

基于多尺度特征的路面不平度识别方法^{*}张娜¹ 吴信元¹ 赵强² 彭文韬¹

(1. 黑龙江科技大学电气与控制工程学院 哈尔滨 150022; 2. 东北林业大学机电工程学院 哈尔滨 150040)

摘要: 在智能驾驶技术中,路面不平度识别的结果直接影响着后续驾驶的决策过程。然而,现有的路面不平度识别算法存在准确率低、识别速度慢的问题。针对这一现状,提出了一种基于改进多尺度特征提取网络的隐马尔科夫路面不平度识别方法。该方法在识别准确率和识别速度上均取得了显著提升。首先,改进的多尺度卷积神经网络被用于从原始数据中自动学习并提取多层次的特征。然后,利用 t-SNE 技术对提取的特征进行可视化处理,以便更好地理解和分析特征分布。最后,利用隐马尔科夫模型对提取的特征进行识别。实验结果表明,对于仿真数据和实际采集数据识别准确率分别达到了 99.6% 和 98.6%,适用于路面不平度识别。

关键词: 智能驾驶;路面不平度;多尺度特征提取;隐马尔科夫模型

中图分类号: TN911.72 **文献标识码:** A **国家标准学科分类代码:** 520.2

Pavement roughness identification method based on multi-scale features

Zhang Na¹ Wu Xinyuan¹ Zhao Qiang² Peng Wentao¹

(1. School of Electrical and Control Engineering, Heilongjiang University of Science and Technology, Harbin 150022, China;

2. School of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China)

Abstract: In the field of autonomous driving technology, the identification of pavement roughness directly influences subsequent driving decision-making processes. However, existing algorithms for pavement roughness recognition suffer from issues of low accuracy and slow recognition speed. Addressing this challenge, a Hidden Markov Model based pavement roughness recognition method is proposed, leveraging an improved multi-scale feature extraction network. Significant enhancements in both recognition accuracy and speed are achieved by an enhanced multi-scale convolutional neural network, which autonomously learns and extracts hierarchical features from raw data. Subsequently, t-SNE visualization is applied to the extracted features for improved understanding and analysis of feature distributions. Finally, a Hidden Markov Model is utilized for feature recognition. Experimental results demonstrate recognition accuracies of 99.6% for simulated data and 98.6% for real-world collected data, thereby proving effective for pavement roughness recognition.

Keywords: intelligent driving; pavement roughness; multi-scale feature extraction; Hidden Markov Model

0 引言

在传感技术发展的帮助下,汽车工业正在向智能化和自动驾驶时代发展^[1-2]。路面不平度作为车辆行驶过程中的主要激励源,对乘车人员舒适性和车辆操纵稳定性有着直接影响。路面不平度的准确识别能对悬架调节提供先验信息,提高车辆操纵稳定性和乘车舒适性^[3-5]。目前,路面不平度识别方法主要分为 3 种类型:接触式测量、非接触式测量^[6]和基于车辆响应的方法^[7-9]。接触式测量一般需要

专用路面测量仪,且要求测试车辆低速行驶,在高速时容易造成测量错误。此外,安装额外的路面测量仪存在成本较高,检测效率低等问题,限制其大规模应用。非接触式测量方法相较于接触式测量更先进,实时性好、准确性高,但也存在成本高昂、设备结构复杂等问题,在雾霾等复杂环境下识别准确率较低。基于车辆响应的方法是利用车载传感器获取车辆的相关信息,间接识别路面不平度。随着车载传感的不断发展,该方法易于应用,无需特殊测量仪器就有着较高的识别精度。

收稿日期:2024-05-23

^{*} 基金项目:黑龙江省普通高校毕业生创新创业人才培养计划项目(UNPYSCT-2020034)、黑龙江省省属本科高校基本科研业务费青年创新人才培养计划(2022-KYYWF-0561)、黑龙江省重点研发项目(JD22A014)资助

基于车辆响应识别路面不平度的方法可分为基于模型的识别方法和基于数据驱动的识别方法。基于模型的识别方法是将车辆的振动响应和路面不平度联系起来,通过估计车辆动力学模型的参数来识别路面不平度。主要方法有卡尔曼滤波、构建观测器法等。李韶华等^[10]基于1/4车辆模型,提出了考虑车身加速度的GA-LSTM自适应卡尔曼滤波识别方法。刘浪等^[11]基于半车模型,提出了一种考虑车辆加速度的增广卡尔曼滤波算法,实现路面不平度的识别。张青霞等^[12]基于半车模型,提出了利用车辆动态响应识别路面不平度的方法。但是,基于模型的识别方法其准确性依赖于所建立模型的准确性。对于数据驱动的识别方法,不依赖车辆模型,而是通过训练建立已知路面和对应的车辆响应信息之间的映射关系,然后基于此关系进行路面不平度识别。Xu等^[13]建立1/4车辆模型,以车身加速度作为输入,通过残差卷积网络实现路面不平度识别。Jeong等^[14]提出了一种深度学习IRI估计方法,使用匿名车辆并通过智能手机测量的响应作为道路粗糙度传感器。薛俊俊等^[15]提出了一种注意力门控循环单元网络和车辆振动响应的路面不平度等级识别算法。Janani等^[16]建立了基于加速度值的IRI和功率谱密度之间的模型实现道路等级识别。

上述基于车辆响应的识别方法中,基于模型的识别方法十分依赖于所建立模型的精确程度,实际车辆的复杂性和多变的路况使得构建模型较为困难,同时高精度的模型通常伴随着较高的计算复杂度,难以保证实时性。随着轮胎传感技术的发展,一些研究已经探索了在轮胎布置压力传感器,用以获取更精确的路面信息,并取得了显著效果^[17-20],但并未将其应用于路面等级识别中。因此,本文提出了一种使用轮胎压力传感器数据进行路面等级识别的方法,分别利用改进多尺度卷积神经网络和隐马尔可夫模型(hidden markov model, HMM)在数据特征学习和模式识别方面较强的能力,提出了一种基于改进多尺度特征提取网络的隐马尔科夫路面不平度识别方法,并分别使用通过Matlab-Carsim获取的仿真数据和实际采集数据对模型进行了验证。该方法使用改进多尺度卷积神经网络(multi scale convolutional neural network, MSCNN)对数据进行特征提取,通过多个并行卷积同时从不同尺度提取特征,最后,利用HMM实现路面不平度识别。

1 路面不平度识别方法

1.1 仿真数据采集

路面相对于基准面的高度沿着道路走向的变化称为路面不平度函数,通常使用路面不平度功率谱描述路面统计特性。路面不平度函数由路面、参考面和道路方向的水平相对高度的变化来定义。路面不平度函数是随机的,通常被认为是平均值为0且服从正态分布,并且可以用功率谱密度来表示其特性。国际标准ISO 8608:2016采用功率

谱密度作为路面等级分级的标准,表达式如下:

$$G_q(n) = G_q(n_0) \left(\frac{n}{n_0}\right)^{-\omega}$$

(1)

式中: n 为空间频率, n_0 为参考空间频率, $G_q(n_0)$ 为路面不平度系数, ω 为频率指数。

该标准基于 $G_q(n_0)$ 几何平均值和标准化路面分类的上下限,表1给出了A-E类路面的取值范围。

表1 路面不平度分级标准

Table 1 Grading standard for pavement roughness

路面等级	下限	几何平均值	上限
A	8	16	32
B	32	64	128
C	128	256	512
D	512	1 024	2 048
E	2 048	4 096	8 192

白噪声路面激励模型建立的基本思想:将路面高程的随机波动抽象为满足一定条件的白噪声,然后经过一个假定系统进行适当变换而拟合出路面随机不平度的时域模型。其表达式如下:

$$\dot{z}_g(t) = -2\pi n_1 v z_g(t) + 2\pi n_0 \sqrt{G_q(n_0) v} w(t)$$

(2)

式中: $\dot{z}_g(t)$ 为路面激励, n_1 为截止空间频率, v 为车速, $w(t)$ 为均值为0、功率谱密度为1的理想单位白噪声。

通过Matlab-Carsim仿真实现数据获取,其中Carsim是专门针对车辆动力学的仿真软件,其可以设置不同路面和车型通过仿真获取车辆相关数据。如图1所示,首先按照式(2)和表1,采用滤波白噪声法通过Matlab仿真获取不同等级的路面数据。然后将得到的路面数据输入到Carsim中仿真获取车辆行驶时的轮胎垂向力数据。其中车速为20 m/s,仿真数据采集在A-E五个等级下进行,采样频率为50 Hz,以10 s仿真数据为一个样本,构建的数据集包含10 000个样本,每个路面类别包含2 000个样本。如表2所示,数据按照训练集:验证集:测试集=6:2:2划分。

表2 路面不平度等级数据集

Table 2 Data set of pavement roughness grade

路面等级	训练/验证/测试	标签
A	1 200/400/400	1
B	1 200/400/400	2
C	1 200/400/400	3
D	1 200/400/400	4
E	1 200/400/400	5

1.2 多尺度特征提取网络

网络整体结构如图2所示,目前在路面不平度识别中,仍然需要越来越丰富和全面的特征来保证稳定可靠的识别

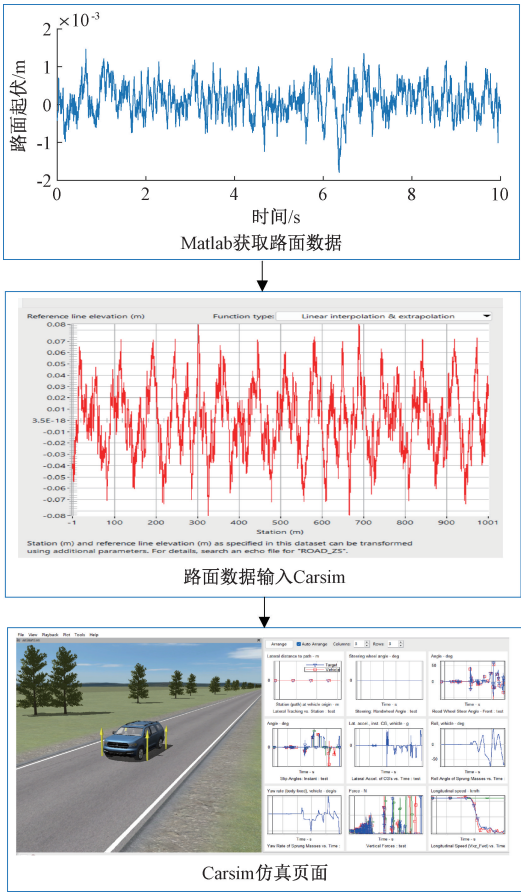


图 1 数据采集流程

Fig. 1 Data acquisition process

效果。为了更好地提取数据中特征,提出了一种改进的多尺度特征提取网络,这种方法改善了由于单一尺度卷积核的粗略分割、不同尺度特征简单拼接或仅增加层数以提取特征所导致的特征遗漏问题。

所示网络结构中,并行使用两个相同的特征提取网络分支,每个分支由两个多尺度残差卷积块、三个池化层、一个卷积层、一个注意力机制组成。最后,将两个并行的多尺度特征提取网络的输出连接起来作为主干网络的输出。注意力机制能够动态地调整对输入数据各部分的关注程度,通过学习得到的权重参数对输入数据进行加权,使得网络能够集中于数据关键部分,从而提高网络对输入数据的处理效率和性能并增强网络的表达能力,使其能够更好地捕捉输入数据之间的相关性和复杂关系。

多尺度残差卷积块能够有效捕捉不同尺度特征,从而获得更丰富的信息,提高网络的性能。多尺度残差卷积块结构如图 3 所示。当数据输入到多尺度残差卷积块中,同时进行 $1 \times 3, 1 \times 5, 1 \times 7$ 三个不同尺度的卷积运算,提取不同尺度的特征。

同时,为了防止出现过拟合,避免网络模型退化的问题,在多尺度残差卷积块中增加了残差单元,其通过引入跳跃连接允许信息在层间传递,使网络更有效地学习特征。残差单元将输入 x 直接添加到多尺度残差卷积块的输出 y 中。当输入 x 经过 3 个不同尺度的卷积核输出后,将三个部分的输出连接起来,即对应元素点相加,而多尺度残差卷积块的输出如下:

$$y = \text{Conv}_3 + \text{Conv}_5 + \text{Conv}_7 + x \quad (3)$$

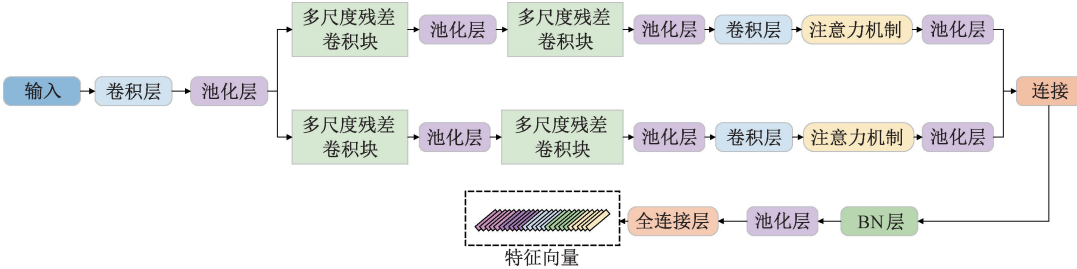


图 2 多尺度特征提取总体框架

Fig. 2 Overall framework for multi-scale feature extraction

1.3 隐马尔科夫模型

基于 HMM 的路面不平度识别模型建立流程如图 4 所示。

隐马尔科夫模型是一种时间序列的概率模型,它描述一条隐马尔科夫链来生成不可观测的状态序列。该模型有很强的动态时间序列建模能力,能够很好地利用时间上下文信息。根据隐马尔科夫模型在评估问题中的解决思路,识别路面不平度需要对每个等级路面建立模型,将所有路面不平度等级的模型构成识别模型库,如图 5 所示。在本文中需要识别 A~E 5 个等级的路面不平度,因此组成如下式:

$$\lambda = \{\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5\} \quad (4)$$

在训练过程中,每个路面等级的 HMM 模型参数初始化为:

$$\lambda = (\pi, A, B) \quad (5)$$

式中:初始概率 $\pi = (\pi_i)$ 表示了隐含状态 S 在初始时刻的概率分布,状态转移概率矩阵 $A = [a_{ij}]_{N \times N}$ 描述了所有状态之间的概率转移关系,观测概率矩阵 $B = [b_j(k)]_{N \times M}$ 描述了状态与观测之间的概率转移关系。

首先,将经过多尺度特征提取网络得到的特征记为 o ,输入到初始化模型中,用于更新模型参数,观测序列样本可描述为:




图 3 多尺度残差卷积块

Fig. 3 Multi-scale residuals convolution block




图 4 HMM 识别模型建立

Fig. 4 HMM recognition model establishment

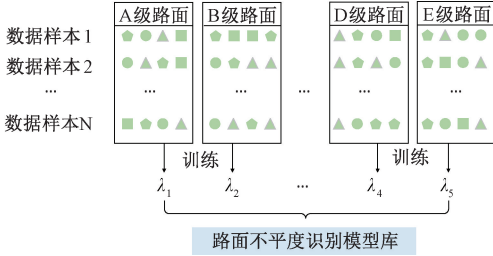


图 5 路面不平度识别模型库

Fig. 5 Pavement roughness recognition model base

$$o = [o_1, o_2, \dots, o_i, \dots, o_T] \quad (6)$$

在更新阶段假设每个观测特征序列相互独立,将特定事件的所有观测样本的联合概率分布计算为给定模型下观测集中所有序列样本概率的乘积。

$$P(O|\lambda) = \prod_{i=1}^g P(o_i|\lambda) \quad (7)$$

式中: g 为观测集的特征向量个数。

然后根据 Baum-Welch 算法更新 HMM 参数以找到最大联合概率 $P(O|\lambda)$ 。在识别过程中将测试样本输入至 HMM 模型库中,根据前向-后向算法计算测试样本在每个 HMM 模型中的输出似然概率 $P(o|\lambda_i)$,最后比较每个路面不平度模型计算得到的概率,概率的大小反应序列与 HMM 模型对应路面等级的相似程度,将概率最大的模型判断为其对应路面不平度等级。

2 结果与分析

2.1 路面不平度识别总体方案

本文所提出的路面不平度识别方法总体流程如图 6 所示,包括数据采集,对数据进行多尺度特征提取,将提取得到的特征向量作为观测序列输入到 HMM 模型实现对路面不平度等级的识别。




图 6 识别总体框架

Fig. 6 Identification global framework

2.2 多尺度特征提取

本次实验采用的硬件环境为: Intel(R) Core(TM) i5-10300H CPU、NVIDIA GeForce RTX 1650 Ti GPU、内存 16 G;软件环境为: Matlab R2024a 软件, Deep Network Designer 深度学习框架。

网络将通过前向学习和后向更新来完成训练过程。在学习过程中,训练数据在网络中前向传播,得到该类别的预测概率,与样本的真实概率进行比较,计算损失值。这里使用交叉熵作为损失函数,得到的交叉熵损失值代表真实类别和预测类别之间的差异。为了提高模型的收敛速度和精度,对数据集进行了归一化处理。在更新过程中,计算损失的梯度,并使用特定的学习率更新模型参数,遵循后向传播算法。损失值将迭代减小,直到差异几乎消失或模型收敛。当模型训练好后,保存最优模型,旨在将数据信号转换为一组特征向量。最优模型输出的特征序

列将作为 HMM 模型的观测序列输入。网络采用 Adam 优化器,激活函数采用 ReLU 函数,学习率初始值为 0.001,epoch 为 140,每次迭代的批大小为 64。图 7 所示为特征可视化结果。

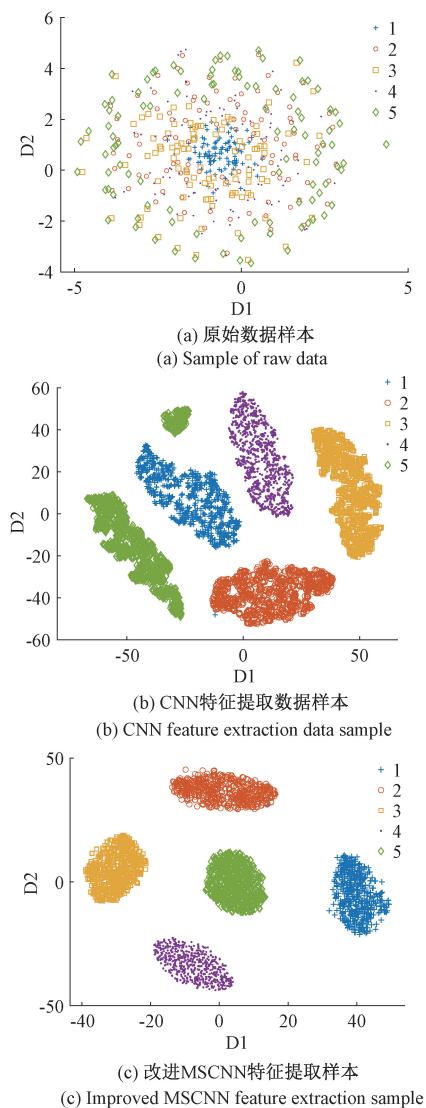


图 7 数据可视化

Fig. 7 Data visualization

五个路面等级数据经过 CNN 和改进 MSCNN 提取后特征的可区分性如图 7 所示。特征通过 t-SNE 技术映射到 2D 空间可视化,经过 CNN 和改进 MSCNN 特征提取后的特征可视化如图 7(b)和(c)所示,明显改进 MSCNN 的特征提取能力更好。在图 7(b)中虽然有着明显的类间距离,但是存在同一类别样本被分成两部分的情况,且有个别样本并没有被区分出来。图 7(c)中每种类别之间有着很好的类间距离并且显示了 5 个边界清晰的聚类中心,证明了改进 MSCNN 模型提取特征的有效性。

2.3 仿真数据结果分析

经过多尺度特征提取得到的特征向量将作为 HMM

模型的观测序列输入进行训练,设置最大迭代次数为 50,迭代中止条件为达到最大迭代次数或误差小于阈值。最后,将最终获得的模型参数保存在 HMM 库中,作为该路面等级的最优模型,其他路面等级的 HMM 模型也以该方式构建。当使用 HMM 识别时,将未知道路数据经过特征提取后输入 HMM 模型库中,将最大输出结果作为识别结果,如图 8 所示。

使用测试集对本文所提出的改进 MSCNN-HMM 模型进行测试,每个等级数据各 400 组。图 8 中(a)~(e)5 个子图说明了 5 种路面等级的识别输出结果。在图 8(a)中对于 A 级路面,其样本点明显高于其他类别,这说明 A 级路面被很好的识别了出来。在图 8(b)中分别有两个样本被错误识别成 A 级路面。图 8(c),图 8(d)中所识别样本高于其他类别,并未出现识别错误的情况。图 8(f)为本次测试的混淆矩阵,其中展示了预测结果与真实结果之间的关系,对角线中的数字表示识别结果与真实结果相吻合,识别准确率最低的 E 级路面也达到了 99.0%。

2.4 实际数据结果分析

使用上述仿真数据对本文模型进行了初步验证。随后,为进一步验证模型在实际应用中的有效性,进行了实际数据的采集并进行验证。如表 3 所示,为依据《公路工程技术标准》(JTG B01-2014)对实际路面等级的划分。由于 D、E 等级路面比较少见,目前仅采集黑龙江科技大学校区中常见的 A~C 3 个路面等级下的数据。采集路面如图 9 所示。

传感器被布置在轮胎轮毂和胎面之间,如图 10 所示。实际采集数据构造的数据集包含 357 个样本数据,其中 A 级 128 个,B 级 119 个,C 级 110 个。

利用实际数据对路面不平度等级识别模型进行测试,结果如图 11 所示。

在图 11(b)有一个 A 级路面的样本点明显高于其他类别样本,这表明实际为 B 级路面的样本被错误识别为 A 级路面。在图 11(a)和图 11(c)中所识别样本曲线明显高于其他类别,没有出现识别错误的情况。同时混淆矩阵如图 12,可以看出,模型的预测类别与真实类别较为接近,误差较小。主要的错误识别在 B 级路面,这可能是因为相邻的两级路面数据特征相似性较高,使得模型将其混淆,导致小部分样本识别错误的情况。

为了评估所提出的改进 MSCNN-HMM 模型性能,进一步对模型进行了十次测试试验。十次试验的分类准确率如图 13 所示。

本文所提方法与 CNN-LSTM,CNN,SVM 四种模型 10 次测试的平均准确率分别为 98.3%、94.3%、91.5%、83.2%。这意味着本文所提出的改进 MSCNN-HMM 模型是其中表现最好的。

此外,还评估了上述四种模型的识别时间成本。如图 14 所示,四种模型对样本的平均识别时间为,SVM:0.009 9 s,

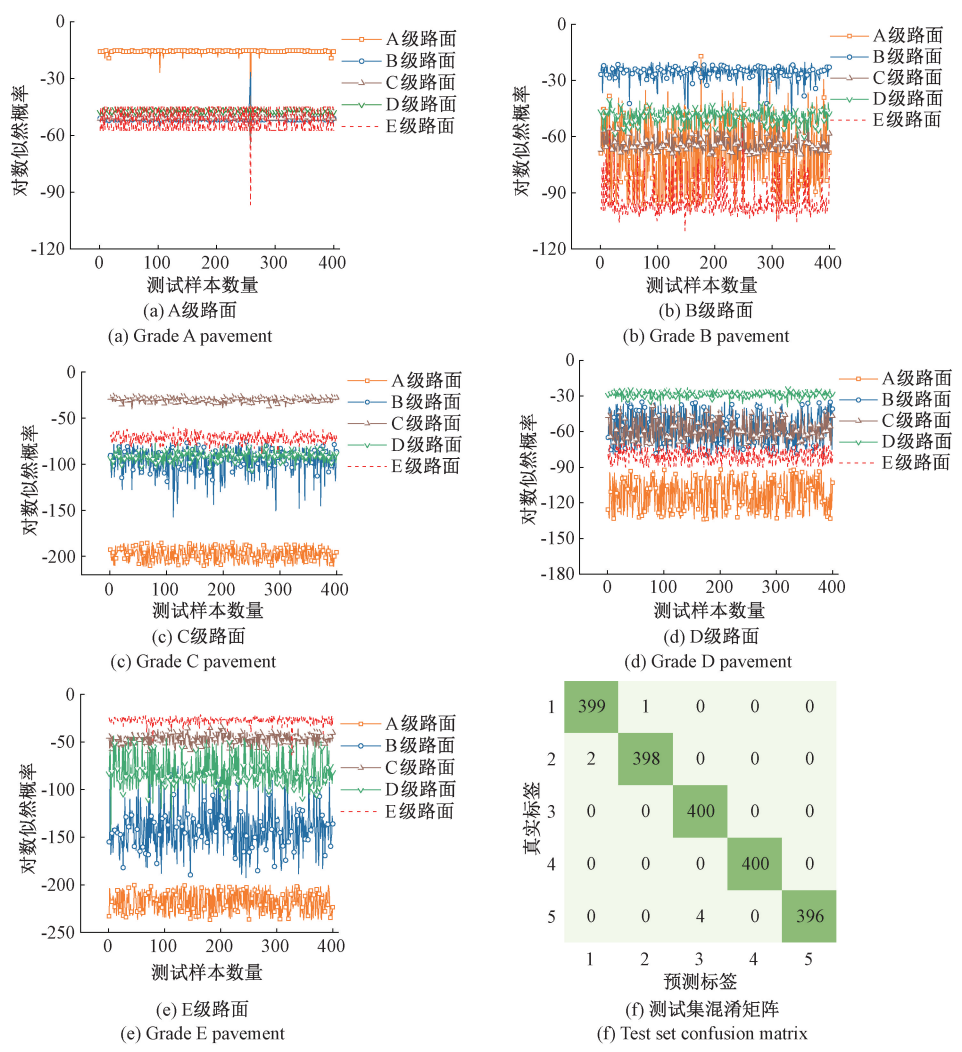


图 8 HMM 识别结果

Fig. 8 HMM recognition result

表 3 路面等级划分标准

路面等级	实际路面
A	没有明显凹凸适合高速行驶路面
B	有轻微凹凸但仍能提供相对安全的行驶条件
C	有明显凹凸的碎石、土路
D	较多 10 cm 的凹凸石块,10 cm 深的长距离泥路
E	20 cm 深的长距离泥路、积雪路面,坡度 23 以下的碎石路面

CNN:0.000 6 s,CNN-LSTM:0.000 3 s,改进 MSCNN-HMM:0.000 23 s。四种模型中,本文所提方法的识别速度最快,同时有着最好的识别准确率。对于需要考虑实时性的路面不平度识别,该模型在识别速度和准确性上均有优势。




图 9 实际数据采集

Fig. 9 Actual data acquisition

2.5 消融实验

将改进 MSCNN-HMM 模型在实际采集数据集上与以下几种模型进行消融实验:常规的 MSCNN-HMM 模型、仅包含多尺度残差卷积块(MSRCB)的 MSCNN-HMM-M 模型、仅包含注意力机制(Attention)的 MSCNN-HMM-A 模型。消融实验结果如表 4 所示。

与 MSCNN-HMM 模型相比,加入多尺度残差卷积块



图 10 轮胎传感器
Fig. 10 Tire sensor

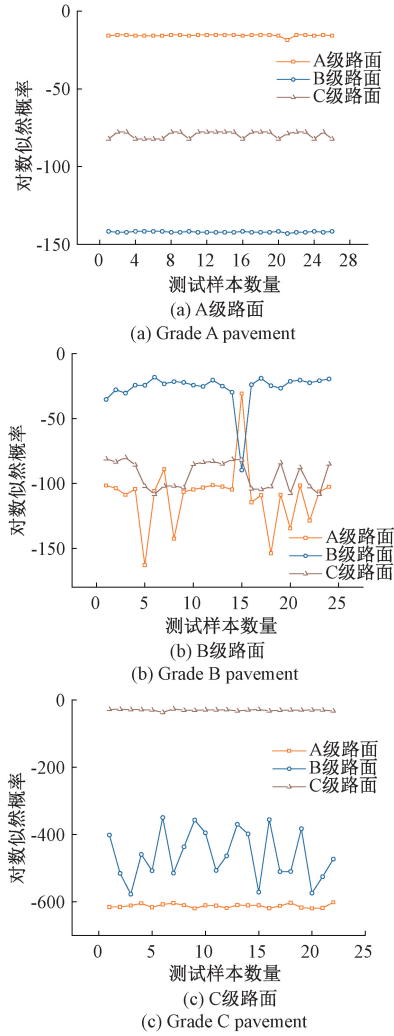


图 11 HMM 识别结果
Fig. 11 HMM recognition result

和注意力机制模型的准确率分别提高了 1.4% 和 2.8%，证明了多尺度残差卷积和注意力机制的有效性。结果表明，同时引入多尺度残差卷积和注意力机制对模型识别路面等级有着显著提升，能有效减少识别结果的误判。




图 12 混淆矩阵
Fig. 12 Confusion matrix




图 13 十次试验样本分类准确性
Fig. 13 Classification accuracy of ten tests

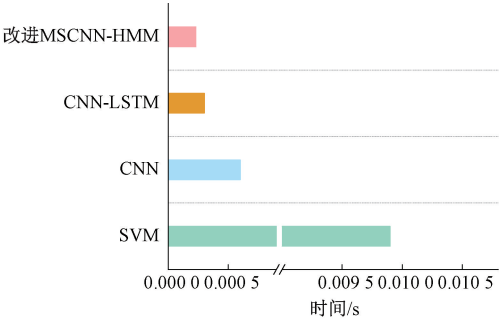


图 14 四种模型识别时间成本
Fig. 14 Four models identify time costs

表 4 消融实验
Table 4 Ablation experiment

	MSRCB	Attention	准确率
改进 MSCNN-HMM	✓	✓	98.6%
MSCNN-HMM-A	×	✓	97.2%
MSCNN-HMM-M	✓	×	95.8%
MSCNN-HMM	×	×	94.4%

3 结 论

针对现有路面不平度识别准确率和识别速度问题，提出了一种基于改进 MSCNN-HMM 的路面不平度识别方

法。其中改进 MSCNN 网络能够提取数据中的多尺度特征,然后利用 HMM 进一步挖掘所提取特征中的序列信息,提高识别性能。该方法利用了 MSCNN 和 HMM 在数据特征提取和模式识别方面较强的能力。结果表明改进 MSCNN 有着比传统 CNN 更优异的特征提取能力。此外所提方法有着出色的识别速度,这对有着时间要求的路面不平度识别而言有着明显优势。在仿真数据和实际采集数据上识别准确率分别达到了 99.6% 和 98.6%。因此,本文提出的模型能够准确识别路面不平度等级,为后续车辆动力学控制的参数调整提供有效依据。

参考文献

- [1] 李海青,李永福,郑太雄,等.智能汽车拟人驾驶风险量化方法研究[J].电子测量与仪器学报,2023,37(8):120-127.
LI H Q, LI Y F, ZHENG T X, et al. Research on human-like driving risk quantification method for intelligent vehicles [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (8): 120-127.
- [2] ENTEZARI M S, GOLROO A. A review on the impacts of connected vehicles on pavement management systems [J]. International Journal of Pavement Engineering, 2023, 24(1): 2246093.
- [3] 潘公宇,冯鑫,王万青.主动悬架多目标切换控制策略研究[J].电子测量技术,2023,46(18):67-75.
PAN G Y, FENG X, WANG W Q. Research on multi-objective switching control strategy of active suspension[J]. Electronic Measurement Technology, 2023, 46(18): 67-75.
- [4] 潘公宇,范菲阳,冯鑫.基于主动悬架的整车车身姿态控制策略研究[J].电子测量技术,2024,47(2):79-88.
PAN G Y, FAN F Y, FENG X. Research on the whole vehicle attitude control strategy based on active suspension[J]. Electronic Measurement Technology, 2024, 47(2): 79-88.
- [5] 寇发荣,郭杨娟,刘朋涛,等.基于路面等级识别的车辆半主动悬架内外环控制[J].噪声与振动控制,2024,44(2):171-177.
KOU F R, GUO Y J, LIU P T, et al. Semi-active suspension inner and outer ring control of vehicles based on pavement grade recognition[J]. Noise and Vibration Control, 2024, 44(2): 171-177.
- [6] 刘秋,孙晋伟,张华,等.基于卷积神经网络的路面识别及半主动悬架控制[J].兵工学报,2020,41(8):1483-1493.
LIU Q, SUN J W, ZHANG H, et al. Road identification and semi-active suspension control based on convolutional neural network [J]. Acta Armamentarii, 2020, 41(8): 1483-1493.
- [7] GUO W, ZHANG J, MURTAZA M, et al. An ensemble learning with sequential model-based optimization approach for pavement roughness estimation using smartphone sensor data [J]. Construction and Building Materials, 2023, 406: 133293.
- [8] JANANI L, DOLEY R, SUNITHA V, et al. Precision enhancement of smartphone sensor-based pavement roughness estimation by standardizing host vehicle speed [J]. Canadian Journal of Civil Engineering, 2022, 49(5): 716-730.
- [9] AFSHARNIA H, GHAVAMI S M. Comparison of smartphone-based and drone-based approaches for assessing road roughness[J]. Transportation Research Record, 2024, 2678(2): 24-34.
- [10] 李韶华,李健玮,冯桂珍.基于 GA-LSTM 自适应卡尔曼滤波的路面不平度识别[J].振动与冲击,2024,43(9):121-130.
LI SH H, LI J W, FENG G ZH. Road roughness recognition based on GA-LSTM adaptive kalman filtering[J]. Journal of Vibration and Shock, 2024, 43(9): 121-130.
- [11] 刘浪,张志飞,鲁红伟,等.基于增广卡尔曼滤波并考虑车辆加速度的路面不平度识别[J].汽车工程,2022,44(2):247-255,297.
LIU L, ZHANG ZH F, LU H W, et al. Road roughness identification based on augmented kalman filtering with consideration of vehicle acceleration[J]. Automotive Engineering, 2022, 44(2): 247-255, 297.
- [12] 张青霞,侯吉林,安新好,等.基于车辆脉冲响应的路面不平度识别方法[J].吉林大学学报(工学版),2023,53(6):1765-1772.
ZHANG Q X, HOU J L, AN X H, et al. Road roughness identification method based on vehicle impulse response [J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(6): 1765-1772.
- [13] XU J, YU X. Pavement roughness grade recognition based on one-dimensional residual convolutional neural network[J]. Sensors, 2023, 23(4): 2271.
- [14] JEONG J H, JO H, DITZLER G. Convolutional neural networks for pavement roughness assessment using calibration-free vehicle dynamics[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(11): 1209-1229.
- [15] 薛俊俊,陈双.基于深度学习的路面不平度等级识别研究[J].机电工程技术,2021,50(11):66-69.

XUE J J, CHEN SH. Research on road roughness level recognition based on deep learning [J]. Mechanical & Electrical Engineering Technology, 2021, 50(11): 66-69.

[16] JANANI L, SUNITHA V, MATHEW S. Influence of surface distresses on smartphone-based pavement roughness evaluation [J]. International Journal of Pavement Engineering, 2021, 22(13): 1637-1650.

[17] EMON M O F, CHOI J W. Flexible piezoresistive sensors embedded in 3D printed tires [J]. Sensors, 2017, 17(3): 656.

[18] MENG X, ZHANG C, XIE H, et al. A continuous pressure positioning sensor with flexible multilayer structures based on a combinatorial bionic strategy [J]. Advanced Functional Materials, 2024, 34(17): 2314479.

[19] MATSUBARA M, TOYOSHIMA T, SHISHIDO H, et al. Measurement of the three-directional contact force using a smart tire with a force sensor [J]. Vehicle System Dynamics, 2024: 1-15.

[20] LI Z, LI K, WANG W, et al. Ultrawide linear range, high sensitivity, and large-area pressure sensor arrays enabled by pneumatic spraying broccoli-like microstructures [J]. Materials Horizons, 2024, 11(9): 2271-2280.

作者简介

张娜, 讲师, 硕士生导师, 主要研究方向为车辆动力学与控制。
E-mail: 2018800587@usth.edu.cn

吴信元(通信作者), 硕士研究生, 主要研究方向为模式识别。
E-mail: wu190135@163.com

赵强, 教授, 博士生导师, 主要研究方向为车辆动力学及控制。
E-mail: zhaoqiang@nefu.edu.cn

彭文韬, 硕士研究生, 主要研究方向为图像处理。
E-mail: 1131771348@qq.com