

基于延迟回声状态网的光伏电池板温度预测方法

范思远¹ 姚显双¹ 曹生现¹ 赵波¹

摘要 光伏电池温度变化影响光伏系统输出的稳定性, 精准地预测光伏电池板温度的变化趋势, 对光伏系统智能运行具有重要意义. 为了更好地预测温度的变化趋势, 本文考虑了光伏电池板温度的迟滞效应, 将先前的温度输出作为延迟项引入回声状态网中, 提出了一种基于延迟回声状态网的光伏电池板温度预测模型. 给出一个延迟回声状态网具有回声状态特性的判定条件, 使得预测模型能够稳定地预测光伏电池板温度. 同时, 建立了一套光伏多传感器监测系统, 利用该监测系统采集的数据, 训练和验证模型的准确性. 与回声状态网 (Echo state network, ESN), Leaky ESN (Leaky-integrator ESN) 和 VML ESN (ESN with variable memory length) 相比, 仿真结果表明, 本文所提出的延迟回声状态网具有更好的预测性能, 平均绝对百分比误差甚至达到 3.45%.

关键词 光伏, 电池板温度, 回声状态网, 热迟滞效应, 回声状态特性

引用格式 范思远, 姚显双, 曹生现, 赵波. 基于延迟回声状态网的光伏电池板温度预测方法. 自动化学报, 2020, 46(12): 2701-2710

DOI 10.16383/j.aas.c200167

Temperature Prediction of Photovoltaic Panels Based on Delayed Echo State Network

FAN Si-Yuan¹ YAO Xian-Shuang¹ CAO Sheng-Xian¹ ZHAO Bo¹

Abstract The temperature change of photovoltaic (PV) cells can affect the output stability of PV system, and then the temperature change trend of PV panels can be predicted accurately, which will be significance for the intelligent operation of PV system. In order to better predict the change trend of temperature, this paper takes into account the hysteresis effect of PV panels temperature, and the previous temperature output is introduced into the echo state network (ESN), and thus, an improved prediction model of PV panels temperature based on the delayed echo state network is proposed in this paper. A criterion condition for the echo state characteristic of the delayed echo state network is given, such that the prediction model can predict the temperature of the PV panels stably. At the same time, a multi-sensor monitoring system of PV is established, and the collected data by monitoring system are used to train and verify the accuracy of model. Compared with ESN, Leaky ESN (Leaky-integrator ESN) and VML ESN (ESN with variable memory length), the simulation results show that the Delay ESN has better prediction performance, and the average absolute percentage error of 3.45%.

Key words Photovoltaic (PV), temperature of panels, echo state network (ESN), thermal hysteresis effect, echo state property

Citation Fan Si-Yuan, Yao Xian-Shuang, Cao Sheng-Xian, Zhao Bo. Temperature prediction of photovoltaic panels based on delayed echo state network. *Acta Automatica Sinica*, 2020, 46(12): 2701-2710

我国积极推行“清洁、低碳、安全、高效”的能源体系建设, 预计到 2030 年, 清洁能源发电总量将占装机发电总量的 50%^[1]. 光伏发电作为新能源发电的重要组成部分, 截至 2019 年底, 全国并网光伏总

规模达 204.68 GW, 且以平均每年 10% 的速率快速增长. 然而, 光伏发电的不稳定性给并网带来了严重的挑战. 当前在电网的日常运维调度中, 利用光伏发电短期预测, 统筹规划常规能源发电与光伏发电之间的关系 (并网功率与调峰政策等), 然而, 在同等气象条件下, 光伏电池温度变化直接影响光伏系统输出稳定性. 因此, 精准地预测光伏电池板温度变化特性, 将有助于提高光伏功率预测精度, 提升光伏发电系统并网的安全.

光伏电池板温度作为光伏发电最相关的参数之一, 比环境温度更能直接体现外部因素对发电效率的影响. 根据光生伏特效应可知, 硅晶体的光伏电池板实际的光电转换效率只有 15%~20%, 未被利用的能量将会转化成热能, 积累的热量将会破坏光

收稿日期 2020-03-30 录用日期 2020-07-12

Manuscript received March 30, 2020; accepted July 12, 2020

国家重点研发计划 (2018YFB1500800), 吉林省科技发展计划 (20190302079GX), 吉林市科技创新发展计划 (201830819) 资助

Supported by National Key Research and Development Program of China (2018YFB1500800), Science and Technology Development Program of Jilin Province (20190302079GX), Science and Technology Innovation Development Program of Jilin City (201830819)

本文责任编辑 孙秋野

Recommended by Associate Editor SUN Qiu-Ye

1. 东北电力大学自动化工程学院 吉林 132012

1. School of Automation Engineering, Northeast Electric Power University, Jilin 132012

伏板的电气性能,导致光伏板温度升高,甚至会引起“热斑效应”,造成系统输出功率降低,给光伏系统的预测工作带来困难。

而在光伏系统实际发电过程中,引起电池板温度变化的因素较多,其变化机理复杂,受气象条件、电池材料和晶体内部构造等影响。早期工作多集中于稳态热模型(Steady state thermal model, SSTM)的研究,即忽略温度变化过程中存在的热迟滞效应,基于气象条件建立半经验模型^[2]。事实上,光伏电池板温度的变化存在一定延迟,热传导过程与时间具有强关联性,如何能够在建立的模型中准确地描述热迟滞过程,提高模型的预测精度,变成了一个值得探讨的问题。

国内外学者就光伏电池板温度预测问题开展了广泛的研究,提出了许多有效的模型。赵志刚等^[2]建立了基于粒子群优化支持向量机(Particle swarm optimization-support vector machine, PSO-SVM)的光伏电池温度预测热模型,通过实验对比,其模型的预测精度优于反向传播(Back propagation, BP)神经网络和稳态热模型。徐瑞东等^[3]分析了光伏电池板温度与环境温度和输出功率的关系,提出了一种基于BP神经网络的光伏阵列电池板温度预测方法,实现了利用前一天的数据来预测当天的温度。Xu等^[4]分析了光伏电池板温度、环境温度与输出功率之间的关系,提出了一种基于高斯过程的光伏电池板温度预测方法,并通过实验验证了该方法的有效性。Ceylan等^[5]利用测量的光照幅度和环境温度数据对神经网络进行训练,建立了基于BP神经网络的光伏电池板温度预测模型。鹏飞等^[6]提出了一种计及太阳能表面晶硅纹理结构的光热特性耦合预测模型,并用于短、中期光伏电池温度变化预测。Sun等^[7-8]提出了基于BP神经网络和基于SVM神经网络的光伏电池板温度短期逐级预测方法,通过相关系数分析确定了影响电池板温度变化的主要因素,并建立了各气候类型下逐级预测模型,利用实际运行数据验证了模型的精度。Jakhrani等^[9]研究了不同模型对光伏电池板温度预测的适用性,并评估了环境温度和光照幅度对电池板温度的影响。

由于光伏电池板温度变化受多种因素影响,具有非线性、迟滞性等特点,而传统神经网络存在收敛速度慢、训练方法复杂等问题,难以获得理想的结果。Jaeger等^[10]在2001年提出了回声状态网(Echo state network, ESN),将储备池的概念引入传统的递归神经网络中,能有效地克服神经网络中局部最小问题,取得了良好的预测性能。为了获得更好的泛化能力,以适用不同的应用场景,研究学者针对回声状态网络进行了多种优化改进。Gallicchio

等^[11-12]提出了深度回声状态网(Deep echo state network, DeepESN)和深度树型回声状态网(Deep tree echo state network, DeepTESN),并证明了该方法的可行性和准确性。Chitsazan等^[13]提出了一种具有非线性函数的回声状态网,并应用于风速、风向的预测。Matino等^[14-15]将改进回声状态网应用于高炉煤气生产预测,减少了资源的损失和废气的排放。伦淑娴等^[16]提出了利用改进的小世界网络优化泄露积分型回声状态网(Leaky-integrator echo state network, Leaky ESN)的时间序列预测方法,提高了时间序列的预测精度。许美玲等^[17]提出了一种改进差分进化法来优化回声状态网的预测模型,具有能够适应不同时间序列的动力学特性,提高了模型的预测精度和泛化性能。刘颖等^[18]针对高炉煤气发生量的预测问题,提出了一种基于数据的改进回声状态网预测方法,克服了线性回归算法出现的病态问题,提高了模型的预测精度。雷苗等^[19]针对具有多周期特性的话务量序列预测问题,提出了一种基于先验簇复杂回声状态网的移动通信话务量预测模型。田中大等^[20]针对网络流量预测控制问题,提出了种基于混沌理论与改进回声状态网的网络流量预测方法。姚显双等^[21-23]对光伏发电系统特性及影响发电的因素进行分析,提出了正弦回声状态网(Sinusoidal echo state network, SESN)和宽度回声状态网(Broad echo state network, Broad-ESN),用于光伏发电量时序预测,取得了良好的预测性能。Li等^[24]提出了一种多簇回声状态网(Multiclustered echo state network, MCESN),并应用于光伏发电预测。通过数据挖掘方法定性地研究了实测和估算的光伏功率数据特征,与自回归移动平均(Autoregressive moving average, ARMA)、BP神经网络相比,MCESN具有更高的预测精度。

通过总结上述文献,这些方法都是对储备池状态或网络结构进行一定的改进,但是,针对光伏电池板温度预测问题,这些方法都难以很好的适用。光伏电池板温度变化常受前一个或几个时刻的影响,本文结合温度变化的热迟滞效应,将延迟输出项引入回声状态网中,提出一种基于延迟回声状态网的光伏电池板温度预测方法,使其能够充分地反映出温度变化特性。

同时,为了保证所提出的延迟回声状态网能够稳定地应用于光伏电池板温度预测,我们给出延迟回声状态网具有回声状态特性的一个充分条件。此外,为了反映出改进方法的有效性,通过建立光伏多传感器监测系统,获取历史数据信息,以环境温度、光照幅度、风速、风向为输入变量,光伏电池板温度为输出变量,建立基于延迟回声状态网的光伏

电池板温度预测模型, 与其他改进方法对比, 延迟回声状态网具有更高的预测性能。

1 改进回声状态网

为了更好地描述光伏电池板温度变化存在的热滞效应, 在泄露积分型回声状态网^[25]中引入延迟输出项, 并给出了延迟回声状态网的离散储备池状态更新方程和输出方程。

1.1 标准回声状态网

回声状态网是一种新型的递归神经网络, 内部具有一个循环网络结构, 构成了回声状态储备池, 具有较强的非线性学习能力. 其网络结构和学习方法与传统神经网络不同, 只需采用线性方法训练输出权值即可, 这样大大简化了网络的训练过程. 回声状态网的结构如图 1 所示, 网络内包括一个输入层, 一个储备池和一个输出层. 输入为 $u(n)$, K 个节点, 储备池状态为 $x(n)$, N 个节点, 输出为 $y(n)$, L 个节点. $W^{\text{in}} \in \mathbf{R}^{N \times K}$ 表示从输入层到储备池的权值矩阵, $W \in \mathbf{R}^{N \times N}$ 表示储备池内部权值矩阵, $W^{\text{fb}} \in \mathbf{R}^{N \times L}$ 表示从输出层到储备池的输出反馈权值矩阵, $W^{\text{out}} \in \mathbf{R}^{L \times (K+N)}$ 表示从储备池到输出层的权值矩阵。

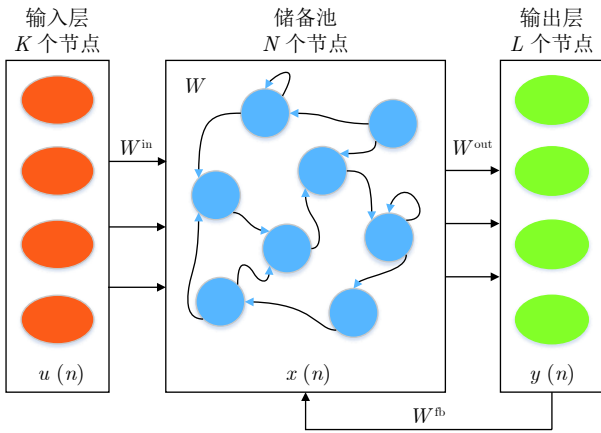


图 1 回声状态网的结构

Fig.1 The structure of echo state network

标准回声状态网的离散储备池状态更新方程和输出方程为

$$x(n+1) = f(W^{\text{in}}u(n+1) + Wx(n) + W^{\text{fb}}y(n)) \quad (1)$$

$$y(n) = g(W^{\text{out}}[x(n); u(n)]) \quad (2)$$

其中, f 表示储备池激活函数 (通常使用 \tanh 函数), g 表示输出激活函数 (通常使用 identity 函数)。

回声状态网的训练过程是根据给定的训练样本

确定系数输出连接权矩阵 W^{out} 的过程. 其训练过程可以分为两个阶段: 采样和权值计算. 完成网络训练后建立模型, 就能够进行相应的问题预测。

1.2 延迟回声状态网

光伏电池板温度变化存在热滞效应, 当前时刻的温度常受前一个或几个时刻的温度影响. 为了满足光伏电池板温度变化的特点, 考虑温度变化的延迟效应, 本文提出一种具有时延特性的改进回声状态网, 将延迟输出项引入泄露积分型回声状态网中, 其结构如图 2 所示. 网络内包括一个输入层, 一个储备池, 一个输出层和一个输出延迟项. 输入为 $u(n)$, K 个节点, 储备池状态为 $x(n)$, N 个节点, 输出为 $y(n)$, L 个节点, 期望输出 $\hat{y}(n)$ 与输出 $y(n)$ 的差值为误差 $e(n)$, $W^{\text{fb}1} \in \mathbf{R}^{N \times L}$ 表示从输出层到储备池的输出反馈权值矩阵, $W^{\text{fb}2} \in \mathbf{R}^{N \times L}$ 表示延迟反馈权值矩阵。




图 2 延迟回声状态网的结构

Fig.2 The structure of delayed echo state network

延迟回声状态网的离散储备池状态更新方程和输出方程为

$$x(n+1) = ax(n) + f(W^{\text{in}}u(n+1) + Wx(n) + W^{\text{fb}1}y(n) + W^{\text{fb}2}y(n-\tau)) \quad (3)$$

$$y(n) = W^{\text{out}}[x(n); u(n)] - \alpha y(n-\tau) \quad (4)$$

其中, $a \in (0, 1]$ 表示泄露积分率, α 表示延迟因子, τ 表示延迟跨度. 因此, 把满足式 (3) 和式 (4) 的模型称为延迟回声状态网。

在延迟回声状态网的训练过程中, 能够考虑输出反馈和延迟反馈来提高对之前输出信息的利用率, 更好地匹配输入延迟特征。

2 温度预测模型

针对光伏电池板温度预测问题, 在本节构建一种基于延迟回声状态网的光伏电池板温度预测模

型, 该模型能够在考虑温度变化热迟滞效应的基础上, 充分地反映出温度变化的特性.

2.1 预测模型的稳定性分析

由于延迟回声状态网是一种特殊的回声状态网, 其属性也应该具有回声状态特性. 回声状态特性能够保证延迟回声状态网在光伏电池板温度预测中稳定应用. 因此, 我们将为延迟回声状态网的回声特性提供一个充分条件.

对于输出权值矩阵 W^{out} , 将其分解如下形式

$$W^{\text{out}} = [W_x^{\text{out}} \ W_u^{\text{out}}] \quad (5)$$

其中, 矩阵 W_x^{out} 和 W_u^{out} 的维数分别为 $L \times N$ 和 $L \times K$.

那么, 输出方程重新写为

$$y(n) = W^{\text{out}}[x(n); u(n)] - \alpha y(n - \tau) = W_x^{\text{out}}x(n) + W_u^{\text{out}}u(n) - \alpha y(n - \tau) \quad (6)$$

因此, 延迟回声状态网的储备池状态更新方程为

$$\begin{aligned} x(n+1) &= ax(n) + f\left(W^{\text{in}}u(n+1) + Wx(n) + W^{\text{fb1}}(W_x^{\text{out}}x(n) + W_u^{\text{out}}u(n) - \alpha y(n - \tau)) + W^{\text{fb2}}y(n - \tau)\right) = \\ &= ax(n) + f\left(W^{\text{in}}u(n+1) + Wx(n) + W^{\text{fb1}}W_x^{\text{out}}x(n) + W^{\text{fb1}}W_u^{\text{out}}u(n) + (W^{\text{fb2}} - \alpha W^{\text{fb1}})y(n - \tau)\right) = \\ &= ax(n) + f\left(W^{\text{in}}u(n+1) + W^*x(n) + W_u^*u(n) + W_{\text{fb}}^*y(n - \tau)\right) \end{aligned} \quad (7)$$

其中, $W_{\text{fb}}^* = W^{\text{fb2}} - \alpha W^{\text{fb1}}$, $W^* = W + W^{\text{fb1}}W_x^{\text{out}}$, $W_u^* = W^{\text{fb1}}W_u^{\text{out}}$.

对于延迟回声状态网具有回声状态特性问题, 我们给出定理 1.

定理 1. 对于延迟回声状态网络模型, 如果能够满足如下条件:

- 1) $W^{\text{fb2}} \neq 0$, $\alpha W^{\text{fb1}} \neq 0$;
- 2) $n = m\tau$;
- 3) $|a| + \delta_{\text{max}}^* + \delta_{\text{fbmax}}^* (1 - \alpha + \alpha^2 - \alpha^3 + \dots + (-\alpha)^{m-1}) < 1$.

那么, 延迟回声状态网络模型具有回声状态特性. 其中, δ_{max}^* 和 δ_{fbmax}^* 分别是 W^* 和 $W_{\text{fb}}^*W_x^{\text{out}}$ 的最大奇异值.

证明. 对于任意两个储备池状态 $x(n+1)$ 和

$x'(n+1)$, 可得

$$\begin{aligned} \|x(n+1) - x'(n+1)\| &= \|ax(n) + f(W^{\text{in}}u(n+1) + W^*x(n) + W_u^*u(n) + W_{\text{fb}}^*y(n - \tau)) - ax'(n) - f(W^{\text{in}}u(n+1) + W^*x'(n) + W_u^*u(n) + W_{\text{fb}}^*y'(n - \tau))\| \leq \\ &= \|ax(n) - ax'(n)\| + \|f(W^{\text{in}}u(n+1) + W^*x(n) + W_u^*u(n) + W_{\text{fb}}^*y(n - \tau)) - f(W^{\text{in}}u(n+1) + W^*x'(n) + W_u^*u(n) + W_{\text{fb}}^*y'(n - \tau))\| \leq \\ &= |a|\|x(n) - x'(n)\| + \|W^{\text{in}}u(n+1) + W^*x(n) + W_u^*u(n) + W_{\text{fb}}^*y(n - \tau) - W^{\text{in}}u(n+1) - W^*x'(n) - W_u^*u(n) - W_{\text{fb}}^*y'(n - \tau)\| \leq \\ &= |a|\|x(n) - x'(n)\| + \|W^*x(n) - W^*x'(n)\| + \|W_{\text{fb}}^*y(n - \tau) - W_{\text{fb}}^*y'(n - \tau)\| \leq \\ &= |a|\|x(n) - x'(n)\| + W^*\|x(n) - x'(n)\| + W_{\text{fb}}^*\|y(n - \tau) - y'(n - \tau)\| \end{aligned} \quad (8)$$

其中, $\|\cdot\|$ 表示欧拉范数.

对于式 (8) 中的 $y(n - \tau) - y'(n - \tau)$, 我们能够得到

$$\begin{aligned} \|y(n - \tau) - y'(n - \tau)\| &= \|W_x^{\text{out}}x(n - \tau) + W_u^{\text{out}}u(n - \tau) - \alpha y(n - 2\tau) - W_x^{\text{out}}x'(n - \tau) - W_u^{\text{out}}u(n - \tau) + \alpha y'(n - 2\tau)\| \leq \\ &= W_x^{\text{out}}\|x(n - \tau) - x'(n - \tau)\| - |\alpha|\|y(n - 2\tau) - y'(n - 2\tau)\| \end{aligned} \quad (9)$$

同理,

$$\begin{aligned} \|y(n - 2\tau) - y'(n - 2\tau)\| &= \|W_x^{\text{out}}x(n - 2\tau) + W_u^{\text{out}}u(n - 2\tau) - \alpha y(n - 3\tau) - W_x^{\text{out}}x'(n - 2\tau) - W_u^{\text{out}}u(n - 2\tau) + \alpha y'(n - 3\tau)\| \leq \\ &= W_x^{\text{out}}\|x(n - 2\tau) - x'(n - 2\tau)\| - |\alpha|\|y(n - 3\tau) - y'(n - 3\tau)\| \end{aligned} \quad (10)$$

因此,

$$\begin{aligned} \|y(n - (m - 1)\tau) - y'(n - (m - 1)\tau)\| &= \|W_x^{\text{out}}x(n - (m - 1)\tau) + W_u^{\text{out}}u(n - (m - 1)\tau) - \alpha y(n - m\tau) - W_x^{\text{out}}x'(n - (m - 1)\tau) - W_u^{\text{out}}u(n - (m - 1)\tau) + \alpha y'(n - m\tau)\| \leq \\ &= W_x^{\text{out}}\|x(n - (m - 1)\tau) - x'(n - (m - 1)\tau)\| - |\alpha|\|y(0) - y'(0)\| \end{aligned} \quad (11)$$

将式 (10) 和式 (11) 代入式 (9) 中, 得到

$$\begin{aligned} \|y(n-\tau) - y'(n-\tau)\| \leq & W_x^{\text{out}} \|x(n-\tau) - x'(n-\tau)\| - \\ & \alpha W_x^{\text{out}} \|x(n-2\tau) - x'(n-2\tau)\| + \\ & \alpha^2 W_x^{\text{out}} \|x(n-3\tau) - x'(n-3\tau)\| - \\ & \alpha^3 W_x^{\text{out}} \|x(n-4\tau) - x'(n-4\tau)\| + \dots + \\ & (-\alpha)^{m-1} W_x^{\text{out}} \|x(n-m\tau) - x'(n-m\tau)\| \end{aligned} \quad (12)$$

将式 (12) 代入式 (8) 中, 得到

$$\begin{aligned} \|x(n+1) - x'(n+1)\| \leq & |a| \|x(n) - x'(n)\| + W^* \|x(n) - x'(n)\| + \\ & W_{fb}^* \left(W_x^{\text{out}} \|x(n-\tau) - x'(n-\tau)\| - \right. \\ & \alpha W_x^{\text{out}} \|x(n-2\tau) - x'(n-2\tau)\| + \\ & \alpha^2 W_x^{\text{out}} \|x(n-3\tau) - x'(n-3\tau)\| - \\ & \left. \alpha^3 W_x^{\text{out}} \|x(n-4\tau) - x'(n-4\tau)\| + \dots + \right. \\ & \left. \alpha^{m-1} W_x^{\text{out}} \|x(n-m\tau) - x'(n-m\tau)\| \right) \leq \\ & |a| \|x(n) - x'(n)\| + W^* \|x(n) - x'(n)\| + \\ & W_{fb}^* W_x^{\text{out}} \left(\|x(n-\tau) - x'(n-\tau)\| - \right. \\ & \alpha \|x(n-2\tau) - x'(n-2\tau)\| + \\ & \alpha^2 \|x(n-3\tau) - x'(n-3\tau)\| - \\ & \left. \alpha^3 \|x(n-4\tau) - x'(n-4\tau)\| + \dots + \right. \\ & \left. (-\alpha)^{m-1} \|x(n-m\tau) - x'(n-m\tau)\| \right) \end{aligned} \quad (13)$$

根据 Banach 压缩映象原理^[26], 如果

$$\begin{aligned} |a| + \delta_{\max}^* + \delta_{fb_{\max}}^* (1 - \alpha + \alpha^2 - \\ \alpha^3 + \dots + (-\alpha)^{m-1}) < 1 \end{aligned} \quad (14)$$

那么,

$$\lim_{n \rightarrow \infty} \|y(n-\tau) - y'(n-\tau)\| \rightarrow 0 \quad (15)$$

因此, 延迟回声状态网具有回声状态特性. \square

推论 1. 当 $W^{\text{fb}2} - \alpha W^{\text{fb}1} = \mathbf{0}$ 时, 如果能够满足 $|a| + \delta_{\max}^* < 1$, 那么, 延迟回声状态网络模型具有回声状态特性.

证明. 对于任意两个储备池状态 $x(n+1)$ 和 $x'(n+1)$, 可得

$$\begin{aligned} \|x(n+1) - x'(n+1)\| = & \|ax(n) + f(W^{\text{in}}u(n+1) + W^*x(n) + \\ & W_u^*u(n)) - ax'(n) - f(W^{\text{in}}u(n+1) + \\ & W^*x'(n) + W_u^*u(n))\| \leq \\ & |a| \|x(n) - x'(n)\| + \|(W^{\text{in}}u(n+1) + \\ & W^*x(n) + W_u^*u(n)) - (W^{\text{in}}u(n+1) + \\ & W^*x'(n) + W_u^*u(n))\| \leq \\ & |a| \|x(n) - x'(n)\| + W^* \|x(n) - x'(n)\| \leq \\ & |a| \|x(n) - x'(n)\| + \delta_{\max}^* \|x(n) - x'(n)\| \end{aligned} \quad (16)$$

如果以下条件成立:

$$|a| + \delta_{\max}^* < 1 \quad (17)$$

那么,

$$\lim_{n \rightarrow \infty} \|y(n-\tau) - y'(n-\tau)\| \rightarrow 0 \quad (18)$$

因此, 延迟回声状态网具有回声状态特性. \square

注 1. 由于 $W^{\text{fb}1}$, $W^{\text{fb}2}$ 和 α 的选择具有随机性和不确定性, 导致模型的构建范围过大, 使模型在获得较高预测精度和网络学习时间方面, 增加了一定的难度. 因此, 在实际应用中, 一般情况下使用推论 1, 简化了训练过程的复杂程度, 为构建模型提供了一个简单的指导依据.

2.2 确定模型输入变量

在确定延迟回声状态网的输入变量之前, 引入 Pearson 相关系数分析方法^[27], 对各影响因素与光伏电池板温度进行分析, 其定义为

$$\gamma_{X,Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \times \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (19)$$

其中, n 为样本长度, \bar{X}, \bar{Y} 分别表示序列 X_i, Y_i 的平均值. 利用 Pearson 相关系数分析, 用于确定模型输入变量, 具体实现流程如下:

步骤 1. 根据光伏电池板温度预测模型, 选取可能输入影响因素.

步骤 2. 对于可能输入影响因素, 根据式 (19) 计算任意一个输入与光伏电池板温度的 Pearson 相关系数.

步骤 3. 在确定模型输入的过程中, 为了区分强相关性和弱相关性, 给出了一个合适的阈值 ξ .

步骤 4. 若 $|\gamma_{X,Y}| \geq \xi$, 则 X 与 Y 是强相关性, 作为预测模型的输入; 若 $|\gamma_{X,Y}| < \xi$, 则 X 与 Y 是弱相关性, 不作为模型的输入.

2.3 确定延迟跨度 τ

引入自相关系数来确定延迟跨度 τ 的取值, 对光伏电池板温度不同时间点的关联性进行分析, 其定义如下:

$$R_k = \frac{\sum_{i=1}^{n-k} (X_i - \bar{X})(X_{i+k} - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (20)$$

其中, k 为时间间隔 ($k = 1, 2, \dots, k_m$), \bar{X} 为光伏电池板温度 X_i 的平均值. 通过光伏电池板温度自相关系数 R_k 的分析, 确定延迟跨度 τ 的取值, 具体实现流程如下:

步骤 1. 根据式 (20) 计算相关系数 R_k , 通过增加 k_m 的数值获取自相关系数的周期;

步骤 2. 根据自相关系数的周期和预测精度的要求, 给出一个合适的阈值 R_τ ;

步骤 3. 比较自相关系数 R_i 与 R_τ 之间的关系, 如果 $R_i > R_\tau$, $i \in k_m$, 那么延迟 τ 就取值为 i , 并将 $y(n - \tau)$ 增加在输出更新状态方程中;

步骤 4. 如果 $R_1 \gg R_2$, 那么延迟 τ 就取值为 1, 将 $y(n - 1)$ 增加在输出更新状态方程中.

2.4 模型训练方法

在实际光伏电池板温度预测过程中, 为了使预测模型能够获得更好的预测精度, 我们需要训练模型的输出权值, 使得的输出误差

$$e(n) = y(n) - \hat{y}(n) \quad (21)$$

或均方根误差 (Root mean square error, RMSE)

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y(n) - \hat{y}(n))^2} \quad (22)$$

或平均绝对百分比误差 (Mean absolute percentage error, MAPE)

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left| \frac{y(n) - \hat{y}(n)}{y(n)} \right| \times 100\% \quad (23)$$

越来越小, 以致于预测模型输出 $y(n)$ 能够匹配上期望输出 $\hat{y}(n)$. 其中, N 表示为训练样本数量, n 表示第 n 次训练.

对于输出权值, 采用伪逆法求解, 则有

$$W^{\text{out}} = YX^\dagger \quad (24)$$

其中, X 表示训练过程中 $x(n)$ 的状态收集矩阵, Y 表示 X 对应的期望输出矩阵, X^\dagger 表示 X 的伪逆矩阵.

3 仿真与分析

为验证基于延迟回声状态网的光伏电池板温度预测模型的准确性, 采用吉林省西部某光伏电站内所建立的数据采集系统的实际数据对模型进行训练和验证.

3.1 数据来源

光伏电池板多传感器监测系统建立于吉林省西部某分布式光伏电站, 该电站建设规模 1.2 万 kW, 年均利用阳光时间数为 1 300 小时, 年均发电量 1 580 万 kW 时. 选用 46 200 块由中电电气生产的 260 瓦多晶硅光伏电池板, 板面朝正南方向布置, 垂直于地面倾斜角度为 43° , 且固定支架倾斜角度不可调节.

通过建立光伏电池板多传感器监测系统, 采集并记录光伏电池板温度数据、电气运行数据和气象数据, 用于分析各因素对光伏电池板温度的影响和建立预测模型, 其系统组成如图 3 所示. 主要包括:

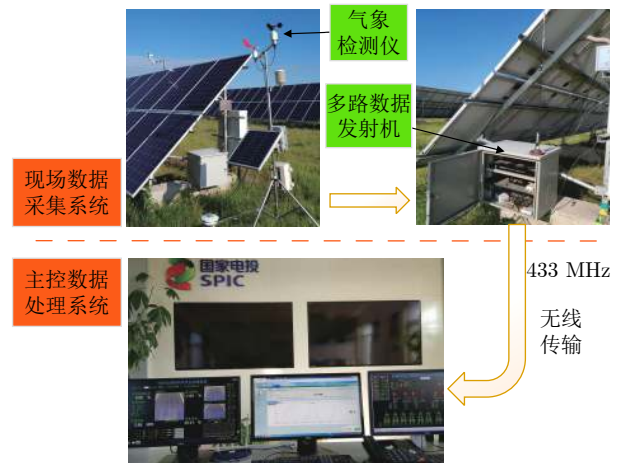


图 3 光伏电池板多传感器监测系统

Fig. 3 Multi-sensor monitoring system for PV panel

1) 现场数据采集系统: PC-6 型气象监测仪 (光照幅度、环境温湿度、风速、风向等), PZ96-DP 型智能电表 (电流、电压), DS18B20 贴片式数字温度传感器 (光伏电池板温度), 数据发射机;

2) 主控数据处理系统: 数据接收机, 工控机, 监测管理软件;

3) 数据传输系统: 现场数据采集系统与主控数据处理系统之间, 通过 433 MHz 无线模块进行数据传输, 减少了现场布线的复杂.

3.2 光伏电池板温度数据采集

吉林省位于我国东北地区, 属于温带大陆性季

风气候, 具有四季分明, 雨热同季, 干湿适中的气候特征. 因此, 选用贴片式 DS18B20 数字温度传感器对光伏电池板温度进行采集, 测温范围 $-55^{\circ}\text{C} \sim 125^{\circ}\text{C}$, 分辨率为 0.0625°C . 温度传感器具有独特的单总线接口方式, 仅需一条信号线即可实现与处理器双向通讯. 对光伏电池板不同位置测量的温度平均值 T_a 定义为

$$T_a = \frac{T_1 + T_2 + T_3 + T_4}{4} \quad (25)$$

其中, T_a 为光伏电池板平均温度, $T_{1,2,3,4}$ 为不同位置测量点的温度.

3.3 数据相关性分析

光伏电池板多传感器监测系统每隔 15 分钟, 记录一次光伏电池板温度、电压、电流和气象信息等数据. 使用 2018 年 1 月~6 月不同天气情况下的 3 000 组数据样本进行预测模型的训练和相关性分析. 利用 Pearson 相关系数分析方法, 根据式 (19) 计算出, 环境温度、光照幅度、风速、风向与光伏电池板温度的相关系数, 分别为 0.946, 0.742, 0.144, 0.114.

通过分析结果可以看出, 环境温度和光照幅度与光伏电池板温度是强相关, 将光照幅度、环境温度选作预测模型的输入. 风速、风向与光伏电池板温度是弱相关, 但在光伏系统实际运行过程中, 自然风也是影响光伏电池板的温度变化的重要因素之一, 相关研究表明, 随着风速的提升将会加快散热, 导致光伏电池板的实际工作温度降低^[28].

因此, 选取光照幅度、环境温度、风速和风向作为预测模型的输入变量, 光伏电池板温度为输出变量, 结合延迟回声状态网, 建立一个光伏电池板温度预测模型. 监测系统记录的数据如表 1 所示.

表 1 监测系统记录的数据

Table 1 Data recorded by monitoring system

时间	输入				输出
	光照幅度 (W/m^2)	环境温度 ($^{\circ}\text{C}$)	风速 (m/s)	风向 ($^{\circ}$)	电池板温度 ($^{\circ}\text{C}$)
8:00	585	25.10	2.2	205	34.53
8:15	610	26.50	2.0	224	35.79
8:30	649	26.50	2.1	252	35.62
8:45	665	27.30	2.9	199	38.60
⋮	⋮	⋮	⋮	⋮	⋮
15:15	699	32.50	2.2	242	45.22
15:30	518	32.30	2.6	242	41.97
15:45	311	31.10	3.2	273	38.62
16:00	159	30.80	2.4	205	34.64

3.4 仿真结果分析

为了更好地说明延迟回声状态网在光伏电池板温度预测的应用效果, 我们选取来自吉林省西部某光伏电站实际采集的数据进行训练和验证. 网络训练和测试的输入维度为 4, 输出维度为 1, 训练样本长度为 1 400, 初始样本长度为 100, 预测样本长度为 100, 训练滑动窗口样本长度为 33 (仿真平台: Intel Core 3.2 GHz 处理器, 16 GB 内存, 软件 MATLAB R2016a).

基于延迟回声状态网的光伏电池板温度预测模型的储备池参数, 如表 2 所示.

表 2 延迟回声状态网储备池参数

Table 2 The reservoir parameters of delayed ESN

储备池规模	谱半径	稀疏度 (%)	训练样本长度
50	0.82	2	1400

根据式 (20) 计算得出光伏电池板的温度相关系数, 由于得出 $R_1 \gg R_2$, 那么 τ 取值为 1. 当泄露积分率 a 为 0.312 时, 延迟回声状态网模型修改如下:

$$x(n+1) = 0.312x(n) + f(W^{\text{in}}u(n+1) + Wx(n) + W^{\text{fb1}}y(n) + W^{\text{fb2}}y(n-1)) \quad (26)$$

$$y(n) = W^{\text{out}}[x(n); u(n)] - \alpha y(n-1) \quad (27)$$

为证明延迟回声状态网对光伏电池板温度的预测性能, 选取文献 [10] 中的 ESN、文献 [25] 中的 Leaky ESN 和文献 [29] 中的 VML ESN (ESN with variable memory length) 三种方法进行对比分析. 使用相同的训练和测试样本, 采用 RMSE 和 MAPE 作为性能指标, 仿真结果如表 3 所示.

表 3 四种方法的预测精度对比

Table 3 Comparison of prediction accuracy of four methods

预测模型	储备池规模	训练 RMSE	测试 RMSE	测试 MAPE (%)
ESN ^[10]	50	0.66058	1.4475	6.81
Leaky ESN ^[25]	50	0.5922	1.2052	5.27
VML ESN ^[29]	50	0.47278	0.7931	4.17
延迟 ESN	50	0.42802	0.6399	3.45

通过表 3 可以看出, 在储备池规模相同的情况下, 对比文献 [10, 25, 29] 中方法, Leaky ESN 和 VML ESN 网络都考虑了储备池状态的延迟特性, 相对 ESN 的预测结果有很大的提高. 但延迟回声状态网通过增加延迟输出项, 提高了对之前输出信息的利用率, 从而具有更高的预测精度 $\text{MAPE} =$

3.45%。延迟回声状态网的预测精度分别是 ESN 的 1.97 倍, Leaky ESN 的 1.52 倍, VML ESN 的 1.21 倍。

四种方法的预测输出和原始数据结果对比如图 4 所示, 它们所对应的预测误差统计如图 5 所示。

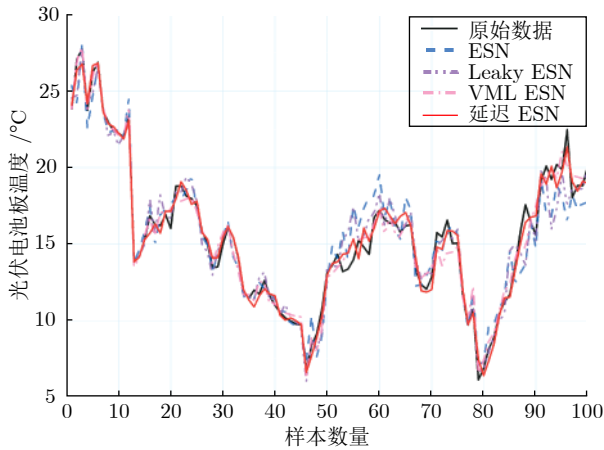


图 4 四种方法的预测输出和原始数据

Fig. 4 The actual output and original data of four methods

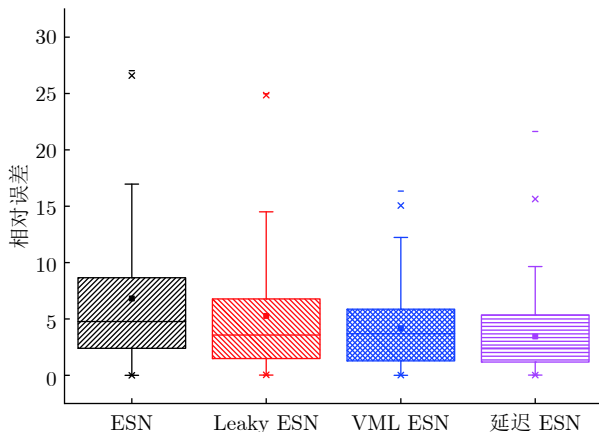


图 5 四种方法的预测误差

Fig. 5 The prediction error of four methods

通过图 4 和图 5 可以看出, 基于延迟回声状态网的温度预测模型输出与原始数据的偏差较小, 在实际运行过程中, 能够较好地匹配光伏电池板温度变化存在的热迟滞效应。因此, 本文所建立模型的预测性能优于其他三种方法, 能充分地反映出光伏电池板温度变化的特性。

为进一步研究延迟回声状态网的储备池规模 N 、延迟因子 α 与光伏电池板温度预测精度的关系, 采用正交实验设计方法, 通过选取不同的储备池规模 N 和延迟因子 α 进行正交仿真实验, 结果如图 6 所示。




图 6 不同延迟因子和储备池规模优化性能分析

Fig. 6 The optimization performance analysis of different delay factors and sizes of reservoir

如图 6 所示, 在样本长度为 1400 的条件下, 当储备池规模为 50, 延迟因子 α 为 1 时, 光伏电池板温度预测模型的预测精度最好。

同时, 在延迟因子 $\alpha = 1$ 时, 我们给出了不同规模 (如, $N = 20, 30, \dots, 90$) 的储备池来分析网络的预测性能, 结果如表 4 所示。

表 4 延迟回声状态网不同储备池规模性能分析

Table 4 Delayed ESN performance analysis for different sizes of reservoir

储备池规模 (N)	样本长度	评价指标 (测试MAPE)
20	1400	0.0514
30	1400	0.0495
40	1400	0.0407
50	1400	0.0345
60	1400	0.0352
70	1400	0.0667
80	1400	0.0542
90	1400	0.0571

从表 4 可以看出, 当储备池规模 $N = 50$ 时, 预测模型的 MAPE 最小; 当 $N = 70$ 时, 预测模型的 MAPE 最大。事实上, 储备池规模的选择不存在一定的规律性, 通常采用试凑法来给出合适的储备池规模大小。在今后的研究中, 可以选择合适的优化方法对延迟回声状态网储备池规模进行优化, 从而获得更高的预测精度。

4 结论

光伏电池板温度变化机理复杂, 常受气象条件、电池片材料、内部构造等多重因素影响, 采用传统方法建立数学模型十分困难。本文在分析温度变化特性的基础上, 提出了一种包含延迟输出项的改进回声状态网来预测光伏电池板温度。这个方法克

服了传统回声状态网预测中忽略输出反馈的问题, 能够更好地关联上一时刻的输出. 同时, 为了保证网络能够稳定地应用于光伏电池板温度预测, 给出了延迟回声状态网具有回声状态特性的一个充分条件. 此外, 建立了一套光伏电池板多传感器信息采集系统, 实时采集气象信息和板温信息, 训练并验证了延迟回声状态网对电池板温度预测的适用性. 最后, 以光伏电站采集的数据开展了验证分析, 结果表明, 延迟回声状态网能够更准确预测光伏电池板温度变化.

致谢

本文中现场实验数据采集等工作是在国家电力投资集团公司、吉林电力股份有限公司、白城发电公司、林海光伏电站等工作人员的大力支持下完成的, 在此表示衷心感谢.

References

- Zhou Xiao-Xin, Chen Shu-Yong, Lu Zong-Xiang, Huang Yan-Hao, Ma Shi-Cong, Zhao Qiang. Technology features of the new generation power system in China. *Proceedings of the Chinese Society for Electrical Engineering*, 2018, **38**(7): 1893–1904, 2205 (周孝信, 陈树勇, 鲁宗相, 黄彦浩, 马士聪, 赵强. 能源转型中我国新一代电力系统的技术特征. *中国电机工程学报*, 2018, **38**(7): 1893–1904, 2205)
- Zhao Zhi-Gang, Zhang Chun-Jie, Gou Xiang-Feng, Sang Hu-Tang. Solar cell temperature prediction model of support vector machine optimized by particle swarm optimization algorithm. *Acta Physica Sinica*, 2015, **64**(8): 380–386 (赵志刚, 张纯杰, 苟向峰, 桑虎堂. 基于粒子群优化支持向量机的太阳能电池温度预测. *物理学报*, 2015, **64**(8): 380–386)
- Xu Rui-Dong, Dai Yue, Sun Xiao-Yan. Temperature prediction of photovoltaic array based on BP neural network. *Industry and Mine Automation*, 2012, (7): 63–67 (徐瑞东, 戴渝, 孙晓燕. 基于 BP 神经网络的光伏阵列温度预测. *工矿自动化*, 2012, (7): 63–67)
- Xu R D, Wu J W, Sun X Y. Photovoltaic module temperature prediction with Gaussian process. *International Journal of Advanced Mechatronic Systems*, 2012, **4**(3/4): 187–196
- Ceylan İ, Erkamaz O, Gedik G E, Gürel A E. The prediction of photovoltaic module temperature with artificial neural networks. *Case Studies in Thermal Engineering*, 2014, **3**: 11–20
- Peng Fei, Ren Jing-Guo, Chen Yu-Feng, Gu Chao, Zhu Wen-Bing. Temperature prediction model for crystalline silicon solar cell considering surface textured structure. *Acta Energetica Sinica*, 2016, **37**(2): 337–343 (彭飞, 任敬国, 陈玉峰, 辜超, 朱文兵. 计及表面纹理结构的晶硅太阳能电池温度预测模型. *太阳能学报*, 2016, **37**(2): 337–343)
- Sun Y J, Wang F, Zhen Z, Mi Z Q, Liu C, Wang B, Lu J. Research on short-term module temperature prediction model based on BP neural network for photovoltaic power forecasting. In: Proceedings of the 2015 IEEE Power and Energy Society General Meeting. Colorado, USA: IEEE, 2015. 1–5
- Sun Y J, Wang F, Mi Z Q, Zhen Z, Sun H B, Lu J, et al. Short-term prediction model of module temperature for photovoltaic power forecasting based on support vector machine. In: Proceedings of the 2015 International Conference on Renewable Power Generation. Beijing, China: IET, 2015.
- Jakhrani A Q, Othman A K, Rigit A R H, Samo S R. Determination and comparison of different photovoltaic module temperature models for Kuching, Sarawak. In: Proceedings of the 2011 Clean Energy and Technology. Kuala Lumpur, Malaysia: IEEE, 2011. 231–236
- Jaeger H, Hass H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication. *Science*, 2004, **304**(5667): 78–80
- Gallicchio C, Micheli A, Pedrelli L. Design of deep echo state networks. *Neural Networks*, 2018, **108**: 33–47
- Gallicchio C, Micheli A. Deep reservoir neural networks for trees. *Information Sciences*, 2019, **480**: 174–193
- Chitsazan M A, Fadali M S, Trzynadlowski A M. Wind speed and wind direction forecasting using echo state network with nonlinear functions. *Renewable Energy*, 2019, **131**: 879–889
- Matino I, Dettori S, Colla V, Weber V, Salame S. Forecasting blast furnace gas production and demand through echo state neural network-based models: Pave the way to off-gas optimized management. *Applied Energy*, 2019, **253**: 113578
- Matino I, Dettori S, Colla V, Weber V, Salame S. Application of echo state neural networks to forecast blast furnace gas production: pave the way to off-gas optimized management. *Energy Procedia*, 2019, **158**: 4037–4042
- Lun Shu-Xian, Lin Jian, Yao Xian-Shuang. Time series prediction with an improved echo state network using small world network. *Acta Automatica Sinica*, 2015, **41**(9): 1669–1679 (伦淑娴, 林健, 姚显双. 基于小世界回声状态网的时间序列预测. *自动化学报*, 2015, **41**(9): 1669–1679)
- Xu Mei-Ling, Wang Yi-Wen. Time series prediction based on improved differential evolution and echo state network. *Acta Automatica Sinica*, 2019, DOI: 10.16383/j.aas.c180549 (许美玲, 王依雯. 基于改进差分进化和回声状态网的时间序列预测研究. *自动化学报*, 2019, DOI: 10.16383/j.aas.c180549)
- Liu Ying, Zhao Jun, Wang Wei, Wu Yi-Ping, Chen Wei-Chang. Improved echo state network based on data-driven and its application to prediction of blast furnace gas output. *Acta Automatica Sinica*, 2009, **35**(6): 731–738 (刘颖, 赵珺, 王伟, 吴毅平, 陈伟昌. 基于数据的改进回声状态网络在高炉煤气发生量预测中的应用. *自动化学报*, 2009, **35**(6): 731–738)
- Lei Miao, Peng Yu, Guo Jia, Peng Xi-Yuan. Traffic forecasting for prior knowledge based clustered complex echo state networks. *Chinese Journal of Scientific Instrument*, 2011, **32**(10): 2190–2197 (雷苗, 彭宇, 郭嘉, 彭喜元. 基于先验簇复杂回声状态网络的话务量预测. *仪器仪表学报*, 2011, **32**(10): 2190–2197)
- Tian Zhong-Da, Li Shu-Jiang, Wang Yan-Hong, Wang Xiang-Dong. Networks traffic multi-step prediction based on chaos theory and improved echo state networks. *Journal on Communications*, 2016, **37**(3): 59–74 (田中大, 李树江, 王艳红, 王向东. 基于混沌理论与改进回声状态网络的网络流量多步预测. *通信学报*, 2016, **37**(3): 59–74)
- Yao Xian-Shuang, Lun Shu-Xian. Photovoltaic power generation forecasting based on echo state network. *Electronic Design Engineering*, 2015, **23**(22): 92–93, 96 (姚显双, 伦淑娴. 基于回声状态网的光伏发电量预测. *电子设计工程*, 2015, **23**(22): 92–93, 96)
- Yao X S, Wang Z S, Zhang H G. Prediction and identification of discrete-time dynamic nonlinear systems based on adaptive echo state network. *Neural Networks*, 2019, **113**: 11–19
- Yao X S, Wang Z S, Zhang H G. A novel photovoltaic power

- forecasting model based on echo state network. *Neurocomputing*, 2019, **325**: 182–189
- 24 Li Q, Wu Z, Xia X. Estimate and characterize PV power at demand-side hybrid system. *Applied Energy*, 2018, **218**: 66–77
- 25 Jaeger H, Lukoševičius M, Popovici D, Siewert U. Optimization and applications of echo state networks with leaky-integrator neurons. *Neural Networks*, 2007, **20**(3): 335–352
- 26 Kieu P C, Erdal K, Tran D T. A generalized contraction principle in partial metric spaces. *Mathematical and Computer Modelling*, 2012, **55**(5–6): 1673–1681
- 27 Mu Y S, Liu X D, Wang L D. A Pearson's correlation coefficient based decision tree and its parallel implementation. *Information Sciences*, 2018, **435**: 40–58
- 28 Dhaundiyal A, Atsu D. The effect of wind on the temperature distribution of photovoltaic modules. *Solar Energy*, 2020, **201**: 259–267
- 29 Lun S X, Yao X S, Hu H F. A new echo state network with variable memory length. *Information Sciences*, 2016, **370–371**: 103–119



范思远 东北电力大学博士研究生. 2018 年获得东北电力大学仪器科学与技术硕士学位. 主要研究方向为新能源发电系统检测及智能控制.

E-mail: fans@neepu.edu.cn

(**FAN Si-Yuan** Ph.D. candidate at Northeast Electric Power University.

He received his master degree from Northeast Electric Power University in 2018. His research interest covers renewable energy system detection and intelligent control.)



姚显双 工学博士, 东北电力大学副教授. 主要研究方向为新能源发电系统建模与控制.

E-mail: xianshuang_yao@163.com

(**YAO Xian-Shuang** Ph.D., associate professor at Northeast Electric Power University. His research

interest covers modeling and control for renewable power generation system.)




曹生现 工学博士, 东北电力大学教授. 主要研究方向为新能源发电测控技术. 本文通信作者.

E-mail: csxlb_jl@163.com

(**CAO Sheng-Xian** Ph.D., professor at Northeast Electric Power University. His research interest covers

renewable energy power generation detection and control technology. Corresponding author of this paper.)



赵波 工学博士, 东北电力大学副教授. 主要研究方向为新能源发电检测技术与自动化装置, 表面污垢监测与控制.

E-mail: zhaobo@neepu.edu.cn

(**ZHAO Bo** Ph.D., associate professor at Northeast Electric Power

University. His research interest covers renewable energy power generation detection technology, surface dirt monitoring and control.)