

# 基于 t-SNE 降维和 DBSCAN 算法的多参数雷达信号分选方法

李开宇, 宋长波, 胡继军, 张国玉  
(北京遥测技术研究所 北京 100076)

**摘要:** 随着雷达信号的复杂性增加, 传统的信号处理方法逐渐暴露出诸多不足之处。本文提出了一种基于 t-分布随机邻居嵌入 (t-SNE) 降维技术与基于密度的聚类算法 (DBSCAN) 的雷达信号分选算法, 旨在解决多参数雷达信号分选中的挑战。t-SNE 通过降低数据的维度, 能够有效提取出数据的主要特征并减少噪声和冗余信息, 从而为后续的 DBSCAN 聚类提供了更清晰的数据分界。实验生成了五种不同类型的雷达信号数据, 并使用 t-SNE 和 DBSCAN 进行降维和聚类, 实验结果显示: t-SNE 降维结合 DBSCAN 聚类算法在纯度和轮廓系数等指标上均表现出色, 验证了该方法在复杂雷达信号分选中的有效性。

**关键词:** t-SNE 降维; PDW 脉冲描述字; 雷达信号分选; 聚类分析

中图分类号: TN953

文献标志码: A

文章编号: 2095-1000(2025)03-0139-07

DOI: 10.12347/j.ycyk.20250214004

CSTR: 32406.14.ycyk.20250214004

引用格式: 李开宇, 宋长波, 胡继军, 等. 基于 t-SNE 降维和 DBSCAN 算法的多参数雷达信号分选方法[J]. 遥测遥控, 2025, 46(3): 139-145.

## Multi-Parameter Radar Signal Sorting Based on t-SNE Dimensionality Reduction and DBSCAN Algorithm

LI Kaiyu, SONG Changbo, HU Jijun, ZHANG Guoyu  
(Beijing Research Institute of Telemetry, Beijing 100076, China)

**Abstract:** This study explores the combination of t-Distributed Stochastic Neighbor Embedding (t-SNE) dimensionality reduction technique and the Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm to address the challenges in multi-parameter radar signal sorting. As the complexity of radar signals has been increasing, traditional signal processing methods have revealed limitations. t-SNE effectively extracts essential features from the data by reducing dimensionality, eliminating noise and redundant information, and providing a clearer boundary for subsequent DBSCAN clustering. In the experiment, we generated five different types of radar signal data and conducted analyses using t-SNE and DBSCAN. The results show that the t-SNE dimensionality reduction combined with the DBSCAN clustering algorithm performs well in terms of purity and silhouette score, confirming the effectiveness of this method in complex radar signal sorting.

**Keywords:** t-SNE dimensionality reduction; DBSCAN algorithm; radar signal sorting; clustering analysis

**Citation:** LI Kaiyu, SONG Changbo, HU Jijun, et al. Multi-Parameter Radar Signal Sorting Based on t-SNE Dimensionality Reduction and DBSCAN Algorithm[J]. Journal of Telemetry, Tracking and Command, 2025, 46(3): 139-145.

## 0 引言

雷达信号分选是现代电子战与信号处理领域中的关键技术之一。随着雷达技术的不断发展, 雷达信号变得越来越复杂, 传统的信号处理方法在应对高密度、多模式和多功能雷达信号时显得

力不从心<sup>[1]</sup>。因此, 研究和开发能够有效识别和分类雷达信号的先进技术变得尤为重要。

雷达信号分选主要涉及从大量接收到的雷达脉冲描述词 (Pulse Descriptor Words, PDW) 中提取出有意义的特征, 并将其分类到不同的雷达信号源中<sup>[2]</sup>。PDW 通常包含脉冲到达时间 (Time of

Arrival, TOA)、脉冲宽度 (Pulse Width, PW)、脉冲重复间隔 (Pulse Repetition Interval, PRI) 和载波频率 (Carrier Frequency, CF) 等信息<sup>[1]</sup>。传统的雷达信号分选方法主要依赖于脉冲描述词的统计特性和阈值判定, 但随着雷达信号的复杂度增加, 这些方法的效果逐渐下降<sup>[3]</sup>。

近年来, 深度学习和机器学习技术在图像处理和语音识别等领域取得了显著成果, 这为雷达信号分选提供了新的思路。然而, 雷达信号数据通常是高维和非线性的, 直接应用传统的机器学习方法可能无法充分挖掘其中的复杂关系。因此, 这促使研究者探索对分选算法更为有效的改进方案<sup>[4]</sup>。

文献[5]提出了一种基于 DBSCAN 算法和特征聚类的雷达信号分选方法。DBSCAN 是一种基于密度的聚类算法, 能够发现任意形状的簇并有效处理噪声。然而, 该方法直接在高维数据上进行 DBSCAN 聚类, 导致了计算复杂度的增加。此外, 未经过降维处理的高维数据中可能包含大量冗余信息, 这进一步影响了聚类的效果。

文献[6]开发了一种基于复杂图卷积网络和自适应谱聚类的方法来对雷达信号进行分选。这种方法通过处理非线性和高维数据, 解决了部分传统聚类算法的局限性。然而, 该方法的计算复杂度较高, 尤其是在处理大规模数据集时, 效率较低。此外, 该方法依赖于图的构建和调整, 如果图的构建存在不准确或偏差 (例如错误的边连接或不完整的图结构), 那么 GCN (图卷积网络) 的输入就会受到影响, 进而导致分类结果的准确率下降。

类似的, 文献[7]研究了基于卷积神经网络的雷达信号分选方法。尽管这种方法在处理非线性和复杂信号方面表现出色, 但由于深度学习模型的黑箱特性, 其可解释性较差, 决策过程难以理解和解释。这种可解释性的缺乏可能会导致在实际应用中对模型决策的信任度下降。

为了解决过去聚类算法可解释性差的问题以及提升聚类算法性能, 本文旨在利用 t-Distributed Stochastic Neighbor Embedding (t-SNE, t-分布随机邻居嵌入) 技术对高维雷达信号数据进行降维, 并结合基于密度的聚类算法实现高效的雷达信号分选。t-SNE 是一种非线性降维方法, 能够在低维空间中有效保留高维数据的局部结构<sup>[8]</sup>。通过 t-SNE

降维, 雷达信号的内在结构得以揭示, 不同类别信号的分布变得更加清晰, 从而为后续的聚类分析提供有力支持。

## 1 t-SNE 降维和 DBSCAN 聚类算法

本文提出了一种结合 t-SNE 降维和 DBSCAN 聚类算法的多参数雷达信号分选方法 (以下称为 t-SNE-DBSCAN 算法)。这种方法旨在解决高维雷达信号数据处理中常见的计算复杂度高和可解释性差的问题。

首先, t-SNE 算法被用来将高维雷达信号特征数据映射到低维空间。t-SNE 通过保留数据的局部相似性结构, 能够在降维过程中去除数据中的噪声和冗余信息, 使得不同类别信号之间的差异在低维空间中更加明显<sup>[9]</sup>。

其次, 在降维后的低维数据上, 采用 DBSCAN 算法进行聚类。由于 t-SNE 降维有效减少了数据的复杂性, DBSCAN 在低维数据上能够更清晰地识别不同的信号簇, 进而提高分类的准确性。

总体流程如图 1 所示。




图1 t-SNE-DBSCAN 算法总体流程

Fig. 1 Process of the t-SNE-DBSCAN algorithm

### 1.1 t-SNE 算法

#### 1.1.1 高维空间中的相似性计算

t-SNE 首先在高维空间中计算数据点之间的相似性。对于每一对高维数据点  $x_i$  和  $x_j$ , t-SNE 通过高斯分布计算它们的条件概率  $p_{ji}$ , 表示数据点  $x_j$  被选择为  $x_i$  的邻居的概率<sup>[10]</sup>。

条件概率定义为:

$$p_{ji} = \frac{\exp\left(-\|x_i - x_j\|^2 / 2\sigma_i^2\right)}{\sum_{k \neq i} \exp\left(-\|x_i - x_k\|^2 / 2\sigma_i^2\right)} \quad (1)$$

其中,  $\sigma_i$  是根据数据点  $x_i$  的局部密度调整的参数, 以保证每个数据点在高维空间中有类似数量的邻居。

#### 1.1.2 低维空间中的相似性计算

在低维空间中, t-SNE 使用 T 分布 (而不是高斯分布) 来计算数据点  $y_i$  和  $y_j$  之间的相似性。低维空间

中的相似性通过以下公式计算

$$q_{ij} = \frac{\left(1 + \|y_i - y_j\|^2\right)^{-1}}{\sum_{k \neq i} \left(1 + \|y_k - y_i\|^2\right)^{-1}} \quad (2)$$

使用T分布而非高斯分布的原因是t分布在低维空间中有更长的尾部，能够更好地处理数据点间的距离差异<sup>[11]</sup>。

### 1.1.3 损失函数(KL散度)

t-SNE通过最小化高维空间和低维空间中相似性分布的差异来找到最佳的低维嵌入。损失函数使用Kullback-Leibler散度(KL散度)来度量两种分布之间的差异<sup>[12]</sup>，见公式(3)。

$$KL(P||Q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (3)$$

式中， $p_{ij}$ 是对称化的高维空间中的联合概率，定义为：

$$p_{ij} = \frac{p_{ji} + p_{ij}}{2N} \quad (4)$$

其中， $N$ 是数据点的总数。

## 1.2 DBSCAN算法

DBSCAN是一种基于密度的聚类算法，因其特别适用于发现任意形状的簇并能有效处理噪声点的特性，将其应用于降维后的聚类<sup>[13]</sup>。以下是DBSCAN算法的基本原理和步骤：

### 1.2.1 聚类原理

核心点、边界点和噪声点：

DBSCAN根据数据点周围的密度来定义核心点、边界点和噪声点。

核心点：在半径为 $\epsilon$ 的邻域内包含至少MinPts(邻域内的最少点数)个数据点。

边界点：在半径为 $\epsilon$ 的邻域内包含少于MinPts个数据点，但位于某个核心点的邻域内。

噪声点：既不是核心点也不是边界点的数据点。

簇的形成：

从任意一个核心点开始，将其邻域内的所有点(包括核心点和边界点)归为同一个簇。继续扩展该簇，将新的核心点的邻域内的所有点也归入该簇，直到没有新的核心点可以添加为止。重复上述过程，直到所有点都被标记为某个簇或噪声点<sup>[14]</sup>。

具体步骤如下：

① 参数设置：选择合适的 $s$ (邻域半径)和

MinPts。

② 邻域查询：对每个数据点，计算其 $\epsilon$ 邻域内的点的数量。

③ 簇的扩展：从一个未被访问的核心点开始，扩展形成一个新的簇。

④ 处理边界点和噪声点：将所有边界点和噪声点进行标记。

### 1.2.2 算法步骤

① 计算高维空间中的相似性矩阵：计算每对数据点 $x_i$ 和 $x_j$ 之间的相似性，得到高维空间的相似性矩阵 $P$ 。

② 初始化低维嵌入：随机初始化低维空间中的数据点位置 $Y$ 。

③ 迭代优化：在每次迭代中，计算低维空间中的相似性矩阵 $Q$ 。

计算梯度并更新低维嵌入 $Y$ 以最小化KL散度：

$$\frac{\partial C}{\partial y_i} = 4 \sum_j (p_{ij} - q_{ij})(y_i - y_j)(1 + y_i - y_j^2)^{-1} \quad (5)$$

使用梯度下降或其他优化算法更新 $Y$ 。

迭代收敛后，输出低维空间中的嵌入结果 $Y$ ，可以用于数据可视化和分析。

## 2 实验设置

### 2.1 实验流程

在实验中，使用t-SNE进行降维，并应用DBSCAN聚类算法对雷达信号数据进行聚类。然后将实验结果与同样属于降维聚类算法的谱聚类<sup>[15]</sup>结果进行对比。

具体流程如下：

① 数据集生成，数据集生成指标见2.2节。

② 读取数据并对特征(TOA、PW、PRI、PA)进行标准化处理，然后使用t-SNE算法将数据降维到二维。

③ 将降维后的数据与原始数据中的类型信息一起保存以进行算法评估。

④ 计算每个点的第 $k$ 个最近邻距离并绘制 $k$ 距离图，以确定DBSCAN算法的参数 $\epsilon$ ，本次实验中采用 $k$ 距离的中位数作为 $\epsilon$ 的估计值以简化计算<sup>[16]</sup>。

⑤ 使用DBSCAN对t-SNE降维后的数据进行聚类。

⑥ 分别计算t-SNE-DBSCAN(2D)、DBSCAN(4D)以及谱聚类算法在数据集上的评估指标以进

行对比分析, 评估指标见 2.3 节。

## 2.2 数据集生成

生成五种不同类型的雷达信号数据, 以到达

时间 TOA、载频 RF、脉幅 PA、脉宽 PW 的形式存储, 按照到达时间排序, 每组时间长度 10 ms, 共 200 组, 具体设置见表 1。

表 1 雷达信号参数设置

Table 1 Radar signal parameter setting

雷达类型	重复周期/ $\mu\text{s}$	载频/MHz	脉宽/ $\mu\text{s}$	跳频间隔/MHz	跳频数	脉幅
常规	[50,1 000]	[1 000,2 000]	[1, 200]		—	[-75, 20]
重频抖动(抖动幅度 10% 或 30%)	[50,1 000]	[1 000,2 000]	[1, 200]			[-75, 20]
重频参差(3 或 6 参差)	子周期[100,200]	[1 000,2 000]	[1, 200]			[-75, 20]
捷变频	[50,1 000]	起始频率[1 000,1 500]	[1, 200]	[15, 25]	[20,32]	[-75, 20]
脉组捷变频	[50,1 000]	起始频率[1 000,1 500]	[1, 200]	[20, 50]	[5,100]	[-75, 20]

雷达类型包括常规雷达、重频抖动雷达、重频参差雷达、频率跳变雷达和脉组捷变频雷达。

每种雷达的参数误差在 1%~5% 之间。随机丢失 5%~15% 的脉冲。

## 2.3 数据降维与特征处理

数据降维的目标是将高维数据(具有多个特征维度)映射到二维或三维空间中, 以便于可视化和后续的分析。为此, 需要对雷达信号的四个主要参数进行标准化, 然后应用 t-SNE 对其进行降维。由于原始数据中的不同特征 (TOA、RF、PW 和 PA) 在数量级上差异较大, 首先对数据进行标准化处理, 确保每个特征在相同的尺度上进行处理。标准化后的数据具有零均值和单位方差, 避免了某些量纲较大的特征在降维过程中的主导作用。

t-SNE 算法通过计算高维数据点之间的相似性, 并通过最小化低维空间与高维空间中数据分布之间的差异, 将数据映射到二维或三维空间。具体过程如下:

① 计算高维空间中的相似性: t-SNE 首先在高维空间中计算数据点之间的相似性, 通常通过高斯分布来描述。高相似的数据点具有较高的相似性概率。

② 映射到低维空间: 然后, t-SNE 将数据点映射到低维空间(例如二维或三维), 并使用 t 分布来重新计算相似性。使用 t 分布的原因是其具有较长的尾部, 能够更好地处理低维空间中较远数据点之间的关系。

③ 最小化 KL 散度: t-SNE 通过最小化高维和低维空间中相似性分布的 KL 散度 (Kullback-Leibler Divergence) 来优化数据的低维表示, 从而得到最优的低维嵌入。

经过 t-SNE 降维后, 原始数据从四个维度 (TOA、RF、PW、PA) 映射到二维或三维空间中。每个数据点在低维空间中的坐标 (例如, Component 1 和 Component 2) 对应了原始数据的某种组合特征。

在降维后的数据中, 信号的类别和结构通常会在低维空间中显示出一定的分离, 尤其是对于不同类型的雷达信号, 它们往往在降维后呈现出明显的分隔区域。将降维后的数据进行可视化, 以便观察信号类别之间的分布。使用 Matplotlib 库, 对一组实验数据部分截取后绘制了三维图和二维图, 以展示信号在降维后空间中的分布情况。将原始数据 (包括 TOA、RF 和 PW) 用于三维可视化。图 2 展示了信号在三维空间中的分布, 并帮助观察各类信号之间的差异。其次, 利用 t-SNE 对数据进行降维, 并生成二维可视化图。通过这种方式, 能够直观地看到各类别信号之间的边界和分布情况。

在 t-SNE 降维后的二维空间中, Component 1 和 Component 2 分别表示信号在低维空间中的两个主要成分, 无量纲, 如图 3 所示。每个数据点在这两个维度上的位置反映了其与其他数据点的相似性。通过降维后的结果, 可以看到不同类别的信号通常会被映射到低维空间中的不同区域。这种分离性表明, 不同信号类型在原始高维空间中的特征存在明显差异。

尽管降维可能会导致一些信息的损失, 但 t-SNE 在降维过程中专注于保留信号的局部结构特征, 因此不会显著影响信号的分类性能。实际上, 降维后的数据为后续的分析提供了更加简洁和易于处理的表示, 减少了计算复杂度。

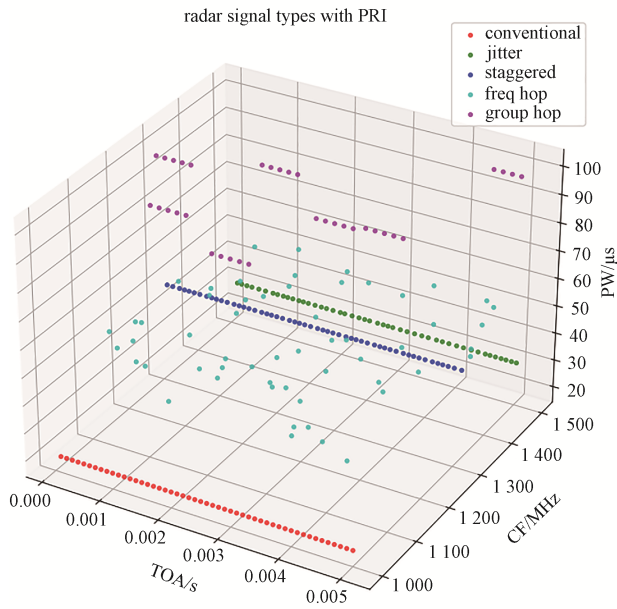


图2 原始数据三维可视化(TOA、RF和PW)

Fig. 2 3D visualization of original data (TOA, CF, and PW)

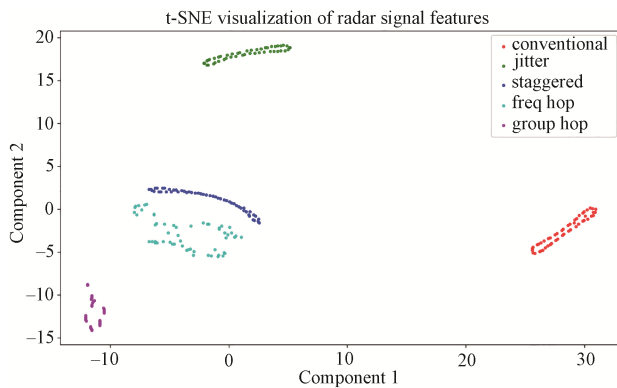


图3 原始数据t-SNE降维可视化

Fig. 3 t-SNE dimensionality reduction visualization of original data

通过降维,不仅能够提高可视化效果,还能在后续的聚类和分类任务中更加高效地处理数据,同时保持足够的信号特征用于有效识别和分类。

## 2.4 算法性能评估

在未降维的数据集上运行DBSCAN算法与谱聚类算法,与t-SNE-DBSCAN算法结果进行对比评估。计算聚类结果的纯度 $P$ 以评估类内结果的准确率<sup>[17]</sup>。计算聚类结果的轮廓系数<sup>[18]</sup>(Silhouette Score)以评估每个数据点与其所属簇中的其他点的紧密度,以及与最近邻簇的分隔度。

纯度(Purity):

找出每个簇 $i$ 中出现频率最高的真实类别,记

为 $max_i$ ,即在簇 $i$ 中该类别的样本数,对所有簇 $i$ ,将每个簇中最大频率的样本数相加<sup>[19]</sup>,得:

$$P = \frac{1}{n} \sum_{i=1}^k max_i \quad (6)$$

其中, $n$ 是数据集中样本的总数。纯度的意义非常直观,它表示了在每个簇中占据主导地位类别所占的比例。考虑到雷达信号分选的目的,可以认为纯度与准确性正相关。

轮廓系数:

轮廓系数定义为

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (7)$$

其中, $a(i)$ 为样本 $i$ 与同一簇中所有其他样本的平均距离, $b(i)$ 为样本 $i$ 与最近邻簇中所有样本的平均距离。

这个公式表明:如果 $s(i)$ 接近1,说明样本 $i$ 被很好地聚类,它与其所在簇的样本距离较近,而与最近邻簇的样本距离较远;如果 $s(i)$ 接近0,说明样本 $i$ 位于两个簇的边界上;如果 $s(i)$ 为负值,说明样本 $i$ 可能被错误地分配到了一个错误的簇。

轮廓系数可以用来评价簇内紧密度和簇间分隔度<sup>[20]</sup>,仅有纯度作为评估指标可能导致对簇的数量敏感以及忽略簇的内部结构等问题,因此引入轮廓系数进行综合评价。

## 3 实验结果与分析

### 3.1 数据集生成与降维

成功生成五种不同类型的雷达信号数据,并通过t-SNE算法将高维数据映射到二维空间。保存了降维后的数据,便于后续聚类分析和可视化,如图4所示。

从降维可视化图可以看出,t-SNE将高维雷达信号数据映射到了二维空间中,数据点被有效地分布在不同的区域,形成了明显的簇状结构。这表明t-SNE在降维过程中很好地保留了数据的局部结构,使得原本在高维空间中复杂的数据关系在二维空间中得以清晰展现。从图中可以观察到,降维后的数据点明显分为几个不同的簇,每个簇之间有明显的间隔,表明这些簇之间的差异较大,彼此独立。这种分隔度为后续的聚类算法提供了良好的基础。

### 3.2 DBSCAN聚类结果

经降维生成的二维特征经过DBSCAN聚类后

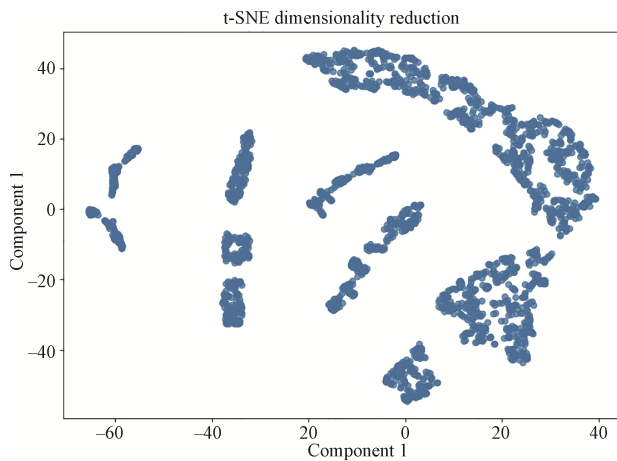


图 4 数据集在 t-SNE 降维算法下的可视化结果

Fig. 4 Clustering visualisation results of the dataset under the t-SNE dimensionality reduction algorithm

的聚类结果如图 5 所示。

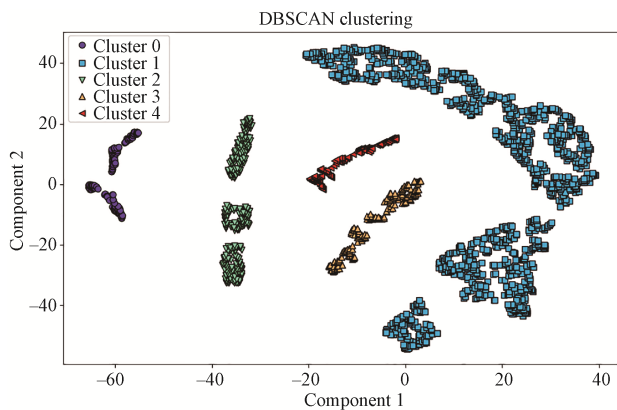


图 5 DBSCAN 算法对降维后数据的聚类结果

Fig. 5 Clustering results of the DBSCAN algorithm for data after dimensionality reduction

在应用 DBSCAN 算法后, 降维后的数据被分为了多个簇 (不同颜色和形状的标记代表不同的簇)。从图中可以看出, DBSCAN 成功地识别出了多个密度较高的区域, 并将它们划分为不同的簇。

### 3.3 算法性能评估

评估过程中对 200 组数据进行算法验证和评估, 根据先验信息分别计算每组数据在各个算法上的纯度和轮廓系数, 评估结果取平均值, 见表 2。

### 3.4 实验结果分析

降维后的 DBSCAN 聚类 (2D) 在纯度 (Purity) 上表现显著优于基于原始四维特征的 DBSCAN 聚类, 并且也比谱聚类的纯度要高。虽

表 2 聚类算法评估结果

Table 2 Clustering algorithm evaluation results

	纯度 (Purity)	轮廓系数 (Silhouette Score)
谱聚类 (Spectral Clustering)	0.847	0.556
DBSCAN (4D)	0.745	0.205
t-SNE-DBSCAN (2D)	0.978	0.292

然轮廓系数 (Silhouette Score) 方面, 降维后的效果并不如谱聚类, 但仍然比四维特征的 DBSCAN 要好。这进一步支持了降维对聚类效果的提升作用。这表明 t-SNE 降维通过减少数据维度, 能够提取出数据的主要特征, 同时去除不重要的噪声和冗余信息, 从而使得聚类算法可以更清晰地识别不同类别的边界<sup>[21]</sup>。同时 t-SNE 会根据点之间的局部相似性, 将相似的点聚集在一起, 这样当 DBSCAN 在这种经过处理的二维空间中运行时, 能够更容易地找到密度较高的区域并形成簇<sup>[22]</sup>。

## 4 结束语

通过 t-SNE 降维和 DBSCAN 聚类算法的结合, 成功地对雷达信号数据进行了有效的聚类, 并通过可视化和外部指标评估了聚类效果。结果显示, t-SNE 降维能够有效提升基于密度聚类的 DBSCAN 算法的聚类性能, 并且提升后的聚类在纯度等性能指标方面达到了较高标准。这表明, t-SNE 降维不仅能减少数据的噪声和冗余信息, 还能增强数据的局部结构, 使 DBSCAN 更容易识别和分离不同的密度集群。因此, t-SNE 与 DBSCAN 的结合是处理高维数据的一种有效方法, 尤其在需要精确识别和分离复杂模式的应用场景中, 具有广泛的潜力和应用前景。

### 参考文献

- [1] WANG Shiqiang, GAO Caiyun, ZHANG Qin, et al. Research progress on key technologies of radar signal sorting[C]//International Conference on Intelligent Computing, Communication and Devices, Wuhan, 2018: 773-779.
- [2] LI B, SUN S, LIU Y. Research on real radar pulse signal sorting technology based on machine learning[C]//Signal and Information Processing, Networking and Computers: Proceedings of the 7th International Conference on Signal and Information Processing, Networking and Comput-

- ers (ICSINC), Beijing, 2021. Singapore: Springer, 2021: 861-869.
- [3] 黄颖坤, 金炜东, 葛鹏, 等. 基于多尺度信息熵的雷达辐射源信号识别[J]. 电子与信息学报, 2019, 41(5): 1084-1091. HUANG Yingkun, JIN Weidong, GE Peng, et al. Radar emitter signals identification based on multi-scale information entropy[J]. Journal of Electronics & Information Technology, 2019, 41(5): 1084-1091.
- [4] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [5] 王星, 陈相, 周一鹏, 等. 一种基于改进DBSCAN的雷达信号分选算法[J]. 空军工程大学学报(自然科学版), 2021, 22(3): 47-54.
- [6] 王易丽, 杨宇明. 一种基于改进谱聚类的雷达信号分选算法[J]. 电讯技术, 2023, 63(9): 1348-1354. WANG Yili, YANG Yuming. A radar signal sorting algorithm based on improved spectral clustering[J]. Telecommunication Engineering, 2023, 63(9): 1348-1354.
- [7] 张旭威, 黎仁刚, 王一鸣. 基于深度网络的雷达信号分选[J]. 舰船电子对抗, 2021, 44(6): 73-77. ZHANG Xuwei, LI Rengang, WANG Yiming. Radar signal sorting based on deep network[J]. Shipboard Electronic Countermeasure, 2021, 44(6): 73-77.
- [8] 张先芝, 尚尚, 戴圆强, 等. 强海杂波背景下目标检测方法综述[J]. 遥测遥控, 2022, 43(1): 13-20. ZHANG Xianzhi, SHANG Shang, DAI Yuanqiang, et al. Review on target detection in the background of strong sea clutter[J]. Journal of Telemetry, Tracking and Command, 2022, 43(1): 13-20.
- [9] 卢晓艳, 颜培玉, 解志斌, 等. 无线传感器网络中故障节点检测与修复方法综述[J]. 遥测遥控, 2021, 42(4): 104-111. LU Xiaoyan, YAN Peiyu, XIE Zhibin, et al. Overview of fault node detection and repair in wireless sensor networks[J]. Journal of Telemetry, Tracking and Command, 2021, 42(4): 104-111.
- [10] 李霞, 韩来望, 李勋. 一种宽带高增益全向赋形测控天线的设计与实现[J]. 遥测遥控, 2021, 42(4): 76-81. LI Xia, HAN Laiwang, LI Xun. Design and realization of a wideband high gain omnidirectional shaped-beam TT & C antenna[J]. Journal of Telemetry, Tracking and Command, 2021, 42(4): 76-81.
- [11] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.
- [12] VAN DER MAATEN L. Accelerating t-SNE using tree-based algorithms[J]. The Journal of Machine Learning Research, 2014, 15(1): 3221-3245.
- [13] HINTON G E, ROWEIS S. Stochastic neighbor embedding[C]//Advances in Neural Information Processing Systems, MIT Press, 2002.
- [14] SCHUBERT E, SANDER J, ESTER M, et al. DBSCAN revisited, revisited: why and how you should (still) use DBSCAN[J]. ACM Transactions on Database Systems (TODS), 2017, 42(3): 1-21.
- [15] VON LUXBURG U. A tutorial on spectral clustering[J]. Statistics and computing, 2007, 17(4): 395-416.
- [16] ERTÖZ L, STEINBACH M, KUMAR V. Finding clusters of different sizes, shapes, and densities in noisy, high dimensional data[C]//Proceedings of the 2003 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics, 2003: 47-58.
- [17] CHAO G, SUN S, BI J. A survey on multiview clustering[J]. IEEE Transactions on Artificial Intelligence, 2021, 2(2): 146-168.
- [18] ARBELAIZ O, GURRUTXAGA I, MUGUERZA J, et al. An extensive comparative study of cluster validity indices[J]. Pattern recognition, 2013, 46(1): 243-256.
- [19] VENDRAMIN L, CAMPELLO R J G B, HRUSCHKA E R. Relative clustering validity criteria: A comparative overview[J]. Statistical Analysis and Data Mining: The ASA Data Science Journal, 2010, 3(4): 209-235.
- [20] PEZZOTTI N, LELIEVELDT B P F, VAN DER MAATEN L, et al. Approximated and user steerable tSNE for progressive visual analytics[J]. IEEE Transactions on Visualization and Computer Graphics, 2016, 23(7): 1739-1752.
- [21] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396.
- [22] WANG Z F, YUAN P Y, CAO Z Y, et al. Feature reduction of unbalanced data classification based on density clustering[J]. Computing, 2024, 106(1): 29-55.

#### [作者简介]

- 李开宇 1999年生, 硕士研究生。  
宋长波 1979年生, 博士, 研究员。  
胡继军 1981年生, 硕士, 研究员。  
张国玉 1987年生, 硕士, 高级工程师。

(本文编辑: 杨秀丽)