

## 基于迁移学习的矿井复杂环境下的自适应信号检测

李旭虹 王廷玥\* 王安义

(西安科技大学通信与信息工程学院 西安 710054)

**摘要:** 针对矿井复杂环境下无线信道的衰落动态变化时, 离线模型的线上检测表现会遭遇性能下降的问题, 该文研究了基于迁移学习的自适应信号检测网络(ADN)。ADN的主要改进是使用并行网络对动态信道离散化以提高网络泛化能力; 对线上接收端信号采取域对抗训练神经网络(DANN)的无监督学习方式, 从而将离线训练知识迁移到线上矿井复杂环境中并且实时调整网络参数以适应信道的变化, 从而实现矿井复杂环境下的自适应信号检测。实验表明对正交相移键控(QPSK)和正交幅度调制(QAM)信号, 在动态变化的矿井Nakagami-m衰落信道中, 随着离散信道的增加, ADN获得信道间的分集效益, 性能逐渐提高。在高信噪比(SNR)时, 其性能接近卷积神经网络(CNN), 低信噪比时显著提高深度检测网络的鲁棒性和线上检测效果。

**关键词:** 信号检测; 自适应; 深度学习; 迁移学习

中图分类号: TN911.23

文献标识码: A

文章编号: 1009-5896(2023)12-4440-08

DOI: 10.11999/JEIT221442

## Adaptive Signal Detection in Complex Mine Environment Based on Transfer Learning

LI Xuhong WANG Tingyue WANG Anyi

(College of Communication and Information Engineering, Xi'an University of Science and  
Technology, Xi'an 710054, China)

**Abstract:** Considering the problem that the online detection performance of the offline model will experience performance degradation when the fading dynamics of the wireless channel in the complex environment of the mine are changed, the Adaptive Detection Network (ADN) based on transfer learning is studied. The main improvement of ADN is the use of parallel networks to discretize dynamic channels to improve network generalization capabilities. The unsupervised learning method of Domain Adversarial training of Neural Network (DANN) is adopted for the online receiver signal, so as to transfer the offline training knowledge to the complex environment of the online mine and adjust the network parameters in real time to adapt to the change of channel. Finally, it realizes the adaptive signal detection in the complex environment of the mine. Experiments show that ADN obtains the diversity benefit between channels for Quadrature Phase Shift Keying (QPSK) and Quadrature Amplitude Modulation (QAM) signals in the dynamically changing Nakagami-m fading channel. The performance gradually improves with the increase of discrete channels. At high Signal-to-Noise Ratio (SNR), its performance is close to that of Convolutional Neural Network (CNN). The robustness and online detection effect of deep detection networks are significantly improved at low SNR.

**Key words:** Signal detection; Adaptive; Deep Learning (DL); Transfer learning

### 1 引言

煤矿井下无线通信环境复杂多变, 巷道中的电磁波传播模式有很多种, 多种信号并存, 与普通的

地面无线传播差异较大。井下传播空间通常比较长且存在多分支, 巷道壁和各种用电设备产生的电磁场对无线电波易产生吸收和干扰, 粉尘对传输信号的损耗影响较大<sup>[1]</sup>。因此具备鲁棒性的多模信号检测方法是发展智能矿井通信<sup>[2]</sup>的基础。

深度学习(Deep Learning, DL)是解决上述挑战的一个很有前途的工具, 信号检测本质上是一个复杂的分类问题, DL提供了一种端到端优化的思路<sup>[3]</sup>。Ye等人<sup>[4]</sup>将深度神经网络(Deep Neural Net-

收稿日期: 2022-11-16; 改回日期: 2023-03-15; 网络出版: 2023-03-17

\*通信作者: 王廷玥 21207040030@stu.xust.edu.cn

基金项目: 国家自然科学基金(U19B2015)

Foundation Item: The National Natural Science Foundation of China (U19B2015)

works, DNN)应用到正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)系统进行信道估计和信号检测, 仿真结果表明误码率可以与传统的最小均方误差(Minimum Mean Square Error, MMSE)方法相媲美, 验证了用一个神经网络来代替传统通信中多个模块的可行性。Samuel等人<sup>[5]</sup>提出一种检测网络(Deterministic Network, DetNet), 通过将投影梯度下降算法展开构建网络, 仿真结果优于传统正交近似消息传递(Orthogonal Approximate Message Passing, OAMP)检测算法<sup>[6]</sup>, 但随着深度的增加, DetNet性能会逐渐到达瓶颈。为解决这个问题, Jim等人<sup>[7]</sup>提出并行检测网络(Parallel Detection Network, PDN), 该网络由多个基于深度学习的检测网络并行组成, PDN的性能随着并行网络数量的增加而显著提高。上述工作证明了利用深度学习技术检测信号的可能性。

当训练样本充分表征信道时, 深度检测方法表现出合理的性能。然而对于复杂多变的大型通信环境, 训练集与现实的实时信道服从相同分布是困难的, 而神经网络对分布改变极为敏感<sup>[8]</sup>, 因此深度学习面临泛化能力、鲁棒性方面的挑战。Sun等人<sup>[9]</sup>使用生成对抗网络(Generative Adversarial Network, GAN)对复杂信道估计, 使接收机能够跟踪动态信道条件而无需从头开始进行训练, 证明了GAN在深度信号检测方面的潜力。Li等人<sup>[10]</sup>针对动态范围较宽, 分布复杂的水声信道提出用生成对抗网络(GAN)去除噪声, 效果显著优于现有的DL方法。Van Huynh等人<sup>[11]</sup>给出一种迁移学习框架应用于无线网络的信号检测中, 通过冻结和微调的方法提高网络鲁棒性, 实验表明检测性能优于传统的基于DL的检测器, 验证了迁移学习能够解决目前深度信号检测的局限性。上述研究提供了新思路, 但仍依赖一定数量的线上标签信号做有监督的训练, 也未对矿井无线通信环境做相关优化。

本文针对矿井Nakagami- $m$ 动态信道提出基于迁移学习的自适应信号检测方法, 将动态信道切片为一些离散信道, 训练过程分为离线训练和线上适应两个阶段对正交相移键控(Quadrature Phase Shift Keying, QPSK)和正交幅度调制(Quadrature Amplitude Modulation, QAM)信号检测。通过域对抗训练神经网络(Domain Adversarial training of Neural Networks, DANN)<sup>[12]</sup>将离线知识迁移到线上模型并且跟随井下信道分布的变化自动更新参数, 从而提高泛化能力。文献<sup>[13]</sup>指出这种方法存在分类器偏移的问题, 因此为了减小偏差, 提出改进的判别器以增加偏差修正过程。

## 2 模型与问题分析

煤矿井下信道不同于地面无线信道, 无线电波通常传播于结构和尺寸不规则的巷道中, 众多的机械设备和粗糙的巷道壁岩石等复杂环境因素都会影响矿井无线信道。信号检测模型常用的瑞利衰落<sup>[14]</sup>、复高斯衰落<sup>[15]</sup>等不足以表征这种大型复杂多变的传播环境, 因此选用参数可变的Nakagami- $m$ 分布统计井下信号的包络特性<sup>[1]</sup>, 其概率密度函数为

$$p_R(r) = \frac{2m^m r^{2m-1}}{\Gamma(m)\Omega^m} \exp\left(-\frac{mr^2}{\Omega}\right) \quad (1)$$

其中, 多径散射场的平均功率 $\Omega = E(r^2)$ , 衰落因子 $m = \frac{\Omega^2}{E(r^2 - \Omega^2)^2}$ ,  $\Gamma(\cdot)$ 是标准Gamma( $\cdot$ )函数,  $m = 0.5$ 是单边高斯衰落,  $m = 1$ 是瑞利衰落。

本文考虑一个包含Nakagami- $m$ 衰落的井下信道 $\mathbf{H}_m$ , 接收信号 $\mathbf{y}_m \in \mathbb{C}$ 写作

$$\mathbf{y}_m = \mathbf{H}_m \mathbf{x} + \mathbf{n} \quad (2)$$

其中,  $\mathbf{x} \in \mathbb{C}$ 是发端信号,  $\mathbf{H}_m$ 跟随衰落因子 $m$ 的改变而反映变化的信道分布, 噪声 $\mathbf{n}$ 服从复高斯分布 $\mathcal{CN}(0, \sigma^2)$ 。

接收端信噪比(Signal to Noise Ratio, SNR)写作

$$\text{SNR} = \frac{E \|\mathbf{H}_m \mathbf{x}\|^2}{E \|\mathbf{n}\|^2} \quad (3)$$

$\mathbf{x}$ 来自 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ ,  $|\mathbf{X}| = N$ , 信号检测通常使用极大似然(Maximum Likelihood, ML)检测, 写作

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x} \in \mathbf{X}} \|\mathbf{y}_m - \mathbf{H}_m \mathbf{x}\|^2 \quad (4)$$

在检测中, 通常假设信道矩阵 $\mathbf{H}_m$ 是完全已知的。利用完美的信道状态信息(Channel State Information, CSI)和关于高斯噪声的假设, 求解上述最小化问题, 可以得到传输信号 $\hat{\mathbf{x}}$ 。然而, 由于信道估计误差是不可避免的, 在接收机中没有完美的 $\mathbf{H}_m$ <sup>[16]</sup>。深度神经网络可以近似求解这个问题, 采取的方法是选择一个合适的 $m$ 值估计矿井通信环境<sup>[7]</sup>。假设某个 $m$ 值的矿井信道 $\mathbf{H}_{\text{off}}$ 作为深度神经网络的训练环境, 深度信号检测机就是求解

$$\hat{\mathbf{x}}_{\text{off}} = \arg \min_{\mathbf{x} \in \mathbf{X}} \mathcal{L}(\mathbf{y}_{\text{off}}, \mathbf{H}_{\text{off}} \mathbf{x}) \quad (5)$$

其中,  $\mathcal{L}$ 是损失函数。

然而, 线上矿井信道 $\mathbf{H}_m$ 的衰落因子 $m$ 动态变化, 其衰落分布很难与离线 $\mathbf{H}_{\text{off}}$ 保持一致, 这导致泛化能力弱的机器的线上信号检测性能下降。下一节提出一种自适应检测网络(Adaptive Detection Network, ADN)以近似地解决这个问题。

### 3 自适应检测网络

#### 3.1 自适应检测网络

领域自适应(Domain Adaptation, DA)作为迁移学习的一个分支有广阔的发展空间,其通过利用不同但相关的源领域中的训练数据来解决目标领域中的学习问题<sup>[18]</sup>。ADN结合DA与DNN来完成线上自适应信号检测,其由若干个子网络并行组成,每个子网络包含采样器S,特征提取网络F,信号检测层T和信道判别器D,如图1所示。采样器对接收端信号采样。特征提取网络包含 $L$ 个级联的特征提取层 $F_{L1}, F_{L2}, \dots, F_{LL}$ ,用于从信号中提取利于检测的特征。全连接层作为信号检测层连接在网络的尾部,输出检测概率。特征提取网络的输出也会送入信道判别器,判别器由多个相同结构的二分类子判别器组成,负责判断当前所处的信道环境,判决结果通过损失函数反馈给特征提取网络,以此执行迁移学习任务来调整网络的参数适应当前信道。最后,网络的所有部分通过最小化特定的损失函数来同时进行训练。

ADN相较于目前深度网络流行的离线训练配合线上检测的模式,增加了线上自适应的环节,这使其具备了应对信道变化的能力。ADN实现自适应过程的关键是信道判别器,其负责判断当前信号的信道环境并且使用偏差器输出信道差异信息。这让ADN获得了鉴别信道的能力,为信号检测提供了信道相关的先验知识。同时ADN使用并行结构将动态变化的信道切片成多个离散信道,具体来说,对于 $M$ 个不同衰落分布的信道,第 $k$ 个采样信号 $y_k^S$ 经过F后的输出特征 $c_k$ 会作为子判别器的输入,如图2所示。每个子判别器包含一个分类器G、

偏差器B和信道标签 $d = [d_1 d_2 \dots d_M]^T$ ,分类器产生判决结果 $\hat{d}_k$ ,偏差器输出检测偏差 $I_k$ 。其中, $\hat{d}_k$ 是对 $c_k$ 所属信道的预测, $I_k$ 用于修正离线与线上的信号检测层之间的偏差。上述过程写作

$$\hat{d}_k = G(c_k) \quad (6)$$

$$I_k = B(d_{k-1}, \hat{d}_{k-1}, c_{k-1}) \quad (7)$$

式(7)是受文献<sup>[13]</sup>的启发,其提出特征生成器的两个域特征分布不能完全一样,那么领域之间分类器就有一定的偏差,写作

$$f_S(x) = f_T(x) + \Delta f(x) \quad (8)$$

其中, $f_S(x)$ , $f_T(x)$ 是源域和目标域的分类器, $\Delta f(x)$ 描述二者之间的偏差,作者将 $c_k$ 送入残差网络(ResNet)学习偏差。在式(7)中,输入包含第 $k-1$ 个信号的信道知识,这是为了替代第 $k$ 个信号,这样处理是基于信道分布变化是连续光滑的假设,短时内的信道分布是近似的。偏差为信号检测提供了额外信息,也能加速信号检测层的收敛。

分类器的结构参考文献<sup>[12]</sup>,偏差器是一个小型的多层感知机(Multilayer Perceptron, MLP),共3层。考虑到信道衰落的非线性特点,分类器使用激活函数sigmoid,偏差器使用tanh,输入偏差器的 $c_k$ 会经历随机裁剪,这有利于减少输入和增强模型的稳定性。

特征提取网络基于轻量的卷积神经网络(Convolutional Neural Network, CNN),如图3所示,文献<sup>[19,20]</sup>的实验表明CNN具备良好的泛化和迁移能力。但特征提取网络与信道判别器的任务恰好相反,旨在将来自不同信道的信号映射到同一个特征空间 $C = \{c_i\}$ ,描述为 $f: y_k^S \rightarrow c_i$ 。其与信道判别

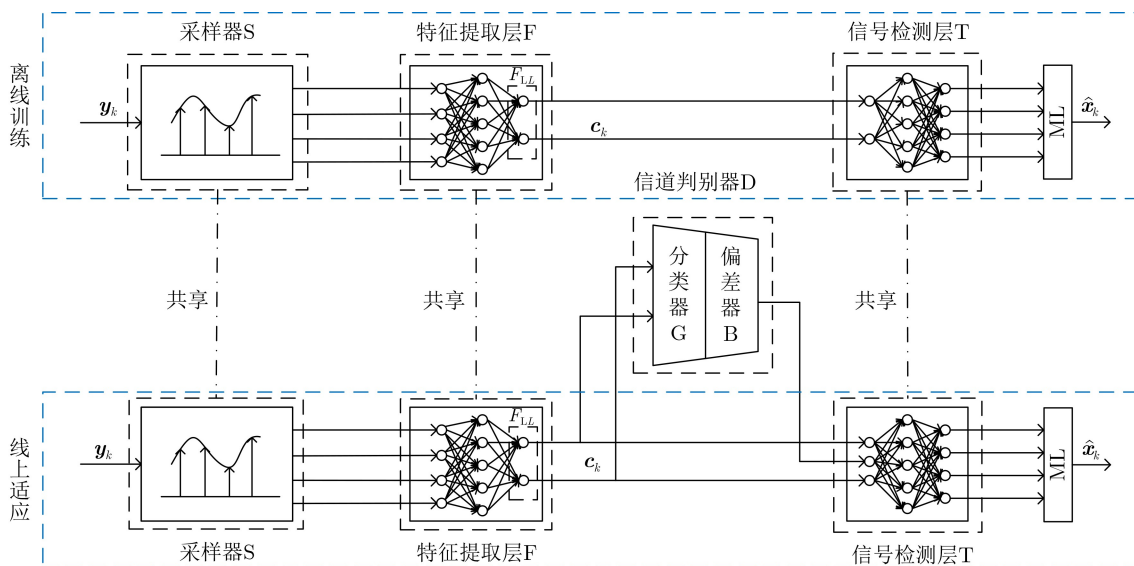


图1 自适应检测网络的子网络结构

器形成对抗关系，促进离线知识迁移到新环境并且增强泛化能力，使信号检测从被动接收变为主动调节。最后， $c_i$ 通过信号检测层输出概率，反映检测结果 $\hat{x}_k$ ，上述过程写作




图2 信道判别器的结构




图3 特征提取层与信号检测层的结构

$$\hat{x}_k = T(F(y_k^S)) \quad (9)$$

### 3.2 迁移与分集算法

在ADN中，要求提取来自不同信道信号的共同特征，等价于要求所提取的特征尽可能欺骗信道判别器，因此ADN的优化目标为减小检测损失 $\mathcal{L}_T$ 和增大判别损失 $\mathcal{L}_G$ ，总损失函数写作

$$\text{Loss} = \mathcal{L}_T - \lambda \mathcal{L}_G \quad (10)$$

其中，超参数 $\lambda$ 调节迁移学习的尺度。

具体来说，ADN需要优化的参数有特征提取网络的内部参数 $\mathbf{W}_F$ ，信号检测层的参数 $\mathbf{W}_T$ 和信道判别器的参数 $\mathbf{W}_G, \mathbf{W}_B$ 。分类器通过最小化 $\mathcal{L}_G$ 以优化 $\mathbf{W}_G$ 来提高判别能力，写作

$$\mathbf{W}_G^* = \arg \min \mathcal{L}_G(d_k, \hat{d}_k) \quad (11)$$

其中， $d_k$ 是真实的信道标签。特征提取网络、偏差器和信号检测层都通过最小化 $\mathcal{L}_T$ 优化各自参数 $\mathbf{W}_F, \mathbf{W}_B, \mathbf{W}_T$ ，写作

$$\mathbf{W}_F^*, \mathbf{W}_B^*, \mathbf{W}_T^* = \arg \min \mathcal{L}_T(x_k, \hat{x}_k) \quad (12)$$

ADN使用并行结构将动态衰落信道切片为若干个离散的有代表性的信道，使深度检测网络可以在多信道中获得分集效益，降低对精确信道估计的要求。为了说明这是如何工作的，下面提供一个示例做更详细的解释。该工作依赖于并行的ADN子网络，如图4，并行的网络可以实现动态信道的离散化以提高鲁棒性。假设在自适应过程的窗口期有接收信号数 $P$ 和 $M \in \mathbb{N}^*$ 个不同的信道。由于ADN有 $M$ 个相同结构的子分类器 $G$ 和子偏差器 $B$ ，所以本文使用一个特殊的判别损失，基本原则是选择损失最小的信道做对抗迁移，写作

$$\mathcal{L}_G = \min_{i \in \{1, 2, \dots, M\}} \frac{1}{P} \sum_{k=1}^P l_i(y_k^S, d_i) \quad (13)$$

其中， $l_i$ 是第 $i$ 个子信道分类器 $G_i$ 的损失，写作

$$l_i = d_i \lg \frac{1}{G_i(F_i(y_k^S))} + (1-d_i) \lg \frac{1}{1-G_i(F_i(y_k^S))} \quad (14)$$

$\mathcal{L}_T$ 使用基于信号检测结果的交叉熵损失函数更新参数，写作

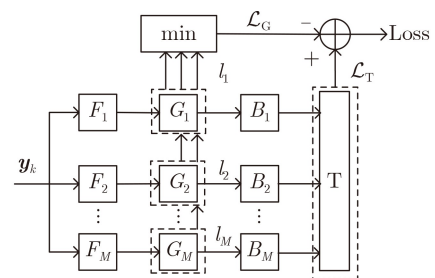


图4 ADN的并行结构

$$\mathcal{L}_T = \frac{1}{P} \sum_{j=1}^P \sum_{q=1}^N x_{j,q} \lg \frac{1}{p_{j,q}} \quad (15)$$

其中,  $N = |X|$  是信号类型数,  $\mathcal{P}$  是信号检测层输出的检测概率。

在本例中, ADN 离线使用的衰落因子  $m_i \in \{m_1, m_2, \dots, m_M\}$  被逐一分配给  $M$  个并行子网络, 并且保存训练后各自的网络参数。在自适应阶段, 所有子分类器  $G_i$  同时工作判断接收信号所代表的  $m$  值与  $m_i$  的关系, 依据损失最小原则决定信道归属。每个子偏差器  $B_i$  提供有关线上信道衰落分布与离线信道分布之间的差异信息, 这样的  $M$  个信息为信号检测带来分集效益。在整个迁移学习过程中, ADN 首先共享离线的网络参数, 然后通过最小化总损失函数调整权重完成自适应。

### 3.3 两阶段训练方法

整个过程执行在 PyTorch 框架中, 使用 Adam 优化器。自适应检测网络的流程是离线训练检测器, 然后直接应用于复杂多变的矿井信道环境中。为了达到这一目标和减少自适应耗时, 本文使用以下3种策略:

- (1) 分为离线训练和线上适应的两阶段训练法;
- (2) 离线参数完整迁移到线上以减少耗时;
- (3) 以衰落因子  $m \in \{0.5, 0.6, 0.85, 1, 1.15, 1.3\}$  切分 Nakagami- $m$  信道为离散信道。

在离线训练阶段, 选择  $m = 0.85$  代表井下环境, 信号样本  $(x, y)$  的  $N_{\text{batch}} = 32$ , 网络的迭代次数  $N_{\text{epoch}} = 1000$ , 损失函数使用  $\mathcal{L}_T$ , 传输信号样本总数为 160 000 个。接收端信号经过特征提取层 F 后直接送入信号检测层。在第  $j$  次迭代中反向传播更新网络的参数并且计算误符号率  $p_j$ , 然后与之前的最小值  $p_{\text{min}}$  比较以决定是否更新参数, 如果  $p_j < p_{\text{min}}$ , 则用本次参数  $\mathbf{W}_j$  替换, 经过  $N_{\text{epoch}}$  次迭代获得最优参数  $\mathbf{W}^*$  后, 即可部署于线上环境。

在线上适应阶段, 衰落因子  $m$  持续变化以模拟动态的矿井环境。接收信号通过 F 之后的结果同时送入信道判别器和信号检测层, 使用总损失函数更新网络。最终, 经过偏差修正的信号检测层输出信号检测结果。

## 4 仿真实验与结果分析

第3节提出一个自适应检测网络, 目标是使用深度网络在线上矿井环境中完成信号检测。本节包含3个实验, 目的分别是分析 CNN 所遭遇的线上检测挑战、验证 ADN 的鲁棒性和对比 ADN 线上检测性能。实验仿真平台: CPU 为 i9-9900k, GPU 为双 RTX2080Ti, 内存 32 GB, 采用 Python 作为软件平台。

**实验1** CNN 的信道泛化能力。为了清楚显示深度检测网络在矿井环境中面临的泛化挑战, 本节比较了 CNN, 如图3, 在面对线上信道衰落改变时的误符号率 (Symble Error Rate, SER), 如图5。测试是发生在线上信道与离线信道分布不同的情况, 因此为了尽可能让网络适配线上环境, 常规思路是融合多时段采集的信号样本以离线学习到动态变化的信道衰落分布特征。衰落因子  $m$  可以视作  $m$  时段的信道衰落,  $m$  的取值数量就是动态信道离散化后的信道类数  $M$ 。离线阶段的训练集包含  $M$  类样本, 线上检测集是  $m = 0.6$  的接收信号。除了  $M = 1$  外, 其他训练集均包含  $m = 0.6$  的样本。  $M = 1$  时训练集没有使用  $m = 0.6$ , 而是使用  $m = 0.85$ , 这是模拟离线机器遭遇离线与线上信道分布不同的情况。

该实验的训练集融合  $M$  类信道样本,  $m \in \{0.5, 0.6, 0.85, 1, 1.15\}$ , 检测集为  $m = 0.6$ 。从曲线整体观察到线上 SER 高于离线 SER, 其中离线 SER 在  $M > 1$  时有大幅上升,  $M > 5$  时损失函数已经无法收敛, 故未画出。造成这样结果的原因是线上信道衰落发生了改变, 这在实际矿井信道中是时常发生的。线上 SER 的上升是因为面对复杂变化的信道分布时, 网络的泛化能力不足。虽然在  $M = 2$  时 SER 有明显下降, 但这是因为检测集中开始包含离线训练使用的信道衰落  $m = 0.85$ 。因此, 常规的大数据样本融合训练方法对于线上信号检测没有取得令人满意的效果, 即使线上信号已经在离线训练时被捕获得。

图5(b) 显示增大信噪比可以发挥积极作用, 具体表现在网络开始学习变化的信道分布, 但仅限于  $M \leq 2$  的情况, 线上检测表现几乎没有改善。这可能是因为大功率信号抵抗衰落的能力更强, 但无法避免邻道间干扰。随着信号功率的增加, 衰落的负面作用减小, 邻道的同类样本共性增加而差异减小, 据此可以提出一个关于信道泛化的猜想:

将一个分布动态变化的信道切片离散化, 设离散数为  $M \in \mathbb{N}^*$ , 当前网络可泛化的信道数记为  $M_e$ , 则有  $M_e \leq M$ , 如果  $\text{SNR} \rightarrow +\infty$ , 那么  $M_e \rightarrow +\infty$ 。

研究者致力于提高深度检测网络的实用性, 理想情况下  $M_e \rightarrow +\infty$ , 网络完全泛化整个信道分布, 离线与线上的检测表现将保持一致的优秀。但 SNR 与  $M_e$  的关系尚不明朗, 构建可学习的泛化网络也难以实现, 因此通常假定离线信道衰落与线上信道是同分布的, 这正是本文力求解决的问题。

**实验2** ADN 的鲁棒性和分集效应。本实验在 3 dB 信噪比条件下开展, 目标是测试 ADN 的鲁棒性。其中图6(a) 的训练集是单一的高斯衰落, 图6(b) 的

训练集在  $M = 1$  时是瑞利衰落,  $M > 1$  时是  $M$  类衰落样本的集合, 图6(a)和图6(b)的线上检测集都来自各个分布的样本, 这是最常见的两种信道估计和信号检测情况, 分别对应单一训练和融合训练。ADN的子网络并联数与衰落样本类别  $M$  保持同步, 即  $M$  既是信道离散数, 也是ADN的并联数。

图6(a)是一个采集窗口期非常长的过程, 足够收集到  $M$  类衰落的信号, 因此检测集包含丰富的信道动态信息, 这在实际的线上检测活动中不会发生, 但能充分表现网络的鲁棒性。图6(b)意在模拟一个动态的矿井环境, 接收端会收到6种衰落类型的信号, CNN训练集的样本从1种衰落逐渐扩充至5种衰落, 但始终缺失  $m = 1.3$  的信号样本, ADN的并行级数也从1级逐渐扩展到5级, 这能展示ADN处理未知信号的能力和分集效应的收益。值得注意的是本实验及下一个实验的ADN与CNN的网络结构是完全一样的, 不同之处仅在于ADN增加的部分, 所使用的衰落因子  $m \in \{0.5, 0.6, 0.85, 1, 1.15, 1.3\}$ 。

其中, 图6(a)的训练集为高斯衰落样本, 检测集包含  $M$  种信道衰落。图6(b)的训练集在  $M = 1$  时是瑞利衰落样本, 检测集包含6种信道衰落。观察曲线发现随着检测集衰落类型的增加, CNN的SER

逐渐上升, 这是因为检测集包含越来越多的未知信道分布。图6(a)表明ADN有良好的鲁棒性, 这得益于迁移学习的成果。在  $M = 1$  时ADN的SER高于CNN, 这是因为此时离线与线上信道同分布, 信道判别器反而会造成额外的偏差。图6(b)表明融合训练并不是对信道分布覆盖越全面越好, 受制于网络本身的泛化能力和信噪比, SER呈现先降低后升高的趋势。随着信道离散数和网络并行数的同步增加, ADN可以获得更多的信道间差异信息, 这种分集效应带来的好处是SER逐渐下降。

**实验3** ADN的线上检测性能。为了测试ADN的性能, 本文将其与线性最小均方误差(Linear Minimum Mean Square Error, LMMSE)、最佳接收机和同网络结构的CNN, 如图3, 进行比较。实验信号为QPSK和4-QAM, 检测集包含6种衰落, 衰落因子  $m \in \{0.5, 0.6, 0.85, 1, 1.15, 1.30\}$ , CNN的离线训练集包含前3种衰落样本; ADN为  $M$  级并联结构,  $M \in \{2, 4, 6\}$ , 即将整个线上信道切分散化为  $M$  个, 同时离线训练集分别包含前  $M$  种衰落样本。

图7是关于  $M$  级并联ADN的线上检测SER对比, 接收信号是4-QAM和QPSK, 信噪比为3 dB。其展示了在低信噪比时的分集效应。其中SER的下降

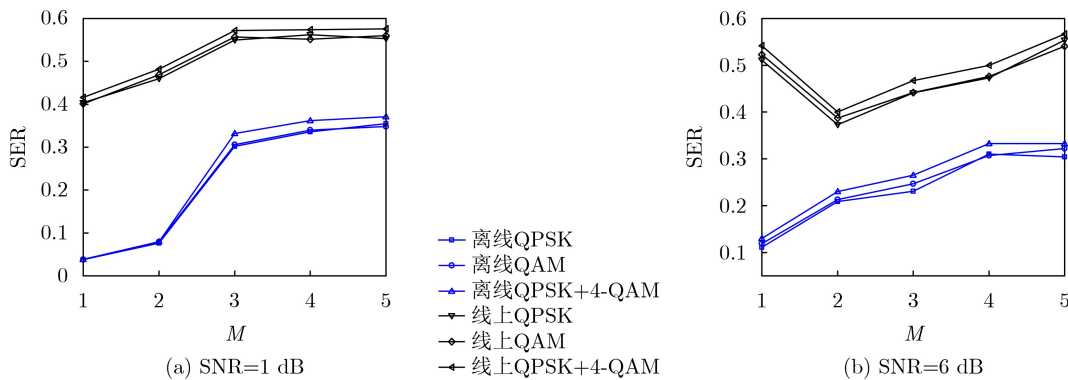


图5 CNN的离线SER和线上检测SER对比

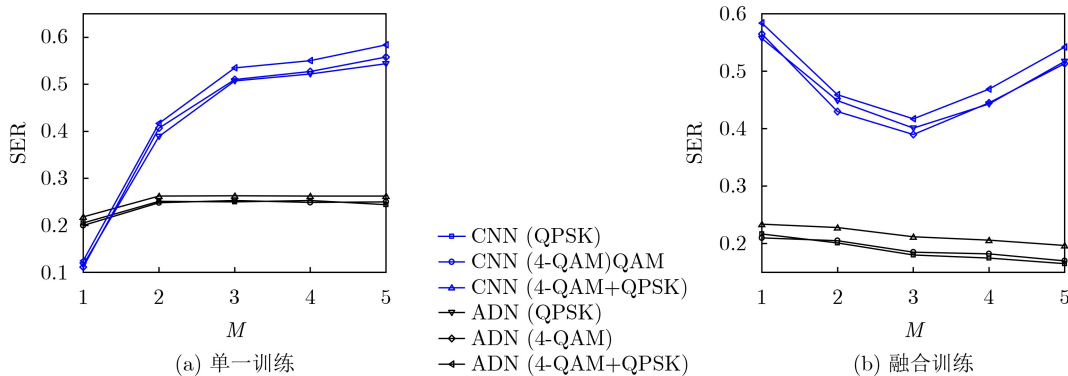


图6 CNN和ADN的线上检测SER

得益于信道判别器的工作和递增的信道离散数 $M$ ，因为如果 $M$ 增大，ADN就可以获得更多有利于信号检测的信道知识。可以发现当信噪比较大时，分集效应减弱，具体表现在随着 $M$ 增大，SER没有明显的改善。这是由于来自不同衰落的信号本身的抗衰落能力变强，信道间差异也变小，同时也与信道判别器的判别能力有关。

图8、图9是关于线上检测性能的测试，衰落信道数 $M$ 依次为2, 4, 6。其展现了ADN在低信噪比下的优秀迁移能力，这是未使用自适应方法的CNN无法达到的泛化水平。观察曲线看到在大信噪比时CNN的SER反超ADN，这是因为信道判别器造成的额外偏差的影响，所以设计一个高灵敏的信道判别器是本文方法之关键。同时构建一个优秀的特征

提取网络可以缩小与最佳接收的差距，本文使用的是一个轻量的CNN。在低信噪比条件下的性能排序是：CNN低于等于LMMSE低于ADN低于最佳接收；大信噪比条件下的性能排序是：LMMSE低于ADN低于CNN低于最佳接收。

## 5 结论

通过研究衰落变化的矿井无线信道下的信号检测问题，本文提出一个基于迁移学习的并行自适应检测网络(ADN)。它由常规的深度检测网络和信道判别器组成，通过一个特殊的迁移损失函数优化参数，同时用并行网络对动态信道离散化，这使网络获得分集效益并且改善线上检测能力。特别是在面对复杂多变的大型无线环境时，传统的基于DL的检测器需要重新训练以应对变化的衰落分布。ADN增加的信道判别器和动态信道离散化策略，使深度网络以自适应的方式实时保证良好的检测性能和鲁棒性。

实验使用QPSK和4-QAM信号，以衰落可变的Nakagami-m信道验证了在大信噪比时，ADN的线上检测误符号率接近CNN；低信噪比时，CNN的性能严重下降而被ADN超越，并且随着离散数增加，ADN性能逐渐提高。这表明ADN能帮助网络适应动态的信道环境，从而表现出更好的检测性能和鲁棒性。此外，这展示出迁移学习在处理大型复杂无线通信的实际意义，对于智能信息处理有重要的研究价值。

## 参考文献

- [1] FOROOSHANI A E, BASHIR S, MICHELSON D G, *et al.* A survey of wireless communications and propagation modeling in underground mines[J]. *IEEE Communications Surveys & Tutorials*, 2013, 15(4): 1524–1545. doi: [10.1109/SURV.2013.031413.00130](https://doi.org/10.1109/SURV.2013.031413.00130).
- [2] CAI Meifeng, LI Peng, TAN Wenhui, *et al.* Key engineering technologies to achieve green, intelligent, and sustainable development of deep metal mines in China[J]. *Engineering*, 2021, 7(11): 1513–1517. doi: [10.1016/j.eng.2021.07.010](https://doi.org/10.1016/j.eng.2021.07.010).
- [3] ALBREEM M A, ALHABBASH A H, SHAHABUDDIN S, *et al.* Deep learning for massive MIMO uplink detectors[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(1): 741–766. doi: [10.1109/COMST.2021.3135542](https://doi.org/10.1109/COMST.2021.3135542).
- [4] YE Hao, LI G Y, and JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(1): 114–117. doi: [10.1109/LWC.2017.2757490](https://doi.org/10.1109/LWC.2017.2757490).
- [5] SAMUEL N, DISKIN T, and WIESEL A. Deep MIMO detection[C]. 2017 IEEE 18th International Workshop on

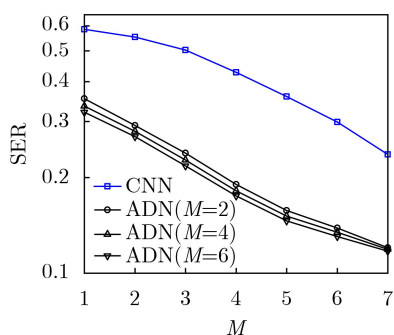


图7 ADN的分集效应对比

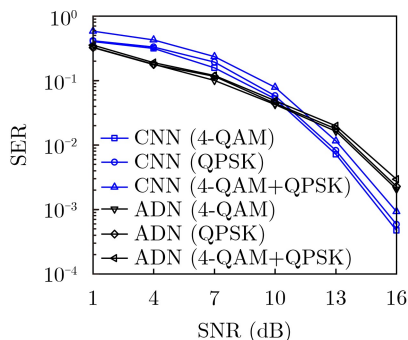


图8 所提自适应方法(ADN)对CNN的改善

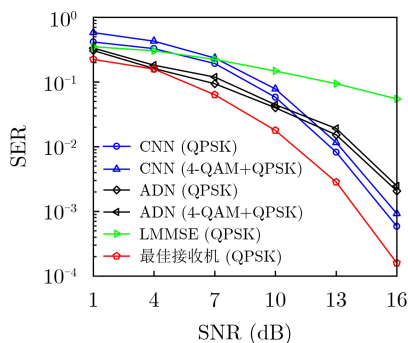


图9 不同方法的线上检测性能对比

- Signal Processing Advances in Wireless Communications (SPAWC), Sapporo, Japan, 2017: 1–5. doi: [10.1109/SPAWC.2017.8227772](https://doi.org/10.1109/SPAWC.2017.8227772).
- [6] JEON C, GHODS R, MALEKI A, *et al.* Optimality of large MIMO detection via approximate message passing[C]. 2015 IEEE International Symposium on Information Theory (ISIT), Hong Kong, China, 2015: 1227–1231. doi: [10.1109/ISIT.2015.7282651](https://doi.org/10.1109/ISIT.2015.7282651).
- [7] JIN Xianglan and KIM H N. Parallel deep learning detection network in the MIMO channel[J]. *IEEE Communications Letters*, 2020, 24(1): 126–130. doi: [10.1109/LCOMM.2019.2950201](https://doi.org/10.1109/LCOMM.2019.2950201).
- [8] SAMUEL N, DISKIN T, and WIESEL A. Learning to detect[J]. *IEEE Transactions on Signal Processing*, 2019, 67(10): 2554–2564. doi: [10.1109/TSP.2019.2899805](https://doi.org/10.1109/TSP.2019.2899805).
- [9] SUN Li, WANG Yuwei, SWINDLEHURST A L, *et al.* Generative-adversarial-network enabled signal detection for communication systems with unknown channel models[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(1): 47–60. doi: [10.1109/JSAC.2020.3036954](https://doi.org/10.1109/JSAC.2020.3036954).
- [10] LI Yongbin, WANG Bin, SHAO Gaoping, *et al.* Blind detection of underwater acoustic communication signals based on deep learning[J]. *IEEE Access*, 2020, 8: 204114–204131. doi: [10.1109/ACCESS.2020.3036883](https://doi.org/10.1109/ACCESS.2020.3036883).
- [11] VAN HUYNH N and LI G Y. Transfer learning for signal detection in wireless networks[J]. *IEEE Wireless Communications Letters*, 2022, 11(11): 2325–2329. doi: [10.1109/LWC.2022.3202117](https://doi.org/10.1109/LWC.2022.3202117).
- [12] GANIN Y, USTINOVA E, AJAKAN H, *et al.* Domain-adversarial training of neural networks[J]. *The Journal of Machine Learning Research*, 2016, 17(1): 2096–2030.
- [13] 臧文华. 基于生成对抗网络的迁移学习算法研究[D]. [硕士学位论文], 电子科技大学, 2018.
- ZANG Wenhua. Research on transfer learning based on generative adversarial networks[D]. [Master dissertation], University of Electronic Science and Technology of China, 2018.
- [14] BAEK M S, KWAK S, JUNG J Y, *et al.* Implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters[J]. *IEEE Transactions on Broadcasting*, 2019, 65(3): 636–642. doi: [10.1109/TBC.2019.2891051](https://doi.org/10.1109/TBC.2019.2891051).
- [15] WANG Shengyao, YAO Rugui, TSIFTISIS T A, *et al.* Signal detection in uplink time-varying OFDM systems using RNN with bidirectional LSTM[J]. *IEEE Wireless Communications Letters*, 2020, 9(11): 1947–1951. doi: [10.1109/LWC.2020.3009170](https://doi.org/10.1109/LWC.2020.3009170).
- [16] ZHANG Yiqing, SUN Jianyong, XUE Jiang, *et al.* Deep expectation-maximization for joint MIMO channel estimation and signal detection[J]. *IEEE Transactions on Signal Processing*, 2022, 70: 4483–4497. doi: [10.1109/TSP.2022.3205478](https://doi.org/10.1109/TSP.2022.3205478).
- [17] WANG Anyi, FENG Zhiyuan, LI Xuhong, *et al.* Mine intelligent receiver: MIMO-OFDM intelligent receiver for mine information recovery[J]. *Energies*, 2022, 15(18): 6550. doi: [10.3390/en15186550](https://doi.org/10.3390/en15186550).
- [18] PAN S J, TSANG I W, KWOK J T, *et al.* Domain adaptation via transfer component analysis[J]. *IEEE Transactions on Neural Networks*, 2011, 22(2): 199–210. doi: [10.1109/TNN.2010.2091281](https://doi.org/10.1109/TNN.2010.2091281).
- [19] 蒋伊琳, 尹子茹, 宋宇. 基于卷积神经网络的低截获概率雷达信号检测算法[J]. *电子与信息学报*, 2022, 44(2): 718–725. doi: [10.11999/JEIT210132](https://doi.org/10.11999/JEIT210132).
- JIANG Yilin, YIN Zirui, and SONG Yu. Low probability of intercept radar signal detection algorithm based on convolutional neural networks[J]. *Journal of Electronics & Information Technology*, 2022, 44(2): 718–725. doi: [10.11999/JEIT210132](https://doi.org/10.11999/JEIT210132).
- [20] SHIN H C, ROTH H R, GAO Mingchen, *et al.* Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1285–1298. doi: [10.1109/TMI.2016.2528162](https://doi.org/10.1109/TMI.2016.2528162).
- 李旭虹: 女, 副教授, 研究方向为通信电路与系统技术、无线通信。  
王廷玥: 男, 硕士生, 研究方向为智能信息处理。  
王安义: 男, 教授, 研究方向为移动通信、智能信息处理及煤矿智能化等。

责任编辑: 余蓉