



スタートアップゼミ
個人発表⑤

Activity-Based Models

2026/04/23
B4 饗場清日



Activity-Based Models



Activity Based Model(ABMs)とは？

ABMs = 行動モデルが記述する選択行動を単独のトリップから一日の活動スケジュール全体に拡張するという視点に立つモデルの総称


分析の基本単位

これまで:トリップ



交通手段選択、経路選択などを扱ってきた
4段階推定法の問題点:1日の中で活動がどのように連鎖し、トリップがいかにして生じるかということ記述できない

ABMs:活動スケジュール全体



トリップ=活動の派生需要

個人の行動は、
活動種類、開始時刻、終了時刻、活動場所
の**活動経路**と呼ばれる系列で記述される

活動スケジュール全体を対象とすることで、個人の行動をより**包括的に記述**することができる

Activity Based Modelsの基本的な考え方

・個人の活動スケジュールを基本単位とする枠組み



・トリップは活動の派生需要

・時間的制約(1日は24h)、空間的制約(移動には時間がかかる)、個人属性による制約(自動車免許の有無など)のもと決定される

・活動ベースアプローチの利点

- ・活動間の連鎖、時間配分の制約を明示的に扱うことができる
- ・通勤帰りに買い物に立ち寄る行動、勤務時間の変更が余暇活動に与える影響などの記述が自然にできる

・経路選択モデルを用いて記述可能

(a)階層的選択モデル: 活動スケジュールの決定を階層的なNLモデルとして記述する

1日の活動パターン、主活動の時間帯、目的地や交通手段をそれぞれ異なる階層において設定する。理論的整合性と解釈可能性にすぐれるが設定が困難。


(b)逐次的選択モデル: Recursive Logit Modelを活動スケジュールリングに適用し、活動の逐次的な選択過程を記述するモデル

様々なActivity-Based Models

活動ニーズモデル

実際の個人の活動スケジュールは日ごと (day-to-day) で変動する
活動ニーズに基づくモデル

- 日間変動の構造を明示的に表現できる
- × 閾値やニーズ蓄積関数の設定が分析者の事前知識に依存する
- × 明示的な構造を仮定するために柔軟な代替パタンの表現が難しい



離散連続モデル

活動種類の選択 (離散選択) と各活動への時間配分 (連続選択) を同時に扱うモデル

行うか行わないか？

何分割くか

離散連続モデル

Corner Solution

K種類の活動に対して、各個人は各活動 k に対して、 $t_k \geq 0$ 分

制約: $\sum_{k=1}^K t_k = T$ (T は総利用可能時間)を最大化する

この時に、その日に行わない活動種類に対しては配分時間が 0 になる

多くの活動種類に対して配分時間が 0 になる

Corner Solution = 最適解が定義域の境界上に位置する状況のこと

通常の連続最適化では内点解であることを前提とするので適切に扱うことができない

離散連続モデルは Corner Solution に対処することができる

離散連続モデルの2系譜

2つの系譜

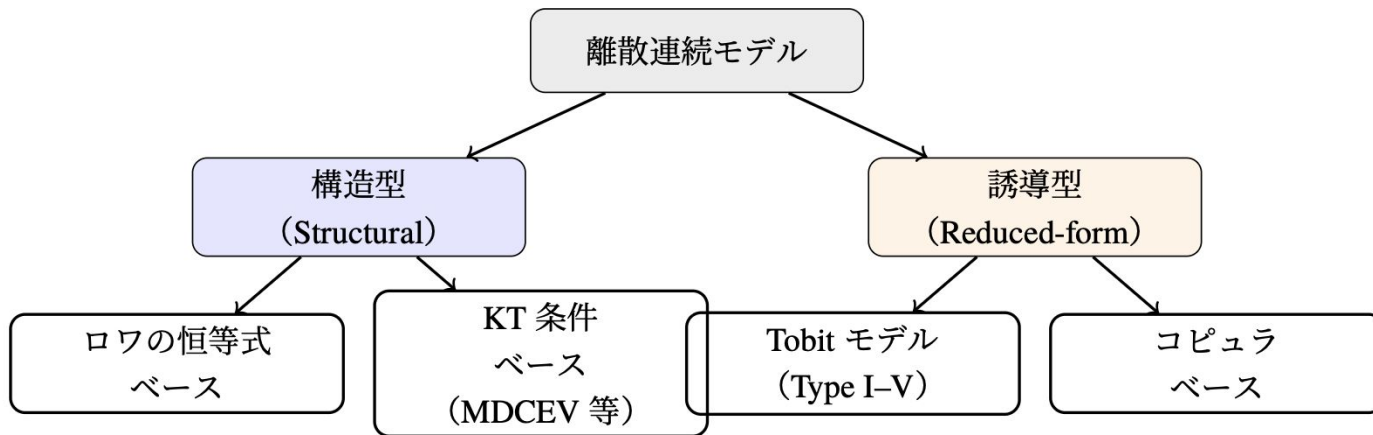


図 3.6 離散連続モデルの系譜. 福田・力石 [22] に基づく分類.

離散連続モデル: 構造型

ミクロ経済理論に立脚

資源制約下での効用最大化問題 からモデルを導出する方法

○ 経済理論との整合性

× 効用関数の関数形が制約される

行うか行わないか 何分行うか

× 離散選択と連続選択に**同一の評価関数**を用いるので、
活動頻度と活動時間が比例しないような活動の記述が困難
e.g. 頻度は低いですが時間がかかる(旅行、冠婚葬祭、健康診断 ...)

構造型の例: MDCEVモデル

活動種類と時間配分の同時決定
が統一的に扱える! 広く使用

構造型離散モデルの中で最も広く使われているモデル

KT条件に基づき、K個の財の消費量を資源制約のもと決定する
個人は直接効用関数を **資源制約のもとで最大化** する

限られた時間の中でどの活動に
どれだけの時間を割けば幸せになれる
か?

変換パラメータ(消費単位を調整)

飽和パラメータ: 限界効用逓減の法則
 α_k 同じ活動だけやり続けても満足度上がりにくくなる。複数の活動 \downarrow に時間を割こうとする。

$$\max_{\mathbf{t}} U(\mathbf{t}) = \sum_{k=1}^K \frac{\gamma_k}{\alpha_k} \psi_k \left[\left(\frac{t_k}{\gamma_k} + 1 \right)^{\alpha_k} - 1 \right], \quad \text{s.t.} \quad \sum_{k=1}^K t_k = T, \quad t_k \geq 0$$

\uparrow ベースライン効用
 $\psi_k = \exp(\beta^T \mathbf{x}_k + \varepsilon_k)$

\downarrow 各活動への時間配分ベクトル

KT条件

活動kに正の時間が配分されるための条件はその活動の限界効用が Shadow price λ 以上であること
(費やす時間が増えた時に増える満足度)

$$\frac{\partial U}{\partial t_k} = \lambda \quad \text{if } t_k > 0$$
$$\frac{\partial U}{\partial t_k} < \lambda \quad \text{if } t_k = 0$$

限界効用が λ に達しなければ $t_k=0$ であり、
Corner Solution が **内生的に生じる**
(外からルールを与えずに)

誤差項 ε_k にはガンベル分布を仮定するので活動の選択確率が閉じた形で得られる

離散連続モデル;誘導型

統計モデルによる**現象の直接的な記述**に主眼をおく

- 資源制約を明示的に課さないため、現象記述の自由度が高い
- 離散選択と連続選択に異なる評価関数を用いることもできる
- × 経済理論との整合性は必ずしも保証されない

代表的なもの:Tobitモデルとその拡張

誘導型の例: Tobitモデル

Tobit Model;
潜在変数が閾値を超えた時にのみ正の値が観測される構造

[1] Type I Tobit モデル: by Tobin

離散問題と連続問題を同一の評価関数で記述する。双方の選択に共通のパラメータ β
「活動の実行しやすさ」と「実行した場合の時間の長さ」に異なる要因が影響する状況記述不可

$$t_k = \max(0, t_k^*), \quad t_k^* = \beta^\top \mathbf{x}_k + \varepsilon_k$$

潜在変数 $t_k^* > 0$ 時に活動が実行され、その値がそのまま活動時間になる。
端点解($t_k = 0$: 離散選択問題として解釈すればKT条件下の構造型モデルと同じ

[2] Type II Tobit モデル (Heckmanモデル)

離散問題と連続問題に異なる評価関数を許容する。それぞれに互いに独立な潜在変数をおく。

$$y_{\text{act}}^* = \alpha^\top \mathbf{w} + \varepsilon_{\text{act}} \quad \text{活動実行}$$

$$y_{\text{time}}^* = \beta^\top \mathbf{x} + \varepsilon_{\text{time}} \quad \text{活動時間}$$

$$y_{\text{time}} = \begin{cases} y_{\text{time}}^*, & \text{if } y_{\text{act}}^* > 0 \\ 0, & \text{if } y_{\text{act}}^* \leq 0 \end{cases} \quad y_{\text{act}}^* > 0 \text{ の時のみ、時間現れる}$$

誤差項: 二変量正規分布に従い、相関係数をもつ

誤差項に相関がある $\rho \neq 0$ の時、活動実行の判断と活動時間の決定が共通の非観測要因で結びつけられる
 $\rho = 0$ では [1] と同じ

実行と時間別なパラメータで表現
逐次的に実行有無や時間を決定できる
資源制約が不要である

誘導型の例: Tobitモデル2

[3] Type II Tobitモデルの応用

モデルの判別関数に対して、活動欲求の概念を導入

個人がまちなかに流入してから退出するまでの一連の活動を対象とする。

活動欲求 = 閾値 - 充足度で定義し、活動発生を記述する

n回目の活動終了後の活動欲求は以下で定義される。

潜在時間による充足、 T_t はt回目の活動の滞在時間
その場所に長くいるほど満足度は上がるかどうか

↓活動内容(履歴)による充足c

S_{nj} : 駅が近い、駐車場がありなど
駅が近いと満足して帰ろうかとなりやすい

$$V_{act,n} = N^* - N_n, \quad N_n = \sum_{t=1}^n \left(\beta_{act} T_t + \sum_i \gamma_{ti} I_{ti} \right) + \sum_j \delta_{nj} S_{nj} \quad (3.57)$$

活動欲求 = 閾値 - 充足度

過去の活動における蓄積

現在地空間特性

個人属性・ツアー変数で決定↑

$V_{act,n} > 0$ であれば活動欲求が残存しており、次の活動が発生

$V_{act,n} \leq 0$ であれば欲求が充足され、回遊が終了する

この活動欲求を Type II Tobitモデルの判別関数として用いることで以下のモデルが立式される

活動欲求↓

$$y_{act}^*(n) = V_{act,n} + \epsilon_{act} \quad (3.58)$$

$$y_{time}^*(n) = \beta_{time}^\top \mathbf{x}_{time,n} + \epsilon_{time} \quad (3.59)$$

$$y_{time}(n) = \begin{cases} y_{time}^*(n), & \text{if } y_{act}^*(n) > 0 \\ 0, & \text{if } y_{act}^*(n) \leq 0 \end{cases} \quad (3.60)$$

これまでに活動に満足したからもう参加しない、が表現できる

尤度関数は誤差項に2変量正規分布を仮定して以下

標準正規分布の ρ ; 確率密度関数、 Φ ; 分布関数

標準正規密度関数の累積分布関数

$y_{act}^*(n) \leq 0$ なる確率を計算

活動時間が y_{time} になる確率密度

参加したという事実とその時間が y_{time} であったという事実を同時に満たす確率を求めている
= y_{time} が分かっている状況下での $y_{act}>0$ になる確率

ϵ_{time} は平均0、標準偏差 σ ↓

↓予測よりもどれだけ長く活動したか

$$L = \prod_{y_{act}=0} (1 - \Phi(V_{act,n})) \times \prod_{y_{act}>0} \left[\frac{1}{\sigma} \phi\left(\frac{y_{time} - \beta_{time}^\top \mathbf{x}}{\sigma}\right) \Phi\left(\frac{V_{act,n} + \sigma^{-1} \rho (y_{time} - \beta_{time}^\top \mathbf{x})}{\sqrt{1 - \rho^2}}\right) \right] \quad (3.61)$$

活動しなかったケース

活動したケース

↑ ρ : ϵ_{act} と ϵ_{time} の相関係数
大きいほど分母は小さくなり予測の精度

右側の項について、2変量正規分布の条件付き累積分布関数について ϵ_{time} が確定した時平均が ϵ_{time}/σ 、分散が $1-\rho^2$ にシフトする。その条件下で $y_{act}>0$ となる確率を表す。

$$\Phi\left(\frac{V_{act,n} + \text{補正項}}{\text{修正後の標準偏差}}\right)$$

→推定の結果; 買い物、娯楽活動の累積が次の活動発生を推進すること
主目的地での活動後に回遊が終了しやすい

活動履歴が次の活動の発生確率に与える影響 と活動時間の決定を統一的に扱うことができる!

比較表

表 3.3 MDCEV モデルと Type II Tobit モデルの比較

	MDCEV (構造型)	Type II Tobit (誘導型)
理論的基盤	KT 条件に基づく効用最大化	統計モデルによる現象記述
評価関数	離散・連続に同一の効用関数	離散・連続に異なる関数を許容
資源制約	$\sum t_k = T$ を明示的に課す	資源制約を必要としない
誤差分布	ガンベル分布 (閉じた形の確率)	正規分布 (二変量正規で相関を記述)
Corner Solution	KT 条件から内生的に導出	潜在変数の閾値構造で記述
活動間相互作用	飽和パラメータで間接的に表現	判別関数への履歴変数導入で直接表現可能
適用場面	複数活動の同時配分	逐次的な活動実行・時間決定

経済理論との適合性を重視し、資源制約下での配分問題として記述する場合

現象記述の自由度や不完全性への対処重視する場合に適している

折衷モデルの構築も試みられている

3.5 モデルの推定と検定

モデルの推定と検定

行動モデルを用いた分析の真髄

実データを下にモデルパラメータを推定すること

モデル推定の目標

モデルの出力が実データにできるだけ近くなるようなパラメータ β を見つける

離散選択モデルにおいては？

最尤推定法 ; 尤度を最大化するようなパラメータを求める

あるパラメータのもとで実際に観測されたデータが得られる確率のこと

MNL モデルにおける尤度関数

M人がN個の選択肢の中から独立に選択行動を行うとして

$$P(y_1; \mathbf{x}_1, y_2; \mathbf{x}_2, \dots, y_M; \mathbf{x}_M) = \prod_{k=1}^M P(y_k; \mathbf{x}_k) \quad (3.62)$$

↑説明変数

k番目の人が説明変数 \mathbf{x}_k の下で選択結果 y_k を選択する確率

パラメータ β の下で観測データが得られる確率そのものである。尤度関数は以下

$$L(\beta) := \prod_{k=1}^M P(y_k; \mathbf{x}_k) = \prod_{k=1}^M \frac{\exp(V_{y_k})}{\sum_{a=1}^N \exp(V_a)}$$

尤度関数

期待効用

実際の計算では尤度は非常に小さな値を取る所以对数尤度を考え、対数尤度の最大化を考える(対数は単調増加関数なので結果は変わらない)

$$LL(\beta) := \log L(\beta) = \sum_{k=1}^M \log P(y_k; \mathbf{x}_k)$$

識別可能性

尤度を最大化するパラメータの組が一意に定まること が最尤推定で意味のある結果を返すために必要

離散選択モデルにおいて、識別の問題が起きるパターン
: 選択肢固有の定数項 (ASC) の扱い

全選択肢に同じ定数項を加えても選択確率は変化しない
 $(\beta_S, \beta_B, \beta_P)$ $(\beta_S + c, \beta_B + c, \beta_P + c)$: 選択確率

$$V_S = \beta_{time}x_{S,time} + \beta_{cost}x_{S,cost} + \beta_{S,age}x_{age} + \beta_S$$

$$V_B = \beta_{time}x_{B,time} + \beta_{cost}x_{B,cost} + \beta_{B,age}x_{age} + \beta_B$$

$$V_P = \beta_{time}x_{P,time} + \beta_{cost}x_{P,cost} + \beta_{P,age}x_{age} + \beta_P$$



$$V_S = \beta_{time}x_{S,time} + \beta_{cost}x_{S,cost} + \beta_{S,age}x_{age}$$

$$V_B = \beta_{time}x_{B,time} + \beta_{cost}x_{B,cost} + \beta_{B,age}x_{age} + \beta_B$$

$$V_P = \beta_{time}x_{P,time} + \beta_{cost}x_{P,cost} + \beta_{P,age}x_{age} + \beta_P$$

自由度を一つ下げれば
いい!

効用の絶対値に意味はなく、差だけが選択確率を決定する

検定

パラメータの値が信頼できるか？ 以下の問い2つに答える必要

1. 推定された各パラメータが0と有意に異なるのか？
2. 全体がNull Model(パラメータが全部0)の比べて有意に適合度が高いかを判定する(尤度比検定)

検定の流れ(共通)

1. 推定量が確率変数であることを利用してその分布を考える
2. 帰無仮説のもとで観測結果がどの程度起こりうるか？を評価

推定値、推定量、最尤推定量の性質

最尤推定値 : $\hat{\beta}$ 具体的な値、標本の選び方により変化 値

統計量 : 標本変量の関数

推定量 ; 推定のために構成される統計量 データを入れたら数値がかえる数式の方

最尤推定量の特徴; 漸近的な性質

1. 一致性; 標本数を無限に増やすと、最尤推定値がパラメータの真値に収束
2. 漸近正規性; 標本数が十分に多い時、最尤推定量の分布は正規分布に従う
3. 漸近有効性; 標本数が十分に多い時、最尤推定量の分散は不偏推定量の下限に近づく

不偏推定量 ; 推定量の期待値がパラメータの真値に一致するとき

有効推定量 ; 不偏推定量が他の不偏推定量よりも分散が小さいとき c.f. クラメル・ラオの不等式

最尤推定量は不偏推定量ではないが、**標本が多ければ漸近的に有効推定量と同じ振る舞いを示す(漸近有効性)**

t検定; 個々のパラメータの有意性

帰無仮説

各パラメータについて「 $\beta_i=0$ 」(その説明変数は効用に影響しない)

方法

t値を計算する。

$$t_i := \frac{\hat{\beta}_i}{s_i}$$

漸近正規性により、

$|t_i| > 1.96$ 水準で帰無仮説棄却

$|t_i| > 2.58$ 1%有意水準で帰無仮説棄却

なお、効かないことの証明ではなく、効くとは言い切れないことを示すのみであることには注意する

尤度比検定;モデル全体の適合度の比較

モデルAとモデルBを比較する

帰無仮説

モデルAとモデルB の尤度比は0である

Aの方が説明変数、パラメータを追加した上位モデルであると示したい

$2(LL(\hat{\beta}_A) - LL(\hat{\beta}_B))$ 尤度 ($N_A - N_B$ のパラメータ数の差) のカイ二乗分布に従うと知られており、カイ二乗分布の上側5%の点を超えれば5%有意水準で棄却可能

ランダム予測よりも優れていることを示すには？

全モデルのパラメータを0としたモデルを基準とすれば良い

注意;モデルAがモデルBを包含する入れ子構造である必要がある

McFaddenの擬似決定係数

尤度比検定のカイ二乗統計量は自由度に依存するため、異なるモデル間の適合度を直感的に比較しにくい...

McFaddenの擬似決定係数 ; 回帰分析における決定係数に対応する指標
広く用いられている

$$\rho^2 := 1 - \frac{LL(\hat{\beta})}{LL(\mathbf{0})}$$

0 (Null Model同様) から 1 (完全な予測) までの範囲をとる

自由度調整済み決定係数 ; パラメータ数Nによるペナルティを加えたもの
過度なパラメタリゼーションを抑制する

$$\bar{\rho}^2 := 1 - \frac{LL(\hat{\beta}) - N}{LL(\mathbf{0})}$$

0.2以上あれば十分な適合度、0.15以上でも概ね良好。Logitモデル推定結果報告時には明記する。

観測の不確実性とモデル推定

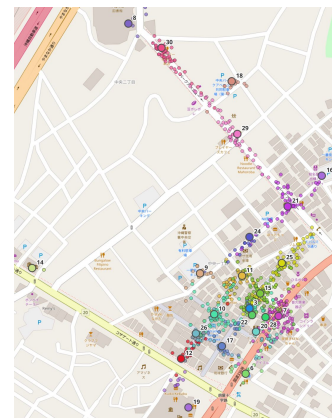
これまで; 観測データが真の行動を正確に反映しているケース



観測誤差が不可避免的に存在し、不確実性が伴うケース

GPS、BLE (Bluetooth Low Energy) などのセンサーデータに基づく観測

観測モデルと行動モデルを統合的に推定する枠組みを推定する




経路観測モデル

従来の二段階推定

経路推定 ⇨ パラメータ推定

経路推定で得た経路が違うとその後も影響



Oyama and Hato (2018)

経路同定とパラメータ推定分離せず、観測モデルと行動モデルを統合的に扱う枠組みを提案

着想;

- 経路観測モデル (GPSの位置情報と真の経路の関係を確率的に記述) を導入
- リンクa上の位置xで観測されたGPS座標 の観測確率をリンク固有の分散で正規分布でモデル化
 - 空間的な異質性 (アーケードでな分散が大きく、見通しのいい道路では少ないなど) を明示的にモデルに組み込むことが可能に

経路観測モデル

道選びとパラメータ推定をバラバラにせず、お互いに影響を与えながら正解を探す

- 観測モデルと行動モデルを結合したリンク尤度
 - 各時点で観測尤度「観測データがどの程度そのリンクと整合的か？」と事前確率「行動モデルに基づいてそのリンクがどの程度選ばれやすいか」の積により、リンクの事後確率を計算

$$p(a_t | \hat{m}^t, a_{t-1}) = \frac{p(\hat{m}^t | a_t; \sigma_{a_t}) p(a_t | a_{t-1}; \theta)}{\sum_{a \in \mathcal{A}(a_{t-1})} p(\hat{m}^t | a; \sigma_a) p(a | a_{t-1}; \theta)}$$

- リンク尤度が観測パラメータと行動パラメータの双方に依存するため、両者を同時に推定する必要がある
 - ⇨ 観測モデルと行動モデルの不動点を探索する構造推定で定式化
 - 多様体学習のEMのアルゴリズムと類似の構想
 - 不動点では観測モデルが推定に用いる事前情報(行動モデル)と推定結果から得られる行動パラメータが整合的になる

量子化と観測多様体

屋内のBLEビーコン観測のように観測点密度が低く、観測分散が大きい状態では前ページまでの手法でも不十分

Matsunaga and Hato (2026)

リンクの確定的な同定を一切回避する量子化アプローチ提案

1つの道に決めるのをやめて、道Aである確率は0.7、Bである確率は0.3など

量子化とは？

古典的な確率的な状態同定(0/1判定)を複数の状態に対する確率分布に緩和する操作のこと
以下の一般化対数尤度(←最大化したい目的関数)では、**各リンクの確率的な重み Q** を使って計算を行う

$$\tilde{L}L(\sigma, \theta) = - \sum_i \sum_{T=1}^{T^{\max}} Q_{S_T, S_{T-1}}(S^{\text{obs}}; \sigma, \theta) \ln p(S_T | S_{T-1}; \theta)$$

通常対数尤度では0or1だった重みづけが連続的な確率分布になるのが重要な点

潜在状態モデル

二つのモデルで共通すること

真の経路は直接理解できない潜在変数であり、観測されるのは観測誤差を含んだセンサーデータであるという視点に立った枠組みである

この枠組みでは、**行動モデル**と**観測モデル**が**相互に依存**している
どちらかの精度が上がれば、もう片方も変化する

精度向上すればより正確な経路情報に基づいて行動パラメータを推定できる

観測モデル



行動モデル

パラメータの変化で推定に用いられるデータ変わる

データは真であるという仮定から解放される

課題に関して



課題説明



MDCEVモデルとRecursive Logit Modelの比較

MDCEV モデル

1日を観測単位として、活動への時間配分を「離散的な活動選択＋連続的な時間配分」として定式化する

MDCEVは時間列を必要としない、時間配分の集計のみから学習する

Recursive Logit Model

1日を時間ステップ列とみなし、各時刻における活動選択を逐次的なマルコフ選択としてモデル化する

RLは1ステップごとの遷移列から学習する

場所次元と過去活動の効果は両方とも無視する

「時間配分」と「時系列推移」の2つのモデルでそれぞれ何を表現する / できるか？

使用するデータ

東京都市圏で実施された4つのPP調査

period	期間	文脈	n_users (raw)
1	2019-07-08 .. 2020-02-11	コロナ前	305
2	2021-10-03 .. 2021-11-25	コロナ規制明け直後	115
3	2022-12-19 .. 2023-01-30	コロナ後・冬	182
4	2023-11-15 .. 2023-11-29	コロナ後・秋	223

MDCEVモデル(γ -profile、Bhat 2008)

- 活動カテゴリ(RLモデルでも共通)
 - H(home)、S(Shopping)、W(Commute/Work)、W2(Business)、O(Other)
 - 予算 $T=24$ h、代替選択肢はout活動(S,W,W2,O)+1つのoutside good (H)
- 各out活動について、

$$V_k = \psi_k - \log(x_k / \gamma_k + 1)$$

↓ベース効用 ↓費やした時間

↑飽和パラメータ
大きければなかなか飽きない、ということ

- 選択確率は、以下の閉形式で表される

$$P(x) = \left[\prod_{k \in M} \frac{1}{x_k + \gamma_k} \right] \cdot \left[\sum_{k \in M} (x_k + \gamma_k) \right] \cdot \left[\prod_{k \in M} \frac{e^{V_k}}{\sum_j e^{V_j}} \right]$$

空き具合の逆数↑

調整↑
消費された時間とパラメータの合計

↑ロジットモデルの選択確
魅力度の比較

- ベクトル化、パラメータが各 out活動に対して、ベース効用と $\log \gamma$

Recursive Logit Model

- 時刻tにおける活動、遷移効用
- 1時間ごとに次の行動を決める
- s_t : 時刻tにおいて、どの活動(H,S,W,W2,O)をしているか

↓朝の外出インセンティブ

$$U_t(i \rightarrow j) = \alpha_j + \delta_{\text{stay}} 1[j = i] + \delta_{\text{morn}} 1[i = H, j \neq H, 6 \leq t < 10] + \delta_{\text{eve}} 1[i \neq H, j = H, 17 \leq t < 22]$$

↑ベース効用
Hが基準で0になっている

↑継続ボーナス、
次も同じ活動を選ぶ場合に+になる、活動を変えるのは面倒なので、今の活動を続ける方が+

- ベルマン方程式の後ろ向き反復; 動的計画法
 - 24時の満足度を0とおき、そこから遡る

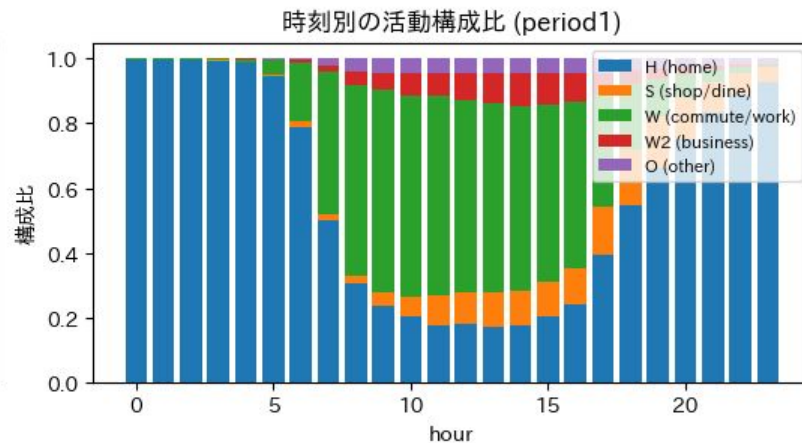

分析結果



PPデータの処理

1日24時間の1時間ごとの状態

コロナ前(2019年7月~2020年2月)



MDCEVモデル

流れ

1. 尤度計算
 - a. 効用関数の定義
2. パラメータ推定の実行
 - a. 全て0からスタート
 - b. 準ニュートン法
3. パラメータの推定値と標準誤差の計算

MDCEVモデル 結果の解釈

対数尤度 初期値;11146.07 最終値;-8938.14 (period1: pre-COVID)

ベース効用

Hが基準で0

ほとんどの活動も0以下なので何もしなければ選ばれにくいことを示す

飽和パラメータ

全てプラスの値である。
数字が大きいほど、長う続く

t値

絶対値が1.96を超えていれば
そのパラメータは5%有意水準
で有意である。

	param	estimate	std_err	t_value
0	psi_S	-0.7392	0.0506	-14.62
1	psi_W	0.0295	0.0465	0.63
2	psi_W2	-1.7580	0.0701	-25.09
3	psi_O	-1.9597	0.0758	-25.86
4	log_gamma_S	1.1533	0.0736	15.67
5	log_gamma_W	2.2314	0.0722	30.91
6	log_gamma_W2	1.8356	0.1202	15.27
7	log_gamma_O	1.3246	0.1281	10.34

〈解釈〉

仕事のベース効用(唯一正の値)が大きいので、
仕事に行く動機は他の活動と比べて強い
飽和パラメータが大きいので、仕事は一度始めると比較的長く続くが、買い物、その他は比較的短く切り上げる
仕事のt値は低いですが、自宅との値の差が小さいためと考えられる

Recursive Logit Model

流れ

1. パラメータを受け取る
 - a. θ を受け取る
2. 効用行列の作成
3. 価値観数算出
 - a. ベルマン方程式を解く
 - b. $BETA = 0.95$ (割引因子); 1時間後の幸せを現在の幸せに換算する際の係数
 - c. 逆向きのループ
 - d. 機体最大効用
4. 尤度計算
5. 最適化
 - a. 負の対数尤度が最小になるように θ の値を調整

Recursive Logit Model 結果の解釈

対数尤度 初期値:-55525.60 最終値:-13547.41

ベース効用

Hが基準で0

ほとんどの活動も0以下なので何もしなければ選ばれにくいことを示す

活動継続のボーナス

同じ活動を続けることへのボーナス

朝の外出ダッシュ

6~10時の間に自宅を出るボーナス

夕方の帰宅ダッシュ

17~22時の間に自宅に帰るボーナス

	param	estimate	std_err	t_value
0	alpha_S	-0.2119	0.0102	-20.79
1	alpha_W	-0.0341	0.0062	-5.49
2	alpha_W2	-0.3249	0.0141	-22.97
3	alpha_O	-0.4137	0.0182	-22.79
4	delta_stay	3.6363	0.0251	145.12
5	delta_morn	2.3296	0.0608	38.35
6	delta_eve	2.3148	0.0592	39.08

突出して高い！

delta-stayのt値が突出して高く、一度始めたら動かない

朝の外出と夕方の帰宅に強いバイアスがある。t値の基準を大幅にクリアしている。


RLの再現性

モデルから観測時間配分の再現を試す

RL: 推定パラメータのもとで各user,dayをt=0開始からforward simulateする

	observed [h]	RL simulated [h]
H (home)	14.23	14.69
S (shop/dine)	1.65	1.67
W (commute/work)	6.61	6.13
W2 (business)	0.92	0.93
O (other)	0.59	0.59

ほぼ完全に表現できていると言える
朝の外出項などが、時間制約などを学習しているのに役立っている



MDCEV vs RL

両方のモデルから観測時間配分の再現を試す

MDCEV; 期待時間 = 推定 γ_k から決まる代表値

観測モデルが異なるため、直接比較はできないが、**パラメータの符号** と各活動の**相対的な魅力度の傾向** (ψ_k , α_k) は一致する

MDCEV

RL

	param	estimate	std_err	t_value
0	psi_S	-0.7392	0.0506	-14.62
1	psi_W	0.0295	0.0465	0.63
2	psi_W2	-1.7580	0.0701	-25.09
3	psi_O	-1.9597	0.0758	-25.86
4	log_gamma_S	1.1533	0.0736	15.67
5	log_gamma_W	2.2314	0.0722	30.91
6	log_gamma_W2	1.8356	0.1202	15.27
7	log_gamma_O	1.3246	0.1281	10.34

	param	estimate	std_err	t_value
0	alpha_S	-0.2119	0.0102	-20.79
1	alpha_W	-0.0341	0.0062	-5.49
2	alpha_W2	-0.3249	0.0141	-22.97
3	alpha_O	-0.4137	0.0182	-22.79
4	delta_stay	3.6363	0.0251	145.12
5	delta_morn	2.3296	0.0608	38.35
6	delta_eve	2.3148	0.0592	39.08

時期による比較(実データ)

- 家にいる時間はコロナ規制後(直後ではなく少し経ってから)1時間程度長くなっている
- 仕事、通勤時間は減少した
 - コロナ規制後から普及した各種オンラインサービスの普及により、対面での仕事が減少したのだろう
- Business(業務)は、コロナ規制直後～翌年の冬にかけて半減していることがわかるが、翌年の秋には元の水準に復活している
- 買い物に使う時間30分程度増加した
 - 通勤時間が減ってついでが減って必要な時間が増えた？

	Phase1 コロナ前	Phase2 コロナ規制直後	Phase3 コロナ後冬	Phase4 コロナ後秋
サンプル数	6532	2299	1394	1581
observed H(home)	14.23	14.77	15.49	15.45
observed S(shop/dine)	1.65	1.84	1.77	2.19
observed W(commute/work)	6.61	6.54	5.56	4.73
observed O(other)	0.59	0.44	0.77	0.63

RLモデルのパラメータによる比較

- コロナ規制後、Workの α 値は下がっている
- 2.コロナ規制直後、3.コロナ後において、ビジネスの α 値が下がっていることがわかる
 - コロナを受けて暫くは出張、訪問が減っていたと言える
- 4. コロナ後秋の結果を見ると朝の出発に関する α 値がコロナ前と比べると下がっている
 - コロナを経てリモートワークの普及により朝出勤する人の割合が下がったと言える
- パラメータで見てもShoppingの α 値は少し大きくなっている

	param	estimate	std_err	t_value
0	alpha_S	-0.2119	0.0102	-20.79
1	alpha_W	-0.0341	0.0062	-5.49
2	alpha_W2	-0.3249	0.0141	-22.97
3	alpha_O	-0.4137	0.0182	-22.79
4	delta_stay	3.6363	0.0251	145.12
5	delta_morn	2.3296	0.0608	38.35
6	delta_eve	2.3148	0.0592	39.08

	param	estimate	std_err	t_value
0	alpha_S	-0.2225	0.0097	-22.91
1	alpha_W	-0.0580	0.0061	-9.47
2	alpha_W2	-0.5551	0.0237	-23.42
3	alpha_O	-0.5360	0.0227	-23.57
4	delta_stay	3.5142	0.0251	140.11
5	delta_morn	2.3911	0.0611	39.12
6	delta_eve	2.0468	0.0593	34.52

	param	estimate	std_err	t_value
0	alpha_S	-0.2339	0.0102	-22.85
1	alpha_W	-0.0825	0.0066	-12.46
2	alpha_W2	-0.5482	0.0238	-23.03
3	alpha_O	-0.4069	0.0167	-24.29
4	delta_stay	3.5265	0.0257	137.35
5	delta_morn	2.2846	0.0630	36.25
6	delta_eve	2.1253	0.0618	34.41

	param	estimate	std_err	t_value
0	alpha_S	-0.1874	0.0089	-21.09
1	alpha_W	-0.0906	0.0067	-13.59
2	alpha_W2	-0.3376	0.0137	-24.62
3	alpha_O	-0.4351	0.0179	-24.24
4	delta_stay	3.5514	0.0240	148.00
5	delta_morn	2.0919	0.0598	34.99
6	delta_eve	2.1750	0.0592	36.76

左から順にPhase 1,2,3,4

実データとRLデータの整合性

- 全体的にどの時期のデータについても推定精度は高い
- 4つ全ての時期のデータについて、H在宅を0.5h程度高く見積もる傾向があった
- 4つ全ての時期のデータについて、W通勤・仕事を0.5h程度低く見積もる傾向にあった
- S買い物、W2業務とOその他については極めて高い精度で予測できていた

	observed [h]	RL simulated [h]
H (home)	14.23	14.69
S (shop/dine)	1.65	1.67
W (commute/work)	6.61	6.13
W2 (business)	0.92	0.93
O (other)	0.59	0.59

	observed [h]	RL simulated [h]
H (home)	14.77	15.25
S (shop/dine)	1.84	1.83
W (commute/work)	6.54	6.10
W2 (business)	0.42	0.38
O (other)	0.44	0.44

	observed [h]	RL simulated [h]
H (home)	15.49	15.88
S (shop/dine)	1.77	1.78
W (commute/work)	5.56	5.19
W2 (business)	0.43	0.41
O (other)	0.74	0.74

	observed [h]	RL simulated [h]
H (home)	15.45	15.84
S (shop/dine)	2.19	2.26
W (commute/work)	4.73	4.29
W2 (business)	0.99	1.00
O (other)	0.63	0.60

左上、右上、左下、右下の順
に時期の1,2,3,4

分析

MDCEVモデルのforecast

Bhat (2008) のForecasting Algorithm (決定論的最適配分) を実装し、観測平均と比較する


$$P(x) = \left[\prod_{k \in M} \frac{1}{x_k + \gamma_k} \right] \cdot \left[\sum_{k \in M} (x_k + \gamma_k) \right] \cdot \left[\prod_{k \in M} \frac{e^{V_k}}{\sum_j e^{V_j}} \right] \cdot (M - 1)!$$

Hは除いて計算を行った

	observed [h]	MDCEV pred (obs active set) [h]	diff
H	14.229	-0.000	-14.229
S	1.648	1.440	-0.208
W	6.615	7.621	1.007
W2	0.918	0.337	-0.581
O	0.590	0.372	-0.218

MDCEVモデルでは、W(通勤、仕事)を多く見積もる傾向がある
RLモデルの方がS、W2、Oの活動時間をより正確に見積もることができている

観測 vs MDCEV vs RL 推定モデル (period1: pre-COVID)



Day-to Day Dynamics



History_window-1日の各活動の最後に行った日からの経過日数も考慮に入れる

$$U_t(i \rightarrow j) = [\text{baseline}] + \theta_{\text{rec}} \cdot \text{recency}_u(a(j))$$

history (recency) feature shape: (1500, 5)

recency mean per activity: [1.11 3.31 2.32 4.26 4.3]

	param	estimate	std_err	t_value
0	alpha_S	-0.1449	0.0109	-13.27
1	alpha_W	0.0065	0.0068	0.96
2	alpha_W2	-0.2210	0.0156	-14.13
3	alpha_O	-0.3076	0.0194	-15.89
4	delta_stay	3.6110	0.0251	144.14
5	delta_morn	2.3335	0.0606	38.52
6	delta_eve	2.3115	0.0592	39.04
7	theta_recency	-0.0387	0.0028	-13.84



$\theta_{\text{rec}} < 0$ になるので、普段やらない活動は将来も選ばれにくい傾向があると言える

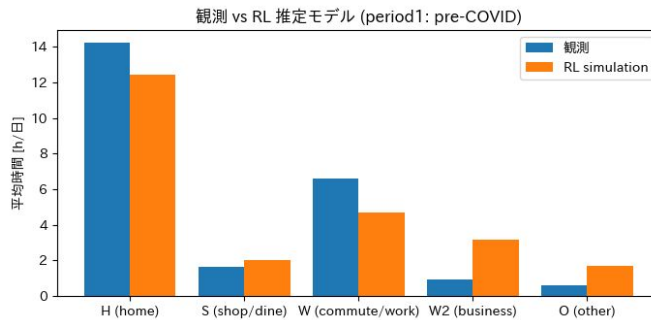
recencyを入れた方がWの時間についてより正確に推定することができていた

活動種類ごとのDay-to Day Recencyの導入

活動ごとの個別のパラメータの導入を行い、各活動ごとに違いを見たレコードごとに効用が異なるのでN個の異なる効用関数を解くことで一人一人の現在の状況に合わせた将来予測を計算

	param	estimate	std_err	t_value
0	alpha_S	-0.1269	0.0192	-6.61
1	alpha_W	-0.0118	0.0121	-0.97
2	alpha_W2	-0.0618	0.0262	-2.36
3	alpha_O	-0.1615	0.0355	-4.55
4	delta_stay	3.5902	0.0251	142.85
5	delta_morn	2.3178	0.0605	38.31
6	delta_eve	2.2871	0.0592	38.65
7	theta_rec_H (home)	-0.0246	0.0081	-3.03
8	theta_rec_S (shop/dine)	-0.0401	0.0055	-7.34
9	theta_rec_W (commute/work)	-0.0233	0.0035	-6.64
10	theta_rec_W2 (business)	-0.0833	0.0073	-11.46
11	theta_rec_O (other)	-0.0770	0.0094	-8.16

モデルのハマリ具合は見た感じあまり向上していない(むしろ悪化)



LLMの利用

- Gemini を利用
- あまりpdfの読み込みは得意ではない印象
- テキストのスクショを送って数式の解説を重点的に、など指示をつけて解説してもらった
- コードも意味の解説と課題のコードの検討をしてもらった

ありがとうございました



参考資料(その他の分析結果)




Phase2

init nll: 10890.555931534715

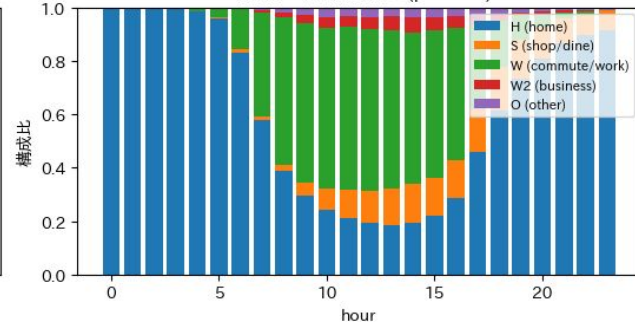
final nll: 8507.33267208852

	param	estimate	std_err	t_value
0	psi_S	-0.6443	0.0497	-12.97
1	psi_W	0.0678	0.0464	1.46
2	psi_W2	-2.3397	0.0891	-26.27
3	psi_O	-2.1295	0.0813	-26.20
4	log_gamma_S	1.1581	0.0721	16.05
5	log_gamma_W	2.1685	0.0710	30.55
6	log_gamma_W2	1.4939	0.1514	9.86
7	log_gamma_O	1.1338	0.1355	8.37

活動別の平均時間配分 (period2: COVID restrictions just lifted)



時刻別の活動構成比 (period2)



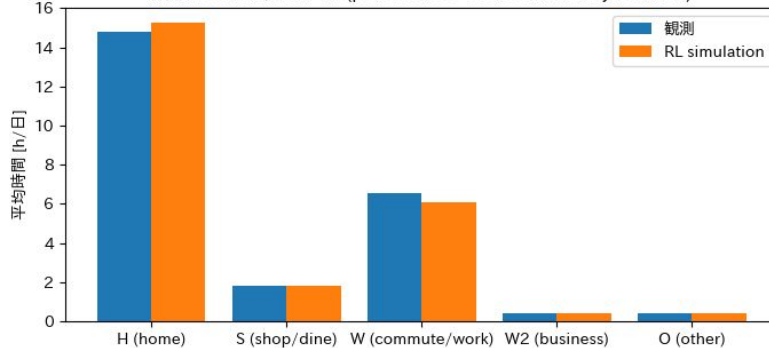
RI

init nll: 55525.60797897643

final nll: 13148.424309336024

	param	estimate	std_err	t_value
0	alpha_S	-0.2225	0.0097	-22.91
1	alpha_W	-0.0580	0.0061	-9.47
2	alpha_W2	-0.5551	0.0237	-23.42
3	alpha_O	-0.5360	0.0227	-23.57
4	delta_stay	3.5142	0.0251	140.11
5	delta_morn	2.3911	0.0611	39.12
6	delta_eve	2.0468	0.0593	34.52

観測 vs RL 推定モデル (period2: COVID restrictions just lifted)



	observed [h]	RL simulated [h]
H (home)	14.77	15.25
S (shop/dine)	1.84	1.83
W (commute/work)	6.54	6.10
W2 (business)	0.42	0.38
O (other)	0.44	0.44


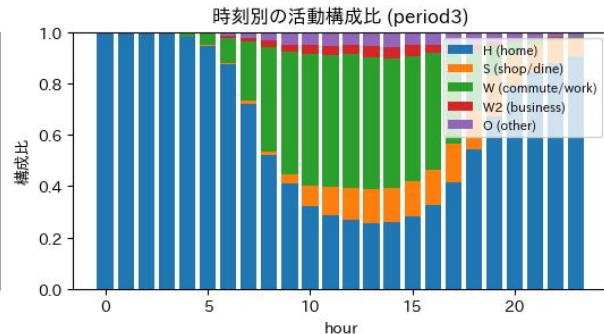

Phase3

init nll: 9935.593574231236
 final nll: 8166.035244104343

	param	estimate	std_err	t_value
0	psi_S	-0.4367	0.0497	-8.78
1	psi_W	-0.2779	0.0480	-5.79
2	psi_W2	-2.2657	0.0897	-25.27
3	psi_O	-1.5168	0.0665	-22.82
4	log_gamma_S	0.8527	0.0680	12.54
5	log_gamma_W	2.5337	0.0842	30.09
6	log_gamma_W2	1.3659	0.1500	9.10
7	log_gamma_O	1.0053	0.1045	9.62

init nll: 51601.79834846211
 final nll: 12502.848997724122

	param	estimate	std_err	t_value
0	alpha_S	-0.2339	0.0102	-22.85
1	alpha_W	-0.0825	0.0066	-12.46
2	alpha_W2	-0.5482	0.0238	-23.03
3	alpha_O	-0.4069	0.0167	-24.29
4	delta_stay	3.5265	0.0257	137.35
5	delta_morn	2.2846	0.0630	36.25
6	delta_eve	2.1253	0.0618	34.41



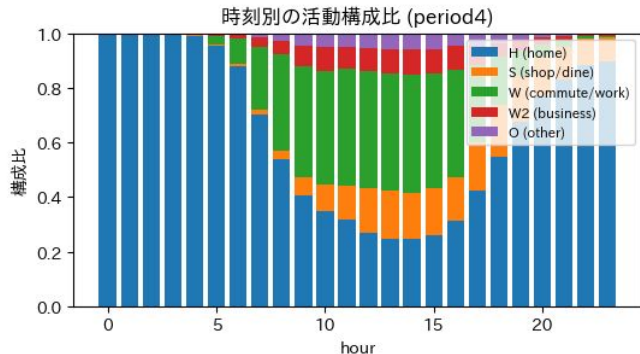
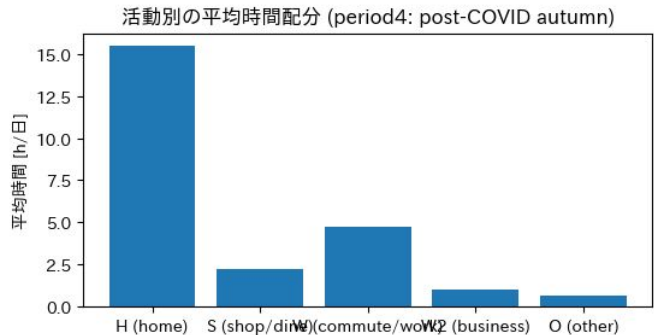
	observed [h]	RL simulated [h]
H (home)	15.49	15.88
S (shop/dine)	1.77	1.78
W (commute/work)	5.56	5.19
W2 (business)	0.43	0.41
O (other)	0.74	0.74

Phase4

init nll: 10823.3149929502

final nll: 9115.559942920154

	param	estimate	std_err	t_value
0	psi_S	-0.3567	0.0472	-7.55
1	psi_W	-0.4403	0.0471	-9.34
2	psi_W2	-1.5730	0.0653	-24.10
3	psi_O	-1.7439	0.0697	-25.04
4	log_gamma_S	1.0076	0.0655	15.39
5	log_gamma_W	2.5348	0.0844	30.05
6	log_gamma_W2	1.6116	0.1093	14.75
7	log_gamma_O	1.1814	0.1119	10.56




RL

init nll: 55525.60797897643

final nll: 14071.805016517683


	param	estimate	std_err	t_value
0	alpha_S	-0.1874	0.0089	-21.09
1	alpha_W	-0.0906	0.0067	-13.59
2	alpha_W2	-0.3376	0.0137	-24.62
3	alpha_O	-0.4351	0.0179	-24.24
4	delta_stay	3.5514	0.0240	148.00
5	delta_morn	2.0919	0.0598	34.99
6	delta_eve	2.1750	0.0592	36.76




	observed [h]	RL simulated [h]
H (home)	15.45	15.84
S (shop/dine)	2.19	2.26
W (commute/work)	4.73	4.29
W2 (business)	0.99	1.00
O (other)	0.63	0.60

時期により比較


観測 vs RL 推定モデル (period1: pre-COVID)




観測 vs RL 推定モデル (period2: COVID restrictions just lifted)



観測 vs RL 推定モデル (period3: post-COVID winter)




観測 vs RL 推定モデル (period4: post-COVID autumn)




MDCEV forecastにおけるRLとの比較 (Phase2,3,4)


観測 vs MDCEV vs RL 推定モデル (period1: pre-COVID)



観測 vs MDCEV vs RL 推定モデル (period2: COVID restrictions just lifted)



観測 vs MDCEV vs RL 推定モデル (period3: post-COVID winter)



観測 vs MDCEV vs RL 推定モデル (period4: post-COVID autumn)

