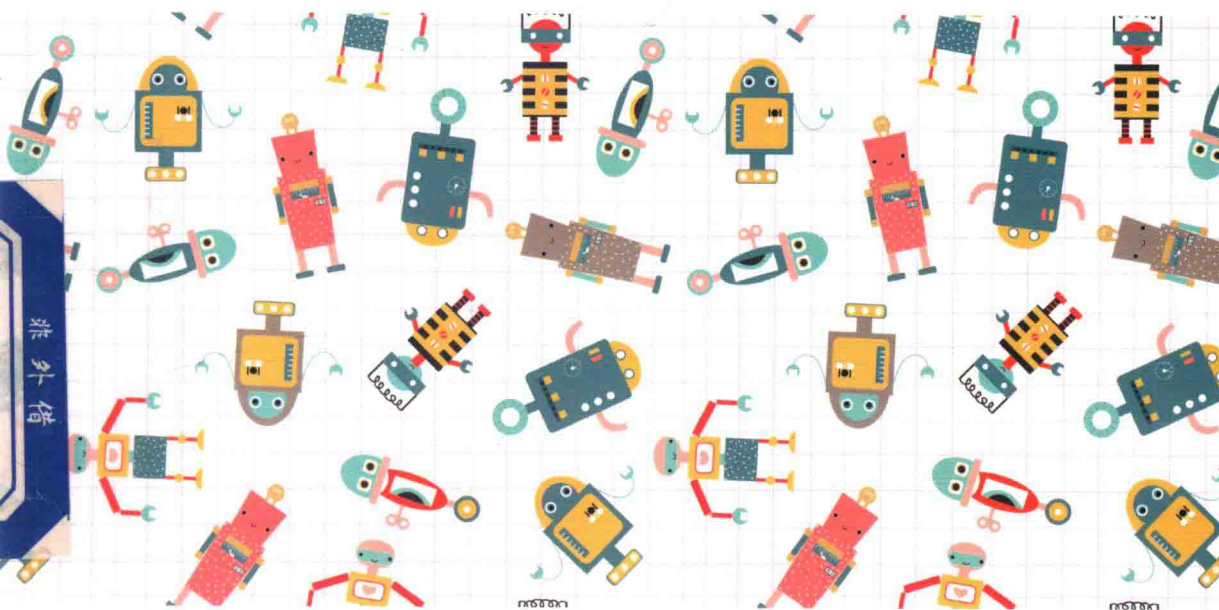


Machine Learning
Deep Learning & Reinforcement Learning

机器学习

深度学习与强化学习

林强 编著



非外借



知识产权出版社


全国百佳图书出版单位

Machine Learning
Deep Learning & Reinforcement Learning

机器学习

深度学习与强化学习

林强 编著



知识产权出版社

全国百佳图书出版单位

图书在版编目 (CIP) 数据

机器学习、深度学习与强化学习/林强编著. —北京: 知识产权出版社, 2019. 5

ISBN 978-7-5130-6253-4

I. ①机… II. ①林… III. ①机器学习—研究 IV. ①TP181

中国版本图书馆 CIP 数据核字 (2019) 第 087094 号

内容提要

本书尝试从计算流和信息流相结合的角度, 从自组织网络的角度, 对计算科学与信息科学结合的原理、方法和意义进行阐述, 从而形成一套融合数学思维和信息思维的理论体系。本书坚持理论与应用相结合, 既从较高的抽象的层次来认识和分析学习与认知形式, 也对其应用层的实际呈现进行阐述, 由浅入深地对学习与认知形式的发展走向、趋势以及其中的深刻内涵进行探讨。

本书获得北京市教委科研计划项目资助 (项目编号: KM201611232015)。

责任编辑: 张水华

责任校对: 王 岩

封面设计: 臧 磊

责任印制: 孙婷婷

机器学习、深度学习与强化学习

林 强 编著

出版发行: 知识产权出版社有限责任公司 网 址: <http://www.ipph.cn>

社 址: 北京市海淀区气象路 50 号院 邮 编: 100081

责编电话: 010-82000860 转 8389 责编邮箱: 46816202@qq.com

发行电话: 010-82000860 转 8101/8102 发行传真: 010-82000893/82005070/82000270

印 刷: 北京虎彩文化传播有限公司 经 销: 各大网上书店、新华书店及相关专业书店

开 本: 720mm×1000mm 1/16 印 张: 10.5

版 次: 2019 年 5 月第 1 版 印 次: 2019 年 5 月第 1 次印刷

字 数: 180 千字 定 价: 59.00 元

ISBN 978-7-5130-6253-4

出版版权专有 侵权必究

如有印装质量问题, 本社负责调换。

序 言

机器学习、深度学习和强化学习是人工智能的核心技术，三者之间既相互独立又关系密切，共同构成学习的主要形式。学习形式的优化和升级是提高人工智能认知行为的一种重要手段。

以上述三大技术为代表的人工智能技术是近年来学界和商界广泛关注的领域之一，在实践中表现出领域的多样性、应用的多样性、呈现的多样性，对学习和研究带来了内容的广泛性和理解的复杂性。

本书尝试从计算流和信息流相结合的角度，从自组织网络的角度，对计算科学与信息科学结合的原理、方法和意义进行阐述，从而形成一套融合数学思维和信息思维的理论体系。本书坚持理论与应用相结合，既从较高的抽象的层次来认识和分析学习与认知形式，也对其应用层的实际呈现进行阐述，由浅入深地对学习与认知形式的发展走向、趋势以及其中的深刻内涵进行探讨。

本书的创新之处在于：一是结合数学的发展，提出计算流的概念；二是从计算流和信息流相结合的角度分析机器学习的发展与演进，建立与其他著作不同的视角；三是从自组织的角度将机器学习与深度学习、强化学习统一起来，强调探索式前进、反馈和改进的自组织行为是上述领域的共同范式。

以上述创新型成果为框架，在素材整理和编撰过程中，本书参考和借鉴了许多前人的研究成果，如教材、著作和网络文献等，由于时间紧，加之部分网络文献出处不详，未能列出这些成果的所有出处，在此向各类文献的作者表示真挚敬意、歉意和由衷的感谢。

由于编著者水平有限，本书尚存在不足之处，敬请广大读者批评指正，以便不断修改、完善和提高。

本书可作为对机器学习和人工智能进行研究的相关部门和人员的参考读物，也可作为高等院校信息管理与信息系统专业、计算机科学与技术专业以及其他相关专业的参考用书。

知识产权出版社对本书的出版给予了极大支持，在此表示感谢。

林 强

2018年12月15日

目 录

第一章 数据、数学与机器学习	001
1.1 概述 / 003	
1.2 数学与机器学习 / 005	
1.3 数据与机器学习 / 008	
1.4 深度学习与强化学习 / 014	
1.5 本章小结 / 019	
第二章 分类与回归	021
2.1 常用的分类方法 / 024	
2.2 分类的数学解释 / 032	
2.3 回归分析 / 038	
2.4 回归分析的数学解释 / 041	
2.5 本章小结 / 046	
第三章 特征选取	047
3.1 数据预处理的步骤 / 050	
3.2 数据预处理与特征提取 / 057	

3.3	主成分分析 / 059	
3.4	因子分析 / 063	
3.5	特征提取问题的数学解析 / 067	
3.6	本章小结 / 072	
第四章	聚 类	075
4.1	基本概念 / 078	
4.2	聚类的过程 / 082	
4.3	分析方法 / 083	
4.4	基于 K-means 算法的聚类规则 / 088	
4.5	聚类问题的数学解释 / 091	
4.6	本章小结 / 094	
第五章	深度学习	097
5.1	概述 / 099	
5.2	神经网络模型 / 101	
5.3	神经网络学习方法 / 103	

5.4	神经网络的数学解释 / 106
5.5	本章小结 / 111
第六章	强化学习 113
6.1	朴素贝叶斯 / 115
6.2	贝叶斯信念网 / 118
6.3	动态贝叶斯网络 / 120
6.4	一般时序模型 / 121
6.5	马尔可夫模型 / 131
6.6	本章小结 / 138
第七章	计算流与自组织 141
7.1	信息流与计算流的结合 / 143
7.2	学习中的自组织行为 / 144
7.3	神经动力学与自组织 / 153
参考文献 157

第一章

数据、数学与机器学习

1.1 概述

人类对世界的认识是理论来源于实践又服务于实践的过程。作为对人类认知行为的近似，机器学习、深度学习和强化学习的过程也是认知来源于世界又服务于世界的过程。当离开人类的参与，这一行为完全由计算机自主实现时，这一过程表现为建立在机器学习、深度学习、强化学习（为表达方便，除非特别指出，采用机器学习代表三种学习形式，下同）基础之上的自组织过程。

交换是经济社会中一种常见的基本的经济形式。现代交换经济中，物理世界的产品流通过与信息流结合，将现实世界映射到数字的世界。机器学习又将这个数字的世界

映射到有限维或无限维的空间中，局部的或整体的空间中，呈现出结构与结构之间的关系。

人类最重要的两个智能行为是学习和解决问题的能力。机器学习是让计算机模拟和实现人类的学习，以获取解决问题的知识。专家系统是基于经验的学习，也是机器学习的初级方式。专家系统利用专家的知识来解决实际问题，解决问题的能力达到了专家水平。但是专家系统在发展过程中遇到了不少的困难。一方面，从专家那里获取知识是一项既费时又费力的困难工作。专家能在实际中有效地解决问题，但要专家整理出自己的知识和经验，他往往无从下手。这为知识获取带来了困难，形成了知识获取的“瓶颈”现象。另一方面，基于经验的学习虽然在解决问题上具有一定功效，但是却难以反映问题以及解决方法本质特征。机器学习是基于数据或样本的学习，为解决知识获取的问题提供了有效的途径。它使得计算机可以从大量实例中自动归纳，产生描述和抽象这些实例的一般规则知识，从而在反复学习中不断逼近问题以及解决方案的本质。

机器学习被列为人工智能的核心技术，它以知识处理为主体，利用知识进行推理，完成人类定性分析的部分智能行为。人工智能技术融入决策支持系统后，使决策支持系统在模型技术和数据处理技术的基础上，增加了知识推理技术，使决策支持系统的定量分析和 AI 的定性分析结合起来，从而提高辅助决策和支持决策的能力。

传统的机器学习是从海量样本（也称为大数据）中找出有用的知识即数据挖掘技术。依据学习方式的不同，可以划分为以下两类：

(1) 监督学习，计算机从样本中学习，依据从外界获得的已知的明确的结论判断。

(2) 无监督学习，计算机从样本中学习，得不到明确判断。目标标签不明确。

将神经网络和上述机器学习的思想综合起来可以完成更难的学习任务，这些学习任务往往是传统的神经网络或者机器学习自身无法完成的，这一类的学习方法被称为深度学习。除了神经网络之外，支持深度学习的另一类重要方法是核方法，如支持向量机（SVM）和核主分量分析，这些内容源自统计学习理论。支持向量机通常被认为是一种监督学习方法，其本质是一个两类分类器。SVM的设计原理源于希尔伯特空间构想和再生核希尔伯特空间构想（RKHS）的作用。以现代数学理论为依据，SVM成为监督学习中一个具有强大计算能力的一流的工具。在RKHS基础之上可以进一步建立Tikhonov经典正则化理论，正则化最小二乘估计和正则化参数估计。

强化学习是不同于上述两类学习方式的学习形式。在强化学习中，计算机自己从样本中学习，自己从样本中进行判断寻找答案。

1.2 数学与机器学习

从数学的角度看，机器学习方法研究的是建立在趋势为有限数的集合、集合族的笛卡尔积及其映射的基础之上的代数运算。两值分类任务是机器学习中最常见的代数运算，多类别的任务可以看作两分类问题的变体形式。极端一些，抛弃类别的概念，对具体值进行预测的任务称为回归（regression）。其本质是依据标注有函数输出真值的训练样本集来学习形成一个范畴。比如，可以随机抽取一定数量的样本生成一个训练集合，先选定一类映射（如映射值与数值型特征存在线性依赖关系的映射族），然后依据该训练集合构造一个能够将映射预测值与其真值之差最小化的（目标）代数运算。在此过程中，特征的选择与提取可以视为中间集合的产

生。集合的结构与变换是聚类产生的依据。训练样本的有限性，意味着可以利用的信息量有限，它所计算的度量值可解释为待分类样本到决策的距离，因而可将该度量值作为预测可信度的一种度量。分类和回归的共同假设是可以获得由带有类别真值或函数真值标注的样本所构成的训练集合。基于此训练集合，现代计算技术的发展为上述算法的实现提供了可能。

通过机器学习得到自由模下的范畴，需要将目标对象映射为一组新的对象。范畴、对象及映射是机器学习的三大要素。在这三大要素中，映射占据着中心地位；范畴通过映射来完成，学习问题通过能够产生的学习算法来解决。所以机器学习要解决的问题是建立自由模下的范畴，建立从特征描述的对象到输出对象的恰当映射（即模型），对于机器学习来说，要解决的中心任务就是研究如何从训练样本或训练对象中获取这样的映射。所以机器学习所关注的问题是使用正确的对象来构建正确的范畴以完成既定的任务。为完成某个实际任务，需要借助各种学习方法和来自相应任务领域的样本所构造的模型。因此，从现代数学的角度看，机器学习可以概括为“使用正确的对象来构建正确的映射，以建立既定的自由模下的范畴”。现实中，这里的正确的对象由特征（feature）来体现，范畴由数学模型来体现。一旦获得对问题域中对象的某种正确的特征表示，通常不再去关注这些对象本身，而把这种正确的特征作为机器学习的研究对象。

这里的范畴是对我们所期望解决的、与问题域对象有关的问题的一种抽象表示。许多任务都可抽象为一个从样本集合到输出对象的映射，而这种映射或范畴本身最终表现为应用于训练样本的某个具体的机器学习算法的输出。

机器学习对范畴的描述有三种方式：几何范畴（geometric model）、概率范畴（probabilistic model）和逻辑范畴（logical model）。这三种划分并

非严格相斥的。它为解释和分析同一问题提供了不同的解析角度。

第一种为几何范畴。实例空间 (instance space) 是由所有可能的或可描述的实例 (或样本) 所构成的集合, 无论它们是否存在于已有数据集中。通常该集合具有一定的拓扑结构。若所有的特征对象都是数值型的, 则可将每个特征视为笛卡尔坐标系中的一个点。几何模型是借助于一些几何概念 (如线、平面及距离) 直接在实例空间中构建的。实例空间的维数不超过三维, 运用于高维空间的几何概念通常都带有前缀“超” (hyper-)。借助矩阵符号, 可方便地表示 d 维笛卡尔坐标系中的各种变换。

第二种为概率范畴, 贝叶斯分类器便属于这个范畴。这类范畴基于下列基本观点: 令 X 为已知集合 (如实例的特征), Y 为我们感兴趣的目标集合 (如实例所属的类别)。机器学习中最关键的问题是如何对 X 和 Y 之间的依赖关系进行建模。统计学家所采取的方法是, 假设这些集合的观测值由一些潜在的随机过程按照某个明确定义但却未知的概率分布所产生。希望通过这些样本来获得与该分布有关的更多信息。在研究这一问题之前, 一般假设已经学习到该分布, 那么应如何利用它来导出一些有用的结论。

第三种逻辑范畴本身更偏向于规则系统, 这种类型的模型之所以被称为“逻辑模型”, 是因为它很容易被翻译成可为人所理解的规则, 如 IF..., THEN... 的形式, 这些规则很容易用树形结构来表示。这种树也可称为特征树。这种方法的主要思想是利用特征以迭代方式不断划分实例空间。逻辑范畴所拥有的与大多数几何范畴和概率范畴不同的特性之一是, 它能够一定程度上对其预测结果进行解释。例如, 由决策树给出的预测结果可通过读取从根节点到叶节点的条件而获得解释。

特征对象与范畴的关系非常密切, 不仅仅因为范畴是依据特征对象而定义的, 而且还因为可将单个特征对象转化为单变量范畴。由此, 可对特

征对象的两种用法进行区分：一种比较常见的特征对象使用方法是重点关注实例空间中的某个特征区域；另一种用法是比较集中地出现在监督学习中，如线性分类器所运用的是形式为 $\sum_{i=1}^n \omega_i x_i > t$ 的决策规则，其中 x_i 为一个数值型特征。该决策规则为线性，这意味着每一维特征对象对于待分类实例得分的贡献是彼此独立的，而贡献的大小则依赖于权值 ω_i ：如果 ω_i 值较大且为正，则当 x_i 为正时，得分为增加；若 $\omega_i \leq 0$ ，当 x_i 为正时，得分则会降低；若 $\omega_i \approx 0$ ，则 x_i 的影响可以忽略。因此，特征对象对于模型的最终决策所做的贡献既精确又可度量。还应注意，进行决策时，每一维特征对象并未被“阈值化”，其“分辨率”被完整地运用于计算实例的得分。特征对象的这两种用法（即“作为划分用的特征对象”和“作为预测器的特征对象”）有时会在一个范畴中同时出现。

在分类问题中，依据类别的不同，特征对象之间的相关性也不尽相同。两个特征对象可能是正相关的，也可能是负相关的。此外，特征对象之间还有一些其他的关联方式。在进行特征搜索以添加到逻辑模型中时，可利用这种特征对象之间的关系。

在上述范畴所构成的拓扑空间基础上，进一步基于同胚和连通性进行拓展，为机器学习算法的改进提供了新的途径，如 SVM 中核函数的确定。

1.3 数据与机器学习

基于样本的决策支持是信息技术自然演化的结果。信息技术的大致发展过程如下：从早期的数据样本收集到数据样本存储和检索、数据库

事务处理等数据样本管理，到涉及数据样本分析与信息处理知识的理解，再到与环境的交互。除了传统的依赖经验的专家系统，决策者又多了一种从海量样本中提取有价值知识和利用价值知识的工具，通过使用知识发现工具进行数据分析，可以发现重要的规律、模式，破除数据与信息鸿沟。

基于知识发现决策属于高层次上的主动式自动发现和决策方法，是指从数据样本中提取正确的、有用的、未知的和综合的信息，并用它进行决策的过程。这一过程实现了从数据样本到信息、知识、决策的跨越，如图 1-1 所示。



图 1-1 从数据样本到决策支持

从机器学习的角度看，上述过程是通过如下智能体结构实现的。

图 1-2 是基本单元——智能体的结构。智能体由传感器（Sensors）、处理器（Processors）、执行器（Actuators）三部分组成，具有感知外部环境、产生信息流、完成信息流与计算流的结合以及采取自适应行动的功能。