

状態観測の不完全なセミマルコフ決定過程について

長岡工業高専 淳田和芳

§1. 序

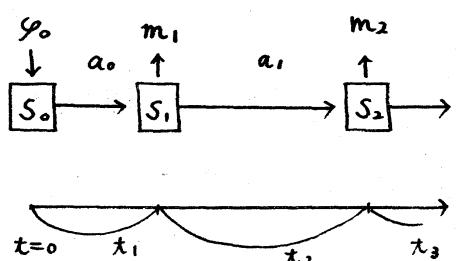
ここでは、状態観測の不完全なセミマルコフ決定過程について述べる（これを SMDP-II と表わし、通常のセミマルコフ決定過程は SMDP-I と表わす）。簡単にこの問題をふりかえてみよう。状態観測の不完全なマルコフ決定過程（これを MDP-II と表わす）は多くの人々により研究された。Dynkin [4] と Shiryaev [9] は数理統計学より生じた部分的観測ランダム列の制御を研究した。Åström [1] は、有限段階の MDP-II を扱った。また、Bellman [2] でも確率過程の部分的観測について言及している。Sawaragi and Yoshioka [8] は、これらの研究と Blackwell [3], Strauch [11] の研究との関連を明確にした。Rhenius [6] は、非定常で一般の状態空間をもつ場合を扱った。Sondik [10], Sawaki and Ichikawa [7] は、 ε -最適政策を求めるアルゴリズムを、それぞれ、政策改良法と逐次近似法より求めた。Kurano [5] は、平均基準を扱った。一方、MDP-II では、各状態での滞在時間はつねに 1 単位時間であるが、この制約を除いて C.C. White [13] は SMDP-II について研究した。そこでは、有限段階で離散時間（整数値上でのみ推移が起る）の場合が扱われた。ここでは、無限段階で（

離散時間を含む) より一般的な推移の場合について述べる。

§2. 定義と準備

X, Y はボ렐集合とする (ボ렐集合とは完備可分距離空間のボ렐部分集合をいう). このとき, X 上のすべての確率測度を $P(X)$ で表わし, X が与えられたときの Y の条件付確率測度のすべてを $Q(Y|X)$ で表わす. また, X 上のすべての有界ボ렐可測関数を $M(X)$ で表わす.

SMDP-II は $(S, M, A, p_s, p_a, g, \varphi_0, c, \alpha)$ により決定される. S, M は可算集合で, それぞれ, システムの状態集合, 観測信号の集合. A はボ렐集合で, 行動集合. $p_s \in Q(S|SA)$ は, 状態の推移確率. $p_a \in Q(R+|SAS)$ ($R+ \equiv [0, +\infty)$) は, 状態の帶在時間分布. p_a は, ある σ 有限測度入に関して, 密度関数 $f(\sigma|s, a, s')$ をもち, f は (σ, s, a, s') に対してボ렐可測とする. $g \in Q(M|S)$ は観測信号を伝える確率. $\varphi_0 \in \Psi$ ($\Psi \equiv P(S)$) はシステムの初期分布. $c \in M(R+SA)$ はコスト関数. α ($\alpha > 0$) は割引因子.



$$\text{オ1 区間でのコスト } \int_0^{t_1} c(t, s_0, a_0) e^{-\alpha t} dt$$

$$\text{オ2 区間でのコスト } e^{-\alpha t_1} \int_0^{t_2} c(t, s_1, a_1) e^{-\alpha t} dt$$

次の条件を全体を通して仮定する.

条件1.

$$\sum_{s'} p_t([0, \delta] | s, a, s') p_s(s' | s, a) \leq 1 - \varepsilon \quad (\forall s, a)$$

なる $\delta > 0$, $\varepsilon > 0$ が存在する.

政策は $\omega = \{\omega_0, \omega_1, \dots\}$ と表わされる. ここで, $\omega_n \in Q(A|H_n)$, $H_n \equiv \text{重}(AR+M)^n(\gamma_n)$ である. 政策 ω を用いたときの期待合計割引コストは,

$$J_\omega^\alpha(\gamma_0) \equiv E_\omega \left[\sum_{n=0}^{\infty} e^{-\alpha(t_1 + \dots + t_n)} \int_0^{t_{n+1}} c(t, s_n, a_n) e^{-\alpha t} dt \mid \gamma_0 \right]$$

で与えられる. ここで, $E_\omega[\cdot | \gamma_0]$ は

$$p_\omega\{\cdot | \gamma_0\} \equiv g^P \otimes \bigotimes_{n=0}^{\infty} (\omega_n \otimes p_s \otimes p_a \otimes g)$$

$$\text{ただし, } g^P(s_0 | \gamma_0) \equiv \gamma_0(s_0)$$

による条件付期待値である. 我々の目的は, すべての政策の中で, $J_\omega^\alpha(\gamma_0)$ を最小にすることである.

$$J_{\omega^*}^\alpha(\gamma_0) \leq \inf_{\omega} J_\omega^\alpha(\gamma_0) \quad (\forall \gamma_0)$$

ならば, ω^* は α -最適であるという.

システムの歴史 $h_n \equiv (\gamma_0, a_0, t_1, m_1, \dots, m_n)$ が観測されたときの状態 s_n の条件付確率を $g_n(\cdot | h_n)$ で表わすと, ベイズの公式より

$$g_{n+1}(s_{n+1} | h_{n+1})$$

$$= g_{n+1}(s_{n+1} | h_n, a_n, t_{n+1}, m_{n+1})$$

$$(3.1) = \frac{\sum_{s_n} f(t_{n+1} | s_n, a_n, s_{n+1}) g(m_{n+1} | s_{n+1}) p_\theta(s_{n+1} | s_n, a_n) g_n(s_n | h_n)}{\sum_{s_n} \sum_{s_{n+1}} [\quad]}$$

ここで、 $g_n(s_n) \equiv g_n(s_n | h_n)$ ($\forall s_n$) として、(3.1)をおきかえると $g_{n+1}(s_{n+1}) = u(g_n, a_n, t_{n+1}, m_{n+1})(s_{n+1})$ ($\forall s_{n+1}$) なるボレル可測写像 $u: \bar{\Omega} A R + M \rightarrow \bar{\Omega}$ が存在する。この u を繰り返し適用すれば、 $h_n \equiv (y_0, a_0, t_1, m_1, \dots, m_n)$ に対して $b_n \equiv (y_0, a_0, t_1, \dots, g_n)$ が定まる。この b_n にまとめて政策を I-政策という。すなはち、I-政策は、 $\pi = \{\pi_0, \pi_1, \dots\}$, $\pi_n \in Q(A | B_n)$, $B_n \equiv \bar{\Omega}(A R + \bar{\Omega})^n$ (ν_n) と表わされる。この I-政策 π に対する期待合計引コストは

$$I_\pi^\alpha(y_0) \equiv \bar{E}_\pi \left[\sum_{n=0}^{\infty} e^{-\alpha(t_1 + \dots + t_n)} \int_0^{t_{n+1}} c(t, s_n, a_n) e^{-\alpha t} dt \mid y_0 \right]$$

で与えられる。ここで、 $\bar{E}_\pi[\cdot | y_0]$ は

$$\bar{\pi}_\pi(\cdot | y_0) \equiv g^* \otimes \bigotimes_{n=0}^{\infty} (\pi_n \otimes p_s \otimes p_t \otimes g \otimes u)$$

による条件付期待値である。政策 ω に対して同様に、 $\bar{\pi}_\omega$, \bar{E}_ω を定義する。そうすると、 J_ω^α は E_ω のかわりに \bar{E}_ω でおきかえて表わすことができる。

§ 3. 主な結果

命題 1.

$$J_\omega^\alpha(y_0) = \bar{E}_\omega \left[\sum_{n=0}^{\infty} e^{-\alpha(t_1 + \dots + t_n)} \bar{c}_\alpha(y_n, a_n) \mid y_0 \right]$$

が成り立つ。ただし、

$$c_a(t, s, a) \equiv \int_0^t c(t, s, a) e^{-at} dt,$$

$$\bar{c}_a(\varphi, a) \equiv \sum_s \sum_{s'} \int_0^\infty c_a(t, s, a) d\hat{P}_t(t | s, a, s') p_s(s' | s, a) \varphi(s),$$

$$\varphi \in \mathbb{R}.$$

証明

$$\begin{aligned} J_w^a(\varphi_0) &= \bar{E}_w \left[\sum_{n=0}^{\infty} e^{-a(t_1 + \dots + t_n)} \int_0^{t_{n+1}} c(t, s_n, a_n) e^{-at} dt \mid \varphi_0 \right] \\ &= \sum_{n=0}^{\infty} \bar{E}_w \left[e^{-a(t_1 + \dots + t_n)} \bar{E}_w [c(t_{n+1}, s_n, a_n) \mid t_n] \mid \varphi_0 \right] \end{aligned}$$

ここで、 $t_n' \equiv (\varphi_0, a_0, t_1, m_1, \varphi_1, \dots, \varphi_n, a_n) - \bar{t}_n$ 、

$$\begin{aligned} &\bar{E}_w [c_a(t_{n+1}, s_n, a_n) \mid t_n'] \\ &= \sum_{s_n} \sum_{s_{n+1}} \int_0^\infty c_a(t, s_n, a_n) d\hat{P}_t(t | s_n, a_n, s_{n+1}) p_s(s_{n+1} | s_n, a_n) \varphi_n(s_n) \\ &= \bar{c}_a(\varphi_n, a_n). \end{aligned}$$

ゆえに、命題が成り立つ。

注意 1. この命題は I-政策元に対しても成り立つ。

定理 3.1. 任意の行動の列 $\{a_0, a_1, \dots\}$ を固定し、 a_n は各番目の推移区间で選択される行動とする。このとき、過程 $\{\varphi_n, t_n; n \in \mathbb{N}\}$ は次の性質をもつ。

(i) 過程が φ_n あるとき、次の推移が φ_{n+1} 起る確率 $\bar{g}(t_{n+1} | \varphi_n, a_n)$ にだけ依存し、次式で与えられる。

$$\begin{aligned} \bar{g}(t | \varphi_n, a_n) &= \sum_{s_n} \sum_{s_{n+1}} \sum_{m_{n+1}} \int_{\bar{T}_m} f(t_{n+1} | s_n, a_n, s_{n+1}) d\lambda(t_{n+1}) \\ &\quad \times g(m_{n+1} | s_{n+1}) p_s(s_{n+1} | s_n, a_n) \varphi_n(s_n), \end{aligned}$$

ただし、至の任意のボレル部分集合 $\bar{\Gamma}$ に対して

$$\bar{\Gamma} = \bar{\Gamma}(y_n, a_n; \bar{\Gamma}) \equiv \{(t_{n+1}, m_{n+1}); u(y_n, a_n, t_{n+1}, m_{n+1}) \in \Gamma\}$$

$$\bar{\Gamma}_m = \bar{\Gamma}_m(y_n, a_n, m_{n+1}; \bar{\Gamma}) \equiv \{t_{n+1}; u(y_n, a_n, t_{n+1}, m_{n+1}) \in \Gamma\}.$$

(ii) 過程の次の状態が y_{n+1} であるという条件の下での y_n の
帶在時間分布 \bar{g} は、 y_n, a_n, y_{n+1} にだけ依存し、次式を満す。

$$\begin{aligned} & \int_{\bar{\Gamma}} \bar{g}(B | s_n, a_n, y_{n+1}) d\bar{g}(y_{n+1} | y_n, a_n) \\ &= \sum_{s_n} \sum_{s_{n+1}} \hat{p}_x(B | s_n, a_n, s_{n+1}) \hat{p}_s(s_{n+1} | s_n, a_n) g_n(s_n), \end{aligned}$$

ただし、 B は \mathbb{R}_+ の任意のボレル部分集合。

$\{y_n, t_n; n \in N\}$ は、 \bar{g} と $\bar{\Gamma}$ により定まるマルコフ再生過程である。

証明

$$\begin{aligned} & \hat{P}\{y_{n+1} \in \Gamma, t_{n+1} \in B | y_0, a_0, t_1, y_1, \dots, y_n, a_n\} \\ &= \hat{P}\{(t_{n+1}, m_{n+1}) \in \bar{\Gamma}, t_{n+1} \in B | \dots\} \\ &= \sum_{s_n} \sum_{s_{n+1}} \hat{P}\{(t_{n+1}, m_{n+1}) \in \bar{\Gamma}, t_{n+1} \in B | s_n, s_{n+1}, \dots\} \\ &\quad \times \hat{P}\{s_{n+1} | s_n, \dots\} g_n(s_n) \\ &= \sum_{s_n} \sum_{s_{n+1}} \sum_{m_{n+1}} \int_{\bar{\Gamma}_m \cap B} f(t_{n+1} | s_n, a_n, s_{n+1}) d\lambda(t_{n+1}) \\ &\quad \times g(m_{n+1} | s_{n+1}) \hat{p}_s(s_{n+1} | s_n, a_n) g_n(s_n). \end{aligned}$$

ここで、 $B = \mathbb{R}_+$ における (i) が得られる。また、

$$\begin{aligned} & \hat{P}\{y_{n+1} \in \Gamma, t_{n+1} \in B | y_n, a_n\} \\ &= \int_{\bar{\Gamma}} \hat{P}\{t_{n+1} \in B | y_n, a_n, y_{n+1}\} d\hat{P}\{y_{n+1} | y_n, a_n\} \end{aligned}$$

が成り立つ。そこで、

$$\bar{P}(B | y_n, a_n, y_{n+1}) \equiv P\{\tau_{n+1} \in B | y_n, a_n, y_{n+1}\}$$

とおくと、この $\bar{P} \in Q(R_+ | A)$ が次の状態が y'_n であるとい
う条件の下での y_n の帶在時間分布を表す。そして、(i) の
証明より (ii) の式が成り立つ。更に、

$$\begin{aligned} & P\{\{(y_{n+1}, \tau_{n+1})\} | y_0, a_0, t_1, y_1, \dots, y_n, a_n\} \\ &= P\{\{(y_{n+1}, \tau_{n+1})\} | y_n, a_n\} \\ &= \bar{g} \otimes \bar{P}(\{(y_{n+1}, \tau_{n+1})\} | y_n, a_n) \end{aligned}$$

が成り立つので、 $\{y_n, t_n; n \in N\}$ は \bar{g} と \bar{P} により定まるマル
コフ再生過程である。

定理 3.2. 任意の政策 ω に対して

$$J_\pi^\omega(y_0) = J_\omega^\omega(y_0) \quad (\forall y_0)$$

なる I-政策 ω が存在する。

証明 任意に与えられた政策 ω に対して I-政策 $\pi^\omega = \{\pi_0^\omega, \pi_1^\omega, \dots\}$ を次のように定義する。

$$\begin{aligned} \pi_0^\omega(\{a_0\} | y_0) &\equiv \omega_0(\{a_0\} | y_0) \\ \pi_n^\omega(\{a_n\} | y_0, a_0, t_1, y_1, \dots, y_n) &\equiv \sum_{m_1, \dots, m_n} \omega_n(\{a_n\} | y_0, a_0, t_1, m_1, \dots, m_n) \\ &\quad \times \bar{P}_n(m_1, \dots, m_n | y_0, a_0, t_1, y_1, \dots, y_n), \end{aligned}$$

ここで、 $b_n^k \equiv (y_0, a_0, t_1, y_1, \dots, y_n)$ は $t_n \equiv (y_0, a_0, t_1, m_1, \dots, m_n)$ に対応する。この π^ω の作り方から、 ω と π^ω は A 上で同一の条件付確率

$$\bar{\Phi}_{\pi^w} \{ \{a_n\} | y_0, a_0, t_1, y_1, \dots, y_n \} = \bar{\Phi}_w \{ \{a_n\} | \text{" } \}$$

を与える。一方、定理3.1.より、

$$\begin{aligned} & \bar{\Phi}_{\pi^w} \{ \{y_{n+1}, t_{n+1}\} | y_0, a_0, t_1, y_1, \dots, y_n, a_n \} \\ &= \bar{\Phi}_w \{ \{ \text{" } \} | \text{" } \} \\ &= \bar{\gamma} \otimes \bar{\Phi} (\{y_{n+1}, t_{n+1}\} | y_n, a_n). \end{aligned}$$

と/or,

$$\bar{\Phi}_{\pi^w} \{ \{a_0, t_1, y_1, \dots, y_n, a_n\} | y_0 \} = \bar{\Phi}_w \{ \{ \text{" } \} | y_0 \}$$

が成り立つ。命題1とその注意より、 π^w が求めるものである。

次に、新しいモデル SMDP-I(重, A, $\bar{\gamma}$, $\bar{\Phi}$, \bar{C}_α , α)を考える。

この SMDP-I の政策は、I-政策と同じものであり、I-政策
 π による期待合計割引コストは

$$I_\pi^\alpha(y_0) = E_\pi \left[\sum_{n=0}^{\infty} e^{-\alpha(t_1 + \dots + t_n)} \bar{C}_\alpha(y_n, a_n) | y_0 \right]$$

で与えられる。ここで、 $E_\pi[\cdot | y_0]$ は、

$$\phi_\pi(\cdot | y_0) = \bigotimes_{n=0}^{\infty} (\pi_n \otimes \bar{\gamma} \otimes \bar{\Phi})$$

による条件付期待値である。

定理 3.3. 任意の I-政策 π に対して、

$$J_\pi^\alpha(y_0) = I_\pi^\alpha(y_0) - \psi(y_0)$$

が成り立つ。

証明 定理3.1.より、 $(A \oplus R_+)^n A$ 上の条件付確率 $\bar{\Phi}_\pi(\cdot | y_0)$ は、次のように分解される。

$$\begin{aligned}
 \bar{\Phi}_\pi \{ \cdot | \varphi_0 \} &= \bar{\Phi}_\pi \{ \{a_0\} | \varphi_0 \} \otimes \bar{\Phi}_\pi \{ \{\varphi_1, t_1\} | \varphi_0, a_0 \} \\
 &\quad \otimes \cdots \otimes \bar{\Phi}_\pi \{ \{a_n\} | \varphi_0, a_0, t_1, \varphi_1, \dots, \varphi_n \} \\
 &= \pi_0 \otimes \bar{\Phi} \otimes \bar{\Phi} \otimes \cdots \otimes \pi_n \\
 &= \bar{\Phi}_\pi \{ \cdot | \varphi_0 \}.
 \end{aligned}$$

したがって、注意1と I_π^α の定義より

$$J_\pi^\alpha(\varphi_0) = I_\pi^\alpha(\varphi_0) \quad (\forall \varphi_0)$$

が成り立つ。

以上の二つの定理より、SMDP-II ($S, M, A, \bar{\Phi}_S, \bar{\Phi}_A, \bar{g}, \varphi_0, C, \alpha$) は、SMDP-I ($\bar{S}, A, \bar{\Phi}, \bar{\Phi}, \bar{C}_\alpha, \alpha$) に同値変形されることがわかる。次の命題は、条件1と定理3.1(ii)より明らかである。

命題2.

$$\int_{\bar{S}} \bar{\Phi}([0, \delta] | \varphi, a, \varphi') d\bar{\Phi}(\varphi' | \varphi, a) \leq 1 - \varepsilon \quad (\forall \varphi, a)$$

なる $\delta > 0$ と $\varepsilon > 0$ が存在する。

$$I^\alpha(\varphi) \equiv \inf_{\pi \in \bar{\Phi}} I_\pi^\alpha(\varphi) \quad (\forall \varphi)$$

ておく。

定理3.4. A は可算集合とする。このとき、 $I^\alpha(\varphi)$ は、 \bar{S} 上のボレル可測関数で次の方程式の一意の解である。

$$(3.2) \quad I^\alpha(\varphi) = \inf_{a \in A} \left\{ \bar{C}_\alpha(\varphi, a) + \int_{\bar{S}} \int_0^\infty e^{-\alpha t} I^\alpha(\varphi') \right. \\ \left. \times d\bar{\Phi}(t | \varphi, a, \varphi') d\bar{\Phi}(\varphi' | \varphi, a) \right\} \quad (\forall \varphi).$$

この方程式は次のように表わすことができる。

$$(3.3) \quad I^\alpha(\varphi) = \inf_{a \in A} \left\{ \bar{C}_\alpha(\varphi, a) + \sum_s \sum_{s'} \sum_{m'} \int_0^\infty e^{-\alpha t} \right. \\ \times I^\alpha(u(\varphi, a, t, m')) d\bar{\rho}(t | s, a, s') \bar{\rho}_s(s' | s, a) g(m' | s) \varphi(s) \right\}$$

(3.2) や (3.3) で、もし各 φ について右辺を最小化する行動が存在すれば、そのように定める定常 I-政策 f_α は α -最適である。

証明 MDP-I での Strauch [11] の結果を SMDP-I に適用する。その結果、 $I^\alpha(\varphi)$ は絶対可測であることと (φ, ε) -最適 I-政策が存在することがわかる。そこで、まず、 $I^\alpha(\varphi)$ が (3.2) の解であることを示す。

$$T_a u(\varphi) = \bar{C}_\alpha(\varphi, a) + \int_0^\infty e^{-\alpha t} u(\varphi') \\ \times d\bar{\rho}(t | \varphi, a, \varphi') d\bar{g}(\varphi' | \varphi, a)$$

ておく。命題 2 より

$$\int_0^\infty e^{-\alpha t} d\bar{\rho}(t | \varphi, a, \varphi') d\bar{g}(\varphi' | \varphi, a) \leq 1 - \varepsilon + \varepsilon e^{-\alpha \delta} < 1 \\ (\forall \varphi, a)$$

が成りたつことを注意する。

$$I_\pi^\alpha(\varphi_0) = E_\pi \left[\sum_{n=0}^{\infty} e^{-\alpha(t_1 + \dots + t_n)} \bar{C}_\alpha(\varphi_n, a_n) \mid \varphi_0 \right] \\ \geq \sum_{a_0 \in A} \varphi_{a_0} T_{a_0} I^\alpha(\varphi_0),$$

ここで、 $\varphi_{a_0} \equiv \pi_0(a_0 | \varphi_0)$ ($\forall a_0$)。したがって、

$$I^\alpha(\varphi_0) \geq \inf_{a_0 \in A} T_{a_0} I^\alpha(\varphi_0).$$

もう一方の不等式を得るために、まず $t=0$ で a_0 を選択し、続いて $\varphi \equiv \bar{g}(\cdot | \varphi_0, a_0)$ に関する (φ, ε) -最適 I-政策 π' を

選択する I-政策を π とする。このとき、

$$\begin{aligned} I_\pi^d(\varphi_0) &= T_{\alpha_0} I_{\pi'}^d(\varphi_0) \\ &\leq T_{\alpha_0}(I^d + \varepsilon)(\varphi_0) \\ &\leq T_{\alpha_0} I^d(\varphi_0) + \varepsilon(1 - \varepsilon + \varepsilon e^{-d\delta}). \end{aligned}$$

したがって、

$$I^d(\varphi_0) \leq \inf_{\alpha_0 \in A} T_{\alpha_0} I^d(\varphi_0) + \varepsilon(1 - \varepsilon + \varepsilon e^{-d\delta}).$$

$\varepsilon > 0$ は任意なので、

$$I^d(\varphi_0) \leq \inf_{\alpha_0 \in A} T_{\alpha_0} I^d(\varphi_0).$$

ゆえに、 $I^d(\varphi)$ は (3.2) の解である。

次に、 $I^d(\varphi)$ はボレル可測であることを示す。再び Strauch [11] より、(3.2) に対する他の有界な解は存在しないことがわかる。すなわち、 $I^d(\varphi)$ は有界な関数の中で (3.2) の一意な解である。一方、

$$\left\| \inf_{\alpha \in A} T_\alpha u - \inf_{\alpha \in A} T_\alpha v \right\| \leq (1 - \varepsilon + \varepsilon e^{-d\delta}) \|u - v\|$$

なので、 $\inf_{\alpha \in A} T_\alpha$ は有界ボレル可測関数の中で一意の不動点をもつ。ゆえに $I^d(\varphi)$ はボレル可測である。

次に定理の後半を証明する。定常 I-政策 f に対して、

$$T_f u(\varphi) \equiv T_{f(\varphi)} u(\varphi) (\forall \varphi)$$

とおく。 f_α の定義より

$$I^d(\varphi) = T_{f_\alpha} I^d(\varphi) (\forall \varphi).$$

一方、 $I_{f_\alpha}^d(\varphi)$ は、

$$I_{f_\alpha}^*(\varphi) = T_{f_\alpha} I_\alpha^*(\varphi) \quad (*\varphi)$$

の一意な解である。したがって、

$$I_{f_\alpha}^*(\varphi) = I^*(\varphi) \quad (*\varphi).$$

ゆえに, f_α は α -最適である。

最後に, (3.2) と (3.3) が同値であることを示す。今は (φ, t) に関する有界なボレル可測関数とする。このとき, 定理

3.1 より

$$\begin{aligned} & \int_0^\infty g(\varphi', t) d\bar{\rho}(t|\varphi, a, \varphi') d\bar{g}(\varphi'|\varphi, a) \\ &= \sum_s \sum_{s'} \sum_m \int_0^\infty g(u(s, a, t, m'), t) d\rho_t(t|s, a, s') \\ & \quad \times \phi_s(s'|s, a) g(m'|s') \varphi(s) \end{aligned}$$

が成り立つ。ちなみに, (3.2) と (3.3) は同値である。

§ 4. 平均基準

これまでには, 割引コスト基準のSMDP-IIについて述べたが, ここでは平均コスト基準のSMDP-IIについて述べる。平均コスト基準のSMDP-IIも α と同様に $(S, M, A, \rho_s, \rho_t, g, c)$ で定義する。割引因子 α はもはや必要なくなる。また, 政策 ω を用いたときの期待平均コストは

$$\bar{J}_\omega(\varphi_0) = \lim_{n \rightarrow \infty} \frac{E_\omega \left[\sum_{i=0}^{n-1} c'(t_{i+1}, s_i, a_i) \mid \varphi_0 \right]}{E_\omega \left[\sum_{i=1}^n t_i \mid \varphi_0 \right]}$$

で与えられる。ただし,

$$c'(t_{i+1}, s_i, a_i) = \int_0^{t_{i+1}} c(t, s_i, a_i) dt$$

もし、以下 c' は有界とする。

$$\bar{J}_{\omega^*}(\varphi_0) \leq \inf_{\omega} \bar{J}_{\omega}(\varphi_0) \quad (\forall \varphi_0)$$

が成り立つとき、 ω^* は平均最適であるといふ。

$$C(s, a) \equiv \sum_{s'} \int_0^\infty c'(t, s, a) dP_t(t|s, a, s') p_s(s'|s, a)$$

$$\tau(s, a) \equiv \sum_{s'} \int_0^\infty \tau dP_t(t|s, a, s') p_s(s'|s, a)$$

とおくと、

$$\bar{J}_{\omega}(\varphi_0) = \lim_{n \rightarrow \infty} \frac{E_{\omega} \left[\sum_{i=0}^{n-1} C(s_i, a_i) \mid \varphi_0 \right]}{E_{\omega} \left[\sum_{i=0}^{n-1} \tau(s_i, a_i) \mid \varphi_0 \right]}$$

が成り立つ。更に、

$$\bar{c}(\varphi, a) \equiv \sum_s C(s, a) \varphi(s)$$

$$\bar{\tau}(\varphi, a) \equiv \sum_s \tau(s, a) \varphi(s), \quad \varphi \in \mathbb{R},$$

とおく。

定理 4.1.

$$(a) \quad \bar{E}_{\omega} [C(s_n, a_n) \mid \varphi_0] = \bar{E}_{\omega} [\bar{c}(\varphi_n, a_n) \mid \varphi_0]$$

$$(b) \quad \bar{E}_{\omega} [\tau(s_n, a_n) \mid \varphi_0] = \bar{E}_{\omega} [\bar{\tau}(\varphi_n, a_n) \mid \varphi_0] \quad (\forall \varphi_0)$$

が成り立つ。

証明

$$\begin{aligned} & \bar{E}_{\omega} [C(s_n, a_n) \mid \varphi_0] \\ &= \int_{S \times A} C(s_n, a_n) d\bar{P}_{\omega} \{ (s_n, \varphi_n, a_n) \mid \varphi_0 \} \\ &= \int_{A} \sum_{s_n} C(s_n, a_n) \bar{P}_{\omega} \{ s_n \mid \varphi_0, \varphi_n, a_n \} d\bar{P}_{\omega} \{ (\varphi_n, a_n) \mid \varphi_0 \} \end{aligned}$$

$$= \int_{\bar{A}} \bar{c}(y_n, a_n) d\bar{\rho}_w \{ (y_n, a_n) | y_0 \} \\ = \bar{E}_w [\bar{c}(y_n, a_n) | y_0].$$

でこれに対しても同様に成り立つ。

注意2. これは、I-政策πに対してても成り立つ。

定理4.2. 任意の政策ωに対して、次の(a), (b)を満すI-政策πが存在する。

$$(a) \bar{E}_\pi [\bar{c}(y_n, a_n) | y_0] = \bar{E}_w [\bar{c}(y_n, a_n) | y_0]$$

$$(b) \bar{E}_\pi [\bar{t}(y_n, a_n) | y_0] = \bar{E}_w [\bar{t}(y_n, a_n) | y_0] \quad (\forall y_0)(\forall n)$$

証明は定理3.2と同様にできる。

平均コスト基準のSMPP-Iもさうの後半と同様に(重、
A, \bar{t} , $\bar{\rho}$, \bar{c})で定義する。また、I-政策πを用いたときの期待平均コストは、

$$\bar{I}_\pi(y_0) \equiv \lim_{n \rightarrow \infty} \frac{E_\pi \left[\sum_{i=0}^{n-1} \bar{c}(y_i, a_i) | y_0 \right]}{E_\pi \left[\sum_{i=1}^n t_i | y_0 \right]} \\ = \lim_{n \rightarrow \infty} \frac{E_\pi \left[\sum_{i=0}^{n-1} \bar{c}(y_i, a_i) | y_0 \right]}{E_\pi \left[\sum_{i=1}^n \bar{t}(y_i, a_i) | y_0 \right]}$$

で与えられる。ここでオスの等式は、 \bar{t} の定義と定理3.1より成り立つことに注意する。

定理4.3. 任意のI-政策πに対して

$$\bar{T}_\pi(y_0) = \bar{I}_\pi(y_0) \quad (\forall y_0)$$

が成り立つ。

証明は定理3.3と同様にできる。

以上の2)の定理より、平均コスト基準のSMDP-II ($S, M, A, \phi_s, \phi_A, g, c$) は SMDP-I ($\bar{S}, \bar{A}, \bar{g}, \bar{F}, \bar{c}$) へ可逆変形されることがわかる。左が、平均最適な I-政策が存在するための十分条件については、Wakuta [12] が議論している。

参考文献

- [1] Åström, K. J. (1965). Optimal control of Markov processes with incomplete state information. *J. Math. Anal. Appl.* 10, 174-205.
- [2] Bellman, R. (1968). New classes of stochastic processes. *J. Math. Anal. Appl.* 22, 602-617.
- [3] Blackwell, D. (1965). Discounted dynamic programming. *Ann. Math. Statist.* 36, 226-235.
- [4] Dynkin, E. B. (1965). Controlled random sequences. *Theory Probability Appl.* 10, 1-14.
- [5] Kurano, M. (1977). On the existence of an optimal stationary I-policy in non-discounted Markov decision processes with incomplete state information. *Bull. Math. Statist.* 17, 75-81
- [6] Rhenius, D. (1974). Incomplete information in Markovian decision models. *Ann. Math. Statist.* 2, 1327-1334.

- [7] Sawaki, K. and A. Ichikawa.(1978). Optimal control for partially observable Markov decision processes over an infinite horizon. J. Oper. Res. Soc. Japan, 21,1-16.
- [8] Sawaragi, Y. and T. Yoshikawa.(1970). Discrete time Markov decision processes with incomplete state observation. Ann. Math. Statist. 41,78-86.
- [9] Shiryaev, A.N. Some new results in the theory of controlled random sequences.
- [10] Sondik, E.(1978). The optimal control of partially observable Markov processes over the infinite horizon; Discounted costs. Oper. Res. 26, 282-304.
- [11] Strauch, R.E.(1966). Negative dynamic programming. Ann. Math. Statist. 37, 871-890.
- [12] Wakuta, K.(1980). Semi-Markov decision processes with incomplete state observation - Average cost criterion-. J. Oper. Res. Soc. Japan. 24, 95-108.
- [13] White, C.C.(1976). Procedure for the solutions of a finite horizon, partially observed, semi-Markov optimization problem. Oper. Res. 24, 348-358.