

# 基于机器学习的智能光伏充电桩 能源调度系统研究

魏飞<sup>1</sup>, 许迪<sup>1</sup>, 陈鑫<sup>1</sup>, 张兆杰<sup>1</sup>, 刘雪<sup>1</sup>, 张东东<sup>2</sup>

(1. 国网天津营销服务中心, 天津 300220; 2. 南京工程学院, 江苏 南京 211167)

**摘要:** 文章提出了一种基于机器学习的智能充电桩能源调度系统, 该系统应用于配备光伏系统和使用二次寿命电动汽车电池的储能系统的公共快速充电站微电网, 可以用于处理电动汽车的能源需求不确定性和电网连接与快速充电服务之间的功率差距。此外, 文章使用机器学习方法自动合成适合的基于模糊规则的能源调度系统, 该能源调度系统考虑了不同的电动汽车车队和光伏规模, 为光伏系统的最佳规模和微电网系统的有效性提供了参考。最后, 在实验中采用混合确定性—随机过程模拟电动汽车能源需求, 相对于最优基准解决方案, 在性能上有所提升。表明该系统可以更有效地处理电动汽车的能源需求不确定性以及电网连接与快速充电服务之间的功率差距。

**关键词:** 机器学习; 智能充电桩; 能源调度; 光伏系统

**中图分类号:** TK9 **文献标志码:** A **文章编号:** 1671-5292(2025)02-0268-07

## 0 引言

随着全球对可再生能源和电动汽车 (EV) 的关注不断增加, 智能充电基础设施在电动汽车的普及过程中扮演着越来越重要的角色<sup>[1]</sup>。尤其是在配备光伏发电系统和二次寿命电动汽车电池的储能系统的公共快速充电站微电网中, 如何高效管理和调度能源资源成为了一个关键问题<sup>[2]</sup>。当前, 电动汽车的广泛应用导致了对充电基础设施的需求激增, 而电动汽车的能源需求的不确定性以及电网连接与充电服务之间的功率差距, 对充电系统的可靠性和经济性提出了挑战。

传统的能源调度方法往往难以适应复杂的运行环境和动态的能源需求。近年来, 研究者们提出了不同的智能化技术, 如物联网、人工智能和大数据分析等, 用于充电桩的监测、控制和通信<sup>[3-5]</sup>。这些技术能够帮助实现充电桩的远程监控、故障检测和服务优化。张辉<sup>[3]</sup>以国家电网公司标准和模块化为主要原则, 设计出一款智能充电桩。杨家全<sup>[4]</sup>设计了一种分布式智能充电桩控制信息加密方案, 利用 SM2 算法进行充电桩信息加密, 实现充电桩机密性保护。郝庆利<sup>[5]</sup>建立了基于国家电网公司的智能充电桩大数据预测故障应用体系。但

由于智能充电桩与电网之间的复杂交互和多样性, 现有的智能充电桩能源调度系统往往需要复杂的算法和方法来应对各种情况。此外, 当充电需求激增时, 系统的可扩展性也可能成为一个问题, 因此本文提出了智能充电桩能源调度系统来解决以上问题。

智能充电桩能源调度是指对充电桩的能源供应和需求进行优化调度, 以达到能源高效利用和电网负荷平衡的目标<sup>[6]</sup>。传统的充电桩能源调度系统旨在通过合理分配和调度电动汽车的充电需求, 实现电网负荷平衡和能源高效利用。文献[7-9]的算法考虑了电动汽车的能量需求、电网的负荷情况和可再生能源的供应等因素。现有的方法往往无法有效地应对电动汽车能源需求的不确定性和电网连接与快速充电服务之间的功率差距。因此, 为了实现高效、智能、可持续的电动汽车充电服务, 可以引入机器学习技术来改进能源调度系统<sup>[10-12]</sup>。

本文提出了一种基于机器学习的智能充电桩能源调度系统, 该系统应用于配备光伏系统和使用二次寿命电动汽车电池的储能系统的公共快速充电站微电网。此系统的关键优势在于能够处理

收稿日期: 2024-05-06。

基金项目: 江苏省自然科学基金项目(BK20181021)。

作者简介: 魏飞(1992-), 男, 工程师, 研究方向为营销计量、电工理论与新技术、充电桩设备等。

通信作者: 张东东(1990-), 男, 博士, 副教授, 研究方向为电工理论与新技术。E-mail: 1138625806@qq.com

电动汽车的能源需求不确定性和电网连接与快速充电服务之间的功率差距。同时,本文还采用机器学习方法自动合成适合的基于模糊规则的能源调度系统,以提高系统的智能化水平。

### 1 智能充电桩微电网能源模型构建

本文对智能充电桩能源微电网模型做出以下几个假设,这些假设定义了一个标准,以确保对不同问题进行分析时有一个统一的模型<sup>[13]</sup>。

①微电网能量系统功率流以 15 min 的时间间隔离散化,将每个时间间隔中的功率水平视为恒定不变。

②不考虑电压和无功功率控制等低电平操作。

③微电网和连接电网之间的电力传输损耗可以忽略不计。

④在线控制模块确保在微电网主干总线上实时运行期间可以实现功率平衡。

⑤能源调度系统的采样时间比储能系统功率控制的特征时间大得多,因此可以忽略储能系统内环动力学。

⑥将微电网子组件相互连接的功率转换器,包括专用于电网连接的功率变换器视作理想运行状态。

⑦电池管理系统能够正确监测和控制储能系统充电状态,确保其安全性。在本文中电池充电状态(短期)预测被简化为积分运算。

本文所分析的微电网架构如图 1 所示。

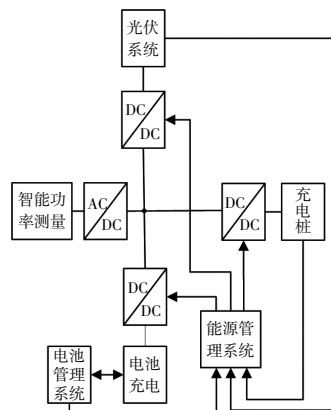


图 1 智能充电桩微电网模型

Fig.1 Intelligent charging pile microgrid model

如图 1 所示,在给定的第  $k$  个时间间隔,微电网主干线上的能量平衡为 3 个能源系统(快速充电站接口、光伏发电系统和储能系统)和电网交换

的能量之和。

$$E_k^{\text{FC}} + E_k^{\text{PV}} + E_k^{\text{S}} + E_k^{\text{N}} = 0, k=1, 2, \dots \quad (1)$$

式中:  $E_k^{\text{FC}}$  为由 DC 总线提供给快速充电(Fast Charge, FC)站的能量,  $E_k^{\text{FC}} \leq 0$ ;  $E_k^{\text{PV}}$  为光伏系统实际利用的能量,  $E_k^{\text{PV}} \geq 0$ ;  $E_k^{\text{S}}$  为与储能系统交换的能量,在放电情况下,  $E_k^{\text{S}} \geq 0$ ;  $E_k^{\text{N}}$  为从电网购买的能源,  $E_k^{\text{N}} \geq 0$ 。

为了强制微电网在充电功率达到 20 kW 时调峰,并促进能源的自动消耗,  $E_k^{\text{N}}$  受到以下限制:

$$0 \leq E_k^{\text{N}} \leq 5 \text{ kW} \cdot \text{h} (20 \text{ kW} \cdot 15 \text{ min}), k=1, 2, \dots \quad (2)$$

光伏系统最大电量  $E_k^{\text{PV}*}$  与其实际用电量  $E_k^{\text{PV}}$  之间的关系为

$$E_k^{\text{PV}} = p_k \eta_{\text{PV}} E_k^{\text{PV}*}, p_k \in [0, 1], k=1, 2, \dots \quad (3)$$

式中:  $p_k$  为实际利用的  $E_k^{\text{PV}*}$  的占比,为 0~1 的实数;  $\eta_{\text{PV}}$  为光伏系统中 DC-DC 功率转换器的能效。

插电式电动汽车能源需求  $E_k^{\text{FC}*}$  与其实际值  $E_k^{\text{FC}}$  之间的关系为

$$E_k^{\text{FC}} = f_k \cdot \frac{1}{\eta_{\text{FC}}} E_k^{\text{FC}*}, f_k \in \{0, 1\}, k=1, 2, \dots \quad (4)$$

式中:  $f_k$  为一个二进制值,  $f_k=1$  为满足充电需求,  $f_k=0$  为不满足充电需求;  $\eta_{\text{FC}}$  为能量转换和传输给出的快速充电站功率损耗。

微电网储能系统充电状态由电池管理系统监控,满足以下关系:

$$\text{SoC}_k = \text{SoC}_{\text{in}}, k=1 \quad (5)$$

$$\text{SoC}_{k+1} = \text{SoC}_k + \delta_k, k=1, 2, \dots \quad (6)$$

$$\delta_k = \begin{cases} \frac{E_k^{\text{S}}}{\eta_{\text{dch}} C^{\text{max}}}, E_k^{\text{S}} \geq 0 (\text{放电}) \\ \frac{E_k^{\text{S}}}{C^{\text{max}}}, E_k^{\text{S}} \leq 0 (\text{充电}) \end{cases} \quad (7)$$

$$\text{SoC}^{\text{min}} \leq \text{SoC}_k \leq \text{SoC}^{\text{max}}, k=1, 2, \dots \quad (8)$$

式中:  $\delta_k$  为  $E_k^{\text{S}}$  能量交换的充电状态变化函数;  $C^{\text{max}}$  为储能系统容量;  $\eta_{\text{ch}}, \eta_{\text{dch}}$  分别为储能系统充电、放电效率。

用于储能系统建模的电池组是为汽车应用设计的,即额定功率远高于 50 kW,因此对  $E_k^{\text{S}}$  的约

束应该是其他能源系统(光伏系统、快速充电负载和电网连接最大功率)的函数。

本文能源调度系统的作用是通过利用连接的光伏系统的本地生产来满足插电式电动汽车能源需求( $f_k$  和  $p_k$  必须保持等于 1),然而事实上这两个目标是相互冲突的。一方面,为了最大限度地提高光伏利用率,储能系统必须始终能够接受能量(其充电状态必须保持在最低水平),因为没有假设微电网可以向电网出售能量;另一方面,储能系统必须保持在高充电状态,以最大限度地满足再充电需求,因为电网和微电网之间的最大功率交换被视为低于最大快速充电功率需求。为了合理、有效地解决这种矛盾,本文应用数据驱动的方法,通过机器学习技术训练高效的能源调度决策系统,有效地(实时)调度储能系统充电状态和与其他微电网交换的能量。

## 2 基于机器学习的智能充电桩能源调度

### 2.1 目标函数定义

基于混合-整数线性规划(MILP)和动态规划(DP)的工具通常用于采用滚动时域策略实时优化调度微电网能量流。然而这种方法对于本文所建立的模型是不可行的,因为负载(快速充电站的能量需求)是不灵活的(不协调的),难以有效预测间歇性和随机行为。

本文选择了一段时间内的  $E_k^{PV*}$  和  $E_k^{FC*}$  扩展数据的时间序列定义的数据集,使用动态规划方法,利用未来样本的准确信息(从而避免使用预测算法),评估不同的解决方案,这些解决方案的目标函数在定义方式上有所不同。

本文将快速充电需求的实现、光伏发电的开发和储能系统压力 3 个能量调度系统的目标函数分别定义如下:

$$f_{fc} = \frac{\sum_k^N (1-f_k)}{N} \quad (9)$$

$$f_{pv} = \frac{\sum_k^N \left[ (1-p_k) \cdot \frac{E_k^{PV*}}{12.5} \right]}{N} \quad (10)$$

$$f_{soc} = \frac{\sum_k^N [P^{SoC}(SoC_k)]}{N} \quad (11)$$

式中: $N$  为保证可行的时间序列长度; $12.5 \text{ kW} \cdot \text{h}$

对应于一个时间间隔的快速充电需求。

在第一阶段中,对两种边界情况进行公式化,根据式(9)和式(10)定义能源调度系统性能阈值的上限和下限。其中:第一种解决方案定义为  $\Gamma^{FC}$ ,旨在通过惩罚光伏利用率来最大化快速充电能量;第二种解决方案定义为  $\Gamma^{PV}$ ,旨在通过惩罚快速充电能量来开发光伏发电。

对于目标函数  $F = \alpha_{fc} \cdot f_{fc} + \alpha_{pv} \cdot f_{pv} + \alpha_{soc} \cdot f_{soc}$ , 考虑到训练集、验证集和测试集中的第  $i$  个通用数据集,两种解决方案的目标函数和权值分别如下:

$$\Gamma_{FC}^i = \{ f_{fc}^i, f_{pv}^i, f_{soc}^i, \omega^i \},$$

$$\omega^i = \{ \alpha_{fc} = 0.5, \alpha_{soc} = 0.5, \alpha_{pv} = -10^{-3} \} \quad (12)$$

$$\Gamma_{PV}^i = \{ f_{fc}^i, f_{pv}^i, f_{soc}^i, \omega^i \},$$

$$\omega^i = \{ \alpha_{fc} = -10^{-3}, \alpha_{soc} = 0.5, \alpha_{pv} = 0.5 \} \quad (13)$$

第三种解决方案用于评估同时满足光伏开发和快速充电需求的最优解决方案,定义能源调度系统训练阶段的标记模式集。

目标函数定义如下:

$$\bar{F}^{TR} = \frac{1}{3} \frac{f_{fc}^{TR} - f_{FC,fc}^{TR}}{f_{PV,fc}^{TR} - f_{FC,fc}^{TR}} + \frac{1}{3} f_{soc}^{TR} + \frac{1}{3} \frac{f_{pv}^{TR} - f_{PV,pv}^{TR}}{f_{FC,pv}^{TR} - f_{PV,pv}^{TR}} \quad (14)$$

式中:  $f_{FC,fc}^{TR}$ ,  $f_{PV,fc}^{TR}$ ,  $f_{FC,pv}^{TR}$ ,  $f_{PV,pv}^{TR}$  分别为不同目标函数的训练集数据对应的值。

### 2.2 快速充电需求负荷预测

人工神经网络在光伏发电预测中的应用非常有效。基于回声状态网络(Echo State Network, ESN)的预测算法可以用于预测扩展到给定时间范围的光伏发电趋势。该模型在每个预测时间间隔都会合成一个多输入单输出的 ESN。因此,要合成的 ESN 的数量等于覆盖预测时间范围的时间间隔的数量,该合成过程可以更好地研究预测时间的最佳范围选取。因为当时间范围扩展时,已经训练的 ESN 保留在新的预测器中。

ESN 是一种三层递归神经网络,包括一个隐藏层(储存层)、一个输入层和一个输出层。在不涉及太多细节的情况下,定义神经元之间连接的储存层和输入层矩阵是随机生成的,而输出层的权重通过最小二乘回归来估计,最小二乘回归的优化目标是 minimized 近似曲线上的最小平均误差。ESN 建模主要通过设置部分参数和适当的目标函数公式来生成储存层(伪随机),以评估其性能。

ESN 实用且概念简单,但该方法需要一些经验和观察力才能获得良好的性能。事实上,有监督的 ESN 训练一般不需要应用在多层感知器神经网络中的错误反向传播过程中。为了弥补在某些情况下可能缺乏的 ESN 训练经验,可以使用遗传算法(GA)来调整一些 ESN 参数,包括储层尺寸、储层频谱半径、储层连通性、ESN 输入缩放系数、输入移位矢量等,这些参数定义了如何(随机)生成储存层和输入层。其中,储层频谱半径用来限制储层连接权重,储层连通性定义矩阵的稀疏性。基于遗传算法的 ESN 参数调整过程如下。

#### ①确定待调整的参数

在使用遗传算法进行参数优化时,确定需要调整的参数,包括储层尺寸、储层频谱半径、储层连通性、ESN 输入缩放系数、输入移位矢量等。这些参数的选择会直接影响 ESN 的性能。

#### ②定义适应度函数

在遗传算法中,定义一个适应度函数来评估每个个体(参数组合)的优劣。在调整 ESN 参数时,适应度函数可以是模型在训练集上的预测准确度或者其他性能指标,如均方误差、交叉熵等。

#### ③编码参数

将 ESN 的参数编码成遗传算法中的染色体,这可以通过将参数值映射到二进制编码或其他编码方式来实现。例如,可以将权重矩阵的每个元素编码成一串二进制数。

#### ④初始化种群

随机生成一定数量的个体作为初始种群。每个个体代表了一个 ESN 的参数组合。

#### ⑤遗传算法的迭代过程

遗传算法通过遗传操作(选择、交叉、变异)迭代地优化参数。具体过程如下。

选择:根据适应度函数的评价,选择一定数量的个体作为父代。

交叉:随机选择一些个体进行交叉操作,生成新的个体(子代)。

变异:对部分个体进行变异操作,以引入新的基因组合。

评价:计算每个个体的适应度,根据适应度函数对个体进行评价。

选择下一代:根据评价结果选择下一代个体。

迭代:重复以上步骤,直到达到停止条件。

#### ⑥终止条件

可以通过设置迭代次数或达到一定的适应度阈值来确定遗传算法的终止条件。

在训练过程中,ESN 的目标函数  $f_{\text{ESN}}$  考虑了模型预测性能和复杂性,如下所示:

$$f_{\text{ESN}}=0.99\xi+10^{-1}\nu+10^{-4}\psi \quad (16)$$

式中: $\xi$  为相对于预测信号的均方根误差(RMSE); $\nu$  为优化的输出权重除以其自身长度的总和; $\psi$  为通过各自的下界和上界归一化的储层大小。

ESN 的合成过程可以简要总结如下。给定一组训练集和验证集,以及由其染色体表示的遗传算法个体,ESN 参数由染色体的值(基因)确定。这些参数用于在训练集上生成 ESN,在验证集上计算 ESN 的目标函数  $f_{\text{ESN}}$ 。对种群中的每个个体重复这个过程,在不断的迭代过程中对最好的个体及其基因进行分类和保存,直至达到停止标准。

一旦合成了预测算法,即调整了与给定预测时间范围成比例的多个 ESN,就将最小均方误差线性回归(LMSELR)应用于预测输出阵列。该算法允许定义光伏系统(未来)发电趋势,允许保持输出数量等于 2,而与光伏系统预测输出阵列长度扩展无关。

另外,由于负荷的随机性和间歇性,使用基于神经网络的预测算法在预测快速充电能源需求方面并不是完全有效。因此,快速充电需求的未来趋势由非参数直方图方法估计的在当前小时发生插电电动汽车的概率来定义,直方图是通过考虑训练集上的快速充电需求而生成的。

### 2.3 自适应神经模糊推理系统

能源管理系统(Energy Management System, EMS)的决策系统核心是一个具有一阶 TS 模糊规则的自适应神经模糊推理系统(Adaptive Neuro Fuzzy Inference Systems, ANFIS),该规则具有高斯多变量隶属函数特征。多元高斯多变量隶属函数具有以下形式:

$$\Phi^{(i)}(\mathbf{u})=e^{-\frac{1}{2}(\mathbf{u}-\boldsymbol{\mu}_i)\mathbf{C}_i^{-1}(\mathbf{u}-\boldsymbol{\mu}_i^T)} \quad (17)$$

式中: $\Phi^{(i)}$  为通用的第  $i$  个多变量隶属函数,由  $\boldsymbol{\mu}_i$  和  $\mathbf{C}_i$  定义; $\boldsymbol{\mu}_i$  为多变量隶属函数的质心向量; $\mathbf{C}_i$  为多变量隶属函数的协方差矩阵; $\mathbf{u}$  为  $[0, 1]$  中归

一化的输入向量,  $\mathbf{u}$  由  $E_k^{PV*}, E_k^{FC*}, SoC_k, m_k^{PV}, q_k^{PV}, h_k^{FC}$  组成。

由于多变量隶属函数的多维性, 第  $i$  个多变量隶属函数  $\Phi^{(i)}$  也用于定义具有以下形式的第  $i$  个规则的规则先行集: 若  $\mathbf{u}$  为  $\Phi^{(i)}$ , 则  $y^{(i)} = \gamma^{(i)} \mathbf{u}^T$ , 其中,  $\gamma^{(i)}$  是第  $i$  个规则结果, 由一个适当调整的仿射超平面定义。由于多变量隶属函数的多维性和不存在“AND”—“OR”算子, 激发规则强度  $r$  恰好是多变量隶属函数值,  $r^{(i)} = \Phi^{(i)}$ 。

解模糊过程由一个 Winner Takes All(WTA) 算子来选择规则, 本文考虑将最高多变量隶属函数值为特征的超平面函数用于计算总体输出。

图 2 为自适应神经模糊推理系统的 EMS 架构, 在下一时间间隔中, 该架构输出与储能系统交换的能量。图 2 在不同的层中分别表示了输入规范化过程、规则评估和 WTA 去模糊算子。

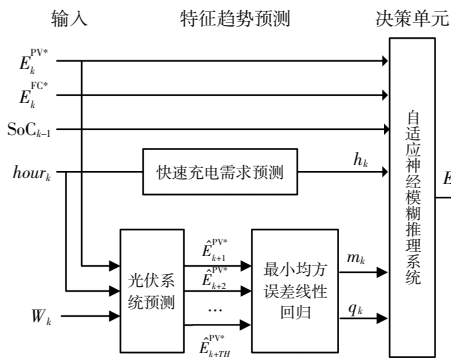


图 2 能源调度系统决策系统架构

Fig.2 Energy management system decision system architecture

### 3 仿真验证

#### 3.1 仿真实验设计

本文以配备 ESS 和光伏发电厂的微电网作为仿真对象, 该微电网可以支持 50 kW 公共快速充电站。通勤插电式电动汽车电池组(用于快速充电负载分析)和微电网 ESS 效率值见文献[14]。假设电动汽车储能系统锂离子电池的效率约为 95%, 考虑变速器、电池调度系统和功率转换器的功率损耗, 电池组的整体效率( $\eta_{FC}$ )设置为 90%; 假设微电网储能系统容量降低到 80% 时, 充、放电效率( $\eta_{ch}, \eta_{dch}$ )为 80%。微电网储能系统由发电数据集生成 5 种不同的光伏分布, 峰值功率分别设置为 10, 20, 30, 40 kW 和 50 kW。为了生成类似的时间序列, 首先将原始功率分布归一化为

[0, 1] 内的数据, 然后乘以特定的给定峰值功率。

对数据集进行定义, 可以制定  $3 \times 5 = 15$  个不同的场景, 每个场景由正确定义的不同快速充电站和光伏系统表示。对于每个场景均分别使用上一节中的决策系统综合程序, 该程序依赖于 3 组不同训练集—验证集的定义和通过  $k$  倍交叉验证的单个 TS 模糊规则。每个数据集涵盖 15 min 频率采样下总周期 60 d 的数据, 总周期划分为相同维度的 4 个子集(15 d, 相当于数据集的 25%), 其中, 两个子集中的数据用于训练集, 一个子集的数据用于验证集, 一个子集的数据用于测试集。与给定场景相关的 EMS 性能通过相应的 TS 模糊规则进行评估, 然后与最佳解决方案(一般由 TS 模糊规则所制定)进行比较。

为了更好地评估 ANFIS EMS 的性能, 对所有仿真场景下的 Mamdani-FIS(Fuzzy Inference System)的 EMS 进行训练。Mamdani-FIS 设计为与 ANFIS EMS 执行相同的任务, 考虑相同的输入阵列, 从而实现可支持预测模型。采用的模糊推理系统中每个术语集(术语集基数是输入数量的幂)由 3 个多变量隶属函数定义, 并且规则库拥有  $3^6 = 729$  个规则, 以便考虑每个可能的规则先行组合。

由于规则数量庞大, 因此本文选择使用遗传算法而非专家知识来合成规则库。这种合成技术不需要 ANFIS 的目标输出, 通过在训练集和验证集的并集上模拟 Mamdani-FIS 来评估适应度函数。

#### 3.2 仿真结果分析

表 1 和表 2 分别给出了每个给定模拟场景下, 快速充电站和光伏电站相对于 TS 的总体累积能量需求和能量生成。图 3 为考虑到整体数据集, 每个通勤车队每小时在快速充电站进行充电的插电式电动汽车数量。从图 3 中可以看出, 3 条

表 1 快速充电对每个场景的 TS 规则需求

Table 1 TS rule requirements for each scenario for fast charging

通勤车队/辆	1 600	2 400	3 200
整体快速充电需求/kW·h	800	1 600	1 900
需要模糊规则数量/个	64	130	156

表 2 考虑光伏峰值功率函数的光伏发电量

Table 2 PV power generation considering PV peak power function

光伏电网规模/kW	10	20	30	40	50
整体能量生成/kW·h	850	1 700	2 550	3 400	4 250




图 3 各通勤车队的电动汽车快速充电需求

Fig.3 The fast charging needs of electric vehicles for various commuting fleets

曲线在早上均呈现峰值,在晚上呈现更高的峰值,这两个高峰主要可归因于全日制通勤者,他们占有了较高的渗透率,证明了本文所提方法的有效性。事实上,第一个高峰是在 08:00 之后,即全日制通勤者的平均出发时间,第二个高峰大约在 8 h 之后,即全日制通勤者的返回时间。在 3 种情况下,快速充电需求在深夜和清晨均可以忽略不计。因此,非全日制和非定期通勤者在两个高峰之间做出了主要贡献。

对于光伏预测的结果,通过考虑归一化的光伏发电概况来评估误差,所有回声状态网络在 TS 上的 RMSE 均低于 8%。

ANFIS 和 Mamdani-FIS 的 EMS 性能在 TS 上与最佳解决方案以及表 1 和表 2 中展示的整体快速充电需求和光伏发电数据进行了比较。为了更好地评估本文所提出算法的鲁棒性,将 ANFIS 合成过程重复 5 次。

图 4 显示了在 TS 上计算的每个模拟场景的未满足快速充电需求的数量,对该数据进行归一化,分别得到最佳解决方案、ANFIS EMS 和 Mamdani-FIS 能源调度系统 3 种情况下的总快速




图 4 不同模拟场景、不同解决方案的快速充电性能

Fig.4 Fast charging performance for different simulation scenarios and solutions

充电需求。图 5 显示了最佳解决方案、ANFIS EMS 和 Mamdani-FIS 能源调度系统解决方案的未利用光伏发电量相对于总产量的比例(表 2)。




图 5 不同模拟场景、不同解决方案的光伏系统性能

Fig.5 Performance of photovoltaic systems with different simulation scenarios and solutions

从仿真结果可以看出,在大多数情况下,由于购买能源时电网的连接之间存在能源约束,即使是最优解也不能满足整体快速充电需求。ANFIS EMS 在满足快速充电需求方面的表现等于或小于其各自总需求的 13%。此外,对于超过 20 kW 的光伏系统,目标函数[式(14)]的第一项等于或低于 0.05。

须要注意的是,光伏能源开发受到快速充电需求(电动汽车车队规模)和光伏规模的制约。当光伏系统较小(10 kW),电动汽车通勤者数量较高(每日有 2 400 或 3 200 通勤者)时,最优解决方案的性能非常接近总产量;对于小型车队和大型光伏系统,光伏能源开发可能会减少到总产量的 50%以下。ANFIS EMS 的性能与其各自的最优解最多相差约 10%。

#### 4 结论

本文提出了一种基于机器学习的智能充电桩能源调度系统,以解决公共快速充电站微电网中电动汽车能源需求不确定性和电网连接与快速充电服务之间的功率差距的问题。通过应用光伏系统和二次寿命电动汽车电池储能系统,能够有效处理电动汽车的能源需求与供应之间的平衡。

实验结果表明,相对于最优基准解决方案,本文所提出的能源调度系统在性能上有所提升,能更有效地处理电动汽车的能源需求不确定性以及电网连接与快速充电服务之间的功率差距。同时,通过对光伏系统的最佳规模和微电网系统的有效性进行分析,为电动汽车充电设施的优化提供了参考依据。

## 参考文献:

- [1] 谭润,麻硕琪.面向电动汽车自用充电桩协同共享的关键技术研究[J].产业创新研究,2023(16):144-146.
- [2] 于志江.电动汽车智能充电桩设计及关键技术研究[J].互联网周刊,2022(21):24-26.
- [3] 张辉,马岩,张璘.新能源汽车智能充电桩设计与应用[J].南方农机,2020,51(24):169,172-173.
- [4] 杨家全,冯勇.分布式智能充电桩控制信息的机密性保护方案[J].云南电力技术,2022,50(5):21-26.
- [5] 郝庆利,周荣臻,乔宁,等.考虑用电效用的用户购电决策优化[J].南京理工大学学报,2023,47(2):277-284.
- [6] 易远超,桂康哲,卜小兵.一种电动汽车公共智能充电桩的管理系统[J].汽车电器,2023(8):1-2.
- [7] 付萍萍,郑富永,王华,等.基于云平台的充电桩智能管理系统及移动应用开发[J].微型电脑应用,2022,38(6):180-183.
- [8] 张明慧,周天睿,于静,等.电动汽车智能充电桩管理系统的设计与开发[J].现代计算机,2021,27(33):110-115.
- [9] 蒋涛,秦奋,俞伟勇,等.基于物联网的智能充电桩及运行管理平台的设计[J].产业与科技论坛,2017,16(1):67-68.
- [10] 钱强,陈海,郑义,等.基于机器学习的电动汽车无线充电异物目标检测方法[J].现代电子技术,2023,46(13):43-48.
- [11] 肖白,朱珈汛,刘鑫,等.基于CRITIC法和非合作博弈的电动汽车充电站双层规划[J].东北电力大学学报,2022,42(4):35-49.
- [12] 柴万腾,程志江,李永东,等.基于群系统一致性电动车充电桩接入微电网的控制研究[J].可再生能源,2018,36(6):882-887.
- [13] 周雪会,王希平.考虑顾客满意度的电动汽车充电桩规划策略[J].可再生能源,2017,35(6):933-939.
- [14] Heymans C, Walker S B, Young S B. Economic analysis of second use electric vehicle batteries for residential energy storage and load-levelling [J]. Energy Policy, 2014, 71(8):22-30.

## Research on intelligent photovoltaic charging station energy testing system based on machine learning

Wei Fei<sup>1</sup>, Xu Di<sup>1</sup>, Chen Xin<sup>1</sup>, Zhang Zhaojie<sup>1</sup>, Liu Xue<sup>1</sup>, Zhang Dongdong<sup>2</sup>

(1.State Grid Tianjin Marketing Service Center, Tianjin 300220, China; 2.Nanjing Institute of Technology, Nanjing 211167, China)

**Abstract:** This article proposes an intelligent charging station energy scheduling system based on machine learning, which is applied to public fast charging station microgrids equipped with photovoltaic systems and energy storage systems using secondary life electric vehicle batteries. The energy dispatch system can be used to address the uncertainty of energy demand for electric vehicles and the power gap between grid connection and fast charging services. In addition, this article uses machine learning methods to automatically synthesize suitable energy scheduling systems based on fuzzy rules. The energy dispatch system proposed in this article considers different electric vehicle fleets and photovoltaic scales, providing a reference for the optimal scale of photovoltaic systems and the effectiveness of nanogrid systems. Finally, in the experiment, a mixed deterministic stochastic process was used to simulate the energy demand of electric vehicles, which showed an improvement in performance compared to the optimal benchmark solution. This indicates that the system can more effectively handle the energy demand uncertainty of electric vehicles and the power gap between grid connection and fast charging services.

**Keywords:** machine learning; intelligent charging station; energy scheduling; photovoltaic system