.edu.cn

机理融合的专用作物模型<sup>[4]</sup>。

常见的作物模型构建方法一般为统计回归和神经网络(neural network, NN)。回归模型的形式简单,物理意义明确,在应用中占主导地位<sup>[5]</sup>,但由于环境及作物本体参数众多,且各参数之间具有密切的非线性关系,回归模型输出的单一目标函数具有难以精确、高效描述的弊端<sup>[6]</sup>。NN模型通过并行分布式处理和自学习方式,能够充分逼近任意复杂的非线性关系<sup>[7]</sup>,但是网络的权值、阈值和中心值等参数不易确定<sup>[8]</sup>,一般需要结合遗传算法(genetic algorithms, GA)<sup>[9]</sup>、粒子群算法<sup>[10]</sup>、经验模态分解<sup>[11]</sup>等进行优化才能获得较好的预测性能,目前还在探索新的优化方法。另外,NN可组成多输入-多输出模型,但是现有的应用大多还是单输出模式,例如基于Bp神经网络的温室番茄气孔导度的模拟<sup>[12]</sup>、基于遗传算法和RBF网络的番茄生长模型辨识<sup>[13]</sup>等。

基于当前作物建模方法的输出单一、参数优化困难和预测精度不足等缺陷,本研究将基因表达式编程(gene expression programming, GEP)和多输出RBF神经网络(radial basis function neural network)相结合进行作物建模。RBF网络具有任意非线性函数逼近特性,且无局部极小,学习收敛速度快,训练简洁<sup>[14]</sup>,而GEP综合了遗传算法和遗传编程(genetic programming, GP)二者的优点,既保持了GA遗传操作的便捷性,又拥有GP的非线性树结构,实现了利用简单编码解决复杂问题的目的,克服了结构表达策略的弊端,运算效率和优化能力更佳<sup>[15]</sup>。与回归和神经网络相比,GEP模型具有最高的预测精度和最佳的预测时效性,且算法复杂度与神经网络相当<sup>[16]</sup>。在此基础上,研究GEP优化的多输出RBF神经网络建模方法,以典型作物水稻和番茄为试验对象,针对2种重要生理参数——CO<sub>2</sub>交换率和蒸腾速率进行建模预测,并与RBF网络、GA-RBF网络比较,期望获得1种性能良好的作物建模方法,为现有研究和应用提供有益补充。

## 1 材料与方法

### 1.1 试验数据

采用PTM-48A植物生理和环境监测系统<sup>[17]</sup>,对露天种植的水稻和番茄进行连续无损监测,获得空气温度、相对湿度、光照强度、CO<sub>2</sub>浓度、空气流速、绝对湿度、大气压力、水蒸汽压亏空、露点、叶片温度、叶片CO<sub>2</sub>交换速率和蒸腾速率等数据。试验数据分为2组:对水稻的监测开始于2015年8

月1日7:30,结束于2015年8月11日18:00,监测间隔为30min,共494组数据;对番茄的监测开始于2015年7月3日12:00,结束于2015年7月15日15:45,监测时间间隔为15min,共1168组数据。由于水稻的叶片窄长、而PTM-48的叶片光合生理监测室比较大,因此需要拼接2~3片叶片进行测量。为了减小误差,在监测时取4个叶片光合生理监测室测量值的平均值作为水稻、番茄的观测样本。

### 1.2 RBF网络及GA优化

RBF神经网络是用隐单元的“基”构成隐含层空间,将输入矢量直接(即不通过权连接)映射到隐空间,当确定中心向量后,随后确定映射关系,隐含层空间到输出层空间的映射是线性的,即网络的输出是隐单元输出的线性加权和<sup>[8]</sup>,其结构如图1所示。




图1 RBF网络结构

Figure 1 The structure of RBF network

RBF网络的输入层到隐含层实现 $x \rightarrow u_j(x)$ 的非线性映射,隐含层节点的作用函数一般采用最常见的高斯函数,RBF网络隐含层第 $j$ 个节点的输出可由(1)式表示:

$$u_j = \exp \left[ -\frac{\|x_i - c_j\|^2}{2b_j^2} \right] \quad (j=1,2,\dots,h) \quad (1)$$

其中 $u_j$ 是第 $j$ 个隐含层节点的输出; $\|x_i - c_j\|$ 是欧式范数; $x_i = (x_1^i, x_2^i, \dots, x_m^i)^T$ 为第 $i$ 个输入样本; $c_j$ 是高斯函数的中心向量; $b_j$ 是高斯函数的方差; $h$ 为隐含层总节点数<sup>[18]</sup>。由图1的RBF神经网络的结构可得到网络的输出为:

$$y_k = \sum_{j=1}^h w_{jk} u_j \quad (k=1,2,\dots,n) \quad (2)$$

其中 $y_k$ 为输入样本对应网络的第 $k$ 个输出节点的实际输出; $w_{jk}$ 为隐含层到输出层的连接权值。

因为RBF算法存在要事先确定中心向量个数、

中心向量以及权值本身不易确定等缺陷,采用 GA 优化可以解决 RBF 网络随机初始化中心向量和权值的弊端,达到全局寻优和快速高效的目的。在 RBF 网络结构确定的前提下,先用 GA 优化算法确定 RBF 网络的初始中心向量和权值,然后利用 RBF 算法搜索出中心向量和权值的最优解<sup>[19]</sup>。虽然 GA 优化可以解决中心向量、权值的初始值问题,但该算法同样要预先估计中心点的个数,即需要根据先验知识来事先估计类的个数,因而也存在局限性。

### 1.3 多输出 GEP-RBF 模型

RBF 算法的关键在于中心向量  $c_j$  的确定,而在 RBF 网络确定中心向量最常用的方法是 K-均值算法,其最大的局限性是需要事先根据先验知识确定中心向量个数,因此极大地限制了 RBF 网络的应用。尽管 GA-RBF 算法优于 RBF,但仍无法确定中心向量个数以及中心向量本身,因而对整个多输出网络的收敛性、稳定性和精度均有较大的影响。为了弥补这个不足,采用一种自适应式随机搜索的 GEP 优化 RBF 算法,在 GEP 算法高效函数挖掘的基础上,引入聚类运算符,对初始染色体的簇中心进行分割和合并得到新的聚类中心<sup>[20]</sup>,以实现网络模型自主确定中心向量个数、中心向量本身以及优化 RBF 多输出网络结构。

GEP 优化 RBF 多输出模型的优越性体现在其独特的染色体编码形式和适应度计算网络上。本研究 GEP 染色体采用整数编码,每个染色体由单基因

构成,代表一个 RBF 多输出网络,而每个基因由基因头、基因尾以及附加的权值域拼接而成,其中基因头由聚类运算符组成,基因尾由随机抽取的数据集构成<sup>[21]</sup>。图 2 为一个合法的染色体结构,其中聚类运算符后的数字代表中心向量,字母代表权值。

```
0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6 7 8
U U n n U 1 2 3 4 5 6 a b c d e f g h
```

图 2 染色体示意图

Figure 2 Schematic diagram of chromosome

适应度计算网络则是将染色体解码构建多输出 RBF 网络后,分别根据各输出节点误差计算适应度  $J$ ,定义如(3)式:

$$J_k = 1 - 100 \times f_k \quad (3)$$

式中  $k$  为输出节点数,  $f_k$  为第  $k$  个输出预测误差。

GEP-RBF 模型算法的基本原理是将 RBF 的初始化中心值、权值编码表达为 K-表达树的形式,通过聚类运算得到新的 K-表达树,并将其解码构成 RBF 网络,根据样本数据输入该网络得到实际输出,然后利用多输出网络特点计算各输出适应度,将适应度值大的保留到下一代,同时用 GEP 遗传算子对染色体进行操作。随着染色体的不断进化,RBF 网络的中心向量和权值朝着使整个多输出网络总误差最小的方向逐步靠拢,从而达到优化的目的。算法结构如图 3 所示。

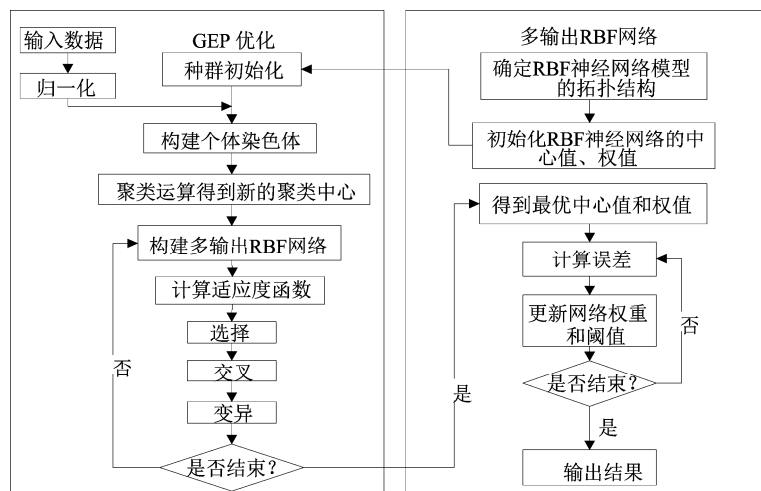


图 3 多输出 GEP-RBF 算法结构

Figure 3 The algorithm structure of multi output GEP-RBF network

根据图 3, GEP 优化的多输出 RBF 网络作物生理参数建模主要有以下 5 个步骤:

(1) 确定输入变量组合。在影响作物各生理参

数的众多环境因子中,针对多输出模型的各个输出选取影响其变化的主要环境因子组合,并将各组合取交集形成新的环境因子组合,新的环境因子组合

应包含影响输出的所有环境因子。

(2) 构建个体染色体。从权值域数组  $w$  中随机挑选若干点作为初始权值, 从数据集中随机挑选若干数据点作为初始中心向量, 采用整数编码, 构成 GEP 的个体染色体。

(3) 选择适应度函数。本研究选用针对多输出网络每个输出的基于相对误差的适应度函数。

(4) 确定遗传算子。本研究选用选择、交叉以及变异算子进行遗传操作, 更新个体染色体。

(5) 选择进化终止条件。当相对误差无限接近 0 或进化全部完成, 接受适应度最大的染色体作为最佳染色体并构建 RBF 网络结构。

对比 RBF 基本算法和 GA-RBF 算法, 理论上 GEP-RBF 算法可以获得较高的精度, 并能提高模型的鲁棒性。

#### 1.4 评价指标

为了定量比较各模型方法的优劣, 从模型的预测精度和输出结果平衡性两个方面进行评价。分别用均方根误差 RMSE (root mean square error)、平均相对误差 MAPE (mean absolute percentage error) 与残差平方和 RSS (residual sum of squares) 来反映模型的预测误差偏差、预测结果总体接近水平和拟合程度, 其计算公式分别为公式 (4)、(5)、(6) 所示; 同时自定义平衡性指标 PB (the percentage of balance) 计算公式如公式 (7), 用于综合考虑各输出的误差及其波动情况, 此值越小则表示模型的平衡性效果越好。

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - y'_i)^2}{N}} \quad (4)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y'_i} \right| \quad (5)$$

$$RSS = \sum_{i=1}^N (y_i - y'_i)^2 \quad (6)$$

$$PB = \sum_{j=1}^M MAPE_j \times \sum_{j=1}^M \left| MAPE_j - \frac{1}{M} \sum_{j=1}^M MAPE_j \right| \quad (7)$$

上述公式中  $y_i$ 、 $y'_i$ 、 $N$  以及  $M$  分别为实测值、预测值、样本数和输出节点数。

## 2 结果与分析

采用多输出 GEP-RBF 算法分别对水稻及番茄的  $CO_2$  交换率和蒸腾速率进行建模和验证, 并与 RBF、GA-RBF 模型进行性能比较。使用水稻数据集的前 8 d 数据作为训练数据, 使用后 3 d 数据作为测试数据, 而番茄使用前 9 d 数据作为训练集, 以

后 3 d 数据作为测试集。根据上述构建 GEP-RBF 模型的主要步骤, 分别选取影响  $CO_2$  交换率和蒸腾速率的主要环境变量<sup>[6, 22-23]</sup>, 确定环境因子组合为光照强度、空气温度、相对湿度、水蒸气压亏空和露点 5 个变量, 得到 3 个模型预测结果与实测值对比如图 4 和图 5 所示。其中, GEP-RBF 和 GA-RBF 的参数设置如表 1 所示。

表 1 GEP-RBF 和 GA-RBF 模型的参数设置  
Table 1 Parameters of the GEP-RBF and GA-RBF model

| 参数 Parameter           | GEP-RBF | GA-RBF |
|------------------------|---------|--------|
| 种群规模 Population size   | 20      | 10     |
| 进化代数 Evolution algebra | 50      | 50     |
| 头长 Head length         | 60      | -      |
| 交叉率 Crossover rate     | 0.4     | 0.4    |
| 变异率 Aberration rate    | 0.2     | 0.2    |

从图 4 和图 5 可明显看出  $CO_2$  交换率和蒸腾速率随着时间的推移而变化的周期性, 其中水稻的 3 d 训练数据中, 由于第 2 天突然出现阴雨天气, 导致作物的光合作用下降, 因此  $CO_2$  交换率和蒸腾速率的数值也相应降低。

图 4-A、4-B 显示了水稻叶片  $CO_2$  交换率和蒸腾速率预测结果与实测值的曲线变化, 可以直观看出 GEP-RBF 模型整体上准确性和平衡性较好, GA-RBF 模型次之, RBF 模型最差。而在一些转折点附近, GEP-RBF 多输出模型的输出 1 ( $CO_2$  交换率) 相比输出 2 (蒸腾速率) 更能在实测值变化较大的时刻迅速做出反应, 贴近实测值。观察图 4-A、4-B 前期的预测时间序列, GA-RBF 模型的预测值波动巨大, 某些预测值误差甚至高达 80%, 严重偏离预测的误差允许范围, 其原因可能是 GA-RBF 的全局搜索能力不佳, 导致在模型的多输出预测结果中, 某些预测输出序列前期效果不佳。


从图 5-A 可以观察到, RBF 模型的拟合程度远不如 GA-RBF 模型和 GEP-RBF 模型, 而 GA-RBF 模型在某些数值波动较大的转折点的反应能力也不如 GEP-RBF 模型, 说明在输出 1 ( $CO_2$  交换率) 的预测中 GEP-RBF 模型的拟合能力和反应能力都较好。观察图 5-B, GA-RBF 模型和 RBF 模型在输出 2 (蒸腾速率) 预测过程中, 约前 10 组数据波动幅度极大, 导致预测结果偏差极大; 同时可以观察到 GEP-RBF 模型的预测结果基本上维持了与实测值相同的变化趋势, 且数值接近, 因此可以验证 GEP 全局搜索能力的强大性。

综合图 5-A 和 5-B, 可以看出 GEP-RBF 模型与

另 2 种模型相比, 多输出预测结果的精度、稳定性和平衡性均有了一定的提高。

为了定量分析多输出 GEP-RBF 模型及 GA-RBF、RBF 模型的预测值与实测值之间的误差,


根据上述的评价指标, 计算并统计各评价指标的数值如表 2 和表 3 所示。



(a) CO<sub>2</sub> 交换率 CO<sub>2</sub> exchange rate; (b) 蒸腾速率 Transpiration rate

图 4 3 种模型对水稻 CO<sub>2</sub> 交换率、蒸腾速率预测结果对比

Figure 4 The prediction results of three models on CO<sub>2</sub> exchange rate and transpiration rate for rice



(a) CO<sub>2</sub> 交换率 CO<sub>2</sub> exchange rate; (b) 蒸腾速率 Transpiration rate

图 5 3 种模型对番茄 CO<sub>2</sub> 交换率、蒸腾速率预测结果对比

Figure 5 The prediction results of three models on CO<sub>2</sub> exchange rate and transpiration rate for tomato

表 2 3 种模型对水稻、番茄 CO<sub>2</sub> 交换率、蒸腾速率的预测误差对比

Table 2 The prediction error three models on CO<sub>2</sub> exchange rate and transpiration rate for rice and tomato

| 品种<br>Variety | 指标<br>Index | 输出 1 (CO <sub>2</sub> 交换率)               |         |         | 输出 2 (蒸腾速率)                   |             |             |
|---------------|-------------|--|---------|---------|-------------------------------|-------------|-------------|
|               |             | Export 1 / CO <sub>2</sub> exchange rate |         |         | Export 2 / Transpiration rate |             |             |
|               |             | GEP-RBF                                  | GA-RBF  | RBF     | GEP-RBF                       | GA-RBF      | RBF         |
| 水稻<br>Rice    | RMSE        | 0.4438                                   | 0.6200  | 0.7159  | 0.9390                        | 9.2269      | 2.5222      |
|               | MAPE        | 0.1359                                   | 0.1052  | 0.2532  | 0.6413                        | 1.1022      | 0.7304      |
|               | RSS         | 23.2403                                  | 45.3544 | 60.4831 | 104.0363                      | 1.0046e+004 | 750.6306    |
| 番茄<br>Tomato  | RMSE        | 0.2985                                   | 0.6921  | 0.5786  | 1.1337                        | 4.5864      | 3.4454      |
|               | MAPE        | 0.0741                                   | 0.1420  | 0.1329  | 0.0450                        | 0.0684      | 0.1575      |
|               | RSS         | 18.5324                                  | 99.6322 | 69.6350 | 267.3371                      | 4.3753e+003 | 2.4691e+003 |

分析表 2 数据, 对于水稻, 从整体 MAPE 和 RSS 上看, 模型的精度和拟合程度高低顺序依次是: GEP-RBF 模型、GA-RBF 模型、RBF 模型; 从 RMSE 上看, 与 GA-RBF、RBF 模型相比, GEP-RBF 模型中 CO<sub>2</sub> 交换率的 RMSE 分别降低了约 28.4%和 38.0%, 蒸腾速率分别降低了约 89.9%和 62.8%; 同

理, 对于番茄的 GEP-RBF 模型来说, 与 GA-RBF 模型、RBF 模型对比, CO<sub>2</sub> 交换率的 RMSE 分别降低了约 56.9%和 48.4%, 蒸腾速率的 RMSE 分别降低了约 75.3%和 67.1%。这表明 GEP-RBF 模型能够在一定程度上提高预测结果的准确性。

表 3 3种模型对水稻、番茄 CO<sub>2</sub> 交换率、蒸腾速率的预测结果平衡性误差对比

Table 3 Balance error of three models on CO<sub>2</sub> exchange rate and transpiration rate for rice and tomato

| 品种 Variety | GEP-RBF | GA-RBF | RBF    |
|------------|---------|--------|--------|
| 水稻 Rice    | 0.3925  | 1.2038 | 0.4694 |
| 番茄 Tomato  | 0.0035  | 0.0155 | 0.0073 |

针对水稻与番茄 2 种作物, 从各评价指标的整体数值上来看, 番茄的误差比水稻的误差小, 其原因可能是测量时存在选择的叶片生长状况不同、拼接存在缝隙等问题。

从表 3 中可以看出, GA-RBF 模型平衡性最差, RBF 模型次之, GEP-RBF 模型最优, 提高了约 16.4%~77.4%, 这源于本研究 GEP-RBF 多输出结构中单独计算各输出节点适应度函数的特点, 使得 GEP-RBF 模型可以更好地找出各输出结构内在的趋势和规律, 从而更好的在保证准确度的同时追求各输出结果平衡, 也同样验证了 GEP 的全局搜索能力。

### 3 讨论

在分析了 RBF 神经网络不足之处的基础上, 利用 GEP 强大的全局搜索能力, 设计了 GEP 优化的 RBF 多输出模型算法, 以水稻、番茄的 CO<sub>2</sub> 交换率和蒸腾速率为对象进行建模验证, 并与 RBF 模型、GA-RBF 模型进行性能比较。试验结果显示: (1) GEP-RBF 算法可同时获得多个目标模型, 提高了作物建模的效率; (2) GEP-RBF 多输出模型具有较高的预测精度; (3) GEP-RBF 多输出模型采用分开计算各输出目标适应度值的方法, 克服了 RBF 和 GA-RBF 算法各输出结果不平衡的缺点。

本研究设计的 GEP 优化多输出 RBF 模型算法在一定程度上存在以牺牲时间、空间复杂度为代价, 提高预测精度、平衡性等性能。在今后研究中, 将对本研究方法继续改进, 包括对 GEP 优化算法改良、增加作物品种和试验数据量、对原始数据进行预处理、提高运算速度等, 可望进一步提高模型性能, 争取在实践中应用推广。

### 参考文献:

- [1] RODRÍGUEZ F, BERENGUEL M, GUZMÁN J L, et al. Modeling and control of greenhouse crop growth[M]. London: Springer, 2015.
- [2] 王文佳, 冯浩. 国外主要作物模型研究进展与存在问题[J]. 节水灌溉, 2012(8): 63-68.
- [3] LUO Y, GUO W. Development and problems of crop models[J]. Trans Chinese Soc Agric Eng, 2008, 24(5): 307-312.
- [4] 曹宏鑫, 赵锁劳, 葛道阔, 等. 作物模型发展探讨[J]. 中国农业科学, 2011, 44(17): 3520-3528.
- [5] JIANG Z H, ZHANG J, YANG C H, et al. Performance of classic multiple factor analysis and model fitting in crop modeling[J]. Int J Agr Biol Eng, 2016, 9(2): 119-126.
- [6] 张静. 小样本数据作物模型研究[D]. 合肥: 安徽农业大学, 2015.
- [7] 许童羽, 王泷, 张晓博, 等. RBF 神经网络在北方日光温室湿度模拟预测中的应用[J]. 沈阳农业大学学报, 2014, 45(6): 726-730.
- [8] 张德丰. MATLAB 神经网络应用设计[M]. 北京: 机械工业出版社, 2009.
- [9] 冯禹, 王守光, 崔宁博, 等. 基于遗传算法优化神经网络的参考作物蒸散量预测模型[J]. 资源科学, 2014, 36(12): 2624-2630.
- [10] 刘坤, 谭营, 何新贵. 基于粒子群优化的过程神经网络学习算法[J]. 北京大学学报(自然科学版), 2011, 47(2): 238-244.
- [11] 迟道才, 郑俊林, 许杏娟, 等. 基于经验模态分解与人工神经网络的参考作物腾发量混合预测模型研究[J]. 沈阳农业大学学报, 2015, 46(1): 67-73.
- [12] 杨再强, 黄川容, 费玉娟, 等. 基于 Bp 神经网络的温室番茄气孔导度的模拟研究[J]. 东北农业大学学报, 2011, 42(11): 70-77.
- [13] 张娟, 陈杰, 王珊珊. 基于遗传算法和 RBF 网络的番茄生长模型辨识[J]. 控制与决策, 2005, 20(6): 682-685.
- [14] HUANG G B, SARATCHANDRAN P, SUNDARARAJAN N. A generalized growing and pruning RBF (GGAP-RBF) neural network for function approximation[J]. IEEE T Neural Networ, 2005, 16(1): 57-67.
- [15] FERREIRA C. Gene expression programming: a new adaptive algorithm for solving problems[J]. Complex Syst, 2001, 13(2): 87-129.
- [16] 李婷婷, 江朝晖, 闵文芳, 等. 基于基因表达式编程的番茄叶片 CO<sub>2</sub> 交换率建模与预测[J]. 浙江农业学报, 2016, 28(9): 1616-1623.
- [17] JIANG Z H, WANG C S, ZHANG J, et al. Online monitoring and analysis of plant photosynthetic physiology and environmental factors[C]//Applied mechanics and materials. Trans Tech Publications, 2013, 241: 75-80.
- [18] 周维华. RBF 神经网络隐层结构与参数优化研究[D]. 广州: 华东理工大学, 2014.
- [19] 王宏刚, 钱锋. 基于遗传算法的前向神经网络结构优化[J]. 控制工程, 2007, 14(4): 387-390.
- [20] 古凌岚. 基于 GEP-RBF 的协同过滤数据稀疏性问题研究[J]. 计算机与数字工程, 2013, 41(9): 1433-1436.
- [21] 元昌安, 彭昱忠, 覃晓, 等. 基因表达式编程算法原理与应用[M]. 北京: 科学出版社, 2010.
- [22] 王升, 陈洪松, 聂云鹏, 等. 基于基因表达式编程算法的参考作物腾发量模拟计算[J]. 农业机械学报, 2015, 46(4): 106-112.
- [23] 王升, 付智勇, 陈洪松, 等. 基于 GEP 和地理位置信息的湘鄂地区月参考作物腾发量模拟计算[J]. 中国生态农业学报, 2015, 23(4): 490-496.