

最適化と行動モデル

浦田淳司（筑波大学）

第25回行動モデル夏の学校

2026年9月8日

尤度最大化

行動モデル（離散選択モデル）：

選択効用
$$U_{ia} = \sum_k \underbrace{\beta_{ak} x_{iak}}_{\text{確定効用}} + \underbrace{\varepsilon_{ia}}_{\text{誤差効用}}$$

a : 選択肢
 i : 個人
 β : 選好パラメータ
 x : 説明変数
 δ_i : 選択結果
 $\varepsilon \sim i.i.d \text{ Gumbel}$

選択確率
$$P_i(a|\boldsymbol{\beta}) = \frac{\sum_k \beta_{ak} x_{ak}}{\sum_{\forall a} \sum_k \beta_{ak} x_{ak}}$$

パラメータ推定
 （尤度最大化）
$$\hat{\boldsymbol{\beta}} = \underset{\boldsymbol{\beta}}{argmax} \left(LL(\boldsymbol{\beta}|\boldsymbol{\delta}) = \sum_{\forall i} \delta_i(a) \log P_i(a|\boldsymbol{\beta}) \right)$$

最適化

尤度最大化の手法

<https://www.bin.t.u-tokyo.ac.jp/kaken/pdf/mnl.pdf> より

9 対数尤度関数の最大化

```
76 ##### 対数尤度関数 fr の最大化#####
77
78 ##パラメータ値の最適化
79 res <- optim(b0, fr, method = "Nelder-Mead", hessian = TRUE, control=list(fnscale=-1))
80
```

パラメータ”b0”に対して対数尤度関数”fr”を最大化し、その結果を”res”に出力します。

※optim 関数について

optim 関数は以下のような引数をとります。

```
optim(par, fn, gr = NULL, method = "Nelder-Mead", lower = -Inf, upper = Inf,
      control = list(), hessian = FALSE)
```


par	初期値(必須)
fn	最適化する目的関数(必須)
gr	一階偏微分関数の指定(NULL でデフォルト関数使用)
method	最適化手法の指定(5 種類から選ぶ, Nelder-Mead(デフォルト), BFGS, CG, L-BFGS-B, SANN)
lower	L-BFGS-B 法での変数の下限(デフォルトは -Inf)
upper	L-BFGS-B 法での変数の上限(デフォルトは Inf)
control	制御パラメータ
fnscale	関数に与える比例定数, optim 関数は最小化を行うので, 最大化のときは, control=list(fnscale=-1) と指定します. ここでは尤度を最大化しています.
hessian	最適解のヘッセ行列を返すかどうか, パラメータ推定では, t 値計算にヘッセ行列が必要なので, hessian = TRUE とします.

尤度（連続量）を
最大化するための手法

最大化アルゴリズムの考え方

周りが見えない中で、近傍の情報から頂点を目指す

- 対数尤度関数の段階的な最大化
 - 初期値を与える
 - 初期値周りで勾配(1次微分) 等を用いて次の推定値の方向を決める
 - 初期値付近で1次微分, 2次微分を用いて適切に次の点を決めて推定値を得る
 - 収束基準(一次微分ベクトル)で判定し, 収束していない場合は, 現在の値から次の推定値に移る



佐々木先生
BMSS2023



代表的な繰り返し計算法


尤度関数を最大化 尤度関数の一階微分 = 0 を解く

- Newton-Raphson法

- テイラー展開の1次近似を利用して進める

- 準Newton法 (BFGS, L-BFGS法)

- ヘッセ行列を, パラメータの差分と一階微分の差分を用いて逐次近似する.
 - L-BFGSはヘッセ行列の更新式を展開して, 初期値と差分の関数とで表す.



H: 尤度関数の二階微分 ヘッセ行列
g: 尤度関数の一階微分

佐々木先生
BMSS2023



シミュレーション最適化

微分によらない最適化

Simulated ANNealing (SANN) ※Kirkpatrick et al. (1983), Belisle (1992)

$$\max_{\beta} \left(LL(\beta|\delta) = \sum_{\forall i} \delta_i(a) \log P_i(a|\beta) \right)$$

現在の解 β_t から近傍解 y を生成

$$y \sim q(y|\beta_t)$$

目的関数の差を算出

$$\Delta = LL(y) - LL(\beta_t)$$

改善解の場合


$$\text{if } \Delta \geq 0 \Rightarrow \beta_{t+1} = y$$

悪化解の場合

$$\text{if } \Delta < 0 \Rightarrow \beta_{t+1} = y \text{ with } P(\text{accept}) = \exp\left(\frac{\Delta}{T_t}\right)$$

温度 T を徐々に冷却

$$T_{t+1} = \alpha T_t \quad (0 < \alpha < 1)$$



1.尤度最大化（連続量最適化）

a. 基礎編

詳しくは22回のスライド

b.入れ子型の行動モデル ←



2.離散最適化と行動モデル


a. 解法

b. 目的関数


動的選択問題とは

静学問題

時刻 t_0




3選択肢



動学問題


時刻 t



3^4 選択肢

動的離散選択モデル(概要)

Rust, J.(1987) のバスエンジン補修/交換の問題を例に説明



ある期の効用関数 u

$$u(x, d, \varepsilon; \theta_1, RC) = v(x, d; \theta_1, RC) + \varepsilon(d)$$

$$v(x, d; \theta_1, RC) = \begin{cases} -c(x; \theta_1), & \text{if } d = 0 \\ -RC - c(0; \theta_1), & \text{if } d = 1 \end{cases}$$

$d=1$: 交換, $d=0$: 補修のみ
 x : バスエンジンの状態

ε : 非観測項

c : 補修コスト

θ_1 : 補修パラメータ

RC : 交換コスト

θ_2, θ_3 : 状態推移パラメータ

状態 x の推移確率 (一次マルコフ性を仮定)

$$p(x_{t+1}, \varepsilon_{t+1} | x_t, \varepsilon_t, d_t; \theta_2, \theta_3)$$

動的離散選択モデル(定式化)

将来の価値関数は、時間割引を考慮した効用の最大化となる

$$V(x_t, \varepsilon_t) = \max_{\{d_t, d_{t+1}, d_{t+2}, \dots\}} \mathbb{E} \left[\sum_{\tau=t}^{\infty} \beta^{\tau-t} u(x_\tau, d_\tau, \varepsilon_\tau; \theta_1, \text{RC}) \right] \quad \text{時間割引率 } \beta \in (0,1)$$

最適意思決定は無限期間先までを考慮しており、期によらず一定である

- 今期と次期の状態に依り、価値関数を定義

- 次期の期 **入れ子になっているP・EVをどう計算するか**

$$\boxed{V(x, \varepsilon)} = \max_d \left\{ \overbrace{\nu(x, d; \theta_1, \text{RC}) + \varepsilon(d)}^{\text{今期の効用}} + \beta \underbrace{\int_{x'} \int_{\varepsilon'} \boxed{V(x', \varepsilon')} p(x', \varepsilon' | x, \varepsilon, d; \theta_2, \theta_3) dx' d\varepsilon'}_{\text{次期の期待価値関数EV}} \right\} \quad \text{次期状態}(x', \varepsilon')$$

次期の効用 今期の選択後の次期状態の推移確率


$$\text{選択確率 } P(d|x; \theta) = \frac{\exp[\nu(x, d; \theta_1, \text{RC}) + \beta \text{EV}(x, d)]}{\sum_{d' \in \{0,1\}} \exp[\nu(x, d'; \theta_1, \text{RC}) + \beta \text{EV}(x, d')]$$

$$\text{尤度 } \ell(\theta) = \prod_{i=1}^M \ell_i(X^i; \theta) = \prod_{i=1}^M \prod_{t=2}^T P(d_t^i | x_t^i; \theta) p_3(x_t^i | x_{t-1}^i, d_{t-1}^i; \theta_3)$$

パラメータ推定方法①：NFXP法

Rust, J.(1988) Statistical Models of Discrete Choice Processes, Transportation Research Part B, Vol. 22(2), pp. 125-158.

NESTED FIXED POINT MAXIMUM LIKELIHOOD ALGORITHM



推定法②：NPL(擬似最尤推定法)

Aguirregabiria and Mira(2002)

Step1: EV_0 をランダムに与える

Step2: EV_k を次式の右辺に代入し，尤度最大化するパラメータ θ_k を求める

$$P(d|x; \theta) = \frac{\exp[\nu(x, d; \theta_1, RC) + \beta EV(x, d)]}{\sum_{d' \in \{0,1\}} \exp[\nu(x, d'; \theta_1, RC) + \beta EV(x, d')]}$$

Step3: EV_k と θ_k を用いて，次式より EV_{k+1} を求める $\Leftrightarrow$ NFXPのInner Algorithm

$$EV(\hat{x}_k, d) = \sum_{j=0}^J \log \left\{ \sum_{d' \in \{0,1\}} \exp[\nu(x', d'; \theta_1, RC) + \beta EV(x', d')] \right\} \\ \times p_3(x'|\hat{x}_k, d, \theta_3).$$

仮のEVのまま，繰り返し計算する

収束判定: $|EV_{k+1} - EV_k|$ と $|\theta_{k+1} - \theta_k|$ が十分小さければ収束
収束していなければ，step2に戻る

無限回の繰り返し計算によって不動点を得ることができ，NFXPと漸近等価

推定法3：MPEC型アルゴリズム

(Su & Judd (2012))

MPEC (Mathematical Programming with Equilibrium Constraints)を用いた求解
等価な均衡制約条件付き最適化問題と定式化.

$$\begin{aligned} \max_{(\theta, \underline{\mathbf{EV}})} \quad & \frac{1}{M} \mathcal{L}(\theta, \mathbf{EV}) && \text{(最適化問題)} \\ \text{subject to} \quad & \mathbf{EV} = T(\mathbf{EV}, \theta) && \text{(不動点制約)} \end{aligned}$$

NFXPが不動点の算出プロセスを毎回解いているのに比べて、
Bellmanの等式を一度評価すればよいので、計算負荷は小さい。

1. 尤度最大化（連続量最適化）

- a. 基礎編

- b. 入れ子型の行動モデル

2. 離散最適化と行動モデル

- a. 解法

- b. 目的関数

離散最適化と行動モデル



最適化問題とは

目的関数

制御変数 $\rightarrow x$
(離散/連続)

$$\min f(x)$$

subject to $g(x) = 0, h(x) > 0$

制約条件 (等式制約, 不等式制約)

The diagram illustrates the components of an optimization problem. The objective function $f(x)$ is labeled '目的関数' (Objective Function) with a red arrow pointing to it. The decision variable x is labeled '制御変数 (離散/連続)' (Control Variable (Discrete/Continuous)) with a red arrow pointing to it. The constraints $g(x) = 0$ and $h(x) > 0$ are collectively labeled '制約条件 (等式制約, 不等式制約)' (Constraint Conditions (Equality Constraint, Inequality Constraint)) with a red arrow pointing to the constraint part of the equation.

交通分野の最適化とは？

$$\min_x f(x)$$

subject to $g(x) = 0, h(x) > 0$

制御変数

目的関数


制約条件

トラック配送

配送経路

旅行時間最小化

配送場所



交通分野の最適化とは？

$$\min_x f(x)$$

subject to $g(x) = 0, h(x) > 0$

制御変数

目的関数

制約条件

トラック配送

配送経路

旅行時間最小化


配送場所

バス路線

路線選定

収益最大化？
乗客効用最大化？

車両台数



交通分野の最適化とは？

$$\min_x f(x)$$

subject to $g(x) = 0, h(x) > 0$

制御変数

目的関数

制約条件

トラック配送

配送経路

旅行時間最小化

配送場所

バス路線

路線選定

収益最大化？
乗客効用最大化？


車両台数

シェアサイクル

ポート位置

収益最大化

自転車配置数



(シミュレーション評価)

交通分野の最適化とは？

$$\min_x f(x)$$

$$\text{subject to } g(x) = 0, h(x) > 0$$

制御変数

目的関数

制約条件

トラック配送

配送経路

旅行時間最小化

配送場所

バス路線

路線選定

収益最大化？
乗客効用最大化？

車両台数

シェアサイクル

ポート位置

収益最大化

自転車配置数

公共施設

位置配置

受益者利益？
まちなか回遊？

利用可能敷地
予算

最適化と行動モデルの組合せ（二段階最適化）

最適化問題

上位問題：ネットワーク計画

便益最大化（B/C），旅行時間最小化

サービスレベル変化

需要変化

下位問題：利用者行動

交通需要，立地選択，経路選択

交通ネットワーク配分／交通需要予測

（シミュレーションの場合も）

（行動モデル）

二段階最適化：鉄道整備事業

活動・移動パターン⇔鉄道ネットワーク

企業・住宅の立地パターン⇔鉄道ネットワーク



制御変数

：リンク

目的関数・効用


：交通量，移動時間，地価

制約条件


：投資額，開発余地



二段階最適化：最適施設設計画



離散最適化（組合せ最適化）



$$x_{ij} = 0 \text{ or } 1$$

リンクの組み合わせ数 $2^{\text{リンク数}}$ → 組み合わせ爆発

- 厳密解法：分枝限定法，動的計画法
- 近似解法：メタヒューリスティックス

※厳密解にこだわらない場合も ⇔ 問題設定自体が近似

貪欲法：最小木問題

貪欲法(Greedy algorithm)：


最も効果的なものから追加していく。

※問題によって、厳密解を得られる場合と、近似解しか得られない場合とある

最小木問題(Minimum spanning tree)：


最小となる全域木を求める問題。

全域木：すべてのノードが連結し、閉路をもたない木



最小木問題→道路ネットワーク計画²⁶


6つの都市を、(最小のコストで)繋ぐ自動運転ネットワーク計画



メタヒューリスティクス

厳密解法 (Exact Algorithm)

最適性の保障された解を求める手法



近似解法 (Approximate Algorithm)

ある程度良い解が得られると保証されている手法

発見的解法 (Heuristics)

求められた解に精度の保証はないが、経験的に近似解が得られるとわかっている方法


汎用的発見的解法 (Meta-Heuristics)

最適化問題の特徴に依存せず、経験的に近似解が得られるとわかっている方法

メタヒューリスティクス

解くための工夫の仕方が色々ある.


- 近傍の利用：暫定解の近傍を探索する
- 履歴：直前にダメだった解に戻らないよう探索する
- ランダム性：行き詰ったらランダムに解を生成
- 変形：目的関数／制約条件内の重みを変化
- 複数の解：並行して探索する



メタヒューリスティクス

解くための工夫の仕方が色々ある.


- 近傍の利用：暫定解の近傍を探索する
- 履歴：直前にダメだった解に戻らないよう探索する
- ランダム性：行き詰ったらランダムに解を生成
- 変形：目的関数／制約条件内の重みを変化
- 複数の解：並行して探索する



メタヒューリスティクス

解くための工夫の仕方が色々ある.


- 近傍の利用：暫定解の近傍を探索する
- 履歴：直前にダメだった解に戻らないよう探索する
- ランダム性：行き詰ったらランダムに解を生成
- 変形：目的関数／制約条件内の重みを変化
- 複数の解：並行して探索する



メタヒューリスティクス

解くための工夫の仕方が色々ある.


- 近傍の利用：暫定解の近傍を探索する
- 履歴：直前にダメだった解に戻らないよう探索する
- ランダム性：行き詰ったらランダムに解を生成
- 変形：目的関数／制約条件内の重みを変化
- 複数の解：並行して探索する




メタヒューリスティクス

解くための工夫の仕方が色々ある.

- 近傍の利用：暫定解の近傍を探索する
- 履歴：直前にダメだった解に戻らないよう探索する
- ランダム性：行き詰ったらランダムに解を生成
- 変形：目的関数／制約条件内の重みを変化
- 複数の解：並行して探索する



目的関数の設定～最適避難計画を例に～




最適避難計画の考え方：流出時混雑

限られた流入路上で渋滞が発生

⇒ ①早期避難のための流出制御，ネットワーク計画

▼「もうここまで渋滞になっているわけさ，皆山に逃げるために～」(陸前高田市インタビュー)

▼「向こうに行く車は，完全に川とか海の方に行く道なので，を止めて，こっちの高田一中に向かうこの道になっているんですが，全部こっちに誘導する形ですね。」(NHK東日本大震災アーカイブス)




最適避難計画の考え方：共同避難

限られた流入路上で渋滞が発生

⇒ ①早期避難のための流出制御，ネットワーク計画

▼「もうここまで渋滞になっているわけさ，皆山に逃げるために～」(陸前高田市インタビュー)

▼「向こうに行く車は，完全に川とか海の方に行く道なので，を止めて，こっちの高田一中に向かうこの道になっているんですが，全部こっちに誘導する形ですね。」(NHK東日本大震災アーカイブス)



避難開始の遅れ

⇒ ②促進のための共同避難とその動的制御


共同避難が増えれば，避難促進は進むが，道路混雑悪化

▼「同居する両親が気掛かりで，迷わず～自宅に車を走らせた．～．日和大橋を抜ける道は大渋滞で，～．自宅前も渋滞しており，～．両親が出たのを確認後，隣に住むおじいちゃんと一緒に逃げようと思った」(三陸河北新報社インタビュー)

目的関数の色々

		避難猶予時間 短への対応	全員避難の 方策検討	時空間 リスク分布	計算設定上 の課題
総旅行時間 最小化	$\min \int_0^T \sum_a x_a(t) dt$	×	○	×	—
避難完了人数 最大化	$\max \int_0^T \mu_{out}(t)$			×	×
全員避難完了 時刻最小化	$\min T$			×	○
総被災リスク 最小化	$\min \int_0^T \sum_e R_e$			○	×
$x_a(t)$: 時刻t リンクaの交通量	$\mu_{out}(t)$: 時刻t ゾーンeのリスク				

全員避難の猶予がある状況で、避難移動の効率化が目標



× × Tの設定
な人への対策・計画が必要

× ○ Tの設定なし
ないという最大目標と合致

○ × R_e の設定
バラつき・推移を反映可能

時刻t ゾーンeのリスク T: 終端時刻

最適化問題とは

目的関数

制御変数 $\longrightarrow x$
(離散/連続)

$$\min f(x)$$

subject to $g(x) = 0, h(x) > 0$

制約条件 (等式制約, 不等式制約)