

DOI:10.19651/j.cnki.emt.2211327

# 基于 ICEEMDAN-CNN 的非视距识别方法\*

尚德良 赵旭 李连鹏 刘文

(北京信息科技大学高动态导航技术北京市重点实验室 北京 100192)

**摘要:** 在超宽带室内定位中,受复杂室内环境下各种障碍物的干扰导致信号处于非视距场景传播,进而产生定位误差。针对非视距传播对室内定位精度影响的问题,提出了一种基于 ICEEMDAN 的非视距识别方法。首先对信道脉冲响应进行模态分解,得到含有不同尺度特性的 IMF,其次利用皮尔森相关系数法选取部分 IMF 进行重构,保留较为有效的信息,并对重构信号进行小波变换获得有效的时频特征,最后通过构建卷积神经网络识别非视距信号。实验数据基于 802.15.4a UWB 模型和开源数据集,结果表明所提出的识别方法平均准确率达到 98.5%,与其他算法相比模拟数据集提高了 5.6%,PDS 数据集提高了 14.3%,验证了所提出识别方法的有效性。

**关键词:** 超宽带定位;非视距;信道脉冲响应;ICEEMDAN;卷积神经网络

**中图分类号:** TN92 **文献标识码:** A **国家标准学科分类代码:** 510.40

## NLOS recognition method based on ICEEMDAN-CNN

Shang Deliang Zhao Xu Li Lianpeng Liu Wen

(Beijing Key Laboratory of High Dynamic Navigation Technology, Beijing Information Science &amp; Technology University, Beijing 100192, China)

**Abstract:** In ultra-wideband indoor positioning, the signal propagates in the non-line-of-sight scene due to the influence of various obstacles in the complex indoor environment, resulting in positioning errors. Aiming at the issue of the influence of non-line-of-sight propagation on indoor positioning accuracy, a non-line-of-sight recognition method based on improved complete ensemble empirical mode decomposition with ICEEMDAN was proposed. Firstly, the channel impulse response is completely decomposed to obtain the IMF with different scale characteristics. Secondly, the Pearson correlation coefficient method is used to select some IMFs for reconstruction to retain more effective information, and the wavelet transform is used to obtain effective time-frequency characteristics of the reconstructed signal. Finally, the non-line-of-sight signal is identified by constructing a convolutional neural network. The experimental data are based on the 802.15.4a UWB model and open-source data set. The experimental results indicate that the average accuracy of the proposed recognition method reaches 98.5%, which is 5.6% higher than that of other algorithms in the simulation data set and 14.3% higher than that in the PDS data set, which verifies the effectiveness of the proposed recognition method.

**Keywords:** ultra-wide band positioning; non-line-of-sight; channel impulse response; ICEEMDAN; convolutional neural network

## 0 引言

近年来,随着科技的发展与大众生活方式的改变,人们日常生活的所处环境由户外逐渐转换为室内,相对而言室内场景的位置服务需求也在不断增长。目前对于室外条件下高精度的位置获取往往依赖于全球定位系统(global positioning system, GPS)、北斗卫星导航等<sup>[1]</sup>。由于室内

条件的特殊性,卫星信号在室内环境下的覆盖率较差,难以有效提供室内定位服务,室内定位系统研究随之发展起来。超宽带(ultra-wide band, UWB)技术是一种使用 1 GHz 以上频率带宽的无线载波通信技术,利用纳秒级的非正弦波窄脉冲传输数据,所占的频谱范围很大,具有较高传输速率,穿透性强,和较强的抗干扰能力等优势。超宽带室内定位技术由基站和标签构成,位置固定的基站用于测量计算

收稿日期:2022-09-08

\* 基金项目:国家重点研发计划课题(2020YFC1511702)项目资助

位置,标签用来发射、接收信号。为了提高基于 UWB 的室内定位精度,需在位置估计阶段前进行非视距(non-line-of-sight,NLOS)信号识别。最直接的方法是基于 UWB 信号传播路径损耗模型或信道脉冲响应波形分析视距(line-of-sight,LOS)和非视距信号特性。

根据信道冲激响应(channel impulse response,CIR)和其它信号指标,现有的 LOS/NLOS 识别方法基本分为两类。一种是基于误差项统计用于 LOS/NLOS 分类。距离噪声在 LOS 条件下服从零均值高斯分布,但是在 NLOS 条件下可以近似为非零均值高斯分布。因此,可以根据距离方差和均值差值作为判别依据<sup>[2]</sup>。但该方法对环境的依赖性较强,普适性较差。

另一种是基于 CIR 的 LOS/NLOS 分类,其主要思想是依据信道特征提取来开展研究。随着机器学习的发展,基于 CIR 的统计特征被用于识别非视距信号,如峰度、总能量、平均附加时延和均方根时延等<sup>[3-4]</sup>。文献[5]使用原始 CIR 数据计算上述特征,将其输入到支持向量机(support vector machine,SVM)进行信号分类。但是在不同的场地和环境下,仅使用单一维度下的特征来进行并不理想。随着深度学习的发展,卷积神经网络(convolutional neural network,CNN)也被用于非视距识别。在文献[6]中 CIR 原始信号数据被直接使用输入至神经网络当中对 NLOS 信号进行识别。文献[7]提出 CNN 与长短期记忆(long short term memory,LSTM)结合的方式,利用 CNN 对 CIR 原始信号进行特征提取,之后输入 LSTM 中来进行 LOS/NLOS 分类,但仅使用原始信号数据输入 CNN 不能充分提取信号特征进行 NLOS 识别。

改进自适应噪声完全集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise,ICEEMDAN)能够依据频率特性将信号分解成多个不同频率成分的单分量信号。该方法常用于分析处理非线性、非稳态信号,在多个领域的信号处理方面有较广泛的应用,如轴承故障诊断<sup>[8]</sup>、心音信号处理<sup>[9]</sup>等,本文引入 ICEEMDAN 结合 CNN 的方法用于 NLOS 识别。1)使用 ICEEMDAN 方法将原始 CIR 信号按照频率特征进行逐层分解,并通过皮尔森相关系数法设定阈值,保留包含信号特征信息的本征模态函数(intrinsic mode function,IMF)分量进行信号重构。2)对重构信号执行小波变换生成具有精确时频特征的时频谱图像提高 LOS/NLOS 识别准确率。3)通过改进的 GoogLeNet 神经网络模型提升分类精度。通过实验验证,所提出的 ICEEMDAN-CNN 方法具有较好的分类性能。

## 1 NLOS 识别方法

本部分详细阐述了基于 ICEEMDAN-CNN 的非视距识别方法。介绍了 ICEEMDAN 方法的原理,建立了包含 CIR 信号的分解、筛选、重构等完整性步骤,其次提出了通

过小波变换生成时频图的具体过程,最后给出了设计的神经网络结构和工作流程。

### 1.1 基于 ICEEMDAN 的信号分解

经验模态分解(empirical mode decomposition,EMD)是一种针对非平稳信号的分析方法,但是该方法容易出现模态混叠问题。模态混叠是指在一个本征模态函数中包含差异极大的特征时间尺度,或者相近的特征时间尺度分布在不同的 IMF 中。为抑制模态混叠现象,提升信号分解质量,有学者提出了集合经验模态分解(ensemble empirical mode decomposition,EEMD)算法和互补集合经验模态分解(complementary ensemble empirical mode decomposition,CEEMD)<sup>[10]</sup>,但这两种算法将原始信号分解得到的 IMF 分量中依然会残留一定的白噪声和伪模态<sup>[11]</sup>,且计算成本也较高。

为了解决这些方法的局限性,Colominas 等<sup>[12]</sup>提出了 ICEEMDAN 方法,该算法能够增强信号的信噪比并有效防止伪模态和残余噪声模态的发生。

ICEEMDAN 方法原理如下:

步骤 1)在原始输入信号  $y$  的基础上构建白噪声的信号:

$$y^{(i)} = y + \eta_0 E_1[\omega^{(i)}] \quad (1)$$

其中, $y^{(i)}$ 是第  $i$  个构造的噪声信号; $\eta_0$ 是分解时信号的噪声标准偏差;算子  $E_1(\cdot)$ 代表信号分解时的第 1 个 IMF 分量; $\omega^{(i)}$ 是添加的第  $i$  个白噪声。

步骤 2)通过  $M(\cdot)$  值,并根据平均次数  $L$  求其均值。得到第一个残差信号  $R_1$ :

$$R_1 = \frac{1}{L} \sum_{i=1}^L M(y^{(i)}) \quad (2)$$

其中, $M_1(\cdot)$ 为局部均值函数, $R_1$ 为残差信号。

步骤 3)将原始信号  $y$  减去残差  $R_1$  得到  $IMF_1$ :

$$IMF_1 = y - \frac{1}{L} \sum_{i=1}^L M[y^{(i)}] \quad (3)$$

之后将前一次计算所得的残差  $R_{k-1}$  与本次计算所得  $R_k$  相减,可得第  $K$  个 IMF 分量:

$$IMF_k = R_k - \frac{1}{L} \sum_{i=1}^L M\{R_{k-1} + R_{k-1} A^L(t)\} \quad (4)$$

步骤 4)重复步骤 3)直至满足迭代终止条件即残差  $R_k$  为单调函数,此时停止计算,所得即为原始信号分解得到的 IMF 分量。

通过 ICEEMDAN 的分解,原始 CIR 信号被分解为多个包含不同频率成分的 IMF 分量。

### 1.2 信号筛选重构

皮尔森相关系数(Pearson correlation coefficient,PCC)用来反映两个变量之间的线性相关程度,是一种线性相关系数<sup>[13]</sup>,记为  $C$ ,用来反映两个变量之间的线性相关程度, $C$  值的取值范围为  $[-1,1]$ , $C$  的绝对值越大代表信号之间相关性越强。

$$C = \frac{\sum_{i=1}^n (e_i - \bar{e})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (e_i - \bar{e})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5)$$

其中,  $C$  表示各 IMF 分量与原始信号的相关系数,  $e$  为 IMF 分量,  $y$  是原始信道脉冲响应信号,  $n$  为 IMF 信号的个数。 $C$  的值越大, 则  $e$  与  $y$  的相关性越大。若  $C$  接近于 0, 则表明  $e$  与  $y$  的相关性较弱。根据相关系数公式计算各 IMF 分量与原始信号的相关系数, 并根据阈值式(6):

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (C_i - C)^2}{n}} \quad (6)$$

由此可得各组数据的相关系数阈值。将小于相关系数阈值的分量去除, 对大于相关系数阈值的 IMF 分量保留并进行重构, 流程框架如图 1 所示。

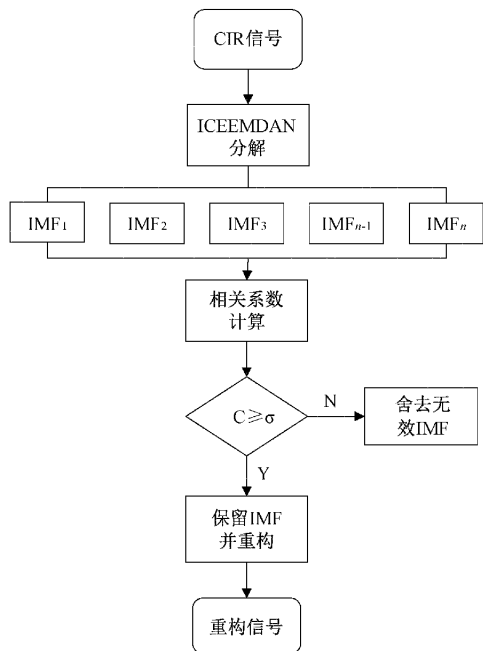


图 1 信号分解重构流程

### 1.3 小波变换

小波变换可以通过改变时频窗口的形状来调整信号的时间分辨率和频率分辨率。由于 LOS/NLOS 的信道脉冲响应信号的性质不同, 通过小波变换能够较好的表征出两种信号的时频域特征。因此, 为突出 CIR 信号的频域特性并保留其随时间变化的信息, 构造信道脉冲响应时频图, 用于 LOS/NLOS 的识别。小波变换是小波分析理论的基础, 可以定义为:

$$WT_f(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} g(t) \psi\left(\frac{t-b}{a}\right) dt \quad (7)$$

式中:  $g(t)$  是经过重构之后所得的 CIR 信号,  $\psi_{a,b}(t)$  是通过母小波  $\psi(t)$  的比例因子  $a$  缩放和平移因子  $b$  移位所得 ( $a \neq 0$ ), 可以表示为:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) dt \quad (8)$$

选取效果较好的 morlet 小波作为母小波<sup>[14]</sup>, 从同一小波在频率和时间上的能量分布来看, LOS 和 NLOS 的时频图明显不同。此外, 由于 CIR 信号的延迟和多径影响的衰减, 在图中 LOS 的能量比 NLOS 的能量更加集中。并且不同于原始 CIR 数据, CIR 时频图的特征是二维的, 可通过时间和频率特征来对 LOS/NLOS 信号进行识别。

### 1.4 卷积神经网络结构

神经网络的发展推动了图像分类领域和计算机视觉的研究<sup>[15-16]</sup>, 其网络由输入层、卷积层、池化层、全连接层等部分组成。CNN 不同于传统上依赖于手工制作特征的方式来提取信息特征集, 有自主学习特征的能力。卷积操作有助于从局部相关的数据点中提取有用的特征, 可检测提取图像中包含的各类特征信息, 例如边缘、形状、纹理和对象, 在处理图像分类问题时速度和准确度上有着极大的优势。

本文所使用的网络是在 GoogLeNet 模型<sup>[17]</sup>上进行改进, 网络共包含 22 层。与其他卷积网络相比, GoogLeNet 引入 Inception 模块代替卷积层, 模块由 4 个基本成分组成, 分别是  $1 \times 1$  卷积核、 $3 \times 3$  卷积核、 $5 \times 5$  卷积核以及  $3 \times 3$  最大池化层组成, 通过采用多尺度的卷积核实现不同尺度的感知进而有效提取图像局部特征, 且在每一个支路中都增加了  $1 \times 1$  卷积核, 能有效对通道数压缩降维, 减少参数量。网络模型通过 9 个 Inception 模块堆叠连接而成。网络的输入层数据为  $224 \times 224 \times 3$  的 RGB 图像, 且都进行了零均值化的预处理操作。Conv1 和 Conv2 层是处于网络开始的卷积层, 具有较小的感受野, 学习较为简单特征。池化层用于对先前卷积层中的特征进行压缩, 提取主要特征。Inception 模块用于提取图案和纹理这样的高阶特征信息。在输出之前还增加了全局平均池化层, 以降低特征维度减少计算量, 神经网络结构如图 2 所示。

同时为缓解梯度消失问题, 使用 Leaky ReLU 激活函数替代原网络中的 ReLU 激活函数<sup>[18]</sup>。激活函数的作用是加入非线性因素, 建立神经元输入输出之间的映射的多样性。Leaky ReLU 激活函数如式(9)所示, (其中  $\alpha > 0$ )。

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (9)$$

Leaky ReLU 和 ReLU 函数形式十分相似, 但 Leaky ReLU 函数会使  $x \in (-\infty, 0)$  区间内产生一个非零的倾斜。当隐藏层输入  $x$  为负值时, 激活值会有一个小的梯度, 通过一个较小的正值可以使神经元对大多数训练样本都处于活跃状态, 有效解决在小于 0 的区间内部分隐藏层神经无法被激活的问题。

## 2 实验结果与分析

模型效果的测试采用两个不同的数据集来完成, 使用

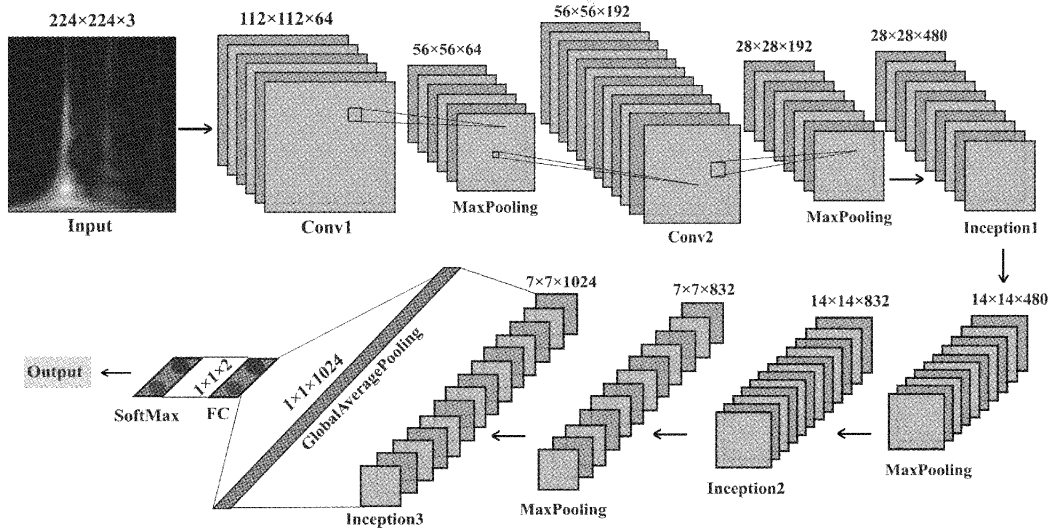


图 2 神经网络结构

SVM<sup>[5]</sup>、CNN<sup>[6]</sup>、决策树(decision tree,DT)<sup>[19]</sup>作为基准比较算法。SVM、DT、ICEEMDAN-CNN 算法是在 MATLAB R2020b 软件实现的,CNN 使用 Python3.7 和 TensorFlow2.0 框架实现。

2.1 数据集描述

模拟数据集是基于 IEEE 802.15.4a UWB 模型生成的 CIR 数据,该数据集共包含了 3 种不同的室内环境:办公室环境,工厂环境,住宅环境。共计 9 000 条数据测量值,其中 4 500 条用作非视距信道条件,4 500 条用作视距信道条件。数据集每条数据都是基于 500 MHz 带宽和 6 GHz 中心频率下产生的。PDS(pozyx data set)数据集<sup>[20]</sup>来自于网络开源数据集,该数据集是基于 Pozyx 设备进行测量获取的信道脉冲响应信号。数据集共包含 3 400 条数据,1 700 条用于 NLOS 信道条件,1 700 条用于 LOS 条件。实验数据 60%作为训练集,20%作为验证集,20%作为测试集。

2.2 评价指标

使用常用的评价指标来评估网络模型的性能:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

式中:TP 为真阳性率表示正确识别的 LOS 信号数,TN 为真阴性率是正确识别的 NLOS 信号数,FP 为假阳性率是错误识别为 LOS 信号的 NLOS 信号数,FN 是错误识别为 NLOS 信号的 LOS 信号数。

$$F_1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (11)$$

Accuracy 用来表示正确分类的所占百分比。 $F_1$  分数值用来衡量模型得精确度指标,同时兼顾了分类模型的精确率和召回率。

2.3 实验结果与分析

输入的信道脉冲响应点数由原始的 1016 截断成 300

个点,被截断的信号保留了原始信号中主要的能量和部分延续信息,避免了将完整信道脉冲响应信号执行 ICEEMDAN 和小波变换时计算量较大冗余信息较多的问题。

首先将被截断的信号进行 ICEEMDAN 分解,分解后的各模态时序图及频谱图如图 3 所示。信号白噪声的添加次数设为 100,分解时信号的噪声标准偏差  $\eta_0$  设为 0.2。分解得到的本征模态函数按照从高频到低频排列,信号特征被有效的分解到了不同频带,具有良好的多尺度的特性。

对分解所得的 IMF 分量通过相关系数阈值筛选,保留相关系数大于阈值的分量并重构,使用小波变换对重构的信道脉冲响应信号进行时频分析,其中比例因子  $a$  设为 128,最终输出为  $224 \times 224 \times 3$  的 RGB 图像,像素的颜色表示归一化能量,像素亮度越高表示能量越高。

由图 4 可见两种信号在频率和时间上的能量传播方面存在着明显的差异。同时受多径效应的影响导致 CIR 信号出现延迟和衰减,在时频图中表现为 LOS 的能量较 NLOS 能量更为集中。

分类模型的学习率设为 0.001,批量大小设为 32,使用动量随机梯度下降优化器,动量参数设为 0.9,进行 10 轮次的训练。根据以上设定参数和模型评估指标。实验结果如表 1 所示。

从表 1 中可以看出,相较于其他 3 种方法,本文提出的方法识别准确度更高,模拟数据集平均准确率达到了 98.5%与其他 3 种方法相比准确度分别提高了 4.1%,5%,7.8%。PDS 数据集平均准确率达到了 98.4%,与其他 3 种方法相比准确度分别提高了 14.1%,12.8%,16.2%。这表明了所提出的模型具有较好的识别精度。

表 2 展示了不同方法的  $F_1$  值。本文提出的方法在模拟数据集和 PDS 数据集的  $F_1$  分数值分别达到了 98.5%

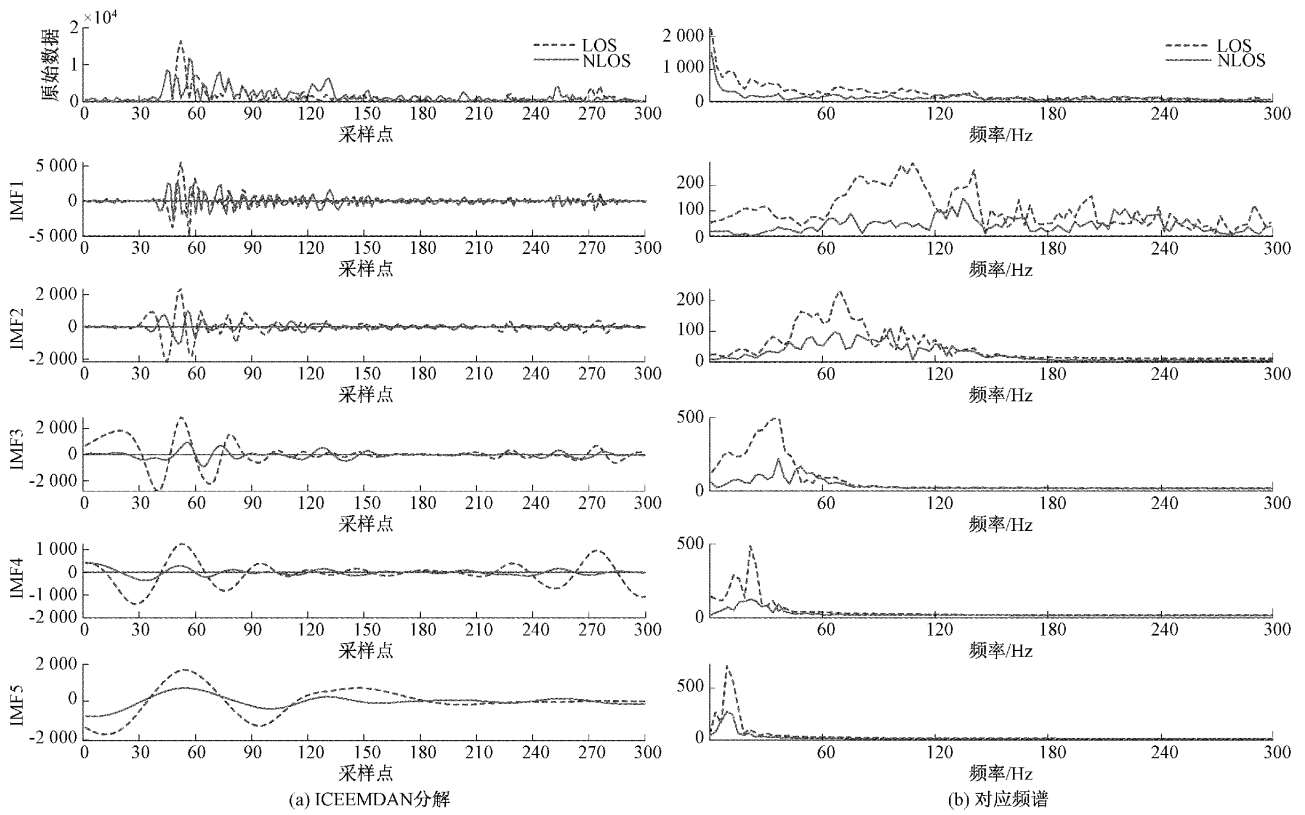


图 3 ICEEMDAN 分解图




图 4 LOS/NLOS 时频图

表 1 不同场景下的分类精度比较 %

方法	办公室	工厂	住宅	PDS
CNN	91.2	100	92.1	84.3
DT	94.7	100	85.7	85.6
SVM	87.8	100	84.4	82.2
本文	98.5	100	97.0	98.4

表 2 不同场景  $F_1$  分数比较 %

方法	办公室	工厂	住宅	PDS
CNN	91.1	100	91.9	84.6
DT	94.7	100	85.5	85.2
SVM	88.6	100	84.2	81.9
本文	98.5	100	97.1	98.3

和 98.3%，较其他 3 种方法相比，模拟数据集提升了 4.2%，5.1%，7.6%。PDS 数据集提升了 13.7%，13.1%，16.4%。

在时间指标方面，相较于基准算法使用一维数据处理作为特征进行非视距信号识别，本文将一维数据处理转换为二维图像，提取更为精细特征，识别时间相较于几种基准算法有所增加，在不同场景下测试集每条数据识别时间平均增加 5 ms 左右。在损失了一定的时间效率下极大程度上提升了 NLOS 识别精度，精度平均提高 10% 左右。

图 5 展示了不同算法的准确率和  $F_1$  分数，实验结果表明本文提出的方法能够较好提取信号中的有效信息，并通过时频分析的方法获得精确的时频特征进行 LOS/NLOS 识别。





图 5 不同方法性能对比

### 3 结 论

针对非视距传播对室内定位精度的影响，提出了一种基于改进自适应噪声完全集合经验模态分解和卷积神经网络相结合的方法，与仅使用原始 CIR 数据的传统方法不同，从时域、频域多角度分析信道脉冲响应信号，能够更加

充分提取信号特征，有效提升 LOS/NLOS 识别精度。首先对 CIR 信号进行分解，依据相关系数法设定阈值选取 IMF 分量进行重构，将重构信号进行小波变换生成时频图，最后将图像输入 CNN 进行分类识别。通过实验表明，较其他方法相比在模拟数据集和 PDS 数据集上平均准确率分别提高了 5.6%，14.3%，验证了所提出方法的有效性。在未来的工作中，考虑对识别的 NLOS 信号测量值进行修正处理，降低位置估计误差，提高定位精度。

### 参考文献

- [1] 齐小刚,陈湛,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.
- [2] MUQAIBEL A H, LANDOLSI M A, MAHMOOD M N. Practical evaluation of NLOS/LOS parametric classification in UWB channels [C]. 2013, 1st International Conference on Communications, Signal Processing, and their Applications (ICCSIPA), IEEE, 2013, DOI:10.1109/ICCSIPA.2013.6487304.
- [3] HUANG A, TIAN L, JIANG T, et al. NLOS identification for wideband mmWave systems at 28 GHz [C]. 2019 IEEE 89th Vehicular Technology Conference (VTC2019-Spring), Kuala Lumpur, Malaysia, IEEE, 2019, DOI: 10.1109/VTCSpring.2019.8746362.
- [4] 李海,解云龙,刘月圆,等.基于 CIR 特征参量的 NLOS 识别方法研究[J].中国测试,2021,47(9):20-25.
- [5] ZENG Z, LIU S, WANG L. NLOS identification for uwb based on channel impulse response [C]. 2018 12th International Conference on Signal Processing and Communication Systems (ICSPCS), IEEE, 2018, DOI: 10.1109/ICSPCS.2018.8631718.
- [6] STAHLKE M, KRAM S, MUTSCHLER C, et al. NLOS detection using UWB channel impulse responses and convolutional neural networks [C]. 2020 International Conference on Localization and GNSS (ICL-GNSS), IEEE, 2020, DOI: 10.1109/ICL-GNSS49876.2020.9115498.
- [7] JIANG C, SHEN J, CHEN S, et al. UWB NLOS/LOS classification using deep learning method [J]. IEEE Communications Letters, 2020, 24(10): 2226-2230.
- [8] KOU Z M, YANG F, WU J, et al. Application of ICEEMDAN energy Entropy and AFSA-SVM for fault diagnosis of hoist sheave bearing [J]. Entropy (Basel, Switzerland), 2020, 22(12): 1347.
- [9] 杨洋,郭兴明,郑伊能,等.基于 ICEEMDAN-MSE 的左室舒张功能障碍心音信号的识别研究[J].仪器仪表学报,2022,43(1):274-281.
- [10] CHAABI L, LEMZADMI A, DJEBALA A, et al.

- Fault diagnosis of rolling bearings in non-stationary running conditions using improved CEEMDAN and multivariate denoising based on wavelet and principal component analyses[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 107(9): 3859-3873.
- [11] 常乐,汪庆年. 基于优化聚类分解与 XGBOOST 的超短期电力负荷预测[J]. *国外电子测量技术*, 2022, 41(5):46-51.
- [12] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: A suitable tool for biomedical signal processing[J]. *Biomedical Signal Processing and Control*, 2014, DOI: 10.1016/j.bspc.2014.06.009.
- [13] 尚海昆,许俊彦,李宇才,等. CEEMDAN 在变压器振动信号提取中的应用[J]. *控制理论与应用*, 2022, 39(3):459-468.
- [14] CUI Z, GAO Y, HU J, et al. LOS/NLOS identification for indoor UWB positioning based on morlet wavelet transform and convolutional neural networks [J]. *IEEE Communications Letters*, 2020, 25(3): 879-882.
- [15] 王立刚,张志佳,李晋,等. 基于卷积神经网络的 LED 灯类字体数字识别[J]. *电子测量与仪器学报*, 2020, 34(11):148-154.
- [16] 周冬. 卷积神经网络的隧道桥梁安全风险评估研究[J]. *电子测量技术*, 2020, 43(16):46-50.
- [17] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[J]. *IEEE Computer Society*, 2014, DOI: 10.1109/CVPR.2015.7298594.
- [18] BALAGOUROUCHETTY L, PRAGATHEESWARAN J K, POTTAKKAT B, et al. GoogLeNet-based ensemble FCNet classifier for focal liver lesion diagnosis [J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 24(6): 1686-1694.
- [19] MUSA A, NUGRAHA G D, HAN H, et al. A decision tree-based NLOS detection method for the UWB indoor location tracking accuracy improvement [J]. *International Journal of Communication Systems*, 2019, 32(13): 3997.
- [20] BARRAL V. February 10, 2020, Pozyx CIR and range with LOS and NLOS[DB/OL]. *IEEE Dataport*, DOI: 10.21227/sr92-6s06.

### 作者简介

尚德良, 硕士研究生, 主要研究方向为超宽带室内定位。

E-mail: shangdeliang1216@163.com

赵旭(通信作者), 博士, 助理研究员, 硕士生导师, 主要研究方向为室内定位、仿生机器人等方面。

E-mail: zhaoxu@bistu.edu.cn

李连鹏, 博士, 讲师, 主要研究方向为 CPS 安全、机器人控制、激光雷达和惯性导航。

E-mail: llpstdy@163.com

刘文, 硕士研究生, 主要研究方向为超宽带定位, 机器学习等。

E-mail: lwbistu615@163.com