

基于 1DCNN 和 LSTM 融合的超宽带 NLoS/LoS 识别方法研究

郑恩让¹, 孟鑫¹, 姜苏英^{1,2}, 薛晶¹, 张毅¹, 李强¹

(1. 陕西科技大学电气与控制工程学院, 陕西 西安 710021; 2. 贵州大学大数据与信息工程学院, 贵州 贵阳 550025)

摘要: 为提升超宽带 (UWB) 定位系统在非视距 (NLoS) 条件下的测距精度与定位性能, 提出一种基于一维卷积-卷积长短期记忆 (LSTM) 注意力网络 (1DCNN-CLANet) 的深度学习模型。该模型首先利用卷积神经网络 (CNN) 提取通道脉冲响应 (CIR) 的空间特征, 并利用长短期记忆网络捕捉 CIR 的时序特征。其次, 利用 CNN 深度挖掘距离数据、信号振幅、最大噪声强度等额外特征。最后, 引入注意力机制并构建 CIR 分支和额外特征分支的融合模型, 实现对 UWB 信号的非视距/视距识别。实验结果表明, 复杂环境下 1DCNN-CLANet 的二分类和四分类识别准确率分别为 99.51% 和 98.47%, 优于其他方案。该模型在 UWB 定位系统中表现出良好的非视距识别能力, 具有较强的应用前景。

关键词: 超宽带; 非视距; 深度学习模型; 卷积神经网络; 长短期记忆网络

中图分类号: TN98

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025102

Research on ultra wide band NLoS/LoS recognition method based on the fusion of 1DCNN and LSTM

ZHENG Enrang¹, MENG Xin¹, JIANG Suying^{1,2}, XUE Jing¹, ZHANG Yi¹, LI Qiang¹

1. School of Electrical and Control Engineering, Shaanxi University of Science and Technology, Xi'an 710021, China

2. School of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China

Abstract: A deep learning model based on one-dimensional-convolutional neural network-convolutional long short-term memory (LSTM) attention network (1DCNN-CLANet) was proposed to improve the ranging accuracy and positioning performance of ultra wide band (UWB) localization systems under non-line-of-sight (NLoS) conditions. Convolutional neural network (CNN) was first employed to extract spatial features from channel impulse response (CIR) data, and LSTM network was used to capture their temporal characteristics. Then, CNN was further applied to extract additional features such as distance data, signal amplitude, and maximum noise strength. Finally, An attention mechanism was then incorporated to fuse the CIR and additional feature branches for accurate NLoS/LoS classification. Experimental results show that 1DCNN-CLANet achieves classification accuracies of 99.51% for binary classification and 98.47% for four-class classification in complex environments, outperforming other approaches. The model demonstrates strong potential for robust NLoS identification in practical UWB localization systems.

Keywords: UWB, NLoS, deep learning model, CNN, LSTM network

0 引言

随着社会经济和科学技术的快速发展, 各行各业对精确定位的需求越来越高, 基于位置的服务在

人类生活中发挥着至关重要的作用^[1], 如室内机器人、自动驾驶、智能交通等^[2]。现今, 在一般的室外环境下, 全球导航卫星定位 (GNSS, global navi-

收稿日期: 2025-02-14; 修回日期: 2025-05-23

基金项目: 陕西省自然科学基金基础研究计划基金资助项目 (No.2024JC-YBQN-0400)

Foundation Item: The Natural Science Basic Research Program of Shaanxi Province (No.2024JC-YBQN-0400)

gation satellite system) 已经满足绝大部分行业的定位精度需求^[3]。但是在一些卫星拒止环境下, GNSS就失去其有效性了, 这也促使了室内定位系统的快速发展^[4-5]。随着传感器技术的进步, Wi-Fi、接收信号强度指示 (RSSI, received signal strength indication)、超宽带 (UWB, ultra wide band) 定位等技术被广泛应用^[6]。UWB定位技术因其精度高、低功耗以及强穿透能力, 逐渐成为卫星拒止环境下精确定位的理想选择^[7]。目前, UWB定位技术主要按照信号的接收方式分为基于到达时间 (TOA, time of arrival)、基于到达时间差 (TDOA, time difference of arrival)、基于接收强度 (RSS, received signal strength) 等^[8-9]。为了更好地利用UWB定位技术的带宽大、持续时间长、时间分辨率高的优势, 主要采用TOA的测距方式^[10]。但是使用UWB定位技术存在一定的问题, 其容易受到非视距 (NLoS, non line of sight) 情况的影响, 并且多径效应的影响大大降低了UWB定位技术的定位精度。在现有的大部分UWB定位设备中, 所使用的三边定位、最小二乘法和泰勒算法等定位算法^[11], 都假设是在理想的视距 (LoS, line of sight) 情况下。

UWB定位设备在实际使用过程中必须在锚点与标签之间没有遮挡且距离墙壁1.5 m左右才可以保证厘米级别的精度。因此, 对于NLoS的识别以及对其进行距离修正至关重要。近年来, UWB定位技术的NLoS识别的进步极大地提高了室内环境中的定位精度。Lee等^[12]提出了一种基于卡尔曼滤波器的NLoS识别方法, 通过分析信号路径截面的变化来判断NLoS状态。然而, 该方法对环境变化较为敏感, 识别率不够稳定。Yang等^[13]则提出了一种基于特征选择策略的NLoS识别方法, 通过优化特征集合来提高定位精度, 但其识别效果在不同环境下波动较大, 缺乏通用性。Yu等^[14]开发了一种环境依赖性较低且无须先验知识的NLoS识别方法, 能够识别特定的NLoS信道特征, 然而, 该方法在复杂环境中识别准确率较低, 难以满足实际应用需求。韦子辉等^[15]基于信道冲激响应 (CIR, channel impulse response) 提出了一种结合特征饱和度和特征选择优化的加权K近邻算法, 显著提升了NLoS识别准确率。尽管该算法计算复杂度较低, 适用于资源受限的设备, 但其依赖于人工特征提取, 可能遗漏潜在的关键信息。此

外, 手动提取特征的过程复杂, 存在一定的主观性和信息损失风险。随着深度学习技术的快速发展, 基于深度学习的NLoS/LoS识别方法逐渐受到广泛关注。这类方法通过让模型直接学习UWB定位数据中的特征, 自动提取有效信息, 实现端到端的识别过程。Jiang等^[16]提出了一种结合可逆变换去噪处理与卷积神经网络 (CNN, convolutional neural network) 的NLoS识别方法, 在欧洲地平线2020项目动态无线网络实验 (eWINE, elastic wireless networking experimentation) 的公开数据集上最高识别准确率为81.68%。Jiang等^[17]结合CNN和长短期记忆 (LSTM, long short-term memory) 网络, 使识别准确率提升至82.14%, 但依然面临模型性能提升空间有限的问题。Pei^[18]提出了一种基于全卷积网络 (FCN, fully convolutional network) 的方法, 通过引入自注意力机制增强特征提取能力, 最终在公开数据集上的分类准确率达到88.24%。尽管相比CNN、LSTM、CNN-LSTM等方法有了显著提升, 但该方法在数据集质量和规模不足的情况下表现较差, 模型的泛化能力存在局限性。文献[19-20]提出了将一维CIR数据转换为二维图像再利用深度学习进行识别的创新方法。然而, 这种方法的识别精度受图像转换过程及尺寸参数的影响, 且运行效率较低, 不适用于实时场景。

针对现有NLoS识别方法中人工提取特征可能忽略其他特征的潜在信息、复杂环境中难以选取合适的阈值导致最后的识别效果不佳, 以及使用深度学习方法的识别精度、通用性以及运行效率不高等问题, 本文以构建一个识别准确率较高、通用性较强的NLoS识别模型为目的, 将接收到的UWB信号输入模型, 进行信号分类。本文采用一种创新性的并联卷积神经网络架构, 旨在充分挖掘UWB定位的CIR及额外特征中的潜在信息, 以提升NLoS识别的准确性与鲁棒性。模型的CIR分支针对CIR数据, 设计了多层一维卷积网络, 用以提取CIR数据的空间特征, 再进入两层LSTM网络, 用以提取其深层次的时序特征; 额外特征分支通过多层一维卷积网络处理额外特征, 捕捉不同层级的信息。在特征融合之前, 模型在两分支输出中引入注意力机制, 自动调整特征权重, 增强对分类有用信息的聚焦效果。融合后的综合特征通过全连接层进行进一步学习, 以生成最终的分类预测。此并联结构通过

多通道信息的协同处理,显著提升了系统在复杂环境下的稳定性与泛化能力。本文的主要贡献如下。

1)提出一种创新性的并联网络架构,CIR分支通过一维CNN(1DCNN)和LSTM网络提取CIR数据的空间和时序特征;额外特征分支则利用1DCNN处理额外特征,从而全面挖掘UWB定位信号数据的潜在信息。

2)在两分支的输出中引入注意力机制,自动聚焦于分类任务中最为重要的信息,提高NLoS识别的准确性和鲁棒性。

3)1DCNN-CLANet模型在各类遮挡物构成的复杂环境下进行实验,在本地数据集上,二分类和四分类任务中分别达到了99.51%和98.47%的准确率;在公开数据集上,二分类识别准确率最低达到90.83%。对比现有模型,本文模型在NLoS识别方面表现优异,并在多个数据集上展示了良好的通用性和泛化能力。

1 相关理论

目前,国内应用最广泛的UWB定位设备主要基于DWM1000射频芯片,该芯片遵循IEEE 802.15.4-2011超宽带标准,具有低发射功耗的特点,并能够实现厘米级别的测距精度。这使UWB定位技术在精确定位、物体追踪等应用中得到了广泛采用。现实情况中使用UWB定位设备时,锚点与标签之间出现NLoS情况,锚点发出的信号会通过反射到达标签端,如图1所示。




图1 NLoS情况传播示例

在UWB定位技术中,UWB锚点发射脉冲信号,标签接收信号之后再给锚点发送脉冲信号,CIR是接收脉冲的总和,通过评估累积传入样本与其前序序列的相关性获取,如式(1)所示。

$$r(t) = \sum_{i=1}^{N_m} a_i p(t - \tau_i) + n(t) \quad (1)$$

其中, N_m 表示多径分量的总数, a_i 表示第 i 条分量的振幅, τ_i 表示第 i 条分量的时延, $n(t)$ 表示高斯白噪声, $p(t)$ 表示接收的脉冲。接收端在LoS和NLoS情况下的CIR波形如图2和图3所示。




图2 LoS情况下的CIR波形




图3 NLoS情况下的CIR波形

从图2和图3可以看出,在LoS环境下,信号可以通过直视路径从锚点发射端传输到标签接收端,因此,信号的衰减较慢且CIR的波形峰值较高。而在NLoS环境下,信号受到遮挡物的影响,仅能通过反射路径从锚点发射端传递到标签接收端,这导致信号的幅度较小,衰减速度较快。通过分析700~900CIR样本点区间可以看出,LoS和NLoS环境下第一路径的峰值差异。在LoS情况下,第一路径的峰值为整个波形的最大值;在NLoS情况下,第一路径的峰值并不是最大值,图3中显示的是下一个波峰。如图1所示,在NLoS环境中,第一路径的信号是由锚点发射端穿墙后到达标签端,信号强度明显减弱;下一个波峰则是由锚点发出的信号经过墙壁反射后传递到标签接收端。

减小 UWB 定位技术在 NLoS 情况下的测距误差或者选择处于 LoS 情况下测距结果进行位置解算对于提高 UWB 定位技术的定位精度是至关重要的。为了解决这个痛点, 科研工作者进行了大量的研究, 目前最常用的方法就是使用 UWB 定位技术在测距过程中的 CIR 特征来识别锚点和标签现在是处于 LoS 还是 NLoS 情况。CIR 可以很详细地描述信道对简短脉冲信号的响应, 从而推测出通信信道的特性。因此, 根据这些不同的特征使得使用机器学习的方法识别 NLoS/LoS 的情况成为可能。

采用 DWM1000 射频芯片可以获取一些特征参数, 如测量距离、CIR 第一路径索引、第一路径振幅点 1、第一路径振幅点 2、第一路径振幅点 3、噪声标准差、总信道脉冲响应功率、噪声最大值以及 CIR 值等, 本文将基于这些特征数据进行 NLoS/LoS 场景识别, 下面将对几种特征进行简单阐述。

1) 测量距离

通过 UWB 定位锚点和标签之间电波的飞行时间乘以光速计算出两模块之间的距离。

$$d = t \cdot c \quad (2)$$

其中, t 表示电波飞行时间, c 表示光速。

2) CIR 第一路径相关值

FP_i 是指通过前沿检测 (FP) 算法检测到的第一路径信号上升沿在累加器中的位置索引。它标识了接收到的信号最早到达路径的时间点。 FP_1 是该索引后第一个累加器抽头处的信号振幅值, 用于表示第一路径信号的强度, 是一个 16 位无符号值。 FP_2 和 FP_3 分别表示累加器中后续路径的信号振幅, 通常对应于多径效应下的其他反射路径。这 3 个振幅值可综合用于评估接收信号质量以及第一路径时间戳的准确性, 特别是在多径环境中判断信号干扰和路径分辨情况。

3) 噪声标准差

$$s_{n(t)} = \sqrt{\frac{\sum_{i=1}^N (n(t) - u_{n(t)})^2}{N}} \quad (3)$$

$$u_{n(t)} = \frac{1}{N} \sum_{i=1}^N n(t) \quad (4)$$

其中, $s_{n(t)}$ 表示噪声标准差, $n(t)$ 表示噪声, $u_{n(t)}$ 为噪声均值, N 表示 CIR 样本点总数。

4) 总信道脉冲响应功率

$$P = \frac{1}{N} \sum_{i=1}^N (h(t))^2 \quad (5)$$

其中, $h(t)$ 表示脉冲大小。

5) 噪声最大值

$$n(t)_{\max} = \max\{|n(t_i)|\}, i = 1, \dots, N \quad (6)$$

其中, $n(t_i)$ 表示第 i 个 CIR 样本点的噪声大小。

本文所选取的特征有 CIR 特征 $X_1 = [z^1, z^2, \dots, z^N]^T$, 其中 z 表示每个 CIR 样本点; 额外特征 $X_2 = [d, FP_1, FP_2, FP_3, s_{n(t)}, P, n(t)_{\max}]^T$ 。

2 识别算法

为了提高 NLoS 的识别准确率, 本文提出一种基于 1DCNN-CLANet 的 UWB 定位 NLoS/LoS 识别情况的轻量化网络模型。1DCNN-CLANet 架构提取 CIR 信号的空间和时序特征, 以及计算出的额外特征, 用于 UWB 的信道模型分类, 如图 4 所示。1DCNN-CLANet 架构主要由 CIR 分支和额外特征分支组成, 进行特征提取, 融合得到最后的分类结果。CIR 分支集成了 CNN 和 LSTM 网络, CNN 用于 CIR 的空间特征提取, LSTM 网络用于 CIR 时间特征提取。额外特征分支主要是为了深度发掘测量范围、CIR 中检测到的第一个路径元素的指数、第一路径振幅、噪声标准差、总信道脉冲响应功率和噪声最大值的潜在信息来提高最终识别的准确率。

此外, 为防止模型在训练过程中发生过拟合并提升其泛化能力, 本文在各卷积层后及全连接层之间引入了随机失活 (Dropout) 方法, 在训练阶段以一定概率丢弃部分神经元。为将卷积层输出的多维特征张量传递至全连接层, 进一步采用展平 (Flatten) 操作, 将其转化为一维向量以供后续分类处理。

2.1 CIR 分支

2.1.1 卷积神经网络

在 CIR 分支中, 使用了 CNN。CNN 是一种受生物自然视觉认识机制启发而来的前馈神经网络, 通过构建多个滤波器对输入数据进行多次卷积与池化运算, 从而得到数据内部的高级特征。1DCNN 主要包括卷积层、池化层和全连接层。

卷积层利用滑动卷积核执行卷积操作, 之后这些卷积核的输出通常会被馈送到激活函数中以提取特征, 一维卷积为

$$y_j^l = f\left(\sum_{i=1}^N w_{ij}^l * x_i^{l-1} + b_j^l\right) \quad (7)$$

其中, $*$ 表示卷积运算, N 表示第 $l-1$ 层的输入通

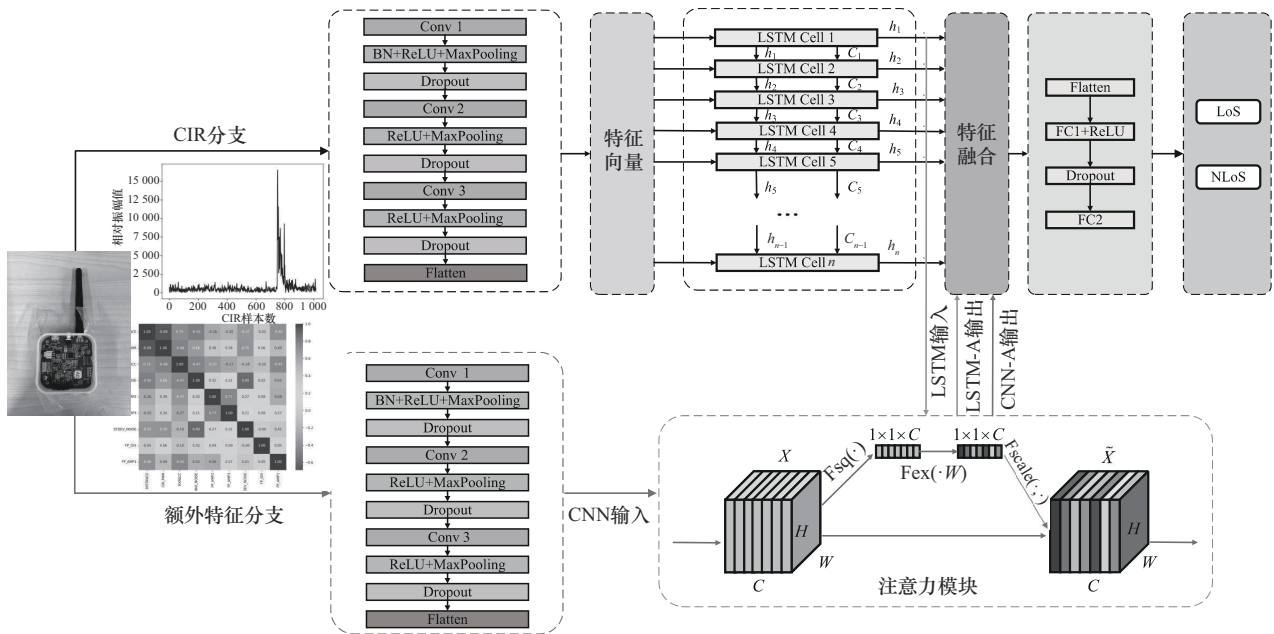


图 4 1DCNN-CLANet 架构

道数, x_i^{l-1} 表示 $l-1$ 层的第 i 个特征映射, w_{ij}^l 表示权重, b_j^l 表示 l 层第 j 个卷积核的偏置, y_j^l 表示非线性激活函数。本文使用 ReLU 函数, 可以使神经元具有稀疏激活性。

为进一步减少训练参数, 通常需要进行池化操作。本文使用最大池化 (MaxPooling) 对滑动区域内的数据进行压缩处理, 其过程为

$$p_i^{l+1}(j) = \max_{(j-1)w+1 \leq t \leq jw} \{q_i^l(t)\} \quad (8)$$

其中, $q_i^l(t)$ 表示第 l 层内第 i 个特征量对应的第 t 个神经元的值, w 表示池化层宽度, $p_i^{l+1}(j)$ 表示第 $l+1$ 层神经元。

将网络末端的池化层进行扁平化处理并与一层或多层全连接层相连进行最后的分类。CIR 分支 1D-CNN 网络结构输入是 1×1016 序列的数据, 设计使用 3 个卷积层, 第一层具有批量归一化层 (BN, batch normalization)、ReLU 激活函数、最大

池化以及 Dropout, 第二、三层不具有 BN, 其他与第一层结构一致。CIR 分支 1DCNN 结构如图 5 所示。

2.1.2 LSTM 网络

1DCNN 具有一定的局限性, 由于固定窗口感受野的限制, 难以直接捕获长期依赖关系, 参数过多而倾向于过拟合, 以及对含有时间序列的数据关系识别不足。为了让网络具有长期记忆能力, Hochreiter 等^[21]提出了 LSTM 网络, 其是循环神经网络 (RNN, recurrent neural network) 的一种变体, 通过合并内存块熟练地处理时间序列数据。LSTM 网络包含一个遗忘门、一个输入门、一个单元状态更新和一个输出门, 这些门决定了哪些信息应该被遗忘, 哪些信息应该被存储在单元状态中, 以及哪些信息应该在输出中体现出来。

在 CIR 分支中, 将 CNN 提取的特征进行平面化处理, 然后送进具有 128 个隐藏单元的 LSTM 网

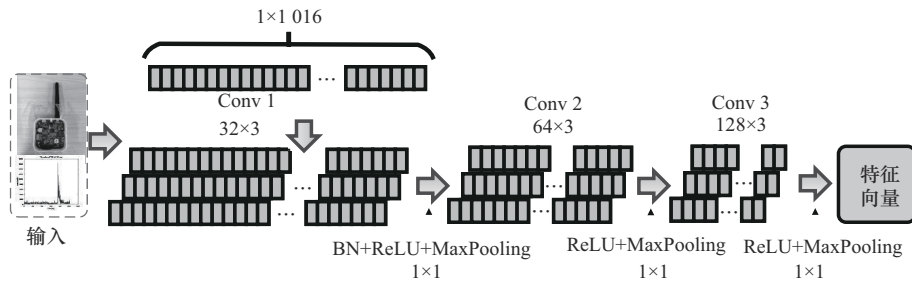


图 5 CIR 分支 1DCNN 结构

络中生成时空特征序列。LSTM网络可以有效地管理时间依赖性和复杂序列，从而抑制传统前馈神经网络中的计算限制和错误传播问题。LSTM网络结构如图6所示。

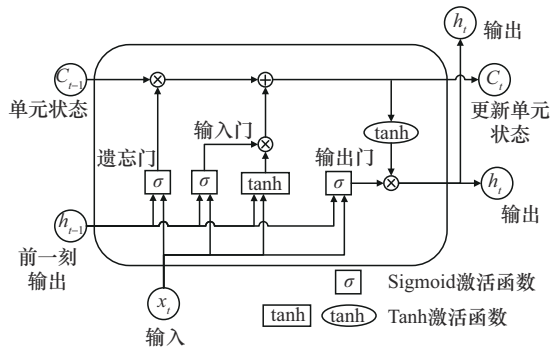


图6 LSTM网络结构

遗忘门决定什么信息应该被遗忘，它使用 Sigmoid 激活函数，得到一个 0~1 的数值，这个生成的数值代表的是有多少的信息会被保留。0 表示遗忘所有信息，1 表示保留所有信息。具体数学表达式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

其中， f_t 表示遗忘门的激活向量（输出）， W_f 表示权重矩阵， b_f 表示偏置项， h_{t-1} 表示前一个时间步的隐藏状态， x_t 表示当前时间步的输入， σ 表示 Sigmoid 函数。

输入门控制当前时间步的输入如何影响记忆单元的状态。输入门包括 2 个部分，第一部分是 Sigmoid 层，决定哪些信息会更新到记忆单元；第二部分是 Tanh 层，创建一个新的候选值向量，这个向量可能会被加到状态中，具体数学表达式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (11)$$

其中， i_t 表示输入/更新门的激活向量， \tilde{C}_t 表示单元输入激活向量，Tanh 表示双曲正切函数（得到的值为 -1~1）。

新的记忆单元状态 C_t 是前一段时间步的状态 C_{t-1} 和当前时间步的候选记忆 \tilde{C}_t 的加权和。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (12)$$

输出门决定了基于单元状态输出什么值。首先，使用 Sigmoid 层决定哪部分状态将输出，然后将单元状态经过 Tanh 激活，得到的结果再与 Sigmoid 门的输出相乘，最终形成模型的预测输出。具体数学表达式为

$$O_t = \sigma(W_O[h_{t-1}, x_t] + b_O) \quad (13)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (14)$$

其中， O_t 表示输出门的激活向量， h_t 表示当前单元的输出。

2.2 额外特征分支

在额外特征分支中，其数据并不具备时序信息因此采用 1DCNN 对数据进行特征提取。额外特征分支 1DCNN 结构输入的是 1×9 序列的数据，设计使用 3 个卷积层，第一层具有 BN、ReLU 激活函数、Sigmoid 以及 Dropout，第二、三层不具有 BN，其他与第一层结构一致。额外特征分支 1DCNN 结构如图 7 所示。

2.3 自定义 AttentionLayer 模块

在现实复杂的电磁环境下，UWB 定位锚点与标签之间的区别特征较弱。由于特征提取有限，无法捕捉足够的长期依赖关系以及高度依赖特征工程，传统办法难以将 CIR 数据用于 NLoS/LoS 分类。计算机视觉研究表明，注意力机制可以很好地增强神经网络的特征学习。注意力机制根据特征的重要性自适应地对其进行加权。在本文研究的 UWB 定位的 CIR 数据以及额外特征数据场景分类中，数据特征的分布通常具有较为稀疏或高维的特性，数据特征之间的依赖关系可能会影响最终的分类效果。注意力机制是一种适应性特征加权方法，能够动态地分配特征权重，突出重要特征的贡献。本文采用自定义的 AttentionLayer 模块实现局部特征的加权处




图7 额外特征分支 1DCNN 结构

理,如图8所示。该模块通过一个密集神经层(Dense)计算每个特征的重要性权重,并基于这些权重调整特征在模型中的表达能力。具体而言,Attention-Layer模块通过单独定义的密集神经层,利用Softmax激活函数为每个输入特征分配一个归一化的权重,进而使得各特征的权重在整体集合中形成加权分布,从而提升模型对重要特征的关注。该模块的实现过程如下。




图8 AttentionLayer模块结构

首先进行权重计算,设输入特征为 $X=[x_1, x_2, \dots, x_n]$,该层通过密集神经层计算出每个特征的注意力权重 a_i 。

$$a_i = \text{Softmax}(w_{\text{att}} \cdot x_i + b_{\text{att}}) \quad (15)$$

其中, x_i 表示第*i*个输入特征, w_{att} 表示密集神经层的权重参数, b_{att} 表示偏置项。

在权重分配之后,每个特征的值通过与相应的权重 a_i 相乘,形成加权输出 X' 。


$$X' = [a_1 x_1, a_2 x_2, \dots, a_n x_n] \quad (16)$$

这种加权方式实际上是一种逐特征加权机制,使得网络能够关注对分类有较大贡献的特征,抑制信息量较少的特征。


为验证AttentionLayer模块在架构中对关键特征的关注能力,本文从特征间相关性角度进行分析。若AttentionLayer模块有效,应能增强重要特征之间的一致性,或抑制与任务无关特征的干扰。例如,多个特征之间若表现出较强的正相关性,说明它们在注意力作用后得到了同步增强;反之,若存在负相关性,则可能表明某些特征被Attention-Layer模块抑制。

本文分别对不同输入分支在注意力机制前后的特征输出进行相关性热图绘制。考虑到Attention-Layer模块前一层的特征输出维度较高,为确保相关性分析的可视性,本文选取其中10个特征进行分析。图9(a)展示的是额外特征分支在进入注意力

机制前后的相关性热图。从图9(a)中可以看出,特征1、特征3、特征4、特征6、特征8和特征10之间呈现出较高的正相关,而特征5与其他特征则普遍呈现负相关关系,这表明AttentionLayer模块在该分支中有效地区分了应被增强与应被抑制的特征集合。图9(b)展示的是CIR分支进入AttentionLayer模块前后的相关性热图。结果显示,特征1与特征5、特征7、特征8之间具有较强正相关性,而特征2与其他特征之间的相关性整体较低,表明AttentionLayer模块加强了关键特征,同时对无关特征(如特征2)起到了抑制作用。



(a) 额外特征分支



(b) CIR分支

图9 额外特征分支和CIR分支进入AttentionLayer模块前后的相关性热图

综上所述,通过特征相关性变化的可视化分析可得,本文所引入的AttentionLayer模块在关键特

征聚焦和非关键特征抑制方面具有良好效果，体现出其在提升模型判别能力方面的有效性。

2.4 预测分类

1DCNN-CLANet的网络结构如表1所示。在利用注意力机制增强CIR分支以及额外特征分支输出序列中的关键UWB特征之后，本文首先将两支分路进行融合 $\text{combined} = \text{Concatenate}([x, y])$ ，然后使用Dense全连接层进行特征变换，激活函数使用ReLU函数，最后使用Softmax层作为分类器，定义输出二分类的结果。

表1 1DCNN-CLANet的网络结构

模型	层级结构	卷积核	输出
CIR分支	Conv 1	32×3	32×1016
	BN+ReLU+MaxPooling	1×2	32×508
	Conv 2	64×3	64×508
	ReLU+MaxPooling	1×2	64×254
	Conv 3	128×3	128×254
	ReLU+MaxPooling	1×2	128×127
	LSTM	127	Sequence
额外特征分支	Attention	64, 1	—
	Flatten	—	1×64
	Conv 1	16×3	16×8
	BN+ReLU+MaxPooling	1×2	16×4
	Conv 2	32×3	32×4
	ReLU+MaxPooling	1×2	32×2
	Conv 3	64×3	64×2
标签预测	ReLU+MaxPooling	1×2	64×1
	Attention	64, 1	—
	Flatten	—	1×64
	Dense	32	—
	输出	2	—

1DCNN-CLANet的超参数设置如表2所示，采用Adam优化器，训练批次大小设置为32，训练初始学习率设置为0.0001，训练次数设置为100。为防止过拟合并提高泛化能力，使用L2正则化、学习率衰减、早停法和Dropout，其中Dropout设置为0.5。

表2 1DCNN-CLANet的超参数设置

超参数	设置大小
批次大小	32
训练次数	100
优化器	Adam
学习率	0.0001
损失函数	categorical_crossentropy

模型采用独热编码，因此将损失函数设置为categorical_crossentropy，这种编码方式的选取使得模型具备扩展为多分类模型的潜力。

3 实验验证

3.1 实验设置与数据集描述

本节使用本地的数据集测试了本文提出的NLoS识别模型的二元分类性能。数据集是从地下停车场以及大厅走廊收集而来的，在墙壁遮挡环境下，提供3700个LoS样本以及3700个NLoS样本，总共7400个样本；在单车遮挡的环境下，提供3200个LoS样本以及3200个NLoS样本，总共6400个样本。实验使用的是DecaWave DWM1000射频芯片进行数据收集，模块固定在三脚架上面，在LoS情况下UWB高度为1.5m，在墙壁遮挡和单车遮挡的情况下UWB高度为1m。在大厅走廊的环境下，提供500个LoS样本以及500个NLoS样本，总共1000个样本数据。

在每批UWB数据的采集过程中，“ Δ ”表示LoS锚点，“ \square ”表示LoS标签，“ \blacktriangle ”表示NLoS锚点，“ \blacksquare ”表示NLoS标签。具体实验过程中，首先，将锚点的位置保持静止。随后，标签每次以0.5m的固定步长依次移动，进行采样，直至覆盖所需采样区域，完成一组数据采集。最后，将锚点移动至下一个指定位置，重复上述标签的移动和采样操作，直至完成全部的数据采集实验。图10(a)是在地下停车场采集的数据，分别进行了LoS、NLoS（墙壁遮挡和单车遮挡）情况下测距；图10(b)给出了每一批UWB数据采集时锚点和标签的大致位置信息。测距位置中，空心标记代表LoS情况下的采样点，实心标记代表NLoS情况下的采样点。

实验在一台运行Ubuntu 20.04操作系统的台式计算机上执行，该计算机配备了12th Gen Intel(R) Core(TM) i7-12700KF CPU、32 GB内存和NVIDIA GeForce RTX 4060，本文模型主要基于TensorFlow。

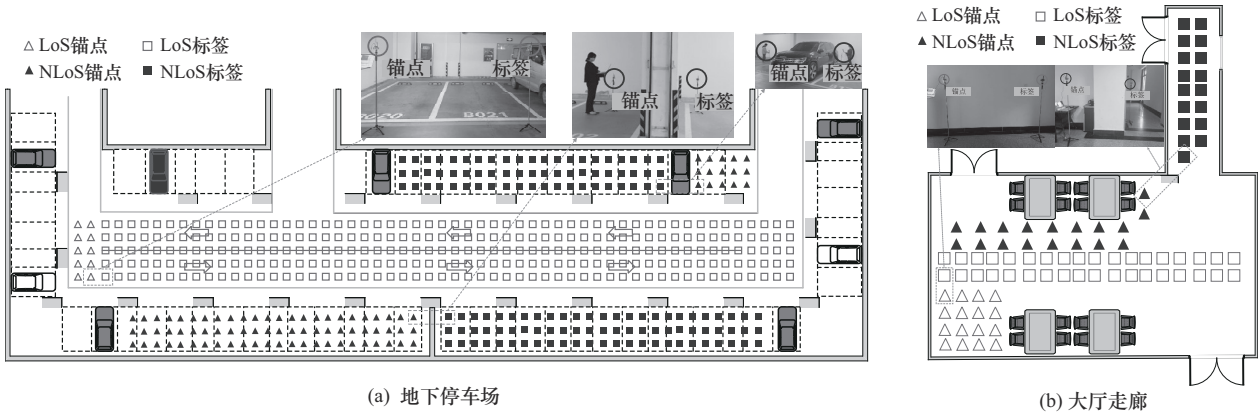


图10 实验环境

本文使用准确率 (Accuracy)、召回率 (Recall)、精确率 (Precision) 和 F1 分数 (F1) 这 4 个指标评估 NLoS 识别的准确性。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

$$Recall = \frac{TP}{TP + FN} \quad (18)$$

$$Precision = \frac{TP}{TP + FP} \quad (19)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (20)$$

其中, 真阳性 (TP) 为正确分类的阳性样本, 真阴性 (TN) 为正确分类的阴性样本, 假阳性 (FP) 为错误分类的阳性样本, 假阴性 (FN) 为错误分类的阴性样本。

3.2 结果与分析

本文从以下方面对 1DCNN-CLANet 模型进行了评估。首先, 验证其在 NLoS/LoS 二分类任务中的有效性; 其次, 扩展至 LoS 及多 NLoS 场景进行验证; 最后, 通过消融实验分析不同结构对分类性能和训练成本的影响, 并与其他模型对比, 进一步证明了本文模型的有效性。为了贴切真实场景中的不同障碍物的遮挡造成的不同程度的测距误差, 本节进行了对数据集的多分类实验。

3.2.1 不同识别模型的对比实验

选取传统机器学习模型支持向量机 (SVM, support vector machines) [22]、偏最小二乘法判别分析 (PLS-DA, partial least squares discriminant analysis)、CNN^[16]以及 CNN-LSTM^[23]模型与本文的 1DCNN-CLANet 模型进行比较, 验证其先进性。SVM 使用文献[22]的原始模型和参数。将表 2 的超参数作为

1DCNN-CLANet、CNN 和 CNN-LSTM 的超参数设置。CNN 和 CNN-LSTM 的结构如图 11 所示。

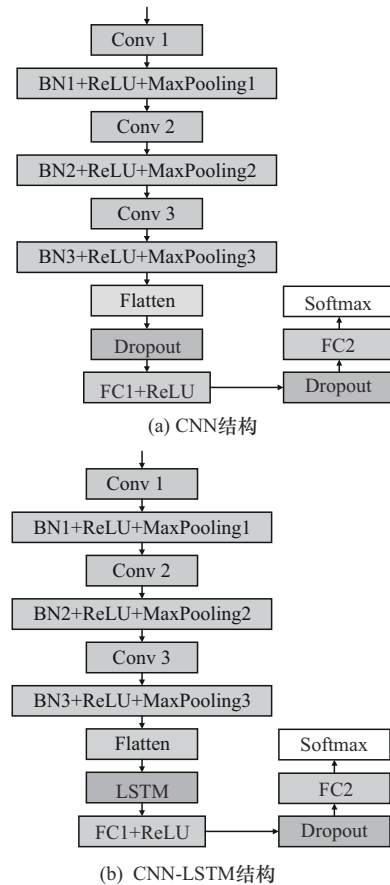


图11 CNN和CNN-LSTM的结构

网络结构的具体参数如表 3 所示。本文在 CNN、CNN-LSTM 和 1DCNN-CLANet 的模型中将数据集划分为 70% 训练集、20% 验证集以及 10% 测试集, 在 SVM 和 PLS-DA 的模型中将数据集划分为 80% 训练集和 20% 测试集。实验结果展示了各种

NLoS/LoS二分类模型在准确率、精确率、召回率以及F1分数这4个评估指标上的性能比较。

表3 网络结构的具体参数

模型	网络层	卷积大小
CNN	Conv 1	16 × 3
	BN1+ReLU+MaxPooling1	1 × 2
	Conv 2	32 × 3
	BN2+ReLU+MaxPooling2	1 × 2
	Conv 3	64 × 3
	BN3+ReLU+MaxPooling3	1 × 2
	FC1+ReLU	128
CNN-LSTM	Dropout	0.5
	Conv 1	16 × 3
	BN1+ReLU+MaxPooling1	1 × 2
	Conv 2	32 × 3
	BN2+ReLU+MaxPooling2	1 × 2
	Conv 3	64 × 3
	BN3+ReLU+MaxPooling3	1 × 2
CNN-LSTM	LSTM	512
	FC1+ReLU	128
	Dropout	0.5

在单场景下先后进行了墙壁遮挡情况下和单车遮挡情况下的数据集的训练和测试，实验结果分别如表4和表5所示。在墙壁遮挡情况下，与

CNN-LSTM相比，1DCNN-CLANet的准确率、精确率、LoS/NLoS召回率以及F1分数分别提高了3.5%、3.5%、2.46%、4.56%以及3.5%；剩下的3种对比模型中，CNN的准确率为94.83%，PLS-DA的准确率为87.21%，SVM的准确率为86.33%。

在单车遮挡的情况下，与CNN-LSTM相比，1DCNN-CLANet的准确率、精确率、LoS/NLoS召回率以及F1分数分别提高了3.76%、3.74%、2.94%、4.68%以及3.78%；剩下的3种对比模型中，CNN的准确率为92.58%，PLS-DA的准确率为87.01%，SVM的准确率为85.50%。

不同的遮挡情况会对模型的分类结果产生影响。为此，本文将墙壁遮挡、单车遮挡和墙壁拐角遮挡3种数据集合并，重新划分训练集、验证集和测试集，并将融合后的数据集（以下简称3种情况混合数据集）用于模型的NLoS识别。与CNN-LSTM相比，1DCNN-CLANet的准确率、精确率、LoS/NLoS召回率以及F1分数分别提高了6.89%、6.88%、8.14%、5.55%以及6.88%；剩下的3种对比模型中，CNN的准确率为92.30%，SVM的准确率为89.39%，PLS-DA的准确率为87.83%。经过3次实验表明，引入额外特征分支可以提高模型的二分类精度。

此外，本文对比了各模型在训练单个样本的时间和总参数量，实验结果如表6所示，以衡量模型的计算效率和结构复杂度。从训练时间来看，SVM的单个样本训练时间最高，达3.093 8 ms/样本，

表4 墙壁遮挡的数据集结果

模型	准确率	精确率	LoS召回率	NLoS召回率	F1分数
SVM	86.33%	86.37%	84.65%	88.04%	86.33%
PLS-DA	87.21%	87.56%	82.24%	92.26%	87.21%
CNN	94.83%	94.78%	95.04%	94.64%	94.81%
CNN-LSTM	95.42%	95.43%	95.68%	95.17%	95.43%
1DCNN-CLANet	98.92%	98.93%	98.14%	99.73%	98.93%

表5 单车遮挡的数据集结果

模型	准确率	精确率	LoS召回率	NLoS召回率	F1分数
SVM	85.50%	85.51%	87.43%	83.33%	85.43%
PLS-DA	87.01%	87.03%	88.80%	85.02%	86.96%
CNN	92.58%	93.39%	98.61%	85.93%	92.49%
CNN-LSTM	95.09%	95.11%	95.95%	94.12%	95.07%
1DCNN-CLANet	98.85%	98.85%	98.89%	98.80%	98.85%

表 6 3 种情况混合数据集结果

模型	准确率	精确率	LoS 召回率	NLoS 召回率	F1 分数	运行时间/(ms·样本 ⁻¹)	总参数
SVM	89.39%	89.47%	86.83%	92.13%	89.39%	3.093 8	~2 564 384
PLS-DA	87.83%	87.83%	86.83%	88.89%	87.83%	0.531 5	~101 180
CNN	92.30%	92.39%	94.22%	90.27%	92.29%	1.281 3	120 034
CNN-LSTM	92.62%	92.63%	91.38%	93.94%	92.63%	2.218 7	160 802
1DCNN-CLANet	99.51%	99.51%	99.52%	99.49%	99.51%	1.531 3	483 972

PLS-DA 在该指标上表现最佳, 仅为 0.531 5 ms/样本。CNN 的训练时间为 1.281 3 ms/样本, 明显优于 CNN-LSTM (2.218 7 ms/样本) 和 1DCNN-CLANet (1.531 3 ms/样本)。在模型参数量方面, SVM 由于支持向量数量较多, 其参数量近似为支持向量个数与输入特征维度的乘积, 达到约 2 564 384。PLS-DA 的参数量近似为输入特征至潜在空间的投影权重与潜在变量至输出标签的映射之和, 总计 101 180, 明显低于 SVM。相比之下, 深度学习模型的参数量随结构复杂度增加而上升, 其中, CNN、CNN-LSTM 和 1DCNN-CLANet 的参数量分别为 120 034、160 802 与 483 972。值得注意的是, 尽管 1DCNN-CLANet 结构更复杂, 其单样本训练时间仍低于 CNN-LSTM, 体现出其在计算效率与模型能力之间的好权衡。

此外, 图 12 绘制了 1DCNN-CLANet、SVM、PLS-DA、CNN 和 CNN-LSTM 在 3 种情况混合数据集下识别 NLoS 的受试者工作特性 (ROC, receiver operating characteristic) 曲线, 来进一步评估 1DCNN-CLANet 的有效性。很明显, 1DCNN-CLANet 的曲线下面积 (AUC) 高于其他 4 个模型。

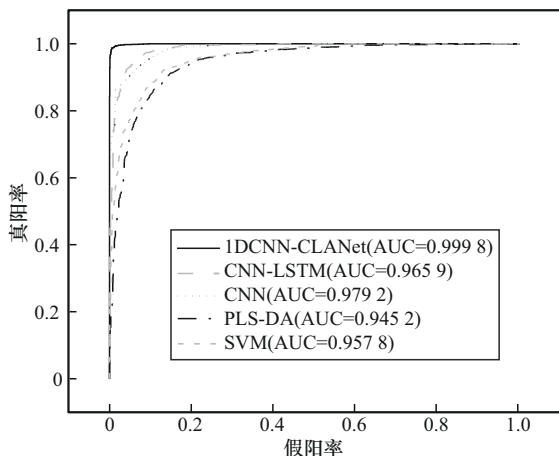


图 12 不同模型在 3 种情况混合数据集下的 ROC 曲线

在判别能力评估基础上, 分别引入标准差为 0.01、0.05、0.10 和 0.20 的高斯噪声, 对测试集进行干扰, 以评估 1DCNN-CLANet 在受噪环境下的鲁棒性, 并与 SVM、PLS-DA、CNN 和 CNN-LSTM 模型进行对比, 实验结果如图 13 所示。结果表明, 当噪声标准差为 0.2 时, 除 SVM 在高噪声下准确率略升外, 其余模型均随噪声增强而性能下降。其中, 1DCNN-CLANet 在噪声最强时仍保持 98.80% 的准确率, 仅下降 0.71%, 表现优于其他模型, 体现出其显著的鲁棒性与稳定性, 具备良好的实际应用潜力。

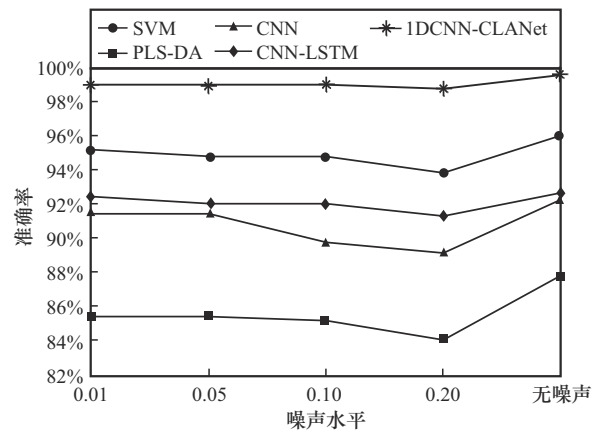


图 13 不同噪声水平下各模型准确率比较

为进一步验证 1DCNN-CLANet 在 UWB NLoS 识别任务中的泛化能力, 采用在欧洲地平线 2020 计划项目 eWINE 资助下由 Bregar 等^[24]构建的公开数据集进行实验, 实验结果如表 7 所示。该数据集涵盖了 7 种典型的室内场景, 分别为办公室 1、办公室 2、小公寓、小作坊、带客厅的厨房、卧室和锅炉房, 其中每个场景包含 3 000 个 LoS 测量样本和 3 000 个 NLoS 测量样本。1DCNN-CLANet 在各类场景中均表现出优越的识别性能, 其在 7 种场景下的最低准确率仍达 90.83%, 并在 NLoS/LoS 两类的召回率上保持良好的均衡性。

表7 eWINE的7种典型场景的数据集结果

数据集	模型	准确率	精确率	LoS 召回率	NLoS 召回率	F1 分数
办公室1	SVM	83.58%	84.19%	90.34%	77.05%	83.54%
	PLS-DA	82.75%	82.03%	86.69%	76.97%	82.72%
	CNN	87.32%	88.21%	95.46%	78.79%	87.13%
	CNN-LSTM	86.65%	87.51%	94.80%	78.10%	86.45%
	1DCNN-CLANet	91.58%	91.81%	95.68%	87.62%	91.57%
办公室2	SVM	80.83%	81.62%	88.85%	72.29%	80.61%
	PLS-DA	80.00%	80.18%	85.13%	74.54%	80.85%
	CNN	83.45%	83.60%	87.74%	78.87%	83.34%
	CNN-LSTM	82.44%	82.61%	87.08%	77.47%	82.32%
	1DCNN-CLANet	90.83%	91.44%	97.28%	83.97%	90.70%
小公寓	SVM	83.17%	83.48%	88.02%	78.30%	83.12%
	PLS-DA	82.42%	82.48%	83.87%	78.96%	82.40%
	CNN	90.19%	90.88%	97.39%	83.36%	90.15%
	CNN-LSTM	89.51%	90.33%	97.39%	82.05%	89.47%
	1DCNN-CLANet	92.17%	92.37%	95.85%	88.47%	92.15%
小作坊	SVM	82.08%	82.93%	90.10%	73.91%	81.94%
	PLS-DA	79.58%	79.76%	84.04%	75.03%	79.51%
	CNN	88.84%	89.18%	93.85%	83.86%	88.80%
	CNN-LSTM	90.19%	90.31%	93.18%	87.21%	90.17%
	1DCNN-CLANet	91.50%	92.11%	97.91%	84.96%	91.42%
带客厅的厨房	SVM	82.08%	83.09%	90.86%	73.56%	81.98%
	PLS-DA	81.33%	81.87%	88.25%	74.62%	81.26%
	CNN	88.84%	89.64%	96.43%	75.27%	88.55%
	CNN-LSTM	82.78%	83.94%	73.89%	92.81%	82.73%
	1DCNN-CLANet	92.33%	92.54%	96.20%	88.58%	92.33%
卧室	SVM	83.08%	83.57%	89.15%	77.21%	83.05%
	PLS-DA	80.58%	80.75%	84.32%	76.97%	80.57%
	CNN	85.13%	86.99%	97.13%	72.47%	84.71%
	CNN-LSTM	86.31%	87.09%	94.18%	78.01%	86.11%
	1DCNN-CLANet	91.33%	91.48%	94.66%	88.11%	91.33%
锅炉房	SVM	85.25%	85.67%	90.82%	79.90%	85.23%
	PLS-DA	82.17%	82.28%	85.27%	79.18%	82.16%
	CNN	89.18%	89.39%	93.27%	84.79%	89.10%
	CNN-LSTM	85.64%	85.66%	84.15%	87.23%	85.64%
	1DCNN-CLANet	92.67%	92.94%	97.18%	88.33%	92.66%

综上所述, 相比于 SVM、PLS-DA、CNN 和 CNN-LSTM, 1DCNN-CLANet 在多个场景下均展现出更高的识别准确率与更强的泛化能力。实验结果

也进一步验证了经过挖掘 UWB 额外特征的潜在信息有利于提高对 NLoS 的识别准确率, 但对于 1DCNN-CLANet 本身而言结构是不是最佳还有待考证。

3.2.2 消融实验

为了验证1DCNN-CLANet是否处于最佳,将进行以下对比消融实验(实验所用的数据集为3种情况混合数据集)。1)去掉额外特征分支,只选取CIR特征进入CNN-LSTM加AttentionLayer的模型中,得到最后的结果;2)去掉CIR分支,选取额外特征进入CNN层加AttentionLayer的模型中,得到最后的结果;3)去掉AttentionLayer模块,将两支分路通过融合,直接进入全连接层,得到最后的分类结果。为了验证各类额外特征是否对模型都有提升作用,进行额外特征消融实验,结果如表8所示。由表8可知,去掉额外特征分支的CIR_Branch模型准确率为97.17%,精确率、LoS/NLoS召回率和F1分数分别为97.17%、95.72%/98.73%和97.17%;去掉CIR分支的CNN_Branch模型准确率为88.20%,精确率、LoS/NLoS召回率和F1分数分别为89.25%、80.02%/96.95%和88.16%;去掉注意力机制模块的No_Attention模型准确率为95.94%,精确率、LoS/NLoS召回率和F1分数分别为96.06%、92.75%/99.36%和95.94%;1DCNN-CLANet优于其他模型。

为进一步验证所提出的各类额外特征在模型训练中对提升NLoS识别准确率的贡献,本文设计了

额外特征消融实验(实验在3种情况混合数据集上开展),对比分析在去除某一特征的情况下,模型性能的变化情况。在该实验中,分别去除以下8种额外特征中的一种: d 、 FP_i 、 FP_1 、 FP_2 、 FP_3 、 $s_{n(t)}$ 、 P 以及 $n(t)_{max}$,并评估模型的性能,实验结果如表9所示。从表9可以看出,去除任一特征均会导致模型准确率及其他评价指标出现不同程度的下降。其中,当去除 FP_2 特征时,模型准确率下降至96.21%,相较于保留全部8种额外特征时的准确率下降了3.30%。结果表明,所选的额外特征对提升NLoS/LoS识别性能具有重要作用,且各特征在模型中均发挥了积极贡献。

因此,1DCNN-CLANet有效地发现额外特征数据的潜在信息提高了NLoS识别的准确率,注意力机制模块也有效地提高了重要特征在模型中的重要性,提高了最终的识别准确率。

混淆矩阵提供了各种分类性能的详细信息,可以很清楚地看到真实分类和预测分类的样本个数或者占比,现将墙壁遮挡、单车遮挡以及3种情况混合数据集使用SVM、PLS-DA、CNN、CNN-LSTM以及1DCNN-CLANet进行训练实验得到结果的分类混淆矩阵图,如图14~图16所示。此外,还展示了消融实验的混淆矩阵图,如图17所示。

表8 消融实验结果

模型	准确率	精确率	LoS召回率	NLoS召回率	F1分数
CIR_Branch	97.17%	97.17%	95.72%	98.73%	97.17%
CNN_Branch	88.20%	89.25%	80.02%	96.95%	88.16%
No_Attention	95.94%	96.06%	92.75%	99.36%	95.94%
1DCNN-CLANet	99.51%	99.51%	99.52%	99.49%	99.51%

表9 额外特征的消融实验结果

d	FP_i	FP_1	FP_2	FP_3	$s_{n(t)}$	P	$n(t)_{max}$	准确率	精确率	平均召回率	F1分数
×	√	√	√	√	√	√	√	96.34%	96.37%	96.31%	96.34%
√	×	√	√	√	√	√	√	97.75%	97.75%	97.76%	97.75%
√	√	×	√	√	√	√	√	97.02%	97.07%	97.02%	97.02%
√	√	√	×	√	√	√	√	96.21%	96.23%	96.27%	96.22%
√	√	√	√	×	√	√	√	97.35%	97.34%	97.37%	97.35%
√	√	√	√	√	×	√	√	97.23%	97.22%	97.26%	97.23%
√	√	√	√	√	√	×	√	96.95%	96.94%	96.97%	96.95%
√	√	√	√	√	√	√	×	97.47%	97.47%	97.51%	97.48%
√	√	√	√	√	√	√	√	99.51%	99.51%	99.51%	99.51%

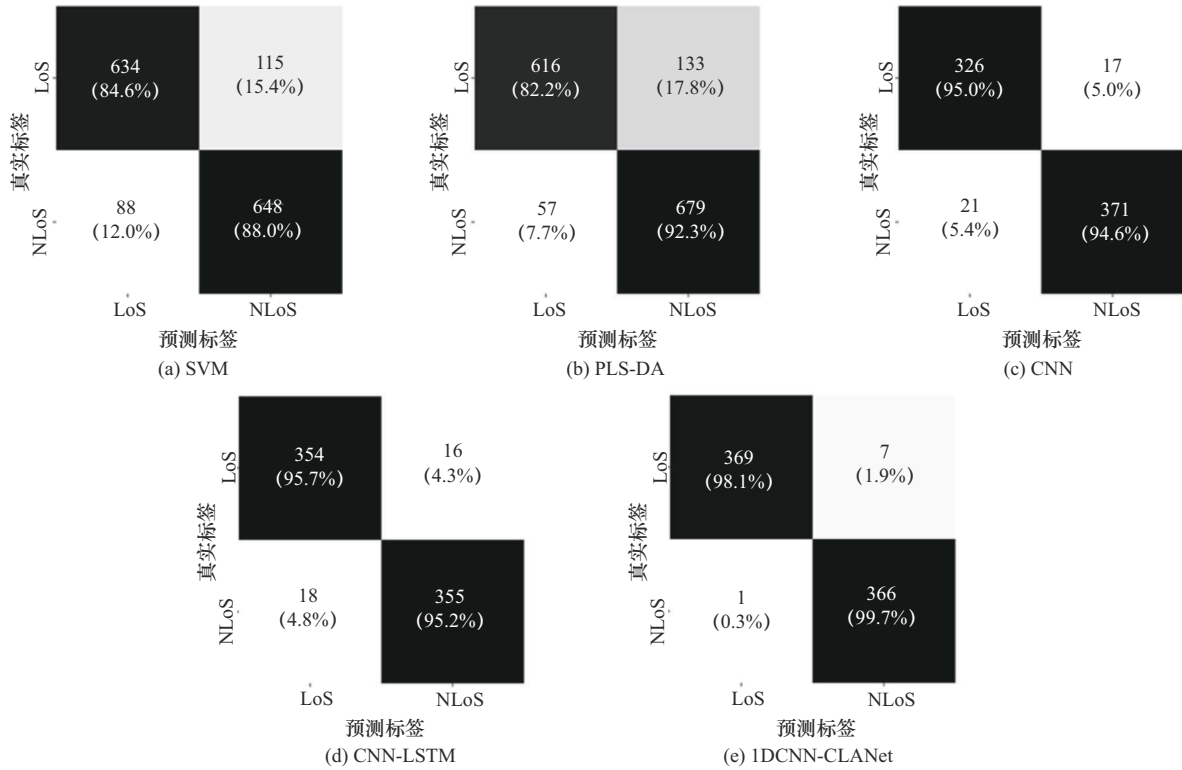


图 14 墙壁遮挡混淆矩阵结果

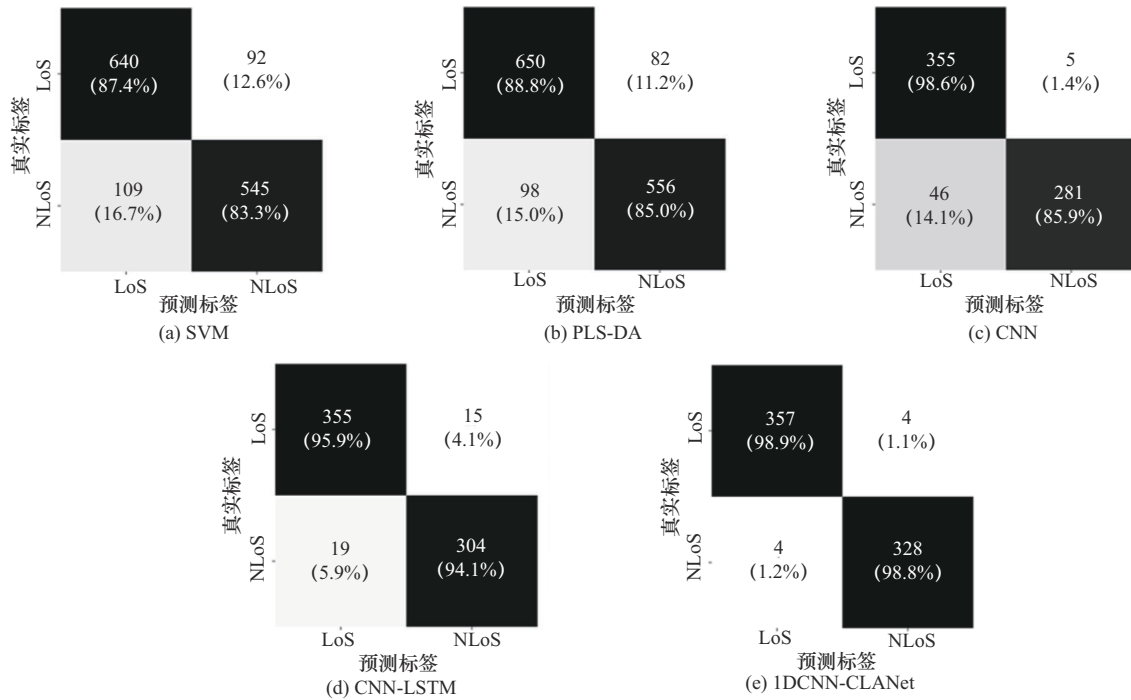


图 15 单车遮挡混淆矩阵结果

3.3 多分类实验

在实际情况中使用 UWB 进行定位，可能会遇到多种障碍物的阻挡，如果粗略地将障碍物分为 NLoS 和 LoS 这 2 种情况可能会导致 NLoS 测距误

差抑制部分的效果不够好，影响最终的位置解算，因此，本文将所采集的数据集按照实际情况划分为 4 类情况，分别为无遮挡、墙壁遮挡、单车遮挡和墙壁拐角遮挡 (class0~class3)。调整对比模

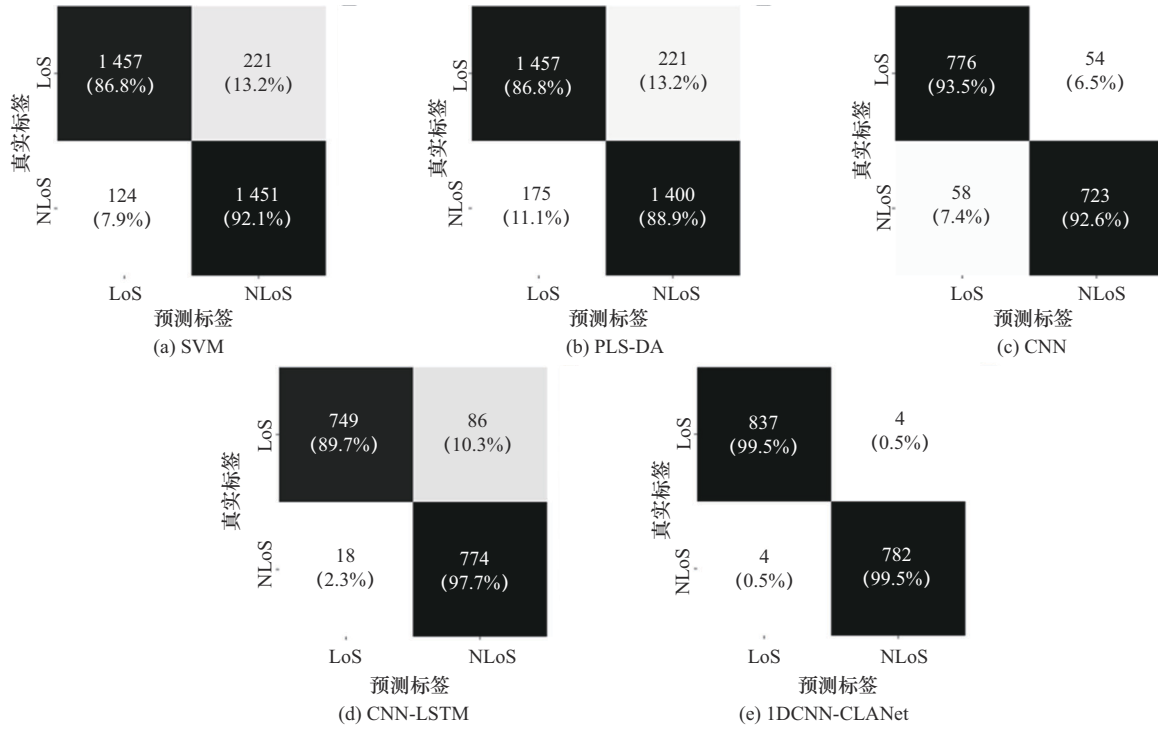


图 16 3 种情况混合数据集的混淆矩阵结果




图 17 3 种情况混合数据集进行消融实验的混淆矩阵结果

型, 本文模型只需将独热编码标签类别数改为 4, 且将 FC2 层输出单元数设为 4, 其他实验条件不变, 实验结果如表 10 所示。由表 10 可知, 1DCNN-CLANet 的准确率为 98.47%, 精确率为 98.40%, 4 个分类的召回率分别为 99.41%、98.13%、96.49%

和 98.04%, F1 分数为 98.21%。相比于其他模型, 1DCNN-CLANet 的准确率至少提升了 4.65%。实验所得到的混淆矩阵 (如图 18 所示) 以及训练曲线 (如图 19 所示) 表明, 1DCNN-CLANet 多分类的效果明显优于其他几种模型。

表 10 3 种情况混合数据集的四分类结果

模型	准确率	精确率	召回率 _{Class0}	召回率 _{Class1}	召回率 _{Class2}	召回率 _{Class3}	F1 分数
SVM	91.04%	89.14%	93.40%	90.71%	84.07%	95.05%	90.47%
PLS-DA	83.15%	79.21%	95.13%	74.18%	62.02%	84.16%	81.76%
CNN	91.11%	89.47%	93.43%	83.24%	91.67%	100.00%	90.65%
CNN-LSTM	93.82%	92.78%	98.27%	83.51%	92.67%	97.53%	92.74%
1DCNN-CLANet	98.47%	98.40%	99.41%	98.13%	96.49%	98.04%	98.21%

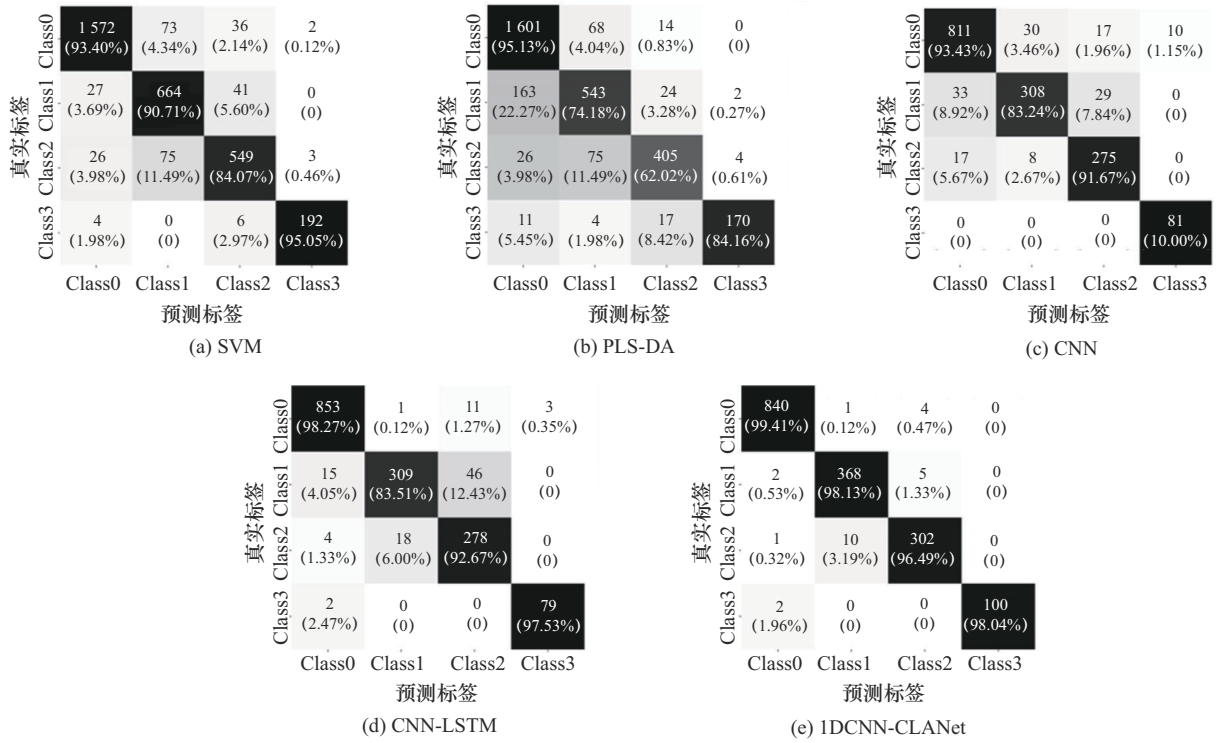


图 18 3 种情况混合数据集进行多分类实验的混淆矩阵结果

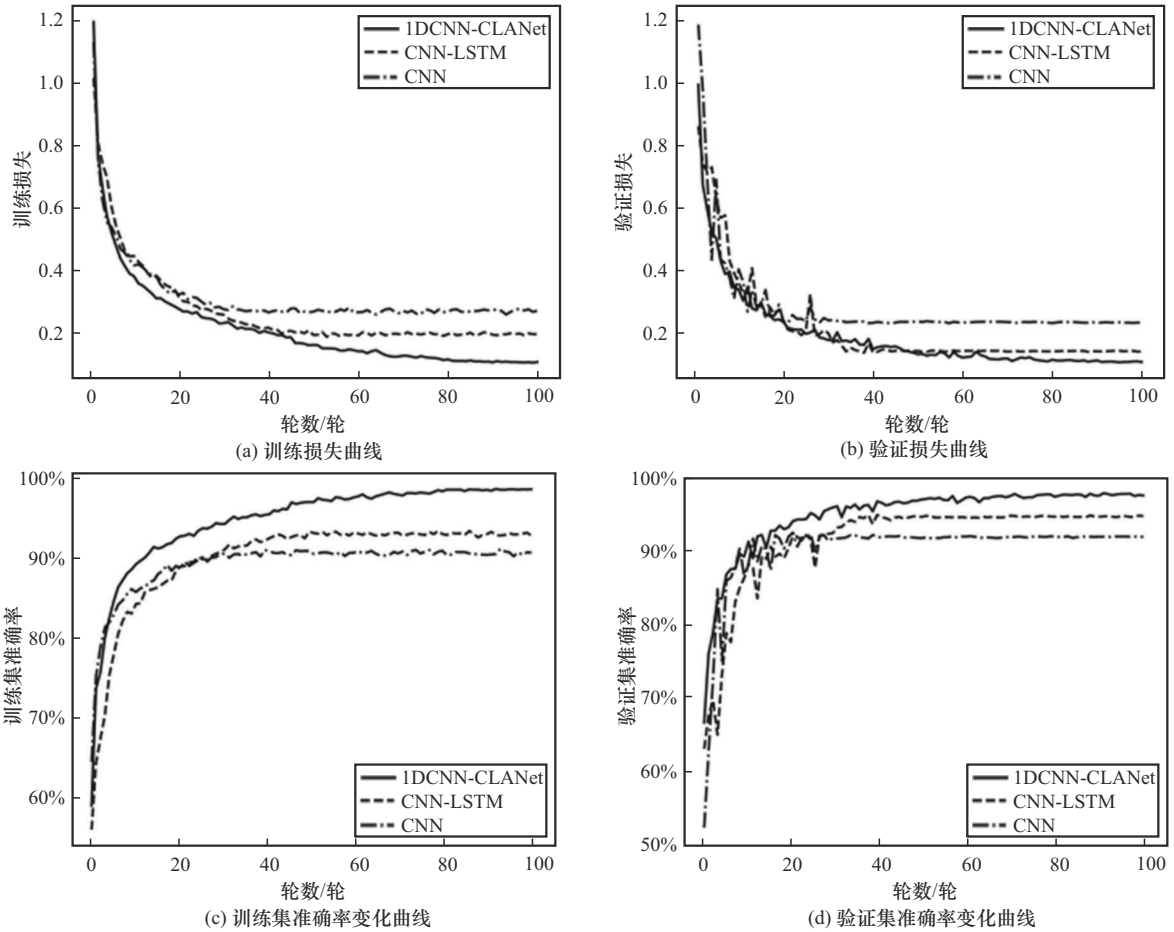


图 19 3 种情况混合数据集进行多分类实验结果曲线


4 结束语

本文提出一种新的1DCNN-CLANet模型,结合了CNN、LSTM并且深度挖掘其潜在信息。该方法利用1DCNN的深度特征提取能力、LSTM的时间序列处理强度,显著提高了NLoS分类的准确率。在数据集上的应用结果表明,与SVM、PLS-DA、CNN以及CNN-LSTM相比,1DCNN-CLANet的二元分类准确率高达99.51%,准确率、召回率和F1分数至少提高了6.89%。为了验证1DCNN-CLANet的唯一性,进行了消融实验去掉额外特征分支、去掉CIR分支以及去掉注意力机制模块,经过实验得到1DCNN-CLANet确实一定程度上挖掘了额外特征分支的潜在信息,并且注意力机制模块也有效地提升重要特征在分类中的表现,使模型对NLoS识别的准确率有所提升。在涉及多分类识别实验中,1DCNN-CLANet也表现出优异的性能准确率,高达98.47%,相较于其他模型准确率至少提高4.65%。在未来的工作中,将继续优化本文提出的NLoS识别模型,并且将其与UWB测距和定位误差抑制方法相结合,不断探索UWB定位技术在卫星拒止环境下的定位应用。

参考文献:

- [1] 孙大洋,石文孝,张定国. 基于室内地图推演与信号穿墙修正的定位优化方法[J]. 通信学报, 2022, 43(10): 146-156.
SUN D Y, SHI W X, ZHANG D G. Positioning optimization method based on indoor map deduction and signal through-wall correction[J]. Journal on Communications, 2022, 43(10): 146-156.
- [2] VEDDER B, SVENSSON B J, VINTER J, et al. Automated testing of ultrawideband positioning for autonomous driving[J]. Journal of Robotics, 2020, 2020(1): 9345360.
- [3] LEE J C, CHEN C C, SHEN C T, et al. Landmark-based scale estimation and correction of visual inertial odometry for VTOL UAVs in a GPS-denied environment[J]. Sensors, 2022, 22(24): 9654.
- [4] 王慧强,高凯旋,吕宏武. 高精度室内定位研究评述及未来演进展望[J]. 通信学报, 2021, 42(7): 198-210.
WANG H Q, GAO K X, LYU H W. Survey of high-precision localization and the prospect of future evolution[J]. Journal on Communications, 2021, 42(7): 198-210.
- [5] 蒋锐,虞跃,徐友云,等. 基于CHAN的改进卡尔曼滤波室内定位算法[J]. 通信学报, 2023, 44(2): 136-147.
JIANG R, YU Y, XU Y Y, et al. Improved Kalman filter indoor positioning algorithm based on CHAN[J]. Journal on Communications, 2023, 44(2): 136-147.
- [6] MOON S, YOUN W. A novel movable UWB localization system using UAVs[J]. IEEE Access, 2022, 10: 41303-41312.
- [7] 从飞云,洪纵横,汤子安,等. 基于脉冲响应消歧重构的UWB测距优化方法[J]. 仪器仪表学报, 2022, 43(10): 13-21.
CONG F Y, HONG Z H, TANG Zian, et al. An optimization method of UWB ranging based on pulse response disambiguation and reconstruction[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 13-21.
- [8] 李文锋,周敬龙,王其,等. 超宽带信号的非视距识别与测距误差抑制[J]. 控制与决策, 2024, 39(8): 2605-2612.
LI W F, ZHOU J L, WANG Q, et al. Non-line-of-sight identification and ranging error mitigation for ultra wide band signal[J]. Control and Decision, 2024, 39(8): 2605-2612.
- [9] 李荣冰,王念曾,刘建业,等. 面向相对导航的UWB测距误差估计与补偿方法[J]. 仪器仪表学报, 2019, 40(5): 28-35.
LI R B, WANG N Z, LIU J Y, et al. UWB ranging error estimation and compensation method for relative navigation[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 28-35.
- [10] LEE S M, YOO S, LEE J Y, et al. Drone positioning system using UWB sensing and out-of-band control[J]. IEEE Sensors Journal, 2022, 22(6): 5329-5343.
- [11] 齐小刚,陈谌,李芷楠. 室内定位中非视距的识别和抑制算法研究综述[J]. 控制与决策, 2022, 37(8): 1921-1933.
QI X G, CHEN C, LI Z N. A review of non-line-of-sight identification and mitigation algorithms for indoor localization[J]. Control and Decision, 2022, 37(8): 1921-1933.
- [12] LEE K, OH J, YOU K. CLoSed-form solution of TDOA-based geolocation and tracking: a recursive weighted least square approach[J]. Wireless Personal Communications, 2017, 94(4): 3451-3464.
- [13] YANG X F, ZHAO F, CHEN T J. NLoS identification for UWB localization based on import vector machine[J]. AEU - International Journal of Electronics and Communications, 2018, 87: 128-133.
- [14] YU K G, WEN K, LI Y B, et al. A novel NLoS mitigation algorithm for UWB localization in harsh indoor environments[J]. IEEE Transactions on Vehicular Technology, 2019, 68(1): 686-699.
- [15] 韦子辉,廖戈,李明轩,等. 基于ISODATA改进K均值聚类算法的NLoS识别技术[J]. 电子测量技术, 2024, 47(4): 172-180.
WEI Z H, LIAO G, LI M X, et al. NLoS identification technology based on ISODATA improved K-means clustering algorithm[J]. Electronic Measurement Technology, 2024, 47(4): 172-180.
- [16] JIANG C H, CHEN S, CHEN Y W, et al. An UWB channel impulse response de-noising method for NLoS/LoS classification boosting[J]. IEEE Communications Letters, 2020, 24(11): 2513-2517.
- [17] JIANG C H, SHEN J C, CHEN S, et al. UWB NLoS/LoS classification using deep learning method[J]. IEEE Communications Letters, 2020, 24(10): 2226-2230.
- [18] PEI Y, CHEN R Z, LI D R, et al. FCN-Attention: a deep learning UWB NLoS/LoS classification algorithm using fully convolution neural network with self-attention mechanism[J]. Geo-spatial Information Science, 2024, 27(4): 1162-1181.
- [19] CUI Z C, GAO Y F, HU J, et al. LoS/NLoS identification for indoor UWB positioning based on morlet wavelet transform and convolutional neural networks[J]. IEEE Communications Letters, 2021, 25(3): 879-882.

- [20] WANG J, YU K G, BU J W, et al. Multi-classification of UWB signal propagation channels based on one-dimensional wavelet packet analysis and CNN[J]. IEEE Transactions on Vehicular Technology, 2022, 71(8): 8534-8547.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] WYMEERSCH H, MARANO S, GIFFORD W M, et al. A machine learning approach to ranging error mitigation for UWB localization[J]. IEEE Transactions on Communications, 2012, 60(6): 1719-1728.
- [23] WANG Q, CHEN M S, LIU J J, et al. 1D-CLANet: a novel network for NLoS classification in UWB indoor positioning system[J]. Applied Sciences, 2024, 14(17): 7609.
- [24] BREGAR K, MOHORČIČ M. Improving indoor localization using convolutional neural networks on computationally restricted devices[J]. IEEE Access, 2018, 6: 17429-17441.



姜苏英（1990-），女，陕西商洛人，博士，陕西科技大学讲师，主要研究方向为车辆导航定位技术、V2X无线信道建模与信道参数估计、车联网连通性建模等。



薛晶（2001-），女，河南三门峡人，陕西科技大学硕士生，主要研究方向为室内定位算法、信号处理。

[作者简介]




郑恩让（1962-），男，陕西宝鸡人，博士，陕西科技大学教授，主要研究方向为工业过程智能控制、机器学习与模式识别等。



张毅（2001-），男，陕西西安人，陕西科技大学硕士生，主要研究方向为工业过程智能控制。



孟鑫（1999-），男，陕西商洛人，陕西科技大学硕士生，主要研究方向为机器学习、信号处理和卫星拒止环境下的无人机定位方法等。



李强（2000-），男，陕西汉中人，陕西科技大学硕士生，主要研究方向为机器学习。