

# 基于神经网络的配网系统光伏输出功率控制分析

孟庆强, 刘 铭

(南瑞集团有限公司(国网电力科学研究院有限公司), 南京 210000)

**摘要:** 随着目前世界上的能源需求愈发扩大, 光伏发电凭借其储备量大, 且清洁无污染的特性, 逐步成为目前新能源发电的主流, 但是, 由于光伏发电效率受到环境光照强度的影响, 因此, 其输出功率时时发生变化, 所以, 目前光伏电池的最大功率跟踪(Most Power Point Trace, MPPT)与控制技术已经成为了业界最为关注的问题; 针对该问题, 文章利用BP神经网络技术对光伏电池的最大输出功率进行检测以及控制, 通过对光伏系统以及人工神经网络的基本原理进行介绍, 引入了BP神经网络的基本概念, 最后搭建了基于BP神经网络的配网光伏输出功率控制系统, 通过仿真, 证明了其理论的可行性与正确性, 能够为我国光伏产业提供一定帮助。

**关键词:** 太阳能; BP神经网络; 最大输出功率; 配网系统

## Analysis of Photovoltaic Output Power Control of Distribution Network System Based on Neural Network

Meng Qingqiang, Liu Ming

(Nari Group Corporation/State Grid Electric Power Research Institute, Nanjing 210000, China)

**Abstract:** With the increasing demand for energy in the world, photovoltaic power generation has gradually become the mainstream of new energy power generation due to its large reserve volume and clean and non-polluting characteristics. However, because the efficiency of photovoltaic power generation is affected by the environmental lighting intensity, so, its output power changes from time to time, so at present, the maximum power tracking (MPPT) and control technology of photovoltaic cells have become the most concerned issues in the industry. Aiming at this problem, this paper uses BP neural network technology to detect and control the maximum output power of photovoltaic cells. By introducing the basic principles of photovoltaic systems and artificial neural networks, the basic concept of BP neural network is introduced. Finally, a power control system based on BP neural network is built. Through simulation, the feasibility and correctness of the theory are proved, which can provide some help to the photovoltaic industry in China.

**Keywords:** solar energy; BP neural network; maximum output power; distribution network system

## 0 引言

现阶段, 由于化石能源的不断减少, 以及全球性气候的恶化, 越来越多的国家都开始了新型能源的研究, 比较火热的有潮汐能、核能、地热能、可燃冰、太阳能、风能、水能等, 其中, 使用最广的是太阳能。太阳能由于是可再生的资源、储量大、清洁, 受到了人们的普遍关注, 也是现在以及今后研究的重点。但是, 太阳能光伏电池由于本身的特性, 容易受到环境的影响, 进而造成光伏电池最大输出功率不稳定, 经常发生变化。国内在几年前就开始了关于太阳能光伏电池最大输出功率的研究, 很多的学者都是采用电压、电流的方法, 以及蚁群算法、马尔科夫算法等。但是, 这些算法的缺点也是比较明显的, 计算不准确, 耗时间, 并且算法的过程也比较复杂, 不容易掌握。同时, 国内对于太阳能光伏电池输出功率的检测与控制需求也不断在增大, 在这种情况下, 采用新的技术去解决太阳能光

伏电池方面的问题变得非常迫切。因此, 本文提出了利用BP神经网络建模的可能性, 利用这种算法的特性来控制光伏电池的最大输出功率<sup>[1]</sup>。

## 1 光伏发电系统组成及工作原理

### 1.1 系统组成

太阳能光伏发电系统的组成是比较简单的, 主要是由众多个光电转换单元组成, 每个光电转换单元都拥有一个P-N结, 当太阳光照射到光电转换器上时, 光能就会转换为电能, 在接线两端形成电势差, 图1就是光伏发电系统组成<sup>[2-3]</sup>。

### 1.2 工作原理

当光伏发电系统进行工作时, 系统里会有电流产生, 可以将电流分为输出电流、最大电流, 同时, 也会有稳定的功率输出, 可以用 $I_0$ 表示输出电流,  $I_1$ 表示最大电流,  $P$ 表示输出功率。满足以下的公式<sup>[4]</sup>:

$$I = I_L - I_0 \left[ \exp\left(\frac{q * v}{A * K * T}\right) - 1 \right] \quad (1)$$

$$P = I_L * V - I_0 * V * \left[ \exp\left(\frac{q * v}{A * K * T}\right) - 1 \right] \quad (2)$$

收稿日期: 2019-08-01; 修回日期: 2019-09-05。

作者简介: 孟庆强(1975-), 男, 徐州市人, 高级工程师, 硕士研究生, 主要从事电力信息化方向的研究。

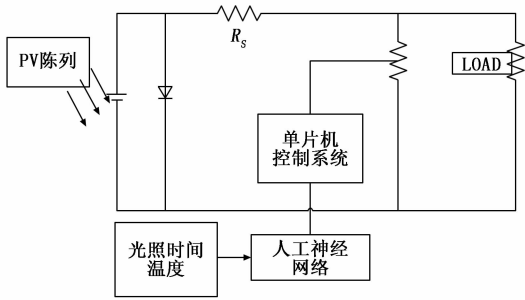


图 1 光伏模型等效电路图

$$I_0 = I_{T_1} \left( \frac{T}{T_1} \right)^3 * \exp \left[ \frac{q * v}{A * K} \left( \frac{1}{T_1} - \frac{1}{T} \right) \right] \quad (3)$$

在 (1) ~ (3) 公式下，可以利用相关的检测设备测出电压、电流、功率之间的关系，具体的情况如图 2~5 所示。




图 2 温度不同，光照相同的电池 P-V 曲线




图 3 温度不同，光照相同的电池 I-V 曲线




图 4 光照不同，温度相同的电池 P-V 曲线




图 5 相同温度，不同光照的电池 I-V 曲线

从图中可以看出，当温度上升时，光伏电池最大输出功率逐渐下降；光伏电池最大输出功率随着电压的上升而

上升，如果电压上升到一定值后无论是最大输出功率，还是电流都开始急剧下降。因此，光伏电池必定有最大的输出功率点。之所以要对其进行控制，就是想一天当中，得到光伏电池的最大输出功率<sup>[5]</sup>。

## 2 神经网络理论简介

### 2.1 神经网络基本原理

通常来说，神经网络是在生物神经网络的基础上构建而成的，其具有生物神经网络的基本结构以及基本特点，并且在此基础之上进行了部分的完善，从而能够实现对于生物神经网络基本工作原理以及过程的模拟，从原理上看，我们可将神经网络视为一种基于分布式理论的并行处理器；而从结构上看，神经网络主要由许多微小的处理单元以及可实现双向通信的信号通道组成。每个神经元都具备各自独立的存储器以及实现基本运算的能力，同时，每个神经元也都有一个输出通道，可通过输出通道与其他神经元进行信号的交换。各个输出通道之间以并联的方式进行连接，也就是说，来自更高级神经元的输出信号不会由于并行的分支通道数量变化，从而在质量上发生变化<sup>[6]</sup>。

1943 年，美国科学家麦克卡洛和皮茨就对人工神经元的基本模型进行了简单的定义。也就是经典的网状点 (MP) 模型。其中包含了多个组合输出通道以及独立神经元。该结构如图 6 所示<sup>[7]</sup>。




图 6 网状点 (MP) 模型结构图

神经元的输入数据可以表示为：

$$X = (x_1, x_2, \dots, x_n) \quad (4)$$

通常将神经元与输入量之间的链接以及输入数据所对应的相应权值表示，为如式 (5) 所示：

$$W = (w_1, w_2, \dots, w_n) \quad (5)$$

若神经元的阈值设为 \$\theta\$，输出量定义为 \$y\$，则：

$$y = f \left( \sum_{i=1}^n w_i x_i - \theta \right) \quad (6)$$

上式中的 \$f(x)\$ 为激活函数，其表达式为：

$$f(x) = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (7)$$

虽然目前来说，MP 模拟的数学原理简单，但是考虑到其基本原理是基于生物学原理的真实反应，因此，其依然能够较好地反映人工神经网络的一些基本特点。

在使用生物神经网络的活动机制时，切勿仅仅借助于单个神经元进行实现配网信息的处理、反馈。可以将大量的神经元组成庞大、复杂的神经网络，此时，可以利用神

神经网络中所包含的单个神经元彼此时间互相传递信息, 这样可以处理、反馈输入的配网信息。采用这种方式非常近似于生物界中神经网络的活动机制, 与人工神经元相比, 错综复杂的人工神经元编制、构造成巨大的网络系统。在网络系统中, 能够按照一定的模式来改变每个神经元之间进行连接的连接权重, 这样能够促进输入信息的识别、训练、学习<sup>[8-10]</sup>。由于成千上万个生物神经元构造、编织成巨大的生物神经元系统网络, 这样, 只能按照统计规律来计算形成的庞大生物神经元系统网络。在具体应用中, 以便计算神经元, 并降低构建成神经元物理系统的难度, 构建的人工神经网络中的神经元个数应当远远比组成生物神经网络的神经元数量少的多, 按照合适的规律构建组成人工神经网络的各个神经元。

在当前使用时, 可以将大部分生物中的神经网络归类为层次型结构, 以人类的大脑为例, 以便更好地说明, 将人的大脑和小脑分别划分为不同的层次, 比如将大脑大致划分为六个不同层次, 小脑划分 3 个不同层次, 基于仿生学原理, 可以建立人工神经网络, 其也由三个部分组成, 即包括输入层、中间层(隐藏层)以及输出层。也可以根据处理函数的不同, 将人工神经网络更进一步地分为前馈神经网络、反馈神经网络。下文将详细描述:

#### 1) 前馈型神经网络结构。

作为常见的神经网络, 本文使用前馈神经网络。当信息被输入时, 输入的信息渐渐地通过输入层被传输到下层。下层的各个神经元将上层的输入信号吸收。即在单个神经元中处理输入信息, 然后输入信息进一步被传输到下层的神经元结构中。在神经网络结构中, 错误的信息难以通过信道而进行反向地传输。如图 7 所示<sup>[11]</sup>, 图 7 为前馈型神经网络结构。




图 7 前馈型神经网络基本结构

#### 2) 反馈型网络。

在上述描述中, 在信息进行传递时, 由于反馈神经网络具有的特性是信息能够实现反向循环, 这种递归网络非常常用。在不同的递归反馈网络中, 节点不同, 其存储信息的能力也不同, 因此反馈网络除了能够接收配网系统外部信息的数据输入, 还能够通过神经元的不同通道辐射式地向外部发射传输信息。其结构图如 8 所示。

### 2.2 神经网络的学习

神经网络通常具有智能的特性, 在经历了训练、学习




图 8 反馈型神经网络结构示意图

人工神经网络、生物神经网络的全过程后。如果输出信息不满意, 可以在网络学习过程中调整连接神经元的权重。以实现最佳的学习效果, 提高数据处理的精度<sup>[12]</sup>, 在具体使用时, 可分为以下几个方面:

#### 1) 监督学习。

监督学习能够通过监督学习信号, 进而调整网络权重。其中当做导师作用的信号能够提供已经获知的输入信号、输出信号, 而后通过将网络实际输出信息与理论输出信息的误差进行比对、分析, 来进一步反馈网络误差信息, 进一步调整网络权重, 这样能够使网络的实际输出值可以无限地接近理论值。一旦神经网络学习了所有的信息的运行规则后, 网络则能够工作, 最终使问题得到最终解决。

#### 2) 无监督学习。

无监督学习在信息训练、学习期间, 通常无引导信号, 网络仅仅从外界被动地吸收信息, 难以将信息输出。仅仅能够通过网络本身的结构找到潜在的、不为人所知的信息规律。无监督学习对于信息量获取有限的群体较为适用。

#### 3) 强化学习。

当神经网络输出的奖惩的学习结果是基于网络的输出结果而给出时, 则可认为该神经网络系统能够通过增强所获得的结果来逐步提升自身的学习性能。这种学习能力被划分介于上述两种不同学习方法。

## 3 BP 神经网络的最大功率输出点控制系统建模

### 3.1 BP 神经网络的方法

基于上述描述, BP 人工神经网络通过多层前馈网络结构构成, 使用时, 通常基于误差反向传播算法来实现神经网络的训练, 利用误差的反向传播原理, 在训练过程中能够不断地提升神经网络系统的阈值、权重, 以便使网络中的误差最小, 拟合度最高, 从而实现最高的精度。由于 BP 神经网络自身的特性的局限, 目前 BP 人工神经网络已经大量被应用在数据处理、模式识别、学习、过程控制、声音识别等不同的技术领域。在配电网系统中, 光伏发电系统具有强非线性的性质, 则可以采用上文描述的神经网络进行跟踪光伏系统的最大功率。具体地讲, 选取样本, 用已知的样本中温度、光照强度、遮挡率本来训练神经网络。这种学习方式被称为监督学习, 将这种方法以神经网络的形式评估最大功率跟踪, 具有很好的实用价值。

### 3.2 BP 神经网络的结构

BP 神经网络在各个行业中使用都很广泛，尤其是大数据分析、机器学习、深度学习等范围中应用比较多。这种算法可以对输入、输出的阈值进行调整，以建立起评估数据的多种模型，模型的建立与用户需求也相关，这些模型能够解决各种各样的技术问题。在本文设计中，将该模型应用到光伏电池最大输出功率的预测上具有明显的价值，通常将这种算法在结构上划分为输入层、隐含层、输出层三个组成部分。

### 3.3 BP 网络的学习过程

从本质上讲，BP 神经网络学习算法实质是将神经网络的信息输入和输出映射问题转变为非线性问题的优化问题。该算法通过前向计算过程和误差反向传播过程<sup>[14]</sup>实现数据反复学习和有用信息萃取。正向计算的信息传递过程是输入层—中间层—输出层。前一层神经元状态对下一层的神经元工作状态具有重要的影响意义。在应用时，如果实际输出结果与理论输出结果相偏离，或者出现很大的误差，则误差信号会沿着原始的信息传输路径从输出层而反馈回来。以便使不同的神经元能够根据自身的反馈可以修改当前的权值，进而减小网络实际输出值与预期输出值的误差。影响神经网络权重校正的主要因素包括后一个神经元节点的误差以及前一个神经元节点的输出。下面通过公式进一步说明。

现选取 S 型函数 (sigmoid) 为转移函数，即  $f(x) = \frac{1}{1 + e^{-x}}$ ，将网络权值设置为  $(W_{ij}, T_{ij})$ ，最后，将系统中的阈值定义为  $\theta$ ，另外，将系统的输入节点定义为  $X$ ，其中的第  $j$  个节点可以用  $X_j$ ，将系统的隐含节点定义为  $Y$ ，其中的第  $j$  个节点可以用  $Y_j$ ，将系统的输出节点定义为  $Q$ ，其中的第  $j$  个节点可以用  $Q_j$ ，另外，将系统的误差函数定义为  $E$ ，从而可以得到如下的 BP 神经网络计算公式：

其中，隐含层的输出公式可以写为：

$$y_i = f\left(\sum_j w_{ij}x_j - \theta_i\right) = f(\text{net}_i) \quad (8)$$

输出层的输出公式可以写为：

$$Q_i = f\left(\sum_j T_{ij}y_j - \theta_i\right) = f(\text{net}_i) \quad (9)$$

从而得到输出层的误差公式为：

$$E = \frac{1}{2} \sum_i (t_i - O_i) = \frac{1}{2} \sum_i (t_i - f(\sum_j T_{ij}f(\sum_j w_{ij}x_j - \theta_i) - \theta_i))^2 \quad (10)$$

使用神经网络调节的最终目标是使得误差函数  $E$  的取值最小，所以，求取最值时，只要求误差函数对权值的偏导数即可，因此可得：

$$\frac{\partial E}{\partial T_{ik}} = \sum_{k=1}^n \frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial T_{ik}} = \frac{\partial E}{\partial O_i} \frac{\partial O_i}{\partial T_{ik}} \quad (11)$$

这时，考虑到 S 函数的导数可以表示为  $f' = f(1-f)$ ，设  $\delta_i = (t_i - O_i)O_i(1 - O_i)$ ，从而可以得到：

$$\frac{\partial E}{\partial T_{ik}} = -\delta_i y_i \quad (12)$$

由于对于权重的修正系数与  $E$  的梯度呈正比关系，所以，对于隐含层而言， $E$  的偏导数可以表示为：

$$\frac{\partial E}{\partial w_{ij}} = \sum_l \sum_i \frac{\partial E}{\partial O_l} \frac{\partial O_l}{\partial y_i} \frac{\partial y_i}{\partial w_{ij}} \quad (13)$$

同理可以得到隐含层节点的误差公式为：

$$\delta'_i = y_i(1 - y_i) \sum_l \delta_l T_{li} \quad (14)$$

### 3.4 最大功率输出点控制系统建模

BP 神经网络就是运用了它的结构特点，让误差反向进行传播，在层之间的连接方式上拒绝采用间断相连的方式，而是另辟新径采取全互连的模式，在同一层之间选择断开模式。根据问题的实际情况确定输入的神经元，在确定输出层后，就需要进行多次的仿真实验确定隐层的神经元数，这也是这种算法的核心所在。

对于太阳能光伏电池输出功率的检测与控制，使用最多的是电流法以及电压法，但是这些方法都存在很大的问题，而采用神经网络，就可以很好检测最大功率输出点，进而研究温度、光强与最大输出功率之间的联系。已有的很多研究已经通过实验证实三层的前馈网络的合理性，本文就是选择了前馈网络，然后，进行了相关的仿真实验，最后，才有效对光伏电池最大输出功率进行了控制。

基于神经网络的配网光伏系统仍然由输入层、隐藏层以及输出层组成。其中，输入层包括一个三维向量  $X$ ，它由时间 ( $t$ )、光照强度 ( $S$ ) 以及温度 ( $T$ ) 组成。输出层  $Y$  只有一个元素，即光伏阵列最大功率点的输出电压 ( $V_{mp}$ )，该神经网络的结构见图 9。




图 9 光伏阵列的 BP 网络结构

从图 9 可以看出，光伏阵列的 BP 网络结构结构比较简单，通过输入层、隐藏层的时间、光强、温度之间的联系，进而在输出层得到最大功率点。对于最后的输出功率，可以通过对样本  $X$  的并网调节，根据实际的需求对权重进行重复设置，直到达到要求，再进行输出即可。

为了得到系统优化工作点的模型，先对一些光伏电池的样本进行实际测量，得到一组优化模型。将优化模型中的数据作为 PV 工作点的目标值，然后对神经网络进行训练，最终达到误差收敛，使系统一直跟踪最佳工作点并输出最大功率。

## 4 仿真与测试结果分析

### 4.1 仿真实验

在所有的准备工作都做好之后，本文选择了在新疆乌

鲁木齐的一个地区进行了仿真测试, 测试的时间为早上 4 点到晚上 18 点半, 测试的因素是光强以及温度, 具体的测试数据如表 1 所示:

表 1 光强、温度观测数据(单位都是标准情况)

时间	4	4.5	5	5.5	6	6.5	7	7.5	8	8.5
光强	0	0	0	0.01	0.03	0.07	0.12	0.14	0.25	0.44
温度	15.1	15.2	15.1	15.3	15.4	17.4	18.5	19.6	20.3	21.4
时间	9	9.5	10	10.5	11	11.5	12	12.5	13	13.5
光强	0.17	0.5	0.21	0.33	0.57	0.49	0.23	0.38	0.6	0.63
温度	20.1	21.2	22.3	24	24.2	24.5	25.2	25.7	26.1	25.2
时间	14	14.5	15	15.5	16	16.5	17	17.5	18	18.5
光强	0.60	0.57	0.51	0.43	0.35	0.13	0.05	0.02	0	
温度	24.1	25.2	25.4	25.2	25.1	25.4	25.1	26.1	27	

采用输入层、隐藏层和输出层各有 3, 6, 1 个神经元的神经网络, 时间、光照和温度作为神经网络的输入, 相应的最大功率点电压作为目标向量。利用神经网络工具箱中的 newff 函数建立了神经网络, 隐层传递函数采用传递函数, 学习函数采用梯度下降权值和阈值学习函数学习, 网络的训练过程是一个不断修正权值和阈值的过程。通过调整, 使网络的输出误差达到最小, 训练函数 trainlm 是利用 L-M 算法对网络进行训练的。

#### 4.2 结果分析

从仿真测试的所有数据中我们可以清楚看到随着时间的变化, 温度、光强的实际变化情况。然后, 本文最大功率点测试的误差进行了相关的分析, 具体情况如图 10 以及图 11 所示:




图 10 光电阵列最优电压以及开路电压




图 11 光伏阵列最优电压以及实际端电压的误差

可以清楚看出, 利用神经网络算法可以非常精准控制电压的变化, 特别是最有电压以及开路电压。实际测试的误差非常小, 不影响实验的结果, 在一天时间的变化中, 最大输出功率始终都是出于最大的水平, 并且能够被精准跟踪。所以, BP 神经网络算法是比较适合对光伏电池输出

功率的检测与控制。

## 5 结论

太阳能光伏发电已经越来越受到人们的青睐, 太阳能将来必将成为化石能源的有效替代品。本文首先对此次的研究背景进行了说明; 接着, 分析了国内以及国外太阳能光伏产业的发展现状; 然后, 提出了 BP 神经网络的最大功率输出点控制系统建模, 并且对 BP 神经网络进行了详细介绍; 再接着, 进行了仿真实验, 并且对仿真结果进行了分析; 最后, 得出了相关的结论。结果显示, BP 神经网络运用于太阳能光伏电池输出功率的检测以及控制非常高效, 能够精准算出最大功率点, 这种算法比之前的蚁群算法、马尔科夫算法、电压算法、电流算法都要精准、高效得多, 并且这种算法非常容易理解, 值得推广。

#### 参考文献:

- [1] 刘志. 光伏电站输出功率预测研究 [D]. 合肥: 合肥工业大学, 2016.
- [2] 张程熠, 唐雅洁, 李永杰, 等. 适用于小样本的神经网络光伏预测方法 [J]. 电力自动化设备, 2017, 37 (1): 101-106.
- [3] 许童羽, 马艺铭, 曹英丽, 等. 基于主成分分析以及遗传优化 BP 神经网络的光伏输出功率短期预测 [J]. 电力系统保护与控制, 2016, 44 (22): 90-95.
- [4] 何雅静, 汪登. 神经网络在光伏中的应用综述 [J]. 太阳能, 2019 (1): 17-20.
- [5] 张一平, 宋红, 罗敏, 等. 神经网络算法在光伏发电短期功率预测中的应用 [J]. 太阳能, 2019 (4): 47-53.
- [6] 张立影, 刘智显, 孟令甲, 等. 基于小波变换以及神经网络的光伏功率预测 [J]. 可再生能源, 2015, 33 (2): 171-176.
- [7] 张立影, 孟令甲, 王泽忠. 基于双层 BP 神经网络的光伏电站输出功率预测 [J]. 电测与仪表, 2015, 52 (11): 31-35.
- [8] 钟春霞. 基于相似日选择算法以及 Elman 神经网络的光伏输出功率预测 [J]. 南京工程学院学报 (自然版), 2016, 14 (1): 42-47.
- [9] 孙永辉, 范磊, 卫志农, 等. 基于小波分析以及集成学习的光伏输出功率短期预测 [J]. 电力系统及其自动化学报, 2016, 28 (4): 6-11.
- [10] 冉成科, 夏向阳, 杨明圣, 等. 基于日类型及融合理论的 BP 神经网络光伏功率预测 [J]. 中南大学学报 (自然科学版), 2018, 49 (9): 2232-2239.
- [11] 杨蕾. 太阳能光伏电站输出功率预测研究 [D]. 兰州: 兰州交通大学, 2014.
- [12] 卫东, 楼洪, 肖昌允. 太阳能光伏输出特性最大功率点计算与模型参数求解 [J]. 中国电机工程学报, 2013, 33 (10): 121-127.
- [13] 廖卫强, 张认成, 俞万能, 等. 基于相似样本及 PCA 的光伏输出功率预测 [J]. 太阳能学报, 2016, 37 (9): 2377-2385.
- [14] 郑建鄂, 谭建军, 鄂翔宇, 等. 基于人工蜂群算法改进 BP 神经网络的光伏发电量预测 [J]. 湖北民族学院学报 (自然科学版), 2019, 37 (1): 90-95.