

doi:10.13756/j.gtxyj.2023.06.009

无线通信技术

李雨泽, 李心安. 基于 GCNet 的毫米波波束选择算法[J]. 光通信研究, 2023(6):72-76.

Li Y Z, Li X A. Beam Selection Algorithm in Millimeter Wave based on GCNet [J]. Study on Optical Communications, 2023(6):72-76.

基于 GCNet 的毫米波波束选择算法

李雨泽, 李心安

(重庆邮电大学 a. 通信与信息工程学院; b. 新一代宽带移动通信重点实验室, 重庆 400065)

摘要:在车辆到基础设施(V2I)通信中,毫米波波束宽度窄、设备移动性高,有效的毫米波波束选择是一项关键而又富有挑战性的任务。针对波束搜索过程开销大的问题,文章提出了一种基于雷达和位置信息的毫米波波束选择算法。所提算法使用 Top- k 分类度量在激光雷达数据和波束跟踪通道数据集上训练神经网络结构,并且使用全局上下文网络(GCNet)模型预测最佳波束对。仿真结果表明,所提算法性能在分类识别准确率上有明显提升,与此同时,仅需搜索 5 个波束便能接近穷举搜索的性能,大大减少了波束搜索开销。

关键词:毫米波;波束选择;机器学习;神经网络;GCNet

中图分类号: TN928

文献标志码: A

文章编号: 1005-8788(2023)06-0072-05

Beam Selection Algorithm in Millimeter Wave based on GCNet

LI Yu-ze, LI Xin-an

(a. School of Communication and Information Engineering; b. Key Laboratory of New Generation Broadband Mobile Communication Technology, Chongqing University of Posts and Telecommunication, Chongqing 400065, China)

Abstract: In the vehicle to infrastructure communication, the millimeter wave beam width is narrow and user equipment mobility is high. Therefore, effective millimeter wave beam selection is a key and challenging task. Aiming at the problem of high overhead in the beam search process, this paper proposes a millimeter-wave beam selection algorithm based on radar and location information. The proposed algorithm trains a neural network structure on the lidar and beam tracking channel datasets using the Top- k classification metric. It also predicts the best beam pair using the Global Context Net (GCNet) model. The simulation results show that the performance of the proposed algorithm is significantly improved in the classification and recognition accuracy. At the same time, it only needs to search 5 beams to approach the performance of the exhaustive search, which greatly reduces the beam search overhead.

Key words: millimeter wave; beam selection; machine learning; neural network; GCNet

0 引言

毫米波频段具有丰富的频谱资源,数据传输速率高,是未来移动通信的关键技术^[1]。毫米波具有较高路径损耗,通常在基站使用大规模天线阵列获得波束赋形增益^[2]。因此,需要实现高精度的波束对准和跟踪。传统算法大多采用穷举搜索确定最佳波束^[3],但穷举搜索开销较大,难以应用于车辆到基础设施(Vehicle to Infrastructure, V2I)的通信场景^[4]。

近年来,机器学习广泛应用于毫米波波束对准和跟踪^[5]。文献[6]提供了可靠的数据集,为后续研究奠定了基础;文献[7]将从车辆获得的位置信息用于神经网络训练,降低了波束选择开销;文献[8]使

用雷达数据提升波束选择准确率,尤其是非视距(Non Line of Sight, NLOS)场景;文献[9]说明了分布式体系结构性能优于集中式体系结构;文献[10]简化了分类器结构,并使用联邦学习的方式训练,在提高性能的同时降低了计算成本。

针对波束选择开销大的问题,本文提出了一种基于全局上下文网络(Global Context Net, GCNet)的神经网络结构,在位置和雷达数据辅助下识别最佳波束对。仿真结果表明,本文所提算法有效地提高了波束预测的准确率,并且吞吐量更接近穷举搜索。

1 系统模型

本文采用模拟波束成形的下行正交频分复用

收稿日期:2022-09-08; 修回日期:2022-10-08; 纸质出版日期:2023-12-10

基金项目:国家科技重大专项资助项目(2018ZX03001026-002)

作者简介:李雨泽(1998-),女,四川广安人。硕士,主要研究方向为毫米波波束管理。

通信作者:李雨泽,硕士。Email: 975120972@qq.com

© Editorial Office of Study on Optical Communications. This is an open access article under the CC BY-NC-ND license.

(Orthogonal Frequency Division Multiplexing, OFDM)毫米波系统,位于街道边缘的基站利用子载波在其覆盖区域为车辆服务。发送端和接收端均配备具有单个射频链和固定码本的天线阵列,分别用 $C_t = \{f_i\}_{i=1}^{N_t}$ 和 $C_r = \{w_j\}_{j=1}^{N_r}$ 表示,其中, f_i 为发送端码本元素, w_j 为接收端码本元素, N_t 为发送端天线数量, N_r 为接收端天线数量。根据文献[7]中的信道模型,使用波束追踪技术,结合波束追踪,输出和宽带毫米波几何信道模型。假设第 m 个子载波的信道响应为 $H[m]$,则每一组波束对 (p, q) 上所有子载波的接收信号功率总和 $y(p, q)$ 为

$$y(p, q) = \sum_{m=0}^{M-1} |w_q^H H[m] f_p|^2, \quad (1)$$

式中: M 为总子载波数; $(\cdot)^H$ 为共轭转置运算; $|\cdot|$ 为绝对值运算; w_q 和 f_p 分别为发射端预编码向量与接收端合并向量。因此,最大化接收信噪比(Signal Noise Ratio, SNR)的最佳波束对 (p^*, q^*) 为

$$(p^*, q^*) = \underset{(p, q)}{\operatorname{argmax}} y(p, q). \quad (2)$$

在没有其他信息辅助的情况下,穷举搜索需要搜索 $N_t \times N_r$ 对波束才能找到最佳波束对 (p^*, q^*) 。

2 基于 GCNet 的毫米波波束选择算法

本文提出了一种基于 GCNet 的毫米波波束选择算法,使用车辆与基站的位置信息和预处理后的激光雷达(Light Detection and Ranging, LIDAR)数据训练神经网络。采用 Top- k 分类度量,识别最优波束对集合,缩小波束搜索范围, k 为神经网络预测的结果。

2.1 LIDAR 数据预处理

基站广播其位置信息 $P_b = (x_b, y_b, z_b)$, 车辆根据全球定位系统(Global Positioning System, GPS)获取自身位置 $P_v = (x_v, y_v, z_v)$ 。LIDAR 的测量值为 $P = \{(x_i, y_i, z_i)\}_{i=1}^{|P|}$, 其中 $|P|$ 为障碍点的数量, (x_i, y_i, z_i) 为 LIDAR 传感器测量的障碍点 i 的坐标。

二维表示法将基站覆盖区域划分为若干二维等边网格,生成覆盖区域平面图。若至少一个障碍点位于网格内,则将该网格标识设置为 1, 否则设置为 0。车辆和基站所在网格的标识分别设置为 -1 和 -2, 如图 1 所示。二维表示法将观测数据降维,在降低了数据处理复杂度的同时,保证了波束分类的准确性^[10]。





图 1 数据预处理^[9]

Figure 1 The scheme of data preprocess

2.2 神经网络结构

图 2 所示为本文所提基于 GCNet 的神经网络结构框图,该架构分别由 LIDAR 和 GPS 输入的分支组合而成。在 LIDAR 支路,通过卷积层、最大池化层和线性层对预处理的雷达数据进行特征提取。相邻的卷积层之间加入最大池化层可以有效地缩小参数矩阵的尺寸,从而减少最后连接层中的参数数



注:ReLU 为线性整流函数。

图 2 神经网络结构框图

Figure 2 The diagram of Neural network structure block

量,加快计算速度,防止过拟合。在 GPS 支路,对 GPS 坐标同样进行特征提取,然后与 LIDAR 支路汇合。激活函数使用 ReLU,最后一层线性层使用 Softmax 函数将基站坐标固定于整个数据集中,不需要参与训练。

本文在 LIDAR 处理分支的第 5 层最大池化层之后添加了 GCNet 模块增强神经网络结构。文献[11]中提出了一种捕获长距离依赖关系的开创性方法,使用非局部注意力(Non-Local Attention, NLA)模块将特定的全局上下文聚合到每个查询位置。但是,NLA 建模的全局上下文在不同的查询位置几乎相同,浪费了大量的计算空间;文献[12]提出了轻量级神经网络 GCNet,由全局上下文模块和压缩激励(Squeeze and Excitation, SE)模块融合而成,充分结合了前者全局上下文建模能力强和后者参数计算量小的优点。另外,仅仅通过堆叠来提取特征将导致特征缺乏多样性,而 GCNet 是对全局特征进行上下文建模。实验表明,该模型对于分类识别任务性能优于卷积神经网络。因此,本文基于 GCNet 训练神经网络模型。

图 3 所示为 GCNet 模型流程图。全局上下文模块采用 NLA 简化后的模型,不同之处在于直接将全局上下文建模为所有位置特征的加权平均值,然后将全局上下文特征聚集到每个位置的特征上。转换模块结合了 SE 模型,减少了参数计算量,并添加了层归一化以降低优化难度和提高泛化性能。GCNet 模型既能建立有效的长距离依赖,又能减少参数计算量。




图 3 GCNet 模型流程图

Figure 3 The block diagram of GCNet

2.3 仿真

本文提出的神经网络结构使用数据集 Ray-mobtime 中的 s008 进行训练,s009 进行仿真验证。

这两组数据集基于弗吉尼亚州罗斯林一条街道的模拟数据,分别包含 2 086 和 2 000 集。所选数据集使用一系列模拟器生成,包括将卫星图像转换为真实三维场景的工具、生成交通数据的移动模拟器和波束跟踪的工具等。同时,数据集包含每个发射器或接收器的波束对平均接收功率和 LIDAR 传感器收集的三维坐标。选取数据集参数如表 1 所示^[9]。

表 1 数据集参数

Table 1 Dataset parameters

参数	值
载波频率/GHZ	60
基站发射功率/dBm	0
基站天线高度/m	4
波束数量	100
雷达模型	Velodyne HDL-64E2
雷达扫描距离/m	120

所提神经网络结构的对比结构为文献[8]和[9]提出的 13 层神经网络以及文献[10]提出的 8 层神经网络和联邦学习。

本文采用 Top- k 波束搜索准确率 $A(k)$ 和吞吐量比 $T(k)$ 来衡量算法性能。 $A(k)$ 定义为

$$A(k) = E[I\{(p^*, q^*) \in S_k\}], \tag{3}$$

式中: $E[\cdot]$ 为取平均; S_k 为神经网络输出的波束对集合; $I\{\cdot\}$ 为指示函数,定义为

$$I\{(p^*, q^*) \in S_k\} = \begin{cases} 1, & (p^*, q^*) \in S_k \\ 0, & (p^*, q^*) \notin S_k \end{cases} \tag{4}$$

$T(k)$ 定义为

$$T(k) = \frac{E[\max_{(p,q) \in S_k} \log_2(1 + y(p,q))]}{E[\log_2(1 + y(p^*, q^*))]}, \tag{5}$$

式中:分子为神经网络预测的最优波束对的平均吞吐量;分母为穷举搜索的平均吞吐量。

图 4 所示为 Top- k 准确率 $A(k)$ 性能对比,神经网络建议的备选波束数量越多, $A(k)$ 越高。从整体趋势来看,本文所提算法在搜索神经网络建议的波束对中找到最佳波束的 $A(k)$ 更接近 100%。在无需搜索而仅采用神经网络预测波束对的情况下,本文所提模型预测 $A(k)$ 达到 57.7%,相比于其他模型的 31%和 52%有明显提升^[8-10]。并且,本文所提模型仅需平均搜索 7 个波束即可达到 90%准确率。

图 5 所示为 Top- k 吞吐量比 $T(k)$ 性能对比。由式(5)可知, $T(k)$ 越大,算法实现的吞吐量越接近于穷举搜索实现的吞吐量。本文所提算法的 Top- k




图 4 Top- k 准确率 $A(k)$ 性能对比

Figure 4 The comparison of Top- k accuracy $A(k)$

吞吐量比 $T(k)$ 较对比算法更大,性能更优。在无需搜索而仅采用神经网络预测波束对的情况下,本文所提模型的 $T(k)$ 达到穷举搜索的 76.3%,而对比模型^[8-10]仅为 46%和 70%。




图 5 Top- k 吞吐量比 $T(k)$ 性能对比

Figure 5 The comparison of Top- k throughput $T(k)$

图 6 所示为算法收敛性对比,横坐标 $epoch$ 为神经网络迭代次数,纵坐标为神经网络仅预测一个最优波束对的准确率即 $A(1)$ 。由图可知,3 类算法均具有收敛性,且本文所提 GCNet 算法估计准确性明显优于对比算法。




图 6 算法收敛性对比

Figure 6 The comparison of algorithm convergence

表 2 所示为本文所提算法和对比算法的运行时间。由表可知,本文所提算法运行时间略高于对比算法,原因在于所提算法增加了 GCNet 模块,提高

了估计准确率。尽管新增的模块略微增加了算法复杂度,但极大地提高了算法性能。

表 2 运行时间对比

Table 2 Running time comparison

方案	时间/ μs
GCNet	2.842
文献[10]	2.760
文献[8-9]	2.584

3 结束语

针对毫米波波束搜索开销较大的问题,本文提出了一种基于 GCNet 的毫米波波束选择算法,所提算法利用位置和 LIDAR 数据训练神经网络,预测最佳波束对,减少波束搜索开销。本文所提算法在雷达数据输入的卷积层之间添加最大池化层防止过拟合,并加入了 GCNet 加强特征提取,GPS 坐标也同样先经过两个线性层,再将两个支路汇总进行训练。GCNet 模型结合 NLA 模型与 SE 模型,在对全局特征上下文建模的同时减少了参数计算量。仿真结果表明,本文所提算法在波束分类精度上更接近 100%,同时,吞吐量比更接近穷举搜索算法。

参考文献:

[1] Choi J, Va V, Gonzalez-Prelcic N, et al. Millimeter-wave Vehicular Communication to Support Massive Automotive Sensing[J]. IEEE Communications Magazine, 2016, 54(12):160–167.

[2] Va V, Choi J, Heath R W. The Impact of Beamwidth on Temporal Channel Variation in Vehicular Channels and Its Implications[J]. IEEE Transactions on Vehicular Technology, 2017, 66(6):5014–5029.

[3] Wei L L, Li Q, Wu G. Initial Access Techniques for 5G NR: Omni/beam SYNC and RACH Designs[C]// 2018 International Conference on Computing, Networking and Communications (ICNC). Maui, HI, USA: IEEE, 2018:249–253.

[4] Hur S, Kim T, Love D J, et al. Millimeter Wave Beamforming for Wireless Backhaul and Access in Small Cell Networks[J]. IEEE Transactions on Communications, 2013, 61(10):4391–4403.

[5] 侯嘉智,梁晶,刘高路. 基于机器学习的波束搜索算法设计[J]. 光通信研究, 2020(4):62–67.

Hou J Z, Liang J, Liu G L. A Beam Search Algorithm based on Machine Learning [J]. Study on Optical Communications, 2020(4):62–67.

[6] Klautau A, Batista P, González-Prelcic N, et al. 5G

- MIMO Data for Machine Learning: Application to Beam-selection Using Deep Learning[C]//2018 Information Theory and Applications Workshop (ITA). San Diego, CA, USA: IEEE, 2018:8503086.
 - [7] Wang Y Y, Klautau A, Ribero M, et al. Mmwave Vehicular Beam Training with Situational Awareness by Machine Learning [C]//2018 IEEE Globecom Workshops (GC Wkshps). Abu Dhabi, United Arab Emirates: IEEE, 2018:8644288.
 - [8] Klautau A, González-Prelcic N, Heath R W. LIDAR Data for Deep Learning-based mmWave Beam-selection [J]. IEEE Wireless Communications Letters, 2019, 8(3):909—912.
 - [9] Dias M, Klautau A, González-Prelcic N, et al. Position and LIDAR-aided mmWave Beam Selection Using Deep Learning [C]//2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Cannes, France: IEEE, 2019:8815569.
 - [10] Mashhadi M B, Jankowski M, Tung T Y, et al. Federated mmWave Beam Selection Utilizing LIDAR Data [J]. IEEE Wireless Communications Letters, 2021, 10(10):2269—2273.
 - [11] Zecchin M, Mashhadi M B, Jankowski M, et al. LIDAR and Position-aided mmWave Beam Selection with Non-local CNNs and Curriculum Training[J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 2979—2990.
 - [12] Cao Y, Xu J R, Lin S, et al. Gcnet: Non-local Networks Meet Squeeze-excitation Networks and Beyond [C]//2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW). Seoul, Korea (South): IEEE, 2019:00246.
- ~~~~~
- (上接第 71 页)
- [38] Luo L F, Wang S. The Design and Implement of an Underwater Wireless Optical Communication and Localization System [C]//2008 Chinese Control and Decision Conference. Yantai, China: IEEE, 2008:4597932.
 - [39] 许力. 水下无线光通信网络节点移动模型与部署算法研究[D]. 武汉: 华中科技大学, 2020.
Xu L. Research on Node Mobility Model and Deployment Algorithm of Underwater Wireless Optical Communication Network [D]. Wuhan: Huazhong University of Science and Technology, 2020.
 - [40] Zhang D, Doye I N, Ballal T, et al. Localization and Tracking Control Using Hybrid Acoustic-optical Communication for Autonomous Underwater Vehicles [J]. IEEE Internet of Things Journal, 2020, 7(10):10048—10060.
 - [41] Tomic S, Beko M, Tuba M. A Linear Estimator for Network Localization Using Integrated RSS and AOA Measurements [J]. IEEE Signal Processing Letters, 2019, 26(3):405—409.
 - [42] Tomic S, Beko M, Dinis R. Distributed RSS-AoA based Localization with Unknown Transmit Powers [J]. IEEE Wireless Communications Letters, 2016, 5(4): 392—395.
 - [43] Akhoundi F, Minoofar A, Salehi J. Underwater Positioning System based on Cellular Underwater Wireless Optical CDMA Networks [C]//2017 26th Wireless and Optical Communication Conference (WOCC). Newark, NJ, USA: IEEE, 2017:7928991.
 - [44] Saeed N, Celik A, Al-Naffouri T Y, et al. Underwater Optical Sensor Networks Localization with Limited Connectivity [C]//2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Calgary, AB, Canada: IEEE, 2018:8461567.
 - [45] Saeed N, Celik A, Al-Naffouri T Y, et al. Performance Analysis of Connectivity and Localization in Multi-hop Underwater Optical Wireless Sensor Networks [J]. IEEE Transactions on Mobile Computing, 2019, 18(11):2604—2615.
 - [46] Saeed N, Celik A, Al-Naffouri T Y, et al. Energy Harvesting Hybrid Acoustic-optical Underwater Wireless Sensor Networks Localization [J]. Sensors, 2018, 18:18010051.
 - [47] Li Y, Liu M Q, Zhang S L, et al. Node Dynamic Localization and Prediction Algorithm for Internet of Underwater Things [J]. IEEE Internet of Things Journal, 2022, 9(7):5380—5390.
 - [48] Li Y, Liu M Q, Zhang S L, et al. Particle System-based Ordinary Nodes Localization with Delay Compensation in UWSNs [J]. IEEE Sensors Journal, 2022, 22(7):7157—7168.
 - [49] Irshad M, Liu W Y, Wang L, et al. Cogent Machine Learning Algorithm for Indoor and Underwater Localization Using Visible Light Spectrum [J]. Wireless Personal Communications, 2021, 116(2):993—1008.