

利用新型卷积神经网络识别 MPSK 信号调制方式

王爱丽¹, 张佳炜¹, 姜开元¹, 吴海滨¹, 岩堀祐之²

(1. 哈尔滨理工大学 测控技术与通信工程学院, 哈尔滨 150080;

2. 中部大学 计算机科学学院, 日本 爱知 487-8501)

摘要:随着人工智能技术的快速发展,卷积神经网络越来越多地应用到通信信号调制识别领域。针对数字信号在低信噪比的识别准确率较低的问题,采用 InceptionResNetV2 网络与迁移适配相结合的方法,研究了一种调制识别模型,称之为 InceptionResnetV2-TA,对 MPSK 信号的调制方式进行识别。结果表明,信噪比为 3dB 时,InceptionResnetV2-TA 对 BPSK 的识别率达到 99.33%,比次优模型 InceptionResNetV2 高出 3%。对 QPSK 的识别率达到 95.33%,比 InceptionResNetV2 高出 2%。对 8PSK 的识别率达到 86.33%,比 InceptionResNetV2 高出 5%。综上,结合了迁移适配的 InceptionResnetV2-TA,对 BPSK、QPSK 和 8PSK 在低信噪比的识别准确率高于其他对比方法。同时验证了这种调制识别模型的有效性。

关键词:调制识别;卷积神经网络;迁移适配;InceptionResNetV2

DOI:10.15938/j.jhust.2021.05.013

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1007-2683(2021)05-0097-07

Modulation Recognition of MPSK Signals Based on Novel Convolutional Neural Network

WANG Ai-li¹, ZHANG Jia-wei¹, JIANG Kai-yuan¹, WU Hai-bin¹, Yuji Iwahori²

(1. School of Measurement-Control Technology and Communication Engineering, Harbin University of Science and Technology, Harbin 150080, China;

2. Department of Computer Science, Chubu University, Aichi 487-8501, Japan)

Abstract: With the rapid development of artificial intelligence, convolutional neural network is more and more applied to the field of communication signal modulation recognition. Aiming at the problem of low recognition accuracy of digital signals at low SNR, a modulation recognition model named InceptionresnetV2-TA was studied by combining InceptionresnetV2 network with migration adaptation to identify the modulation mode of MPSK signals. The results show that when the SNR is 3dB, the recognition rate of InceptionresnetV2-TA for BPSK is 99.33%, which is 3% higher than that of the suboptimal model InceptionresnetV2. The recognition rate of QPSK is 95.33%, which is 2% higher than InceptionresnetV2. The recognition rate of 8PSK is 86.33%, which is 5%

收稿日期: 2020-09-20

基金项目: 国家自然科学基金(61671190).

作者简介: 王爱丽(1979—),女,副教授,硕士研究生导师;

张佳炜(1995—),男,硕士研究生.

通信作者: 吴海滨(1977—),男,教授,博士研究生导师, E-mail: woo@hrbust.edu.cn.

higher than that of Inceptionresnetv2. The above results indicate that InceptionresnetV2-TA combined with migration adaptation has higher identification accuracy of BPSK, QPSK and 8PSK at low SNR than other comparison methods. At the same time, the validity of the modulation recognition model is verified.

Keywords: modulation recognition; convolutional neural network; transfer adaptation; InceptionResNetV2

0 引 言

无线通信技术的发展,经历了由模拟到数字、由单一到多元的多个阶段,针对不同的应用场景,随之衍生出多种不同类型的信号调制方式。如今无线通信手段日趋多样化,电磁环境日渐复杂。在协作通信条件下,确定信号的调制方式是获取通信信号内容的基础;在非协作环境中,调制识别作为信号检测与信号解调之间的一项技术,其主要目的是确定待检信号的调制方式,也是后续估计待检信号参数(如载波频率、码元速率等)的决定性前提。调制识别在民用与军事领域有着广泛的应用。

近年来,深度学习被引入到数字信号调制识别的研究中。牛国庆等^[1]提出了一种将反向传播神经网络和决策树相结合的调制识别技术,该技术具有较高的平均识别率。黄媛媛等^[2]通过构建深度置信网络,实现了对通信信号的调制识别。侯涛等^[3]提出了一种基于深度学习的通信信号调制识别方法。该方法通过设计深层神经网络模型解决了端到端信号识别问题,从而简化了人工特征提取的繁琐过程。Peng 等^[4]提出以网格拓扑的形式表示数据,并与卷积神经网络结合以完成调制信号的分类。Wang 等^[5]提出了一种基于星座图的卷积神经网络识别算法来识别不同信号的调制方式。彭超然等^[6]提出了一种基于深度神经网络的调制识别方法。该方法对接收到的信号进行预处理,生成星座图,并使用星座图的形状作为深度卷积神经网络的输入。利用训练后的网络,模型可以对调制信号进行分类和识别。

另外,Yang 等^[7]使用聚类算法提取和优化信号的特征参数,通过分层算法训练支持向量机,提高了收敛速度和低信噪比时的识别性能,从而实现了信号调制识别。Li 等^[8]提出了一种使用聚类算法提取信号的特征参数,并通过可变梯度校正算法训练

神经网络,以实现信号的调制识别。Xu 等^[9]提出了一种基于星座图的模糊分类算法,该算法以星座图为输入,通过模糊逻辑分析和处理系统对其进行处理,实现对各种数字信号的调制识别。

上述算法的共同问题是在低信噪比下识别率低。因此,本文在 InceptionResNetV2 网络中引入了迁移适配的思想,称为 InceptionResnetV2-TA,该网络通过深层和并行网络结构充分提取输入特征,以识别 MPSK 信号的调制方式,并提高在低 SNR 环境中信号的识别精度。

现有方法中多数是利用数学公式推导求得特征参数,再将特征参数送入分类器中进而对信号的调制方式进行识别,计算复杂度较高,且识别结果会因为特征参数的选取而受到影响,特征参数选择不合理会对结果带来偏差。因此这类方法在识别性能方面不稳定,没有用来作为对比方法。而本文选取的对比方法主要为深度学习的方法。这几种方法具备自主学习机制,能够自动提取数据集样本中携带的特征向量并进行充分学习,在识别性能方面要优于现有方法。因此选取这几种方法进行对比会更有价值,也更能突显本文设计的方法的优势。

1 算法概述

InceptionResnetV2-TA 算法包括 3 个步骤:预处理,特征提取和识别。InceptionResnetV2-TA 算法的框图如图 1 所示。

在预处理操作中,通过正交解调待检测的信号来获得信号星座图。在特征提取操作中,采用迁移适配的思想,从 ImageNet 数据集中随机选择 12 类图像样本,将其发送到 InceptionResNetV2 网络完成训练,再保存训练权重。最后,将星座图送入存储权重的网络中进行进一步训练,以用于获取星座图中的幅度和相位特征。在识别操作中,将网络学习到的有效特征送到分类器,从而完成对数字信号调制方式的识别。




图1 InceptionResNetV2-TA 算法的框图

Fig. 1 The flowchart of InceptionResNetV2-TA

2 数字信号预处理

通过采样、量化和编码3个过程,将发送端的模拟信号转换为基带信号,然后通过频带发送到达接收端。由于该信号在传输过程中携带噪声,因此在接收端获得的信号是一个有噪声的信号,其写法如下:

$$s(t) = \text{Re} \left\{ \sum_m A_m e^{j\theta_m} g[t - mT_s] e^{j(2\pi f_c t + \theta_i)} + n(t) \right\} \quad 0 < t < T = NT_s \quad (1)$$

式中: A_m 为第 m 个符号的幅度值; T_s 为符号间隔; $e^{j\theta_m}$ 为星座点; f_c 为信号的载波频率; θ_i 为载波相位差且 $g(t)$ 是矩形脉冲函数; N 为观察时间 T 中的符号数; $n(t)$ 为噪声。

在数字通信中,星座图是观察信号幅度和相位的最直接方法。通过正交解调接收信号获得。接收器接收到信号 $s(t)$ 后,将信号分成两个通道,并与两个相位差为 $\pi/2$ 的载波相乘,然后通过低通滤波器对高频分量进行滤波。最后,获得两个相对独立

的分量:同相(I)分量和正交(Q)分量。这两个分量彼此正交并且是不相关的。这两个分量通常以复数形式表示为 $a + jb$,与复数平面上的一个点对应,这就是一个星座点。此外,每种类型的振幅相位调制信号具有用于表示这种调制方法的对应点集,并且这些点集形成表示该信号的星座图。模量表示信号的振幅变化,而相位表示信号的相位变化。将星座图做归一化处理,再送入 InceptionResNetV2 网络以完成特征提取操作。

3 Inception ResNetV2 网络

传统的神经网络结构都通过增加网络深度来提高训练效果,但是增加层数会导致过度拟合,梯度消失,梯度爆炸等问题。解决方案是将完整连接更改为稀疏连接,但是硬件会优化密集矩阵,因此对最优局部稀疏结构计算密集局部矩阵结构,得到其初始结构。InceptionResNetV2 网络来自 GoogLeNet,其中的 Inception 模块可以更有效地利用计算资源,并且可以在相同计算量下提取更多特征,从而提高训练效果。通过级联操作,可以聚合具有不同内核比例的特征图,以提高网络对比例和网络宽度的适应性,并提高资源利用率。由于所有卷积核都采用前一层作为输入, 5×5 卷积核的计算量太大,因此前一层的输出将合并到网络套网络的方法中。

Inception 模块使用 1×1 卷积有两个目的:一是在相同大小的感受野上叠加更多的卷积,提取星座图中更丰富的特征;另一个目的是减少维数和计算复杂度。在进行 3×3 和 5×5 卷积之前,使用网络中的 1×1 卷积进行降维。其次,对多个大小的卷积执行聚合操作,通过将稀疏矩阵分解为稠密矩阵来提高算法的收敛速度。

在传统的卷积层中,输入与某一尺度的卷积核进行卷积(如 3×3),输出数据为固定维数(如 256 个特征),特征均匀分布在 3×3 的卷积核中。Inception 模块提取星座图中的幅度和相位特征在多个不同的尺度上映射,不再均匀分布。相反,具有高相关度的特征被组合到一起,低相关度或不相关的特征被弱化,使得输出特征冗余相对较小,收敛速度较快。同时,网络还增加了批处理规范化(BN)层。当 BN 层作用于神经网络的某一层时,可以对每个小批量星座图进行归一化处理,避免梯度消失^[16]。

$$\nabla x = \text{Norm}(x, \chi) \quad (5)$$

另外,网络在原始基础上添加了残差结构。也就是说,将直通通道添加到网络,使星座图中的原始输入信息可以直接传输到下一层,从而加快训练速度,防止梯度分散,降低网络复杂性并确保网络深度,从而不会降低性能^[17]。ReLU 被用作激活函数,并且网络模型最后的全连接层用 softmax 完成分类。InceptionResNetV2 网络架构如图 2 所示。




图 2 InceptionResNetV2 网络架构

Fig. 2 Network structure of InceptionResNetV2

4 结合迁移适配的 MPSK 信号调制识别

迁移学习是机器学习的重要分支,其目的是利用数据、任务或模型之间的相似性,将从源项目学到的知识迁移到目标项目。与机器学习相比,迁移学习的优点是:在数据分布中,可以服从不同的分布;在数据标注中,不需要大量的数据标注;在模型中,从训练模型获得的特征和权重可用于训练新模型和完成新任务^[10-12]。

迁移学习主要分为四类:基于样本的、基于特征的、基于模型的和基于关系的迁移学习^[13-15]。本文将 InceptionResNetV2 网络与基于特征的迁移学习相结合,即从 ImageNet 数据集和星座图中共享权重矩阵来进行微调,并将迁移适配方法应用于网络。

基于特征的传递自适应方法进一步分为边缘分布自适应和条件分布自适应。在边缘分布自适应中,为了减小边缘分布 $P_\alpha(x_\alpha)$ 和 $P_\beta(x_\beta)$ 之间的差异,利用经验最大平差(MMD)衡量不同概率分布的适应程度。最小化 $P_\alpha(x_\alpha)$ 和 $P_\beta(x_\beta)$ 之间的距离以进行调整。MMD 定义如下:

$$MMD_\Omega^2(P_\alpha, P_\beta) = \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=n+1}^{n+m} \phi(x_j) \right\|_\Omega^2 \quad (2)$$

$\phi: X \rightarrow \Omega$ 是核空间中的无穷大非线性特征图。根据泰勒定理,可以将 ϕ 扩展为无穷级多项式级数,从而适应不同概率分布下的各阶统计量。

在条件分布自适应中,最小化条件分布 $Q_\alpha(y_\alpha|x_\alpha)$ 和 $Q_\beta(y_\beta|x_\beta)$ 之间的差异对于分布自适应的稳定性非常重要。直接标注学习用于获得星座图中的预标记,然后获得条件分布距离。当分类器未知时,类后验概率 $Q_\alpha(y_\alpha|x_\alpha)$ 和 $Q_\beta(y_\beta|x_\beta)$ 难以拟合。然后,类条件分布 $Q_\alpha(y_\alpha|x_\alpha)$ 和 $Q_\beta(y_\beta|x_\beta)$ 匹配。利用星座图中预先标记的 dB 值和 ImageNet 数据集中的实际标签,星座图 $\gamma \in \{1, \dots, 12\}$ 中的每一类可以用来获得类条件分布 $Q_\alpha(x_\alpha|y_\alpha=\gamma)$ 和 $Q_\beta(x_\beta|y_\beta=\gamma)$ 。其中 $Q_\alpha(x_\alpha|y_\alpha=\gamma)$ 和 $Q_\beta(x_\beta|y_\beta=\gamma)$ 的距离可以使用式(3)得到。

$$MMD_\Omega^2(Q_\alpha^{(\gamma)}, Q_\beta^{(\gamma)}) = \left\| \frac{1}{n^{(\gamma)}} \sum_{x_i \in D_\alpha^{(\gamma)}} \phi(x_i) - \frac{1}{m^{(\gamma)}} \sum_{x_j \in D_\beta^{(\gamma)}} \phi(x_j) \right\|_\Omega^2 \quad (3)$$

式中: $D_\alpha^{(\gamma)} = \{x_i: x_i \in M_\alpha \wedge y(x_i) = \gamma\}$ 为 ImageNet 中属于 γ 类别的图像集合; $y(x_i)$ 为图像 x_i 的实际标签; $D_\beta^{(\gamma)} = \{x_j: x_j \in M_\beta \wedge y(x_j) = \gamma\}$ 为星座图中属于 γ 类别的图像集合,而 $y(x_j)$ 是星座图 x_j 的 dB 值。合并式(2)和(3),可以得到自适应正则项:

$$D_\Omega(J_\alpha, J_\beta) = MMD_\Omega^2(P_\alpha, P_\beta) + \sum_{\gamma=1}^7 MMD_\Omega^2(Q_\alpha^{(\gamma)}, Q_\beta^{(\gamma)}) \quad (4)$$

通过最小化正则项,这两种分布的任意阶矩估计都可以适用于无穷阶非线性特征映射。给定已标记的 ImageNet 数据集 $D_\alpha = \{(x_1, y_1), \dots, (x_n, y_n)\}$ 和未标记的星座图数据集 $D_\beta = \{x_{n+1}, y_{n+1}\}$, 满足 $F_\alpha = F_\beta, H_\alpha = H_\beta, P(x_\alpha) \neq P(x_\beta), Q(y_\alpha|x_\alpha) \neq P(y_\beta|x_\beta)$ 。由于星座图中有 12 类图像,因此在 ImageNet 数据集中随机选择 12 类图像,将其送入 Inception-ResNetV2 网络以完成训练任务。根据迁移适配原理,将通过训练获得的权重矩阵应用于星座图中。

InceptionResNetV2 网络在学习特征 F 或分类模型 f 的同时,将边缘分布 $P(x_\alpha)$ 和 $P(x_\beta)$ 最小化,并使条件分布 $Q(y_\alpha|x_\alpha)$ 与 $P(y_\beta|x_\beta)$ 之间的差异最小化。利用 ImageNet 数据集 D_β 训练 Inception-ResNetV2 网络,再将训练之后的网络应用到星座图 D_α 之中。与直接使用 ImageNet 数据集训练网络相比,本文在 ImageNet 数据集中选择了与星座图中类别数相同的图像来完成训练任务。然后,将所得的权重矩阵用于训练星座图。最后,利用星座图的正确分类来提高 MPSK 信号调制方式的识别精度。

本文利用了这种卷积神经网络去识别 PSK 信

号的调制方式。因为卷积神经网络具有自学习机制,能够对数据集样本中的特征向量进行自主学习并提取。本文所设计的 InceptionResNetV2-TA 方法,是在 InceptionResNetV2 方法基础上加入了迁移适配,根据迁移适配原则先对网络模型进行预训练,以此获得网络权重优化之后的训练模型。再利用该模型对 PSK 信号样本进行训练,自主学习样本中携带的特征向量,进而对 PSK 信号的调制方式进行识别。

本文提出的这种方法相比于没有结合迁移适配原则的 InceptionResNetV2 方法而言,优势在于,通过预训练可以获得权重矩阵得到优化的网络模型。而利用 InceptionResNetV2 方法直接训练 PSK 信号时,网络模型的初始权重是随机生成的,没有得到优化,因此会影响最终的识别结果。

传统方法,如基于高阶累积量的方法,需要通过专家先推导复杂的数学公式得到特征参数,再对特征参数进行设定阈值,根据阈值对 PSK 信号的调制方式进行分类。而阈值是依靠经验来设定的,因此会对识别结果带来影响。

5 实验结果和分析

为了验证本文所提算法的有效性,利用 Matlab 仿真得到相移键控信号,以获得 BPSK, QPSK 和 8PSK 在 6 种信噪比(范围为 1 至 6 dB)下的星座图。图 3 至图 5 是 SNR 为 4 dB 时三种信号的星座图。同时,搭建了 Tensorflow - 1.8.0 + Keras - 2.2.4 框架来训练 InceptionResNetV2-TA 网络。实验所需的数据集包括训练集和测试集。通过训练网络,可以对不同信噪比下的三种信号的星座图进行分类,从而正确识别出 MPSK 信号的调制方式。本节采用 InceptionResNetV2-TA 算法识别 MPSK 信号的调制方式。同时,将 InceptionResNetV2^[18], InceptionV3^[19], ResNet50^[20], DenseNet121^[21] 和准混和似然比(QHLRT-UB)^[22] 作为对比算法,评价指标是对低信噪比下三种信号的星座图的识别率。

这几种方法在其他领域的分类问题中被广泛使用并且有很好的表现。其中,InceptionResNetV2 这种深度卷积神经网络模型,对图像分类表现优异,通过数据增强方法对数据集 BreaKHis 进行实验,识别率基本达到 80% 以上,比大部分已有研究成果效果更优。

InceptionV3 这种网络能够对 6 种球类图像进行



图 3 BPSK (SNR = 4dB)
Fig. 3 BPSK (SNR = 4dB)



图 4 QPSK (SNR = 4dB)
Fig. 4 QPSK (SNR = 4dB)




图 5 8PSK (SNR = 4dB)
Fig. 5 8PSK (SNR = 4dB)

分类。通过与其他分类器进行比较后发现,这种网络在六个类别上成功地达到了 96.64% 的平均分类准确率,高于其他几种分类器。

表 1 显示了通过 6 种算法获得的 3 种信号的识别准确率的结果。从表中可以看出, Inception-ResNetV2-TA 算法对 3 种信号的星座图的识别率最高,识别效果明显优于其他几种方法。在表 1 中,当 SNR 为 3 dB 时, BPSK、QPSK、8PSK 的识别率达到 99.33%、95.33% 和 86.33%, 比 InceptionResNetV2 算法分别提高了 2.67%、2.00% 和 5.00%。

表 1 低信噪比下 BPSK、QPSK 和 8PSK 的识别率比较
Tab. 1 Recognition rate of BPSK, QPSK and 8PSK at low SNR

识别率		Inception – ResNetV2-TA	Inception – ResNetV2	Inception V3	ResNet50	DenseNet 121	QHLRT-UB
BPSK	1 dB	0.893 3	0.863 3	0.82	0.833 3	0.843 3	0.206 0
	2 dB	0.956 6	0.943 3	0.903 3	0.923 3	0.923 3	0.366 7
	3 dB	0.993 3	0.966 6	0.943 3	0.963 3	0.943 3	0.499 7
	4 dB	1.0	1.0	0.993 3	0.996 6	1.0	0.602 7
	5 dB	1.0	1.0	1.0	1.0	1.0	0.6838
	6 dB	1.0	1.0	1.0	1.0	1.0	0.7480
QPSK	1 dB	0.743 3	0.733 3	0.693 3	0.713 3	0.726 6	0.205 5
	2 dB	0.863 3	0.843 3	0.813 3	0.833 3	0.833 3	0.365 8
	3 dB	0.953 3	0.933 3	0.876 6	0.906 6	0.923 3	0.498 9
	4 dB	0.996 6	0.966 6	0.933 3	0.963 3	0.966 6	0.603 3
	5 dB	1.0	0.993 3	0.966 6	0.996 6	0.996 6	0.683 4
	6 dB	1.0	1.0	1.0	1.0	1.0	0.7506
8PSK	1 dB	0.633 3	0.603 3	0.570 0	0.596 6	0.593 3	0.205 5
	2 dB	0.723 3	0.693 3	0.653 3	0.670 0	0.706 6	0.369 1
	3 dB	0.863 3	0.810 0	0.766 6	0.793 3	0.796 6	0.497 1
	4 dB	0.966 6	0.943 3	0.893 3	0.923 3	0.933 3	0.601 9
	5 dB	0.996 6	0.963 3	0.943 3	0.963 3	0.953 3	0.686 4
	6 dB	1.0	0.996 6	0.966 6	0.993 3	0.993 3	0.750 3

6 结 论

本文提出了 InceptionResNetV2-TA 算法,通过将迁移适配与 InceptionResNetV2 相结合,提高了 MPSK 信号的识别准确率。实验表明,该算法在相移键控信号调制方式的识别中具有良好的识别性能。特别是在低 SNR 下,对 BPSK、QPSK 和 8PSK 三种信号调制方式的识别率高于其他对比算法。今后的工作重点是在低 SNR 下识别更多类型的数字信号。

参 考 文 献:

[1] 牛国庆,姚秀娟,闫毅,等. 基于神经网络的数模混合信号调制识别算法[J]. 计算机工程, 2016, 42(4): 101.
NIU Guoqing, YAO Xiujian, YAN Yi, et al. Modulation Recognition Algorithm of Digital and Analog Mixed Signal Based on Work[J]. Computer Engineering, 2016, 42(4): 101.

[2] 黄媛媛,张剑,周兴建,等. 应用深度学习的信号解调[J]. 电讯技术, 2017, 57(7): 741.
HUANG Yuanyuan, ZHANG Jian, ZHOU Xingjian, et al. Demodulation with Deep Learning[J]. Telecommunication Engineer-

ing, 2017, 57(7): 741.

[3] 侯涛,郑郁正. 基于深度学习的通信信号调制方式识别[J]. 无线电工程, 2019, 49(9): 796.
HOU Tao, ZHENG Yuzheng. Communication Signal Modulation Recognition Based on Deep Learning[J]. Radio Engineering, 2019, 49(9): 796.

[4] PENG Shengliang, JIANG Hanyu, WANG Huaxia. Modulation Classification Based on Signal Constellation Diagrams and Deep Learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(3): 718.

[5] WANG Yu, LIU Miao, YANG Jie, et al. Data-Driven Deep Learning for Automatic Modulation Recognition in Cognitive Radios[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 4074.

[6] 彭超然,刁伟鹤,杜振宇. 基于深度卷积神经网络的数字调制方式识别[J]. 计算机测量与控制, 2018, 26(8):222.
PENG Chaoran, DIAO Weihe, DU Zhenyu. Digital Modulation Recognition Based on Deep Convolutional Neural Network[J]. Computer Measurement & Control, 2018, 26(8):222.

[7] YANG Faquan, YANG Ling, WANG Dong, et al. Method of Modulation Recognition Based on Combination Algorithm of K-means Clustering and Grading Training SVM[J]. IEEE Transactions on China Communications, 2018, 15(12): 55.

[8] LI Zan, YANG Faquan, LI Hongyan, et al. Method of Neural Network Modulation Recognition Based on Clustering and Polak-

- Ribiere Algorithm[J]. IEEE Transactions on Journal of Systems Engineering and Electronics, 2014, 25(5): 742.
- [9] 崔旭,熊刚.一种基于星座图模糊分析的数字调制识别方法[J].通信技术,2016,49(9):1155.
- CUI Xu, XIONG Gang. Digital Modulation Recognition Based on Constellation Diagram Fuzzy[J]. Communications Technology, 2016, 49(9): 1155.
- [10] PAI-HENG H, FENG-JU C, YEN-YU L. Learning Discriminatively Reconstructed Source Data for Object Recognition with Few Examples[J]. IEEE Transactions on Image Processing, 2016, 25(8): 3518.
- [11] SHAO Ling, ZHU Fan, LI Xuelong. Transfer Learning for Visual Categorization: A Survey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(5): 1019.
- [12] YANG Liu, JINGLiping, YU Jian, et al. Learning Transferred Weights From Co-Occurrence Data for Heterogeneous Transfer Learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(11): 2187.
- [13] LONG Mingsheng, WANG Jianmin, CAO Yue, et al. Deep Learning of Transferable Representation for Scalable Domain Adaptation[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(8): 2027.
- [14] SHAO Kun, ZHU Yuanheng, ZHAO Dongbin. StarCraft Micromanagement with Reinforcement Learning and Curriculum Transfer Learning[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2019, 3(1): 73.
- [15] LONG Mingsheng, WANG Jianmin, SUN Jiaguang, et al. Domain Invariant Transfer Kernel Learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2015, 27(6): 1519.
- [16] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]// Proceedings of the 32nd International Conference on Machine Learning. 2015, 37: 448.
- [17] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition[C]// IEEE Transactions on CVPR, 2016: 770.
- [18] 刘靖雯;黄理灿.基于Inception-ResNet-V2的乳腺癌病理图像识别研究[J].软件导刊,2020,19(5):225.
- LIU Jingwen, HUANG Lican. Pathological Image Recognition of Breast Cancer Based on Inception-ResNet-V2[J]. Software Guide, 2020, 19(5): 225.
- [19] Ketan Joshi, Vikas Tripathi, Chitransh Bose, et al. Robust Sports Image Classification Using InceptionV3 and Neural Networks[J]. Computer Science. 2020, 167: 2374.
- [20] 王恒,李霞,刘晓芳,等.基于ResNet50网络的乳腺癌病理图像分类研究[J].中国计量大学学报,2019,30(1):78.
- WANG Heng, LI Xia, LIU Xiaofang, et al. Classification of Breast Cancer Histopathological Images Based on ResNet50 Network[J]. Journal of China University of Metrology, 2019, 30(1): 78.
- [21] 蒋斌,涂文轩,杨超,等.基于DenseNet的复杂交通场景语义分割方法[J].模式识别与人工智能,2019,32(5):472.
- JIANG Bin, TU Wenxuan, YANG Chao, et al. Semantic Segmentation Method for Complex Traffic Scene Based on DenseNet[J]. Pattern Recognition and Artificial Intelligence, 2019, 32(5): 472.
- [22] HAMEED F, DOBRE O, POPESCU D. On the Likelihood-based Approach to Modulation Classification[J]. IEEE Transactions on Wireless Communications, 2009, 8(12): 5884.

(编辑:温泽宇)