

Research on the Prediction of Electric Vehicle Range Based on an Improved Neural Network Algorithm

Guoliang Zhang, Yanliang Zhang, Lei Xue, Shengjian Li, Yang Zhang

Weichai Power Co., Ltd., Electronic Control and Software Research Institute, Weifang, Shandong, 261001

Abstract

The driving range of electric vehicles is influenced by various factors such as battery temperature, current, cell voltage, load, driving behavior, remaining battery level, and vehicle speed, and there is a nonlinear relationship between these factors. Traditional Backpropagation (BP) neural network algorithms can be used to train the collected data to obtain a driving range training model. However, the BP algorithm has the drawbacks of being prone to local optima, slow convergence, and difficulty in determining initial weight values. Therefore, it is possible to combine genetic algorithms to optimize the parameters of the BP neural network to compensate for these shortcomings, while also using the collected data to repeatedly train the network to achieve a more accurate driving range training model.

Keywords: Backpropagation Algorithm; Genetic Algorithm; Driving Range; Artificial Neural Network

基于改进的神经网络算法对电动车续航里程的预测研究

张国良, 张廷良, 薛雷, 李升建, 张杨

潍柴动力股份有限公司电控与软件研究院, 山东省 潍坊市 261001

摘要: 电动车的续航里程受电池温度、电流、单体电压、载重、驾驶行为、剩余电量、车速等多个因素的影响, 各个因素之间是一种非线性关系。可以利用传统 BP 神经网络算法对采集数据进行训练得到续航里程训练模型, 但 BP 算法存在局部最优差、收敛速度慢和初始权阈值不易确定的缺点, 因此, 可以结合遗传算法对 BP 神经网络的参数进行优化弥补其缺点, 同时利用采集的数据对网络进行重复学习, 得到更高精度的续航里程训练模型。

关键词: BP 算法; 遗传算法; 续航里程; 人工神经网络

1 引言

续航里程是电动车性能的重要指标, 除受车辆自身的电池温度、电压、电机功率、电池年限等因素外, 还受天气、道路状况、驾驶行为等因素影响。以上各种因素是一种非线性关系, 对其建立一个精确的数据模型比较困难。神经网络算法具有较强的非线性特征, 其学习能力较强, 可以利用外部输入对自身结构进行动态调整。因此利用神经网络算法对续航里程进行预测建模可以得到更好的结果, 为用户提供更精确的里程导航, 防止出现误报的信息具有重要意义。

2 基于遗传算法的 BP 神经网络

2.1 BP 神经网络算法

BP 神经网络^[2]是由输入层、隐含层、输出层组成的多层前馈神经网络, 同一层网络由多个神经元组成且

神经元之间没有相互关联，而相邻层之间的每一个神经元相互关联，因此决定了信号是单向传播的，且分配到各个神经元上，具体结构如下图 1 所示。




图 1 神经结构网络图

2.2 遗传算法

遗传算法是模拟自然界生物进化理论提出的一种搜索最优解的方法，其原理为将问题的求解转化为对进化中染色体进行变异、交叉，寻找到最优的变异个体，进而得到问题的最优解。

2.3 遗传神经网络算法

遗传算法可以对神经网络的样本进行编码得到合适的权值和参数，利用随机产生的初始化种群 n 维向量作为神经网络的权值向量，同时利用神经网络中 Sigmoid 函数计算适应度，保证在误差越小的情况下，得到的染色特越好^[3]，在交叉变异中对算子进行计算得到高适应的的样本，具体的流程如下图 2 所示。




图 2 遗传神经网络流程图

3 续航里程预测建模

3.1 结构参数的确定

续航里程是纯电车的一个重要性能指标，其输出与多个因素有关，包括电池温度、单体电压、电池电流、电机功率等。本文主要考虑远程终端采集的 GB/T-32960 数据的 11 个变量，包括车速、累计里程、电压、电流、SOC 数值、绝缘电阻、油门开度、刹车开度、电机转速、电机电流和电机电压。因此，在神经网络中输入节点数为 11。神经网络的隐含层数量决定了仿真的精度、训练时间和泛化能力，若神经元数量太少不利于网络获取解决问题的信息，神经元太多则导致训练时间增加，泛化能力下降；因此隐含层神经元数量至关重要。选择不同的隐含层数量对采集数据经过多次训练以后，均可以达到理想的收敛结果。通过对比测试理想误差，确定隐含层数为 2，神经元理想组合为[10, 7]。纯电车续航里程是目标输出，即作为神经网络的输出节点，其为 1。

激活函数是神经网络的重要组成部分，在该模型中主要采用 S 形对数（Log-Sigmoid）和线性（purelin）函数。其目的在于向多层神经网络中引入非线性，以更好地拟合非线性映射关系。激活函数表达式分别为

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$f(x) = x \quad (2)$$

式中：x 是网络模型输入参数。

在隐含层中第一层传递函数为 purelin，第二层的传递函数为 Sigmoid，训练最大次数为 100，目标精度为 0.05，训练的平滑度为 0.1。

遗传算法对参数进行初始化，选择的迭代次数为 10，种群的规模数为 30，交叉概率为 0.7，变异概率为 0.1。

为了提高实验的准确性，数据来源于某客户的纯电动某新能源车型进行跑车测试，跑车时间为 1.5h，采集周期为 10s/次，轨迹如下图 3 所示。




图 3 车辆轨迹图

为避免各输入参数之间的量纲差异，需对获取的试验数据样本进行归一化处理，以有效消除不同输入参数因单位不统一的影响。将采集的数据进行剔除，最后采用 670 条数据，并进行归一线性化转化，如公式(3)所示。为提高样本的多样性和差异性，选取前 550 个点为训练样本，后 120 个点数据为测试样本数据。

$$\hat{\lambda} = \frac{\lambda - \lambda_{\min}}{\lambda_{\max} - \lambda_{\min}} \quad (3)$$

式中： λ 代表原始数据各输入及输出变量的真实数值，即归一化前的数值； $\lambda_{\min}$ 、 $\lambda_{\max}$ 分别为对应变量的最小、最大值。

车速	累计里程	总电压	总电流	SOC	绝缘电阻	油门开度	刹车开度	电机转速	电机电压	电机电流	续航里程
4.5	41616.2	591.3	2.2	50	59000	0	42	457	0	48	102.5
12.5	41616.2	592.1	0.7	50	57500	0	21	1516	-108	50	102.4
21	41616.2	591.4	-3.7	50	56000	0	0	2410	-22	48	102.5
24.5	41616.1	591.4	-4.9	50	58500	0	0	2851	-20	48	102.4
26	41616	590	13.7	50	57000	2	0	2880	18	48	102.2
19	41615.9	588.5	36.2	50	55500	27	0	1850	94	51	102
30	41615.9	591.3	-24.5	50	58000	0	0	3522	-24	48	102.3
37	41615.8	589.1	18	50	56500	3	0	4171	19	50	101.9
25.5	41615.7	591.7	6.6	50	55000	0	0	2870	-21	49	103.1
50.5	41615.6	591.9	-18	50	57500	0	0	5797	-25	48	102
57	41615.4	587.9	22.3	50	56000	7	0	6464	11	48	101.8
59.5	41615.3	585.1	69.8	50	54500	43	0	6595	53	49	102
55.5	41615.1	585.8	60.1	50	58500	43	0	6266	57	48	102.1
62	41614.9	591.2	-33.6	50	55500	0	0	7160	-1	49	102.8
52.5	41614.8	586.6	51.9	50	59500	26	0	5823	36	48	102.5
46	41614.6	585.1	70	50	58000	40	0	5039	64	52	102.2
23	41614.5	594.7	-28.1	50	55000	0	14	2946	-142	51	103
43.5	41614.4	588.4	17.2	50	59000	1	0	4945	14	50	102.7
32.5	41614.3	581	122.7	50	57500	56	0	3521	179	55	101.5
0	41614.3	590.9	4	51	54500	0	52	0	0	48	103.9
0	41614.3	591	1.2	51	58500	0	52	0	0	48	103.9
0	41614.3	590.8	1.1	51	57000	0	52	0	0	48	103.9
0	41614.3	590.5	4	51	59500	0	52	0	0	48	103.8
0	41614.3	590.4	4	51	58000	0	52	0	0	47	103.8
6	41614.3	590.6	0.5	51	56500	0	18	812	-25	51	103.8
45.5	41614.2	589.1	1.7	51	55000	1	0	5275	17	50	103.4
44	41614.1	590.8	-15.3	51	57500	0	0	5126	-57	49	103.6
49	41613.9	585.6	45.7	51	56000	27	0	5532	42	50	103.1
38.5	41613.8	586.6	56	51	54500	33	0	4296	60	48	103.4
39	41613.7	586.7	43.4	51	57000	26	0	4354	57	52	103.3
6	41613.6	589.7	30	51	55500	44	0	361	137	47	103.9
6.5	41613.6	591.5	1.1	51	59500	0	32	867	-54	52	104.5
51	41613.5	596.7	-104.9	51	56500	0	13	6112	-103	47	103.6
64	41613.3	586.5	36.1	51	55000	27	0	7275	33	49	102.9
58.5	41613.2	588.4	17	51	59000	0	0	6640	7	48	104.3
59	41613	587.4	25.2	51	56000	9	0	6693	13	48	104
58	41612.8	586.1	62.2	51	54500	28	0	6540	35	48	103.8

图 4 采集国标数据

3.2 训练模型参数

训练样本的目的是预测值与目标值之间具有最小的误差，两者的曲线达到最佳拟合。将采集的训练 550 个样本导入模型以后，得到续航里程跟踪曲线如下图 5 所示。根据训练样本和真实值对比，测量最大相对误差为 4.1%。




图 5 训练样本跟踪图

3.3 测试结果分析

将采集的 120 个数据导入到训练好的模型中, 得到预测值与真实值之间的跟踪曲线如下图 6 所示。测试样本的最大误差如图 7 所示, 最大值为 1.5km, 最大的相对误差为 1.8%, 如下图 8 所示。




图 6 测试样本跟踪图




图 7 测试样本误差图




图 8 测试样本绝对误差值

4 结论

本文通过使用自带前馈 BP 神经网络工具箱对试验数据进行非线性预测，得到最小化的误差。同时结合遗传算法的交叉编译能力对高适应度样本进行选择得到最佳的网络参数，进一步优化网络权重和结构，提高网络的预测精度和性能。硬件采集数据的性能要提高，满足更高频率的数据采集，提高了市场成本，但是在实际应用时可以给客户提供准确的里程预测，减少不必要的成本浪费，提供最大的实际收益。

参考文献

- [1] 王辉, 胡斐. MATLAB 智能算法 30 个案例分析[M]. 1 版. 北京: 北京航空航天大学出版社, 2011.
- [2] 陈虞涛, 曾凡明. 基于动态神经网络的柴油机建模研究[J]. 海军工程大学学报. 2003, 15(1): 90-92.
- [3] 谢秋. 基于遗传算法和 BP 神经网络的协同设计效率研究及应用[D]. 重庆大学, 2013.
- [4] 李炎. 一种 BP 神经网络改进算法的研究[J]. 齐齐哈尔大学学报, 2010, 29(2): 29-31.