

机器学习——回顾与展望

洪家荣 (哈尔滨工业大学)

摘 要

如所周知,机器学习(ML)已成为人工智能的热门学科。近年ML有了许多新的发展,如联接学习(人工神经网络)、分析学习、遗传算法等。本文对ML的历史和现状做一综述,并展望其未来发展。特别介绍了神经网络、人工智能及ML方法的彼此关系、局限性和应用领域。对各种ML方法给以客观的时评价,供国内同行参考。

1 机器学习的崛起

学习是人类智能的主要标志和获得智慧的基本手段。机器学习(machine learning)是使计算机具有智能的根本途径。正如R. Shank所说:“一台计算机若不会学习,就不能称为是具有智能的。”由于机器学习的研究有助于发现人类学习的机理和揭示人脑的奥秘,所以在人工智能发展的早期阶段,机器学习的研究就占有重要地位。然而由于线性感知器(perceptron)的局限性,使得早期非符号学习的研究被符号学习的研究潮流所湮没。八十年代以来,(符号)机器学习如异军突起,发展甚为迅速。研究队伍不断扩大,各种研究中心、小组相继成立;研究报告、论文如雨后春笋,在各种国际人工智能会议上都占有相当大的比重;1980年创立的两年一届的国际机器学习研讨会IMLW在1988年又发展为正式的国际机器学习年会IMLC,此外欧洲还举行地区年会EWSL,第一个机器学习季刊《Machine Learning》于1986年创刊,现在已拥有一千多订户,至今已出版发行了数十本有关机器学习的书籍;国际人工智能联合会IJCAI颁发的“计算机与思维”的几次大奖,竟有半数以上授予机器学习学者。如今机器学习的研究

正方兴未艾,理论正在创立,方法日臻完善,应用愈加广泛。更加可喜的是:由于隐单元的成功引入,使得长期萧条的联接学习(Connectionist learning),即人工神经网络(artificial neural network),已从低谷走出,并以迅猛发展的势头向符号主义的人工智能提出了挑战。

2 学习的概念

由于学习的机理尚不清楚,关于什么是学习的问题众说纷云,没有严格的定义。一种观点认为学习是使系统性能改善。如H. A. Simon认为:“学习是使系统做一些适应性变化,使得系统在下一次完成同样的或类似的任务时比前一次更有效。”这种观点从行为效果上去把握学习的本质,摸得到见得着,因而较为普遍地被接受。这种观点的欠缺在于它只强调效果而忽视动机。例如,一个想学坏的人越学品质越坏,这不能算做学习。第二种观点认为学习是(有用)知识的获取。确实,一般来说,一个人通过学习都可以增长新的知识。因此,这一观点也具有较普遍的实用性。然而是否获得了新的有用知识需要由行为的效果来衡量。另一方面,某些学习过程(如学骑自行车)不能用获取知识来说明,因为这些过程主要不是思维活

动。第三种观点以 R. S. Michalski 为代表,认为“学习是构造或修改所经历事物的表示”。这种观点的可取之处在于学得任何知识都必须以某种形式来表示和存储,并且系统性能的改善可看做这种表示的目的和结果。但这种观点只说明了学习的内部过程,缺乏透明性,很难从外部把握它。作者认为一个较完整的学习概念应当把上述三种观点结合起来。即,学习是一个有特定目的的知识获取过程:其内部表现为新知识结构的建立和修改,而外部表现为性能的改善。这个定义从不同侧面揭示了学习的实质,而作者的 THOUGHT 系统是这种学习观的最好例证。关于学习的概念,也有人(如 P. Langley)主张暂时避开抽象的定义而着重搞清楚该领域的主要特征和倾向。例如,和人工智能类似,机器学习倾向于使用符号表示而不是数值表示,使用启发式方法而不是算法。这两个倾向曾使人工智能和认知科学同计算机科学的其他学科及模式识别区别开来,也使机器学习同前 two 门科学更紧密地结合起来。机器学习另一主要倾向是使用归纳(induction)而不是演绎(deduction),这一倾向又使它同人工智能的其他学科(例如定理证明、专家系统等)区别开来。

3 机器学习同认识科学 及人工智能的关系

3.1 机器学习与认知心理学

认知心理学(cognitive psychology)是近二十年来发展起来的心理学的一个新方向。认知心理学是用信息加工过程来研究人的智能的性质及思维的过程,因此也叫信息加工心理学。在历史上,心理学的研究有一半以上是关于学习的。因此,学习问题也是认知心理学的主要研究课题。机器学习旨在建立学习的计算理论,构造各种学习系统,应用这些系统到各个领域。因此,机器学习和认知心理学关系十分密切。认知心理学为

机器学习提供心理学依据和指导;机器学习对学习进行计算机模拟,有助于揭示学习的机理和智能的本质。但是,人类学习同机器学习有许多不同之处。例如,人类学习是一个长期的缓慢过程,而机器学习是短暂快速的;人类是“健忘的”,他只能记住他所学过的知识中最重要部分,而机器却能记住它学过的一切;一个人的知识不能直接传递给另一个人,而机器学习系统学得的知识却可以直接复制给另一个系统;人类学习的最大特点是能以最优的方式产生概念,而机器学得的概念很难达到最优。因此,机器学习不可能走完全模拟人类学习的道路,而应当充分发挥自身的特长,克服人类学习的局限性。另一方面,学习的认知模拟又是机器学习研究的终极目标和指南,一个合理的学习模型将有助于机器学习的发展。

3.2 机器学习与人工智能

人工智能的发展为机器学习提供了丰富的工具和广阔的活动场所,并且终于把它推到前台。当前机器学习已成为人工智能的核心,它的应用已遍及人工智能的各个领域,特别是专家系统、自然语言理解、模式识别、计算机视觉和机器人学。学习是一切智能行为的基础,但是现存的智能系统都普遍缺乏学习的能力。例如,当它们遇到错误时,不能自我改正;它们不会通过经验改善自身的性能;它们不能自动获取和发现所需要的知识;它们不能自动产生合理的启发式方法和推理策略;而且它们的推理只限于演绎而缺少归纳,因此它们至多能够证明已存在的事实、定理,而不能发现新的定律、定理。为了克服这些局限性,人工智能不得不求助于机器学习。下面我们仅以专家系统为例,说明机器学习的作用。在专家系统方面,虽然它仍然是人工智能获得最成功的领域,但当前也遇到了巨大的困难。当前专家系统存在的主要问题概述如下。

1) 知识获取“瓶颈”问题 为了建立专家系统的知识库,需要领域专家与知识工程

师合作,总结专家经验,然后形式化并编码输入计算机中。由于领域知识往往很模糊,难于抽取和描述,知识获取是一项耗资费时的大难题。解决这个问题的办法之一是知识自动获取。即应用示例学习(learning from examples),从大量的实例中自动归纳产生描述这些实例的一般规则。一个成功的例子是Michalski和R. L. Chi lausky的PLANT/ds系统。PLANT/ds是一个大豆病害诊断防治专家系统。该系统用示例学习系统AQ₁₁自动产生规则进行诊断,比由专家给出的规则进行诊断的正确率还要高。另外,近年来用神经网络进行知识自动获取,也获得了令人瞩目的成果。

2) 知识悬崖(knowledge cliff)或脆弱性(brittleness) 当推理所用的知识稍稍超过知识库的范围时,系统运行就会失败。这个问题原则上可以通过添加新知识来解决。但知识库的扩充又会造成不一致性和知识库的重组。这些问题可以用渐进学习(incremental learning)来克服。

3) 知识库过于庞大和非结构性 这些问题可通过概念聚类(conceptual clustering)和概念获取对知识库结构化来解决。THOUGHT系统是一个成功的例子。

4) 求解方法单一 单一的求解方法不能适应领域知识的多样性,往往导致系统的失败。机器学习的一个解决方法是策略学习。例如,T. Mitchell的解释学习系统(explanation based learning)LEX和LEAP就具有策略学习的功能。

5) 缺乏直觉(intuition)判断的能力 直觉是当前人工智能和认知心理学学界对一个专家系统是否真正达到专家级水平的争论热点。而现存专家系统即使遇到过去解决了的问题,但仍需要重新一步步推理。机器学习可以把一个专家系统过去的求解经验积累起来,并进行分类与抽象,使知识库面向目标的结构化,来达到直觉的功能。THOUGHT就是这种新型专家系统工具。

4 主要学习方法

正像人有各种各样的学习方法一样,机器学习的方法也很多,为了系统地了解机器学习,有必要对学习方法进行分类。当前国际上流行的分类方法主要有四种:按应用领域分类(如专家系统、问题求解和认知模拟等);按获取的知识的表示分类(如逻辑表达式、产生式规则、决策树、框架、神经网络等);按推理策略分类(如演绎推理和归纳推理的程度和比重);及按系统性分类(综观历史渊源、知识表示、推理策略及应用领域)。后两种分类方法比较合理,其中按推理策略分类一直被广泛采纳,而按系统性分类是最近提出来的方法,它综合了前三种分类法,比较科学和自然。因此,在这里我们仅介绍后两种分类法。

4.1 基于推理策略的分类

一个学习过程本质上是学生(学习系统)把教师或环境(如书本)提供的信息转换成能够理解的形式记忆下来以便将来使用。这种转换是一种推理过程,它决定了学习的类型。在学习过程中,学生使用的推理越少,他对教师的依赖就越大,因而教师的负担就越重;反过来,学生使用的推理越多,教师的负担就越轻。因此,一种自然的学习分类方法是按学生使用推理的多少和难易来进行。在这种分类中,学习方法按学生推理从少到多(或教师负担由重到轻)排列如下。

1) 机械学习(rota learning) 不需要推理,直接编程或存储外部信息。A. Newell和Simon的LT就是这样的学习系统。

2) 讲授学习(learning from instruction或learning by being told) 学生对教师或环境提供的知识进行选择或重新表述(形式化)并编码成机内表示。目前大多数

专家系统使用这种方法建立知识库。

3) 演绎学习 (deductive learning)

这是通常的逻辑推理方法。推理过程通常是从公理出发, 经过逻辑变换, 推导出结论。这种推理是一种“保真”变换和特化的过程 (specialization)。这是一种证明定理的方法。

下述的学习方法将涉及另一种重要的推理过程——归纳推理 (inductive inference)。归纳推理能够对输入信息进行推广 (generalization) 并且选择较理想的结果。归纳推理不是保真变换, 但却是“保假”变换。即前提假, 归纳出的结论也假。归纳推理是人类最重要的思维方法之一, 它也是发现科学定律和定理的有力工具。归纳推理同演绎推理互为逆过程, 并且在大多数学习方法中同时出现。

4) 解释学习 (explanation-based learning, EBL) 学生根据教师提供的目标概念、该概念的一个例子、领域理论及操作准则, 首先构造一个解释说明为什么该例子能满足目标概念, 然后使用回归将解释推广为目标概念的一个满足操作准则的充分条件。EBL的第一步是演绎, 第二步是归纳, 并用领域知识指导归纳, 增加结果的可信度。EBL被广泛应用于知识库求精和改善系统的性能。著名的EBL系统有 G. DeJong 的 GENESIS, T. Mitchell 的 LEX 和 LEAP, 以及 S. Minton 等的 PRODIGY。

5) 类比学习 (learning by analogy)

已知两个不同领域: 源域和目标域, 并且知道这两个领域具有相同或相似的性质, 则可以猜测源域中的其他性质也可能在目标域中成立。形式地, 设 S 和 T 分别是源域和目标域。S 的元素 s 同 T 的元素 t 相对应并且具有相同性质 P, 即 $P(s)$ 及 $P(t)$ 成立。s 还具有性质 Q, 即 $Q(s)$ 。可以推出 t 也具有性质 Q, 即 $Q(t)$ 。亦即

$$P(s) \wedge Q(s), P(t) \vdash Q(t)$$

类比推理过程分两步: 第一步是找出源域与

目标域的公共性质 P, P 同源域另一性质的关系 $P(s) \rightarrow Q(s)$, 并且推广之 $\forall x (P(x) \rightarrow Q(x))$; 第二步, 从源域到目标域的映射以得到目标域的新性质, 即从 $\forall x (P(x) \rightarrow Q(x))$ 和 $P(t)$ 应用假言推理, 得出 $Q(t)$ 。因此, 类比学习也是演绎和归纳的结合: 第一步主要是归纳, 第二步主要是演绎。类比学习在人类科学技术发展历史中起着重要作用, 许多重大科学技术发现都是用类比方法得到的。例如, 著名的卢瑟福类比就是通过将原子结构 (目标) 同太阳系 (源) 进行类比, 从而发现原子结构的奥密。从事这方面研究的代表人物有 P. Winston, J. G. Carbonell, D. Gentaer 和 R. Greiner 等。

6) 归纳学习 (inductive learning)

教师或环境提供某概念的一些例子, 学生使用归纳推理将这些例子推广, 产生该概念的一般描述。归纳学习是最基本的、发展较为成熟的学习方法。归纳学习又可根据有无教师指导分为示例学习和观察与发现学习。

① 示例学习 (learning from examples)

教师提供某概念的正例集合与反例集合, 学生通过归纳推理产生复盖所有正例并排除所有反例的该概念的一般描述。这是一种从具体事例产生抽象概念的方法, 因此也叫概念获取 (concept acquisition)。示例学习是人类最基本的学习能力, 也是机器学习的主要研究对象。加之示例学习可以被用于专家系统自动构造知识库, 因而成为机器学习的核心领域。示例学习系统较多, 其中较有影响的有 E. B. Hunt 等的 CLS 及其扩充 J. R. Quinlan 的 ID₃、Michalski 的 AQ₁₁ 及其扩充作者的 AQ₁₅、Mitchell 的变形空间、作者的 AE₁ 和 L. Rendell 的 PLS₁ 等。此外, 有导师的联接学习本质上也是示例学习。

② 观察与发现学习 (learning from observation and discovery)

环境提供一组观察事例, 学生构造一个一般的概念描述 (即理论) 来复盖所有或大多数事例; 这是一种无导师学习, 是归纳学习的更一般、更复

杂的形式。这种学习又分为观察学习与机器发现。

a. 观察学习 学生将已知事例分类,同时产生每一类的一般概念描述。观察学习又可依据是否渐近 (incremental) 方式而细分为概念形成和概念聚类。此外,无导师联接学习也可归入此类。

(I) 概念聚类 (conceptual clustering) 学生对已知事例分类,产生每一类的概念描述,再用该概念描述指导进一步分类,直到结果满意为止。概念聚类思想是由Michalski首创的,较有名的系统有Michalski和R. Stepp的CLUSTER/z、P. Langley等的GLAUBER。

(II) 概念形成 (concept formation) 学生将依次出现的事例分类,产生概念描述,并且构造一个层次结构。著名的概念形成系统有E. A. Feigenbaum的EPAM、M. Lebowitz的UNIMEM、和D. F. Sher的COBWEB。

b. 机器发现 (machine discovery) 学生从观察事例或经验数据中归纳产生规律或规则。机器发现被看作观察与发现学习的最困难、也最富创造性的一种学习形式。机器发现原来专指经验发现,现在又包括一种新的发现方法:知识发现。此外,遗传算法也可并入该领域。

(I) 经验发现 (empirical discovery) 从经验数据中发现规律和定律。例如,重新发现理想气体定律、能量守恒定律、欧姆定律等。著名的经验发现系统有Langley的BACON.4,其次是B. Falkenhainer与Michalski的ABACUS,和J. M. Zytkow的FAHRENHEIT。

(II) 知识发现 (knowledge discovery) 从已知观察事例或数据中发现知识 (一般是产生式规则)。这是刚刚兴起的一个新领域。有关的知识发现系统有作者的KD₁、Langley的GLAUBER、J. G. Ganascia的CHARADE、R. M. Goodman与P. Smyth的I-

TRVLE、以及G. Piatetsky-Shapiro的规则发现系统。

基于推理策略的分类比较适合以往机器学习的发展状况。但是,近几年来机器学习有了较大的发展,研究领域不断扩大,原有方法更加成熟。例如,联接学习的兴起、遗传算法脱颖而出、解释学习变成热门,凡此种种使以往的分类法已无法容纳这些新领域,不再适应这种新发展。为了适应这些新的情况,近年来出现了系统性分类法。

4.2 系统性分类

这种分类综合考虑了各种学习方法出现的历史渊源、知识表示、推理策略以及结果评估的相似性、应用领域等诸因素,因此比较合理。系统性分类一般包括四大部分,即归纳学习、分析学习、联接学习、和遗传算法与分类器系统。

1) 归纳学习 同基于策略分类,但去掉其中的联接学习和遗传算法部分。

2) 分析学习 (analytic learning) 从一个或少数几个实例出发,应用领域知识进行分析来学习。分析学习的主要特征有:(1)推理策略是演绎而非归纳;(2)使用过去的问题求解经验(实例)指导新的问题求解,或产生能更有效地应用领域知识的搜索控制规则。即,分析学习目标是改善系统的效率,而不是扩充概念描述的范围。分析学习主要包括解释学习、类比学习、多级组块(chunking)、迭代的宏操作、以及实例学习(case based learning)

3) 联接学习(或神经网络) 一个联接模型(神经网络)由一些简单的类似神经元的单元以及单元间带权的联接组成。每个单元具有一个状态,这个状态是由同这个单元相联接的其他单元的输入决定的。联接学习的目的是区分输入的模式等价类。联接学习通过用各类的例子来训练网络,产生网络的内部表示,并用来识别其他输入例子。学习主要表现在调整网络中的联接权。联接学习是非符号的,并且具有高度并行分布式处理的

能力,近年来获得极大的成功与发展。比较著名的学习算法有感知器(perceptron)、Hopfield网络、Boltzmann机、和误差反向传播算法(backpropagation)等。

4) 遗传算法(genetic algorithm)与分类器系统(classifier systems) 分类器系统是一种高度并行的、信息传递(message-passing)的规则库系统。分类器系统通过信任分配(排队列算法)和规则发现(遗传算法)来学习。遗传算法模拟了生物繁殖的突变(互换、倒位、点突变等)和达尔文的自然选择(在每一生态环境中适者生存)。具体地,一个概念描述的变形(分类器)对应于一个物种的个体,这些概念的诱导变化和重组用一个目标函数(相应于自然选择准则)来衡量,看其中哪些能够保留在基因库中。遗传算法适用于非常复杂困难的环境,比如,带有大量噪音和无关数据的不断更新的事物,不能明显和精确地定义的问题目标以及通过很长的执行过程才能确定当前行为的价值等。同神经网络一样,遗传算法的研究已经发展为人工智能的一个独立分支。这个领域的杰出代表是J. H. Holland。

5 发展简史

机器学习的研究和人工智能同时起步,并一直起着核心的作用。根据研究目标、方法、倾向与侧重点,机器学习可分为四个发展阶段。

1) 第一阶段——神经元模型研究。这一阶段开始于五十年代中期,主要是研制通用学习系统,即神经网络或自组织系统。当时是基于这样一种朴素想法:如果给一个系统一组刺激、一个反馈源、和修改自身组织的足够的自由度,那么该系统就可能自适应地趋向最优组织。但由于当时计算技术水平的限制,这种想法只能停留在理论上的探讨或专用实验硬件系统的构造上。这方面代表

性的工作有F. Rosenblatt的感知器(1958)。奠基性的理论成果有N. Rashevsky的数学生物物理学(1948)、和W. S. McCulloch与W. Pitts的用带有阈逻辑输出的离散决策元件模拟神经元的理论(1943)。相关的工作还有R. M. Friedberg对进化过程的模拟(1958),旨在通过随机突变和自然选择来创造智能系统。这方面的研究获得了两个副产品:形成了人工智能的一个新分支——模式识别,并创立了学习的决策论方法。这一时期最有影响的成果是A. L. Samuel的下跳棋程序(1959),经过反复训练,这个程序达到了大师级水平。但是好景不长,1969年M. Minsky与S. Papert揭示了神经元模拟理论上的严重缺陷。这个打击使这个领域的研究队伍迅速解体:一部分人转向知识库系统和自然语言理解,另一部分人继续从事自适应系统研究,但已脱离人工智能队伍,加入到线性系统论的研究队伍中。

2) 第二阶段——符号概念获取的研究。这一阶段始于六十年代初期,并源于心理学和人类学习的模拟。这个领域的特点是使用符号表示而不是数值表示,目标在于学习表达高级知识的符号描述。代表性的工作有Hunt与C. I. Hovland的CLS(1963),影响较大的有P. Winston的结构学习系统(1975)。知识获取系统还有B. G. Buchana等的META-DENDRAL(1978)和Michalski的AQVAL(1973)。这一时期的研究工作者已意识到知识的重要性,并且开始将领域知识编入学习系统,如META-DENDRAL和D. B. Lenat的AM(1976)。

3) 第三阶段——符号学习兴旺发达时期。这一阶段始于七十年代中期。当时人工智能的新分支专家系统蓬勃发展起来,知识获取变成当务之急,各种有关的学习策略相继出现。如讲授学习(D. J. Mostow, 1983),观察与发现学习(Michalski与Steepe, 1983; Langley, 1983)。同时,分析学习也出现了,如类比学习(Winston,

1979, Carbonell, 1983), 和解释学习 (DeJong, 1983; Mitchell, 1986)

4) 第四阶段——联接学习同符号学习争奇斗艳。这一个阶段始于八十年代后期。当年忍恨退出人工智能队伍的神经网络的一些先驱及其后继者们经过二十多年卧心藏胆的潜心研究, 发现了用隐单元来计算与学习非线性函数的方法, 从而克服了早期神经元模型的局限性。加之计算机硬件的突飞猛进的发展, 使神经网络的实现成为现实。因此, 在八十年代末期, 神经网络迅速崛起, 并在声音识别、图象处理等诸多领域获得很大的成功。各种研究中心、学术会议层出不穷、规模越来越大。进而非符号的神经网络向传统的符号人工智能发起挑战, 大有山雨欲来风满楼之势。其中半是成功的喜悦, 半是耿耿的积怨, 半是未来的憧憬, 半是称霸的野心。这个新浪潮的学术带头人有 D. E. Rumelhart(1986)、J. J. Hopfield(1982) G. E. Hinton(1981)、J. A. Feldman(1982)、K. Fukushima(1982)、和 T. Kohonen(1982)等。然而, 符号的人工智能毕竟已走过四十多年的发展道路, 它在许多方面已经变得成熟起来, 虽然它受到神经网络的冲击, 但仍能把握自己的航向, 并且从竞争中获得新的生机。在符号学习方面也是如此。事实上, 在这一阶段符号学习的各种方法已全面发展并日臻成熟, 应用领域不断扩大, 达到了一个巅峰时期。其中最突出的成就包括分析学习(特别是解释学习)的发展 (DeJong, 1986; Mitchell, 1986; S. Minton等, 1987)、遗传算法的成功 (Holland, 1986)、决策树归纳 (Quinlan, 1983)。此外, 类比学习的结构映射理论与实现 (B. Falkenhainer与Gentner, 1986)、经验学习系统SOAR (J. E. Laird等,

1986)、通用渐近示例学习系统AQ₁₅ (洪家荣与Michalski, 1986)、概念形成系统UNIMEN (Lebowitz, 1987)与COBWEB (Fisher, 1987)、经验发现系统BACON.4 (Langley, 1986)和ABACUS (Falkenhainer与Michalski, 1986)诸方面也都有了新的进展。

在我国, 八十年代以来机器学习受到普遍的关注, 研究队伍逐渐形成, 于1987年7月召开了第一届全国机器学习研讨会, 1989年7月召开了第二届研讨会, 并正式成立了中国人工智能学会机器学习学会。我国学者在机器学习的许多领域中都获得了可喜的成果。其中国际上影响较大的成果有作者的AQ₁₅和示例学习的扩张矩阵理论*, 被引用的工作还有吴轶华的经验发现系统及作者与毛成江的知识发现系统KD₁₁, 国内已产生影响的工作有: 讲授学习(何志均、陆汝钫、余瑞钊)、解释学习(石纯一、马志方、徐立本)、类比学习(蔡庆生、史忠植、洪家荣)、示例学习(洪家荣、陆汝钫、陈世福、史忠植)、概念聚类(洪家荣、马志方)、经验发现(吴轶华、蔡庆生)、知识发现(洪家荣、毛成江)、经验学习与搜索(张伟、余瑞钫、洪家荣)、联接学习(戴沃为、王珏、蔡义发、史忠植)、集成化学习系统(洪家荣、毛成江)。

6 展 望

当前机器学习研究继续向纵深发展。人们由神经网络的初步成功产生的狂热已经降温, 逐渐认识到神经网络对模拟人类较低级的神经活动(如感觉活动)比较有效, 面对人类高级思维活动符号的人工智能仍然不可缺少。联接学习和符号学习应用领域可分工如

*关于示例学习的计算理论(如它属于NP难题的证明)以前一直误认为美国学者D. Haussler首创。直到1990年美国著名刊物《Artificial Intelligence》才发表Haussler本人的声明, 承认作者的工作领先于他, 并向作者致歉。

下。

联接学习最适用于连续发音的语音识别及连续模式的识别。对于离散模式的识别，归纳学习的决策树方法最好；新概念描述获取的最好方法是归纳学习，而遗传算法和联接学习都不能产生概念描述；专家系统的规则获取，在有很强领域理论时，类比学习或解释学习最能奏效，在没有很强领域理论时，归纳学习或遗传算法比较适用，而联接学习由于不能记忆以往的状态因而不能模拟多步推理或演绎链；在提高规则库系统的执行效率方面当首推分析学习；对交互式符号推理，知识必须显式编码以便双方彼此理解和共享，最理想的算法是归纳推理或分析推理（通常是实例类比推理）；对集成化推理系统，原则上所有学习方法均可使用，但目前以分析方法应用最成功。

总之，对非结构的连续领域的单步格式塔识别，在有大量训练例子的情况下，联接

学习最有优势；相反，对良结构的知识丰富的领域，如果要求多步推理和深层推理，即使只有少数训练例子也是分析方法最理想；归纳方法和分析方法适合界于上述两个极端的广大领域。另一方面，对于复杂的任务（如人类思维模拟）需要多种学习方法协同工作才能完成。

因此，机器学习未来的发展方向将是：

(1)学习的形式理论的研究，目前这方面工作比较薄弱；(2)面向实际应用，在应用中发展和完善现有方法；(3)多种学习方法协同工作的集成化系统研究，以便解决复杂任务和模拟思维过程，这包括符号学习中各种方法的联合（如THOUGHT系统），以及联接方法与符号方法相结合（如作者的联接符号专家系统LNES），使得低级神经活动用联接方法，而高级神经活动用符号方法。

参考文献（略）

（接第62页）

- Explicit, Proc. IFIP 88, North Holland Publishing Company, Amsterdam, 1986
- [7] JE. Laird, A. Newell and PS. Rosenbloom, SOAR: an architecture for general intelligence, AI 33, 1987
- [8] L. Bottacci, Modifiability of rule-based expert systems, PhD Thesis, Division of Cybernetics, Brunel University, UK, 1985
- [9] L. Steels, Second-generation expert systems, Research and development in expert systems II. Bramer MA (ed.), Cambridge, Cambridge University Press, 1986
- [10] Michael Z. Bell, 专家系统为什么失败, 计算机科学, No.2, 1987.
- [11] P. Reind, van de Riet, 专家系统遇到了麻烦, 计算机科学, No.2, 1987
- [12] R. Davis, Reasoning from first principles in electronic trouble-shooting, Int. J. Man-Machine Studies 19, 1983
- [13] R. Reiter, A Theory of Diagnosis from First Principles, «Readings in nonmonotonic reasoning» ed. by Matthew L., Ginsberg, 1987
- [14] RS. Patil, P. Szolovits and WB. Schwartz, Modelling knowledge of the patient in acid-base and electrolyte disorders, «Artificial intelligence in medicine», ed. by P. Szolovits, 1982
- [15] WJ. Clancey, Heuristic classification, AI 27, 1985
- [16] WJ. Clancey, From Guidon to Neomycin to Heracles in twenty short lessons, ORN final 1979—1985, The AI Magazine, Aug. 1986
- [17] 金芝、刘凤歧、胡守仁, 知识系统问题求解方法评述, 1989年全国人工智能及其应用学术会议文集, 1989年, 北京