

Chapter.1 - HW

HW 1-1

1.1 表 1.1 中若只包含编号为 1 和 4 的两个样例, 试给出相应的版本空间.

样例如下:

编号	色泽	根蒂	敲声	好瓜
1	青绿	蜷缩	浊响	是
4	乌黑	稍蜷	沉闷	否

Solve

可以先得到样本空间, 共 $(2 + 1) * (2 + 1) * (2 + 1) + 1 = 28$ 种:

#	色泽	根蒂	敲声
1	青绿	蜷缩	浊响
2	青绿	蜷缩	沉闷
3	青绿	蜷缩	*
4	青绿	稍蜷	浊响
5	青绿	稍蜷	沉闷
6	青绿	稍蜷	*
7	青绿	*	浊响
8	青绿	*	沉闷
9	青绿	*	*
10	乌黑	蜷缩	浊响
11	乌黑	蜷缩	沉闷
12	乌黑	蜷缩	*
13	乌黑	稍蜷	浊响
14	乌黑	稍蜷	沉闷
15	乌黑	稍蜷	*

#	色泽	根蒂	敲声
16	乌黑	*	浊响
17	乌黑	*	沉闷
18	乌黑	*	*
19	*	蜷缩	浊响
20	*	蜷缩	沉闷
21	*	蜷缩	*
22	*	稍蜷	浊响
23	*	稍蜷	沉闷
24	*	稍蜷	*
25	*	*	浊响
26	*	*	沉闷
27	*	*	*
27	∅	∅	∅

然后根据样本, 一条条删除与正例不符的样本, 得到剩下的即为版本空间:

#	色泽	根蒂	敲声
1	青绿	蜷缩	浊响
3	青绿	蜷缩	*
7	青绿	*	浊响
9	青绿	*	*
19	*	蜷缩	浊响
21	*	蜷缩	*
25	*	*	浊响

2. HW 1-2

析合范式即多个合取式的析取。

1.2 与使用单个合取式来进行假设表示相比, 使用“析合范式”将使得假设空间具有更强的表示能力. 例如

$$\begin{aligned} \text{好瓜} \leftrightarrow & ((\text{色泽} = *) \wedge (\text{根蒂} = \text{蜷缩}) \wedge (\text{敲声} = *)) \\ & \vee ((\text{色泽} = \text{乌黑}) \wedge (\text{根蒂} = *) \wedge (\text{敲声} = \text{沉闷})), \end{aligned}$$

提示: 注意冗余情况, 如 $(A = a) \vee (A = *)$ 与 $(A = *)$ 等价.

会把“ $(\text{色泽} = \text{青绿}) \wedge (\text{根蒂} = \text{蜷缩}) \wedge (\text{敲声} = \text{清脆})$ ”以及“ $(\text{色泽} = \text{乌黑}) \wedge (\text{根蒂} = \text{硬挺}) \wedge (\text{敲声} = \text{沉闷})$ ”都分类为“好瓜”. 若使用最多包含 k 个合取式的析合范式来表达表 1.1 西瓜分类问题的假设空间, 试估算共有多少种可能的假设.

样例如下:

编号	色泽	根蒂	敲声	好瓜
1	青绿	蜷缩	浊响	是
2	乌黑	蜷缩	浊响	是
2	青绿	硬挺	清脆	否
4	乌黑	稍蜷	沉闷	否

Solve

根据样例, 共有3个属性 - 色泽, 根蒂, 敲声: 色泽 有 2 个种类, 根蒂 有 3 个种类, 敲声 有 3 个种类. 又因为存在正例, 排除 $\emptyset$ 的假设.

我们可以计算单个合取式的假设空间规模: $(2 + 1) * (3 + 1) * (3 + 1) = 48$.

接下来做的事就是将 48 个合取式挑 $i (i \leq k)$ 种进行组合, 我们可以简单的得到此时所有可能的假设数量 N :

$$N = \sum_{i=1}^k C_k^i$$

我们注意到因为存在题目提示冗余情况, 根据逻辑等价式的分配率^[1]:

$$(A \wedge B) \vee (A \wedge C) \equiv A \wedge (B \vee C)$$

因此存在通配符($*$)时, 可能出现以下可能:

$$\begin{aligned} ((x_1 = a) \wedge (x_2 = b)) \vee ((x_1 = a) \wedge (x_2 = *)) & \Leftrightarrow (x_1 = a) \wedge ((x_2 = b) \vee (x_2 = *)) \\ & \Leftrightarrow (x_1 = a) \wedge (x_2 = *) \end{aligned}$$

我们注意到题目中 k 使用了修饰词 最多. 根据上述冗余情况将其合并, 得到结论: 在假设空间中, 每个析合范式未必具有同样个数的合取式. 因此 k 为假设空间中析合范式中所含合取式个数的最

大值并非为 48.

不难发现, 当一个析合范式包含了所有不含泛化通配符 $*$ 的 $2 * 3 * 3 = 18$ 个合取式时, 若再添加包含泛化通配符 $*$ 的合取式, 则必然会造成冗余, 合取式必然会被消除而减少. 因此我们可以得到 $k_{max} = 18$.

故得到答案, $k = k_{max} = 18$ 时, 共有可能的假设数量 N :

$$N = \sum_i^k C_k^i = \sum_i^{18} C_{18}^i = 2^{18} = 262143$$

HW 1-3

即不存在训练错误为 0 的假设.

1.3 若数据包含噪声, 则假设空间中有可能不存在与所有训练样本都一致的假设. 在此情形下, 试设计一种归纳偏好用于假设选择.

Solve

直接想法是存在噪声就尽可能地消除噪声.

- 若存在两个样例属性取值都相同, 标记却不同, 则只保留标记为正例(或反例)的样例;

除此之外, 另外, 考虑归纳偏好应尽量与问题相匹配, 这里可使归纳偏好与噪声分布相匹配.

HW 1-4

1.4* 本章 1.4 节在论述“没有免费的午餐”定理时, 默认使用了“分类错误率”作为性能度量来对分类器进行评估. 若换用其他性能度量 ℓ , 则式(1.1)将改为

$$E_{ote}(\mathcal{L}_a | X, f) = \sum_h \sum_{x \in \mathcal{X} - X} P(x) \ell(h(x), f(x)) P(h | X, \mathcal{L}_a),$$

试证明“没有免费的午餐定理”仍成立.

$$E_{ote}(\mathcal{L}_a | X, f) = \sum_h \sum_{x \in \mathcal{X} - X} P(x) l(h(x), f(x)) P(h | X, \mathcal{L}_a) \quad (1.3)$$

Solve

类似于笔记 式7.2 的计算.

假设 f 是均匀分布的, 一半的 f 对 x 的预测与 $h(x)$ 不一致, 另一半则一致.

根据 式7.3, 得到:

$$\sum_f E_{ote}(\mathcal{L}_a|X, f) = \sum_f \sum_h \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) l(h(\mathbf{x}), f(\mathbf{x})) P(h|X, \mathcal{L}_a) \quad (1.4)$$

计算 式1.4:

$$\begin{aligned} \sum_f E_{ote}(\mathcal{L}_a|X, f) &= \sum_f \sum_h \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) l(h(\mathbf{x}), f(\mathbf{x})) P(h|X, \mathcal{L}_a) \\ &= \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) \sum_h P(h|X, \mathcal{L}_a) \sum_f l(h(\mathbf{x}), f(\mathbf{x})) \end{aligned}$$

由于 f 均匀分布, 一半的 f 对 $\mathbf{x}$ 的预测与 $h(\mathbf{x})$ 不一致. 同时对于二分类问题, 预测成功(失败)的度量分数应当如同 式1.2 中的 $\mathbb{I}(\cdot)$, 预测成功(失败)的分数是固定且一致的. 那么此时我们可以设函数 $l(h(\mathbf{x}), f(\mathbf{x}))$ 中:

- $h(\mathbf{x}) = f(\mathbf{x})$ 时, $l = A_1$
- $h(\mathbf{x}) \neq f(\mathbf{x})$ 时, $l = A_2$

得到:

$$\begin{aligned} \sum_f l(h(\mathbf{x}), f(\mathbf{x})) &= \frac{1}{2} \cdot 2^{|\mathcal{X}|} \cdot A_1 + \frac{1}{2} \cdot 2^{|\mathcal{X}|} \cdot A_2 \\ &= \frac{1}{2} \cdot 2^{|\mathcal{X}|} \cdot (A_1 + A_2) \\ &= \frac{1}{2} A \cdot 2^{|\mathcal{X}|} \end{aligned}$$

将上式代入并继续计算:

$$\begin{aligned} \sum_f E_{ote}(\mathcal{L}_a|X, f) &= \sum_f \sum_h \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) l(h(\mathbf{x}), f(\mathbf{x})) P(h|X, \mathcal{L}_a) \\ &= \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) \sum_h P(h|X, \mathcal{L}_a) \sum_f l(h(\mathbf{x}), f(\mathbf{x})) \\ &= \frac{1}{2} A \cdot 2^{|\mathcal{X}|} \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) \sum_h P(h|X, \mathcal{L}_a) \\ &= 2^{|\mathcal{X}|-1} A \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) \cdot 1 \\ &= 2^{|\mathcal{X}|-1} A \sum_{\mathbf{x} \in \mathcal{X}-X} P(\mathbf{x}) \end{aligned}$$

得到了与 式1.2 类似的结论, 度量结果与学习算法 $\mathcal{L}$ 无关, NFL仍成立.

HW 1-5

1.5 试述机器学习能在互联网搜索的哪些环节起什么作用.

Solve

1. 在向搜索引擎提交信息的阶段, 能够从提交文本中进行信息提取, 进行语义分析;
 2. 在搜索引擎进行信息匹配的阶段, 能够提高问题与各个信息的匹配程度;
 3. 在向用户展示搜索结果的阶段, 能够根据用户对结果感兴趣的程度进行排序.
-

1. 《离散数学及其应用》 P.25 [↩](#)