

# 人工智能在实际应用中的瓶颈及未来研究展望

戴国强 高芳 徐峰

中国科学技术信息研究所 北京 100038

**摘要** 2016年以来人工智能迎来新一轮发展热潮,以计算机围棋程序AlphaGo的连续性突破为代表,人工智能为人类展示了其拥有的巨大潜力。本文简要梳理了人工智能研究历史上的两条路线,阐述了算法、数据以及计算能力等在AlphaGo运行中的作用,剖析了人工智能在医疗保健、电力系统两大领域的应用瓶颈,分别在算法研究、工程应用、数据可用性以及对伦理道德法律等风险维度对人工智能的未来进行了展望。

**关键词:** AlphaGo; 人工智能; 深度学习; 数据可用性; 工程应用

**中图分类号:** G350

开放科学(资源服务)标识码(OSID)



## The Bottleneck and Future Research Prospect of Artificial Intelligence in Practical Application

DAI Guoqiang GAO Fang XU Feng

Institute of Scientific and Technological Information of China, Beijing 100038, China

**Abstract** Artificial Intelligence (AI) has been engaged in a new wave of development since 2016. Especially, the continuous breakthrough of AlphaGo has shown the great potential of AI. This paper briefly reviewed two history lines of AI research, expounded the role of algorithm, data and computing power in AlphaGo operation, and analyzed the application bottlenecks of AI in two major areas: healthcare and power system. Moreover, the future of AI algorithm research, engineering applications, data availability and ethical and legal risk were also prospected.

**Keywords:** AlphaGo; Artificial Intelligence; deep learning; data availability; engineering application

**基金项目:** 科学技术部科技创新战略研究专项(ZLY201631, ZLY201739)。

**作者简介:** 戴国强(1961-), 工学硕士, 中国科学技术信息研究所所长, 研究方向: 科技创新战略, 重点科技领域政策; 高芳(1980-), 副研究员, 工学博士, 情报学博士后, 研究方向: 科技政策、重点科技领域信息分析, Email: gaof@istic.ac.cn; 徐峰(1976-), 研究员, 情报学博士, 研究方向: 科技创新战略与政策。

2016年3月,在复杂的棋类游戏中AlphaGo以4:1成绩战胜人类职业围棋高手<sup>[1,2]</sup>,引发全世界对人工智能的关注。随后Master以AlphaGo的不同身份先后战胜六十多位世界级围棋选手,通过了围棋对弈的图灵测试<sup>[3]</sup>,进一步向世人展示了人工智能近期的进展和成就<sup>[4]</sup>。如今人工智能开始迅速而又广泛的渗透到各个行业和领域,对部分传统产业和行业的升级改造效果正初步显现,同时也创造出了令人耳目一新的新应用、新模式等,然而人工智能发展至今仍要面临诸多挑战,需要学术界、产业界共同探索。

## 1 人工智能研究简况

人工智能起源于1956年的Dartmouth(达特茅斯)会议,实际在此之前关于如何借助机器(硬件和软件)解决复杂问题已成为学术界关注的重点,从而基本奠定了早期人工智能研究的两大学派——结构模拟和功能模拟。

结构模拟学派的研究路线是通过模拟人类大脑皮层神经网络的结构及其工作机理来实现人工智能,即通过构造人工的神经网络来模拟人类的思维能力。模拟神经网络最早的理论源自1943年McCulloch和Pitts提出的神经元数理逻辑模型<sup>[5]</sup>,1957年Rosenblatt利用神经元电路构成了“感知机”(Perceptron)——具有单层计算单元的神经网络<sup>[6,7]</sup>,并在IBM-704计算机上进行了模拟,该模型已经能够完成简单的视觉处理任务,可识别印刷体英文字母,与感知机同期出现的经典模型还有Widrow提出的具有自适应能力的Adaline系统等。1969年

Minsky和Papery基于单层感知机的局限性提出了多层感知机的概念<sup>[8]</sup>,然而多层感知机的训练遇到了瓶颈,从而使人工神经网络的发展进入低潮。直到20世纪80年代Hopfield网络以及并行分布式处理思路的提出实现了Minsky等人关于多层网络的设想<sup>[9]</sup>,学界重又燃起对人工神经网络的研究热情。2006年Hinton提出“深度学习”算法将神经网络研究推进了第三次快速发展期<sup>[10-12]</sup>。

功能模拟学派著名的“物理符号系统假设”是探讨利用计算机来模拟人类的思维,虽然计算机系统和人类大脑系统的物质成分与能量形式不同,但它们都是处理符号的物理系统,可以互相等效<sup>[13-15]</sup>。经过多年的探索与实践,功能模拟学派的研究重点从初期的面向通用问题求解逐渐聚焦到面向专用领域的专家系统研究<sup>[16]</sup>。专家系统需要将专家知识映射到计算机中,推理系统运用其推理能力为用户生成解决问题的策略。自1965年第一个专家系统Dendral问世以来,各种专家系统已广泛应用于语音识别、图像处理、医疗诊断、金融决策、地质勘探、石油化工、计算机设计等领域,解决预测、设计、规划、监测和控制等问题<sup>[17,18]</sup>。1997年首次在正式比赛中战胜人类国际象棋世界冠军的深蓝系统就是专家系统的典型代表。

## 2 AlphaGo到AlphaZero突破的实质

目前普遍认为,人工智能迅速发展得益于统计与概率估算方法的进步、海量数据的供给以及日益增强的计算机处理能力。特别是近十年来人工智能的一些细分领域已经展示出了日

益精准的智能处理结果，使得许多人对人工智能未来发展充满憧憬。AlphaGo 就是其中最为典型的代表之一。

AlphaGo 采用的关键算法主要包括深度学习、强化学习与蒙特卡洛树搜索算法<sup>[19-23]</sup>。其中深度学习（Deep Learning）常用于对复杂对象进行表示学习（Representation Learning）以自动产生对象的特征描述，其本质是通过多层神经网络来构建端对端的从输入到输出的非线性映射，端对端学习（End-to-end Learning）思想、非线性学习（Non-linear Learning）能力以及可扩展性（Scalability）构成了深度学习优于传统有监督学习的基本要素<sup>[24]</sup>。更具体的其中价值网络（Value Network）用于评估棋盘位置、预测赢棋的可能性，策略网络（Policy Network）实现对动作进行抽样、选择下棋步法。与此同时运用强化学习（Reinforcement Learning）进行自我博弈，即自己与自己下棋得到新的棋谱数据，从而进一步改善策略网络的性能。蒙特卡洛树搜索则是一种基于蒙特卡洛算法的启发式搜索技术，目前已成为围棋程序普遍采用的搜索方法。

AlphaGo 中模型的训练和验证仍然要依靠人类在围棋方面的先验知识以及大量的棋谱数据。其中用于训练策略网络的数据来自 KGS 数据集，包括 KGS 平台上 6 段到 9 段围棋棋手总共 16 万场比赛（有 35.4% 的比赛含有让子棋局）中积累下来的 2,940 万棋子位置信息，而由强化学习进行自我博弈生成的棋子位置信息则达到了 3,000 万个，即自我博弈生成的棋谱数据超过了人类棋谱数据。与此同时 AlphaGo 还用到了人类总结的近 11 万个模式。对于计算资源的使用和调度，AlphaGo 采用 CPU+GPU（中央

处理器 + 图形处理器）的硬件平台，单机版本运行需要 48 块 CPU 和 8 块 GPU，分布式版本运行则调用了 1202 块 CPU 和 176 块 GPU，两个版本均采用 40 个搜索线程。

实际上，AlphaGo 中用的神经网络并非是最近才出现的新网络，深度学习、强化学习以及蒙特卡洛树搜索算法等也都有着较为久远的研究历史，但是巧妙的是 AlphaGo 创新性地将三者有机结合在一起。首先深度学习感知能力较强但缺乏一定的决策能力，强化学习则恰恰相反，具有决策能力却无法解决感知问题，两者相结合能够实现优势互补，从而为感知决策类问题提供新的解决思路。而在蒙特卡洛树搜索中引入策略网络来评估可能的落棋位置并从中选出最优位置，可极大地缩小树搜索中扩展节点的范围，从而大幅提升搜索效率，使得赢棋的预测更加精确。

AlphaGo 也成为人工智能研究史上两大学派的高度融合体，将结构模拟和功能模拟相结合，既对神经网络这一工具进行了改造升级，又充分运用了人类“专家”在围棋这一特定问题领域积累的大量的先验知识和模式，而这也是 AlphaGo 与深蓝系统的本质区别。同样是解决某一特定领域的问题，深蓝系统采用 20 世纪 60 年代就提出的  $\alpha$ - $\beta$  剪枝算法，直接基于人类已总结的下棋模式和知识对棋局进行评估并优化搜索落棋位置，由此深蓝系统实现的关键是足够的先验知识和计算资源，同时由于  $\alpha$ - $\beta$  剪枝算法的专用性（专门用于双人博弈问题）使得深蓝系统无法向解决通用问题转变。比较而言，虽然 AlphaGo 同样无法直接用来解决其他领域的问题，但却为这些问题的解决提供了新

的思路，特别是如何融合与升级已有算法并推动高效的工程实现方面为世人展示了人工智能的无尽潜力。

2017年10月，AlphaGo升级版AlphaGo Zero问世，人类在“让机器像人一样认识世界”这条路上又有了新的历史性突破，计算机围棋程序实现了信息技术领域著名的摩尔定律增长与升级<sup>[25]</sup>。这主要表现在AlphaGo Zero中神经网络的初始化已不需要人类专家的经验与知识，同时神经网络的训练也不需要人类棋谱数据，所有训练数据都产生于强化学习的自我博弈过程，而起始棋局也是随机的。与此同时，AlphaGo Zero在自我训练过程中实现了对围棋相关知识的认知，这其中不仅包含人类已构建的围棋规则，甚至还归纳生成了人类尚未总结出来的“非标准策略”。而在技术实现上，策略网络和价值网络已经融为一体合并成为一个神经网络，使得AlphaGo Zero的整体设计架构比之前的版本更加简单；对硬件资源的需求大幅度缩减<sup>[26]</sup>，从战胜李世石版本AlphaGo需要使用48块TPU（Tensor Processing Unit）下降到4块TPU。

2017年12月，AlphaGo的研发团队推出AlphaGo Zero的通用化版本AlphaZero，实现了从单一棋种向多棋种的进化<sup>[27]</sup>。在自我博弈强化学习性能比较中，AlphaZero超越李世石版本AlphaGo用了8小时（16.5万步），超越世界顶级国际象棋程序Stockfish用了4小时（30万步），超越世界顶级将棋程序Elmo用了2小时（11万步）。从AlphaGo Zero到AlphaZero的演进，其核心算法机制并未进行大幅度调整，甚至在某种程度上对流程和算法进行了简化，一是神经网络训练时不需要进行版本替代，二是搜索

部分的超参数也不再通过优化获取，所有博弈都使用了相同的超参数。简化的流程又能呈现出如此高的计算效率，其背后需要的计算资源远远超过了AlphaGo Zero，AlphaZero通过自我博弈生成棋谱过程使用了5000块第一代TPU，神经网络训练时则调用了64块第二代TPU。

### 3 人工智能的典型应用及瓶颈

AlphaGo的出现向世人展示了人工智能领域高度集成性成果，也让人们对AI未来的应用充满憧憬。作为最早将发展人工智能上升为国家战略的国家，美国认为人工智能可以促进几乎所有行业领域的健康发展，在促进经济繁荣、提升民生保障以及保护国家安全等维度都是不可能或缺的要素<sup>[28,29]</sup>。Gartner提出人工智能是最具破坏性的技术<sup>[30]</sup>，可以解决若干人类解决效率低或难以解决的问题。埃森哲则对人工智能在信息通信、制造、金融、交通、医疗保健、农业、公共服务等16个行业领域的应用进行了展望<sup>[31]</sup>，并开创性的将人工智能作为一种新的生产要素引入经济增长模型。实际在人工智能发展史上，各种通过软硬件实现系统模拟、预测、优化与控制等功能的应用层出不穷，然而在真正帮助人类解决实际问题方面，仍有若干瓶颈需要突破。

#### 3.1 人工智能用于医疗保健案例分析

在众多的AI应用中，人工智能在医疗领域的应用被认为是最容易落地的场景之一，且主要划分为两大类。一类是用于医疗以及辅助医疗的智能型服务机器人，比如手术机器人、假肢机器人、康复机器人、个人护理机器人以

及智能监控系统等，这其中以 1996 年推出至今已更新至第四代产品的达芬奇手术机器人最为典型<sup>[32]</sup>，它已成为全球应用最广泛、技术水平最高的手术机器人之一。另一大类是基于数据与算法的辅助诊疗、新药研发以及健康管理等。Watson 系统是辅助诊疗领域的典型代表，融合了自然语言处理、认知技术、自动推理以及机器学习等技术。而将深度学习应用于药物临床前研究，可快速准确的挖掘和筛选合适的化合物和生物<sup>[33]</sup>，从而达到缩短新药研发周期、降低新药研发成本和提高新药研发成功率的目的。

近两年人工智能用于医疗影像识别的准确度、诊断效率和覆盖病种数量都不断取得突破<sup>[34-36]</sup>。在其处理流程中，一般先通过图像识别对影像这类非结构化数据进行挖掘分析得到特征信息——即实现“感知”功能，而为了掌握“诊断”能力也需要大量的影像数据和诊断知识对诊断网络进行训练和验证。从技术上来说这些环节似乎都已不存在难题，但实际在诸如皮肤癌、乳腺癌等各种癌变检测与预测分析时，必须首先对影像数据库中不同来源的含有病变特征的原始数据进行预处理，因为这些数据中通常还有大量模糊的、不完整的、带有噪声和冗余的信息，需要通过清理和过滤操作以确保数据的一致性和确定性，从而将其转化成适合挖掘的数据形式。这种数据预处理是图像处理中的基本操作<sup>[37]</sup>，实现起来并不难，但原始图像数据的可用性、人类医生对数据标识的可信度，图像预处理操作中是否可能将含有关键病变特征的数据过滤掉，以及如何将人类对病症的先验知识（这些知识通常都是模拟量）精确的转化为数字图像处理过程中的参数信息

等仍然要在实际应用中进一步探索。

### 3.2 人工智能用于电力系统案例分析

电力生产和管理流程一般包括发电、输电、变电、配电和用电等环节，整个系统运行的基本目标是为各类用户尽可能地提供经济、可靠而且符合标准要求的电能。人工智能在电力系统中的应用由来已久<sup>[38, 39]</sup>，包括早期的专家系统以及简单的人工神经网络等<sup>[40, 41]</sup>，后来的智能电网则是将智能感知、在线分析与决策以及人机协同理念引入输电、配电等环节<sup>[42, 43]</sup>，以更加系统化、整体性的理念实现对资源的最优配置，从而成为人工智能在电能供应领域的集成式应用。2017 年初，英国国家电网公司开始探索与 AlphaGo 开发团队 DeepMind 公司的合作，期望借助最新的机器学习技术预测电力需求负荷以及电力供应的峰值等，从而最大限度的利用风能、太阳能等可再生能源。此前 DeepMind 研究的算法已经有效预测了谷歌数据中心冷却系统和控制设备的负荷<sup>[44]</sup>，从而将用于系统冷却的用电量减少了 40%，进而推动谷歌数据中心的整体用电量减少了 15%。然而真正将这些算法移植到电网上并使之发挥作用，首先要进一步明确可能对系统运行产生影响的各类要素并将其转化为可被软硬件认知的表达方式。比如风能和太阳能的间歇性有可能成为电力负荷短期预测稳定性和准确度的关键影响要素<sup>[45-48]</sup>，而中长期负荷预测时还涉及电力消费结构变化、电价变动、气象因素变化以及电力供应侧的变化等一系列因素<sup>[49-51]</sup>，定量因素与定性因素、结构化因素和非结构化因素相互交叉，使得电力负荷预测的难度越来越大。

其次面对智能电网这种复杂的工程化应用场景，将类似深度学习这样的新型算法集成进来，如何与传统的预测技术相结合，从而达到取长补短的效果还值得进一步探讨。比如在新算法的推动下，如何将工程一线负荷预测调度工程师积累多年的生产经验转换成可重复可验证的知识表达，在庞大而复杂的知识库中如何有效的组织知识间的逻辑关系等。目前仍有很多复杂的工程问题无法用数学模型来描述，即便是可以建立复杂模型，在系统建模和模型优化，以及分析计算和决策生成的过程中，还需要进行大量的符号运算和推理，由此带来的挑战就是新的人工智能算法如何与符号推理方法集成。此外智能电网的运行涉及多任务多功能，系统中包含众多分散的硬件设备（多类型的计算机、传感器、测试元件以及控制装置等）和各种各样的软件子系统（传输系统、控制系统等），因此在工程实现时除了可分别对分散的软硬件系统进行优化之外，更重要的是能否借助人工智能模拟生成复杂系统的整体框架和运行模式。

除了智能电网相对侧重的输电和配电环节，人工智能在发电端的应用也有着悠久的历史。以火力发电为例，燃煤机组在稳定运行的基础上追求煤炭燃烧效率的最大化，同时污染物排放要降至最低<sup>[52]</sup>，过程控制的各个环节是可以用力学方程进行表达的，而流程上的多个环节连接在一起如何直观表达也是个工程难题。因此，为了直接观察燃煤煤种特性、给煤机转速、一次风和二次风风速、氧量以及燃尽风门开度等这些锅炉燃烧的可调整因素与燃烧效率、污染物排放量之间的关系，基于智能计算的方法对锅炉燃烧系统进行建模成为一种有效途径<sup>[53,54]</sup>。理

论上，在模型建立之后，再通过群体智能、进化计算等启发式随机优化方法对模型参数进行优化便可指导现场可调整因素的设置<sup>[55,56]</sup>。然而从仿真试验到工程实际应用的转变仍然面临诸多挑战，首先已有研究中在建模时通常会提出一些简化条件，而实际上锅炉可调参数众多再加上动力配煤本身就是极其复杂的问题，会导致模型与锅炉的实际运行情况不一致。其次现有研究大多都是基于燃烧现场的数据进行离线建模与优化，离实时在线优化尚有一定距离，建模误差与离线优化的结果相叠加又可能成为导致锅炉非稳定运行的因素。如今人工智能在深度学习以及计算资源调度上的优势或许能为解决这些瓶颈问题提供新的思路。

#### 4 人工智能未来研究展望

当前的人工智能在解决特定领域中的特定问题时确实表现非凡，以深度学习为主流的机器学习方法的进步带动了计算机芯片的同步发展，同时对数据资源的利用也提出了新的需求。同时也应看到，从 AlphaGo 到 AlphaZero 本质上只是某一类问题的“通用”引擎进化之路，不管是围棋、国际象棋还是日本将棋，这类问题奖励机制分明、规则明确且不存在不可预测的干扰，奖励机制分明是目标，即待解问题的目标是数学可明确表达的，规则明确是路径，每一步都可计算得到“奖励”或者“惩罚”，同时博弈双方，不管是人与程序博弈，还是程序与程序博弈，都遵循这一机制和规则，不受外界任何的干扰。而如前文所述，实际生产生活中并不是所有的问题都具备这样的特征，走向未来通用人工智

能的道路上还有很多问题值得思考。

进一步拓宽人工智能研究的思路和途径,避免过于集中在深度学习这一路径上。从传统认知科学出发,人工智能应包括感知能力、记忆与思维能力、学习与自适应能力以及决策与行为能力,而深度学习目前所擅长的模式识别还仅仅是感知能力的一部分。不论是传统的BP神经网络,还是如今的策略网络和价值网络等,这些网络模型的理论基础薄弱、结构单一、数据依赖性强,对现实系统的模拟以及生成的决策仍然不具备可解释性,缺乏深层次的语义挖掘。人类实际并不知道这些决策过程是如何进行的,更无法在过程中给予评价、监督以及适当调节。与此同时,单纯以增加网络中隐层(hidden layers)层数来提升算法性能的做法,实际上更增加了这种决策不可控的风险。一种思路就是对深度学习算法进行解析,尝试在隐层设置若干关键节点,进而以这些节点为基点实现每一层隐层决策过程的语义表达,之后层层迭代进而得到一个“透明”的决策过程。另一种思路就是人工智能研究历史上的几大学派或许要进一步加强融合、或许将产生新的分支,将“黑箱”变成“白箱”走出一条不同的路。

从感知到决策,人类希望人工智能成为一个得力的助手,那么在解决实际问题时应是一个删繁就简的过程。越是面对复杂的问题和复杂的应用场景,人工智能的感受、认知与思维在具备可解释性的基础上,越需要向人们展示一个相对简化的模型,在此基础上形成的决策与行为能力才更容易在工程上得以实现,这是人工智能在实际应用中得以有效推广的根本。就像前文提到人工智能在热力系统中的应用,

越是用简单的几个PLC(可编程逻辑控制器)元件便能够完成调节、控制与优化功能的方案,在工程实际中越容易被接受。与此同时,在实时变化的环境中还要确保人工智能具有理想的泛化性能,并进一步降低能耗。

数据是当前人工智能研发的关键要素,但数据可用性问题还需要进一步探讨。机器学习通常会将数据中最常见的内容作为真理,而把统计学上较为少见的内容排除在外,这种认知方式与人类的认知方式仍有差异,有可能导致对事物的认知产生偏差。从数据源头供给上,快速发展的物联网和大数据确实为人们提供了越来越多的数据,然而面对解决特定问题的需求来说,真实、可靠、可信数据在数据总量中所占的比例又能否达到机器学习需求的下限。ImageNet图像数据集已经过人类专家精心标注,Google的Open Image数据集则是借助机器进行了弱标注;AlphaGo用到的训练数据是人类棋手的真实数据,到AlphaGo Zero开始自我生成数据,也许依靠人工智能自身提高数据可用性也是值得进一步探索的。

因此当人工智能向自主学习、决策与执行进阶时,人工智能带来的伦理、道德、法律等影响理应受到广泛关注。为保障人类未来的安全和利益,国际社会已共同达成阿西洛马人工智能原则,但这些原则尚处于初级阶段,更加细节的问题和具体的实施方式仍有待进一步探索,并需要达成更加广泛的共识。美国即将推出的自动驾驶法案和纽约市即将生效的算法问责法案,韩国推出的机器人基本法案,德国推出的全球首个自动驾驶汽车伦理原则等都是人工智能细分应用领域进行积极的探索和实践。

同时这些规则要真正落实到具体的研发和应用端,除了公共部门的监管之外,在人工智能的基础软硬件开发方面,比如芯片的设计上,采用类似传统“看门狗电路”机制实现芯片乃至系统自毁,或许能够在人工智能危及人类的关键时刻发挥不可替代的作用。

## 参考文献

- [1] Silver D, Huang A, Maddison C J, et al. Mastering the Game of Go with Deep Neural Networks and Tree Search[J]. Nature, 2016, 529(7587):484-489.
- [2] Gibney E. Google AI Algorithm Masters Ancient Game of Go[J]. Nature, 2016, 529(7587):445-446.
- [3] Turing A M. Computing Machinery and Intelligence[J]. Mind, 1950, 59(236):433-460.
- [4] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level Control Through Deep Reinforcement Learning[J]. Nature, 2015, 518(7540):529-533.
- [5] McCulloch W C, Pitts W. A Logic Calculus of the Ideas Immanent in Nervous Activity[J]. Bulletin of Mathematical Biophysics, 1943(5): 115-133.
- [6] Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain [J]. Psychology Review, 1958, 65(6):386-408.
- [7] White B W, Rosenblatt F. Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms[J]. American Journal of Psychology, 1962, 76(4):705.
- [8] Minsky M L, Papert S. Perceptrons: an Introduction to Computational Geometry[M]. Perceptrons: An Introduction to Computational Geometry. The MIT Press, 1969:3356-62.
- [9] Hopfield J J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities[J]. Proceedings of the National Academy of Sciences of the United States of America, 1982, 79(8):2554.
- [10] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets.[J]. Neural Computation, 2006, 18(7):1527.
- [11] Lecun Y, Bengio Y, Hinton G. Deep Learning[J]. Nature, 2015, 521(7553):436.
- [12] Schmidhuber J. Deep Learning in Neural Networks: An Overview[J]. Neural Networks, 2015(61):85-117.
- [13] McCarthy J. Proposal for the Dartmouth Summer Research Project on Artificial Intelligence[R]. Dartmouth College, 1955.
- [14] Simon H A. The Sciences of Artificial [M]. Cambridge: The MIT Press, 1969.
- [15] Newell A. Physical Symbol Systems[J]. Cognitive Science, 1980, 4(2):135-183.
- [16] 钟义信. 人工智能的突破与科学方法的创新[J]. 模式识别与人工智能, 2012, 25(3):456-461.
- [17] 张煜东, 吴乐南, 王水花. 专家系统发展综述[J]. 计算机工程与应用, 2010, 46(19):43-47.
- [18] Liao S H. Expert System Methodologies and Applications—A Decade Review from 1995 to 2004[J]. Expert Systems with Applications, 2005, 28(1):93-103.
- [19] Maddison C J, Huang A, Sutskever I, et al. Move Evaluation in Go Using Deep Convolutional Neural Networks[J]. Computer Science, 2015.
- [20] Clark C, Storkey A. Training Deep Convolutional Neural Networks to Play Go[C].International Conference on International Conference on Machine Learning. JMLR.org, 2015:1766-1774.
- [21] Tian Y, Zhu Y. Better Computer Go player with Neural Network and Long-term Prediction. In 4th International Conference of Learning Representations (ICLR).2016.
- [22] Cazenave T. Residual Networks for Computer Go[J]. IEEE Transactions on Computational Intelligence & Ai in Games, 2017 (99):1-1.
- [23] Dyster T, Sheth S A. Ready or Not, Here We Go: Decision-Making Strategies From Artificial Intelligence Based on Deep Neural Networks[J]. Neurosurgery, 2016, 78(6):N11.
- [24] Bengio Y, Courville A, Vincent P. Representation Learning: A Review and New Perspectives[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(8):1798.
- [25] Silver D, Schrittwieser J, Simonyan K, et al. Mastering the Game of Go without Human Knowledge.[J]. Nature, 2017, 550(7676):354.
- [26] Jouppi N P, Young C, Patil N, et al. In-Datacenter Performance Analysis of a Tensor Processing Unit[J]. 2017:1-12.

- [27] Silver D, Hubert T, Schrittwieser J, et al. Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm, 2017[EB/OL]. (2017-12)[2018-01]. [http://www0.cs.ucl.ac.uk/staff/d.silver/web/Publications\\_files/alphazero.pdf](http://www0.cs.ucl.ac.uk/staff/d.silver/web/Publications_files/alphazero.pdf).
- [28] National Science and Technology Council, Networking and Information Technology Research and Development Subcommittee. The National Artificial Intelligence Research and Development Strategic Plan[R]. Washington, D.C., 2016.
- [29] Stone P, Brooks R, Brynjolfsson E, et al. Artificial Intelligence and Life in 2030[R]. CA: Stanford University, 2016.
- [30] Kasey Panetta. Top Trends in the Gartner Hype Cycle for Emerging Technologies, 2017[EB/OL]. (2017-08)[2018-01]. <https://www.gartner.com/smarterwithgartner/top-trends-in-the-gartner-hype-cycle-for-emerging-technologies-2017>.
- [31] Mark Purdy, Paul Daugherty. Why Artificial Intelligence is the Future of Growth[R]. Dublin: Accenture, 2017.
- [32] Rosen J, Hannaford B, Satava R M. Surgical Robotics: Systems, Applications and Visions[M]. New York: Springer US, 2011.
- [33] 搜狐科技. 利用人工智能技术开发新化合物 这家公司已将触角从医药领域延伸到农药领域[EB/OL]. (2017-06)[2018-01]. [http://www.sohu.com/a/150796207\\_267487](http://www.sohu.com/a/150796207_267487).
- [34] Martino A D, O'Connor D, Chen B, et al. Enhancing Studies of the Connectome in Autism using the Autism Brain Imaging Data Exchange II[J]. Scientific Data, 2017(4):170010.
- [35] Zou Y, Wang Y, Zhang Y, et al. Arctic Sea Ice, Eurasia Snow, and Extreme Winter Haze in China[J]. Science Advances, 2017, 3(3):e1602751.
- [36] Esteva A, Kuprel B, Novoa R A, et al. Dermatologist-level Classification of Skin Cancer with Deep Neural Networks[J]. Nature, 2017, 542(7639):115.
- [37] 高月华, 高芳, 刘英, 等. 基于LS-SVM的氧乙炔火焰图像分类研究[J]. 数字技术与应用, 2010(11):42-43.
- [38] 韩璞. 现代工程控制论[M]. 北京: 中国电力出版社, 2017.
- [39] 王建平. 人工智能在电力系统中应用及发展[J]. 四川电力技术, 1990(1):1-4.
- [40] 蔡自兴, 徐光祐. 人工智能及其应用[M]. 北京: 清华大学出版社, 2010
- [41] 韩祯祥, 文福拴. 人工智能及其在电力系统中的应用:从专家系统到人工神经网络[J]. 电力系统自动化, 1991(3):5-15.
- [42] 余贻鑫, 栾文鹏. 智能电网述评[J]. 中国电机工程学报, 2009(34):1-8.
- [43] Von Dollen D. Report to NIST on the Smart Grid Interoperability Standards Roadmap[R]. CA: Electric Power Research Institute, 2009.
- [44] Richard Evans, Jim Gao. DeepMind AI Reduces Google Data Centre Cooling Bill by 40%[EB/OL]. (2016-07)[2018-01]. <https://deepmind.com/blog/deepmind-ai-reduces-google-data-centre-cooling-bill-40/>
- [45] 彭小圣, 邓迪元, 程时杰, 等. 面向智能电网应用的电力大数据关键技术[J]. 中国电机工程学报, 2015, 35(3):503-511.
- [46] 冯丽. 数据挖掘和人工智能理论在短期电力负荷预测中的应用研究[D]. 杭州: 浙江大学, 2005.
- [47] 杨奎河. 短期电力负荷的智能化预测方法研究[D]. 西安: 西安电子科技大学, 2004.
- [48] 王富强. 风电场短期风速预测及模拟的理论与方法研究[D]. 北京: 华北电力大学(北京), 2013.
- [49] Tasadduq I, Rehman S, Bubshait K. Application of Neural Networks for the Prediction of Hourly Mean Surface Temperatures in Saudi Arabia[J]. Renewable Energy, 2002, 25(4):545-554.
- [50] Mohandes M A, Rehman S, Halawani T O. A neural Networks Approach for Wind Speed Prediction[J]. Renewable Energy, 1998, 13(3):345-354.
- [51] 金义雄, 段建民, 徐进, 等. 考虑气象因素的相似聚类短期负荷组合预测方法[J]. 电网技术, 2007, 31(19):60-64.
- [52] 高芳. 基于智能计算的大型锅炉燃烧系统建模与优化问题研究[D]. 北京: 华北电力大学, 2013.
- [53] Jaques Reifman, Feldman E. Identification and Control of NOx Emissions Using Neural Networks[J]. Air Repair, 1998, 48(5):174-185.
- [54] Bakal B, Fakory R. NOx and CO Prediction in Fossil Fuel Plants by Time Delay Neural Networks[J]. Integrated Computer-Aided Engineering, 1999, 6(1):27-40.
- [55] Tronci S, Baratti R, Servida A. Monitoring Pollutant Emissions in a 4.8MW Power Plant Through Neural Network[J]. Neurocomputing, 2002, 43(1-4):3-15.
- [56] Kalogirou S A. Artificial Intelligence for the Modeling and Control of Combustion Processes: A Review[J]. Progress in Energy & Combustion Science, 2003, 29(6):515-566.