

文章编号:2095-6134(2021)04-0549-08

基于神经网络的车联网频谱感知组合算法*

纪玉峰^{1,2†}, 郑敏¹, 谭冲¹, 刘洪¹

(1 中国科学院上海微系统与信息技术研究所 中国科学院无线传感网与通信重点实验室, 上海 200050;

2 中国科学院大学, 北京 100049)

(2019 年 11 月 12 日收稿; 2020 年 1 月 6 日收修改稿)

Ji Y F, Zheng M, Tan C, et al. Combination algorithm of spectrum sensing in vehicle network based on neural network[J]. Journal of University of Chinese Academy of Sciences, 2021, 38(4): 549-556.

摘 要 针对车联网环境下无线频谱资源短缺的问题,提出一种基于神经网络的多条件频谱感知组合算法。该算法利用神经网络较强的多分类能力,将信号能量、协方差矩阵的最大特征值、最小特征值、迹和平均特征值融合作为神经网络特征参数实现合作频谱感知,并从理论上分析参数选择方案,算法还充分考虑信道多径衰落和阴影效应导致的信噪比很低的情况以及车辆移动产生的多普勒效应,达到提高频谱感知成功率的目的,从而提高频谱的利用率。仿真结果表明,该算法在低信噪比情况下比已有的频谱感知算法具有更好的检测性能。

关键词 认知无线电;车联网;频谱感知;神经网络;低信噪比

中图分类号:TN929 文献标志码:A doi:10. 7523/j. issn. 2095-6134. 2021. 04. 015

Combination algorithm of spectrum sensing in vehicle network based on neural network

Ji Yufeng^{1,2}, ZHENG Min¹, TAN Chong¹, LIU Hong¹

(1 Key Laboratory of Wireless Sensor Networks and Communications of CAS, Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 200050, China; 2 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract In this paper, a multi-conditional spectrum sensing combination algorithm based on neural network is proposed to address the current shortage of spectrum resources in vehicular network. The algorithm combines signal energy, the maximum-minimum of eigenvalues, traces, and the average eigenvalue of the covariance matrix as neural network characteristic parameters, which are achieved through the strong multi-classification ability of neural network. To improve the successful rate of spectrum sensing and the utilization rate of the spectrum, we focus on analyzing the selection of parameter in theory as well as the low signal-to-noise ratio caused by channel fading and shadow effect. Meanwhile, the Doppler effective caused by car moving is also our consideration. Under low signal-to-noise ratio, the simulation results show that the proposed algorithm has better detection performance than existing spectrum sensing algorithms.

Keywords cognitive radio; vehicular network; spectrum sensing; neural network; low signal-to-noise ratio

* 中国科学院青年创新促进会(2018269)资助

† 通信作者, E-mail: jiyf@mail. ustc. edu. cn

车联网 (vehicular network) 作为智能交通里的关键技术, 通过完成车车通信 (vehicle-to-vehicle) 和车路通信 (vehicle-to-road) 来感知道路环境, 从而实现合理规划路线、避免拥堵和减少交通事故。近年来, 随着生活水平的提高, 由于新用户激增给车联网的无线频谱资源带来巨大的挑战。为此, 将采用动态频谱共享技术即认知无线电 (cognitive radio, CR) 来解决无线频谱资源匮乏的问题^[1-4]。

认知无线电的概念是频谱复用/共享, 允许认知车辆用户 (cognitive vehicle user, CVU) 在授权用户 (primary user, PU) 没有充分利用频谱情况下, 占用分配给 PU 的频谱进行通信。为了避免 CVU 对 PU 通信造成干扰, CVU 需要准确检测到 PU 是否存在, 因此, 频谱感知是认知车联网的前提^[5-6]。

现有的车联网频谱感知技术主要有能量检测、循环平稳特征检测、匹配滤波检测、特征值检测等。针对车联网复杂的通信环境, 文献[7]提出一种分布式车联网频谱感知算法, 此方法考虑大尺度衰落和多径效应的影响, 提高了频谱感知的检测概率; 文献[8]提出一种认知车载辅助网络 (CRVANET), 采用合作三态频谱感知模型来感知高速公路上频谱使用情况; 文献[9]在文献[8]的单门限值的基础上, 引入范围内车辆数将算法改进为双门限值, 提高了频谱感知检测性能。但是在车联网中, 由于车辆快速移动, 信道是快速时变的, 此时信噪比 (signal-to-noise ratio, SNR) 将不再是一个定值, 这就需要车联网频谱感知在不同 SNR 下均能有较好的检测性能, 而传统能量检测算法在低 SNR 环境下性能会有很大的不足, 文献[10]提出一种把信号能量值和神经网络结合 (energy detection with neural network, EDNN) 的频谱感知算法, 此算法的神经网络参数为多个 CVU 接收到的信号的能量, 利用神经网络分类的优势提高低 SNR 环境中的检测概率。基于特征值检测的方法利用接收信号的样本协方差矩阵的特征值等信息来识别信号, 在低 SNR 环境有着比较高的用户感知能力, 这引发了一些基于特征值算法的提出。如文献[11]提出基于协方差矩阵最大值和最小值组合的全盲检测融合算法 (mean-to-square extreme eigenvalue, MSE); 文献[12]在文献[11]的基础上利用协方差矩阵的最大特征值、迹和几何平均值组合得出一种融合检测算法

(α -maximum eigenvalue-trace-geometric mean, α -MTG), 该算法有效提高了检测概率并降低了虚警概率。

基于特征值的检测算法能够表现出很好的检测性能主要是因为协方差矩阵的特征值能够很好地捕捉到信号的相关性和噪声的特性, 基于神经网络的能量检测利用神经网络在分类上的优势达到一个比较好的检测性能。在低 SNR 情况下, 由于信号相对于噪声极小, 无论是能量检测还是特征值检测都没有一个很好的阈值能够判断是否存在 PU, 本文利用神经网络多特征参数和分类优势, 将信号的能量、最大-最小特征值的比值、最大-最小特征值的差值、平均-最小特征值的比值以及矩阵迹和特征值组合, 提出一种基于神经网络的合作频谱感知的组合算法, 放大有无 PU 的区别, 从而使得检测性能更高。本算法不需要提前设定阈值, 并且可以在低 SNR 情况下保证感知效果。

1 系统模型

1.1 网络模型

如图 1 所示, 本文考虑的是多用户协作频谱感知, 假设车联网环境中有 1 个 PU, M 位 CVU 独立接收 PU 发射的信号, 1 个融合中心接收 CVU 数据并进行计算和决策。当检测到 PU 信号不存在时, CVU 即可占用 PU 的频谱空间进行信息传输。

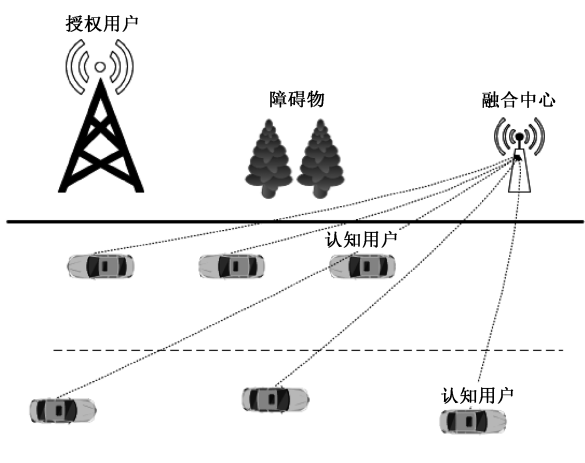


图 1 车联网频谱感知模型

Fig. 1 Spectrum sensing model of vehicular network

1.2 频谱感知模型

车联网频谱感知可以看作一个二分类的问题。用 H_0 表示 PU 信号不存在, 用 H_1 表示 PU 信

号存在。合作频谱感知中, CVU 接收到的信号可以表示为

$$y_i(n) = \begin{cases} H_0: w_i(n), & i = 1, \dots, M \\ H_1: h_i(n)s(n) + w_i(n), & n = 1, \dots, N \end{cases} \quad (1)$$

其中, H_0 和 H_1 分别代表 PU 信号存在和不存在的状况, $w_i(n)$ 代表均值为 0 且方差为 δ_w^2 的加性高斯白噪声(AWGN), 加性高斯白噪声是车联网研究中广泛采用的噪声, s 表示 PU 发射的信号, h_i 代表第 i 个信道的信道响应, 此处假设这个信道是不变的且是瑞利分布。假定 $w_i(n), s(n), h_i(n)$ 是相互独立的。

假设 CVU 感知的信号样本点数目是 N 个, 共 M 个信号并进行合作感知, 那么同一时刻的数据可以表示为

$$\begin{aligned} \mathbf{y}(n) &= [y_1(n), y_2(n) \cdots y_M(n)]^T, \\ \mathbf{s}(n) &= [s_1(n), s_2(n) \cdots s_M(n)]^T, \\ \mathbf{w}(n) &= [w_1(n), w_2(n) \cdots w_M(n)]^T, \\ \mathbf{h}(n) &= [h_1(n), h_2(n) \cdots h_M(n)]^T. \end{aligned} \quad (2)$$

接收信号向量可以表示为

$$\mathbf{y}(n) = \mathbf{H}\mathbf{s}(n) + \mathbf{w}(n), \quad (3)$$

其中 \mathbf{H} 为 PU 与 CVU 之间的相应矩阵。此时接收信号的协方差矩阵可以定义为

$$\mathbf{R}_y(n) = \mathbf{H}\mathbf{R}_s\mathbf{H}^H + \delta_w^2\mathbf{I}_{MM}, \quad (4)$$

其中 \mathbf{I}_{MM} 为 $M \times M$ 的单位矩阵, $\mathbf{R}_y, \mathbf{R}_s$ 分别为

$$\mathbf{R}_y = E[\mathbf{Y}\mathbf{Y}^H], \quad (5)$$

$$\mathbf{R}_s = E[\mathbf{S}\mathbf{S}^H]. \quad (6)$$

由于采样序列个数为 N , 接收信号的样本协方差矩阵可以表示为

$$\mathbf{R}_y(N) = \frac{1}{N} \sum_{n=1}^N \mathbf{y}(n)\mathbf{y}^H(n). \quad (7)$$

在车联网通信中, 当 CVU 靠近 PU 时, 信号频率变高, 远离 PU 时, 信号频率变低, 所以要充分考虑多普勒效应导致的多普勒频移。CVU 接收的信号频率和 PU 发射的信号频率关系为

$$f' = \left(\frac{v \pm v_0}{v \mp v_s} \right) \times f. \quad (8)$$

其中, f' 为 CVU 接收到的信号频率, f 为 PU 发射的信号频率, v 为信号传播速度, v_0 为认知车辆的移动速度, v_s 为 PU 移动速度, 此处为 0。当车辆以恒定速度 v 在路上行驶时, 多普勒频移可以表示为

$$f' = \frac{v}{\lambda} \cos \theta. \quad (9)$$

其中: λ 代表波长, θ 为认知车辆与 PU 连线和道路的夹角。本文在得出多普勒频移之后进行修正补偿, 从而保证认知车辆在移动过程中接收信号的频率处于一个稳定的水平。

由于本文采用神经网络进行频谱感知, 通过接收信号的协方差矩阵和信号能量提取的特征参数来判断信号是否存在, 检测概率 P_d 和虚警概率 P_{fa} 可以表示为

$$P_d = \frac{N_d}{N_p}, \quad (10)$$

$$P_{fa} = \frac{N_f}{N_{np}}. \quad (11)$$

其中, N_d 为信号存在且检测结果为存在的次数, N_p 为存在信号的样本个数, N_f 为信号不存在但检测结果为存在的次数, N_{np} 为不存在信号的样本个数。

2 频谱感知组合算法

2.1 组合特征参数

本文利用神经网络在多特征参数分类问题上具有比较好的检测性能并结合能量检测和特征值检测的优点, 改善神经网络的层数和激活函数, 提出一种基于神经网络的多特征参数融合的频谱感知算法。

考虑到低 SNR 的车联网通信环境下 H_0 和 H_1 的差异性较小, 本文选取多个神经网络特征参数来放大这 2 种情况的差异, 从而实现更高性能的频谱感知。特征参数选取如下:

1) β_1 : 选取协方差最大特征值与最小特征值组合作为特征参数。

2) β_2 : 选取协方差矩阵平均特征值和最小特征值的组合作为特征参数。

3) β_3 : 选取协方差矩阵最大特征值、迹和所有特征值的几何平均值的组合作为特征参数。

4) β_4 : 选取信号的能量作为特征参数。

β_1, β_2 的具体推导如下:

根据式 (7) 得出 \mathbf{R}_y , 然后将 \mathbf{R}_y 代入 $|\mathbf{R}_y - \lambda_i \mathbf{E}| = 0$ 得到 \mathbf{R}_y 的特征值 $\lambda_{y1} \geq \lambda_{y2} \geq \cdots \geq \lambda_{ymin}$, 同样, 计算得出 \mathbf{R}_s 的特征值 $\lambda_{s1} \geq \lambda_{s2} \geq \cdots \geq \lambda_{smin}$, \mathbf{R}_w 的特征值是 δ_w^2 , 根据式 (6) 可以推导出

$$\lambda_{yn} = \lambda_{sn} + \delta_w^2. \quad (12)$$

在 H_0 即 PU 不存在的状态下, 发射信号为 0, 即 $\mathbf{R}_s = 0$, 此时特征值 $\lambda_{s1} = \lambda_{s2} = \cdots = \lambda_{smin} = 0$, 因

此, $\lambda_{yn} = 0 + \delta_w^2 = \delta_w^2$, 可得 $\lambda_{ymax}/\lambda_{ymin} = 1$ 。在 H_1 即 PU 存在的情况下, $\lambda_{s1} > \lambda_{smin}$, 因此 $\lambda_{ymax}/\lambda_{ymin} > 1$ 。在 CVU 个数为 1 时, 发射信号特征值为定值, 此时 $\lambda_{ymax}/\lambda_{ymin} = 1$, 但是本文使用多用户协作频谱感知, 可以不考虑 CVU 个数为 1 的情况。 $\lambda_{ymax}/\lambda_{ymin}$ 在 PU 存在和不存在时有区别, 因此可以通过 $\lambda_{ymax}/\lambda_{ymin}$ 来判断 PU 是否存在。但是在 SNR = -20 dB 环境下, $\delta_w^2 = 100\lambda_{sn}$, 这时, $\lambda_{ymax}/\lambda_{ymin} \approx 1$, 此时神经网络便不能准确地判断 PU 是否存在。因此将 $\lambda_{ymax}/\lambda_{ymin}$ 乘一个参数 σ 来放大这一特征值, 得出

$$\beta_1 = \frac{\lambda_{ymax}}{\lambda_{ymin}} \sigma. \quad (13)$$

同理, 设 λ_{yavg} 为 \mathbf{R}_y 的几何平均特征值。通过下式得出:

$$\lambda_{yavg} = \left(\prod_{i=1}^M \lambda_{yi}(\mathbf{R}_y(N)) \right)^{\frac{1}{M}}. \quad (14)$$

在 H_0 即 PU 不存在的状态下, 发射信号为 0, 即 $\mathbf{R}_s = 0$, 此时特征值 $\lambda_{s1} = \lambda_{s2} = \dots = \lambda_{smin} = 0$, 因此, $\lambda_{yn} = 0 + \delta_w^2 = \delta_w^2$, 此时可得 $\lambda_{yavg}/\lambda_{ymin} = 1$ 。在 H_1 即 PU 存在的情况下, $\lambda_{savg} > \lambda_{smin}$, 因此 $\lambda_{yavg}/\lambda_{ymin} > 1$ 。同上, 此处需设置一个参数来放大特征值以避免低 SNR 情况下检测精度不高的问题:

$$\beta_2 = \frac{\lambda_{yavg}}{\lambda_{ymin}} \sigma. \quad (15)$$

β_3 的具体推导如下:

结合 α -MTG 算法以及 MSEE 算法, 给出检测统计量, 如下所示

$$T = \left(\frac{\lambda_{ymax} + \lambda_{ymin}}{2\sqrt{\lambda_{ymax}\lambda_{ymin}}} \right)^{\alpha} \left(\frac{2\sqrt{\lambda_{ymax}\lambda_{ymin}}}{\lambda_{yavg}} \right)^{1-\alpha}. \quad (16)$$

其中, α 的取值范围是 0~1, 在 H_0 即 PU 不存在的状态下, 发射信号为 0, 此时 $\lambda_{ymax} = \lambda_{ymin}$, $T = 1$ 。在 H_1 即 PU 存在的情况下, $\lambda_{ymax} > \lambda_{ymin}$, $T > 1$ 。此时的统计量已经可以很好地区分 PU 是否存在的情况, 但是作为神经网络的参数之一, 此处需要一个系数来保证神经网络各个参数处于统一量级。因此, 得出 β_3 表达式为

$$\beta_3 = \left(\left(\frac{\lambda_{ymax} + \lambda_{ymin}}{2\sqrt{\lambda_{ymax}\lambda_{ymin}}} \right)^{\alpha} \left(\frac{2\sqrt{\lambda_{ymax}\lambda_{ymin}}}{\lambda_{yavg}} \right)^{1-\alpha} \right)^{\rho}. \quad (17)$$

其中: ρ 的大小由 β_1, β_2 及 T 的大小来确定。

β_4 的具体推导如下:

由于信号样本点数目是 N 个, 可以将能量的检测统计量表示为

$$E = \sum_n (y(N))^2. \quad (18)$$

在 H_0 时, $E = \delta_w^2$ 。在 H_1 时, $E = s^2 + \delta_w^2$ 。在 PU 存在和不存在 2 种情况下有着一定的差距。因此选取能量作为神经网络特征参数, 此处, 仍需一个参数来调整能量统计值的大小, 保证和其他特征值处于一个量级, 因此, β_4 表示为

$$\beta_4 = \sum_n (y(N))^2 \sigma. \quad (19)$$

此时已经得出用于神经网络训练的特征参数 $\beta_1, \beta_2, \beta_3, \beta_4$, 本文所提算法融合了能量检测和协方差矩阵特征值检测, 虽然传统的能量检测需要先验信息, 但是本文算法利用神经网络分类的优点, 使得能量检测也不需要任何信道和信号的先验信息。因此, 是一种具有高感知性能的盲检测融合算法。

2.2 人工神经网络

人工神经网络 (artificial neural networks, ANN) 是模仿生物的神经网络的结构和功能的数学模型。具有强大的学习能力和容错性, 在分类问题上有着出色的表现。本文神经网络采用 1 层输入层、2 层隐藏层和 1 层输出层的结构。由于用于神经网络训练的特征参数是 4 个, 输入层神经元个数 L 为 4。对于隐藏层, 节点个数由经验公式得出:

$$N_p = \sqrt{N_x + N_y} + \alpha. \quad (20)$$

式中: N_p 代表隐藏层节点个数, N_x 代表输入层节点个数, N_y 为输出层节点个数, α 是一个范围为 1~10 的常数。此处 ANN 网络在第 1 隐藏层节点数为 P_1 , 第 2 隐藏层节点数为 P_2 。输出层节点个数 Q 为 2。

假设 $w_{ij}^{(1)}$ 是第 i 个输入神经元和第 1 隐藏层第 j 个神经元之间的权重, $w_{ij}^{(2)}$ 是第 1 隐藏层第 i 个神经元和第 2 隐藏层第 j 个神经元之间的权重。 $w_{ij}^{(3)}$ 是第 2 隐藏层第 i 个神经元和输出层第 j 个神经元之间的权重。 $t_i^{(k)}$ 为第 i 个神经元的阈值, k 表示神经元所在的层数, $k=1$ 表示隐藏层 1, $k=2$ 表示隐藏层 2, $k=3$ 表示输出层。由于 sigmoid 函数可以将输出值限制在 $[0, 1]$ 之间, 隐藏层第 1 层的激活函数 f_1 为 sigmoid 函数, 隐藏层第 2 层和输出层激活函数 f_2, f_3 采用收敛速度快、计算复杂度低的 relu 函数。sigmoid 函数和 relu

函数表达式如下:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}, \quad (21)$$

$$\text{relu}(x) = \max(0, x). \quad (22)$$

隐藏层第 1 层的第 i 个神经元的输入 in_i 和输出 out_i 可以表示为

$$\text{in}1_i = \sum_{i=1}^4 w_{ij}^{(1)} x_i, \quad (23)$$

$$\text{out}1_i = f_1(\text{in}_i + t_i^{(1)}). \quad (24)$$

隐藏层第 2 层第 j 个神经元的输入和输出可以表示为

$$\text{in}2_j = \sum_{i=1}^8 w_{ij}^{(2)} \text{out}1_i, \quad (25)$$

$$\text{out}2_i = f_2(\text{in}2_i + t_i^{(2)}). \quad (26)$$

输出层的第 k 个神经元的输入和输出可以表示为

$$\text{in}3_k = \sum_{i=1}^2 w_{ik}^{(3)} \text{out}2_i, \quad (27)$$

$$\text{out}3_k = f_3(\text{in}3_i + t_i^{(3)}). \quad (28)$$

由于频谱感知的应用场景需要快速检测信号,因此神经网络的学习训练函数采用学习率可变的最速下降 BP 算法 traingda。上述网络中,待学习的参数分别是 $w_{ij}^{(1)}$ 、 $w_{ij}^{(2)}$ 、 $w_{ij}^{(3)}$ 、 $t_i^{(1)}$ 、 $t_i^{(2)}$ 、 $t_i^{(3)}$ 。此时的损失函数 C 可表示为

$$C = \frac{1}{2m} \sum_{i=1}^m \sqrt{(\text{out}3 - y)^2 + \varepsilon} + \frac{\lambda}{2m} \|w\|_2^2. \quad (29)$$

式中: m 为样本的个数; $\|w\|_2^2$ 为正则化,可以有效地避免神经网络过拟合或者陷入局部最优解; λ 为正则化系数,可以调整损失函数 C 和正则化函数 $\|w\|_2^2$ 之间的关系。假设网络的学习速率是 α , 那么下降梯度可以表示为

$$\Delta w_{ij}^{(k)} = \alpha \frac{\partial C}{\partial w_{ij}^{(k)}} = \alpha \left(\frac{\partial C}{\partial w_{ij}^{(k)}} + \frac{\lambda}{m} w_{ij}^{(k)} \right), \quad (30)$$

$$\Delta t_i^{(k)} = \alpha \frac{\partial C}{\partial b_i^{(k)}} = \alpha \frac{\partial C}{\partial t_i^{(k)}}. \quad (31)$$

此时,权值和阈值更新公式为

$$w_{ij}^{(k)} = w_{ij}^{(k)} - \Delta w_{ij}^{(k)}, \quad (32)$$

$$t_i^{(k)} = t_i^{(k)} - \Delta t_i^{(k)}. \quad (33)$$

神经网络训练过程中就是更新权重,直到训练误差小于阈值或者训练次数达到最大则停止网络训练。

2.3 神经网络实现频谱感知流程

本文提出的基于神经网络的频谱感知组合算法流程如图 2 所示。通常来说,通信过程中的数据量比较大,而车联网频谱感知需要快速处理数据,因此首先需要进行特征值提取来降低数据的

维度从而提高感知速率。然后将数据按照比例分为训练集、验证集和测试集,把训练集的数据放入改进的神经网络中进行训练,训练停止条件为误差小于期望值或者达到最大迭代次数,然后使用验证集的数据进行验证,找出识别效果最好的神经网络模型,然后将测试集的数据放在车联网环境下,在多普勒频移修正后进行频谱感知,得出感知性能。

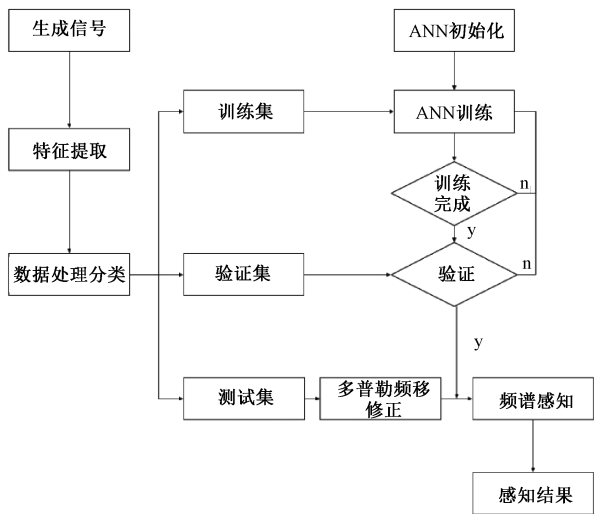


图 2 基于神经网络的组合频谱感知流程图
Fig. 2 Flow chart of combined spectrum sensing based on neural network

3 仿真实验

3.1 仿真参数设置

本节训练集、验证集和测试集均由 Matlab 仿真产生。共使用 10 000 组数据,其中训练集 6 000 组,验证集和测试集均为 2 000 组。采样点数 N 为 1 000,噪声是加性高斯白噪声 AWGN,信道使用的是 10 阶的瑞利衰落信道,仿真中的所有数据都是单跳发送,不进行路由转发,并假设全路段均在 PU 覆盖范围内且认知车辆互不干扰,所有车辆于 0 时刻从道路一端向另一端移动,本文的仿真参数如表 1 所示。

如表 1 所示,PU 到车道距离、道路长度、车道宽度、车速均为已知,车辆位置可以由车辆速度和时间求出,所以可以得出多普勒频移和时间的关系,然后在不同感知时刻进行多普勒频移修正即可保证认知车辆接收的信号频率稳定。此时,CVU 在不同时刻接收信号的频率相对稳定,主要变量为 SNR。

表 1 仿真参数设置

Table 1 Simulation parameter setting

参数名称	参数值
车道数量	2
车道长度/m	2 000
车道宽度/m	5
PU 到车道距离/m	200
车速/km/h	60
车辆个数	10
认知车辆数	2, 5, 10
信噪比/dB	[−20,10]
噪声类型	AWGN
信道类型	Rayleigh fading channel

3.2 ANN 结构参数对频谱感知性能的影响

神经网络的学习速率和隐藏层节点个数的选择都会影响频谱感知的性能。本节使用 5 个

CVU 协作的数据集,在 SNR=−20 dB 环境下进行测试。

1) 学习速率对频谱感知性能影响

隐藏层第 1 层节点个数设为 8,隐藏层第 2 层节点个数设为 2,同时改变学习速率,迭代 400 次,重复实验 20 次取平均值,得到的 ANN 模型的频谱感知性能如表 2 所示。

由表 2 可知,随着学习速率的减小,神经网络的收敛速度逐渐变慢,在学习速率很低且迭代次数不足的时候,由于阈值很低,所有信号都被判定为 PU 存在,所以检测概率和虚警概率都为 100%。但是在接近最优解时,学习速率对神经网络的稳定性影响较小。综合考虑频谱感知的性能,本文算法采用的学习速率为 0.001。

表 2 学习速率对频谱感知性能的影响

Table 2 Effect of learning rate on spectrum sensing performance

迭代次数	0.01		0.001		0.000 1		0.000 01		%
	P_d	P_{fa}	P_d	P_{fa}	P_d	P_{fa}	P_d	P_{fa}	
50	37.3	46.2	100	100	100	100	100	100	
100	75.3	20.7	52.2	31.1	37.1	43.5	15.2	53.3	
150	82.3	20.1	72.1	22.1	67.8	33.4	40.8	45.1	
200	82.7	19.5	82.1	22.5	78.9	23.7	71.2	23.3	
250	82.2	20.2	82.6	22.8	82.7	22.9	77.3	22.3	
300	82.1	19.5	82.1	22.2	82.5	22.1	82.2	21.9	
350	82.9	19.5	82.1	22.6	82.6	22.1	82.7	22.1	
400	82.1	22.5	82.5	22.4	82.6	22.4	82.4	22.5	

2) 隐藏层节点个数对频谱感知性能的影响

ANN 模型的频谱感知性能也受到神经网络隐藏层节点个数的影响^[13],由于隐藏层第 2 层连接输出层,故隐藏层第 2 层节点个数固定为 2,在学习速率为 0.001 的前提下,第 1 层隐藏层采用不同节点个数进行测试,得到的频谱感知的 P_d 和 P_{fa} 如表 3 所示。

表 3 隐藏层节点个数对频谱感知性能影响

Table 3 Influence of the number of hidden layer nodes on spectrum sensing performance

节点个数	迭代次数	P_d /%	P_{fa} /%
2	5 000	79.7	24.5
4	5 000	80.3	23.5
6	5 000	79.1	24.3
8	5 000	82.5	22.4
10	5 000	81.2	23.2

由表 3 可知,将隐藏层第 1 层的节点个数设置为 8 的时候模型可以达到最好的频谱感知性能。因此本文神经网络第 1 隐藏层节点个数为

8,第 2 隐藏层节点个数为 2。

3.3 算法性能对比

本节通过在本文假设的车联网环境中实现各个算法的仿真实验来证明所提算法的优异性,首先选择 CVU 个数为 5 的情况对 EDNN、 α -MTG、文献[9]算法以及本文提出的算法进行仿真和性能比较。对于每一个 SNR 的值,均通过 1 000 次仿真实验实现。神经网络的正则参数 $\lambda = 0.1$,目标误差阈值设为 0,最大迭代次数为 5 000。

本文在频谱感知方向采用的是协作频谱感知,因此仿真还针对 CVU 个数为 2、5、10 的 3 种情况进行仿真。

由于 α -MTG、文献[9]算法需要提前假设虚警概率来确定检测的门限值,为了保证检测的精度,先假设虚警概率为 0.1。然后根据所得的阈值进行信号检测,得出实际的检测概率和虚警概率。首先在 CVU 个数为 5 的情况下对各个算法进行比较。

如图 3(a) 所示,在 SNR 从 −20~10 dB 范围比较不同算法的检测概率 P_d ,明显本文算法检测

性能最优。

在 $\text{SNR} = -20 \text{ dB}$ 时,本文算法的 P_d 可以达到 82.5%,ED-NN 算法的 P_d 可以达到 68%,文献 [9] 算法的 P_d 可以达到 20%, α -MTG 的 P_d 仅为 5%。在 -14 dB 时,本文算法的 P_d 已可以达到 100% 的检测概率,同时,ED-NN 的 P_d 达到 90%,而 α -MTG 算法和文献 [9] 的 P_d 仅达到 10% 和 30%。因此,在实际检测特别是低 SNR 情况下,本文算法的检测性能有着很大的提高。

如图 3(b) 所示,SNR 从 $-20 \sim 10 \text{ dB}$ 范围比较不同算法的虚警概率 P_{fa} 。由于文献 [9] 算法和

α -MTG 是在假设虚警概率 P_{fa} 为定值的前提下设置的阈值,实际所测的虚警概率 P_{fa} 相对稳定,处于 0.1 附近。在 $\text{SNR} = -20 \text{ dB}$ 的情况下,本文算法的 P_{fa} 为 22.4%,而 ED-NN 算法的 P_{fa} 为 40%。在 $\text{SNR} = -18 \text{ dB}$ 时,本文算法即可达到和文献 [9]、 α -MTG 算法一样的虚警概率,因此在相同条件下,本文算法的感知性能是远远高于文献 [9] 算法和 α -MTG 算法的。在 $\text{SNR} = -14 \text{ dB}$ 是,本文算法的 P_{fa} 可以达到 0%,而此时 ED-NN 算法的 P_{fa} 为 9%。由此可知,本文算法提供了更加优秀的频谱感知性能。





图 3 不同算法检测性能对比
Fig. 3 Comparison of detection performance of different algorithms


由于在 CVU 个数为 5 的情况下,ED-NN 算法在低 SNR 情况下的表现也大大优于文献 [9] 算法和 α -MTG 算法,因此在讨论 CVU 个数对频谱感知性能影响的时候,仿真只需验证 ED-NN 算法和本文算法在不同 CVU 个数下的表现。分别仿真了 CVU 个数为 2、5、10 共 3 种情况下的频谱感知性能。

如图 4(a) 所示,在不同 CVU 个数 M 情况下对本文算法的 P_d 和 ED-NN 算法的 P_d 进行对比。在 $M=2$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本文算法的 P_d 为 68%,ED-NN 算法的 P_d 为 60%。本文算法在 $\text{SNR} = -10 \text{ dB}$ 即可达到 100% 检测概率,而 ED-NN 算法需要在 $\text{SNR} = -6 \text{ dB}$ 才能达到 100% 的检测概率。在 $M=5$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本算法的 P_d 为 82.5%,ED-NN 算法的 P_d 为 68%。本文算法在 $\text{SNR} = -14 \text{ dB}$ 时可以达到 100% 检测概率,而 ED-NN 需要 $\text{SNR} = -10 \text{ dB}$ 时才可以达到 100% 的检测率。在 $M=10$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本算法的 P_d 为 92%,而 ED-NN 算法的 P_d 为


70%。本文算法在 $\text{SNR} = -18 \text{ dB}$ 即可达到 99.5% 的检测概率,而 ED-NN 在 $\text{SNR} = -12 \text{ dB}$ 时才可达到 99% 的检测概率。

如图 4(b) 所示,在不同 CVU 个数 M 情况下对本文算法的 P_{fa} 和 ED-NN 算法的 P_{fa} 进行对比。在 $M=2$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本文算法的 P_{fa} 为 40.33%,ED-NN 算法的 P_{fa} 为 45%。本文算法在 $\text{SNR} = -10 \text{ dB}$ 即可达到 0% 虚警概率,而 ED-NN 算法需要在 $\text{SNR} = -6 \text{ dB}$ 才能达到 0% 的虚警概率。在 $M=5$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本算法的 P_{fa} 为 22.4%,ED-NN 算法 P_{fa} 为 40%。本文算法在 $\text{SNR} = -14 \text{ dB}$ 时可以达到 0% 虚警概率,而 ED-NN 需要 $\text{SNR} = -10 \text{ dB}$ 时才可以达到 0% 的虚警概率。在 $M=10$ 时, $\text{SNR} = -20 \text{ dB}$ 情况下,本文算法的 P_{fa} 为 7.2%,而 ED-NN 算法的 P_{fa} 为 32%。本文算法在 $\text{SNR} = -18 \text{ dB}$ 即可达到 0.38% 的虚警概率,而 ED-NN 在 $\text{SNR} = -12 \text{ dB}$ 时才可达到 0.2% 的虚警概率。

上述实验中,对于不同的 CVU 个数,本文算



(a) 检测概率对比图



(b) 虚警概率对比图

图 4 不同 CVU 个数检测性能对比

Fig. 4 Comparison of detection performance of different CVU numbers

法在 $M=2$ 甚至与 ED-NN 算法 $M=5$ 的性能相近,在相同 CVU 个数的情况下,本文算法明显优于其他算法的感知性能,而且虚警概率也达到更低的水平。

4 结束语

为了更精确地感知 PU 以实现更好的频谱复用,本文提出一种基于神经网络的频谱感知融合算法,创新性地利用神经网络将信号能量和协方差矩阵特征值检测结合在一起。仿真实验表明,本文所提的算法在复杂车联网通信环境中能有效增加频谱感知检测的概率,从而提高频谱利用率。基于本文思想考虑的频谱感知融合算法,可以对车联网频谱感知研究有着积极的促进意义。

参考文献

[1] Xu T H, Zhang M Y, Hu H L, et al. Sliced spectrum sensing: a channel condition aware sensing technique for cognitive radio networks[J]. IEEE Transactions on Vehicular Technology, 2018, 67(11): 10815-10829.

[2] Shbat M, Ordaz-Salazar F C, González-Salas J S. Spectrum sensing challenges of IoT nodes designed under 5G network standards[C]//2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE). Mexico City, Mexico: IEEE Press, 2018: 1-6.

[3] Ejaz W, Ibnkahla M. Multiband spectrum sensing and resource allocation for IoT in cognitive 5G networks[J]. IEEE Internet of Things Journal, 2018, 5(1): 150-163.

[4] Katz M, Matinmikko-Blue M, Latva-Aho M. 6Genesis flagship program: building the bridges towards 6G-enabled wireless smart society and ecosystem [C]//2018 IEEE 10th Latin-American Conference on Communications (LATINCOM) Guadajajara, Mexico: IEEE Press, 2018: 1-9.

[5] Rawat D B, Alsabet R, Bajracharya C, et al. On the performance of cognitive internet-of-vehicles with unlicensed user-mobility and licensed user-activity [J]. Computer Networks, 2018, 137: 98-106.

[6] Wu Y B. Localization algorithm of energy efficient radio spectrum sensing in cognitive internet of things radio networks [J]. Cognitive Systems Research, 2018, 52: 21-26.

[7] Aygun B, Wyglinski A M. A voting-based distributed cooperative spectrum sensing strategy for connected vehicles [J]. IEEE Transactions on Vehicular Technology, 2017, 66(6): 5109-5121.

[8] Eze J, Zhang S J, Liu E J, et al. Cognitive radio-enabled Internet of Vehicles (IoVs): a cooperative spectrum sensing and allocation for vehicular communication [J]. IET Networks, 2018, 7(4): 190-199.

[9] 尚佳庆,郑国强,马华红,等. 基于双门限能量检测的认知车联网协作频谱感知[J]. 计算机应用研究, 2020, 37(10): 3131-3134, 3138.

[10] Tang Y J, Zhang Q Y, Lin W. Artificial neural network-based spectrum sensing method for cognitive radio[C]//2010 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM). Chengdu, China: IEEE Press, 2010: 1-4.

[11] Bouallegue K, Dayoub I, Gharbi M, et al. Blind spectrum sensing using extreme eigenvalues for cognitive radio networks [J]. IEEE Communications Letters, 2018, 22(7): 1386-1389.

[12] 赵文静,李贺,金明录,等. 基于特征值的频谱感知融合算法[J]. 通信学报, 2019, 40(11): 57-64.

[13] 蓝润荣,程希骏. 基于改进 RBF 神经网络的银行个人信用评级[J]. 中国科学院研究生院学报, 2013, 30(3): 298-303.