



東莞理工學院
DONGGUAN UNIVERSITY OF TECHNOLOGY

人工智能概论

第九章：降维与度量学习

丁烨，计算机科学与技术学院

dingye@dgut.edu.cn



目录

- ❖ 基本概念
- ❖ 特征选择
- ❖ 特征提取
- ❖ 度量学习

基本概念

降维

- ❖ 降维 (Dimensionality Reduction)
- ❖ 在某些限定条件下
- ❖ 降低特征数量、得到一组“不相关”的特征的过程
- ❖ 降维可进一步细分为特征选择和特征提取两大方法


基本概念

降维

- ❖ 降维可以处理数据中存在的两个核心问题：
- ❖ 维度灾难：
- ❖ 特征维度太大，导致训练无法进行或训练过程漫长
- ❖ 特征之间存在着相互关联关系：
- ❖ 导致解的空间不稳定，从而导致模型的泛化能力弱

基本概念

降维



目录

- ❖ 基本概念
- ❖ 特征选择
- ❖ 特征提取
- ❖ 度量学习

特征选择

基本概念

- ❖ 我们能用很多特征描述一个西瓜
- ❖ 例如色泽、根蒂、敲声、纹理、触感等
- ❖ 但有经验的人往往只需看看根蒂、听听敲声就知道是否好瓜
- ❖ 换言之，对一个学习任务来说，给定特征集
- ❖ 其中有些特征可能很关键、很有用
- ❖ 另一些特征则可能没什么用

特征选择

基本概念

- ❖ 特征选择 (Feature Selection)
- ❖ 从给定的特征集合中选出相关特征子集的过程
- ❖ “数据预处理 (Data Preprocessing)” 的一部分
- ❖ 对当前学习任务有用的特征称为 “相关特征 (Relevant Feature)”
- ❖ 没什么用的特征称为 “无关特征 (Irrelevant Feature)”
- ❖ 核心目标：降低特征数量、去除无关特征

特征选择

基本概念

- ❖ **基础方法：**
- ❖ 从初始的特征集合中选取一个包含了所有重要信息的特征子集
- ❖ 评价出它的好坏，基于评价结果产生下一个候选子集，再对其进行评价
- ❖ 这个过程持续进行下去，直至无法找到更好的候选子集为止
- ❖ **关键问题：**
- ❖ 如何根据评价结果获取下一个候选特征子集？
- ❖ 如何评价候选特征子集的好坏？

特征选择

基本概念

- ❖ 第一个环节是子集搜索 (Subset Search) 问题
- ❖ 给定特征集合 $\{a_1, a_2, \dots, a_d\}$, 将每个特征看作一个候选子集
- ❖ 对这 d 个候选单特征子集进行评价
- ❖ 假定 $\{a_2\}$ 最优, 于是将 $\{a_2\}$ 作为第一轮选定集
- ❖ 然后在上一轮的选定集中加入一个特征, 构成包含两个特征的候选子集
- ❖假定在第 $k + 1$ 轮时, 最优的候选 $(k + 1)$ 特征子集不如上一轮
- ❖ 则停止生成候选子集并将上一轮选定的 k 特征集合作为特征选择结果

特征选择

基本概念

- ❖ 这样逐渐增加相关特征的策略称为“前向 (Forward)”搜索
- ❖ 类似的，若我们从完整的特征集合开始，每次尝试去掉一个无关特征
- ❖ 这样逐渐减少特征的策略称为“后向 (Backward)”搜索
- ❖ 还可将前向与后向搜索结合起来
- ❖ 每一轮逐渐增加选定相关特征（这些特征后续将确定不会被去除）
- ❖ 同时减少无关特征
- ❖ 这样的策略称为“双向 (Bidirectional)”搜索

特征选择

基本概念

- ❖ 显然，上述策略都是贪心的
- ❖ 因为它们仅考虑了使本轮选定集最优
- ❖ 例如在第二轮假定选择 a_5 优于 a_6 ，于是选定集为 $\{a_2, a_4, a_5\}$
- ❖ 然而在第四轮却可能是 $\{a_2, a_4, a_6, a_8\}$ 比所有的 $\{a_2, a_4, a_5, a_i\}$ 都更优
- ❖ 遗憾的是，若不进行穷举搜索，则这样的问题无法避免

特征选择

基本概念

- ❖ 第二个环节是子集评价 (Subset Evaluation) 问题
- ❖ 给定数据集 D , 假定 D 中第 i 类样本所占的比例为 p_i
- ❖ 对特征子集 A , 假定根据其取值将 D 分成了 V 个子集
- ❖ 于是我们可计算特征子集 A 的信息增益

$$\text{Gain}(A) = \text{Ent}(D) - \sum_{v=1}^V \frac{|D^v|}{|D|} \text{Ent}(D^v)$$

特征选择

基本概念

- ❖ 其中信息熵定义为：

$$\text{Ent}(D) = - \sum_{i=1}^{|\mathcal{Y}|} p_k \log_2 p_k$$

- ❖ 信息增益 $\text{Gain}(A)$ 越大
- ❖ 意味着特征子集 A 包含的有助于分类的信息越多
- ❖ 于是，对每个候选特征子集
- ❖ 我们可基于训练数据集 D 来计算其信息增益，以此作为评价准则

特征选择

基本概念

- ❖ 将特征子集搜索机制与子集评价机制相结合，即可得到特征选择方法
- ❖ 常见的特征选择方法大致可分为三类：
 - ❖ 过滤式 (Filter)
 - ❖ 包裹式 (Wrapper)
 - ❖ 嵌入式 (Embedding)

特征选择

过滤式特征选择

- ❖ 过滤式 (Filter) 特征选择
- ❖ 先对数据集进行特征选择，然后再训练模型
- ❖ 特征选择过程与后续训练过程无关
- ❖ 这相当于先用特征选择过程对初始特征进行“过滤”
- ❖ 再用过滤后的特征来训练模型

特征选择

过滤式特征选择

- ❖ Relief
- ❖ 一种著名的过滤式特征选择方法
- ❖ 该方法设计了一个“**相关统计量**”来度量特征的重要性
- ❖ 该统计量是一个向量，其每个分量分别对应于一个初始特征
- ❖ 特征子集的重要性由每个特征所对应的**相关统计量分量之和**来决定
- ❖ 最终只需选择比指定阈值大的**相关统计量分量**所对应的特征即可
- ❖ 也可指定欲选取的特征个数，然后选择**相关统计量分量最大的若干特征**

特征选择

过滤式特征选择

- ❖ 相关统计量
- ❖ 先从每个样本的同类样本中寻找其最近邻
- ❖ 称为“猜中近邻 (Near-hit)”
- ❖ 再从每个样本的异类样本中寻找其最近邻
- ❖ 称为“猜错近邻 (Near-miss)”
- ❖ 如果“猜中近邻”

特征选择

过滤式特征选择

- ❖ 若真相与其猜中近邻在某个特征上的距离小于与其猜错近邻的距离
- ❖ 则说明该特征对区分同类与异类样本是有益的
- ❖ 于是增大该特征所对应的统计量分量
- ❖ 反之，则说明该特征起负面作用
- ❖ 于是减小该特征所对应的统计量分量
- ❖ 最后，对基于不同样本得到的估计结果进行平均
- ❖ 就得到各特征的相关统计量分量
- ❖ 分量值越大，则对应特征的分类能力就越强

特征选择

包裹式特征选择

- ❖ 包裹式 (Wrapper) 特征选择
- ❖ 与过滤式特征选择不考虑后续模型训练过程不同
- ❖ 包裹式特征选择直接把模型的性能作为特征子集的评价准则
- ❖ 目的就是为指定算法选择最有利于其性能、“量身定做”的特征子集

特征选择

包裹式特征选择

- ❖ 一般而言，由于包裹式特征选择方法直接针对指定算法进行优化
- ❖ 因此从最终模型性能来看
- ❖ 包裹式特征选择比过滤式特征选择更好
- ❖ 但另一方面，由于在特征选择过程中需多次训练模型
- ❖ 因此包裹式特征选择的计算开销通常比过滤式特征选择大得多

特征选择

包裹式特征选择

- ❖ LVW (Las Vegas Wrapper)
- ❖ 一个典型的包裹式特征选择方法
- ❖ LVW 在拉斯维加斯方法 (Las Vegas Method) 框架下使用随机策略来进行子集搜索
- ❖ 并以最终模型的误差为特征子集评价准则

输入: 数据集 D ;
特征集 A ;
学习算法 \mathcal{L} ;
停止条件控制参数 T .

过程:

```
1:  $E = \infty$ ;  
2:  $d = |A|$ ;  
3:  $A^* = A$ ;  
4:  $t = 0$ ;  
5: while  $t < T$  do  
6:   随机产生特征子集  $A'$ ;  
7:    $d' = |A'|$ ;  
8:    $E' = \text{CrossValidation}(\mathcal{L}(D^{A'}))$ ;  
9:   if  $(E' < E) \vee ((E' = E) \wedge (d' < d))$  then  
10:      $t = 0$ ;  
11:      $E = E'$ ;  
12:      $d = d'$ ;  
13:      $A^* = A'$   
14:   else  
15:      $t = t + 1$   
16:   end if  
17: end while
```

输出: 特征子集 A^*

图 11.1 LVW 算法描述

特征选择

嵌入式特征选择

- ❖ 嵌入式 (Embedding) 特征选择
- ❖ 在过滤式和包裹式特征选择方法中
- ❖ 特征选择过程与模型训练过程有明显的分别
- ❖ 与此不同，嵌入式特征选择是将特征选择过程与模型训练过程融为一体
- ❖ 两者在同一个优化过程中完成
- ❖ 即在模型训练过程中自动地进行了特征选择

特征选择

嵌入式特征选择

- ❖ 给定数据集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$
- ❖ 其中 $x \in \mathbb{R}^d$, $y \in \mathbb{R}$
- ❖ 我们考虑最简单的线性回归模型，以平方误差为损失函数
- ❖ 则优化目标为：

$$\min_{\mathbf{w}} \sum_{i=1}^m (y_i - \mathbf{w}^T \mathbf{x}_i)^2$$

特征选择

嵌入式特征选择

- ❖ 当样本特征很多，而样本数相对较少时
- ❖ 上式很容易陷入过拟合
- ❖ 为了缓解过拟合问题，可对上式引入正则化项
- ❖ 若使用 L_2 范数正则化，则有：

$$\min_{\mathbf{w}} \sum_{i=1}^m (y_i - \mathbf{w}^T \mathbf{x}_i)^2 + \lambda \|\mathbf{w}\|_2^2$$

特征选择

嵌入式特征选择

- ❖ 上式被称为“岭回归 (Ridge Regression)”
- ❖ 通过引入 L_2 范数正则化，的确能显著降低过拟合的风险
- ❖ 那么，能否将正则化项中的 L_2 范数替换为 L_p 范数呢？
- ❖ 答案是肯定的
- ❖ 若令 $p = 1$ ，即采用 L_1 范数，则有：

$$\min_{\mathbf{w}} \sum_{i=1}^m (y_i - \mathbf{w}^T \mathbf{x}_i)^2 + \lambda \|\mathbf{w}\|_1$$

特征选择

嵌入式特征选择

$$\min_{\mathbf{w}} \sum_{i=1}^m (y_i - \mathbf{w}^T \mathbf{x}_i)^2 + \lambda \|\mathbf{w}\|_1$$

- ❖ 上式被称为：
- ❖ LASSO (Least Absolute Shrinkage & Selection Operator)
- ❖ L_1 范数和 L_2 范数正则化都有助于降低过拟合风险
- ❖ 但前者还会带来一个额外的好处：
- ❖ 它比后者更易于获得“稀疏 (Sparse) 解”
- ❖ 即它求得的 \mathbf{w} 会有更少的非零分量

目录

- ❖ 基本概念
- ❖ 特征选择
- ❖ 特征提取
- ❖ 度量学习

特征提取

基本概念

- ❖ 特征提取 (Feature Extraction)
- ❖ 与特征选择类似，特征提取的核心目的也是：
- ❖ 降低特征数量
- ❖ 得到一组“不相关”的特征
- ❖ 与特征选择不同，特征提取不再保留原始特征
- ❖ 而是产生新的特征，而这些特征是原始特征的某种组合

特征提取

基本概念

- ❖ 特征提取可以看作特征选择方法的一般化：
- ❖ 特征选择假设在原始数据中：
- ❖ 特征数目浩繁，但只有少数几个真正起作用
- ❖ 而特征提取则认为：
- ❖ 在所有特征可能的组合（例如：线性组合）中
- ❖ 只有少数几个真正起作用

特征提取

基本概念

- ❖ 常见的特征提取方法：
- ❖ 主成分分析（PCA）
- ❖ 核化（Kernelized）线性降维
- ❖ 非负矩阵分解（NMF）

特征提取

主成分分析

- ❖ 主成分分析 (PCA)
- ❖ 最常用的一种降维方法
- ❖ 在介绍 PCA 之前, 不妨先考虑这样一个问题:
- ❖ 对于正交特征空间中的样本点
- ❖ 如何用一个超平面 (直线的高维推广) 对所有样本进行恰当的表达?

特征提取

主成分分析

- ❖ 若存在这样的超平面，那么它大概应具有这样的性质：
- ❖ **最近重构性**：样本点到这个超平面的距离都足够近
- ❖ **最大可分性**：样本点在这个超平面上的投影能尽可能分开
- ❖ 有趣的是，基于最近重构性和最大可分性
- ❖ 能分别得到主成分分析的两种等价推导

特征提取

主成分分析

- ❖ 假定数据样本进行了中心化, 即 $\sum_i x_i = 0$
- ❖ 再假定投影变换后得到的新坐标系为 $\{w_1, w_2, \dots, w_d\}$
- ❖ 其中 w_i 是标准正交基向量
- ❖ 若丢弃新坐标系中的部分坐标, 即将维度降低到 $d' < d$
- ❖ 则样本点 x_i 在低维坐标系中的投影是: $z_i = (z_{i1}, z_{i2}, \dots, z_{id'})$
- ❖ 其中 $z_{ij} = w_j^T x_i$ 是 x_i 在低维坐标系下第 j 维的坐标
- ❖ 若基于 z_i 来重构 x_i , 则会得到: $\hat{x}_i = \sum_{j=1}^{d'} z_{ij} w_j$

特征提取

主成分分析

- ❖ 考虑整个训练集
- ❖ 原样本点 x_i 与基于投影重构的样本点 \hat{x}_i 之间的距离为：

$$\begin{aligned} \sum_{i=1}^m \left\| \sum_{j=1}^{d'} z_{ij} \mathbf{w}_j - \mathbf{x}_i \right\|_2^2 &= \sum_{i=1}^m \mathbf{z}_i^T \mathbf{z}_i - 2 \sum_{i=1}^m \mathbf{z}_i^T \mathbf{W}^T \mathbf{x}_i + \text{const} \\ &\propto -\text{tr} \left(\mathbf{W}^T \left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right) \mathbf{W} \right). \end{aligned}$$

特征提取

主成分分析

- ❖ 根据最近重构性，上式应被最小化
- ❖ 考虑到 w_j 是标准正交基， $\sum_i x_i x_i^T$ 是协方差矩阵，有：

$$\begin{aligned} \min_{\mathbf{W}} \quad & -\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W}) \\ \text{s.t.} \quad & \mathbf{W}^T \mathbf{W} = \mathbf{I}. \end{aligned}$$


- ❖ 这就是主成分分析的优化目标

特征提取

主成分分析

- ❖ 从最大可分性出发，能得到主成分分析的另一种解释
- ❖ 我们知道，样本点 x_i 在新空间中超平面上的投影是 $W^T x_i$
- ❖ 若所有样本点的投影能尽可能分开
- ❖ 则应该使投影后样本点的方差最大化


$$\begin{aligned} \max_{\mathbf{W}} \quad & \text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W}) \\ \text{s.t.} \quad & \mathbf{W}^T \mathbf{W} = \mathbf{I}. \end{aligned}$$



特征提取

主成分分析

$$\begin{aligned} \max_{\mathbf{W}} \quad & \text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W}) \\ \text{s.t.} \quad & \mathbf{W}^T \mathbf{W} = \mathbf{I}. \end{aligned}$$



$$\begin{aligned} \min_{\mathbf{W}} \quad & -\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W}) \\ \text{s.t.} \quad & \mathbf{W}^T \mathbf{W} = \mathbf{I}. \end{aligned}$$

- ❖ 最近重构性和最大可分性的推导很明显在数学上是等价的
- ❖ 使用拉格朗日乘子法可得：

$$\mathbf{X} \mathbf{X}^T \mathbf{W} = \lambda \mathbf{W}.$$

特征提取

主成分分析

输入: 样本集 $D = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$;
低维空间维数 d' .

过程:


- 1: 对所有样本进行中心化: $\mathbf{x}_i \leftarrow \mathbf{x}_i - \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i$;
- 2: 计算样本的协方差矩阵 $\mathbf{X}\mathbf{X}^T$;
- 3: 对协方差矩阵 $\mathbf{X}\mathbf{X}^T$ 做特征值分解;
- 4: 取最大的 d' 个特征值所对应的特征向量 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_{d'}$.

输出: 投影矩阵 $\mathbf{W} = (\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_{d'})$.

图 10.5 PCA 算法


特征提取

主成分分析



特征提取

主成分分析




“本征脸 (Eigenface)”

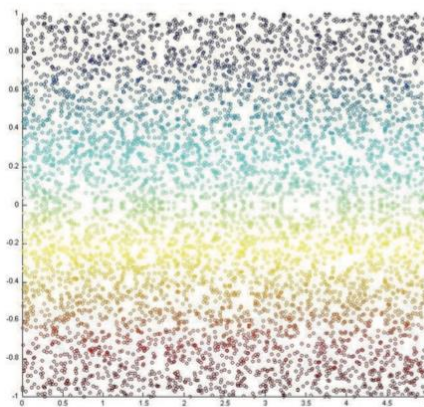
特征提取

核化线性降维


- ❖ 线性降维方法假设从高维空间到低维空间的函数映射是线性的
- ❖ 然而，在现实任务中，可能需要非线性映射才能找到恰当的低维嵌入



(a) 三维空间中的观察



(b) 本真二维结构



(c) PCA 降维结果

图 10.6 三维空间中观察到的 3000 个样本点，是从本真二维空间中矩形区域采样后以 S 形曲面嵌入，此情形下线性降维会丢失低维结构。图中数据点的染色显示出低维空间的结构。

特征提取

核化线性降维

- ❖ 非线性降维的一种常用方法
- ❖ 是基于核技巧对线性降维方法进行“核化” (Kernelized)
- ❖ 假定我们将在高维特征空间中把数据投影到由 W 确定的超平面上
- ❖ 即 PCA 欲求解：

$$\left(\sum_{i=1}^m z_i z_i^T \right) \mathbf{W} = \lambda \mathbf{W}.$$

特征提取

核化线性降维

- ❖ 假定 z_i 是由原始属性空间中的样本点 x_i 通过映射 ϕ 产生，即：

$$z_i = \phi(x_i)$$

- ❖ 若 ϕ 能被显式表达出来，则通过它将样本映射至高维特征空间
- ❖ 再在特征空间中实施 PCA 即可

特征提取

核化线性降维

- ❖ 但一般情形下，我们不清楚 ϕ 的具体形式，于是引入核函数：

$$\kappa(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^\top \phi(\mathbf{x}_j).$$

- ❖ 最终即可求出原始 PCA 的解
- ❖ 这个方法叫做：核主成分分析（Kernelized PCA, KPCA）

特征提取

非负矩阵分解

- ❖ 非负矩阵分解 (Non-negative Matrix Factorization, NMF)
- ❖ 顾名思义, 就是将非负的大矩阵分解成两个非负的小矩阵, 使得:


$$V \approx WH$$

- ❖ V 是 $n * m$ 维的矩阵
- ❖ W 是 $n * k$ 维的矩阵, 即 k 个基向量
- ❖ H 是 $k * m$ 的矩阵, 每一列为 V 投影到 W 上得到的向量

特征提取

非负矩阵分解

- ❖ PCA 的原数据是有正有负的
- ❖ PCA 的基向量是指向四面八方的，相互正交着
- ❖ NMF 的原数据只分布在非负子空间
- ❖ 它的基向量则在这个非负子空间靠近边缘的区域，像一组长短不一、间隔不一的伞骨



特征提取

非负矩阵分解

- ❖ NMF 如何求解?
- ❖ 有点复杂, 可以参考:
- ❖ https://en.wikipedia.org/wiki/Non-negative_matrix_factorization
- ❖ <http://oa.ee.tsinghua.edu.cn/~zhangyujin/Download-Paper/C151=Dzxb-08.pdf>

目录

- ❖ 基本概念
- ❖ 特征选择
- ❖ 特征提取
- ❖ 度量学习

度量学习

基本概念

- ❖ 对高维数据进行降维的主要目的是希望找到一个合适的低维空间
- ❖ 在此空间中进行学习能比原始空间性能更好
- ❖ 事实上，每个空间对应了在样本特征上定义的一个距离度量
- ❖ 而寻找合适的空间，实质上就是在寻找一个合适的距离度量
- ❖ 那么，为何不直接尝试“学习”出一个合适的距离度量呢？
- ❖ 这就是**度量学习**（Metric Learning）的基本动机

度量学习

基本概念

- ❖ 欲对距离度量进行学习，必须有一个便于学习的距离度最表达形式
- ❖ 我们在之前的课程中给出了很多种距离度量的表达式
- ❖ 但它们都是“固定的”、没有可调节的参数
- ❖ 因此不能通过对数据样本的学习来加以改善
- ❖ 为此，我们先来做一个推广

度量学习

基本概念

- ❖ 对两个 d 维样本 \mathbf{x}_i 和 \mathbf{x}_j , 它们之间的平方欧氏距离可写为:

$$\text{dist}_{\text{ed}}^2(\mathbf{x}_i, \mathbf{x}_j) = \|\mathbf{x}_i - \mathbf{x}_j\|_2^2 = \text{dist}_{ij,1}^2 + \text{dist}_{ij,2}^2 + \cdots + \text{dist}_{ij,d}^2,$$

- ❖ 其中 dist_{ijk} 表示 \mathbf{x}_i 与 \mathbf{x}_j 在第 k 维上的距离
- ❖ 若假定不同特征的重要性不同, 则可引入特征权重 w , 得到:

$$\begin{aligned} \text{dist}_{\text{wed}}^2(\mathbf{x}_i, \mathbf{x}_j) &= \|\mathbf{x}_i - \mathbf{x}_j\|_2^2 = w_1 \cdot \text{dist}_{ij,1}^2 + w_2 \cdot \text{dist}_{ij,2}^2 + \cdots + w_d \cdot \text{dist}_{ij,d}^2 \\ &= (\mathbf{x}_i - \mathbf{x}_j)^{\text{T}} \mathbf{W} (\mathbf{x}_i - \mathbf{x}_j), \end{aligned}$$

度量学习

基本概念

- ❖ 上式中的 W 可通过学习确定，但我们还能再往前走一步
- ❖ W 的非对角元素均为零，这意味着坐标轴是正交的，即特征之间无关
- ❖ 但现实问题中往往不是这样
- ❖ 例如考虑西瓜的“重量”和“体积”这两个特征
- ❖ 它们显然是正相关的，其对应的坐标轴不再正交

度量学习

基本概念

- ❖ 为此，将上式中的 W 替换为一个普通的半正定对称矩阵 M
- ❖ 于是就得到了“马氏距离 (Mahalanobis Distance)”

$$\text{dist}_{\text{mah}}^2(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{W} (\mathbf{x}_i - \mathbf{x}_j) = \|\mathbf{x}_i - \mathbf{x}_j\|_M^2,$$

- ❖ 其中 M 亦称“度量矩阵”，而度量学习则是对 M 进行学习
- ❖ 求解 M 的具体过程和优化目标请参考教科书第 10.6 节

总结

- ❖ 「西瓜书」周志华《机器学习》，清华大学出版社
- ❖ <https://item.jd.com/12762673.html>
- ❖ 「南瓜书」谢文睿、秦州《机器学习公式详解》，人民邮电出版社
- ❖ <https://github.com/datawhalechina/pumpkin-book/>

总结

❖ Scikit-Learn

❖ <https://scikit-learn.org>

❖ TensorFlow

❖ <https://www.tensorflow.org>



TensorFlow



HAPPY
Mother's
DAY





東莞理工學院
DONGGUAN UNIVERSITY OF TECHNOLOGY

Thank You!

丁焯，计算机科学与技术学院

dingye@dgut.edu.cn

