



一种面向复杂场景的无线通信节点智能适变架构

尹浩^{1,2}, 魏急波², 赵海涛², 熊俊², 梅锴², 张利军³, 任保全^{1*}, 马东堂²

1. 军事科学院, 北京 100076

2. 国防科技大学电子科学学院, 长沙 410073

3. 南京大学计算机软件新技术国家重点实验室, 南京 210023

* 通信作者. E-mail: renbq@126.com

收稿日期: 2020-03-01; 接受日期: 2020-04-09; 网络出版日期: 2021-02-01

国家自然科学基金 (批准号: 61931020) 资助项目

摘要 针对可能存在对抗的未知通信环境, 本文探讨了一种能进行智能适变的通信节点体系架构. 该架构包括通信环境理解、通信波形适配和智能节点学习进化 3 个核心功能, 以及支持这些功能的通信计算融合硬件平台. 所提出的智能适变架构支持通信环境知识库、通信波形库, 以及波形与环境适配知识图谱的不断累积和进化, 通过波形在线重构, 通信节点既能匹配典型通信场景, 又能快速适应未知环境, 因而支持智能通信节点的可持续发展. 进一步本文梳理了强化学习、在线学习和迁移学习等 3 种机器学习技术在智能适变无线通信节点中的应用, 并以最经典的信道估计过程为代表, 给出了机器学习应用于通信环境识别的典型范例.

关键词 智能节点, 通信环境理解, 智能适变, 学习生长, 机器学习, 信道估计

1 引言

通信要解决的核心问题是如何在接收端正确恢复出发送端所传递的信息. 1948 年 Shannon 在其划时代的著作《通信中的数学原理》^[1] 中, 抽象出了信息传输的经典系统模型, 系统分析了信道对信号造成的损伤, 提出了著名的信道容量公式, 对如何有效进行传输做出了详细的论述, 并重点关注了如何使用编码来提升系统性能. 从此, 人们就致力于消除信号损伤对信息传输的影响, 不断追求达到最大信道容量的通信系统设计. 无线通信系统的设计也是先建立通信系统的典型信道模型, 再根据模型和典型应用场景, 设计通信体制, 并经过反复迭代, 形成国际或业界的通信标准.

信道模型来源于对通信环境的测量, 为了完成对通信环境的认知, 人们进行了大量的典型通信环境测量以提供无线信道的参考模型^[2]. 如果将某一典型环境中所有通信信道看作是一个样本库, 信道测量实际上仅仅获得了有限的样本, 参考信道模型也只反映了这些有限样本的统计特性. 然而, 在实

引用格式: 尹浩, 魏急波, 赵海涛, 等. 一种面向复杂场景的无线通信节点智能适变架构. 中国科学: 信息科学, 2021, 51: 294–304, doi: 10.1360/SSI-2020-0038
Yin H, Wei J B, Zhao H T, et al. An intelligent adaptative architecture for wireless communication in complex scenarios (in Chinese). Sci Sin Inform, 2021, 51: 294–304, doi: 10.1360/SSI-2020-0038

际通信中,某一次通信所面对的是特定的信道样本,以这样事先完成的信道模型为参考而设计的通信系统往往达不到期望的通信性能.具体而言,其原因主要有三:首先,实际通信环境与信道测量时的环境可能并不一致.比如在 4G 扩展信道模型中给出了典型的市区信道模型,但实际环境中同样是市区,在不同的地点其市区环境并不完全相同.而且任何建筑物的修建或拆除、公园植被的增加或减少都会引起通信环境的变化,这些实时环境变化并不能在静态的参考信道模型中得以反映.其次,实际通信环境中还有干扰的存在.在参考信道模型建立过程中,主要考虑了物理环境对信号的反射、折射或散射等.而实际场景中,诸多通信设备不可避免产生相互的干扰,甚至可能存在恶意的干扰,这些物理信息环境动态变化的电磁干扰也无法在事先测量的典型信道模型中实时、准确地反映出来.第三,由于通信的突发性、紧急性和信道环境的复杂性等因素造成来不及通过测量或者根本无法建立准确的信道模型,如无人机编队应用、灾害应急等.

为了应对上述问题,目前的解决方法主要分为两种.第 1 种方法是增加网络资源、缩短通信双方的距离,例如在商用移动通信系统中,可以通过补充部署大量的基站、小基站和微基站等来利用更多的资源换取更佳的性能.第 2 种方法是设计自适应的通信系统,即在一定的规则下,“当发生某种情况时,执行某种改变”,由于制定的规则集必定是有限的,这类方法可实现有限规则下的有限适应.这两种方法都不能解决我们在实际中遇到的两大类场景:一是没有基础设施可用的网络,特别是在诸如军事行动、受灾区域救援等许多应用场景中,由于潜在的应用场景是未知的,既无法事先进行信道测量也无法快速部署大量的基站.二是存在对抗的复杂通信场景,因为通信对抗是无法预先设计出来的,其通信系统的设计是不可知规则下的优化设计.因此,迫切需要通信系统具有智能适变的能力,即通信节点能够适应动态的环境变化,持续提供稳定的信息传输.

要完成对通信环境的智能适变是个复杂的问题,因为影响性能的环境因素包括网络空间用户行为、频谱利用情况和信号传输路径周围的物理信道环境等.与之对应,通信系统需要对网络路由、使用频段、射频控制,以及传输的调制、编码、功率等多维参数做出调整.近年来人工智能技术的快速发展和广泛验证,为解决上述问题提供了可能的解决途径^[3].包括机器学习在内的人工智能技术拥有比传统信号处理技术更强的数据分析能力,在图像识别等领域已经取得了瞩目的成果^[4].这种潜在的能力,可以被应用到对通信环境的分析中,为通信系统的性能带来质的提升.很多学者已在基于人工智能解决无线通信中所面临瓶颈问题方面做了诸多有益尝试,将人工智能技术应用于认知无线电^[5,6]、软件定义网络^[7]、5G 系统^[8]、物联网^[9]、无人机网络^[10,11]和面向未来的智能网络^[12,13]设计中.

本文试图针对可能存在对抗的未知通信环境,探讨利用机器学习等人工智能技术来建立智能无线通信节点所面临的基础性问题和研究方向.智能节点可以将物理层的接收信号与设备对内容的理解相结合,完成对通信环境的准确认知和理解,并自主完成对通信环境的适配.更进一步,节点还具备学习能力,能不断扩充知识图谱,对遇到过的场景迅速甄别和适配,对未遇到过的场景能通过推理快速适变.

本文分成以下几个部分:第 2 节提出一种基础的面向适变的智能节点架构,并描述架构中涉及的 3 个方面科学问题;第 3 节分析了机器学习在通信节点进行智能适变过程中可能的应用;第 4 节基于一个通过数据训练的信道估计范例来说明基于机器学习进行通信场景感知和识别的可行性;第 5 节给出了对本文的研究进行小结.

2 面向复杂场景的无线通信节点智能适变架构

在构建智能节点的体系架构前,先思考一下我们最熟悉的人与人之间的沟通方式和过程.人与人




图 1 (网络版彩图) 面向智能适变的无线通信节点的体系结构
Figure 1 (Color online) Architecture for intelligent adaptive wireless communication nodes

之间的沟通往往是期望达到“心有灵犀一点通”，这其实是一种非常高效的沟通方式。要达到这个目标并非易事，但也是有章可循的。具体而言，需要具备至少以下 3 个方面的能力：首先，沟通双方要在恰当的环境和时机下进行沟通，即能对环境有清楚的认知；其次，沟通过程中，双方根据情况的变化选择了最合适的语言或沟通方式，即具有适变能力；第三，沟通的双方都“通情达理”、理解背景，既有一定的知识图谱为基础，又能根据新掌握的信息迅速做出推理。这种通信方式是高效的，因为它可以根据环境的变化，用最合适的资源和方式达到最佳的沟通效果。与此类似，要使通信节点也实现这种智能通信的能力，需要具备对环境的认知和理解能力、应对不同环境选择恰当通信方式的适变能力，以及能根据知识图谱和获取的新知识进行推理和增强的进化能力，这些都需要通信节点有丰富的感知、计算、存储和通信资源进行支持，其体系架构可以描绘如图 1 所示。此体系架构为实现节点的智能适变提供了可能，而要将人类的高效沟通和对环境的适应能力推行到通信节点上，仍有 3 个方面的基础性问题需要解决。

(1) 基础性问题一：基于多域信息的通信环境理解。

网络节点准确理解通信环境是其进行适变的基础。然而“什么是通信环境？”、“它与复杂电磁环境、信道模型是什么关系？”等基础性问题还需要深入研究。为此智能节点需要将感知到的影响通信的环境信息进行融合以准确、全面地理解当前所处的通信环境。这一基础性问题将面临两方面的挑战：首先，通信环境不仅仅是频谱环境。频谱资源、地理位置、信道状态等都对节点的通信环境产生重要影响，而这几者之间又是相互关联的。因此需要将其关联性进行建模，提取无线信道的特征，以对通信环境进行准确的认知。其次，感性世界和知识世界需要统一起来，即需要将网络节点所感知到的多维信息融合为其可理解和操作的知识描述，才能直接为智能通信决策提供支撑。

(2) 基础性问题二：通信波形对通信环境的智能适配。

对于特定的通信环境，网络节点如何能做出最佳通信决策、实时进行波形的重构，从而达到通信波形对环境的最佳适配（在这里我们统一把传输体制和协议定义为一个波形）？这一基础问题是实现

适变的关键,该问题的解决将面临 3 方面的挑战:首先,面向特定环境的匹配波形和优化配置需要建立完备的理论依据.什么样的波形适合当前的信道环境,以及不同因素对通信性能的定量影响等都需要这一理论的支撑;其次,需要构建细粒度的软件可定义波形架构,以支撑波形的重构和优化.波形的软件定义和细粒度重构是实现最佳波形匹配的基础,而当前的波形都是固定和封闭的,不具备环境适配能力.需要突破传统的波形设计框架,建立软件定义、可细粒度重构的通信波形体制;第三,实际中通信波形不可能是任意粒度可重构的,如何通过离散的波形重构来逼近性能上限?这一问题也需要深入的研究.

(3) 基础性问题三:适应未知通信环境的学习和生长机制.

具备智能适变能力的节点不是固化不变的,而是可进化、可生长的.如何让智能节点形成“理解-适变-进化”的环路,不断学习进化,并可迁移适应未知的通信环境?本基础性问题的解决也面临 3 个方面的挑战:首先,智能节点需要具备学习能力,能对通信的控制决策进行自我完善,从而可应对无法预知的对抗环境,并可不断生长、变强大;其次,动态无线通信场景中面临很多未知的通信场景,是知识库中所不具备的,在适应当前通信场景的同时,智能节点需要具备知识表示能力,可完成数据、知识和经验的积累;第三,智能网络节点在学习和生长过程中,要利用计算能力(即个体推理),减少控制信息交互,不会因为进化功能而消耗不必要的珍贵计算、存储和通信资源.

3 机器学习在通信节点智能适变中的应用

机器学习可以从以下 3 个方面助力实现无线通信的智能适变:机器学习可望通过对复杂通信环境感知数据的挖掘、分析、融合和推理,为准确感知无线通信环境提供支撑;机器学习可以针对所认知的无线信道环境,快速匹配多维通信参数,设计出与环境相适应的最佳通信波形;机器学习可以为通信设备安装“大脑”,使其在适变的迭代过程中具备自我学习和进化的能力.具体而言,笔者认为强化学习、在线学习和迁移学习 3 类方法将在智能节点相关技术的研究中发挥重要作用,其中强化学习和在线学习能够对通信环境的理解和适变提供支撑,而迁移学习则会支撑节点的学习进化以快速适应未知的通信环境,如图 2 所示.

3.1 强化学习的应用

强化学习是一类特殊的机器学习范式,智能体通过与所在环境进行交互来学习决策策略,旨在最大化长期累积奖赏^[14~16].强化学习无法提前获得训练数据,这是强化学习与其他机器学习方式(比如监督学习)的主要不同点,智能体需要通过和环境的交互来获得反馈,并且在和环境的交互中改变环境的状态.同时,强化学习中的反馈通常不是实时的,智能体在执行一个动作之后继续与环境交互,一定时间后才能获得环境给与的评价及新的环境状态,从而推断之前动作的好坏.这种主动交互的性质,使得强化学习适用于对通信环境的理解、识别和通信波形适配上.强化学习也有很多研究分支,可以应对不同的智能通信问题,主要包括基于表格的强化学习、策略梯度强化学习、深度强化学习,以及多智能体强化学习等.

在简单的通信自适应场景中,如果节点动作空间和状态空间都是离散的且规模较小,可将 Monte-Carlo 的采样思想与动态规划的更新方式结合可以取得较好的学习策略.此类方法首先通过采样对状态值函数和状态-动作对函数进行估计,用表格记录下来,然后通过与环境不断交互,获得新样本来更新表格内的值,其中经典的学习算法包括时序差分(TD)学习算法^[17,18]、Sarsa 学习算法^[19],以及 Q-学习算法^[20]等.不过,在实际智能通信的问题中我们经常会遇到连续的状态空间以及动作空




图 2 (网络版彩图) 机器学习在智能通信中的应用

Figure 2 (Color online) Application of machine learning in intelligent communication

间, 由于函数空间的扩大, 此时基于表格的学习算法难以进行有效的学习, 我们可以采用基于策略梯度的学习方法, 比如最具代表性的 Actor-Critic 算法^[21]. 更进一步, 在面对更复杂的通信环境时, 我们可以利用深度学习来获得高维数据的低维特征, 将处理过的特征作为强化学习算法的输入, 提升算法的性能. 将具有感知能力的深度学习和具有决策能力的强化学习相结合, 就是最近兴起的深度强化学习^[22]. 更进一步, 从网络的角度来看, 由于在网络场景中不止存在一个通信节点, 即存在多个处理问题的主体, 因此更适合将多智能体系统看作强化学习的主体. 多智能体系统的强化学习, 不仅要考虑学习任务本身, 还要对智能体之间的相互关系进行相应的建模. 博弈论这一数学工具能够为多智能体强化学习提供相应的建模分析方法^[23]. 在多智能体模型中, 每个智能体获得的回报不仅取决于自身的动作, 同时还依赖于其他智能体的动作.

总而言之, 将恰当的强化学习技术应用于通信节点的智能化处理场景可以对变化的环境有更好的适应性, 能提高通信系统的自主处理能力.

3.2 在线学习的应用

在复杂的电磁环境下, 通信环境中的干扰呈现不可预测性, 用户每次选择环境适配方案 (或者抗干扰策略) 时, 并不知道环境在接下来的时段会发生什么变化 (或采用何种干扰策略). 因此, 该问题并不能通过传统的最优化问题来建模, 但可以利用在线优化的思想建模为在线学习问题. 在线学习是一种强大的学习框架, 可以用于多种机器学习任务^[24]. 在线学习可以描述为一个学习器和对手之间的博弈过程: 在博弈的第 t 轮中, 学习器首先从决策集 W 中选择一个决策 w_t , 同时对手选择一个损失函数 f_t . 接着, 学习器观测到损失函数, 并遭受损失 $f_t(w_t)$. 衡量在线学习效果的指标是遗憾 (regret), 定义为学习器的累计损失与最优决策累计损失的差. 通过刻画遗憾的上界, 我们能够比较学习器和最优决策的性能差异. 在这里, 最优决策指的是提前看到所有损失函数情况下所选择的能最小化累计损失的决策. 在过去数十年中, 针对不同的应用场景, 研究人员已经提出了多种具有次线性遗憾界的在线学习算法^[24, 25].

当决策集包含有限个元素时,研究者将在线学习形式化为基于专家建议的在线学习,每一个元素被认为是一个专家^[24].在这个学习框架中,假设存在 N 个专家可以对未来进行预测,学习器可以观测到专家的预测结果,进而做出自己的判断.利用多项式加权平均预测器和指数加权平均预测器,能够设计出有效的在线学习算法,取得很小的遗憾.近期,许多研究工作开始借助优化理论来丰富和发展在线学习,提出了在线凸优化这样的学习框架^[25].在这种学习框架中,假设决策集 W 是凸集合,损失函数 f_t 是定义在该集合上的凸函数.与基于专家建议的在线学习相比,在线凸优化的优势在于其解空间是凸集合,因此可以存在无穷个元素,并且算法的性能跟元素个数无关,这特别适合无法确定边界的复杂(甚至存在干扰)的电磁环境.在大多数实际应用中,环境通常会发生变化,最优决策也会随之改变.在这种情况下,不再存在一个固定的最优决策可以取得较小的累积损失,最小化遗憾无法保证学习器取得较小的累计损失.以智能通信为例,由于通信性能直接受通信环境、敌方干扰策略、己方抗干扰策略,设置人为操作等众多因素影响,最优的通信策略会频繁的变化.为了更好地衡量动态环境中学习器的效果,研究人员在遗憾的基础上分别提出了自适应遗憾和动态遗憾两个新的指标^[26,27],并提出了一系列针对动态环境的在线学习算法^[28].

传统的在线学习也被称为完全信息在线学习,因为算法假设学习器可以观测到损失函数,可以计算其梯度、黑塞矩阵等信息,辅助学习器更新决策.而在许多现实应用中,学习器能够观测到损失函数这种假设是不成立的,使得现有的在线学习算法不能被直接应用.对于智能通信,当我们没有合适的损失函数来表示某种物理现象背后的机制时,就面临了反馈不充分的学习问题.这种反馈不充分的在线学习被称为赌博机在线学习^[29].因为观测的不充分,赌博机在线学习存在探索和利用之间的困境.一方面,为了准确地估计损失函数的结构,学习器需要尝试更多的新决策;而另一方面,为了最小化遗憾,学习器又倾向于选择能最小化损失的决策.置信上界和指数加权是用来解决探索和利用之间困境的常用策略,前者适用于损失函数是随机产生的情况,后者针对非随机情况.

由上可以看出在线学习包含许多关键技术,对于对抗环境下智能节点的适配通信,需要根据实际问题,选择合适的在线学习算法.

3.3 迁移学习的应用

面对陌生地域的战场环境,通信的干扰形式可能不同,短时间内难以获得大量新环境下的数据使系统达到良好的工作状态.这时,就需要对已知环境下的数据进行处理,将新旧数据结合使用,从而在最短时间内实现通信节点的参数重配置.该问题可以通过迁移学习的方法解决.

在应用迁移学习的过程中,必须先回答以下 3 个问题^[30]: (1) 迁移什么:有些知识是各个领域独有的,而也有一部分知识是多个领域之间共享的,迁移不同领域共享的知识才能提升性能. (2) 何时迁移:如果两个领域并不相关,强行迁移并不会改善系统性能,反而会使事情更糟(也称为负迁移).因此,需要根据各个具体问题判断是否应该进行迁移学习. (3) 如何迁移:当明确何时迁移以及迁移哪些知识后,就可以进一步确定在领域/任务间实际迁移知识的方法.

迁移学习按照特征分类可分为同构迁移学习、异构迁移学习^[31].如果特征语义和维度相同,就是同构,否则就是异构.智能通信领域面临的问题主要是同构情况.对于同构迁移学习,如果我们拥有一个和目标领域相关的数据集,那么使用同构迁移的方法可以为目标领域学得一个模型^[31].已有工作按照学习方法可以分为基于样本、特征、模型、关系等 4 种类型^[30],其中前三者在智能通信节点的研究中大有用武之地.下面结合具体的迁移学习方法讨论其在智能节点研发中的应用.

基于样本的迁移学习基本出发点是:尽管不能直接使用目标领域的数据,但是存在一部分可以重用的数据和少量目标领域的有标记数据^[30].针对样本迁移可以采用 TrAdaBoost 算法^[32].该算法假

定源域和目标域的数据特征以及标记都相同, 但是数据的分布不同, 通过一种迭代的方式, 不断对样本重新赋予权重, 减小不好源域数据的影响, 增加有用源域数据的比重. 例如, 在智能通信的问题设定下, 当系统迁移到一个新的环境中, 新环境与老环境之间仅仅是数据的分布发生了改变, 数据的特征空间并没有发生变化. 此时通过对已有样本进行重新赋权, 改变已有样本的分布, 可以在一定程度上弥补新环境样本不足的问题, 加速系统对新环境的适应.

基于特征的迁移学习旨在找到一个好的特征表示使得源域和目标域的差异尽可能小^[30]. 如果源域中有标记数据充足就利用监督学习的方法构造特征; 如果源域有标记数据不足, 就采用无监督的方法进行特征学习. 在智能通信的问题设定下, 新环境和旧环境的特征分布可能不同, 但是可以通过特征迁移方法, 利用旧环境中的数据辅助构造一个更好的特征表示, 提取更一般化的特征, 从而辅助模型的训练. 有监督的特征学习如文献 [33], 无监督的特征学习如文献 [34]. 随着深度学习的发展, 对于深度学习中的特征迁移也有相关研究成果出现^[35].

模型迁移假设对应各个相关任务的模型共享部分参数、先验分布或者超参数^[30]. 模型迁移比样本迁移更加直接, 也更加省时. 最简单的应用方式就是深度学习中的 fine-tune, 基于已公开的模型, 通过微调网络的部分权重, 可以避免从零训练, 加速神经网络的收敛. 例如, 对某一特定环境, 已经训练好了一个神经网络, 对于不同的环境, 神经网络中提取环境特征的部分很可能是接近的, 我们可以复用这部分参数. 通过共享这些相似的模型参数, 可以有效地节约目标模型的训练成本, 加快训练速度, 提高训练结果的质量.

综上, 将迁移学习应用到智能节点对未知通信环境的适应中有其可行性, 通过挖掘不同环境之间的共性, 可以一定程度上利用已有的数据和模型实现迁移.

4 范例: 基于机器学习的信道估计方法

由于通信场景感知是通信节点智能适变的基础, 在传统通信中通信场景主要是通过信道模型来体现的. 在本节, 我们就以信道估计为例来说明将机器学习方法用于通信场景识别的可行性^[36].

区别于传统方法直接求解统计模型下的估计表达式, 基于机器学习的信道估计将信道模型看作黑盒子, 通过针对有限数据样本的优化, 来获得在数据总体下有效的信道估计器. 与统计抽样的基本规律一致, 在基于机器学习的信道估计中, 训练样本量越大, 针对数据样本的优化所获得的估计器在所有可能数据下的平均性能就会越好. 所以, 该方法要获得理想性能, 其先决条件是有理想的训练数据集作为支撑, 针对这一个特性, 我们建模分析了训练数据集与学习性能的关系, 为了得到明确简洁的结果, 做如下假设: (1) 学习算法总能得到在训练数据上损失函数最小的映射; (2) 输出的误差服从 Gauss 分布; (3) 训练数据相互独立, 由此可以得到图 3(a) 所示学习性能与训练数据量的关系. 图中, 放缩性能上界在估计问题中是指学习所得的估计器的 MSE (mean squared error) 与最佳估计的 MSE 之差的上界除以最佳估计的 MSE, 当该值为 0.1, 表明性能损失上界比最佳性能低一个数量级, 所以很大概率可以通过学习得到有效估计. 此时数据量约为 1200, 由于基带信号为复数, 含实、虚两部分, 在估计问题, 需要提供的样本量约为 600, 我们在 64 子载波的 OFDM 系统中验证了此结论, 仿真结果如图 3(b) 所示, 仿真中信道为线性平稳系统, 且信道衰落服从复 Gauss 分布, LMMSE (linear minimum mean squared error) 估计为最优估计, 采用 600 训练数据, 学习模块为线性结构的估计器性能与 LMMSE 十分接近.

在原理分析中发现, 训练数据不是必须用准确信道响应作为标签, 当标签受噪声影响发生偏差时, 依然可以得到有效估计器, 只是需要的训练数据量更大. 我们将此类估计方法归纳称为数据驱动的信道估计, 其框架如图 4 所示.




图 3 (网络版彩图) 学习性能仿真

Figure 3 (Color online) Simulation of learning performance. (a) Data volume and learning performance; (b) simulation of learning performance




图 4 (网络版彩图) 数据驱动信道估计框架

Figure 4 (Color online) A framework for data-driven channel estimation

图 4 中, $\hat{h}_s$ 表示含噪信道响应, 可以是性能最差的 LS (least square) 估计, 也可以是最理想的准确信道响应, $\hat{h}_p^{LS}$ 表示利用多个导频对多个信道响应的 LS 估计, $\hat{h}_s$ 中的噪声需要与 $\hat{h}_p^{LS}$ 独立. 学习模块的设计自由度较高, 可以采用线性结构、具有非线性拟合能力的神经网络 (ANN)、深度神经网络 (DNN) 等多种机器学习方法. 我们的研究解决了国内外相关研究面临的两大难题: (1) 产生训练数据时需要用准确的信道响应, 而实际系统中准确的信道响应无法获取; (2) 训练数量大, 导致在实际系统中生成训练数据以及后续对学习模块的训练需要付出很高的代价. 基于该数据驱动的信道估计框架, 结合对该类方法的理论分析, 在目前常用的帧结构下也可以相应地设计出低复杂度数据驱动的信道估计.

我们针对梳状导频的 OFDM 系统设计了二阶数据驱动的插值器, 导频结构如图 5(a) 所示, 首先发送训练符号用于学习二阶插值系数, 接着发送数据符号. 从图 5(b) 的仿真结果可以看到, 通过一个训练




图 5 (网络版彩图) 数据驱动的插值器

Figure 5 (Color online) Data-driven interpolator. (a) Data frame structure; (b) simulation of learning performance

符号学习得到的插值器性能明显优于线性插值器, 当发送 3 个训练符号用于学习二阶插值系数时, 性能十分接近 MMSE (minimum mean squared error) 插值. 这也说明了这种基于机器学习的数据驱动的信道估计方法是行之有效的, 可以使通信节点识别未知的通信环境, 进而支持通信节点进行智能适变.

5 结束语

无线通信智能适变技术希望基于人工智能为通信系统的设计与优化提供一种超越传统理念与性能的可能, 该技术既可利用已有的信道模型, 又可摆脱传统无线通信系统设计中信道模型的高度依赖, 可迅速适应环境的动态变化甚至是未知环境, 进行通信波形的自主重构, 从而达到对通信环境的适配. 而且随着在应用过程中网络自身知识的积累和推理能力的增强, 智能节点还可实现进化功能, 其通信能力和性能也会不断提高.

具备智能能力的网络节点研究和实现涉及到的科学问题多、专业面广, 尽管目前各学科专业也有很多成果, 但还没有一个完整合适的体系架构来支持网络节点的智能进化, 其中还有很多理论和具体的技术问题亟需进一步深入研究. 不过随着通信技术和人工智能技术研究的不断推进和局部验证的开展, 我们有理由期待该技术将会引起通信系统设计的变革.

参考文献

- Shannon C E. A mathematical theory of communication. Bell Syst Tech J, 1948, 27: 379–423
- Wang C X, Bian J, Sun J, et al. A survey of 5G channel measurements and models. IEEE Commun Surv Tut, 2018, 20: 3142–3168
- Zhou Z H. Machine learning: recent progress in China and beyond. Natl Sci Rev, 2018, 5: 20
- Zhuang Y T, Wu F, Chen C, et al. Challenges and opportunities: from big data to knowledge in AI 2.0. Front Inform Technol Electron Eng, 2017, 18: 3–14
- Bkassiny M, Li Y, Jayaweera S K. A survey on machine-learning techniques in cognitive radios. IEEE Commun Surv Tut, 2013, 15: 1136–1159
- Wei J B, Wang S, Zhao H T. Cognitive wireless networks: key techniques and state of the art. J Commun, 2011, 32: 147–158 [魏急波, 王杉, 赵海涛. 认知无线网络: 关键技术与研究现状. 通信学报, 2011, 32: 147–158]
- Xie J, Yu F R, Huang T, et al. A survey of machine learning techniques applied to software defined networking (SDN): research issues and challenges. IEEE Commun Surv Tut, 2019, 21: 393–430

- 8 You X H, Zhang C, Jin S, et al. AI for 5G: research directions and paradigms. *Sci Sin Inform*, 2018, 48: 1589–1602
[尤肖虎, 张川, 金石, 等. 基于 AI 的 5G 技术 —— 研究方向与范例. *中国科学: 信息科学*, 2018, 48: 1589–1602]
- 9 Li J X, Zhao H T, Hafid A S, et al. A bio-inspired solution to cluster-based distributed spectrum allocation in high-density cognitive Internet of things. *IEEE Int Thing J*, 2019, 6: 9294–9307
- 10 Wang H J, Zhao H T, Zhang J, et al. Survey on unmanned aerial vehicle networks: a cyber physical system perspective. *IEEE Commun Surv Tut*, 2020, 22: 1027–1070
- 11 Zhao H T, Wang H J, Wu W Y, et al. Deployment algorithms for UAV airborne networks toward on-demand coverage. *IEEE J Sel Areas Commun*, 2018, 36: 2015–2031
- 12 Fadlullah Z M, Tang F X, Mao B M, et al. State-of-the-art deep learning: evolving machine intelligence toward tomorrow's intelligent network traffic control systems. *IEEE Commun Surv Tut*, 2017, 19: 2432–2455
- 13 Zhao H T, Ding K Q, Sarkar N I, et al. A simple distributed channel allocation algorithm for D2D communication pairs. *IEEE Trans Veh Technol*, 2018, 67: 10960–10969
- 14 Chen X G, Yu Y. Reinforcement learning and its application to the game of go. *Acta Autom Sin*, 2016, 42: 685–695
[陈兴国, 俞扬. 强化学习及其在电脑围棋中的应用. *自动化学报*, 2016, 42: 685–695]
- 15 Sutton R S, Barto A G. Reinforcement learning: an introduction. Cambridge: MIT Press, 2014
- 16 Gao Y, Chen S F, Lu X. Research on reinforcement learning technology: a review. *Acta Autom Sin*, 2004, 30: 86–100
[高阳, 陈世福, 陆鑫. 强化学习研究综述. *自动化学报*, 2004, 30: 86–100]
- 17 Sutton R S. Learning to predict by the methods of temporal differences. *Mach Learn*, 1988, 3: 9–44
- 18 Dayan P. The convergence of TD (λ) for general λ . *Mach Learn*, 1992, 8: 341–362
- 19 Singh S, Jaakkola T, Littman M L, et al. Convergence results for single-step on-policy reinforcement-learning algorithms. *Mach Learn*, 2000, 38: 287–308
- 20 Watkins C J, Dayan P. Q-learning. *Mach Learn*, 1992, 8: 279–292
- 21 Barto A G, Sutton R S, Anderson C W. Neuronlike adaptive elements that can solve difficult learning control problems. *IEEE Trans Syst Man Cybern*, 1983, 13: 834–846
- 22 Lange S, Riedmiller M. Deep auto-encoder neural networks in reinforcement learning. In: *Proceedings of the 7th International Joint Conference on Neural Networks (IJCNN)*, 2010
- 23 Littman M L, Szepesvari C. A generalized reinforcement-learning model: convergence and applications. In: *Proceedings of the 13th International Conference on Machine Learning (ICML)*, 1996. 310–318
- 24 Cesa-Bianchi N, Lugosi G. Prediction, Learning, and Games. Cambridge: Cambridge University Press, 2006
- 25 Hazan E. Introduction to online convex optimization. *FNT Optim*, 2015, 2: 157–325
- 26 Zinkevich M. Online convex programming and generalized infinitesimal gradient ascent. In: *Proceedings of the 20th International Conference on Machine Learning (ICML)*, 2003. 928–936
- 27 Hazan E, Seshadhri C. Efficient learning algorithms for changing environments. In: *Proceedings of the 26th Annual International Conference on Machine Learning (ICML)*, 2009. 393–400
- 28 Zhang L J, Lu S Y, Zhou Z H. Adaptive online learning in dynamic environments. In: *Proceedings of the 32nd International Conference on Neural Information Processing Systems*, 2018. 1330–1340
- 29 Bubeck S, Cesa-Bianchi N. Regret analysis of stochastic and nonstochastic multi-armed bandit problems. *Found Trend Mach Learn*, 2012, 5: 1–122
- 30 Pan S J, Yang Q. A survey on transfer learning. *IEEE Trans Knowl Data Eng*, 2010, 22: 1345–1359
- 31 Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning. *J Big Data*, 2016, 3: 9
- 32 Dai W Y, Yang Q, Xue G R, et al. Boosting for transfer learning. In: *Proceedings of the 24th International Conference on Machine Learning (ICML)*, 2007. 193–200
- 33 Argyriou A, Evgeniou T, Pontil M. Multi-task feature learning. In: *Proceedings of Advances in Neural Information Processing Systems*, 2007. 41–48
- 34 Raina R, Battle A, Lee H, et al. Self-taught learning: transfer learning from unlabeled data. In: *Proceedings of the 24th International Conference on Machine Learning (ICML)*, 2007. 759–766
- 35 Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks? In: *Proceedings of Advances in Neural Information Processing Systems*, 2014. 3320–3328
- 36 Liu J, Mei K, Ma D T, et al. Deep neural network aided scenario identification in wireless multi-path fading channels. 2018. ArXiv:17811.09346

An intelligent adaptative architecture for wireless communication in complex scenarios

Hao YIN^{1,2}, Jibo WEI², Haitao ZHAO², Jun XIONG², Kai MEI², Lijun ZHANG³,
Baoquan REN^{1*} & Dongtang MA²

1. *Military Academy of Sciences, Beijing 100076, China;*

2. *College of Electronic Science and Technology, National University of Defense Technology, Changsha 410073, China;*

3. *National Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China*

* Corresponding author. E-mail: renbq@126.com

Abstract This paper discusses a communication node architecture that can intelligently adapt to the unknown and possible confrontation-communication environment. The architecture includes three core functions: communication environment understanding, communication waveform adaptation, and learning and evolution. To support these functions, it also provides a hardware platform that integrates the capabilities of communication and computation. The proposed intelligent adaptive architecture supports the continuous accumulation and evolution of knowledge bases of communication environments, communication waveforms, and the match between them. Through online waveform reconfiguration, communication nodes can adapt to typical communication scenarios and unknown environments, thus support the sustainable development of intelligent communication. Furthermore, this paper summarizes the applications of reinforcement learning, online learning, and transfer learning in intelligent adaptive wireless communications, also providing a typical example of the application of machine learning to the channel estimation process.

Keywords intelligent node, communication environment understanding, intelligent adaptation, learning and evolution, machine learning, channel estimation




Technology, Changsha, China. Dr. Yin is a member of Chinese Academy of Sciences. His research interests include communication networks.

Hao YIN received his B.S. and M.S. degrees in electronic engineering from Nanjing University of Posts and Telecommunications, Nanjing, China, in 1982 and 1987, respectively, and his Ph.D. degree in electronic engineering from Beijing Institute of Technology, Beijing, China, in 1999. He currently works with the Academy of Military Sciences, Beijing, and is also a guest professor at National University of Defense



protocols, signal processing in communications, cooperative communications, and cognitive networks.

Jibo WEI received his B.S. and M.S. degrees in electronic engineering from the National University of Defense Technology (NUDT), Changsha, China, in 1989 and 1992, respectively, and his Ph.D. degree in electronic engineering from Southeast University, Nanjing, China, in 1998. He is currently a professor at the College of Electronic Science and Engineering, NUDT. His research interests include wireless network protocols, signal processing in communications, cooperative communications, and cognitive networks.



the College of Electronic Science and Engineering, NUDT. His main research interests include cognitive radio networks, self-organized networks, and cooperative communications.

Haitao ZHAO was born in 1981 and received his M.S. and Ph.D. degrees in information and communication engineering from National University of Defense Technology (NUDT), Changsha, China, in 2004 and 2009, respectively. He has been a research visitor at the Institute of Electronics, Communications and Information Technology, Queen's University Belfast, U.K., from 2007 to 2009. He is currently a professor at



He is currently a senior engineer at the Institute of Systems Engineering, Academy of Military Sciences, Beijing. His current research interests include the Internet-of-Things, wireless communications, and mobile communication network technology.

Baoquan REN received his B.S. degree from Zhangjiakou Communication College, Xuanhua, China, in 1997, his M.S. degree from Commanding Communications Academy, Wuhan, China, in 2002, and his Ph.D. degree from the Institute of China Electronic System Engineering Corporation, Beijing, China, in 2010. He has worked as an engineer at the Institute of China Electronic System Engineering Corporation.