

DOI: 10.13382/j.jemi.B2508619

基于退化 GRU 网络的混合式胎压监测系统设计

朱元¹ 窦雨琪¹ 徐世寒¹ 蔡炜旻² 苏丹²

(1. 同济大学汽车与能源学院 上海 201804; 2. 上海蔚来汽车有限公司 上海 201804)

摘要:针对物理传感器成本高、间接式胎压监测系统需手动校准胎压基准值的问题,设计了一种基于退化 GRU 网络(degeneration gated recurrent unit,DGRU)的混合式胎压监测系统(hybrid tire pressure monitoring system,hTPMS)。首先分析轮胎扭转振动模型,以此作为胎压辨识的理论依据;设计简单的滤波方法修正齿圈误差,结合阿克曼转向模型消除小转向工况下的内外轮速差,拓展半径迭代法的有效工况区间;融合单个物理胎压传感器与防抱死刹车系统(anti-lock braking system,ABS)传感器信号,在时域和频域分别构建 DGRU 神经网络估计器,实现胎压值的实时精准估计。实车路试结果表明,该系统在胎压从 2.6 bar 突降至 1.9 bar 时,频域特征输入模式的响应时间最快达 73.6 s,胎压估计误差控制在国标允许范围内;时域特征输入较序列输入响应速度最高提升 62.66%,算法在 Aurix TC397 芯片上运行时 CPU 平均占用率仅 0.464%。本系统较传统直接式胎压监测系统减少 75% 的物理传感器成本,且多工况下的准确性与稳定性均满足国标 GB 26149-2017 要求,为胎压监测技术提供了融合机械建模与智能算法的创新路径。

关键词: 混合式胎压监测系统(hTPMS);退化 GRU 神经网络;共振频率;ABS 传感器

中图分类号: U467.1⁺4;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 580.2010

Design of a hybrid tire pressure monitoring system based on degeneration GRU

Zhu Yuan¹ Dou Yuqi¹ Xu Shihan¹ Cai Weimin² Su Dan²

(1. School of Automotive and Energy Engineering, Tongji University, Shanghai 201804, China;

2. Shanghai NIO Co., Ltd., Shanghai 201804, China)

Abstract: To address the challenges of high costs pertaining to physical sensors and the necessity for manual calibration of tire pressure reference values in indirect tire pressure monitoring systems (iTPMS), this paper proposes a hybrid tire pressure monitoring system (hTPMS) based on the degeneration gated recurrent unit (DGRU) network. First, this study conducts a theoretical analysis of the tire torsional vibration model, which serves as the fundamental basis for tire pressure identification. A simplified filtering algorithm is devised to compensate for ring gear errors, and in conjunction with the Ackermann steering model, the wheel speed discrepancy between the inner and outer tires under small-steering conditions is eliminated, thereby extending the effective operating envelope of the radius iteration method. By fusing the signals from a single physical tire pressure sensor and anti-lock braking system (ABS) sensors, DGRU neural network estimators are established independently in both the time and frequency domains, enabling real-time and high-precision estimation of tire pressure values. Results of real-vehicle road tests demonstrate that when the tire pressure experiences a sudden drop from 2.6 bar to 1.9 bar, the frequency-domain feature input mode achieves a minimum response time of 73.6 s, with the tire pressure estimation error confined within the tolerance range specified by national standards. Compared with sequence-based input, the time-domain feature input mode enhances the response speed by up to 62.66%, and the algorithm operates on the Aurix TC397 chip with an average CPU utilization rate of merely 0.464%. This system reduces the cost of physical sensors by 75% relative to conventional direct tire pressure monitoring systems (dTPMS), and its accuracy and stability across diverse operating conditions fully comply with the requirements of the national standard GB 26149-2017, offering an innovative approach that integrates mechanical modeling and intelligent algorithms for tire pressure monitoring technology.

Keywords: hybrid tire pressure monitoring system (hTPMS); degeneration gated recurrent unit (dGRU) neural network; abs sensor; resonant frequency

0 引言

截至 2024 年 1 月,国内机动车的总量攀升至 4.35 亿辆。汽车行驶时,爆胎是引起汽车突发事件的重要原因之一,排除外力干扰引起的爆胎事故,行驶过程中爆胎的主要原因是胎压不足或胎压过高。中国在胎压监测系统(tire pressure monitoring system, TPMS)领域的研究起步较晚,于 2017 年 10 月发布了强制性国家标准 GB 26149-2017,详细规定了 TPMS 的性能要求,强制要求 M1 类车辆最晚于 2020 年 1 月 1 日安装 TPMS^[1]。

然而,TPMS 的作用远不止于爆胎预警。在汽车智能化、网联化飞速发展的当下,精确、可靠的轮胎状态信息已成为车辆底盘动力学控制系统(如汽车防抱死制动系统(anti-lock brake system, ABS)、电子稳定程序)进行最优决策的关键参数输入^[2]。因此,研发更智能、更可靠的 TPMS,不仅是满足法规的必然要求,更是提升车辆主动安全性能、支撑未来智能交通体系的基础性环节。

TPMS 一般分为直接型(direct TPMS, dTPMS)和间接型(indirect TPMS, iTPMS)。dTPMS 直接在轮胎上安装物理传感器测量轮胎压力和温度^[3],但 dTPMS 需考虑传感器成本和电磁兼容性等相关问题^[4]。iTPMS 使用 ABS 中的轮速传感器信号,通过分析轮胎的滚动半径、共振频率等参数来间接监测胎压状态^[2],但 iTPMS 的准确率和实用性仍有待提高。

对 iTPMS 的研究集中在胎压状态的监测及其分类,常通过半径法和频域法判断胎压状态。半径法通过比较各车轮转速来判断轮胎半径的变化,当车轮胎压降低时其滚动半径变小,从而产生比其他车轮更快的转速,由此间接判断胎压变化^[5]。轮速信号在保留轮速整体变化趋势的基础上添加低通滤波器消除高频抖动信息,从而取得更稳定的参数辨识结果^[6]。频域法利用胎压和轮胎周向振动频率之间的关系来实现胎压监测^[7],轮胎气压变化影响轮胎刚度和带束张力,进而改变轮胎固有频率^[8]。频域法的应用需建立轮胎周向振动模型,周向振动频率在 30~60 Hz 范围内,通过带通滤波聚焦轮胎振动的共振频段,排除无关频率干扰^[9]。并对该频段时域信号进行快速傅里叶变换(fast fourier transformation, FFT),根据共振频率并实现胎压判断^[10]。

混合式胎压监测系统(hybrid TPMS, hTPMS),由 Simone 等^[11]提出,通过单个物理胎压传感器以及其他车辆信号的估计器,使用信号处理和估计技术,在 5 min 内检测到胎压状态并计算出胎压估计值。hTPMS 减少了

物理传感器的数量,利用车辆已有的传感器信号,通过软件算法实现传感器融合与胎压估计,使得车辆的布线更加简洁,降低故障率。与 dTPMS 使用的 4 轮物理轮速传感器相比,减少了额外传感器的安装和维护成本。

随着状态监测要求的提高,多种深度学习算法被用于间接胎压监测算法的故障诊断和状态监控等方面。王小平等^[12]将长短期记忆网络(long short-term memory networks, LSTM)应用于 iTPMS 中的数据处理,可以在更低的速度下识别欠压轮胎,并且响应速度更快;Alex 等^[13]在 iTPMS 中将仿真的加速度计数据分别用于训练和评估长短期记忆网络 LSTM 和卷积神经网络(convolutional neural networks, CNN);魏凌涛等^[14]在 iTPMS 中将决策树与贝叶斯分类器结合,用于监测轮胎压力损失;Zoltán 等^[15]将 CNN 与胎压共振频率提取相结合,得出优于傅里叶变换和重心法的胎压共振频率提取方法;Vinod 等^[16]使用具有 CNN 层的 4 个预训练深度学习网络 GoogLeNet、VGG-16、AlexNet 和 ResNet-50 来确定轮胎状况,并以集成方法执行特征提取、特征选择和分类;Arun 等^[17]利用加速度计采集振动数据,使用多种预训练网络,通过调整学习率、批量大小、训练-测试拆分比和求解器等超参数,确定了使用 ResNet-50 时达到了分类准确率高达 97.20%;Siddhant 等^[18]采用了具有成本效益的微机电系统传感器,使用失重神经网络进行胎压状态监测。Qiu 等^[19]用 LSTM 检测具有固有时变性的数据结构变化,所提出的模型在均值偏移检测方面优于其他基于神经网络的预测监测方法。Sivashankar 等^[20]利用径向加速度进行预处理,结合实际驾驶条件下的噪声,提出了一种基于门控循环单元(gate recurrent unit, GRU)的 TPMS,实现胎压状态监测。

现有研究基本能够实现各轮胎压状态的辨识,较少实现准确的数值估计。本文将退化 GRU 网络(degeneration gated recurrent unit, DGRU)应用于胎压监测,结合单个物理胎压传感器和 ABS 传感器,提出一种间接胎压监测方法。首先建立轮胎扭转振动模型,分析轮胎压力的变化引起的共振频率的变化。在轮速信号预处理方面,设计均值滤波方法对齿圈误差进行辨识修正,利用插值法重采样将轮速信号转化为时间均匀。并根据阿克曼转向模型修正小转向状态下的等效半径与理论等效半径的比值,在时域特征的计算中拓展半径迭代法的使用范围。在频域方面,通过带通滤波器提取目标频带,使用 FFT 结合重心法提取频域特征值。最后对时域方法特征输入和频域特征输入分别设计深度学习估计器,实现各轮胎压数值估计,并将所提方法部署在 Aurix

TC397 上进行城市道路工况下的测试。

1 轮胎扭转振动模型建立

为分析轮胎扭转振动模型对轮胎扭转刚度的影响,建立基于轮胎扭转振动频率分析的轮胎压力估计算法。轮胎扭转振动模型如图 1 所示,模型中考虑了胎面的道路力和轮辋的扭矩,不考虑悬架系统的作用。将胎面和带束层简化为一个集中质量块,具有转动惯量 J_1 ;将轮辋视为刚性体,具有转动惯量 J_2 ;胎面与轮辋通过轮胎的扭转刚度 k_t 和阻尼系数 c_t 耦合;路面激励简化为作用于胎面的外部扭矩 T_{road} ;胎面和轮毂的旋转角速度分别为 ω_M 和 ω 。




图 1 轮胎扭转振动模型

Fig. 1 Tire torsional vibration model

基于牛顿第二定律,胎面和轮毂的扭矩平衡方程:

$$J_1 \dot{\omega}_M = T_{road} - k_t \theta - c_t \dot{\theta} \quad (1)$$

$$J_2 \dot{\omega} = k_t \theta + c_t \dot{\theta} \quad (2)$$

胎面和轮毂之间的扭转角 θ :

$$\dot{\theta} = \omega_M - \omega, \ddot{\theta} = \dot{\omega}_M - \dot{\omega} \quad (3)$$

将式(2)代入式(1)并使用 Laplace 变换可得传递函数和共振频率 f_{res} :

$$G(s) = \frac{\omega(s)}{T_{road}(s)} = \frac{c_t s + k_t}{J_1 J_2 s^3 + c_t (J_1 + J_2) s^2 + k_t (J_1 + J_2) s} \quad (4)$$

$$f_{res} = \frac{1}{2\pi} \sqrt{\frac{2k_t(J_1 + J_2) - c_t^2}{2J_1 J_2}} \quad (5)$$

$$k_t = 2\pi r^3 (0.064 26p + 0.296 9) \quad (6)$$

轮胎的扭转刚度主要由胎体结构和内部胎压共同决定^[21],当胎压处于线性敏感区间内 ($1.5 \text{ bar} < p < 3.5 \text{ bar}$),扭转刚度可由式(6)计算。由式(6)可知,轮胎刚度的变化直接影响了轮胎的固有频率,因此通过频谱分析方法能够有效检测到胎压变化引起的固有频率偏移。

2 轮速信号特征的提取

基于深度学习的混合胎压估计方案如图 2 所示,该方法包括轮速信号预处理、轮速信号特征的提取和轮胎压力估计 3 个部分。




图 2 基于深度学习的混合胎压估计方案

Fig. 2 Research scheme of hybrid tire pressure estimation method based on deep learning

在轮速信号预处理部分,针对轮速信号中的齿圈制造误差和噪声干扰问题,采用均值滤波消除齿圈误差,通过插值重采样实现信号均匀化处理并添加滤波器消除噪声干扰。

在轮速信号特征的提取部分中,在时域特征的计算

中通过增加阿克曼转向模型修正轮胎半径,拓展半径迭代法的使用范围,在半径迭代法同轴半径对比的基础上加入同侧半径对比;在频域特征的计算中利用 FFT 将时域轮速信号转化成频率域,提取频域轮速信号的特征。

在轮胎压力估计部分中,根据输入轮速信号时域和

频域特征,分别构建 GRU 神经网络模型实现胎压辨识,并基于动力学状态监测对基于频域的胎压估计算法和基于轮速信号的胎压状态识别算法分别进行使用。

2.1 均值滤波消除齿圈误差

图 3 为轮速时间戳信号及齿圈误差示意图,假设齿圈有 N_i 个齿, N_i 个齿经过霍尔传感器产生 $2N_i$ 个脉冲信号,共采集到齿圈旋转 k 圈的轮速信号, $\Delta t_i(k)$ 为齿圈旋转第 k 圈时第 i 个齿廓与前一个齿廓的时间间隔, $\theta_i(k)$ 为第 i 个齿廓与前一个齿廓之间的真实弧度,在第 k 圈时第 i 个齿廓的旋转角速度如式(7)所示。

$$\omega_i(k) = \frac{\theta_i(k)}{\Delta t_i(k)} \quad (7)$$




图 3 轮速时间戳信号及齿圈误差示意图

Fig. 3 Schematic diagram of wheel speed timestamp signal and ring gear error

理论上各齿均匀分布于齿圈之上,但由于制造误差使相邻齿之间存在误差值,误差值 $\Delta\theta_i(k)$ 由式(8)计算得出,其中齿圈相邻齿廓的理论弧度 θ_0 可由式(9)计算得出。

$$\Delta\theta_i(k) = \theta_0 - \theta_i(k) \quad (8)$$

$$\theta_0 = \frac{2\pi}{N_i} \quad (9)$$

齿圈第 i 个齿廓从 $k-1$ 圈转到第 k 圈经过 $2N_i$ 个齿廓,将第 i 个齿廓从 $k-1$ 圈转到第 k 圈的平均角速度近似为第 i 个齿廓在第 k 圈时的瞬时角速度 $\bar{\omega}_i(k)$:

$$\bar{\omega}_i(k) = \frac{2\pi}{\sum_{m=i+1}^{N_i} \Delta t_m(k-1) + \sum_{m=1}^i \Delta t_m(k)} \quad (10)$$

$$\theta_i(k) \approx \bar{\omega}_i(k) \Delta t_i(k) \quad (11)$$


本文使用均值滤波消除齿圈误差,在齿圈旋转 k 圈内的第 i 个齿廓的误差估计值 $\Delta\hat{\theta}_i$ 为:

$$\Delta\hat{\theta}_i = \frac{\sum_{m=1}^k \Delta\theta_i(m)}{k} \quad (12)$$

每个齿经过传感器产生 2 个脉冲信号,48 个齿因齿圈误差产生的误差值数为 96 个,图 4 为均值滤波的齿圈误差估计结果,图 4(a) 为轮胎旋转 50 圈的估计的误差值, x 轴为第 i 个齿廓, y 轴和 z 轴分别为齿圈旋转的圈数


和每圈的误差估计值。图 4(b) 为估计误差的最终收敛结果,根据计算出的误差估计值 $\Delta\hat{\theta}_i$,可以通过式(13)得到消除齿圈误差后的旋转角速度,在原始轮速信号的基础上消除齿圈误差,可得如图 4(c) 所示的前后轮速对比结果,截取 7~14 s 内轮速值。

$$\omega_i(k) \approx \frac{\theta_0 - \Delta\hat{\theta}_i}{\Delta t_i(k)} \quad (13)$$




(a) 旋转 50 圈的误差估计值

(a) Estimated error value for 50 rotations



(b) 最终误差估计结果

(b) Final error estimation result



(c) 轮速信号消除齿圈误差对比图

(c) Comparison diagram of wheel speed signals with ring gear error eliminated

图 4 均值滤波的齿圈误差估计结果

Fig. 4 Estimation results of ring gear error with mean filtering

通过去除齿圈误差,提高了轮速精度的同时也削弱了由齿圈误差引起的周期分量,降低了基频叠加对时域、频域信号的干扰。轮胎的齿廓通过霍尔传感器后产生脉冲信号,由此计算出的速度信号是基于事件触发,同时具有不相等的时间间隔。而谐振频率的估计需要对轮速进行频域分析,用于频谱估计的采样数据必须是时间间隔相等且长度有限的序列。使用线性插值对轮速信号进行重构,以获得具有均匀采样间隔的轮速信号。

排除车辆激烈驾驶工况,轮胎振动系统的输入可以

认为是路面白噪声,在路面白噪声激励下对轮胎振动系统的振动响应进行谱估计可知轮胎的周向固有频率在 30~60 Hz 范围内,在信号中加入带通滤波器以提取出该频域成分用于频率分析,其中二阶带通滤波器如式(14)所示, K 为滤波器增益, ξ 为阻尼系数。

$$G(s) = \frac{\xi K \omega s}{s^2 + \xi \omega s + \omega^2} \quad (14)$$

2.2 阿克曼转向模型

结合车辆结构参数设计阿克曼转向模型,以车轮的转角和车速之间的关系描述车辆的转向机制,使其在直行工况、小角度转向工况下均能够稳定计算 4 轮等效半径的差值。该模型的核心目的是确保在车辆转弯时,4 个车轮按照特定的角度旋转,使得所有车轮的路径都与转弯中心保持一致。图 5 为阿克曼转向模型示意图,其中 δ 表示前轮的转向角度, L_a 和 L_b 分别表示车辆车身的前部轴距与后部轴距, B_1 和 B_2 分别表示前后轴轮距, O 为理论回转中心。通过车辆的前轮转向角度 δ 来计算车辆的转弯半径,如式(17)所示,其中 R_1 和 R_{center} 分别是后车轴中心和车辆质心的转弯半径。




图 5 阿克曼转向模型示意图

Fig. 5 Schematic diagram of ackermann steering model

$$L = L_a + L_b \quad (15)$$

$$R_1 = \frac{L}{\tan(\delta)} \quad (16)$$

$$R_{center} = \sqrt{R_1^2 + L_b^2} \quad (17)$$

使用阿克曼转向模型修正轮速,根据每个车轮所在位置的转弯半径和其对应的几何关系,计算出每个车轮的转向半径与相对质心点转向半径的比值,分别为左前轮 β_{FL} 、右前轮 β_{FR} 、左后轮 β_{RL} 和左后轮 β_{RR} 。

$$\begin{cases} \beta_{FL} = \frac{\sqrt{(R_1 - B_1/2)^2 + L^2}}{R_{center}} \\ \beta_{FR} = \frac{\sqrt{(R_1 + B_1/2)^2 + L^2}}{R_{center}} \\ \beta_{RL} = \frac{(R_1 - B_2/2)}{R_{center}} \\ \beta_{RR} = \frac{(R_1 + B_2/2)}{R_{center}} \end{cases} \quad (18)$$

图 6 为转弯工况下前轮转角值对应的四轮比例值,假设左转时转角值为正,在转角值较大且为正时,FL 轮和 RR 轮的比例值绝对值比另两轮大,转角影响 4 轮轮速大小,使用式(18)的比例值消除转弯影响。




图 6 转弯工况下的 4 轮转速比值

Fig. 6 Four-wheel proportion values under turning condition

理论上前轮转角为 0 时 4 轮轮速完全相同,图 7 为经阿克曼计算前后的 4 轮轮速值,其工况为图 6 中 35~45 s 的前轮转角变化区间。从图中可看出转角为正时 FL 轮轮速按 β_{FL} 对应放大,此时 RR 轮轮速按 β_{RR} 对应缩小,依此在小转向场景下消除前轮转角带来的影响。

2.3 时域特征提取

本文使用深度学习实现胎压估计需先对轮速信号进行特征提取,根据时域和频域的特征输入分别设计神经网络。特征值选取结合 iTPMS 和 dTPMS,使用单个物理胎压传感器和 ABS 传感器,其中物理胎压传感器选取 FR 轮作为神经网络的准确胎压输入。时域信号特征值的获取在半径迭代法同轴半径对比的基础上加入同侧半径对比,获得 6 个时域特征值;频域信号特征值的获取先将轮速信号经过带通滤波处理,通过 FFT 从轮速信号中提取与胎压相关的频率特征值。

时域特征的提取通过阿克曼转向模型修正小转向工况下车身结构产生的轮速差,并计算滚动半径比值来表征转弯状况下的轮速滚动半径差异,其中比值选取如图 8 所示。在车辆实际运行中,轮胎的有效滚动半径无法直接测得,借助有效滚动半径与车轮滚动角速度之间的反比关系,修正后的 4 轮角速度如式(19)所示。

$$\begin{cases} \hat{\omega}_{FL} = \frac{\omega_{FL}}{\beta_{FL}}, \hat{\omega}_{FR} = \frac{\omega_{FR}}{\beta_{FR}} \\ \hat{\omega}_{RL} = \frac{\omega_{RL}}{\beta_{RL}}, \hat{\omega}_{RR} = \frac{\omega_{RR}}{\beta_{RR}} \end{cases} \quad (19)$$




图7 阿克曼修正前后的轮速值(转向角对应图6中35~45 s数据)

Fig. 7 Wheel speed values of four wheels before and after ackermann correction

(steering angle corresponds to data from 35~45 s in Fig. 6)




图8 滚动半径比值选取

Fig. 8 Selection of rolling radius ratio

右侧轮速对比差值 γ_2 , 并将同轴轮速差异表征值和同侧轮速差异表征值都纳入时域特征向量 $\mathbf{F}_1$, 同时在输入特征值中加入 FR 轮胎压值作为参考, 时域特征值如式(22)所示。以 FL 轮为例, FL 轮常压和单轮欠压至 1.8 bar 时域特征值的变化如图 9 所示。根据各轮常压和欠压的时域特征值作为时域深度网络估计器的训练集。

$$\mathbf{F}_1 = \left[P_{FR}, \gamma_1, \frac{\hat{\omega}_{FL}}{\hat{\omega}_{FR}}, \frac{\hat{\omega}_{RL}}{\hat{\omega}_{RR}}, \gamma_2, \frac{\hat{\omega}_{FL}}{\hat{\omega}_{RL}}, \frac{\hat{\omega}_{FR}}{\hat{\omega}_{RR}} \right] \quad (22)$$

经阿克曼模型修正后的轮速需要通过低通滤波从频谱中提取 0~10 Hz 的低频成分, 消除高频的噪声导致的噪声干扰。

2.4 频域特征提取

实车 ABS 信号以 200 Hz (5 ms) 的采样频率进行采样, 并通过 FFT 得到 4 轮的频率特征, 使用重心法提取固有频率。FFT 是一种高效计算离散傅里叶变换 (DFT) 的算法, 其具体实现方式和运算效率由基数 r 和信号点数 N 的组合决定, FFT 的频率分辨率 Δf 由采样频率 f_s 和 N 决定, 当采样频率 $f_s = 200$ Hz 且使用 256 点 FFT 时, $\Delta f = f_s / N \approx 0.78125$ Hz, 选择 256 点 FFT 即可保证 1 Hz 以内的频率精度。


FFT 通过将长序列的 DFT 分解为多个短序列的

$$\gamma_1 = \frac{R_{FR}}{R_{FL}} - \frac{R_{RR}}{R_{RL}} = \frac{\hat{\omega}_{FL}}{\hat{\omega}_{FR}} - \frac{\hat{\omega}_{RL}}{\hat{\omega}_{RR}} \quad (20)$$


式中: R_{FL} 、 R_{FR} 、 R_{RL} 、 R_{RR} 依次为 FL、FR、RL、RR 轮的有效滚动半径; $\hat{\omega}_{FL}$ 、 $\hat{\omega}_{FR}$ 、 $\hat{\omega}_{RL}$ 、 $\hat{\omega}_{RR}$ 依次对应轮的滚动角速度; $\hat{\omega}_{FR}$ 、 $\hat{\omega}_{FL}$ 、 $\hat{\omega}_{RL}$ 、 $\hat{\omega}_{RR}$ 依次为对应轮的角速度修正值; γ_1 为同轴轮速对比差值。

$$\gamma_2 = \frac{\hat{\omega}_{FL}}{\hat{\omega}_{RL}} - \frac{\hat{\omega}_{FR}}{\hat{\omega}_{RR}} \quad (21)$$

在同轴对比的基础上增加左右侧轮速对比, 设定左



(a) 4 轮胎压正常时的时域特征值
(a) Time-domain eigenvalues of four tires under normal tire pressure



(b) FL 轮缺压 1.8bar 时的时域特征值
(b) Time-domain eigenvalues of fl wheel when tire pressure drops to 1.8 bar

图 9 FL 轮的轮速对比估计值迭代结果
Fig. 9 Iterative results of wheel speed comparison estimation for FL wheel

DFT,利用旋转因子的周期性和对称性,FFT 中的核心基本运算是单元蝶形运算公式,式(23)为第 $m + 1$ 级蝶形运算公式,其中 $m = 0,1,\cdots,M - 1,M$ 为蝶形总运算级数, $k = 0,1,\cdots,N - r^{m+1}$ 为当前级蝶形组的起始索引, $s, l = 0,1,\cdots,r - 1$ 为输出和输入组内的偏移量, $A_m(i)$ 表示为第 m 级运算后索引为 i 的数据值, $W_N^{sl} = e^{-j\frac{2\pi sl}{N}}$ 为旋转因子。

$$A_{m+1}(k + s \cdot \frac{N}{r}) = \sum_{l=0}^{r-1} A_m(k + l \cdot \frac{N}{r}) W_N^{sl} \quad (23)$$

表 1 为 256 点 FFT 不同基的计算总运算量,其中基数 r 是将长度为 N 的序列不断地分解为长度为 N/r 的子序列,基数越高,蝶形运算复杂度增加,但复数加法和乘法的理论计算量减少,总蝶形单元个数也相应减少,因此选择 16~256 点 FFT 提取轮速信号的固有频率。

通过 FFT 获取均匀采样间隔的轮速信号的频率特征,并使用重心法提取共振频率,图 10 为 FL 轮在不同胎压时提取的共振频率值,可以看出胎压减小时频率值相应减小,根据各轮常压和欠压的频域特征值作为频域深度网络估计器的训练集。




图 10 FL 轮在不同胎压时的频率值
Fig. 10 Frequency values of FL wheel under different tire pressures

表 1 FFT 计算总运算量 ($N=256$)

Table 1 Table title in english FFT calculation total computation load ($N=256$)

基数 r	蝶形总运算级数 $M = \log_r N$	总蝶形单元个数 $\sum_{m=0}^{M-1} N/r^{m+1}$	蝶形单元旋转因子数 $r - 1$	复数乘法 $((r - 1)/r) N \log_r N$	复数加法 $N \log_r N$
2	8	32 640	1	1 024	2 048
4	4	5 440	3	768	1 024
16	2	272	15	400	512

在频域输入特征值中加入 FR 轮的胎压值作为参考,频域特征值如式(24)所示。

$$\mathbf{F}_2 = [P_{FR} f_{FL} f_{FR} f_{RL} f_{RR}] \quad (24)$$

根据各轮常压和欠压的频域值作为频域深度网络估计器的训练集。以 RR 轮为例,RR 轮常压和单轮欠压至 1.8 bar 时的频域特征值的变化如图 11 所示。

2.5 动力学状态检测与算法使能策略

为在全工况范围内实现最优的胎压估计性能,本文

设计了一套基于实时车辆动力学状态检测的智能使能策略。该策略通过监测车速、纵向加速度和转向角等传感器参数,自适应地选择最可靠的估计算法,从而在成本与性能之间取得平衡。

1) 决策变量与阈值设定

策略以 3 个可实时获取的车辆参数为输入,并设定相应阈值:

(1) 4 轮车速阈值 $V_{th} = 50$ km/h: 当车速低于此值时,




图 11 频域特征值迭代结果

Fig. 11 Iterative results of frequency domain eigenvalues

轮速信号的共振频率信噪比不足,不适用频域分析方法。速度大小符合国标所规定的在中高速行驶工况;

(2)纵向加速度阈值 $a_{x,th} = 0.15 \text{ g}$:此阈值确保车辆处于相对平稳的纵向运动状态,避免加减速对轮速频谱产生显著污染;

(3)转向角动态阈值:转向会导致左右轮速差增大,影响时域特征的准确性,同时也会对轮速信号的频谱产生调制。为适应不同车速下的转向特性,转向角阈值设计为随车速变化的线性函数:

$$\theta_{th}(V) = \max(\theta_{\min}, -kV + b) \quad (25)$$

式中: $\theta_{\min}$ 为最小阈值,用于限制高速下的最大允许转向角, $k = 0.13 \text{ deg/kph}$ 与 $b = 15 \text{ deg}$ 通过实车测试标定确定。

在算法实现中,直接使用来自 CAN 总线的方向盘转角信号 θ_{sw} 其与前轮实际转角 θ_w 的关系由转向系统传动比 $i = \theta_w / \theta_{sw}$ 决定,本试验车辆传动比如图 12 所示。

2) 使能逻辑与状态转移

基于上述决策变量,定义理想频域工况的布尔条件为:

$$Cond_{freq} = (V > 50) \& (|a_x| < 0.15) \& (|\theta_{sw}| < \theta_{th}(V)) \quad (26)$$

系统在每个控制周期 (10 ms) 内执行如下决策流程: 若 $Cond_{freq}$ 为真,选择基于频域特征的 DGRU 网络作为主输出源,同时并行运行但赋予基于时域特征的 DGRU 网络较低权重作为辅助验证。若 $Cond_{freq}$ 为假,选择基于时域特征的 DGRU 网络作为主输出源,频域估计器被禁用。




图 12 方向盘转角与前轮转角传动比

Fig. 12 Steering ratio between steering wheel angle and front wheel angle

基于上述决策变量,系统在每个运算周期内,执行如图 13 所示的逻辑流程,以自适应地选择最优的胎压估计特征。




图 13 胎压估计双通路选择策略流程图

Fig. 13 Flowchart of the dual-path selection strategy for tire pressure estimation

为防止在阈值附近因信号噪声导致算法频繁切换,本策略为关键决策变量设置了死区。以车速为例,设定中心阈值 $V_{th} = 50 \text{ kph}$ 及死区半宽 $\Delta V = 2 \text{ kph}$ 。则系统逻辑为:当车速持续高于 52 km/h 时,切换至频域算法;当车速持续低于 48 km/h 时,切换至时域算法;当车速处于死区范围内时,算法状态将锁定,不执行切换。对转向角阈值 $\theta_{th}(V)$ 亦采用相同的死区设计原则。该策略仅包含比较运算与简单逻辑,计算开销小,满足 TC397 微控制器任务周期的实时性要求,确保了系统响应的即时性与稳定性。

3 基于 DGRU 网络的胎压估计器

考虑到输入特征已经过预处理的,其时间步间的长期依赖已被前置的均值滤波等环节弱化,若直接采用标准门控循环单元网络处理此类特征,其内部的时序递归机制将带来不必要的计算开销。因此,本文提出一种 DGRU 网络变体,该变体保留了 GRU 的更新门和重置门结构,利用其强大的特征选择与非线性融合能力,同时移除其对历史隐藏状态 $\mathbf{h}_{t-1}$ 的依赖,使其退化为一个针对当前输入特征 $\mathbf{x}_t$ 进行瞬时映射的强非线性函数。这种设计在保持 GRU 核心优势的同时,显著降低了模型复杂度和计算延迟,适合于本文实时性要求严苛的车载嵌入式部署环境。

基于时域和频域特征分别构建 DGRU 神经网络模型,融合单个物理传感器胎压为基准,实现其余 3 个车轮胎压的准确估计。

3.1 基于时域特征的胎压估计器

图 14 为基于时域的胎压估计器网络结构简图,输入频域特征值 $\mathbf{F}_1$, 其中 DGRU 为退化门控循环单元,FC 为全连接层,BN 为批量归一化层,Threshold 为自定义激活函数如式(27)所示,输出为除 FR 轮的另外 3 个轮胎压力值。




图 14 基于时域特征的胎压估计器网络结构简图

Fig. 14 Schematic diagram of tire pressure estimator network structure based on time domain feature

GRU 作为 LSTM 的变体,通过更新门和重置门的协同作用调控序列数据特征的记忆与遗忘过程^[22],在状态检测中展现出显著优势。同时处理多个特征向量,适用于大规模数据集的处理及预测,有助于分析特征对输出结果的影响^[23]。

标准的 GRU 的基本公式为式(28),其中 $\mathbf{r}_t$ 和 $\mathbf{z}_t$ 为重置门和更新门, $\mathbf{h}_t$ 为时间步 t 的隐藏状态, $\tilde{\mathbf{h}}_t$ 为对应候选隐藏状态, $\mathbf{W}_i, \mathbf{b}_i, \mathbf{R}_i$ 分别为 reset 门、update 门和候选

隐藏状态的输入权重、偏置以及重置权重, $i = \mathbf{r}, \mathbf{z}$, $\tilde{\mathbf{h}}$ 。tanh 为双曲正切函数。序列长度为 T 时最终输出为 $\mathbf{h}_t$, 包含整个输入序列的信息。

$$\begin{cases} \mathbf{r}_t = \text{sigmoid}(\mathbf{W}_r \mathbf{x}_t + \mathbf{b}_r + \mathbf{R}_r \mathbf{h}_{t-1}) \\ \mathbf{z}_t = \text{sigmoid}(\mathbf{W}_z \mathbf{x}_t + \mathbf{b}_z + \mathbf{R}_z \mathbf{h}_{t-1}) \\ \tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_{\tilde{\mathbf{h}}} \mathbf{x}_t + \mathbf{b}_{\tilde{\mathbf{h}}} + \mathbf{r}_t \odot (\mathbf{R}_{\tilde{\mathbf{h}}} \mathbf{h}_{t-1})) \\ \mathbf{h}_t = (1 - \mathbf{z}_t) \times \tilde{\mathbf{h}}_t + \mathbf{z}_t \times \mathbf{h}_{t-1} \end{cases} \quad (28)$$

本文提出的 DGRU 是将 GRU 单元退化为一个无记忆的、前馈式的非线性变换层,但其核心的门控机制得以保留。使用门控机制进行动态的特征选择与融合,根据输入的不同调制信息流,比全连接层 (MLP) 具有更强的特征交互与表征能力。DGRU 原理如式 (29) 所示, DGRU 的模型结构相对简化,更关注当前特征输入与输出之间的映射关系,可以同时处理多个特征向量,实现输入与输出之间实时拟合的效果。而标准的 GRU 模型由于涉及到隐藏状态的更新和长期依赖关系的捕捉,模型结构和训练过程相对复杂。

$$\begin{cases} \mathbf{z}_t = \text{sigmoid}(\mathbf{W}_z \mathbf{x}_t + \mathbf{b}_z) \\ \tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_{\tilde{\mathbf{h}}} \mathbf{x}_t + \mathbf{b}_{\tilde{\mathbf{h}}}) \\ \mathbf{h}_t = (1 - \mathbf{z}_t) \tilde{\mathbf{h}}_t \end{cases} \quad (29)$$

3.2 基于频域特征的胎压估计器

轮速信号中的频域信息经过 FFT 和重心法提取后转换为了轮胎周向振动频率值,重心法的使用相当于直接对频率值在带通频带上进行滤波,使 4 轮频率信息转换为单一的直流量。因此,频域法胎压估计器不需要实现频域上的特征提取,仅需要完成频率值到胎压值的非线性映射。通过特征预提取方法,降低了神经网络计算出输入、输出信号之间关联的复杂性,大大降低了神经网络的复杂度,进而使得算法能够便于在车载嵌入式平台上运行,故采用与图 14 相同的神经网络结构。图 15 为基于频域的胎压估计器网络结构简图,输入频域特征值 $\mathbf{F}_2$ 。时域输入特征值 $\mathbf{F}_1$ 和频域输入特征值 $\mathbf{F}_2$ 均使用时序输入和特征输入 2 种模式。




图 15 基于频域特征的胎压估计器网络结构简图

Fig. 15 Schematic diagram of tire pressure estimator network structure based on frequency domain feature

4 实车测试

将算法部署在如图16所示已量产的电驱动乘用车上进行道路测试。神经网络数据集由该型号车辆的耐久试验数据组成,主要为城市道路日常驾驶工况。



图16 测试车辆图片

Fig. 16 Test vehicle picture

共采集9组实车数据,分别进行时域和频域特征提取,并训练深度学习估计器,其中1组数据中为4轮胎压均为2.6 bar,另外8组中分别有1个轮的胎压下降,为2.6和1.9 bar。

本文的测试标准为GB 26149-2017《乘用车轮胎气压监测系统的性能要求和试验方法》^[1],该标准的核心要求如下:

1) 快速漏气(胎压突降)报警要求:当某条轮胎胎压在1 min内下降至低于推荐冷压的70%时,系统应在小于10 min的行驶时间内发出明确的欠压报警信号;

2) 缓慢漏气(胎压缓降)报警要求:当某条轮胎的胎压在大于24 h内下降至低于推荐冷压的80%时,系统应在小于60 min的行驶时间内发出报警信号;

3) 胎压指示精度要求:对于提供胎压数值显示的系统,其显示值与实际值的误差应在 $\pm 10\%$ 范围内。

首先,验证系统基础合规性,即测试其在模拟快速漏气工况下的响应时间与估计精度是否满足国标要求;其次,针对当前基于深度学习的iTMS多集中于胎压状态分类,缺乏直接输出连续胎压值的能力这一现状,利用所提的DGRU模型与工况自适应策略评估系统的进阶性能;最后,分析系统整体鲁棒性,考察从信号预处理到深度学习估计器在真实噪声环境下的协同工作性能。


4.1 与传统iTMS标定方法的对比分析

为全面评估本文所提hTPMS的性能,将其与典型的iTMS所采用的阈值标定方法^[6]进行定量对比。这类方法仅提供胎压状态输出,无法给出连续的胎压估计值。针对经典的阈值标定法^[8]进行基于数据集的对比测试,使其在胎压数值估计误差的同一维度上与本文方法进行比较。该方法的核心是监测由轮胎滚动半径变化引起的轮速变化,时域法使用式(21)中的前后轴比值,频域法


使用式(24)中不同轮的频率值。

实际应用中,传统方法受阈值设定、工况单一、轮胎磨损等限制,性能通常低于本文模拟结果。除Formentin等的混合式TPMS^[11],达标时间约5 min外,鲜有直接从轮速信号回归胎压数值的公开方案,故本对比具有合理参照意义。

使用实车测试数据集计算2种传统方法和DGRU网络方法在不同单轮胎压缺压工况下的胎压估计值(除FR轮),并除以真实胎压值得到相对误差比值,结果如图17所示。在全部测试工况下,本文方法的估计误差绝对值均显著低于传统方法,传统方法的相对误差值较大,这反映了仅依赖单一滚动半径比、且基于线性假设的标定方法在应对实际复杂轮胎动力学时的局限性。本文方法得益于DGRU网络模型对多维度特征的融合能力,以及以单个物理传感器为基准的混合架构,显著提升了估计精度与鲁棒性。对比结果表明,即使在对传统方法理想化模拟的有利条件下,本文所提的方案在胎压数值估计精度上仍具有明显优势。



(a) DGRU和传统时域法的相对误差百分比
(a) The relative error percentage between DGRU and the Time-domain method



(b) DGRU和传统频域法的相对误差百分比
(b) The relative error percentage between dgru and the frequency-domain method

图17 本文方法与模拟传统方法胎压估计误差对比

Fig. 17 Comparison of tire pressure estimation errors between the proposed method and the simulated traditional method

4.2 基于时域的胎压估计验证

时域特征值在输入神经网络前加入了均值滤波,均

值滤波的长度导致拟合胎压值有延迟和波动。考虑到胎压从 2.6 bar 变为 1.9 bar 的实验受时间成本与环境控制限制,本文将 2 段工况整合,构建测试数据集,时域特征值的采集覆盖城市道路典型工况,车轮转速范围为 30~50 kph,以 10 ms 采样间隔对 ABS 轮速信号进行同步采集。该工况设置基于对轻型车辆城市道路行驶特性的统计,满足 GB/T 28046.2-2011 对车载传感器信号采样的要求。

图 18 为 FL 和 RL 轮分别单轮胎压突变情况下的 DGRU 和 GRU 网络的胎压估计值,图中后缀 DGRU 表示使用 DGRU 网络的实验结果,后缀 GRU 表示使用 GRU 网络的实验结果,后缀 Real 表示当前工况下的真实胎压值。工况分别为 FL 轮和 RL 轮胎压在 200 s 由 2.6 bar 突降至 1.9 bar,其余轮胎压波动较小,可看出使用 DGRU 网络比 GRU 网络的拟合速度快且波动小,DGRU 网络更适用于实时的胎压估计。




图 18 使用 DGRU 和 GRU 网络的胎压估计值(时域)

Fig. 18 Tire pressure estimated values using DGRU and GRU networks (time domain)

图 19 为由图 18 计算出的误差比例值,图 19(a)为 FL 轮胎压突变情况下的误差比例值,图 19(b)为 RL 轮胎压突变情况下的误差比例值,图中黑色点划线为相对目标值误差的 $\pm 5\%$ 。在 FL 轮胎压突变时,使用 DGRU 网络在 98.3 s 到达目标值,GRU 网络在 156.2 s 到达目标值,使用 DGRU 网络较 GRU 网络的响应速度提升 37.07%。在 RL 轮胎压突变时,DGRU 网络和 GRU 网络分别在 95.1 和 254.7 s 到达目标值,DGRU 网络较 GRU 网络的响应速度提升 62.66%。对于其他轮,DGRU 网络的拟合均在相对目标值误差的 $\pm 5\%$ 内,GRU 网络需捕捉长期依赖关系经过一段时间的计算才能达到要求。




图 19 使用 DGRU 和 GRU 网络的误差比例值(时域)

Fig. 19 Error proportion values using DGRU and GRU networks (time domain)

在嵌入式平台评估 2 种神经网络模型的 C 代码的资源占用特性,算法部署在主频为 300 MHz 的英飞凌 TC397 芯片上,作为目标硬件平台该芯片具备高性能嵌入式处理能力,适用于实时性要求较高的场景。实验采用 Trace32 调试工具对目标平台的 CPU 负载数据进行实时采集与记录,以确保数据的精准性和时效性。

图 20 为采样频率 100 Hz(10 ms)下 2 种神经网络输入的 CPU 运行时间占比,DGRU 网络的平均占比为 0.464%,GRU 网络的平均占比为 2.216%。该负载水平远低于目标硬件的算力冗余阈值,表明两种神经网络的运行均不会占用过多计算资源,为系统处理其他核心任务预留了充足算力,在单独运行场景下特征输入展现出

更优的轻量化特性;另一方面,该神经网络结构轻量化优化实现了更低的资源占用,更符合车载嵌入式设备对低功耗、高实时性的要求。





图 20 时序和特征输入的 CPU 运行时间占比
(10 ms 周期任务)

Fig. 20 CPU running time ratio of time-series input and feature input (10 ms periodic task)


4.3 基于频域的胎压估计验证

频域法使用的工况为车速 50~70 kph,频域特征值在输入神经网络前加入了均值滤波,同样导致拟合胎压值有相应的延迟。系统采用 5 ms 的 FFT 窗口与 10 ms 的神经网络输入窗口的组合架构,较短的 FFT 窗口通过提高时间分辨率减少了频谱泄漏,特别是在处理瞬态信号时能更精确地捕捉频率变化。神经网络输入采用 10 ms 输入即可使 DGRU 的门控机制在时间尺度内动态整合多尺度频域特征,使 DGRU 能够在保持 FFT 高精度频率检测能力的同时,有效建模相邻频谱间的时序依赖关系。特别地,10 ms 采样周期与典型车载传感器的输出频率(100~200 Hz)适配,能够完整捕获车辆动力系统的特征频率。

图 21 为基于频域的 FL 和 RL 轮分别单轮胎压突变情况下两种神经网络的胎压估计值,图中工况为单轮胎压在 200 s 突变。同样,使用 DGRU 网络比 GRU 网络的拟合速度快且波动小。



(a) FL 轮模拟胎压突变的胎压估计值
(a) Tire pressure estimated values for simulated sudden tire pressure changes of FL wheel




(b) RL 轮模拟胎压突变的胎压估计值
(b) Tire pressure estimated values for simulated sudden tire pressure changes of RL wheel

图 21 使用 DGRU 和 GRU 网络的胎压估计值(频域)

Fig. 21 Tire pressure estimated values using DGRU and GRU networks (frequency domain)

图 22 为图 21 计算出的误差比例值,图 22(a) 为 FL 轮胎压突变情况下的误差比例值,图 22(b) 为 RL 轮胎压突变情况下的误差比例值。在 FL 轮胎压突变时,DGRU 网络和 GRU 网络分别在 73.6 和 279.2 s 到达目标值,DGRU 网络的响应速度提升 73.63%。在 RL 轮胎压突变时,DGRU 网络和 GRU 网络分别在 87.2 和 206.4 s 到达



(a) 四轮胎压正常时的频域特征值FL轮胎压突变情况下的误差比例值
(a) Error proportion values under sudden tire pressure change of FL tire

(b) RL 轮胎压突变情况下的误差比例值
(b) Error proportion values under sudden tire pressure change of RL tire

图 22 使用 DGRU 和 GRU 网络的胎压估计值(频域)

Fig. 22 Error proportion values using DGRU and GRU networks (frequency domain)

目标值,DGRU 网络的响应速度提升 57.75%。频域法特征值数目少于时域法,且神经网络结构相同,因此并未对频域法的 CPU 运行时间进行分析。

频域法与时域法相比,明显缩短了响应时间,且使用特征输入的响应速度和波动更小。在时域法和频域法中,基于深度学习的胎压估计器都能够在胎压发生突变的情况下,快速、准确地反映胎压变化。尤其是在不同胎压工况下,所提出的系统能够有效地抑制噪声干扰,减少由轮速传感器和物理胎压传感器误差引起的影响,提供可靠的实时胎压估计。

5 结 论

本文提出将退化 GRU 网络与混合轮胎压力监测系统结合,旨在解决传统直接式胎压监测系统物理传感器成本高、间接式需手动校准基准值的问题。通过均值滤波修正齿圈误差、阿克曼转向模型拓展半径迭代法的工况适应性,构建了融合单个物理胎压传感器 ABS 轮速传感器信号的双路径监测框架。针对时域与频域分别设计 DGRU 神经网络估计器,结合滚动半径比值与 FFT 共振频率特征,实现了胎压的实时高精度估计。实车测试结果表明,本文提出的基于深度学习的混合式胎压监测系统在城市工况下具有较高的准确性与稳定性,当胎压从 2.6 bar 突降至 1.9 bar 时,频域特征输入模式的响应时间最快达 73.6 s,胎压估计误差控制在 $\pm 5\%$ 以内,所有测试工况均满足国标 GB 26149-2017 要求。所提出方法被部署在 Aurix TC397 上,完成了多种工况下道路测试,较传统 dTPMS 减少了 75%的物理传感器成本,同时通过深度学习算法提升了复杂工况下的监测鲁棒性。该研究为胎压监测技术提供了融合建模与智能算法的解决方案,验证了深度学习在汽车传感器信号融合中的工程价值。未来可进一步引入多种传感器数据优化特征空间,推动胎压监测系统向智能化、集成化方向发展。需要指出的是,本文方法存在一定的局限性,受实车试验条件与周期所限,仅验证了系统对快速胎压突降工况的响应性能。对于国标 GB 26149-2017 中缓慢漏气工况(如 24 h 内胎压下降超过标称值 10%),尚未进行系统性验证。这是由于在真实道路环境中,难以精确、安全且可重复地模拟线性缓慢的泄压过程。针对此局限,未来的研究工作将重点聚焦于搭建高精度的轮胎压力可控实验台架,或设计更长期的实车数据采集方案,以完整覆盖所有测试场景,同时进一步拓展测试工况至持续高速巡航与恶劣路况,以全面评估系统的极端环境鲁棒性,推动其满足未来智能汽车对传感器系统全工况、高可靠性的严苛要求。

参考文献

[1] 王兆,陈平,邓湘鸿,等.乘用车轮胎气压监测系统

的性能要求和试验方法[S]. GB 26149-2. 中华人民共和国国家质量监督检验检疫总局;中国国家标准化管理委员会,2017.

WANG ZH, CHEN P, DENG X H, et al. Performance requirements and test methods of tire pressure monitoring system for passenger cars [S]. GB 26149-2. General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China; Standardization Administration of the People's Republic of China, 2017.

[2] YANG S, CHEN Y, SHI R, et al. A survey of intelligent tires for tire-road interaction recognition toward autonomous vehicles [J]. IEEE Transactions on Intelligent Vehicles, 2022, 7(3): 520-532.

[3] 符气叶,李法春,周景川,等.直接型汽车轮胎压力监测系统设计[J].安徽电子信息职业技术学院学报,2014,13(6):17-21.

FU Q Y, LI F CH, ZHOU J CH, et al. Design of direct tire pressure monitoring system for automobiles [J]. Journal of Anhui Vocational College of Electronics & Information Technology, 2014, 13(6): 17-21.

[4] LI T. Intelligent tire and autonomous electric vehicle[M]. 2023: 589-615.

[5] 苏静.基于轮速特征分析的胎压估计算法研究[D].长春:吉林大学,2017.

SU J. Research on tire pressure estimation algorithm based on wheel speed feature analysis [D]. Changchun: Jilin University, 2017.

[6] ZHAO J, DU J, ZHU B, et al. Indirect tire pressure monitoring method based on the fusion of time and frequency domain analysis [J]. Measurement, 2023, 220: 113282.

[7] KANG J. Robust estimation method of tire torsional resonance frequency to detect decrease in tire inflation pressure[J]. Vehicle System Dynamics, 2022, 60(7): 2358-2374.

[8] 罗新帅.基于轮胎滚动半径和频域特征的间接式胎压监测算法研究[D].长春:吉林大学,2021.


LUO X SH. Research on indirect tire pressure monitoring algorithm based on tire rolling radius and frequency domain features[D]. Changchun: Jilin University, 2021.

[9] KIM J, LIM D G, JUNG W, et al. Condition monitoring of intelligent tires utilizing 1D CNN and vibration measurement [C]. Health Monitoring of Structural and Biological Systems XVIII: SPIE, 2024: 129511H.

[10] 于璐,唐亮,魏凌涛,等.基于机器学习的间接式胎压监测算法研究[J].汽车安全与节能学报,2022,13(2):290-299.

- YU L, TANG L, WEI L T, et al. Research on indirect tire pressure monitoring algorithm based on machine learning [J]. *Journal of Automotive Safety and Energy*, 2022, 13 (2): 290-299.
- [11] FORMENTIN S, ONESTO L, COLOMBO T, et al. h-TPMS: A hybrid tire pressure monitoring system for road vehicles[J]. *Mechatronics*, 2021, 74: 102492.
- [12] WANG X, CHEN Z, CAO W, et al. Artificial neural network-based method for identifying under-inflated tire in indirect TPMS [J]. *IEEE Access*, 2020, 8: 213799-213805.
- [13] KOST A, ALTABEY W, NOORI M, et al. Applying neural networks for tire pressure monitoring systems[J]. *Structural Durability & Health Monitoring*, 2019, 13: 247-266.
- [14] WEI L, WANG X, LI L, et al. A low-cost tire pressure loss detection framework using machine learning [J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(12): 12730-12738.
- [15] MARTON Z, SZALAY I, FODOR D. Convolutional neural network-based tire pressure monitoring system[J]. *IEEE ACCESS*, 2023, 11: 70317-70332.
- [16] VASAN V, VENKATESH S N, SREELATHA A, et al. Tire condition monitoring using transfer learning-based deep neural network approach [J]. *Sensors*, 2023, 23: 2177.
- [17] MUTURATNAM A, VENKATESH S N, SREELATHA A, et al. Enhanced tyre pressure monitoring system for nitrogen filled tyres using deep learning[J]. *Machines*, 2023, 11: 434.
- [18] ARORA S, VENKATESH S N, SUGUMARAN V, et al. Enhancing tire condition monitoring through weightless neural networks using mems-based vibration signals[J]. *Journal of Engineering*, 2024, 2024.
- [19] QIU J, LIN Y, ZWETSLOOT I M. An LSTM-based predictive monitoring method for data with time-varying variability [J]. *International Journal of Production Research*, 2025, 63(7): 2622-2637.
- [20] G S, PRASAD S K, A S, et al. Influence of unbalance on tyre pressure monitoring system based on C-GRU approach [C]. 2023 7th International Conference on Electronics, Communication and Aerospace Technology (ICECA). 2023: 565-570.
- [21] 张锋. 基于扭转刚度的轮胎压力监测方法研究[D]. 淄博: 山东理工大学, 2007.
- ZHANG F. Research on tire pressure monitoring method based on torsional stiffness [D]. Zibo: Shandong University of Technology, 2007.
- [22] ZENG X, CHEN W. A hybrid model integrating GRU with artificial rabbit optimization for stock price prediction[J]. *International Journal of Intelligent Computing and Cybernetics*, 2025: 18 (2): 418-443.
- [23] SINGH V, SAHANA S, BHATTACHARJEE V. A novel CNN-GRU-LSTM based deep learning model for accurate traffic prediction [J]. *Discover Computing*, 2025, 28(1): 28-38.

作者简介



朱元, 1998 年于清华大学获得学士学位, 2003 年于清华大学获得博士学位。现为同济大学汽车学院副教授, 主要研究方向为电动驱动系统的控制和参数识别、高速 PMSM、以及嵌入式软件系统。

E-mail: yuan.zhu@tongji.edu.cn

Zhu Yuan received his B. Sc. degree from Tsinghua University in 1998 and Ph. D. degree from Tsinghua University in 2003. Now he is an associate professor at the College of Automotive Studies, Tongji University. His main research interests include control and parameter identification of electric drive systems, high-speed permanent magnet synchronous motors (PMSM), and embedded software systems.



窦雨琪, 2022 年于西南交通大学获得学士学位, 现为同济大学硕士研究生, 主要研究方向为车辆状态参数辨识。

E-mail: 2332985@tongji.edu.cn

Dou Yuqi received her B. Sc. degree from Southwest Jiaotong University in 2022. Now she is M. Sc. candidate at Tongji University. Her main research interests include vehicle state parameter identification.



徐世寒 (通信作者), 2019 年于沈阳理工大学获得学士学位, 2022 年于合肥工业大学获得硕士学位, 现为同济大学博士研究生, 主要研究方向为 PMSM 的参数识别、多相 PMSM 的故障诊断技术和车辆动力学。

E-mail: sh_xu@tongji.edu.cn

Xu Shihan (Corresponding author) received his B. Sc. degree from Shenyang Ligong University in 2019, M. Sc. degree from Hefei University of Technology in 2022. Now he is a Ph. D. candidate at Tongji University. His main research interests include parameter identification of PMSM, fault diagnosis technology for multiphase PMSM, and vehicle dynamics.