

基于模型辨识的 BP 神经网络在光伏系统 MPPT 中的应用

胡桂廷, 仲程超, 张伟君, 张正江

(温州大学 电气数字化设计技术国家地方联合工程实验室, 浙江 温州 325035)

摘要: 光伏电池作为光伏发电系统的重要组成部分, 研究其模型的准确性并对其最大功率点进行预测与跟踪, 对于光伏发电效率的提高具有重大意义; 首先根据光伏电池的内部结构和伏安特性建立其数学模型, 并对所建立的模型进行参数辨识, 进而得到模型输出与测量信息偏差最小的参数值, 验证模型的准确和有效性; 根据模型所反映的规律, 将温度和光照强度作为输入变量, 最大功率点对应的电压作为输出变量, 构建了用于 MPPT 的神经网络模型; 神经网络经训练后对最大功率点电压进行预测与跟踪, 结果表明构建的神经网络具有良好的适应性。

关键词: 光伏电池; 数学模型; 参数辨识; 最大功率点; 神经网络

Application of BP Neural Network Based on Model Identification in Photovoltaic System MPPT

Hu Guiting, Zhong Chengchao, Zhang Weijun, Zhang Zhengjiang

(National-Local Joint Engineering Laboratory of Electrical Digital Design Technology, Wenzhou University, Wenzhou 325035, China)

Abstract: Photovoltaic cell is an important part of photovoltaic power generation system. It is of great significance to study the accurate model of photovoltaic cell and to predict and track the MPP (maximum power point). Firstly, according to the internal structure and the I-V characteristics of photovoltaic cell, the mathematical model is established. The parameters of the model can be identified by searching the minimum deviations between outputs of the identified model and actual measurement information, and the accuracy and validity of the model can be verified. According to the law of the PV model, the temperature and illumination are considered as the input variables, and the corresponding voltage of MPP is used as the output variables, a neural network model for MPPT is constructed. The neural network is trained to predict and track the voltage of MPP. The results show that the neural network has good adaptability.

Keywords: Photovoltaic cell; mathematical model; parameter identification; maximum power point; neural network

0 引言

随着传统能源的不断消耗和环境污染问题的日益突出, 清洁、可再生的太阳能越来越受到人们的重视。但目前太阳能光伏发电系统仍存在一些问題, 如造价成本高, 发电效率低, 且其实际输出功率随光照强度、环境温度等因素的变化而变化。为最大限度地利用光伏电池所产生的功率, 需要对太阳能电池板的最大功率点进行跟踪。

目前国内外学者常用的最大功率点跟踪的方法有恒压法^[1]、电导增量法^[2-3]、扰动观察法等^[4], 但是针对恒压法, 跟踪精度较低且不能适应环境的改变; 对于电导增量法, 对硬件要求较高, 算法实现复杂; 而扰动观察法不能判定何时到达

MPP, 存在震荡现象。吴雨薇等针对传统的定步长扰动观察法跟踪存在的不足, 提出了一种新的变步长方法^[5]。翟小军等人则将粒子群算法与电导增量法相结合^[6], 在减小震荡功率的同时, 提高了跟踪的精度。随着神经网络理论的应用不断发展, 其非线性映射以及强大的自学习能力引起了越来越多的学者关注。Gupta 等通过对光伏特性的研究, 建立 NN 模型, 实现了对光伏发电系统最大功率点的良好跟踪^[7]。阳同光等针对光伏发电的扰动问题, 提出了一种基于神经网络反推控制技术的最大功率点跟踪方法^[8]。谢维等针对光伏发电系统 MPPT 问题, 提出了一种人工神经网络与模糊控制技术相结合的方案^[9]。Kassem 等在太阳能光伏水泵系统中, 基于神经网络设计的控制器实现了对 MPPT 有效跟踪, 从而优化系统的效率^[10]。本文提出采用基于参数辨识后准确数学模型来产生数据, 采用模型产生的数据建立神经网络的方法。基于 50 KW 光伏并网系统实验测试数据, 将提出的方法应用于最大功率点的预测与跟踪上。结果表明, 该方法能快速跟踪光伏电池的最大功率点, 有效适应外界环境变化, 具有较好的控制精度和稳定性。

1 光伏电池数学模型的建立

根据太阳能电池板的内部结构和输出伏安特性得到光伏电

收稿日期: 2017-03-29; 修回日期: 2017-04-18。

基金项目: 国家自然科学基金项目(51207112); 浙江省科技计划项目(2015C31157; 2014C31074; 2014C31093); 浙江省大学生科技创新活动计划暨新苗人才计划(2015R426059)。

作者简介: 胡桂廷(1996-), 男, 山东曲阜人, 大学生, 主要从事最大功率点跟踪技术方向的研究。

张正江(1982-), 男, 江西乐平人, 博士, 副教授, 硕士研究生导师, 主要从事光伏发电系统建模与控制方向的研究。

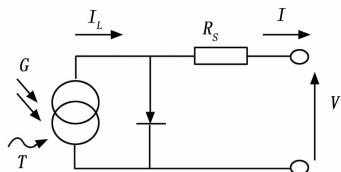


图 1 光伏电池等效电路图

池的等效电路如图 1，它由一个与二极管并联的电流源外加一个串联电阻组成，电流源的输出受光照强度和温度影响。光伏电池等效电路中，二极管品质因数影响光伏电池模型的输出特性。可通过依次增加光伏电池数学模型中的参数个数，来增加光伏阵列的复杂性与准确性。根据二极管的特性及基尔霍夫电流定律可得：

$$I = I_L - I_O(e^{q(V+IR_S)/nkT} - 1) \quad (1)$$

其中： I 为光伏电池输出电流； I_L 为光生电流； I_O 为二极管饱和电流； q 是电子电荷，其值为 $1.6029 \times 10^{-19} \text{ C}$ ； V 是光伏电池板的电压； R_S 为串联电阻； K 是玻尔兹曼常数，其值为 $1.3819 \times 10^{-23} \text{ J/K}$ ； n 是二极管的品质因数； T 是光伏电池板温度；

当电池短路时，可以忽略流向二极管的电流。以下表达式可以求出电池在温度为 T 、光照强度为 G 时的电池参数：

$$I_L = I_{L(T_1)}(1 + K_O(T - T_1)) \quad (2)$$

$$I_{L(T_1)} = G * I_{SC(T_1, nmm)} / G_{(nmm)} \quad (3)$$

$$K_O = (I_{SC(T_2)} - I_{SC(T_1)}) / (T_2 - T_1) \quad (4)$$

$$I_O = I_{O(T_1)} * (T/T_1)^{3/n} * e^{-qV_g/nk * (1/T - 1/T_1)} \quad (5)$$

$$I_{O(T_1)} = I_{SC(T_1)} / (e^{qV_{OC(T_1)}/nkT_1} - 1) \quad (6)$$

$$R_S = -dV/dI_{V_{OC}} - 1/X_V \quad (7)$$

$$X_V = I_{O(T_1)} * q/nkT_1 * e^{qV_{OC(T_1)}/nkT_1} \quad (8)$$

式中， $T_1 = 25 \text{ }^\circ\text{C}$ ； I_{SC} 为短路电流； $G_{nmm} = 1 \text{ sun} = 1000 \text{ w/m}^2$ ； $T_2 = 75 \text{ }^\circ\text{C}$ ； V_g 为带隙电压； V_{oc} 为开路电压；

由上面的光伏模组的数学模型建立 Matlab 下的仿真模型，光伏电池的最大输出功率主要受温度 T 和照度 G 的影响，且呈非线性状态。根据所建立的模型，分析不同温度 T 和照度 G 对光伏电池输出电流的影响，并计算出最大输出功率点和对应的输出电压值。

2 参数辨识

为了使由模型计算得到的数值结果能与实验测试数据相一致，需要对所建立的数学模型进行参数辨识，从而实现理论模型与实际对象的匹配。参数辨识是根据实验测试数据和建立的模型来确定一组参数值，使得由模型计算得到的数值结果能最好的拟合测试数据，它是一个逆向求解的过程，同时参数估计的好坏也决定了用模型来解释实际问题的可信度。参数辨识框架如图 2 所示，其原理就是通过调整辨识模型的参数使测试数据与模型输出之间的偏差 e 达到最小，在辨识过程中光伏电池数学模型用作参数化模型，将未知系统的输入输出状态 u, y 看作实验测试所得样本数据，以 e 的取值作为网络训练的目标，通过一定的辨识算法来训练网络，使 e 足够小，就可以达到辨识模型参数的目的。

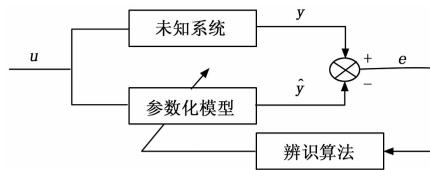


图 2 参数辨识框架

本文将光伏电池的数学模型作为参数辨识问题的非线性约束，当光伏发电系统实际测量信息只有输出电压和输出电流时，构造参数辨识问题如下：

$$\min f_{obj} = \sum_{i=1}^N \left(\frac{V_i - V_i^m}{\sigma_V} \right)^2 + \left(\frac{I_i - I_i^m}{\sigma_I} \right)^2 \quad (9)$$

$$\begin{cases} I = I_L - I_O(e^{q(V+IR_S)/nkT} - 1) \\ I_L = I_{L(T_1)}(1 + K_O(T - T_1)) \\ I_{L(T_1)} = G * I_{SC(T_1, nmm)} / G_{(nmm)} \\ K_O = (I_{SC(T_2)} - I_{SC(T_1)}) / (T_2 - T_1) \\ I_O = I_{O(T_1)} * (T/T_1)^{3/n} * e^{-qV_g/nk * (1/T - 1/T_1)} \\ I_{O(T_1)} = I_{SC(T_1)} / (e^{qV_{OC(T_1)}/nkT_1} - 1) \\ R_S = -dV/dI_{V_{OC}} - 1/X_V \\ X_V = I_{O(T_1)} * q/nkT_1 * e^{qV_{OC(T_1)}/nkT_1} \end{cases} \quad (10)$$

$$i=1, 2, \dots, N$$

其中： V_i 为模型的电压输出值， V_i^m 为输出电压的测量值， I_i 为模型的电流输出值， I_i^m 为输出电流的测量值。 σ_v, σ_i 分别为输出电压和电流的权重。 n 和 R_s 作为模型待辨识的参数，根据给定的测量信息，包括输出电压、输出电流、太阳能电池板结温以及光照度，通过序列二次规划方法优化求解出与实际光伏电池特性相一致的最优辨识参数 n 和 R_s 。经辨识后所得输出电压值和输出电流值与实验测试数据相一致或误差较小，结果表明所建立的光伏电池数学模型可以对实际对象进行准确的模拟。在实际中，利用数学模型对最大功率点进行预测存在过程复杂且不能进行实时预测等问题。故考虑引入神经网络，采用经参数辨识后的数学模型产生的数据，建立与之近似等效的 NN 模型，对最大功率点的电压进行预测与追踪，最大功率点的电压分布与温度和照度的关系如图 3 所示。由图可知温度和照度的改变会直接影响最大功率点的变化。因此，NN 模型可将温度和照度作为输入变量，最大功率点的电压作为输出变量。

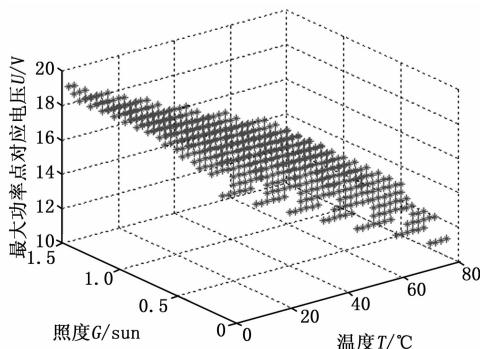


图 3 最大功率点电压分布曲线

3 BP 神经网络

3.1 BP 神经网络的拓扑结构

BP 学习算法的本质是对各连接权值进行动态调整使网络总误差最小, 即采用梯度搜索技术, 以期望输出值为目标不断地修正各层单元的权值使输出的误差减少到可接受的程度, 从而得到偏差最小的一组最优权值系数。其网络学习过程是一种误差边向后传播边修正权系数的过程。BP 神经网络特别适合非线性特征的拟合, 通过多层神经网络系统, 可精确地拟合光伏非线性模型。图 4 为本文设计的 BP 神经网络拓扑结构图, 在设计中, 神经网络的结构选用经典的 3 层结构, 即输入层、隐含层、输出层。其中输入层有 2 层, 隐含层有 5 层, 输出层有 1 层。输入层结点由照度与温度两个结点构成, 输出层结点为最大功率点的输出电压。

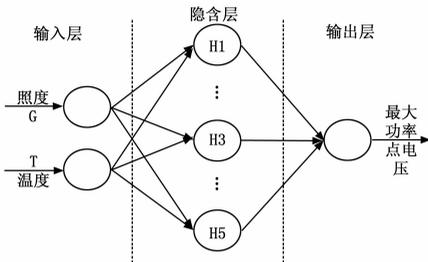


图 4 BP 神经网络的拓扑结构图

隐含层的节点数选择非常重要, 隐含层节点数太少, 网络将不能建立复杂的映射关系, 使网络培训效果较差, 容错性不理想; 节点数过多, 又使网络学习时间过长, 误差也不一定最小。因此, BP 神经网络应有一个最佳隐含层节点数。本文根据经验式^[1]得到可供选择的结点个数为范围, 然后通过多次实验确定最合适的隐含层节点数为 5 个。

3.2 BP 神经网络的学习过程

神经网络能够通过反向学习训练, 不断改变网络的连接权值以及拓扑结构, 使网络的输出值不断地接近期望的输出, BP 算法沿着误差函数减小最快的方向调整权值和偏差。在学习阶段, 训练样本集为 $X = [x_1, x_2, \dots, x_m]$, 期望响应为 $D = [d_1, d_2, \dots, d_m]$, 实际输出为 $Y = [y_1, y_2, \dots, y_m]$, 则隐含层的第 j 个神经元的输入为:

$$net_j = \sum_{i=1}^n w_{ij} x_i - \theta_j^1 \quad (11)$$

式中, n 是输入层神经元个数; w_{ij} 是输入层第 i 个神经元到隐含层第 j 个神经元的连接权值; θ_j^1 是隐含层第 j 个神经元的阈值; 隐含层第 j 个神经元的输出为:

$$o_j = f\left(\sum_{i=1}^n w_{ij} x_i - \theta_j^1\right) \quad (12)$$

式中, $f(\cdot)$ 为隐含层的激励函数。

输出层的第 r 个神经元输出值, 即网络的输出为:

$$y_r = \sum_{j=1}^k w_{jr} o_j + \theta_r^2 \quad (13)$$

式中, k 为隐含层节点个数; w_{jr} 是隐含层第 j 个神经元到输出层第 r 个神经元的连接权值; θ_r^2 是输出层第 r 个神经元的阈值。

若对于每一样本输入模式的二次型误差函数为:

$$e = \frac{1}{2} \sum_{o=1}^p (d_r - y_r)^2 \quad (14)$$

则系统对所有 N 个训练样本的总误差函数为:

$$E = \frac{1}{2m} \sum_{q=1}^m \sum_{o=1}^p (d_r - y_r)^2 \quad (15)$$

输出层的任意神经元 k 在样本作用时的加权系数增量公式为:

$$W_{jr}^{N+1} = W_{jr}^N + \eta \delta_k^1 o_k \quad (16)$$

δ_k^1 为误差函数对输出层各神经元的偏导数。

隐含层的任意神经元 k 在样本作用时的加权系数增量公式为:

$$W_{ij}^{N+1} = W_{ij}^N + \eta \delta_k^2 x_k \quad (17)$$

δ_k^2 为误差函数对隐含层各神经元的偏导数。

从光伏模型可知, 如果温度 T 和光照强度 G 已知, 就可确定最大功率点电压。本文在设计 BP 神经网络时, 从小到大地改变光照强度与光伏电池板温度, 通过参数辨识后的模型得到一系列不同光照强度与光伏电池板温度下模型的输出电压与输出电流数据。使用产生的温度 T 、 G 和最大功率点对应电压, 通过理论样本的训练, 最后达到误差收敛, 从而使输出得到期望的最大功率电压。该算法能在短时间的训练下使模型逼近最大功率点电压, 从而可显著提高跟踪的响应速度和精度。

4 仿真

4.1 仿真过程的实现

本仿真的样本数据是通过建立的光伏电池模型在不同照度与光伏电池板温度下运行得到的。根据光伏电池的实际工作环境, 光伏电池板采用的温度范围和照度范围分别为 $0 \sim 80^\circ\text{C}$ 和 $0 \sim 1\,500\text{ w/m}^2$ 。本文采用 MATLAB 的神经网络工具箱进行仿真, 具体仿真步骤如下:

1) 数据的采集及处理: 采用温度 T 、光照强度 G 和它们对应的最大功率点的电压作为初始样本数据。本仿真样本数据为 500 组, 其中训练数据随机选取 400 组, 预测数据为剩余的 100 组。由于温度和光照强度的数值变化范围较大, 为了避免奇异样本的出现, 先要对数据进行归一化处理。这里选用 `premnmx` 函数, 将数据归一到 $[-1, 1]$ 。因为在训练网络时所用数据是经过归一化的样本数据, 那么以后使用网络时所用的新数据也应该和样本数据接受相同的预处理, 这就要用到 `trannmx` 函数将数据进行处理, 然后输出结果需用函数 `postmnmx` 还原。

2) 建立 BP 神经网络: 选择隐含层和输出层神经元传递函数分别为 `tansig` 和 `purelin`, 网络算法采用 Levenberg-Marquardt 算法 `trainlm`。学习函数为 `learngdm`, 性能函数为 `msereg` (即 LS, 最小二乘)。

3) 训练参数设置: 在网络进行训练之前, 需要设置训练参数, 设学习率为 0.01, 训练最大迭代次数为 100, 训练要求精度为 0.001, 其余参数使用缺省值。

4) 网络测试: 对训练好的网络进行检测, 绘制网络输出曲线, 并与原始数据曲线进行比较。

5) 性能误差分析。

4.2 仿真结果与分析

本仿真实验的输入节点数为两个，输出节点数为 1 个。且网络经训练后可近似达到预定的精度要求，从训练过程曲线来看，网络的训练速度较快，经过几十次循环迭代就可达到最佳状态。

图 5~图 7 是训练后得到的图形。其中图 5 是最大输出功率点处的预测电压值，从图中可看出，得到的预测曲线和原始数据的非线性曲线很接近，说明经过训练后，神经网络对最大功率点电压有很好的跟踪效应。图 6 和图 7 分别为电压预测输出误差和相对误差图，通过误差分析可以反映出预测的准确性。从图中可以看出，基于最小二乘学习算法神经网络的电压预测误差分布在 0 左右，相对误差在 4% 以内。仿真结果表明，该文设计 BP 神经网络可以对光伏电池的最大输出功率点的电压实施预测与跟踪，具有很好的自适应能力。

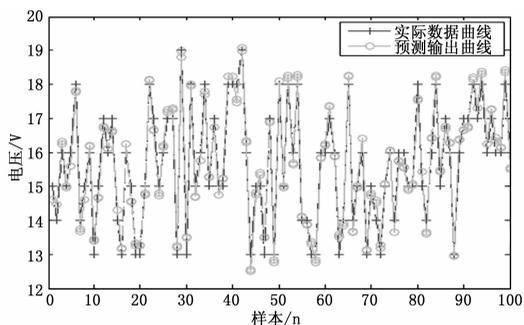


图 5 电压预测输出

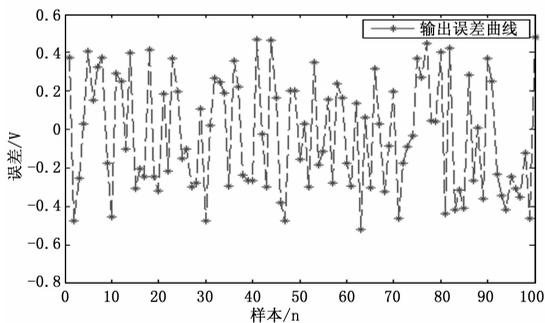


图 6 电压预测输出误差

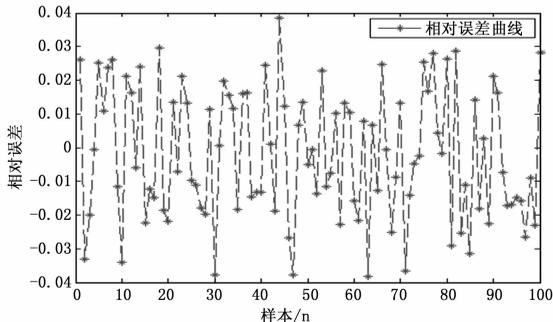


图 7 电压预测相对误差

5 实验验证与分析

上述从理论和仿真说明了神经网络方法的有效性后，将此方法应用到实验室 50 kW 光伏并网系统的实验测试中。根据

串联电流相等，电压相加，并联电压相等，电流相加的原则对所建立的数学模型做适当调整，经参数辨识后得到准确的光伏阵列模型，采用与实际过程相一致的模型产生的数据，建立实际最大功率点电压预测的神经网络模型。在神经网络的参数设置中，隐含层节点个数的多少对网络性能的影响较大，节点数过多会增加运算量，使得训练所需的时间较长，甚至不能收敛；而当节点数过少时，网络的容错能力下降，训练所需的次数也会增多。学习率影响着网络收敛的速度及其效果，学习率设置偏小可以保证网络收敛，但是收敛较慢；相反，学习率设置偏大则有可能使网络振荡或发散，影响识别效果。经调试后确定本次训练隐含层节点个数为 5 个，学习率设置为 0.01。神经网络经训练后，随机选取 30 组光伏电池板实测数据导入建立的神经网络进行预测，所得结果如下：

由图 8 和图 9 可知建立的神经网络对实测数据有良好的跟踪效应，只在个别样本点处偏差值较大，产生原因为该样本点对应的测试数据偏离于整体样本测试数据。然而整体上来看，预测相对误差都控制在 10% 范围内，大部分样本点的预测相对误差都落在 4% 以内。说明基于辨识后的数学模型所设计的 BP 神经网络具有很好的自适应能力，可以实现对最大功率点电压的预测与跟踪。

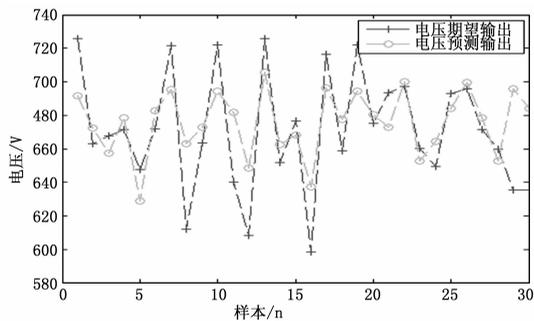


图 8 电压预测输出（实例）

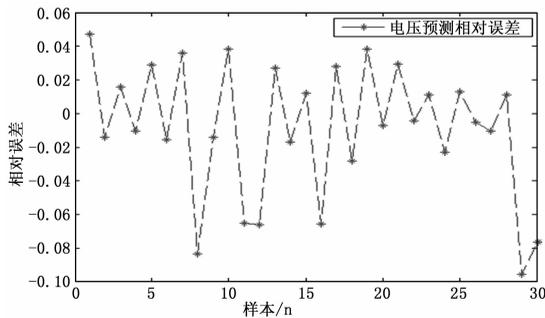


图 9 电压预测相对误差（实例）

6 结论

本文提出了一种采用参数辨识后光伏电池数学模型产生的数据构建 BP 神经网络方法并将其用于光伏最大功率点的电压跟踪。该方法能很好地解决光伏发电的非线性问题，通过对大量太阳能光照、温度及其输出电压样本数据的处理和学习，就可较为准确的预测最大功率点的输出电压。仿真与实验结果显示了方法的有效性与实用性。

（下转第 266 页）

壤各养分的综合指数和养分等级。土壤各养分的综合指数是以专业数据和历史资料为参考,根据土壤中各养分的特点及其在土壤肥力构成中的重要性,先计算出土壤养分各参评指标的权重值(计算得出有机质的权重为 0.3,碱解氮(N)、速效磷(P)、速效钾(K)的权重分别为 0.25, 0.25 和 0.2),再通过加法模型: $I = \sum F_i \times W_i (i=1,2,3,\dots,n)$,计算出土壤各养分的综合指数。其中 I 代表地块养分综合指数, F_i 表示第 i 个指标的评分值, W_i 表示第 i 个指标的权重。土壤养分等级是依据“土壤养分等级划分规则”制定的,对于不同综合指数的养分可以分为极高、高、中、低、极低 5 个等级。土壤综合肥力评价的试验效果如图 5 所示。

4.2.3 配方施肥决策功能

该功能是以养分丰缺指标法、肥料效应函数法和养分平衡法为基础,结合测土施肥技术而得出的施肥决策。

养分丰缺指标法是将土壤养分测试结果和田间肥效试验的结果相结合,通过分析建立某区域、某作物的土壤养分丰缺指标,根据田间肥效试验的施肥效应规则设计的施肥推荐,其直感性强,简捷方便,但精确度较差。

肥料效应函数法是建立在田间试验和生物统计基础上的计量施肥方法,其精确度较高,贴切实际情况,但地区局限性强,费工费时。

养分平衡法也叫目标产量法,是以计算作物达到目标产量的养分需求量和土壤实际供养量之间的差值来计算施肥量的。其概念清晰,计算方便,但精确度受各个参数的影响较大,准确度难以控制。



图 5 综合肥力评价试验效果



图 6 养分丰缺指标法决策试验效果图

用户可以自行选择 3 种方法之一进行施肥推荐。养分丰缺指标法决策试验效果如图 6 所示。

4.2.4 其他功能

用户通过输入作物的缺素症状,使用模糊搜索和精准搜索,就可判断出作物的缺素种类并给出施肥意见。

5 试验结果与分析

试验表明,本文所设计的系统能对土壤数据的采集、方便管理土壤信息、农作物信息和施肥信息,能提供较准确的种植方案与施肥方案,在提高农作物经济收益方面有一定的应用前景。

参考文献:

- [1] 李莎莎,朱一鸣. 测土配方施肥技术推广对农户过量施肥风险认知影响分析 [J]. 农林经济管理学报, 2017, 16 (1): 65-73.
- [2] 宋艳茹. 测土配方施肥技术的推广与应用探讨 [J]. 中国农业信息快讯, 2014, (7S): 55-55.
- [3] 贾生尧. 基于光谱分析技术的土壤养分检测方法与仪器研究 [D]. 杭州: 浙江大学, 2015.
- [4] 左现刚,刘艳昌,王建平. 基于 Arduino 和 VI 的农田信息无线采集系统设计 [J]. 农机化研究, 2016 (2): 213-217.
- [5] 杨海钢,孙嘉斌,王慰. FPGA 器件设计技术发展综述 [J]. 电子与信息学报, 2010, 32 (3): 714-727.
- [6] 喻旋,张东旭,付文卓. 基于 SHT11 传感器的温湿度测量系统设计 [J]. 电子科技, 2014, 27 (6): 121-125.
- [7] 王海波. 海水淡化用 pH 及电导率在线检测系统研究 [D]. 杭州: 杭州电子科技大学, 2011.
- [8] 廖斯达,贾志军,马洪运,等. 电化学基础 (II) ——热力学平衡与能斯特方程及其应用 [J]. 储能科学与技术, 2013, 2 (1): 63-68.
- [9] 白旭,胡辉,李万军,等. 基于 ADS7945 的微弱信号采集系统 [J]. 北华航天工业学院学报, 2015, 25 (5): 15-18.
- [10] 岳洋,兰国辉,周红进. 基于 SIM300 和 CC1010 的无线数据采集监控系统 [J]. 化工自动化及仪表, 2016, 43 (2): 215-217.
- [11] 任周桥,陈睿,程街亮,等. 基于知识库的施肥决策系统及应用 [J]. 农业工程学报, 2011, 27 (12): 126-131.
- [12] 张涛,刘长征,张泽,等. 基于 Web 在线咨询施肥系统的设计 [J]. 石河子大学学报 (自然科学版), 2014 (2): 260-264.

(上接第 216 页)

参考文献:

- [1] 卢可,张寅孩. 基于恒压法和变步长滞环比较法结合的 MPPT 算法研究 [J]. 工业控制计算机, 2013, 26 (5): 114-116.
- [2] Chafle S R, Vaidya U B. Incremental conductance MPPT technique FOR PV system [J]. International Journal of Advanced Research in Electrical Electronics & Instrumentation Engineering, 2013, 2 (6).
- [3] 栗晓政,孙建平. 基于分段数值逼近的自适应步长电导增量法 MPPT 控制仿真 [J]. 太阳能学报, 2012, 33 (7): 1164-1170.
- [4] 宋亮,王晓东,刘雯,等. 光伏电池 MPPT 扰动观察法的研究现状 [J]. 半导体光电, 2012, 33 (4): 455-462.
- [5] 吴雨薇,时斌,朱海勇,等. 基于变步长扰动观察法的光伏电池最大功率点跟踪 [J]. 电气技术, 2014, (06): 23-25.
- [6] 翟小军,杜衡,刘建义,等. 粒子群算法与电导增量法的双级

- 最大功率点跟踪控制 [J]. 红外与激光工程, 2016, (06): 198-203.
- [7] Gupta A, Kumar P, Pachauri R K, et al. Performance analysis of neural network and fuzzy logic based MPPT techniques for solar PV systems [A]. Power India International Conference [C]. IEEE, 2014: 1-6.
- [8] 阳同光,桂卫华. 神经网络反推控制在光伏系统最大功率点跟踪中的应用 [J]. 太阳能学报, 2016, 37 (12): 3030-3036.
- [9] 谢维,段建民. 改进模糊控制的光伏发电系统最大功率点跟踪 [J]. 电源技术, 2016, 40 (5): 1042-1045.
- [10] Kassem A M. Maximum power point tracker control design of a photovoltaic-generator powered DC Motor-Pump System Based on Artificial neural networks [J]. Australian Journal of Electrical & Electronics Engineering, 2015, 9 (2): 127-136.
- [11] 胥芳,张任,吴乐彬,等. 自适应 BP 神经网络在光伏 MPPT 中的应用 [J]. 太阳能学报, 2012, 33 (3): 468-472.