

基于神经网络算法的驾驶员制动需求预测研究

邢孟阳

上海工程技术大学机械与汽车工程学院, 上海

收稿日期: 2023年4月7日; 录用日期: 2023年5月24日; 发布日期: 2023年5月31日

摘要

由于线控制动系统在结构上的解耦关系, 驾驶员的制动需求识别成为线控制动系统研究中的焦点。本文建立了一种基于动态时间规整DTW (Dynamic Time Warping) 算法和长短时记忆模型LSTM (Long-Short-Term Memory) 融合的驾驶员制动需求识别模型。该模型主要包括数据收集、数据处理、分类匹配、需求预测四个模块。在搭建的线控底盘实验台上进行了实验, 采集了大量的驾驶员制动数据, 数据经过处理后首先利用动态时间规整算法进行驾驶员制动习惯分类匹配, 然后将分类后的数据分别用长短时记忆模型进行训练, 在完成训练后对模型性能进行了测试。同时我们还将本文所建立的模型与其它方法进行了对比实验, 结果表明, 本文所提出的模型能够准确地对不同驾驶习惯的驾驶员实现高准确度的制动需求预测。

关键词

线控制动, 制动需求, LSTM, 预测

Research on Driver Braking Demand Prediction Based on Neural Network Algorithm

Mengyang Xing

School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai

Received: Apr. 7th, 2023; accepted: May 24th, 2023; published: May 31st, 2023

Abstract

Due to the structural decoupling relationship of the brake-by-wire system, the identification of the driver's braking demand has become the focus of research on the brake-by-wire system. This pa-

per establishes a driver's braking request recognition model based on the fusion of dynamic time warping algorithm and long-short-term memory model. The model mainly includes four modules: data collection, data processing, classification matching, and request predication. The experiment was carried out on the test bench of chassis controlled-by-wire, and the driver braking data was collected. Using the conditioned sample data, dynamic time-warping algorithm was used to classify and match the driver's braking habits, and then the classified data is trained with the long-short-term memory model. The model is validated after the training is completed. The proposed prediction model performance is compared with other approaches and the effectiveness is verified with the expected driver brake habit as per driving situations. The results show that the model proposed in this paper can accurately predict the braking request of drivers with different driving habits.

Keywords

Brake-by-Wire, Brake Request, LSTM (Long-Short-Term Memory), Prediction

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

线控制动系统正在替代传统的机械液压制动系统以满足汽车智能化的需求。与传统制动系统相比，线控制动系统具有节能、响应快、控制精确以及拓展应用性强等优点，因此线控制动系统将成为未来汽车制动系统的主流[1] [2] [3]。线控制动系统是指用机电液一体化系统替代传统机械液压制动系统中的机械部件，同时用线束来传递信号，这种结构上的改变使其同时拥有响应迅速、控制精确、稳定性强等优点，因此能够满足下一代制动系统的需求[4] [5] [6]。在线控制动系统中，制动踏板与液压控制系统之间是解耦的，驾驶员踩制动踏板产生的信号通过线束传递到液压控制单元[7] [8]，那么如何准确识别驾驶员制动意图成为一项重要的研究课题。当前在研究过程中所采用的方法主要有以下几类，一：模糊预测法，主要采用模糊网络对制动位移和制动压力等参数进行筛选和预测；二：基于脑电波信号进行识别预测的方法，这一类方法主要采集驾驶员的脑电波信号进行分析预测；三：采用神经网络的方法进行分类，这一类方法主要采用了人工神经网络、循环神经网络、高斯隐马尔可夫算法以及长短时记忆模型等方法，这种方法相比前两种方法而言，识别效果更为准确，对设备要求相对较低。本文主要针对驾驶员制动需求的预测问题提出了一种基于动态时间规整算法(DTW)结合长短时记忆模型(LSTM)的方法，该方法能够通过采集驾驶员制动过程中所产生的数据，提取数据中的特征，对驾驶员的制动习惯准确分类，并根据不同的制动习惯对驾驶员的制动需求进行实时预测。

Yang [9]提出一种利用制动踏板位移数据及其求解的位移变化率作为主要参考，达到精确各制动轮缸的力矩的目的，以此来反映驾驶员制动意图。Li [10]提出利用采集到的制动踏板速度和位移数据作为判断依据，将驾驶员制动意图分为紧急制动和正常制动，根据不同的制动意图设计了不同的控制策略，以达到能量再生的目的。上述方法采用制动踏板数据作为主要判断依据，根据不同的阈值分类，设计不同的控制策略以达到间接反映驾驶员制动意图的同时实现车辆控制和能量回收。这些方法实用性强，但是由于对参数处理过于简单，所反映的驾驶员制动意图也不够细化，不能够完全真实代表驾驶员制动意图。在制动过程中，由于惯性作用，会给驾乘人员带来不适的感受，因此 Chen [11]提出了一种能有效提高制

动过程舒适性的制动意图分类方法,同时设计了一种基于滑移率控制的制动力分配策略,二者相结合在仿真驾驶模拟器和 CarSim 中进行了联合仿真实验,实验结果表明能有效提高制动过程舒适度。Zheng [12]提出了两种分别基于人工神经网络和模糊逻辑方法的制动意图识别模型,通过实验采集大量制动数据,用 k-means 聚类算法和最小二乘估计的方法提高神经网络的识别精度,考虑到汽车运行的不同工况,采用模糊逻辑算法模型进行制动意图识别,其准确率能够达到 98.2%。Qi [13]通过融合多个传感器数据,来推测驾驶员意图,然后建立了一个人-车-路闭环模型,最后基于模糊逻辑算法建立电机转矩补偿控制策略。上述方法都提出了应用模糊逻辑算法,或直接用来识别制动意图,或配合已识别的制动意图建立控制系统,其优点在于实现难度小、控制稳定、识别准确率高,但是上述方法将系统的性能局限于模糊逻辑中阈值的确定上,且根据不同的分类结果需要设计不同的控制策略。驾驶员是制动行为的发起者,因此 Hernández L G [14]提出用支持向量机(SVM)和卷积神经网络(CNN)的方法对驾驶过程中采集的驾驶员脑电图信号进行分类识别,其准确率分别能够达到 71.1%和 71.8%。Nguyen T H [15]收集了驾驶员模拟驾驶过程中的脑电图数据和运动信息,研究了脑电波频率结合神经网络实现制动意图分类,在驾驶员制动行为发生前 600 ms 处检测到紧急制动信号的准确率达 91%。Wang [16]对脑控驾驶进行了研究,从多点位、高频率采集脑电波数据,利用意图解码器对采集的脑电波数据进行解读,对驾驶员的制动意图进行分类,实验结果表明其平均准确率达 90%。上述方法创新应用脑电波作为输入信号,利用神经网络或其它分类器对驾驶员制动意图进行判别。但采用脑电波信号进行判别分类对信号处理要求高,且需要专用的脑电波采集设备,导致难以在实际驾驶过程中实现。Meng [5]总结了线控制动技术近些年来的进展,认为大量可用的训练数据的出现,使得将机器学习的方法应用于线控制动系统当中成为了可能,机器学习自身在数据学习和自优化方面的能力相较其它方法更有优越性,在制动预测过程中应用该方法能够显著提升制动稳定性。机器学习(ML)是一门对算法和统计模型进行专门研究的科学,它在对不同类别工作具有较强的自学习能力[17],Zhao [18]对如何有效提高驾驶意图识别的准确率进行了深入研究,认为当前驾驶辅助系统的难点在于驾驶意图识别模型的准确性、实用性和时效性。为了提高模型识别的精度,提出了一种基于高斯混合隐马尔可夫模型(GHMM)和广义生长剪枝径向基函数神经网络(GGP-RBFNN)的驾驶员制动意图识别模型,将制动踏板和车速作为最主要的观测序列数据,通过实车实验结果表明,该模型对驾驶员制动意图中的正常制动和轻微制动的准确率分别为 94.69%和 95.57%。随着深度学习相关研究的不断深入,其在预测领域展现出了极大的优势,如深度学习框架中的 RNN,在与文本,语音等相关的时序数据预测中占据主导地位[19],但是,由于 RNN 网络结构的原因,使得它在处理由前后关联的时序数据时容易出现梯度爆炸或者梯度消失的问题,为此 Hochreiter and Schmidhuber [19]在 1997 年提出了一种新型的深度学习算法,即长短时记忆模型(LSTM)算法,它是在 RNN 的基础上通过引入输入门、遗忘门和输出门这三个特殊的门,来解决 RNN 无法处理那些在时间序列上具有依赖关系的缺陷。Wang [20]建立了一种基于长短时记忆模型(LSTM)的制动意图识别模型,采用支持向量机递归特征消除(SVM-RFE)算法选择制动意图识别模型的特征参数。然后利用随机搜索对 LSTM 超参数进行优化,实验结果表明,基于长短时记忆模型(LSTM)的制动意图识别方法能够达到 95%的准确度。Xing [21]利用制动压力对制动过程进行预估,建立了一个融合长短时记忆模型(LSTM)和回归神经网络(RNN)的时间序列预测模型(TSM),将制动压力数据作为主要观测量,以此对制动系统状态进行预估,测试结果表明该方法能够实现较高准确度的单步长和多步长制动压力预测。Lv [22]等人提出了一种混合学习方法模型,用于对驾驶员制动强度进行分类和高精度识别。首先利用 GMM 算法将驾驶员的制动强度分为低、中、高三等级。然后利用随机森林方法在 GMM 的分类输出和车辆状态 CAN 信号之间对制动强度进行分类和确定。在预测方面,采用了神经网络制动压力观测的连续估计方法,混合机器学习方法可以实现对制动强

度和制动压力的高精度分类预测。Yang [23]等人提出了一种基于反向传播(BP)神经网络和隐马尔可夫模型(HMM)的前车驾驶员意图识别模型。选择制动踏板、加速踏板和车辆速度数据作为 BP-HMM 模型的输入,识别车辆先行驾驶员的制动意图。驾驶员的制动目的通过车辆的互联网传输,然后他们针对前一辆车提出了一种特定的 AEB 方法。AEB 模型可以在不同工况下动态改变临界制动距离以避免碰撞。上述研究都采用了神经网络的方法进行识别预测,预测准确度高,识别速度快,在当前智能汽车发展中是一条十分理想的途径。

2. 模型与方法

2.1. 人 - 机协同线控制动系统工作原理

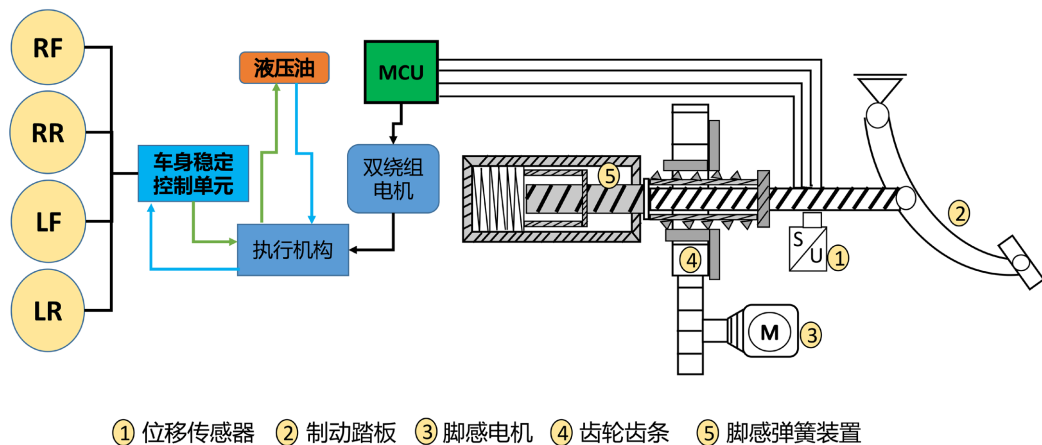


Figure 1. Schematic diagram of human-machine collaborative line control system
图 1. 人 - 机协同线控制动系统示意图

如图 1 所示为人 - 机协同线控制动系统工作原理简图。在该系统中制动踏板和制动执行器之间解耦,在工作时,驾驶员踩动制动踏板模拟器,模拟器上装有位移传感器,传感器产生电信号,信号传递给制动执行系统,制动执行系统接收到制动踏板的位移信号后开始对制动系统内的制动液进行加压,制动轮缸在液压力作用下对推动刹车片作用在制动盘上,使其抱紧车轮制动盘,实现制动。为了采集驾驶员驾驶过程中的制动位移和制动压力数据,我们分别在制动踏板模拟器和四个制动轮缸处,安装了踏板位移传感器和压力传感器,用来收集踏板位移数据和制动压力数据。

2.2. DTW-LSTM 模型框架

如图 2 所示为本文提出的驾驶员制动需求预测方法 DTW-LSTM 模型框架图,该方法共包含四个模块,其一是数据采集模块,其中包含驾驶员制动位移采集和线控制动系统制动压力采集两个部分,分别如图 1 中的 1、2 位置所示。在线控制动系统中,系统的输入和输出是最为关键的两个部分,因此我们在制动位移输入部分采用数据采集仪设置了制动位移数据采集点,采用制动压力传感器进行制动轮缸采集压力数据;其二为数据预处理模块,由于采样频率和设备自身的原因会导致采集的信号夹杂有高频噪声,因此添加滤波模块是必要的,本文采用低通滤波的方法去除信号中的高频噪声影响;其三为制动习惯匹配分类模块,该模块的主要是根据驾驶员的制动行为习惯进行匹配和分类,将驾驶员的制动行为习惯分为三种类型,分别为缓和型(Soft)、普通型(Normal)、急促型(Hurried),在匹配和分类过程中主要采用 DTW (Dynamic time Warping)算法,该算法主要是通过计算两次制动过程中产生的制动数据之间的欧式距离,

根据相似度来实现分类和匹配目的；最后为 LSTM 预测和结果输出模块，该模块通过接收匹配分类模块的信息分别对不同类型驾驶习惯的驾驶员的制动压力进行预测，驾驶员的制动需求主要是对车辆减速的需求，而与车辆减速度相关的主要参数之一就是制动压力，且制动压力是由驾驶员操作产生的，因此，我们认为对驾驶员制动压力的预测是能够反映驾驶员的制动需求的。

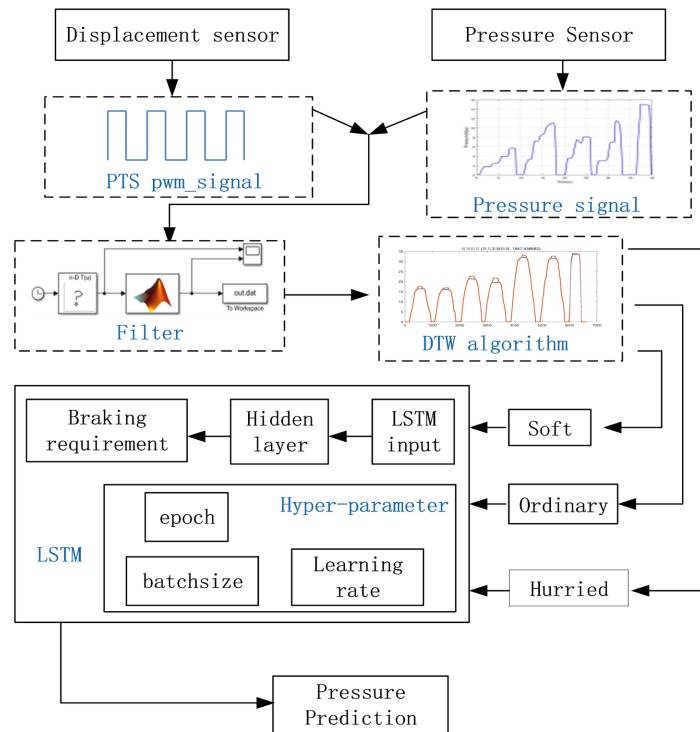


Figure 2. DTW-LSTM driver braking requirement predicting
图 2. 基于 DTW-LSTM 的驾驶员制动需求预测框图

2.3. DTW 匹配算法

DTW 算法即动态时间规整算法，其主要通过将时间序列规整来计算两个时间序列间的相似性，故其在处理存在非等长、偏移或振幅及时间轴的伸缩等问题的时间序列匹配上具有显著的优势，我们认为制动过程产生的数据也属于时序数据，因此采用 DTW 算法用来匹配分类是适合的。假设当前系统内正常刹车的时间序列为 $X = (x_1, x_2, \dots, x_n)$ ，当前从制动系统中采集到时间序列为 $Y = (y_1, y_2, \dots, y_m)$ ，那么 DTW 算法处理主要分为以下两步：第一步计算两个时间序列之间的距离矩阵 D 。假设现有目标时间序列 $X = (x_1, x_2, \dots, x_n)$ 和待匹配时间序列 $Y = (y_1, y_2, \dots, y_m)$ ，按照公式 1 计算序列 X 和 Y 之间任意两点之间的距离：

$$d(i, j) = \|x_i - y_j\|_w \quad (1)$$

式中： $i = 1, 2, 3, \dots, n$ 、 $j = 1, 2, 3, \dots, m$ ，当 $w=1$ 时为曼哈顿距离，当 $w=2$ 时为欧式距离。

经过上述计算我们可以得到距离矩阵 D ：

$$D = \begin{bmatrix} d(1,1) & \dots & d(1,m) \\ \vdots & \ddots & \vdots \\ d(n,1) & \dots & d(n,m) \end{bmatrix} \quad (2)$$

第二步在矩阵 D 中规划出最短路径 T ，并计算出最短路径的距离 $DTW(X, Y)$ ，这一步的核心思想是寻找最优规划路径 T_{best} ：

$$T_{best} = (T_1, T_2, \dots, T_k, \dots, T_n) \tag{3}$$

其中： T_k 表示规整路径位置，即 $T_k = (i, j)_k$ 表示 x_i 与 y_j 对齐，且 $\max(n, m) \leq k \leq n + m - 1$ 。规整路径 P_{best} 应满足边界性、单调性与连续性，即：

- 1) $T_1 = (1, 1)$ ， $T_k = (n, m)$ 。
- 2) 给定 $p_k = (i, j)$ 和 $p_{k+1} = (i', j')$ ，有 $i' \geq i$ ， $j' \geq j$ 。
- 3) 给定 $p_k = (i, j)$ 和 $p_{k+1} = (i', j')$ ，有 $i' \leq i + 1$ ， $j' \leq j + 1$ 。

p_1 与 p_k 间规整路径位置 p_k ，通过构造代价矩阵确定，矩阵元素 $\gamma(i, j)$ 定义为

$$\gamma(i, j) = d(i, j) + \min[\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1)] \tag{4}$$

其中： $i \in \{1, 2, \dots, n\}$ ， $j \in \{1, 2, \dots, m\}$ ， $\gamma(0, 0) = 0$ ， $\gamma(i, 0) = \gamma(0, j) = \infty$ 。

最优规整路径 P_{best} 的动态时间规整距离 $DTW(X, Y)$ 应使得 X 和 Y 的累积距离值最小。动态时间规整距离计算如式

$$DTW(X, Y) = \min_T \left\{ \frac{1}{k} \sum_{k=1}^k d(p_k) \right\} \tag{5}$$

2.4. 制动系统关键参数时序特征预测

长短时记忆模型(LSTM)结构如图 3 所示，其主要通过门控机制来实现有选择的传递信息，也正是由于这种机制使得其能够在具有前后关联的时序数据处理中脱颖而出，而制动的过程前后是存在关联的，因此采用该方法对驾驶员制动需求进行预测是合适的。




Figure 3. LSTM network model diagram
图 3. LSTM 网络模型图

图中： X_t 为模型输入， h_t 为模型输出，1 为遗忘门，2 为细胞状态，3 为输入门，4 为输出门， σ 和 \tanh 激活函数。

LSTM 网络模型中输入门是负责信息输入，它主要包括一个 sigmoid 层和一个 tanh 层，sigmoid 和 tanh 都是激活函数，它们的主要作用是将所传递给它的值进行缩放，但不同的是 sigmoid 会将值压缩到 0~1 之间，而 tanh 会将值压缩到 -1~1 之间。输入门的数学模型如公式 6 和 7 所示

$$I_t = \text{sig}(w_i * [h_{t-1}, x_t] + b_i) \tag{6}$$

$$C'_t = \tanh(w_c * [h_{t-1}, x_t] + b_c) \quad (7)$$

式中： w_i 和 b_i 分别是输入门中的权重矩阵和偏差矩阵， w_c 和 b_c 分别为记忆单元的权重矩阵和偏差矩阵。

输出门的主要作用是根据遗忘门和输入门计算后更新的“细胞”状态决定模型输出的信息。第一步是将数据输入到 sigmoid 函数中来计算输出内存单元的哪个状态。在第二步中，是将模型计算出的细胞状态输入到 tanh 激活函数中进行处理。第三步就是将第二步和第一步分别计算出的值相乘，然后输出。输入门的数学模型如公式 8 和 9 所示：

$$O_t = \text{sig}(w_o [h_{t-1}, x_t] + b_o) \quad (8)$$

$$H_t = o_t * \tanh \quad (9)$$

遗忘门的主要作用是用来筛选信息，同时将筛选出的信息传递出去，这个过程是通过遗忘门内的 sigmoid 层进行计算的，根据计算值的不同而选择传递或舍弃。遗忘门的数学模型如公式 10 所示：

$$F_t = \text{sig}(w_f * [h_{t-1}, x_t] + b_f) \quad (10)$$

LSTM 模型中细胞更新的规则如公式 11 所示：

$$C_t = F_t * C_{t-1} + I_t * C'_t \quad (11)$$

根据模型图 2 所示，驾驶员制动需求预测模型主要是制动压力预测模块，即制动压力估计 LSTM (p-lstm)，LSTM 模型在 t 时刻的输入和输出分别定义为：

$$X_t = \{a(t), b(t)\} \quad (12)$$

$$H_{t+p} = \{Pre_{t+p}\} \quad (13)$$

X_t 为 LSTM 模型在 t 时刻的输入，其中 $a(t)$ 为制动主缸位移； $b(t)$ 为制动轮缸压力。

H_{t+p} 为 LSTM 模型在 $t+p$ 时刻的输出， p 是步长， Pre_{t+p} 为 $t+p$ 时刻制动轮缸压力。

3. 实验和结果分析

在模拟驾驶场景下进行了实验数据收集，验证了本文所提出的基于 DTW-LSTM 的驾驶员制动需求预测算法的有效性，在本节中，我们介绍了模拟驾驶场景的设计。然后对实验收集到的数据进行处理。最后，将处理后的数据导入预测模型进行训练和预测。

3.1. 实验设计

制动台架实验是在江苏超力电器有限公司线控底盘实验室进行的。为了通过实验收集更多的数据，本次实验招募了八名驾驶员，其中两名女性、六名男性，两名女性驾驶员驾驶年限均为三年以内，六名男性驾驶员中，驾驶年限三年以内的两名，三至五年的三名，五年以上的一名。实验过程中要求，每名驾驶员进行 10 次模拟驾驶，本次实验在模拟环境下采集驾驶员的制动数据，为了能够获取驾驶员真实的制动习惯，我们设计了一个多工况模拟场景，该场景包含了多种实际驾驶过程中的情景，如红绿灯、斑马线、障碍物等。实验进行过程中，驾驶员在无外界干扰情况下进行模拟驾驶，利用数据采集仪实时采集驾驶员驾驶过程中踩动制动踏板模拟器时产生的位移数据，同时压力传感器采集制动轮缸的压力数据，并通过双通道测量仪进行数据记录。实验中所需用到的实验仪器如直流电源、油压传感器、双通道测量仪等的详细信息如表 1 所示。

Table 1. Experimental instrument Information**表 1.** 实验设备信息表


设备	型号	精度
压力传感器	RL-2088	0.2%
数据测量仪	GDM-9060	0.05 + 0.02 ma
位移传感器	MLX-90365	0.1 V
直流电源	LW-30100	0.1 V

3.2. 数据预处理

低通滤波算法常用于电路设计当中，本文主要采用低通滤波算法对采集的制动器主缸位移和驾驶员制动压力数据进行处理，原因在于低通滤波算法能够有效的去除实验数据中的噪声，使制动主缸位移和制动轮缸压力曲线更加的平滑从而确保信号能够真实反映驾驶员的制动需求。该算法的传递函数如公式 14 所示：

$$H(s) = \frac{1}{1 + \tau s} \quad (14)$$

式中 τ 为滤波系数，且 τ 的大小直接影响着滤波的强度。

**Figure 4.** Data changes under different filter coefficients**图 4.** 不同滤波系数下的数据变化图

如图 4 所示为滤波效果展示图，为了展示滤波对制动数据的影响，邀请志愿者随机自由踩动制动踏板，从图 4 中的局部放大图可以看出原始数据中有许多微小的波动，造成这些波动的主要原因是由于实验过程中，数据采集仪精度较高，且数据采集的频率是固定的，当我们无法保证制动踏板绝对稳定时就会在采集的波形上呈现出微小的波动，这些波动不仅不能真实代表驾驶员的意图，反而还会对预测过程造成一定影响，因此要通过滤波的方法对数据去除噪声干扰。本文主要采用的是低通滤波器来实现噪声去除，如图 4 所示，设置 τ 分别为 0.1，0.5 及原始数据对比图像，从图中可知当 τ 为 0.5 时与原始数据图像相比有较大差别，这时说明滤波强度过大，导致了失真现象，这是我们应该避免的现象，当 τ 设置为

0.1 时其波形可以明显消除波浪, 这说明滤波强度适中, 且从波形对比可以发现, 滤波后波形没有失真现象, 因此 τ 设置为 0.1。

3.3. DTW 算法匹配

对驾驶员的制动行为习惯进行分类是我们所建立的模型中的一个关键环节, 我们认为不同的驾驶习惯会对制动过程有非常大的影响, 因此我们考虑采用 DTW 算法根据驾驶员制动过程对驾驶员的驾驶习惯进行分类, 将制动习惯分为急促型(Hurried)、普通型(Ordinary)、缓和型(Soft)三种类型。为了测试 DTW 算法的有效性, 我们将实验过程中收集到的驾驶员制动位移数据进行数据分析, 经数据分析后, 截取出三种不同类型制动数据图像如图 5 所示:




Figure 5. Stroke-Time curve of different braking habits

图 5. 不同制动习惯下的位移时间曲线

从图中位移 - 时间曲线, 可以明显看出这三种曲线代表着不同的制动习惯, 其中急促型制动习惯的位移时间曲线变化速率快, 位移能够在较短时间内迅速上升, 在达到一定水平后又迅速恢复到初始水平, 相较而言, 普通型和缓和型的曲线变化速率就依次减慢, 但缓和型制动过程持续的时间相较普通型和急促型要长。因此, 从数据图像上看可以明显看出不同类型的制动习惯数据图像差异明显, 因此我们可以依照这些特点对采集的数据进行分类匹配, 其结果如图 6 和图 7 所示, 从图 6 中我们可以看出, 制动行为相似的制动数据进行匹配时, 其两曲线能够绝大部分重合, 且他们之间的欧式距离相较于制动习惯不同的制动数据曲线之间欧式距离较小, 这一点我们可以通过图 7, 不同类型制动习惯匹配图可以明显看出。根据 DTW 算法的匹配原理可知, 其在判别两种制动行为习惯是否为同一类型时, 主要的方法是通过计算两曲线之间的欧式距离, 欧式距离越大, 两种制动行为习惯越不相似, 欧式距离越小, 两种制动行为习惯越可能属于同一类型。通过大量的实验数据分析和总结, 我们设定两曲线间欧式距离小于等于 300 为同一类型制动习惯。将所有采集到的驾驶员制动位移数据进行 DTW 算法匹配处理后的结果如表 2 所示, 结果表明, DTW 对缓和型制动习惯的识别效果最好, 对三种类型制动习惯的识别的综合准确率能够达到 96%。

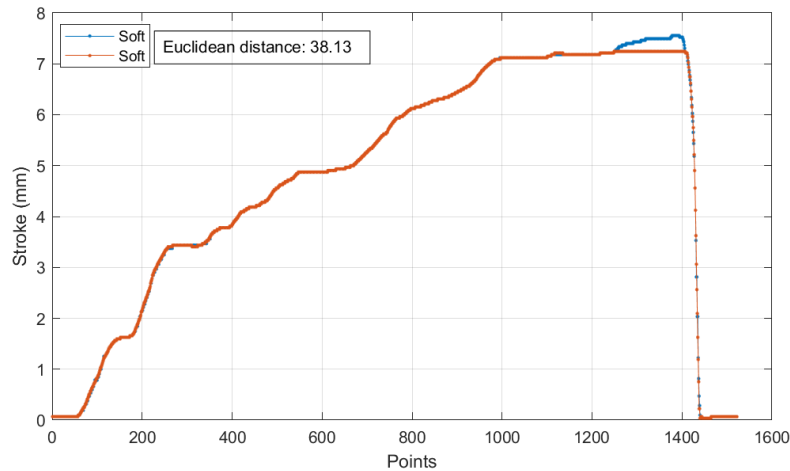


Figure 6. Classification and matching diagram of the same type of braking habits
图 6. 相同类型制动习惯分类匹配图

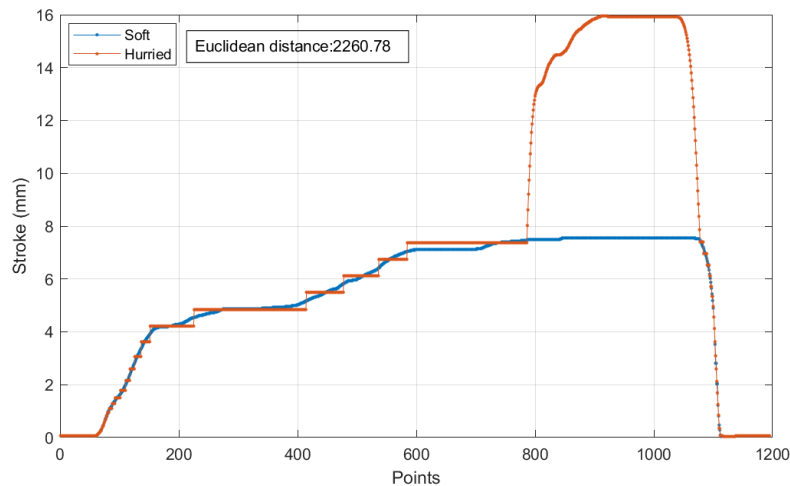


Figure 7. Classification and matching diagram of the different type of braking habits
图 7. 不同类型制动习惯分类匹配图

Table 2. Classification and recognition results of different braking types
表 2. 不同制动类型的分类识别结果

	缓和型	普通型	紧急型	总计
次数	25	40	15	80
成功	25	39	13	77
准确度	100%	97.5%	87%	96.3%

3.4. 制动需求预测

如上所述 LSTM 在时序数据预测领域具有独特的优势，由于制动行为过程的发生是具有前后因果关系的，因此 LSTM 的门控机制的效果能够发挥作用。本节主要介绍了如何利用 LSTM 模型对不同类型的制动习惯进行制动需求预测，以及利用 LSTM 模型实现单步长和多步长预测的效果。实验采集的数据经过预处理后由 DTW 算法按照不同类型制动习惯进行分类匹配，然后导入到不同参数设置的 LSTM 模型中，利用 LSTM 模型分别进行单步长预测和多步长预测，并在同等条件下基于同样的实验数据同其它现

行方法进行对比。

3.4.1. 单步长预测

本小节主要介绍使用 LSTM 模型进行单步长制动压力预测。为了测试本文提出的数据经滤波和制动行为习惯分类后,再由 LSTM 模型进行预测的效果,根据 DTW 分类,将分类习惯中的 Hurried 型和 Ordinary 型制动习惯的位移和压力数据进行了整理,制作了训练测试数据集,数据集按照 70%:30% 划分训练集和测试集,预测的准确度和模型的超参数设定有很大关系,针对单步长 LSTM 模型的参数进行多次调试,参数调试完成后进行了模型训练和测试。




Figure 8. Single-time-step prediction chart of Hurried braking request

图 8. 单步长紧急型制动需求预测




Figure 9. Single-time-step prediction chart of ordinary braking request

图 9. 单步长普通型制动需求预测

如图 8 和图 9 所示分别为单步长 Hurried 和 Ordinary 型制动需求预测结果, 从图中可以明显看出单步长 LSTM 模型的预测在参数调整后的准确度十分高, 原始数据和预测数据变化趋势基本相同, 预测数据和原始数据的主要差异在于在压力值接近 0 和压力值接近最大值时会出现偏差, 但这样的预测效果已经满足当前需求。

3.4.2. 多步长预测

由于驾驶员制动行为的发生是一个紧急的过程, 正常情况下其持续的时间十分短暂, 但是驾驶员制动需求预测的意义在于能够提前预知对制动压力的需求, 使线控制动系统能够提前建压, 这样有助于实现更快, 更高效的制动, 同时为车辆和乘客的安全提供更高的安全保障, 在查阅相关资料后选择设定 0.15 s 作为我们多步长预测的目标。多步长 LSTM 模型的参数调试过程与单步长预测类似, 通过多次训练测试选择效果最好的参数进行训练和预测,




Figure 10. Multi-time-step prediction chart of Hurried braking request

图 10. 多步长紧急型制动需求预测




Figure 11. Multi-time-step prediction chart of ordinary braking request

图 11. 多步长普通型制动需求预测

如图 10 和图 11 所示为多步长制动压力预测效果图，从图中可以明显看出，多步长预测的效果在参数调试后效果良好，但是多步长预测容易出现数据波动现象，出现这样的原因主要与步长设定的原因有关，但整体上多步长预测的结果是符合需求的。

实验结果的评价只要主要有以下三部分组成，即预测准确度，MAPE (Mean Absolute Percentage Error)值及 RMSE (Root Mean Square Error)值，MAPE 值和 RMSE 值的数学表达式分别如公式 15 和 16 所示：

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{\sum_i^N (P_i - T_i)^2}{N}} \quad (16)$$

在相同条件下对采用对比方法进行对比实验，结果希纳是，本文建立的 DTW-LSTM 预测模型具有预测准确度高的优点，实验结果对比如表 3 所示：

Table 3. Displays the experimental results and a comparison of each method

表 3. 对比实验结果展示

方法	准确度	RMSE	MAPE
Lstm-s	98.3	0.069	0.010
Lstm-m	97.2	0.37	0.028
SVR	94.9	0.808	0.051
RNN	97	0.439	0.030
MLP	95.4	0.66	0.046

表中，Lstm-s 和 Lstm-m 分别代表基于 DTW-LSTM 的单步长和多步长预测，它们同 SVR (Support Vector Regression)、RNN (Recurrent neural network)、MLP (Multi-Layer Perceptron) 分别进行对比，从表中数据相比较可以看出，本文建立的 DTW-LSTM 模型在单步长预测中表现效果最好，准确度能够达到 98.3% 其误差损失率相较于其它方法都低，这说明模型在驾驶员制动需求预测方面具有良好的性能，多步长的预测中，虽然准确率有所下降，但是考虑到我们的步长设置为提前 0.15 s 进行预测，这样的准确度已经是非常良好的结果。

4. 结论

本文提出了一种基于 DTW 算法和 LSTM 模型的线控制动系统驾驶员制动需求预测的方法，通过驾驶员模拟实验，采集了驾驶员在模拟驾驶过程中产生的制动位移和制动压力数据，所采集的数据先经过滤波处理去除高频噪声，然后通过 DTW 算法对不同类型的制动习惯进行分类，最后利用 LSTM 模型对制动需求进行单步长和多步长预测，结果表明：

(一) 在单步长和多步长预测过程中，通过多次实验，其平均预测准确度分别能够达到 98.3%、97.2%。

(二) 制动过程时间较短，预测的难度大准确度要求高，因此本文在查阅相关资料后设定 0.15 s 作为多步长预测的目标时间是满足当前需求的。

(三) 制动过程的数据可以被视为时序数据进行处理，LSTM 能够实现高准确度的时序数据预测。

对未来工作的展望：其一、预测的结果需要与控制策略相结合，因此在将来我们需要建立控制策略这一关键环节，其二，制动过程是一个对安全性要求十分高的环节，因此实车实验是必不可少的一环，

在条件允许情况下，将进行实车试验。

参考文献

- [1] Nadeau, J., Micheau, P. and Boisvert, M. (2017) Ideal Regenerative Braking Torque in Collaboration with Hydraulic Brake System. 2017 12th International Conference on Ecological Vehicles and Renewable Energies (EVER), Monte Carlo, 11-13 April 2017, 1-5. <https://doi.org/10.1109/EVER.2017.7935934>
- [2] Gong, X., Ge, W., Yan, J., Zhang, Y. and Gongye, X. (2020) Review on the Development, Control Method and Application Prospect of Brake-by-Wire Actuator. *Actuators*, **9**, Article No. 15. <https://doi.org/10.3390/act9010015>
- [3] Han, W., Xiong, L. and Yu, Z. (2019) A Novel Pressure Control Strategy of an Electro-Hydraulic Brake System via Fusion of Control Signals. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, **233**, 3342-3357. <https://doi.org/10.1177/0954407018821016>
- [4] Zhao, X., Wang, S. and Wang, X. (2018) Characteristics and Trends of Research on New Energy Vehicle Reliability Based on the Web of Science. *Sustainability*, **10**, Article No. 3560. <https://doi.org/10.3390/su10103560>
- [5] Meng, B., Yang, F., Liu, J. and Wang, Y. (2020) A Survey of Brake-by-Wire System for Intelligent Connected Electric Vehicles. *IEEE Access*, **8**, 225424-225436. <https://doi.org/10.1109/ACCESS.2020.3040184>
- [6] Li, D., Tan, C., Ge, W., et al. (2022) Review of Brake-by-Wire System and Control Technology. *Actuators*, **11**, Article No. 80. <https://doi.org/10.3390/act11030080>
- [7] Yu, L., Liu, X., Xie, Z. and Chen, Y. (2016) Review of Brake-by-Wire System Used in Modern Passenger Car. *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, Charlotte, 21-24 August 2016, 50138.
- [8] Xiao, F., Gong, X., Lu, Z., et al. (2021) Design and Control of New Brake-by-Wire Actuator for Vehicle Based on Linear Motor and Lever Mechanism. *IEEE Access*, **9**, 95832-95842. <https://doi.org/10.1109/ACCESS.2021.3094030>
- [9] Yang, Y., He, Y., Yang, Z., Fu, C. and Cong, Z. (2020) Torque Coordination Control of an Electro-Hydraulic Composite Brake System During Mode Switching Based on Braking Intention. *Energies*, **13**, Article No. 2031. <https://doi.org/10.3390/en13082031>
- [10] Li, W., Du, H. and Li, W. (2018) Driver Intention Based Coordinate Control of Regenerative and Plugging Braking for Electric Vehicles with in-Wheel PMSMs. *IET Intelligent Transport Systems*, **12**, 1300-1311. <https://doi.org/10.1049/iet-its.2018.5300>
- [11] Chen, S., Zhang, X. and Wang, J. (2020) Sliding Mode Control of Vehicle Equipped with Brake-by-Wire System considering Braking Comfort. *Shock and Vibration*, **2020**, Article ID: 5602917. <https://doi.org/10.1155/2020/5602917>
- [12] Zheng, H., Ma, S., Fang, L., Zhao, W. and Zhu, T. (2019) Braking Intention Recognition Algorithm Based on Electronic Braking System in Commercial Vehicles. *International Journal of Heavy Vehicle Systems*, **26**, 268-290. <https://doi.org/10.1504/IJHVS.2019.101464>
- [13] Qi, W. (2020) Fuzzy Control Strategy of Pure Electric Vehicle Based on Driving Intention Recognition. *Journal of Intelligent & Fuzzy Systems*, **39**, 5131-5139. <https://doi.org/10.3233/JIFS-179998>
- [14] Hernández, L.G., Mozos, O.M., Ferrández, J.M., and Antelis, J.M. (2018) EEG-Based Detection of Braking Intention under Different Car Driving Conditions. *Frontiers in Neuroinformatics*, **12**, Article 29. <https://doi.org/10.3389/fninf.2018.00029>
- [15] Nguyen, T.-H. and Chung, W.-Y. (2019) Detection of Driver Braking Intention Using EEG Signals during Simulated Driving. *Sensors*, **19**, Article No. 2863. <https://doi.org/10.3390/s19132863>
- [16] Wang, H., Bi, L. and Teng, T. (2017) EEG-Based Emergency Braking Intention Prediction for Brain-Controlled Driving Considering One Electrode Falling-off. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, 11-15 July 2017, 2494-2497. <https://doi.org/10.1109/EMBC.2017.8037363>
- [17] Mahesh, B. (2020) Machine Learning Algorithms—A Review. *International Journal of Science and Research (IJSR)*, **9**, 381-386.
- [18] Zhao, X., Wang, S., Ma, J., et al. (2019) Identification of Driver's Braking Intention Based on a Hybrid Model of GHMM and GGAP-RBFNN. *Neural Computing and Applications*, **31**, 161-174. <https://doi.org/10.1007/s00521-018-3672-1>
- [19] Yu, Y., Si, X., Hu, C. and Zhang, J. (2019) A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, **31**, 1235-1270. https://doi.org/10.1162/neco_a_01199
- [20] Wang, S., Zhao, X., Yu, Q. and Yuan, T. (2020) Identification of Driver Braking Intention Based on Long Short-Term Memory (LSTM) Network. *IEEE Access*, **8**, 180422-180432. <https://doi.org/10.1109/ACCESS.2020.3027811>

-
- [21] Xing, Y. and Lv, C. (2019) Dynamic State Estimation for the Advanced Brake System of Electric Vehicles by Using Deep Recurrent Neural Networks. *IEEE Transactions on Industrial Electronics*, **67**, 9536-9547.
<https://doi.org/10.1109/TIE.2019.2952807>
- [22] Lv, C., Xing, Y., Lu, C., *et al.* (2018) Hybrid-Learning-Based Classification and Quantitative Inference of Driver Braking Intensity of an Electrified Vehicle. *IEEE Transactions on Vehicular Technology*, **67**, 5718-5729.
<https://doi.org/10.1109/TVT.2018.2808359>
- [23] Yang, W., Liu, J., Zhou, K., Zhang, Z. and Qu, X. (2020) An Automatic Emergency Braking Model considering Driver's Intention Recognition of the Front Vehicle. *Journal of Advanced Transportation*, **2020**, Article ID: 5172305.
<https://doi.org/10.1155/2020/5172305>