



国防科技大学学报

Journal of National University of Defense Technology

ISSN 1001-2486, CN 43-1067/T

《国防科技大学学报》网络首发论文

题目：特征与语义驱动的调制信号增量识别方法
作者：张泽辉，叶能，远航，叶琳佳，凌宇轩，李雯池，杨凯
收稿日期：2025-05-15
网络首发日期：2026-03-18
引用格式：张泽辉，叶能，远航，叶琳佳，凌宇轩，李雯池，杨凯. 特征与语义驱动的调制信号增量识别方法[J/OL]. 国防科技大学学报.
<https://link.cnki.net/urlid/43.1067.t.20260318.1520.002>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

doi: 10.11887/j.issn.1001-2486.25050020

特征与语义驱动的调制信号增量识别方法

张泽辉¹, 叶能¹, 远航^{2*}, 叶琳佳³, 凌宇轩¹, 李雯池², 杨凯²

(1. 北京理工大学 网络空间安全学院, 北京 100081; 2. 北京理工大学 信息与电子学院, 北京 100081; 3. 北京理工大学 长三角研究院, 浙江 嘉兴 314000)

摘要: 针对动态场景下新型调制信号持续涌现且识别精度不足的问题, 提出了一种特征与语义驱动的调制信号增量识别方法。构建了调制信号的多维特征表达, 在并行时域卷积网络中引入类增量的知识蒸馏学习机制, 解决了动态场景多任务迭代下的特征漂移问题。同时基于多维特征构建了调制语义图谱, 采用最近邻策略实现了新增和原有调制信号的分类。最后设计了一种联合损失函数, 结合距离损失、拉普拉斯特征值优化损失以及知识蒸馏损失, 增强了语义空间中不同调制信号的类内聚合性与类间分离性, 提升了识别精度。实验结果表明, 在多个增量任务中所提方法实现了 84.46% 的平均识别准确率, 较传统增量识别方法提升 10%, 有效提升了动态场景下信号调制类型增量识别能力。

关键词: 电磁空间认知; 调制识别; 增量学习; 多维特征; 语义空间

中图分类号: TN911.3; TP18 **文献标志码:** A

Incremental recognition method for modulated signals driven by features and semantics

ZHANG Zehui¹, YE Neng¹, YUAN Hang^{2*}, YE Linjia³, LING Yuxuan¹, LI Wenchi², YANG Kai²

(1. School of Cyberspace Science and Technology, Beijing Institute of Technology, Beijing 100081, China; 2. School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China; 3. Yangtze Delta Region Academy, Beijing Institute of Technology, Jiaxing 314000, China)

Abstract: To address the issue of insufficient recognition accuracy caused by the continuous emergence of novel modulated signals in dynamic scenarios, an incremental recognition method for modulated signals driven by feature and semantics was proposed. A multi-dimensional feature representation of modulated signals was constructed. A class-incremental knowledge distillation learning mechanism was introduced into a parallel temporal convolutional network to mitigate feature drift under multi-task iteration in dynamic environments. Meanwhile, a modulated semantic map was built based on multi-dimensional features, and a nearest neighbor strategy was adopted to classify both new and existing modulated signals. Furthermore, a joint loss function was designed by integrating distance loss, Laplacian eigenvalue optimization loss, and knowledge distillation loss, which enhances intra-class compactness and inter-class separability of different modulated signals in the semantic space, thereby improving recognition accuracy. Experimental results demonstrate that the proposed method achieves an average recognition accuracy of 84.46% across multiple incremental tasks, outperforming conventional incremental recognition methods by 10%. It effectively enhances the capability of incremental recognition of signal modulation types in dynamic scenarios.

Keywords: electromagnetic space cognition; modulation recognition; incremental learning; multi-dimensional features; semantic space

在电磁空间认知领域, 调制识别技术作为信号检测与盲解调的核心环节^[1], 发挥着极为关键的作用。调制识别是指通过解析信号数据并与先

验模板进行匹配, 从而识别信号的调制方式。当前, 如通信基础设施、物联网产品、信号塔和雷达等各类信号设备迅速增多^[2], 致使电磁空间中

* 收稿日期: 2025-05-15

基金项目: 国家自然科学基金资助项目 (62522103, 62201055)

第一作者: 张泽辉 (1995—), 男, 河北张家口人, 博士研究生, E-mail: zzhui@bit.edu.cn

* 通信作者: 远航 (1994—), 男, 山东青岛人, 副研究员, 博士, 硕士生导师, E-mail: yuanhang@bit.edu.cn

引用格式: 张泽辉, 叶能, 远航, 等. 特征与语义驱动的调制信号增量识别方法[J]. 国防科技大学学报,

Citation: ZHANG Z H, YE N, YUAN H, et al. Incremental recognition method for modulated signals driven by features and semantics[J]. Journal of National University of Defense Technology,

新型调制方式也随之变得丰富^[3]，这就要求现有系统具备在动态环境下识别新增调制方式的能力。传统方法通常在特定场景下使用人工或深度学习构造特征，无法满足当前对新增未知信号的识别需求^[4-5]。因此，如何准确识别新增调制类型，已成为当下信号调制识别领域亟待攻克的难题。

传统深度学习方法依赖全量数据重新训练，计算成本高、灵活性差^[6]，增量学习提供了解决方案^[7-8]。为了实现不同调制方式的增量学习，Yang等提出一种基于星座图特征的调制识别增量学习方法，通过顺序数据流逐步引入新类别^[9]。在此基础上，Xu等提出基于偏置补偿的增量学习方法，通过K-D树构建的彩色星座图增强信号视觉特征，结合示例重放与知识蒸馏机制抑制灾难性遗忘^[10]。为了增强对不同调制类别的学习能力，Ma等提出通过初始阶段和多增量阶段的损失函数，结合蒸馏损失与新调制方式的交叉熵损失持续学习新增调制方式的方法^[11]。上述方法增强了模型对于不同调制方式的学习能力，缓解了任务间的遗忘。除了上述基于数据驱动的增量学习探索外，Li等^[12]提出的知识图谱驱动的调制识别框架（knowledge graph driven automatic modulation classification, KGAMC）。利用一个外部的调制知识图谱来指导模型训练，从而学习到更鲁棒的特征表示。上述方法高度依赖于人工构建的知识库。虽然在一定场景下表现优异，但难以适应知识快速迭代或未知的动态环境。

在实际应用中，动态环境下的调制方式会产生特征漂移，尤其是对于不同任务场景下的时变信道^[13]。为了提升模型鲁棒性，Zhao等基于样本记忆与回放的增量学习框架，通过选择不同信噪比数据增强了模型的泛化能力^[14]。Fan等构建了复值类增量学习框架C-SRCIL，通过复值神经网络提取信号的幅度和相位信息^[15]。Duan等针对信号的时变特性，提出基于小波神经网络集成的增量学习方法^[16]。Hao等^[17-21]提出了多专家增量学习框架，为不同任务训练独立的专家网络，并由一个路由模块进行决策分发，实现对旧知识的物理隔离，避免数据之间的影响。上述方法增强了模型对于动态场景的适应能力，但模型的特征表达能力严重受限于训练数据集^[22]，当训练集样本不均衡时，现有增量学习方法在环境适应性和鲁棒性方面仍显示不足^[23]。

针对传统增量学习在动态场景多任务迭代中因样本不均衡和特征漂移导致的识别精度下降问题，本文提出基于语义空间的调制方式增量识别

方法，利用信号的调制语义信息作为模型识别分类的依据，实现对新增调制信号的持续学习在语义空间中，不同调制方式，幅移键控(amplitude-shift keying, ASK)、高斯最小频移键控(gaussian minimum-shift keying, GMSK)、相移键控(phase-shift keying, PSK)、正交幅度调制(quadrature amplitude modulation, QAM)等被映射为向量，在空间中的距离与方向关系直观地表征了它们之间的特征相似性与差异性。

该空间依赖于底层特征提取的有效性。若基础特征对信道变化、噪声等干扰敏感，则语义表示将发生偏移，影响后续所有增量阶段的识别效果。为此，本框架对网络进行了鲁棒性设计。首先，通过并行时域卷积网络处理信号的多维物理特征，并结合层级知识蒸馏机制，避免不同维度信息的过早混淆，使网络能够学习到每种特征的时序模式。随后，构建调制语义图谱，采用最近邻策略进行分类。最后，设计了联合损失函数，融合距离损失、谱值优化损失以及知识蒸馏损失，有效缓解灾难性遗忘，增强语义空间中调制类型的类内聚合与类间分离，提升对新增调制类型的识别能力。综上，本文模型通过并行网络与流形约束的特征提取机制来抵御信号层面的特征漂移，通过层级蒸馏与动态图谱这种高效的增量学习策略来适应类别层面的新类型出现，从而实现动态场景的自适应。

1 问题描述

1.1 信号模型

在典型调制识别场景下，调制信号发射机产生不同调制方式的信号。信号被天线、射频模块及模数转换后变为基带信号，其表达式如下：

$$R[n] = \sum_{l=1}^L h_l[n] S[n - \tau_l] + N[n] \quad (1)$$

其中， $h_l[n]$ 为信道响应， $S[n]$ 表示调制信号， $N[n]$ 代表噪声， n 为信号采样点， L 代表信道多径数量， τ_l 代表时延。接收信号由实部与虚部数据组成：

$$R[n] = \hat{I}[n] + j\hat{Q}[n] \quad (2)$$

其中， $\hat{I}[n]$ 表示I路信号， $\hat{Q}[n]$ 表示Q路信号。

1.2 多维特征构建

现有的开集识别方法普遍采用 IQ 数据或单维特征作为模型的输入。然而单维特征表示的调制信息局限性较大，难以表征信号全面性。而 IQ 数据中的信道噪声、偏移等冗余信息，可能会对模型产生负面影响^[24]。

为此，本文提取瞬时幅度 $A[n]$ 、瞬时相位 $\phi[n]$ 、瞬时频率 $f[n]$ 构建多维特征。其中， $A[n]$ 计算公式如下所示：

$$A[n] = \sqrt{\hat{I}[n]^2 + \hat{Q}[n]^2} \quad (3)$$

原始瞬时相位 $\phi[n]$ 的计算公式如下：

$$\phi[n] = \arctan\left(\frac{\hat{Q}[n]}{\hat{I}[n]}\right) \quad (4)$$

其中， n 为采样点。由于反切函数的数值范围是 $[-\pi/2, \pi/2]$ ，直接计算得到的瞬时相位序列存在取值局限性。为获得完整周期内的相位信息，需对瞬时相位进行区间拓展，因此瞬时相位序列的计算表达式为：

$$\hat{\phi}[n] = \begin{cases} \phi[n], & \hat{I}[n] > 0, \hat{Q}[n] \geq 0 \\ \frac{\pi}{2}, & \hat{I}[n] = 0, \hat{Q}[n] > 0 \\ \phi[n] + \pi, & \hat{I}[n] < 0, \hat{Q}[n] \geq 0 \\ \phi[n] - \pi, & \hat{I}[n] < 0, \hat{Q}[n] < 0 \\ -\frac{\pi}{2}, & \hat{I}[n] = 0, \hat{Q}[n] < 0 \\ \phi[n], & \hat{I}[n] > 0, \hat{Q}[n] < 0 \end{cases} \quad (5)$$

经过上述公式的计算得出的瞬时相位范围为 $[-\pi, \pi]$ ，但此时会出现相位折叠现象，即在计算瞬时频率时，一个周期内的信号的相位差可能被映射到 $[0, 2\pi]$ 。当 n 大于 1 时，瞬时相位的修正序列 $\bar{C}[n]$ 的计算公式如下：

$$\bar{C}[n] = \begin{cases} \bar{C}[n-1] - 2\pi, & \hat{\phi}[n+1] - \hat{\phi}[n] > \pi \\ \bar{C}[n-1] + 2\pi, & \hat{\phi}[n] - \hat{\phi}[n+1] > \pi \\ \bar{C}[n-1], & \text{其他} \\ \bar{C}[0] = 0 \end{cases} \quad (6)$$

由此可得到无卷绕的瞬时相位 $\phi[n]$ 如下：

$$\phi[n] = \hat{\phi}[n] + \bar{C}[n] \quad (7)$$

瞬时频率 $f[n]$ 通过计算 $\phi[n]$ 得到：

$$f[n] = \frac{f_s}{2\pi} (\phi[n+1] - \phi[n]) \quad (8)$$

其中， f_s 为采样率。信号采样长度为 N 的多维特征的三维数据集 $\mathbf{z} \in \mathbb{R}^{N \times 3}$ 表示为：

$$\mathbf{z} = \left[\left\{ A[n] \right\}_{n=1}^N, \left\{ f[n] \right\}_{n=1}^N, \left\{ \phi[n] \right\}_{n=1}^N \right] \quad (9)$$

1.3 系统建模

在增量学习中，前 $n-1$ 个任务中所包含的调制方式为 $\mathbf{C} = \{C_1, C_2, \dots, C_{n-1}\}$ ，在第 n 个任务中新增的调制方式为 C_n ，数据集中调制信号样本和对应的标签为 $\{\mathbf{z}_n^i, \mathbf{y}_n^i\}_{i=1}^{N_i}$ ， N_i 表示样本总数。增量学习下第 i 个样本的调制识别结果可表示为：

$$r^* = \underset{r \in \{C_1, C_2, \dots, C_{n-1}, C_n\}}{\operatorname{argmax}} P(\hat{y} = r | z_n^i) \quad (10)$$

其中， $P(\cdot)$ 代表后验概率估计函数， \hat{y} 代表模型输出的预测结果。

2 网络模型设计

2.1 模型总体架构

本文提出了一种基于语义空间的增量学习调制识别模型，旨在实现对新型调制方式的持续学习，该模型主要由基于并行时域卷积的语义提取模块和语义图谱构建及分类模块组成，模型总体架构如图 1 所示。

该模型可以表示为：

$$\mathbf{P} = f(d(\mathbf{z}_n^i)) \quad (11)$$

其中， \mathbf{P} 表示模型输出的分类特征； $d(\cdot)$ 表示基于并行时域卷积的深度调制语义提取模块，主要负责从输入特征中提取具有判别性的调制语义信息，模块引入蒸馏损失，利用前一任务的网络参数作为教师模型，为旧任务提供语义指导，当前任务的网络参数作为学生模型，在训练过程中逐步学习并捕捉新调制方式的语义信息； $f(\cdot)$ 表示基于语义空间的语义图谱构建及分类模块，利用已提取的调制语义构建语义图谱进行分类决策，此模块使得模型能够在少量样本的情况下，实现对新调制信号的有效分类，显著提升了系统的持续学习能力与扩展性。在模型学习新任务时，引入语义图谱中距离调制语义类中心较近的 m 个样本，通过联合训练使模型在掌握新知识的同时维持对旧知识的记忆，实现对模型知识迁移和稳定性的有效平衡。

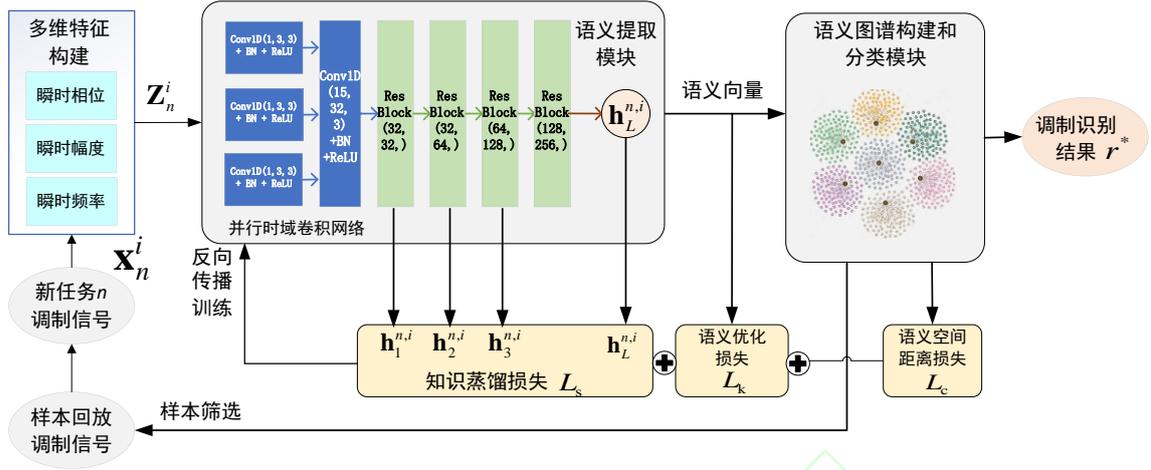


图 1 基于语义提取的调制方式增量识别网络架构

Fig. 1 Incremental recognition network architecture of modulation mode based on semantic extract

2.2 基于并行时域卷积的深度调制语义提取

为了挖掘多维特征中的调制语义，本节设计了一种基于并行时域卷积的语义提取模块，并结合残差连接机制，实现对信号调制语义的有效提取。语义提取模块由并行时域卷积模块和基于残差连接的深度时域卷积模块组成。

2.2.1 并行时域卷积模块

在标准的一维卷积层中，多个输入通道分别与各自的卷积核进行逐通道卷积，之后在通道维度上对结果进行累加，从而得到单通道的输出。这种加权操作虽然简化了信息通路，但也可能引发特征间的信息混淆问题，尤其是在处理包含频率、幅度与相位等多维属性的数据时。单次卷积后的求和操作可能使得不同通道中代表不同尺度与内在关联的特征发生叠加与抵消，从而导致有效信息的损失。

为缓解上述问题，在一维卷积特征提取阶段引入了并行卷积结构。首先对当前任务第 i 个多维特征数据 \mathbf{z}_i 进行各通道并行的一维卷积计算，具体表现如下：

$$\mathbf{v}_{i,j}^p = \text{ReLU}\left(\text{BN}\left(\text{Conv1D}\left(z_{i,j}\right)\right)\right) \quad (12)$$

其中， $j \in \{1, 2, 3\}$ 代表输入的多维特征数据的第 j 个通道， $\text{ReLU}(\cdot)$ 表示激活函数， $\text{BN}(\cdot)$ 表示批量归一化操作， $\text{Conv1D}(\cdot)$ 表示一维卷积计算。

随后将各通道的一维卷积结果 $\mathbf{v}_{i,j}^p$ 拼接得到并行的一维卷积块输出 \mathbf{v}_i^p ，形式如下：

$$\mathbf{v}_i^p = \text{Concat}\left(\mathbf{v}_{i,1}^p, \mathbf{v}_{i,2}^p, \mathbf{v}_{i,3}^p\right) \quad (13)$$

其中， $\text{Concat}(\cdot)$ 表示特征拼接。并行时域卷积增强了特征表达的多样性与判别能力，为后续深层特征提取提供了有力支撑。

2.2.2 基于残差连接的深度时域卷积模块

为了学习多维特征数据中的长距离时域语义，需要提升模型对时域的长程依赖建模能力。由于膨胀卷积操作会造成卷积层中抽样间隔部分数据特征丢失。因此，在卷积核长度有限的情况下，在并行时域卷积后增加基于残差连接的时域卷积模块有效保留输入序列的长距离时域特征。

其中一维残差块（ResBlock）作为深度时域卷积模块的基础单元，主要由两部分组成：第一部分是直连路径（identity mapping, IM），实现输入的多维特征数据与输出的特征向量的直接映射；第二部分则是通过多层非线性变换构成的特征提取模块。一维残差卷积块的公式如下所示：

$$F^0 = \text{ReLU}\left(\text{BN}\left(\text{Conv1D}\left(\mathbf{v}^p\right)\right)\right) \quad (14)$$

$$F_H^b = \text{BN}\left(\text{Conv1D}\left(\text{ReLU}\left(\text{BN}\left(\text{Conv1D}\left(F^{b-1}\right)\right)\right)\right)\right) \quad (15)$$

$$F_{\text{IM}}^b = \text{BN}\left(\text{Conv1D}\left(F^{b-1}\right)\right) \quad (16)$$

$$F^b = \text{ReLU}\left(F_H^b + F_{\text{IM}}^b\right) \quad (17)$$

其中， b 代表了时域卷积网络中第 b 个一维残差块， b 大于等于 1。 F_H^b 表示特征提取模块在层次化卷积计算中的输出结果。每个残差块由一维卷积层与批量归一化层串联构成，用于将残差卷积块的输出 $F_{\text{IM}}^b(x)$ 与层次化卷积计算得到的输出 F_H^b 相加，得到输出结果 F^b 。通过堆叠多个基于

在中间层的行列维度上分别计算 L2 范数，以衡量两者输出差异，从而引导学生模型在特征提取过程中与教师模型保持一致。通过最小化该差异，学生模型可有效学习教师模型的深层语义信息。如图 3 所示，这种蒸馏方式优化了学生模型的特征表示，缓解灾难性遗忘，并提升新任务中调制语义的适应与提取能力。

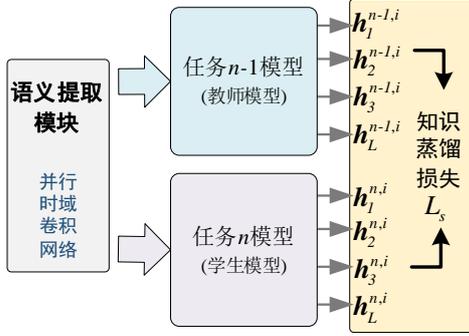


图 3 知识蒸馏流程图

Fig. 3 Knowledge Distillation Flowchart

为了提取每一个时域卷积残差块的输出张量，语义提取模块的输出可以表示为：

$$\left[\mathbf{h}_{1,c,w}^{n,i}, \mathbf{h}_{2,c,w}^{n,i}, \mathbf{h}_{3,c,w}^{n,i}, \mathbf{h}_L^{n,i} \right] = d(\mathbf{z}_n^i) \quad (26)$$

其中， $\mathbf{h}_{l,c,w}^{n,i}$ 表示每一个时域卷积残差块的输出张量， n 代表任务序号， i 代表样本序号， l 代表模型的第 l 个时域卷积残差层， c 代表通道数， w 代表向量的长度。 $\mathbf{h}_L^{n,i}$ 表示语义提取网络最后的输出向量。损失函数 L_{row} 和 L_{column} 被设计在张量的行和列上进行计算，可有效保留各个特征维度在横轴通道上的变化规律以及纵轴时域上的关联，计算公式如下所示：

$$L_{row}(\mathbf{h}_l^{n-1,i}, \mathbf{h}_l^{n,i}) = \left\| \sum_{w=1}^W \mathbf{h}_{l,c,w}^{n-1,i} - \sum_{w=1}^W \mathbf{h}_{l,c,w}^{n,i} \right\|^2 \quad (27)$$

$$L_{column}(\mathbf{h}_l^{n-1,i}, \mathbf{h}_l^{n,i}) = \left\| \sum_{c=1}^C \mathbf{h}_{l,c,w}^{n-1,i} - \sum_{c=1}^C \mathbf{h}_{l,c,w}^{n,i} \right\|^2 \quad (28)$$

两者相加可以得到单个中间层张量各通道的蒸馏损失，表示如下：

$$L_{space} = L_{row} + L_{column} \quad (29)$$

语义提取网络最后通过平均池化操作将多个维度合并为一维，得到多通道的语义向量 $\mathbf{h}_L^{n,i}$ ，计算样本语义向量的蒸馏损失公式如下：

$$L_{output}(\mathbf{h}_L^{n-1,i}, \mathbf{h}_L^{n,i}) = \left\| \mathbf{h}_L^{n-1,i} - \mathbf{h}_L^{n,i} \right\|^2 \quad (30)$$

整个蒸馏损失的计算将包含中间层和输出

层的损失函数，公式如下：

$$L_s = \frac{1}{N_b} \sum_{i=1}^{N_b} \left(\frac{\lambda_c}{3} \sum_{l=1}^3 L_{space}(\mathbf{h}_l^{n-1,i}, \mathbf{h}_l^{n,i}) + \lambda_f L_{output} \right) \quad (31)$$

其中， L_s 表示最终的蒸馏损失， N_b 表示每个 batch 的样本数量，超参数 λ_c 和 λ_f 用于平衡二者在损失函数中的占比。

通过知识蒸馏损失函数的约束，能够有效限制旧任务样本在新任务中特征向量的变化，缓解已知类别样本的特征漂移现象。模型在保留原有识别能力的基础上，持续加深对调制方式的理解，进一步提取其语义。

3.2 基于拉普拉斯矩阵特征值的聚类损失函数

受限于知识蒸馏损失函数的记忆约束，当前任务中的学生模型可能会继承冻结的教师模型对新增类别样本的不合理表征，从而妨碍对新类别的有效学习。为此引入了语义聚类损失 L_k ，借助流形空间的等距不变性，在维持高维空间特征分布的内在结构的基础上，增强模型对新增类别样本的学习能力，进而提升同类样本的聚集性与异类样本的分离性。

传统的特征学习方法通常侧重于点之间的欧氏距离，而流形学习方法则假设样本分布在一个潜在的低维流形上，能够更准确地保留数据的局部邻域结构。拉普拉斯特征图作为一种经典的流形建模工具，通过构建图结构并分析其拉普拉斯矩阵的谱特性，能够有效捕捉语义空间中类内的紧密性与类间的可分性。

为了构建拉普拉斯矩阵，以语义向量 \mathbf{h}_n^i 为节点，计算所有节点间的欧式距离，并使用 k-NN 算法构建带权邻接矩阵，邻接矩阵的每个元素表示为：

$$S_{ij} = \left\| \mathbf{h}_n^i - \mathbf{h}_n^j \right\|_2, \quad i, j \in \{1, 2, \dots, N_b\} \quad (32)$$

为了防止自连接，定义对角线元素为 $S_{ii} = +\infty$ 。对 $\mathbf{S} \in \mathbb{R}^{N_b \times N_b}$ 中的第 i 行（或列）进行排序，取前 k 个最小值对应的列建立索引集合 $\mathcal{N}_k(i)$ 。其次，定义二值邻接矩阵 $\mathbf{A} \in \mathbb{R}^{N_b \times N_b}$ ，邻接矩阵的元素 $a_{i,j}$ 的计算如下：

$$a_{i,j} = \begin{cases} 1, & j \in \mathcal{N}_k(i) \\ 0, & \text{其他} \end{cases}, \quad i, j \in \{1, 2, \dots, N_b\} \quad (33)$$

根据邻接矩阵 \mathbf{A} ，计算邻接矩阵的度矩阵 $\mathbf{D} \in \mathbb{R}^{N_b \times N_b}$ ，公式如下：

$$\mathbf{D} = \text{diag} \left(\sum_{i=1}^{N_b} a_{1,i}, \sum_{i=1}^{N_b} a_{2,i}, \dots, \sum_{i=1}^{N_b} a_{N_b,i} \right), \quad i \in \{1, 2, \dots, N_b\} \quad (34)$$

归一化的拉普拉斯矩阵 $\mathbf{L} \in \mathbb{R}^{N_b \times N_b}$ 公式如下：

$$\mathbf{L} = \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{A} \mathbf{D}^{-1/2} \quad (35)$$

其中， \mathbf{I} 为单位矩阵。求解特征多项式后，获取前 $N_m + 1$ 个最小的拉普拉斯矩阵特征值 $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_{N_m} \leq \lambda_{N_m+1}$ ，其中 N_m 是调制类别总数。特征值反映了图中数据点的几何结构，其中小特征值对应于类内紧密性，而较大特征值则表征了类别之间的分离度。由特征值计算损失函数：

$$L_k(\lambda) = -\lambda_{N_m+1} + \sum_{i=1}^{N_m} \lambda_i \quad (36)$$

通过最小化前 N_m 个特征值使得同一类别的调制样本在语义空间中变得更加聚集，通过最大化第 $N_m + 1$ 个特征值，能够间接增加不同类别之间的距离，从而使类别之间的边界更加明显。从流形学习的角度同时考虑了局部几何结构保持和全局判别性增强。

3.3 基于语义空间距离的分类损失函数

为了在引入新类别的同时保持原有类结构的稳定，并提升新类别的可区分性，本节设计了基于语义空间距离的损失函数，包含类内紧致损失和类间分类损失。其中类内紧致损失用于最小化样本与其所属类别中心之间的距离，以保证类内样本聚合紧密。该损失项表示为：

$$L_{pos} = \frac{1}{N_b} \sum_{i=1}^{N_b} \| \mathbf{h}_L^{n,i} - \mathbf{u}_c' \|^2 \quad (37)$$

类间分离损失用于增加样本与非所属类别中心之间的距离，增强类别区分性，采用如下形式：

$$L_{neg} = \frac{1}{N_b} \sum_{i=1}^{N_b} \sum_{c \neq c'} \max(0, \beta_{min} - \| \mathbf{h}_L^{n,i} - \mathbf{u}_c' \|^2) \quad (38)$$

其中， β_{min} 为安全间隔控制类间分离的最小距离，只有当样本距离错误类中心太近时，才产生损失。最终语义分类总损失为：

$$L_c = L_{pos} + \lambda_n L_{neg} \quad (39)$$

其中，超参数 λ_n 控制类间损失项的权重。为了保持语义图谱与当前特征分布的一致性，模型在每次损失优化完成后，同步更新图谱中的类中心信息。

4 增量识别流程

在训练之前，计算多种调制信号的多维特征构建输入数据集。令每次新任务中包含一种调制方式的输入特征。流程如算法 1 所示。

在初次任务中，输入数据不包含回放样本。模型采用全连接层与 Softmax 层作为分类器，计算交叉熵损失 L_{ce} 和语义聚类损失 L_k 来反向传播训练模型。初次训练完成后，以各类别的语义均值作为类中心 \mathbf{u}_c ，构建语义图谱 M 实现分类。

在后续的新增的任务中，首先对新增样本构建多维特征数据集。接着通过先前任务的冻结语义提取网络 d_{n-1} 与当前语义提取网络 d_n ，得到语义向量 $\mathbf{h}_n^{L,i}$ 和 $\mathbf{h}_{n-1}^{L,i}$ ，由此计算损失 L_s 和损失 L_k 。完成语义图谱的更新后，获得损失 L_c 。通过三总损失 L_M 训练模型。训练完成后，模型会筛选记录 m 个样本用于下次任务的回放。

在测试阶段，输入数据将包含先前所有任务的调制类别样本。测试样本经过语义提取、优化和语义图谱分类后得到预测的调制方式标签，并计算调试识别的准确率，以全面评估模型在开放集场景下的泛化能力和持续学习性能。

算法 1 模型训练与测试流程

Alg. 1 Model training and testing process

输入： 训练集为当前任务 n 的输入样本 $\{z_i^i\}_{i=1}^{N_i}$ ，测试集为先前任务与当前任务的所有类别样本 $\{z_i^i\}_{i=1}^T$ ，训练次数 $epoch$

输出： 对输入样本的预测标签 \hat{y}

if 开始训练 then

当前任务 n 的语义提取网络 $h_L^{n,i} = d_n(z_i^i)$

if $n = 1$ then

输入样本记为 $\{z_i^i\}_{i=1}^{N_i}$

for $i_e = 1, 2, \dots, epoch$ do

for $i = 1, 2, \dots, N_i$ do

$h_L^{n,i}, h_1^{n,i}, h_2^{n,i}, h_3^{n,i} = d_n(z_i^i)$

通过全连接层与 Softmax 层获得预测标签

end for

计算总损失 $L_{ce} + L_k$ ，训练网络

构建语义图谱 M

end for

模型训练完成后，筛选保留样本 $\{z_i^i\}_{i=1}^m$

else

训练集加入数量为 m 的回放样本，输入样本为

$\{z_i^i\}_{i=1}^{N_i+m}$

冻结先前任务 $n-1$ 的教师模型 $h_L^{n-1,i} = d_{n-1}(z_{n-1}^i)$

for $i_e = 1, 2, \dots, epoch$ do

```

for  $i = 1, 2, \dots, N_i + m$  do
     $h_L^{n,i}, h_1^{n,i}, h_2^{n,i}, h_3^{n,i} = d_n(z_i)$ 
     $h_L^{n-1,i}, h_1^{n-1,i}, h_2^{n-1,i}, h_3^{n-1,i} = d_{n-1}(z_i)$ 
    更新语义图谱  $M$ 
end for
    计算总损失  $L_c + L_k + L_s$ , 并构建语义图谱  $M$ 
end for
    模型训练完成后, 筛选保留样本  $\{z_i\}_{i=1}^m$ 
end if
else
    for  $i_r = 1, 2, \dots, T$  do
        将  $z_i$  输入到语义提取网络  $d_n$  中, 获得语义向量  $h_L^i$ 
        通过  $u_c$  与  $h_L^i$  进行最近邻分类, 获得结果  $\hat{y}$ 
    end for
end if

```

5 仿真结果

5.1 数据集设置

针对上述增量识别方法, 使用公开的数据集 RadioML2018.01A 进行调制识别增量学习模型的实验评估。

实验选取 32QAM、32PSK、16PSK、32APSK、16QAM、128APSK、FM、BPSK、8PSK 和 128QAM 等共计 10 种调制方式作为初始任务的调制信号输入。为了模拟增量任务的学习场景, 选取 256QAM、64APSK、16APSK、4ASK、QPSK、64QAM、GMSK 等 7 种调制方式作为新增的调制信号。调制信号的信噪比范围为 0-20 dB, 间隔为 2dB。不同任务中的每种调制方式选择 11000 个样本作为训练集, 1100 个样本作为测试集。

实验设置每个任务新增一种调制方式作为增量学习的对象, 任务序号为 T0-T7。在每个新任务中, 旧任务的所有调制方式保留回放的样本数量设置为 200, 在训练阶段与新任务的新增调制方式样本共同进行训练。模型在测试时使用所有任务中的调制方式样本进行测试。

实验所用模型的学习率设置为 0.01, 每次任务训练的 epoch 次数为 160, 单个批次的样本数量为 168。实验使用 Pytorch 框架, 优化器使用 SGD 优化器。

5.2 仿真结果分析

5.2.1 消融实验结果分析

为验证本文所提语义聚类损失函数的有效性, 以本文所提出的完整模型作为实验组, 通过与删除语义聚类损失函数的对照组进行比较, 衡

量语义聚类损失函数的实际作用。

如图 4 所示, 在 0-20 dB 的信噪比范围内, 未采用语义聚类损失的对照组在任务增多时识别准确率持续下降, 表现出明显的性能退化; 而引入语义聚类损失的实验组在各任务中提升了性能, 验证了该优化机制的有效性。在初始任务中, 256QAM 的学习使两组准确率均下降约 13%, 主要由于其高阶调制特性导致类间可分性降低。在任务 T5 的 64QAM 学习中, 两组均出现明显性能衰减, 表明在该任务中出现了更严重的灾难性遗忘。总体来看, 实验组在七个任务中平均识别率较对照组提升 8.16%。

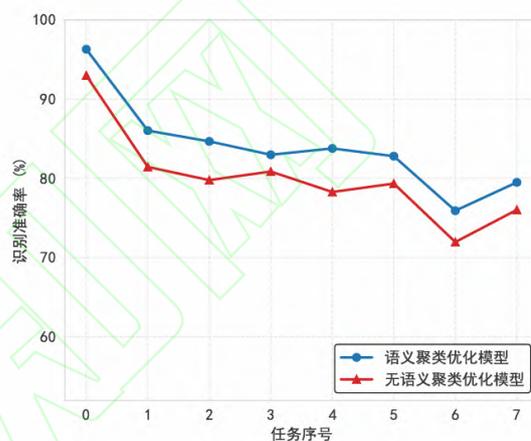


图 4 消融实验对比图

Fig. 4 Comparison chart of ablation experiment

5.2.2 对照实验结果分析

为验证本研究提出的调制方式增量识别模型的优越性, 实验选取 LwF^[25]与 iCaRL^[26]两种经典增量学习算法作为基准对照组与本文所提方法的实验组进行对比实验, 数据集采用本文设置的调制类型, 在 0-20 dB 的信噪比下, 对比三种方法的识别效果。

对照组和实验组在不同任务中的平均识别准确率如图 5 所示。传统方法 (LwF 和 iCaRL) 在早期任务 (任务 0-3) 中可能保持较高准确率, 但随着任务数量增加 (任务 4-8), 准确率显著下降。尤其是面对新增的 4ASK 幅移键控调制类型时, 灾难性遗忘现象加剧, 导致旧任务性能退化。

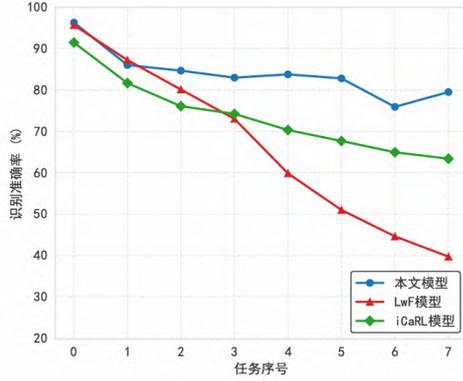


图 5 对照组实验对比图

Fig. 5 Comparison chart of control group experiment

在任务 T4 学习 4ASK 时，对照组模型 LwF 和 iCaRL 分别出现 13.18% 和 3.9% 的识别率下降，因为 4ASK 的判别信息几乎完全存在于幅度维度，这使模型在学习时，调整权重以强化对幅度特征的敏感性。对于 LwF 和 iCaRL 的通用特征提取器，破坏了先前 QAM/PSK 等类别学习的相位特征表示能力，导致旧类别的特征混淆，出现明显遗忘现象；相比之下，本文方法在该任务中反而提升了 0.8% 的平均识别率，体现出对新型调制类型的高效学习能力与旧任务知识的良好保留能力。

在任务 T3-T7 中，本文模型最大准确率下降仅为 7.86%，显著优于 LwF (33.32%) 和 iCaRL (10.84%)，验证了其在抑制知识遗忘方面的有效性。最终在 T7 任务中取得 16.12% 的识别准确率增益，七个增量任务的平均识别率达到 84.46%，较 iCaRL 提升超过 10%。

三种模型的参数量和复杂度如表 1 所示。本文提出的模型仅有 116 142 个可训练参数，其推理阶段的计算量为 996 M。相比之下，作为基线的 LwF 和 iCaRL 方法采用了更为复杂的网络结构，造成了更高的计算负载。本文所提出的模型在模型紧凑性和计算效率方面均展现出明确的优越性。

表 1 参数量与计算量对比

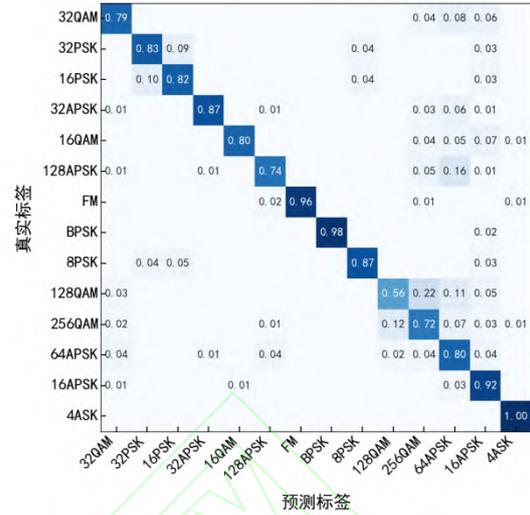
Tab.1 Comparison of Model Parameters and Computational Complexity

Model	Params	FLOPs
LwF	192 736	1 652 M
iCaRL	207 499	17 296 M
本文模型	116 142	996 M

5.2.3 调制识别实验结果分析

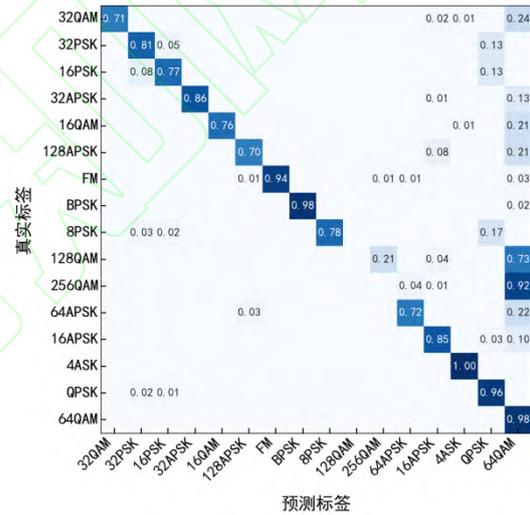
为了验证模型在不同任务中对不同调制方

式的识别能力，本节绘制了任务 T4 和 T6 的识别结果的混淆矩阵，如图 6 所示。



(a) 任务 T4 混淆矩阵

(a) Task T4 confusion matrix



(b) 任务 T6 混淆矩阵

(b) Task T6 confusion matrix

图 6 不同任务的混淆矩阵

Fig. 6 Confusion matrix for different task

其中，图 6(a)显示，调制识别准确率显著下降，主要由于模型在学习新增的 256QAM 时，与原有的 128QAM 识别产生混淆。这源于两者同属高阶调制，语义提取模块难以有效区分。图 6(b)进一步表明，在任务 T6 中新增 64QAM 导致 128QAM 和 256QAM 的识别率大幅下降，出现灾难性遗忘。原因可能在于高阶 QAM 类别之间的样本不平衡，以及高阶调制本身语义特征接近，使模型难以通过少量样本准确区分，进而影响识别效果。

为了进一步研究不同信噪比下本文模型对各类调制方式的识别效果，实验绘制了任务 T7 的信噪比准确率曲线图。如图 7 所示，在 0-5 dB 低

信噪比条件下, 4ASK、FM、GMSK 及 BPSK 等低阶调制方式平均识别准确率达 83%以上。此类信号的调制特征差异较大, 使得语义提取模块能有效分离信号与噪声成分。

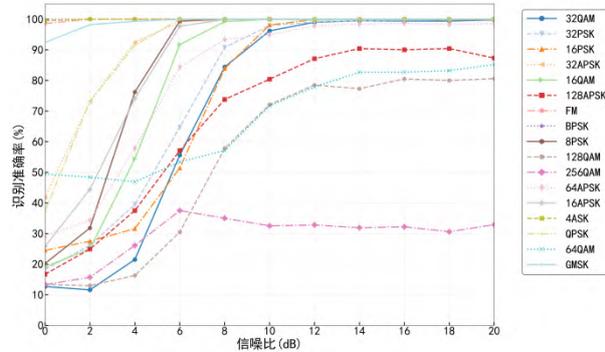


图 7 任务 T7 中不同信噪比下各调制方式的识别准确率
Fig. 7 Recognition accuracy of various modulation schemes under different signal-to-noise ratios in task T7

相较而言, 32APSK、QPSK、16PSK、8PSK、16QAM 和 16APSK 在 0 dB 信噪比下准确率均未超过 50%, 在 6 dB 时显著提升。在 10 dB 时, 64APSK、32PSK、32QAM 的准确率已超过 90%。这是由于高阶调制方式符号集更大、点间距更小, 语义在低信噪比下难以有效提取, 因此其准确率提升相较低阶调制更为滞后。同理, 128APSK、64QAM、128QAM 和 256QAM 的识别准确率随信噪比提升增长缓慢, 其中 256QAM 的识别准确率仍需进一步提升。

6 结论

本文面向动态环境下认知新型调制方式场景, 提出了一种基于语义空间的调制方式增量识别模型, 解决了不同任务动态场景下因特征漂移和样本分布不均导致的调制方式识别精度不足的难题。实验结果表明, 所提方法在多个增量任务中取得了 84.46% 的平均识别准确率, 较主流增量学习方法提升超过 10%, 效果显著, 但仍存在一定的局限性。在高维复杂的语义空间中, 当前分类器容易在类别分布密集区域发生混淆, 限制了其对细粒度调制类型的识别精度。下一步研究的重点将通过构建非线性的决策边界和对类别特征进行更精细的概率分布建模, 来有效提升细粒度分辨能力。

参考文献 (References)

[1] KUMAR A, MAJHI S, GUI G, et al. A survey of blind

modulation classification techniques for OFDM signals[J]. *Sensors*, 2022, 22(3): 1020.

[2] KHANH Q V, HOAI N V, MANH L D, et al. Wireless communication technologies for IoT in 5G: vision, applications, and challenges[J]. *Wireless Communications and Mobile Computing*, 2022, 2022(1): 3229294.

[3] XIAO W S, LUO Z Q, HU Q. A review of research on signal modulation recognition based on deep learning[J]. *Electronics*, 2022, 11(17): 2764.

[4] 焦翔, 魏祥麟, 薛羽, 等. 基于深度学习的自动调制识别研究[J]. *计算机科学*, 2022, 49(5): 266-278.
JIAO X, WEI X L, XUE Y, et al. Automatic modulation recognition based on deep learning[J]. *Computer Science*, 2022, 49(5): 266-278. (in Chinese)

[5] 肖易寒, 刘序斌, 于祥祯, 等. 基于多流 ConvNeXt 网络和马氏距离度量的未知信号增量识别[J]. *上海交通大学学报*, 2024, 58(4): 481-491.

XIAO Y H, LIU X B, YU X Z, et al. Unknown signal incremental recognition based on multi-flow ConvNeXt network and mahalanobis distance metric[J]. *Journal of Shanghai Jiao Tong University*, 2024, 58(4): 481-491. (in Chinese)

[6] VAN DE VEN G M, TUYTELAARS T, TOLIAS A S. Three types of incremental learning[J]. *Nature Machine Intelligence*, 2022, 4(12): 1185-1197.

[7] QI P H, ZHOU X Y, DING Y L, et al. Collaborative and incremental learning for modulation classification with heterogeneous local dataset in cognitive IoT[J]. *IEEE Transactions on Green Communications and Networking*, 2023, 7(2): 881-893.

[8] OWFI A, ABBASI A, AFGHAH F, et al. Dynamic online modulation recognition using incremental learning[C]//*Proceedings of the International Conference on Computing, Networking and Communications (ICNC)*, 2024: 412-416.

[9] YANG Y, CHEN M H, WANG X Y, et al. Modulation recognition based on incremental deep learning[C]//*Proceedings of the 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*, 2020: 1701-1705.

[10] XU B, WANG H H, WU B, et al. Signal modulation recognition via bias adjustment-based class incremental learning[J]. *IEEE Sensors Journal*, 2024, 24(24): 41437-41450.

[11] MA S, ZHANG L, SONG Z L, et al. Leveraging

- incremental learning for dynamic modulation recognition[J]. *Electronics*, 2024, 13(19): 3948.
- [12] LI Y K, ZHOU F H, YUAN L, et al. A novel knowledge graph driven automatic modulation classification framework for 6G wireless communications[J]. *IEEE Transactions on Wireless Communications*, 2025, 24(3): 2373-2388.
- [13] FENG T, WANG M, YUAN H J. Overcoming catastrophic forgetting in incremental object detection *via* elastic response distillation[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022: 9417-9426.
- [14] ZHAO Y, CHEN S C, CHEN T, et al. Incremental learning of radio modulation classification based on sample recall[J]. *China Communications*, 2023, 20(7): 258-272.
- [15] FAN Z Y, TU Y, LIN Y, et al. Class-incremental learning for recognition of complex-valued signals[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(2): 417-428.
- [16] DUAN F, DAI L L. Recognizing the gradual changes in sEMG characteristics based on incremental learning of wavelet neural network ensemble[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(5): 4276-4286.
- [17] HAO X Y, YANG S Y, LIU R Y, et al. SMTC-CL: continuous learning *via* selective multi-task coordination for adaptive signal classification[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2025, 11(3): 1664-1681.
- [18] ZHUANG L, LUO K, YANG Z B. A multimodal gated recurrent unit neural network model for damage assessment in CFRP composites based on lamb waves and minimal sensing[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3506911.
- [19] WANG W C, TIAN W C, HU X X, et al. DTTR: Encoding and decoding monthly runoff prediction model based on deep temporal attention convolution and multimodal fusion[J]. *Journal of Hydrology*, 2024, 643: 131996.
- [20] LI C J, LI S B, FENG Y X, et al. Small data challenges for intelligent prognostics and health management: a review[J]. *Artificial Intelligence Review*, 2024, 57(8): 214.
- [21] 郝晓阳. 复杂学习条件下的电磁信号智能检测与识别关键技术研究[D]. 西安: 西安电子科技大学, 2024.
- HAO X Y. Research on key technologies for intelligent detection and identification of electromagnetic signals under complex learning conditions[D]. Xi'an: Xidian University, 2024. (in Chinese)
- [22] ZHANG F X, LUO C B, XU J L, et al. Deep learning based automatic modulation recognition: Models, datasets, and challenges[J]. *Digital Signal Processing*, 2022, 129: 103650.
- [23] LI Q W, PENG Y X, ZHOU J H. FCS: feature calibration and separation for non-exemplar class incremental learning[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2024: 28495-28504.
- [24] LI T T, WEN Z Y, LONG Y, et al. The importance of expert knowledge for automatic modulation open set recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(11): 13730-13748.
- [25] LI Z Z, HOIEM D. Learning without forgetting[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(12): 2935-2947.
- [26] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. iCaRL: incremental classifier and representation learning[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 5533-5542.