



# 机器学习入门

[UNIX2GO.com](http://UNIX2GO.com)




# 目录

- 机器学习介绍
- 机器学习用途
- 机器学习类型
- 机器学习实践
- 参考书籍



# (一) 何为机器学习




简单说，机器通过一系列「任务」从「经验」（数据）中学习，并且评估「效果」如何。



# 样本、特征、标签

面积 (平米)	朝向	居室	价格 (w)
105	South	4	300
160	East	6	450






## (二) 机器学习用途


- Classification 分类，如垃圾邮件识别(detection, ranking)
- Regression 回归，例如股市预测
- Clustering 聚类，如 iPhoto 按人分组

# 分类





# 回归



# 聚类



## Clustering:

- Clustering is the task of gathering samples into groups of similar samples according to some predefined similarity or dissimilarity measure



sample



Cluster/group



## (三) 机器学习类型

- 监督学习：给出定义好的标签，程序「学习」标签和数据之间的映射关系
- 无监督学习：在没有标签的数据集上进行学习




# 监督学习案例：逻辑回归

- 目标：预测美女是否有男友
- 样本：

身高（厘米）	外貌（分数）	独自逛街次数	是否有男友
165	80	5	1
158	65	20	0



# 监督学习案例：逻辑回归



- 计算公式： $y = f(h(x)) = f(w^T \cdot x + b)$ ，其中 $f(z)$ 为激活函数。
- $y$ 是函数输出结果， $w$ 是权重参数集， $x$ 是特征向量， $b$ 是偏移量。
- $b$ 在实际中也当作一项特殊参数处理（ $w_0$ ），它对应的输入值 $x$ 始终是1。



# 监督学习案例：逻辑回归

接上，得到公式：

$$y = \text{sigmoid}(w_1 * \text{身高} + w_2 * \text{外貌} + w_3 * \text{独自逛街次数} + b)$$

sigmoid是激活函数，返回值在[0,1]。

假设模型训练后，得到的参数集：

w1	w2	w3	b
0.6	0.7	-0.9	-140



# 监督学习案例：逻辑回归

那么，开始预测：

假设某美女身高165，外貌75分，独自逛街次数15，套用公式一算：

- $165 * 0.6 + 75 * 0.7 + 15 * (-0.9) + (-140) = -2.0$
- $\text{sigmoid}(-2.0) = 0.1192$ （大概率没有男友）


上述关键过程，在于通过大量的样本训练，得到模型的参数集（ $w_1, w_2, w_3, b$ ）。训练有2个关键要素：

- 损失函数
- 优化方式

详细过程，不在此描述，请见本人撰文：[《如何写一个模型训练器》](#)




# 无监督学习：k-means






## (四) 机器学习实践

- 虎牙直播App个性推荐系统
- 在“全部直播”和“发现”栏目，接入个性化推荐引擎





# 个性推荐特征工程





# 个性推荐原理

- 采用简单的逻辑回归模型（可解释性）
- 业务流程上分为召回服务（matching）、排序服务（ranking），ranking部分用到逻辑回归
- 模型的训练过程，请见陈聪撰文《[生产模型的训练过程](#)》



## (五) 参考书籍

- 李航：[统计学习方法](#)
- 周志华：[机器学习](#)
- 吴军：[数学之美](#)
- 开源书籍：[Deep Learning](#)（中译版）
- 开源书籍：[THE LION WAY, Machine Learning plus Intelligent Optimization](#)