

# 利用智能水滴算法优化神经网络的 MPPT

赵文清, 李 瑶

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

**摘要:** 光伏系统最大功率点跟踪(MPPT)对于提高光伏发电效率有着重大意义。给出一种智能水滴(IWD)算法优化 Elman 神经网络的 MPPT 方法。利用 IWD 算法对 Elman 神经网络的权值和阈值进行优化,提高 Elman 神经网络的训练效果。将 IWD 算法优化 Elman 神经网络的 MPPT 方法与传统预测方法进行对比,结果验证了所提方法的有效性。

**关键词:** 光伏系统; MPPT; 智能水滴算法; Elman 神经网络

**中图分类号:** TM 615

**文献标识码:** A

**DOI:** 10.16081/j.issn.1006-6047.2017.07.002

## 0 引言

光伏阵列是光伏发电系统的重要组成部分,其输出特性受多种外界因素影响,具有非线性特征。在光伏发电系统中使用最大功率点跟踪(MPPT)技术,能显著提高太阳能的转换效率<sup>[1-2]</sup>。

目前 MPPT 技术已成研究热点,国内外学者提出了多种控制算法,主要有恒定电压控制法、干扰观测法、电导增量法、模糊逻辑控制法等<sup>[3-4]</sup>。这些方法虽然结构简单,但是在实际应用中受环境影响,鲁棒性较差。神经网络具有逼近非线性映射的能力,可以很好地模拟光伏电池的非线性特征,具有很强的自适应性。文献[5]中采用针对光伏电池特性的 PV 神经网络对其建模,利用遗传算法对 PV 曲线进行寻优操作,取得了较高精度,提高了系统稳定性,克服了传统神经网络采集训练数据的难度。文献[6]提出遗传算法优化 BP 神经网络(BPNN)的建模方法,测试及仿真结果表明,该方法精度高,能够有效地反映光伏阵列的输入输出特性,体现了很好的自适应性。文献[7]将 Elman 神经网络(ElmanNN)应用于风功率预测,在环境变化时,仍能快速准确地预测风电输出功率。但由于 ElmanNN 采用误差反向传播算法(BP 算法)修正权值,难免会存在陷入局部最优值、收敛速度慢等缺陷。

智能水滴 IWD(Intelligent Water Drop)算法是 Shah Hosseini 在 2007 年提出的一种新兴群体智能算法<sup>[8]</sup>,是由模仿自然界水系统和其周围环境的相互作用而形成河道的过程进行迭代运算,最后得到优化的结果。该算法已成功运用在组合优化(旅行商<sup>[8]</sup>、多背包<sup>[9]</sup>)、生产调度<sup>[10]</sup>、路径规划(单机无人机路径规划<sup>[11]</sup>、机器人路径规划<sup>[12]</sup>)等多个方面。本文提出一种基于 IWD 算法优化 ElmanNN 权值向量和

阈值向量的光伏系统 MPPT 模型。预测实例表明,利用 IWD 算法优化 ElmanNN(IWD-ElmanNN)的方法与传统的 ElmanNN 方法相比,具有较高的预测精度。

## 1 MPPT 控制原理

光伏电池的最大输出功率是随外界环境变化而改变的,虽然是非线性的,但在任何光照强度和环境温度条件下,电池组件都会存在一个最大功率点。即使光强和温度都稳定不变,输出功率也会因为外接负载的不同而不同<sup>[13]</sup>。为了提高光伏电池的转换效率需采用 MPPT 技术,MPPT 控制原理如图 1 所示。

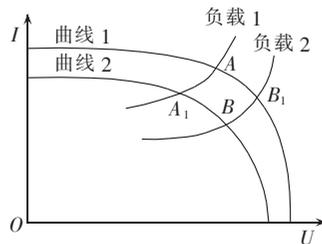


图 1 MPPT 控制原理

Fig.1 Principle of MPPT control

图 1 中,曲线 1、曲线 2 为光伏阵列在不同光照下的  $I-U$  特性;若某一时刻的光照使得电池输出为曲线 1,此时对应的最大功率点为 A 处。当光照改变,电池输出曲线变为曲线 2 时,系统的工作点会偏移到  $A_1$  处,为了使功率点最高,则需要调整负载,使得系统输出工作点运行在 B 处,即当外界环境变化时,实时调整负载大小使系统始终工作在最大功率点,以提高光伏阵列的输出功率。

## 2 ElmanNN

ElmanNN 由 Jeffrey L. Elman 于 1990 年提出,是一种典型的局部反馈神经网络。该模型具有反馈环节,网络结构如图 2 所示,分为 4 层:输入层、隐含层、承接层和输出层。承接层(或状态层)是 ElmanNN 特有的层,该层从隐含层接受反馈信号,记忆隐含层

收稿日期:2016-04-29;修回日期:2017-03-16  
基金项目:中央高校基本科研业务费专项资金资助项目(12MS121)  
Project supported by the Fundamental Research Funds for the Central Universities(12MS121)

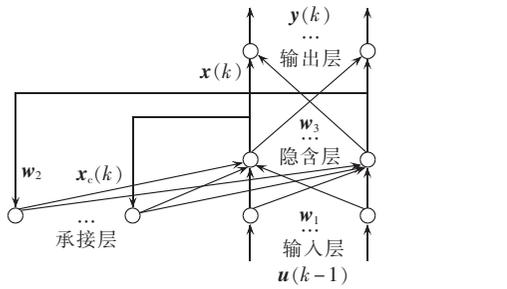


图 2 ElmanNN 结构图

Fig.2 Structure of ElmanNN

前一时刻的输出值,输出经延迟与存储再输入隐含层。除承接层以外,其余 3 层结构的连接与前馈神经网络类似<sup>[14-15]</sup>。

根据图 2,网络的输出  $y(k)$  由式(1)确定。

$$y(k) = g(\mathbf{w}_3 \mathbf{x}(k) + \mathbf{b}_2) \quad (1)$$

其中,  $\mathbf{w}_3$  为隐含层到输出层的权值矩阵;  $\mathbf{b}_2$  为输出层阈值;  $g(\mathbf{x})$  为输出层传递函数。

隐含层输出  $\mathbf{x}(k)$  表达式为:

$$\mathbf{x}(k) = f(\mathbf{w}_1 \mathbf{u}(k-1) + \mathbf{w}_2 \mathbf{x}_c(k) + \mathbf{b}_1) \quad (2)$$

其中,  $\mathbf{w}_1$ 、 $\mathbf{w}_2$  分别为输入层到隐含层、承接层到隐含层的权值矩阵;  $\mathbf{u}(k-1)$  为输入向量;  $\mathbf{b}_1$  为隐含层阈值;  $f(\cdot)$  为隐含层神经元的传递函数;  $\mathbf{x}_c(k)$  为承接层在第  $k$  步时到隐含层的反馈输出,如式(3)所示。

$$\mathbf{x}_c(k) = \mathbf{x}(k-1) \quad (3)$$

ElmanNN 采用误差反向传播算法(BP 算法)修正权值,误差函数定义为:

$$E(k) = \frac{1}{2} (\hat{\mathbf{y}}(k) - \mathbf{y}(k))^T (\hat{\mathbf{y}}(k) - \mathbf{y}(k)) \quad (4)$$

其中,  $\hat{\mathbf{y}}(k)$  为实际输出;  $\mathbf{y}(k)$  为期望输出。

### 3 利用 IWD 算法优化 ElmanNN

IWD 算法是一种新兴的群体智能优化算法,在解决复杂的优化问题中,它比其他群智能算法更具优势。基于上述特点,本文提出用 IWD 算法优化 ElmanNN 权值和阈值这一新思路。

#### 3.1 IWD 算法的数学描述

IWD 算法是模拟自然界中水滴运动的过程而被发明的。可以构建一个抽象的数学模型,称为智能水滴,它具有 2 个重要性质:水滴携带的泥土量和水滴当前前进的速度。水滴在路径中流动时,它的 2 个性质都会发生改变,算法的目标是按照某些约束条件寻找到从起点到终点的一条最佳路径。

假设在节点  $i$  的速度为  $v(i)$ ,在节点  $j$  的速度为  $v(j)$ ,其值与节点  $i$  到节点  $j$  间路径中的泥土量  $s(i,j)$  呈非线性反比关系,表达式如下:

$$v(j) = v(i) + \frac{a_v}{b_v + c_v(s(i,j))} \quad (5)$$

其中,  $a_v$ 、 $b_v$ 、 $c_v$  为用户预先设定的静态参数。

当水滴  $k$  由节点  $i$  移动到节点  $j$  时,水滴携带泥土变化量  $\Delta s(\text{IWD})$  和路径中的泥土变化量  $\Delta s(i,j)$  是相等的,泥土变化量  $\Delta s(i,j)$  与水滴由节点  $i$  流动到节点  $j$  所需时间  $t(i,j)$  呈非线性反比关系:

$$\Delta s(\text{IWD}) = \Delta s(i,j) \quad (6)$$

$$\Delta s(i,j) = \frac{a_s}{b_s + c_s(t(i,j))} \quad (7)$$

其中,  $a_s$ 、 $b_s$ 、 $c_s$  为用户预先设定的静态参数;  $t(i,j)$  为水滴由节点  $i$  流动到节点  $j$  所需时间,如式(8)所示。

$$t(i,j) = \frac{\text{HUD}(i,j)}{v(\text{IWD})} \quad (8)$$

其中,  $\text{HUD}(i,j)$  为定义的反向启发函数,为水滴拒绝移动的程度,与节点  $i$  到节点  $j$  之间的距离成正比。

从节点  $i$  到节点  $j$ ,水滴携带的泥土量  $s(\text{IWD})$  和路径中泥土量  $s(i,j)$  的更新公式为:

$$s(\text{IWD}) = s(\text{IWD}) + \Delta s(i,j) \quad (9)$$

$$s(i,j) = (1 - \rho_n)s(i,j) - \rho_n \Delta s(i,j) \quad (10)$$

其中,  $\rho_n \in (0,1)$ ,为权重系数,一般取值 0.9。

在水滴移动过程中,可能出现多条路径,河床中的泥土阻碍水滴前进,水滴倾向于找到一条最容易的路径流向目的地,即含泥土量最少的路径。假设水滴在节点  $i$  时选择  $j$  为下一节点的概率为  $P_i^{\text{IWD}}(j)$ ,其表达式如下:

$$P_i^{\text{IWD}}(j) = \frac{f(s(i,j))}{\sum_{k \in V_c(\text{IWD})} f(s(i,k))} \quad (11)$$

其中,  $s(i,j)$  为节点  $i$  到节点  $j$  路径上的泥土量;  $V_c(\text{IWD})$  为水滴流过的节点集;  $f(s(i,j))$  的表达式见式(12)。

$$f(s(i,j)) = \frac{1}{\xi + g(s(i,j))} \quad (12)$$

其中,  $\xi$  为极小的正数,其作用是保证函数  $f$  的分母不为零;函数  $g$  的功能是保证节点  $i$ 、 $j$  之间的泥土量  $s(i,j)$  非负,表达式如式(13)所示。

$$g(s(i,j)) = \begin{cases} s(i,j) & \min_{l \in V_c(\text{IWD})} (s(i,l)) \geq 0 \\ s(i,j) - \min_{l \in V_c(\text{IWD})} (s(i,l)) & \text{其他} \end{cases} \quad (13)$$

其中,函数  $\min$  表示当前节点  $i$  到与所有能选择的下一节点  $l$  之间泥土量  $s(i,l)$  的最小值。

#### 3.2 算法改进

由水滴路径选择概率公式可知,当出现以下情况时,算法容易陷入局部收敛:

a. 当一条路径的选择概率远远大于其他路径时,水滴无法选择其他路径;

b. 当多条路径含有的泥土量比较少,且差别不大时,水滴很难选择下一节点。

针对基本 IWD 算法易因节点的选择机制不当而出现陷入局部最优解的问题,本文加入参数  $\varphi$  对其进行改进。

$$P_i^{\text{IWD}}(j) = \begin{cases} \frac{f(s(i,j))}{\sum_{k \in V_c(\text{IWD})} f(s(i,k))} & \varphi \leq \varphi_0 \\ p & \varphi > \varphi_0 \end{cases} \quad (14)$$

其中,  $\varphi, p \in (0, 1)$  为随机数;  $\varphi_0$  为常数。

水滴在选择下一节点前先为  $\varphi$  随机赋值, 作用是增加选择概率的随机性。通过  $\varphi$  与  $\varphi_0$  的大小比较, 确定选择节点  $j$  概率的计算公式。通过引入常数  $\varphi_0$ , 增加水滴选择其他路径的概率, 使水滴路径选择多样化, 更加有利于快速找到最优解。

每次迭代都会得到一个当前最优解  $T_{\text{IB}}$ , 最优解所包含的路径称为精英路径, 得到最优解的 IWD 称为精英水滴。为了使前一次迭代得到的精英路径在下次迭代中被水滴选择的概率更高, 每次迭代后按式(15)对精英路径中的泥土量进行更新。

$$s(i,j) = s(i,j) - \lambda + n/s(i,j) \quad \forall (i,j) \in T_{\text{IB}} \quad (15)$$

其中,  $\lambda$  为常数;  $n$  为精英水滴的个数。

### 3.3 IWD 算法优化 ElmanNN

建立 ElmanNN 后, 利用 IWD 算法优化 ElmanNN 权值、阈值, 它们的取值直接影响着神经网络的性能。基本思想为: 首先确定每个参数的取值范围, 假设网络中需要优化的参数为  $u_1 - u_m$ , 共  $m$  个参数, 对于任一参数  $u_i$ , 其可能的取值构成的集合为  $I_{u_i}$ , 水滴从每个集合 ( $I_{u_1} - I_{u_m}$ ) 中遍历取值。选取均方误差 MSE (Mean Square Error) 作为评价指标, 对每一个参数组合进行验证, 重复这一过程, 直到达到最大迭代次数或满足误差要求。选择 MSE 最小值所对应的参数作为 ElmanNN 最优参数。具体寻优过程描述如下。

输入: 训练样本数据集。

初始化 IWD 算法参数;

while(迭代次数不够或者精度不满足)

{ for(每个水滴){

for(每个参数取值集合){

根据式(14)选择下一个参数取值;

根据式(5)更新水滴的速度;

根据式(9)更新当前水滴携带的泥土量;

根据式(10)更新路径中的泥土量;

根据式(15)对当前最优路径进行保留操作;

if(MSE( $T_{\text{IB}}$ ) < MSE( $T_{\text{SB}}$ ))

{ //  $T_{\text{SB}}$  表示全局最优解

$T_{\text{SB}} = T_{\text{IB}};$

// 更新全局最优解

输出: 最优参数组合, 即输出  $T_{\text{SB}}$ 。

## 4 基于 IWD-ElmanNN 的光伏系统 MPPT

### 4.1 光伏系统 MPPT

基于 IWD-ElmanNN 的光伏系统 MPPT 控制系统如图 3 所示, 利用 IWD 算法对 ElmanNN 的权值

和阈值进行优化, 然后用优化后的 ElmanNN 预测最大功率点的工作电压  $U_m$ , 并将预测的最大工作点电压  $U_m$  设定为恒电压控制法的参考电压  $U_{\text{ref}}$ 。DC/DC 包含 1 个双向全桥电路, 可以用来调节输出电压。当光伏发电系统的工作环境发生变化时, 实时根据预测得到的  $U_m$  来修改  $U_{\text{ref}}$ , 从而达到 MPPT 的目的, 使光伏系统始终工作在最大功率处。

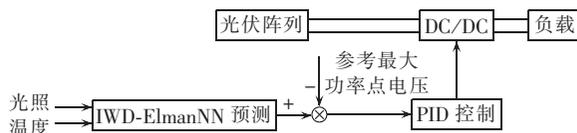


图 3 基于 IWD-ElmanNN 预测的 MPPT 控制系统

Fig.3 MPPT control system based on IWD-ElmanNN

### 4.2 预测过程

基于 IWD-ElmanNN 的光伏系统 MPPT 的预测过程描述如下。

a. 数据预处理。利用式(16)对样本数据进行归一化。

$$\bar{X} = (X - X_{\min}) / (X_{\max} - X_{\min}) \quad (16)$$

其中,  $X$  为原始数据值;  $\bar{X}$  为归一化后的数据;  $X_{\min}$ 、 $X_{\max}$  分别为原始数据  $X$  中的最小值、最大值。

b. 采集光伏电站的光照和温度数据, 划分出训练样本和测试样本。

c. 根据所采集的样本数据, 构造 ElmanNN。

d. 利用 IWD 算法优化 ElmanNN 的权值和阈值, 具体算法参照 3.3 节。

e. 使用训练好的 IWD-ElmanNN 对测试样本进行预测, 并对预测结果进行误差分析。

## 5 实例预测及结果分析

### 5.1 研究对象

本文以中国某光伏电站示范验证平台于 2015 年 8 月 1 日至 7 日在 06:00 — 18:00 的实测数据为实验样本, 样本数据每 1 min 采样一次, 为满足预测需求, 将每 15 min 内的数据做平均值处理, 即每天 48 个样本点。样本数据为电站在不同时刻的环境温度  $T$ 、光照强度  $L$  和最大功率点处的电压, 部分实验数据样本如表 1 所示。

表 1 部分实验样本

Table 1 Partial experimental samples

$T/^\circ\text{C}$	$L/(W \cdot \text{m}^{-2})$	$U_{\text{max}}/V$
27.41	547.45	18.66
27.99	655.96	19.02
29.16	798.11	19.56
29.83	838.68	20.07
30.77	871.96	20.72
31.12	905.51	23.03
31.44	926.58	24.76

将电站 8 月 1 日至 6 日的数据作为训练样本,

将 8 月 7 日的数据作为测试样本。为验证 IWD 算法优化 ElmanNN 的预测效果,利用 MATLAB 进行编程,分别使用 BPNN、ElmanNN 和 IWD-ElmanNN 3 种预测方法对表 1 的测试样本进行预测,预测值与实际值的曲线如图 4 所示。

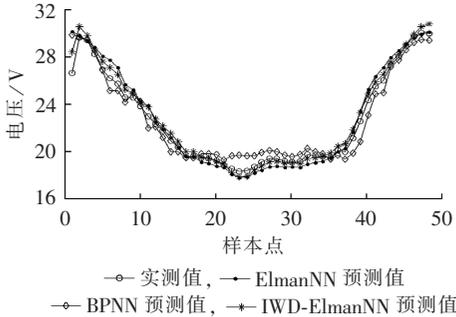


图 4 电压预测误差曲线

Fig.4 Error curves of voltage prediction

### 5.2 参数设定

在表 1 中输入向量维数为 2,即输入神经元数目为 2,由影响光伏系统最大功率输入的主要因素组成。目标输出向量维数为 1,即输出神经元数目为 1,隐含层神经元数目设为 5。网络的最大训练次数设为 500,训练的目标误差设为 0.001。根据文献[6-10]的实验测试和结果,对 IWD 算法中的参数进行设置,其中水滴的初始速度为 1,水滴初始携带的泥土量为 0,IWD 数为 40,扰动参数为 0.8, $\rho_n=0.9$ , $a_n=a_s=1$ , $b_v=b_s=0.01$ , $c_v=c_s=1$ 。

### 5.3 结果分析

本文从预测结果的训练效率和预测误差两方面进行分析,验证 IWD-ElmanNN 的有效性。

#### a. 训练效率。

同时对 BPNN、ElmanNN 和 IWD-ElmanNN 3 种预测方法进行训练,为了方便比较,3 种方法采用完全一样的输入输出和训练数据。

由于篇幅限制,本文只给出了 IWD-ElmanNN 和 ElmanNN 训练误差曲线,分别见图 5、图 6。由图 5 可知,IWD-ElmanNN 的训练最终误差为 0.0097654,训练次数为 85;由图 6 可知,ElmanNN 的训练最终误差为 0.0099798,训练次数为 121;训练结果显示

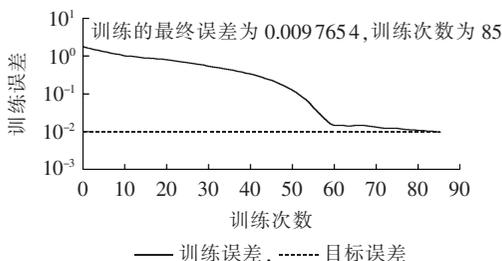


图 5 IWD-ElmanNN 的训练误差曲线

Fig.5 Curve of training error vs. training times of IWD-ElmanNN

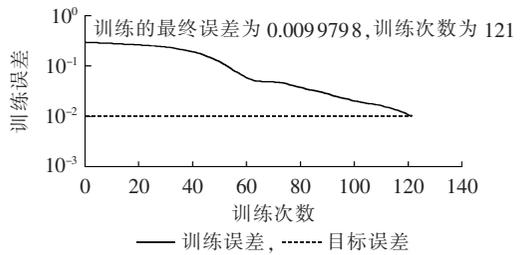


图 6 传统 ElmanNN 的训练误差曲线

Fig.6 Curve of training error vs. training times of traditional ElmanNN

IWD-ElmanNN 的训练最终误差和训练次数均优于传统 ElmanNN。

#### b. 预测误差。

为了评估预测结果的准确性,误差评价函数采用平均绝对百分比误差 MAPE(Mean Absolute Percentage Error)和均方根误差 RMSE(Root of the Mean Squared Error)。

表 2 为 BPNN、ElmanNN 和 IWD-ElmanNN 3 种预测方法预测结果的比较。由表 2 可知,IWD-ElmanNN 的 RMSE 为 2.2062 V,在 3 种方法中最低;同时 MAPE 为 8.1378%,在 3 种方法中也最低,同 Elman-NN 和 BPNN 相比,分别降低了 2.8122% 和 5.1911%;由实验结果可知 IWD-ElmanNN 的 MAPE 和 RMSE 均优于 ElmanNN 和 BPNN。BPNN 预测精度较低,这是因为初始权值和阈值的选取对网络造成的影响较大,ElmanNN 具有反馈环节,收敛速度较快。

表 2 3 种预测方法的 MAPE 和 RMSE

Table 2 MAPE and RMSE of three prediction methods

方法	MAPE/%	RMSE/V
IWD-ElmanNN	8.1378	2.2062
ElmanNN	10.9500	3.2478
BPNN	13.3289	3.6905

## 6 结论

本文给出一种基于 IWD-ElmanNN 的光伏系统 MPPT 预测方法,使用 IWD 算法对 ElmanNN 的权值和阈值进行优化。预测实例表明,与传统的 ElmanNN 相比,本文提出的 IWD-ElmanNN 方法具有更高的预测精度、更快的收敛速度,为 MPPT 控制算法的改进提供了一种新思路,克服了传统 MPPT 控制算法控制精度低、容易发生误跟踪的缺点,实现光伏阵列最大工作点的准确预测,大幅提高了 MPPT 控制系统的性能。

### 参考文献:

[1] 韩伟,王宏华,陈凌. 光伏组件参数拟合及输出特性研究[J]. 电力自动化设备,2015,35(9):100-107.  
HAN Wei,WANG Honghua,CHEN Ling. Study on parameters

- fitting and output characteristics of photovoltaic module[J]. Electric Power Automation Equipment, 2015, 35(9): 100-107.
- [2] 李善寿, 张兴. 改进的光伏组件工程数学模型建模方法[J]. 电力自动化设备, 2015, 35(9): 108-112.  
LI Shanshou, ZHANG Xing. Improved mathematical modeling method for PV modules[J]. Electric Power Automation Equipment, 2015, 35(9): 108-112.
- [3] 陈剑, 赵争鸣. 光伏系统最大功率点跟踪技术的比较[J]. 清华大学学报(自然科学版), 2010, 50(5): 700-704.  
CHEN Jian, ZHAO Zhengming. Comparison of maximum power point tracking techniques for photovoltaic systems[J]. Journal of Tsinghua University (Natural Science Edition), 2010, 50(5): 700-704.
- [4] 孙博, 梅军, 郑建勇. 局部阴影条件下最大功率点跟踪改进算法[J]. 电力自动化设备, 2014, 34(1): 115-119, 127.  
SUN Bo, MEI Jun, ZHENG Jianyong. Improved algorithm for maximum power point tracking under local shading condition[J]. Electric Power Automation Equipment, 2014, 34(1): 115-119, 127.
- [5] 龙洁. 基于 NN 模型估计的光伏最大功率点跟踪控制技术研究[J]. 电力系统保护与控制, 2011, 39(20): 38-42.  
LONG Jie. Research on photovoltaic maximum power point tracking control based on NN model[J]. Power System Protection and Control, 2011, 39(20): 38-42.
- [6] 林虹江, 周步祥, 冉伊, 等. 基于遗传优化 BP 神经网络算法的光伏系统最大功率点跟踪研究[J]. 电测与仪表, 2015, 52(5): 35-40.  
LIN Hongjiang, ZHOU Buxiang, RAN Yi, et al. Research on maximum power point tracking of photovoltaic system based on genetic algorithm BP neural network algorithm[J]. Electrical Measurement and Instrumentation, 2015, 52(5): 35-40.
- [7] 杨楠, 周峥, 李臻. 基于总体平均经验模态分解与改进 Elman 神经网络的风功率组合预测[J]. 电网与清洁能源, 2015, 31(10): 112-117.  
YANG Nan, ZHOU Zheng, LI Zhen. Wind power combination forecasting based on ensemble average empirical mode decomposition and improved Elman neural network[J]. Power Grid and Clean Energy, 2015, 31(10): 112-117.
- [8] SHAH-HOSSEINI H. Problem solving by intelligent water drops [C]//IEEE Congress on Evolutionary Computation, 2007. CEC 2007. [S.l.]: IEEE, 2007: 3226-3231.
- [9] SHAH-HOSSEINI H. Intelligent water drops algorithm: a new optimization method for solving the multiple knapsack problem[J]. International Journal of Intelligent Computing and Cybernetics, 2008, 1(2): 193-212.
- [10] 周季华, 叶春明, 盛晓华. 基于智能水滴算法置换流水线调度问题的研究[J]. 计算机科学, 2013, 40(9): 250-253.  
ZHOU Jihua, YE Chunming, SHENG Xiaohua. The study of permutation flow shop scheduling problem based on intelligent water drop algorithm[J]. Computer Science, 2013, 40(9): 250-253.
- [11] DUAN H, LIU S, WU J. Novel intelligent water drops optimization approach to single UCAV smooth trajectory planning[J]. Aerospace Science and Technology, 2009, 13(8): 442-449.
- [12] SALMANPOUR S, OMRANPOUR H, MOTAMENI H. An intelligent water drops algorithm for solving robot path planning problem[C]//IEEE 14th International Symposium on Computational Intelligence and Informatics (CINTI). Budapest, Hungary: IEEE, 2013: 333-338.
- [13] 王红艳, 万盟. 基于粒子群算法的 MPPT 控制策略研究[J]. 南京工程学院学报(自然科学版), 2014, 12(2): 24-27.  
WANG Hongyan, WAN Meng. Research on MPPT control strategy based on particle swarm optimization algorithm[J]. Journal of Nanjing Institute of Technology (Natural Science Edition), 2014, 12(2): 24-27.
- [14] 王晓霞, 马良玉, 王兵树. 进化 Elman 神经网络在实时数据预测中的应用[J]. 电力自动化设备, 2011, 31(12): 77-81.  
WANG Xiaoxia, MA Liangyu, WANG Bingshu. Application of evolutionary Elman neural network in real time data prediction [J]. Electric Power Automation Equipment, 2011, 31(12): 77-81.
- [15] 尹东阳, 盛义发, 蒋明洁. 基于粗糙集理论-主成分分析的 Elman 神经网络短期风速预测[J]. 电力系统保护与控制, 2014, 42(11): 46-51, 90.  
YI Dongyang, SHENG Yifa, JIANG Mingjie. Elman neural network based on rough set theory and principal component analysis for short-term wind speed forecasting[J]. Power System Protection and Control, 2014, 42(11): 46-51, 90.

#### 作者简介:



赵文清(1973—),女,山西朔州人,教授,博士,主要研究方向为机器学习、数据挖掘、贝叶斯网络学习与智能技术在电力系统中的应用等(E-mail: jbwq@126.com)。

## MPPT based on neural network optimized by intelligent water drop algorithm

ZHAO Wenqing, LI Yao

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

**Abstract:** MPPT(Maximum Power Point Tracking) of photovoltaic system is of great significance for improving the efficiency of photovoltaic power generation. A method of MPPT based on Elman neural network optimized by IWD(Intelligent Water Drop) algorithm is proposed, which applies IWD algorithm to optimize the weights and thresholds of Elman neural network for improving its training efficiency. The proposed method is compared with traditional prediction methods to verify its effectiveness.

**Key words:** photovoltaic system; MPPT; intelligent water drop algorithm; Elman neural network