

# 马尔科夫决策规划

董泽清

中国科学院应用数学研究所  
1981年7月

# 目 录

## 第一章 绪论

§ 1. 引言	1 - 1
§ 3. 马尔科夫决策规划研究的内容及例	1 - 6
§ 3. 基本假设和定义	1 - 8
§ 4. 马氏决策过程	1 - 13
§ 5. 报酬过程同目标函数	1 - 17

## 第二章 $\Delta$ 有限的折扣模型

§ 1. 引言	2 - 1
§ 2. 平稳策略优势	2 - 4
§ 3. 存在一个平稳策是最优的	2 - 7
§ 4. 策略迭代法	2 - 10
§ 5. 逐次逼近法	2 - 18
§ 6. 策略迭代—逐次逼近法	2 - 23
§ 7. 线性规划法	2 - 24
§ 8. 关于几个称法的说明	2 - 28

## 第三章 $\Delta$ 有限的平均模型

§ 1. 引言	3 - 1
§ 2. 平稳最优策略的存在性	3 - 1
§ 3. 策略迭代法	3 - 5
§ 4. 线性规划法	3 - 12
§ 5. 特殊情形	3 - 13
§ 6. 数值例子	3 - 15

~ ~ ~

§ 7. 逐次逼近法 ..... 3-18

第四章 有限阶段模型

§ 1. 引言	4-1
§ 2. 存在一个马氏策略是最优的	4-1
§ 3. 数值例子	4-7

第五章 折扣模型

§ 1. 引言	5-1
§ 2. 存在一个马氏策略是 $\bar{\pi}$ -最优的	5-4
§ 3. 压缩映像 $T_f$ , $T$	5-7
§ 4. $\bar{\pi}$ -最优平稳策略的存在性	5-12
§ 5. 平稳最优策略	5-14
§ 6. ( $\bar{\pi}$ -)最优策略关于折扣因子的依赖性, 方差最小策略问题	5-19

第六章 折扣模型的解法 ( $F$ 为无限集)

§ 1. 引言	6-1
§ 2. 策略迭代法	6-1
§ 3. 逐次逼近法	6-7
§ 4. 策略迭代——逐次逼近法	6-11
§ 5. 有限状态逼近法	6-14
§ 6. 关于几个办法的说明	6-17
§ 7. 数值例子	6-18

第七章 平均模型

§ 1. 引言及最优化假设	7-1
§ 2. 最优平稳策略的存在性	7-4

~ 3 ~

§ 3. 化平均模型为折扣模型	7-11
§ 4. $\bar{\epsilon}$ -最优策略	7-13
§ 5. 特殊情形	7-17

## 第八章 半马氏模型 (暂缺)

## 第九章 无界报酬模型 (一)

§ 1. 引言、反例及最优化假设	9-1
§ 2. 存在一个马氏策略是 $\bar{\epsilon}$ -最优的	9-4
§ 3. $\bar{\epsilon}$ -最优平稳策略的存在性	9-15
§ 4. 最优平稳策略	9-17
§ 5. 解法	9-18

## 第十章 无界报酬模型 (二)

§ 1. 引言	10-1
§ 2. 定义同记号	10-1
§ 3. 折扣目标情形	10-4
§ 4. 平均目标情形	10-16

## 第十一章 连续时间折扣模型

§ 1. 引言	11-1
§ 2. 基本解法同定义	11-2
§ 2.1 连续时间MDP	11-2
§ 2.2 策略	11-3
§ 2.3 马氏决策过程	11-3
§ 2.4 目标函数	11-5
§ 3. 折扣模型	11-8
§ 3.1 方程 (10) 的有界解与 ( $\bar{\epsilon}$ -) 最优平稳策略的关系	11-9

~ 4 ~

§ 3.2 (E-) 最优平稳策略的存在性 与策略迭代法	11-13
§ 3.3 进一步的结果与压缩映像	11-17
§ 3.4 化连续时间折扣模型为间断时 间折扣模型	11-20

## 第十二章 连续时间平均模型

§ 1. 引言	12-1
§ 2. 附加假设与预备知识	12-1
§ 3. 最优平稳策略的存在性	12-10
§ 4. E-最优平稳策略	12-16
§ 5. 策略迭代法及其收敛性	12-19
§ 6. 化为间断时间平均模型	12-23

## 第十三章 应用

§ 1. 更换问题	13-1
§ 2. 更换存贮问题	13-7
§ 3. 检查、维修与更换问题	13-12
§ 4. 存贮问题	13-14
§ 5. 排队问题	13-15
§ 6. 目的问题	13-16
§ 7. 质量控制问题	13-18
§ 8. 序贯搜索问题	13-21
§ 9. 連續抽样问题	13-25
§ 10. 可靠性问题	13-29
§ 11. 随机旅行售货员问题	13-30

# 马尔科夫决策规划

(Markovian Decision Programming)

## 第一章 結論

### § 1. 引言

在人类的社会实践中，会遇到各种各样的决策（措施、作用、行动等）问题。其中有一类决策问题，当人们选定决策之后，其结果是不确定的。选取决策的目的，是使得在某种意义上达到最优，从而改进作决策的进程。研究这种不确定性决策的理论称为决策分析（Decision Analysis）。如要决定是否开采某油井？可供选择的决策是“开采”或“不开采”。其结果是“有油”或“无油”均是可能的。我们根据各种资料判断得：有油的可能性为 0.3，无油的可能性为 0.7；如开采，且有油将获利 48 元，如开采，且无油则亏本 2 元；如不开采，则既不亏本也不获利。我们应该采取什么决策？如开采，其平均获利为

$$48 \times 0.3 - 2 \times 0.7 = 13 \text{ (元)}.$$

因此在平均目标的意义下，开采是有利的。如果决策者有足够的资本，在此目标下，当有油的可能性大于 0.04 时，决定开采都是有利的。

决策分析中，其结果的不确定性是用主观概率（如上例中，有油的可能性为 0.3 等）来刻划的；各个可能结果的优劣是以“效用”（如上例中，开采有油将获利 48 元等）函数来刻划的。这里应着重指出，决策分析中使用的是“主观概率”而不是概率论中的概率，为了区别起见，后者称为“客观概率”。

客观概率是随机事件的一种客观属性，是唯一决定的。而主观概率是决策者对随机事件是否发生的一种信任程度，它是根据各种已有资料对随机事件的客观属性的一种合理判断，随着人们对随机事件的深入了解，会修改这种主观信任程度，但决不是主观臆断。如我随机地掷一枚铜板，若连续 10 次均掷出了正面，问下一次仍掷出正面的概率为多少？也许有人会回答仍是  $\frac{1}{2}$ ，为何有这样的回答呢？他是基于铜板的质量完全为均匀的假设之上。若确实如此，那么连续 10 次均掷出正面的客观概率  $= (\frac{1}{2})^{10} = \frac{1}{1024} = 0.001$ ，这是一小概率事件。

居然在一回（连续掷 10 次当一回）试验中发生了，这只能使我们怀疑该铜板是不均匀的。因此若连续掷 10 次都出现了正面，那么掷第 11 次仍出正面的主观概率就应大于  $\frac{1}{2}$ 。其具体数值可借助贝叶斯定理来确定（如见 Payff 等（1965））。事实上这是根据样本信息对随机事件的客观属性更接近真实的反映，但带有主观的成份。当然，若客观概率已知，我们就可以客观概率作为主观概率。但事实上，客观概率往往是不知道的，只好用主观概率。

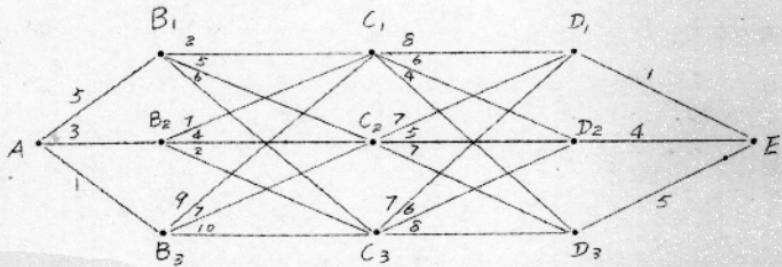
决策分析已发展了一套较科学的方法来评定结果的主观概率，以及评定结果优劣的效用理论。但仍带有艺术性质，未严格数学化。（如见 Keeney（1978））。

虽然决策分析也讨论多周期决策问题，用决策树的方法进行分析。但实际上仅对小数目的周期才可行。

决策分析首先成功地应用于石油和天然气工业的重大决策问题。Matheson（1969）研究了新产油的引进，美国对火星的无人探险，以及核动力引入墨西哥国家动力系统的可能性的决策问题。总之应用范围极为广泛。

还有一类决策问题，虽然所作决策的结果是完全确定的，但必须在一系列彼此相互联系的阶段（一般理解为时间）上都要作决策，每个阶段，在各个可能状态上的诸决策均有一定的经济效益，而且所有阶段的总的经济效益是各个阶段经济效益的某种形式的和。这使得问题变得较复杂。研究这种带动态性的决策理论是“动态规划”。特别应该指出：在各个阶段作决策时，不能只顾眼前的利益，必须与长远利益结合起来考虑，只顾眼前利益是一种近视眼策略，经常不会是最优的。问题是在各个阶段应该选取什么决策，使总的经济效益达最优。

如从 A 地要修一条路（取油管、取气管、水渠、线路等）到 E 地，中间可供选择的途经地有若干个，如下图。两当连线上的数字表示距离（造价、获利等），试如何选取一条从 A 地到 E 地的最短路线（最低造价、最大获利）。



我们用向后归纳法来求解这个问题。

令  $f_n(i)$  表示从  $i$  地出发，按最短路线走，到 E 地还有几段要走的最短距离， $n = 1, 2, 3, 4$ ， $i$  取  $A, B_j, C_j, D_j$ 。  
 $j = 1, 2, 3$ ：

$r(i, j)$  表示从  $i$  地到  $j$  地的距离。

1)  $n = 1$ .

$$f_1(D_1) = r(D_1, E) = 1, \quad f_1(D_2) = r(D_2, E) = 4.$$

1 ~ 4

$$f_1(D_3) = r(D_3, E) = 5.$$

2)  $n=2$

$$f_2(C_1) = \min_i [r(C_1, D_i) + f_1(D_i)]$$

$$= \min [8+1, 6+4, 4+5] = 9,$$

故从  $C_1$  到 E 的最短距离为 9, 最优决策是到  $D_1$  或  $D_3$ .

$$f_2(C_2) = \min_i [r(C_2, D_i) + f_1(D_i)]$$

$$= \min [7+1, 5+4, 7+5] = 8,$$

故从  $C_2$  到 E 的最短距离为 8, 最优决策是到  $D_1$ .

$$f_2(C_3) = \min_i [r(C_3, D_i) + f_1(D_i)]$$

$$= \min [7+1, 6+4, 8+5] = 8,$$

故从  $C_3$  到 E 的最短距离为 8, 最优决策是到  $D_1$ .

3)  $n=3$

$$f_3(B_1) = \min_i [r(B_1, C_i) + f_2(C_i)] = 11$$

故从  $B_1$  到 E 的最短距离为 11, 最优决策是到  $C_1$ .

$$f_3(B_2) = \min_i [r(B_2, C_i) + f_2(C_i)] = 10,$$

故从  $B_2$  到 E 的最短距离为 10, 最优决策是到  $C_3$ .

$$f_3(B_3) = \min_i [r(B_3, C_i) + f_2(C_i)] = 15,$$

故从  $B_3$  到 E 的最短距离为 15, 最优决策是到  $C_2$ .

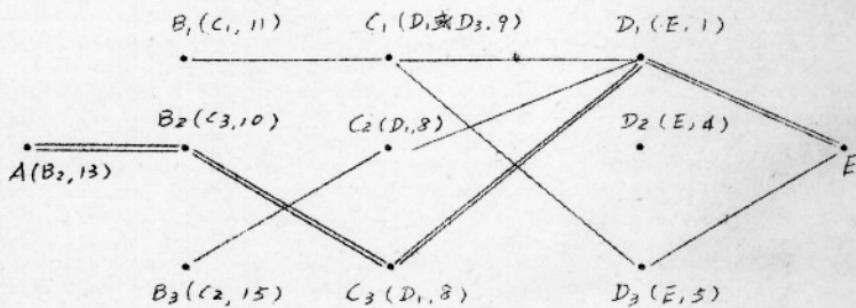
4)  $n=4$

$$f_4(A) = \min_i [r(A, B_i) + f_3(B_i)] = 13,$$

故从 A 到 E 的最短距离为 13, 最优决策是到  $B_2$ , 而  $B_2$  的

最优决策是到  $C_3$ ,  $C_3$  的最优决策是到  $D_1$ ,  $D_1$  到  $E$ , 故最优路线为  $A_1 \rightarrow B_2 \rightarrow C_3 \rightarrow D_1 \rightarrow E$ .

在各点上它的最优决策, 及它到  $E$  的最短距离, 仅保留最短路(子路), 得下图(从  $A$  到  $E$  的最短路线用双线标出). 标出这个图是便于作做估计的。



我们为何能用如上的向后归纳法求解呢? 这是因为有贝尔曼的最优化规则所保证。所谓最优化规则, 对于上述例子, 即为: “最短路的子路(即部分路)也是最短路”, 用最优化规则导出  $f_n(i)$  满足的泛函方程, 然后从泛函方程求最优解.

我们应着重指出: 向后归纳法, 丰富了求解内容, 我们不仅求出了从  $A$  到  $E$  的最短路线, 而且同时求出了任一地点到  $E$  的最短路线; 同时它比穿举法(即把所有从  $A$  到  $E$  的可能的路线的距离均求出来, 然后选一个最短的路线)优越多。它把指数型(乘积型)的计算量(上例中为  $3 \times 3 \times 3 = 27$  条路)化为线性(加法型)的计算量(上例中  $3 + 3 + 3 = 9$ ). 问题越大, 向后归纳法的优越性越明显.

动态规划已成功地解决了许多实际问题, 如见 Bellman 与 Dreyfus (1962), 但动态规划的数学基础还不够严格, “最优化规则”成立的范围有多大, 至今未搞清楚。

在上例中  $A, B_1, C_1, D_1$  及  $E$  称为状态。 $A$  有三个可供选择的决策：下阶段到  $B_1$  或  $B_2$  或  $B_3$ ， $D_1, D_2$  均只有一个决策（即无决策可供选择）；下阶段到  $E$ ，等等。

还有一类决策问题，既要在一系列彼此联系的时刻上均要作决策，而且每次决策的结果也是不确定的。这使问题变得更加错综复杂。必须当经历一个时段，就观察实际发生的结果，即收集新的信息，然后再选取新的决策。也就是要作序贯决策。马尔科夫决策规划就是研究一类特殊的（状态转移规律具有无后效性）序贯决策问题。

在序贯决策中，如果存放和提取信息的费用可忽略不计，则显然在给定时刻选取决策，最好依赖于在那个时刻以前收集的全部历史信息。即人类应该作序贯决策，因为，只有这样做才能使人类对自然界的适应性达最大。但人们往往是幸运的，对许多实际问题，人类总能不顾已收集的部分历史信息，甚至不顾已收集的全部历史信息。因此作决策时，只依赖余下那部份历史信息已足够了。这使问题又变得简单一些。如用现代火炮打高速敌机，若用太多的信息描述敌机的运行轨迹，並不一定好。比如敌机已转弯，再用转弯前的观察数据去拟合轨迹，反而不好。在研究某种疾病的遗传规律时，也不用去查太老的祖宗的患病史。

马尔科夫决策规划，从一开始就在严明的数学基础之上，成为随机运筹学的一个主要分枝，也可以说是应用数学的一个分枝。它是使用客观概率。

## 3.2 马尔科夫决策规划研究内容及例

马尔科夫决策规划（以后简记为 MDP）是研究如下动态

概率系统的最优化问题。该系统可连续地或周期地被观察，在观察时刻，决策者根据观察到的状态，从可用的决策集中选取其一，并予以实施，则有两个结果：1) 系统状态转移的概率规律就确定了，且与该时刻以前的历史无关，即具有马尔科夫(无后效)性；2) 将获得一定的经济效益（可以是钱，也可以是物，在工程技术领域，有着广泛的解释），也与历史无关。系统发展的不同路径将获得不同的经济效益。问题是在各个时刻应如何选取决策，使系统处于最优运行。即选取最优策略，所谓策略，它将告诉决策在各个时刻如何选取决策，当然“最优”与衡量策略优劣的指标有关。

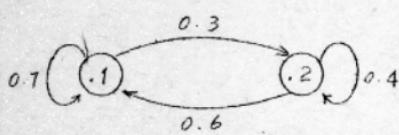
### 例 1. 存贮最优化问题

周期地（如以月为周期）检查某物品的存贮量（即系统的状态），每次检查之后，可供选取的决策是物品允许的定货量，把新进之货加到已有的存贮中，系统的转移律由相继检查时刻之间对该物品的（随机）需求模型所决定。比如，各时期的需求数量是独立、同分布的随机变量，其分布是已知的。所涉及的经济效益有：新增物品的定货费，库存物品的存贮费，不足物品的损失费等。衡量目标（指标）一般是每单位时间的平均费用。今后我们将看到：在相当一般的条件下，存在一对正整数  $S^*, S'' (S^* < S'')$ ，当检查时发现存货量  $\leq S^*$ ，则进货到  $S''$ ；当检查时的存货量  $> S^*$ ，则还进货，乃一最优策略。

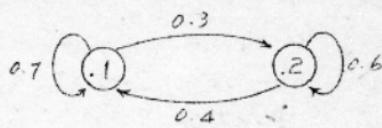
### 例 2. 机田维修的最优化问题

我们周期地（如一小时）观察该机田，有两个可能的状态，正常生产（以 1 表示），出了故障（以 2 表示）。发生的故障，可修理复原。在任何周期，如机田生产，可获报酬 10 元，下一周期仍处于状态 1 的概率为 0.7，而转移到状态 2 的概率为 0.3。如机田发生了故障，我们有两种措施可供采取：快修记

作 1 ) , 需要费用 5 元 ( 即报酬为 -5 元 ) . 一周期能修好的概率为 0.6 ; 另一个 是常规修理 ( 记作 2 ) , 需要费用 2.5 元 , 一周期能修好的概率为 0.4 , 转移图如下 :



快修转移图



常规修理转移图

其中箭头“ $\curvearrowright$ ”表示转移方向，上面的数值表示相应的转移概率。 $i$  表示状态  $i$ ， $i = 1, 2$ 。

问题是在各个时刻应如何决策，使某种总的平均报酬达最大。

这个问题可推广为：机囗可分为  $L+1$  个状态  $\{0, 1, \dots, L\}$ 。状态  $i$  表示机囗处于  $i$  级磨损， $i = 1, 2, \dots, L-1$ ，0 表示新机囗， $L$  表示不能用的坏机囗，在状态  $i$  可供选择的措施是：照常生产，或更换成一个新机囗。其费用为  $C_i$  ( $C_i < C_{i+1}$ ,  $i = 1, 2, \dots, L-1$ )。更换成新机囗的费用为  $C_L$ 。如机囗磨损服从马尔科夫规律，今后我们将看到，在相当弱的条件下，存在一个  $i^*$ ，当检查发现机囗的状态  $i < i^*$ ，则照常生产；当  $i \geq i^*$  时，则更换为新机囗，将是一个最优策略。

### § 3. 基本假设和定义

我们首先研究周期地观察系统的特征。为简便计，我们假定在时刻  $t = 0, 1, 2, \dots$  处观察系统（才可以采取有限值）。

如无特别声明，我们总假定系统状态的转移律族是时间上齐次的（次）随机律。

(离散时间) MDP是由如下意义的五重组  $\{S, (A(i)), i \in S, \gamma, r, V\}$  所构成：

1.  $S$  是一非空集。称为系统的“状态集”或“状态空间”， $S$  的元素称为“状态”，今后将用有足标或无足标的小写英文字母  $s, i, j, \dots$  来表示。如无特别声明，我们总假定  $S$  为一可列集（即有限集或可数无限集），关于  $S$  的结构不作任何假定。

2.  $A(i)$  ( $i \in S$ ) 也为一非空集，称  $i$  可用的“决策”（作用、行动、措施等）集。 $A(i)$  的元素称为“决策”。今后将用有足标或无足标的小写英文字母  $a, b, \dots$  表示。如无特别声明，我们总假定  $A(i)$  为一可列集。

3. 对每个  $t \geq 0$ ，令

$$h_t = (i_0, a_0, i_1, a_1, \dots, s_t, a_t), a_n \in A(i_n), \\ i_n \in S,$$

$$n = 0, 1, \dots, t.$$

称  $h_t$  为系统直到时刻  $t$  的一个“历史”。全体如此历史所成立集记  $H_t$ ，称为“系统直到时刻  $t$  的历史集”。

$g$  是一族时间上齐次的马尔科夫转移律，即对任何  $h_{t-1} \in H_{t-1}$ ,  $i_t \in S$ ,  $a_t \in A(i_t)$ ,  $g(\cdot | h_{t-1}, i_t, a_t)$  与  $g(\cdot | i_t, a_t)$  均有定义且

$$g(j | h_{t-1}, i_t, a_t) = g(j | s_t, a_t), j \in S, t = 0, 1, 2, \dots$$

其中  $h_{-1}$  表示无历史，以及

$$g(j | i_t, a_t) \geq 0, \sum_{j \in S} g(j | i_t, a_t) \leq 1$$

即对任给的  $i_t \in S$ ,  $\{g(j|i_t, a_t); j \in S\}$  为一族次随机向量, 其参数为在  $i_t$  处可用的决策  $a_t \in A(i_t)$ 。

用话来说, 即每当系统处于状态  $i$ , 选取决策  $a \in A(i)$ , 则不管系统的历次如何, 下次转移到状态  $j$  的概率为  $g(j|i, a)$ , 这个概率有时写作  $g_{ij}(a)$ 。

4. 令  $\Gamma = \{(i, a); a \in A(i), i \in S\}$ ,  $\Gamma$  是定义在  $S$  上的单位实函数, 称为系统的“报酬函数”(注意, 负的报酬就是费用)。每逢系统处于状态  $i$ , 选取决策  $a$ , 则我们将获得(一周期期望)报酬  $r(i, a)$ , 它与系统的历次无关。如无特殊声明, 我们总假设  $r$  是有界的, 即存在一个正数  $M$ , 使得  $r$  的绝对值  $|r(i, a)| \leq M$ ,  $a \in A(i)$ ,  $i \in S$ , (以后我们将放弃这个假设)。

5.  $V$  是定义在  $S \times \Gamma^*$ <sup>\*</sup> 上单值实函数, 称为系统的“目标函数”或“最优化准则”。其中  $\Gamma$  是全体策略的成立集, 具体定义将在下面给出。常用的目标函数将在 3.5 中给出。

研究的问题有: 在各个时刻如何选取决策(即选取什么策略)使  $V(i)$ , 对所有  $i \in S$  同时达到极值, 这种策略是否存在? 或在什么意义下存在? 能否在较小的策略类中找到? 怎样把一个复杂的问题化为一个简单的问题? 以及获得最优策略的算法, 特别是对特殊模型的特殊有效算法等。

注意我们只研究目标函数达最大值的问题。如过求最小值, 只要用  $-r$  代替  $r$ , 仍求最大值即可, 或把  $r$  解释为费用, 理论发展完全是一致的。

注 1.  $S$ ,  $A(i)$  ( $i \in S$ ) 均可为有限集, 至少一个为可数无穷集, 甚至各种各样的非可数无限集。转移律族  $\Gamma$  的时间

\*<sup>\*</sup>  $S \times \Gamma$  表示集  $S$  与集  $\Gamma$  的笛卡儿乘积集。

参数可以是离散的，连续的；有有限时段、无限时段； $\theta$ 可以是时齐的、非时齐的，半马尔科夫的； $\theta$ 也可以是未知的。报酬函数 $r$ 可以是有界，各种各样的无界的，甚至 $r$ 与系统的历史有关。状态信息可以是部分可观察的，状态信息延迟的。目标函数也可以是各种各样的。几种成份的任何一个组合均构成一个可研究的模型。

注2. 我们之所以假定 $S$ 为一可列集，一方面是尽可能照顾到应用的广泛性；另一方面也是为了避免一般状态空间带来的测度论上的纷扰。因为 $S$ 非可数时，许多叙述的合理性应当予以证明。

注3. 在实际应用时，对于状态 $i$ 可用的决策 $a$ ，与对于状态 $j$  ( $\neq i$ ) 可用的同一决策 $a$ ，所代表的实际内容可以完全不同。 $a$ 仅表示在可用的决策集中编号为 $a$ 的决策。

一个“策略”（规则，计划）（Policy, Strategy, Plan, rule） $\pi$ ，是一个取列 $\pi = \{\pi_0, \pi_1, \pi_2, \dots\}$ ，其中对每个 $t \geq 0$ ,  $h_{t-1} \in H_{t-1}$ ,  $i_t \in S$ ,  $\pi_t(\cdot | h_{t-1}, i_t)$ 是 $A(i_t)$ 上的一个概率分布。其概率意义为：“当用策略 $\pi$ 时，系统历史 $h_{t-1}$ 已发生，在时刻 $t$ 系统到达状态 $i_t$ 的条件下，选取决策 $a \in A(i_t)$ 的概率为 $\pi_t(a | h_{t-1}, i_t)$ ”。即 $\pi_t$ 是时刻 $t$ 选取决策的规则，我们总有 $0 \leq \pi_t(a | h_{t-1}, i_t) \leq 1$ ，且有 $\sum_{a \in A(i_t)} \pi_t(a | h_{t-1}, i_t) = 1$ 。注意 $h_{t-1}$ 理解为无历史。全体策略之集记作 $\Gamma$ 。一个决定性策略，即 $\pi = \{\pi_0, \pi_1, \pi_2, \dots\}$ 的每个 $\pi_t$ 均为退化分布，即对每个 $h_{t-1} \in H_{t-1}$ ,  $i_t \in S$ 总存在一个 $a_t \in A(i_t)$ 使得 $\pi_t(a_t | h_{t-1}, i_t) = 1$ ， $t \geq 0$ 。全体决定性策略所成立集记作 $\Gamma^d$ 。

我们对特殊策略特别感兴趣，一个策略 $\pi = \{\pi_0, \pi_1, \pi_2, \dots\}$

如果对每个  $t \geq 0$ , 它的  $\pi_t$  只依赖于时刻  $t$  所处的状态  $i_t$ , 即  $\pi_t(\cdot | h_{t-1}, i_t) \equiv \pi_t(\cdot | i_t)$ , 则称为“随机马氏策略”, 有时也称它为“无记忆策略”; 全体如此策略所成立集称为“随机马氏策略类”, 记作  $\Pi_m$ 。一个随机马氏策略  $\pi = \{\pi_0, \pi_1, \pi_2, \dots\}$ , 如果它的每个  $\pi_t$  均是一个退化概率分布, 则称它为“(决定性)马氏策略”, 全体马氏策略所成立集称为“马氏策略类”, 记作  $\Pi_m^d$ 。

定义在  $S$  上的映像  $f$ , 映  $i$  入  $A(i)$ , 即  $f(i) \in A(i)$ ,  $i \in S$ , 则称  $f$  为一“决策函数”。全体决策函数所成立集, 记作  $F$ , 不难看出一个马氏策略  $\pi = \{\pi_0, \pi_1, \pi_2, \dots\}$  必存在一串  $f_n \in F$ , 使得  $\pi \equiv \{f_0, f_1, f_2, \dots\}$ 。

一个随机马氏策略  $\pi = (\pi_0, \pi_1, \pi_2, \dots)$ , 如果它的每个  $\pi_t$  均与  $t$  无关, 而  $\pi = \{\pi_0, \pi_0, \pi_0, \dots\}$ , 则称它为“随机平稳策略”; 全体如此策略所成立集称为“随机平稳策略类”, 记作  $\Pi_s$ 。一个随机平稳策略  $\pi = \{\pi_0, \pi_0, \pi_0, \dots\}$ , 如果  $\pi_0$  是退化的, 即存在一个  $f \in F$ , 使  $\pi_0 \equiv f$ , 则称它为“平稳策略”; 全体平稳策略所成立集称为“平稳策略类”, 记作  $\Pi_s^d$ 。平稳策略  $\pi = \{f, f, f, \dots\}$  有时写作  $f^\infty$ 。显然平稳策略是一特殊马氏策略。

从上面的定义, 我们不难看出有如下结论:

$$1) \quad \Pi_m^d \subset \Pi_m, \quad \Pi_m^d \subset \Pi_m, \quad \Pi_s^d \subset \Pi_s;$$

$$2) \quad \Pi_s^d \subset \Pi_m^d \subset \Pi^d, \quad \Pi_s \subset \Pi_m \subset \Pi;$$

$$3) \quad \Pi_s^d \text{ 与 } F \text{ 含的元素数目是相等的}.$$

有些作者(如 Blackwell [1962], Mine & Osaki [1970]) 仅在  $\Pi_m^d$  类上研究了所提的模型。有些作者(如 Howard [1960]) 在更小的  $\Pi_s^d$  类上研究了所提的模型。