

# 应用 PSO-RBF 神经网络预测太阳能 PV/T 系统的热、电性能

何迪<sup>1</sup>, 王聪聪<sup>1</sup>, 陈红兵<sup>1</sup>, 孙俊辉<sup>2</sup>, 高雪宁<sup>1</sup>, 王传岭<sup>1</sup>, 马卓越<sup>3</sup>

(1.北京建筑大学 环境与能源工程学院 供热供燃气通风及空调工程北京市重点实验室, 北京 100044; 2.中国建筑第六工程局有限公司, 天津 300012; 3.同圆设计集团股份有限公司, 山东 济南 250024)

**摘要:** 为准确预测太阳能光伏光热 (Solar Photovoltaic/Thermal, PV/T) 系统的热、电性能, 文章利用 PSO (Particle Swarm Optimization) 算法优化了 RBF (Radial Basis Function) 神经网络, 并基于此方法建立了太阳能 PV/T 系统性能的仿真预测模型, 与基于未优化 RBF 神经网络建立的预测模型进行了对比分析。同时, 搭建了太阳能 PV/T 实验平台, 通过云平台采集实验数据用于上述模型。研究表明: 使用 PSO 算法优化后的 RBF 神经网络模型相较于未优化模型预测精度提高了 20%, 预测稳定性提高了 30%, 拟合优度  $R$  值有所提升。基于 PSO-RBF 神经网络建立的预测模型可精确预测太阳能 PV/T 系统的热、电性能。

**关键词:** PV/T; RBF 神经网络; PSO 算法; 模拟预测

**中图分类号:** TK519 **文献标志码:** A **文章编号:** 1671-5292(2024)04-0455-09

## 0 引言

在国内“双碳”背景下, 太阳能作为一种清洁能源引起了广泛关注。相比于单一的太阳能光伏或光热系统, 太阳能光伏/光热技术在提高光伏板发电效率的同时得到热能, 能够更高效地利用太阳能<sup>[1]</sup>。由于太阳能 PV/T 系统的运行受到环境因素的高度影响, 当系统投入使用时, 多数情况下电能与热能的产出处于波动的状态。如果并网运行的 PV/T 系统电能输出功率不稳定, 会给整个电网系统带来冲击<sup>[2]</sup>; 同时, 如果不能提前预知太阳能 PV/T 系统的热能产量, 无法对热能进行合理分配和利用, 就会导致能源的浪费。为了降低太阳能 PV/T 设备在运行中的电能安全风险和减少能源损失, 就需要对系统的热、电性能进行精准预测。

国内外众多学者大多采用有限元数值模拟的方式对太阳能 PV/T 系统进行研究, 然而 PV/T 系统的几何模型往往很复杂, 为了简化模型的计算需要设定大量假设条件, 这种做法一定程度上会影响数值模拟的准确性和稳定性<sup>[3]</sup>。在太阳能领域的模拟仿真研究中, 系统的热、电性能受众多因

素影响, 不仅要考虑外界环境因素对系统的影响, 还要考虑系统各组件之间的能量转化与传递过程。人工神经网络不需要明确的数学表示或详尽的实验过程, 提供充足的实验数据即可预测系统的热、电性能, 并且预测精度高、处理速度快。

在众多人工神经网络类型中, 径向基函数 (Radial Basis Function, RBF) 神经网络具备人工神经网络的普遍优点, 同时因其独特的多层前馈结构使得它具有实现任何复杂非线性映射的功能, 特别适合用于求解内部机制复杂的问题, 因此被诸多国内外学者应用于太阳能领域的研究<sup>[4]</sup>。李崎勇<sup>[5]</sup>在研究 PV/T 系统用热、电协调控制组件进行温度控制时, 采用 RBF 神经网络建立组件温度数据预测模型, 该预测方法在晴天时预测精度较高, 最大平均相对误差为 3.60%。但 RBF 神经网络在单独使用过程中, 某些缺点会导致预测误差增大, 如神经网络的网络结构会随隐含层节点的增加变得更加复杂、网络中心点对样本的选择依赖程度高等问题<sup>[6]</sup>。粒子群算法 (Particle Swarm Optimization, PSO) 是一种随机搜索算法, 能够以较高的概率收敛于全局最优解, 可以根据自己的

收稿日期: 2023-03-31。

基金项目: 北京市科技计划项目 (KM202010016012)。

通信作者: 马卓越 (1990-), 女, 硕士, 工程师, 主要从事暖通空调相关研究设计。E-mail: mazhuoyuejiayou@163.com

学习速率决定搜索方向,避免了复杂的遗传操作。Yang Z<sup>[7]</sup>提出了应用 PSO 算法优化 RBF 神经网络模型,预测短期太阳能发电量,结果表明 PSO-RBF 模型可以达到更高的预测精度。Hamdi H<sup>[8]</sup>通过引入 PSO 算法优化 RBF 神经网络模型来追踪光伏系统的最大功率点,发现 PSO-RBF 模型在训练、检验和预测数据的平均相对误差均优于 RBF 算法。上述研究仅对太阳能系统热性能或者电性能某一方面进行了预测,鲜有文献采用人工神经网络对太阳能 PV/T 系统的热、电性能进行综合预测。

由于影响 PV/T 系统热、电性能的原因较多,传统数值模拟难以对系统的热、电性能进行综合

分析与预测。因此,本文提出将 PSO 算法优化的 RBF 神经网络应用到太阳能 PV/T 系统的热、电性能预测中。搭建太阳能热管式 PV/T 实验平台,通过云平台采集实验数据,建立预测热管式太阳能 PV/T 系统的 PSO-RBF 神经网络模型,并与 RBF 神经网络模型进行了对比分析。

### 1 平板热管式太阳能 PV/T 实验系统

#### 1.1 系统工作原理

本文搭建的平板热管式太阳能 PV/T 集热系统主要由平板热管式 PV/T 收集器、联箱、蓄热水箱、补水箱、循环水泵、MPPT (Maximum Power Point Tracking) 控制器、蓄电池、放电设备等组成。图 1 为 PV/T 系统与数据采集系统原理图。

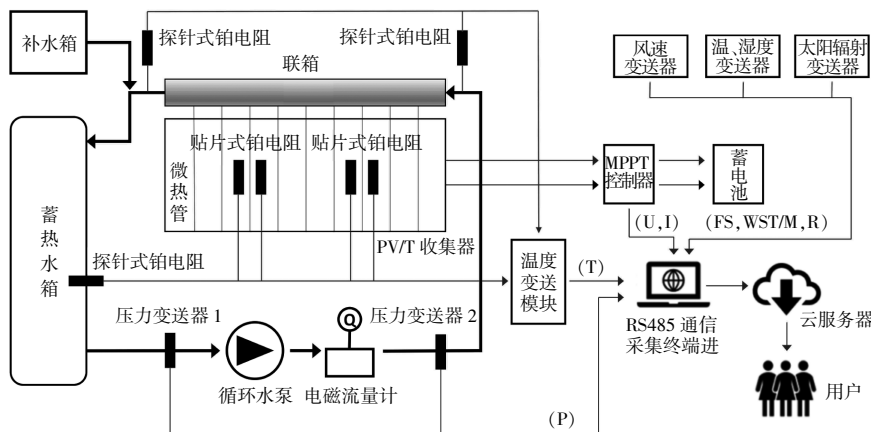


图 1 PV/T 系统与数据采集系统原理图

Fig.1 The schematic diagram of PV/T system and data acquisition system

该平板热管式太阳能 PV/T 系统的工作原理:太阳光照射在 PV/T 收集器上的光伏板,蓄电设备开始储存电能;光伏板被太阳光加热,PV/T 收集器中的热管把热量传递到联箱的水中,循环泵将热水送到蓄热水箱,便可将光伏板上多余的热量转移至蓄热水箱中,光伏板也可因工作温度的降低提高发电效率<sup>[9]</sup>。设备具体参数见表 1。

#### 1.2 数据采集系统

为了方便快捷获取大量数据,本文为上述太阳能 PV/T 系统搭建了互联网数据采集系统,采用 Modbus 协议,通过 RS485 串口与各采集设备进行通信,并汇集到基于树莓派 3 核心板设计的 EdgeBox-RPI 数据采集终端,数据终端将采集数据存储在本地后并上传至阿里云服务器<sup>[10]</sup>。

在联箱进、出口处设置了两个探针式铂电阻,

表 1 PV/T 系统设备参数

Table 1 PV/T equipment system parameters

设备名称	参数	数值
循环水泵	功率/W	200
	流量/L·min <sup>-1</sup>	60
	扬程/m	8
PV/T 收集器	集热面积/m <sup>2</sup>	1.32
	光伏覆盖率/%	95
补水箱	容积/L	40
蓄热水箱	容积/L	120
MPPT 控制器	系统电压/V	12/24
	光伏功率/W	240
	最大太阳能电压/V	50
	电池电流/A	20
	工作电压/V	12
蓄电池	容量/Ah	200
放电设备	功率/W	100

测量联箱进、出口温度;在 PV/T 收集器后面的 4 个贴片式铂电阻分别用于测量 2 处光伏背板温度与 2 处热管温度;在蓄热水箱中的探针式铂电阻用于测量蓄热水温度;铂电阻经过变送模块与数据采集终端进行通信并保存数据。在循环水泵前和电磁流量计后分别布置一个压力变送器以测量系统压降。风速变送器,温度、湿度变送器,太阳辐射变送器分别测量环境风速、温度、湿度,太阳辐射强度。采用具有 Modbus 协议的 MPPT 控制器对光伏板电流、电压进行测量。数据采集相关设备性能、参数见表 2。

表 2 数据采集设备性能参数

Table 2 Performance parameters of data acquisition equipment

设备名称	型号	测量范围	测量精度
探针式铂电阻	WZP-01	-200~450 °C	±0.15 °C
贴片式铂电阻	WZPM-02	-200~550 °C	±0.15 °C
压力变送器	PM-BPS316B	-2~100 kPa	±2%
风速变送器	RS-FS-N01	0~60 m/s	±(0.2+0.03) m/s
温湿度变送器	RS-WS-N01-2-2	-40~60 °C	±0.5 °C
		0%~80%RH	±3%RH
太阳总辐射仪	YGQ-TBQ	0~2 000 W/m <sup>2</sup>	±3%
电磁流量计	JGLDG-DN20SX	0.12~16.96 m <sup>3</sup> /h	±0.5%

1.3 实验结果

以夏季某晴天测量数据为例,对实验台运行结果进行简要分析。

图 2 与图 3 为夏季某晴天测试中的室外环境参数变化情况。

从图 2 中可以看出,测试时间内最高辐射强度时刻位于 11:40,最大辐射强度为 923 W/m<sup>2</sup>;环




图 2 辐射强度与环境温度变化

Fig.2 Variation of solar radiation intensity and ambient temperature




图 3 环境湿度与环境风速变化

Fig.3 Variation of environmental humidity and wind speed

境温度全天维持在 28.60~37.60 °C,环境平均温度为 33.15 °C,最高环境温度点出现在 14:40。从图 3 中可以看出,测试时间内环境湿度全天维持在 50%~60%,环境平均湿度为 54.33%,风速波动为 0~4 m/s,全天基本处于微风状态。

图 4 为当天光伏板的电功率与系统电效率变化。




图 4 光伏板发电功率与系统电效率变化

Fig.4 Variation of photovoltaic panel power generation and system electrical efficiency

从图 4 中可以看出:电功率变化趋势与太阳辐射强度和电流的变化保持一致,最大功率点同样出现在 11:40,此时的太阳辐射强度为 923 W/m<sup>2</sup>,最大发电功率为 117 W;电效率有趋于缓慢上升的趋势,但上升过程中有两处明显大幅度波动,这是由于当系统输出功率过小时,测量设备自身误差使得测量数据与实际值有所偏离,导致电效率的计算结果呈现波动较大的情况。为了减少测量仪器对实验数据的影响,本文在为神经网络模型选择训练数据时,均采用运行期间较为

稳定的数据。

图 5 为系统蓄热水箱温度与系统热效率变化情况。




图 5 蓄热水箱温度与系统热效率变化  
Fig.5 Variation of hot water storage tank and system thermal efficiency

从图 5 中可以看出,水箱初始温度为 26.80℃,在上午阶段,联箱出口的系统循环水温度与蓄热水箱温差较大,水箱此时的吸热速率快,使得蓄热水箱温度能够较为稳定的上升。当系统运行至 15:00 时,联箱出口的系统循环水温度与水箱的温差减小,水箱的吸热效率减弱,水箱温度增长缓慢,并最终在 16:00 左右达到最大值,蓄热水箱最高温度为 47.80℃。系统的平均热效率为 27.20%,最大热效率为 54.15%。由于在 9:00-10:00 时,太阳辐射强度不高以及光伏板被太阳光加热时间较短,联箱中的水温不高,与蓄热水箱的换热较为平缓,因此热效率平稳地增加。在系统运行至 10:00 后,太阳辐射强度的迅速增大使得光伏板表面温度迅速升高,此时系统循环水与水箱温差较大,换热量大,系统热效率在此阶段迅速上升,随着联箱出口温度与蓄热水箱温差的缩小,热效率逐渐减小,当蓄热水箱温度与系统循环水温度一致时,热效率为 0。若此后继续运行,蓄热水箱对系统循环水放热,系统热效率将为负值。

#### 1.4 实验系统性能评价参数

对太阳能 PV/T 系统的性能评价主要从热性能和电性能两方面进行,评价参数分别为蓄热水箱温度、系统热效率与系统电功率、系统电效率。蓄热水箱温度通过实验设备直接测量得到,电功率、电效率及热效率计算式<sup>[9]</sup>分别为

电效率:

$$\eta_e = \frac{Q_e}{GA_{PV}} = \frac{IU}{GA_{PV}} \quad (1)$$

式中: $\eta_e$ 为光伏板发电效率; $Q_e$ 为光伏板发电功率, $W$ ;  $G$ 为太阳辐射强度, $W/m^2$ ;  $A_{PV}$ 为光伏电池的净面积, $m^2$ ;  $I$ 为光伏板输出电流, $A$ ;  $U$ 为光伏板输出电压, $V$ 。

热效率:

$$\eta_{th} = \frac{Q_{th}}{GA_{PVT}} = \frac{cm\Delta T}{GA_{PVT}} \quad (2)$$

式中: $\eta_{th}$ 为热管式 PV/T 系统的热效率; $Q_{th}$ 为热管式 PV/T 系统的蓄热功率, $W$ ;  $A_{PVT}$ 为 PV/T 收集器的集热面积, $m^2$ ;  $c$ 为水的比热容, $J/(kg \cdot ^\circ C)$ ;  $m$ 为蓄热水箱内水的质量, $kg$ ;  $\Delta T$ 为热水箱单位时间的温升, $^\circ C$ 。

电功率:

$$P=UI \quad (3)$$

式中: $P$ 为太阳能光伏板电功率, $W$ 。

## 2 人工神经网络模型建立

### 2.1 RBF 人工神经网络模型

RBF 神经网络<sup>[11]</sup>是由数学家 Powell 在 1987 年首次提出的,根据人工神经网络拓扑结构的分类,RBF 神经网络属于前馈神经网络,图 6 为 RBF 人工神经网络结构。




图 6 RBF 人工神经网络拓扑结构图  
Fig.6 The topological structure diagram of RBF neural network

由图 6 可知,RBF 人工神经网络结构包含 3 层:输入层、隐含层、输出层,输入层和隐含层之间采用直接连接,隐含层与输出层之间采用权值连接。

通过训练,可以得到 RBF 神经网络的核心参数,包括径向基函数中心  $c$ 、方差  $d$  和权值  $\omega$ 。对 RBF 神经网络的训练分为两步<sup>[12]</sup>:首先为无监督

式学习,确定隐含层中的径向基函数中心  $c$  与方差  $d$ ;然后为有监督式学习,提供输入向量  $X$  与对应的目标输出向量  $Y$  和径向基函数宽度向量  $D$ ,训练确定隐含层与输出层间的权值  $\omega$ 。

## 2.2 PSO 算法优化 RBF 神经网络

### 2.2.1 粒子群算法

粒子群算法的基本要素<sup>[13]</sup>可以概括为

$$PSO=(N, X, V, J, K, W, C) \quad (4)$$

式中: $N$  为粒子总数; $X$  为粒子搜寻范围; $V$  为粒子搜寻速度; $J$  为适应性函数,用于计算每次迭代的适应度值; $K$  为迭代计算系数; $W$  为惯性系数,一般取 0.9~1.2; $C$  为学习系数。

在 PSO 算法中,将优化问题的每一个潜在解转化为搜索空间  $X$  中的一个粒子,粒子总数为  $N$ ,采用适应性函数  $J$  计算所有粒子的迭代适应度值,所有粒子以速度  $V$  追随当前的最优粒子在解空间中搜索最优值。惯性系数  $W$  与学习系数  $C$  用于调节粒子的搜寻能力。通过  $I$  次迭代后,输出问题解的全局最优值。

粒子群算法是在多个粒子行为的运动过程中得到全局最优解,每个粒子都能单独进行仿生优化,同时各个粒子之间可以相互并行协作以更好的适应各类环境。传统优化算法如遗传算法、蚁群算法等在动态、多目标优化环境中进行求解的过程相对缓慢,而粒子群算法得益于快速的求解能力和全面的搜索性能,更适合在复杂变换的环境中进行求解寻优。粒子群算法也同时具备人工神经网络的存储、记忆功能,可以根据历史搜索情况对搜索方向和范围进行重新判断,实时更新求解方案。这些特点对于求解复杂的太阳能系统参数能起到良好的作用。

### 2.2.2 优化过程

PSO 算法对 RBF 神经网络的优化流程如图 7 所示。

初始化粒子群参数(位置、速度、惯性系数等),并映射到 RBF 神经网络中;评价出每个粒子的初始适应值并作为该粒子的最优值,每个初始适应值对应的位置作为该粒子的最优位置;迭代更新粒子速度与粒子位置;对比各粒子的适应值是否优于历史最优值,如果是则替换之,否则继续迭代更新直到满足设定的最小误差或达到最大迭

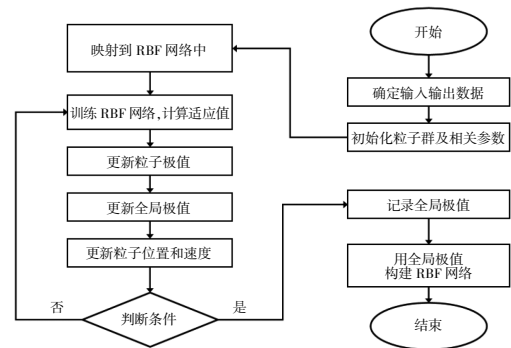


图 7 粒子群算法优化 RBF 神经网络流程

Fig.7 The flow chart of particle swarm optimization optimizes BP neural network

代次数;最后输出最优粒子的全局最优值和其对应的位置以及每个粒子的局部最优值和对应的位置,导入最优值到 RBF 神经网络中,构建优化后的模型,该模型经过网络训练后对输出向量进行预测输出<sup>[14]</sup>。

### 2.3 预测模型运行参数确定

影响热管式太阳能 PV/T 系统热、电性能的主要环境因素有环境温度、环境湿度、光伏板温度、太阳辐射强度和太阳入射角度,并且系统的热性能与电性能之间会产生相互影响<sup>[15]</sup>。本文分别建立模型对热性能和电性能指标进行预测,选择上述 5 种主要环境因素作为输入向量,同时考虑到热性能与电性能之间的相互影响,在预测系统电性能时加入蓄热水箱温度作为输入向量,输出向量为电功率与电效率;在预测系统热性能时加入系统电功率作为输入向量,输出向量为热效率与蓄热水箱温度。网络的输入节点数为 6,输出节点数为 1,隐含层节点的选择会影响神经网络预测精度,一般按经验公式选取初始值并通过反复对比确定最终节点数,确定隐含层节点数  $M$  的经验公式<sup>[16]</sup>为

$$M=\sqrt{i+j}+p \quad (5)$$

式中: $M$  为隐含层节点数; $i$  为输入层神经元个数; $j$  为输出层神经元个数; $p$  为 1~10 的常数。经反复试用调节,本文中神经网络的训练与测试中预测模型的隐含层节点数选取为 6 个。

RBF 神经网络具体的运行参数值设置如表 3 所示。

表 3 RBF 神经网络模型运行参数

Table 3 Operation parameter of RBF artificial neural network model

参数	设定值	参数	设定值
输入节点数/个	6	隐含层节点数/个	6
输出节点数/个	1	训练速率	0.01
最大允许误差/%	0.001	迭代次数/次	100
训练样本数/个	19 900	检验样本数/个	100

PSO-RBF 神经网络模型对太阳能 PV/T 系统热、电产出进行预测前要设置网络运行参数,除设置 RBF 神经网络模型的网络节点(输入节点数、隐含层节点数、输出节点数)、训练速率、允许误差、训练次数 4 种基本参数外,还要对遗传算法的运行参数进行设定,包括粒子群总数  $N$ 、粒子维度、迭代次数  $K$ 、惯性系数  $W$  和学习系数  $C$ 。相关参数设定值如表 4 所示。

表 4 PSO-RBF 神经网络模型运行参数值

Table 4 Operation parameter values of PSO-RBF neural network model

参数	设定值	参数	设定值
输入节点数/个	6	隐含层节点数/个	6
输出节点数/个	1	训练速率	0.01
最大允许误差/%	0.001	训练次数/次	100
训练样本数/个	19 900	检验样本数/个	100
粒子群总数/个	30	粒子维度数/个	9
惯性系数	0.9	学习系数	1.5
迭代次数/次	150		


确定以上参数后,本文调取数据端夏日某晴天的 2 000 组数据,其中取 1 900 组做为训练数据,其余 100 组样本作为检验组与实验数据进行对比分析。为方便分析,检验组数据在系统运行时段随机取值,按照数值大小进行排序。

### 3 模型预测结果分析


为了验证本文提出的 PSO-RBF 神经网络模型是否可行,将 RBF 和 PSO-RBF 两组模型的预测结果均与实验数据进行了对比,并且计算出了两种模型的平均绝对误差 MAE、平均相对误差 MRE、均方误差 MSE、均方根误差 RMSE 及拟合度  $R$  值共 5 种模型评价指标。MAE 与 MRE 值越小,表明模型预测的精度越高;MSE 与 RMSE 值越小,表明模型预测的稳定性越好; $R$  值越接近 1,表示模型预测效果越好。

#### 3.1 电能产出结果分析

图 8,9 为两种神经网络模型预测系统电性能



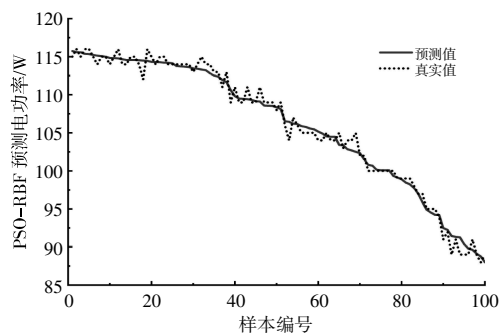
(a)RBF 预测电功率




(b)RBF 预测电效率

图 8 RBF 预测电性能

Fig.8 RBF predicted electrical performance



(a)PSO-RBF 预测电功率



(b)PSO-RBF 预测电效率

图 9 PSO-RBF 预测电性能

Fig.9 PSO-RBF predicted electrical performance

的情况。

由图 8,9 可见,预测值与检验样本真实值较

为匹配,且当检验样本真实值波动较为明显时,两种模型的平均预测误差也能保持较为稳定的水平。

表 5 为两种模型电性能的评价指标。

表 5 两种模型预测电性能的评价指标  
Table 5 Evaluation indicators for predicting electrical performance using two models

预测方法	电性能	MAE	MRE	MSE	RMSE	R
RBF	电功率	1.20 W	1.30%	2.63	1.620 0	0.998 7
	电效率	0.14%	1.20%	$1.50 \times 10^{-7}$	0.002 0	0.988 5
PSO-RBF	电功率	0.84 W	0.91%	1.96	1.400 0	0.999 7
	电效率	0.16%	1.30%	$6.00 \times 10^{-7}$	0.002 4	0.988 5


由表 5 可以看出,PSO-RBF 模型相比未优化

的 RBF 模型在电功率预测中的 5 种评价指标上均有所提升,PSO-RBF 模型的电功率平均相对误差为 0.91%,低于 RBF 模型的 1.30%;最大相对误差为 2.71%,低于 RBF 模型的 4.40%。在电功率方面,PSO-RBF 模型具有更高的预测精度和稳定度;在电效率方面,两种模型的预测精度与稳定度相差不大。


### 3.2 热能产出结果分析

图 10,11 为两种神经网络模型预测热性能的情况。

由图 10,11 可以看出,预测值与检验样本真实值较为匹配。




(a)RBF 预测热效率




(b)RBF 预测蓄热水箱温度

图 10 RBF 预测热性能

Fig.10 RBF Predicted thermal performance



(a)PSO-RBF 预测热效率



(b)PSO-RBF 预测蓄热水箱温度

图 11 PSO-RBF 预测热性能

Fig.11 PSO-RBF Predicted thermal performance

表 6 为两种模型热性能的评价指标。

由表 6 可见,对于系统热性能的预测,PSO-RBF 模型明显优于 RBF 模型,5 项评价指标均有所提高,其中,PSO-RBF 模型预测热效率与蓄热水箱温度的平均相对误差分别为 0.60%,0.52%,高于未优化的 RBF 模型的 0.80%,0.60%;拟合度 R 值相较于未优化前均有所提高,证实了优化后的 PSO-RBF 模型预测值与真实值拟合度更高,

表 6 两种模型预测热性能的评价指标

Table 6 Evaluation indicators for predicting thermal performance using two models

预测方法	热性能	MAE	MRE	MSE	RMSE	R
RBF	热效率	0.32%	0.80%	$4.00 \times 10^{-7}$	0.006 0	0.997 2
	水箱温度	0.30 °C	0.60%	0.21	0.460 0	0.996 8
PSO-RBF	热效率	0.24%	0.60%	$1.10 \times 10^{-7}$	0.003 3	0.998 4
	水箱温度	0.24 °C	0.52%	0.15	0.390 0	0.997 6

化后的模型在系统热性能预测上具有更高的精度

与稳定度。

#### 4 结论

本文基于 PSO 算法优化了 RBF 神经网络模型,并建立了太阳能 PV/T 实验系统,对其电功率、电效率、蓄热水箱温度和热效率进行预测。通过对比未优化的 RBF 神经网络模型和实际的实验数据,得出以下结论。

①PSO-RBF 神经网络模型能够很好地预测太阳能 PV/T 系统的热、电性能。电功率、电效率、蓄热水箱温度和热效率的平均相对误差分别为 0.91%、1.30%、0.52%、0.60%,相对误差最大值低于 2.70%。

②PSO-RBF 模型预测精度优于 RBF 神经网络模型。优化后的模型预测 MAE 值与 MRE 值平均下降了 20%,相较于未优化前的 RBF 网络模型预测精度提高了 20%。

③PSO-RBF 模型预测稳定度优于 RBF 神经网络模型。优化后的模型预测 MSE 值与 RMSE 值平均下降了 30%,相较于未优化前的 RBF 网络模型预测稳定度平均提高 30%。

#### 参考文献:

- [1] Abdelrazik A S, Al-Sulaiman F A, Saidur R, et al. A review on recent development for the design and packaging of hybrid photovoltaic/thermal (PV/T) solar systems[J]. *Renewable and Sustainable Energy Reviews*, 2018, 95: 110-129.
- [2] Aste N, Del Pero C, Leonforte F, et al. Performance monitoring and modeling of an uncovered photovoltaic-thermal (PVT) water collector [J]. *Solar Energy*, 2016, 135: 551-568.
- [3] 陈红兵, 孙俊辉, 王聪聪, 等. 应用遗传算法优化 BP 神经网络预测太阳能 PV/T 系统热电产出[J]. *热科学与技术*, 2021, 20(5): 480-487.
- [4] Syed M A, Khalid M. Neural network predictive control for smoothing of solar power fluctuations with battery energy storage [J]. *Journal of Energy Storage*, 2021, 42: 103014.
- [5] 李崎勇, 赵振东, 南君培, 等. 基于 RBF 神经网络 PV/T 组件短期温度预测[J]. *广西大学学报(自然科学版)*, 2017, 42(3): 1035-1041.
- [6] Kalogirou S A, Panteliou S, Dentsoras A. Modeling of solar domestic water heating systems using artificial neural networks [J]. *Solar Energy*, 1999, 65 (6): 335 - 342.
- [7] Yang Z, Mourshed M, Liu K, et al. A novel competitive swarm optimized RBF neural network model for short-term solar power generation forecasting [J]. *Neurocomputing*, 2020, 397: 415-421.
- [8] Hamdi H, Regaya C B, Zaafouri A. Real-time study of a photovoltaic system with boost converter using the PSO -RBF neural network algorithms in a MyRio controller[J]. *Solar Energy*, 2019, 183: 1-16.
- [9] 陈红兵, 姚华宁, 龚雨桐, 等. 新型平板热管式太阳能 PV/T 集热系统的性能研究 [J]. *可再生能源*, 2019, 37 (8): 1139-1145.
- [10] 张晓坤. 基于云平台的太阳能利用监测系统设计与应用研究[D]. 北京: 北京建筑大学, 2021.
- [11] Powell J D. Radial basis function approximations to polynomials[A]. *Proceedings of 12th Biennial Numerical Analysis Conference [C]*. Dundee: Longman Publishing Group, 1987. 223-241.
- [12] Talaat M, Said T, Essa M A, et al. Integrated MFFNN-MVO approach for PV solar power forecasting considering thermal effects and environmental conditions [J]. *International Journal of Electrical Power & Energy Systems*, 2022, 135: 107570.
- [13] Kennedy J, Eberhart R. Particle swarm optimization[A]. *Proceedings of ICNN'95 - International Conference on Neural Networks[C]*. Perth: IEEE, 1995. 1942-1948.
- [14] 李宏宇, 王莹, 陆震, 等. 基于 PSO-GA 算法和神经网络的水下机器人姿态协调控制[J/OL]. *中国测试*: 1-7 [2023 -04 -27]. <http://kns.cnki.net/kcms/detail/51.1714.TB.20220322.1838.048.html>.
- [15] Gang P, Huide F, Tao Z, et al. A numerical and experimental study on a heat pipe PV/T system[J]. *Solar Energy*, 2011, 85(5): 911-921.
- [16] 王嵘冰, 徐红艳, 李波, 冯勇. BP 神经网络隐含层节点数确定方法研究[J]. *计算机技术与发展*, 2018, 28(4): 31-35.

## Prediction of thermal and electrical performance of solar PV/T system using PSO-RBF neural network

He Di<sup>1</sup>, Wang Congcong<sup>1</sup>, Chen Hongbing<sup>1</sup>, Sun Junhui<sup>2</sup>, Gao Xuening<sup>1</sup>, Wang Chuanling<sup>1</sup>, Ma Zhuoyue<sup>3</sup>

(1.School of Environment and Energy Engineering, Beijing Municipal Key Lab of HVAC, Beijing University of Civil Engineering and Architecture, Beijing 100044, China; 2.China Construction Sixth Engineering Bureau Corp., Ltd, Tianjin 300012, China; 3.Tong Yuan Design Group Co.,Ltd, Ji'nan 250024, China)

**Abstract:** In order to accurately predict the thermal and electrical performance of solar photovoltaic/thermal (PV/T) systems, this study utilized the Particle Swarm Optimization (PSO) algorithm to optimize the Radial Basis Function (RBF) neural network. Based on this method, a simulation prediction model for the performance of solar PV/T systems was established and compared with a prediction model based on an unoptimized RBF neural network. Additionally, this research built a solar PV/T experimental platform and collected experimental data using a cloud platform for the aforementioned model. The research results indicate that the RBF neural network model optimized using the PSO algorithm exhibits better prediction accuracy compared to the unoptimized RBF neural network model. The optimized RBF neural network model demonstrates a 20% improvement in prediction accuracy and a 30% increase in prediction stability compared to the unoptimized model. The goodness of fit, as indicated by the  $R$ -value, is also improved compared to the unoptimized model. The prediction model established based on the PSO-RBF neural network can accurately predict the thermal and electrical performance of solar PV/T systems.

**Keywords:** PV/T; RBF neural network; PSO algorithm; simulation prediction