

An Introduction to Dynamic Programming

一人の意思決定者 (DM) の長期最大化問題

$t = 1$: *initial state* $s_1 \in S$ (exogenous), choose $a_1 \in A$

get reward $r(a_1, s_1) \in \mathfrak{R}$

$t = 2$: state is generated by $s_2(a_1, s_1)$. Choose $a_2 \in A$

get reward $r(a_2, s_2)$

...

a_t は歴史に依存してかまわない

A が s_t に依存したり、 $r(\cdot, \cdot)$ が t に依存したりもある

s_t は確率的に生成されることもある

2 回繰り返しゲームにあてはめると

$$G = (\{1, 2\}, A_1, A_2, u_1, u_2)$$

Focus on Player i as the DM

Player j 's strategy (s_{j1}, s_{j2}) determines states

$s_{j1} \in A_j$: initial state

next period state $s_{j2} : A_i \times A_j \rightarrow A_j$

set of DM's feasible actions $A = A_i$

reward function $u_i : A_i \times A_j \rightarrow \mathfrak{R}$

A_i が有限ならば、2 期間最大化問題とは

$$\max_{a_{i1}, a_{i2} \in A_i} \left\{ u_i(a_{i1}, s_{j1}) + u_i(a_{i2}, s_{j2}(a_{i1}, s_{j1})) \right\} =: f(s_{j1}).$$

($f(s_{j1})$ は Optimal value function と呼ばれる。)

明らかに

$$\begin{aligned} & \max_{a_{i1}, a_{i2} \in A_i} \left\{ u_i(a_{i1}, s_{j1}) + u_i(a_{i2}, s_{j2}(a_{i1}, s_{j1})) \right\} \\ &= \max_{a_{i1} \in A_i} \left\{ u_i(a_{i1}, s_{j1}) + \max_{a_{i2} \in A_i} u_i(a_{i2}, s_{j2}(a_{i1}, s_{j1})) \right\}. \end{aligned}$$

Backward Induction

Optimal value function に書き換える

$$f(s_{j1}) = \max_{a_{i1} \in A_i} \left\{ u_i(a_{i1}, s_{j1}) + f_2(s_{j2}(a_{i1}, s_{j1})) \right\},$$

ここで

$$f_2(s_{j2}(a_{i1}, s_{j1})) = \max_{a_{i2} \in A_i} u_i(a_{i2}, s_{j2}(a_{i1}, s_{j1})).$$

これを一般化して、任意の有限期間最大化の解は後ろ向き帰納法で求められる！

Infinite Horizon Dynamic Programming

割引和を最大化する定常的問題を扱う（一般にはそうでもない）

$t = 1$: initial state $s_1 \in S$. Choose $a_1 \in A$. Get reward $u(a_1, s_1)$.

$t \geq 2$: state transition function $s_t : \{A \times S\}^{t-1} \rightarrow S$

Choose $a_t \in A$ based on the history $h_{t-1} \in \{A \times S\}^{t-1}$.

→ choose a *strategy* $\mathbf{a} = (a_1, a_2, \dots,)$

$a_1 \in A, a_t : \{A \times S\}^{t-1} \rightarrow A, t = 2, 3, \dots$

a sequence of transition functions $\mathbf{s} = (s_1, s_2, \dots)$ も似たような形

(例 : other players' pure strategy combination)

目的関数は

$$V(\mathbf{a}; s_1) := \sum_{t=1}^{\infty} \delta^{t-1} \cdot u(a_t(h_t), s_t(h_t)),$$

where $h_1 = (a_1, s_1)$ and $h_t = (a_t(h_{t-1}), s_t(h_{t-1}))$.

Optimal value function

$$f(s_1) := \sup_{\mathbf{a}} V(\mathbf{a}; s_1).$$

Unimprovable Strategy in One Step

Def. Fix an initial state s_1 and a strategy \mathbf{a} .

For each $t = 1, 2, \dots$ and each history until t -th period, consider a *one-step deviation strategy* : chooses a different action in period t from \mathbf{a} but follows \mathbf{a} from $t + 1$ -th period on.

If no one-step deviation strategy gives a greater total discounted payoff than that of \mathbf{a} ,

then \mathbf{a} is called *unimprovable in one step*.

Lemma. Fix an initial state s_1 . If a strategy \mathbf{a} is unimprovable in one step, then it is unimprovable in any finite steps.

Proof. Unimprovable in one step より

$$V(\mathbf{a}; s_1) = \max_{x_1} \left[u(x_1, s_1) + \delta V(\mathbf{a}(x_1, s_1); s_2(x_1, s_1)) \right],$$

ここで、 $\mathbf{a}(x_1, s_1)$ は continuation strategy と呼ばれ、 $s_2(x_1, s_1)$ を initial state とみなし、 $a_2(x_1, s_1) \in A$ を初期行動としてあとは \mathbf{a} と同じことをするもの

$h_1 = (x_1, s_1)$ の後も unimprovable in one step より

$$V(\mathbf{a}(h_1); s_2(h_1)) = \max_{x_2} \left[u(x_2, s_2(h_1)) + \delta V(\mathbf{a}(x_2, s_2(h_1)); s_3(x_2, s_2(h_1))) \right],$$

合わせると

$$\begin{aligned} V(\mathbf{a}; s_1) &= \max_{x_1} \left[u(x_1, s_1) + \delta \cdot \max_{x_2} \left\{ u(x_2, s_2(x_1, s_1)) \right. \right. \\ &\quad \left. \left. + \delta V(\mathbf{a}(x_2, s_2(x_1, s_1)); s_3(x_2, s_2(x_1, s_1))) \right\} \right] \\ &= \max_{x_1, x_2} \left[u(x_1, s_1) + \delta u(x_2, s_2(x_1, s_1)) \right. \\ &\quad \left. + \delta V(\mathbf{a}(x_2, s_2(x_1, s_1)); s_3(x_2, s_2(x_1, s_1))) \right]. \end{aligned}$$

つまり、 \mathbf{a} は unimprovable in two steps。これを繰り返せばよい。

□

Proposition. Fix an initial state s_1 . If a strategy \mathbf{a} is unimprovable in one step, then \mathbf{a} is an optimal strategy that attains $f(s_1)$.

Proof. 背理法の仮定として、 \mathbf{a} は unimprovable in one step なのに optimal でないとする。すると他の戦略 \mathbf{x} と $\epsilon > 0$ が存在して

$$V(\mathbf{a}; s_1) + 2\epsilon \leq V(\mathbf{x}; s_1).$$

割引和なので、 ϵ を固定すると、十分大きい T が存在して、 \mathbf{x} と最初の T 期間は同じ行動計画をする任意の戦略 \mathbf{y} について、二つの割引総和はほとんど同じにできる。

$$V(\mathbf{x}, s_1) - \epsilon \leq V(\mathbf{y}, s_1).$$

特に y として T 期以降は a と同じ行動計画を持つ戦略にしてもよい。
合わせて

$$V(\mathbf{a}; s_1) + \epsilon \leq V(\mathbf{y}, s_1).$$

しかし、 y は T 期間しか a と違う行動をしないから、これは Lemma より a が unimprovable in finite steps であることに矛盾する。 \square