

基于随机森林的脉冲超宽带雷达微动手势识别

李瑶*, 王欣, 贺文涛, 史宝岱

中国人民解放军空军工程大学防空反导学院跟踪制导教研室, 陕西 西安 710051

摘要 针对雷达微动手势识别中的回波信噪比低、数据量大、特征可解释性差的问题,提出了一种基于随机森林的超宽带雷达微动手势识别系统。微动手势雷达截面积小,进而导致信噪比低、正向特征模糊等问题。针对这些问题,采用聚类算法提取回波主向量并构建多项式特征,以减少冗余数据,提高手势回波信噪比。对于训练过程中特征图谱可解释性破坏的问题,采用随机森林可视化特征贡献率并以此选择特征应用于模型。实验结果表明,在不同底噪的回波信号下,该算法相比于其他算法具有更好的识别性能,这验证了算法的有效性。

关键词 图像处理; 动态手势识别; 多普勒处理; 多项式特征; 随机森林

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.2207002

Hand Gesture Recognition Using Ultra-Wideband Radar with Random Forest

Li Yao*, Wang Xin, He Wentao, Shi Baodai

Tracking Guidance Teaching and Research Section, Air Defense and Missile Defense College, Air Force Engineering University, Xi'an, Shaanxi 710051, China

Abstract Aiming at the problems of low echo signal-to-noise ratio, large amount of data, and weak interpretability of features in radar micro-motion gesture recognition, a micro-motion gesture recognition system using an ultra-wideband radar based on random forest is proposed. The small radar cross section of the micro-motion gesture causes problems such as low signal-to-noise ratio and blurred positive features. As for these problems, the clustering algorithm is used to extract the main vector of echo and construct polynomial features to reduce redundant data and improve the signal-to-noise ratio of gesture echo signals. For the destruction of interpretability during training process of feature maps, random forest is used to visualize the feature contribution rate and select features for applying to the model. Experimental results show that the algorithm has better recognition performance than other algorithms under echo signals with different noise floors, which verifies the effectiveness of the algorithm.

Key words image processing; dynamic gesture recognition; Doppler processing; polynomial feature; random forest

OCIS codes 100.3008; 100.5010; 070.2465

1 引言

随着人类生活的高速智能化,人脸识别、手势识别等非接触式人机交互技术有了愈发迫切的需求和更加积极的现实意义^[1]。雷达技术的日益成熟和雷达检测精度的日益提高,使得雷达传感器在这类任务中的应用也愈加广泛。

目前,国内外研究人员对基于雷达传感器的手势识别进行了大量相关研究。文献[2]基于超宽带雷达分析不同手势的时域回波波形差异,利用卷积神经网络进行分类,能够实现静态手势时域波形的快速识别。然而实际环境中电磁干扰复杂,基于单一时域回波振幅特征的手势识别系统的抗干扰能力差且无法识别动态手势。文献[3]针对上述问题,设

收稿日期: 2021-04-15; 修回日期: 2021-06-01; 录用日期: 2021-07-05

通信作者: *liyao_kaye@outlook.com

计了高速采样模块,将动态手势采样为手势序列,构建 3 层卷积神经网络拼接长短期记忆网络(LSTM)以实现手势识别,从而取得了较好的检测效果。但高速采样模块对硬件成本要求较高。文献[4]基于动态手势的原始时域回波,设计串联式 1 维神经网络(1D-ScNN)拼接长短期记忆网络(LSTM),提取时域回波波形特征以及帧间时序特征。文献[5]基于调频连续波雷达手势回波的联合多普勒图谱,利用卷积神经网络进行微动手势识别。文献[6]用基于 Resnet50 残差网络的 SSD 模型识别光学缝纫动作。文献[7]设计基于自适应增强的卷积神经网络双分类器,实现了对光学图像的单双手势的识别。文献[8]利用集成卷积神经网络解决了特征提取不充分的问题,取得了较好的面部表情分类结果。然而这类基于神经网络的雷达手势识别方法具有一定的局限性:1)通过拼接 LSTM 网络提取时序信息,造成计算资源二次损耗;2)联合多普勒图谱造成冗余信息增加,未能有效改善信噪比;3)利用神经网络处理雷达回波的多普勒特征图谱时,中间特征模糊。

针对以上问题,本文提出了一种基于随机森

林^[9](RF)的脉冲超宽带雷达微动手势识别方法。本文采用连续距离多普勒图谱生成(CRG)算法^[10]积累输出特征图谱,单帧图谱中包含连续若干时刻的回波信号,设计基于 K -means^[11]聚类和多项式特征的信号处理算法对雷达手势回波的距离多普勒图谱(RDM)进行特征重建以提高回波信噪比,并根据特征贡献率选择特征调整随机森林模型,实现超宽带雷达微动手势分类。

2 雷达回波预处理

2.1 雷达回波时频转换

本文基于双基地脉冲超宽带雷达捕获微动手势回波。通过混频模块和等效采样模块接收回波信号,对传输至终端的数字信号进行解析,具体的信号处理流程如图 1 所示。回波信号被离散化并打包为 .mat 文件,接着在终端回放数据并利用脉冲重排将信号重组为数据矩阵。最后,利用 CRG 算法输出连续的 RDM。CRG 算法可以大大减少由信号突变带来的帧间不连续现象,相比传统多普勒处理有更高的处理精度,且不必使用 LSTM 网络再次提取帧间的时序信息^[12]。




图 1 回波信号处理流程

Fig. 1 Flow chart of echo signal processing

2.2 手势模型建立

不同手势的手指及手掌运动速度以及雷达截面积都不同,即回波信号中包含的多普勒速度分量有

所不同,在 RDM 中表现为其分布有区别。微动手势时域回波经过时频转换得到多普勒信息,对比时频域图谱得出,不同手势间的特征差异在频域表现

得更明显。

经过对图 2 的分析得出, 手势 Z_i 仅存在一个主多普勒速度分量 V_i , 不同手势间雷达截面积 σ_i 不同, 由此引起周围环境的耦合噪声 n_i 也存在差异, 平均背景像素值反映 σ_i 及 n_i 的水平, RDM 中距离维的保持长度 L_i 由手势运动的幅度决定。因此,

手势信号定义为

$$\begin{cases} Z_i = f(a_i V_i + b_i L_i + d_i \sigma_i) + c_i n_i, \\ n_i = g(\sigma_i) \end{cases}, \quad (1)$$

式中: n_i 服从高斯分布; f 与 g 均为线性函数; a_i 、 b_i 、 c_i 、 d_i 为回波信号中各分量的权重系数。

基于以上分析, 微动手势雷达回波中的数据可

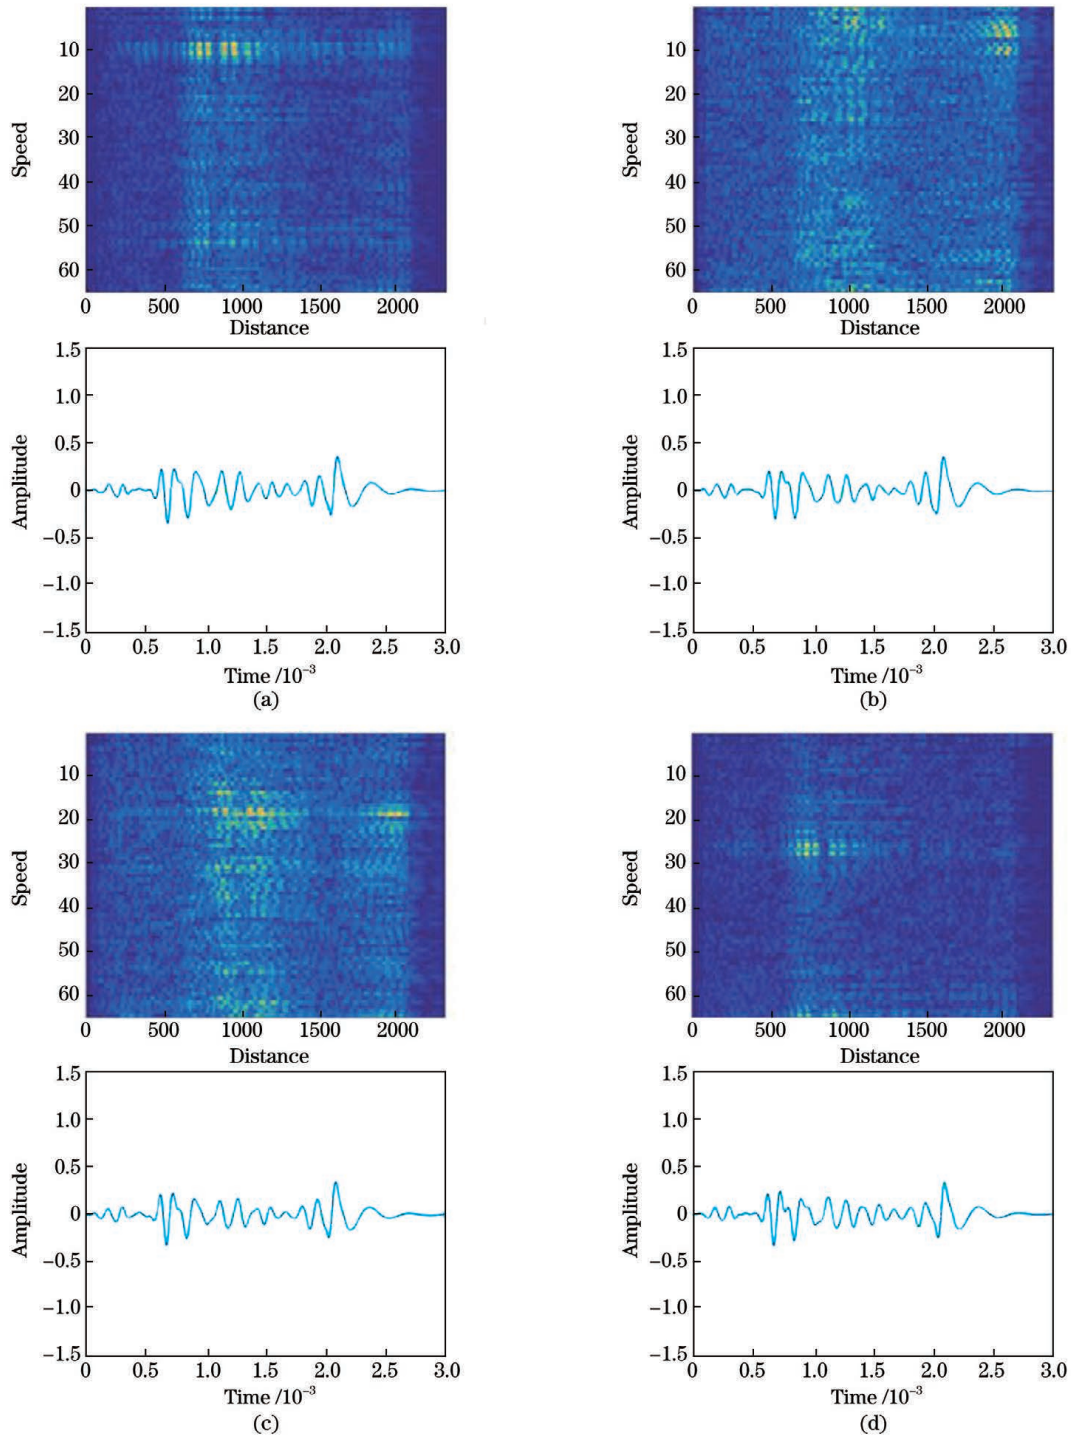


图 2 不同手势回波信号的时频域对比。(a) 手势 1; (b) 手势 2; (c) 手势 3; (d) 手势 4

Fig. 2 Comparison of time domain and frequency domain among different gestures. (a) Gesture 1; (b) gesture 2; (c) gesture 3; (d) gesture 4

以被拆分并量化分析,这样可在减少冗余的同时,为特征保留可解释性,而不必使用卷积神经网络对不具备明显的纹理或边缘特征的 RDM 提取特征。基于系统在复杂电磁环境^[13]中应用的考虑,决定采用 K 均值聚类算法分析回波信号并降维,再通过构建多项式特征提高信号的信噪比(SNR)。

2.3 手势特征构建

K 均值聚类算法是无监督的数据划分算法,通过相似性衡量数据中的关联性,并将关联紧密的数据归为一类。

数据 D 定义为

$$D = \{x_1, x_2, \dots, x_m\}, \quad (2)$$

式中: x_1, x_2, \dots, x_m 为数据集 D 中的元素。当设定聚类簇数为 K 时,簇划分结果为

$$C = \{C_1, C_2, \dots, C_K\}. \quad (3)$$

式中: C 为聚类集合; C_1, C_2, \dots, C_K 为各聚类向量。定义平方误差 E 为

$$E = \sum_{i=1}^K \sum_{x \in C_i} \|x - \mu_i\|_2^2, \quad (4)$$

式中: μ_i 为簇 C_i 的均值向量,即质心,定义为

$$\mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x. \quad (5)$$

采用迭代方式求取平方误差的最小值, E 达到最小值时,簇内数据相似度最高,簇间相似度最低。

利用 K 均值聚类算法对频域回波信号进行分析和可视化,回波中的目标与噪声可以被分离,其分离的簇数根据 K 值设定。

RDM 经过聚类分析得到 K 个聚类区域,以 $\mu_i (i=1, 2, \dots, K)$ 为聚类中心,每簇数据的标签为 K -Means 算法为其分配的 $1-K$ 的自然数。

聚类中心为 $\mu_1, \mu_2, \dots, \mu_K$, 聚类区域为 C_1, C_2, \dots, C_K , 其中,

$$C_i = (x_1, x_2, \dots, x_q). \quad (6)$$

在进行特征构建时,将聚类中心与簇内数据合并,定义当前簇的特征为

$$F_i = (\mu_i, x_1, x_2, \dots, x_q). \quad (7)$$

分析聚类结果,若簇间数据存在线性关系,则当前聚类结果中存在冗余簇,需要通过数据降维消除冗余簇,即选择 l 簇数据作为手势回波的 l 个特征。

3 手势识别系统设计

3.1 多项式特征生成

手势动作与周围环境存在复杂的耦合现象,采

用线性系统无法对其进行准确描述。故针对经过聚类算法得到的信号主成分构建多项式特征,将数据映射到高维空间以捕获交互特征,增强模型拟合能力。为了与手势速度相匹配,本文将特征构建阶数设为 2。

建立手势回波与 V_i, L_i, σ_i 和 n_i 间的非线性关系。由(1)式可推导得到

$$Z_i = f(a_i V_i + b_i L_i + d_i \sigma_i) + c_i g(\sigma_i). \quad (8)$$

针对聚类降维后的数据构建特征:

$$F = (F_1, F_2, \dots, F_l). \quad (9)$$

针对 (F_1, F_2, \dots, F_l) 构建二阶多项式特征:

$$F' = (F_1, F_2, \dots, F_l, F_1 F_2, \dots, F_{l-1} F_l, F_1^2, F_2^2, \dots, F_l^2), \quad (10)$$

另记为

$$F' = (A_1, A_2, \dots, A_N), \quad (11)$$

其中

$$\begin{cases} A_i = (a_1, a_2, a_3, \dots, a_n) \\ n = q + 1 \\ N = l(l-1)/2 \end{cases}. \quad (12)$$

以此非线性因子拟合回波模型:

$$\hat{Z}_i(\omega, C) = \omega_{0i} + \omega_{1i} A_1 + \dots + \omega_{Ni} A_N^2, \quad (13)$$

式中: $\hat{Z}_i(\omega, C)$ 是关于 C 的二次非线性函数、关于 ω 的一次非线性函数; $\omega_{0i}, \omega_{1i}, \dots, \omega_{Ni}$ 为各分量权重。对每个特征赋予参数,即以不同权重配置特征。二次项因子可以更准确地拟合出动态手势模型。

3.2 随机森林

随机森林是机器学习算法的一种,2001 年由 Breiman 等提出。随机森林由多个弱学习器和 CART 二叉决策树^[14]组合而成,属于集成算法。

基尼系数是 CART 决策树节点的分裂规则,可以衡量集合的不确定性,服从最小化准则。更新手势数据集 D :

$$D = \{A_1, A_2, \dots, A_N\}. \quad (14)$$

基尼系数定义为

$$\begin{aligned} \text{Gini}(D) &= \sum_{k=1}^n p(a_k) \cdot [1 - p(a_k)] = \\ &= 1 - \sum_{k=1}^n p(a_k)^2, \end{aligned} \quad (15)$$

式中: $p(a_k)$ 为样本 a_k 出现的概率; n 为类别数量; $\text{Gini}(D)$ 表示从 D 中随机抽取两样本的类别不一致的概率。

根据样本 a 是否属于特征 A 对数据集 D 进行二元分割,得到子集 D_1 和 D_2 ,数据集 D 的不纯度增益(基尼系数)重新定义为

$$\text{Gini}(D | \mathbf{A} = a) = \frac{C_{D_1}}{C_D} \text{Gini}(D_1) + \frac{C_{D_2}}{C_D} \text{Gini}(D_2) - \text{Gini}(D), \quad (16)$$

式中: C_D 表示数据集 D 的元素个数; C_{D_1} 表示数据集 D_1 的元素个数; C_{D_2} 表示数据集 D_2 的元素个数。(16)式中需要计算各子集的基尼系数, 并进行加权求和, 其权重系数由子集中样本个数在总数据集样本中的占比定义。由上述定义可知, 子集中样本越多, 其权重越大。

特征 \mathbf{A} 的最优二分点 a^* 定义为

$$a^* = \min_{a \in \mathbf{A}} \text{Gini}(D, a). \quad (17)$$

数据集 D 的最优二分属性 \mathbf{A}^* 定义为

$$\mathbf{A}^* = \min_{\mathbf{A} \in \text{Attribute}} \text{Gini}(D, \mathbf{A}). \quad (18)$$

根据 \mathbf{A}^* 和 a^* 得到最优分割属性和最优分割点, 在该分割点上分裂出两个子节点。

随机森林是由样本生成的决策树组合而成, 其中, 决策树数量和叶子节点样本数量需要通过交叉验证法获得。决策树的建立完全依赖于训练样本,

其决策也是依据信息增益进行, 因此会存在过拟合问题, 需要对决策树进行后剪枝^[15]。将样本输入生成的最优随机森林中, 利用若干决策树对样本进行独立投票, 通过多数投票得到最终结果。同时, 随机森林在对数据进行分类时, 可以给出各个变量(特征)的重要性评分。

4 实验分析

4.1 实验环境

本文的脉冲超宽带雷达实验平台由 LeCroy 任意波形发生器、回波采样模块、超宽带全向天线^[16]、示波器及计算机(win7, 64 位)搭建。计算机控制任意波形发生器产生超宽带脉冲信号, 经混频器、射频信号放大模块和发射天线辐射至空间中, 手部回波信号由接收天线接收, 经过滤波器、等效采样模块等进入示波器, 计算机接收来自示波器的数据流, 回波数据由信号处理算法进行预处理, 经过手势识别算法训练后得到稳定模型, 由此模型完成分类任务。实验流程图如图 3 所示。

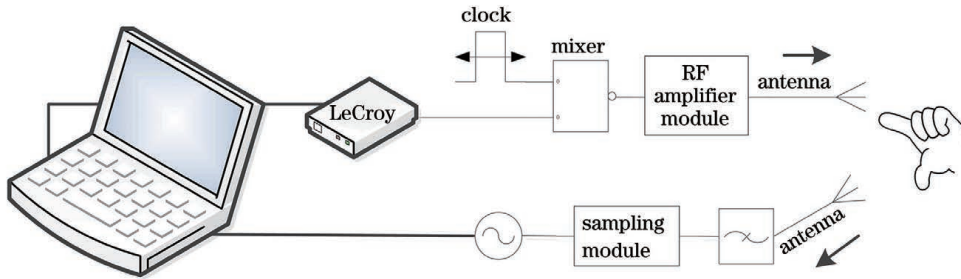


图 3 系统工作流程图

Fig. 3 Flowchart of system working

4.2 构建手势数据集

本文设计并建立微动手势回波数据集, 该数据集包含 6 种微动手势: 响指(snap fingers)、手指整体向左挥动并保持手掌和大拇指不动(wave left)、拇指食指向前捻搓(turn up)、拇指食指向后捻搓(turn down)、手指连续波动并保持手掌和大拇指不动(wake up)、5 根手指由平铺到指尖聚拢(close)。实验中 6 种手势的手部整体不发生平移、运动部位仅限于手指。本文共有 6 名实验人员, 在距离雷达天线正向视角 20 cm 以内完成上述动作。根据 2.1 节算法获得 6 类手势的 RDM, 每类手势包含 600 张特征图谱, 由每名参与者的各 100 张手势图片组成。按照训练、测试样本之比为 8:2 划分数据集, 每类手势有训练样本 480 张, 测试样本 120 张, 数据集共含 3600 张图片。

4.3 训练与分类

数据采集时, RDM 大小被统一到 $512 \times 512 \times 3$ 。使用聚类算法对 RDM 进行降维时, 每张图中的数据量降维至特征数量 \times 特征维数。将 RDM 的聚类结果可视化, 如图 4 所示, 右图表示当 $K=8$ 时, 每簇数据所占比例。




图 4 特征图谱聚类分析

Fig. 4 Feature map clustering analysis

针对同一信号,采用不同的 K 值会产生不同的聚类结果,如图 5 所示。当聚类数 $K=8$ 时,RDM

中的目标区域、余晖区域和背景区域都被清晰分割,将 $K=8$ 的聚类结果可视化,如图 6 所示。

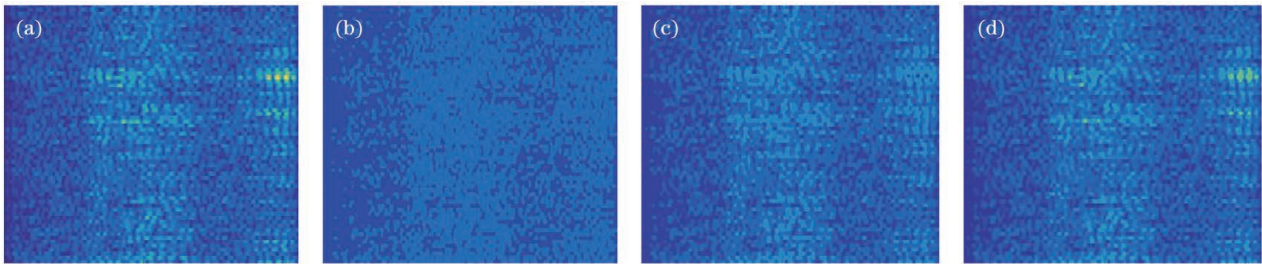


图 5 不同 K 值的聚类结果。(a)原图;(b) $K=2$;(c) $K=4$;(d) $K=8$

Fig. 5 Clustering results for different K values. (a) Original image; (b) $K=2$; (c) $K=4$; (d) $K=8$




图 6 聚类结果可视化

Fig. 6 Visualization of clustering results

将所得聚类结果再次进行下采样后构建多项式特征。微动手势运动速度缓慢,加速度足以描述其运动过程,故将多项式特征的阶数设为 2。将多项式特征进行预处理后,将其分别输入到决策回归树、决策分类树以及随机森林中,其中随机森林中的决策树数量和叶子节点的最少样本数量由交叉验证法产生,随机森林的部分结构和其中一颗决策树可视化如图 7 所示,部分特征的贡献率如图 8 所示。




图 7 随机森林可视化

Fig. 7 Random forest visualization

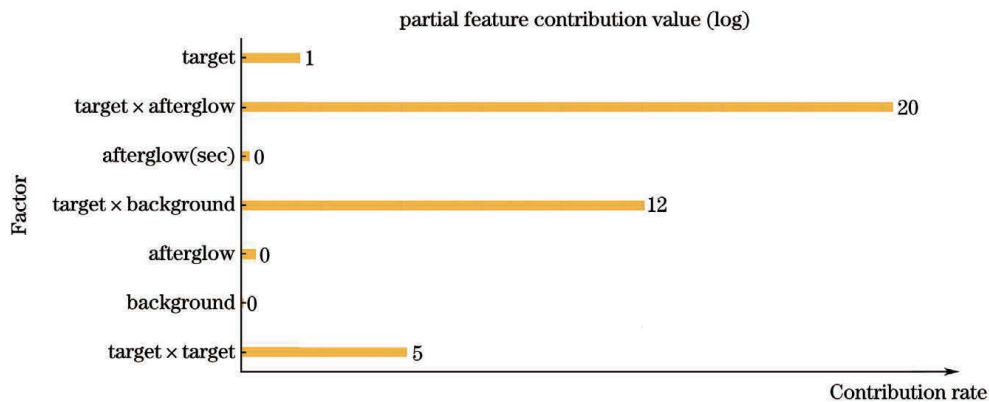


图 8 部分特征的贡献率

Fig. 8 Contribution rate of some features

4.4 方法对比

为了验证不同回波脉冲积累个数对手势识别性能的影响,分别以 24、48、96 和 128 为数据矩阵中的脉冲存储个数,在相同的随机森林分类器参数设置下进行训练与验证,训练样本和验证样本比为 8:2,

分类准确率对比结果如表 1 所示。

表 1 中结果显示,脉冲数达到 256 时准确率最高,相比 128 个脉冲,准确率提升了 1.3 个百分点,但同时计算成本增加。当积累脉冲数较少时,分类准确率较低,因为手势细节描述不够完整。

表 1 不同脉冲积累个数下的识别准确率对比

Table 1 Comparison of recognition accuracy for different number of accumulated echo pulses

| Number of accumulated echo pulses | 48 | 96 | 128 | 256 |
|--|-------|-------|-------|-------|
| Average accuracy of classification / % | 67.23 | 81.46 | 98.67 | 99.97 |

为了验证输入数据对手势表征能力的影响,分别将 RDM 的灰度图、单通道图和原 RGB 图作为手势特征提取的输入数据,进行随机森林分类器的训练与验证,其中脉冲积累个数均设置为 128。

对 6 种微动手势的不同图谱表征效果进行验证,得到的分类准确率如表 2 所示。由表 2 结果可以看出 RGB 图像具有明显优势,这是因为 RGB 图像保留了原有的色彩信息。本文基于像素的色彩分布进行聚类分析,削弱了数据的次要分量,一定程度上提高了信号的信噪比(SNR),从而验证了本文所采用的特征提取方法的有效性。

为了对比不同表征方式下信号的信噪比,取各手势集中 50 张特征图谱为样本,计算样本的背景聚类中心及目标聚类中心之间的加权欧氏距离均值以

表 2 不同手势特征图的准确率对比

Table 2 Comparison of accuracy for different feature maps

| Type of feature map | Average accuracy of classification / % |
|---------------------|--|
| RGB map | 98.67 |
| R channel map | 77.98 |
| G channel map | 81.25 |
| B channel map | 78.25 |
| Gray-scale map | 83.54 |

衡量其相似度,将归一化加权欧氏距离均值作为 SNR 的参照指数,结果如图 9 所示。可以看出 RGB 特征图谱的信噪比相比其他单通道的图谱提升了约 1.5~3.5 倍。

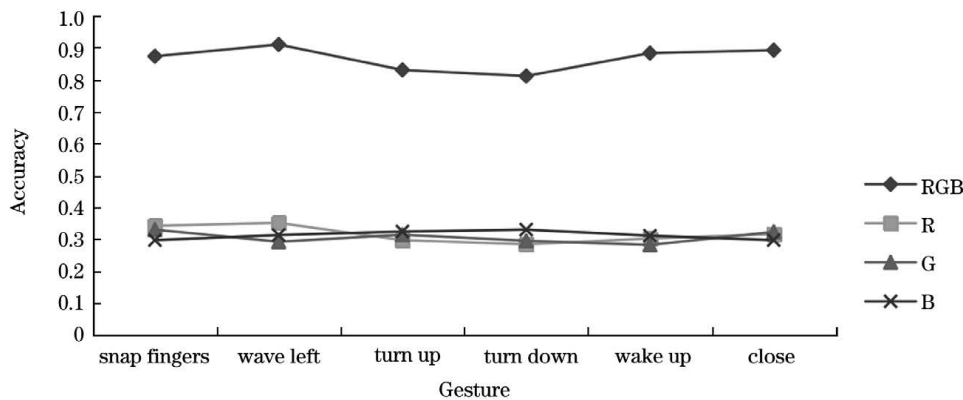


图 9 不同通道数图谱的信噪比

Fig. 9 SNR of maps with different channel numbers

为了探究随机森林的参数对分类准确率的影响,分别设置不同的决策树数量和决策树的最大特征数进行实验。输入的训练样本和测试样本为三通道 RDM,决策树数量分别设置为 50、100 和 200,最大特征数分别设置为 6、12 和 20。6 类手势的平均分类准确率如表 3 所示。

从表 3 可以看出,决策树数量为 50 时,分类能力不够导致准确率不高,当决策树数量为 100 时,准确率得到了明显提高,当决策树数量为 200 时,准确率趋于一定值,泛化误差趋于收敛。

根据以上实验结果,将识别算法参数设置为如表 4 所示的参数值,并在此参数设置下,将本文所提算法与深度学习算法进行对比,如表 5 所示。

表 3 随机森林不同参数设置下的分类结果对比

Table 3 Results of classification for different parameter settings of random forest

| Type of input | CART number | Maximum number of features | Average accuracy of classification / % |
|---------------|-------------|----------------------------|--|
| RDM | 50 | 6 | 79.26 |
| | | 12 | 85.32 |
| | | 20 | 86.17 |
| | 100 | 6 | 87.34 |
| | | 12 | 98.67 |
| | | 20 | 99.12 |
| 200 | 6 | 86.54 | |
| | 12 | 97.12 | |
| | 20 | 98.31 | |

表 4 手势识别算法参数设置

Table 4 Setting of parameters in gesture recognition algorithm

| Parameter | Setting |
|-----------------------------------|---------------------------|
| Number of transmitting antennas | 1 |
| Number of receiving antennas | 1 |
| Number of integrated radar pulses | 128 |
| RDM frame duration /ms | 14 |
| Number of sampling points | 8000 |
| Type of input | RDM |
| Size of input | $512 \times 512 \times 3$ |
| CART number | 100 |
| Maximum number of features | 12 |
| Number of gesture classes | 6 |

表 5 本文算法与其他算法的对比

Table 5 Comparison of proposed algorithm with other algorithms

| Algorithm | Training time /h | Recognition speed / (frame \cdot s ⁻¹) | Accuracy /% |
|------------------------------------|------------------|--|-------------|
| ShuffleNet V2 | 4.46 | 41 | 90.64 |
| Mobilenet V2 | 4.52 | 42 | 91.53 |
| VGG 16 | 4.21 | 46 | 86.63 |
| Algorithm proposed in this article | 2.61 | 41 | 98.93 |

5 结 论

提出了一种基于随机森林的脉冲超宽带雷达手势识别方法,利用聚类算法分析特征图谱并构建多项式特征,针对 RDM 不具有清晰具象特征的特点,选择随机森林作为手势识别任务的分类器,利用三通道和单通道图像等 5 种不同类型的手势数据集,设定不同的系统参数进行训练并测试,得到了系统的最佳参数设置,并且获得了较高的分类准确率。所提算法具有数据量少、分类速度快的优点,训练过程中手势特征保持良好的可解释性。分类结果显示,三通道 RDM 能够最大程度地反映出微动手势的特征,当决策树数量为 100 时,微动手势分类任务的准确率与计算时间达到平衡点,取得最优分类表现。实验结果显示,本文算法在消除冗余数据且保持低计算复杂度的情况下对 6 名参与者的微动手势的平均分类准确率达到 98.67%。

参 考 文 献

[1] Tian H Y. The application of gesture recognition

system based on radar technology in human-computer interaction[J]. Information Technology and Informatization, 2020(4): 105-107.

田寒宇. 基于雷达技术的手势识别系统在人机交互中的应用[J]. 信息技术与信息化, 2020(4): 105-107.

[2] Kim S Y, Han H G, Kim J W, et al. A hand gesture recognition sensor using reflected impulses[J]. IEEE Sensors Journal, 2017, 17(10): 2975-2976.

[3] Park J, Jang J, Lee G, et al. A time domain artificial intelligence radar system using 33-GHz direct sampling for hand gesture recognition [J]. IEEE Journal of Solid-State Circuits, 2020, 55(4): 879-888.

[4] Jin B, Peng Y, Kuang X F, et al. Dynamic gesture recognition method based on millimeter-wave radar by one-dimensional series neural network[J]. Journal of Electronics & Information Technology, 2021, 43(9): 2743-2750.

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.

[5] Xia Z Y, Zhou C L, Jie J Y, et al. Micro-motion gesture recognition based on multi-channel frequency

- modulated continuous wave millimeter wave radar [J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 164-172.
- 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.
- [6] Yao W M, Wang X H, Wu N. Sewing gesture image detection method based on improved SSD model[J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181017.
- 姚炜铭, 王晓华, 吴楠. 基于改进 SSD 模型的缝纫手势图像检测方法[J]. *激光与光电子学进展*, 2020, 57(18): 181017.
- [7] Zhang Z, Xu Y. Adaptive single-handed gesture recognition based on dual classifiers [J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0210005.
- 张政, 徐杨. 基于双分类器的自适应单双手手势识别[J]. *激光与光电子学进展*, 2021, 58(2): 0210005.
- [8] Zhou T, Lü X Q, Ren G Y, et al. Facial expression classification based on ensemble convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141501.
- 周涛, 吕晓琪, 任国印, 等. 基于集成卷积神经网络的面部表情分类[J]. *激光与光电子学进展*, 2020, 57(14): 141501.
- [9] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [10] Li Y, Wang X, Shi B D, et al. Hand gesture recognition using IR-UWB radar with ShuffleNet V2 [C]//*Proceedings of the 5th International Conference on Control Engineering and Artificial Intelligence*, January 14, 2021, Sanya, China. New York: ACM, 2021: 126-131.
- [11] Krishna K, Narasimha Murty M. Genetic K-means algorithm[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 1999, 29(3): 433-439.
- [12] Donahue J, Hendricks L A, Rohrbach M, et al. Long-term recurrent convolutional networks for visual recognition and description[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 677-691.
- [13] Li Y S, Wang C, Rong J G, et al. A review of quantitative characterization methods of complex electromagnetic environment[J]. *Aerospace Electronic Warfare*, 2020, 36(6): 23-27.
- 李岩松, 王超, 戎建刚, 等. 复杂电磁环境量化表征方法研究综述[J]. *航天电子对抗*, 2020, 36(6): 23-27.
- [14] Zhang S L. An introduction to the methodology of cart-classification and regression trees[J]. *Volcanology & Mineral Resources*, 1997, 18(1): 67-75.
- 张松林. CART-分类与回归树方法介绍[J]. *火山地质与矿产*, 1997, 18(1): 67-75.
- [15] Kim H, Koehler G J. An investigation on the conditions of pruning an induced decision tree [J]. *European Journal of Operational Research*, 1994, 77(1): 82-95.
- [16] Quan X L. Broadband omnidirectional antennas[D]. Guangzhou: South China University of Technology, 2013.
- 全旭林. 宽带全向天线研究[D]. 广州: 华南理工大学, 2013.