

DOI:10.15923/j.cnki.cn22-1382/t.2017.2.06

支持向量机纯电动客车驾驶意图识别

李 慧, 谭盛彬, 张 硕

(长春工业大学 电气与电子工程学院, 吉林 长春 130012)

摘 要: 以支持向量机为模型判断驾驶意图,通过对支持向量机进行训练,以加速踏板开度、加速踏板位移加速度为输入,利用网格优化算法得到了驾驶意图判断模型。仿真结果验证预测精度可达到99%。

关键词: 驾驶意图; 支持向量机; 纯电动客车

中图分类号: TP 181 **文献标志码:** A **文章编号:** 1674-1374(2017)02-0133-05

Identification of drive intention of HEV based on SVM

LI Hui, TAN Shengbin, ZHANG Shuo

(School of Electrical & Electronic Engineering, Changchun University of Technology, Changchun 130012, China)

Abstract: Support Vector Machine (SVM) is used for predicting driver intention by training the SVM. The opening degree and displacement of acceleration pedals are the inputs of the driver intention judgement model with grid optimization algorithm. Simulation results show the accuracy of the judgement is up to 99%.

Key words: drive intention; Support Vector Machine (SVM); Hybrid Electric Vehicle (HEV).

0 引 言

纯电动汽车与传统汽车^[1]相比具有零排放、噪声小、能源利用率高的特点,是未来汽车行业发展方向。纯电动汽车的续航里程现阶段还达不到令人满意的要求,这成为制约纯电动汽车发展的一个重要因素。为了纯电动汽车延长续航里程,许多学者进行了各种研究,指出能量管理与扭矩分配^[2-4]是最为关键的两个方面。同时指出能量管理和扭矩分配还需要符合驾驶员的驾驶意图。

目前,纯电动汽车对驾驶员驱动意图的识别

主要依靠加速踏板开度和制动踏板开度等参数。文献[5]通过识别车速、加速度均值和电池荷电状态(SOC)3个参数,利用隶属度函数和模糊规则判断驾驶意图,输出目标的驱动模式。文献[6]等将整车驱动模式分为常规模式、经济模式和动力模式,以加速踏板、电机转速、SOC等为输入,利用模糊控制算法输出目标转矩。文献[7-8]将加速意图分为平缓加速、紧急加速和一般加速三类,并把加速踏板变化率、加速踏板开度做为输入量,建立了神经网络模型,从而得到驾驶意图推理规则。

收稿日期: 2017-01-20

基金项目: 长春工业大学与中国第一汽车股份有限公司技术中心合作项目(W65-GNZX-2016-0009)

作者简介: 李 慧(1973-),女,汉族,吉林长春人,长春工业大学教授,博士,主要从事生产过程控制、自动化、最优控制方向研究,
E-mail: lihui@ccut.edu.cn.

为了精确识别驾驶意图,延长纯电动汽车的续驶里程,文中针对驱动方面的驾驶意图提出一种利用多个参数支持向量机识别驾驶意图的方法。

1 驾驶意图参数的选取

文中驾驶意图分为三类:紧急加速、一般加速和平缓加速。主要把加速踏板位移加速度、加速踏板开度作为支持向量机模型的输入量,用于辨别驾驶员的加速意图。这两个参数直接反映了驾驶员对速度要求的程度。




图 1 参数选择分类图

2 支持向量机概述

支持向量机 (Support Vector Machine, SVM) 是基于统计学习理论的一种机器学习方法,可在模型的复杂度和学习能力之间获得较佳折衷,并可转化为凸二次优化问题进行求解。因支持向量机算法简单,且学习后得到的模型有较强的推广能力,适合文中小样本学习的情况。

设序号为 i 的训练样本点为 (x_i, y_i) , 其中 x_i 为样本的属性,在文中 x_i 由 2 个属性构成,分别是加速踏板位移 s_i , 加速踏板位移变化率 a_i ; y_i 为该样本的分类标签,标签 1 表示平缓加速,标签 2 表示一般加速,标签 3 表示紧急加速。

一般情况下,设样本有 m 个属性,则在训练过程中支持向量机希望获得 m 维分类超平面 $w \cdot x + b = 0$,使所有训练样本 (x_i, y_i) 满足:

$$y_i(w \cdot x_i + b) \geq 1 \quad (1)$$

同时使得这两类样本间的分类间隔 $\frac{2}{\|w\|}$ 最大,以此获得最佳推广能力,即求下式函数的最小值:

$$\varphi(x) = \frac{1}{2} \|w\|^2 \quad (2)$$

为了求解上述优化问题,构造拉格朗日函数:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i(w \cdot x + b) - 1) \quad (3)$$

式中: n —— 训练样本的个数。

为了求解该函数,分别对 w, b, α_i 求偏导,并令其等于 0,则式(3)的优化问题可转化为 α_i 的凸二次规划寻优的对偶问题:

$$\begin{cases} \max \left(\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \right) \\ \text{s.t. } \alpha_i \geq 0 \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (4)$$

此时,若 α_i^* 为最优解,则 $w^* = \sum_{i=1}^n \alpha_i y_i x_i$, 其中大部分训练样本 x_i 对应的 α_i^* 为 0,少数不为 0 的 x_i 即为支持向量。同时, b^* 可由式(1)求得,此时可得识分类函数:

$$f(x) = \text{sgn}((w^* \cdot x) + b^*) = \text{sgn} \left(\sum_{i=1}^n \alpha_i^* y_i (x_i \cdot x) + b^* \right) \quad (5)$$

式中: x —— 待识别的样本。

式(4)的计算中包含向量的点积,为提高计算效率,引入核函数 $K(x_i, x_j)$ 来计算变换后高维空间中的向量点积 $z_i \cdot z_j$,并且引入松弛变量 ξ_i 来容许部分训练样本错分,最后引入惩罚项 $C\xi_i$ 来劝和错分点对最优分类面的影响。此时最优分类面的求解转化如下:

$$\begin{cases} \min_{w_i, \xi_i} \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \right) \\ \text{s.t. } y_i (w \cdot x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases} \quad (6)$$

其对偶的凸二次规划问题为:

$$\begin{cases} \max_{\alpha_i} \left(\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \right) \\ \text{s.t. } 0 \leq \alpha_i \leq C \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (7)$$

求解后可得 α_i 的最优解,此时得到最佳的分类识别器,其判别函数为:

$$f(x) = \text{sgn} \left(\sum_{i=1}^n \alpha_i^* y_i K(x_i \cdot x) + b^* \right) \quad (8)$$

3 驾驶意图识别器训练

文中采用径向基核函数 $K(x, x_i) = \exp(-\gamma \|x - x_i\|^2)$ 作为支持向量机模型的核

函数。RBF 核函数可以将一个样本映射到一个更高维的空间,而且与多项式核函数相比,RBF 需要确定的参数要少,减少了函数的复杂程度,同时也减少了数值的计算困难。在上述优化问题中,主要存在两个优化参数惩罚因子 c 和核函数参数 γ ,这两个参数直接影响了预测精度,所以选择这两个参数尤为重要。文中通过网格划分^[9]的方法对参数 c 和 g 进行选取。选取了 60 组数据,其中 30 组作为训练数据,30 组作为验证数据,分别见表 1 和表 2。

表 1 训练数据

序号	加速踏板开度	加速踏板开度变化率	驾驶意图
1	0.005 085	0.001 333	1
2	0.006 838	0.006 862	1
3	0.008 065	0.018 081	1
4	0.013 033	0.020 520	1
5	0.013 501	0.021 333	1
6	0.020 982	0.036 779	1
7	0.022 385	0.045 072	1
8	0.025 307	0.056 779	1
9	0.036 236	0.088 973	1
10	0.043 483	0.090 761	1
11	0.135 593	0.223 928	2
12	0.158 971	0.241 488	2
13	0.170 485	0.272 219	2
14	0.178 667	0.275 417	2
15	0.189 363	0.294 820	2
16	0.194 915	0.322 136	2
17	0.205 319	0.328 152	2
18	0.207 949	0.330 266	2
19	0.208 065	0.353 354	2
20	0.210 111	0.357 419	2
21	0.282 992	0.547 332	3
22	0.311 397	0.548 307	3
23	0.323 787	0.561 803	3
24	0.339 158	0.568 307	3
25	0.345 003	0.589 444	3
26	0.399 591	0.695 457	3
27	0.411 572	0.732 366	3
28	0.422 794	0.733 830	3
29	0.425 599	0.765 861	3
30	0.443 717	0.819 843	3

表 2 验证数据

序号	加速踏板开度	加速踏板开度变化率	驾驶意图
1	0.047 808	0.109 785	1
2	0.048 276	0.112 224	1
3	0.054 646	0.127 671	1
4	0.055 523	0.140 516	1
5	0.055 932	0.148 971	1
6	0.059 848	0.163 442	1
7	0.060 023	0.174 661	1
8	0.062 770	0.182 303	1
9	0.071 946	0.203 766	1
10	0.077 440	0.207 668	1
11	0.220 222	0.367 663	2
12	0.223 963	0.378 719	2
13	0.228 054	0.427 823	2
14	0.235 652	0.460 831	2
15	0.240 210	0.467 660	2
16	0.240 678	0.471 704	2
17	0.241 029	0.475 302	2
18	0.252 016	0.482 456	2
19	0.254 296	0.495 138	2
20	0.256 517	0.512 048	2
21	0.454 179	0.847 647	3
22	0.489 246	0.851 712	3
23	0.526 651	0.890 247	3
24	0.583 640	0.891 873	3
25	0.593 513	0.900 816	3
26	0.667 446	0.903 418	3
27	0.860 549	0.917 726	3
28	0.900 584	0.936 913	3
29	0.901 344	0.937 400	3
30	0.902 922	0.952 684	3

4 交叉验证选择最佳参数 c 和 g

目前对 SVM 参数选取常用的方法是让 c 和 g 两个参数在一定范围内取值,对于 c 和 g 取定值的时候,把训练数据集作为原始数据集并利用 K-CV 方法得到在此组 c 和 g 下训练集验证分类准确率,最终取使训练集验证分类准确率最高的那组 c 和 g 作为最佳参数。由于 c 越小使得分类器的泛化能力越强,当有多组 c 和 g 取得最高分类准确率时,取 c 最小的那组参数。

文中先让 c 和 g 在 $[2^{-10}, 2^{10}]$ 的范围内寻找

最佳取值。经过训练得到最优解,其中,第 1 组 $c = 0.435\ 28, g = 4$,该参数选择结果等高线图和 3D 视图分别如图 2 和图 3 所示。




图 2 参数选择结果等高线视图




图 3 参数选择结果 3D 视图

等高线表示取相对应的 c 和 g 后对应的 K-CV 方法的准确率。

通过上图可以看出, c 的最佳取值范围在 $[2^{-4}, 2^4]$, 所以在该基础上再进行一次筛选, 从而得到比较精确的 c 和 g 。再次训练可得 $c = 0.062\ 5, g = 4$, 该参数选择结果等高线图和 3D 视图分别如图 4 和图 5 所示。




图 4 参数选择结果等高线视图




图 5 参数选择结果 3D 视图

5 训练结果

经过参数寻优的 SVM 训练之后, 对于 3 个加速意图的识别, 该模型的预测精度达到了 99.33%。实验对比如图 6 所示。




图 6 测试集实际分类和预测分类

6 结 语

1) 预测实验获得了很好的预测精度, 验证了支持向量机算法应用于纯电动客车驱动驾驶意图判断的可行性。

2) 在采取 SVM 模型进行驾驶意图预测时, 受限于实验数据, 只选择了两个特征向量。在实际应用时, 可以通过多次试验获得关于纯电动客车加速情况下的其它参数, 如电池 SOC、电机转矩的变化率等, 使得 SVM 预测模型的属性增多, 提高预测模型的精度。

对 SVM 在纯电动客车驾驶意图预测领域内的应用研究进行了初步探索, 提出了把参数优化后的 SVM 应用于识别纯电动客车驾驶意图的方法。实验表明, SVM 可以有效地识别出纯电动汽车的驾驶意图, 但是实验还需要更多的数据进行

支持验证和进一步的完善。

参考文献:

- [1] 孙国春, 郭辉. 汽车动力总成振动控制研究[J]. 长春工业大学学报: 自然科学版, 2009, 30(2): 162-168.
- [2] 钱立军, 袁著永, 赵韩. 基于模糊神经网络的混合动力汽车控制策略仿真[J]. 系统仿真学报, 2006, 18(5): 1384-1387.
- [3] 吴剑, 张承慧, 崔纳新. 并联式混合动力汽车的 BP 网络实时能量管理[J]. 电机与控制学报, 2008, 12(5): 610-614.
- [4] Ehsani M, Gao Y, Miller J M. Hybrid electric vehicles: architecture and motor drivers [J]. Proceeding of the IEEE, 2007, 95(4): 719-728.
- [5] 初亮, 张培志, 林婷婷. 纯电动轿车模式识别及模式切换策略[J]. 华中科技大学学报: 自然科学版, 2014, 42(6): 12-16.
- [6] 王佳, 杨建中, 蔡志标, 等. 基于模糊控制的纯电动轿车整车优化控制策略[J]. 汽车工程, 2009, 31(4): 362-365.
- [7] 王庆年, 唐先智, 王鹏宇, 等. 基于驾驶意图识别的混合动力汽车控制策略[J]. 吉林大学学报: 工学版, 2012, 42(4): 789-795.
- [8] 王庆年, 唐先智, 王鹏宇. 基于神经网络的混合动力汽车驾驶意图识别方法[J]. 农业机械学报, 2012, 43(8): 32-36.
- [9] 王健峰, 张磊, 陈国兴, 等. 基于改进的网格搜索法的 SVM 参数优化[J]. 应用科技, 2012, 39(3): 28-31.