

文章编号: 2095-4980(2022)01-0016-07

基于大数据的复杂环境下调制分类方法

师长立^{1,2}, 韦统振^{1,2}, 吴理心^{*1}, 叶泽雨^{1,2}, 尹靖元^{1,2}

(1.中国科学院 电工研究所, 北京 100190; 2.中国科学院大学, 北京 100049)

摘要: 随着频率使用设备的激增和大数据时代的到来, 频谱管理和控制面临着有效性和准确性的挑战。调制分类技术是频谱管理和控制的基础, 也是其关键部分。因此, 在大数据场景下进行有效的调制分类技术非常重要。本文不仅考虑了大数据背景下分类模型的有效性, 还考虑了复杂电磁环境中噪声的动态性。因此, 构建了一个包含不同信噪比下不同信号的大数据集, 并利用大数据驱动深度学习模型, 最终得到调制分类的结果。该方法只需训练一个模型即可实现调制分类, 避免了以往算法中模型训练的冗余。仿真结果验证了该方法的有效性和可靠性。

关键词: 大数据; 非高斯噪声; 调制分类; 深度学习

中图分类号: TN914.3

文献标识码: A

doi: 10.11805/TKYDA2021189

Modulation classification based on big data in complex environment

SHI Changli^{1,2}, WEI Tongzhen^{1,2}, WU Lixin^{*1}, YE Zeyu^{1,2}, YIN Jingyuan^{1,2}

(1.Institute of Electrical Engineering, Chinese Academy of Sciences, Beijing 100190, China;
2.University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: With the proliferation of frequency-using devices and the advent of the era of big data, spectrum management and control are faced with challenges of effectiveness and accuracy. Modulation classification technology is the foundation and key part of spectrum management and control. Therefore, the effectiveness of modulation classification technology in big data scenario is very important. This paper considers not only the validity of the classification model under the background of big data, but also the dynamics of noise in the complex electromagnetic environment. A big dataset containing different signals under different Mixed Signal-to-Noise Ratios(MSNR) is constructed, and the big data is utilized to drive the Deep Learning model, and the classification results are finally obtained. The proposed method can realize modulation classification by training just one model, which avoids the redundancy of model training in previous algorithms. The simulation results demonstrate the effectiveness and reliability of the proposed method.

Keywords: big data; non-Gaussian noise; modulation classification; deep learning

自动调制分类是物理层传输技术的关键部分, 分类后的信号调制类型为后续的信号处理奠定了基础, 该技术广泛用于5G、物联网和电子战等诸多领域。随着无线通信场景的日益复杂, 影响调制分类算法的因素越来越多, 单一场景下的识别算法不再适用。因此, 开发对环境适应性强的调制分类算法是非常重要的^[1]。研究发现, 调制分类算法主要分为两类: 基于深度学习的自动分类算法和人工计算分类算法^[2]。人工计算分类算法主要分为: 基于似然比(Likelihood ratio Based, LrB)算法和基于特征提取(Feature Extraction Based, FEB)算法。LrB算法主要计算并比较不同信号的似然函数值, 从而获得较高的分类准确率, 但代价也较高, LrB算法的似然函数复杂, 计算量大, 一些通信系统难以承受; 同时 LrB算法的适应性较差, 需要大量的先验知识, 且参数是在一定条件下推导出来的, 只适用于特定场景。FEB算法在计算复杂度上有很明显的提高, 且信号特征易于提取, 在先验知识较少的情况下, 将 FEB算法提取的参数与机器学习分类器进行匹配, 能获得较好的识别性能。但 FEB算法通常是根据特定的信号样本提取特征并设定决策算法, 因此受信道环境的影响^[3-4]。

收稿日期: 2021-05-08; 修回日期: 2021-06-02

基金项目: 国防基础科研计划资助项目(JCKY2019130C002)

*通信作者: 吴理心 email:wulixin@mail.iee.ac.cn

近年来,随着深度学习的发展,深度学习在物理层的应用也应运而生。在物理层传输的基础上,利用深度学习实现调制分类技术是目前研究的热点。深度学习首先将接收到的信号转换成数据集,然后将数据集发送至深度学习网络进行自动分类,得到分类结果^[5]。将深度学习用于信号的调制分类,避免了人工特征提取和选择,降低了特征对环境的敏感性;深度学习模型是数据驱动的,需要大量的数据训练模型,且可以通过设备轻松获取通信信号,满足深度学习网络的输入条件;深度学习的方法符合当前的研究趋势,具有更多的探索价值。

深度学习已应用到调制分类中。文献[6]首次提出将信号域转换成图域,利用星座图的几何关系识别调制类型,并构造不同信号的星座图使其具有不同的特点。文献[3]研究了信号生成星座图的影响因素,包括数据的转换方法、图片大小和图片的像素大小,并分析了不同深度学习网络下的识别性能。在文献[6]提出的星座图变换方法的基础上,随后的几位作者对算法和结构进行了改进。文献[4]提出了一种点密度方法来对星座图进行着色,利用辅助分类器遗传对抗网络对数据进行增强,并使用卷积神经网络(Convolutional Neural Networks, CNN)模型对数据进行分类,准确率可以提高 0.1%~6%。据此,本文采用基于深度学习的自动调制分类方法。

除算法之外,许多学者也研究了不同噪声对调制分类的影响,主要包括高斯噪声和非高斯噪声。高斯白噪声常用来模拟理想的噪声环境,对信号分类的影响相对较小。随着信道环境的日益复杂,高斯白噪声不足以描述信道的特性,基于高斯噪声进行仿真时建立的分类模型性能下降。考虑到信道质量的恶化,使用非高斯噪声模拟实际噪声环境的算法层出不穷。在处理非高斯白噪声时,有两种方法:一种是对色噪声进行白化,另一种是将非高斯噪声定义为一种广义高斯分布,即适用于描述通信信道的噪声的 Alpha 稳定分布(Alpha-Stable Distribution, ASD)噪声。目前几乎所有的算法都是在单噪声环境下进行,但单噪声设置有一定的局限性。在实际的通信过程中,存在着许多不确定因素,给通信系统的决策带来挑战。信噪比通常用来衡量接收信号中信号与噪声之间的关系,信噪比对信号分类有一定的影响。目前采用基于深度学习的算法对信号进行分类,将每个信噪比下的每个数据集发送到深度学习网络中训练一个模型,并以多个信噪比训练多个模型。如果将所有信噪比下的数据集同时馈入深度学习网络,则得到的分类结果将更有说服力^[6]。

为避免自动调制分类协同计算中信息质量不均的问题,本文提出两种信号转换方法:采用基于深度学习的自动调制分类方法,结合大数据样本驱动的深度学习模型来获得更好的分类结果。在信号产生过程中,模拟噪声包括高斯噪声和非高斯噪声,并考虑了不同非高斯度的噪声。多信噪比条件下的所有数据集一起发送到网络进行分类。所提出的方法在高斯噪声和非高斯噪声下均能获得较好的性能,对噪声具有较强的包容性^[7]。

1 系统模型

1.1 系统组成

在非合作通信中,接收端不知道信号的先验信息。传统调制分类算法的步骤如图 1 所示,主要包括信号预处理、特征提取和分类。此外,为了匹配分类模型,还需要估计当前信道的信噪比^[8]。




Fig.1 Traditional modulation classification steps
图 1 传统的调制分类步骤

传统方法中的调制分类算法操作步骤复杂,模型训练繁琐。本文提出的方法如图 2 所示,接收到的信号经过预处理后送入神经网络,神经网络自动提取特征并进行分类。该算法避免了信噪比估计的冗余,只需要训练一个模型,大大降低了算法的复杂度^[9]。




Fig.2 The proposed modulation classification steps
图 2 改进的调制分类步骤

1.2 信号模型

通常,接收到的信号(数字信号)表示为:

$$x(t) = s(t) + n(t) \quad (1)$$

式中： $x(t)$ 和 $s(t)$ 分别表示接收信号和发射信号； $n(t)$ 为模拟环境中的噪声，包括高斯噪声和非高斯噪声^[10]。

1.3 噪声信号模型

Alpha 稳定分布(ASD)是高斯分布的一种广义形式，也是实际无线通信系统中的主要误差源。由于它在概率分布和峰值脉冲特性方面的稳定性，可用来准确地描述实际无线通信环境中噪声的统计特性。

ASD 的本征函数可表示为：

$$\phi(\theta) = \exp\left\{j\mu\theta - \gamma|\theta|^\alpha \left[1 + j\xi \operatorname{sgn}(\theta)\omega(\theta, \alpha)\right]\right\} \quad (2)$$

式中： $\omega(\theta, \alpha) = \begin{cases} \tan(\pi\alpha/2), & \alpha \neq 1 \\ (2/\pi)\log|\theta|, & \alpha = 1 \end{cases}$ ， $\alpha(0 < \alpha \leq 2)$ 为特征指数，表示稳定分布的集中程度， α 值越小，对应的稳定分布越集中，即脉冲特性越强； $\xi(-1 \leq \xi \leq 1)$ 为一个偏态参数，用来衡量稳定性分布是否具有对称特征； μ 为用来确定稳定分布位置的位置参数； $\gamma \geq 0$ 为尺度参数，用来测量稳定分布的宽度； $\operatorname{sgn}(\cdot)$ 为符号函数，定义为：

$$\operatorname{sgn}(\theta) = \begin{cases} 1, & \theta > 0 \\ 0, & \theta = 0 \\ -1, & \theta < 0 \end{cases} \quad (3)$$

由于 ASD 噪声的二阶统计矩不存在，无法表示其方差，传统意义上的信噪比(SNR)并不完全符合 ASD 噪声，因此混合信噪比(MSNR)的定义如下：

$$MSNR = 10 \lg \left(\frac{\delta_s^2}{\gamma} \right) \quad (4)$$

式中 δ^2 为信号方差。

值得注意的是，ASD 可看作是高斯分布的一种推广，高斯分布本身具有一种特殊的性质。当 $\alpha=2$ 时， α 稳定分布退化为高斯分布。因此，本文所设的 α 值包含了0~2之间的一些采样点。当 $\alpha=2$ 时，认为当前噪声为高斯白噪声；当 $\alpha \neq 2$ 时，认为当前噪声是非高斯噪声。 α 越小，非高斯特征越强^[11]。

1.4 深度学习网络

深度学习的本质是通过构建具有多隐藏层和大量训练数据的机器学习模型来学习更多有用的特征，从而提高分类或预测的准确性。因此，“深度模型”是一种手段，“特征学习”是一种目的。深度学习强调模型结构的深度、特征学习的重要性。通过逐层特征变换，将原始空间中的样本特征表示转化进入新的特征空间，使其更易于分类或预测。与通过人工规则构造特征的方法相比，利用大数据学习特征更能够描绘数据丰富的内部信息。

CNN 是前馈神经网络的一种，对图像处理具有独特的影响，在结构上至少包括卷积层和池化层。CNN 是近年来发展起来的一种深度学习网络，受到了企业的广泛关注和应用。代表性的 CNN 模型包括 AlexNet, VGG, LeNet 等。因为本文数据集图片内容相对简单，因此使用经典的 CNN 模型 AlexNet。

2 调制分类方案

基于深度学习的调制分类框架如图 2 所示，接收到的信号经过信号处理后转换成图像，并发送到 CNN 进行自动分类。在将信号转换成图像的过程中，会出现干扰问题，因此本文主要在信号处理阶段对算法进行改进。

2.1 数据转换

星座图是信号的二维几何特征。本文利用复信号生成星座图。值得注意的是，ASK 信号是虚部为 0 的复信号，经过复噪声叠加后仍具有二维特征。

采用点密度法对星座图进行着色。第 i 个符号在每个样本 $\rho(i)$ 中的点密度计算如下：

$$\rho(i) = \frac{\sum_{j=1}^L f[|m(i) - m(j)| < r \ \&\& \ |n(i) - n(j)| < r]}{L} \quad (5)$$

式中： $m(i)$ 为第 i 个符号的横轴值； $n(i)$ 为第 i 个符号的纵轴值； L 为样本的符号个数； r 为计算点密度时所选正方形区域长度的一半。

2.2 存在的问题

实际环境中，噪声往往具有峰值和脉冲突发特性。这类噪声最显著的特点是其代数尾部比高斯分布的指数尾部粗，概率密度函数的幅值明显高于高斯分布的幅值。因此，单一的高斯分布模型不能完全描述这种脉冲噪声。理论研究表明，ASD 噪声的特殊性质可以有效地描述真实环境中的噪声。ASD 噪声的散点图如图 3 所示，可以看到方框圈出的尖锐噪声点。由于 ASD 噪声不具有二阶和高阶的统计特性，传统的时频特征和统计特征提取方法不适用于该噪声。

将文献[6]中的高斯白噪声替换为 ASD 噪声，图中集中的部分受到噪声的影响，出现不规则跳动，原有的几何特征丢失，因此无法看到 QPSK 信号的星座点。

ASD 的尖脉冲噪声对信号星座图的特征提取和分类有很大影响，本文主要任务是在信号域转化为图域之前对尖脉冲进行预处理，抑制或去除尖脉冲。

2.3 算法改进

由于噪声具有严重的拖尾和尖锐的脉冲，且信号的幅值处于稳定的范围内，因此本文提出一种既能抑制尖锐噪声点，又能在一定范围内提高弱值的灵敏度的方法——对数。对数是一种常用的统计方法，它的主要作用是根据一定的基数对大值点进行弱化，同时提高微小值的灵敏度，可以解决当前的问题。本文直接对接收的复序列进行对数运算，生成星座图。将原始星座图映射到对数域，形成对数星座图，这种方法称为直接对数(D-Log)法。

假设接收到的复信号为 $x_n = a_n + ib_n$ ，也可以表示为：

$$a_n + ib_n = \sqrt{a_n^2 + b_n^2} (\cos \theta_n + i \sin \theta_n) \quad (6)$$

式中： $\cos \theta_n = \frac{a_n}{\sqrt{a_n^2 + b_n^2}}$ ； $\sin \theta_n = \frac{b_n}{\sqrt{a_n^2 + b_n^2}}$ 。

根据欧拉公式 $e^{i\theta} = \cos \theta + i \sin \theta$ 对 x_n 进行自然对数运算，可得

$$\ln(a_n + ib_n) = \ln \left[\sqrt{a_n^2 + b_n^2} (\cos \theta_n + i \sin \theta_n) \right] = \ln \left(\sqrt{a_n^2 + b_n^2} \right) + \ln \left[(\cos \theta_n + i \sin \theta_n) \right] = A_n + i\theta_n \quad (7)$$

式中 A_n 为实数。

由于 θ 可以相加无数个周期，理论上会有无数个解，但在数学运算中通常只选取单位周期内的角度值。根据对数的换底公式，可以得到任意底数的对数值。

$$\log_m(X) = \frac{\log_n(X)}{\log_n(m)} \quad (8)$$

式中： m 为想要改变的底数； n 为已知的底数。为了在很大程度上抑制噪声的尖锐值，本文假设 $m=10$ 。

3 算法仿真实验

对直接对数算法进行仿真实验。实验主要包括 3 个内容：a) 未知信噪比下的分类结果；b) 不同 α 条件下的分类结果，即高斯噪声和非高斯噪声下的分类结果。其中 $\alpha=2$ 为模拟高斯噪声环境，其他参数代表不同非高斯度的噪声；c) 与传统基于特征提取的调制识别方法进行比较。

3.1 数据集构建

采用 Matlab 生成信号并仿真数据集，利用其自身的深度学习网络工具箱对数据集进行分类，生成分类结果的混淆矩阵和准确率曲线。在此，通过一些仿真实验来验证改进算法的有效性。实验中使用的信号包括 2ASK,4ASK,8PSK,QPSK,OQPSK,16QAM 和 64QAM。每个接收信号的实部和虚部包括 5 000 个采样点，




Fig.3 Scatter diagram of Alpha-stable distribution noise
图 3 Alpha 稳定分布噪声散点图

dataset				
BPSK	QPSK	OQPSK	8PSK	16QAM
0 dB	0 dB	0 dB	0 dB	0 dB
2 dB	2 dB	2 dB	2 dB	2 dB
4 dB	4 dB	4 dB	4 dB	4 dB
6 dB	6 dB	6 dB	6 dB	6 dB
8 dB	8 dB	8 dB	8 dB	8 dB
⋮	⋮	⋮	⋮	⋮
16 dB	16 dB	16 dB	16 dB	16 dB

Fig.4 Dataset construction
图 4 数据集构建

用于生成图像。每个信号在相同的信噪比或相同的 α 值下生成 500 幅仿真图像,将这些图像放入 AlexNet 中,70% 用于训练,30% 用于测试,如图 4 所示,构建了一个包含大量数据的数据集。数据集用每种信号类型进行标记,其中每个信号包含多个信噪比下的数据。同样的方法用于构建 α 的数据集。

3.2 训练模式

如图 5 所示,在传统的调制分类方法中,无论使用哪种分类器,都是在每个信噪比下训练一个模型。这意味着模型训练需要多次迭代。同时,为了在验证过程中匹配模型,需要估计当前的 MSNR。可见,这种方法不仅操作过程非常繁琐,而且模型训练也很冗余。

如图 6 所示,将本文提出的算法中构造的混合信噪比作为数据集同时输入网络中,只需进行一次模型训练。训练后的模型可用于多种信噪比环境。同时,该方法避免了估计信噪比的步骤。

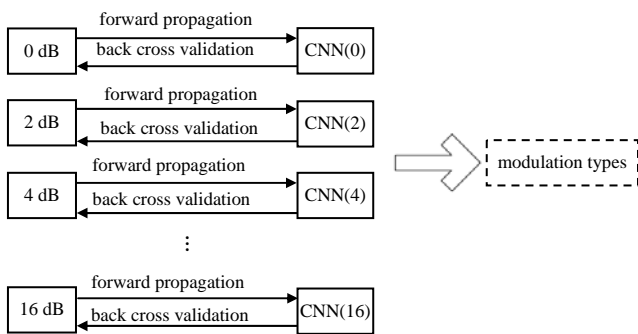


Fig.5 Training pattern of traditional modulation classification method
图 5 传统调制分类方式的训练模式

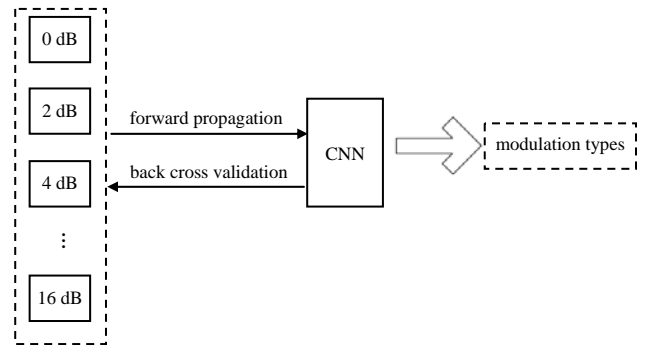


Fig.6 Training pattern of the proposed modulation classification method
图 6 改进的调制分类方式的训练模式

3.3 不同 MSNR 条件下的仿真

D-Log 算法下的实验包括 16QAM, BPSK, QPSK, OQPSK 和 8PSK 信号。MSNR 的范围为 0~16 dB, 步长为 2。 α 值设置为 1.6。每个信号在不同 MSNR 下生成 500 个图像数据集。将同一信号在不同 MSNR 下的数据集视为同一标签,将不同的信号作为不同的标签。其中 70% 的数据用于训练模型,20% 的数据用于测试结果,10% 的数据用于验证集。

一般来说,对不同 MSNR 的数据分别进行训练,得到测试数据的分类结果,在一定程度上缺乏通用性。本实验中,不同信号的数据集在不同的 MSNR 下同时训练,只需要训练一个模型。在 0~16 dB 的混合信噪比范围内,在未知信噪比下使用该模型可以获得较好的分类效果。

D-Log 算法下的模型训练过程如图 7 所示,从图 7 可以看出,在 D-Log 算法下,验证集的准确率随批量数据损失值的下降而波动,达到 9 个训练周期后,训练结果趋于稳定。稳定阶段的损失值越低,验证集的精确度越高。




Fig.7 Model training under D-Log method
图 7 D-Log 算法下的模型训练

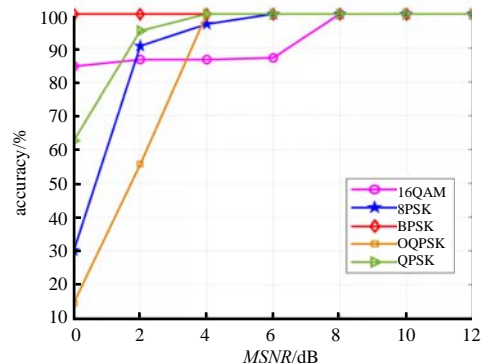


Fig.8 Test results of different MSNRs in D-Log trained model
图 8 D-Log 训练模型中不同 MSNR 的测试结果

将不同信噪比下的数据分别发送至训练模型进行测试。不同信噪比下 D-Log 法测试分类结果如图 8 所示。可以看出, QPSK, OQPSK 和 8PSK 在 MSNR 较低的情况下分类性能较差,5 种信号在 4 dB 以上的准确率都可以达到 85% 以上。

3.4 不同 α 条件下的仿真

在调制分类过程中，除了考虑信噪比的影响外，还需考虑 α 参数对分类的影响。首先，尝试在未知 α 值条件下进行仿真验证，将不同 α 值对应的信号数据集放在一起进行模型训练，使其具有 α 值的普适性。由于不同 α 值对应的信号数据特征存在明显差异，在训练过程中很难找到其共同特征，导致分类效果较差。因此，采用传统的算法对不同 α 值进行分类仿真实验，即每个 α 值分别用于训练一个模型。

当 α 小于 2 时， α 的选择范围为 0.3~1.8，步长为 0.3。每个信号在不同的 α 值下产生 500 个图像数据集。MSNR 的值为 10 dB。如图 9 所示，在不同 α 值下采用 D-Log 法对信号进行分类，从图中可以看出，这 5 个信号对非高斯噪声都有很好的抑制性能，适用于高斯噪声和非高斯噪声。当 MSNR 的值为 10 dB， α 大于 0.3 时，信号分类的准确率可以达到 95% 以上。




Fig.9 Classification results of D-Log method under unknown α
图 9 未知 α 下 D-Log 算法的分类结果

3.5 实验结果分析

本文提出的方法具有以下优点：

- 1) 在识别性能方面，本文提出的算法在信噪比大于 4 dB 时可稳定获取 80% 的识别准确率。
- 2) 在鲁棒性方面，本文提出的方法可以在一定的 MSNR 范围内实现独立和自适应，可用于高斯噪声和非高斯噪声。
- 3) 在模型训练方面，本文构建的混合数据集只需要训练一个模型，减少了模型训练的复杂操作。

本文仍存在以下不足：

1) 模型训练后随机选取的测试集也会对分类结果产生一定的影响。如，改进后的 16QAM 信号星座图在低信噪比下有 4 个星座点，在高信噪比下有 16 个星座点，而 QPSK 信号也是 4 个星座点。如果随机选取的测试集在低信噪比下包含较多的 16QAM 数据，则可能会被识别为 QPSK 信号，从而导致分类结果不佳。

2) 一般情况下，如果有 N 个信噪比采样点，则需对模型进行 N 次训练。本文只需要训练一个模型，在一定程度上降低了复杂性，但单个模型的训练时间要比多个模型的训练时间长。

这些问题也是未来改进的方向。

4 结论

本文提出了一种将对数星座图算法、深度学习、混合数据集训练结合起来的通信信号调制模式识别方法。仿真结果表明，这种方法可用于高斯噪声和非高斯噪声环境。与传统的在每个信噪比下进行模型训练方法相比，将不同信噪比的数据同时发送至深度学习网络上训练一个模型，具有更广泛的通用性。使用不同的 α 来模拟不同的噪声，仿真结果表明，本文提出的方法在未知信噪比下具有较好的分类性能，且在不同的 α 条件下仍有较好的分类性能。

参考文献：

- [1] DOBRE O. Signal identification for emerging intelligent radios: classical problems and new challenges[J]. IEEE Instrumentation & Measurement Magazine, 2015,18(2):11–18.
- [2] O'SHEA T,HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017,3(4):563–575.
- [3] PENG S,JIANG H,WANG H,et al. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019,30(3):718–727.
- [4] TU Y,LIN Y,WANG J,et al. Semi-supervised learning with generative adversarial networks on digital signal modulation classification[J]. Computers,Materials & Continua, 2018,55(2):243–254.
- [5] HU S,PEI Y,LIANG P P, et al. Deep neural network for robust modulation classification under uncertain noise conditions[J]. IEEE Transactions on Vehicular Technology, 2020,69(1):564–577.