

机器学习背后的朴素思想

文档编号: ML-T-00101

JEROD YAN*

December 13, 2019

摘要: 本文档介绍机器学习过程中所涉及的基础概念与基本流程, 以使得准备进入机器学习领域的人员能够有清晰且正确的概念, 少走些弯路, 少被人忽悠。

目 录

1	学习技术的方法	1	3.2	相关的人物	6	
2	机器学习框架概念	2	3.3	人工智能的派别	7	
	2.1	概念层次的划分	2	4	回归分析	7
	2.2	机器学习的步骤	4	5	增强学习	8
3	周边的相关概念	6				
	3.1	概念之间的关系	6			

1 学习技术的方法

任何一门学问或是技术, 都是由一系列的概念构成的。如果你准确地理解了其中的概念和概念产生的思维过程, 那么这门学问就不能难学了。通常, 一个概念在产生的时候, 它来自于简单的、朴素的思考。英文中称之「Common Sense」。然后, 可能是由于逻辑严谨性的原因, 学者们会使用一些看起来高深的数理化符号来做逻辑推导或证明, 其目的是为了防止朴素思考带来的思维偏差。

但是, 作为学习者而言, 这些概念通常已经是被证明正确了。我们的目的是学会它。而逻辑符号及数理符号的抽象性, 会学习带来障碍和困难。所以, 我认为, 既然

*jerod74 DOT yan AT gmail DOT com

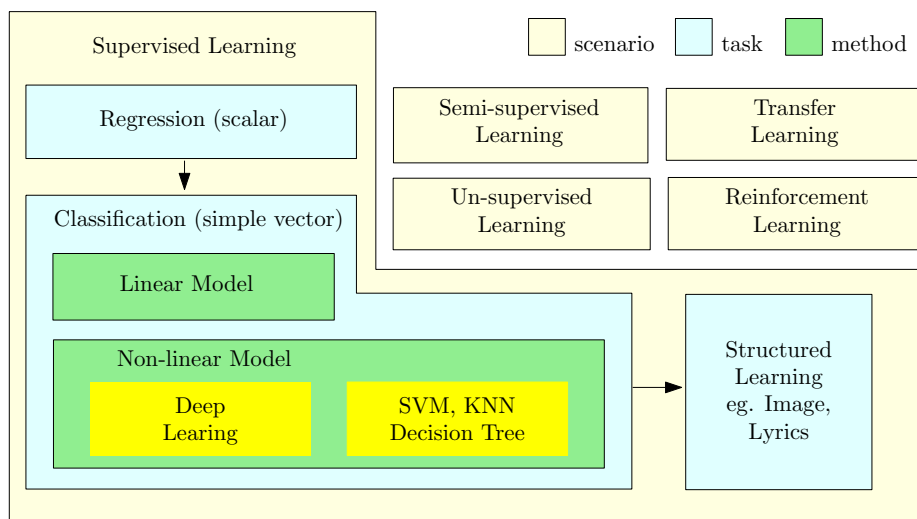


图 1: 概念层次图

概念是由朴素思想产生出来的。那么，在学习的过程中，就要先去学习那些概念背后的朴素的思想。试想一下，如果你是一个概念的发明人，你会直接上来就先想一个包括二阶导数的微积分公式吗？

通常，了解概念或定义其背后的思想会帮助你理解这个概念数理化定义。

然后，当你掌握了一门学科的概念后，你要做得是把这些概念放在一起，比较一下，比较它们的区别与联系。你可在「同中求异」和「异中求同」的两个思路下，做一些分析工作，就可以建立起整个知识的体系。

2 机器学习框架概念

2.1 概念层次的划分

- 1) 首先，如图1所示，从输入的数据(Input)来划分。机器学习方法是通过已经采样好的数据来区分学习的场景 (Scenario)。先看输入数据的整体，根据全量的数据是否标注过，分为监督学习 (Supervised Learning) 和非监督学习 (Unsupervised Learning)。如果是有部分数据被标注过，而还有一些未被标记过，称为半监督学习 (Semi-supervised Learning)。如果输入数据的部分和本次任务有关，部分无关，被称为迁移学习 (Transfer Learning)。如果是只有实时的采样且有一定的最后成败判断规则，完全由规则来确定学习的结果，可以称为增强学习 (Reinforcement Learning)。
- 2) 其次，从输出的结果(Output)或是学习的目的 (Task) 来划分。如果输出的结果是个标量 (Scalar)，可以称之为回归 (Regression)。如果输出的结果是

个简单向量，可以称之为分类（Classification）。如果输出的结果是个复杂向量或矩阵（Matrix）或高阶矩阵（张量Tensor），称之为（Structure Learning）。Structure Learning 的任务的例子，比如中英文的机器翻译，人的语音到文字的识别，生成一首歌词，生成一张世界上不存在的人的头像¹。

- 3.) 最后，对于模型的复杂类型可简单分为线性模型（Linear Model）和非线性模型（Non-Linear Model）。线性模型中最常见就是线性回归模型。而非线性模型就分为黑盒模型，如神经网络模型，深度神经网络模型（Deep Learning），以及灰白盒模型，如SVM，Decision Tree，K-NN等。

打个比方，就是你有什么数据，想做什么的任务（输出什么样的结果），然后设计一个线性或非线性的模型。对于非线性的模型，你可以使用黑盒的方式，让计算机的强大的算力和足够多的数据，自己去学习模型中的参数的具体取值；也可以采用白盒的方式，自己设计输入数据特征，数据变换的方法，来得到模型中事先定义好的有意义的模型参数的具体取值。

举个例子，你任务是要识别图片中动物是猫或是狗。你有 10,000 张图片，都是猫和狗的，也请人标记了每一张是猫或是狗，你这个场景就属于监督学习。如果你经费紧张，请人标记了其中 5,000 张，场景就变成了半监督学习。

再举个例子，你任务还是要识别图片中动物是猫或是狗。你有 10,000 张种类繁多的图片，你打开一些图片文件看了一下，乱七八糟的，有猫、狗、大象、老虎，甚至还有卡通人物，如一休哥的，蝙蝠侠、钢铁侠、蜘蛛侠的。你没经费，只能自己标记，标记了20分钟时间，一共标记了410张图片，其中 200 张是狗，100 张是猫，50 张是大象、50 张是老虎，10 张是一休哥的。然后，你不想标记了，那么到此为止，你遇到的场景是迁移学习。注意，迁移学习场景中隐含了一个意思，就是你要使用所有 10,000 张图片，那些没有标记的图像，甚至是与任务目标无关的图片也可以对完成任务有帮助。这个可以理解为，我们小时候，并不是看到的所有的东西，都会有人给你指正，有时看到东西虽然不知道是什么，但是对于分辨其它已知的东西，仍旧是有帮助的。

无监督学习的场景，就是要让机器无师自通，在没有直接反馈及帮助的情况下学习。把这 10,000 张没标记过的图片，统统让它看一遍，可能它会把猫、狗、老虎认为一类事物，而一休，蝙蝠侠，钢铁侠是一类事物。这个例子当前不是太好，这要和具体的任务相结合。

最后我们提一下增强学习。

后面提到吴恩达在学术上的成就，主要是使用增强学习来控制无人直升机的。增强学习的特点与遗传算法有点像，都是要多步以后才能看到效果。增强学习的例子，

¹建议你点开这个网址感觉一下 Nvidia 公司的算法实力。<https://thispersondoesnotexist.com/>

主要集中在打游戏，包括电子游戏或是围棋类的游戏。这类场景的特点是，周围环境不是太复杂，而且规则比较明确。机器做出了一系列的决策和环境的反馈之后，只有在最后才知道成败。因为决策的次数太多以及环境的随机反馈，不太可能回溯整个决策的每一个步骤。这样的场景通常可以归为增强学习。如果拿打游戏来做比喻，增强学习是第一人称的游戏，你看的世界就是周围的世界，你不太能注意到自身。而监督学习是拿了超级权限或开了外挂的第三人称的游戏，而且是拥有后台数据库读权限的大 Boss 的第三者视角来看的游戏中的各种行动，是个上帝视角。游戏的角色的行为一举一动，你都知道其结果的对错。

再举一个不是太恰当的例子，增强学习有点类似我们大学毕业后，走向真实的社会中的学习。没有人告诉你，今天这点做的对，那一点不太好，要改进。你忙碌了几个月的项目，甚至一整年，得到的是一个非零即一的结果。幸运的话，努力没白费，成功了。不幸的话，项目失败了。无论成功与否，你都回头复盘，你有可以回想到的决策，而大量的细小的决策基于于当时决策前的环境，可能包括各种因素，有形的，无形的，你可能都想不起来了。这时，你如何总结学习到成功的经验或是失败的教训呢？我想如果增强学习能够发展起来的话，那么可能机器真是有了些智慧呢。

你读到这里，我想问一个问题：如果一个问题被归为监督学习场景，那么是还可以使用所谓的增强学习方法吗？想一下？

.....

对于监督学习和增强学习这两个概念，是针对场景而言的。其划分标准是输入数据的情况。监督学习的输入数据都会请人提前做标注好，而增强学习的数据是训练过程中，一边训练，一边收集到的，也没有人标注它。所以，如果一个输入数据已经被归为监督学习的场景，那么就不能再归为其它的场景。每一个场景都是独立的，他们之间本质上是不会有交集的。换句话说，就是适用于监督学习领域的方法，是不太会在其它场景中有较好效果的。反过来，也一样。所以，上面问题的答案是：不行。

2.2 机器学习的步骤

机器学习的任务是输入一些数据，再输出一些数据，其就是一种数据转换器。从数学意义上讲，就是一个合适的函数映射。我们的目的是要找到一个可以完成任务的映射函数。如图2所示：¹

- 1) 第一步，定义一个函数集合 (Model, A set of functions)。这个集合中的每一个元素都是一个有确定参数的函数。
- 2) 第二步，因为要在此函数集合中选一个函数，所以要确定一个函数的挑选准

¹<https://datawhalechina.github.io/leeml-notes/>

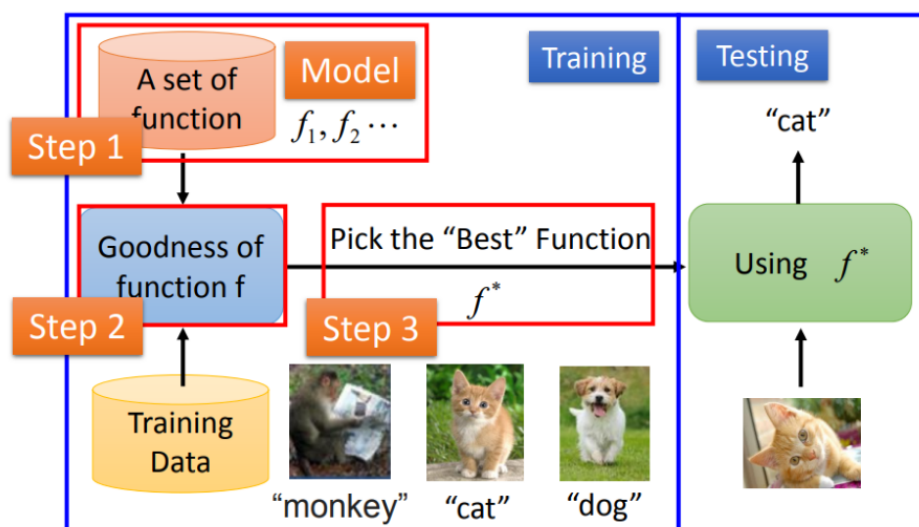


图 2: 机器学习的步骤

则 (Goodness of function f)。

- 3.) 第三步，在上述函数集合中，根据挑选的准则以及训练数据 (Training Data) 具体地找到那个函数 (Pick the best function)。
- 4.) 第四步，在测试数据 (Testing Data) 上测试，测试刚刚找到这个函数的效果。

前三步被称为训练 (Training)，最后一步称为测试 (Testing)。

打个比方，把大象放到冰箱里，也分为三个步骤：打开冰箱门，把大象赶过去，关上冰箱门。这里，我们也是三个步骤来搞定它。当拿到一个任务，确定输入数据和输出数据后，那么基本可以确定大的方向。然后，要设计一个函数映射的集合。在这个集合里，各个元素函数看起来大模样都差不多，只有参数的系数不一样。注意，这个集合里包含的函数通常有无穷多个。我们只能通过一个方法来描述这个函数，譬如说一个方程或是一个拓扑结构。接下来，我们的目的是挑一个好用的，合适的函数，所以要确定一个准则来判断，哪个函数好用。比如说，让所有训练用的数据使得函数映射的误差最小。最后，我们所要做的是根据准则找到一组具体的参数系数。当所有参数系数都确定下来的时候，即一个合适的函数映射也找到了。至此，训练过程也结束了。

通常，用深度学习方法来确定函数的形式，其并不是一个传统意义上的数学表达式或代数式子。它是一个用网络拓扑结构描述的函数映射关系。其参数数量一般都是几百万个。与之相对的，传统方法的映射函数所涉及的参数或系数数量级就小得多。一般就是几个，十几个，上百个系数的都不多见。这个设计函数集合的思路，初学的时候要特别注意。而且，传统方法中的参数一般会有明确的意义，或者说设计者会去

分析这些参数及系数的意义。但是深度学习中的参数第一太多，没法分析；第二，好像也分析不出来什么意义。

当前的学术界研究方向以及工业界的应用，也都是在这三个步骤中开展的。有的聚焦于设计函数映射集合；有的着重在设计误差准则；有的精力放在如何更快地、更方便地训练，找到那个合适的函数。每一步骤中推进，都会对任务的解决有帮助。其实，在工作中，如果最终实际应用效果不好（或称之为泛化能力不足），你努力的方向也是这三个方面。

3 周边的相关概念

3.1 概念之间的关系

编程与程序员：在一般的IT公司中，程序员只要基于常识性的知识就可以对业务理解，再辅以充足的时间和编程技巧，已经足够完成任务。而机器学习，其实是一种数据编程的思路，确定好一个函数的大模样，让程序通过数据自己去确定函数参数的具体值。

科学家与工程师：在一般人的想象中，科学家更喜欢纸上谈兵，就是发文章，写书籍。但是当前，在机器学习领域，一流的科学家是写代码的。他们也是一流的工程师。如果你仔细翻看大牛们简历，他们写的代码又多又好，都是动手能力超强的人。如卷积神经网络的发明人 Yann Lecun，是 Djvu Viewer 的软件作者。吴恩达开发过 Citeseer 搜索引擎的代码。

学术界与工业界：学术界与工业界紧密分工合作关系 系统研究者负责构建更好的工具，统计学家建立更的模型，分工也使得深度学习可以更快地发展。同时，与传统行业的技术封锁相比，机器学习领域的研究人员，受互联网开源思维的影响，他们对自己的算法、数据和成果一向采取开放的态度。各个国家，各个公司的研究团队一起参加比赛，并相互切磋，追求的是共同的进步。

算法与数据：优秀的算法、快速而廉价的算力、大量的数据以及方便好用的软件工具，使得机器学习可从学术界的纸上谈兵开始走向商业中的产品。

3.2 相关的人物

在机器学习的领域，杰出人物极多。我个人认为，下面三个人可以简单介绍一下。

Jeffrey Hinton，其贡献在于设计优秀的机器学习算法。其提出了在深度学习的网络中，使用降维和逐层训练的方法及应用的办法。他解决了优秀的算法应该如何做

的问题。¹

吴恩达，其贡献在于基于 GPU 的算力的推广。他极力推广 GPU 在机器学习中的应用。最终使得 GPU 被广泛地应用在机器学习领域，并使得 Nvidia 一个原本生产游戏显卡的硬件公司，在机器学习领域占了一席之地。²

李飞飞，其贡献在于对大量数据的理解和实践。其创建的 ImageNet，人工标记了 1400 万张图片，使得算法研究者终于相信，大量数据的输入会使得算法的效果得到惊人的提升，证明了数据与算法是同等重要的。³

3.3 人工智能的派别

人工智能的目标是让机器通过某种方式具备了类似于人类的智慧。而这种方式，自打这门学科创立以后，有两个派别：

- 1) 唯物主义派，其核心思维是重建人类的大脑。我们要造一个可以模拟大脑神经网络的机器或是程序。先别管为啥大脑长这个样，然后，用大量的数据去让这个机器自己去学就好了。比如，想让它识别猫狗问题，就搞大量的标注后的猫狗图片输入机器，然后机器就学会了识别猫狗。尼克在他的书中称之为「吃啥补啥」[2]。
- 2) 唯心主义派，其核心思维是，我们要根据已经证明「正确的逻辑系统或基于规则式的方法（rule-based）和符号系统（symbolic systems）」，将相关领域的人类专家智慧写进软件，进而搭建一套智能系统。其强调要顶层设计，至顶向下，仔细规划和理解系统中每一个部分。然后，上线运行，一定能OK。此派又戏称为「想啥来啥」。

两派长时间论战，各自都有道理。唯心派批评唯物派，只模仿不理解。就像学开车，会开却不理解。啥都不懂，有啥用？要对其中发动机原理，机械传动要门清，否则出了问题都不知道是哪里的问题。没有才是专家教授应有的样子。唯物派批评唯心派，你们的模型太简单，处理不了实际的复杂问题，有啥用？形势情况比人强，能用再说，以后再慢慢琢磨其中的原理。当然，如果两条腿走路那就是最好不过了。

4 回归分析

¹这里小八卦一下，Hinton 是布尔代数的创始人布尔的后代。Hinton 的姥姥的妈妈，是布尔的亲闺女。

²吴恩达曾在斯坦福大学建立了一个超级大的神经网络，有112亿个参数。如此规模的网络，也必须使用 GPU 才行。

³李飞飞 1999 年大学毕业后，在中国西藏做过一年的医学药物研究。

5 增强学习

增强学习有两个理论基础：

1.) 马尔可夫决策过程

2.) 动态规划

(未完待续)

致谢

本文档承蒙好友 Hyde 对初稿给出的建设性意见，使文档的质量与可读性有了质的提高，在此表示十分感谢！¹

参考文献

- [1] This Person Does Not Exist. <https://thispersondoesnotexist.com/>
- [2] 尼克. 人工智能简史. 人民邮电出版社, 2017
- [3] Khalid Sayood. 数据压缩导论. 人民邮电出版社, 2014.
- [4] Ian Goodfellow and Yoshua Bengio et.al. . Deep Learning. MIT Press, 2016.
- [5] 阿斯顿·张, 李沐等. 动手学深度学习. 人民邮电出版社, 2019.
- [6] Hung-yi Lee. Machine Learning. https://www.youtube.com/playlist?list=PLJV_e13uVTsPy9oCRY30oBPNLCo89yu49.
- [7] 李飞飞. <https://zh.wikipedia.org/wiki/%E6%9D%8E%E9%A3%9B%E9%A3%9B>

(THE END) ■

¹本文档中出现的图片除ML相关的图片为作者手工绘制以外，其余的只是学习时，从互联网上搜索得到，当时未存留原始的一些标记信息。所以，当前还不能准确地标注每幅图片的出处与原始作者信息。在此，首先衷心地感谢这些图片的原始作者，正是他们精致且恰当的图片使得本文档得以顺利完成；其次，在后面的写作更新中，我会逐步找到它们的原始出处，并在此文档中标注出来。