

文章编号: 2095-4980(2024)11-1289-07

基于渐进式神经架构搜索的自动调制分类方法

陈啸锋, 张茜茜, 桂 冠

(南京邮电大学 通信与信息工程学院, 江苏 南京 210003)

摘要: 近年来, 深度学习的方法已广泛用于信号处理领域并获得了良好的效果。深度学习的方法可利用专家设计的神经网络模型从海量信号数据中自动获取有用的信号特征, 但人工设计深度神经网络模型仍是一个耗时且易出错的过程。为此, 提出一种基于渐进式神经架构搜索的自动调制分类(AMC)方法。该方法可根据特定调制分类任务自动设计网络结构, 并通过遵循最大化模型性能的搜索策略获得最优的轻量级深度神经网络。仿真结果表明, 与基于深度学习的调制分类方法相比, 本文提出的方法可在无需人工设计神经网络的情况下, 且在低参数量和浮点运算下实现最优的调制分类准确率, 其平均识别准确率可达 92.82%。

关键词: 自动调制分类; 深度学习; 渐进式神经架构搜索; 轻量级深度神经网络

中图分类号: TP391

文献标志码: A

doi: 10.11805/TKYDA2023080

Progressive neural architecture search based automatic modulation classification method

CHEN Xiaofeng, ZHANG Xixi, GUI Guan

(College of Telecommunications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing Jiangsu 210003, China)

Abstract: In recent years, deep learning methods have been widely applied in the field of signal processing and have achieved good results. Deep learning methods can automatically acquire useful signal features from massive signal data using neural network models designed by experts, but the manual design of deep neural network models remains a time-consuming and error-prone process. To address this, a method for Automatic Modulation Classification(AMC) based on progressive neural architecture search is proposed. This method can automatically design network structures according to specific modulation classification tasks and obtain the optimal lightweight deep neural network by following a search strategy that maximizes the model performance. Simulation results show that compared to deep learning-based modulation classification methods, the proposed method can achieve optimal modulation classification accuracy without manual design of neural networks, with low parameter volume and floating-point operations, achieving an average recognition accuracy up to 92.82%.

Keywords: Automatic Modulation Classification; deep learning; progressive neural architecture search; lightweight deep neural network

自动调制分类(AMC)的主要目标是检测接收信号的调制类型, AMC技术已广泛用于军事、民用、情报和安全等领域^[1]。在军事应用中, 主要用于从加密的调制信号中提取发射信息, 也可识别电子战中的发射单元以产生匹配的干扰信号。在现代民用领域, 主要用于根据信道条件自适应地选择调制方案, 优化传输可靠性和数据速率。因此, AMC已成为信号处理领域不可或缺的一部分。传统的AMC方法主要有两种: 基于似然比(Likelihood Based, LB)的方法和基于特征(Featured Based, FB)的方法。LB方法通过将似然比与阈值进行比较做出决策, 该方法在已知信道先验信息时可达最优性能, 但计算复杂, 且实际通信系统中信道状态等先验信息一般难以获取。FB方法需要人工提取有效的信号特征, 如, 统计特征、过零点特征、瞬时特征和星座特征等^[2-3], 并且要选择适用的分类器。可见, 只有具备一定的专业知识和经验并事先知道调制信号信息, 才能提取到有用的信号特

征。因此,特征和分类器的选择决定了调制信号的分类性能。

近年来,深度学习(Deep Learning, DL)在图像分类、机器翻译和目标识别等领域的应用已取得显著进展,得益于其强大的特征提取和分类回归能力,许多学者尝试将DL应用于通信领域^[4-6],并获得了不错的效果。基于DL的AMC方法,相较于手动提取调制信号特征,DL方法能够通过端到端的方式自动提取信号特征并实现分类。由于DL的快速发展,出现了很多性能高效的网络模型,如:ResNet、MobileNet、Inception和DenseNet等,这些经典的网络模型经过微调之后,可在AMC任务中充当分类器的角色,并能够取得较好的分类性能。ZHU等^[7]结合深度神经网络和高阶累积量实现了AMC;杨洁等^[8]提出一种轻量级的AMC方法。现有的基于DL的AMC方法存在计算量大、硬件要求高等问题;此外,高性能的DL网络模型设计是一个非常具有挑战性且耗时的过程。因此,本文将自动机器学习(Auto Machine Learning, AutoML)方法引入AMC领域中。

神经网络架构搜索(Neural Architecture Search, NAS)作为AutoML的一个子领域,其目的在于实现网络模型设计和选择过程自动化,降低网络模型设计难度,解决DL模型中复杂的调参问题^[9]。NAS可分为搜索空间、搜索策略和性能评估策略3个基本要素,其中NAS中常见的搜索策略有:随机搜索(Random Search, RS)、基于强化学习(Reinforcement Learning, RL)^[10]、基于进化算法(Evolutionary Algorithm, EA)^[11]、基于贝叶斯优化(Bayesian Optimization, BO)^[12]和基于梯度^[13-14]等。具体而言,首先,搜索空间给出了网络模型的各个层级之间的所有可能选择的连接操作;然后,应用不同的搜索策略和优化算法自动调整神经网络的结构和参数;最后,通过性能评估策略得到最优的网络模型结构。本文提出了一种基于渐进式NAS的AMC方法,该方法将基于梯度下降的渐进式NAS用于AMC任务中,并根据特定的调制信号分类任务自动搜索出最优的轻量级网络模型。

1 信号模型与数据集描述

1.1 信号模型

若接收机从单个信号源接收信号,则接收信号的第*i*个样本用数学表达式可表示为:

$$r_i = h * s_i + n_i, i = 1, 2, \dots, I \quad (1)$$

式中:*h*为服从瑞利分布的随机信道;*为卷积;*s_i*为发送的调制信号;*n_i*为振幅服从高斯分布的加性高斯白噪声;*I*为样本总数。

1.2 数据集生成与处理

根据上述信号模型,使用Matlab 2021a仿真软件模拟出上述信道环境下的调制信号数据,其数据集生成的流程图如图1所示。

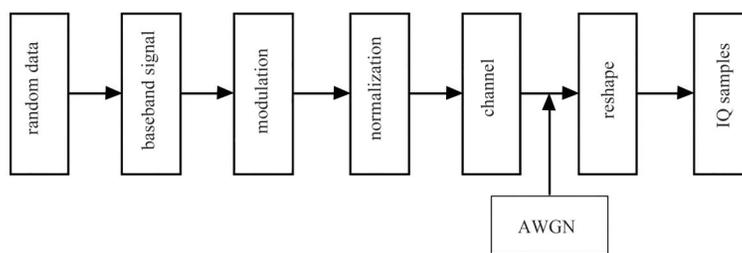


Fig.1 The process of dataset generation

图1 数据集生成流程

将接收到的调制信号分解为实部与虚部两部分,实部即为信号的同相分量,虚部为信号的正交分量,则信号的实部与虚部可表示为:

$$r_{re} = [\text{Real}(r(1)), \text{Real}(r(2)), \dots, \text{Real}(r(I))] \quad (2)$$

$$r_{im} = [\text{Imag}(r(1)), \text{Imag}(r(2)), \dots, \text{Imag}(r(I))] \quad (3)$$

式中:*r_{re}*为调制信号的实部,记为I;*r_{im}*为调制信号的虚部,记为Q。最后再将I路信号与Q路信号进行纵向合并,可得到I/Q信号:

$$r_{IQ} = N \times [r_{re} \ r_{im}]_{L \times 2} \quad (4)$$

式中:*N*为调制信号的样本数;*L*为信号序列的长度。可以看出I/Q信号数据集由*N*行、*L*列的二维矩阵组成,本

文所用的数据集中 L 为 128。

本文的信号数据集中共有 8 种不同的调制方式，包括 3 种相移键控：二进制相移键控(Binary Phase Shift Keying, BPSK)、正交相移键控(Quadrature Phase Shift Keying, QPSK)、八移相键控(8 Phase-Shift Keying, 8PSK)；3 种频移键控：二进制频移键控(2 Frequency-Shift Keying, 2FSK)、4FSK、8FSK；最小频移键控(Minimum Shift Keying, MSK)和正交幅度调制(Quadrature Amplitude Modulation, QAM)。其在上述信道环境下的调制信号的采样频率设置为 8 kHz，载波频率设置为 2 GHz，多普勒频移设置为 100 Hz。该调制信号数据集共有 176 000 个数据样本，其中 8 种不同的调制方式都各有 22 000 个数据样本，每种调制方式的信噪比(Signal-to-Noise Ratio, SNR)以 2 dB 为间隔，在 0~20 dB 之间均匀分布。

2 基于渐进式 NAS 的 AMC 方法

本文采用渐进式 NAS 方法，根据特定的 AMC 任务自动构建神经网络模型，其本质上是一种通过自动化的方式寻找最优神经网络架构的算法。NAS 算法的流程如图 2 所示，包含 3 个具体部分：搜索空间、搜索策略和性能评估策略。首先，定义一个搜索空间 α ；其次，按照一定的搜索策略从搜索空间 α 中搜索网络架构 A ；最后，依据性能评估策略对网络架构 A 进行评估，以此进行不断的迭代，最终得到性能最佳的神经网络架构。

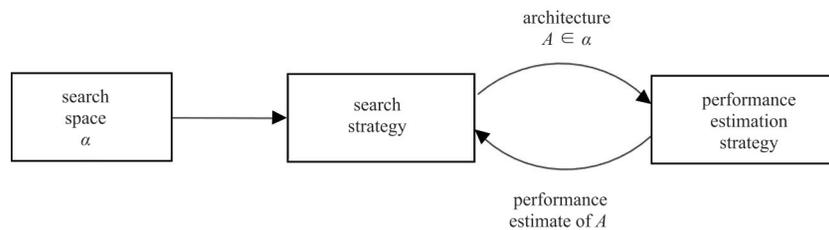


Fig.2 Flowchart of NAS algorithm
图 2 NAS 算法流程图

2.1 搜索空间

早期的 NAS 方法试图搜索整个网络结构，这是一项非常耗时和困难的任务。为减少搜索时间，近年来，NAS 方法侧重于寻找最优的单元(cell)，然后将这些 cell 堆叠起来构建最终的神经网络，这种基于 cell 的网络结构如图 3 所示。这种方法减小了自由度并达到了减小搜索空间的目的，同时也使搜索到的结构具有更好的数据迁移能力。本文也采用此方法进行搜索，cell 单元一共分为两种，分别是 Normal cell 和 Reduction cell，其中 Normal cell 的输入尺寸与输出尺寸相同；Reduction cell 的输出尺寸为输入尺寸的一半。本文中，由于信号样本是一组 2×128 的向量，因此将接收到的调制信号作为一维数据传输到搜索网络。最终搜索到的网络模型如图 4 所示，其由 2 个 cell 单元堆叠而成，分别是 1 个 Normal cell 和 1 个 Reduction cell。

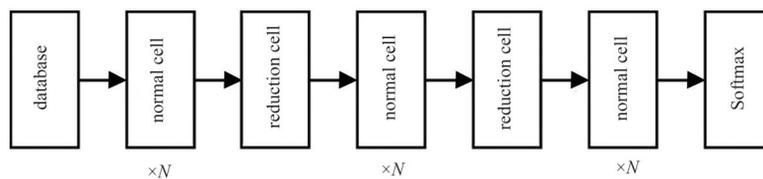


Fig.3 Cell-based network structure
图 3 基于 Cell 单元的网络结构

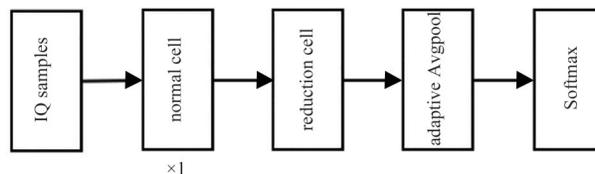


Fig.4 The final searched network structure
图 4 最终搜索到的网络结构

cell 被定义为一个有向无环图(Directed Acyclic Graph, DAG)。DAG 由 N 个有序的节点组成，即： $\{x_0, x_1, \dots, x_{N-1}\}$ ，每一个节点 x_i 都代表一个隐式的表达式，有向边 $E_{i,j}$ 与节点 x_i 处的操作 $o_{i,j}$ 相关联。假设 cell 有 2 个输入节点和 1 个输出节点，对于卷积操作的 cell，输入节点是前 2 层中的输出，则 cell 的输出可由所有中间节

点的相互操作得到。每一个中间节点 x_j 都可通过它的前序节点经过操作 $o_{i,j}$ 得到，其数学表达式为：

$$x_j = \sum_{i < j} o_{i,j}(x_i) \quad (5)$$

式中 $o_{i,j}$ 为节点 x_i 和节点 x_j 之间的所有可能操作。其可能为零操作(zero)，表示 2 个节点之间没有连接。因此，可以把搜索 cell 的过程简化为搜索 cell 中的有向边 $E_{i,j}$ 上的操作。

2.2 可微分的搜索策略

使用基于可微分架构搜索(Differentiable Architecture Search, DARTS)的策略方法，把离散的搜索空间变为连续空间，使目标函数可微，则可以通过梯度下降的方法进行有效且快速的网络架构搜索。假设 O 为整个预定义的操作空间，即所有可能的操作候选集，如：卷积操作、池化操作、零操作等， O 中的每一个元素都表示为用于节点 x_i 的某个操作函数 $o(i)$ 。为使搜索空间变为连续空间，使用 Softmax 函数将节点的某一个特定操作放宽到所有可能的操作，其数学表达式为：

$$\bar{o}_{i,j}(x) = \sum_{o \in O} \frac{e^{\alpha_{o(i,j)}}}{\sum_{o' \in O} e^{\alpha_{o'(i,j)}}} o(x) \quad (6)$$

式中节点 x_i 和节点 x_j 之间的操作权重值由维度为 $|O|$ 的向量 $\alpha_{(i,j)}$ 进行参数化。因此，可把搜索 cell 中的有向边 $E_{i,j}$ 操作转化为搜索一组连续的变量值，即： $\alpha = \{\alpha_{(i,j)}\}$ 。当搜索过程结束后，只需把每一混合操作 $\bar{o}_{i,j}$ 替换为最大 Softmax 值的操作，就能得到最终的 cell 结构。

搜索空间变为连续的空间后，训练的目标转换为网络架构 α 和模型权重 ω 。因为搜索空间是连续的，可使用梯度下降的方法。本文的搜索策略类似于 RL 或 EA，把验证集的准确率作为奖励(Reward)或适应度(Fitness)，然后使用梯度下降的方法优化验证集的损失值。设 L_T 和 L_V 分别为训练集和验证集的损失函数，这两种损失函数由网络架构 α 和模型权重 ω 共同决定。因此，网络架构搜索的目的旨在找到最佳的网络架构 α^* 和最小的验证集损失值 $L_V(\alpha^*, \omega^*)$ ，其中与最佳的网络架构 α^* 相关的 ω^* 由最小的训练集损失值确定，即： $\omega^* = \arg \min_{\omega} L_T(\omega, \alpha^*)$ 。这也意味着一个双层优化的问题：

$$\begin{cases} \min_{\alpha} = L_V[\omega^*(\alpha), \alpha] \\ \text{s.t. } \omega^* = \arg \min_{\omega} L_T(\omega, \alpha) \end{cases} \quad (7)$$

对于这一双层优化问题，通过梯度下降的方法虽然可以准确地评估网络架构，但这种内部优化带来了巨大的计算量。因此，可对以上的算法做一个简单的近似优化：

$$\nabla_{\alpha} L_V[\omega^*(\alpha), \alpha] \approx \nabla_{\alpha} L_V(\omega - \zeta \nabla_{\omega} L_T(\omega, \alpha), \alpha) \quad (8)$$

式中： ω 为当前算法所保持的权重值； ζ 为进行内部优化的学习率。它的主要思想是只通过一个训练步骤简单的自适应 ω 去近似 $\omega^*(\alpha)$ ，而不是完全地通过训练到收敛的方式进行内部优化。

2.3 渐进式搜索策略

在 DARTS 方法的模型搜索阶段中，每轮训练后 2 个节点之间的操作方式都要重新选择，这无疑增加了训练成本，造成了一定的冗余度且可能导致整个网络模型出现过拟合问题。因此，本文对模型搜索阶段进行优化，采用一种渐进式搜索方式，把整个模型搜索过程再细分为 3 个阶段：在第一阶段，初始候选集的操作数为 8，经过搜索与评估得到每种候选操作的 Softmax 值，以此为依据进行排序并保留 5 种操作作为下一阶段的候选集；在第二阶段，初始候选集的操作数为 5，经过搜索与评估得到每种候选操作的 Softmax 值，以此为依据进行排序并保留 3 种操作作为下一阶段的候选集；在第三阶段，初始候选集的操作数为 3，经过搜索与评估得到每种候选操作的 Softmax 值，以此为依据进行排序并保留 1 种操作得到最终的 cell 结构。模型搜索过程的 3 个阶段示意图如图 5 所示。本文中的候选集 O 中的候选操作数共有 8 种，分别是：3×3 扩张卷积、5×5 扩张卷积、3×3 可分离卷积、5×5 可分离卷积、3×3 平均池化、3×3 最大池化、跳跃连接和零操作。另外，为减小整个网络的参数量，本文设置了 4 个中间节点。

3 仿真实验及结果分析

3.1 实验细节

信号数据集由 Matlab 2021a 生成，所有实验运行在 PyCharm2021 上，CPU 为 Inter (R) Xeon (R) Silver 4210R@

2.40 GHz，GPU 为 NVIDIA GeForce RTX 2080Ti。在模型搜索阶段，3 个阶段中的每一个阶段的 epoch 都设置为 25，即：基于渐进式 NAS 的 AMC 方法的搜索阶段的 epoch 为 75。在模型评估阶段，训练的 epoch 设置为 150，详细的参数设置如表 1 所示。另外，为显示渐进式方法的优越性，还进行了一组基于普通 NAS 的 AMC 方法的对比实验，模型搜索阶段的 epoch 设置为 100，其余参数设置与表 1 相同。

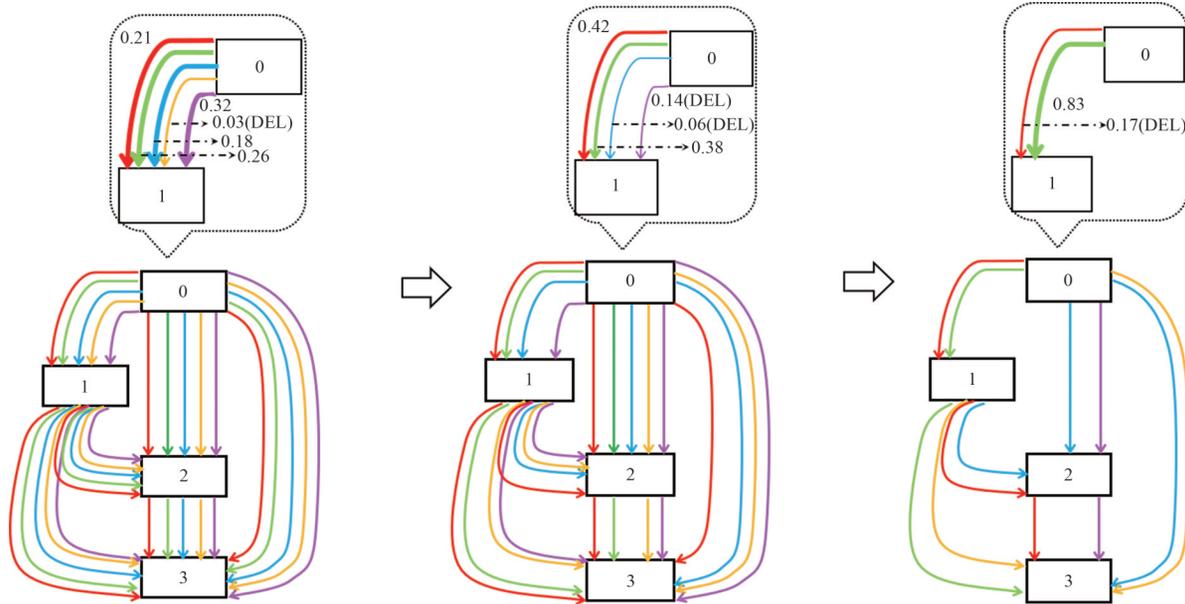


Fig.5 Three stages of the model search process
图 5 模型搜索过程的 3 个阶段

表 1 参数设置

Table1 Parameter setting

parameter	value
modulation type	BPSK,QPSK,8PSK,2FSK,4FSK,8FSK,MSK,QAM
Doppler shift/Hz	100
input	16 × 16
input channel	16
searching stage:batchsize	256
training stage:batchsize	128
searching stage:learning rate	0.1
training stage:learning rate	0.025
searching stage ratio of training set to verification set	5:5
training stage:ratio of training set to verification set	7:3

本文选用了 6 种 DL 网络模型，分别为 AlexNet、InceptionV2、VGG16、ResNet18、MobileNetV3 和 DenseNet121，并引入到 AMC 任务作为对比实验。为更好地适应 DL 网络模型，仿真实验中将调制信号数据集的维度由 2×128 转变为 16×16 ，并对网络模型进行微调，把每个模块的第 2 个卷积操作的步长从 2 调整为 1。为保证仿真实验的公平性，本文对 6 种网络模型设置了相同的训练参数，即：batchsize 为 128，初始学习率为 0.025，epoch 为 150，训练集与测试集的比例为 7:3。

3.2 实验结果

经过搜索过程的 3 个阶段后，搜索出的最优的 Normal cell 和 Reduction cell 如图 6 和图 7 所示，由这 2 个 cell 堆叠形成最终的神经网络，然后经过模型训练阶段后得到调制信号的分类结果。对最终的神经网络进行测试，得到每种 SNR 下的分类准确率和整个网络模型的平均准确率如图 8 与表 2 所示。

从表 2 中可以看出，基于 DL 的 AMC 方法中，性能最好的是 MobileNetV3，2 种基于 NAS 的 AMC 方法：DARTS 和 PDARTS(Progressive DARTS)平均准确率都在 92% 以上，其平均准确率已超过了 6 种基于 DL 的 AMC 方法。最重要的是，PDARTS 的参数数量比 MobileNetV3 减少近 244 倍，其轻量化性能得到了大幅提升。从图 8 中可以明显看出，两种基于 NAS 的 AMC 方法在每一个 SNR 上的分类准确率都比基于 DL 的 AMC 方法要高，特别是在 0~10 dB 之间。因此，基于 NAS 的 AMC 方法不仅不需要人工地设计网络模型，而且也有着更好的分类性能。

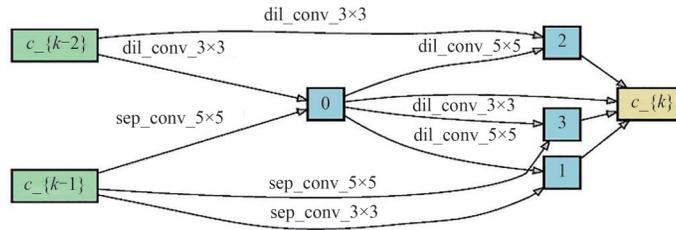


Fig.6 Normal cell structure
图6 Normal cell结构图

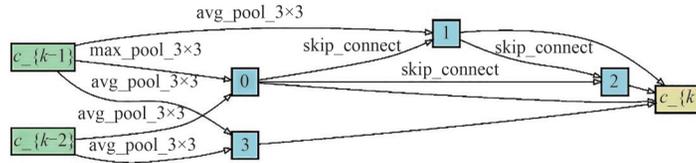


Fig.7 Reduction cell structure
图7 Reduction cell结构图

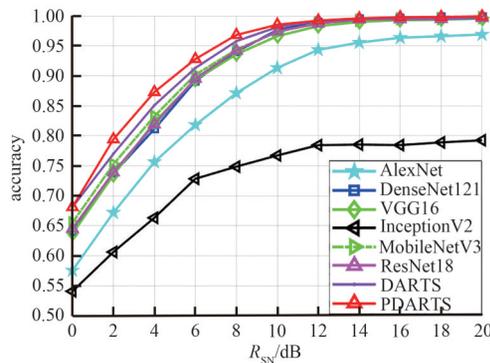


Fig.8 The classification accuracies of eight network models with different SNRs
图8 八种网络模型随着不同的SNR的分类准确率

表2 八种网络模型的平均准确率和计算开销

Table2 The average accuracy and computational cost of eight network models

network model	average accuracy/%	parameter amount	FLOPs
AlexNet	85.48	466 216	18 727 000
DenseNet121	90.69	7 467 000	444 875 000
VGG16	90.39	15 771 000	3 770 000 000
InceptionV2	72.64	7 334 000	11 005 000
MobileNetV3	91.15	3 215 000	44 374 000
ResNet18	90.73	11 172 000	138 871 000
DARTS	92.02	19 992	3 051 000
PDARTS	92.82	13 160	3 122 000

从表2和图8中也可以看出，基于渐进式NAS的AMC方法(PDARTS)与基于NAS的AMC方法(DARTS)在分类性能上也有一定的提升，PDARTS的平均分类准确率提升了0.8%，参数量减少了1.5倍。因为这两种方法的搜索阶段总的epoch不同，比较网络模型搜索阶段的总时间不公平。因此，在完成网络模型的整个搜索过程后，分别统计每个阶段完成每个epoch所需要的平均时间，其结果如表3所示。从表3中可以看出，基于渐进式NAS的AMC方法的3个阶段每个epoch的平均消耗时间都在逐步降低，且均比基于NAS的AMC方法低。因此，基于渐进式NAS的AMC方法能够更好地完成本文的AMC任务，达到预期的分类性能。

表3 两种方法在网络模型搜索阶段完成每个epoch的平均消耗时间
Table3 The average time consumption of the two methods to complete each epoch in the network model searching stage

method	the average training time per epoch/s
DARTS	255
PDARTS stage 1	223
PDARTS stage 2	122
PDARTS stage 3	99

4 结论

本文提出了一种基于渐进式 NAS 的 AMC 方法，不需要手工设计网络模型，可通过构建搜索空间、优化算法及模型评估三个角度自动调整网络的结构和参数，得到最优网络模型。仿真结果表明，该方法与传统基于 DL 的 AMC 方法相比，不仅提升了调制分类的准确率，而且大大降低了网络模型的计算开销。该方法与基于 NAS 的 AMC 方法相比，进一步提升了分类和轻量化性能。未来，将优化搜索空间中的候选操作空间，并探索不同的搜索策略，以自动搜索到更轻量级的模型，并实现更好的分类性能。

参考文献：

- [1] ZHU Z C, NANDI A K. Automatic modulation classification: principles, algorithms and applications[M]. Hoboken: John Wiley&Sons, 2015.
- [2] HUANG Sai, YAO Yuanyuan, WEI Zhiqing, et al. Automatic modulation classification of overlapped sources using multiple cumulants[J]. IEEE Transactions on Vehicular Technology, 2017,66(7):6089–6101. doi:10.1109/TVT.2016.2636324.
- [3] HSUE S Z, SOLIMAN S S. Automatic modulation recognition of digitally modulated signals[C]// IEEE Military Communications Conference, 'Bridging the Gap. Interoperability, Survivability, Security. Boston, MA, USA: IEEE, 1989:645–649.
- [4] KATO N, MAO B M, TANG F X, et al. Ten challenges in advancing machine learning technologies toward 6G[J]. IEEE Wireless Communications, 2020,27(3):96–103. doi:10.1109/MWC.001.1900476.
- [5] ZHOU Zhenyu, LIAO Haijun, GU Bo, et al. Robust mobile crowd sensing: when deep learning meets edge computing[J]. IEEE Network, 2018,32(4):54–60. doi:10.1109/MNET.2018.1700442.
- [6] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. 通信学报, 2019,40(2):19–23. (GUI Guan, WANG Yu, HUANG Hao. Deep learning based physical layer wireless communication techniques: opportunities and challenges[J]. Journal on Communications, 2019,40(2):19–23.) doi:10.11959/j.issn.1000-436x.2019043.
- [7] ZHU X, FUJII T. A novel modulation classification method in cognitive radios using higher-order cumulants and denoising stacked sparse autoencoder[C]// 2016 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA). Jeju, Korea (South): IEEE, 2016:1–5. doi:10.1109/APSIPA.2016.7820860.
- [8] 杨洁, 董标, 付雪, 等. 基于轻量化分布式学习的自动调制分类方法[J]. 通信学报, 2022,43(7):134–142. (YANG Jie, DONG Biao, FU Xue, et al. A lightweight decentralized learning-based automatic modulation classification method[J]. Journal on Communications, 2022,43(7):134–142.) doi:10.11959/j.issn.1000-436x.2022145.
- [9] ELSKEN T, METZEN J H, HUTTER F. Neural architecture search: a survey[DB/OL]. (2019-04-26). <https://arxiv.org/abs/1808.05377>.
- [10] ZOPH B, LE Q V. Neural architecture search with reinforcement learning[DB/OL]. (2016-11-05). <https://arxiv.org/abs/1611.01578>.
- [11] XIE L X, YUILLE A. Genetic CNN[C]// 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017:1388–1397. doi:10.1109/ICCV.2017.154.
- [12] KANDASAMY K, NEISWANGER W, SCHNEIDER J, et al. Neural architecture search with Bayesian optimisation and optimal transport[C]// Neural Architecture Search with Bayesian Optimisation and Optimal Transport. [S.l.]: ACM, 2018:2020–2029.
- [13] LIU H X, SIMONYAN K, YANG Y M. Darts: differentiable architecture search[DB/OL]. (2019-04-29). <https://arxiv.org/abs/1806.09055>.
- [14] CHEN Xin, XIE Lingxi, WU Jun, et al. Progressive differentiable architecture search: bridging the depth gap between search and evaluation[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019:1294–1303. doi:10.1109/ICCV.2019.00138.

作者简介：

陈啸锋(1998–)，男，在读硕士研究生，主要研究方向为基于自动机器学习的自动调制分类技术。email: 1020010409@njupt.edu.cn.

桂冠(1982–)，男，博士，教授，博士生导师，主要研究方向为人工智能、深度学习、智能通信、智能物联网等 6G 技术。

张茜茜(1997–)，女，在读博士研究生，主要研究方向为调制信号分类、辐射源识别、网络流量监测与深度学习等。