



東京理科大学

TOKYO UNIVERSITY OF SCIENCE

行動モデルの夏の学校

2026年9月8日

AI時代の行動モデル

Behavior Model in the Age of AI

東京理科大学 創域理工学部 社会基盤工学科

柳沼 秀樹

yaginuma@rs.tus.ac.jp

(我々の言う) 行動モデル ≡ 離散選択モデル

- 人々（意思決定主体）はどのように選択を行うのか？
→ 経済理論に立脚したモデル化 + データに基づくパラメータ推定
- 行動モデル夏の学校では理論から実装まで学べる！
→ すごい！でも最先端すぎてわからん！問題
- 本講義は「行動モデルの深淵」にダイブ（研究）するための準備


第1世代：胎動期

$$\begin{aligned} \max_x & U(x) \\ \text{s.t. } & p^T x \leq I \end{aligned}$$


第2世代：黎明期

$$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)}$$

第3世代：発展期



第4世代：融合期



第5世代：???

行動モデルの成立から現代まで


第1世代から第3世代を振り返る

[1] 古典的な消費者行動理論（1880頃）

- 効用最大化問題：消費者は予算制約の下で**効用**（望ましさ）が**最大**となる財の数量を選択

$$\begin{aligned} \max_x & U(x) \\ \text{s.t. } & p^T x \leq I \end{aligned}$$


x : 財の数量
 p : 財の価格 I : 予算制約



- 連続量の最適な選択が対象
→有限個の選択肢から1つを選ぶ「離散」選択の枠組みが必要

[2] 離散選択の理論構築（1920-60頃）

- Thurstone(1927) : A law of comparative Judgment
 - ✓ 一対比較における比較判断（選択）を記述
 - ✓ 価値（効用）の揺らぎ（確率的な変動）を導入
→ **ランダム効用最大化（RUM）** 理論の原型
 - ✓ 誤差項に正規分布を仮定した二項**Probitモデル**の導出
- Luce(1959) : Individual choice behavior
 - ✓ 選択確率が満たすべき**性質**を検証（Luceの選択公理）
 - ✓ 選択肢の選ばれやすさは他の選択肢に依存しない
→ **IIA** (Independence from Irrelevant Alternatives) 特性
 - ✓ 公理を満たす選択確率は多項**Logitモデル（MNL）** となる
- Marschak(1960) : 効用理論との整合性
 - ✓ Luceモデルは経済理論（効用理論）で説明可能か？
→ 効用最大化理論との**理論的整合性**を確認



離散選択の理論構築（1970頃）

- McFadden(1974)：これまでの知見を統合した基礎理論の完成
 - ✓ ガンベル分布を仮定したMNLの導出
→ 積分を含まないClosed-form形式で扱いやすい
 - ✓ 効用を費用や時間などの説明変数と関連付けて推定
 - ✓ Logsumから便益が計測可能
→ 実用的な政策分析を前提としたモデリング

The Sveriges Riksbank Prize in Economic Sciences in Memory of Alfred Nobel 2000



James J. Heckman
Prize share: 1/2



Daniel L. McFadden
Prize share: 1/2

The Sveriges Riksbank Prize in Economic Sciences in Memory of Alfred Nobel 2000 was divided equally between James J. Heckman "for his development of theory and methods for analyzing selective samples" and Daniel L. McFadden "for his development of theory and methods for analyzing discrete choice".

If the random vector $\langle \varepsilon(i, a) \rangle_{i \in \mathcal{I}}$ has a joint cumulative distribution function F , and we write $\mathcal{I} = \{1, \dots, I\}$, the right-hand side of equation (7) can be written as an integral in the i 'th partial derivative, F_i , of F :

$$P(i|a, \mathcal{I}) = \int_{-\infty}^{+\infty} F_i[x + v(i, a) - v(1, a), \dots, x + v(i, a) - v(I, a)] dx. \quad (8)$$

In particular, if the random variables $\varepsilon(i, a)$ are independently distributed with cumulative distribution function $\exp[e^{-\sigma x_i}]$ for $\sigma > 0$ (the Gumbel, or type-I, extreme-value distribution), their joint distribution F becomes:

$$F(x_1, \dots, x_I) = \exp \left[- \sum_{j \in \mathcal{I}} e^{-\sigma x_j} \right], \quad (9)$$

and the choice probabilities in equation (7) reduce to the analytically convenient logit form:

$$P(i | a, \mathcal{I}) = \frac{\exp \sigma v(i, a)}{\sum_{j \in \mathcal{I}} \exp \sigma v(j, a)}. \quad (10)$$


The parameter $\sigma > 0$ is inversely proportional to the standard deviation of the random utility terms $\varepsilon(i, a)$. In the limit as $\sigma \rightarrow \infty$, the choice probabilities $P(i | a, \mathcal{I})$ in (10) assign all probability mass to the alternatives with maximum "representative" utility $v(i, a)$ — and we obtain the traditional microeconomic model of fully deterministic utility maximization.

MNLの導出と政策評価への活用

- 個人 n が選択肢 i を選択する確率 $P_n(i)$

$$P_n(i) = \Pr\{U_{in} \geq U_{jn}, \text{ for } \forall j, i \neq j\}$$

$$\begin{aligned} &= \Pr\{V_{in} + \varepsilon_{in} \geq V_{jn} + \varepsilon_{jn}\} \\ &= \Pr\{\varepsilon_{jn} - \varepsilon_{in} \leq V_{in} - V_{jn}\} \\ &= \Pr\{\varepsilon_n \leq V_{in} - V_{jn}\} \quad (\because \varepsilon_n \equiv \varepsilon_{jn} - \varepsilon_{in}) \\ &= F_\varepsilon(V_{in} - V_{jn}) \\ &= F_\varepsilon(V) \end{aligned}$$



- 誤差項にガンベル分布を仮定すれば
MNLが導出可能


$$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)}$$



- Logsumを用いた便益計測


$$UB = \sum_i \sum_j \frac{1}{2} (Q_{ij}^{wo} + Q_{ij}^w) (C_{ij}^{wo} - C_{ij}^w)$$

$$C_{ij} = \frac{1}{\beta} \ln \sum_m \exp(V_{ijm})$$



モデルの精緻化・高度化（1980-2020代）

- IIA特性への対処（選択肢間の相関性）→ 誤差項にアプローチ
 - ✓ GEVによる多様な派生モデルの導出
 - ✓ MXL（mixed logit）によるGEV派生モデルの近似（Error Component）



モデルの精緻化・高度化

- 記述・予測性能の向上

- ✓ 多様な変数の導入（センサーデータから心理的変数、潜在変数の導入）
- ✓ セグメンテーション（属性別パラメータ）
- ✓ 効用関数の形状（線形加法から各種非線形）
- ✓ 個人の異質性（ランダム係数モデル）

パラメータが確率分布に従うと仮定して異質性を考慮

⇒パラメータが正規分布に従って分布すると仮定した場合、分布の母数である平均値と分散(標準偏差)そのものを推定

$$U_{car,n} = \beta_n T_{car,n} + v_{car,n}$$


$$\beta_n \approx N(\bar{\beta}, \sigma^2)$$

$$U_{car,n} = \bar{\beta} T_{car,n} + \sigma \eta_n T_{car,n}$$

$$U_{bus,n} = \bar{\beta} T_{bus,n} + \sigma \eta_n T_{bus,n}$$

$$U_{rail,n} = \bar{\beta} T_{rail,n} + \sigma \eta_n T_{rail,n}$$

$$\eta_n \approx N(0,1) \quad \bar{\beta}, \sigma : \text{unknown parameter}$$



母数 β を構造化することにより、観測異質性と非観測異質性を同時に考慮可能

$$\bar{\beta}_n = \gamma_0 + \gamma_1 \text{income}_n \quad \beta \text{ が観測可能な所得に依存}$$

モデルの精緻化・高度化

- 記述・予測性能の向上
 - ✓ 多様な変数の導入（センサーデータから心理的変数、潜在変数の導入）
 - ✓ セグメンテーション（属性別パラメータ）
 - ✓ 効用関数の形状（線形加法から各種非線形）
 - ✓ 個人の異質性（ランダム係数モデル）
 - ✓ 選択肢集合の選別過程

土木学会論文集 No. 470/IV-20, pp.115-124, 1993.7

特集論文(交通行動分析の新展開)

主観的要因を考慮した非集計離散型選択モデル



森川高行*・佐々木邦明**

非集計交通行動モデルの説明変数には、計測が容易な変数のみ通常用いられるが、人間の選択行動には定量化されにくい主観的要因や個人の知覚の相違などの潜在要因が大きく影響している。本論文は、潜在要因を考慮した既存研究のレビューとともに、このような潜在要因を含んだより精緻な意思決定機構を内包した非集計離散型選択分析の方法論を提案するものである。

Key Words : discrete choice analysis, latent variable, covariance structure model




図-1 選択行動意思決定のパスダイヤグラム



土木学会論文集 No. 597/IV-40, 99-111, 1998.7

複数交通情報リソース下における 情報獲得・参照行動を考慮した経路選択モデル

羽藤 英二¹・谷口 正明²・杉恵 頼寧³・桑原 雅夫⁴・森田 紳之⁵




図-4 情報利用プロセスを考慮した経路選択構造

モデルの精緻化・高度化

- さらなる拡張
 - ✓ 四段階推定の統合モデル・アクティビティモデル
 - ✓ 世帯意思決定（個人から集団の意思決定 single agent → multi agent）
 - ✓ 社会的相互作用（他者の影響）
 - ✓ 動的な意思決定（逐次的な選択 static → dynamic）など

土木学会論文集 No. 765/IV-64, 49-64, 2004. 7

土木学会論文集 No. 744/IV-61, 123-137, 2003. 10

【特集】

誘発交通を考慮した混雑地域における道路整備の利用者便益推定



円山琢也¹・原田昇²・太田勝敏³




図-2 Nested Logit 型の選択構造

社会的相互作用存在下での交通行動と ミクロ計量分析



福田大輔¹・上野博義²・森地 茂³




図-1 標準集団のマクロな状態と個人のミクロな選択行動との関係

行動モデルとAIの融合

第4世代行動モデルの最前線

機械学習理論およびAIの台頭

- 2000年代：ビッグデータの収取と計算機の発展が後押し
- 2010年代：深層学習の登場と第3次AIブーム
- 2020年代：大規模言語モデル、生成AI技術の急速な発展

人工知能とは？

■ 人工知能（Artificial Intelligence: AI）の定義

- 学習・推論・判断といった**人間の知能が持つ機能**を備えたコンピュータシステム（大辞林）
- 人間の知的作業をアルゴリズムで記述して**コンピュータ上でシミュレート**する技術
- コンピュータサイエンスにおいて実務的な情報処理以外に知的機能を研究する分野、またはその産物、人間以外の（人工の）知識情報処理装置（土郎政宗 攻殻機動隊）


■ AIの種類

- 汎用AI：思考する人型や猫型ロボット
（世間一般がイメージするもの）
- 専用AI：あるタスク処理に特化した知的
情報処理システム
（画像処理、言語処理など）
- ✓ 専用AIを融合した**マルチモードAI**：知能部分
- ✓ ロボットと融合した**フィジカルAI**：身体部分



機械学習理論とAI

- 人工知能分野の1つとして機械学習が位置付けられる
- 大きく教師あり・教師なしに分類
- その中の汎用的な手法の1つとしてNNが位置付けられる
- 強化学習や生成学習が最先端



教師あり学習

入力 $\mathbf{x}$ と出力 $\mathbf{y}$ がある： $(\mathbf{x}, \mathbf{y})$
データ間の関係性を記述

回帰(regression)

- 連続量(数値)を出力

分類(classification)

- 離散量(ラベル)を出力

教師なし学習

入力 $\mathbf{x}$ だけがある： $(\mathbf{x})$
データの構造や特徴を記述

分割(clustering)

- クラスラベルを出力

次元圧縮

- (Dimensionality Reduction)
- 離散量(ラベル)を出力

強化学習

目標を達成する
ルールを作成

生成・合成

入力からデータを
新たな出力を
生成, 変換, 合成

Choice modelling in the age of machine learning

Discussion paper

Sander van Cranenburgh^{I*}, Shenhao Wang^{II}, Akshay Vij^{III}, Francisco Pereira^{IV}, Joan Walker^V

^I Transportation and Logistics group, Department of Engineering Systems and Services, Delft University of Technology

^{II} Urban Mobility Lab, Massachusetts Institute of Technology

^{III} Institute for Choice, University of South Australia


^{IV} Department of Technology, Management and Economics, Technical University of Denmark

^V Department of Civil and Environmental Engineering, University of California Berkeley

* Corresponding author. s.vancranenburgh@tudelft.nl

2022年時点での行動モデル分野における機械学習の適用事例を収集

- ✓ 理論モデルとの融合は可能か？
- ✓ モデルは解釈可能か？
- ✓ モデルは実務に使えるのか？
- ✓ テキストや画像等の非構造化データを組み込めるか？
- ✓ そもそも人間行動を記述している？



Choice modelling in the age of AI

- 機械学習との組み合わせから理論モデル (theory driven) と 機械学習モデル (data driven) を融合したアプローチ (**深層行動モデル**) で論理性・説明性・記述性能の向上を目指す

6

A. NN represents the systematic utility

Model	What $NN(\cdot)$ represents	Utility	What is preserved
Classical MNL	no network	$V_{ni} = \beta^T x_{ni}$	everything, by assumption
F-DNN	the entire utility	$V_n = NN(x_n, z_n)$	No explicit behavioral restrictions
ASU-DNN Wang et al. (2020)	alternative-specific utility	$V_{ni} = NN_i(x_{ni}, z_n)$	IIA
L-MNL Sifringer et al. (2020)	a utility residual	$V_{ni} = \beta^T x_{ni}^K + NN_i(x_n^L)$	linearity on x^K , so WTP for those attributes
TB-ResNet Wang et al. (2021)	a weighted mixture	$V_{ni} = (1 - \delta) V_{T,i} + \delta V_{DNN,i}$	Nothing guaranteed; δ measures the distance from the DCM
GAUNet Nishi & Hara (2026)	attribute-level utility shape	$V_{ni} = ASC_i + \sum_k NN_{ik}(x_{nik})$	additivity; the shape of each attribute's effect
DNN + gradient regularization Feng et al. (2024)	the entire utility	$V_n = NN(x_n, z_n) + \text{Gradient penalty during training}$	monotonicity in designated attributes as a soft penalty
DCM-LN Kim & Bansal (2024)	constrained nonlinear utility	$V_{ni} = NN_i^{mono}(x_{ni})$	monotonicity in designated attributes, as a hard constraint

力石先生の資料がよくまとまっています！

16th International Conference on Travel Behavior Research
December 11 - 22, 2021 – Santiago, Chile

INTERPRETABILITY OF MACHINE-LEARNING BASED TRAVEL BEHAVIOUR MODELS USING XAI

Yushi ISHIJIMA¹, Hideki YAGINUMA², Shintaro TERABE³
and Haruka UNO⁴



首都圏を対象にPTデータを用いて深層行動モデルベースのアクティビティシミュレーション (ABM) を構築

- ✓ Sifringer et al. のL-MNLを適用
- ✓ 既存手法 (MNL) よりも高い記述性能を実現
- ✓ XAI (Explainable AI) による解釈可能性を検証

Networks reflecting elasticity


➤ Considering **elasticity** by changing the model structure like MNL

➤ Sifringer, Brian, Virginie Lurkin, and Alexandre Alahi. "Enhancing discrete choice models with representation learning." Transportation Research Part B: Methodological 140 (2020): 236-261.




個人間の観測異質性と非観測異質性を 考慮した深層行動モデルの検証


高橋 翔¹・柳沼 秀樹²・稲垣 和哉³・寺部 慎太郎⁴・味戸 正徳⁵



■ TasteNet (Han et al., 2022)




■ MVE TasteNet (本研究)



Han et al.(2022)のTasteNetから得られるパラメータにばらつきを考慮

- ✓ 個人（セグメント）の異質性を表現
→ MXLのランダム係数をイメージ
- ✓ 独自の損出関数を構築
- ✓ Swiss Metroデータを用いたシミュレーションにより検証
- ✓ ばらつきを表現できている？



	DCM(MNL)		NN	DCM+NN
	generic	specified		
Interpre- tability	○		◎	◎
	- Feature parameters Sensitivity analysis Elasticity - Probability transition		Feature Importance - Sensitivity analysis (Nonlinear) - Group heterogeneity - Feature contribution - Overall and individual parameters	Feature Importance - Sensitivity analysis (Linear) - Group heterogeneity - Feature contribution - Overall and individual parameters
Accuracy	○	○	◎	○
	Acc 0.761	0.817	• Acc 0.945	• Acc 0.854
	• Slow compute speed		• High computation speed	• High computation speed
Logicity	○		△	△
	• Utility Function		• Minimize loss function	• Minimize loss function

- 深層行動モデルは概ね良好な記述性と解釈性を担保
- 機械学習よりも論理性は高まっている？
→ 効用関数に理論的な制約の導入が必要 (Kim and Bansal, Feng et al.)

次世代の行動モデル（私見）

第5世代の行動モデルとは？

第5世代? : 仮想世界での学習

現実世界を模倣する仮想世界

- 行動の観測・学習・予測・制御を現実世界ではなく仮想世界のみで行う
- 精緻なシミュレーションではなく、圧縮された世界 (world models) を用いたモデルベースでの強化学習により行動原理を学習



[Submitted on 27 Mar 2018 (v1), last revised 9 May 2018 (this version, v4)]

World Models

David Ha, Jürgen Schmidhuber

We explore building generative neural network models of popular reinforcement learning environments. Our world model can be trained quickly in an unsupervised manner to learn a compressed spatial and temporal representation of the environment. By using features extracted from the world model as inputs to an agent, we can train a very compact and simple policy that can solve the required task. We can even train our agent entirely inside of its own hallucinated dream generated by its world model, and transfer this policy back into the actual environment.

An interactive version of this paper is available at [this https URL](https://arxiv.org/abs/1803.10121)




Figure 4. Our agent consists of three components that work closely together: **Vision (V)**, **Memory (M)**, and **Controller (C)**

- Vision
「いま見えているもの」を圧縮
- Memory
「次に何が起こるか」を予測
- Controller
「何をするか」を決定






Figure 8. Flow diagram of our Agent model. The raw observation is first processed by V at each time step t to produce z_t . The input into C is this latent vector z_t concatenated with M's hidden state h_t at each time step. C will then output an action vector a_t for motor control, and will affect the environment. M will then take the current z_t and action a_t as an input to update its own hidden state to produce h_{t+1} to be used at time $t + 1$.



現実世界と仮想世界の相互作用

- 意思決定主体（エージェント）を取り巻く「環境」を再現する世界モデル
- 獲得した行動原理を現実での行動（観測）と整合させる必要がある
- デジタルツインのようなフィジカル/サイバーのシステムを構築し、行動の観測・予測・制御・施策評価・レコメンドを一気通貫に実現



ご清聴ありがとうございました