

认知学习:电磁频谱空间机器学习新范式

阮天宸,吴启晖,赵世瑾,周福辉,黄 洋

(南京航空航天大学电磁频谱空间认知动态系统工信部重点实验室,江苏南京 211106)

摘要: 随着无线设备及其应用呈现指数级增长,以及各种无线技术的出现,电磁频谱环境呈现环境多域、态势多维、应用多样、行为多变、信号密集的复杂特性. 通过对海量数据进行即时有效的分析和处理,实现有效的频谱资源管控,对于频谱高效利用和电磁致胜显得尤为重要. 以机器学习为代表的智能技术方法为电磁频谱数据分析提供了新的发展机遇,目前其已经应用于无线网络、频谱管理、资源管理等场景. 然而,将机器学习应用于电磁频谱空间存在许多挑战. 因为电磁频谱空间环境任务动态变化、高质量标记样本稀缺、频谱决策对高实时性的需求、知识利用和迁移困难等难点,现有机器学习算法难以很好地适用于电磁频谱空间的智能认知和决策. 以干扰识别的研究为例,传统的技术包括信号特征提取和模式识别两个阶段. 随着计算机算力的进步,深度学习技术凭借强大的特征表征能力逐渐占据主导地位. 然而电磁频谱空间环境和数据往往存在未知、动态变化等不确定性因素,深度学习难以快速学习和适应未观测到的任务,其泛化性较差,且依赖大量高质量标记样本和人工调整超参数进行离线训练. 因此,尽管深度学习在大多数研究场景中展现出了传统机器学习难以望其项背的结果,传统的机器学习图像识别模型仍然在某些场景中具备优势. 在干扰识别中,若根据环境和任务特征动态地调度传统机器学习算法和深度学习算法及其超参数,则可以避免单一算法的缺陷,使总体性能得到改善. 由此可见,提出一个能够自适应动态环境与任务、不断积累新知识、对错误样本数据具有鲁棒性、部分可解释的学习范式,对于从感知智能向认知智能跨越、迈向通用人工智能具有重要的研究意义和实际应用价值.

本文从频谱特性出发,提出了电磁频谱空间机器学习新范式:认知学习,试图在“认知”的层面使用机器学习技术. 认知学习范式包括离线训练、在线执行、在线结果反馈、离线自学习过程,对应大脑认知机制的执行控制和内省过程. 离线训练探索算法结构和超参数与环境任务的匹配关系,在线时能够有效地根据实际环境执行快速决策,选择合适的算法和超参数并输出学习结果,同时利用学习结果的反馈传递进行离线自学习的自我优化,形成离线-在线-离线的结构. 具体来说,认知特征提取模块建立环境和任务特征与算法类型和超参数之间的匹配关系,从而得到合适的算法类型和超参数;记忆模块调用具体算法和超参数值,进行算法的重构;学习网络模块根据数据执行所选择的算法,输出在线学习结果;认知评估模块对在线学习结果进行内省,调整记忆中的频谱数据库与认知案例库,更新最合适的算法和超参数. 在离线阶段,根据当前的学习结果判断是否将其作为新的认知案例存储至记忆空间;认知控制模块重新训练算法和超参数的选择,从而不断优化算法和超参数选择性能. 此外,本文揭示了认知学习中的动态匹配定理和最优匹配定理,并根据没有免费午餐定理的思路完成了定理证明. 动态匹配定理论证了最优算法和超参数的存在性与动态性,即对于任意环境和任务,总存在一组性能最优的算法和超参数. 不同的环境与任务对应不同的最佳算法和超参数,并且本文提出的框架可以为动态环境和任务选择出这组算法和超参数. 本文还揭示了最优匹配定理,即当算法和超参数选择的知识增加时,候选的算法类型和超参数搜索空间减小,能够选择到最合适的算法类型和超参数的概率提升.

本文设计了一种面向干扰识别的认知学习方案. 通过认知特征提取,基于差异性的任务需求和信号模态,对不同问题采取不同算法和超参数产生测试结果,生成认知案例库. 将大量认知案例作为训练样本训练算法和超参数选择的神经网络. 对于神经网络结构,采用了径向基函数神经网络,其优势是隐藏单元的数量不需要手动设置. 当各种问题特征的训练样本数量增加时,隐藏层的大小可以根据近似线性相关准则自动扩展,缓解了神经网络中灾难性遗忘的问题. 本文进行了不同数据集和不同识别要求情况下的干扰识别仿真. 仿真结果表明,所提框架能适应动态变化的环境和任务,能通过自学习提升性能,能缓解错误标记样本的影响,对电磁频谱空间机器学习的发展具有启发式意义. 认知学习的发展仍有进步空间,未来需要从多模态计算、知识的可解释性、大规模任务、学习架构的可扩展性等方向寻求突破.

关键词: 电磁频谱空间;机器学习;认知学习;算法选择;干扰识别

基金项目: 国家自然科学基金重点项目(No.62231015)

中图分类号: TN929.5;TP181

文献标识码: A

文章编号: 0372-2112(2023)06-1430-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221137

Cognitive Learning: A New Paradigm for Machine Learning in Electromagnetic Spectrum Environment

RUAN Tian-chen, WU Qi-hui, ZHAO Shi-jin, ZHOU Fu-hui, HUANG Yang

(Key Laboratory of Dynamic Cognitive System of Electromagnetic Spectrum Space, Ministry of Industry and Information Technology, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 211106, China)

Abstract: With the exponential growth in the number of wireless devices and wireless applications, and the emergence of various wireless technologies, the electromagnetic spectrum environment has presented complex characteristics such as multi-domain environments and situations, diverse applications, changeable behaviors, and dense signals. Spectrum resource control through immediate and effective analysis and processing of massive data is vital for efficient spectrum utilization and electromagnetic spectrum dominance. Intelligent technology represented by machine learning methods provides new opportunities to analyze electromagnetic spectrum data. Machine learning methods have been applied to wireless networks, spectrum management, resource management, and other scenarios. There are many challenges when applying machine learning to the electromagnetic spectrum environment. Because of the dynamically changing environment and tasks, the scarcity of high-quality labeled samples, real-time spectrum decision-making, and the difficulty of knowledge utilization and transfer in the electromagnetic spectrum environment, existing machine learning algorithms are not ideal for intelligent cognitive decision-making. Taking the research on interference recognition as an example, the traditional methods include two stages: signal feature extraction and pattern recognition. With the growth in computer computing power, deep learning techniques gradually replace traditional methods because of their powerful feature characterization capability. However, the electromagnetic spectrum environment and data often have uncertainties caused by unknown, dynamic changes. Adapting deep learning to unobserved tasks quickly is challenging, indicating poor generalization capability. Furthermore, it is limited by its reliance on a large number of high-quality labeled samples and manual adjustment of hyperparameters for offline training. Thus, although deep learning has far outperformed traditional methods in most research scenarios, traditional machine learning-based image recognition models still have advantages in some scenarios. In interference recognition, if traditional machine learning algorithms and deep learning algorithms and their hyperparameters can be dynamically scheduled according to the environment and task characteristics, the shortcomings of using a single algorithm can be avoided, resulting in improved overall performance. It is necessary to propose a learning paradigm that continuously adapts to dynamic environments and tasks, accumulates new knowledge, is robust to erroneous sample data, and is partially interpretable. The leap from perceptual intelligence to cognitive intelligence toward general artificial intelligence has research significance and practical value.

Given the characteristics of the electromagnetic spectrum, this paper proposes a new paradigm of machine learning method in the electromagnetic spectrum environment—cognitive learning, attempting to use machine learning techniques at a “cognitive” level. It includes offline training, online execution, online feedback and offline self-learning processes, corresponding to the executive control and introspective processes of the brain’s cognitive mechanisms. Offline training explores the matching relationship between the algorithm type and hyperparameters with the environment and the task. During the online process, it can perform decision-making based on the actual environment, select appropriate algorithms and hyperparameters, and output learning results. The feedback of learning results can be used for self-optimization in offline self-learning, forming an offline-online-offline structure. The cognitive feature extraction module establishes matching relationships between features of environments and tasks and algorithm types and hyperparameters to obtain the appropriate algorithm types and hyperparameters. The memory module calls specific algorithms and hyperparameter values for algorithm reconstruction. The learning network module executes the selected algorithm based on the input data and outputs online learning results.

The cognitive evaluation module introspects the online learning results and adjusts the data in the memory database and cognitive case base, and updates the most appropriate algorithm and hyperparameters. In the offline stage, the current learning results are judged whether to be stored as a new cognitive case in the memory. The cognitive control module retrains the selection of algorithms and hyperparameters to continuously optimize the performance of selecting algorithms and hyperparameters.

Moreover, we reveal and confirm the dynamic matching theorem and the optimal matching theorem in cognitive learning according to the No Free Lunch Theorem. The dynamic matching theorem states the existence and dynamics of optimal algorithms and hyperparameters. For any environment or task, there is always a set of algorithms and hyperparameters with

optimal performance, which differs for different environments and tasks. The proposed cognitive learning paradigm can select appropriate algorithms and hyperparameters. The optimal matching theorem states that as the knowledge of algorithm and hyperparameter selection increases, the search space of candidate algorithm types and hyperparameters decreases, and the probability of selecting the most suitable algorithm type and hyperparameters increases.

A cognitive learning scheme for radio frequency interference identification is designed. Different algorithms and hyperparameters are adopted for different problems to generate test results and a cognitive case base based on the differential task requirements and signal modalities acquired by cognitive feature extraction. A large number of cognitive cases are used as training samples to train the neural network for algorithm and hyperparameter selection. A radial basis function neural network is used for the neural network structure, which has the advantage that the number of hidden units does not need to be set manually. The size of hidden layers can be automatically expanded according to the approximate linear correlation criterion when the number of training samples for various problem features increases, alleviating the problem of catastrophic forgetting in neural networks.

We performed interference recognition simulations with different datasets and different recognition requirements. The simulation results demonstrate that the proposed paradigm can adapt to dynamically changing environments and tasks, improve performance by self-learning, and alleviate the impact of mislabeled samples. The cognitive learning paradigm has a pioneering significance for developing machine learning methods applied to the electromagnetic spectrum environment. There remains room for improvement in cognitive learning. We must seek future research breakthroughs in multimodal computing, knowledge interpretability, large-scale tasks, and learning architecture scalability.

Key words: electromagnetic spectrum environment; machine learning; cognitive learning; algorithm selection; interference identification

Foundation Item(s): National Natural Science Foundation of China (No.62231015)

1 引言

无线电磁频谱资源是支撑国民经济、社会发展和国防建设、具有国家战略意义的稀缺资源^[1]。尤其是在现代化战争中,电磁频谱空间已逐步演化为第六维作战空间,取得电磁频谱战的制胜权具有重要价值和意义^[2]。随着陆、海、空、天、网等多域电磁频谱环境交叠耦合,通信、雷达、测控、导航、电抗等各类电磁频谱应用数量的指数级增长,电磁频谱环境已逐渐呈现出环境多域、态势多维、应用多样、行为多变、信号密集的复杂特性。在这样的复杂环境中,需要对海量数据进行即时有效的分析和处理。利用传统的依靠专业领域知识制定规则的专家系统既昂贵又耗时,且难以适应电磁用频设备的爆炸式增长和电磁环境的快速变化。

为了解决上述问题,以机器学习等为代表的技术为电磁频谱数据分析提供了新的发展机遇。探索电磁频谱领域的机器学习算法变得尤为关键。然而不同于其他研究领域,将机器学习应用于电磁频谱空间面临诸多挑战。

(1) 频谱环境和任务的动态变化

越来越多的无线终端、通信系统、雷达、干扰机和其他设备在电磁频谱环境中运行,释放的高密度、高强度、多频谱的电磁波构成了一个日益复杂的电磁环境。电磁频谱环境和任务变得越来越复杂,呈现高度动态性。现有的机器学习算法大多依赖稳定的环境,无法适应动态变化的环境和任务。文献[3]和文献[4]指出采

用深度学习的一大挑战就是处理复杂和不确定的环境数据。在电磁频谱环境中,这一问题也愈发严峻。同时,算法模型和超参数影响算法性能,如何找到合适的算法模型和超参数组合是一个至关重要的问题。现有的算法一旦完成了训练过程,模型和超参数将不会再次改变,机器学习算法将只能根据固定的映射规则实现训练好的功能。由于这些缺陷,它们的性能和应用范围受到了一定的限制。而根据“没有免费的午餐”(No Free Lunch, NFL)定理^[5],没有一个算法能够完美地适用于所有场景。实际上,神经网络有必要灵活切换状态,以实现复杂环境中的多任务学习^[6]。

(2) 高质量标签样本的数量稀缺

虽然电磁频谱环境中数据总量呈指数级增长,但由于容易受到干扰、电子对抗等影响,标注样本数量少且质量不高。现有的机器学习算法依赖大量的高质量标注数据进行训练,缺乏对错误标记数据和知识的鲁棒性。文献[3]指出采用深度学习的另一挑战是有限的标签数量。由于人工标注,即使是 ImageNet 等大型公开数据集也难免存在标签误差^[7]。若训练时无法自动判别和剔除错误标签或对性能提升无效的训练样本,将会对神经网络的性能造成严重影响。

(3) 频谱决策的高实时性

电磁频谱环境中的任务呈现多样化趋势,可能会面临一些从未遇到过的任务,如需要对抗智能的恶意干扰和攻击模式。在民用尤其是未来电子战中,复杂电

电磁频谱环境的多变性对决策具有时效性要求^[8],需要对实时任务做出及时的响应^[1],然而机器学习算法的重新训练将耗费大量的时间.因此,机器学习算法需要在决策效率和精度之间找到良好的平衡.

(4) 领域知识利用和迁移的困难

现有的机器学习算法尚未很好地利用和迁移频谱领域知识.例如,由于各频段频谱演变规律、衰落模型等特性不同,频谱固有的差异性导致跨频段知识难以迁移.更重要的是,现有的机器学习算法依赖人工选择的算法和超参数,缺乏知识的积累和增量过程.针对这一问题,文献[9]提出神经网络中基于上下文情境处理的连续学习方法.随之而来的问题是缺乏对结果的可解释性.文献[3]指出可解释性是深度学习的另一大挑战.这是由于机器学习的决策过程是一个黑盒模型,本文无法通过一些显式的知识推理得到结果.事实上,神经网络的连接主义对知识的表示不够完备,知识仅存在于神经网络的结构和权重中^[10].

综上所述,大多数现有的机器学习框架难以很好地适用于电磁频谱空间,提出一个能够自适应动态环境与任务、不断积累新知识、对错误样本数据具有鲁棒性、部分可解释的学习范式,对于从感知智能向认知智能跨越、迈向通用人工智能具有重要的研究意义和实际应用价值.

2 电磁频谱空间机器学习的研究现状

近年来,机器学习已逐步成为工业界和学术界进行数据分析的有力工具,并在电磁频谱领域得到了广泛的应用.美国国防高级研究计划局(Defense Advanced Research Projects Agency, DARPA)研发了从数据中学习并以任务为导向的无线电频谱机器学习系统(Radio Frequency Machine Learning Systems, RFMLS),主要研究信号特征学习、注意力引导等核心问题^[11,12],还提出了自适应电子战行为学习(Behavioral Learning for Adaptive Electronic Warfare, BLADE),将机器学习理论研究应用到通信电子战领域.在学术界,一些专家学者调研了机器学习在无线网络^[13]、频谱管理^[14]、资源管理^[15]等方向的研究.本文以干扰识别为例,分析了机器学习算法研究现状.

2.1 针对干扰识别的机器学习算法研究现状

在开放的电磁环境中,无线通信信号容易混杂多种非法干扰信号,对信息传输效率和通信系统安全产生毁灭性的打击.为了避免非法信号占用频谱资源,有效地感知并识别干扰信号类型,对于争夺制电磁权有着重要意义.

传统的干扰识别技术通常包括两个信号处理阶段:信号特征提取和模式识别.特征提取阶段依赖于使

用“专家特征”,即人类专家预先定义一组信号特征,综合分析提取信号频域、时域等多个维度的特征参数,对干扰信号进行识别分类.这些专业信号特征是在昂贵且耗时的预处理过程中得到的.文献[16]利用决策树算法有效识别单音、多音、扫频干扰等典型干扰信号.文献[17]利用基于支持向量机(Support Vector Machine, SVM)的决策树、反向传播(Back Propagation, BP)神经网络实现对干扰信号的分类.文献[18]利用SVM实现对全球卫星通信系统的干扰识别.在干扰识别中,信号的时频域特征可以转化为时频图,从而将信号特征分类问题转化为基于时频图的图像分类问题.文献[19]提取信号时频域图像的特征,输入特征到SVM进行分类前降维操作.在这些方法中,信号需要先经过复杂的前期特征处理,且对低干噪比下的干扰信号识别准确率不高.

随着计算机算力的进步,以深度学习为代表的深度神经网络模型在图像、语音和自然语言处理等多个领域的很多任务上都取得了优异的性能.由于深度学习强大的特征表达能力,可以自动学习到图像深层纹理特征而无需大量的先验知识,对图像的识别有其固有的优势,且频谱空间的海量数据恰好可以作为深度学习的必要条件.其基本原理是首先对一段信号进行时频分析,得到信号的时频图像,然后利用图像识别神经网络对信号进行检测和识别^[20].文献[21]和文献[22]分别提出了干扰识别实数卷积神经网络和干扰识别复数卷积神经网络.为了进一步改善低干噪比下的识别准确率,文献[23]提出了基于频带相关性的长短时记忆网络(Long Short-Term Memory, LSTM).然而电磁频谱空间环境和数据往往存在未知、动态变化等不确定性因素,深度学习难以快速学习和适应未观测到的任务,其泛化性较差,且依赖大量高质量标记样本进行离线训练.另外,深度学习需要人工调整超参数,对应用带来了一定的局限性.

2.2 其他机器学习算法

尽管深度学习模型(如CNN, RNN)展现出了传统机器学习难以望其项背的结果,传统的机器学习图像识别模型,如K邻近(k-Nearest Neighbor, KNN)、SVM等,仍然在某些场景中具备优势.文献[24]通过仿真表明,在小样本数据图像分类识别上,机器学习具有简单高效的优点,并能解决高像素图片的快速分类.在大样本数据上,深度学习模型能进行精准的分类识别,并且具备较强的鲁棒性.一些研究聚焦于“算法选择”的思想,利用一个更高层的分类器,在不同的算法中选择一个最合适的算法,以解决问题.

元学习^[25]也被称为“学会学习”,是一种受教育心理学启发的学习框架.它从历史学习经验(也被称为

“元数据”)中学习,能够快速适应之前未学习到的新任务,例如快速找到合适的算法模型和超参数,从而适应新的问题和任务. 元学习已经被广泛用于解决优化^[26]、分类^[27]、推荐系统^[28]等领域的算法选择问题. 然而,该学习框架也存在一些不足:需要大量的先验任务集,且假定任务之间都是独立同分布的,忽略任务发生改变的非平稳情况. 此外,该框架不能通过在线反馈的数据改善学习模型,因此很难处理复杂的数据和学习环境.

认知学习是一种基于大脑认知机理提出的学习架构^[29],在“认知”层面使用机器学习技术,即用离线的机器学习来探索算法结构和先验知识,在线时能够有效地根据实际环境执行决策和在线学习. 灵长类动物通过执行控制过程和自省过程,面对新环境和新任务时能够快速适应动态环境并执行复杂的动作. 受到这种脑机理的启发,认知学习通过在线学习和离线学习,并自适应地选择一种最合适的算法和超参数. 在干扰识别中,若根据环境和任务特征动态地调度传统机器学习算法和深度学习算法及其超参数,则可以避免利用单一算法的缺陷,使得总体性能得到改善.

3 认知学习范式与理论

3.1 认知学习范式

本文提出了面向复杂电磁频谱环境的认知学习范式,如图1所示. 根据无线通信环境中的任务需求和信号模态,认知学习架构选择合适的算法和超参数,输出学习结果,同时也作为反馈传递给认知学习架构本身,通过自学习进行自我优化.




图1 面向复杂电磁频谱环境的认知学习范式

图2为认知学习框架,包含在线执行、在线结果反馈、离线自学习过程,对应于大脑认知机制的执行控制和自省过程. 在线阶段,根据任务和特征给出实时学习结果,离线阶段进行离线自主学习并改善学习结果. 蓝色实线为在线执行过程,绿色虚线为在线结果的反馈过程,红色虚线为离线自学习过程. 认知特征提取模块对应于大脑的感知皮层,从原始图像数据集中提

取环境 e 和任务 k 的特征. 认知控制模块对应于大脑的前额叶皮层,建立特征与算法类型和超参数之间的匹配关系,从而得到合适的算法类型和超参数. 记忆模块对应于大脑的记忆中枢,根据所选算法类型和超参数组合 A ,调用具体算法和超参数值,进行算法的重构. 学习网络模块对应于大脑的前运动皮层,根据数据执行所选择的算法,输出在线学习结果 y . 认知评估模块对应于大脑的前扣带皮层,对在线学习结果进行内省,用来调整记忆中的频谱数据库与认知案例库,为当前案例和其他案例更新一个最合适的算法和超参数. 在离线阶段,将当前的学习结果 y 与历史最佳学习结果进行比较. 如果当前学习结果的性能更好,则将所选的算法和超参数、学习结果 $[f(e, k), a, y]$ 作为新的认知案例存储至记忆空间,认知控制模块重新训练算法和超参数的选择,从而不断优化环境任务特征和最佳算法超参数之间的匹配关系. 因此,离线自学习过程可以在保证决策时效性的情况下,提高学习算法的性能.

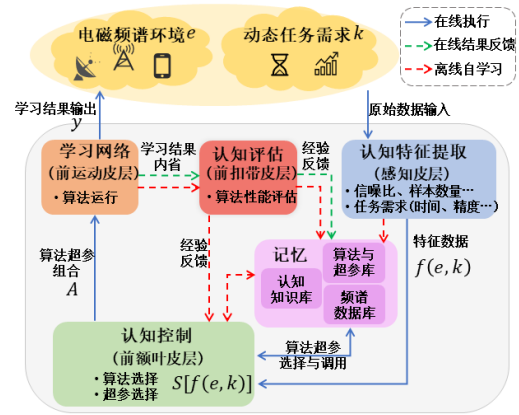


图2 面向复杂电磁环境的认知学习框架

3.2 认知学习定理

本文提出了认知学习的动态匹配定理和最优匹配定理,证明对于任意环境和任务,总存在一组性能最优的算法和超参数. 并且提出的认知学习框架可以为动态环境和任务选择出这组算法和超参数.

定理1 动态匹配定理:对于给定的环境和任务,若可供选择的算法和超参数空间是有限的,则对于任意环境和任务,总能匹配一组最合适的算法和超参数;不同的环境与任务对应不同的最佳算法和超参数.

证明 对定理1的证明思路是基于“没有免费的午餐定理”的证明. “没有免费的午餐定理(NFL)”指出,对于同一个问题域中的所有问题,每个可以采用的算法在这些问题上的总平均性能是相同的. 受NFL定理证明的启发,对定理1给出了证明.

假设所有的问题集合和算法及超参数集合是离散

的,并且它们的大小是有限的. 存在一个性能矩阵(即问题性能矩阵),它的行是所有问题的集合,行数 $|Q|$ 为问题集 Q 的元素个数. 矩阵的列是各种算法和超参数的组合,列数 $|A|$ 为算法和超参数集 A 的大小,每个元素表示一个算法及其一种超参数组合. 矩阵中每个元素的值表示在该问题上选择某种算法和超参数的性能,即第 i 行第 j 列元素表示为 $y_{i,j}=a_j(q_i) \in Y$,代表算法和超参数 a_j 在问题 q_i 上的性能. 假设问题集中每个问题的数量是均匀分布的,满足NFL定理中所有问题同等重要的前提. 本文举例了 $|Q|=8, |A|=5$ 时的场景,如表1所示.

表1 性能矩阵 y_{ij}

q_i	a_j				
	a_1	a_2	a_3	a_4	a_5
q_1	$y_{1,1}$	$y_{1,2}$	$y_{1,3}$	$y_{1,4}$	$y_{1,5}$
q_2	$y_{2,1}$	$y_{2,2}$	$y_{2,3}$	$y_{2,4}$	$y_{2,5}$
q_3	$y_{3,1}$	$y_{3,2}$	$y_{3,3}$	$y_{3,4}$	$y_{3,5}$
q_4	$y_{4,1}$	$y_{4,2}$	$y_{4,3}$	$y_{4,4}$	$y_{4,5}$
q_5	$y_{5,1}$	$y_{5,2}$	$y_{5,3}$	$y_{5,4}$	$y_{5,5}$
q_6	$y_{6,1}$	$y_{6,2}$	$y_{6,3}$	$y_{6,4}$	$y_{6,5}$
q_7	$y_{7,1}$	$y_{7,2}$	$y_{7,3}$	$y_{7,4}$	$y_{7,5}$
q_8	$y_{8,1}$	$y_{8,2}$	$y_{8,3}$	$y_{8,4}$	$y_{8,5}$

根据NFL定理,任意一对算法和超参数对所有可能问题的平均性能是相同的,即性能矩阵中各列的性能值之和相等,表示为

$$\sum_{i=1}^{|Q|} y_{i,1} = \sum_{i=1}^{|Q|} y_{i,2} = \sum_{i=1}^{|Q|} y_{i,3} \quad (1)$$

根据上述条件随机生成这样一个性能矩阵. 矩阵中的每个元素的值可以被画成图3中的一个散点.

图3为性能矩阵散点图. 横坐标是问题序号 i ,每种类型的点代表一种算法超参数组合 a_j ,纵坐标是算法 a_j 在该问题上的表现. 性能1曲线表示固定的算法超参数组合 $A_1 = \{a_1\}$ 在所有问题上的整体性能. 性能2和性能3曲线分别表示当可选的算法超参数集合为 $A_2 = \{a_1, a_2, a_3\}$ 和 $A_3 = \{a_1, a_2, a_3, a_4, a_5\}$ 时在问题集上的最佳性能. 动态匹配定理可以从图3中得到直观的解释. 首先,从性能3的曲线可以看出,对于任意一个给定的环境和任务(即问题 q_i),都存在集合 A 中的一个 a_j ,在该问题上能够有最优性能,这样的算法和超参数就是最优的算法和超参数. 其次,对于不同的问题 q_i ,最佳的算法

$$E_{\text{otc}}(A|D_1, q) = \sum_a \sum_h \sum_{d \in D-D_1} [\Pr(D') \cdot I(h(D') \neq f(D')) \Pr(h|D_1, a) \Pr(a)] \quad (3)$$

设选择最合适的算法和超参数的概率为 $\Pr(a^*)$. 假设其他算法和超参数被选择的概率相同,则 $\Pr(a^*)$ 越大,式(2)结果越大,即算法和超参数集 A 的整体性能越好. 对于已有的学习算法,当环境和任务变化时,算




图3 性能矩阵散点图

和超参数的序号 j 也会发生变化. 从性能1和性能2的曲线对比中可以看出,与固定的算法和超参数 $A_1 = \{a_1\}$ 相比,从 A_2 或 A_3 自适应地选择一个最适合该问题的算法和超参数 a_j 可以获得更好的整体性能. 此外,当算法和超参数集的规模由 A_2 增大至 A_3 时,能够选择到更佳

的算法和超参数,从而进一步提高整体性能.

定理2 最优匹配定理:当算法和超参数选择的知识增加时,候选的算法类型和超参数的搜索空间减小,能够选择到最合适的算法类型和超参数的概率提升.

证明 考虑这样几个集合:数据集 D 、问题集 Q 、算法及超参数集 A . 设 $D_1 \in D$ 表示训练数据集, $D' \in D - D_1$ 表示测试数据集, $a \in A$ 表示某个算法和超参数组合,问题 $q \in Q$. 令 $\Pr(h|D_1, a)$ 表示算法和超参数 a 基于训练数据集 D_1 生成预测结果 h 的概率, f 为真实结果. 则算法和超参数 a 在问题 q 上的误差为

$$E_{\text{otc}}(a|D_1, q) = \sum_h \sum_{D' \in D-D_1} [\Pr(D') \cdot I(h(D') \neq f(D')) \Pr(h|D_1, a)] \quad (2)$$

其中, $E[\cdot]$ 表示期望, $I(\cdot)$ 为指示函数,当 $h(D') \neq f(D')$ 为真时指示函数的值为1. 式(2)表明了算法和超参数 a 在问题 q 上的性能,对应图3中的某个散点. 令 $\Pr(a)$ 表示选择算法和超参数 a 的概率,则算法和超参数集 A 在问题 q 上的性能为

法和超参数的随机选取导致每个算法和超参数被选取的概率是相同的. 因此,现有学习选择最合适算法和超参数的概率为

$$\Pr(a^*)_1 = \Pr(a) = \frac{1}{|A|} \quad (4)$$

本文提出的认知学习利用知识辅助的算法和超参数空间进行算法和超参数选择. 知识辅助的算法和超参数空间是指认知学习在面对新的环境和任务时, 根据之前的知识筛选的算法和超参数集合, 这个集合 A_1 是原算法和超参数空间 A 的子集, 并且它包含了最合适的算法和超参数. 因此, 利用认知学习来选择最佳合适算法和超参数的概率为

$$\Pr(a^*)_2 = \Pr(a|A_1) = \frac{\Pr(a)}{\Pr(A_1)} = \frac{1}{|A_1|} \quad (5)$$

由于 $|A_1| < |A|$, 可以得到

$$\Pr(a^*)_2 > \Pr(a^*)_1 \quad (6)$$

因此, 认知学习相比于现有的机器学习方法, 更能选择出合适的算法和超参数, 学习性能更好.

3.3 面向干扰识别的认知学习方案

本文设计了一种面向干扰识别的认知学习方案. 本文认为干扰信号识别问题满足 NFL 定理. NFL 定理

的前提是需要针对某一个具体问题域的所有问题进行讨论, 而对问题域的内容没有明确的要求. 干扰信号样式识别可以看作一个分类问题. 目前, 已有很多文献考虑到 NFL 定理, 研究分类算法的算法选择问题^[27,30]. 因此, 算法选择的理想可被应用于干扰信号样式识别问题.

将信号 $x(u)$ 通过时频分析通过短时傅里叶变换 $F_x(t, \Omega; h) = \int_{-\infty}^{+\infty} x(u)h(u-t)e^{-j\Omega u} du$ 得到时频二维图像, 其中 $h(t)$ 是窗函数. 时频图反映出某个时刻各个频点的信号强度, 颜色越亮表示强度越大.

确定候选算法和超参数: 算法选择的候选算法包括决策树、随机森林、支持向量机、KNN、AdaBoost、深度学习 (ResNet50 结构). 本文通过调用 python 中的 scikit-learn 算法库实现机器学习分类算法, 并设置可优化的超参数. 表 2 为候选算法及其采用的超参数的种类, 括号中标注了本文仿真中每种算法可调整的超参数个数.

表 2 候选算法及其采用的超参数表格

算法	超参数
决策树	决策树最大深度、最大特征数、叶子节点最小样本数(3个)
随机森林	决策树个数、决策树最大深度、最大特征数、叶子节点最小样本数(4个)
支持向量机	惩罚系数、核函数类型、核函数系数(3个)
KNN	距离权重、类别数、距离度量函数(3个)
AdaBoost	分类器(决策树)个数、决策树最大深度、最大特征数、叶子节点最小样本数(4个)
深度学习(ResNet50)	神经网络层数、通道数、图像缩放大小(3个)

特征提取: 问题特征包括环境特征和任务特征. 环境特征指图像数据集的干噪比、图像样本数量、干扰类别数量. 任务特征为干扰识别对完成时间和精度的具体需求、任务目标. 在本文中任务目标分为“时间优先”和“精度优先”. “时间优先”是指选择能够在规定时间内完成干扰识别的算法(或超参数)中精度最高的算法(或超参数), “精度优先”是指不考虑干扰识别的完成时间, 选择干扰识别准确率最高的算法. 这些特征数据量构成一个六维的向量.

生成认知案例库: 认知案例由一个问题的特征和标记的最适合该问题的算法和超参数组成. 离线时通过大量测试, 得到对于某个问题选择每种算法及超参数的性能(即识别准确率和耗时), 按照数字序号标记出该问题下的最佳算法和超参数, 结合已经提取的问题特征, 构成认知案例存入认知案例库. 其中, 一部分被用作训练案例, 一部分被用作测试案例.

训练算法超参数选择神经网络: 以问题特征和性能要求、应选的最佳算法和超参数作为一个标记训练样本(即认知案例), 用神经网络作为分类器, 通过特征与合适的算法和超参数之间建立映射关系 $S[f(e, k)]$, 获得合适的一组算法和超参数 $a \in A$. 其中, A 表示候选

的算法和超参数库. 本文采用径向基函数神经网络 (Radial Basis Function Neural Network, RBFNN)^[31] 进行算法选择的训练, 这是一种由输入层、单隐藏层和输出层组成的神经网络结构. RBFNN 的输出表示应选算法和超参数的标号, 可以表示为 $\hat{y}_m = \sum_{j=1}^N w_j k(\tilde{\mathbf{x}}_j, \mathbf{x}_m)$, 其中, 当前的问题特征向量表示为 $\mathbf{x}_m = [x_m^{(1)}, x_m^{(2)}, \dots, x_m^{(L)}]^T$, $m = 1, 2, \dots, M$ 是作为训练样本的认知案例的个数, N 代表隐藏层神经元个数, $k(\cdot, \cdot)$ 为核函数, $\tilde{\mathbf{x}}_j$ 为第 j 个径向基函数的中心(即已被训练过的第 j 个问题的特征向量). 在这里, 使用的是问题特征组成的一个五维向量 $f(e, k)$. w_j 为每个核函数的权重, 利用核递归最小二乘法 (Kernel Recursive Least Square, KRLS) 更新权重的解析解. 为了确定隐藏层中神经元的个数, 本文采用了一种向字典中顺序添加码字的方法——近似线性相关 (Approximate Linear Dependence, ALD) 方法. 对于认知学习来说, 一个码字就是一个认知案例. 在这种情况下, 隐藏单元的数量不需要手动设置, 当各种问题特征的训练样本数量增加时, 隐藏层的大小可以自动扩展.

实现干扰识别任务时, 接收干扰识别数据集和任务需求并提取特征, 利用离线训练好的算法超参数选

择神经网络选出一个合适的算法超参数组合并调用,获得干扰识别的结果.一方面将这个结果输出,另一方面存储当前学习结果.离线阶段对当前认知案例或从认知案例库中随机采样进行重新评估,执行与在线过程相似的步骤,获得离线学习结果,并与历史结果相比较,更新该认知案例,并利用更新后的认知案例库重新训练算法超参数选择神经网络,为下一次干扰识别任务做准备.

4 仿真结果与分析

本文对基于信号时频图的干扰信号样式识别进行了一系列仿真.仿真结果验证本文提出的认知学习框架有3个优势,即自学习能力、适应动态环境和任务变化能力和“良币驱逐劣币”能力.

4.1 仿真设置

本文采用信号发生器产生的不同干扰样式数据集,数据集中共有6种干扰信号:单音干扰(窄带)、单音干扰(宽带)、双音干扰(窄带)、双音干扰(宽带)、线性扫频干扰(窄带)、线性扫频干扰(宽带).每种干扰信号包含3种干噪比(-10 dB、0 dB、10 dB),每种干噪比600个样本,每个样本是长度为655 360的序列,经过STFT变换后生成一张时频图.图4是每一种样本的一个示例图.下文当提到10 dB数据集时是指包含所有10 dB干扰样式时频图的一个数据集.生成认知案例库时,环境特征中,干噪比是指需要进行干扰识别的信号干噪比;图像样本数量是指用于训练的每类干扰识别时频图像的样本数;干扰类别数量是指针对哪些干扰信号类别作训练和识别.任务特征中,完成时间要求从0~6 000 s随机采样50个,准确率要求从60%~100%随机采样50个,任务目标为“时间优先”和“精度优先”两种,因此共有5 000个认知案例.生成认知案例库后,80%作为训练案例,20%作为测试案例.每次测试时,从测试案例中随机选取一定数量的测试样本.




图4 干扰识别样本示例图

本文从算法选择准确率、超参数选择准确率、干扰识别准确率这3个指标验证所提算法的性能.每一种指标取20次仿真的平均值作为最终结果.其中,算法选择准确率、超参数选择准确率是本文构建的度量标


准.对算法(或超参数)选择准确率指标的评估是通过测试选择到的算法(或超参数)是否为标记的最佳算法(或超参数).若是,则认为算法(超参数)选择是准确的.算法和超参数选择准确率会直接影响干扰识别准确率,是反映认知学习算法性能的一个重要指标.干扰识别准确率评估是通过检查根据已选算法及其超参数执行干扰识别的结果是否正确.本文首先验证了基于算法选择的干扰识别准确率,是指选择决策树、随机森林、支持向量机、KNN、AdaBoost、深度学习6种算法之一后,这种算法采取可选的超参数,能够达到的最高干扰识别平均准确率.由于深度学习的超参数选择更具有有一定的代表性,本文以深度学习为例,阐述了超参数选择的影响.本文验证了基于超参数选择的深度学习干扰识别准确率,即如果算法选择的过程中选择到了深度学习算法,采用认知学习选择深度学习超参数后,评估深度学习干扰识别准确率.本文将认知学习(Cognitive Learning, CL)与经典的基于算法选择的元学习(Meta-Learning, MtL)框架进行对比.需要注意的是,用于各个领域的元学习概念不完全一致,本文中所述的元学习框架是指用于算法选择的元学习框架^[27].

4.2 仿真结果分析


4.2.1 自学习能力

考虑利用原始干扰信号时频图像数据集,即4 000个认知案例可用于训练,1 000个认知案例可用于测试.每次仿真中从测试案例库中进行随机无放回采样.


图5描述了在测试次数不断增加时,认知学习框架与具有不同大小元案例空间的元学习框架的性能对比.在这些仿真中,元学习框架在首次测试前得到固定的元示例库.而所提算法可以存储已被测试的案例至认知案例空间,使得认知案例空间的大小不断扩大,通过吸收测试案例作为训练样本对神经网络进行再训练,使得性能逐渐得到改善.图5(a)和(b)验证算法选择准确率和算法选择后的干扰识别准确率时,在第一次测试前,认知学习的训练样本数为10.在第1、2、3、4次测试中,从测试案例库中采样的测试样本个数分别为10、10、20、30.由于离线时将测试样本进行再训练,因此在前5次测试中,认知学习的训练样本数可以认为是10、20、30、50、80.而黑色、蓝色、绿色曲线分别以具有10、20、80元示例的元学习框架为例.因此,在第1、2、5次测试中,认知学习利用的训练样本数分别等于黑色、蓝色、绿色曲线所代表的元学习框架的训练样本数.可以看出,当所提算法的训练样本数等于元学习的元案例个数时,两种方法性能几乎一致.但是随着测试次数的增加,采用本方法得到的算法选择/图像分类准确率、干扰分类准确率提高,而采用元学习框架的性能虽然略有波动,但几乎维持稳定.




(a) 算法选择平均准确率



(b) 基于算法选择的干扰识别平均准确率



(c) 深度学习超参数选择平均准确率



(d) 基于超参数选择的深度学习干扰识别平均准确率


图5 测试次数不断增加时的性能对比

4.2.2 适应动态环境和任务变化的能力


训练和测试认知案例与4.2.1节中相同.但在第一次测试前考虑都仅提供10 dB信号、时间优先的案例

进行预训练.随着测试过程的进行,环境和任务会在10 dB信号时间优先、10 dB信号精度优先、-10 dB信号时间优先间变化,每次测试从相应的测试案例库中无放回采样100个测试案例.

图6展示了所提算法和元学习框架在环境和任务不断动态变化时的性能对比.其中,动态环境意味着测试数据集的变化(即干噪比变化),而动态任务则意味着性能需求的变化(时间优先或精度优先).图6分别展示了环境或任务变化时的算法和超参数选择精度,可以看出如下结果.当一开始第1~2次测试在10 dB数据集上选择“时间优先”的算法时,两种方法的选择精度几乎一致.当第3次测试需求变化为“精度优先”时,无论算法还是超参数选择,两种框架的性能都显著下降.随着测试次数的增加,所提算法的性能迅速提高,然而采用元学习框架得到的算法选择准确率却一直较低.当第8~10次测试任务需求继续变化为“时间优先”,本文方法的性能已经逐渐优于元学习框架.第11次测试中,数据集发生变化,即干噪比由10 dB变为-10 dB.可以看到,使用本文提出的认知学习框架或元学习框架的性能显著下降,但是随着测试次数增加本文方法性能迅速提高,采用元学习框架得到的算法选择准确率却一直较低.与元学习框架相比,认知学习由于其自身架构优势,能够快速适应环境、任务的动态变化,且对于之前已学习的任务仍然能保持良好的性能,从而减少由于无线环境的变化导致干扰识别性能下降



(a) 算法选择平均准确率



(b) 深度学习超参数选择平均准确率

图6 环境任务变化下的性能对比

的问题。

4.2.3 良币驱逐劣币能力

训练和测试认知案例与 4.2.1 节中相同。但考虑预训练时分别有 10% 和 30% 错误标记的仿真情况,每次测试从测试案例库中无放回采样 100 个测试案例。

图 7 展示了所提算法和元学习框架在训练样本中存在不同比例错误标记样本时的性能对比图。“劣币”是指认知案例空间中的错误标签案例。劣币率用错误标记案例的比例来表示。算法或超参数选择的训练样本可能贴错了标签,此时面对测试样本很可能做出一个错误的选择。在预训练时,分别在训练样本中加入 10% 和 30% 的错误标记样本。可以看出,不管错误标记的样本比例是多少,认知学习通过离线性能评估并纠正错误标记样本,算法以及超参数选择准确率、干扰识别准确率都会逐渐得到改善。这是因为一方面,环境和任务特征与算法超参数间的匹配关系得到调整,并存储在认知案例空间,错误标记样本量的比例降低;另一方面,在本文中认知评估模块可以将当前的学习结果与之前的学习结果进行比较,并将评价结果反馈给认知控制模块。而采用元学习框架错误标记样本存储在固定的元示例库,始终受到错误标记样本的影响,性能几乎不变。


综合上述仿真结果,本文提出的算法不受环境和任务变化的影响,能根据动态变化的环境和任务,快速自适应地选择最优的算法和超参数,能有效地完成干扰识别的任务。

5 挑战与未来发展方向


应用认知学习范式来解决电磁频谱问题的研究取得了一定的进展,但考虑到未来更复杂的电磁频谱环境(尤其是战场环境),将其投入到国民生活和国防建设的实际应用中仍然存在如下一些关键技术问题有待解决,也意味着认知学习还有巨大的进步空间。

(1)多模态计算。电磁环境涉及雷达、通信、导航等各个领域,因此电磁信号种类复杂多样,包括电子干扰信号、雷达辐射信号、目标回波信号等。并且在大数据时代,环境中不仅仅只有电磁频谱数据,也存在声音、视频、文本等各种形式的的数据。在认知学习中,高效地融合和利用这些多模态数据,辅助电磁频谱环境中的决策非常有研究价值。其中,一个重要的研究方向就是需要更精细地设计不同模态数据的特征提取,充分保证认知特征的有效和完备。


(2)知识的可解释性。需要让智能体通过学习获得更高层的认知能力和推理能力,最终迈向通用人工智能。智能机器人领域的目标是构建出能够在各种环境中执行广泛任务、具有一般人类智能水平的机器人^[32]。



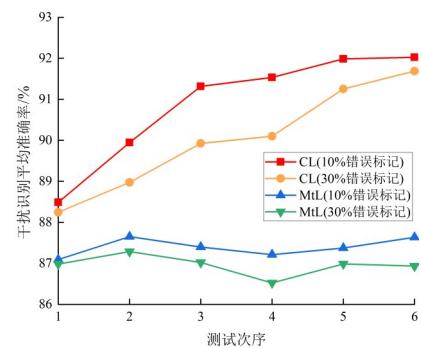
(a) 算法选择平均准确率



(b) 基于算法选择的干扰识别平均准确率



(c) 深度学习超参数选择平均准确率



(d) 基于超参数选择的深度学习干扰识别平均准确率

图 7 存在错误标记样本时的性能对比

可以基于数据和知识双驱动的学习机制,利用知识进一步辅助对数据的学习,增强算法的可解释性。由于认

知学习的案例空间包含知识,可以基于现有的知识图谱等技术,通过对电磁属性的深度挖掘,分析不同时空频电磁频谱数据的规律,从而构建电磁频谱域的知识引擎.在保证算法性能的前提下,增加学习算法的知识推理能力,达到提升神经网络的训练速度与可解释性的效果.

(3)大规模任务.电磁频谱空间每一秒都会产生不计其数的任务和数据,尤其是随着设备数量增加和时间的推移,数据库和知识库会面临内存不够的问题.另外,未来会同时面临无线通信中资源分配、调制分类、干扰分类等更多的任务域,通过认知学习在众多任务域之间选择到合适的算法和超参数是一个挑战.因此,需要找到一种合理的解决方案,在减少数据需求和减少算法复杂度的同时,达到算法精度和效率之间的平衡,满足实时需求.可以先将大规模任务细化拆分成各个子任务,利用分层的思想,用学习算法逐层解决.增量学习、分布式学习的思路也可以借鉴.

(4)学习架构的可扩展性.目前,认知学习的应用主要集中在分类问题方面,如调制识别、干扰识别等,这些都可以总结为图像分类问题,其他领域的问题尚未有充分涉及.事实上,认知学习的思想普遍适用于很多领域.对于认知神经科学的研究有待加深,从而改进出更符合人脑科学的认知学习框架.进一步地,可以探讨在预测问题、优化问题等方面的应用.

6 结语

电磁频谱数据的挖掘与分析在民用和军用方面的作用日趋显著,但也面临着巨大的挑战,例如频谱环境和任务动态变化、高质量标签样本的数量稀缺、频谱决策对高实时性的需求、领域知识利用和迁移的困难.随着新一代人工智能技术向认知智能的跨越式发展,具备对环境的认知能力将是未来电磁频谱空间机器学习研究的必然趋势.本文受脑科学认知机理启发,从频谱特性出发,提出了电磁频谱空间机器学习新范式:认知学习,通过对环境的认知和理解、对自身知识库的更新和完善,可以更稳健地解决复杂电磁频谱环境中的问题.本文探讨了认知学习的理论架构与初步应用,旨在明晰基于机器学习的电磁频谱数据挖掘与分析的未来发展方向之一.在下一步工作中,我们将继续从认知神经科学理论中获得灵感,构建和完善更适配电磁频谱空间的认知学习框架和算法结构.

参考文献

[1] 吴启晖,任敬.电磁频谱空间认知新范式:频谱态势[J].南京航空航天大学学报,2016,48(5):625-632.

WU Q H, REN J. New paradigm of electromagnetic spectrum space: Spectrum situation[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2016, 48(5): 625-632. (in Chinese)

- [2] 李京华,丁国如,徐以涛,等.面向电磁频谱战的群体智能初探[J].航空兵器,2020,27(4):56-63.
LI J H, DING G R, XU Y T, et al. Preliminary study on group intelligence for electromagnetic spectrum warfare [J]. Aero Weaponry, 2020, 27(4): 56-63. (in Chinese)
- [3] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science[J]. Nature, 2019, 566(7743): 195-204.
- [4] PEI J, DENG L, SONG S, et al. Towards artificial general intelligence with hybrid Tianjic chip architecture[J]. Nature, 2019, 572(7767): 106-111.
- [5] WOLPERT D H, MACREARY W G. No free lunch theorems for optimization[J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1): 67-82.
- [6] ELIASMITH C, STEWART T C, CHOO X, et al. A large-scale model of the functioning brain[J]. Science, 2012, 338(6111): 1202-1205.
- [7] BEYER L, HÉNAFF O J, KOLESNIKOV A, et al. Are we done with ImageNet?[EB/OL]. (2020-06-12)[2022-10-01]. <https://arxiv.org/abs/2006.07159>.
- [8] LIU X, SUN Q Q, LU W D, et al. Big-data-based intelligent spectrum sensing for heterogeneous spectrum communications in 5G[J]. IEEE Wireless Communications, 2020, 27(5): 67-73.
- [9] ZENG G X, CHEN Y, CUI B, et al. Continual learning of context-dependent processing in neural networks[J]. Nature Machine Intelligence, 2019, 1(8): 364-372.
- [10] TENENBAUM J B, KEMP C, GRIFFITHS T L, et al. How to grow a mind: Statistics, structure, and abstraction [J]. Science, 2011, 331(6022): 1279-1285.
- [11] AL-SHAWABKA A, RESTUCCIA F, D'ORO S, et al. Exposing the fingerprint: Dissecting the impact of the wireless channel on radio fingerprinting[C]//IEEE INFOCOM 2020 - IEEE Conference on Computer Communications. Toronto: IEEE, 2020: 646-655.
- [12] MAJUMDER U K, BLASCH E P, GARREN D A. IEEE radar conference 2019 tutorial session I machine learning techniques for radar ATR: Monday, April 22, 2019 time: 11: 00AM - 3: 00PM[C]//2019 IEEE Radar Conference (RadarConf). Boston: IEEE, 2019: 1-93.
- [13] SUN Y H, PENG M G, ZHOU Y C, et al. Application of machine learning in wireless networks: Key techniques

- and open issues[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(4): 3072-3108.
- [14] ZHOU F H, LU G Y, WEN M W, et al. Dynamic spectrum management via machine learning: State of the art, taxonomy, challenges, and open research issues[J]. *IEEE Network*, 2019, 33(4): 54-62.
- [15] HUSSAIN F, HASSAN S ALI, HUSSAIN R, et al. Machine learning for resource management in cellular and IoT networks: Potentials, current solutions, and open challenges[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(2): 1251-1275.
- [16] 方芳, 李永贵, 牛英滔, 等. 基于决策树算法的干扰信号识别[J]. *通信技术*, 2019, 52(11): 2617-2623.
FANG F, LI Y G, NIU Y T, et al. Jamming signal recognition based on decision tree algorithm[J]. *Communications Technology*, 2019, 52(11): 2617-2623. (in Chinese)
- [17] 徐国进. 典型通信干扰信号识别技术研究[D]. 成都: 电子科技大学, 2018.
XU G J. Research on Identification of Typical Communication Jamming Signals[D]. Chengdu: University of Electronic Science and Technology of China, 2018. (in Chinese)
- [18] 朱鹏程. GNSS 干扰检测与识别技术研究[D]. 重庆: 重庆大学, 2018.
ZHU P C. Research on GNSS Interference Detection and Identification Technologies[D]. Chongqing: Chongqing University, 2018. (in Chinese)
- [19] 郝万兵, 马若飞, 洪伟. 基于时频特征提取的雷达有源干扰识别[J]. *火控雷达技术*, 2017, 46(4): 11-15.
HAO W B, MA R F, HONG W. Radar active jamming identification based on time-frequency characteristic extraction[J]. *Fire Control Radar Technology*, 2017, 46(4): 11-15. (in Chinese)
- [20] SHEN A, LIU Y, ZHANG Y, et al. The method of interference recognition in mobile communication network based on deep learning[C]//International Conference on Signal and Information Processing, Networking and Computers. Singapore: Springer, 2019: 296-306.
- [21] 练东海. 基于深度学习的无线通信干扰信号识别与处理[J]. *通信电源技术*, 2021, 38(2): 104-107.
LIAN D H. Deep learning based wireless communication interference signal recognition and processing[J]. *Telecom Power Technology*, 2021, 38(2): 104-107. (in Chinese)
- [22] 党泽. 基于深度学习的无线通信干扰信号识别与处理技术研究[D]. 成都: 电子科技大学, 2020.
- DANG Z. Research on the Technology of Wireless Communication Interference Signal Identification and Processing Based on Deep Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2020. (in Chinese)
- [23] 杨岚, 肖海涛, 张渭乐. 基于频带相关性 Deep Learning 的无线通信干扰智能识别[J]. *航空科学技术*, 2022, 33(4): 108-118.
YANG L, XIAO H T, ZHANG W L. Intelligent jamming identification based on deep learning with frequency band correlation for wireless communication[J]. *Aeronautical Science & Technology*, 2022, 33(4): 108-118. (in Chinese)
- [24] 刘华祠. 基于传统机器学习与深度学习的图像分类算法对比分析[J]. *电脑与信息技术*, 2019, 27(5): 12-15.
LIU H C. Comparative analysis of image classification algorithms based on traditional machine learning and deep learning[J]. *Computer and Information Technology*, 2019, 27(5): 12-15. (in Chinese)
- [25] KERSCHKE P, HOOS H H, NEUMANN F, et al. Automated algorithm selection: Survey and perspectives[J]. *Evolutionary Computation*, 2019, 27(1): 3-45.
- [26] 崔建双, 刘晓婵, 杨美华, 等. 基于元学习推荐的优化算法自动选择框架与实证分析[J]. *计算机应用*, 2017, 37(4): 1105-1110.
CUI J S, LIU X C, YANG M H, et al. Meta-learning based optimization algorithm selection framework and its empirical study[J]. *Journal of Computer Applications*, 2017, 37(4): 1105-1110. (in Chinese)
- [27] KHAN I, ZHANG X C, REHMAN M, et al. A literature survey and empirical study of meta-learning for classifier selection[J]. *IEEE Access*, 2020, 8: 10262-10281.
- [28] 任义, 迟翠容, 单菁, 等. 基于元学习的推荐算法选择优化框架实证[J]. *计算机工程与设计*, 2020, 41(6): 1610-1616.
REN Y, CHI C R, SHAN J, et al. Empirical study on recommendation algorithm selection optimization framework based on meta-learning[J]. *Computer Engineering and Design*, 2020, 41(6): 1610-1616. (in Chinese)
- [29] WU Q H, RUAN T C, ZHOU F H, et al. A unified cognitive learning framework for adapting to dynamic environments and tasks[J]. *IEEE Wireless Communications*, 2021, 28(6): 208-216.
- [30] BRITTO A S, SABOURIN R, OLIVEIRA L E S. Dynamic selection of classifiers—A comprehensive review[J]. *Pattern Recognition*, 2014, 47(11): 3665-3680.

- [31] BOHN B, GRIEBEL M, RIEGER C. A representer theorem for deep kernel learning[EB/OL]. (2017-09-29)[2022-10-01]. <https://arxiv.org/abs/1709.10441>.
- [32] KAELBLING L P. The foundation of efficient robot learning[J]. Science, 2020, 369(6506): 915-916.

作者简介




阮天宸 男,南京航空航天大学电子信息工程学院/集成电路学院在读博士生. 主要研究方向为认知学习、信号源识别与搜索.

E-mail: ruantianchen@nuaa.edu.cn



吴启晖(通讯作者) 男,南京航空航天大学特聘教授、副校长,教育部“长江学者”特聘教授,南京航空航天大学电子信息工程学院/集成电路学院教授、博导. 主要研究方向为认知科学与应用、电磁空间频谱认知智能管控、无人机认知集群.

E-mail: wuqihui@nuaa.edu.cn



赵世瑾 女,南京航空航天大学电子信息工程学院/集成电路学院在读博士生. 主要研究方向为认知强化学习、视觉导航.

E-mail: shijin_zhao@nuaa.edu.cn



周福辉 男,国家优秀青年基金获得者,南京航空航天大学电子信息工程学院/集成电路学院教授、博导. 主要研究方向为频谱智能管控和资源鲁棒优化、认知智能与知识图谱.

E-mail: zhoufuhui@nuaa.edu.cn



黄洋 男,南京航空航天大学电子信息工程学院/集成电路学院副教授. 主要研究方向为强化学习、深度学习、最优化理论、协同智能、频谱管控.

E-mail: yang.huang.ceie@nuaa.edu.cn