

Hand Gesture Recognition Method Using FMCW Radar Based on Dual Channel CNN^{*}

QU Lele^{*}, WU Hanxu, YANG Tianhong, SUN Yanpeng

(College of Electronic Information Engineering, Shenyang Aerospace University, Shenyang Liaoning 110136, China)

Abstract: In order to improve the ability of gesture classification, a dual-channel convolutional neural network (CNN) hand gesture recognition method based on frequency modulated continuous wave (FMCW) radar is proposed. Firstly, the FMCW radar system with one transmitting antenna and two receiving antennas is used to detect different gesture actions and collect the echo data. The echo data of each receiving channel are preprocessed to generate range-time-map, range-Doppler-map and Doppler-time-map respectively. Then the three kinds of RGB color maps corresponding to each action are stacked. Finally, the stacked RGB color maps are input into dual channel CNN for gesture feature extraction and feature fusion. The experimental results show that the average classification accuracy of the proposed dual CNN hand gesture recognition method is 97.52%, indicating that the gesture classification ability of the proposed method improves effectively compared with that of the classic single-channel CNN.

Key words: frequency modulated continuous wave (FMCW) radar; hand gesture recognition; deep learning; dual channel; convolutional neural network

EEACC: 6140; 6320

doi: 10.3969/j.issn.1005-9490.2022.06.034

基于双通道 CNN 的 FMCW 雷达手势识别方法^{*}

屈乐乐^{*}, 吴涵旭, 杨天虹, 孙延鹏

(沈阳航空航天大学电子信息工程学院, 辽宁 沈阳 110136)

摘 要: 为了提高对手势动作的分类能力, 提出一种基于双通道卷积神经网络 (CNN) 的调频连续波 (FMCW) 雷达手势识别方法。首先利用具有一个发射天线、两个接收天线的 FMCW 雷达对不同手势动作进行探测并收集回波数据, 之后对每个接收通道的回波数据进行预处理, 分别得到距离时间图、距离多普勒图与微多普勒时频谱图, 然后将每个动作对应的三种彩色 RGB 图像进行堆叠。最后将堆叠后的彩色 RGB 图像输入到双通道 CNN 中进行手势特征提取和特征融合。实测数据处理结果表明所提基于双通道 CNN 手势识别方法对设计的八种手势动作的分类平均识别正确率为 97.52%, 与传统的单通道 CNN 相比, 有效地提高了对手势动作的分类能力。

关键词: 调频连续波雷达; 手势识别; 深度学习; 双通道; 卷积神经网络

中图分类号: TN957.51

文献标识码: A

文章编号: 1005-9490(2022)06-1469-07

手势识别技术在人机交互领域具有重要的应用价值, 可用于智能家居、智能驾驶、手语实时翻译和游戏控制等多种应用场景。现有的手势识别技术很多是基于可见光视觉识别^[1-3], 这种方法受光照条件影响明显, 且存在泄露用户隐私的风险。雷达传感器可以解决视觉系统识别精度较低的问题, 是照明条件较差时的理想选择^[4-6]。此外, 雷达传感器能够比基于

可见光视觉的识别系统更好地保护用户的隐私。因此, 基于雷达传感器的手势识别系统在实际应用中有着非常广阔的应用前景和深远的应用价值^[7-8]。文献[9]和[10]采用单频连续波雷达通过短时傅里叶变换得到手势动作回波信号的时频谱图像, 并将时频谱图作为卷积神经网络 (Convolutional Neural Network, CNN) 的输入数据实现手势识别。但单频连

项目来源: 国家自然科学基金 (61671310); 航空科学基金 (2019ZC054004); 辽宁省兴辽英才计划项目基金 (XLYC1907134); 辽宁省百千万人才工程项目基金 (2018B21); 辽宁省教育厅基金 (LJKZ0172)

收稿日期: 2021-09-13

修改日期: 2021-11-09

续波雷达无法得到目标的距离信息,所以系统的识别能力有限。调频连续波(Frequency Modulated Continuous Wave, FMCW)雷达是一种能够对目标同时进行距离和速度测量的雷达^[11-13]。文献[14]使用串联式一维神经网络对 FMCW 雷达原始回波进行特征提取,这种方法可以实现手势特征的实时提取和分类,收敛速度快,但仅能提取原始信号的特征信息,不能完整地提取出动作的特征信息。有研究人员采用多个接收天线的雷达采集回波数据,并从中获取了目标的角度信息^[15-17]。这类方法增加了网络的复杂度和训练时间,需要更多的训练数据来拟合网络,且角度信息仅适用于运动幅度较大的手势动作。文献[16]提出将三种手势特征图像融合,但由于使用的图像为灰度图像,且 CNN 为单通道网络结构,使得特征信息不够完整。

针对上述问题,提出了一种基于一个发射通道两个接收通道 FMCW 雷达的双通道 CNN 手势识别方法。该方法首先对每个接收通道获取到的原始回波信号进行预处理分别得到距离时间图(Range-Time-Map, RTM)、距离多普勒图(Range-Doppler-Map, RDM)与多普勒时间图(Doppler-Time-Map, DTM),然后分别将每个接收天线对应的三种图像进行堆叠,堆叠后的样本输入到双通道 CNN 中提取特征并在全连接层输出后进行特征融合,采用 Softmax 函数对提取到的手势特征进行分类。最后将所有数据进行五折交叉验证,得出最终手势识别准确率结果。

1 回波信号预处理

1.1 回波信号获取

本文采用一发二收的 FMCW 雷达进行手势数据采集。FMCW 雷达由波形发生器、一个发射天线和两个接收天线、信号解调器和模数转换器(Analog-to-Digital Converter, ADC)组成。波形发生器通过发射天线发送 FMCW 信号。然后利用低通滤波器(Low Pass Filter, LPF)获得中频信号。图 1 为一发二收的 FMCW 雷达系统结构图。

在 FMCW 雷达中,回波信号可以表示为

$$S_{rx}(t) = A_{rx} \cos(2\pi(f_0(t-\tau) + \frac{r}{2}(t-\tau)^2) + \varphi_{rx}) \quad (1)$$

式中: τ 为发射与接收信号的时间差, f_0 为载波频率, r 为调频斜率, φ_{rx} 为接收信号的初始相位, A_{rx} 为接收信号的振幅,根据雷达方程可表示为

$$A_{rx} = \frac{GA\sqrt{P\sigma}}{(4\pi)^{1.5}R^2\sqrt{L_sL_a}} \quad (2)$$




图 1 一发二收的 FMCW 雷达系统结构图

式中: G 为天线增益, P 为发射机功率, σ 为目标雷达横截面积, L_s 和 L_a 分别表示系统和空气中信号的损耗。

然后,接收到的信号由 I/Q 解调器解调得到复中频信号

$$S(t) = I(t) + jQ(t) = A \exp[j\psi(t)] \quad (3)$$

式中: $\psi(t)$ 是信号的相位。采样的 I/Q 信号可以转换为二维矩阵表示,其中行和列分别表示快时间变量和慢时间变量。

1.2 回波信号处理

FMCW 雷达对每个接收通道采集到的手势回波数据进行预处理可以分别得到 RTM、RDM 与 DTM。

1.2.1 RTM

将 FMCW 雷达回波数据表示为二维矩阵 $S(n, m)$, 其中 $n=0, 1, \dots, N-1, m=0, 1, \dots, M-1, N$ 和 M 分别是雷达在一个调频周期内的采样点数和总的调频周期个数。对矩阵 $S(n, m)$ 的每一列进行离散傅里叶变换(Discrete Fourier Transform, DFT)得到

$$R(k, m) = \frac{1}{N} \sum_{n=0}^{N-1} S(n, m) \exp\left(-j \frac{2\pi}{N} kn\right) \quad (4)$$

式中:变量 $k=0, 1, \dots, N-1$ 。对矩阵 $R(k, m)$ 进行动目标显示滤波后取模值得到 RTM, 从 RTM 中可以得到手势动作期间手与雷达天线之间的距离随时间变化的信息。

1.2.2 RDM

对式(4)中的矩阵 $R(k, m)$ 的每一行进行 DFT 得到

$$V(k, l) = \frac{1}{M} \sum_{m=0}^{M-1} R(k, m) \exp\left(-j \frac{2\pi}{M} lm\right) \quad (5)$$

式中:变量 $l=0, 1, \dots, M-1$ 为目标的多普勒频率

信息,

对矩阵 $V(k, l)$ 取模值可得到 RDM, RDM 反映了目标在每个距离单元所对应的多普勒频率信息。

1.2.3 DTM

FMCW 雷达距离分辨率 ΔR 为

$$\Delta R = \frac{c_0}{2B} \quad (6)$$

式中: B 为 FMCW 雷达的信号带宽, c_0 为电磁波在空气中的传播速度。对根据式(4)得到的 RTM 手势动作所在的距离单元范围内的信号进行相干相加得到

$$D(m) = \sum_{k=k_1}^{k_2} R(k, m) \quad (7)$$

式中: k_1 与 k_2 为所设置距离门的最小值和最大值。当 FMCW 雷达工作带宽为 2 GHz 时, 实验时手势动作目标距离雷达的范围为 10 cm~30 cm, 因此 k_1 和 k_2 分别为 10 和 30。然后对 $D(m)$ 进行短时傅里叶变换 (Short-Time Fourier Transform, STFT) 得到

$$T(p, q) = \sum_{m=0}^{M-1} D(m) g(m-p) \exp\left(-j2\pi \frac{mq}{M}\right) \quad (8)$$

式中: $g(m)$ 为汉明窗函数, p 为窗函数移动的索引值, 窗函数每次移动时对应的数据重叠率为 95%。最后根据 $T(p, q)$ 可以得到 DTM, DTM 的横轴单位为时间, 该时间所指的是窗函数 $g(m)$ 沿着时间轴移动所对应的时间, 也就是式(8)中的变量 p , DTM 的纵轴表示多普勒频率, 为式(8)中的变量 q 。

2 双通道 CNN

本文首先分别对每个接收通道的原始回波信号进行预处理分别得到 RTM、RDM 与 DTM 三种彩色图像, 并对三种彩色图像的 RGB 分量进行堆叠, 得到新的三维张量, 其结构如图 2 所示。




图2 三维张量结构图

然后将堆叠后的三维张量分别作为双通道 CNN 的第一通道和第二通道输入, 然后将两个通道在全连接层的输出结果进行特征融合, 从而较为完整地提取出每种手势的特征。最后在网络的 Softmax 层得到最终分类结果。手势识别整体流程图如图 3 所示。其中 CNN1 和 CNN2 具有相同的网络结构, 均为本文自主设计的轻量化卷积神经网络。




图3 手势识别整体流程图

2.1 CNN 图像特征提取

为了充分提取每个手势动作的特征并减少冗余信息, 本文对 VGG-16 网络进行改进, 设计了一种仅包含 4 层的轻量化 CNN, 有效提取数据特征并减少训练时间。网络包括 4 个 2 维卷积层, 每一个卷积层后分别连接 1 个 ReLU 激活函数, 前三个激活函数后连接 1 个池化层, 全连接层连接最后一个激

活函数, 获取到 30×1 维的特征向量。因此, 每个 CNN 包含了 4 个卷积层、3 个池化层和 1 个全连接层, 具体结构如图 4 所示。

2.2 模型训练

CNN 的模型训练过程分为两个阶段。第一个阶段是数据由低层次向高层次传播的阶段, 即前向传播阶段。另外一个阶段是, 当前向传播得出的结



图 4 CNN 结构图

果与预期不相符时,将误差从高层次向底层次进行传播训练的阶段,即反向传播阶段。

当两个通道的手势特征提取完毕后,对两个通道得到的特征进行拼接,即将两个全连接层输出的特征一维向量连接在一起,得到融合后的特征,再添加全连接层将手势特征映射到标本标记空间。最后将全连接层生成的特征向量输入到 Softmax 函数中进行分类

$$y_i = \frac{\exp(z_i)}{\sum_{j=1}^k \exp(z_j)} \quad (9)$$

式中: k 为总的手势种类,本文中 $k=8, i=1, 2, \dots, 8$ 为第 i 类手势, z_i 为特征向量的第 i 个元素。在网络训练中,本文使用交叉熵损失函数来计算损失值

$$H(y_i) = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^k y'_i \log(y_i) \quad (10)$$

式中: N 为每个 batch size 中样本个数, y'_i 为真实结果,取值为 1 或 0, y_i 为 Softmax 的计算结果。此外,本文在训练过程中选择恒定的学习率使网络的损失值快速地收敛到较小值,随着训练步数的不断增加,网络模型的损失值逐渐趋于平稳。

3 实验结果分析

3.1 实验场景

本文使用的实验设备包括一部 Ancortek 公司生产的 K 波段一发双收 FMCW 雷达、NVIDIA - GTX1650 显卡的 PC 机、MALAB 软件和 Tensorflow2.0+Keras 深度学习框架。FMCW 雷达用来收集手势动作的回波数据,其中接收天线 1 和接收天线 2 与发射天线的距离不同,两个接收天线之间的距离为 3 cm。所以对应的原始回波信号在幅度上略有差别。FMCW 雷达系统的具体参数如表 1 所示。

表 1 FMCW 雷达系统参数

参数	数值
发射天线数量	1 个
接收天线数量	2 个
载频	24 GHz
带宽	2 GHz
调频周期	1 ms
基带采样频率	128 kHz
天线增益	10 dBi
发射功率	18 dBm

原始回波信号通过 USB 数据线传入 PC 端,在 MATLAB 上对原始回波数据进行预处理。双通道 CNN 基于 Tensorflow2.0+Keras 深度学习框架,在 NVIDIA-GTX1650 显卡的 PC 机上进行训练。实验场景如图 5 所示。




图 5 实验场景示意图

3.2 构建手势数据集

雷达系统对手势的不同动作回波进行数据采集。采集数据对象为 4 男 1 女,编号为 A 至 E。将雷达放置在桌面上,发射和接收天线水平正对测试实验人员的手部,与手的距离大约为 0.1 m~0.3 m。设计了八种动作,分别为抬手、挥手、招手、画圆、推手、弹手指、拿捏和打响指。首先给雷达提供 5 V 恒定电源,再将雷达与 PC 端用数据线连接,打开数据采集界面开始采集数据。然后将雷达采集到的原始回波数据进行第 1 节中的预处理,得到对应的 RTM、RDM 与 DTM,最后,为了使训练样本集中图像尺寸保持一致,将每张 RGB 彩色图像尺寸均缩放为 64x64x3。具体手势动作以及对应的三种特征图像如图 6 所示。

每个动作每名实验人员重复采集 40 次,每个动作对应的雷达回波信号采集时间是 3 s,其中每个样本都包括两个接收通道的原始回波信号,最终共测得 5x8x40=1 600 组样本。




图6 八种手势动作及对应的 RTM, RDM, DTM

3.3 实验结果

3.3.1 网络训练过程

首先对输入的特征样本进行缩放,双通道 CNN 的每个通道样本输入层尺寸设置为 $64 \times 64 \times 9$, 采用 Adam 梯度下降优化器, 设置 0.001 的恒定学习率, 训练一共 150 轮迭代, 每次迭代的批样本 (batch size) 为 16, 每轮迭代批次为 80, 一次完整的训练过程需要耗时 3 min。在 1 600 组样本的实验中, 双通道 CNN 的训练和测试准确率如图 7 所示。从图中可以看出, 本文所提双通道 CNN 识别方法的准确率在 100 轮迭代之前随着迭代次数持续增加, 100 轮迭代之后达到收敛。

在网络训练中, 损失函数可以计算神经网络每次迭代的前向计算结果与真实值的差距, 从而指导下一步的训练向正确的方向进行, 本文使用交叉熵损失函数作为模型评估的标准。图 8 给出了网络训练过程的损失函数值。由图可以看出, 随着训练轮迭代次数的增加, 损失值逐渐减小。当训练到第 100 轮迭代时, 损失值已经趋于平稳, 误差值接近于 0, 说明此时模型参数已达到最优。




图7 双通道 CNN 识别准确率




图8 双通道 CNN 损失函数

3.3.2 手势识别性能分析

为了比较双通道 CNN 和传统的单通道 CNN 的分类性能, 首先用双通道 CNN 对使用两个接收天线采集的数据进行测试, 然后用单通道 CNN 分别对仅使用第一个接收天线和仅使用第二个接收天线采集的数据进行测试。为了使实验结果具有普遍性, 本文分别使用双通道 CNN 和传统单通道 CNN 对数据进行五折交叉验证实验。每次实验在每一类动作对应的总数据样本中随机抽取 80% 共即 1 280 组数据用于训练, 余下的 20% 共即 320 组数据进行测试。三组实验识别结果的混淆矩阵分别如图 9~图 11 所示。

从混淆矩阵中可以看出, 抬手、招手、挥手、画圈和推手这几种手势动作的分类错误较少, 因为它们相对于雷达运动的幅度相对较大, 动作区分度较高; 而弹手指、拿捏和打响指这些动作的分类错误率相对较高, 因为这几种手势的动作幅度很小, 相对于雷达的运动轨迹也比较相似。表 2 给出了不同网络结构对于测试手势动作分类的平均准确率, 只使用一个接收天线的单通道 CNN 的识别准确率分别为 92.43% 和 92.31%, 而使用两个接收天线的双通道

CNN 的识别平均准确率为 97.52%,比单通道 CNN 的识别精度高 5%左右。




图 9 双通道 CNN 识别混淆矩阵




图 10 单通道 CNN1 识别混淆矩阵




图 11 单通道 CNN2 识别混淆矩阵

表 2 不同 CNN 识别准确率对比

网络结构	双通道	单通道 1	单通道 2
平均识别准确率/%	97.52	92.43	92.31

为了进一步证明双通道 CNN 在手势识别中的优越性并比较不同分类特征的手势表征能力,分别将距

离时间、距离多普勒与微多普勒时频谱图像单独作为手势特征输入到单、双通道 CNN 中进行训练与测试,并与文献[15]中提出的将 RTM 和角度时间图 (Angle-Time-Map, ATM) 融合的手势识别方法进行比较。本实验首先将数据随机抽取 80% 作为训练集,剩余 20% 作为测试集,再将 CNN 输入层大小设置为 $64 \times 64 \times 3$,实验结果如表 3 所示。从表 3 中可以看出,任何一种手势表征方法的双通道 CNN 测试结果都明显优于单通道 CNN,其中 DTM 特征对于本文设计的八种手势动作有最高的平均识别准确率,而 RDM 特征的识别效果仅次于 DTM 特征,而 RTM 特征对于手势动作识别的准确率相对较差,主要是因为本文设计的手势动作相对于雷达运动范围较小,不同手势动作的运动距离差别不大,而手势动作运动速度较快,所以频率变化较为明显,以至于 DTM 特征能达到最佳单一特征识别效果,文献[15]方法的平均识别准确率为 92.06%,以上特征类型的识别准确率均低于本文提出特征融合后的识别准确率。

表 3 不同手势表征方法对比

特征类型	网络结构	平均识别准确率/%
RTM	单通道 CNN	82.81
RTM	双通道 CNN	85.94
RDM	单通道 CNN	89.06
RDM	双通道 CNN	93.13
DTM	单通道 CNN	91.68
DTM	双通道 CNN	95.87
DTM+ATM[15]	双通道 CNN	92.06

为了评估模型的泛化能力,本文进行了留一法实验,即每次实验依次将实验人员 A-实验人员 E 测得数据作为测试集,其余 4 名实验人员测得的数据作为训练集,实验测试准确率如表 4 所示。结果表明,不同实验人员测得的数据分别作为测试集的实验结果较为稳定,每次实验的识别准确率都能达到 96% 以上,证明本文提出的手势动作识别方法具有很好的泛化能力。

表 4 留一法识别准确率 单位:%

测试实验人员	A	B	C	D	E
识别准确率/%	97.27	97.81	97.50	97.19	96.88

4 结论

提出了一种基于双通道 CNN 的 FMCW 雷达手势识别方法。针对雷达特征图像设计了 4 个卷积层和 2 个全连接层的轻量化 CNN,利用 RTM、RDM 与 DTM 三种图像特征,对每种单一特征数据和三种特

征融合后的数据分别用双通道 CNN 和单通道 CNN 对 8 类微动手势进行五折交叉验证实验,并分别对 5 名实验人员的数据做留一法实验。分类结果显示,相比单一特征和单通道 CNN,本文设计的 3 种特征融合的双通道 CNN 取得最优的分类表现,平均识别准确率为 97.52%,证明本文提出的微动手势识别方法有效地提高了分类能力,而且具有较好的测试对象泛化能力。

参考文献:


- [1] Coelho Y L, Salomao J M, Kulitz H R. Intelligent Hand Posture Recognition System Integrated to Process Control[J]. IEEE Latin America Transactions, 2017, 15(6): 1144-1153.
- [2] 冯志全, 杨学文, 徐涛, 等. 结合手势二进制编码和类-Hausdorff 距离的手势识别[J]. 电子学报, 2017, 45(9): 2281-2291.
- [3] Pai N S, Hong J H, Chen P Y, et al. Application of Design of Image Tracking by Combining SURF and TLD and SVM-Based Posture Recognition System in Robbery Prealert System[J]. Multimedia Tools and Applications, 2017, 76(23): 25321-25342.
- [4] Khan F, Leem S K, Cho S H. Hand-Based Gesture Recognition for Vehicular Applications Using IR-UWB Radar[J]. Sensors, 2017, 17(4): 833.
- [5] Zhou Z, Cao Z, Pi Y. Dynamic Gesture Recognition with a Terahertz Radar Based on Range Profile Sequences and Doppler Signatures[J]. Sensors, 2017, 18(1): 10.
- [6] Wang W, Liu A X, Shahzad M, et al. Device-Free Human Activity Recognition Using Commercial WiFi Devices[J]. IEEE Journal on Selected Areas in Communications, 2017, 35(5): 1118-1131.
- [7] Skaria S, Al-Hourani A, Lech M, et al. Hand-Gesture Recognition Using Two-Antenna Doppler Radar with Deep Convolutional Neural Networks[J]. IEEE Sensors Journal, 2019, 19(8): 3041-3048.
- [8] Chen Z X, Li G, Fioranelli F, et al. Dynamic Hand Gesture Classification Based on Multistatic Radar Micro-Doppler Signatures Using Convolutional Neural Network[C]//2019 IEEE Radar Conference (RadarConf19), Boston, MA, USA, IEEE, 2019: 1-5.
- [9] Zhang J J, Tao J K, Shi Z G. Doppler Radar Based Hand Gesture Recognition System Using Convolutional Neural Networks[C]//2017 International Conference on Communications, Signal Processing, and Systems, Singapore, Harbin, China, 2019: 1096-1113.
- [10] Kim Y, Toomajian B. Hand Gesture Recognition Using Micro-Doppler Signatures with Convolutional Neural Network[J]. IEEE Access, 2016, 4: 7125-7130.
- [11] Zhang X H, Wu Q S, Zhao D X. Dynamic Hand Gesture Recognition Using FMCW Radar Sensor for Driving Assistance[C]//2018 10th International Conference on Wireless Communications and Signal Processing(WCSP), Hangzhou, China, 2018: 1-6.
- [12] Sun Y L, Fei T, Schliep F, et al. Gesture Classification with Hand-crafted Micro-Doppler Features Using a FMCW Radar[C]//2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility(ICMIM), Munich, Germany, IEEE, 2018: 1-4.
- [13] Zhang Z, Tian Z, Zhpu M. Dynamic Continuous Hand Gesture Recognition Using FMCW Radar Sensor[J]. IEEE Sensors Journal, 2018, 18(8): 3278-3289.
- [14] 靳标, 彭宇, 邝晓飞, 等. 基于串联式一维神经网络的毫米波雷达动态手势识别方法[J]. 电子与信息学报, 2021, 43(9): 2743-2750.
- [15] 王勇, 王沙沙, 田增山, 等. 基于 FMCW 雷达的双流融合神经网络手势识别方法[J]. 电子学报, 2019, 47(7): 1408-1415.
- [16] 夏朝阳, 周成龙, 介钧誉, 等. 基于多通道调频连续波毫米波雷达的微动手势识别[J]. 电子与信息学报, 2020, 42(1): 164-172.
- [17] 王勇, 吴金君, 田增山, 等. 基于 FMCW 雷达的多维参数手势识别算法[J]. 电子与信息学报, 2019, 41(4): 822-829.




屈乐乐(1983—),男,汉族,沈阳航空航天大学电子信息工程学院教授,主要研究方向为超宽带雷达信号处理技术、稀疏微波成像技术、人体行为雷达识别技术,qulele83@126.com;



吴涵旭(1998—),男,汉族,沈阳航空航天大学电子信息工程学院硕士研究生;



杨天虹(1982—),女,汉族,沈阳航空航天大学电子信息工程学院讲师,主要研究方向为雷达信号处理技术;



孙延鹏(1973—),男,汉族,沈阳航空航天大学电子信息工程学院教授,主要研究方向为雷达信号处理技术。