DOI:10.14075/j.jgg.2025.01.005

文章编号:1671-5942(2025)12-1246-07

面向智能手机 GNSS 接收信号视距/非视距分类的机器学习方法

贾祥龙[1]　王辰宇[2]　王　牌[3]

1　上海交通大学感知与导航研究所,上海市东川路 800 号,200240

2　武汉科技大学计算机科学与技术学院,武汉市黄家湖西路 10 号,430065

3　武汉大学卫星导航定位技术研究中心,武汉市珞喻路 129 号,430079

摘　要:现有的 GNSS 接收信号分类研究主要针对专业级接收机,通过提取信号特征将其区分为视距(LOS)和非视距(NLOS)信号,以实现高精度定位。然而,这些研究中所采用的信号特征和分类方法并不一定适用于智能手机中低成本 GNSS 芯片的信号特性。本文提出一种基于机器学习的智能手机 GNSS 接收信号 LOS/NLOS 分类方法。该方法结合了载噪比、仰角、伪距残差、归一化伪距残差以及伪距残差百分比 5 个关键指标,并融合基于深度学习的天顶视图语义分割和卫星标定技术,构建精确的训练数据集。在典型城市场景下对多种机器学习模型进行评估,结果表明,所提出的方法在不同型号智能手机上的平均分类准确率达到 85.8%。

关键词:智能手机;GNSS 信号分类;机器学习;视距;非视距

中图分类号:P228　　**文献标识码**:A

在复杂的城市环境中,GNSS 信号常常受到建筑物、树木等障碍物的遮挡或反射,导致信号质量下降,从而难以保证 GNSS 定位的准确性和可靠性[1]。现有研究通常将 GNSS 接收信号分为两类:视距(LOS)信号和非视距(NLOS,包括反射或衍射信号)信号[2]。

目前,国内外已开展了大量关于 GNSS 接收信号分类的研究,这些方法主要分为两大类。第一类方法依赖于额外的设备或数据,例如双极化天线[3]、鱼眼相机[4]、三维地图[5-7]等,这些设备或数据通常用于为机器学习模型提供标定数据。第二类方法则通过提取 GNSS 接收信号的特征,并结合机器学习技术来实现信号分类[8-13]。尽管针对专业级 GNSS 接收机的信号分类方法已经较为成熟,但这些方法所采用的信号特征和分类技术并不一定适用于智能手机中低成本 GNSS 芯片产生的信号。

针对智能手机 GNSS 接收信号噪声大且不稳定的特点[14],本文分析并提出一套具有普适性的智能手机 GNSS 接收信号分类特征。同时,开发一种适用于复杂天顶视图的语义分割模型,以实现对卫星信号的精确标定[15]。在此基础上,结合信号特征构建精确的训练集,并对多种适用于 GNSS 接收信号分类的机器学习模型进行评估[8-9]。实验结果表明,在典型城市场景下,所提取的信号特征和所选的机器学习模型能够实现不同智能手机之间平均 85.8%的分类准确率。这一成果为复杂城市环境中智能手机 GNSS 接收信号的分类提供了一种有效的解决方案。此外,信号分类结果还可在未来的研究中应用于智能手机的精细化定位[16-17]或城市地图构建[18-20]等领域,具有广阔的应用前景。

1　智能手机 GNSS 接收信号分类

1.1　智能手机 GNSS 接收信号特征提取

目前,有许多免费的安卓应用程序可用于记录智能手机的原始 GNSS 测量数据,如 GNSSLogger、Geo++ RINEX Logger、rinexON 和 GalileoPVT 等。由于智能手机采用了超低成本的 GNSS 芯片,其观测数据存在质量低、稳定性差且不同型号间差异显著等问题,导致专业级接收机中常用的信号特征难以直接适用于智能手机。在智能手机的原始 GNSS 测量数据中,载波相位测量常伴有频繁的周跳。同时,较大的频率漂移会对多普勒频移的测量

收稿日期:2025-01-12

项目来源:国家自然科学基金(62201344)。

第一作者简介:贾祥龙,硕士生,主要研究方向为智能手机 GNSS 接收信号分类和环境感知,E-mail:jiaxianglong@sjtu.edu.cn。

通讯作者:王牌,博士,研究员,主要研究方向为 GNSS 信号处理与多源融合定位,E-mail:paiwang@whu.edu.cn。

结果造成严重干扰。为确保智能手机 GNSS 接收信号分类方法的适用性,未利用载波相位和多普勒频移的相关特征[21-22]。表 1 列出了安卓应用程序接口中部分涉及原始 GNSS 测量的字段。

表 1　原始 GNSS 测量在 Android API 中的字段内容

Tab. 1　Field contents of raw GNSS measurements in Android API

字段	描述
Cn0DbHz	载波噪声谱密度比范围为[0,63](dB-Hz)
TimeNanos	GNSS 接收机内部硬件时钟值(ns)
TimeOffsetNanos	测量时的时间偏移量(ns)
FullBiasNanos	GPS 接收机内部的 TimeNanos 与真实 GPS 时间的差值(ns)
BiasNanos	GNSS 接收机时钟的亚纳秒偏差(ns)
ReceivedSvTimeNanos	测量时接收到的 GNSS 卫星时间
PseudorangeRateMetersPerSecond	伪距变化率,即多普勒观测值(m/s)

1.1.1　载噪比

载噪比(C/N_0)是评估 GNSS 接收信号强度的常用指标,可通过表 1 中的 Cn0DbHz 字段获取。图 1(a)展示了智能手机在约 30 min 内采集的所有卫星的 C/N_0 数据,其中 LOS/NLOS 标签通过下一节介绍的鱼眼相机标定法进行标定。

根据信号传播理论,GNSS 信号的路径损耗会随着反射次数和传播路径的增加而增大。当信号受到障碍物阻挡时,其信号强度通常会显著降低[22]。如图 1(a)所示,NLOS 信号的 C/N_0 分布显著低于 LOS 信号。然而,两类信号的 C/N_0 存在明显重叠,仅凭 C/N_0 无法进行有效区分[23]。

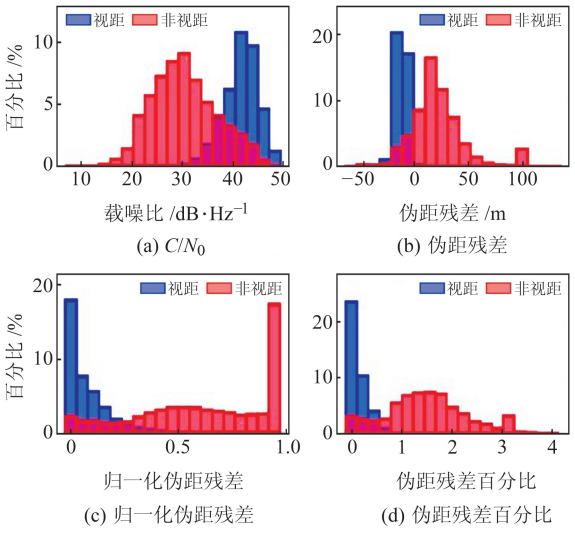


图 1　智能手机 GNSS 接收信号特征

Fig. 1　GNSS signal features of smartphone

1.1.2　仰角

通常情况下,GNSS 接收信号的仰角越大,越可能为 LOS 信号,其计算公式如下:

$$\theta_{\mathrm{el}}=\arcsin\left(\frac{\Delta U}{\sqrt{\Delta E^2+\Delta N^2+\Delta U^2}}\right) \tag{1}$$

$$\begin{bmatrix}\Delta E\\ \Delta N\\ \Delta U\end{bmatrix}=\begin{bmatrix}-\sin\lambda & \cos\lambda & 0\\ -\sin\varphi\cos\lambda & -\sin\varphi\sin\lambda & \cos\varphi\\ \cos\varphi\cos\lambda & \cos\varphi\sin\lambda & \sin\varphi\end{bmatrix}\cdot\begin{bmatrix}x^S-\hat{x}_u\\ y^S-\hat{y}_u\\ z^S-\hat{z}_u\end{bmatrix} \tag{2}$$

式中,φ 和 λ 分别为 GNSS 接收机的纬度和经度;(x^S,y^S,z^S) 和 $(\hat{x}_u,\hat{y}_u,\hat{z}_u)$ 分别为卫星和 GNSS 接收机在 ECEF 坐标系中的位置。由于城市环境下的建筑物分布不规则,仅凭仰角无法有效区分 LOS 和 NLOS 信号[23]。

1.1.3　伪距残差

NLOS 信号因受到环境中障碍物的阻挡或反射,其传播路径变长,导致伪距残差(pseudorange residual, PR)通常较大。基于智能手机原始 GNSS 测量数据计算伪距残差的步骤如下:

首先,原始伪距 ρ_{raw} 根据接收时间 t_{R_x} 和发送时间 t_{T_x} 计算得到[14]。

$$\rho_{\mathrm{raw}}=(t_{R_x}-t_{T_x})\cdot 10^{-9}\cdot c \tag{3}$$

$$t_{R_x}=\mathrm{TimeNanos}+\mathrm{TimeOffsetNanos}-\mathrm{FullBiasNanos}(1)-\mathrm{BiasNanos}(1) \tag{4}$$

$$t_{T_x}=\mathrm{ReceivedSvTimeNanos} \tag{5}$$

式中,c 为光速;式(4)和(5)中参数可由表 1 中对应字段获得。修正后的伪距 ρ_{corr} 通过消除卫星钟差、电离层延迟和对流层延迟计算得到,其表达式为:

$$\rho_{\mathrm{corr}}=\rho_{\mathrm{raw}}+\delta\hat{t}^S-\hat{I}-\hat{T}=d+\delta t_u+\varepsilon \tag{6}$$

式中,$\delta\hat{t}^S$ 是通过广播星历修正的卫星钟差;$\hat{I}$ 和 $\hat{T}$ 分别为通过 Klobuchar 模型和 Saastamoinen 模型估算的电离层延迟和对流层延迟;ε 为所有其他来源的测量误差的总和。利用加权最小二乘法计算每个卫星系统对应的接收机钟差:

$$\delta\hat{T}_u^S=[(\boldsymbol{WG})^{\mathrm{T}}(\boldsymbol{WG})]^{-1}\boldsymbol{G}^{\mathrm{T}}\boldsymbol{W}^{\mathrm{T}}\boldsymbol{W}\cdot\begin{bmatrix}\rho^S_{\mathrm{corr},1}-\hat{d}_1\\ \vdots\\ \rho^S_{\mathrm{corr},n}-\hat{d}_n\end{bmatrix} \tag{7}$$

式中,$\hat{d}_i=\sqrt{(x_i^S-\hat{x}_u)^2+(y_i^S-\hat{y}_u)^2+(z_i^S-\hat{z}_u)^2}$ 为

卫星 i 与接收机 u 之间的估计距离，其中$(\hat{x}_u,\hat{y}_u,\hat{z}_u)$为智能手机的 GNSS 芯片提供的接收机位置；$\rho^S_{\mathrm{corr},i}$ 为卫星 i 的修正伪距；S 为 GPS、GLONASS、Galileo、Beidou；n 为一个历元中每个 GNSS 系统可用的卫星数量；矩阵 $\boldsymbol{G}$ 为一个 $n\times 1$ 的全 1 矩阵；矩阵 $\boldsymbol{W}=\mathrm{diag}\{1/w_1,\cdots,1/w_n\}$ 为对角加权矩阵，其中 w_i 可基于 C/N_0 设置[21]：

$$w_i=\sqrt{\frac{\sum_{i=1}^{n}\left(\frac{C}{N_{0,i}}-\frac{\overline{C}}{N_0}\right)^2}{n}}\cdot 10^{0.05\max(C/N_{0,\max}-C/N_{0,i},0)} \tag{8}$$

式中，$\overline{C}/N_0$ 为一个历元中 n 颗卫星的平均 C/N_0；$C/N_{0,\max}$ 的经验值为 45 dB-Hz[21]。伪距残差最终可以表示为：

$$\mathrm{PR}_i=\rho^S_{\mathrm{corr},i}-\delta\hat{T}^S_u-\hat{d}_i \tag{9}$$

图 1(b)展示了 GNSS 接收信号的伪距残差，结果表明，NLOS 信号的伪距残差大多为正值，且其整体幅度显著高于 LOS 信号的伪距残差。

1.1.4 归一化伪距残差

在复杂的城市环境中，智能手机的定位误差较大，不同历元间计算得到的伪距残差差异显著，所以难以有效区分 LOS 和 NLOS 信号。为解决这一问题，可以在每个历元对伪距残差进行归一化处理[24]：

$$\mathrm{NPR}_i=\frac{\mathrm{PR}_i-\mathrm{PR}_{\min}}{\mathrm{PR}_{\max}-\mathrm{PR}_{\min}} \tag{10}$$

式中，$\mathrm{PR}_{\max}$ 和 $\mathrm{PR}_{\min}$ 分别为每个历元中伪距残差的最大值和最小值。图 1(c)展示了 LOS 信号和 NLOS 信号的归一化伪距残差(normalized pseudorange residual，NPR)。通过比较图 1(b)和图 1(c)的结果可以发现，归一化伪距残差显著减少了伪距残差的分布重叠问题，使类内差异缩小、类间差异增大，从而更加有利于区分 LOS 和 NLOS 信号[2]。

1.1.5 伪距残差百分比

伪距残差百分比(pseudorange residual percentage，PRP)是一种针对历元间伪距残差的归一化方法，可表示为[25]：

$$\mathrm{PRP}_i=\frac{(\mathrm{PR}_i-\mathrm{PR}_{\min})\cdot n}{\sum_{i=1}^{n}(\mathrm{PR}_i-\mathrm{PR}_{\min})} \tag{11}$$

如图 1(d)所示，与归一化伪距残差相比，伪距残差百分比在区分 LOS 和 NLOS 信号时表现出更显著的效果。

1.2 GNSS 接收信号标定

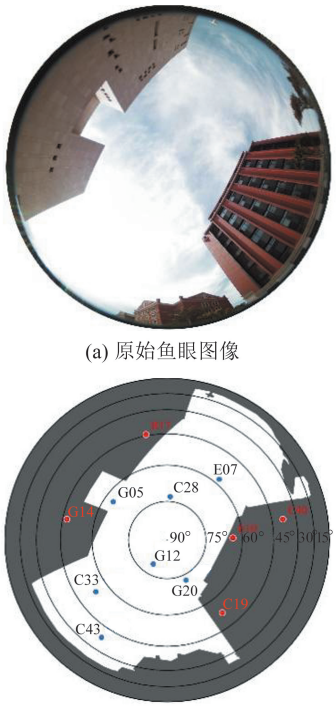
鱼眼相机常用于卫星标定，图 2(a)为典型的天顶视图鱼眼图像。为判断 GNSS 接收信号在视距传播路径上是否受到遮挡，需要将鱼眼图像划分为天空和非天空区域。结合图像的方位角、卫星的方位角与仰角，可以将卫星投影到分割的鱼眼图像中[26-27]：

$$r=f_c\cdot(\varphi+k_1\varphi^3+k_2\varphi^5+k_3\varphi^7+k_4\varphi^9) \tag{12}$$

$$x_{\mathrm{pos}}=x_c+r\cdot\cos(\theta_{\mathrm{az}}-\theta_{\mathrm{cam}}) \tag{13}$$

$$y_{\mathrm{pos}}=y_c-r\cdot\sin(\theta_{\mathrm{az}}-\theta_{\mathrm{cam}}) \tag{14}$$

式中，φ 为 GNSS 接收信号的入射线与鱼眼相机光轴之间的角度；k_1、k_2、k_3 和 k_4 为径向畸变参数；f_c 为鱼眼相机的焦距，通常通过棋盘标定法获得[27]；r 为从图像中心到投影卫星位置的像素距离；(x_c,y_c) 为图像的中心位置；θ_{az} 和 θ_{cam} 分别为卫星的方位角和相机的方位角；$(x_{\mathrm{pos}},y_{\mathrm{pos}})$为卫星投影到图像上的像素坐标。如图 2(b)所示，基于卫星的投影位置，将其与图像中天空与遮挡区域的分割结果进行匹配，以判定该卫星信号是否处于可视天空区域，从而完成 LOS/NLOS 标定。



(a) 原始鱼眼图像

(b) 鱼眼图像分割结果和卫星投影位置

图 2 基于鱼眼图像的 GNSS LOS/NLOS 标定
Fig. 2 GNSS LOS/NLOS calibration based on fisheye images

传统天空图像分割方法(如分水岭算法和 KMlocal)在光照过曝、多云等复杂条件下表现不佳[28-29]。近年来，深度学习方法在图像分割中取得显著进展，尤其在处理复杂图像方面优于传统方法。本文基于 Deeplabv3＋结构[30]，提出一种改进的网络模型，如图 3 所示。为降低计算开销，

主干网络替换为采用深度可分离卷积的 MobileNetV2[31]，适用于资源受限的设备。为提升分割精度，在主干网络输出的高层特征经过 ASPP 模块处理后，以及在低层特征融合之前，分别引入空间注意力机制(ESA)[32]，以增强关键区域特征的响应并抑制无关背景干扰，从而提升模型的特征表达能力与分割性能。

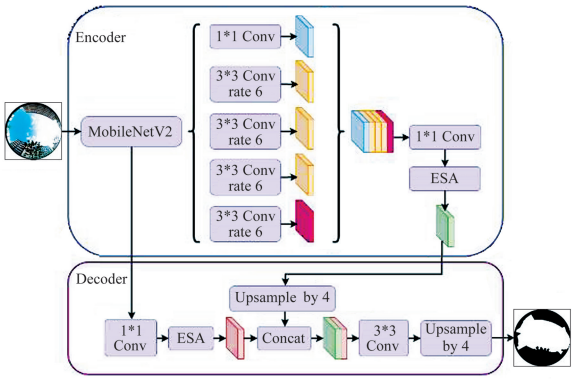


图 3　基于空间注意力机制的 Deeplabv3＋网络

Fig. 3　Deeplabv3＋net based on spatial attention mechanism

2　实验与结果分析

本节通过实验验证本文所提方法在天空图像语义分割和智能手机 GNSS 接收信号分类中的有效性。

2.1　天空图像语义分割实验

为提升天空图像语义分割在复杂城市环境中的鲁棒性与泛化能力，实验在晴天、多云、阴天 3 种天气条件下，选取包含单侧遮挡、双侧遮挡及不同反光材质建筑外立面的典型场景，共采集天顶视角鱼眼图像 2 341 张。

采用 Deeplabv3＋(主干网络使用 Xception[33])和 LiteSeg[34] 网络(主干网络使用 MobileNetV2)进行性能对比。将输入图像统一调整为 512 像素×512 像素，采用学习率为 1×10^{-4} 的 Adam 优化器，并将数据集按8∶1∶1的比例划分为训练集、验证集和测试集。训练结果如表 2 所示。

表 2　不同模型性能对比

Tab. 2　Performance comparison of different models

模型	mIoU/%	mPA/%
LiteSeg	95.7	96.4
Deeplabv3＋	96.8	98.4
本文方法	98.1	99.0

注：mIoU 为平均交并比；mPA 为平均像素精度。

由表 2 可以看出，本文提出的引入空间注意力机制的改进型 Deeplabv3＋模型在分割精度方面表现最优。与原始 Deeplabv3＋模型相比，改进模型在 mIoU 和 mPA 两个指标上分别提升了 1.3%和 0.6%。通过引入 ESA 模块，模型在处理复杂天空场景时的分割能力得到显著增强。图 4 展示了模型在典型复杂场景下的分割效果，包括建筑外立面反射天空、隧道出口强光干扰以及天空中存在电线等情况。结果表明，引入 ESA 模块后，模型在处理边缘模糊、强光干扰与结构遮挡等复杂条件下的表现能力显著提升。

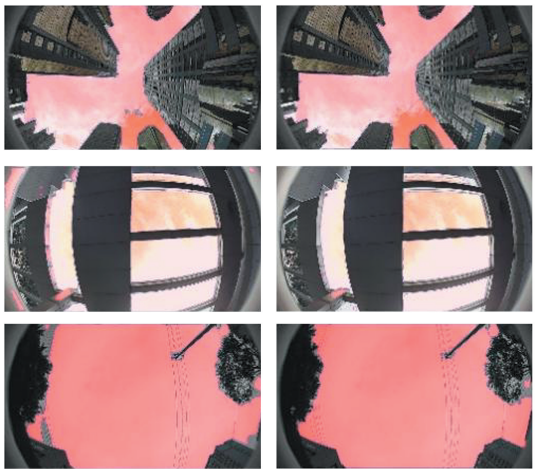


图 4　复杂天顶视图鱼眼图像的分割效果对比

Fig. 4　Comparison of segmentation performance under complex zenith view fisheye images

2.2　智能手机 GNSS 接收信号分类实验

如图 5 所示，在校园区域内选取 11 个典型站点(S_1～S_{11})作为实验区域，进行多设备、多时段的数据采集。实验设备包括 3 款安装有 Google GNSSLogger 应用的智能手机(小米 12S Pro、华为 P40、vivo IQOO Z1)，每部手机均通过三脚架静态固定，顶部安装 DW1600 鱼眼相机以同步采集天顶视图鱼眼图像，供后续图像分割与卫星信号标定使用。每站点进行 3 轮不同时段采集，每轮持续约 20 min，实验策略旨在避免采集到相同的卫星分布情况，提升训练样本的多样性，以防止机器学习模型过拟合。表 3 给出了实验采集的数据总量，其中视距/非视距通过 § 1.2 方法进行标定。

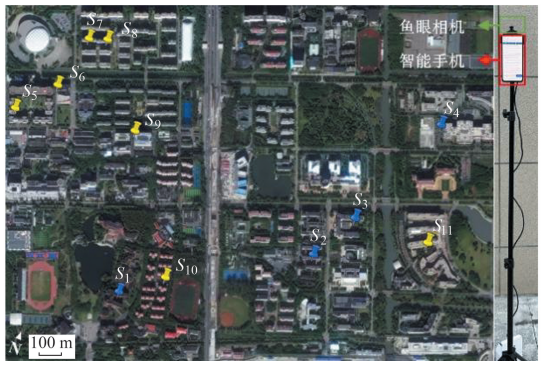


图 5　实验场地及数据采集设置

Fig. 5　Experimental site and data acquisition setup

表 3 实验采集的数据总量

Tab. 3 The total amount of data collected in the experiment

信号类型	小米 12S Pro	华为 P40	vivo IQOO Z1
视距	439 764	232 425	282 945
非视距	367 404	304 573	367 412
总计	807 168	536 998	650 357

为确保伪距残差计算的可靠性，首先验证式(7)中使用智能手机 GNSS 芯片定位结果进行伪距残差计算的可行性。图 6 展示了 S_1 站点小米 12S Pro 的 3 种不同定位方案(RTKLIB SPP、GNSSAnalysis 应用和 GNSS 芯片解)的定位误差。可以看出，RTKLIB 解算误差较大，GNSSAnalysis 应用结果相对稳定，但存在 10 m 左右的偏差，智能手机 GNSS 芯片解的定位结果误差最小，表现最稳定。因此，在计算伪距残差时，选择智能手机的 GNSS 芯片解作为智能手机位置。

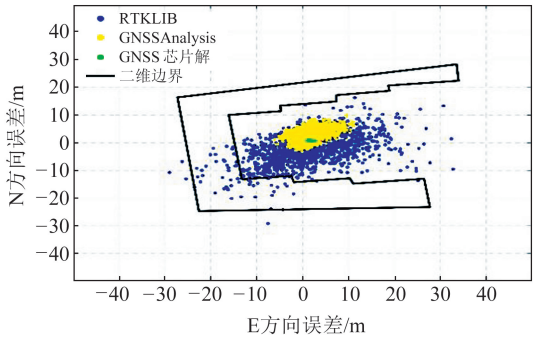


图 6 3 种方案下小米 12S Pro 在 S_1 站的定位误差

Fig. 6 Positioning error of the Xiaomi 12S Pro for three solutions at S_1 station

对未选取载波相位和多普勒频移相关 GNSS 接收信号特征进行进一步说明。小米 12S Pro 和 vivo IQOO Z1 均不支持载波相位观测，考虑选取特征对于智能手机的普适性，未选择载波相位的相关特征。进一步分析所收集数据的多普勒频移，其计算公式如下：

$$\text{dopper} = -\text{PseudorangeRateMetersPerSecond}/\lambda \quad (15)$$

式中，PseudorangeRateMetersPerSecond 为伪距变化率，可通过表 1 中对应字段获取；λ 为 GNSS 接收信号的波长。多普勒频移是由卫星和接收机之间的相对运动引起的，以 GPS 卫星为例，其相对于静态智能手机的最大速度约为 3 840 m/s，所引起的多普勒频移范围应该在 −4.88～4.88 kHz 之间。vivo IQOO Z1 手机所采集的数据中，存在 205 996 条数据(占比 31.67%)超过理论多普勒频移范围，同样考虑特征普适性未选择多普勒频移的相关特征。

在 GNSS 接收信号分类实验中，为评估不同机器学习模型在 GNSS 接收信号分类中的性能，比较 5 种常用的模型[8-13]：支持向量机(SVM)、随机森林(RF)、极限梯度提升(XGBoost)、K 近邻(KNN)和深度神经网络(DNN)。表 4 列出了使用小米 12S Pro 智能手机在图 5 中 S_1～S_4 站点采集的 GNSS 数据的分类准确率，训练数据集由其余 7 个站点的数据构成。结果表明，SVM 在 4 个实验站点中的 3 个上实现了最高的分类准确率，表明其在不同城市场景中的泛化能力较强。

表 4 5 种机器学习模型分类准确率对比

Tab. 4 Comparison of classification accuracy of five machine learning models

模型	分类准确率/%			
	S_1	S_2	S_3	S_4
SVM	85.4	90.7	82.1	82.3
RF	83.1	90.2	81.3	75.3
XGBoost	81.5	87.3	75.1	77.5
KNN	82.2	85.9	79.7	84.7
DNN	81.4	88.6	76.4	82.9

为验证所提取 GNSS 接收信号特征及 SVM 模型在不同智能手机间的泛化能力，选取小米 12S Pro 在 S_5～S_{11} 站点采集的数据作为训练集，并基于此训练 SVM 模型；再使用该模型对 S_1～S_4 站点由 3 款不同智能手机采集的数据进行测试，结果如图 7 所示。

由于不同站点的建筑分布存在差异，且数据采集的时间不同，因此基于小米 12S Pro 训练的 SVM 模型不一定在其自身数据上提供最佳的分类准确率。从图 7 看出，3 种智能手机的平均分类准确率达到 85.8%，验证了所提取的信号特征和 SVM 模型在不同智能手机之间进行 GNSS 接收信号分类的有效性和良好的泛化能力。

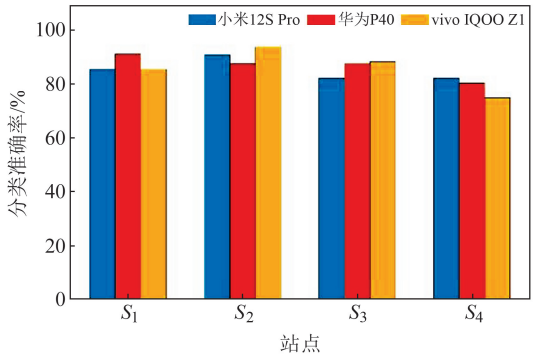


图 7 3 种智能手机数据在 4 个实验站点的视距/非视距分类准确率

Fig. 7 LOS/NLOS classification accuracy rate of three types of smartphone data at four experimental sites

3 结　语

本文提出一种针对智能手机 GNSS 接收信号视距/非视距分类的机器学习方法。针对智能手机 GNSS 接收信号噪声大且不稳定的特点,设计并分析了一系列适用于该信号的分类特征。为实现高精度的卫星标定,对 Deeplabv3+语义分割网络进行改进:通过更换主干网络,有效降低了计算开销;引入注意力机制,显著提升了天空区域分割的精度,使 mIoU 从 96.8%提升至 98.1%。在此基础上,结合图像分割结果与卫星位置信息,构建高质量的训练数据集,并对多种分类模型进行深入评估。实验结果表明,所提取的智能手机 GNSS 接收信号特征与所选用的机器学习模型,在典型城市场景下,能够实现不同智能手机间平均 85.8%的分类准确率,为复杂城市环境中智能手机 GNSS 接收信号的分类提供了一种有效的解决方案。

目前,本文的研究工作仍处于算法设计与离线验证阶段。未来的研究将致力于将所提方法集成到智能手机的实时应用系统中,以实现导航与定位场景下的精细化定位或城市地图构建,进一步拓展其在实际应用中的价值和潜力。

参考文献

[1] Ollander S, Bode F W, Baum M. Multi-Frequency GNSS Signal Fusion for Minimization of Multipath and Non-Line-of-Sight Errors: A Survey[C]. 15th Workshop on Positioning, Navigation and Communications(WPNC), Bremen, 2018

[2] Abolfathi Momtaz A, Behnia F, Amiri R, et al. NLOS Identification in Range-Based Source Localization: Statistical Approach[J]. IEEE Sensors Journal, 2018, 18(9): 3745-3751

[3] Egea-Roca D, Tripiana-Caballero A, López-Salcedo J A, et al. GNSS Measurement Exclusion and Weighting with a Dual Polarized Antenna: The FANTASTIC Project[C]. 8th International Conference on Localization and GNSS(ICL-GNSS), Guimaraes, 2018

[4] Lee M J L, Lee S, Ng H F, et al. Skymask Matching Aided Positioning Using Sky-Pointing Fisheye Camera and 3D City Models in Urban Canyons[J]. Sensors, 2020, 20(17)

[5] Groves P D. Shadow Matching: A New GNSS Positioning Technique for Urban Canyons[J]. Journal of Navigation, 2011, 64(3): 417-430

[6] Suzuki T, Kitamura M, Amano Y, et al. High-Accuracy GPS and GLONASS Positioning by Multipath Mitigation Using Omnidirectional Infrared Camera[C]. 2011 IEEE International Conference on Robotics and Automation, Shanghai, 2011

[7] Miura S, Kamijo S. GPS Error Correction by Multipath Adaptation[J]. International Journal of Intelligent Transportation Systems Research, 2015, 13(1): 1-8

[8] Yozevitch R, Moshe B B, Weissman A. A Robust GNSS LOS/NLOS Signal Classifier[J]. Navigation, 2016, 63(4): 429-442

[9] Hsu L T. GNSS Multipath Detection Using a Machine Learning Approach[C]. 2017 IEEE 20th International Conference on Intelligent Transportation Systems(ITSC), Yokohama, 2017

[10] Guermah B, El Ghazi H, Sadiki T, et al. A Robust GNSS LOS/Multipath Signal Classifier Based on the Fusion of Information and Machine Learning for Intelligent Transportation Systems[C]. 2018 IEEE International Conference on Technology Management, Operations and Decisions(ICTMOD), Marrakech, 2018

[11] Sun R, Wang G Y, Zhang W Y, et al. A Gradient Boosting Decision Tree Based GPS Signal Reception Classification Algorithm[J]. Applied Soft Computing, 2020, 86

[12] Jiang C, Chen Y, Xu B, et al. Convolutional Neural Networks Based GNSS Signal Classification Using Correlator-Level Measurements[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2022, 46: 61-66

[13] Sun Y, Fu L. Stacking Ensemble Learning for Non-Line-of-Sight Detection of Global Navigation Satellite System [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-10

[14] Zangenehnejad F, Gao Y. GNSS Smartphones Positioning: Advances, Challenges, Opportunities, and Future Perspectives[J]. Satellite Navigation, 2021, 2(1)

[15] Jiang Z Y, Groves P D. NLOS GPS Signal Detection Using a Dual-Polarisation Antenna[J]. GPS Solutions, 2014, 18(1): 15-26

[16] Zheng F, Li Q C, Wang J L, et al. GNSS NLOS Detection Method Based on Stacking Ensemble Learning and Applications in Smartphones[J]. GPS Solutions, 2024, 28(3)

[17] 李飞翔, 赵乐文, 唐歌实. 复杂观测环境下 GNSS 信号分类及精度评估[J]. 大地测量与地球动力学, 2022, 42(8): 852-856(Li Feixiang, Zhao Lewen, Tang Geshi. GNSS Signal Classification and Accuracy Evaluation in Complex Observation Environment[J]. Journal of Geodesy and Geodynamics, 2022, 42(8): 852-856)

[18] Basiri A, Lines T, Pereira M F. Scalable 3D Mapping of Cities Using Computer Vision and Signals of Opportunity [J]. International Journal of Geographical Information Science, 2023, 37(7): 1470-1495

[19] Lines T, Basiri A. 3D Map Creation Using Crowdsourced GNSS Data[J]. Computers, Environment and Urban Systems, 2021, 89

[20] Irish A T, Isaacs J T, Quitin F, et al. Belief Propagation Based Localization and Mapping Using Sparsely Sampled GNSS SNR Measurements[C]. 2014 IEEE International Conference on Robotics and Automation(ICRA), Hong Kong, 2014

[21] Geng J H, Li G C. On the Feasibility of Resolving Android GNSS Carrier-Phase Ambiguities[J]. Journal of Geodesy, 2019, 93(12): 2621-2635

[22] Li G C, Geng J H. Characteristics of Raw Multi-GNSS Measurement Error from Google Android Smart Devices [J]. GPS Solutions, 2019, 23(3)

[23] Li F, Dai Z Q, Li T C, et al. GNSS NLOS Signals Identification Based on Deep Neural Networks[C]. 4th International Conference on Information Science, Electrical, and Automation Engineering(ISEAE 2022), Guangzhou, 2022

[24] Xu H S, Angrisano A, Gaglione S, et al. Machine Learning Based LOS/NLOS Classifier and Robust Estimator for GNSS Shadow Matching[J]. Satellite Navigation, 2020, 1(1)

[25] Zhang G, Xu B, Hsu L T. GNSS Shadow Matching Based on Intelligent LOS/NLOS Classifier[C]. 16th IAIN World Congress, Chiba, 2018

[26] Kannala J, Brandt S S. A Generic Camera Model and Calibration Method for Conventional, Wide-Angle, and Fish-Eye Lenses[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(8): 1335-1340

[27] Zhang Z Y. Flexible Camera Calibration by Viewing a Plane from Unknown Orientations[C]. 7th IEEE International Conference on Computer Vision, Kerkyra, 1999

[28] Cohen A, Meurie C, Ruichek Y, et al. Characterization of the Reception Environment of GNSS Signals Using a Texture and Color Based Adaptive Segmentation Technique[C]. 2010 IEEE Intelligent Vehicles Symposium, La Jolla, 2010

[29] Attia D, Meurie C, Ruichek Y, et al. Counting of Satellites with Direct GNSS Signals Using Fisheye Camera: A Comparison of Clustering Algorithms[C]. 2011 14th International IEEE Conference on Intelligent Transportation Systems(ITSC), Washington, 2011

[30] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation[C]. European Conference on Computer Vision(ECCV), Munich, 2018

[31] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, 2018

[32] Liu J, Zhang W J, Tang Y T, et al. Residual Feature Aggregation Network for Image Super-Resolution[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), Seattle, 2020

[33] Chollet F. Xception: Deep Learning with Depthwise Separable Convolutions[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Honolulu, 2017

[34] Emara T, El Munim H E A, Abbas H M. LiteSeg: A Novel Lightweight ConvNet for Semantic Segmentation[C]. 2019 Digital Image Computing: Techniques and Applications(DICTA), Perth, 2019

Machine Learning Methods for Line-of-Sight/Non-Line-of-Sight Classification of GNSS Signals Received by Smartphones

JIA Xianglong[1] *WANG Chenyu*[2] *WANG Pai*[3]

1 Institute for Sensing and Navigation, Shanghai Jiao Tong University, 800 Dongchuan Road, Shanghai 200240, China

2 School of Computer Science and Technology, Wuhan University of Science and Technology, 10 West-Huangjiahu Road, Wuhan 430065, China

3 GNSS Research Center, Wuhan University, 129 Luoyu Road, Wuhan 430079, China

Abstract: Existing research on GNSS signal classification primarily targets professional-grade receivers, distinguishing between line-of-sight(LOS) and non-line-of-sight(NLOS) signals through the extraction of signal features to achieve high-accuracy positioning. However, the signal features and classification methods used in these studies may not be applicable to the signal characteristics of low-cost GNSS chips in smartphones. This paper proposes a machine learning-based method for classifying smartphone GNSS reception signals into LOS and NLOS. The method combines five key indicators: carrier-to-noise ratio, elevation angle, pseudorange residuals, normalized pseudorange residuals, and pseudorange residual percentage. It also integrates deep learning-based zenith view semantic segmentation and satellite calibration techniques to construct an accurate training dataset. Evaluations of various machine learning models in typical urban scenarios show that the proposed method achieves an average classification accuracy of 85.8% across different smartphone models.

Key words: smartphone; GNSS signal classification; machine learning; line-of-sight; non-line-of-sight

Foundation support: National Natural Science Foundation of China, No. 62201344.

About the first author: JIA Xianglong, postgraduate, majors in smartphone GNSS signal classification and environmental perception, E-mail: jiaxianglong@sjtu.edu.cn.

Corresponding author: WANG Pai, PhD, researcher, majors in GNSS signal processing and multi-source integrated positioning, E-mail: paiwang@whu.edu.cn.