

基于混合神经网络的光伏组件输出特性数据驱动建模方法

张国宾, 王新迎

(中国电力科学研究院有限公司, 北京 100192)

摘要: 针对传统物理机理建模方法不适用于复杂光照条件下光伏组件建模的问题, 提出一种基于混合结构神经网络的光伏组件输出特性数据驱动建模方法。在深入分析光伏组件物理机理及输出特性的基础上, 提出利用卷积神经网络和径向基函数神经网络对不均匀光照条件、温度、湿度等环境因素进行特征提取, 并对光伏组件的输出特性进行仿真拟合。为提高模型的拟合效果, 提出针对不均匀光照条件的阴影形态等效分析方法, 同时采用改进型的遗传编码方案对网络参数进行优化, 最后利用实际运行数据对模型效果进行分析验证。结果表明, 该模型对不均匀光照条件具有一定的泛化跟踪能力, 同时仿真结果平均误差保持在 7% 以内。

关键词: 数据驱动建模; 卷积神经网络; 径向基函数神经网络; 遗传算法优化

中图分类号: TP183

文献标识码: A

doi: 10.11959/j.issn.2096-6652.202019

Research on data-driven modeling for photovoltaic characteristics based on hybrid neural network

ZHANG Guobin, WANG Xinying

China Electric Power Research Institute, Beijing 100192, China

Abstract: A data-driven modeling approach of photovoltaic modules based on hybrid structure neural network was proposed to solve the issue that traditional physical mechanism modeling methods are difficult to be applied under some complex lighting conditions. Based on an in-depth analysis of the physical mechanism and output characteristics of photovoltaic modules, the convolutional neural network and radial basis function network were used to extract features of several environmental factors such as uneven lighting conditions, temperature and humidity. In order to improve the fitting effect of the hybrid network model, an equivalent analysis method of shadow morphology for uneven lighting conditions was proposed, a genetic coding scheme was used to optimize network parameters. Model effect was verified by the actual operation data. The model had generalized tracking capacity under various uneven lighting conditions, and the average error of simulation results was kept within 7%.

Key words: data-driven modeling, convolutional neural network, radial basis function neural network, genetic algorithm optimization

1 引言

近年来, 在全球能源消费结构转型^[1]的驱动下, 清洁能源发电发展迅速。自 2015 年以来, 可再生能源发电量同比增长占全球发电量同比增长的大

部分。其中, 光伏发电技术在可持续性、能源转换效率、技术成熟度等方面具有明显优势, 已成为当前非常受青睐的清洁能源之一。随着我国将能源互联网建设作为长期战略目标^[2], 光伏发电技术在未来能源系统中将呈现出巨大的发展潜力。

收稿日期: 2020-04-21; 修回日期: 2020-05-06

通信作者: 张国宾, zhangguobin@epri.sgcc.com.cn

基金项目: 中国电力科学研究院有限公司创新基金项目 (No.52420019000N)

Foundation Item: China Electric Power Research Institute Innovation Foundation Item (No.52420019000N)

包括光伏在内的能源侧建模技术能够为区域能源互联网的协同规划、优化调度、经济运行等多个业务环节提供基础支撑,是能源互联网建设中的关键共性技术^[3-5]。根据光伏发电系统构成、应用场景和建模尺度,光伏建模对象包括光伏电池内部等效电路模型、输出特性模型、最大功率点跟踪(maximum power point tracking, MPPT)控制模型、逆变器控制模型以及功率预测模型等,如图1所示。另外,随着光伏发电容量和渗透率的不断提升,光伏发电系统自身及与电网的协同运行愈加复杂,有学者将各类分布式能源放在信息层面统一考虑,提出了面向多能源协调控制与优化的集成模型^[6]。

光伏建模方法可以分为物理机理建模和数据驱动建模。其中,前者按照模型求解方法又可以分为两类:模型简化方法和参数辨识方法。参考文献[7]利用平抛运动轨迹提出光伏电池输出特性曲线的代替模型,测试结果表明,该代替模型在标准测试条件下能够满足工程应用精度;参考文献[8]针对通用模型含有的超越模型不易求解问题,提出一种基于Bezier函数的光伏电池模型,该方法基于出厂测试数据对光伏电池进行简化建模,优势在于无须估计电池内部参数、易于实现。随着对电池模型准确性要求的提升,不少基于智能算法的参数辨识方法^[9-12]被应用到光伏单二极管(5参数)和双二极管(7参数)等效电路模型中。但参数辨识方法中的光伏模型在数学上通常局限于多项式或超

越函数,导致对参数进行调优或求解较为困难,同时也限制了模型的适应度,微小的外界变化可能会导致较大的参数偏移,很多情况下不能满足灵活性要求。

考虑到光伏物理建模中存在大量无法直接观测的物理参数,在无法或不必要掌握建模对象内部具体逻辑的情况下,基于机器学习和人工智能技术的数据驱动建模方法凭借其约束条件少、结构灵活、适应性强等特点,在光伏建模中逐渐得到应用。在光伏MPPT方面,参考文献[13]提出一种自适应神经网络的MPPT控制模型,实现对多峰值输出特性曲线的寻优;参考文献[14]基于模糊控制的误差反向传播(back propagation, BP)网络建立了温度和光照强度与最大功率点之间的关系;参考文献[15]利用二进制蚁群算法对模糊神经网络MPPT策略进行参数优化;参考文献[16]提出通过负载电压遍历反馈提高MPPT自适应神经网络的收敛速度。在功率预测方面,参考文献[17]尝试利用卷积神经网络(convolutional neural network, CNN)对光伏功率进行概率预测,用于电网的中长期规划;参考文献[18]提出一种基于改进贝叶斯神经网络的光伏功率概率预测方法,同时考虑了持续性和突发性两方面的影响,提高了短期功率预测对偶然因素的适应性。

以深度学习(deep learning, DL)和强化学习(reinforcement learning, RL)为代表的新一代人工智能技术不断成熟,进一步推动了数据驱动建模研究的发展。目前数据驱动的光伏建模研究主要集中




图1 光伏发电建模范围

在 MPPT 控制和大型光伏电站功率预测方面。前者在技术层面正在被强化深度学习取代^[19-20]，后者的建模对象偏向宏观，能够反映整体或局部系统的长时间尺度特征，但尚未深入光伏系统的基本设备层面。

本文针对光伏组件中输出特性的建模问题，在光伏电池及相关组件的研究基础上，利用径向基函数神经网络（radial basis function neural network, RBFNN）和卷积神经网络，建立了不均匀光照条件下的光伏组件模型。结合实际运行数据开展模型训练，得到了不同的不均匀光照条件下的光伏组件输出特性模型。

2 光伏电池特性变化因素分析

光伏电池利用内光电效应，通过由半导体材料构成的 PN 结实现光能到电能的转化，在实际应用中通过串并联方式并配合其他保护及控制元件组成光伏组件和光伏阵列。光伏电池的输出特性与其半导体材料、制作工艺、外界环境和运行条件等相关。

2.1 半导体材料方面

半导体材料是光伏电池的核心部分。通常采用转化效率衡量半导体特性。目前科研和产业中主流的半导体材料可分为天然的无机材料和合成的有机材料，具体见表 1。

无机材料包括单晶硅、铜铟硒、砷化镓、碲化镉 4 类，不同工艺下的单晶硅光伏电池转化效率差异较大。其中单晶硅光伏电池由于其原料易获得、易加工、寿命长等综合优势，成为目前技术最成熟、应用最广泛的电池；铜铟硒光伏电池凭借其比单晶硅光伏电池更高的转化效率被视为下一代廉价光伏电池，但由于制作难度相对较高，尚未在光伏发电设备中大规模应用；砷化镓光伏电池在 4 类材料中具有最高的理论转化效率，同时能够适应较为苛

刻的运行环境，目前应用在极少数高端行业；碲化镉光伏电池具有较高的成本效益，虽然较低的转化效率限制了其应用规模，但碲化镉仍是光伏发电领域应用规模仅次于单晶硅的重要半导体材料。

对有机材料的研究起步较晚，有机材料从材料结构上可以分为单质结、异质结和染料敏化材料。总体来说，有机材料的发展主要基于降低光伏电池成本的目的，其转化效率明显低于无机材料。

大量实验结果表明，半导体材料的转化效率与其禁带宽度 E_g 相关，同时 E_g 也会影响光伏电池的开路电压。在相同的光源条件和外界环境条件下， E_g 大小与光源波长最匹配时，光伏电池的转化效率最高，也可以提供最高的开路电压。

2.2 制作工艺方面

单晶硅光伏电池作为应用最广泛、发展最迅速的光伏电池，具有多样的制作工艺和电池内部结构。目前主流的单晶硅光伏电池按照制作工艺可分为 4 类，分别是钝化发射极背场点接触式（passivation emitter and rear contact, PERC）、交叉指式背接触式（interdigitated back contact, IBC）、硅异质结式（silicon heterojunction, SHJ）、交叉指式背接触异质结式（heterogeneous interdigitated back contact, HBC）。多晶硅材料则以隧穿氧化层钝化接触式（tunnel oxide passivated contact, TOPCon）和氧化物全钝化接触式（polycrystalline on oxide, POLO）为主。

其他无机材料光伏电池以薄膜工艺为主，有机材料光伏电池则以肖特基势垒工艺为主。

不同工艺的差别主要体现在光伏电池对光学损耗的降低程度上。不同的工艺会导致光伏电池内部形成不同的能量路径，从而影响光伏电池对光线的利用率，进而影响内部损耗和电阻大小。

2.3 外界环境和运行条件方面

光伏电池的材料和工艺决定了其固有属性。但

表 1 各类半导体材料对比

类型	材料	优势	劣势
无机材料	单晶硅	原料易获得，易加工，寿命长	转化效率依赖于制作技术
	铜铟硒	转化效率在 20% 以上，优于单晶硅	制作技术存在门槛
	砷化镓	转化效率可达 50%，极端环境下性能稳定	造价昂贵
	碲化镉	成本效益高	转化效率低，在 20% 以下
有机材料	单质结、异质结、染料敏化材料	易合成，成本低廉	转化效率一般低于 10%

光伏电池输出特性会随着光源条件和系统负载情况的变化而变化。

在此按照美国国家标准与技术研究院提供的光伏组件标准参数（见表2），搭建光伏电池仿真组件，输出特性曲线如图2所示。

表2 光伏组件标准参数


参数	含义	单位	标准值
R_s	等效串联电阻	Ω	5×10^{-5}
R_{sh}	等效并联电阻	Ω	5×10^5
I_{D0_st}	标准运行条件下的二级反向饱和电流	A	19.9693×10^{-6}
T_r	参考温度	K	301.08
k_t	温度系数	A/K	0.0017
I_{sc_st}	标准运行条件下的等效短路电流	A	2.3
E_g	半导体材料禁带宽度	eV	1.1
A	品质因数	/	1.72
K	玻尔兹曼常数	J/K	1.38×10^{-23}
G_r	标准光照强度	W/m^2	1000

在正常运行条件（光照强度均匀）下，光伏组件的电流-电压特性与单体光伏电池类似，其输出电流主要受光照强度的影响，开路电压主要受环境温度的影响。


从图2(a)可以看出，在环境温度不变的情况下，电流大小受到光照条件的影响。随着电压升高，电流基本保持不变，即具备恒流源特点。当电压超过一定值时，由于光伏效应会出现输出电流骤降现象，因此在电流-电压特性曲线上必然存在一点使输出功率最大。从图2(b)可以看出，功率与电压在一定范围内基本呈线性关系，但电压超过一定值后，功率同样出现骤降现象。光照强度升高会导致光伏组件的最大功率也相应增加。

为满足更大的负载需求，通常将光伏组件进一步组成光伏阵列。对于普通居民用户来说，光伏阵列通常为4~60片，对于光伏电站来说，其规模为几千到几万片。随着光伏阵列规划的不断扩大，设备安装位置、灰尘、树木、云层等原因导致的不均匀光照情况不可避免^[21-22]。对于不均匀光照条件下的光伏组件电流-电压特性模型，有的学者讨论了部分不均匀光照条件对MPPT控制的影响^[23]，有的学者根据光伏组件结构对局部峰值的出现条件和数量进行了估算^[24-25]。大量研究结果证明，不均匀光照条件会导致部分光伏电池的输出特性出现偏差，可能导致光伏组件的整体输出特性出现多个

局部峰值，影响光伏组件的MPPT控制。在此利用表2中的光伏组件标准参数搭建3×3光伏阵列，在不同运行场景下（见表3）其输出特性如图3所示。



(a) 电流-电压特性



(b) 功率-电压特性

图2 光伏电池仿真组件输出特性曲线

表3 运行场景设置

运行场景	光伏板遮挡位置	环境温度/°C	光照强度/ W/m^2
情景1	(1, 1)、(1, 2)、(2, 3)	20	1000
	(1, 3)、(2, 1)、(2, 2)、	15	500
	(3, 1)、(3, 2)、(3, 3)		
情景2	(1, 2)、(2, 1)、(2, 3)、	20	800
	(3, 2)		
	(1, 1)、(1, 3)、(2, 2)	15	500
	(3, 1)、(3, 3)	15	300

在不均匀光照条件下，随着外部电压升高，弱光照条件下的光伏组件无法提供足够电压，导致其两端出现负压，从而由电源转为负载。光伏阵列的电流-电压输出曲线会在某些电压点出现电流骤降现象；功率-电压输出曲线则相应地出现局部峰值，使得整个光伏阵列的最大功率点发生改变。




图3 不同运行场景下的光伏组件输出特性曲线

2.4 物理机理建模与数据驱动建模差异

物理机理建模与数据驱动建模本质上同样是基于大量的实验和运行数据的。物理机理建模易于理解，可解释性高，但由于物理机理模型中的等效参数与光伏电池的实际物理参数存在误差，在参数辨识时可能会导致测定误差。此外，物理机理模型由于通常只能针对标准或典型的运行场景，灵活性不足，在面对复杂多样、动态变化的外部环境和运行条件时，模型效果可能会与设备实际性能存在较大偏差。而数据驱动建模方法直接将物理机理转化为纯数学关系，同时支持根据实时运行数据在线更新参数，能够很好地解决以上两方面问题。因此本文采用数据驱动建模方法，基于实际运行数据利用混合神经网络对光伏组件的功率输出特性进行拟合。

3 光伏组件输出特性分析

3.1 模型总体结构

光伏组件的输出特性与复杂多变的光照条件

具有强耦合性，同时也在不同程度上受到环境温度、湿度、风力等多重环境条件的影响。因此光伏组件的输出特性在数学上可以被看作连续变化的高维曲面。本文提出的光伏组件仿真模型总体结构如图4所示。




图4 光伏组件仿真模型总体结构

模型根据神经网络结构可以分为两部分。第一部分为双层卷积神经网络，以光照强度矩阵为输入，用于对光照条件进行特征提取和转换，输出为光照强度矩阵的特征向量。第二部分为径向基函数神经网络，以负载电压、温度指标、湿度指标、光照强度特征向量为输入，以同一时间断面下的功率为输出，配合遗传算法对网络参数进行优化，对光伏组件的输出特性进行拟合。

3.2 不均匀光照模型

虽然实际运行环境中各种外部遮挡或运维不当造成阴影形态之间的差异巨大，但考虑到光伏阵列拓扑结构的相似性，其对应的光伏输出特性在部分条件下具有一定的相似性。为提高仿真模型的泛化能力，有必要对阴影形态进行归纳，有选择地设计训练数据集，提高数据多样性。 $m \times n$ 规模的光伏组件电路结构如图5所示，下面对其基本阴影类型进行说明。

在光照强度相同，并且只存在完全遮挡和完全无遮挡两种情况的条件下，根据光伏电池的输出特性可知，当电池两端产生负压时，电池内PN结正向导通，由电源变为负载。推广到 $m \times n$ 规模的光伏阵列中，在不均匀光照条件下，光伏阵列中端电压最高的支路会导致其他支路转变为负载。此时整个光伏阵列可以分为两部分：端电压最高的若干个光伏支路和其他光伏支路，前者作为有效支路决定了整个光伏阵列的输出特性，后者作为无差别负载可

以忽略阴影形态的差异。各有效支路之间互不影响，输出特性可以互相叠加。同一有效支路内部各光伏组件之间的输出特性差异可以忽略。




图5 $m \times n$ 规模的光伏组件电路结构

以 3×4 规模的光伏组件为例，其光照条件如图6所示。在以上假设条件和等效关系下，左侧两条支路各有3个无遮挡光伏组件，右侧两条支路分别有2个和1个无遮挡光伏组件。因此左侧两条支路为有效支路且等价，有效支路上的完全遮挡光伏组件由旁路二极管承担电流；右侧两条支路实际上已成为负载支路，但由于阻塞二极管的作用，电流实际上不会回流到支路中。




图6 不均匀光照条件等效情况

经过上述分析，对于 $m \times n$ 规模的光伏组件，其基本阴影形态可以从 $m! \times n!$ 种简化为 $m \times n$ 种。由于实际采样中对光照强度的选择更为细化，这种简化方式避免重复数据的效果更为明显。

3.3 光照强度二维卷积神经网络

光照强度对光伏组件的输出特性具有决定性

影响。考虑到光伏组件的串并联结构，光伏组件上各点光照强度的变化对光伏组件的影响在部分情况下具有局域性。因此通过卷积神经网络对光照强度进行局部特征提取。按照光伏组件结构形成光伏强度矩阵，该矩阵经过双层卷积操作形成特征矩阵后，再转换为特征长向量，并作为下一步径向基函数神经网络的输入。

光照强度二维卷积神经网络如图7所示。矩阵规模与光伏组件规模相同，假设在同一片光伏电池内光照强度相同。因此光照强度矩阵以每个光伏电池为单位模拟原始光照条件，将平面光照强度分布量化为单通道网络输入。单通道卷积神经网络操作过程可以表示为：

$$Y(m,n) = X(m,n) \otimes H(m,n) \quad (1)$$

$$= \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} X(m+i, n+j) H(i, j)$$

其中， $X(m,n)$ 为光照强度矩阵中的感受域， $H(m,n)$ 为卷积核， $Y(m,n)$ 为特征矩阵中对应位置的元素值。设卷积核大小是 $I \times J$ （卷积核里有 I 行 J 列个光伏板），光伏组件规模是 $X \times Z$ （光伏组件里有 X 行 Z 列个光伏板），在原始情况下（即输入矩阵无边缘填充、卷积核无间隔），特征矩阵的规模是 $(X-I) \times (Z-J)$ 。




图7 光照强度二维卷积神经网络

一般光伏组件中包含的光伏电池数量在几十到上百个，考虑到其规模较小，因此在卷积神经网络中不再设置池化层，以防止信息丢失。同时，在第一层卷积层中相应地增加卷积核数量，以保证特征提取深度。

第一层卷积输出是规模为 $(X-I) \times (Z-J) \times n$ 的数据体， n 是第一层的卷积核数量。为了降低径向基函数神经网络的输入维度，需要对该数据体进行第二次卷

积操作，同时为了尽量保留数据体中的局部特征，采用 1×1 卷积核。

卷积神经网络输出抽象化的光照强度特征，但由于特征本身并无实际物理含义，因此网络输出不存在目标值。对于无监督学习的卷积神经网络来源，目前通常采用自动生成标签或预训练卷积核的方式将无监督学习转化为有监督学习^[26-29]。

本文选择采用自动编码器（autoencoder, AE）确定卷积核。所有神经元统一采用 ReLU 作为激活函数：

$$f(x) = \max(0, x) \quad (2)$$

考虑到 ReLU 函数会导致在 $x < 0$ 时，神经元在正向传播过程中无法被激活，在反向传播过程中无法更新参数。因此选择 Leaky ReLU 函数作为补充激活函数，Leaky ReLU 函数设置如下：

$$f(x) = \max(\alpha x, x) \quad (3)$$

其中， α 固定设置为 0.01。

3.4 遗传算法优化的径向基函数神经网络

径向基函数神经网络在非线形高维曲面拟合方面具有最佳逼近的优点，但其最大的不足在于需要依赖大量数据，数据中心、扩展常数和权值等网络参数难以调解。通过遗传算法对网络参数进行优化是常用手段之一^[30-31]。RBFNN 是 3 层固定结构的前馈型网络，网络结构如图 8 所示。




图 8 RBFNN 的网络结构

计算隐藏层神经元计算样本与数据中心的距离时，通常将高斯函数作为激活函数，神经元处理过程可表示为：

$$R(\mathbf{x}, \mathbf{c}_i) = \exp\left(-\frac{1}{2\sigma_i^2} \|\mathbf{x} - \mathbf{c}_i\|^2\right) \quad (4)$$

其中， $\mathbf{x}$ 为输入样本向量， $\mathbf{c}_i$ 为隐藏层第 i 个神经

元数据中心向量， σ_i 为隐藏层第 i 个神经元响应宽度，即扩展常数。输出层与隐藏层实行权连接，输出层第 j 个神经元的输出为：

$$y_j = \sum_{i=1}^h R(\mathbf{x}, \mathbf{c}_i) = \sum_{i=1}^h w_{ij} \exp\left(-\frac{1}{2\sigma_i^2} \|\mathbf{x} - \mathbf{c}_i\|^2\right) \quad (5)$$

其中， h 为隐藏层神经元数量， w_{ij} 为隐藏层第 i 个神经元与输出层第 j 个神经元的边权重。径向基函数神经网络中需要确定的参数包括 $\mathbf{c}_i$ 、 σ_i 和 w_{ij} 。另外，神经元激活函数对于确定神经元响应域和调解边权重都具有关键作用，因此本文在使用神经网络结构优化的遗传算法的基础上，将径向基函数类型纳入编码范围，形成的染色体结构如图 9 所示。




图 9 染色体结构

染色体采用实数编码，其中， A 为激活函数类型，包括高斯函数、反 S 函数和多重二次函数，编码集为 $[(0, \text{gaussian}), (1, \text{inverse sigmoid}), (2, \text{multiple quadratic})]$ ； $\mathbf{c}$ 、 σ 和 w 采用固定区间连续编码。将激活函数类型编码设计在染色体头部有助于定向提高神经元数量，将 $\mathbf{c}$ 、 σ 交叉排列有助于提高两者同时发生变化的概率。种群进化方式包括如下两种。

交叉运算：选择同一种群的两个个体，随机选取不超过 3 个交叉点，若双方在同一位置的染色体类型相同，则在该位置进行编码互换，如图 10 所示。




图 10 遗传算法交叉运算

变异运算：变异运算包括两种方式，一是随机选取变异点，从相应类型的编码集中选取新值进行替换；二是在染色体头部激活函数的函数编码段扩展新染色体，同时按顺序在 $\mathbf{c}$ 、 σ 和 w 编码段的相应位置扩展染色体，即增加隐藏层的神经元数量，如图 11 所示。

利用全量样本得到的网络输出 y 与实际目标输出 $\hat{y}$ 误差的绝对值之和构造适应度函数：




图 11 遗传算法变异运算

$$\text{fitness} = \frac{1}{\sum |\hat{y} - y|} \quad (6)$$

在进行交叉、变异之前，根据当代个体的适应度排序，按固定比例淘汰部分低适应度个体，同时保留部分高适应度个体，以降低适应度较差的个体对下一代种群的不良影响，同时能够使当前所有个体中适应度最高的个体不会被遗传操作改变，这能够保障遗传算法的收敛性。

4 光伏组件输出特性分析

4.1 建模对象及数据准备

图 12 为实际建模所用的光伏组件参数。在标准光照强度下，根据第 3.2 节提出的不均匀光照模型选取 3 种阴影形态对光伏组件进行遮挡，所选阴影形态中的最大遮挡比例不超过 20%，见表 4。



参数名称	详情
电池材质	单片硅
电池规模	9×4
开路电压/V	21.6
短路电流/A	10.7
最大功率/W	180
最大功率点电压/V	18
最大功率点电流/A	10
工作温度/℃	-40~80

图 12 光伏组件参数

表 4 阴影类型选择

阴影类型编号	遮挡位置
1	(1, 2)、(2, 2)
2	(1, 2)、(1, 3)、(1, 4)
3	(1, 1)、(1, 2)、(2, 2)、(2, 4)

另外采集了温度、湿度、风速 3 项环境指标以

及光伏组件端口电压和有功功率，采集间隔为 1 s。剔除无效数据及坏数据后，共获得 520 015 条数据，按照 7:3 的比例用于模型训练和验证。

4.2 仿真模型参数配置

在光照强度二维卷积神经网络中采用双层卷积，第一层卷积的超参数：卷积核大小为 2×3，卷积核数量为 10，边缘填充为 1，移动步长为 1。第二层卷积的超参数：卷积核大小为 1×1，卷积核数量为 1，边缘填充为 0，移动步长为 1。

用于 RBFNN 优化的遗传算法的参数：种群规模为 30，最大遗传代数为 100，交叉概率为 0.5，变异概率为 0.03， σ 取值范围为[-10,10]。

从图 13 中能够看出前 30 代进化较快，第 30~60 代进化速度逐渐放缓，但适应度仍有稳定提升；从第 60 代开始曲线逐渐趋于稳定，这是由于交叉概率和变异概率随着种群数量的增加而逐渐降低，因此算法得到最优解的过程较为缓慢。




图 13 模型参数收敛过程

利用训练获得的神经网络模型对光伏组件的输出特性进行单点测试，在正常工作电压范围内按固定间隔选取电压点，仿真模型效果如图 14 所示。从图 14 中可以看出，3 种阴影形态下光伏组件的功率-电压输出特性在正常电压范围内都表现出不规律的多峰值现象，并且阴影形态 2 和阴影形态 3 中存在多个支路失效的情况，导致特性曲线在电压较低时出现功率骤降。

从模型总体结果来看，仿真曲线与实测曲线在长期变化趋势上基本保持一致，在输出特性曲线下下降区间的跟踪效果要好于局部峰值区间，但对局部峰值的跟踪效果具有较大差异。仿真模型对于阴影形态 2 和阴影形态 3 的精确度要明显优于阴影形态 1，尤其是对阴影形态 2 中的峰值点跟踪能力较强。综

合3类阴影形态下仿真结果的平均误差来看,误差保持在7%以内。




图14 3种阴影形态下的光伏组件仿真结果

5 结束语

本文针对传统物理机理建模方法参数难以观测、对外界条件适应度低的问题,提出了一种基于混合神经网络的光伏组件输出特性数据驱动建模方法。主要贡献如下:

- 提出基于卷积神经网络和径向基函数神经网络的光伏组件输出特性仿真模型;
- 结合光伏组件电路结构和多峰值输出特性,提出针对不均匀光照条件的阴影形态等效分析方法;
- 采用兼顾模型参数和模型结构的遗传编码方案对径向基函数神经网络的优化遗传算法进行改进。

本文所提的光伏组件输出特性数据驱动建模方法易于实现,同时能够最大程度地保留运行环境信息。但由于模型完全依赖于实际运行数据,在数据不充分的情况下,模型中的部分超参数仍然存在经验成分(即模型参数的选择有主观成分),泛化能力存在瓶颈。因此如何通过改进模型结构和快速


优化参数等方法提高模型效果是后续研究的重点。

参考文献:

- [1] 陈思远,白昱阳,张俊,等.基于区块链和通证经济的跨国跨洲电力市场机制设计[J].智能科学与技术学报,2019,1(1):96-105.
CHEN S Y, BAI Y Y, ZHANG J, et al. Design of transnational and intercontinental electricity market with blockchain and token economics[J]. Chinese Journal of Intelligent Science and Technology, 2019, 1(1): 96-105.
- [2] 郭创新,王惠如,张伊宁,等.面向区域能源互联网的“源-网-荷”协同规划综述[J].电网技术,2019,43(9):3071-3080.
GUO C X, WANG H R, ZHANG Y N, et al. Review of “source-grid-load” co-planning orienting to regional energy Internet[J]. Power System Technology, 2019, 43(9): 3071-3080.
- [3] 郑玉平,王丹,万灿,等.面向新型城镇的能源互联网关键技术及应用[J].电力系统自动化,2019,43(14):2-15.
ZHENG Y P, WANG D, WAN C, et al. Key technologies and applications of energy Internet[J]. Automation of Electric Power Systems, 2019, 43(14): 2-15.
- [4] MIRANGEIGI M, IMANEINI H. Hybrid modulation technique for grid-connected cascaded photovoltaic systems[J]. IEEE Transactions on Industrial Electronics, 2016, 63(12): 7843-7853.
- [5] 侯国莲,弓林娟,苏烨,等.基于ACP的平行发电控制系统[J].智能科学与技术学报,2019,1(3):269-279.
HOU G L, GONG L J, SU Y, et al. ACP based parallel power generation control system[J]. Chinese Journal of Intelligent Science and Technology, 2019, 1(3): 269-279.
- [6] 孙秋野,胡旌伟,张化光.能源互联网中自能源的建模与应用[J].中国科学:信息科学,2018,48(10):1409-1429.
SUN Q Y, HU J W, ZHANG H G. Modeling and application of we-energy in energy Internet[J]. Scientia Sinica (Informationis), 2018, 48(10): 1409-1429.
- [7] 周林,郭珂,刘强,等.光伏电池工程用数学模型研究[J].电工技术学报,2011,26(10):211-216.
ZHOU L, GUO K, LIU Q, et al. Research on engineering analytical model of solar cells[J]. Transactions of China Electrotechnical Society, 2011, 26(10): 211-216.
- [8] 师楠,周苏荃,李一丹,等.基于Bezier函数的光伏电池建模[J].电网技术,2015,39(8):2195-2200.
SHI N, ZHOU S Q, LI Y D, et al. PV cell modeling based on Bezier function[J]. Power System Technology, 2015, 39(8): 2195-2200.
- [9] 徐岩,高兆,朱晓荣.基于混合蛙跳算法的光伏阵列参数辨识方法[J].太阳能学报,2019,40(7):1903-1911.
XU Y, GAO Z, ZHU X R. Parameter identification method of photovoltaic array based on shuffled frog leaping algorithm[J]. Acta Enerciae Solaris Sinica, 2019, 40(7): 1903-1911.
- [10] CHATTERJEE A, KEYHANI A, KAPOOR D. Identification of photovoltaic source models[J]. IEEE Transactions on Energy Conversion, 2011, 26(3): 883-889.
- [11] JING J S, LOW K S. Photovoltaic model identification using particle swarm optimization with inverse barrier constraint[J]. IEEE Transactions on Power Electronics, 2012, 27(9): 3975-3983.
- [12] 程泽,董梦男,杨添凯,等.基于自适应混沌粒子群算法的光伏电池模型参数辨识[J].电工技术学报,2014,29(9):245-252.
CHENG Z, DONG M N, YANG T K, et al. Extraction of solar cell

- based on self-adaptive chaos particle swarm optimization algorithm[J]. Transactions of China Electrotechnical Society, 2014, 29(9): 245-252.
- [13] 沈斌, 尹斌, 孙维广. 基于单神经元自适应 PID 的光伏发电 MPPT[J]. 电力系统及其自动化学报, 2017, 29(2): 89-95.
- SHEN F, YIN B, SUN W G. Single-neuron adaptive PID control in MPPT of photovoltaic generation[J]. Proceedings of the CSUEPSA, 2017, 29(2): 89-95.
- [14] 胡桂廷, 仲程超, 张伟君, 等. 基于模型辨识的 BP 神经网络在光伏系统 MPPT 中的应用[J]. 计算机测量与控制, 2017, 25(10): 213-216.
- HU G T, ZHONG C C, ZHANG W J, et al. Application of BP neural network based on model identification in photovoltaic system MPPT[J]. Computer Measurement & Control, 2017, 25(10): 213-216.
- [15] 杨东海, 刘洋, 王毅, 等. 基于二进制蚁群模糊神经网络的光伏系统 MPPT 控制算法研究[J]. 电气工程学报, 2017, 12(6): 41-46.
- YANG D H, LIU Y, WANG Y, et al. Research on MPPT control algorithm of photovoltaic system by binary ant colony algorithm and fuzzy neural network[J]. Journal of Electrical Engineering, 2017, 12(6): 41-46.
- [16] 张晓强, 刘宜盟, 邹应全, 等. 基于自适应神经网络控制的光伏 MPPT 算法改进[J]. 太阳能学报, 2019, 40(11): 3091-3102.
- ZHANG X Q, LIU Y G, ZOU Y Q, et al. An enhanced photovoltaic MPPT approach based on adaptive neural network control[J]. Journal of Electrical Engineering, 2017, 40(11): 3091-3102.
- [17] WANG H Z, YI H Y, PENG J C, et al. Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network[J]. Energy Conversion and Management, 2017(153): 409-422.
- [18] 赵康宁, 蒲天骄, 王新迎, 等. 基于改进贝叶斯神经网络的光伏出力概率预测[J]. 电网技术, 2019, 43(12): 4377-4386.
- ZHAO K N, PU T J, WANG X Y, et al. Probabilistic forecasting for photovoltaic power based on improved bayesian neural network[J]. Power System Technology, 2019, 43(12): 4377-4386.
- [19] CHOU K Y, YANG S T, CHEN A Y. Maximum power point tracking of photovoltaic system based on reinforcement learning[J]. Sensors (Basel), 2019, 19(22): 5054.
- [20] ZHANG X S, LI S N, HE T Y, et al. Memetic reinforcement learning based maximum power point[J]. Energy, 2019, 174(C): 1079-1090.
- [21] 杨元培, 杨奕, 王建山, 等. 光伏发电传输最大功率储能优化建模仿真[J]. 计算机仿真, 2017, 34(9): 103-108.
- YANG Y P, YANG Y, WANG J S, et al. Model and simulation of the in photovoltaic power energy storage optimization power generation transmission[J]. Computer Simulation, 2017, 34(9): 103-108.
- [22] 陈如亮, 崔岩, 李大勇, 等. 光照不均匀情况下光伏组件仿真模型的研究[J]. 系统仿真学报, 2008, 20(7): 1681-1690.
- CHEN R L, CUI Y, LI D Y, et al. Study on simulation model of PV module under non-uniform insolation[J]. Journal of System Simulation, 2008, 20(7): 1681-1690.
- [23] 吴登盛, 王立地, 刘通, 等. 基于神经网络的光伏阵列多峰 MPPT 的研究[J]. 电测与仪表, 2019, 56(7): 69-74.
- WU D S, WANG L D, LIU T, et al. Research on multi-peak MPPT of PV array based on neural network[J]. Electrical Measurement & Instrumentation, 2019, 56(7): 69-74.
- [24] 王云平, 阮新波, 李颖. 不均匀光照光伏单元串联电路快速 MPPT 方法[J]. 中国电机工程学报, 2015, 35(19): 4870-4878.
- WANG Y P, RUAN X B, LI Y. A rapid hacking method of maximum power point for solar units in series under uneven solar irradiance[J]. Proceedings of the CSEE, 2015, 35(19): 4870-4878.
- [25] 乐全明, 赵健, 郭力. 不均匀光照条件下太阳能电池串联电路特性分析及 GMPPT 控制[J]. 光子学报, 2017, 46(6): 214-224.
- YUE Q M, ZHAO J, GUO L. Analysis of dynamic characteristic for solar arrays in series and GMPPT control[J]. Acta Photonica Sinica, 2017, 46(6): 214-224.
- [26] REHMAN S, TU S S, WAQAS M, et al. Unsupervised pre-trained filter learning approach for efficient convolution neural network[J]. Neurocomputing, 2019(365): 171-190.
- [27] ZHANG J M, WU Y. Complex-valued unsupervised convolutional neural networks for sleep stage classification[J]. Computer Methods and Programs in Biomedicine, 2018(164):181-191.
- [28] AMORIMA W P, TETILAB E C, PISTORIB H, et al. Semi-supervised learning with convolutional neural networks for UAV images automatic recognition[J]. Computers and Electronics in Agriculture, 2019(164): 104932.
- [29] AHN E, KUMAR A, FULHAM M, et al. Convolutional sparse kernel network for unsupervised medical image analysis[J]. Medical Image Analysis, 2019(56): 140-151.
- [30] 文常保, 马文博, 刘鹏里. 基于改进遗传算法的 RBF 神经网络结构优化研究[J]. 计算机工程与科学, 2019, 43(5): 917-923.
- WEN C B, MA W B, LIU P L. Research on structure optimization of RBF neural network based on improved genetic algorithm[J]. Computer Engineering & Science, 2019, 43(5): 917-923.
- [31] JIA W K, ZHAO D, DING L. An optimized RBF neural network algorithm based on partial least squares and genetic algorithm for classification of small sample[J]. Applied Soft Computing, 2016(48): 373-184.

[作者简介]



张国宾(1988—), 男, 中国电力科学研究院有限公司工程师, 主要研究方向为智能配电网及人工智能应用。



王新迎(1987—), 男, 博士, 中国电力科学研究院有限公司工程师, 主要研究方向为能源互联网与人工智能应用。