

简介 机器学习

苑明理
2016年11月

内容

- 引：数据传奇
- 起：基本概念与技术
- 承：人工神经网络
- 转：对玩具模型的理论探讨
- 合：组合、增强、对抗
- 尾：一个观察和猜测

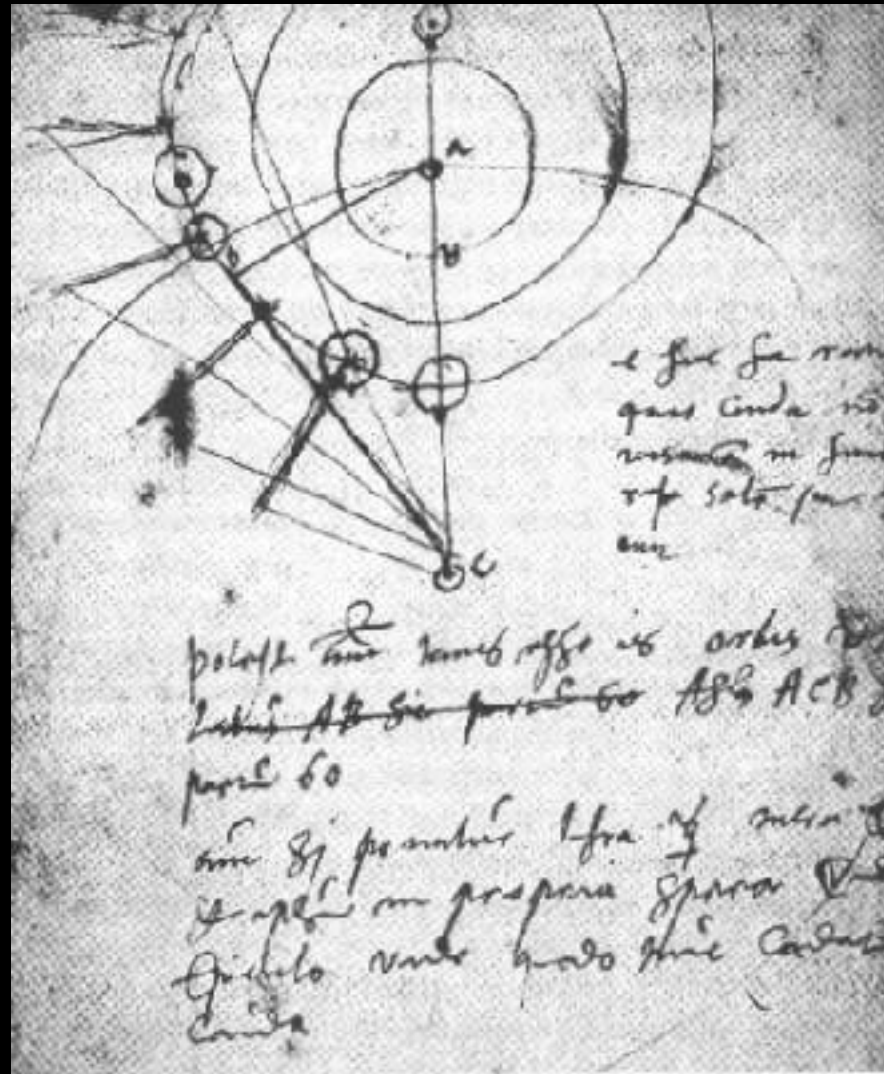
引子

数据传奇







第谷·布拉赫




彗星观测手稿



中世纪的
地心说宇宙观



第谷在汶岛建立的两个
天文台之一



当时的观测仪器

Prosthaphaeresis：当时最新先进的算法

第谷搜集了大量的数据，并采用了当时最先进的计算方法和星体运行理论，来整理这些数据，制定星表

第谷采用 Prosthaphaeresis 来快速查表计算乘法，25年后的 1614 年，纳皮尔发明对数后，该方法逐渐被抛弃。


求 105 和 720 的乘积

1. 缩小：0.105 和 0.720
2. 求反余弦： $\cos(84^\circ) = 0.105$, $\cos(44^\circ) = 0.720$
3. 求角的和差： $84 + 44 = 128$, $84 - 44 = 40$
4. 查表求余弦平均： $\frac{1}{2}[\cos(128^\circ) + \cos(40^\circ)] = \frac{1}{2}[-0.616 + 0.766] = 0.075$
5. 放大：75,000.
6. 验证：75,600.



约翰内斯·开普勒

1596年著作《宇宙的奥秘》中的宇宙观
优美但和精确的观测不符合




1601年第谷去世，作为助手开普勒拿到第谷搜集的大量的数据

1609年行星运动的开普勒第一、二定律发表

1618年行星运动的开普勒第三定律发表

1643年天文学家发现开普勒定律可以解释木星卫星的运动

1687年牛顿的《自然哲学的数学原理》发表，完整表述了万有引力理论



传统学科的范式

广义相对论

原理

牛顿万有引力

动力学

开普勒行星运动定律

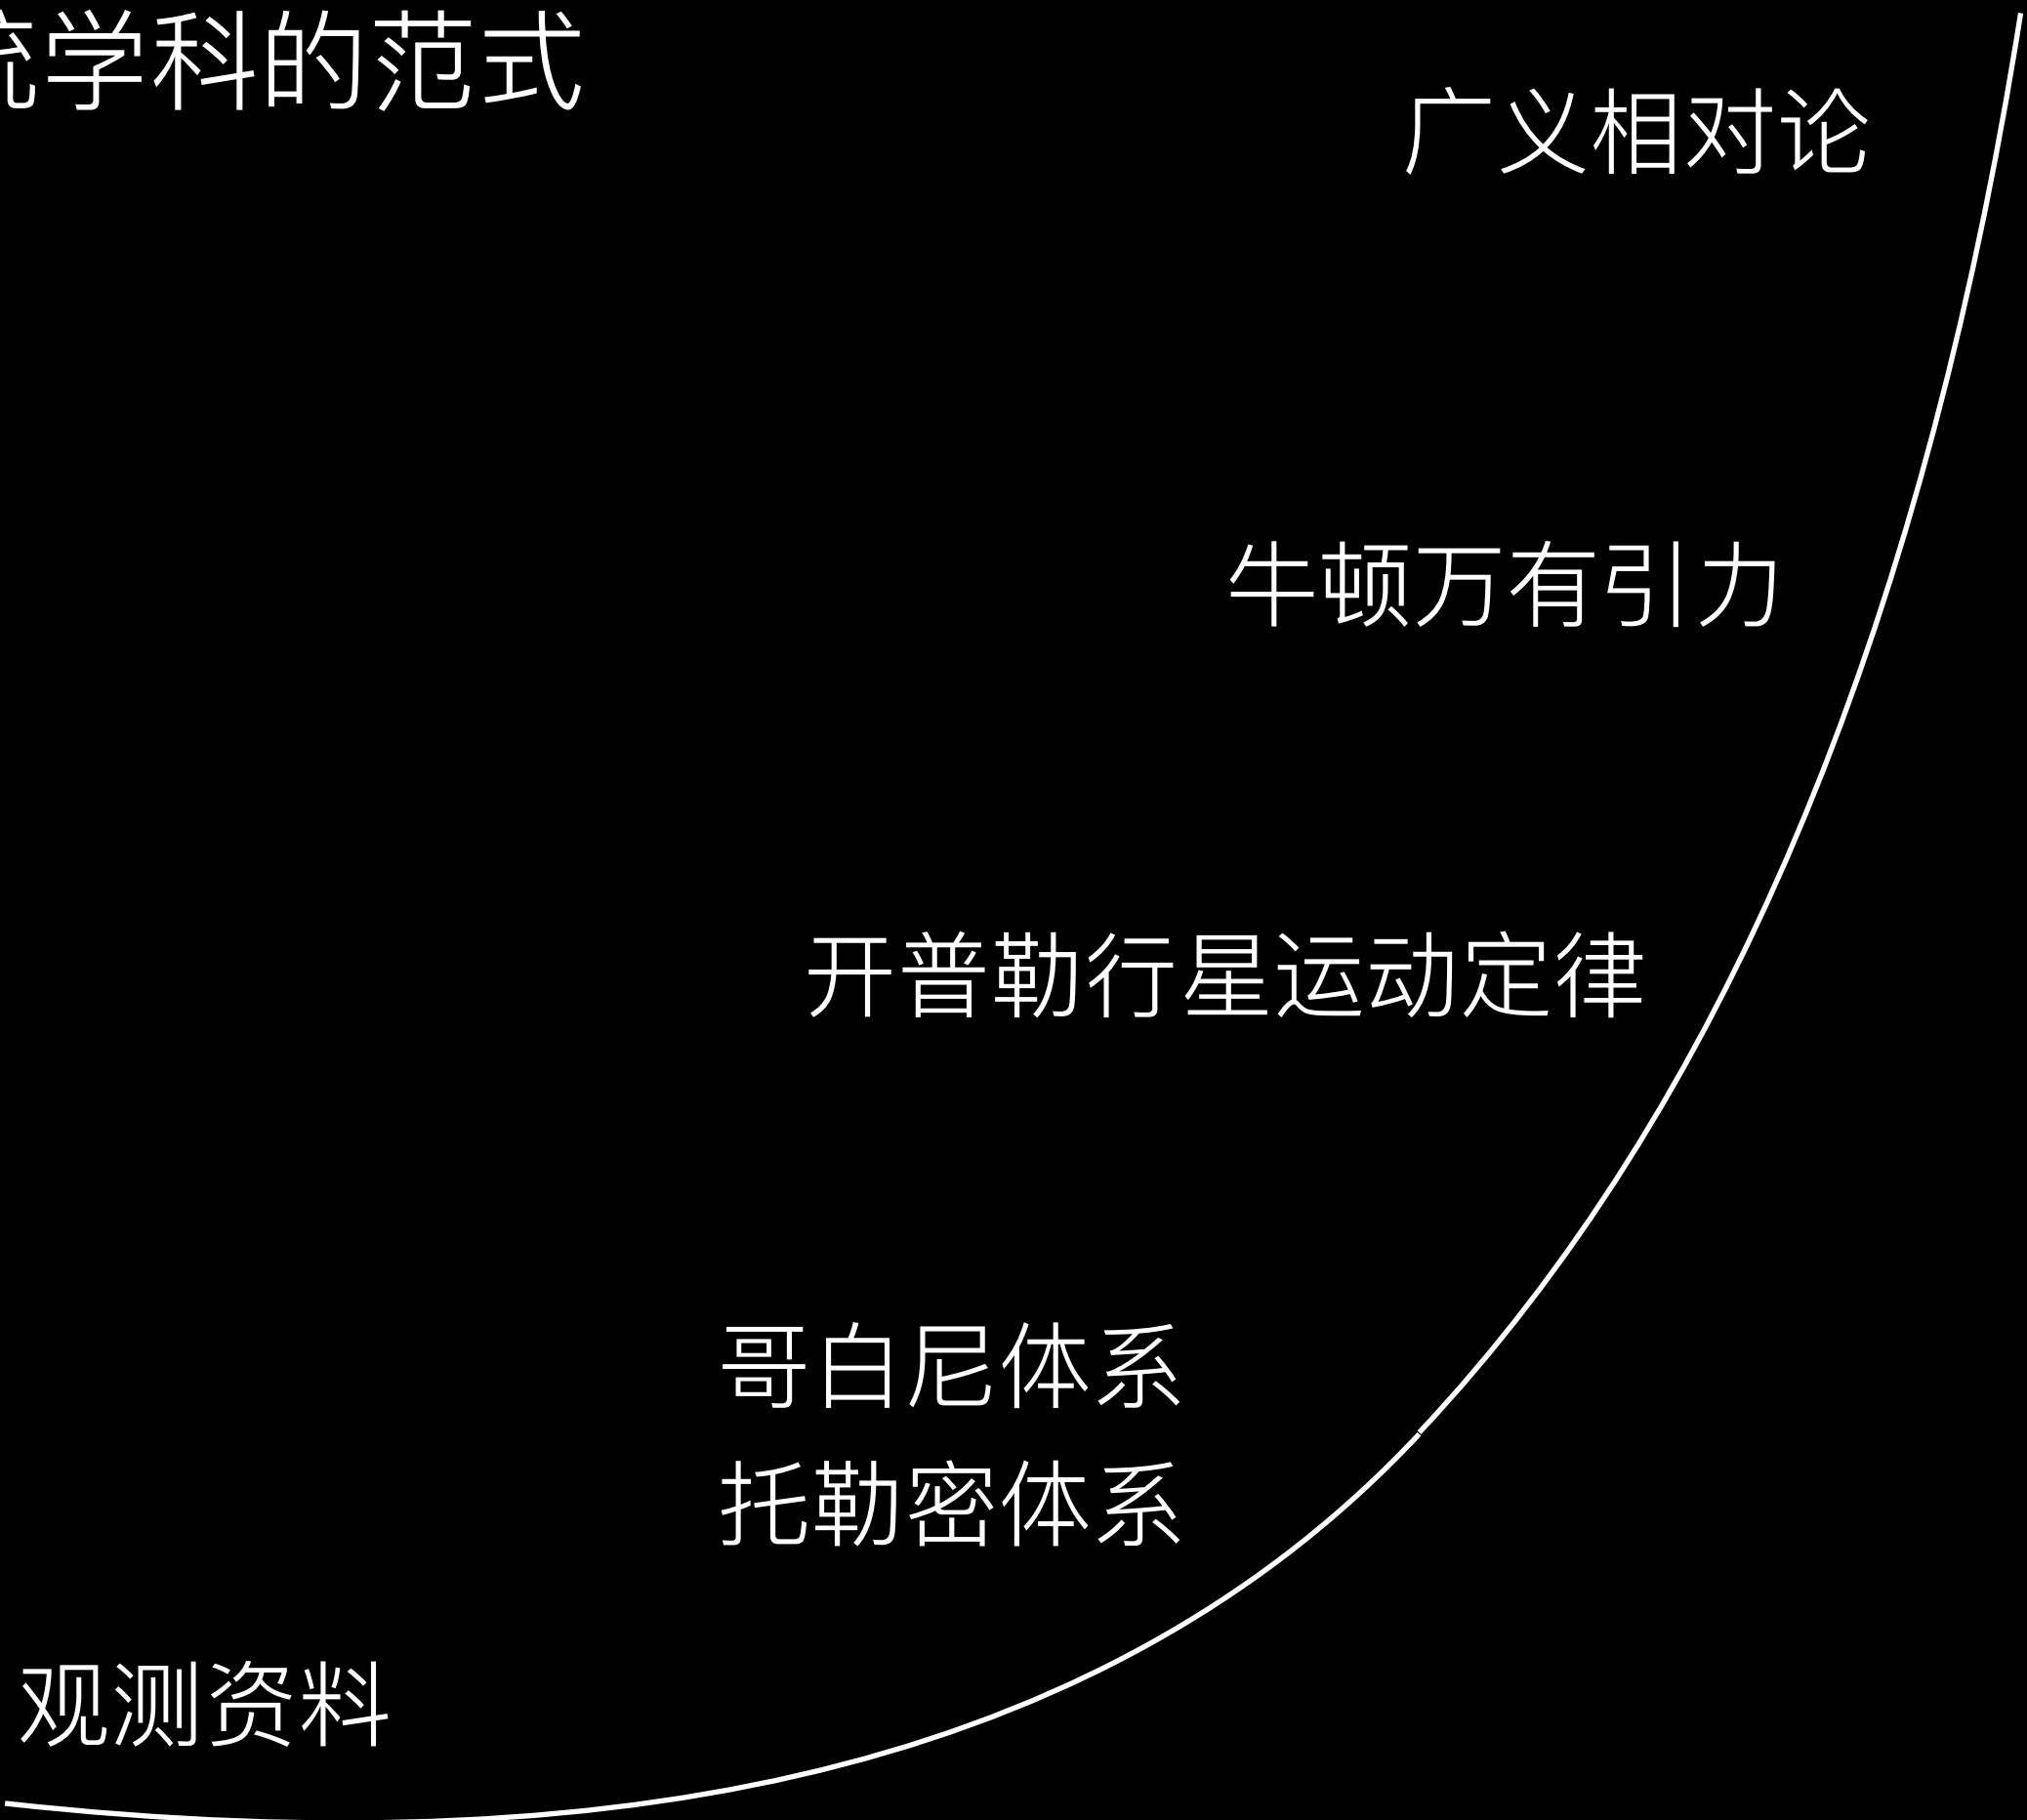
定律

哥白尼体系
托勒密体系


模型

观测资料

数据



- 数据科学带来范式的转变？
- “假设导向”向“数据导向”转变
- 端到端的机器学习，不考虑机理



起

基本概念和技术

具体的一些问题

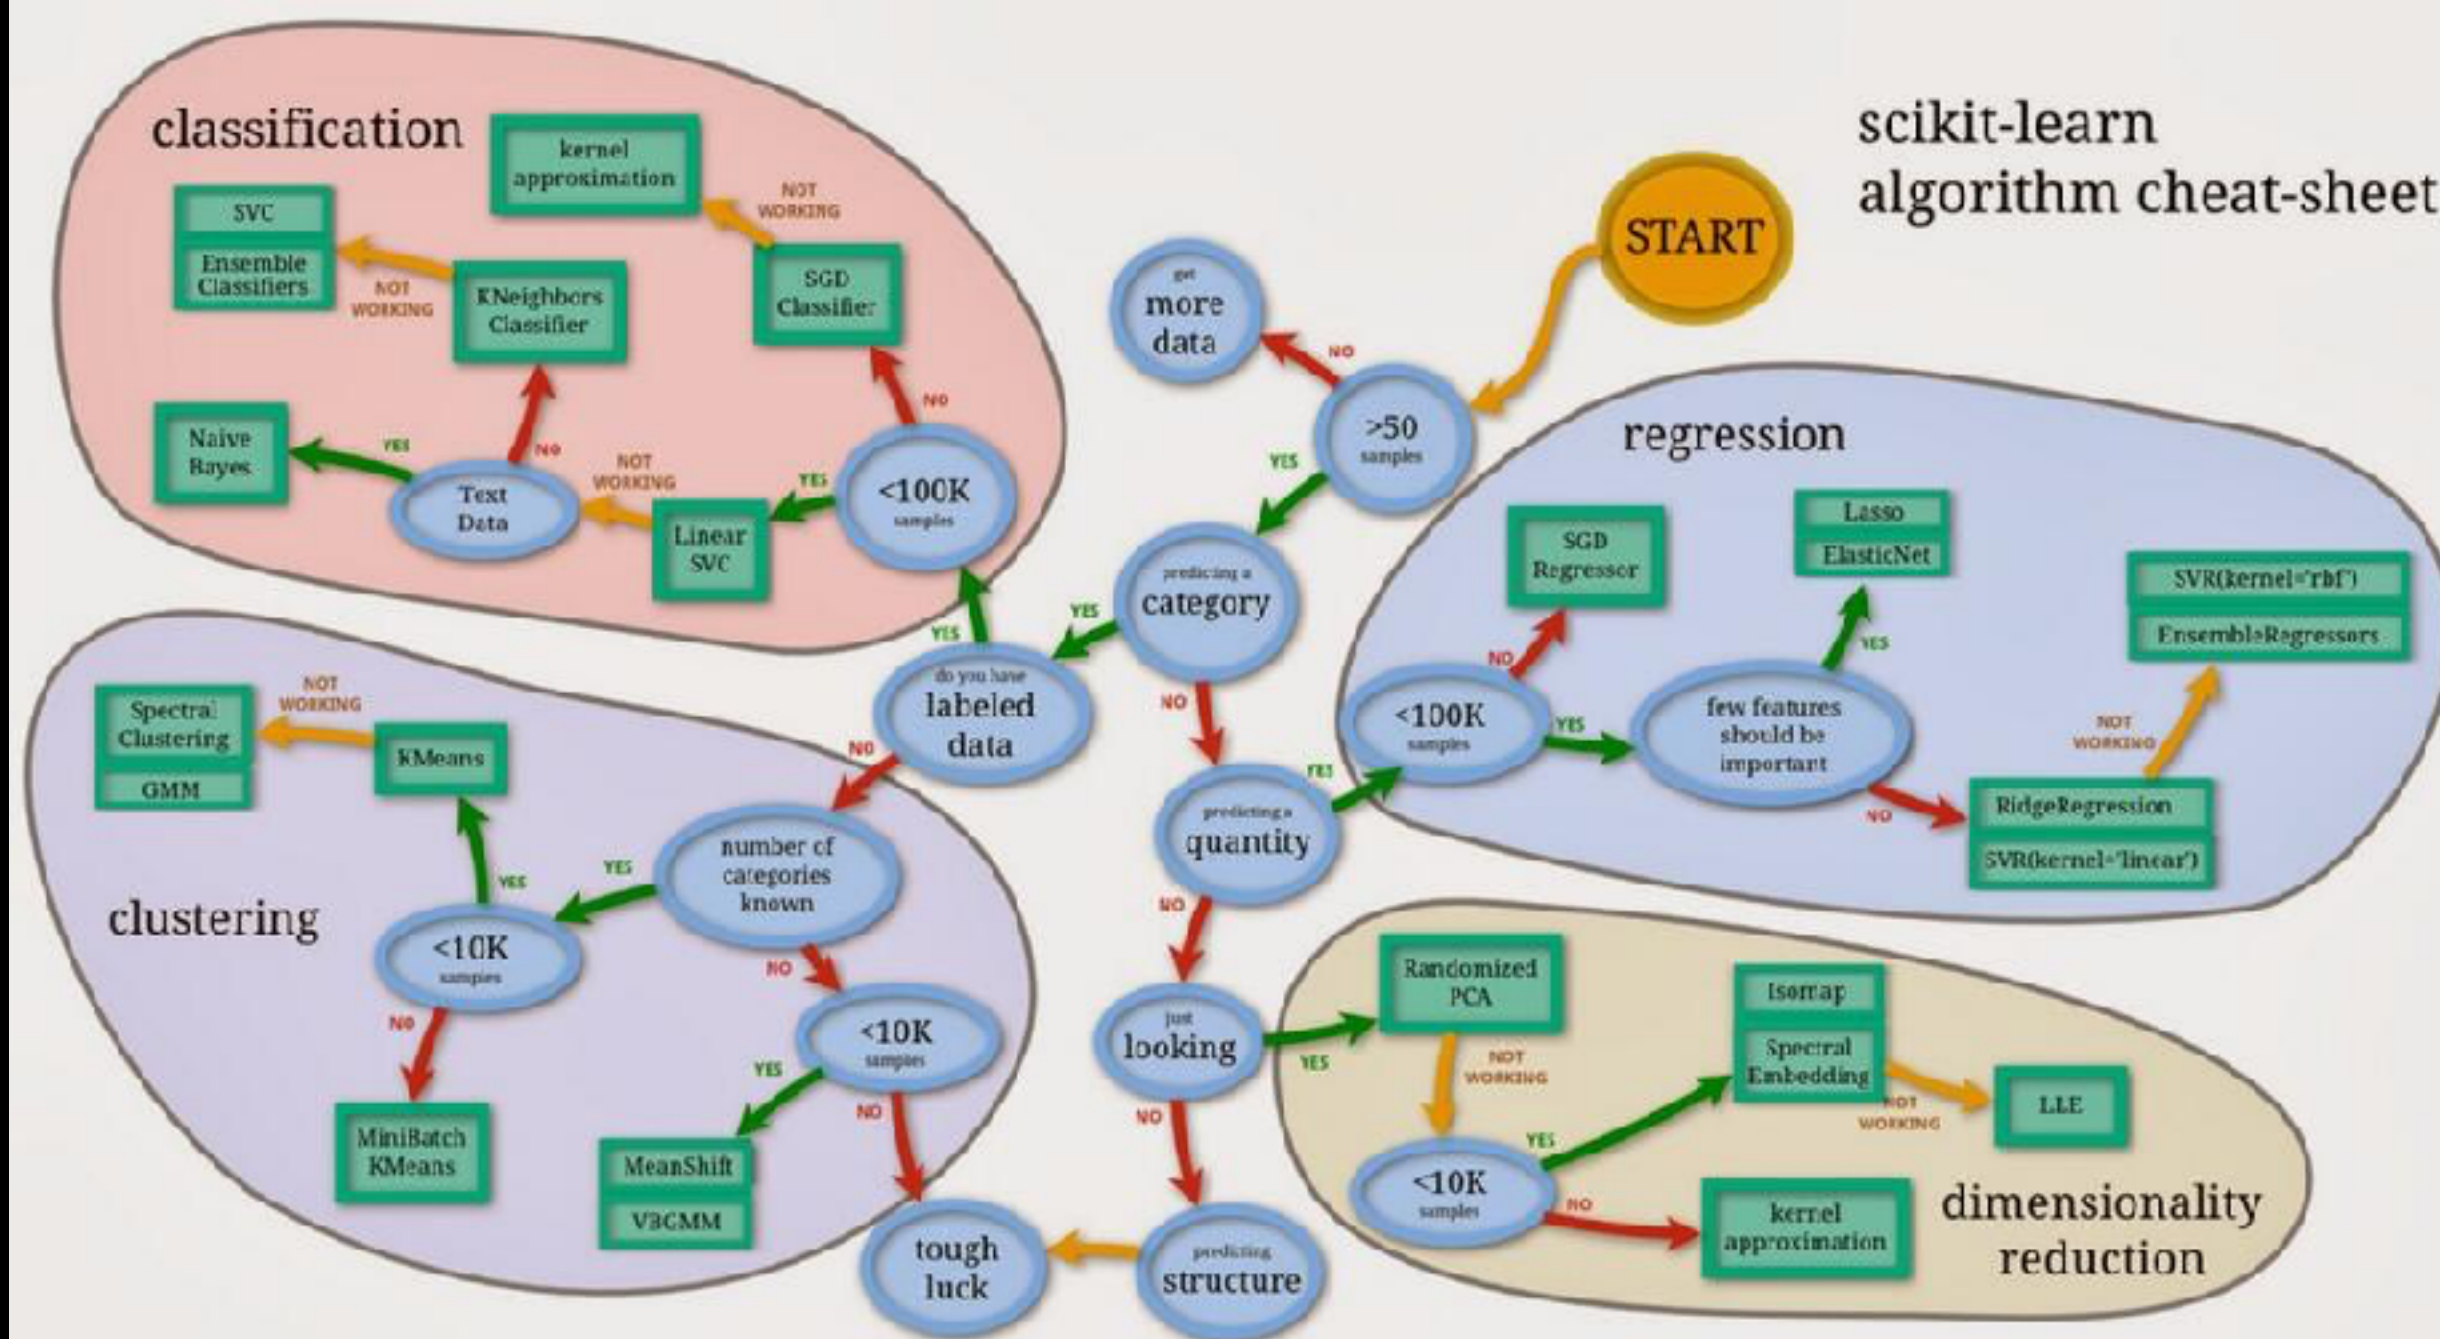
- 找出垃圾邮件
- 快速判断邮箱地址是否重复
- 汉语句子分词
- 推荐类似于这篇文章的其他文章
- 寻找天气变化曲线的简短表示
- 寻找降雨的模式并作预报


问题的类型

- 聚类
- 分类
- 回归
- 表示
 - 降维表示
 - 稀疏表示
- 检索
 - 重复、相似
 - 异常

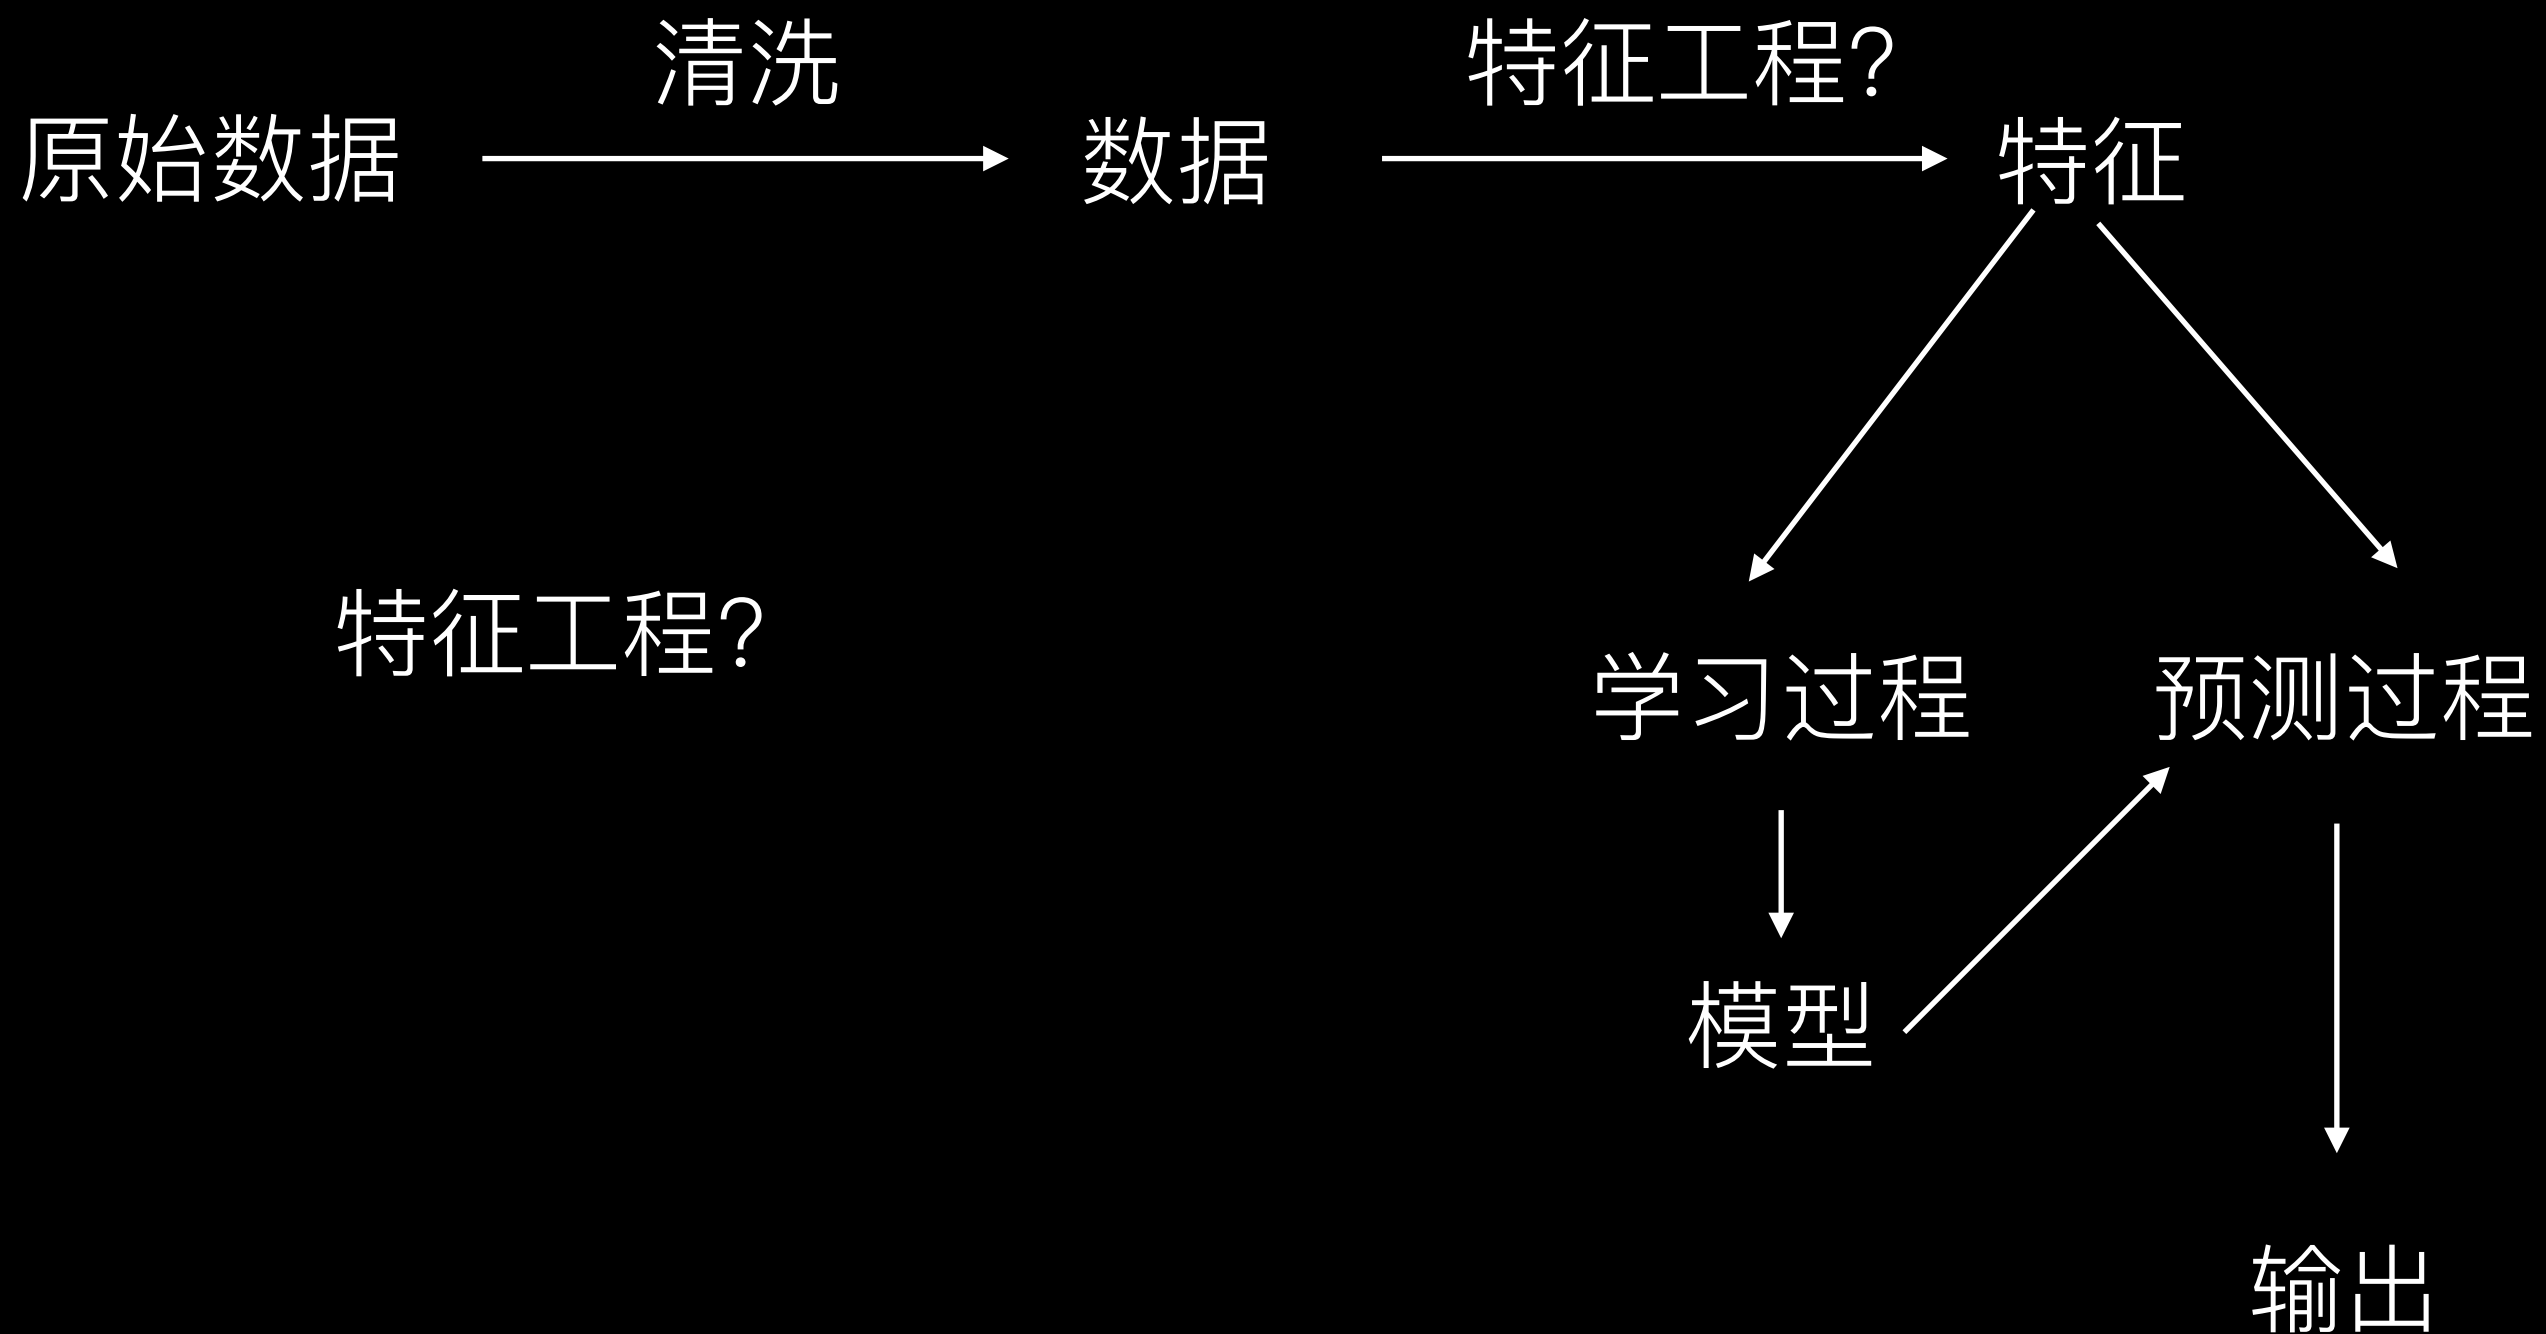
有监督、无监督、半监督

scikit-learn algorithm cheat-sheet







数据流




数据清洗不简单




特征




Spectrogram




MFCC



Flux




ZCR



Rolloff

致敬 AlphaGo




15刺，再次震惊世界！好俗的一手，几乎所有的围棋老师都会告诉你，这步棋不好，如果你下了，首先你会受到老师的批评，可是AlphaGo永远不会在乎别人的评价。

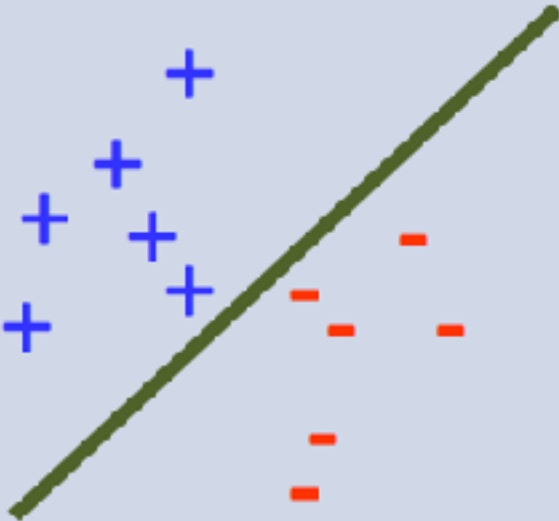
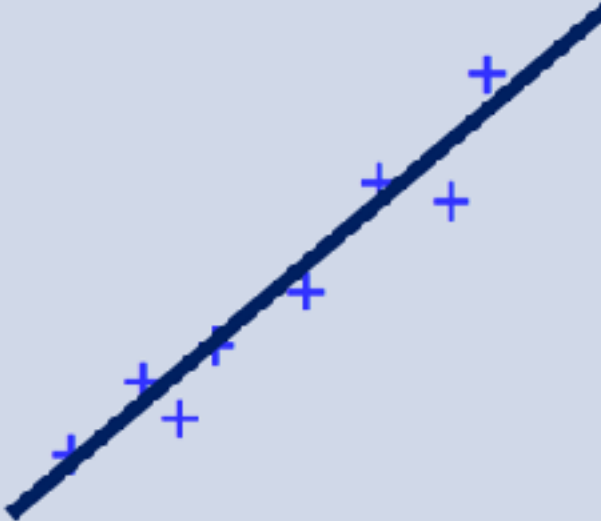
在提高围棋水平的路上，我们都需要经历学习的过程，学习定式、布局、棋形、方向等等，当我们掌握了这些知识，我们还需要学会灵活运用这些知识，可是要想达到宗师级的水平，这还不够！因为在学习的过程中，学习到的东西也同时束缚了我们的创造力，所以真正的挑战是摆脱所有之前知识的束缚，将自己的思想融入到棋里，摆脱所谓的“对”与“错”的观念，从而寻找围棋本质的东西，即子与子之间的联系与作用。或许这样才会达到我们所说的无招胜有招的境界吧。

过拟合、泛化能力

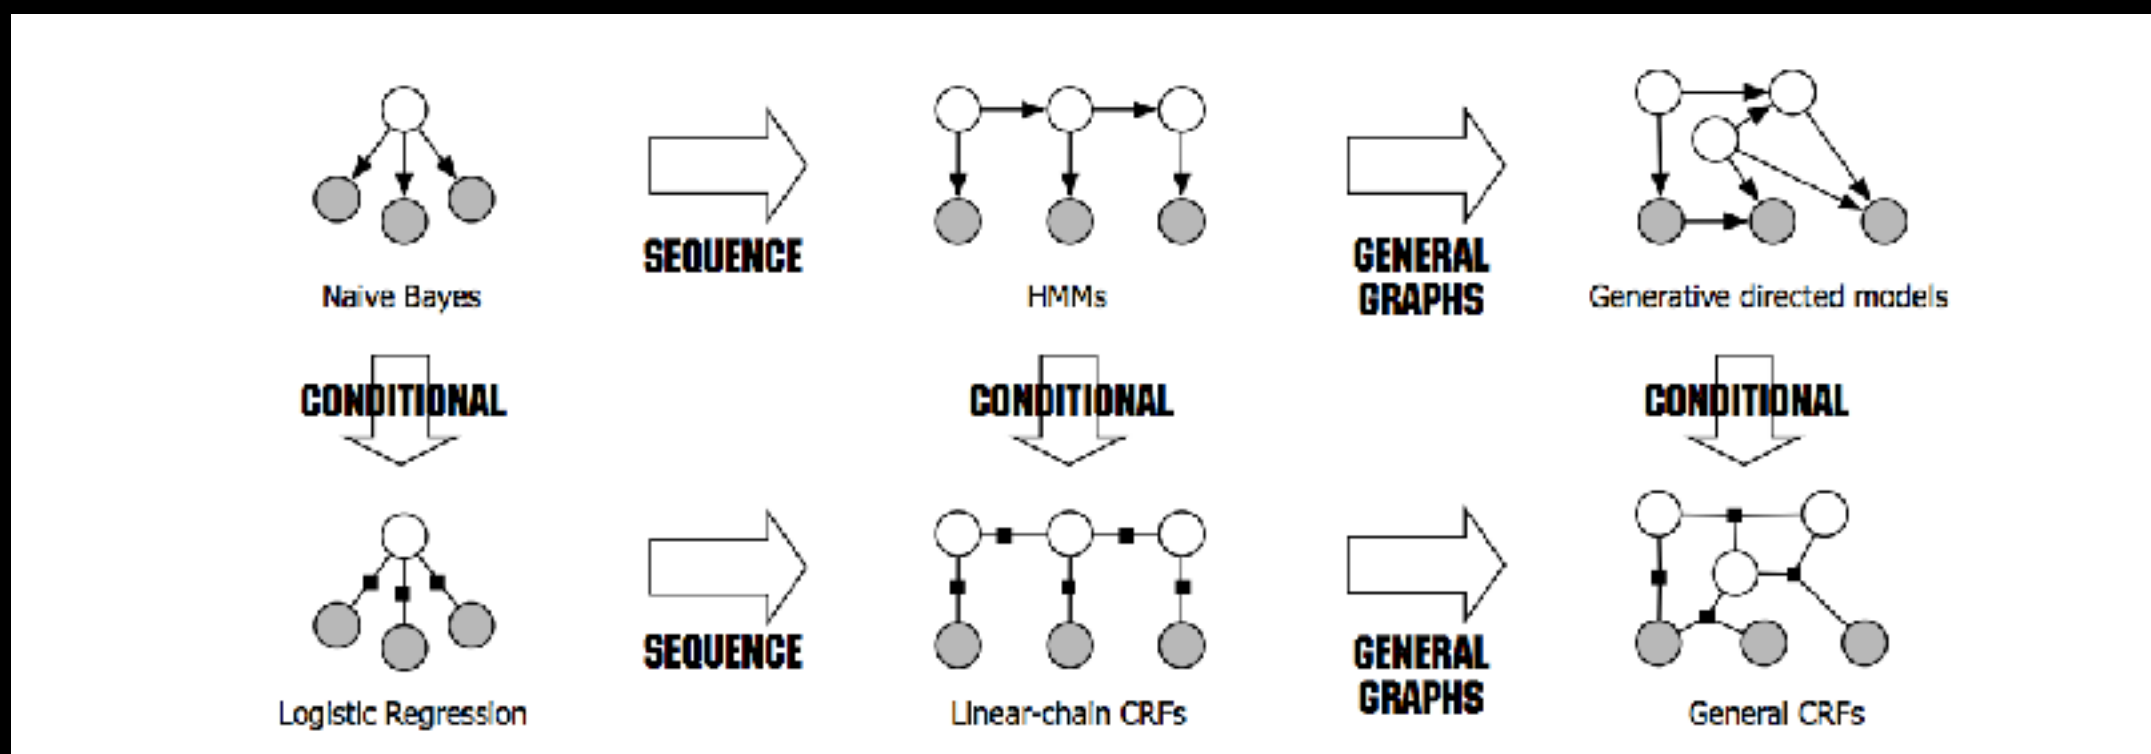
- 人类的小孩见到几只猫就认识了猫这种动物
- Google Brain 认识猫需要成千上万的例子
- 同 AlphaGo 的对弈显示人类策略过拟合
- 有迹象显示一些“俗手”在后来的对弈中发挥了效果
- 人类通过概念、推理来思考有很强的泛化能力
- 但在算力有限的情况下，人类生成的有效实例少，容易过拟合




线性模型

CLASSIFICATION	REGRESSION (THIS TALK)
	
<ul style="list-style-type: none">• Decision tree• Linear Discriminant Analysis• Neural Networks• Support Vector Machines• Boosting	<ul style="list-style-type: none">• Linear Regression• Support Vector Regression

概率图模型



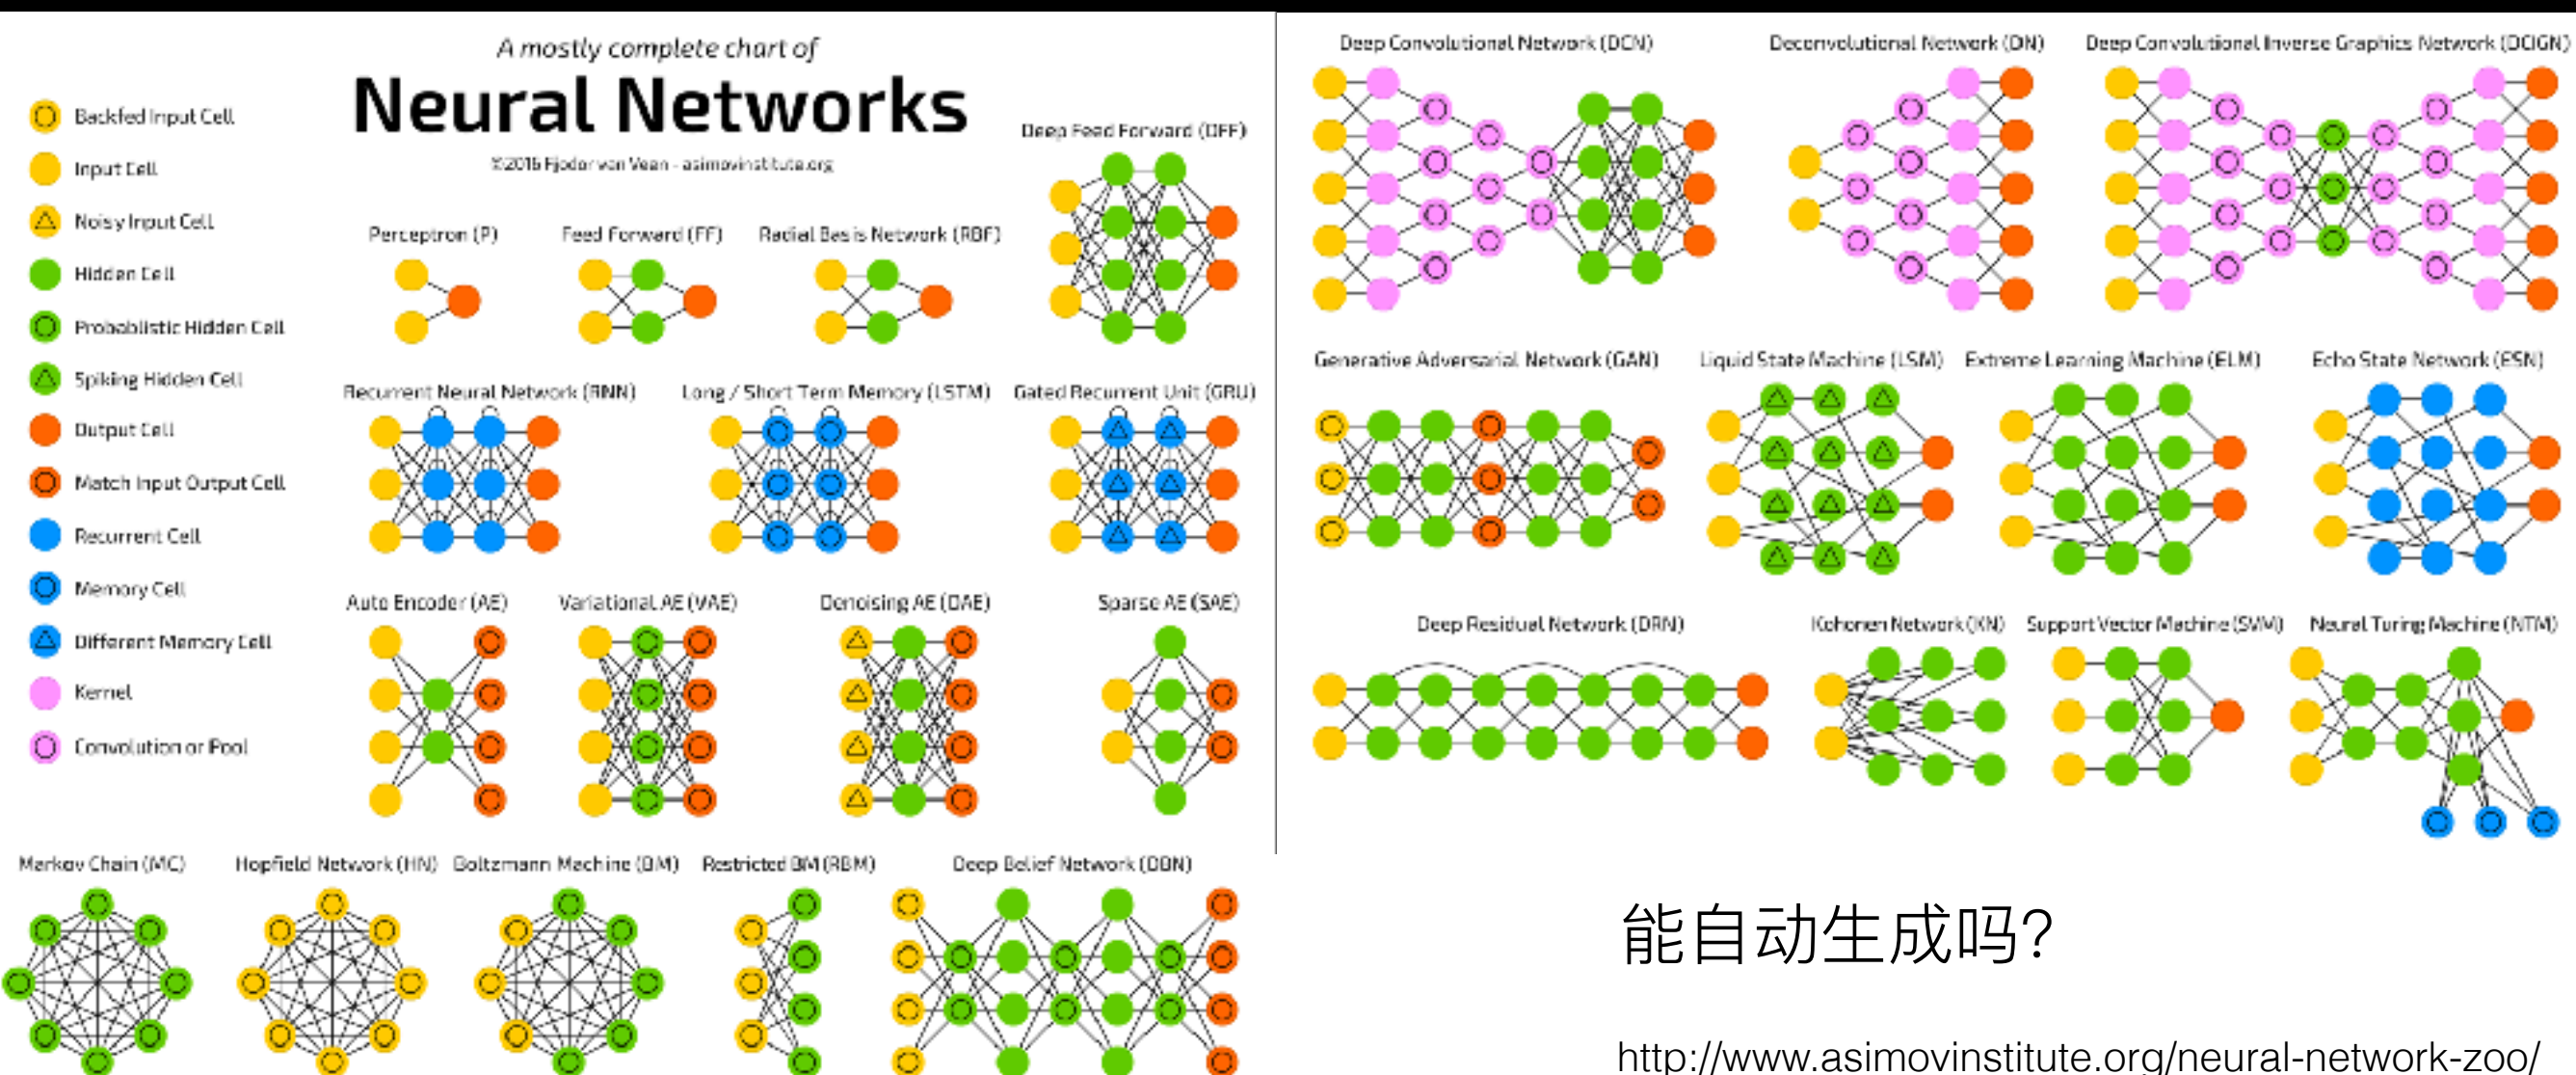
神经网络模型



承 人工神经网络



神经网络动物园

问题：为什么那么多种类？
传统的特征工程变成了网络结构工程？




能自动生成吗？

MLP



ReLU



Dropout

- 计算下层时依照概率只有一部分起作用
- 抽样的思想
- 可以用来对抗过拟合

自动微分 (AD)



- 不是符号微分，也不是数值微分
- 函数复合下的链式法则有关系
- 是深度学习依照梯度下降来优化的技术基础

Forward

$$\frac{\partial y}{\partial x} = \frac{\partial y}{\partial w_1} \frac{\partial w_1}{\partial x} = \frac{\partial y}{\partial w_1} \left(\frac{\partial w_1}{\partial w_2} \frac{\partial w_2}{\partial x} \right) = \frac{\partial y}{\partial w_1} \left(\frac{\partial w_1}{\partial w_2} \left(\frac{\partial w_2}{\partial w_3} \frac{\partial w_3}{\partial x} \right) \right) = \dots$$

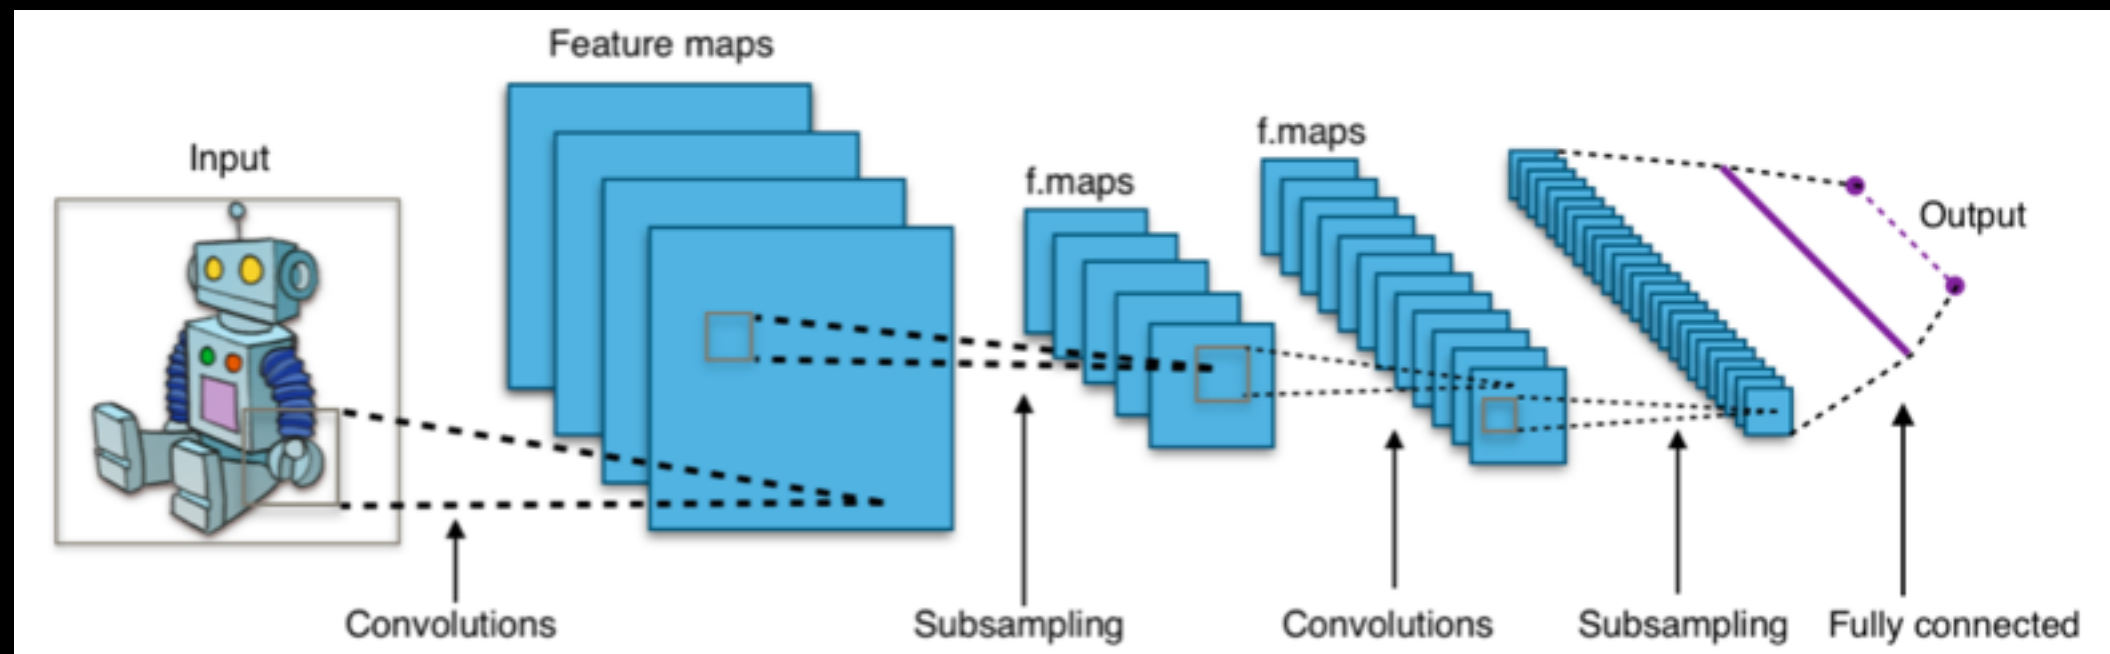
Backward

$$\frac{\partial y}{\partial x} = \frac{\partial y}{\partial w_1} \frac{\partial w_1}{\partial x} = \left(\frac{\partial y}{\partial w_2} \frac{\partial w_2}{\partial w_1} \right) \frac{\partial w_1}{\partial x} = \left(\left(\frac{\partial y}{\partial w_3} \frac{\partial w_3}{\partial w_2} \right) \frac{\partial w_2}{\partial w_1} \right) \frac{\partial w_1}{\partial x} = \dots$$




CNN

- 考虑了空间区域的平移不变性



RNN

- 考虑了时域上的平移不变性



DiffNN (ongoing)

- 把短临降水的动力学简化为一种二维的唯像流动模型

风场模型 用 NN 刻画的复杂模式

$$\frac{dp}{dt} = \frac{\partial p}{\partial t} + (\vec{w} \cdot \nabla)p$$

生消过程


用 NN 刻画的复杂模式

当地预报

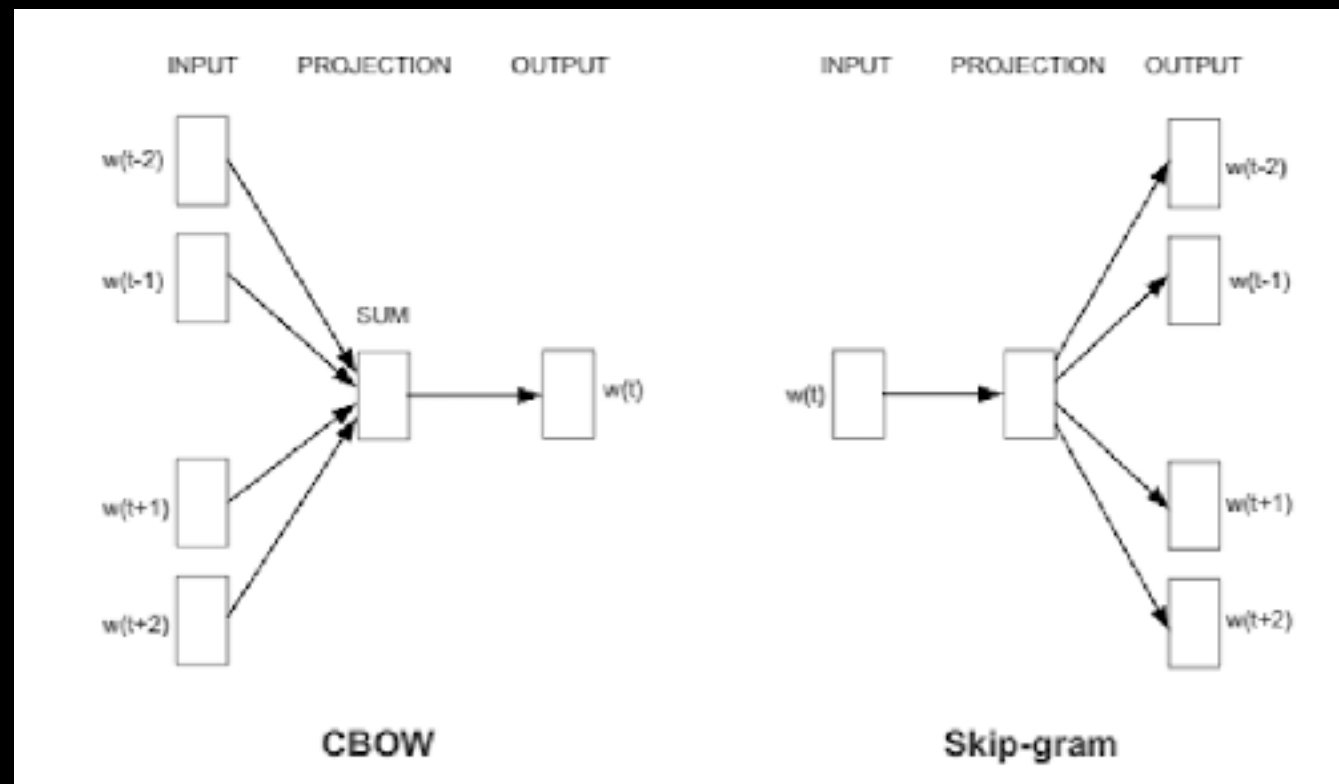
用PDE刻画的严格关系

输送过程

用PDE刻画的严格关系



词嵌入模型的正则性



king:queen ~ man:woman
house:roof ~ castle:dome
knee:leg ~ elbow:forearm

转
对玩具模型的
理论探讨


巨石阵与神谕机



本节基于 Edwin J Beggs 等人的论文的一部分

Unifying science through computation: Reflections on computability and physics


巨石阵不是一次建成的
而是在几千年时间里多次建造
巨石阵一大约建于公元前3100年




本节讨论聚焦在
巨石阵一的 Aubrey 洞
共有 56 个
对此有天文学的解释

<http://en.wikipedia.org/wiki/Stonehenge>
http://en.wikipedia.org/wiki/Aubrey_holes

- 基于 56 的日食预测方案
 - 太阳的运动周期 $365.26 \text{ day} \approx 364 = 56 * 13 / 2$
 - 月亮的运动周期 $27.32 \text{ day} \approx 28 = 56 / 2$
 - 沙罗周期 $18.61 \text{ yr} \approx 18.67 = 56 / 3$





- 每年夏至太阳会从 Heel 石的方向上升起
- 可通过 Heel 石的观测来修正代表太阳运行的标志

从计算的观点看：

带神谕的计数器自动机



讨论一

- 自然规律：天体运行的周期性
- 此处的自然规律是否具有可计算性？
 - 受制于我们观测仪器的精度，无从解答这个问题
- 有限状态的图灵机无法表达周期性的不可公度关系，会遇到误差的不断积累
- 神谕图灵机可以良好的工作
 - 神谕修正了误差，消除了不可预测性

事件序列

- 人类历史早期以天文事件作为计时工具
- 引入记号：日出 S，日落 s，月出 M，月落 m，日食 E，月食 e
- 有天文事件观测序列 SMEsmSMsm.....mSMs.....
- 有了机械计时工具之后，可以定义时刻，于是有
- 00010203040506S07M08091011121314151617sm192021222300
- 问题：我们能通过观测的事件序列，学习出来大自然的规律吗？

简化版问题

- 考虑周期 1 和周期 $\sqrt{2}$ 的事件的混合序列

0, 1, 1.414, 2, 2.828, 3, 4, 4.243, 5, 5.657,

1, 1, 0, , 1, 0, , 1, 1, 0, , 1, 0, ,

eureka! we found it!

But

11010, 11010, 11010, 10

11010,11010,11010,10,11010,11010,10

11010,11010,11010,10,11010,11010,10,11010,11010,11010,10,11010,11010,10,11010,11010,11010,10,11010,11010,10

□ □ □ □ □ □ □ □

[illegible]

Sturm 字有上下文无关文法

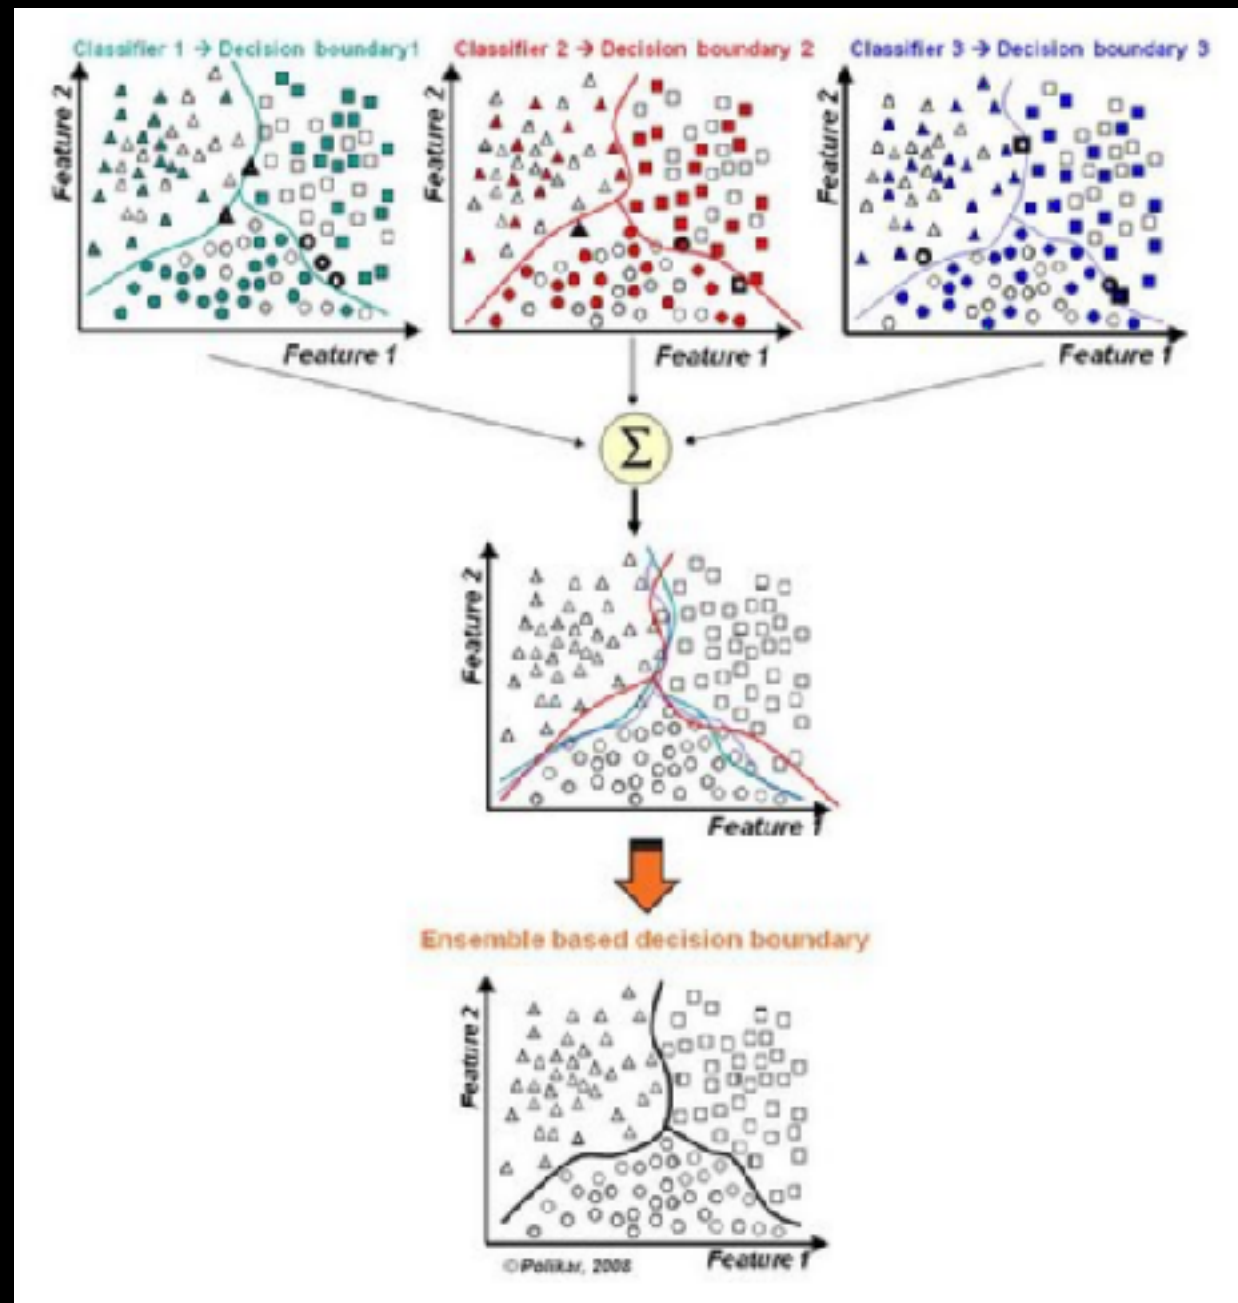
Gold 的可学习性

- Gold, E. Mark (1967). "Language identification in the limit"
- 不存在学习到超有限语言集合的算法。这意味着什么？
- Gold 的可学习性太强；
- 但在哪种可学习性之下，能学习到上下文无关文法的算法是存在的？

合

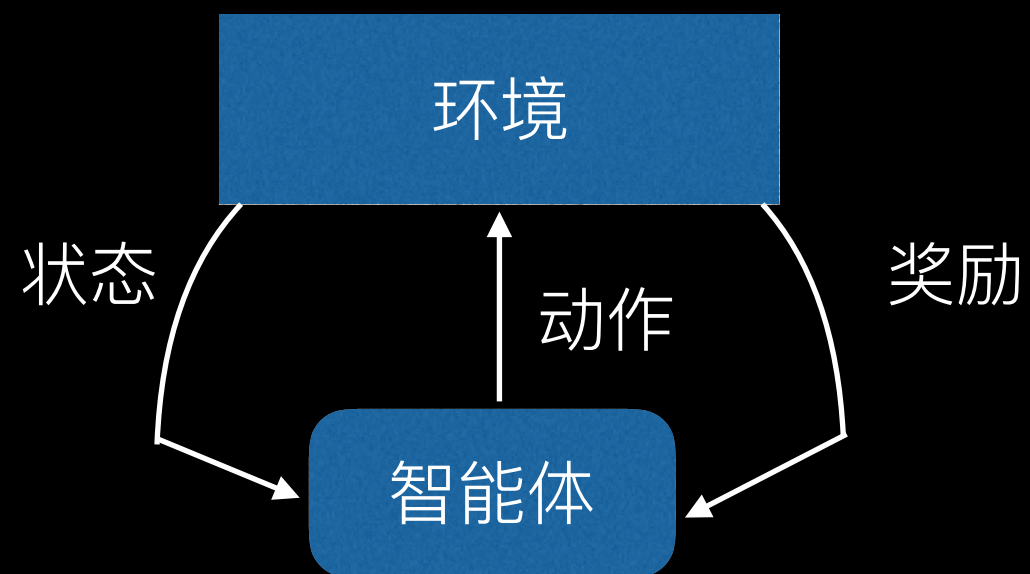
组合、增强、对抗

集成学习



- 组合多个基学习器来提升学习效果
- 相同数据不同学习方法的组合
- 不同数据的融合，如音频、视频
- 一些特殊的组合方案
 - Bagging
 - Boosting
 - AdaBoosting
 - Stacked Generalization
- 组合方案与基学习器无关

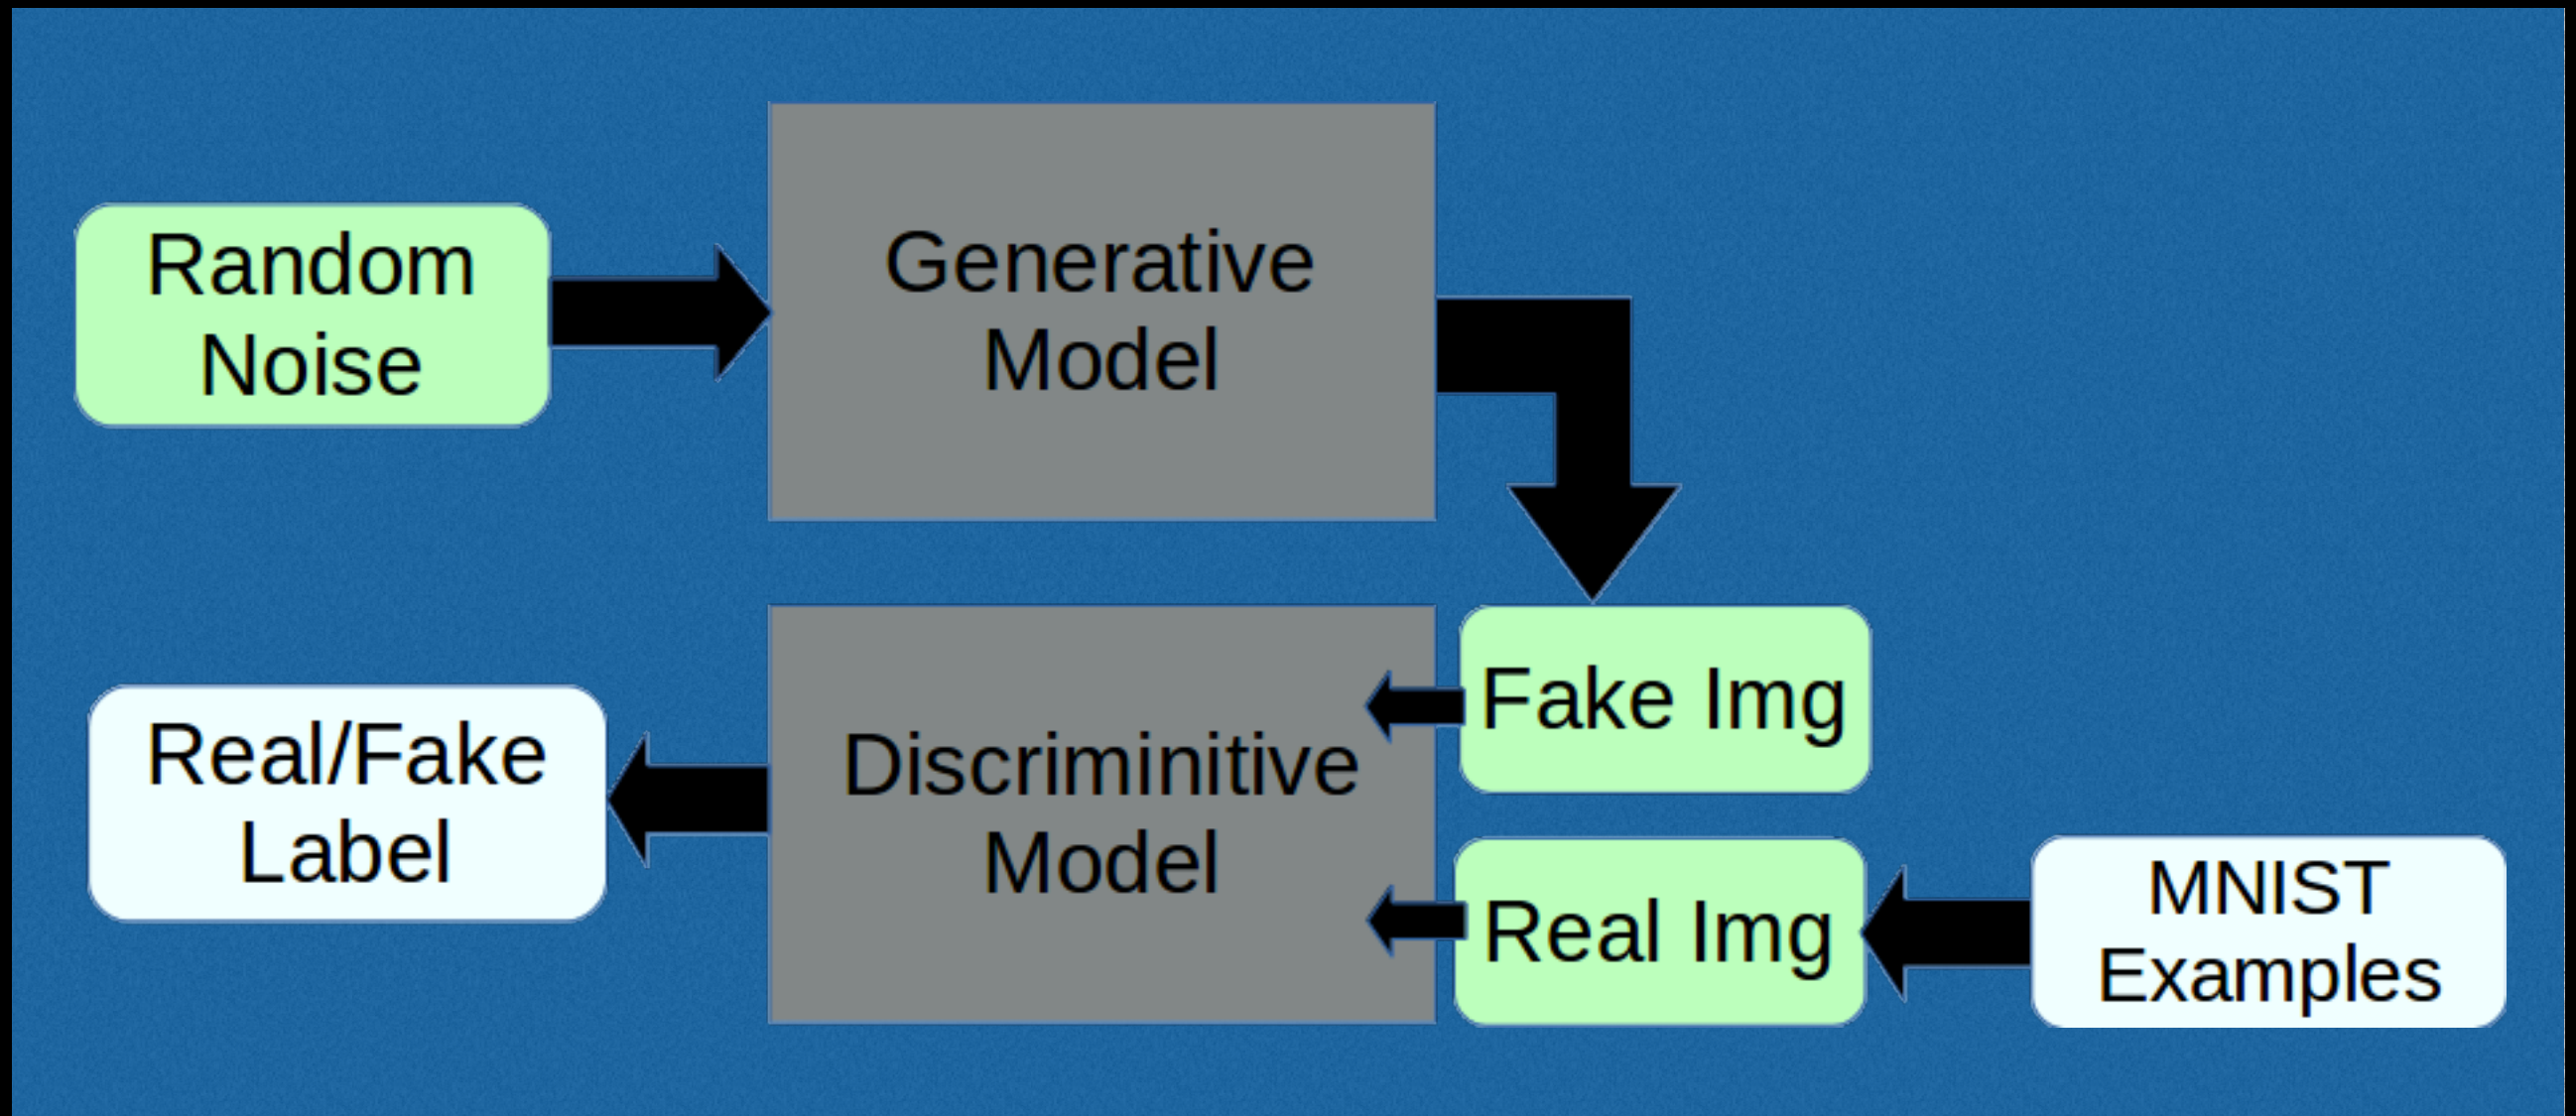
强化学习



Starting out - 10 minutes of training

The algorithm tries to hit the ball back, but it is yet too clumsy to manage.


对抗生成网络



尾声

一个观察和猜测

流体智能与晶体智能




Raymond Cattell

- 流体智能 (Fluid Intelligence) :
 - 解决从未见过的问题的能力
 - 灵活性
- 晶体智能 (Crystallised Intelligence) :
 - 使用已有知识和技能的能力
 - 稳定性

皮亚杰的理论

- 图式 (Schema)
 - 个体知觉、理解和思考世界的方式
- 同化 (Assimilation)
- 整合外部要素进入自己内部结构中
- 顺化 (Accommodation)
- 调节自己内部结构适应特定情境



好奇心与创造

- Jürgen Schmidhuber 在1990 年代的工作
- 好奇是一种增强学习的机制，它会让报酬最大
- 好奇聚焦于那种未知的但能够学到的规则性事物
- 无聊则是
 - 完全可以预测的
 - 完全不可以预测的



大脑的临界性



静不稳定的系统具有灵活性

处于稳定和灵活之间
是最佳的选择


- 自组织临界性
- 大脑的临界性假说
- Dante Chialvo
- Critical brain dynamics at large scale
- A fundamental theory to model the mind

一个猜测

- 对自组织临界的研究会助益人工智能领域的实践
- 对智能现象更深的理解会帮助物理学的研究

彭罗斯的三个投射

- 物理世界
- 心智世界
- 数学世界



这个世界有无穷的奥秘等待我们去探索