

基于模糊 RBF 神经网络算法的灌溉控制系统设计

张丽娜¹, 鲁旭涛¹, 刘 昊¹, 李 静²

(1. 中北大学 信息与通信工程学院, 太原 030051;

2. 中北大学 电气与控制工程学院, 太原 030051)

摘要: 对于一个农田占地面积大, 灌溉用水量少的农业国而言, 高效用水影响着农业的稳步发展; 针对这一现象, 提出一种基于模糊 RBF 神经网络的灌溉策略, 将隐层的输出函数构成一组基来逼近目标函数, 预测出灌溉的需水量, 并用模糊控制计算出具体的灌溉时间; 以山西省忻州地区种植的玉米利合 328 号为例, 对气象条件、土壤条件以及作物特性进行分析, 可以根据不同环境计算出灌溉时间; 对大田采取高效、实时的灌溉策略, 不仅可以提高灌溉用水的利用率, 还可以为大田灌溉的发展奠定基础, 增加了作物的产量。

关键词: RBF 神经网络; 模糊控制; 灌溉时间; 灌溉策略

Design of Irrigation Control System Based on Fuzzy RBF Neural Network Algorithm

Zhang Lina¹, Lu Xutao¹, Liu Hao¹, Li Jing²

(1. School of Information and Communication Engineering, North China University, Taiyuan 030051, China;

2. School of Electrical and Control Engineering, North China University, Taiyuan 030051, China)

Abstract: For an agricultural country with a large area of farmland and little water for irrigation, efficient water use affects the steady development of agriculture. Aiming at this phenomenon, an irrigation strategy based on fuzzy RBF neural network is proposed, which uses the output function of the hidden layer to form a basis to approximate the objective function, predicts the irrigation water demand, and calculates the specific irrigation time by fuzzy control. The meteorological conditions, soil conditions and crop characteristics of Lihe 328 corn planted in Xinzhou, Shanxi Province were analyzed, irrigation time can be calculated according to different environments. The efficient and real-time irrigation strategy can not only improve the utilization rate of irrigation water, but also lay a foundation for the development of field irrigation and increase the yield of crops.

Keywords: RBF neural network; fuzzy control; irrigation time; irrigation strategies

0 引言

我国是一个农业大国, 农田占地面积大, 水资源作为生命的源泉, 关系到农业的发展, 影响着人民的温饱问题。根据最新数据统计显示, 2020 年我国的耕地面积可达到 18.65 亿亩, 长期保护农田面积达到 15.46 亿亩, 高标准的农田面积至少要有 8 亿亩并逐步发展为 10 亿亩。“十二五”期间, 我国的灌溉技术不断发展, 农田灌溉面积不断扩大, 经过改善后新增加了 7500 万亩灌溉面积。我国实施了大量的节水政策, 已经取得较大成效, 灌溉面积增加了 1.2 亿亩, 当今农业发展的关键是要有效落实耕地和灌溉用水措施, 对同作物进行合理化的管理。

因此, 徐景辉等人提出了基于 SOA 算法实现了 PID 参数的自动优化^[1]。王磊提出了枚举法和遗传算法在农田灌溉管道系统优化设计^[2]。安庆杰等人提出了基于改进粒子群算法的两级渠道水资源优化配置。Alonso Campos 提出了

基于并行多目标遗传算法的灌溉调度实时能量优化。Mohammad Ali Asgharzadeh 提出了基于 HADIS 算法的灌溉调用系统。上述灌溉方法无法根据需水量得出灌溉时间, 对此本文提出一种基于 RBF 神经网络模糊控制的灌溉决策系统, 以山西省忻州地区种植的玉米利合 328 号为例, 进行研究, 相比传统灌溉方式增加了产量。

1 作物需水特性

为了保证灌溉的高效性和科学性, 就了解作物的需水特性, 农作物需水量是在作物不受严重的病虫害, 正常的土壤状况下的生长需水量。影响作物需水特性的条件主要分三大部分: 气象条件, 土壤条件, 作物自身的特性等。

1.1 气象条件

气象条件主要是气温、风速大小、气压大小、空气湿度等。这些因素会影响作物的蒸腾作用, 风速会影响空气的温湿度大小, 进而改变作物的蒸腾量。气温越高, 空气的

收稿日期: 2020-05-22; 修回日期: 2020-06-17。

基金项目: 山西省应用基础研究项目(201701D221124); 山西省重点研发计划项目(201903D221025)。

作者简介: 张丽娜(1997-), 女, 山西太原人, 硕士, 主要从事物联网方向的研究。

引用格式: 张丽娜, 鲁旭涛, 刘 昊, 等. 基于模糊 RBF 神经网络算法的灌溉控制系统设计[J]. 计算机测量与控制, 2021, 29(1): 87-92.

表 1 部分气象数据表

日期	最高气温 /℃	最低气温 /℃	平均气温 /℃	天气	降水量 /mm	相对湿度 /%	压强 /hPa	风力 /(km/h)
2019/7/5	35	22	28.5	多云转晴	0	25.22	1053.25	2
2019/7/6	35	14	22	晴	0	37.98	1046.23	2.23
2019/7/7	29	17	23	多云	0	70.38	1030.36	3.24
2019/7/8	29	17	23	多云	0.16	80.45	1026.78	2.56
2019/7/9	27	16	21	小雨	10.09	90.68	1019.78	2.54
2019/7/10	26	16	21.5	小雨	7.5	95.76	1014.09	4.14
2019/7/11	25	15	20	雷阵雨转小雨	11.28	96.25	1012.69	4.78
2019/7/12	31	17	24	多云转晴	0	94.13	1013.78	3.45
2019/7/13	34	15	24.5	多云转晴	0	87.06	1022.36	3.89
2019/7/14	34	17	25.5	多云转阴	0	86.26	1023.45	2.57
2019/7/15	33	19	26	小雨	4.08	92.36	1017.59	2.42

水分越少，蒸腾作用越强。

1.2 土壤条件

土壤条件主要是土壤的种类、土壤的结构、土壤的吸水性、地下水等。不同的土壤类型和土壤结构会影响土壤渗透率，影响土壤的吸水性，进而影响作物的吸水性。地下水量的大小会影响土壤的温湿度。地下水位较高的地方可以适当的减少灌溉量。

1.3 作物特性

作物特性主要是作物的吸水特性、作物生长的不同时期的需水量等。不同种类的作物、不同品种的作物以及不同生长周期的作物对水分的需求量不同。耐寒的作物需水量小，湿生的作物需水量相对较大。幼苗时期需水量大，成熟时期需水量小。

1.4 作物需水量计算

本文中控制的农田面积为 1 亩，预测的农作物种类是内蒙古地区种植的玉米利合 328 号，该作物亩保苗 5 500~6 000 株，行距 55 cm，株距 20.2 cm 为最佳生长环境。在进行算法控制前，需要先根据气象条件计算神经网络要预测的数据，即利合玉米的需水量，再对 RBF 神经网络进行训练。本文利用参考作物蒸发量的大小来计算出作物需水量。

$$Q_{\text{实}} = K_c Q_{\text{参}} \tag{1}$$

式 (1) 中， $Q_{\text{实}}$ 指实际生长过程中作物的需水量； K_c 指作物系数； $Q_{\text{参}}$ 指参考作物需水量。

$$Q_{\text{参}} = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \tag{2}$$

式 (2) 中， R_n 指参考作物冠层表面接收的净辐射； G 土壤热通量； γ 指湿度计常数； u_2 指离地面 2 m 高的风速； e_s 指饱和水气压； e_a 指当地的实际水气压； Δ 指平均气温时饱和水气压与温度曲线斜率。

参考 2019 年 7 月和 8 月 50 天的数据，计算出每日作物的需水量大小，部分气象数据如表 1 所示，计算结果如图 1 所示。

2 模糊 RBF 网络

模糊系统与模糊神经网络二者互相联系又互相独立，




图 1 作物需水量计算结果

模糊系统实现的结果就是模糊神经网络，但是模糊神经网络有自己的特性。将模糊系统和神经网络结合起来可以构成模糊神经网络，将 RBF 网络与模糊系统结合起来可以构成模糊 RBF 网络。

2.1 网络结构

模糊 RBF 神经网络结构有四层，分别为：输入层、模糊化层、模糊推理层和输出层构成。具体的网络结构如图 2 所示。




图 2 模糊 RBF 神经网络结构

模糊 RBF 网络中信号传播及各层的功能如下。

第一层：输入层。

输入层的节点与输入的参数量之间直接建立联系，将输入量传送到输入层。传输节点的输入和输出之间的关系式为：

$$f_1(i) = x_i \quad (3)$$

第二层: 模糊化层, 即隶属函数层。

本文用高斯函数作隶属函数, 在模糊化层中, 各个节点都能进行隶属函数计算, 在第 j 个节点处:

$$f_2(i, j) = \exp(-\frac{(x_i - c_{ij})^2}{b_{ij}^2}) \quad (4)$$

$$net_j^2 = -\frac{(f_1(i) - c_{ij})^2}{(b_{ij})^2} \quad (5)$$

其中: c_{ij} 和 b_{ij} 分别是第 i 个输入变量的第 j 个模糊集合高斯函数的均值和标准差。

第三层: 模糊推理层, 即建立规则层。

该层的各个节点可以与模糊化层建立连接, 通过固定的模糊控制规则组合在一起, 输出相应的数据, 输出的数据具有一定的强度, 其中的节点 j 的输出结果是本节点全部输入信号的总乘积, 即:

$$f_3(j) = \prod_{i=1}^N f_2(i, j) \quad (6)$$

其中: $N = \prod_{i=1}^n N_i$, N_i 为输入层中第 i 个输入隶属函数的个数, 即模糊化层节点数。

第四层: 输出层。

各个节点收到的输入信号的加权总和即为该节点的输出量, 即:

$$f_4(l) = W \cdot f_3 = \sum_{j=1}^N w(l, j) \cdot f_3(j) \quad (7)$$

其中: l 为输出层节点数, W 为输出节点与第三层各节点的连接权矩阵。

2.2 逼近算法

采用模糊 RBF 网络逼近对象, 取网络结构为输入层 2, 模糊化层 4, 输出层 1, 过程如图 3 所示。




图 3 模糊 RBF 神经网络逼近

取 $y_m(k) = f_4$, $y_m(k)$ 和 $y(k)$ 分别表示模糊输出和实际输出。模糊的输入为 $y(k)$ 和 $u(k)$, 模糊的输出为 $y_m(k)$, 则模糊的逼近误差为:

$$e(k) = y(k) - y_m(k) \quad (8)$$

定义如下的目标函数, 便于调整函数:

$$E = \frac{1}{2} e(k)^2 \quad (9)$$

输出层权值的调节方式:

$$\Delta w(k) = -\eta \frac{\partial E}{\partial w} = -\eta \frac{\partial E}{\partial e} \frac{\partial e}{\partial y_m} \frac{\partial y_m}{\partial w} = \eta f_3 e(k) \quad (10)$$

则输出层的权值学习算法:

$$w(k) = w(k-1) + \Delta w(k) + \alpha [w(k-1) - w(k-2)] \quad (11)$$

式中, η 为学习速率, α 为动量因子, $\eta \in [0, 1]$, $\alpha \in [0, 1]$ 。

隶属函数参数的调整方式:

$$\Delta c_{ij} = -\eta \frac{\partial E}{\partial c_{ij}} = -\eta \frac{\partial E}{\partial net_j^2} \frac{\partial net_j^2}{\partial c_{ij}} \frac{\partial y_m}{\partial w} = -\eta f_j^2 \frac{2(x_i - c_{ij})}{b_{ij}^2} \quad (12)$$

$$\Delta b_{ij} = -\eta \frac{\partial E}{\partial b_{ij}} = -\eta \frac{\partial E}{\partial net_j^2} \frac{\partial net_j^2}{\partial b_{ij}} = \eta f_j^2 \frac{2(x_i - c_{ij})}{b_{ij}^3} \quad (13)$$

其中:

$$\begin{aligned} \delta_j^2 &= \frac{\partial E}{\partial net_j^2} = -e(k) \frac{\partial y_m}{\partial net_j^2} = \\ &= -e(k) \frac{\partial y_m}{\partial f_3} \frac{\partial f_3}{\partial f_2} \frac{\partial f_2}{\partial net_j^2} = -e(k) w f_3 \end{aligned} \quad (14)$$

隶属函数参数的学习算法:

$$c_{ij}(k) = c_{ij}(k-1) + \Delta c_{ij}(k) + \alpha [c_{ij}(k-1) - c_{ij}(k-2)] \quad (15)$$

$$b_{ij}(k) = b_{ij}(k-1) + \Delta b_{ij}(k) + \alpha [b_{ij}(k-1) - b_{ij}(k-2)] \quad (16)$$

3 灌溉控制实现

3.1 灌溉控制系统设计

气象条件、土壤条件以及作物特性会影响到农作物的需水特性, 而气象条件中的光照、温度高低、湿度状况以及风速大小对作物的需水量影响较大。为了将农作物的需水量控制在合理高效的范围内, 将这四个参数作为模糊控制的输入, 而玉米的需水量的大小作为控制的输出。灌溉策略结构如图 4 所示, 首先根据输入参数计算出作物的需水量, 再参考实际的土壤含水量计算出需要灌溉的水量的多少, 随后用模糊控制算法计算出灌溉这一需水量所用的灌溉时间, 最后通过控制阀门的状态来控制灌溉。

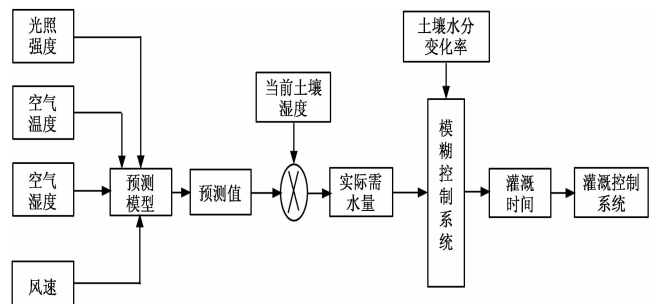


图 4 灌溉结构图

3.2 模糊 RBF 神经网络算法

神经网络预测模型设计步骤如下。

3.2.1 样本预处理

RBF 神经网络要求输入的参数量可以实时的进行采集, 并且对输出变量的影响较大。输入的数据需要处理成 0 到 1 之间的的代表数据, 用来计算权值的大小。具体的预处理计算过程如下:

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (17)$$

式中, x 为原样本; y 为预处理后的样本; x_{\min}, x_{\max} 为原样本中的最小值, 最大值; y_{\min}, y_{\max} 为样本范围。

3.2.2 神经网络节点个数确定

RBF 神经网络能够根据不同的要求和不同的解决方案设计出不同的结构, 结构使用过程比较灵活。本文的输入参数量为光照强度、空气温度、空气湿度以及风速大小 4 个变量, 输出变量为作物需水量。因此需要确定模糊结构中的模糊化层节点数是模糊网络结构的重要影响因素。用如下公式确定模糊化层节点个数:

$$P = \sqrt{m+n} + a \text{ 或 } P = \sqrt{n} \text{ 或 } P = \log_2 a \quad (18)$$

P 指隐含层节点数目; n 指输入层节点数目; m 输出层节点数目; a 是 1~10 之间的调节常数。

对模糊化层节点个数进行假设, 将 4、5、6、7、8 五个数值带入上式进行训练计算, 训练时间和绝对均方误差结果如表 2 所示。

表 2 模糊化层节点个数对神经网络训练的影响

节点数	训练时间/s	绝对均方误差
4	4.23	5.364
5	5.21	5.583
6	6.32	5.133
7	6.73	5.210
8	7.24	5.287

根据计算结果可以得出, 当模糊化层的节点个数为 6 时, 得出的均方误差最小, 计算结果更为准确。故而建立了一个 4-6-6-1 的 RBF 神经网络基本结构, 输出值就是需要灌溉的水量的预测值。

3.2.3 参数选择

为了确保本文的真实可靠性, 以内蒙古地区种植的玉米利合 328 号为例, 适宜在 4 月 25 日至 5 月 10 日种植在 10 厘米低温稳定通过 10℃ 大达到七天以上, 活动积温 2200℃。环境建立参数。

1) 初始值和阈值的选择:

为了方便计算, 初始值和阈值一般采用 (0, 1) 之间的随机数值。

2) 量化因子和比例因子:

在模糊控制器中输入参数是精确数值, 需要进行模糊处理输入到模糊规则中, 对应的输出也是模糊值域, 需要处理为精确值进行输出控制。故而, 要引入量化因子和比例因子对其进行转换控制。

假设输入量 a_i 的分量 $e = [-a, a]$, 模糊论域:

$U = \{-n, -n+1, \dots, 0, \dots, n-1, n\}$ 。则量化因子定义为:

$$k_e = \frac{n}{a} \quad (19)$$

解得, 量化因子分别为:

$$k_Q = \frac{7}{20}, k_E = \frac{3}{5}$$

比例因子定义为:

$$k = \frac{u}{n} \quad (20)$$

解得, 比例因子为:

$$k_T = 257 \text{ s}$$

3) 期望误差的选择:

期望误差设置为 10^{-2} 。

3.3 模糊控制器设计

本文用到的控制器是被广泛使用的 Mamdani 型模糊推理控制器。为了测量准确, 对土壤中的水分采用多个传感器进行测量, 然后取加权平均数作为最终的参考量。灌溉需水量使用 RBF 神经网络进行周期性的预测, 周期为 5 分钟。但是, 当最终计算出的灌溉时间小于 5 分钟时要等待下一个预测周期, 此时需要停止灌溉。

3.3.1 输入输出变量论域

本文的控制器的输入是灌溉需水量和土壤水分的差值 Q 和土壤的水分变化率 E 两个变量。输出量是实际的灌溉时间 T 。 Q 的差值变化范围为 0~20%; E 的变化率范围为 -5%~5%; T 的时间变化范围为 0~30 min。

3.3.2 模糊语言及其量化论域

模糊控制的规则根据不同的输入输出的级别来确定, 首先将输入输出三个变量进行等级定义, 然后根据实际情况排列组合得到模糊控制规则。本文 Q 的变化分为八个等级, 从 0 到 7; E 的变化分为七个等级, 从 -3 到 3; T 的变化分为八个等级, 从 0 到 7。对应的语言如表 3 所示。

表 3 Q, E, T 的模糊语言变量

变量	模糊语言
$Q = \{0, 1, 2, 3, 4, 5, 6, 7\}$	Z(零), XS(很小), S(小); LS(较小); XB(较大), B(大), VB(很大), MB(最大)
$E = \{-3, -2, -1, 0, 1, 2, 3\}$	FL(负快), FM(负中), NS(负慢); ZO(不变); ZS(正慢), ZM(正中), ZB(正快)
$T = \{0, 1, 2, 3, 4, 5, 6, 7\}$	Z(零), XD(很短), D(短); LD(较短); XL(较长), L(长), VL(很长), ML(最长)

3.3.3 隶属度函数

采用三角隶属函数将输入与模糊控制规则联系起来, 隶属函数的形式会影响灌溉用水的使用效率, 进而影响产量。输入输出变量的隶属度函数结果如图 5~7 所示。




图 5 Q 的隶属度函数




图 6 E 的隶属度函数




图 7 T 的隶属度函数

3.3.4 规则表

模糊控制主要是通过设定好的控制规则来实现的, 本文的输入为八个和七个等级, 因此共有 56 个控制的规则组合, 具体的模糊控制规则表 4 所示。

表 4 模糊控制规则表

T		E							
		Z	XS	S	LS	XB	B	VB	MB
EC	FL	Z	LD	XL	L	L	VL	ML	ML
	FM	Z	LD	XL	XL	L	L	VL	ML
	NS	Z	D	LD	XL	XL	XL	VL	VL
	ZO	Z	XD	LD	LD	XL	XL	L	L
	ZS	Z	Z	D	LD	XL	XL	XL	L
	ZM	Z	Z	D	D	LD	LD	XL	XL
	ZB		Z	XD	XD	LD	LD	LD	XL

4 系统测试

采用土壤中安装的传感器检测出土壤含水量, 然后用设计好的 RBF 神经网络计算出需要灌溉的水量和灌溉的时间, RBF 神经网络训练误差如图 8 所示。

由图 8 可知, 误差值开始的时候下降的梯度较大, 随着训练次数的增加, 下降的速度不断减少, 最终趋于稳定。因此, 本文的 RBF 神经网络预测模型能够比较稳定的实现灌溉, 满足设计的需求。

训练结束后对进行预测, 横坐标指样本编号, 纵坐标指需水量, 实现指实际检测的需水量, 虚线指预测到的需水量。具体的预测结果如图 9 所示。

由图可知, 预测值和实际值之间的差值较小, 即预测误差小, 预测值满足实际需求。




图 8 训练误差图




图 9 农作物需水量实际值和预测值分布

在 MATLAB 的工具箱中设置模糊控制器, 设置为双输入单输出的控制器, 并将输入输出变量的命名进行更改, 设计的控制器结构如图 10 所示。




图 10 模糊控制器结构

对模糊控制器的输入和输出函数的隶属度进行编辑后, 建立模糊控制规则, 对本设计的 56 条控制规则逐一设置。模糊控制规则设计窗口如图 11 所示。

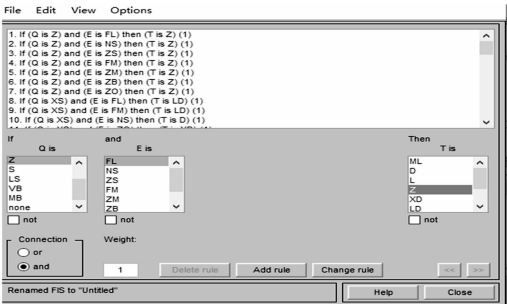


图 11 模糊控制规则

模糊控制器建立完成后, 设置 x 轴为灌溉需水量和土壤水分的差值, y 轴为土壤湿度变化率, z 轴为计算的灌溉时间。实际的输出结果如图 12 所示。




图 12 模糊控制结构曲面图

模糊控制器会根据实际的状况算出实际灌溉时间, 输出结果如图 13 所示。当两个输入分别为 1.93, 1.17 时, 输出为 3.78, 乘以比例因子 257 S, 计算出的灌溉时间为 971.46 s。

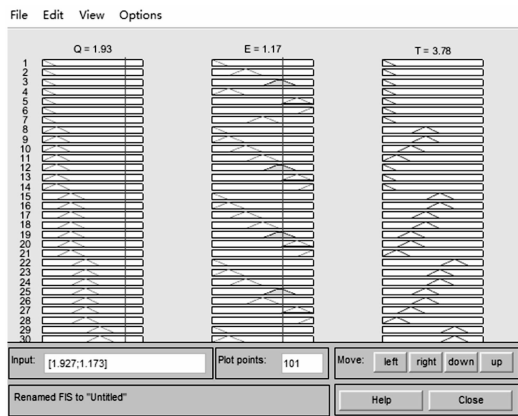


图 13 模糊控制输出结果

5 结束语

本文首先对作物的需水特性进行分析, 确定了四个影响作物因子的函数, 作为 RBF 神经网络的输入来逼近计算作物的需水量, 并以山西省忻州地区种植的玉米利合 328 号为例, 建立模糊控制器, 根据不同的环境参数计算出不同的灌溉时间。并对 RBF 神经网络和模糊控制器进行 MATLAB 仿真, 保证了使用的可行性。最终实验测试结果显示, 在相同的环境条件下, 本设计的灌溉控制器可以实时控制灌溉时间, 在一小时的灌溉时间内, 可以节约用水量达到 21%, 粮食产量每亩同比增加 100 公斤。

参考文献:

- [1] 许景辉, 王 雷, 谭小强, 等. 基于 SOA 优化 PID 控制参数的智能灌溉控制策略研究 [J]. 农业机械学报, 2020 (4): 1-12.
- [2] 王 磊. 枚举法和遗传算法在农田灌溉管道系统优化设计中的应用 [J]. 吉林水利, 2019 (12): 28-31.

- [3] 王庆杰, 岳春芳, 李艺珍, 等. 基于改进粒子群算法的两级渠道水资源优化配置 [J]. 干旱地区农业研究, 2019, 37 (4): 26-33.
- [4] 陈福彬, 柴海莉, 高晶敏. 基于 LabVIEW 的自动化测试平台的设计 [J]. 国外电子测量技术, 2012, 31 (11): 9-14.
- [5] 郭晓玲. 作物需水量预测模型研究及其在灌溉管理信息系统中的应用 [D]. 武汉: 华中科技大学, 2007.
- [6] 陈姬玲, 贾国峰. 神经网络及 BP 网络工作原理 [J]. 郑州牧业工程高等专科学校学报, 2001 (4): 265-267.
- [7] 吴昌友. 神经网络的研究及应用 [D]. 哈尔滨: 东北农业大学, 2007.
- [8] 杨 昊. 基于 BP 神经网络和模糊控制的智能灌溉系统设计 [D]. 淮南: 安徽理工大学, 2019.
- [9] 樊振宇. BP 神经网络模型与学习算法 [J]. 软件导刊, 2011, 10 (7): 66-68.
- [10] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计 [M]. 北京: 清华大学出版社, 2005.
- [11] Alonso Campos J C, Jiménez-Bello M A, Martínez Alzamora F. Real-time energy optimization of irrigation scheduling by parallel multi-objective genetic algorithms [J]. Agricultural Water Management, 2020, 227: 3-4.
- [12] Mohammad Ali Asgharzadeh, Manouchehr Heidarpour, Mohammad Shayannejad, Morteza Rasti-Barzoki. Development of HADIS Algorithm for Deficit Irrigation Scheduling [J]. Irrigation and Drainage, 2018, 67: 2-4.
- [13] Zhang Xuefeng. Comments on "Takagi - Sugeno fuzzy control for a wide class of fractional-order chaotic systems with uncertain parameters via linear matrix inequality" [J]. Journal of Vibration and Control, 2020, 26: 9-10.
- [14] Zhu Yindei, et al. Erratum to Robust control design of electric helicopter tail reduction system: Fuzzy and optimal view [J]. Journal of Vibration and Control, 2020, 26: 9-10.
- [15] Yang Siyang, Han Jiang, Xia Lian, et al. An optimal fuzzy-theoretic setting of adaptive robust control design for a lower limb exoskeleton robot system [J]. Mechanical Systems and Signal Processing, 2020, 141: 3-6.
- [16] Xu Jinghua, Wang Tiantian, Gao Mingyu, et al. Energy and exergy co-optimization of IGCC with lower emissions based on fuzzy supervisory predictive control [J]. Energy Reports, 2020, 6: 7-10.
- [17] Sun Shaoxin, Wang Yingchun, Zhang Huaguang, et al. Multiple intermittent fault estimation and tolerant control for switched T-S fuzzy stochastic systems with multiple time-varying delays [J]. Applied Mathematics and Computation, 2020, 377: 4-5.
- [18] Xin Liping, Yu Bo, Zhao Lin, et al. Adaptive fuzzy backstepping control for a two continuous stirred tank reactors process based on dynamic surface control approach [J]. Applied Mathematics and Computation, 2020, 377: 4-5.