

DOI: 10.7667/PSPC170732

基于深度学习的充电站容量规划方法

李智, 侯兴哲, 刘永相, 孙洪亮, 朱珠, 龙羿, 徐婷婷

(国网重庆市电力公司电力科学研究院, 重庆 401123)

摘要: 随着电动汽车充电设施建设的日益增长, 区域内社会用户所需要的电动汽车供电容量的预测问题成为影响充电站建设规划的关键问题。结合深度学习的数据特征研究理论, 提供了一种基于充电站容量影响因子的机器学习容量规划预测方法。该方法以充电站周边交通、区域发展和电网安全等环境影响因子为基础, 训练并建立服务环境与充电需求的神经网络映射模型。实验表明, 该模型对待建充电站周边环境影响因子进行分析后可以给出待建充电站的理想充电容量, 从而解决待建充电站的充电容量定容问题。

关键词: 充电站定容; 电动汽车; 大数据

A capacity planning method of charging station based on depth learning

LI Zhi, HOU Xingzhe, LIU Yongxiang, SUN Hongliang, ZHU Zhu, LONG Yi, XU Tingting

(State Grid Chongqing Electric Power Research Institute, Chongqing 401123, China)

Abstract: With the increasing growth of charging facilities for electric vehicles, the power supply capacity prediction for electric vehicles required by the social users in a district become a key issue for charging station's construction planning. Combined with the data feature theory of depth learning, a machine learning based capacity planning forecasting method based on charging station capacity impact factors is presented. The method, considering environment impact factors such as traffic around charging station, regional development, power grid security and so on as the basis, trains and builds a neural network mapping model of service environment and charging requirement. Experiments show that the model can give the ideal charging capacity of the to-be-built charging station after analyzing the impact factors of the to-be-built power station surroundings, which could solve the sizing problem of the station charging capacity.

Key words: charging station capacity; electric vehicle; big data

0 引言

随着国家新能源战略的阶段性调整和持续性推进, 传统燃油车在国家能源战略安全和社会环境矛盾层面的问题日益突显, 电动汽车凭借其低能耗、高性能和无污染等特性, 在新能源出行方式变革的大背景下蓬勃发展, 正占据着越来越多的市场份额。与发达国家相比, 国内电动汽车行业存在的起步较晚、充电设施配套不足的问题^[1]急需解决。

1 充电站定容问题

区域内社会用户所需要的电动汽车供电容量预

测问题是影响电网建设规划的关键问题^[2], 目前国内外针对该问题的研究正处于起步阶段。本文基于深度特征学习的研究方法, 提供了一种基于深度置信网络学习的容量规划预测方法。

在本文研究中, 首先通过基于环境影响因子加权修正的沃罗诺伊图对现有充电站进行数据采集域划分, 然后定向采集充电站容量泛化影响因子, 并结合深度学习算法对已运营的历史充电站运营数据进行学习和分析, 提取出泛化影响因子的特征信息, 并据此建立特征映射神经网络, 通过对历史数据的反复学习, 在历史充电站的运营基础上获取最终的神经网络容量预测模型, 最后将其用于充电站容量建设规划期间对新建充电站容量的仿真预测。其流程如图1所示。

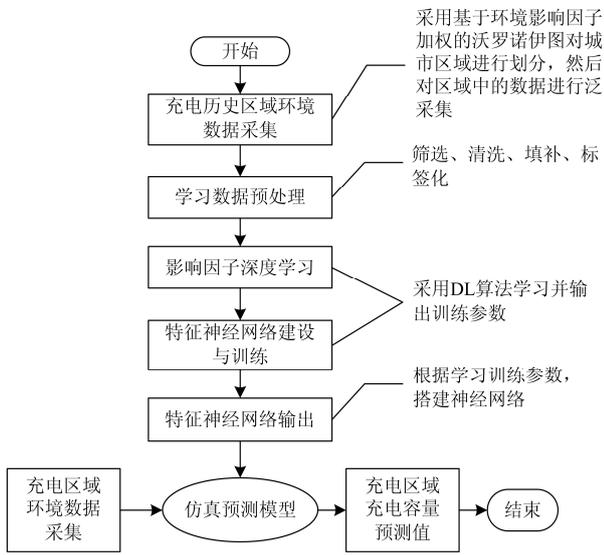


图 1 基于数据特征学习的充电站容量预测模型训练流程图

Fig. 1 Training flow chart of charging station capacity prediction model based on data feature learning

2 充电站建设区域数据采集

目标建设区域内, 充电站供电容量受多维特征因子的影响。本文在确定充电站建设地址后^[3], 首先通过基于环境影响因子加权后的沃罗诺伊图, 对城市进行数据采集区域划分, 随后对各区域内影响充电站容量的因子进行泛采集。

2.1 数据采集域环境加权划分方法

沃罗诺伊图^[4]目前广泛地应用在目标区域空间选址分析领域, 本文将其在数据采集域划分领域。

设平面存在一个点集 $P=\{p_1, p_2, p_3, \dots, p_n\}$, $4 \leq n < \infty$, 则任意点的常规沃罗诺伊图定义为

$$V(p_i) = \{X \in V(p_i) \mid d(X, p_i) \leq d(X, p_j)\}, \quad (1)$$

$$i, j = 1, 2, \dots, n, i \neq j$$

式中, $d(x, p_i)$ 、 $d(x, p_j)$ 分别表示平面上任意点 x 与 p_i 和 p_j 间的欧氏距离。

传统沃罗诺伊图只是确定了理论服务范围, 它只考虑其距离远近, 但没有考虑到城市的实际行政情况、交通分布、人口流动方向和经济潜力等。因此需要对区域实际情况对理论服务范围进行修正, 服务修正参数集为 $\omega\{\omega_1, \omega_2, \dots, \omega_n\}$, 该过程称之为加权沃罗诺伊图^[5], 是常规沃罗诺伊图的一种扩展形式, 本文在加权沃罗诺伊图的基础上还增加了对应的微调系数为 $\varepsilon\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n\}$, 用于进一步优化划分结果, 其定义为

$$V(p_i, \omega_i, \varepsilon_i) = \{X \in V(p_i, \omega_i, \varepsilon_i) \mid \omega_i d(X, p_i) + \varepsilon_i \leq \omega_j d(X, p_j) + \varepsilon_j\},$$

$$i, j = 1, 2, \dots, n, i \neq j$$

(2)

式中: ω_i 为控制点 p_i 的权重; ε_i 为控制点 p_i 的微调系数。服务修正参数 ω 和微调系数 ε 的引入, 使区域边界线变得不再平整^[5], 如图 2 所示, 服务修正参数定义为

$$\omega_i = \frac{P(i) \cdot C}{M(i)} \quad (3)$$

式中: $P(i)$ 为 i 区域内的人口总数; C 为该城市人均汽车消费; $M(i)$ 为 i 区域的总面积, 对应定义了各区域的微调系数 ε_i , 用于微调服务修正参数的精度和准确度。

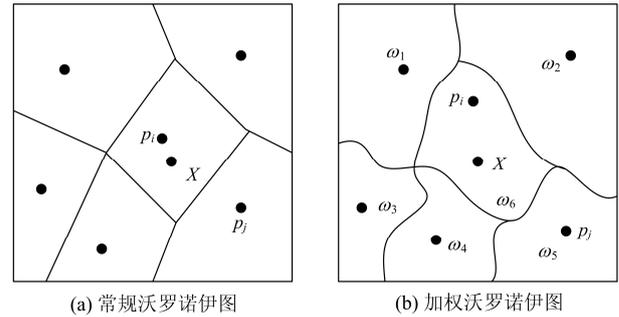


图 2 常规与加权沃罗诺伊图对比

Fig. 2 Comparison of conventional Voronoi diagram and weighted Voronoi diagram

当 $\omega_1 = \omega_2 = \dots = \omega_n$, $\varepsilon_1 = \varepsilon_2 = \dots = \varepsilon_n = 0$, 式(1)和式(2)等价, 即常规沃罗诺伊图是加权沃罗诺伊图权重相等时的特例。加权沃罗诺伊图可以利用权重来描述充电需求分布不均匀, 可以精确各充电站的影响范围^[6], 服务域决定了充电站中容量影响因子的采集范围, 是决定充电站定容量的重要前置条件。

2.2 影响因子数据采集

区域内环境技术指标集合 D 是充电站定容所需要的技术指标, 本文主要有 4 类影响因子: D_t 为交通影响因子、 D_d 为区域发展影响因子、 D_g 为电网安全因子、 D_o 为其他影响因子。

2.2.1 交通影响因子

对于定址的充电站而言, 充电站所在位置的来往交通情况, 会直接影响电动汽车进站充电的情况, 交通影响因子训练集合定义为 D_t , 详见表 1。

T_lane_num , 交通系统中车道的条数越多, 线路的效用越高。

表 1 交通影响因子训练集合

Table 1 Training set of traffic impact factors

变量名称	变量含义	取值域/单位
T_lane_num	车道条数	N (条)
T_lane_port	车道路口数	N (个)
T_lane_flow	道路车量平均负载	N (整数)
T_lane_light	道路红绿灯个数	N (整数)

T_lane_port , 车道路口数直接影响车辆进入充电区域的便捷程度, 一定范围内提升道路的路口数量可以提升道路的使用率。

T_lane_flow , 道路车流量会直接影响进入充电站汽车的数量。本文将分为 4 个等级: 1、2、3、4, 车流量随数字的增大而增大。

T_lane_light , 道路红绿灯数量是影响交通的重要因素, 道路系统的通行通畅度, 随着红绿灯的增加而降低, 但是随着红绿灯的增加, 道路的安全性和吞吐量稳定性随之增加。

2.2.2 区域发展影响因子

区域发展影响因子用于描述充电站选址的区域发展潜力, 合理地选址将有助于提升充电站的经济效益。区域发展影响因子训练集合定义为 D_d , 详见表 2。

表 2 区域发展影响因子训练集合

Table 2 Training set of regional development impact factors

变量名称	变量含义	取值域/单位
Z_people_num	覆盖区域人口数量	N (1000 个)
Z_charge_con	充换电需求负荷距	自定义
$Z_vehicle_num$	区域电动车数量	N (辆)
$Z_city_building$	区域发展等级	N (整数)

Z_people_num , 充电覆盖区域内的总人数。

Z_charge_con , 充电需求负荷距可以对用户进站的方便程度进行量化。作为面向社会用户的充电服务设施, 充电站的便捷程度与对应的经济效益正相关^[7]。负荷距即负荷与距离的乘积, 负荷充电平均距离定义如式(4)。

$$z_charge_con = \frac{\sum_{j=1}^n d_i(j) \cdot s(j)}{\sum_{j=1}^n d_i(j)} \quad (4)$$

式中: $d_i(j)$ 为区域 i 内负荷需求 j 到对应的集中充电设施的距离; $S_i(j)$ 为区域 i 内负荷需求 j 的需求量。

$Z_vehicle_num$, 充电站覆盖区域内的电动汽车的数量, 可以由该区域内车辆总量和对应的电动汽车渗透率计算, 渗透率指电动汽车数量占汽车总量的比例^[7]。

$$z_vehicle_num = a_i \cdot N_i \quad (5)$$

式中: a_i 为第 i 个区域内预期电动汽车渗透率; N_i 为第 i 个区域中汽车的总数量。

$Z_city_building$, 区域发展等级由该区域的发展规划决定, 从待发展到已成熟共分为 1、2、3、4、5 共五个等级。

2.2.3 电网安全影响因子

充电站的建设将产生谐波污染^[8-9]。电动汽车充电期间会对该区域的电网结构产生巨大的充电负荷, 增加峰谷差, 对输配电网会产生影响, 其数据指标为 E_spdw 。充电站接入电网后叠加了非线性负载, 非线性负载在电网的接入运行会在电网中产生谐波, 谐波是影响电能质量的重要因素之一^[10], 谐波影响指标为 E_xb 。电网安全影响因子集合定义为 D_g , 详见表 3。

表 3 电网安全影响因子集合

Table 3 Training set of power grid security impact factors

变量名称	变量含义	取值
E_spdw	充电站对输配电网的影响	0/1/2(正常/一般/严重)
E_xb	充电站谐波的影响	0/1/2(正常/一般/严重)

其中 E_spdw 和 E_xb 根据影响程度分为正常、一般和严重, 分别将各个数值设为 0、1、2 三个值。

2.2.4 其他影响因子

O 为其他影响因子集合, 包括充电站所在的地理环境因素、经济发展因素、充电站之间相互影响因素和天气因素。地理环境因素主要是指充电站所在位置的抵抗自然风险的能力, 在一定范围内充电站的容量与抗风险能力成正比, 其数据指标为 O_hj 。经济发展因素是指充电站所在位置的经济发展潜力, 其数据指标为 O_jj 。充电站互相影响因素是指充电站与周边充电站的相互影响^[11], 主要描述某一充电站在业务繁忙时与周边充电站之间的调配协作程度, 其数据指标为 O_hxyx 。天气因素是指充电站的极端天气对电网的影响, 电网的影响也会对充电站产生影响, 其数据指标为 O_tq 。其他影响因子集合定义为 D_o , 详见表 4。

表 4 其他影响因子集合

Table 4 Training set of other impact factors

变量名称	变量含义	取值
O_hj	充电站的地理环境因素	0/1/2(差/中/优)
O_jj	充电站的经济发展因素	0/1/2(差/中/优)
O_hxyx	充电站互相影响因素	$x\%$ (百分数)
O_tq	充电站天气影响因素	$y\%$ (百分数)

其中 O_hj 、 O_jj 根据实际情况分为差、中、优三个档次, 分别取值为 0、1、2 三个值。 O_hxyx

根据周围充电站的互相影响修正充电站的定容值,根据影响程度取修正容比值为 $x\%$ 。 O_{tq} 根据充电站的天气因素,修正充电站的定容值,根据影响程度修正定容比值为 $y\%$ 。

3 基于深度学习的充电站容量预测算法

本文选择深度置信网络(Deep Belief Network, DBN)深度学习架构来建立充电站容量预测模型, DBN 是深度学习中用于问题分类的代表模型,与传统的机器学习模型相比其具有以下优点:

DBN 能较好地拟合充电站环境特性与服务负载能力的复杂映射关系,并求出最优解。

DBN 能较好地优化模型训练过程中的时效性问题。

根据第 2 节内容,定义了训练数据结构 D_t :

$$D_t = \{D_x, D_y\} \quad (6)$$

D_x 是综合环境变量, D_y 是对应 D_x 下充电站的预期负载:

$$D_x = \{D_t, D_d, D_g, D_o\} \quad (7)$$

若干条 D_t 组合成训练集 $sample_set$, 充电站容量预测模型训练过程如图 3 所示。

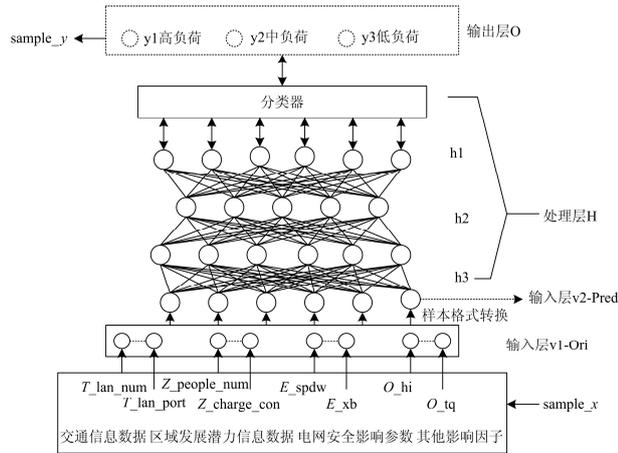


图 3 充电站容量预测模型图

Fig. 3 Prediction model of charging station capacity

本文中的充电站容量预测模型训练算法主要由基于 CD 的 RBM 无监督学习算法^[12]和基于 BP^[13]的有监督反馈调节算法组成。本节将重点介绍如何利用该算法先后完成无监督学习部分对无标签学习样本的学习和有监督学习部分对有标签学习样本的学习,算法总结构如表 5 所示。

训练集 $sample_set$ 的数据来源于已投入运营的充电站,其数据主要包括两个部分:一部分按照第 2 节影响因子集 D 采集的信息数据 $sample_x$ (由若干 D_x 组成);另一部分是对应的充电站理想负载容量

表 5 基于深度学习的充电站负载预测模型训练算法
Table 5 Prediction model training algorithm of charging station load based on depth learning

输入: 训练集 $sample_set(train_x, finetuning_x, finetuning_y, test_x$ 和 $test_y)$;
输出: 充电站负载预测模型
训练算法步骤:
BEGIN:
1) 初始化 DBN 中的 RBM 层数 L 、各层节点数 $N[]$ 、学习速率 μ 、迭代周期 k , 连接权值矩阵 $W[]$, 偏置矩阵 $b[]$ 。
2) 导入 $train_x$, 训练 DBN。
3) 导入 $finetuning_x$ 、 $finetuning_y$, 对已获取的 DBN 采用 BP 算法进行微调。
4) 导入 $test_x$ 、 $test_y$, 测试已训练完成的基于 DBN 的充电站负载预测模型的准确率。
5) 若测试出的准确率不满足要求, 返回步骤 1), 改变深度学习网络内部结构, 重新开始训练过程。
6) 经测试输出后的深度神经网络准确率满足要求后, 输出该模型。

(或实际需求量)数据 $sample_y$ (由若干 D_y 组成)。从 $sample_x$ 中随机抽取大量数据填充无监督学习部分的训练输入集合 $train_x$, 然后再从 $sample_x$ 剩余的数据中随机抽取若干组成微调数据集 $finetuning_x$, 同时从 $sample_y$ 中抽取对应的微调结果对照数据集 $finetuning_y$, 这一组数据将用于优化神经网络的训练。最后再从剩余 $sample_x$ 和 $sample_y$ 中随机抽取若干对应的数据组成测试用例 $test_x$ 和 $test_y$, 用于验证模型的准确性。

3.1 基于 CD 的 RBM 训练算法

在 RBM 堆叠成的 DBN 深度学习神经网络架构中, 训练样本的输入层也称为可视层 $v(v_1, v_2)$, 可视层中的所有细节均可见也可解释, 其对应处理层(隐层 H)中的各神经元只可输出, 节点的具体意义由于高度抽象不可解释。RBM 是一个层内无连接, 层之间全连的单层神经网络能量模型。基于 RBM 模型的对称结构, 以及其中神经元状态的条件独立性, RBM 的训练过程需要借助 Gibbs 采样方法进行采样, 不仅需要大量样本, 还需要多次重复采样, 这些需求极大地加重了 RBM 的训练复杂度, 故该方法虽然理论可行, 但从效率上来说是不可取的^[14]。

与 Gibbs 采样不同, CD 算法使用训练样本初始化 v_0 时, 仅需要使用 k (通常 $k=1$)步 Gibbs 采样便可以得到足够好的近似^[15-16]。在 CD 算法中, 可见单元的状态被初始化为一个训练样本, 该算法可以简述为

对 $\forall x \in X$, 初始化 $v_0 := x$, 然后执行 1 步 Gibbs 采样, 先后执行:

- 1) 利用 $P(h|v^{(t-1)})$ 采样出 $h^{(t-1)}$;
- 2) 利用 $P(v|h^{(t-1)})$ 采样出 $v^{(t)}$;
- 3) 利用采样后得到的近似估计神经网络中的各项参数^[14]。

通过自底向上组合多个 RBM 即可构建一个 DBN, 下层 RBM 的输出即为上层 RBM 的输入, 由于该网络神经元激活函数对 $[0, 1]$ 区间的数数据敏感度较高, 故在训练过程中, 要根据实际情况采用高斯-伯努利 RBM 或伯努利 RBM。逐层学习的高效性在文献[12]中已证明, 它指出逐层学习程序提高了训练数据基于混合模型的似然概率的变化下界。

3.2 基于 BP 算法的有监督训练过程

利用 DBN 深度学习结构完成对无标签数据的学习后, 将得到一个具有一定认知识别能力的神经网络, 随后通过加入带标签的训练样本, 利用 BP 算法继续对所得的 DBN 模型做进一步的调优训练, 从而提升该模型的精准度。与无监督学习部分相比, 有监督的学习部分最大区别在于 BP 算法的训练过程需要期望输出数据项的输入, 在本文中标签项预期负载即为 BP 算法的期望输出数据项^[17]。BP 算法由正向传播和误差反传两个部分组成。

正向传播: 输入样本→输入层→处理层→输出层。

若输出层的实际输出与期望的输出不符, 则开启误差反向传播。

误差反传: 误差→处理层(修正各处理层权值)→输入层。

其主要目的是通过将输出误差回传, 将误差分摊给各层所有的神经单元, 从而获得各层神经单元的误差信号, 进而修正各神经单元的权重。本阶段的 BP 算法主要用于对上一阶段的 DBN 神经网络模型的修正, 在训练结束后通过逻辑回归分类器输出结果。随后判定网络模型的误差是否满足要求, 若误差精度达到预设值或学习次数大于最大迭代次数, 则结束算法, 否则将选取下一个学习样本及对应的期望输出, 进入下一阶段的学习。

值得注意的是, DBN 中的层数 L 和节点数 N 通常是根据经验预选得来^[18], 目前尚无有效的分析方法可以直接获得最优解, 故此需要多次调整模型架构来找出最好的网络结构, BP 算法主要是用于对 DBN 网络的优化, 优化效果主要由训练样本标签化的质量决定。

4 仿真实验

本文用基于时间的随机数据生成算法, 硬件采用 HP Z820 服务器, 24 核, 2.1 GHz, 模拟生成了 10 000 条仿真数据, 其中训练数据 4000 条, 调优数

据 4000 条, 测试数据 2000 条, 并利用 Matlab 来完成对 DBN-RBM 神经网络架构的搭建, 主要进行了两组实验, 第一组用于探索 RBM 层数对 DBN 关于充电站容量规划预测的影响, 第二组用于比较 RBM 中神经元数对 DBN 关于充电站容量规划预测的影响。两组实验共同论证本文提出的新方法的可行性。

在第一组实验中, 本文比较了 1 层、2 层和 3 层 RBM 的效果, 层内节点分别为 200、100、50。实验结果如表 6 所示。

表 6 不同 DBN 网络结构的训练效果

Table 6 Training results of different DBNs

DBN 结构	准确度	耗时/ms
3 层 RBM	0.9333	29.848
2 层 RBM	0.9010	25.791
1 层 RBM	0.6667	7.897

在第二组实验中, 本文在两层 RBM 的 DBN 结构基础上, 测试 RBM 层内不同神经元数对 DBN 性能的影响, DBN 的两层 RBM 层内节点数相同, 实验数据如表 7 所示。

表 7 不同 RBM 网络的效果

Table 7 Training results of different RBMs

RBM 结构	准确度	耗时/ms
90	0.6000	23.518
100	0.6167	24.347
110	0.6333	23.551
120	0.9667	25.192
130	0.9333	28.149

实验结果证明在一定范围内增加 RBM 的层数或层内神经元数有利于提升 DBN 的性能, 当 RBM 层数过少或过多时, 则 DBN 会出现欠拟合或过拟合的现象, 从而降低 DBN 的性能。另一方面, 3 层 RBM 与 2 层 RBM 相比, DBN 的提升效果并不明显, 说明 2 层 RBM 已经足以处理该问题, Hinton 在其研究中也指出, 3 层结构已经足以提取足够的特征用于分类和预测。

上述两个实验包括了两个过程: 一是对神经网络预测模型的训练过程; 二是对该模型有效性的验证过程。训练过程中, 利用训练数据和调优数据, 通过调节神经网络的结构参数, 完成了神经网络内部映射关系的训练, 并确定了神经网络模型中的各项参数; 验证过程中, 通过向模型输入测试数据, 并比较预测模型的输出结果和测试数据预期结果的一致性, 即表 7 中的准确度, 从而证明该模型在输入环境变量参数后预测结果具有较高的可信度。在本文中, 输出结果被粗粒度地划分为高、中、低三挡, 实际生产中, 输出结果可以做更细粒度的划分,

并转换为对应的量化值,如充电站额定最大输出功率或额定最大充电并发数等。

本节实验论证了深度学习在有训练数据的基础上,可用于快速训练并搭建充电站服务环境与充电需求的神经网络映射模型,并证明了该模型可在输入待建充电站服务环境影响因子后,能以较高准确度输出待建充电站的理想负载等级,证明了本文方法的可行性。

5 结语

在未来,电动汽车必然成为人们生活中的主流交通工具之一,充电站建设中的定容问题也将成为一个更值得深入探讨的领域。针对原来单一选址定容的现状,采用深度学习算法对已有充电站的营销大数据进行分析和学习,从而建立具有增量学习和自我演进能力的充电站容量预测模型。该模型为传统的充电站的定容问题提出一个更为高效、准确的解决方案,且该模型具有自学习性,能够针对环境的变化进行自适应。本文成功将大数据应用到充电站定容问题上,借助机器学习对旧问题给出了新的解决思路。

参考文献

- [1] 唐葆君,刘江鹏.中国新能源汽车产业发展展望[J].北京理工大学学报(社会科学版),2015,17(2):1-6.
TANG Baojun, LIU Jiangpeng. Prospects of China's new energy vehicle industry[J]. Journal of Beijing Institute of Technology (Social Sciences Edition), 2015, 17(2): 1-6.
- [2] 刘柏良,黄学良,李军,等.含分布式电源及电动汽车充电站的配电网多目标规划研究[J].电网技术,2015,39(2):450-456.
LIU Bailiang, HUANG Xueliang, LI Jun, et al. Multi-objective planning of distribution network containing distributed generation and electric vehicle charging stations[J]. Power System Technology, 2015, 39(2): 450-456.
- [3] 唐现刚,刘俊勇,刘友波,等.基于计算几何方法的电动汽车充电站规划[J].电力系统自动化,2012,36(8):24-30.
TANG Xiangang, LIU Junyong, LIU Youbo, et al. Electric vehicle charging station planning based on computational geometry method[J]. Automation of Electric Power Systems, 2012, 36(8): 24-30.
- [4] 周培德.计算几何:算法分析与设计[M].北京:清华大学出版社,2000:88-100.
- [5] 张有会.加权 Voronoi 图画法的研究[J].计算机科学,2001,28(6):126-128.
ZHANG Youhui. A method to draw weighted Voronoi diagram[J]. Computer Science, 2001, 28(6): 126-128.
- [6] 葛少云,李慧,刘洪.基于加权 Voronoi 图的变电站优化规划[J].电力系统自动化,2007,31(3):29-34.
GE Shaoyun, LI Hui, LIU Hong. Substation optimization planning based on the weighted Voronoi diagram[J]. Automation of Electric Power Systems, 2007, 31(3): 29-34.
- [7] 郭春林,肖湘宁.电动汽车充电基础设施规划方法与模型[J].电力系统自动化,2013,37(13):70-75.
GUO Chunlin, XIAO Xiangning. Planning method and model of electric vehicle charging infrastructure[J]. Automation of Electric Power Systems, 2013, 37(13): 70-75.
- [8] 赵伟,姜飞,涂春鸣,等.电动汽车充电站并网谐波分析[J].电力自动化设备,2014,34(11):61-66.
ZHAO Wei, JIANG Fei, TU Chunming, et al. Harmonic currents of grid-connected EV charging station[J]. Electric Power Automation Equipment, 2014, 34(11): 61-66.
- [9] 周娟,任国影,魏琛,等.电动汽车交流充电桩谐波分析及谐波抑制研究[J].电力系统保护与控制,2017,45(5):18-25.
ZHOU Juan, REN Guoying, WEI Chen, et al. Harmonic analysis of electric vehicle AC charging spot and research on harmonic restriction[J]. Power System Protection and Control, 2017, 45(5): 18-25.
- [10] 刘敏,周晓霞,陈慧春,等.采用三相不可控整流充电机的电动汽车充电站谐波放大效应分析与计算[J].电力系统保护与控制,2016,44(4):36-43.
LIU Min, ZHOU Xiaoxia, CHEN Huichun, et al. Analysis and calculation on harmonic amplification effect of electric vehicle charging station using three-phase uncontrolled rectification charger[J]. Power System Protection and Control, 2016, 44(4): 36-43.
- [11] 郭煜华,范春菊.含大规模电动汽车的配电网保护技术研究[J].电力系统保护与控制,2015,43(8):14-20.
GUO Yuhua, FAN Chunju. Research on relaying technologies of distribution network including mass electric vehicles[J]. Power System Protection and Control, 2015, 43(8): 14-20.
- [12] 张春霞,姬楠楠,王冠伟.受限波尔兹曼机[J].工程数

- 学学报, 2015, 32(2): 159-173.
ZHANG Chunxia, JI Nannan, WANG Guanwei. Restricted Boltzmann machines[J]. Chinese Journal of Engineering Mathematics, 2015, 32(2): 159-173.
- [13] 苏睿, 张晓杰. 基于BP神经网络的数字识别研究[J]. 电脑知识与技术, 2013, 9(14): 3362-3365.
SU Rui, ZHANG Xiaojie. Study of digit recognition based on BP neural network[J]. Computer Knowledge and Technology, 2013, 9(14): 3362-3365.
- [14] 胡洋. 基于马尔可夫链蒙特卡罗方法的RBM学习算法改进[D]. 上海: 上海交通大学, 2012.
HU Yang. Markov chain Monte Carlo based improvements the learning algorithm of restricted Boltzmann machines[D]. Shanghai: Shanghai Jiao Tong University, 2012.
- [15] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.
- [16] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [17] 丁硕, 巫庆辉. 基于改进BP神经网络的函数逼近性能对比研究[J]. 计算机与现代化, 2012(11): 10-13, 17.
- DING Shuo, WU Qinghui. Performance comparison of function approximation based on improved BP neural network[J]. Computer and Modernization, 2012(11): 10-13, 17.
- [18] 高强, 阳武, 李倩. 基于空间信息的DBN图像分类快速训练模型[J]. 系统仿真学报, 2015, 27(3): 549-558.
GAO Qiang, YANG Wu, LI Qian. Fast training model for image classification based on spatial information of deep belief network[J]. Journal of System Simulation, 2015, 27(3): 549-558.

收稿日期: 2017-05-16; 修回日期: 2017-08-17

作者简介:

李 智(1990—), 男, 硕士, 助理工程师, 研究方向为人工智能与数据挖掘技术; E-mail: nanhuananmu@163.com

侯兴哲(1965—), 男, 硕士, 高级工程师, 研究方向为电测与计量相关政策规划和科技管理; E-mail: 1990041802@qq.com

刘永相(1978—), 男, 博士, 高级工程师, 研究方向为电动汽车充电设施技术。E-mail: 1005750@qq.com

(编辑 魏小丽)