

机器学习与智能决策支持系统

杨善林 倪志伟 著

国家自然科学基金资助项目(项目编号:79970058,70171033)

科学出版社

北京

内 容 简 介

机器学习的研究不仅是人工智能研究的重要问题,而且已成为计算机科学与技术的核心问题之一。智能决策支持系统是将人工智能技术引入决策支持系统而形成的一种新型信息系统。本书首先研究了机器学习的基本概念,在此基础上,详细研究了归纳学习、范例推理、粗糙集、遗传算法等经典学习方法;本书后半部分首先介绍了智能决策支持系统的有关概念,接着详细探讨了基于几类具体机器学习技术的智能决策支持系统,不仅研究了基于机器学习的智能决策支持系统的框架结构,而且针对各种不同的机器学习技术,研究了具体的智能决策支持系统,包括:基于神经网络的智能决策支持系统,基于范例推理的智能决策支持系统,基于遗传算法的智能决策支持系统,基于归纳学习的智能决策支持系统,基于粗糙集的智能决策支持系统,并就最新机器学习技术的发展与智能决策支持系统的结合进行了研究。最后,本书研究了智能决策支持系统中若干相关的新技术。

本书可作为高等学校信息管理与信息系统、电子商务、计算机科学与技术等专业本科生和研究生用书,也可供计算机应用软件开发人员和相关研究人员作为参考书。

图书在版编目(CIP)数据

机器学习与智能决策支持系统/杨善林,倪志伟著.—北京:科学出版社,2004

ISBN 7-03-012814-1

I. 机… II. ①杨…②倪… III. ①机器学习 ②智能决策—决策支持系统 IV. ①TP181 ②TP399

中国版本图书馆 CIP 数据核字(2004)第 005697 号

策划编辑:马长芳/文案编辑:邱璐 贾瑞娜/责任校对:钟洋

责任印制:安春生/封面设计:北新华文

科学出版社 出版

北京东黄城根北街 16 号

邮政编码:100717

<http://www.sciencep.com>

印刷

科学出版社发行 各地新华书店经销

*

2004 年 5 月第 一 版 开本:B5(720×1000)

2004 年 5 月第一次印刷 印张:20

印数:1—3 000 字数:384 000

定价:30.00 元

(如有印装质量问题,我社负责调换〈环伟〉)

前 言

机器学习是人工智能研究中最早的课题之一,也是人工智能中最具有智能特征和最前沿的研究课题之一。机器学习的重大进步往往意味着人工智能研究向前迈进了坚实的一步。机器学习在自然语言理解、非单调推理、机器视觉、模式识别等领域得到了普遍应用,尤其在基于知识的系统和决策科学中的应用,得到了广泛开展。机器学习在智能决策支持系统中的应用也越来越受到专家和学者们的重视。

20世纪70年代初诞生的决策支持系统(DSS),发展至今已有30多年了。随着计算机技术的广泛而深入的应用,各行各业对决策支持都提出了更高的要求。80年代,在决策支持系统中引入了人工智能技术,从而形成了智能决策支持系统(IDSS)的概念。智能决策支持系统是决策支持系统与人工智能技术相结合的产物,它将许多智能技术和思想引入到决策支持系统之中。它是以信息技术为手段,应用计算机科学、管理科学、数理统计等相关理论和方法,针对半结构化和非结构化的问题,为管理人员做出正确决策提供智能型人机交互信息系统。实践表明,只有当决策支持系统具有丰富的知识和较强的学习能力时,才能提供更为有效的决策支持。针对智能决策支持系统存在的问题,研究一种基于机器学习的智能决策支持系统,增加学习部件,提高系统的学习能力,对于改善决策的智能水平,提高系统的性能和应用效果,具有重要的理论意义和较高的实际价值。

本书作者长期从事管理信息系统、决策理论与方法、人工智能、机器学习等理论和应用研究,先后完成了国家自然科学基金课题、国家“十五”攻关课题、中央财政专项课题、教育部重点课题、博士点基金项目、安徽省攻关课题以及企业委托的课题,先后获得多项省部级奖。本书正是对多年来相关领域研究成果的总结。本书总结了多年开发决策支持系统的体会,并充分利用计算机技术、决策理论、建模技术、行为科学等研究成果,从提供有效的决策支持的角度出发,进行需求分析、环境条件分析和实施方法的研究。

本书首先研究了机器学习的基本概念,并详细研究了归纳学习、范例推理、粗糙集、遗传算法等经典学习方法;然后介绍了智能决策支持系统(IDSS)的有关概念,提出了基于一些具体机器学习技术的智能决策支持系统;最后,本书研究了智能决策支持系统相关新技术的最新发展。全书共分八章,第1章阐述了机器学习和智能决策支持系统的基本概念;第2章至第5章着重研究了归纳学习、范例推理、粗糙集、遗传算法等机器学习技术;第6章叙述了决策支持系统的基本框架,研究了在智能决策支持系统融入机器学习的思想与方法;第7章重点研究了基于各类具体机器学习的智能决策支持系统;第8章讨论了智能决策支持系统中相关新技

术的发展。

本书由合肥工业大学杨善林教授、倪志伟教授主编,各章的编著者如下:第1章:杨善林;第2章:赵鹏;第3章:倪志伟;第4章:李建洋;第5章:贾兆红;第6章:李学俊;参与第7章编写的同志有:倪志伟,刘业政,胡彩平,赵鹏,李建洋,贾兆红,马猛,贾瑞玉;参与第8章编写的同志有:倪志伟,马猛,唐理兵,梁昌勇、贾瑞玉。杨善林和倪志伟教授负责全书的策划和大纲的制订,倪志伟教授负责全书的统纂和修改。

在本书的编著过程中,参考了大量的国内外有关研究成果,在此对所涉及的专家和研究人员表示衷心的感谢。刘业政教授仔细地审阅了全部书稿,提出了许多有价值的建议,并在书稿写作后期参与协调;合肥工业大学计算机网络系统研究所的马溪骏、刘心报、梁昌勇、李锋刚、何建民、李兴国、毛学岷等老师对本书的撰写给予了极大的关心和支持,在此谨向他们表示诚挚的谢意。另外,科学出版社的编辑为本书的出版付出了大量的心血,特此致谢。本书还得到了两项国家自然科学基金项目(项目编号:79970058,70171033)的资助,在此表示感谢。

经过多年的研究,我们深深感到有关智能决策支持系统的研究是综合性的,机器学习的发展也是十分迅速的。在机器学习和智能决策支持系统相结合的领域里,需要研究的问题很多,希望本书的出版能成为我们继续研究的新起点。书中错误和不妥之处请各位专家和读者不吝指教。

作 者

2003年11月8日

目 录

前言

第 1 章 绪论	1
1.1 机器学习发展史	1
1.1.1 引言	1
1.1.2 热烈时期	2
1.1.3 冷静时期	3
1.1.4 复兴时期	3
1.1.5 蓬勃发展时期	4
1.2 机器学习研究基础	6
1.2.1 机器学习的一个实例	6
1.2.2 机器学习的基本模型	7
1.2.3 机器学习的主要策略	9
1.2.4 机器学习的算法基础	14
1.3 计算学习理论	17
1.3.1 可能近似正确学习模型(PAC)	18
1.3.2 有限假设空间的样本复杂度	20
1.3.3 与 PAC 模型有关的几种模型	21
1.3.4 假设空间复杂度的一个重要度量标准——VC-维	24
1.4 智能决策支持系统	25
1.4.1 智能决策支持系统发展过程	25
1.4.2 IDSS 的系统功能与体系结构	27
1.4.3 IDSS 的主要研究内容	29
1.4.4 智能决策支持系统的发展趋势	31
1.5 机器学习与智能决策支持系统	33
1.5.1 基于知识的 IDSS 发展中存在的问题	33
1.5.2 对智能的探讨	35
1.5.3 基于机器学习的 IDSS 框架	36
1.5.4 机器学习在智能决策支持系统中的应用	38
参考文献	40
第 2 章 归纳学习	41
2.1 概述	41

2.2	归纳学习	42
2.2.1	规则学习	42
2.2.2	决策树学习	43
2.2.3	科学发现	44
2.2.4	特征子集选择问题	45
2.3	归纳学习的逻辑基础	45
2.3.1	归纳逻辑与归纳推理	45
2.3.2	归纳推理规则	47
2.3.3	归纳学习中的知识表示	50
2.3.4	归纳偏置	52
2.4	决策树归纳学习	54
2.4.1	例子	54
2.4.2	CLS 学习算法	55
2.4.3	ID 系列学习算法	56
2.4.4	C4.5 学习算法	64
2.5	关于决策树的深入讨论	65
2.5.1	决策树的评价标准	65
2.5.2	由决策树提取分类规则	67
2.5.3	测试属性的选择	68
2.5.4	树剪枝	70
2.5.5	测试属性空间的修改	75
	参考文献	77
第3章	范例推理	79
3.1	引言	79
3.2	CBR 研究的历史和现状	80
3.3	CBR 中范例的表示方法及检索技术	82
3.4	CBR 的修正技术	86
3.5	CBR 系统的维护	89
3.5.1	引言	89
3.5.2	相关工作	90
3.5.3	CBR 系统中范例库维护的定义及其构架	93
3.6	基于数据挖掘技术的范例推理系统	94
3.6.1	引言	94
3.6.2	范例推理中基于数据库的数据挖掘技术	95
3.6.3	范例库上知识发现的主要步骤与目标	96
3.6.4	范例库上知识发现的主要方法与技术	97

3.6.5	基于知识发现技术的 CBR 系统框架结构	99
3.7	基于神经网络的 CBR 系统	101
3.7.1	范例推理与神经网络	101
3.7.2	用 IAC 网络来构造 CBR 系统	102
3.8	CBR 方法与其他方法的集成	105
3.8.1	相关研究	106
3.8.2	归纳技术与范例推理的结合	107
3.8.3	范例推理与专家系统的结合	108
3.9	CBR 的进一步研究方向	110
	参考文献	112
第 4 章	粗糙集	117
4.1	概述	117
4.1.1	粗糙集理论发展简史	117
4.1.2	粗糙集理论基本思想	118
4.1.3	粗糙集与其他不确定方法的比较	120
4.1.4	粗糙集理论研究现状	121
4.2	基本概念	123
4.2.1	知识与分类	123
4.2.2	不可分辨关系	125
4.3	粗糙集的基本理论	126
4.3.1	上近似集和下近似集	126
4.3.2	粗糙集中概念的物理意义	126
4.3.3	近似集的性质和近似精度	128
4.3.4	粗糙集的集合关系	130
4.4	知识的约简	132
4.4.1	知识的约简和核	132
4.4.2	知识的相对约简和相对核	133
4.4.3	知识的依赖性度量	135
4.5	决策表达逻辑	136
4.5.1	数据表知识表达系统	136
4.5.2	决策表	137
4.5.3	决策逻辑	139
4.5.4	决策表的约简	140
4.5.5	属性约简的差别矩阵方法	143
4.5.6	差别矩阵方法的约简	145
4.6	粗糙集的具体实现和应用	146

4.6.1	离散归一化	146
4.6.2	引入领域知识的数据约简	147
4.6.3	医疗数据分析	148
4.6.4	模式识别	150
4.7	相似粗糙集及其应用	153
4.7.1	相似粗糙集理论	153
4.7.2	相似粗糙集的应用:气象系统权值发现	154
	参考文献	158
第 5 章	遗传算法	160
5.1	遗传算法的主要特征	160
5.1.1	标准遗传算法	161
5.1.2	遗传算法的优缺点	164
5.2	遗传算法的基本原理	165
5.2.1	模式定理(schema theorem)	165
5.2.2	积木块假设	167
5.2.3	欺骗问题	168
5.2.4	隐并行性	171
5.3	遗传算法的关键问题及方法	171
5.3.1	编码	171
5.3.2	适应度函数	172
5.3.3	遗传操作	175
5.3.4	未成熟收敛问题	179
5.4	遗传算法的应用	182
5.4.1	遗传算法与知识发现	182
5.4.2	遗传算法在神经网络中的应用	185
5.4.3	佳点集遗传算法与货郎担问题	187
5.5	遗传算法的改进	192
5.5.1	统计遗传算法	192
5.5.2	并行遗传算法	195
	参考文献	197
第 6 章	决策支持系统	200
6.1	概述	200
6.1.1	DSS 的产生	200
6.1.2	决策支持系统的基本概念	202
6.1.3	DSS 与 MIS 的关系	204
6.1.4	DSS 在发展中面临的问题	205

6.1.5	DSS 的发展趋势	207
6.2	DSS 的基本体系结构	210
6.2.1	引言	210
6.2.2	人机交互子系统	214
6.2.3	数据库系统	218
6.2.4	模型库系统	221
6.2.5	方法库系统	228
6.3	DSS 的开发与设计	230
6.3.1	DSS 的开发过程	230
6.3.2	决策支持系统的开发方法	233
6.3.3	决策支持系统的设计	234
6.4	智能决策支持系统	235
6.4.1	IDSS 的三种体系结构及其比较	236
6.4.2	IDSS 的模型库系统	238
6.4.3	IDSS 的知识库系统	240
6.4.4	IDSS 的研究现状和存在的问题	244
6.4.5	IDSS 的研究方向	248
	参考文献	251
第 7 章	基于机器学习的智能决策支持系统	254
7.1	基于机器学习的 IDSS	254
7.1.1	概述	254
7.1.2	基于机器学习的 IDSS 的体系结构	255
7.1.3	基于机器学习的 IDSS 知识库和知识表示系统	258
7.2	基于神经网络学习的智能决策支持	261
7.2.1	神经网络的学习算法	261
7.2.2	基于神经网络的 IDSS 的总体框架	266
7.2.3	基于神经网络的 IDSS 自动模型选择	267
7.2.4	基于神经网络和专家系统的 IDSS	268
7.3	基于范例推理的智能决策支持系统	270
7.3.1	引言	270
7.3.2	基于范例推理的决策支持系统	271
7.3.3	基于数据挖掘和范例推理的 IDSS	274
7.3.4	基于范例的集成推理模型的 IDSS	275
7.3.5	基于范例推理的决策支持系统的应用实例	276
7.3.6	总结与展望	277
7.4	遗传算法与智能决策支持系统	278

7.4.1	遗传算法在 IDSS 中的应用	278
7.4.2	基于遗传算法的决策支持系统模型设计	281
7.4.3	一个基于遗传算法的建模实例	285
7.4.4	展望与总结	287
7.5	基于归纳学习的 IDSS	287
7.5.1	基于归纳学习的 IDSS 的技术	287
7.5.2	应用实例	293
7.6	基于粗糙集的智能决策支持系统	294
7.6.1	引言	294
7.6.2	基于粗糙集数据分析的智能决策支持系统	296
7.6.3	小结	300
7.7	其他的机器学习技术在 IDSS 中的应用	301
7.7.1	基于强化学习的 IDSS	301
7.7.2	基于 Bayes 网络的 IDSS	307
7.7.3	统计机器学习及其在 IDSS 中的应用	311
	参考文献	315
第 8 章	智能决策支持系统相关新技术的发展	320
8.1	数据仓库	320
8.1.1	数据仓库产生的背景	320
8.1.2	数据仓库的概念	320
8.1.3	数据仓库的特征	321
8.1.4	数据仓库与传统数据库比较	322
8.1.5	数据仓库系统	322
8.1.6	数据仓库系统的结构	325
8.1.7	元数据	326
8.1.8	数据仓库的设计	326
8.1.9	OLAP	327
8.2	数据挖掘	330
8.2.1	知识发现和数据挖掘概述	330
8.2.2	数据挖掘的功能	331
8.2.3	数据挖掘常用技术	332
8.3	结合数据仓库、OLAP 和数据挖掘的 IDSS	335
8.3.1	结合数据仓库、OLAP 和数据挖掘的 IDSS 的体系结构	335
8.3.2	商业智能 IDSS	338
8.4	基于 Agent 的智能决策支持系统	342
8.4.1	Agent 概述	343

8.4.2	Agent 的类型	344
8.4.3	基于 Agent 的决策支持系统设计方法	347
8.4.4	基于 Agent 的决策支持系统框架结构	348
8.4.5	基于多 Agent 的分布式群体决策支持系统	349
8.4.6	基于 Agent 技术的模型表示及其管理方法	350
8.4.7	IDSS 中 Agent 的机器学习和知识发现	351
8.5	基于地理信息系统的 IDSS	353
8.5.1	基于地理信息系统的 IDSS 概念的提出	353
8.5.2	基于地理信息系统的 IDSS 的关键技术	354
8.5.3	基于地理信息系统的 IDSS 的结构框架	364
8.6	IDSS 中的新理论与新技术	366
8.6.1	熵理论及其应用	366
8.6.2	证据理论	371
8.6.3	不确定性推理方法在模型管理系统中的应用	373
8.6.4	定性推理及其在 IDSS 中的应用	374
	参考文献	380

第 1 章 绪 论

1.1 机器学习发展史

1.1.1 引言

人类自古以来就有着用机器代替人脑劳动的幻想。为了实现人类这一美好的愿望,科学家们为之付出了艰辛而不懈的努力。随着信息社会和知识经济时代的来临,学习已经成为大家谈论最多的话题之一。学习无疑是人类智能的主要标志和获得知识的基本手段。然而在信息社会,人类面对海量的信息,仅靠人脑表现出来的自然智能是远远不够的。人类迫切需要用机器去放大和延伸自己的智能,实现脑力劳动的自动化。学习能力是人工智能研究上最突出和最重要的一个方面。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:“一台计算机如果不会学习,就不能称之为具有智能。”

由于机器学习是机器具有智能的重要标志,同时也是机器获得知识的根本途径,使得机器学习在机器智能中占有重要地位。自 20 世纪 80 年代以来,机器学习作为继专家系统之后人工智能应用的又一重要的研究领域,在人工智能界引起了广泛的关注,它已成为人工智能的重要课题之一。

关于机器学习的定义有很多种。由于学习是一种综合的心理活动,它与记忆、思维、知觉、感觉等多种心理活动密切相关,人们目前尚未完全清楚其机理,而且学习是一种具有多侧面的实践活动,使得人们很难把握它的本质。因此,什么是学习,至今还没有一个统一的定义。不同领域的研究者分别从不同的学科角度对学习给出了不同的解释,提出了不同的观点。目前被普遍接受的说法是 Simon 对学习的阐述:“如果一个系统能够通过执行某种过程而改进它自身的性能,这就是学习”。这一阐述包含这样三个要点:

1) 学习是一个过程,这是很自然的。

2) 学习是对一个系统而言的,这个系统可以是简单的,一个人或一台机器;也可以是相当复杂的,一个计算机系统,甚至是包括人在内的人机计算系统。显然如果此系统为人,即为我们通常所指的人的学习。在本书中,我们将此系统设定为计算机系统或与计算机系统密切相关的人机系统上。

3) 学习能够改进系统性能。

在 Simon 的阐述中,过程、系统与改进性能这三个学习的要点是宽泛的,对计算机科学家来说,这是远远不够的。

从计算机科学的角度来看机器学习,我们认为可以分为工程的观点和科学的观点。工程的观点认为机器学习是人类学习的计算机实现;科学的观点认为机器学习是人类学习的计算机模拟。这两种观点的区别主要在于,实现是指完成相同的功能,模拟是指把握相同的原理。由于目前人类对自身的思维规律和学习奥秘仍然知之甚少,所以要达到人类学习的计算机模拟还不太现实。目前,人工智能界的主流观点倾向于工程的观点。计算机科学家们主要关注不同系统实现机器学习的过程以及性能改进的效果。

机器学习的目标及研究工作主要包括:①面向任务的研究:研究和分析改进一组预定任务的执行性能的学习系统;②认知模拟:研究人类学习过程并进行计算机模拟,由此建造高性能的计算机系统;③理论性分析:从理论上探索各种可能的学习方法和独立于应用领域的算法,加强机器学习的理论背景研究,规范机器学习的技术、方法和理论。

机器学习已经成为一门新的边缘学科,它与认知科学、神经心理学、逻辑学、教育学和哲学等学科都有着密切的联系,并对人工智能的其他分支,例如专家系统、自然语言理解、自动推理、智能机器人、计算机视觉、计算机听觉等方面,都起到重要的推动作用。因此,机器学习必将具有十分广泛的应用前景。

机器学习是人工智能研究较为年轻的分支。回顾它的发展历程,可以划分为不同的阶段。如何划分这些阶段,有不同的方法。例如,可以按照机器学习的研究途径和目标,将其划分为神经元模型研究、符号概念获取、知识强化学习、连接学习和混合型学习四个阶段;也可以按照机器学习的发展过程,将其分为热烈时期、冷静时期、复兴时期和蓬勃发展时期。下面我们按照后一种划分方法将其分为四个时期。

1.1.2 热烈时期

这一阶段是在 20 世纪 50 年代中叶到 20 世纪 60 年代中叶。在这个时期,所研究的是“没有知识”的学习,即“无知”学习,它的主要研究目标是研制各类自组织和自适应系统。例如,如果给系统一组刺激、一个反馈源、以及修改它们自身组织的足够自由度,那么它们将改变自身成为最优的组织,即它们能够修改自身以适应它们的环境。这类系统主要采用的研究方法是不断修改系统的控制参数以改进系统的执行能力,不涉及面向具体问题的知识。

这一阶段研究的理论基础是早在 20 世纪 40 年代就开始的神经网络模型。有的学者将机器学习的起点定为 1943 年,McCulloch 与 Pitts 对神经元模型(简称为 MP 模型)的研究。他们的研究的历史意义是在科学发展进程中,首次发现了人类神经元的工作方式,并给出了这种工作方式的数学描述。这项研究在科学史上的意义是非同寻常的,它第一次揭示了人类神经系统的工作方式;对近代信息技术发展的影响也是巨大的,计算机科学与控制理论均从这项研究中受到了启发。由于

Pitts 的努力,使得这项研究结论没有仅仅停留在生物学的结果上,他为神经元的工作方式建立了数学模型,正是这个数学模型深刻地影响了机器学习的研究。

电子计算机的产生和发展,使得机器学习的实现成为可能。各种神经计算机的模拟被研制和检测,其中 Rosenblatt 的感知机最为著名,它由阈值性神经元组成,试图模拟人脑的感知及学习能力。遗憾的是,大多数希望产生某些复杂智能系统的企图都失败了。不过,这一阶段的研究导致了模式识别这门新学科的诞生,并且同时形成了机器学习的两种重要方法,即判别函数法和进化学习。著名的 Samuel 下棋程序就是使用判别函数法的典型代表。该程序具有一定的自学习、自组织、自适应能力,能够根据下棋时的实际情况决定走步策略,并且从经验中学习,不断地调整棋盘局势评估函数,在不断的对弈中提高自己的棋艺。4年后,这个程序战胜了设计者本人。又过了3年,这个程序战胜了美国一个保持8年之久的常胜不败的冠军。不过,这种脱离知识的感知型学习系统具有很大的局限性。无论是神经模型、进化学习还是判别函数法,所取得的学习结果都是很有限的,它们远远不能满足人类对机器学习系统的期望。

在这一阶段,我国研制了数字识别学习机。

1.1.3 冷静时期

这一阶段是在20世纪60年代中叶到20世纪70年代中叶。这一阶段的主要研究目标是模拟人类的概念学习过程。机器的内部表示采用逻辑结构或图结构,机器采用符号来表示概念,又称符号概念获取,并提出关于所学概念的各种假设。

在此阶段,研究者意识到学习是复杂而困难的过程,因此人们不能期望学习系统可以从没有任何知识的环境中开始,学习到高深而有价值的概念。这种观点使得研究人员一方面深入探讨简单的学习问题,另一方面则把大量的领域专家知识加入到学习系统中。

这一阶段有代表性的工作有 P. H. Winston 的结构学习系统和 Hayes-Roth 等人的基于逻辑的归纳学习系统。1970年,P. H. Winston 建立了一个从例子中进行概念学习的系统,它可以学会积木世界中一系列概念的结构描述。尽管这类学习系统取得了较大的成功,但是所学到的概念都是单一概念,并且大部分都处于理论研究和建立实验模型阶段。除此之外,神经网络学习机因理论缺陷未能达到预期效果而转入低潮。因此,那些曾经对机器学习的发展抱有极大希望的人们感到很失望。人们又称这个时期为机器学习的“黑暗时期”。

这一阶段正是我国的“文化大革命”时期,对机器学习的研究也不可能有实质性的进展。

1.1.4 复兴时期

这一阶段是在20世纪70年代中叶到20世纪80年代中叶。这一阶段的主要

研究目标仍然是模拟人类的概念学习过程,但是研究者已经从学习单个概念扩展到学习多个概念,探索不同的学习策略和各种学习方法。

机器的学习过程一般都是以大规模的知识库作为背景,实现知识强化学习。值得高兴的是,这一阶段研究者开始将学习系统与各种应用系统结合起来,并获得了极大的成功,在实际应用中发挥了重要作用。同时,专家系统在知识获取方面的需求,也极大地刺激了机器学习的研究和发展。在出现第一个专家学习系统之后,示例归纳学习系统成为研究的主流,自动知识获取成为机器学习应用的研究目标。

1980年,在美国的卡内基-梅隆召开了第一届机器学习国际研讨会,标志着机器学习研究已在全世界兴起。此后,机器学习开始得到了大量的应用。*Strategic Analysis and Information System* 国际杂志连续三期刊登有关机器学习的文章。1984年,由 Simon 等 20 多位人工智能专家共同撰文编写的 *Machine Learning* 文集第二卷出版,国际性杂志 *Machine Learning* 创刊,更加显示出机器学习突飞猛进的发展趋势。这一阶段代表性的工作有 D. J. Mostow 的指导式学习, Lenat 的数学概念发现程序 AM, Langley 的 BACON 程序及其改进程序,它们可以根据经验领域的原始数据发现一些基本的物理学定律和化学定律。其他比较著名的归纳学习方法有 Quinlan 的 ID3 算法, Michalski 的星算法及其概念聚类思想;在基于解释学习系统中,有 G. DeJong 的 Genesis 系统, T. M. Mitchell 的 LEX 系统和 S. Minton 的 Prodigy 系统等;在类比学习中, Winston、Carbonell 和 Gentner 等人也做了许多开拓性的工作。

这一阶段的研究特点主要有三点:

- 1) 基于知识的方法,即首先具备大量初始知识。
- 2) 开发出各种各样的学习方法,包括示教学习、观察和发现学习、类比学习以及解释学习等。
- 3) 结合生成和选择学习任务的能力,应用了启发式信息。

在这一阶段,我国的机器学习也开始有了新的起步。20世纪70年代末,中国科学院自动化研究所进行质谱分析和模式文法推理研究,表明我国的机器学习研究得到了恢复。1980年,Simon 来华传播机器学习的火种后,我国的机器学习研究出现了新的局面。

1.1.5 蓬勃发展时期

这一阶段是机器学习发展的最新阶段。它起始于20世纪80年代中叶。

这一阶段,一方面,神经网络的研究重新兴起。在此前的10多年中,虽然神经元模型研究落入低潮,但仍有一部分学者在潜心研究。在他们不懈地努力下,终于克服了神经元模型的局限性,提出了多层网络的学习算法,再加上 VLSI 技术、超导技术、生物技术、光学技术等的发展与支持,神经网络研究又在一个新的起点上再度兴起,从而使机器学习进入连接机制学习的阶段。目前对连接机制

(connectionism)学习方法的研究方兴未艾,机器学习的研究已在全世界范围内出现新的高潮,对机器学习的基本理论和综合系统的研究得到了加强和发展。

另一方面,实验研究和应用研究受到前所未有的重视。随着计算机技术和人工智能技术的迅猛发展,机器学习有了新的更有力、更有效的研究手段和研究环境。例如,这一阶段的符号学习由“无知”学习转向有专门领域知识的增长型学习,因而出现了具有一定领域知识的分析学习。

在连接机制学习重新兴起的的同时,传统的符号学习研究也取得了很大的进展。实际上,连接机制学习和符号学习各有所长,并具有很大的互补性。因此,把符号学习和连接机制学习结合起来的混合型学习系统研究已成为一个新的热点,如果能够把这两种不同的学习机制有机地融合在一起,就可以在一定程度上有机地模拟人类的逻辑思维和直觉思维,这将是人工智能领域的一个重大突破。目前,研究者已经提出了一些混合方法,这些方法的基本思路是将符号学习所学到的不完善的领域知识按照一定的转化规则构成一个神经网络,然后再利用连接机制继续学习。

从国内外的研究现状来看,将两者结合,无论是理论研究还是实际应用都有着广阔的发展前景。例如基于生物发育进化论的进化学习系统和遗传算法,吸收了归纳学习与连接机制学习的长处而受到重视。基于行为主义(activism)的强化学习系统因发展新算法和应用连接机制学习遗传算法的新成就而显示新的生命力。这一阶段代表性的工作有 D. E. Rumelhart 的 BP 模型(此模型对 XOR 问题的解决激发了感知机研究的再生,给整个人工智能领域带来了极大的冲击), J. J. Hopfield 的 Hopfield 模型, T. Kohonen 的 Kohonen 模型, Holland 的遗传算法, Laird 等的经验学习系统 SOAR, Michalski Hong 的示例学习系统 A Q 15, Watkins 的 Q-算法, Sutton 的加强学习 TD 算法, Vapnik 的统计机器学习, Lamma E 等的多策略学习方法等。

这一阶段机器学习具有以下显著特点:

1) 机器学习已成为新的边缘学科,许多高校已将机器学习作为一门课程。它综合应用了心理学、生物学和神经生理学以及数学、自动化和计算机科学形成机器学习理论基础。

2) 开发出各种各样的学习方法,各种学习方法的应用范围不断扩大,相当一部分已形成商品。归纳学习的知识获取工具已在诊断分类专家系统中广泛使用。连接学习在语音识别和图像识别中占有优势。分析学习已用于设计综合型专家系统。遗传算法与强化学习在工程控制中有着较好的应用。与符号系统耦合的神经网络连接学习在企业的智能管理与智能机器人运动规划中发挥作用。

3) 结合各种学习方法,将多种学习方法综合集成的系统研究正在兴起。尤其是连接学习和符号学习的耦合,可以更好地解决连续性信号处理中知识和技能的获取与求精问题,因而受到重视。

4) 机器学习与人工智能各种基础问题的统一性观点正在形成。

5) 与机器学习的有关学术活动空前活跃。世界上每年都要召开机器学习的研讨会,还有计算学习理论会议、神经网络大会以及遗传算法会议。近十多年来,我国的机器学习研究开始稳步发展和逐步繁荣。每两年举办一次全国性的机器学习研讨会,学术讨论和科技开发蔚然成风。

目前,机器学习的研究已不仅是人工智能领域的重要问题,而且它已经成为计算机科学的核心问题,并提出几个迫切需要解决的问题:①计算的个性化,即对个人需求适应的计算。它涉及许多复杂的问题,它必须解决计算机对用户需求的适应计算问题。这种适应性计算是建立在指令空间还是建立在情感空间将产生两类完全不同的计算系统。②由于机器学习中的许多算法受启于认知心理学与神经生理学等非精确科学,这些算法或多或少地存在随意性,理论描述较为缺乏。使用更精确的数学方法深入地研究机器学习中的理论问题,已是当务之急。③对结构化和非结构化海量数据的理解,即所发展的机器学习算法必须能够解决海量数据的理解问题,这是开展机器学习研究和评价研究结果的重要条件。

1.2 机器学习研究基础

1.2.1 机器学习的一个实例

在开始研究机器学习之前,我们先来看一个机器学习的实例。我们先给一个机器学习的非形式化的定义:如果一个计算机程序面向某类任务 T ,用性能指标 P 来衡量,根据经验 E 来自我完善,那么我们就称这个计算机程序在从经验 E 中学习,针对任务 T ,它的性能用 P 来衡量。

下面我们来看一个学习西洋跳棋的计算机程序。这个程序是通过不断地和自己下棋,获取经验,从经验中学习,不断地提高自己的下棋水平,最终达到程序设计者事先无法估计的下棋水平。为了更清晰地说明问题,通常要明确地指出一个学习问题的三个基本特征:任务的种类 T ,衡量任务提高的标准 P ,经验 E 的来源。对于此例,采用下面的表示方式。

西洋跳棋学习问题:

- 1) 任务 T :下西洋跳棋;
- 2) 性能标准 P :对弈中击败对手的百分比;
- 3) 训练经验 E :和自己进行对弈。

这里对学习的定义是个非常宽泛的定义。机器学习并不是要研究“学习”这个词的含义,而是要精确定义这样一类问题,理解这类问题的基本结构和过程,探索解决这类问题的最优策略和方法。下面我们从机器学习的基本模型、主要策略和算法基础几个方面来探讨机器学习。

1.2.2 机器学习的基本模型

Simon 对学习的阐述只是对机器学习的一个一般性的概述,只是一种理念。根据 Simon 对学习的阐述,我们可以得出,一个学习系统应该满足这样一些基本的要求。

1. 具有合适的学习环境

这里所说的学习环境,是指学习系统进行学习时的信息来源。如果把学习系统类比为学生的话,那么学习环境则是为学生提供信息的教师、书本以及各种实验、实验条件等。毫无疑问,没有学习环境,学生就不可能学习到新的知识以及运用所学到的知识来解决问题。

2. 具有一定的学习能力

学习环境为学习系统提供了相应的信息和基础,学习系统还必须具备一定的学习能力和适当的学习方法,否则也学不到知识或者不会有好的学习效果。正如在同样的学习环境中,不同的学生,他们的学习能力和学习方法不同,他们的学习效果也往往大相径庭。

3. 能够运用所学到的知识来求解决问题

学习系统之所以有意义有价值,是在于可以学以致用。和人类学习一样,一个学习系统如果不能将所学到的知识用于实际问题的解决,那么学习也就失去了其最重要的作用和意义。学习系统应该能够将所学到的信息用于未来的估计、分类、决策和控制,以便改进系统的性能。

4. 通过学习提高自身的性能

在 Simon 的阐述中,改进系统性能是学习的三个要点之一。一个学习系统应该能够通过学习增长知识,提高技能,改进性能,使自己能够做一些原来无法做到的事,或者可以将原先能做到的事做得更好。

通过以上分析,可以得出一个学习系统至少应该包括这样四个重要环节:环境、学习单元、知识库和执行单元,它们之间的关系如图 1-1 所示。




图 1-1 机器学习的基本模型

图 1-1 中给出学习系统的基本模型,它由四个部分组成。其中环境是向系统提供信息,它可以是系统的工作对象,也可以是工作对象或客体所处的外界条件。环

境是影响学习系统设计的一个非常重要的因素,或者更严格地说,环境所提供信息的水平和质量是影响学习系统设计的一个非常重要的因素。所谓信息的水平是指信息的普遍化程度,或者说是指信息适用范围的广泛度。环境所提供的信息无论是高水平的还是低水平的,它们与执行单元所需要的信息往往都是有差距的,学习单元就是要缩小这种差距。高水平信息的普遍化程度较高,其适应范围较广,这时,学习系统通常要补充遗漏的细节,以便执行单元将其用于更具体的情况。相反,低水平信息的普遍化程度较低,其适应范围较窄,只适应个别问题,例如环境向学习系统提供的是杂乱无章的、指导执行具体动作的具体信息,则学习系统需要在获得足够的信息之后,删去其不必要的细节,然后再进行总结推广,形成指导动作的一般规则。这样学习单元的任务就比较重,设计起来自然就较为困难。信息的质量是指信息的正确性以及组织上的合理性。知识库中存放的是指导执行单元动作的一般规则,但环境向学习系统提供的信息却是多样的。如果信息的质量较高,与一般规则的差别较小,则学习单元比较容易处理,如果信息的质量比较低,例如向学习系统提供的示例有干扰,或者示例的次序不合理,则学习单元就很难对其进行归纳。

知识库是影响学习系统设计的第二个重要的因素。如何进行有效的知识表示一直是人工智能领域中一个重要的研究方向。知识库的形式与知识的表示直接相关。知识的表示方法有很多种,常用的有特征向量、谓词逻辑、产生式规则、语义网络和框架等。在选择知识表示的方法时主要考虑这样四个方面:表达能力要强、易于推理、易于修改知识库以及知识表示易于扩充。一个知识库,其初始知识是非常重要的。一个学习系统不能在完全没有知识的情况下,凭空获取知识,它总是在具有一定知识的基础上,根据环境所提供的信息,理解、分析和比较,作出假设,检验并修改这些假设。因此,学习系统实质是对现有的知识进行扩展和改进。

执行单元是整个学习系统的核心。学习单元的目的是改善执行单元的动作。执行单元的反馈作用又会反过来影响学习单元。与执行单元相关的问题有任务的复杂性、反馈和透明性。不同的学习任务的复杂性不同,其所需要的知识也不同。复杂的任务比简单的任务需要更多的知识。所有的学习系统都必须要有从执行单元到学习单元的反馈信息,即以某种方式评价学习单元所提出的假设。这种反馈信息是根据执行单元的执行情况对学习单元所提出的假设进行评价。学习单元根据这些反馈信息决定是否还需要从环境中进一步获取信息,以修改、完善知识库中的知识。有些系统是由自身自动进行评价,这些系统有一部分独立的知识专门进行这种评价,例如 AM 系统就有很多探索规则来评价学习单元所提出新假设的意义。更多的系统是由人来协助完成评价的。这种系统是由教师提出外部执行标准,然后观察执行单元相对于这个标准的执行情况,再将执行的结果反馈给学习单元。透明性是指系统执行单元的动作效果是否可以很容易地对知识库的规则进行评价。例如下完一盘棋之后,从最终输赢总的效果来判断所走的每一步的优劣是困难的,但是如果记录了每一步之后的局势,从局势判断每一步的优劣,则是比较直观和容易

的。显然,执行单元的透明性越高越好。

1.2.3 机器学习的主要策略

正如人类有各种各样的学习策略,机器学习也有很多策略。学习是一项复杂的智能活动,学习过程和推理过程是紧密相连的,按照学习中使用的推理的多少,机器学习策略大体可分为五类——机械学习、传授学习、演绎学习、归纳学习、类比学习。机器学习中所使用的推理越多,系统的学习能力就越强。

1. 机械学习(ro te learning)

机械学习是一种最基本的学习策略。这种学习策略就是记忆,不需要任何推理过程,也就是死记硬背式的学习。它把环境提供的知识存储起来,外界输入知识的表示方式与系统内部表示方式完全一致,不需做任何处理和转换,以后所做的工作只是检索,不需要任何计算和推理。

机械学习在方法上看起来十分简单,由于没有推理,它没有足够的能力独立完成智能学习,但是由于计算机的存储容量相当巨大,检索速度又非常快,而且记忆精确,所以也能产生令人难以预料的效果。并且机械学习对任何学习系统来说,都是十分重要的部分。任何学习系统都必须记住它们获取的知识,以备将来使用。Samul的下棋程序就是采用了这种机械学习策略。为了评价棋局的优劣,他给每个棋局都打了分,对自己有利的分数高,对自己不利的分数低,走棋的时候尽量选择导致高分棋局的走步。这个程序可记忆 53 000 多个棋局以及分值,并能在对弈中不断地修改这些分值来提高自己的棋艺。

机械学习的过程是这样的:当机械学习系统的执行单元解决好一个问题后,系统就会记住这个问题和它的解。当以后再遇到此类问题时,系统就不必重新进行计算,只要直接找出原来的解去使用。如果我们将学习系统的执行单元抽象成一个函数 f ,将由环境得到的输入模式记为 (X_1, X_2, \dots, X_n) ,由该输入模式经 f 计算后得到输出模式记为 (Y_1, Y_2, \dots, Y_n) 。机械学习就是要将这一输入输出模式对 $[(X_1, X_2, \dots, X_n), (Y_1, Y_2, \dots, Y_n)]$ 存储到知识库中。机械学习简单的工作模型如图 1-2 所示。




图 1-2 简单的机械学习模型

机械学习非常适用于一些环境相对稳定,输入输出模式相对固定的系统中。例如以医生看病为例,一个有经验的医生,在长期的医疗实践中,从大量的病例中归结出许多诊断经验。如果我们将医生的每一条经验作为一个输入输出模式(对)存储起来,那么当医生遇到一个新病人时,首先可以根据其症状,查找知识库,直接利用已归纳出的诊断经验,而不必每次遇到一个病人都要再去重新归结经验。

Lenat, Hayes-Roth 和 Klahr 等人在 1979 年提出可以将机械学习看成是数据化简分级中的最底层。数据化简的目的就是把初始信息转变为可执行的信息。在机械学习中我们只记忆计算的输入输出,忽略了计算过程,这样就把计算问题简化成存取问题。数据化简级别如图 1-3 所示。



图 1-3 数据化简级别图

正如图 1-3 所示,计算可以简化为存取,其他的推理过程也可以简化为较简单的任务。例如推导可以简化为计算。如果我们要求解一个一元二次方程。第一次求解时,我们需要花费较长的时间进行推导得出方程的求根公式。但是一旦有了求根公式,以后再需要求解一元二次方程时,只需要直接使用求根公式就可以得出方程解,这就将推导问题化简为计算。同样归纳问题也可以化简为推导。例如医生看病。医生在大量的病例基础上归纳总结出诊断经验,当遇到一个新的病例时,就可以直接根据已归纳出的诊断经验去处理它,而不必再从以前众多的病例中归纳诊断办法。由此可见,化简的目的就是为了提高效率。

机械学习实际上是一种用存储空间来换取处理时间的方法。机械学习的设计要考虑如下三个问题:

(1) 存储结构

对于一个问题,只有当它的检索时间小于重新计算的时间,机械学习才有价值,而且检索时间越快,机械学习越有效。因而,如何有效地缩短检索时间是机械学习的一个重要问题。在数据结构与数据库领域,为提高检索速度,人们研究出许多卓有成效的数据存储方式,例如索引、排序、杂凑等。采用适当的存储结构,以及相应的检索方法就可以有效地缩短检索时间。

(2) 环境的稳定性和存储信息的适用性

机械学习的方法适合于环境相对稳定的系统,因为机械学习的一个重要假设是在某一时刻存储的信息必须适用于以后的情况。因此在环境急剧变化的系统中,这个假设就被破坏了,机械学习策略就不再适用了。例如在决定汽车修理费用的汽车保险程序中,20年前收集的有关汽车特征和修理费用的情况,20年后就很少适用了。这20年间,汽车的生产成本,货币的价值,还有保险政策都发生很大的变化,因此查询出来的修理费用也就不再适用了。当然此系统中如果使用的均是短期内收集的信息,机械学习的策略仍然是适用的。

(3) 存储和计算的平衡

机械学习的根本目的是改进系统的性能,因此很重要的一点是机械学习不能

降低系统的效率。如果检索一个项目的超出了重新计算所需要的时间,那么学习就失去了意义。平衡存储和计算通常有两种方法。一种是先估算一下存储信息所花费的存储空间以及检索信息所花费的时间,然后将其与重新计算所花费的代价比较,再决定存储信息是否有利。另一种方法是先将信息存储起来,但为了保证足够的存储速度,限定一定的存储容量,系统只保留那些经常使用的信息,删去那些不常用的信息。这种方法也称“选择遗忘”。

2. 传授学习

比机械学习复杂一点的学习是传授学习策略。传授学习也称指导式学习(learning by being told)或示教学习。对于使用传授学习策略的系统来说,外界输入知识的表达方式与内部表达方式不完全一致,系统在接受外部知识时需要一点翻译、转化和推理。例如,在物流配送中,配送人员会被告知一些路线以及像“尽量选择最短路径”之类的这样的建议,从而配送人员学会有效的物流配送。这种学习策略的特点在于:由于建议是非操作性的,不能被直接执行,因此传授学习的核心问题是如何把外部环境提供的、不能直接操作的信息转化为可操作的知识。将信息可操作的过程也称为操作化。操作化把任务领域的知识转化成用来完成任务的过程。在学习过程中,系统需要不断地对所形成的知识反复进行评价,使其不断完善。

一般来说,传授学习的学习过程通过以下步骤完成:

(1) 请求

传授学习的第一步是向指导者请求提出建议。请求方式可以是简单的(只要求指导者给出一般性的建议),也可以是很复杂的(要求指导者找出知识库中存在的问题,并给出修改办法),可以是主动的(主动地提出询问,将指导者的注意力引导到特定问题上),也可以是被动的(被动地等待指导者提供建议)。

(2) 解释

这一步是接受建议并将其转化为内部表示形式。为了让系统能够接受建议,系统必须有该建议的机器可识别的内部表示,即能表达该建议又不能失去任何有价值的信息。显然,如果指导者的建议是使用不加限制的自然语言,则系统的识别是相对困难的。如果指导者的建议是用一种受限制的语言描述的,则系统的识别就会容易一些。语言受限制越多,系统识别就越容易,但对指导者的要求就越高。

(3) 操作化

这一步是将解释后的建议转换成具体的知识。尽管在上一步中,指导者的建议已经被系统接受并转化成内部表示,它仍可能是不能被操作的,因为指导者的建议通常是抽象的、一般性的建议,而执行单元所要求的是能够指导具体动作的规则。操作化就是将指导者的建议转化成执行单元所要求的规则。

(4) 归并

这一步是将新知识归并到知识库中。把知识添加到知识库中时,必须考虑加入

该知识是否合适。当知识库中增加新的知识时,通常会引引起两种问题,一种是重叠使用问题,一种是结论冲突问题。

所谓重叠使用问题,是指加入新规则时,如果新规则的条件部分比其他规则更具一般性,则会造成使用其他规则的场所也适用这条新规则。解决这个问题的方法有两种,一种是使规则特殊化,一种是元规则法。

所谓结论冲突问题,是指有时同一条件下,会有不止一条适用的规则,这些规则的结论部分推荐了互不相容的动作。解决这个问题的方法有两种,一种是修改规则的结论以消除矛盾,一种是利用元规则排序,以确定应该优先使用哪一条规则。

(5) 评价

传授学习从指导者那里得到建议,经解释、操作化、归并后可能会在知识库中产生某些问题,因此必须对新知识进行评价。学习系统可以通过检查来识别新知识加入到知识库中,是否会引起矛盾。常用的方法还有让系统使用这些新知识来执行某些任务,然后观察其是否能正常执行。

3. 演绎学习

演绎学习(deductive learning)是指以演绎推理为基础的学习。

演绎推理是从已知的一般性知识出发,推出蕴含在这些已知知识中的适合于某些个别情况的结论。它是一种由一般到个别的推理方法,其核心是三段论,常用的三段论是由一个大前提、一个小前提和一个结论三部分组成的。其中,大前提是已知的一般性知识或推理过程得到的判断;小前提是关于某种具体情况或具体实例的判断;结论是由大前提推出的,并且适合于小前提的判断。

例如,有下面三个判断:①鸟儿都会飞;②大雁是鸟;③大雁会飞。

这是一个三段论推理。其中,①是大前提,②是小前提,③是结论。从这个例子中,可以看到,“大雁会飞”蕴含在“鸟儿都会飞”这个大前提中。演绎推理就是从已知的大前提中推导出适应于小前提的结论,即从已知的一般性知识中抽取所包含的特殊性知识。由此可见,只要大前提和小前提是正确的,则由它们推出的结论也必然是正确的。

在演绎学习中,学习系统由给定的知识进行演绎的保真推理,并存储有用的结论。

4. 归纳学习

归纳学习(inductive learning)是指以归纳推理为基础的学习,它是从某个概念的一系列正例和反例中归纳出一个一般的概念描述。根据学习过程有无导师,归纳学习可分为有导师学习和无导师学习。

有导师学习又称为示例学习(learning from example)。它给学习者提供一组正例和反例,学习者归纳出一个总的概念描述,使其覆盖所有正例,排除所有反例。

由于导师没有提供总的概念,也没有与新概念类似的旧概念,因此推理量较多。

根据学习中可用例子的类型,示例学习可以分为:

(1) 仅用正例的示例学习

这种学习方法会使推出的概念外延扩大化。这时可以依靠预先了解的领域知识对推导出的概念加以限制。

(2) 利用正例和反例的示例学习

这是示例学习的典型方式。它用正例来产生概念,用反例来防止概念外延的扩大化。

无导师学习又称为观察与发现学习(learning from observation and discovery)。它通过由环境提供的观察来进行学习,并且这些观察是未经指导者分类的例子。观察与发现学习不需要为学习者提供特定概念的示例,也不需要提供如何将内部产生的例子归类到某一概念的正例或反例的途径。因此,同其他学习方法相比,它需要学习者进行更多的推理。

根据学习者与环境相互作用的程度,观察与发现学习可以分为:

(1) 被动观察学习

这种学习方法,学习者需要把从环境中得到的多方面的观察现象进行分类。

(2) 主动实验学习

这种学习方法需要学习者主动变动一下学习环境,观察其变动情况,然后根据一般规律动态地收集经验,或者在理论的指导下推导出经验。

5. 类比学习

类比学习(learning by analogy)是一种利用相似性来认识新事物的学习方式,其基础是类比推理。类比推理是人们常用的一种推理方式。它是指根据一个已知事物,通过类比去解决另一个未知事物的推理过程,即当一个新的事物和另一个已知事物在某些方面相似时,可以推出这个新的事物和已知事物在其他方面也相似。类比推理的基础是相似性。

类比学习也可以看成是演绎学习与归纳学习的组合。类比学习系统只能得到完成类似任务的有关知识。因此,类比学习系统必须能够发现当前任务与已知任务的相似之处,由此制定出完成当前任务的方案,显然这种学习策略需要更多的推理。

类比学习的一个基本假设是人们每遇到一个新问题时,都会联想起一些以前遇到过的问题,这些问题和新问题的抽象级别虽然不一定相同,但它们具有一定程度上的相似性,因此人们希望以前的解决方案也能适用于新的问题。

类比学习利用相似性从已知的某一领域知识得到另一领域中相似知识的学习方法。它首先匹配不同论域的描述,确定公共子结构,然后再以此公共子结构为基础进行类比映射。其中寻找公共子结构是归纳推理,而实现类比映射则是演绎

推理。

类比学习的学习过程可用以下步骤来描述：

(1) 联想搜索匹配

对一个给定的新事物,根据该事物的描述提取其特征,并用这些特征去搜索一个与之相似的已知事物,并对此已知事物进行匹配。

(2) 检验相似程度

判断已知事物的条件与新事物的相似度,以检验类比的可行性。如果它们的相似度达到了有关的阈值,则说明类比匹配成功。

(3) 修正变换求解

为了把匹配成功的已知事物用于新事物,一般需要对已知事物的有关知识进行适当地修正或变换,即类比映射,以导出适合于新事物的解。

(4) 更新知识库

当新事物的解求出以后,应将此新事物及其解一同并入知识库。

6. 解释学习(explanation-based learning, EBL)

学生根据教师提供的目标概念以及此概念的一个例子、领域理论和操作准则,首先构造一个解释来说明该例子满足目标概念,然后将解释推广为目标概念的一个满足可操作准则的充分条件。和类比学习相反,解释学习第一步是演绎,第二步是概括,并用领域知识指导概括,增强结果的可信度。EBL 已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 T. Mitchell 的 LEXII 和 LEAP, G. DeJong 的 GENESIS, 以及 S. Minton 等的 PRODIGY。

1.2.4 机器学习的算法基础

虽然对人类学习机制的概括可以引入到机器学习之中,但仅仅如此是不够的,机器学习必须考虑到计算机自身的特点。任何一个智能过程,在计算机科学领域中都必须转化为机器可执行的算法。因此,研究机器学习的算法就是必不可少的。一个机器学习的问题通常可以归结为搜索问题,而机器学习算法的本质就是寻找一个最优解,也就是说是一种优化算法。这种优化算法既可以用代数的方法来刻画,也可以用几何的方法来刻画,如果采用几何的方法,这种优化算法将需要考虑空间划分的问题。

由于被学习的对象结构的不同,机器学习可以分为结构化机器学习与非结构化机器学习。如果被学习的对象结构清晰,可以将其对象集合用关系数据库形式表示,称这种基于对象集合的机器学习为结构化机器学习,除此之外则通称为非结构化机器学习。

结构化机器学习又可根据对象的数学性质不同,进一步分类为统计机器学习与符号机器学习,尽管它们所使用的数学基函数、搜索策略和搜索目标不完全相

同,但都可以理解为一种优化算法。对于非结构化机器学习的研究目前尚不成熟,寻找其优化算法也十分困难。

下面我们从数学基函数、搜索策略与目标函数几个要素来讨论机器学习的问题。

1. 表示(数学基函数)和知识表示(模型)

尽管很多人将表示和知识表示理解为同一概念,但实际上,表示和知识表示是两个完全不同的概念。表示是一个数学基函数,而知识表示是指在这个数学基函数意义下的一个模型,通俗地说,就是数学基函数的系数有一固定的取值。例如:对于一函数 $y = f(cx)$,如果系数 c 是待定的,在优化理论中,它就是一个数学基函数。在机器学习中,它就是表示。如果系数 c 是根据现实世界 U 来确定的,在优化理论中,它就是 U 的模型。在机器学习中,它就是知识表示。这样机器学习就可以看做是在给定的数学基函数条件下,对刻画现实世界的一个对象集合的建模过程。下面是机器学习中经常使用的例子。

BP 机器学习算法的基函数为 $y = f_1(\omega_1 \cdot f_2(\omega_2 \cdot x))$,根据给定的现实世界,使用广义 Delta 规则,求出 ω_1, ω_2 ,就建立了一个模型,这个模型就是一个知识表示。广义 Delta 规则就是机器学习算法。

采用最小二乘法的机器学习算法的基函数形如 $y = \sum a_k x^k$,根据给定的现实世界,使用最小二乘法,求出 $a_k, k = 0, 2, \dots, n$,就建立了一个模型,即知识表示。

采用逻辑运算的机器学习算法的基函数是基于析取范式的,形如 $y = V(\wedge c_n x_n)$ 。使用逻辑运算和集合运算或其他运算求出所有的 c_n ,并经过适当的处理便是一个模型了。

上面给出的知识表示仅仅是语法表示,如果赋予它们不同的语义,则可构成不同的语言。

2. 目标函数和搜索策略

选择一个好的目标函数对于一个机器学习算法是至关重要的。目标函数的选择取决于要学习的知识的确切类型以及执行算法如何使用这些知识。我们仍然以西洋跳棋学习问题为例。

我们从一个对于任何棋局都能产生合法走子的西洋跳棋博弈程序开始。我们期望最终的程序能够学会从这些合法的走子中选择最佳的走子。这个学习任务非常典型,它代表了一类任务:合法的走子定义了一个已知的巨大的搜索空间,但是何为最佳的走子,何为最佳的搜索策略。很多优化问题最终都归结于此。

学习任务就是要从这些合法走子构成的搜索空间中作出选择,由此我们知道,要学习的信息类型就是一个程序或一个函数,它对任何给定的棋局能够选出最好的走法,不妨我们将此函数称为 CHOOSEMOVE,此函数以棋局集合中的棋盘状

态作为输入,以合法走子集合中某个走子作为输出,简记为 $CHOOSEMOVE: B \rightarrow M$ 。如果我们将 $CHOOSEMOVE$ 作为目标函数,很快会发现学习这个目标函数是很困难的,这是因为环境提供给系统的是间接的训练经验。因此,我们转而考虑能否将目标函数定义为一个评估函数,它可以为任何给定的棋局赋予一个数字评分。可以发现,在这个学习任务中,学习这个目标函数更为简单。不妨我们将此函数称为 V ,此函数以棋局集合中的棋盘状态作为输入,以一个实数值作为输出,简记为 $V: B \rightarrow R$ 。对于一个好的棋局,令此目标函数 V 赋予其较高的评分,相反对于一个不利的棋局,令此目标函数 V 赋予其较低的评分。如果学习系统能够成功地学会此目标函数,那么这个系统就能够先产生每一个合法走子的所有后续棋局,然后根据 V 轻松地找到当前棋局的最佳的后续棋局,从而选择当前最佳走子。

到此,我们似乎已经找到了目标函数。然而,稍微仔细一想,对于任意棋局,目标函数 V 的准确值应该是多少呢?当然我们知道任何对较好的棋局赋予较高分数的评估函数都是适用的,但是最终我们要在产生最佳对弈的众多方法中定义一个特定的目标函数 V 。因此,对于棋局集合中的任意棋局状态 b ,采用如下定义的目标函数 $V(b)$:

1) If b 是最终的胜局 then $V(b) = 100$;

2) If b 是最终的败局 then $V(b) = -100$;

3) If b 是最终的和局 then $V(b) = 0$;

4) If b 不是最终的棋局 then $V(b) = V(b')$;其中 b' 是从 b 开始双方都采取最优对弈后可达到的终局。

以上的定义很简单,但由于它的递归性,运算效率很低,这个定义对于这个任务是不可用的,因此这个定义也被称为不可操作的定义。下面的学习任务就是发现一个可操作的目标函数 V 的定义,使它能够被西洋跳棋程序采用,在实际有限的时间内估计棋局并选择下一步的走子。通常要发现这样一个完美的可操作的目标函数 V 是相当困难的。这时,我们通常在理想和可能之间寻求一个折中,也就是说通常我们只能发现一个学习算法尽可能好的目标函数,或者说是次优目标函数,因此学习目标函数的过程常被称为函数逼近。下面为了与理想目标函数 V 相区别,我们使用 V' 来表示次优目标函数。

下面我们就来寻找次优目标函数 V' ,当然方法有很多。可以首先将每个棋局的特征提取出来,系统使用一张大表来保存这些信息,对于每一个惟一的棋盘状态,表中有一条记录,记录了该棋盘的特征和状态值,或者用一个规则集配合棋局特征来表示 V' ,或者用一个与棋盘特征有关的多项式函数来表示,或者使用人工神经网络。具体细节这里不再详述。

当目标函数 V' 的表示形式确定后,下面就是根据从训练经验中导出的训练样本,选择某种方法,调整系数,以求最佳拟合这些训练样本。

在机器学习中通常会根据具体问题设计一个函数,并以这个函数的最大值(或最小值)作为学习的目标,最经常而且最容易在理论上分析与处理的是均方差函数。理论上,机器学习中的搜索策略与优化理论中的搜索策略并没有本质的区别,梯度法是最简单也是最经常使用的方法。由于受到计算复杂度的限制,这种方法对海量数据的学习往往是不现实的,因此,在考虑解空间中一个可接受解的时候,搜索策略是十分必要的。搜索理论是计算机科学的一个重要的研究分支,虽然存在着大量有效的搜索算法,但机器学习中所使用的搜索策略与搜索理论研究还有相当的距离,如何借鉴搜索理论,更多地借用搜索算法以改善机器学习算法的性能,是机器学习研究的一个重要课题。

1.3 计算学习理论

为了从理论上回答机器学习所需要的时间、空间和信息资源的多少,分析学习的可能性和学习效率,许多计算机科学家把计算复杂性、形式语言及统计推断等理论与机器学习结合起来,提出了一些新的学习模型,并由此诞生了新的研究领域——计算学习理论(computational learning theory)。计算学习理论研究主要包括四个方面:学习的收敛性(convergence)、学习的可行性(feasibility)、学习的复杂性(complexity)和学习的近似性(approximation)。

学习的收敛性是指学习算法能否在有限的运行时间内将学习的结果收敛于某一固定、正确的结论。学习的可行性是指学习算法需要多少资源才能收敛于某一固定、正确的结论。学习的复杂性是指按照一定的数学规则,将要学习的知识看成某种概率或逻辑公式的空间,研究这些空间中知识的学习可能性和难学习性,以及研究学习中知识表示的复杂性。其中包括有:

1) 样本复杂性(sample complexity):学习器要收敛到成功假设(以高的概率)需要多少训练样本?

2) 计算复杂性(computational complexity):学习器要收敛到成功假设(以高的概率)需要多大的计算量?

学习的近似性是指学习结论与学习目标之间的近似性。许多机器学习的研究表明,在很多情况下要想在多项式时间内求得精确的学习结论是不可能的。所以常常只要求学习算法很好地近似于目标的结论即可。

最早在计算学习理论方面做出工作的有 Gold (1967)。目前,最有影响的是 Valiant 提出的 PAC (probably approximate correct) 学习模型 (Valiant 1984)。其基本思想是:对于一个未知概念 c ,构造一个学习算法 A ,它以任意的概率分布,选取多项式大小的样本,并从中学得一个假设 h ,使该假设 h 可以以足够大的概率以任意精度(以参数 ϵ 来度量)逼近未知的概念 c 。这种新型的计算学习理论后来得到了迅速地发展。1988 年召开了第一次国际研讨会,1997 年召开了第八次国际会

议。随着近年来的发展,计算学习理论已成为人工智能和理论计算机科学的一个热门的学科。

1.3.1 可能近似正确学习模型(PAC)

本节我们考虑学习问题的一种非常重要的模型,称为可能近似正确学习模型(PAC)。令 X 代表所有实例的集合,目标函数在其上定义。令 C 代表学习器要学习的目标概念集合。 C 中每个目标概念 c 对应于某个子集或一个等效的布尔函数 $c: X \rightarrow \{0,1\}$ 。例如, C 中一个目标函数 c 为概念:“是大学生的人”。若 x 是 c 的正例,则 $c(x)=1$;若 x 为反例,则 $c(x)=0$ 。假定实例按照某概率分布 Ψ 从中随机产生。一般, Ψ 可为任何分布,而且它对学习器是未知的。训练样例的生成按照 Ψ 分布随机抽取实例 x ,然后 x 及其目标值 $c(x)$ 被提供给学习器。

1. 假设的错误率

学习器 L 在学习目标概念时考虑可能假设的集合 H 。在观察了一系列关于目标概念 c 的训练样例后, L 必须从 H 中输出某假设 h ,它是对 c 的估计。我们为了描述假设 h 对真实目标概念的逼近程度,首先要定义假设 h 对应于目标概念 c 和实例分布 Ψ 的真实错误率(true error)。

定义 1.3.1 假设 h 的关于目标概念 c 和分布 Ψ 的真实错误率为 h 误分类,根据 Ψ 随机抽取的实例的概率,则

$$\text{error}_{\Psi}(h) = P_{x \in \Psi} [c(x) \neq h(x)]$$

这里符号 $P_{x \in \Psi}$ 代表在实例分布 Ψ 上的概率。

注意,此错误率紧密地依赖于未知的概率分布 Ψ 。例如,如果 Ψ 是一个均匀的概率分布,它对 X 中每个实例都赋予相同的概率,那么假设的错误率为 h 和 c 不一致的空间在全部实例空间中的比例。然而,如果 Ψ 恰好把 h 和 c 不一致区间中的实例赋予了很高的概率,相同的 h 和 c 将造成更高的错误率。

2. PAC 学习

我们学习的目标是得出这样的目标概念,它们能够从合理数量的随机训练样本中通过合理的计算量可靠地学习到。什么是可学习性呢?一种理想的选择是学习到使其真实错误率为零的假设 h ,所需要的训练样本数。遗憾的是,这样的选择是不可行的。所以,我们采取弱化对学习器要求的方法。首先,我们不要求学习器输出零错误率的假设,而只要求其错误率被限定在某常数 ϵ 的范围内, ϵ 可任意小。其次,不再要求学习器对所有的随机抽取的样例序列都成功,只要求其失败的概率被限定在某个常数 δ 的范围内, δ 也可以任意小。

考虑某一可能的目标概念的类别 C 和使用假设空间 H 的学习器 L 。非形式地说,对 C 中任意目标概念 c ,若在观察到合理数目的训练样例并执行了合理的计算

量后, L 以概率 $(1 - \delta)$ 输出一个 $\text{error}_\Psi(h) < \varepsilon$ 的假设 h , 则我们称概念类别 C 是可以被使用 H 的 L 所 PAC 学习的。更精确的定义如下。

定义 1.3.2 考虑定义在长度为 n 的实例集合 X 上的一概念类别 C , 学习器 L 使用假设空间 H 。当对所有 $c \in C$, X 上的分布 Ψ, ε 满足 $0 < \varepsilon < 1/2$ 以及 δ 满足 $0 < \delta < 1/2$ 时, 学习器 L 将以至少 $1 - \delta$ 的概率输出一假设 $h \in H$, 使 $\text{error}_\Psi(h) \leq \varepsilon$, 这时称 C 是使用 H 的 L 可 PAC 学习的。所使用的时间为 $1/\varepsilon, 1/\delta, n$ 以及 $\text{Size}(c)$ 的多项式函数。

这里的定义要求满足两个条件。首先, L 必须以任意高的概率 $(1 - \delta)$ 输出一个错误率任意低 (ε) 的假设。其次, 学习过程必须是高效的, 其时间最多以多项式方式增长, 多项式中 $1/\varepsilon$ 和 $1/\delta$ 定义了对输出假设要求的强度, n 和 $\text{Size}(c)$ 则定义了实例空间 X 和概念类别 C 中的固有的复杂度。这里, n 为 X 中实例的长度。

3. 一些概念类别的 PAC 可学习性

定理 1.3.1 如果存在一个正整数 K , 使概念类 C 中所有目标概念的 CNF 表示中每个合取式均不含多于 K 个句节(这里每个句节是一个正命题 A 或负命题 $\sim A$), 则 C 是 PAC 可学习的, 并且学习时只需要正例。这个可学习概念类称为 K -CNF 概念类。

以疾病判断为例, 如果每一种疾病都能表示成 CNF 形式, 并且其中每个合取式的长度不超过 K , 则该疾病类是 PAC 可学习的。以 $K = 2$ 为例

(腰痛 \vee 腿痛) \wedge 乏力 \wedge (吐白痰 \vee 吐黄痰)

就是符合上述规定的合取式, 注意 CNF 本身的长度是不受限的。

定理 1.3.2 如果存在一个正整数 K , 使概念类 C 中所有目标概念的 DNF 表示最多只含 K 个析取式, 则 C 是 PAC 可学习的。这个可学习概念类称为 K -DNF 概念类。

定理 1.3.3 k -term DNF 可以通过一个算法 A 来学习, 其中算法 A 调用 $L = L(h, 2kn)$ 次训练样例(Examples)和 L 次神谕(Oracle)。这里 n 是变元数。

证明: 算法 A 先构造一个初始公式 g , g 由 k 项组成, 每一项是集合 $\{x_1, x_1, x_2, x_2, \dots, x_n, x_n\}$ 中的所有文字的合取。 A 调用 L 次 Examples 以提供正例, 每次调用 Examples 并得一个例子 e 之后, A 调用 Oracle 一次, 以决定例子 e 去处理 g 的某一项 t_i 。如果 e 不满足 t_i , 则从 t_i 中删去 e 不满足的那些文字。形式地有

```
begin e := Examples
  if Oracle(e) = i then
    从  $t_i$  删去  $e$  不满足的文字  $l_{ij}$ , 即  $e \not\wedge l_{ij}$ 
end.
```

注意, 为简单起见, 如果例子可以处理两个以上项, Oracle 只选择下标小的项加以处理。根据 Valiant 可学习的定义, 在 $L(h, 2kn)$ 次伯努利实验中, 每次以成功