

# 基于神经进化的深度学习模型研究综述

韩 冲, 王俊丽, 吴雨茜, 张超波

(同济大学电子与信息工程学院, 上海 201804)

**摘 要:** 深度学习研究发展至今已可以胜任各类识别、分类、生成任务,但是对于不同的任务,神经网络的结构或参数不可能只是微小的变化,依然需要专家进行调整.在这样的情况下,自动化地调整神经网络的结构或参数成为研究热点.其中,以达尔文自然进化论为灵感的神经进化成为主要优化方法.利用神经进化优化的深度学习模型以种群为基础,通过突变、重组等操作进化,可实现自动地、逐步地构建神经网络并最终选择出性能最优的深度学习模型.本文简述了神经进化与进化计算;详细概述了各类基于神经进化的深度学习模型;分析了各类模型的性能;总结了神经进化与深度学习融合的前景并探讨下一步的研究方向.

**关键词:** 神经进化; 深度学习; 进化计算; 卷积神经网络; 生成式对抗网络; 自动编码器; 长短期记忆网络; 深度强化学习

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112 (2021)02-0372-08

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

DOI: 10.12263/DZXB.20200139

## A Review of Deep Learning Models Based on Neuroevolution

HAN Chong, WANG Jun-li, WU Yu-xi, ZHANG Chao-bo

(College of Electronics and Information Engineering, University of Tongji, Shanghai 201804, China)

**Abstract:** With the development of deep learning, it has been competent to various types of tasks, such as identification, classification, and generation. However, the structures or parameters of artificial neural networks cannot be only a little changed for different task, experts need to adjust the structures or parameters of the neural network. In such situations, the method of automatically adjusting the structures or parameters of the artificial neural network has become a research hotspot, among these methods, neuroevolution inspired by Darwin's natural evolution theory has become the main optimization method for that. Deep learning models optimized by neuroevolution based on population, evolving through mutation, crossover and other operations, can automatically and gradually construct the neural network and then choose the most optimal deep learning model. This paper summarizes the neuroevolution and the evolutionary computation. It elaborates various deep learning models based on neuroevolution, and analyzes the performance of these models. It concludes prospects of the deep learning model based on neuroevolution and discusses the next research directions.

**Key words:** neuroevolution; deep learning; evolutionary computation; convolutional neural networks; generative adversarial networks; autoencoder; long short-term memory networks; deep reinforcement learning

## 1 引言

现如今,在我们的生活中人工智能技术无处不在,从语音识别、人脸识别到无人驾驶,都离不开深度学习模型算法支持.因此,为了真正意义上实现人工智能,对深度学习模型的优化十分重要.

在人工神经网络中,有成千上万的连接,最为广泛的权重调节方法就是随机梯度下降<sup>[1]</sup>,但是对于网络

的结构、神经元之间应该如何连接等问题,还是需要研究人员基于自身经验不断地实验得出.与之相比,人类大脑中的神经元的架构是通过自然进化而来,那么人工神经网络是否也可以通过进化的方式自动地生成,因此神经进化被提出并研究发展至今.

神经进化<sup>[2]</sup>是利用进化计算或生物进化的思想产生人工神经网络的参数、结构和规则的方法.为了优化深度学习等人工神经网络模型,实现自动化调整神经

网络中的参数或结构,研究人员纷纷将神经进化应用于各类深度学习模型中,近几年的研究表明,在某些特定情况下通过神经进化产生的神经网络性能更优.同时,通过进化计算调节网络连接权重可以很好地避免梯度下降常导致的局部优化问题.

## 2 神经进化

神经进化的发展实际要追溯到进化计算的发展.20世纪60年代,继达尔文的进化论提出后,进化论应用于计算机的想法纷纷被提出.美国的计算机科学家 Lawrence J Fogel 提出了进化编程 (Evolutionary Programming, EP)<sup>[3]</sup>,紧随其后,美国密歇根大学的 John Henry Holland 借鉴了达尔文的生物进化论和孟德尔遗传定律的基本思想,提出遗传算法 (Genetic Algorithm, GA)<sup>[4]</sup>.同一时期,德国的 Ingo Rechenberg 和 Hans-Paul Schwefel 提出了模仿自然突变和自然选择的进化策略 (Evolutionary Strategy, ES)<sup>[5]</sup>.但是,由于当时的计算机容量小、运算速度慢,导致它们都没有引起人们过多的关注.到了20世纪90年代初,一种全局优化算法遗传编程 (Evolutionary Programming, EP)<sup>[6]</sup>由斯坦福大学的 Koza 提出的.从此,与进化相关的算法也开始被应用在机器学习和一些复杂函数的优化问题上.

进化计算<sup>[7]</sup>是受生物进化过程中“优胜劣汰”的核心思想启发而提出的计算方法.在人工智能领域,进化计算通常涉及到组合优化问题,通过程序迭代模拟自然选择机制和遗传信息的规律.本小节将对进化计算中的四个主要的分支算法从个体描述、遗传算子、选择方式三个方面进行介绍.

遗传算法将原问题的解空间映射到串空间,使用固定长度的二进制字符串表示群体中的个体.遗传算法以交叉变异为主,突变为辅<sup>[7]</sup>.交叉算子主要用于产生后代,突变算子用于保持种群中个体的差异性.遗传算法基于概率对个体进行选择,适应度高的个体被选中的概率大,适应度低的个体被选中的概率小.同时,适应度低的个体不会百分百淘汰,也有一定的概率选中,保证了个体的多样性,避免某些重要的字符(基因)特征过早的丢失.

遗传编程是通过遗传的思想进行计算机编程.在遗传编程中,广义的计算机程序为一个个体,通常使用树的结构表示,每棵树的分支都由函数集和终止符集组成,函数集由标准数学函数组成,终止符集由变量和常量组成.遗传编程有多种遗传算子,例如交叉变异、突变、编辑操作、封装操作等,以交叉为主,同时其他的遗传算子作为辅助操作提高群体的多样性并保护重要基因不被丢失.遗传编程以个体适应度与总体适应度和的比值作为这个个体的被选择的概率.

进化策略则是直接在解空间进行操作,使用十进制的实数表示个体,以突变为主,重组(交叉)为辅.突变主要是通过改变正态分布中的  $\sigma$  参数来实现.进化策略使用的是百分百淘汰制,根据个体的适应度大小,完全保留适应度高的个体而完全淘汰适应度低的个体.

进化编程也是使用十进制实数来表示个体.进化编程只有突变操作,没有类似交叉或重组的遗传算子.进化编程使用的是随机性的  $q$  竞争选择法. $q$  竞争选择法指的是在  $2\mu$  个父代和子代个体中,随机选择  $q$  个个体作为测试集,对于非测试集的其他个体,例如个体  $i$ ,将个体  $i$  的适应值与测试集中的  $q$  个个体的适应值一一对比,记录个体  $i$  优于或等于测试集  $q$  中个体的次数作为个体  $i$  的分数.根据上述的方法对  $2\mu$  个个体评分,每次一个循环都会重新选择新的  $q$  个个体作为测试集.

根据以上的具体分析,总结对比了遗传算法、遗传编程、进化策略、进化编程,如表 1 所示.

表 1 以上四种算法的总结对比

要素 算法	个体描述	遗传算子	选择方式
遗传算法	固定长度 二进制字符串	交叉为主 突变为辅	基于概率
遗传编程	树状结构表示 计算机程序	交叉为主 突变为辅	基于概率
进化策略	十进制实数	突变为主 重组为辅	淘汰选择机制
进化编程	十进制实数	只有突变	$q$ 竞争选择机制

## 3 基于神经进化的深度学习模型

本节主要对近几年基于神经进化的卷积神经网络 (Convolutional Neural Networks, CNN)、生成式对抗网络 (Generative Adversarial Networks, GAN)、自动编码器 (autoencoder)、长短期记忆 (Long Short-Term Memory, LSTM) 网络、深度强化学习 (Deep Reinforcement Learning, DRL) 这五类深度学习模型进行详细介绍.除此之外,神经进化与其它深度学习模型结合的文献也不在少数,例如基于神经优化的深度置信网络模型 MODBNE (MultiObjective Deep Belief Networks Ensemble)<sup>[8]</sup>,该模型种群以一个深度置信网络为个体,通过单个模型的准确性和多样性作为优化目标对模型逐层进化,另外还有基于神经进化的循环神经网络<sup>[9,10]</sup>等.可见,神经进化几乎涉及了各类深度学习模型,影响也在持续扩大.

### 3.1 卷积神经网络

在卷积神经网络中 ConvGP<sup>[11]</sup> (Convolutional Genetic Programming) 为代表,它是一种利用遗传编程算法优

化 CNN 进行图像分类的方法. ConvGP 将图像分类的各个阶段合并到一个单独的分层树结构中<sup>[12]</sup>. 第一层为卷积层,用于特征表示,池化函数主要用来降低图像的维度,提高图像特征提取的速度. 第二层为聚集层,用于识别图像中的关键区域,在关键区域选择一个适合的函数,并产生特征表示. 第三层为分类层,输出一个数值,用来二分类一个实例,即该实例为正例还是反例. 在初始阶段,树被随机的构建. 在进化过程中,树通过交叉和突变操作被进化,保留每一代表现优异的个体. 到达第 50 代之后,表现最优的个体被返回.

除了 ConvGP 之外,CGP-CNN<sup>[13]</sup> (Cartesian Genetic Programming-CNN) 也是通过遗传编程优化 CNN,原理与 ConvGP 类似,不同的是 CGP-CNN 采用了卷积块、张量连接等高性能模块作为节点函数. 除了这两种基于 GP 的方法,还有利用 GA 优化 CNN 的方法 GeNet<sup>[14]</sup> (Genetic CNN),它通过节点之间的有向边来编码网络结构,并将其表示为一个二进制字符串,再通过进化机制(突变、交叉、选择)来生成具有竞争力的个体并淘汰性能差的个体. 图 1 是 GeNet 对 VGGNet<sup>[15]</sup>、ResNet<sup>[16]</sup>、DenseNet<sup>[17]</sup> 三个经典 CNN 的二进制编码. GeNet 仅对编码区的网络节点编码,图中三种不同类型的 CNN 编码区都有 4 个节点(卷积层),按顺序可以将节点编码为  $V_1$ 、 $V_2$ 、 $V_3$ 、 $V_4$ ,4 个节点网络结构的编码可以由一个 6 位的二进制字符串表示. 其中,字符串第 1 位表示  $V_1$  与  $V_2$  之间是否包含有向边连接,第 2、3 位分别表示  $V_1$  与  $V_3$ 、 $V_2$  与  $V_3$  之间是否包含,第 4、5、6 位则分别表示  $V_1$  与  $V_4$ 、 $V_2$  与  $V_4$ 、 $V_3$  与  $V_4$  之间是否包含,1 表示有有向边连接,0 表示没有.

### 3.2 生成式对抗网络

在生成式对抗网络中,以 EGAN (Evolutionary Generative Adversarial Networks)<sup>[18]</sup> 为代表. 不同于传统的 GAN<sup>[19]</sup> 利用预先设定好的对抗目标函数训练生成器和判别器,EGAN 利用三种不同的生成对抗目标作为突变函数,进化下一代的生成器以适应环境(判别器),并通过评估生成样本的质量与多样性选择后代,只留下表现好的后代,用于以后的训练. 具体步骤为:(1) 初始情况下给定一个单独的生成器,利用突变操作产生后代. 突变操作具体指利用变异函数更新生成器网络权重,一次突变操作即可产生一个后代.(2) 通过适应度函数来评估后代的表现. 主要从生成图像的质量与多样性进行评估.(3) 根据后代的适应值对后代进行选择,移除表现差的后代,剩下的部分用来进化下一代,同时循环以上步骤.

EGAN 的创新之处在于它整合了三种不同的变异函数,分别是最大最小突变(minimax mutation)、启发式突变(heuristic mutation)、最小二乘突变(least-squares

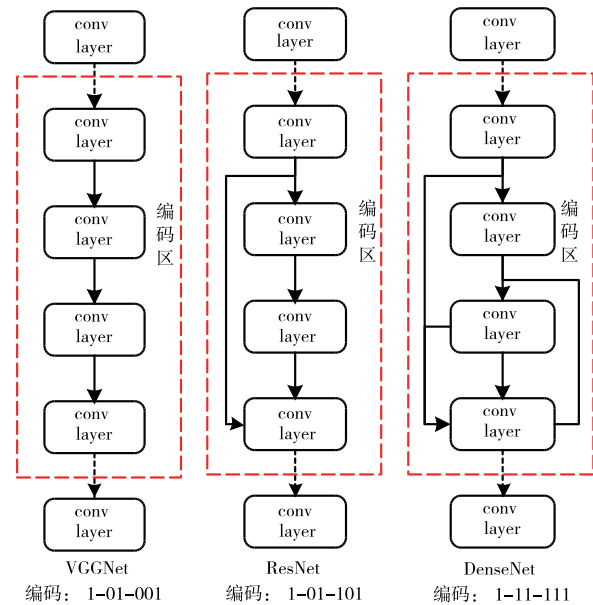


图1 VGGNet、ResNet和DenseNet的二进制编码

mutation), 主要目的是为了有效地缩小生成样本分布与真实数据分布之间的距离,避免梯度消失与模型坍塌. 具体原理为:当生成分布与真实数据分布几乎重叠,最大最小突变提供了有效的梯度,可持续地缩小生成分布与真实数据分布之间的 JS 散度<sup>[20]</sup>;启发式突变的目的在于最大化判别器判断错误的可能性,当判别器完全可以判断出生成器生成的假样本时,仍然可以为生成器提供有效的梯度,避免了梯度消失;最小二乘突变与启发式变异类似,不会在生成器生成明显错误样本时指定一个极高的损失,也不会判别器无法分辨时指定一个极低的损失,在一定程度上避免模型坍塌. 因此,在训练的过程中,EGAN 最大化地抑制了传统的 GAN 受单个目标限制而出现梯度消失和模型坍塌的问题.

### 3.3 自动编码器

EvoAE (Evolutionary AutoEncoders)<sup>[21]</sup> 将自动编码器以种群的方式进化,并同时实现网络的权重与结构优化. 在 EvoAE 中,一个自动编码器视为种群中的个体,首先使用反向传播算法最小化自动编码器对样本的重构误差,满足终止条件后,对训练后自动编码器进行如下进化流程:(1) 根据重构误差和适应值随机选择一对自动编码器.(2) 利用交叉操作生成两个新的编码器. 交叉操作指随机交换两个自动编码器的隐藏层节点以及它们的相关参数.(3) 在给定的突变率下,利用突变操作随机在一个自动编码器上添加或删除一个隐藏层节点,添加与删除概率相同.(4) 使用反向传播算法训练生成的每一个后代,直到满足终止条件,再重复以上步骤. EvoAE 的创新在于并行搜索自动编码器的特

征和结构空间,同时优化自动编码器的权重和结构.此外,EvoAE 在数据的分割和选择上支持不同的训练方法,人工干预较少,对于分布式系统中的大数据集,大大减少了训练所需时间.

除 EvoAE 以外,ES-CAE (Evolutionary Strategy for Convolutional AutoEncoders)<sup>[22]</sup> 则通过基因型表示模型中的每一层网络,根据基因型生成对应的表现型,表现型映射 CAE 网络并生成编码器,并用进化策略搜索结构空间优化生成的编码器,解码器对称编码器自动生成,最终形成完整的自动编码器,如图 2 所示.在初始的基因型中,一共有 9 个卷积神经网络节点和一个输出节点,每个节点有两个基因:前者代表节点类型,即卷积核的个数  $F$  和大小  $K$ ,后者则表示该节点的输入节点.节点类型会事先对所有可能的类型进行编号,如表 2 所示.ES-CA 可以自动生成具有潜力的网络结构,不管是对图像还是文本都具有很高的修复和重构能力.

表 2 节点类型编号

$F \backslash K$	$1 \times 1$	$3 \times 3$	$5 \times 5$
64	0	1	2
128	3	4	5
256	6	7	8

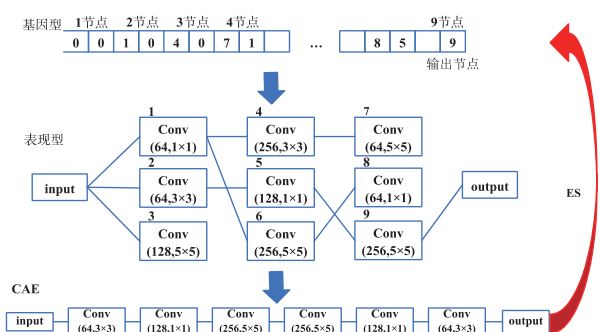


图2 ES-CAE结构图

### 3.4 长短期记忆网络

CoDeepNEAT (Coevolution DeepNEAT) 是 DeepNEAT (Deep NeuroEvolution of Augmenting Topologies)<sup>[23]</sup> 的一种变体,DeepNEAT 则是将 NEAT<sup>[24]</sup> 算法应用在深度神经网络中的算法.这类以 NEAT 为基础的算法可以发现一些复杂地难以通过人类手工构建的深度学习网络.

不同于 NEAT 每个节点基因仅表示一个神经元,DeepNEAT 中的一个基因表示深度神经网络中一层的神经元.节点基因包括一系列实数和二进制超参数,这些参数决定了网络层的类型,例如该层是卷积层、全连接层或循环层,也决定了该层的其他特性,例如神经元的个数、卷积核的大小和激活函数等,并且基因通过均

匀高斯分布和位反转进行突变. DeepNEAT 中的边基因不再表示权重,而是表明神经网络中的每一层是如何连接.同时,还有一部分基因表示全局超参数.因此,只需要将这些基因表示的节点与深度神经网络的每一层一一对应,一个基因组即可构成一个完整的深度神经网络.

目前关于 LSTM 的优化问题主要集中在两个方面,首先是单个 LSTM 记忆单元结构应该如何变化,其次是将 LSTM 连接到网络中的方法<sup>[25]</sup>.将 CoDeepNEAT 方法扩展到 LSTM 网络中可以通过神经进化发现新的 LSTM 单元并将不同的 LSTM 单元连接起来.在这种情况下,主要有两种突变类型:(1) LSTM 层之间的连接可用与否;(2) 添加或移除两个 LSTM 节点之间的跨越连接.实验证明进化生成的跨越连接可使 LSTM 的性能提高 5%,并且这样的连接是人工很难发现的.

### 3.5 深度强化学习

随着深度学习的不断发展,深度学习与强化学习 (Reinforcement Learning, RL) 的分界线渐渐模糊,开始互相影响产生结合方法.2013 年,深度强化学习由 DeepMind 首次提出,它是通过强化学习直接从高维感官输入中成功学习控制策略的深度学习模型<sup>[26]</sup>.在强化学习中,我们虽然可以利用一个神经网络决策去执行一系列动作完成环境中的任务,但是对于当前时刻智能体执行的操作,未来给予智能体的奖励信号梯度是不重要的.因此,OpenAI 的研究学者们提出使用进化策略作为强化学习的可扩展替代方案<sup>[27]</sup>.进化策略可以有效可靠地训练出神经网络的策略,使智能体完成一些复杂的、具有难度的任务. Uber 实验室自 2017 年开始也相继发表了五篇利用进化计算优化深度强化学习的论文<sup>[28-30]</sup>,还提出了安全突变的概念,旨在减小突变对网络造成的影响.

除此之外,将深度强化学习与神经进化结合的算法还有 Google Brain 提出的 WANN (Weight Agnostic Neural Network)<sup>[31]</sup>,它将一个共享权重应用到整个网络中,并将权重视为从固定分布中采样得到的随机变量.整个流程如图 3 所示,可以总结为如下四个步骤:(1) 创建一个初始的最小网络拓扑群体;(2) 通过执行多次 rollout (智能体执行一次行动) 对初始的最小网络拓扑结构进行评估,给每次的 rollout 分享不同的权值;(3) 根据网络的表现和复杂程度对网络评级;(4) 突变排名最高的几个网络通过添加节点或添加连接来产生新的子代网络,并以锦标赛制为概率选择<sup>[32]</sup>,进入下一轮循环.最终通过多轮循环会得到一个结构复杂的神经网络.该方法被证明可替代反向传播算法减少三分之二的计算量,使深度学习模型可以在低精度的硬件上运行,具有更大的储存潜能.

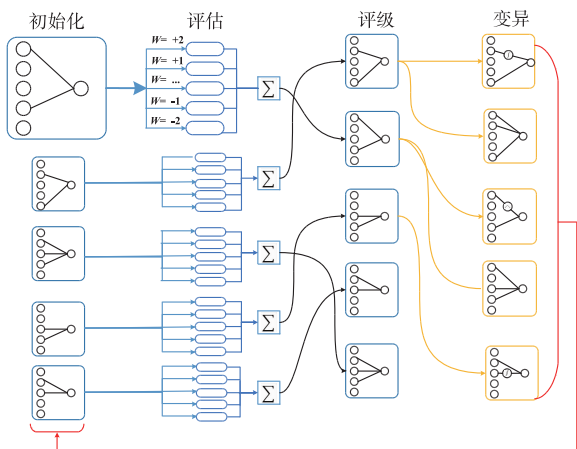


图3 WANN流程图

#### 4 基于神经进化的深度学习模型性能分析

为了评估模型的性能,本节在五种深度学习常涉及的任务上进行实验分析,具体为:时间序列预测、图像分类、图像生成、图像修复、强化学习任务.对于不同的深度学习任务会采用不同的数据集、指标进行对比,以提供客观评价标准.

##### 4.1 时间序列预测

与基于梯度下降的优化算法相比,进化优化一定程度上避免了陷入局部最优的问题,但是却存在计算量大的问题.为了从根源上解决问题, Gregory Morse 等人提出了一种限制评价进化算法<sup>[33]</sup> (LEEA, Limited Evaluation Evolutionary Algorithm), 与传统的进化算法 (TGEA, Traditional Generational Evolutionary Algorithm) 不同,LEEA 选择限制数量的训练样本对每一代中的个体进行评估,而非所有样本,每一代的个体仅需要与小部分的训练样本拟合,从而大大减小了计算量.

为了证明进化优化可以作为深度学习模型中梯度下降的替代方法, Gregory Morse 等人通过时间序列预测等任务,分别利用 LEEA、TGEA、SGD (Stochastic Gradient Descent)、RMSProp (Root Mean Square Prop) 四种优化算法在同一个神经网络中训练,其中 SGD、RMSProp 代表了基于梯度的优化方法,并通过计算均方根误差 (Root Mean Square Error, RMSE) 测试他们的性能.图 4 为实验结果,该实验证明:虽然传统的进化算法与基于梯度下降算法相比性能较差,但是,当对进化算法添加某种受限条件后,进化算法对深度学习模型网络权重的优化也可以像梯度下降算法一样准确高效.

##### 4.2 图像分类

为了直观的认识神经进化对深度学习模型起到的优化作用,主要将第三节提及到的三个基于神经进化的卷积神经网络模型: ConvGP、CGP-CNN、GeNet 与 AlexNet、GoogleNet 等经典 CNN 模型进行对比.训练及

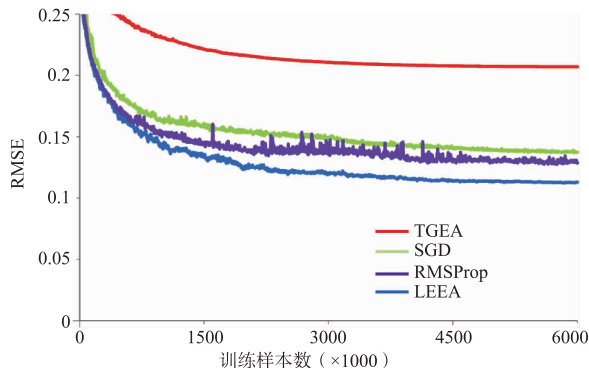


图4 时间序列测试对比

测试数据集为 CIFAR-10 数据集,它包含 60000 张大小为  $32 \times 32$  的彩色图像,共有 10 个种类,每类有 6000 张图片,其中,50000 张用于训练,10000 张用于测试.主要通过训练精度、测试精度、训练时间、测试时间四个指标对模型的图像分类性能进行对比.表 3 是各模型在 CIFAR-10 中的表现:

表 3 各卷积神经网络模型性能对比

模型	训练精度 (%)	测试精度 (%)	训练时间 (min)	测试时间 (ms)
AlexNet <sup>[34]</sup>	85.42	72.86	69.20	0.02
GoogleNet <sup>[35]</sup>	87.10	79.34	106.89	0.53
VGG16	90.10	85.78	120.45	0.34
ResNet101	93.95	85.53	114.96	1.32
DenseNet121	93.43	85.12	137.93	0.89
ConvGP	94.39	90.19	354.09	0.32
CGP-CNN	94.02	91.64	564.30	14.67
GeNet	94.61	93.02	493.62	1.45

从表格中我们可以看到,基于神经进化的三个模型与经典的五个 CNN 模型相比,图像分类的训练精度、测试精度更高,但在训练时间与测试时间方面并不占优势,进一步说明进化优化通常建立在牺牲算法效率上提高算法精度.

##### 4.3 图像生成

GAN 从出现开始便成为图像生成任务的主流模型,除了生成图像是否清晰真实,生成的图像是否具有多样性也是评估 GAN 模型性能的重要参考.因此,引入 IS (Inception Score) 评估 GAN 模型,IS 可以对 GAN 生成图像的多样性进行分析,通过计算生成图像类别的概率分布反应生成图像的多样性,IS 值越高,说明 GAN 生成的图像清晰的同时也均匀分布在各类别之间.图 5 是 EGAN 与几个经典 GAN 模型的 IS 值对比,实验结果显示,EGAN 的 IS 值较高于其它 GAN.由此可见,EGAN 在生成清晰图像的同时也保证了图像种类的多样性,说

明通过神经进化最终训练得到的生成器可以更好的适应环境.

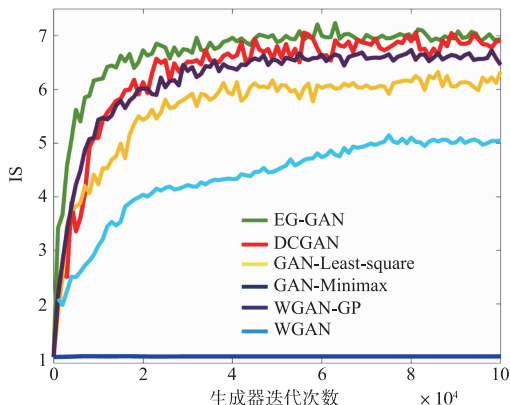


图5 EGAN与其它GAN模型在IS指标上的对比

#### 4.4 图像修复

自动编码器可应用于多种图像处理任务,上一节提到的 ES-CAE 模型主要应用于图像修复. 对于图像修复任务主要通过两个指标评价还原度:PSNR( Peak Signal to Noise Ratio) 与 SSIM (Structural SIMilarity)<sup>[36]</sup>. PSNR 即峰值信噪比,是基于两张相似图像之间像素点误差的最大信号值与误差(噪声)比值,两张图像完全相似的图像的 PSNR 值无穷大,因此 PSNR 值越大图像修复的质量越好. SSIM 即结构相似性,它分别从亮度、对比度、结构三个方面度量图像相似性,范围是 0 到 1, 值越大表示图像修复的质量越高. 表 4 是 ES-CAE 与其他两个主流图像修复算法在 CelebA 数据集和 Cars 数据集<sup>[37]</sup>(斯坦福大学的汽车图像数据集)下 PSNR 和 SSIM 度量值对比.

表 4 各图像修复模型对比

数据集	模型	PSNR	SSIM
CelebA	CE <sup>[38]</sup>	28.5	0.912
	SII <sup>[39]</sup>	19.4	0.907
	ES-CAE	29.9	0.934
Cars	CE	19.6	0.767
	SII	13.5	0.721
	ES-CAE	20.9	0.846

根据实验得到的数据,我们可以看出基于神经进化的自动编码器在执行图像修复任务上具有一定的优势,不仅可以实现对数据的重构,对图像的语义结构也具有一定的预测能力.

#### 4.5 强化学习任务

深度强化学习常应用于机器人控制领域,深度强化学习是与神经进化融合最频繁的一个领域. 本小节将对 WANN 算法在 CartPoleSwingUp 上实验表现进行分

析. 如图 6 是随着代数的递增 WANN 拓扑网络的发展,下方是共享权重与奖励的关系图. 首先,从拓扑网络来看,从第 8 代到 128 代网络拓扑结构明显更加复杂,同时增加了很多计算节点;从共享权重与奖励值的关系来看,在第 8 代时,任意共享权重的奖励都为 0,等到 128 代后,所有共享权重(除 0 之外)都有非 0 奖励,最重要的是在  $[-2, -0.5]$  和  $[0.5, 2]$  这个区间内奖励值不再发生大波动变化,因此共享权重对网络的影响不再重要,这是非常关键的一点.




图6 WANN拓扑网络的进化

### 5 总结与展望

对于生物来说,许多行为是与生俱来的,而不是像人工神经网络一样慢慢学习训练而来. 所以,一个通用性高、可以学习任何知识的通用学习算法是实现真正人工智能的关键,神经进化或许就是实现真正智能的一个重要方法. 但是就目前而言,神经进化仍然面临着一些挑战,在未来还有很大的发展空间.

(1) 进化计算由于庞大的计算量常通过基于 GPU 的并行计算完成,根据训练样本个数,进化优化需要的计算量可能是梯度下降的上千倍. 正如上文中提及的模型,大部分模型仅利用神经进化优化网络结构,而对网络权重的更新仍使用传统的梯度下降算法.

(2) 基于神经进化的网络模型可解释性有待提高. 进化计算的随机性很强,可以生成一些跳跃连接,它们对模型精度的提高起到了关键作用,但是具体的原理无从得知. 提高神经进化的可解释性需要对神经进化更深入的研究,尤其是对神经进化生成的网络结构内部神经元之间关联的探索.

(3) 神经进化要想从计算走向智能,仍需要面对模型精准的问题. 相比用于训练模型的数据,现实世界中的数据存在不可避免的噪声,尽管进化计算一直被认为对噪声具有一定的鲁棒性,但是在解决具体问题时,充分规避噪声的负面影响是很困难的,因此仍需要对神经进化更深刻的理论和方法支持.

## 参考文献

- [1] Ketkar N. Deep Learning with Python [M]. Berkeley: Apress, 2017. 113 – 132.
- [2] Floreano D, et al. Neuroevolution: from architectures to learning [J]. *Evolutionary Intelligence*, 2008, 1 (1): 47 – 62.
- [3] Fogel D B, Fogel L J. An introduction to evolutionary programming [A]. *European Conference on Artificial Evolution* [C]. Berlin: Springer, 1995. 21 – 33.
- [4] Andrew A M. Systems: an introductory analysis with applications to biology, control, and artificial intelligence [J]. *Robotica*, 1993, 11 (5): 489 – 489.
- [5] Beyer H G, Schwefel H P. Evolution strategies—a comprehensive introduction [J]. *Natural Computing*, 2002, 1 (1): 3 – 52.
- [6] Koza J R, Koza J R. Genetic Programming: On the Programming of Computers by Means of Natural Selection [M]. Cambridge: MIT Press, 1992.
- [7] 贾亚军, 丛爽. 进化算法的分析及对比研究 [A]. 2009 系统仿真技术及其应用学术会议论文集 [C]. 合肥: 中国科学技术大学出版社, 2009. 855 – 861.
- [8] Zhang C, Lim P, Qin A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28 (10): 2306 – 2318.
- [9] Smith C, Jin Y. Evolutionary multi-objective generation of recurrent neural network ensembles for time series prediction [J]. *Neurocomputing*, 2014, 143 (1): 302 – 311.
- [10] Lukoševičius M, Jaeger H. Reservoir computing approaches to recurrent neural network training [J]. *Computer Science Review*, 2009, 3 (3): 127 – 149.
- [11] Evans B, Al-Sahaf H, Xue B, et al. Evolutionary deep learning: a genetic programming approach to image classification [A]. *IEEE Congress on Evolutionary Computation* [C]. New York, USA: IEEE, 2018. 1 – 6.
- [12] Atkins D, Neshatian K, Zhang M. A domain independent genetic programming approach to automatic feature extraction for image classification [A]. *IEEE Congress of Evolutionary Computation* [C]. New York, USA: IEEE, 2011. 238 – 245.
- [13] Suganuma M, Shirakawa S, Nagao T. A genetic programming approach to designing convolutional neural network architectures [A]. *Proceedings of the Genetic and Evolutionary Computation Conference* [C]. New York, USA: ACM, 2017. 497 – 504.
- [14] Xie L, Yuille A. Genetic CNN [A]. *Proceedings of the IEEE International Conference on Computer Vision* [C]. New York, USA: IEEE, 2017. 1379 – 1388.
- [15] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-scale Image Recognition [EB/OL]. <https://arxiv.org/abs/1409.1556>, 2014.
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* [C]. New York, USA: IEEE, 2016. 770 – 778.
- [17] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [A]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* [C]. New York, USA: IEEE, 2017. 4700 – 4708.
- [18] Wang C, Xu C, Yao X, et al. Evolutionary generative adversarial networks [J]. *IEEE Transactions on Evolutionary Computation*, 2019, 23 (6): 921 – 934.
- [19] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [A]. *Advances in Neural Information Processing Systems* [C]. Cambridge, UK: MIT Press, 2014. 2672 – 2680.
- [20] Lin J. Divergence measures based on the Shannon entropy [J]. *IEEE Transactions on Information Theory*, 1991, 37 (1): 145 – 151.
- [21] Assuncao F, Sereno D, Lourenco N, et al. Automatic evolution of autoencoders for compressed representations [A]. *IEEE Congress on Evolutionary Computation* [C]. New York, USA: IEEE, 2018. 1 – 8.
- [22] Suganuma M, Ozay M, Okatani T. Exploiting the Potential of Standard Convolutional Autoencoders for Image Restoration by Evolutionary Search [EB/OL]. <https://arxiv.org/abs/1803.00370>, 2018.
- [23] Miikkulainen R, Liang J, Meyerson E, et al. Artificial Intelligence in the Age of Neural Networks and Brain Computing [M]. Amsterdam: Elsevier Inc, 2018. 293 – 312.
- [24] Stanley K O, Miikkulainen R. Evolving neural networks through augmenting topologies [J]. *Evolutionary Computation*, 2002, 10 (2): 99 – 127.
- [25] Agrawal R K, Muchahary F, Tripathi M M. Long term load forecasting with hourly predictions based on long-short-term-memory networks [A]. *2018 IEEE Texas Power and Energy Conference* [C]. New York, USA: IEEE, 2018. 1 – 6.
- [26] Mnih V, Kavukcuoglu K, Silver D, et al. Playing Atari with Deep Reinforcement Learning [EB/OL]. <https://arxiv.org/abs/1312.5602>, 2013.
- [27] Salimans T, Ho J, Chen X, et al. Evolution Strategies as a Scalable Alternative to Reinforcement Learning [EB/OL]. <https://arxiv.org/abs/1703.03864>, 2017.
- [28] Such F P, Madhavan V, Conti E, et al. Deep Neuroevolution: Genetic Algorithms are a Competitive Alternative for Training Deep Neural Networks for Reinforcement Learn-

- ing[EB/OL]. <https://arxiv.org/abs/1712.06567>, 2017.
- [29] Lehman J, Chen J, Clune J, et al. ES is more than just a traditional finite-difference approximator[A]. Proceedings of the Genetic and Evolutionary Computation Conference [C]. New York, USA; ACM, 2018. 450 – 457.
- [30] Conti E, Madhavan V, Such F P, et al. Improving exploration in evolution strategies for deep reinforcement learning via a population of novelty-seeking agents[A]. Advances in Neural Information Processing Systems[C]. Cambridge: MIT Press, 2018. 5027 – 5038.
- [31] Gaier A, Ha D. Weight agnostic neural networks[A]. Advances in Neural Information Processing Systems [C]. Cambridge, UK; MIT Press, 2019. 5365 – 5379.
- [32] Miller B L, Goldberg D E. Genetic algorithms, tournament selection, and the effects of noise[J]. Complex Systems, 1995, 9(3): 193 – 212.
- [33] Morse G, Stanley K O. Simple evolutionary optimization can rival stochastic gradient descent in neural networks [A]. Proceedings of the Genetic and Evolutionary Computation Conference [C]. New York, USA; Association Computing Machinery, 2016. 477 – 484.
- [34] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[A]. Advances in Neural Information Processing Systems [C]. New York, USA; Association Computing Machinery, 2012. 1097 – 1105.
- [35] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. New York, USA; IEEE, 2015. 1 – 9.
- [36] Sara U, Akter M, Uddin M S. Image quality assessment through FSIM, SSIM, MSE and PSNR—A comparative study [J]. Journal of Computer and Communications, 2019, 7(3): 8 – 18.
- [37] Krause J, Stark M, Deng J, et al. 3D object representations for fine-grained categorization [A]. Proceedings of the IEEE International Conference on Computer Vision Workshops [C]. New York, USA; IEEE, 2013. 554 – 561.
- [38] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders; feature learning by inpainting[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. New York, USA; IEEE, 2016. 2536 – 2544.
- [39] Yeh R A, Chen C, Yian Lim T, et al. Semantic image inpainting with deep generative models[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. New York, USA; IEEE, 2017. 5485 – 5493.

### 作者简介



韩 冲 女, 1996 年 11 月出生于山西临汾. 2018 年进入同济大学电子与信息工程学院, 在读硕士研究生. 研究方向为深度学习、进化计算.  
E-mail: 496274966@qq.com



王俊丽(通讯作者) 女, 1978 年 10 月出生于山西祁县. 2007 年获得同济大学工学博士学位, 现为同济大学电子与信息工程学院副研究员、研究生导师. 研究方向为深度学习、网络数据分析.  
E-mail: junliwang@tongji.edu.cn