

第三次作业（贝叶斯网络）

彭煜峰 PB22051087

2024 年 6 月 9 日

本次作业需独立完成，不允许任何形式的抄袭行为，如被发现会有相应惩罚。在上方修改你的姓名学号，说明你同意本规定。

问题 1：概率推断（25%）

a. 画图（3 分）




图 1: 贝叶斯网络

b. 计算（5 分）

根据图 1 可以得出联合分布为：

$$\begin{aligned} P(C = c, D_1 = d_1, D_2 = d_2, D_3 = d_3) \\ = P(C = c) \cdot P(D_1 = d_1 | C = c, a_1) \cdot P(D_2 = d_2 | C = c, a_2) \cdot P(D_3 = d_3 | C = c, a_3) \end{aligned}$$

由于 $D_t \sim \mathcal{N}(\|a_t - C_t\|, \sigma^2)$, 上式可以展开为:

$$P(C = c, D_1 = d_1, D_2 = d_2, D_3 = d_3) = \frac{P(C = c)}{(2\pi\sigma^2)^{3/2}} \cdot \exp\left\{-\frac{\sum_{i=1}^3 (d_i - \|c - a_i\|)^2}{2\sigma^2}\right\}$$

c. 证明 (5 分)

证明. 根据图 1 表示的贝叶斯网络, 车辆的位置 C_t 是一个独立的随机变量, 可作为样本空间的一个完备事件群。

而 D_t 只与 C_t 有关, 若作出观察 $D_t = d_t$, 由贝叶斯定理可计算后验概率:

$$\begin{aligned} &P(C_t = c_t | D_1 = d_1, \dots, D_t = d_t) \\ &= \frac{P(C_t = c_t | D_1 = d_1, \dots, D_{t-1} = d_{t-1}) \cdot p(D_t = d_t | C_t = c_t)}{\sum_{c' \in \{c_t\}} P(C_t = c' | D_1 = d_1, \dots, D_{t-1} = d_{t-1}) \cdot p(D_t = d_t | C_t = c')} \end{aligned}$$

去掉上式的归一化因子:

$$P(C_t = c_t | D_1 = d_1, \dots, D_t = d_t) \propto P(C_t = c_t | D_1 = d_1, \dots, D_{t-1} = d_{t-1}) \cdot p(D_t = d_t | C_t = c_t)$$

又因为假设 $C = c_t = c$ 为常数, 因此:

$$P(C = c | D_1 = d_1, \dots, D_t = d_t) \propto P(C = c | D_1 = d_1, \dots, D_{t-1} = d_{t-1}) \cdot p(D_t = d_t | C = c)$$

□

d. 编程 (12 分)

```
def observe(self, agentX: int, agentY: int, observedDist: float) -> None:
    # BEGIN_YOUR_CODE (our solution is 7 lines of code, but don't worry if you
    # deviate from this)
    for row in range(self.belief.numRows):
        for col in range(self.belief.numCols):
            dist = math.sqrt((util.colToX(col) - agentX) ** 2 + (util.rowToY(row) -
                agentY) ** 2)
            prob_distr = util.pdf(dist, Const.SONAR_STD, observedDist)
            self.belief.setProb(row, col, self.belief.getProb(row, col) * prob_distr
                )
    self.belief.normalize()
    # END_YOUR_CODE
```

问题 2: 转移概率 (25%)

a. 画图 (3 分)




图 2: 贝叶斯网络

b. 计算 (5 分)

根据图 2, 可以得出:

$$\begin{aligned} & P(C_1 = c_1, C_2 = c_2, C_3 = c_3, D_1 = d_1, D_2 = d_2, D_3 = d_3) \\ &= P(C_1 = c_1) \times P(C_2 = c_2 | C_1 = c_1) \times P(C_3 = c_3 | C_2 = c_2) \\ & \quad \times P(D_1 = d_1 | C_1 = c_1, a_1) \times P(D_2 = d_2 | C_2 = c_2, a_2) \times P(D_3 = d_3 | C_3 = c_3, a_3) \end{aligned}$$

同理, 可根据 $D_t \sim \mathcal{N}(\|a_t - C_t\|, \sigma^2)$ 将上式展开:

$$\begin{aligned} & P(C_1 = c_1, C_2 = c_2, C_3 = c_3, D_1 = d_1, D_2 = d_2, D_3 = d_3) \\ &= \frac{P(C_1 = c_1) \cdot P(C_2 = c_2 | C_1 = c_1) \cdot P(C_3 = c_3 | C_2 = c_2)}{(2\pi\sigma^2)^{3/2}} \cdot \exp \left\{ -\frac{\sum_{i=1}^3 (d_i - \|c_i - a_i\|)^2}{2\sigma^2} \right\} \end{aligned}$$

c. 证明 (5 分)

证明. 根据条件概率定义:

$$P(C_{t+1} = c_{t+1} | D_1 = d_1, \dots, D_t = d_t) = \frac{P(C_{t+1} = c_{t+1}, D_1 = d_1, \dots, D_t = d_t)}{P(D_1 = d_1, \dots, D_t = d_t)}$$

再由全概率公式:

$$P(C_{t+1} = c_{t+1}, D_1 = d_1, \dots, D_t = d_t) = \sum_{c_t} p(c_{t+1} | c_t) \cdot P(C_t = c_t | D_1 = d_1, \dots, D_t = d_t)$$

而 $P(D_1 = d_1, \dots, D_t = d_t)$ 为归一化因子, 从而得出:

$$P(C_{t+1} = c_{t+1} | D_1 = d_1, \dots, D_t = d_t) \propto \sum_{c_t} p(c_{t+1} | c_t) \cdot P(C_t = c_t | D_1 = d_1, \dots, D_t = d_t)$$

□

d. 编程 (5 分)

```
def elapseTime(self) -> None:
    if self.skipElapse: ### ONLY FOR THE GRADER TO USE IN Problem 1
        return
    # BEGIN_YOUR_CODE (our solution is 7 lines of code, but don't worry if you
    # deviate from this)
    newBelief=util.Belief(self.belief.numRows, self.belief.numCols, value=0.0)
    for oldTile, newTile in self.transProb:
        value=self.transProb[(oldTile, newTile)]
        if value>0:
            newBelief.addProb(newTile[0], newTile[1], self.belief.getProb(oldTile[0],
            oldTile[1])*value)
    newBelief.normalize()
    self.belief=newBelief
    # END_YOUR_CODE
```

问题 3: 是哪辆车? (30%)

a. 计算 (8 分)

由题意可知, 所求条件概率为一个后验概率, 因此根据贝叶斯定理:

$$p(C_{11} = c_{11}, C_{12} = c_{12} | E_1 = e_1) = \frac{p(E_1 = e_1 | C_{11} = c_{11}, C_{12} = c_{12}) \cdot p(C_{11} = c_{11}, C_{12} = c_{12})}{p(E_1 = e_1)}$$

其中

$$\begin{aligned} & p(E_1 = e_1 | C_{11} = c_{11}, C_{12} = c_{12}) \\ &= p(D_{11} = e_{11}, D_{12} = e_{12} | C_{11} = c_{11}, C_{12} = c_{12}) + p(D_{12} = e_{11}, D_{11} = e_{12} | C_{11} = c_{11}, C_{12} = c_{12}) \\ &= p_N(e_{11}, \|a_1 - c_{11}\|_2, \sigma^2) + p_N(e_{11}, \|a_2 - c_{12}\|_2, \sigma^2) \end{aligned}$$

因此

$$p(C_{11} = c_{11}, C_{12} = c_{12} | E_1 = e_1) \propto [p_N(e_{11}, \|a_1 - c_{11}\|_2, \sigma^2) + p_N(e_{11}, \|a_2 - c_{12}\|_2, \sigma^2)] p(c_{11}) p(c_{12})$$

b. 计算 (8 分)

辅助变量: 变量 z_t 表示在时间步 t 时车辆位置列表 c_t 和感测到的位置列表 e_t 之间的索引偏移量:

$$z_t \in \{0, 1, 2, \dots, k-1\}, \quad k \text{ 为车辆的数量}$$

概率计算： 根据 z_t 的定义：

$$c_{t-1} = g^{-1}(e_{t-1}, z_{t-1})$$

其中函数 g 为 c_t 按 z_t 偏移的映射。

因此条件概率：

$$p(c_t | c_{t-1}) = p(c_t | c_{t-1} = g^{-1}(e_{t-1}, z_{t-1}))$$

其中 z_t 均匀分布且独立，概率为 $p(z_t) = \frac{1}{k}$ 。因此：

$$\begin{aligned} p(c_t | c_{t-1}) &= \sum_{p=0}^{k-1} p(c_t | g^{-1}(e_{t-1}, p)) \cdot p(z_{t-1} = p) \\ &= \frac{1}{k} \sum_{p=0}^{k-1} p(c_t | g^{-1}(e_{t-1}, p)) \\ &= \frac{1}{k} \sum_{p=0}^{k-1} \prod_{i=1}^k p(c_{ti} | g^{-1}(e_{t-1}, p)_i) \end{aligned}$$

且 $p(c_{ti} | g^{-1}(e_{t-1}, z_{t-1})_i)$ 服从车辆独立的转移概率。

c. 建模 (10 分)

贝叶斯网络描述： 我们定义以下变量：

1. $C_{ti} \in \mathbb{R}^2$ 表示时间步 t 时车辆 i 的真实位置。
2. E_t 表示时间步 t 的感测到的位置列表，是车辆真实位置的一个随机排列。
3. $Z_t \in \{0, 1, \dots, K-1\}$ 表示时间步 t 的索引偏移量。

我们有以下条件概率：

1. 车辆位置的转移概率 $p(C_{ti} | C_{(t-1)i})$ 表示车辆 i 在时间步 t 的位置仅依赖于其在时间步 $t-1$ 的位置。
2. 感测到的位置列表 E_t 是真实位置列表 C_t 的随机排列，且均匀分布。

因子图描述

构建因子图：

1. 对于每个时间步 t ，创建变量节点 C_t 表示所有车辆在时间步 t 的位置。
2. 创建因子节点表示车辆位置的转移概率 $p(C_t | C_{t-1})$ 。
3. 创建变量节点 E_t 表示感测到的位置列表。
4. 创建因子节点表示感测到的位置列表是车辆真实位置的随机排列。

定义因子:

1. 位置转移因子: $\phi_t(C_t, C_{t-1}) = \prod_{i=1}^K p(C_{ti}|C_{(t-1)i})$ 。
2. 感测因子: $\psi_t(E_t, C_t, Z_t) = \delta(E_t = g(C_t, Z_t))$, 这里 δ 是指示函数, 表示 E_t 是 C_t 的随机排列 g 的结果。

算法步骤:

1. **初始化:** 设定初始的先验分布 $p(C_1)$ 。
2. **向前传递:** 从时间步 $t = 1$ 到 $t = T$, 递归计算每个时间步的边缘分布 $p(C_t|e_1, \dots, e_t)$:

$$p(C_t|e_1, \dots, e_t) = \sum_{C_{t-1}} p(C_t|C_{t-1})p(C_{t-1}|e_1, \dots, e_{t-1})$$

3. **结合感测数据:** 更新每个时间步的边缘分布以包含感测数据:

$$p(C_t|e_1, \dots, e_t) \propto p(C_t|e_1, \dots, e_{t-1})\psi_t(E_t, C_t, Z_t)$$

4. **向后传递:** 从时间步 $t = T$ 到 $t = 1$, 递归计算每个时间步的平滑分布 $p(C_t|e_1, \dots, e_T)$:

$$p(C_t|e_1, \dots, e_T) \propto p(C_t|e_1, \dots, e_t) \sum_{C_{t+1}} p(C_{t+1}|C_t)p(C_{t+1}|e_1, \dots, e_T)$$

d. 回答问题 (4 分)

粒子滤波器的原理是根据每个粒子的概率不同设置新的权重, 再根据权重选择点进行计算, 而精确计算则要考虑所有的网格。因此前者的时间复杂度低于后者。

问题 4: 模型学习 (10%)

a. 计算 (10 分)

E 步骤: 根据所给出算法, 可以写出后验概率计算公式:

$$P(Z1, Z2|X1, X2) \propto P(X1, X2|Z1, Z2)P(Z1, Z2)$$

其中

$$P(X1, X2|Z1, Z2) = P(X1|Z1)P(X2|Z2), \quad P(Z1, Z2) = P(Z1)P(Z2|Z1)$$

M 步骤: 似然函数:

$$L(\theta) = \prod_{i=1}^N \sum_{Z1, Z2} P(Z1)P(Z2|Z1)P(X1^{(i)}|Z1)P(X2^{(i)}|Z2)$$

取对数似然函数:

$$\log L(\theta) = \sum_{i=1}^N \log \left(\sum_{Z1, Z2} P(Z1)P(Z2|Z1)P(X1^{(i)}|Z1)P(X2^{(i)}|Z2) \right)$$

计算结果：利用 python 计算得到：

概率	值
$P(Z1 = \text{true})$	0.721
$P(Z1 = \text{false})$	0.279
$P(Z2 = \text{true} Z1 = \text{true})$	0.682
$P(Z2 = \text{false} Z1 = \text{true})$	0.318
$P(Z2 = \text{true} Z1 = \text{false})$	0.187
$P(Z2 = \text{false} Z1 = \text{false})$	0.813
$P(X1 = \text{true} Z1 = \text{true})$	1.0
$P(X1 = \text{false} Z1 = \text{true})$	0.0
$P(X1 = \text{true} Z1 = \text{false})$	1.0
$P(X1 = \text{false} Z1 = \text{false})$	0.0
$P(X2 = \text{true} Z2 = \text{true})$	0.362
$P(X2 = \text{false} Z2 = \text{true})$	0.638
$P(X2 = \text{true} Z2 = \text{false})$	0.665
$P(X2 = \text{false} Z2 = \text{false})$	0.335

表 1: 更新后的概率表

b. 阅读网页 (0 分)

EM 算法可以保证收敛到一个稳定点，但是却不能保证收敛到全局的极大值点，因此它是局部最优的算法，当然，如果我们的优化目标是凸的，则 EM 算法可以保证收敛到全局最大值，这点和梯度下降法这样的迭代算法相同。

反馈 (10 分)

在每次实验报告的最后欢迎反馈你上这门课的感受，你可以写下任何反馈，包括但不限于以下几个方面：课堂、作业难度和工作量、助教工作等等。

- 这次作代码难度不高，主要是手写证明部分难度较大。
- 题目的符号用的有点乱，感觉不是很清晰。
- 花费时间在 15 个小时左右（累计）。