



中国计算机学会学术著作丛书  
——知识科学系列 6

# 机器学习及其应用 2009

周志华 王珏 主编

清华大学出版社



中国计算机学会学术著作丛书  
——知识科学系列 6

# 机器学习及其应用 2009

周志华 王珏 主编

清华大学出版社  
北京

## 内 容 简 介

机器学习是人工智能的一个核心研究领域,也是近年来计算机科学中最活跃的研究分支之一。目前,机器学习技术不仅在计算机科学的众多领域中大显身手,还成为一些交叉学科的重要支撑技术。本书邀请相关领域的专家撰文,以综述的形式介绍机器学习中一些领域的研究进展。全书共分 10 章,内容涉及正则化、Boosting、聚类分析、因果发现、维数削减、强化学习、迁移学习、流形学习、多示例多标记学习等。

本书可供计算机、自动化及相关专业的研究人员、教师、研究生和工程技术人员参考。

版权所有,侵权必究。侵权举报电话: 010-62782989 13701121933

## 图书在版编目(CIP)数据

机器学习及其应用 2009/周志华,王珏主编. - 北京: 清华大学出版社, 2009. 9  
(中国计算机学会学术著作丛书. 知识科学系列)  
ISBN 978-7-302-20419-0

I. 机… II. ①周… ②王… III. 机器学习 IV. TP181

中国版本图书馆 CIP 数据核字(2009)第 104128 号

责任编辑: 薛 慧

责任校对: 赵丽敏

责任印制: 王秀菊

出版发行: 清华大学出版社 地 址: 北京清华大学学研大厦 A 座

<http://www.tup.com.cn> 邮 编: 100084

社 总 机: 010-62770175 邮 购: 010-62786544

投稿与读者服务: 010-62776969, c-service@tup.tsinghua.edu.cn

质 量 反 馈: 010-62772015, zhiliang@tup.tsinghua.edu.cn

印 刷 者: 北京市清华园胶印厂

装 订 者: 三河市李旗庄少明装订厂

经 销: 全国新华书店

开 本: 185×230 印 张: 15.5 字 数: 333 千字

版 次: 2009 年 9 月第 1 版 印 次: 2009 年 9 月第 1 次印刷

印 数: 1~3000

定 价: 36.00 元

---

本书如存在文字不清、漏印、缺页、倒页、脱页等印装质量问题,请与清华大学出版社出版部联系调换。联系电话: (010)62770177 转 3103 产品编号: 032718-01

# 评审委员会

名誉主任委员：张效祥

主任委员：唐泽圣

副主任委员：陆汝钤

委员：（以姓氏笔画为序）

王 珊 吕 建 李晓明

林惠民 罗军舟 郑纬民

施伯乐 焦金生 谭铁牛

# 序

第一台电子计算机诞生于 20 世纪 40 年代。到目前为止,计算机的发展已远远超出了其创始者的想象。计算机的处理能力越来越强,应用面越来越广,应用领域也从单纯的科学计算渗透到社会生活的方方面面:从工业、国防、医疗、教育、娱乐直至人们的日常生活,计算机的影响可谓无处不在。

计算机之所以能取得上述地位并成为全球最具活力的产业,原因在于其高速的计算能力、庞大的存储能力以及友好灵活的用户界面。而这些新技术及其应用有赖于研究人员多年不懈的努力。学术研究是应用研究的基础,也是技术发展的动力。

自 1992 年起,清华大学出版社与广西科学技术出版社为促进我国计算机科学技术与产业的发展,推动计算机科技著作的出版,设立了“计算机学术著作出版基金”,并将资助出版的著作列为中国计算机学会的学术著作丛书。时至今日,本套丛书已出版学术专著近 50 种,产生了很好的社会影响,有的专著具有很高的学术水平,有的则奠定了一类学术研究的基础。中国计算机学会一直将学术著作的出版作为学会的一项主要工作。本届理事会将秉承这一传统,继续大力支持本套丛书的出版,鼓励科技工作者写出更多的优秀学术著作,多出好书,多出精品,为提高我国的知识创新和技术创新能力,促进计算机科学技术的发展和进步作出更大的贡献。

中国计算机学会

2002 年 6 月 14 日

# 前言

机器学习致力于“利用经验来改善系统自身的性能”。在计算机系统中，“经验”通常是以数据的形式存在的，要利用经验就不可避免地要对数据进行分析，因此，机器学习已逐渐成为计算机数据分析技术的源泉之一。随着人类收集和存储数据能力的不断增长以及计算机运算能力的飞速发展，利用计算机来分析数据的要求越来越广泛，越来越迫切，从而使得机器学习的重要性越来越显著。机器学习不仅是人工智能的核心研究领域之一，目前还成为计算机科学中最活跃、最受关注的领域之一。

2002 年，陆汝钤院士在复旦大学智能信息处理实验室发起组织了“智能信息处理系列研讨会”，并将“机器学习及其应用”列为当年支持的研讨会之一。2002 年 11 月，研讨会成功举行，并确定了会议不征文、不收费、报告人由组织者邀请，以及“学术至上，其他从简”的办会宗旨。2004 年 11 月，在复旦大学举行了第二次“机器学习及其应用”研讨会，两天半的会议一直有 100 余人旁听。2005 年起研讨会由南京大学软件新技术国家重点实验室举办。2005 年 11 月举办的第三届研讨会吸引了来自全国近 10 个省市的 250 余人旁听；2006 年 11 月、2007 年 11 月分别由南京航空航天大学信息科学与技术学院、南京师范大学数学与计算机学院协办了第四届和第五届研讨会，两次均吸引了来自全国 10 余个省市的约 300 人旁听；2008 年 11 月举行的第六届研讨会，适逢南京大学计算机学科建立 50 周年，吸引了来自全国 10 余个省市的 380 余人旁听。值得一提的是，为了促进研究生之间以及研究生与资深学者之间的交流，从 2006 年开始，在研讨会期间举行“机器学习及其应用学生研讨会”，由研究生通过墙展方式介绍自己的工作，到目前为止共举行了三次，吸引了 100~200 人参加。

清华大学出版社对推介信息科学技术领域的研究进展一直抱有极大的热情。早在“第二届机器学习及其应用研讨会”举行时清华大学出版社就参与其中，并为该研讨会专门出版了文集，即 2006 年发行的《机器学习及其应用》一书。2005 年第三届研讨会期间，出版社和与会专家商定，以后每两届研讨会的部分内容将编成一书，以《机器学习及其应用(出版年)》的形式冠名。第三届和第四届研讨会的部分内容已在《机器学习及其应用 2007》一书中出版发行。

本书是清华大学出版社邀请第五届和第六届“机器学习及其应用”研讨会的部分专家将其报告内容总结成文而得的文集。书中每一章将讨论一个论题，以综述的形式对该方面的研究进展加以介绍，并将报告人自己的一些研究工作嵌入其中。书中章节不仅涉及正则

化、Boosting、聚类分析、因果发现、维数削减、强化学习等传统研究领域,还涉及迁移学习、流形学习、多示例多标记学习等新领域,以及图像超分辨率、无线局域网定位、智能交通控制等应用问题。需要注意的是,书中各章的内容仅表达该章作者本人的见解,并不代表清华大学出版社、编者及其他各章作者的学术观点。本书的出版得到了陆汝钤院士的支持和指导,并得到清华大学出版社计算机专著出版基金的资助,在此谨表示衷心的感谢。

编 者

2009 年 5 月

# 目 录

---

机器学习与人工智能	.....	王 玺	1
1 引言	.....		1
2 机器学习与人工智能的不同理念	.....		4
3 统计机器学习的特点	.....		7
4 集群学习(ensemble learning)	.....		9
5 人工智能对机器学习的补充	.....		11
6 重采样方法——自助法	.....		16
7 变量稀疏化	.....		19
8 知识的集群	.....		24
9 讨论和总结	.....		27
参考文献	.....		31
关系强化学习研究	.....	高 阳 王巍巍 陈兴国 葛 岚	33
1 引言	.....		33
2 Tetris 和强化学习解法	.....		34
2.1 Tetris	.....		34
2.2 Tetris 的抽象和建模	.....		35
2.3 Tetris 的强化学习解法	.....		35
2.4 状态空间抽象	.....		36
3 关系强化学习	.....		39
3.1 关系强化学习及其抽象	.....		39
3.2 逻辑决策树方法	.....		40
3.3 马尔可夫逻辑网方法	.....		44
4 结束语	.....		47
参考文献	.....		47
因果挖掘的若干统计方法	.....	耿 直	49
1 引言	.....		49
2 井底之蛙：因果作用与混杂因素	.....		51
3 替罪羔羊：利用替代指标评价因果作用	.....		54
3.1 几种替代指标准则	.....		54

3.2 替代指标悖论 .....	56
3.3 一致替代指标,严格一致替代指标 .....	57
4 盲人摸象:贝叶斯网络的结构学习 .....	60
4.1 贝叶斯网络结构的分解学习方法 .....	63
4.2 贝叶斯网络结构的递归学习方法 .....	67
4.3 贝叶斯网络结构的聚类学习方法 .....	69
5 纲举目张:确定因果网络方向的主动学习方法 .....	70
5.1 各种干预方法 .....	72
5.2 各种算法的模拟比较 .....	74
6 寻根问底+顺藤摸瓜:寻摸结果变量的原因 .....	74
6.1 外部干预下的预测问题 .....	75
6.2 局部因果挖掘的方法 .....	76
7 讨论 .....	78
参考文献 .....	79
<b>基于学习的图像超分辨率算法 .....</b>	<b>林宙辰 81</b>
1 引言 .....	81
2 基于学习的超分辨率算法综述 .....	82
2.1 间接最大后验算法 .....	82
2.2 直接最大后验算法 .....	85
2.3 基于学习的超分辨率算法的优缺点 .....	86
3 基于学习的超分辨率算法的性能极限 .....	87
3.1 什么是基于学习的超分辨率算法的极限 .....	87
3.2 期望风险的下界 .....	88
3.3 基于学习的超分辨率算法的极限 .....	90
3.4 下界的计算与阈值的选取 .....	90
3.5 讨论 .....	92
4 结语 .....	92
参考文献 .....	92
<b>分类学习的正则化技术 .....</b>	<b>薛 晖 陈松灿 95</b>
1 引言 .....	95
2 经典的正则化技术 .....	96
2.1 Tikhonov 正则化 .....	97
2.2 正则化网络 .....	97
2.3 支持向量机 .....	100
2.4 正则化最小二乘分类器 .....	101

2.5 流形正则化 .....	101
3 最新研究进展 .....	102
3.1 正则化分类器的泛化误差界 .....	102
3.2 正则化项的构造 .....	105
3.3 正则化参数的选择 .....	108
4 结束语 .....	109
参考文献 .....	109

## Transfer Learning and Its Application for WiFi Localization Problems

Sinno Jialin Pan, Vincent Wenchen Zheng and Qiang Yang .....	113
1 Introduction .....	114
2 An Overview of Transfer Learning .....	118
2.1 Instance Based Transfer Learning .....	120
2.2 Transfer Learning Through Dimensionality Reduction .....	121
2.3 Transfer Learning Through Self-taught Clustering .....	123
3 WiFi Localization in Indoor Environments .....	124
4 Transfer Learning for WILP .....	126
4.1 Transferring Localization Models over Time .....	126
4.2 Transferring Localization Models across Space .....	130
4.3 Transferring Localization Models across Devices .....	131
5 Experiments and Discussion .....	134
5.1 ICDM 2007 Data Mining Contest Dataset .....	134
5.2 Experimental Results .....	135
6 Conclusion and Future Work .....	135
References .....	136

关于 boosting 算法的 margin 解释 .....	王立威 景兆祥 142
1 引言 .....	142
2 背景与相关工作 .....	144
3 主要结果 .....	146
4 对 Emargin 上界的解释 .....	148
5 证明 .....	149
5.1 定理 3 的证明 .....	149
5.2 命题 1 的证明 .....	152
5.3 定理 4 的证明 .....	153
5.4 定理 5 的证明 .....	153
5.5 定理 6 的证明 .....	154

6 实验 .....	157
7 结论 .....	158
参考文献 .....	158
<b>最大间隔聚类快速算法研究 .....</b>	<b>张长水 赵斌 160</b>
1 引言 .....	160
1.1 支持向量机 .....	160
1.2 最大间隔聚类 .....	161
1.3 国内外研究现状 .....	163
2 两类问题的最大间隔聚类算法 .....	165
2.1 优化问题的等价转化 .....	165
2.2 切平面算法 .....	168
3 多类问题的最大间隔聚类算法 .....	176
3.1 切平面算法 .....	176
4 实验分析 .....	181
4.1 实验数据集 .....	182
4.2 评价标准 .....	183
4.3 对比算法以及参数选择 .....	184
4.4 聚类精度比较 .....	184
4.5 聚类速度比较 .....	186
4.6 约束凸规划平均迭代次数 .....	187
4.7 切平面算法计算时间与数据集规模的关系 .....	189
4.8 参数 $\epsilon$ 对切平面算法精度以及速度的影响 .....	190
4.9 参数 $C$ 对切平面算法精度以及速度的影响 .....	192
5 总结 .....	192
参考文献 .....	192
<b>自适应 K 段主曲线 .....</b>	<b>张军平 194</b>
1 引言 .....	194
2 主曲线综述 .....	195
2.1 主曲线初步 .....	195
2.2 主曲线发展历史 .....	196
3 自适应 K 段主曲线 .....	200
3.1 引入先验知识 .....	201
3.2 顶点移除 .....	201
3.3 自适应 K 段主曲线实现 .....	202
4 实验 .....	205

5 应用：高精度 GPS 学习 .....	208
6 讨论 .....	210
7 总结 .....	211
附录 .....	212
A. 1 投影步骤细节 .....	212
A. 2 优化步骤细节 .....	212
A. 3 GPS 精度的改进 .....	213
参考文献 .....	214
<b>MIML：多示例多标记学习 .....</b>	<b>周志华 张敏灵 218</b>
1 引言 .....	218
2 MIML 框架 .....	219
3 MIML 学习算法 .....	222
3. 1 基于退化策略的 MIML 学习算法 .....	222
3. 2 基于正则化的 MIML 学习算法 .....	224
4 利用 MIML 学习单示例样本 .....	229
5 利用 MIML 学习复杂高层概念 .....	230
6 结束语 .....	233
参考文献 .....	233

# 1

# 机器学习与人工智能

王 珏

中国科学院自动化研究所复杂系统和智能科学实验室,北京 100190

## 1 引言

“学习”是人类以及各种动物与生俱有的最基本的能力,自从人们试图在计算机上表现人类智能之日起,“学习”自然就成为研究的主要问题。人工智能(*artificial intelligence*)为了将这种在计算机上表现的学习与人类的学习相区别,特为其取了一个新术语——机器学习(*machine learning*)。加在“学习”之前的“机器”二字,也许缘于如果将“人工智能”的“人工(*artificial*)”平行移植到“学习”之前,成为“人工学习”,不足以表示“令计算机学习”的本意,且可能与其他什么意思相混淆,因此,将当时欧洲流行的“机器智能(*machine intelligence*)”的“机器”移植到这个研究领域作为代名词,更为确切。考证其由来,并没有太大的意义,我们仅仅是想告诉读者,“机器学习”这个术语的起源,是来自人工智能的研究。

而在机器学习之前再加上“统计”,变为“统计机器学习(*statistical machine learning*)”,则是统计学家 Vapnik 的建议。大多数机器学习研究者并没有关注这个变化,因为在机器学习的发展历史中(包括模式识别基础),基于统计的学习一直是其研究的一个方面,尽管在 20 世纪整个 70 年代,这类研究在人工智能领域曾经中断过,但是,它一直是模式识别基础的主要研究课题之一,特别是,自从 1986 年多层感知机给出了解决线性不可分问题的一个非线性算法方案之后<sup>①</sup>,这类研究重新兴起。然而,研究者使用“人工神经网络”代替“机器学习”,也许是这类问题的研究者希望与人工智能研究相区分吧!

作为计算机科学家,现在我们不得不关注“统计”二字加在机器学习之前的现实了,因为很多统计学家已经将这类研究纳入他们的研究领域,并作为主要研究课题。换句话说,

\* 此项研究受到国家重大基础研究项目(“973”计划)“数字内容理解的理论与方法”中“机器学习与数据描述”课题(2004CB318103)的支持。

① 这是对分类问题的说法,事实上,使用“回归问题”的语言可能更符合实际。但是,为了直观,本文采用了分类的说法。

目前,机器学习已经不再是人工智能,甚至计算机科学家的专有领域,它在“统计”的伞盖下,已经成为统计学领域中的重要课题,并被赋予新的含义,统计学家希望借此推动统计学的发展。

事实上,机器学习并没有一个公认的指导算法设计的定义。1983年,H. Simon给出了一个关于“学习”哲学式的说明(不是机器学习):“如果一个系统能够通过执行某种过程而改进它的性能,这就是学习”(文献[1])<sup>①</sup>。对算法设计,我们一般将机器学习理解为:给定一个样本集,它是来自对实际问题世界  $y=F(x)$ (本文以后将称其为自然模型)的独立同分布(independent identical distribution,iid)采样,设计一个算法,计算一个函数  $y=f(x)$ ,使得它对自然模型在一定统计指标下为真,即,  $f(x)$  是自然模型的一个近似模型。这里,  $f(x)$  可以是一个规则集。

机器学习的研究一直存在着两种不同的方法:其一,以统计(度量)为基础的感知机;其二,以划分(非度量)为基础的符号归纳。不同的问题,人们关注的侧重不同,例如,由于字符识别的成败取决于所建立的模型对新获得字符的识别精度,而不关注对模型作出识别行为的解释,这时,基于统计的方法有效;而在分子生物学上,如果我们试图寻找致病基因,对模型行为的解释就是必需的,符号归纳也许就更为有用。这也就是为什么数据挖掘将其任务分为预测和描述两类的原因。

事实上,这两种观点的争论,恰恰反映了人工智能研究与当前“统计机器学习”研究在理念上的差异,这种差异是重要的。为了保持文章的完整性,本文只能在这一节剩余的部分阐述符号机器学习的发展历程,以后就不再有机会说明这个问题了。以下,作者流水账式地罗列这类研究的情况,顺便介绍两类研究“结怨”的由来,而其理念的差异,则留在本文以后各小节中讨论。

感知机类的机器学习源自 1957 年 Rosenblatt 的一篇文章(文献[2]),他根据神经科学的三个重要结论(文献[3])——神经元相互连接、兴奋和抑制是神经元的基本工作方式,以及改变神经元之间的连接强度来学习——设计了一个算法,其要点是:其一,统计学基础是线性判别优化理论;其二,算法设计是基于给定空间上的度量;其三,算法对线性可分问题收敛。其本质是使用线性判别理论,进而将优化作为设计算法的基础。这个理念被其他研究者抓住两个话柄:其一,给定数据集合建立的模型是自然模型的真实反映吗?模型仅在输入-输出意义上对自然模型为真,而其本身对自然模型没有解释;其二,对线性不可分问题,算法不收敛。

1969 年,人工智能的奠基人 Minsky 等出版了《感知机》一书(文献[4]),二十年之后,人

<sup>①</sup> 这个翻译引自陆汝钤教授的著作《人工智能》第五章,由于在《人工智能》这本著作中作者没有给出这个说法的原始出处,而本文作者只找到 Simon 在 1983 年的文章与这个译文相近。Simon 在这篇文章中的原文是: Learning denotes changes in the system that is adaptive in the sense that they enable the system to do the same task or tasks drawn from the same population more effectively the next time. 如果陆老师的译文就是来自这篇文章,应该说,这个格言式的翻译实在是漂亮。

们一般将人工智能领域终止对感知机的研究归罪于这本书,然而,这本书提出了机器学习算法需要满足的一个似乎相互矛盾的原则:其一,只能解决玩具世界问题的算法是无用的;其二,算法复杂性应是多项式的。前者,主要考虑数据的数量和数据的性质,特别是线性不可分性质。一般地说,对线性不可分的数据在没有任何领域知识的条件下试图找到一个多项式复杂性且对自然模型具有普遍意义的算法是不可能的,因此,这本书最为重要的动机似乎是告诉研究者,领域知识是解决复杂问题学习所必需的<sup>①</sup>。在今天,这个思想已经几乎被所有机器学习的研究者所认识。应该指出的是,尽管 Minsky 关于“领域经验知识在设计机器学习算法的作用”的论述有重要的意义,但是,否定线性感知机是这本著作的重要缺憾。Minsky 似乎没有注意到 von Neumann 在 1932 年建立量子力学数学基础时暗示的一个哲学道理:如果说一个事物我们已经理解,是说我们找到了一个空间,这个事物在这个空间上可以线性表述。这就是近三十年后,Vapnik 将算法设计建立在 Hilbert 空间的思想源泉。另外,我们猜测,Minsky 在背后的另一个动机,就是试图主张和推广基于符号的人工智能体系的研究。对机器学习而言,在同一个时期,基于符号的学习机制也同时提出。

说到基于符号的学习,就不得不涉及文法归纳的研究。1959 年,Solomonoff 发表了一篇短文(文献[5]),他试图从一组自然语言样本归纳文法,尽管他的研究不是理论性的,但是,这个“理想”还是吸引了当时很多人的眼球。近十年过去之后,这个“理想”不幸被 Gold 在理论上证明是不可行的(文献[6]),Gold 证明:①在“学到”系统“知道”已“学到”的意义上,只有所有实例都是正例且语言类是有限个语句组成的条件下,才是可学习的;②在系统“学到”,但系统无法判定自己是否“学到”的意义上,只有原始递归语言才是可学习的。这揭示了这类学习在理论上不可逾越的障碍。

Minsky 在批评感知机时,使用了一个貌似简单、实质性质复杂的例子 XOR,这使得人们有了“如此简单的问题,感知机却无能为力”的印象。非常有趣的是,在文法归纳中,也有一个看似简单但却实质复杂的例子,就是 Chomsky 给出的“A,B,C 是 a,b,c 的丈夫”。这是使用大于 1 型的文法无法表述的语句。处理这类复杂例子的方法就是引入所谓“语义”,即,考虑(A,a),(B,b) 和(C,c) 的对应关系,由此,上述语句可以分解为:“A 是 a 的丈夫”,“B 是 b 的丈夫”和“C 是 c 的丈夫”三个 3 型文法就可描述的语句。这个思想就是符号机器学习将问题限制在数据以“属性-值对”表示的根据。

以后的符号机器学习就是以处理表述为“属性-值对”数据的方法,Samuel 在研究下棋学习问题时,使用了这种方法(文献[7]),但是将这个方法形成一个理论框架的是 Hunt 提出的 CLS(Concept Learning System)(文献[8]),对这类研究做出最大贡献的是 Quinlan,他所提出的 ID3 和 C4.5,至今还是机器学习经常普遍使用的方法之一(文献[9,10])。这类方法有时也称为“非度量”方法(文献[11])。沿着这个考虑,目前最重要的发展方向是“关

<sup>①</sup> 在那个年代,当时人们的研究主要是在寻找解决复杂问题的普适的方法,例如,从自然语言样本学习文法的研究,以及基于逻辑的知识研究等。

系学习”，其困难在于样本集不能写成给定空间上的向量形式，数据之间存在与领域有关的特定的“关系”，如何解决这类问题，尽管目前已存在大量的研究，但是，至今还没有一个对解决实际问题有本质意义的理论框架。

最后，应该指出，由于近几年所谓“非度量”方法在重采样意义下获得了统计的解释，因此，像 c4.5 这类算法得到研究者和应用者的喜爱。

## 2 机器学习与人工智能的不同理念

一般地说，机器学习<sup>①</sup>研究者不十分关注算法设计所应该遵循的统计学准则和原理，他们的研究往往将问题考虑为优化问题：给定基函数，计算特定约束下使得被选择的损失函数最小的优化解答。这样，他们需要解决的问题就是如何选定合适的基函数与损失函数，以及如何有效计算，即，发展算法才是他们的主要任务。至于统计学，机器学习关注的是对计算结果的统计解释，以及统计学对计算结果检验的指导。

机器学习基于下述统计框架：由于观测数据（一般称为样本<sup>②</sup>）不完整且含有噪音，因此，需要使用后验概率描述  $y_i = f(x_i)$  成立的可能性，其中  $\{x_i, y_i\}$  为一次观察的样本。设计一个损失函数，样本集的风险就等于每个样本损失和每个样本的后验概率乘积之和。计算参数，使得 Bayes 风险（样本集风险）最小。这就是三十余年前 Duda 与 Hart 在他们的著作《模式分类和场境分析（Pattern Classification and Scene Analysis）》中给出的框架（文献[12]）。尽管机器学习近十年获得了重要的进展，但是，这个框架并没有实质地改变，特别是分类问题。

这个框架需要一个重要的假设：样本集与自然模型同分布（来自同一个自然模型的样本趋于无穷大），以及需要每次观察的样本满足独立条件，以便使得计算多个事件的联合分布成为可能，即，独立同分布。

独立的条件可以认为是为了数学处理的方便而人为规定的条件，它可以在设计数据采样时满足。但是，同分布则是机器学习的本质。

同分布可以这样理解：如果样本集趋于无穷大，要求样本集中的所有样本来自同一个自然模型，如果样本集是有限的，要求样本集与自然模型在统计上具有相同分布，或者训练集和测试集具有相同分布。

机器学习要求样本集与自然模型满足同分布是相当显然的，否则使用统计方法建立的模型就有“指鹿为马”的嫌疑了。但是，当样本集是有限的，如何保证它与自然模型同分布

<sup>①</sup> 由于本文以后主要讨论统计机器学习，因此，只有在个别地方，为了避免混淆或为了强调“统计”，才使用“统计机器学习”，大多数情况下，就简称机器学习。

<sup>②</sup> 在统计学中是将一组观察称为样本，在机器学习和模式识别中，则是将一次观测获得数据称为样本，而将一组观察称为样本集，本文将使用后者。

呢？考虑到当前“非可控数据涌现”的现实，这已成为机器学习面临的根本性的困难。人工智能是否能够解决或改善这种窘境？为了说明这个问题，我们需要了解机器学习与人工智能之间理念的差别与联系。

目前机器学习成为吸引众多研究者注意的原因是“泛化”，这是人工智能没有在理论上给予足够关注的问题。对统计学来说，“泛化”的要害就是“同分布”，即，如果在机器学习中考虑“泛化”，就不能回避“同分布”问题。

如果说人工智能不考虑“泛化”，大概也不是真的，开发的任何一个智能系统，其问题求解能力一定是评价这个系统的重要指标，但是，这个指标是基于领域专家对自然模型的认识程度，不是客观的自然模型，即，假设领域专家对自然模型具有深刻理解，由此，对自然模型的泛化取决于领域专家所能够提供的知识的质量而间接考虑。由此，人工智能研究的焦点变为选择最优秀的专家和收集这个专家的所有知识。

为了进一步讨论机器学习与人工智能之间的差别，我们看一个有趣的问题：在人工智能研究中，有时也需要考虑不确定问题，但是，它没有采用统计学原理，而是发展了其他方法，以代替统计学的方法。在人工智能中描述不确定性的最著名理论是模糊集，在这个理论中，隶属度是关键，这是一个与概率“类似”的定义在 $[0,1]$ 上的实数。一个自然的问题是，它与概率有何区别呢？粗略地说，概率满足排中律，但因果律破缺；隶属度满足因果律，但排中律破缺<sup>①</sup>，由于排中律与因果律不能互导，因此，两者不同。

由于机器学习基于统计学，假设对特定自然模型具有特定分布就是自然的事情了，这样，这个分布是这个自然模型的属性，另外，研究这个自然模型的每次观察发生的原因没有意义，因为这将与泛化目标相悖，因此，因果律破缺也不奇怪。总之，机器学习属于因果律破缺范畴。应该指出，机器学习采用这种方式是为强调“泛化”而有意为之。事实上，对机器学习来说，样本数量是否趋于无穷大并不是一个本质的要点，其要点就是同分布，换句话说，样本集对自然模型是充分的。不幸的是，由于机器学习强调“对自然模型一无所知”，这样，给定样本集“充分与否”就是不能判定的。

我们来看人工智能是如何看待世界的。它采用了另外一个假设：智能系统不一定是对自然模型的精确描述，在理想情况下，这取决于领域专家对自然模型认识的程度，即，从人工智能创立之时，就没有试图让它的研究建立在对自然模型的排中律之上，而要求满足一类领域专家特有的因果关系，严格地说是“经验因果关系或似然因果关系”，即，默认“很多事物之间存在某种程度的因果关系，但是不能证明它是否正确”。以人工智能的语言来说，就是可以

<sup>①</sup> 事实上，模糊集理论的隶属度并不严格满足因果律，而仅仅是一种经验因果关系，但是，排中律破缺。我们可以粗略地设立两个口袋——“排中律破缺”和“因果律破缺”，并将不同理论方法放在这两个口袋之中，而不作进一步的细致划分。模糊集可以装入“排中律破缺”的口袋。事实上，机器学习往往采用一种逼近优化的方法，说这样的机器学习满足排中律，同样是不严格的，但是，因果律破缺。由于本文没有讨论“排中律”和“因果律”这两个概念哲学含义的动机，因此，读者不妨将这两个概念理解为作者为了划分机器学习与人工智能各种理论方法所使用的一种简单表述，以便更加显而易见地说明这些理论方法在理念上的差别。