

运筹学

我想分享运筹学基础的概念和在计算机中的应用。

我认为，运筹学主要描述建模的过程，由各种的假设得到各种分布、过程，进而进行决策。

无记忆性和随机变量的分布

1. 唯一具备无记忆性的连续随机变量分布是指数分布。

$$P\{X > s + t\} = P\{X > s\}P\{X > t\} \Leftrightarrow F(x) = P\{X \leq x\} = \begin{cases} 1 - e^{-\lambda x}, & \text{if } x \geq 0, \\ 0, & \text{if } x < 0. \end{cases}$$

我们只验证无记忆性推导出指数分布：设 $g(s) = P\{X > s\}$ ，则：

$$\begin{aligned} P\{X > s + t\} &= P\{X > s\}P\{X > t\} \\ \Leftrightarrow g(s + t) &= g(s)g(t) \\ \Rightarrow g(2/n) &= g(1/n)g(1/n) \\ \Rightarrow g(m/n) &= g(1/n)^m, g(1) = g(1/n)^n \\ \Rightarrow g(m/n) &= g(1/n)^m = (g(1)^{1/n})^m = g(1)^{m/n} \\ \Rightarrow g(x) &= g(1)^x = e^{-\lambda x}, \lambda = -\ln g(1) \end{aligned}$$

2. 唯一具备无记忆性的离散随机变量分布是几何分布。

$$P\{X > s + t\} = P\{X \geq s\}P\{X > t\} \Leftrightarrow P(x = n) = (1 - p)^{n-1}p, n \in \mathbb{N}^+$$

同样我们验证从左边式子推导出右边：

$$\begin{aligned} P\{X > s + t\} &= P\{X \geq s\}P\{X > t\} \\ \Rightarrow P\{X > k + t\} &= P\{X \geq k\}P\{X > t\} \text{ 且 } P\{X > s + k\} = P\{X \geq s\}P\{X > k\} \\ \Rightarrow P\{X \geq k\} \sum_{t=1}^{\infty} P\{X > t\} &= \sum_{t=1}^{\infty} P\{X > k + t\} = \sum_{s=1}^{\infty} P\{X > k + s\} = P\{X > k\} \sum_{s=1}^{\infty} P\{X \geq s\} \\ \Leftrightarrow P\{X \geq k\} \sum_{t=1}^{\infty} P\{X > t\} &= P\{X > k\} \sum_{s=1}^{\infty} P\{X \geq s\} \\ \Leftrightarrow P\{X \geq k\} \sum_{t=2}^{\infty} P\{X \geq t\} &= P\{X \geq k + 1\} \sum_{t=1}^{\infty} P\{X \geq t\} \end{aligned}$$

我们取 $k = 1$ ，设 $p = P\{x = 1\}$ ，设 $\alpha = \sum_{t=2}^{\infty} P\{X \geq t\}$ ，则 $1 * \alpha = (1 - p)(1 + \alpha)$ ，得到 $\alpha = (1 - p)/p$ ，代入原式得到 $P\{X \geq k\}\alpha = P\{X \geq k + 1\}(1 + \alpha)$ ，即 $(1 - p)P\{X \geq k\} = P\{X \geq k + 1\}$ 。于是 $P\{X \geq k\} = (1 - p)^{k-1}$ ，因此 $P\{X = k\} = P\{X \geq k\} - P\{X \geq k + 1\} = p(1 - p)^{k-1}$

3. 泊松 (Poisson) 分布

$$P\{X = i\} = e^{-\lambda} \frac{\lambda^i}{i!}, i = 0, 1, \dots$$

性质：二项分布 (n 次独立重复试验，每次实验成功概率为 p ，则实验成功 k 次的概率为 $C_n^k p^k (1 - p)^{n-k}$) 在 n 很大， p 很小的时候近似于泊松分布。

随机过程

我们平常接触得比较多的是随机变量的分布，但要是考虑时间流动，随机变量的分布可能会变。我们怎么建模这种现象？随机过程！

随机过程 $\mathbf{X} = \{X(t), t \in T\}$ 是一组随机变量。也就是说，对于任意的 $t \in T$ ， $X(t)$ 是一个随机变量。

随机过程特殊性质：

- 独立增量 (independent increments)：对于所有的 $t_0 < t_1 < t_2 < \dots < t_n$ ，随机变量 $X(t_1) - X(t_0), X(t_2) - X(t_1), \dots, X(t_n) - X(t_{n-1})$ 相互独立。
- 稳定增量 (stationary increments)： $\forall s, X(s + t) - X(s)$ 都有相同的分布。

自然语言处理中“语言是稳态的可遍历性的随机过程”中“稳态”就是上面的稳定增量，指的是“从今天《人民日报》和明天《人民日报》分别采样得到的汉语统计特征是一样的”。

泊松过程

记 $N(t)$ 为 $[0, t]$ 内发生的事件个数，则 $\{N(t), t \geq 0\}$ 被称作计数过程。

泊松过程（参数为 λ ）是满足如下性质的计数过程：

- $N(0) = 0$
- 随机过程是独立增量的
- 任意一个长度为 t 的时间段内事件数量服从 λt 的泊松分布。即 $\forall t \geq 0, \forall s \geq 0, P\{N(s+t) - N(s) = n\} = e^{-\lambda t} \frac{(\lambda t)^n}{n!}$
显然泊松过程也具备稳定增量的性质。

泊松过程和指数分布

记 X_n 为第 $n-1$ 个事件和第 n 个事件之间的时间长度。泊松过程（参数为 λ ）等价于 $X_n (\forall n = 1, 2, \dots)$ 服从参数为 λ 的指数分布。
证明：

$$\begin{aligned} P\{X_1 \geq t\} &= P\{N(t) = 0\} = e^{-\lambda t} \\ P\{X_2 > t | X_1 = s\} &= P\{0 \text{ events in } (s, s+t] | X_1 = s\} \\ &\stackrel{\text{independent}}{=} P\{0 \text{ events in } (s, s+t]\} \\ &\stackrel{\text{stationary}}{=} P\{0 \text{ events in } (0, t]\} = e^{-\lambda t} \end{aligned}$$

马尔科夫性与马尔科夫过程

- Markov Property: 给定当前状态，未来状态和过去状态无关。
 $P\{\text{Future} | \text{Present}, \text{Past}\} = P\{\text{Future} | \text{Present}\}$
- 马尔科夫过程分类：

A *stochastic process* that follows the Markov property is called a Markov process.

		Time	
		Discrete	Continuous
State Space	Discrete	DTMC	CTMC
	Continuous	e.g., random walks	e.g., Brownian motions

- This part will focus on *discrete* state spaces and *discrete* time

DTMC

- homogeneous Discrete-Time Markov Chain: $P\{X_{n+1} = j | X_n = i\} = p_{ij}$ ，时间、状态离散，且转移概率和时间无关。
- Chapman-Kolmogorov 等式：记从 i 状态花 n 步转移到 j 状态的概率为 p_{ij}^n ，则 $p_{ij}^{n+m} = \sum_{k=0}^{\infty} p_{ik}^n p_{kj}^m, \forall n, m \geq 0, \forall i, j$ 。矩阵形式： $P^{(n+m)} = P^{(n)} P^{(m)}, P_{ij}^{(n)} = p_{ij}^n$
- state 的分类：recurrent (常返) 和 transient (瞬态)。 j 是 recurrent 的当且仅当 $\sum_{n=1}^{\infty} p_{jj}^n = \infty$ 。
- 例子1: PageRank: 若 i, j 间有链接，则 $p_{ij} = 1/d_i$ ，其中 d_i 表示 i 的度数。Page i 的分数记为 π_i 的话，则 $(\pi_1, \pi_2, \dots) = \pi = \pi P$ 。
- 例子2: HMM (隐马尔科夫模型)：每个输出序列对应着一个隐藏状态序列，输出是关于隐藏状态的随机变量，隐藏状态是个 DTMC。
- 例子3: CRF (条件随机场)：NLP和图像处理中的序列标注和结构划分问题。给定观察序列 X ，输出标识序列 Y ，通过计算 $P(Y|X)$ 求解最优标注序列。

若对于无向图 $G = (V, E)$ ， V 中每个节点对应于 Y_v 的随机变量，且满足 $p(Y_v | X, Y_w, w \neq v) = p(Y_v | X, Y_w, (v, w) \in E, \forall v, w \in V)$ ，则 (X, Y) 为条件随机场。

比如NLP中词性标注任务： X 就是句子， Y 是我们要给每个字标注的词性，词性之间有马尔科夫性（当前字的词性仅仅和前面1个字的词性有关）

比如图像处理中的分割任务： X 就是所有像素， Y 是我们要给每个像素打的标签，某个像素点的标签仅仅和相邻4个像素点的标签有关。

CTMC

- homogeneous Continuous-Time Markov Chain: $P_{ij}(t) = P\{X(s+t) = j | X(s) = i\}, \forall s$. CTMC=DTMC+在状态上的停留时间服从指数分布。
- 生灭过程 (Birth and Death process) : 某个时刻系统内有 n 个人, 那么下一个人到达系统的时间间隔服从 λ_n 的指数分布, 系统内下一个离开的人的时间间隔服从 μ_n 的指数分布。

queueing theory

- 网络流量测量的几个重大发现: 数据对话请求 (session) 的到达服从泊松分布, 或者说, 用户访问服从泊松分布。
- 数据包 (package) 的到达不服从泊松分布 (数据包到达具有突发性)
- 为什么要研究泊松分布? 还记得我们先前说二项分布近似于泊松分布在什么样的场景下吗? 人数量很多 (n), 每个人在此时选择此项服务的概率 (p) 很小。
因此, 现实中很多场景会出现泊松分布。
泊松过程建模的是时间段内发生的事件数量, 等价于事件间隔时间服从指数分布。

因此最经典的排队论模型: M/M/1, M (下一个用户到达时间服从指数分布) / M (服务器服务当前一个人的时间服从指数分布) / 1 (一个服务器)

MDP

MDP: 在DTMC的基础上, 引入动作 (action) 和奖励 (reward) 的概念, 动作 (action) 对应着我们可以影响状态和状态之间的转移概率, 每个状态对应着一个值 (v , 代表这个状态下获得的期望回报), 奖励在采取动作后获得。

Inventory theory

Inventory theory: 每天早上进货, 当天的需求未知, 进货进多了卖不, 进货进少了利润不高。

- newsvendor model (报童模型) : 单份报纸卖 p 元, 单份报纸成本为 c 元, 当天需求 D 的累积分布函数 $\Phi(\cdot)$ 未知, 求最优进货数量 y ?
期望收益为: $E_D[p \min(D, y) - cy]$, 求导为0得到 $\Phi(y^*) = \frac{p-c}{p}$ 。
证明:

$$\begin{aligned} & E_D[p \min(D, y) - cy] \\ &= E_D[pD + p \min(0, y - D) - cD + c(D - y)] \\ &= E_D[pD - cD] + E_D[p \min(0, y - D)] + cE_D[(D - y)] \\ &= (p - c)E_D[D] - pE_D[\max(0, D - y)] + cE_D[(D - y)^+ - (D - y)^-] \\ &= (p - c)E_D[D] - pE_D[(D - y)^+] + cE_D[(D - y)^+ - (D - y)^-] \\ &= (p - c)E_D[D] - (p - c)E_D[(D - y)^+] - cE_D[(D - y)^-] \end{aligned}$$

max上式等价于最小化 $L = (p - c)E_D[(D - y)^+] + cE_D[(D - y)^-] = (p - c) \int_y^\infty (z - y)\phi(z)d(z) + c \int_0^y (y - z)\phi(z)dz$ 。而 $\frac{\partial L}{\partial y} = (p - c)[-1(1 - \Phi(y))] + c\Phi(y) = c - p + p\Phi(y) = 0$

这里用了个公式: $\frac{d}{dt} \int_{h(t)}^{g(t)} F(x, t) dx = F(h, t) \frac{dh(t)}{dt} - F(g, t) \frac{dg(t)}{dt} + \int_{h(t)}^{g(t)} \frac{dF(x, t)}{dt} dx$ 。

因此 $\frac{d}{dy} \int_y^\infty (z - y)\phi(z)d(z) = 0 - 0 * 1 + \int_y^\infty -\phi(z)d(z) = -(1 - \Phi(y))$ 。

下半部分的主题

- 博弈论
- 线性规划
- 非线性规划
- 组合优化
- 复杂性理论