

DOI:10.12158/j.2096-3203.2021.01.024

基于 WNN 与 FCM 的电动汽车动态充电负荷预测方法

张天培¹, 王成亮¹, 崔恒志², 郑海雁¹, 杨庆胜¹, 卞正达³

(1. 江苏方天电力技术有限公司, 江苏 南京 211100; 2. 国网江苏省电力有限公司, 江苏 南京 210024; 3. 东南大学电气工程学院, 江苏 南京 210096)

摘要:随着电动汽车动态无线充电(EV-DWC)技术的发展,针对目前EV-DWC负荷建模理论工作不全面的现状,以交通流量作为影响充电负荷的主要因素,以天气、典型日期、季节等因素为次要影响因素,根据路况建立负荷模型,通过电动汽车型号和状态的聚类不同对汽车分配不同的功率,完成动态充电负荷的建立。采用小波神经网络(WNN)对时序信息进行处理预测,再同误差反向传播神经网络(BPNN)相结合预测充电道路上的车流,短期车流预测精度为85%,用模糊C聚类(FCM)算法对电动汽车的充电类型以及该类型所对应的充电功率进行划分,将进入充电道路的电动汽车分为7种类型。根据各种充电类型分配相应的充电功率,完成日负荷建模。

关键词:电动汽车动态充电(EV-DWC);小波-反向传播混合神经网络(W-BPNN);模糊C聚类(FCM);电动汽车充电方式;负荷模型

中图分类号:TM714

文献标志码:A

文章编号:2096-3203(2021)01-0167-08

0 引言

电动汽车由于其高能效和低污染正受到越来越多的关注^[1-2],但充电设施仍是制约电动汽车发展的瓶颈^[3]。无线充电作为新兴的充电技术,无需在车与桩之间建立电气连接,提高了电动汽车充电过程的安全性和充电设备的耐久性^[4]。电动汽车动态无线充电(electric vehicle dynamic wireless charging, EV-DWC)技术则可以在电动汽车行驶时完成充电,成为电动汽车新型充电方式的代表。而目前尚未有成熟的EV-DWC负荷模型,对EV-DWC行为的研究还处在探索阶段。

文献[5]建立了“车-路-网”模式,分析了交通网络的复杂程度和车型流量等因素对充电方式的影响;文献[6]对不同充电模式进行了建模,包括快充、慢充及换电模式;文献[7]通过大数据处理对电动汽车充电行为进行分类,为负荷建模提供了负荷功率分类依据;文献[8]运用聚类的方法推导得到了充电需求;文献[9]通过整理历史数据和统计值得出每个月的日负荷曲线,但由于其对电动汽车各类型的参数分布模型采用的概率函数较为简单,具有一定局限性。

对于EV-DWC负荷模型,不仅需要考虑电动汽车的自身因素,还要随时关注路况,车流量是影响道路上EV-DWC负荷最重要的因素,车流量越大,负荷需求也越大。目前文献关于短期车流量预测

的方法有神经网络、时间序列模型(autoregressive integrated moving average model, ARIMA)和支持向量回归(support vector regression, SVR)等。文献[10]采用径向基神经网络,通过模糊C聚类(fuzzy C-means, FCM)优化预测高速公路的车流量,提升了网络泛化的能力;文献[11-12]利用收集路段路况信息数据,采用ARIMA算法对城市道路的车流量做出实时预测;文献[13]采用改进后的卷积神经网络通过车流量预测,并与其他常用车流预测算法进行对比。

文中以交通流量作为影响充电负荷的主要因素,将天气、典型日期、季节等因素作为次要影响因素,采用小波-反向传播混合神经网络(wavelet-back propagation neural network, W-BPNN)方法进行1 d内的短期车流量预测。分析电动汽车各参数特性,进行蒙特卡洛(Monte Carlo)随机模拟进入充电路段的EV-DWC的参数并用FCM进行电动汽车充电类型聚类,最终完成对EV-DWC道路的建模。

1 W-BPNN 和 FCM 算法框架搭建

1.1 基于 W-BPNN 的充电行为预测模型

小波神经网络(wavelet neural network, WNN)结构与反向传播神经网络(back propagation neural network, BPNN)相似,但小波变换具有变焦特性、时频局部分析特性和多尺度分解特性等优势^[14-19],对于电动汽车复杂的交通路况来说,前一时间点的车流量对后续车流量有着很大的影响,因此采用WNN预测前端交通流量。将一般BPNN的隐含层传递函

收稿日期:2020-11-28;修回日期:2020-12-15

基金项目:国家自然科学基金资助项目(51877036)

数变换为小波基函数,从而使输出结果在不抛弃时间信息的情况下完成对车流量信息的预测。文中重点研究该算法在 EV-DWC 负荷模型中的应用。

文中提出了一种结合 WNN 与 BPNN 的混合神经网络,即 W-BPNN,前端采用 WNN 处理与时序相关的数据,将前端预测的数据作为后端 BPNN 的输入之一,结合其他非时序因素预测下一时间段的车流。

W-BPNN 混合神经网络算法流程如图 1 所示。其中,初始化过程指:确定输入层的输入节点数 n 、隐含层的隐含节点数 l 以及输出层的神经元个数 m ,并确定输入层各输入变量。对第一部分小波基函数的伸缩因子矩阵 A 、平移因子矩阵 B 和权重矩阵 H 或 W 进行随机初始化,设置学习率 η 、最大迭代次数等必要参数。

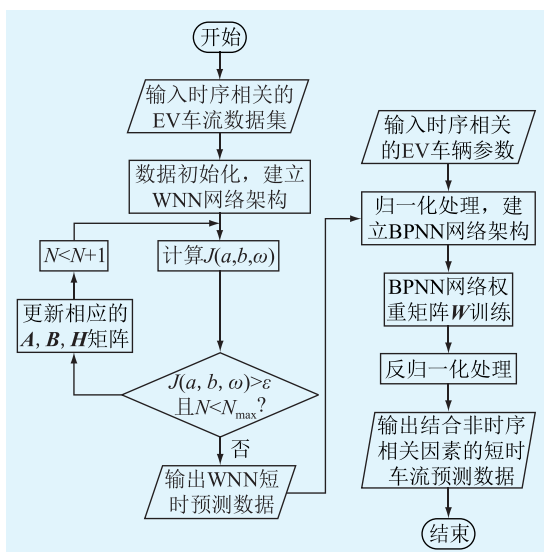


图 1 W-BPNN 混合神经网络算法流程

Fig.1 Flow chart of W-BPNN hybrid neural network algorithm

1.2 层次凝聚聚类和 FCM 算法流程

电动汽车的种类繁多,对每辆进入充电路段的电动汽车都制定相应的充电策略是一项非常复杂的工程。想要尽量满足大部分车辆的充电需求且不给电网施加不必要的负担,电动汽车的分类显得尤为重要。

文中提出了改进的 FCM 方法对进行 DWC 的电动汽车进行聚类分析。由层次凝聚聚类算法(hierarchical agglomerative clustering, HAC)进行初始分类,采用 FCM 对其进行优化。

FCM 的算法以目标函数 $J(u,c)$ 为优化对象,文中 $J(u,c)$ 反映了每辆进入充电路段的电动汽车与每种充电类型的隶属关系,如式(1)所示,其约束条件如式(2)所示。

$$J(u,c) = \sum_{i=1}^k \sum_{j=1}^n u_{ij}^m \|x_j - c_i\|^2 \quad (1)$$

$$\sum_{i=1}^k u_{ij} = 1 \quad (2)$$

采用拉格朗日乘子法求 $J(u,c)$ 在达到极值时的 u_{ij} 和 c_j ,使目标函数达到极小值,计算公式如式(3)、式(4)所示。

$$u_{ij} = \left[\sum_{i=1}^k \left(\frac{\|x_j - c_i\|}{\|x_j - c_i\|} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (3)$$

$$c_i = \frac{\sum_{j=1}^n (x_j u_{ij}^m)}{\sum_{j=1}^n u_{ij}^m} \quad (4)$$

式中: u_{ij} 为每个样本属于某一类电动汽车充电类型 P_i 的隶属度; n 为样本总个数; k 为分类数; m 为隶属度因子,通常用来表示单个数据的重要程度; c_i 为某一充电类型 i 的聚类中心; x_j 为第 j 组样本值。当完成迭代时,根据 u_{ij} 对每组样本进行分类。

1.3 充电行为预测模型

(1) 输入、输出变量选择。文中所提神经网络架构由两部分组成,第一输入层的参数 $V_{x-3}, V_{x-2}, V_{x-1}$ 为被预测时间节点前 3 个时间点的交通流量;第二输入层参数 X_1, X_2, X_3, X_4 分别为天气代号、当天最高气温、当天最低气温和典型日期的数据,其中天气分为晴天、阴天、多云和雨天 4 种情况;典型日期分工作日、休息日 2 种情况。输出变量为下一时刻的车流量数值。

(2) 数据预处理。为取消各个维度数据间数量级差别,减少数据数量级造成的预测误差,将数据进行归一化处理,将数据控制在 $[0, 1]$ 之间。文中采用最大最小法,数据集中第 k 个数据的归一化如式(5)所示。

$$x'_k = \frac{x_k - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中: x_{\min}, x_{\max} 分别为数据集中的最小值和最大值。

(3) 隐含层神经元个数范围。神经网络的隐含层节点数对网络预测的精度有较大影响,节点数太多或太少都会导致网络预测不精准。目前隐含层节点选择采用经验选择的方法,节点个数范围为:

$$l < \sqrt{(m+n)} + a \quad (6)$$

式中: n 为输入层节点数; l 为隐含层节点数; m 为输出层节点数; a 为 $0 \sim 10$ 之间的常数。代入 $n=4, m=1$, 得 $l \in (2, 13)$ 。

(4) 用户充电行为预测模型的网络架构。如图 2 所示, Part I 中的隐含层采用 Morlet 小波基函数

作为激励函数,将当前时间预测点前的车流作输入数据,经过迭代后,将预测点输出车流量作第二层BPNN的输入数据,与其他车流量影响因素的数据一同作为Part II的输入层。文中将采用Sigmoid函数, $S(x) = 1/(1+e^{-x})$, 作为第二隐含层的激励函数进行权重矩阵 W 的计算和迭代。

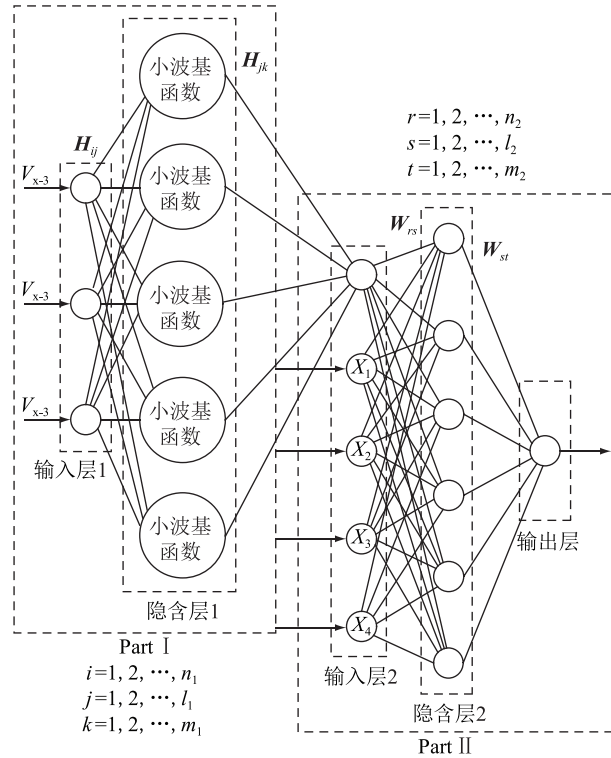


图2 W-BPNN 混合神经网络架构

Fig.2 W-BPNN hybrid Neural network structure

2 充电方式影响因素分析

根据美国汽车工程师协会(SAE)于2019年4月发布的无线充电指南^[20],将无线充电标准的充电输出功率分为四级:普通充电 3.7 kW, 7.7 kW 和快速充电 11 kW, 22 kW。充电类别根据充电功率分为慢充1类(3.7 kW)、慢充2类(7.7 kW)、快充1类(11 kW)及快充2类(22 kW)。影响充电方式的因素如下。

(1) 荷电状态(state of charge, SOC)。SOC 是用户产生充电欲望的一大因素, SOC 越低, 用户产生的充电欲望就越强烈, 文中以调查问卷形式调研显示, 新能源汽车用户充电欲望如图3所示。

充电概率表达式为:

$$f_{\text{Char}}(S_{\text{SOC}}) = a_1 e^{-[(S_{\text{SOC}}-b_1)/c_1]^2} + a_2 e^{-[(S_{\text{SOC}}-b_2)/c_2]^2} \quad (7)$$

式中: $a_1 = 1.002$, $b_1 = 0.0325$, $c_1 = 0.617$, $a_2 = 0.200$, $b_2 = 0.494$, $c_2 = 0.226$ 。考虑到电池本身




图3 车主充电概率与SOC的函数关系

Fig.3 Relation between the charging probability and SOC

的生命周期和用户对电池的维护和保养, 文中假设初始 S_{SOC} 的取值范围为 30% ~ 100%。

(2) 电池容量和续航里程。通过电池容量与续航里程可以大概估算出电动车车主在各个 S_{SOC} 阶段的充电欲望^[21-22], 电池容量 f_{Anxiety} 和里程焦虑 x_{BS} 的函数关系如式(8)所示, 其中, $a_3 = 4.245$, $b_3 = -270.6$, $c_3 = 173.8$ 。

$$f_{\text{Anxiety}}(x_{\text{BS}}) = a_3 e^{-[(x_{\text{BS}}-b_3)/c_3]^2} \quad (8)$$

(3) 各类型汽车占比。车辆类型不同, 则电池容量也不同, 从而影响 Monte Carlo 道路负荷建模精度。文中调研了市场上热门的电动汽车品牌的各类车型, 如表1所示。

表1 各类型热门车辆参数

Table 1 Parameters of various popular electric vehicles

品牌序号	电池容量/ (kW·h)	续航里程/ km	单位电耗/ [km·(kW·h) ⁻¹]
1	26.57	200	7.5
2	31.9	301	9.4
3	43	305	7.1
4	48	318	6.6
5	49	351	7.2
6	52	400	7.7
7	82	400	4.9
8	90	557	6.2
9	35	301	7.52
10	52.5	410	7.63
11	440~660	563	0.85~1.28
11	324	250	0.772

根据《2019年北京市交通发展年度报告》统计, 机动车登记中大部分是小型车。全市小型车辆占比为 85.8%, 大型车辆如大型客车或货车的占比为 3.9%, 小货车及其他中型车辆占比为 10.3%。

3 W-BPNN 及 FCM 算例分析

3.1 数据来源

文中所得的车流量数据取自于中国江苏省扬

州市交通管理局,数据记录了扬州市文昌路市府岗—京华岗路段 2019-09-13—2019-12-16 东西方向的车流量,其中对车流量的检测频率为每 15 min 一次,除去检测装置维修和损坏的情况,共有有效记录数据 3 696 组,其中双休日数据 1 056 组,工作日数据 2 640 组。同时记录了 2019-09-13—2019-12-16 的天气、最高气温和最低气温的数据,数据来源于中国气象网。

3.2 W-BPNN 预测车流结果

图 4 为不同隐含层节点数的预测误差,根据图 4 各节点数平均绝对百分比 e_{MAPE} 可以确定最佳隐含层节点数为 8。




图 4 不同隐含层数的 BPNN 验证测试

Fig.4 Validation test for BPNN with different number of hidden layers

开始算法流程前,将数据的前 91.46% (即前 75 d 的数据)作为训练数据,剩下的数据作为检测数据。随机初始化网络权值矩阵 H_1, H_2 , 偏置矩阵 B 及伸缩因子矩阵 A ,进行 200 次训练,为避免出现局部收敛的情况,以不同的参数值初始化多个神经网络权值矩阵。图 5 为 2019-09-13—2019-12-16 中某一天的车流量预测,为第一部分的输出预测,最大预测误差为 67 辆, e_{MAPE} 为 6.374%。




图 5 WNN 车流量预测

Fig.5 The traffic flow prediction value of WNN

将第一部分的预测输出值同第二部分的输入值一起作为 BP 神经网络的输入,预测车流量,训练结果如图 6 所示。

可以看出,实际数据呈现出很大幅度的波动,且有着非线性和不稳定的特点,无论是实际车流量还是车流量的预测值,其形状大致相同,会有个别




图 6 车流预测结果

Fig.6 Traffic flow forecast training results

数值超过阈值但整体的预测精准误差小于 15%。根据所训练出的参数矩阵预测夏季和冬季各天气和典型日期下的车流量,夏季气温取中国 7 月平均最高气温 30 °C,最低气温 21 °C;冬季取中国 1 月平均最高气温 5 °C,最低气温 -5 °C,预测数据见图 7。

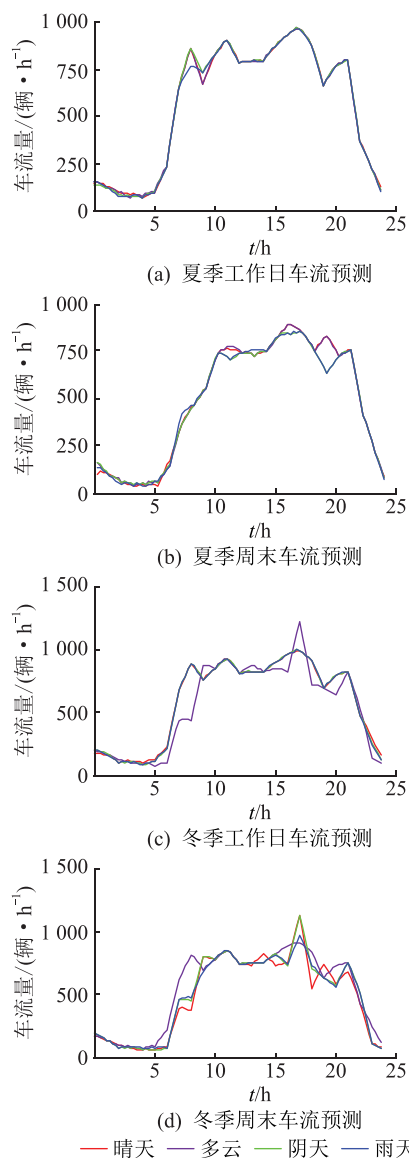


图 7 夏季和冬季不同情况下的日交通流预测

Fig.7 Daily traffic flow prediction under various situations in summer and winter

由图 7 可以看出,预测的车流量曲线有以下特

征:从典型日的角度来看,工作日中,以夏季工作日为例,00:00—06:00 点车流稀少,平均车流量在 80 辆/h 左右;07:00—09:00 为上班高峰期,此期间车流量呈现大幅飙升的趋势,平均车流量在 800 辆/h 左右;10:00—15:00 车流量变化趋势趋于平缓,此区间的车流量平均值为 700 辆/h;16:00—20:00,此期间为下班高峰期,车流量呈现出一个比较明显的尖峰,冬季工作日尤为明显,此时的平均车流量达到 1 000 辆/h;21:00—23:00,此时路上行车量急剧减少,平均车辆流量减至 425 辆/h。与工作日相比,休息日车流的总体曲线没有较为明显的“双峰”形状,车流在早高峰有一个明显的上升后会维持这个高峰,直到下班高峰期到来,才会有一个小幅攀升,总体呈现“单峰”形状。

3.3 充电行为聚类

通过以上分析,结合第 2 章中充电方式影响因素分析和 3.2 节各个时间段的预测数据,以冬季晴天工作日为例,采用 Monte Carlo 方法随机生成电动汽车数据集合 X_{sample} 。共生成数据 13 106 组,包含电池容量、续航里程、SOC 状况以及是否充电的情况,电动汽车是否充电的状况有充电、不充电和放电 3 种。生成的数据中有 386 例对电网充电,12 511 例需充电,209 例无需进行充放电。

将 12 511 例需充电的样本进行层次凝聚聚类,得出适合的分类型,如图 8 所示,共分为 8 种类型。将这 8 类充电类型的聚类中心 $C_i(i=1,2,\dots,8)$ 作为 FCM 的初始聚类中心,再进行 FCM 聚类,聚类结果样本散点分类如图 9 所示。




图 8 电动汽车聚类

Fig.8 Electric vehicle type clustering dendrogram

经过迭代优化,12 511 样本中每个数据在每个分类集合 S_i 的隶属度如图 10 所示,从 8 个分类的隶属度图中可以看出,几乎每个分类集合都有隶属度较高的样本,但所有样本对于第 6 类的隶属度都在 0.4 以下,说明所有样本都与第 6 类的相似度不高,去除聚类中心 C_6 ,剩余 7 种分类的结果与特征见表


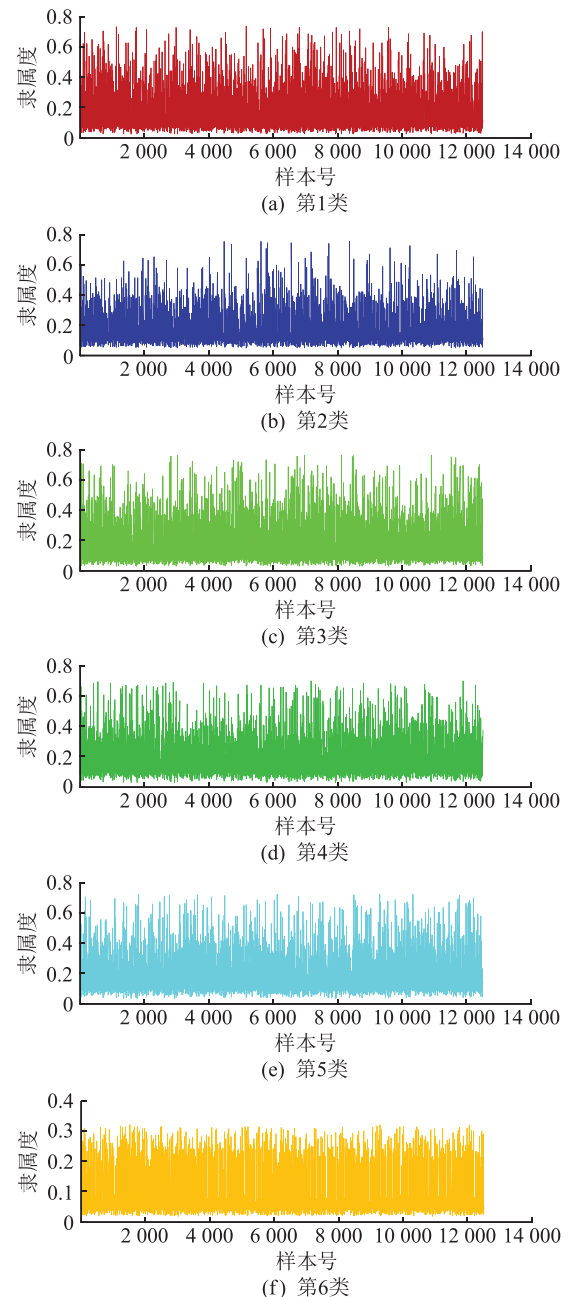


图 9 样本散点聚类图

Fig.9 Sample scatter classification chart

2,并根据这些特征采用不同的充电功率。






图 10 样本中数据在各类别中的隶属度
Fig.10 The degree of membership of the data in the sample in each category

表 2 FCM 聚类结果

Table 2 FCM clustering results

充电类型	S_{soc} /%	电池容量 / (kW·h)	汽车类型	充电方式	充电功率/kW
1	30~50	0~100	私家车、出租车	快充	11
2	30~50	>100	大型车	快充	22
3	50~80	0~100	私家车、出租车	快充	11
4	50~80	>100	大型车	快/慢充	22
5	80~100	0~100	出租车	慢充	3.7
6	80~100	0~100	私家车	有序	0
7	80~100	>100	大型车	慢充	7.7

4 道路负荷曲线建立

根据以上充电车辆状态的分类以及各个分类所分配的充电功率,以冬季晴天工作日天的数据为例, EV-DWC 道路负荷模型的建立过程如下。

1 d 中某时刻 EV-DWC 总负荷为这一时刻各类单车电动汽车充电功率之和。将 1 d 分成 1 440 min,每 15 min 预测 1 次充电负荷,共 96 个负荷点,则每个时间断面的负荷可表示为:

$$P_k = \sum_{n_s=1}^{N_s} P_{n_s,k} + \sum_{n_g=1}^{N_g} P_{n_g,k} + \sum_{n_c=1}^{N_c} P_{n_c,k} \quad (9)$$

式中: P_k 为某个区域电动汽车在第 k 个时间断面上的无线充电总负荷, $k = 1, 2, \dots, 96$; $P_{n_s,k}$, $P_{n_g,k}$, $P_{n_c,k}$ 分别为道路上电动私家车、电动公交车、电动出租车的充电负荷; N_s , N_g , N_c 为道路上电动私家车、电动、电动出租车的保有量。最终道路日负荷曲线如图 11 所示。

由图 11 可见, EV-DWC 道路负荷曲线在道路车流高峰时呈增高趋势, EV-DWC 负荷预测曲线在 18:00 左右达到峰值,为 5 698 kW, 峰谷差为 5 698 kW。05:00—09:00, 负荷处在激增的状态, 这是由




图 11 EV-DWC 日负荷曲线

Fig.11 EV-DWC daily load power curve

于早上大部分电动车开始出行, 充电负荷产生一个小峰值, 中午车流量趋于平缓, 到下班时出租车司机交班加上私家车用户下班, 出现第二个高峰, 从 19:00 至次日 04:00, 大部分用户在休息, 道路上几乎没有负荷。

5 结语

文中通过神经网络算法和 FCM 聚类算法建立了具有较高准确性和可靠性的 EV-DWC 需求预测方法, 对 EV-DWC、电力系统和交通系统的运行和控制至关重要。首先采用 W-BPNN 进行时序和非时序信息的处理, 对充电道路上的车流量进行短期负荷预测, 使负荷建模更贴近实际; 然后通过 FCM 聚类将需充电的电动汽车按充电功率分类, 建立负荷曲线。所提方法可帮助调度中心提前预测需要充电的电动汽车的数量, 避免更高的成本或过高的风险, 有助于 EV-DWC 的发展和规划。

参考文献:

[1] VEGNI A M, BIAGI M, CUSANI R. Smart vehicles, technologies and main applications in vehicular ad hoc networks, in vehicular technologies—deployment and applications. Rijeka, Croatia: InTech, 2013.

[2] GUARNIERI M. Looking back to electric cars[C]//2012 Third IEEE History of Electro-technology Conference (HISTELCON). Pavia, 2012: 1-6.

[3] 杜莎. 逆势增长的中国新能源汽车未来将何去何从聚焦 2019 年中国电动汽车百人会论坛[J]. 汽车与配件, 2019(3): 20-23.

DU Sha. What will be the future of China's new energy vehicles growing against the trend focus on the speech at the High-level Forum of China Electric Vehicle 100 People's Congress[J]. Automobile & Parts, 2019(3): 20-23.

[4] 吴争, 李瑶虹, 杨晓梅, 等. 基于 HMM 的无线充电系统 PFC 装置故障检测[J]. 电力工程技术, 2020, 39(6): 166-171.

WU Zheng, LI Yaohong, YANG Xiaomei, et al. Fault detection of PFC device in wireless charging system based on HMM[J]. Electric Power Engineering Technology, 2020, 39(6): 166-171.

- [5] 邵尹池,穆云飞,徐晓丹,等. “车-路-网”模式下电动汽车充电负荷时空预测及其对配电网潮流的影响[J]. 中国电机工程学报,2017,37(18):5207-5219,5519.
SHAO Yinchi, MU Yunfei, XU Xiaodan, et al. A spatial-temporal charging load forecast and impact analysis method for distribution network using EVs-traffic-distribution model [J]. Proceedings of the CSEE, 2017, 37(18): 5207-5219, 5519.
- [6] WANG Shu, DONG Zhaoyang, LUO Fengji, et al. Stochastic collaborative planning of electric vehicle charging stations and power distribution system[J]. IEEE Transactions on Industrial Informatics, 2018, 14(99): 321-331.
- [7] LIU Yujun, HONG Yi, HU Cheng. Research on big data mining technology of electric vehicle charging behaviour[J]. Elektronika Ir Elektrotehnika, 2019, 25(6): 55-61.
- [8] KRISTOFFERSON T K, CATION K, MEIBOM P. Optimal charging of electric drive vehicles in a market environment[J]. Applied Energy, 2011, 88: 1940-1948.
- [9] DEFLORIO F, PINNA I, CASTELLO L, et al. Dynamic charging systems for electric vehicles; simulation for the daily energy estimation on motorways [J]. IET Intelligent Transport Systems, 2016, 10(4): 258-269.
- [10] 张健. 基于自适应K-means与DNN的短期负荷预测研究分析[J]. 电子测量技术, 2020, 43(17): 58-61.
ZHANG Jian. Research and analysis of short-term load forecasting based on adaptive K-means and DNN[J]. Electronic Measurement Technology, 2020, 43(17): 58-61.
- [11] HUANG Wei, JIA Wenwen, GUO Jianhua, et al. Real-time prediction of seasonal heteroscedasticity in vehicular traffic flow series[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(10): 3170-3180.
- [12] STATHOPOULOS A, KARLAFTIS M G. A multivariate state space approach for urban traffic flow modeling and prediction [J]. Transportation Research Part C Emerging Technologies, 2003, 11(2): 121-135.
- [13] ZHANG Xian, CHAN K W, LI Hairong, et al. Deep-learning-based probabilistic forecasting of electric vehicle charging load with a novel queuing model[J]. IEEE Transactions on Cybernetics, 2020(99): 1-14.
- [14] 吴琛,苏明昕,谢云云,等. 基于BP神经网络的输电线路雷击故障预测[J]. 电力工程技术, 2020, 39(5): 133-139.
WU Chen, SU Mingxin, XIE Yunyun, et al. BP neural network based lightning fault prediction of transmission lines[J]. Electric Power Engineering Technology, 2020, 39(5): 133-139.
- [15] 赵耀洪,杨壮,钱艺华,等. 基于GA-BPNN的多频超声波变压器油密度检测研究[J]. 电力工程技术, 2019, 38(5): 37-41.
ZHAO Yaohong, YANG Zhuang, QIAN Yihua, et al. Transformer oil density based on GA-BPNN method and multi-frequency ultrasound [J]. Electric Power Engineering Technology, 2019, 38(5): 37-41.
- [16] 宋人杰,刘福盛,马冬梅,等. 基于相似日和WNN的光伏发电功率超短期预测模型[J]. 电测与仪表, 2017, 54(7): 75-80.
SONG Renjie, LIU Fusheng, MA Dongmei, et al. A very short-term prediction model for photovoltaic power based on similar days and wavelet neural network [J]. Electrical Measurement & Instrumentation, 2017, 54(7): 75-80.
- [17] 付华,刘公权,邢亮. 基于同步挤压小波变换的故障行波测距方法[J]. 电力系统保护与控制, 2020, 48(2): 18-24.
FU Hua, LIU Gongquan, XING Liang. Fault traveling wave ranging method based on synchrosqueezing wavelet transform [J]. Power System Protection and Control, 2020, 48(2): 18-24.
- [18] 甄永赞,杨荆宜,张冰. 基于小波变换的直流线路行波保护采样数值稳定性研究[J]. 电力系统保护与控制, 2019, 47(9): 42-48.
ZHEN Yongzan, YANG Jingyi, ZHANG Bing. Study on numerical sampling stability of traveling wave protection based on wavelet transform [J]. Power System Protection and Control, 2019, 47(9): 42-48.
- [19] 孙新程,万玥,丁宏,等. 基于小波去噪-KPCA神经网络的光伏功率预测方法[J]. 电力工程技术, 2020, 39(2): 110-116.
SUN Xincheng, WAN Yue, DING Hong, et al. Forecasting method of photovoltaic output power based on wavelet denoising/KPCA/PSOBP [J]. Electric Power Engineering Technology, 2020, 39(2): 110-116.
- [20] Wireless power transfer for light-duty plug-in/electric vehicles and alignment methodology; SAE J2954_201904[S].
- [21] KNUTSEN D WILLEN O. A study of electric vehicle charging patterns and range anxiety [D]. Uppsala: Uppsala University, 2017.
- [22] GARCIA-VILLALOBOS J, ZAMORA I, EGUIA P, et al. Modelling social patterns of plug-in electric vehicles drivers for dynamic simulations [C]//2014 IEEE International Electric Vehicle Conference (IEVC 2014). IEEE, 2015.

作者简介:



张天培

张天培(1969),男,硕士,高级工程师,从事电力物联网、电力营销等领域研究工作(E-mail: ztp@js.sgcc.com.cn);

王成亮(1981),男,硕士,高级工程师,从事高电压技术、无线充电技术、电力物联网等领域研究工作;

崔恒志(1971),男,硕士,研究员级高级工程师,从事电力信息、大数据分析等相关研究工作。

Dynamic charging load prediction method of electric vehicle based on wavelet neural network and FCM

ZHANG Tianpei¹, WANG Chengliang¹, CUI Hengzhi², ZHENG Haiyan¹, YANG Qingsheng¹, BIAN Zhengda³

(1. Jiangsu Fangtian Electric Power Technology Co., Ltd., Nanjing 211100, China;

2. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210024, China;

3. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: With the development of the electric vehicle dynamic wireless charging technology, aiming at the current incomplete theoretical work of dynamic wireless charging modeling, dynamic charging load model is established according to road conditions, and different power is assigned to different vehicles through clustering of EV models and states, so as to complete the establishment of dynamic charging load. Wavelet neural network is used to process and predict the timing sequence information, and then combined with back propagation neural network to predict the traffic flow on the charging road, and the short-term traffic flow forecasting accuracy is 85%. Fuzzy C-means algorithm is used to divide the charging type of EV and the charging power corresponding to the type, and the EV entering the charging road is divided into 7 types. The corresponding charging power is allocated according to various charging types to complete the daily load modeling.

Keywords: electrical vehicle dynamic wireless charging (EV-DWC); wavelet-back propagation neural network (W-BPNN); fuzzy C-means (FCM); EV charging pattern; load model

(编辑 钱悦)

(上接第 166 页)

Lightning grounding dispersion of transmission lines and overvoltage protection of nearby pipelines

GAO Xiaodong¹, AN Yunzhu², BI Bin¹, NIU Jingguang³, XIAN Richang², HAN Zhengxin¹

(1. State Grid Shandong Electric Power Company Maintenance Company, Jinan 250118, China;

2. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China;

3. State Grid Zibo Power Supply Company of Shandong Electric Power Company, Zibo 255030, China)

Abstract: Due to the shortage of transmission corridors, the construction of overhead transmission lines in China is often parallel or cross-erected with oil and gas pipelines. Electromagnetic interference and the pipeline's safety and protection of "two lines and one place" have become research hotspot. However, few studies are on the induced overvoltage of neighboring pipelines when lightning strikes transmission lines. The electromagnetic analysis software CDEGS is used to simulate the influence factors and protective effect of overvoltage induced by lightning of the pipeline anticorrosive coating when the transmission line tower is close to the oil and gas pipeline. A simplified model of the tower and pipeline is established. The distance between the line and pipeline, geological conditions and the structure of the grounding grid of the tower are simulated and analyzed. Corresponding construction suggestions for pipeline overvoltage protection are given. The research results provide reference for the construction and reconstruction of "two lines and one place".

Keywords: lightning current divergence; pipeline overvoltage; spacing; geological conditions; tower grounding grid

(编辑 吴楠)