

# A neural-embedded discrete choice model: Learning taste representation with strengthened interpretability

---

Han, Yafei, et al. "A neural-embedded discrete choice model: Learning taste representation with strengthened interpretability." *Transportation Research Part B: Methodological* 163 (2022): 166-186.

理論談話会 #16

M1 倉澤龍平

# 研究のサマリー

目的：個人特性による**異質性を考慮**したモデルの構築/モデルの**予測精度の向上**/解釈可能なモデルの構築

手法：MNLの効用関数パラメータを出力，個人特性を入力とするニューラルネットワークの構築

結果：数値実験を行い，予測精度が良くなりパラメータのバイアスも少ない結果を出すことに成功。  
実データ適用を行い，モデルがover fittingを起こしていないことを確認。

## 良い点

シンプルな発想でニューラルネットワークを用いた推定の課題を解決した点。

## 課題点

実データのover fitting性の検証は一部分にとどまっている。

# 研究のサマリー

## 新規性

- ニューラルネットワークを選択結果の学習ではなく、パラメータの学習に用いることで柔軟な異質性を許容しつつ、解釈可能性のあるモデルを構築した。

## 有用性

- 効用関数の誤設定を起こしにくいため、バイアスのないパラメータ推定に非常に有用。

## 信頼性

NNとMNLはどちらもよく知られた手法であり、手法自体の信頼性は高い。

しかし、NNを用いる以上得られた結果に信頼性があるかはさまざまな観点で検証する必要がある。

# 目次

## 1. Introduction

## 2. 提案手法

- MNLへのNNの結合方法

## 3. 数値実験

- 予測精度の検証
- パラメータバイアスの検証

## 4. 実データ分析

- 予測精度の検証
- 解釈可能性に関する分析

## 5. 結論

# 離散選択モデル(DCM)の異質性の扱い

## 通常のランダム効用モデル

異質性は選択者の**個人特性と代替属性の相互作用**で記述

ex)MNLの場合

$$V_{train} = ASC + (age > 65) * time$$

とすると、年齢による異質性が表現可能

×問題に対する知識がない場合に効用関数の立式を正しくできない

## 手法① 非線形関数の利用

- 柔軟な異質性の把握が可能
- ×関数の設定方法が多数あり設定が難しい

## 手法② 混合ロジット/潜在クラスの利用

- 柔軟な異質性の把握が可能
- ×効用関数の立式に基づく誤差は解消されない

# ニューラルネットワーク(NN)の利用

## 手法③ NNの利用

○高い精度の予測が可能

×**解釈可能性の欠如**

→”what if”の質問に信頼性のある答えを出せない



## DCMフレームワーク内でのNNの活用

(Neural-embedded Discrete Choice Model :NEDCM)

基本的な枠組みはDCMだが、**効用関数の計算の一部にNNを用いる**

○モデルの解釈性を保ちつつNNで予測精度を向上させることが可能.

# 既往研究：Sifringer et al(2020)によるL-MNL

効用関数の一部分をNNで学習させる

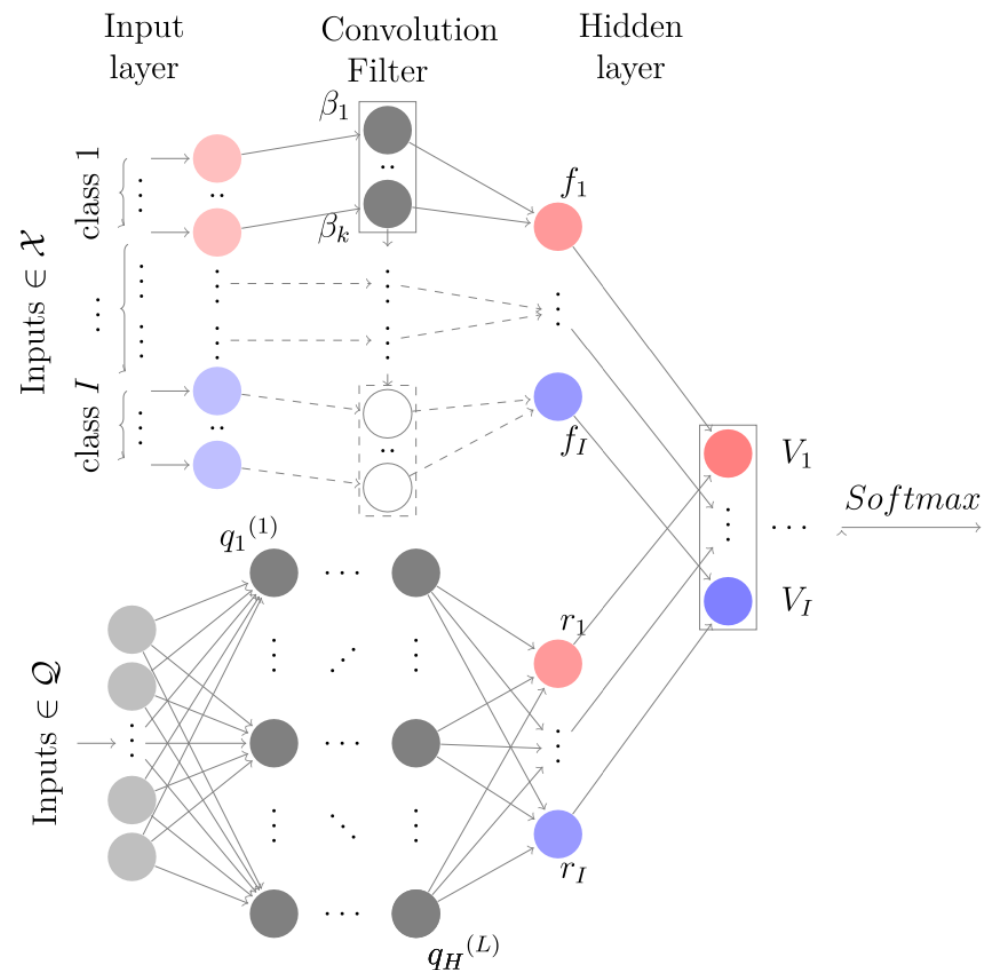
$$V_{in} = \underbrace{f_i(X_n; \boldsymbol{\beta})}_{\text{線形和 (通常のMNLと同一)}} + \underbrace{r_i(Q_n; \mathbf{w})}_{\text{説明変数を入力とし, 効用関数の一部を出力するNN}}$$

線形和

(通常のMNLと同一)

説明変数を入力とし,  
効用関数の一部を出力するNN

効用関数に関する知識がない説明変数に対してNNを使用することで、解釈可能性を損なわず予測精度が向上

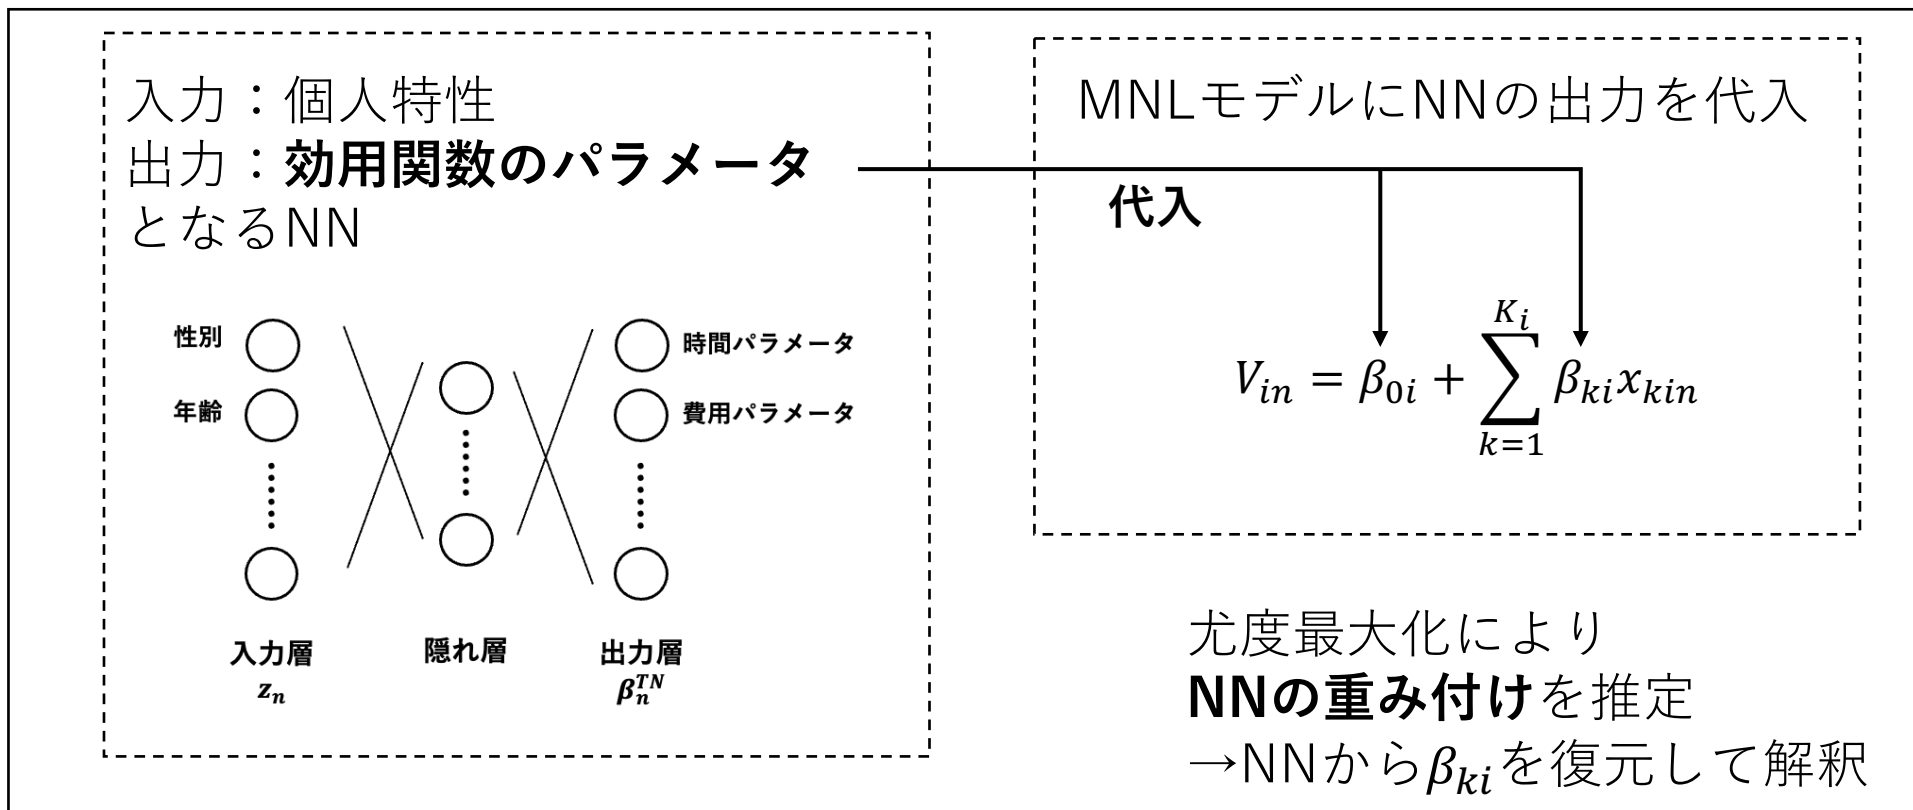


# 研究の全体像

## 実現したいこと

個人特性による異質性の考慮/モデルの予測精度の向上/解釈可能なモデルの構築

## 手法 効用関数のパラメータを学習するNNを構築





# 問題設定とMNLの定式化

MNLで定式化できる状況を考える。

個人間の異質性がない場合の効用(MNL)

$$V_{in} = \beta_{0i} + \sum_{k=1}^{K_i} \beta_{ki} x_{kin}$$

個人に関する変数は含まれない。

異質性を考慮した場合の効用(MNL)

$$V_{in} = \beta_{0i} + \sum_{k=1}^{K_i} \beta_{ki} x_{kin} + \sum_{(p,q) \in I_i} \gamma_{pqi} x_{pin} z_{qn}$$

異質性を個人特性と選択肢属性の交互作用で記述

## 文字設定

$n$ :個人

$C_n$ :  $n$ の選択肢集合

$z_n$ :個人特性 (年齢など)

$x_{in} (\forall i \in C_n)$ :**選択肢**属性 (所要時間など)

$y_n$ :  $n$ の選択結果

# NNの利用

異質性を考慮した場合の効用(MNL)

$$V_{in} = \beta_{0i} + \sum_{k=1}^{K_i} \beta_{ki} x_{kin} + \sum_{(p,q) \in I_i} \gamma_{pqi} x_{pin} z_{qn}$$

異質性を個人特性と選択肢属性の交互作用で記述

どの相互作用を採用するかには膨大な数の組み合わせがあり、全てを試すことは難しい。



パラメータの一部を個人特性の関数としてNNに学習させ、その結果を用いてMNLで推定(TasteNet-MNL)

$$V_{in} = \beta_{ni}^{TN'} x_{in}^{TN} + \underbrace{f(x_{in}^{MNL}, z_{in}^{MNL}, \beta_i^{MNL})}_{\text{通常のMNLの効用形式}}, \quad \beta_n^{TN} = \text{TasteNet}(z_n^{TN}; w)$$

↑  
個人特性から学習した  
パラメータ

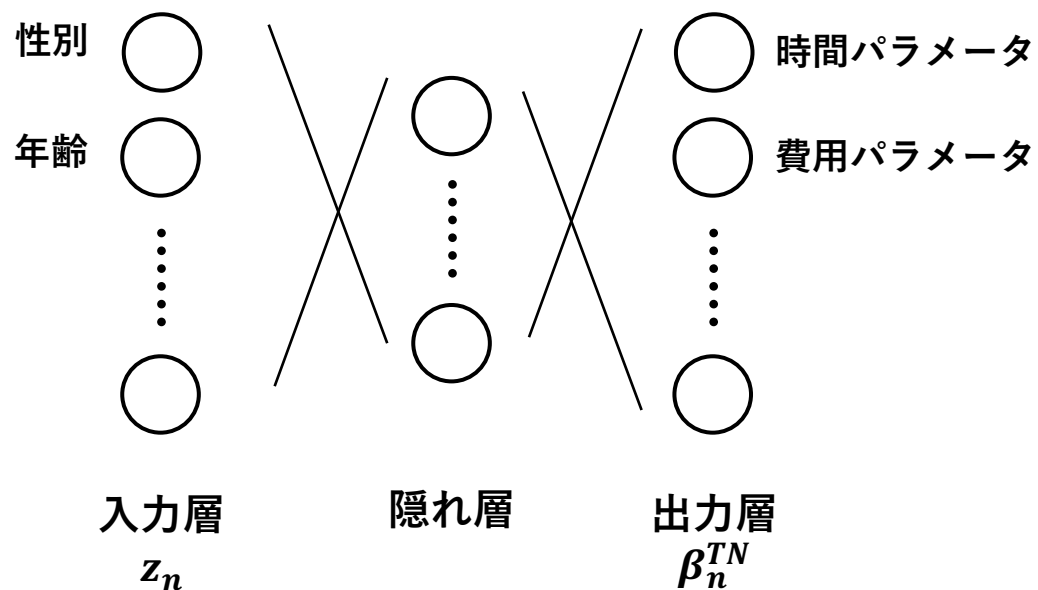
膨大な相互作用の組み合わせを試すことなく個人異質性を考慮可能

# TasteNet-MNL

## ① NNの構築

入力：個人属性  $\mathbf{z}_n$

出力：効用関数のパラメータ  $\beta_n^{TN}$



$$\beta_n^{TN} = \text{TasteNet}(\mathbf{z}_n^{TN}; \mathbf{w})$$

## ② MNLへの代入

全ての係数をTasteNetで求める必要はない

その際は通常のMNLと同様に処理

代入

$$V_{in} = \beta_n^{TN'} \mathbf{x}_{in}^{TN} + f(\mathbf{x}_{in}^{MNL}, \mathbf{z}_{in}^{MNL}, \beta_i^{MNL})$$

$$P(y_n = i | x_n, z_n, w, \beta^{MNL}) = \frac{\exp(V_{in})}{\sum_{j \in C_n} \exp(V_{jn})}$$

※不偏推定量を得るためには


$$\mathbf{z}_n^{TN} \cap \mathbf{z}_n^{MNL} = \emptyset$$

であることが求められる。

# TasteNetの詳細

入力：個人属性  $\mathbf{z}_n$

出力：効用関数のパラメータ  $\beta_n^{TN}$



出力層の  $k$  番目の値は

$$\beta_k^{TN}(\mathbf{z}, \mathbf{w}) = T \left[ \sum_{h=1}^H w_{kh}^{(2)} A^{(1)} \left( \sum_{i=1}^D w_{hi}^{(1)} z_i + w_{h0}^{(1)} \right) + w_{k0}^{(2)} \right]$$

で得られる

$T$  はパラメータの範囲を制約するために用いる

ex) パラメータを正にしたい場合

$$T(x) = \max(0, x)$$

$$T(x) = \exp(x)$$

などとおく。

# パラメータ推定手法

## 通常の場合

対数尤度関数のマイナスをとったもの

$$E(\boldsymbol{\beta}) = - \sum_n \log P(y_n | \mathbf{z}_n, \mathbf{x}_n; \boldsymbol{\beta})$$

を最小化する.

推定対象は  $\boldsymbol{\beta}$

## TasteNet-MNLの場合

対数尤度関数のマイナスをとったものにNNの重みに関するペナルティ項を設けたもの(over fittingを防ぐため)

$$E(\boldsymbol{\beta}) = - \sum_n \log P(y_n | \mathbf{z}_n, \mathbf{x}_n; \mathbf{w}, \boldsymbol{\beta}^{MNL}) + \lambda_p \|\mathbf{w}\|^p$$

を最小化する.

推定対象は  $\mathbf{w}, \boldsymbol{\beta}^{MNL}$

# 数値実験：データセット

モデル：バイナリロジットモデル

個人特性：所得(*inc*), フルタイム雇用ダミー(*full*), フレキシブルワークダミー(*flex*)

選択肢属性：移動コスト(*cost*), 移動時間(*time*), 待ち時間(*wait*)

真の効用関数

$$\begin{aligned} V_{in} = & ASC_i - cost_{in} + \\ & (-0.1 - 0.5inc_n - 0.1full_n + 0.05flex_n \\ & - 0.2inc_n * full_n + 0.05inc_n * flex_n + 0.1full_n * flex_n) * time_{in} + \\ & (-0.2 - 0.8inc_n - 0.3full_n + 0.1flex_n \\ & - 0.3inc_n * full_n + 0.08inc_n * flex_n + 0.3full_n * flex_n) * wait_{in} \end{aligned}$$

データセットの種類

TOY\_UNCORREL：選択肢属性の相関なし

TOY\_CORREL：選択肢属性の相関あり (timeとwaitに0.6の相関)

# 数値実験：比較用モデル

比較用に3種類のMNLモデルを考える

**MNL-I**：二次の相互作用を含まないモデル

$$V_i^{MNL-I} = ASC_i - cost_i + (b_0 + b_1 inc + b_2 full + b_3 flex) * time_i \\ + (c_0 + c_1 inc + c_2 full + c_3 flex) * wait_i$$

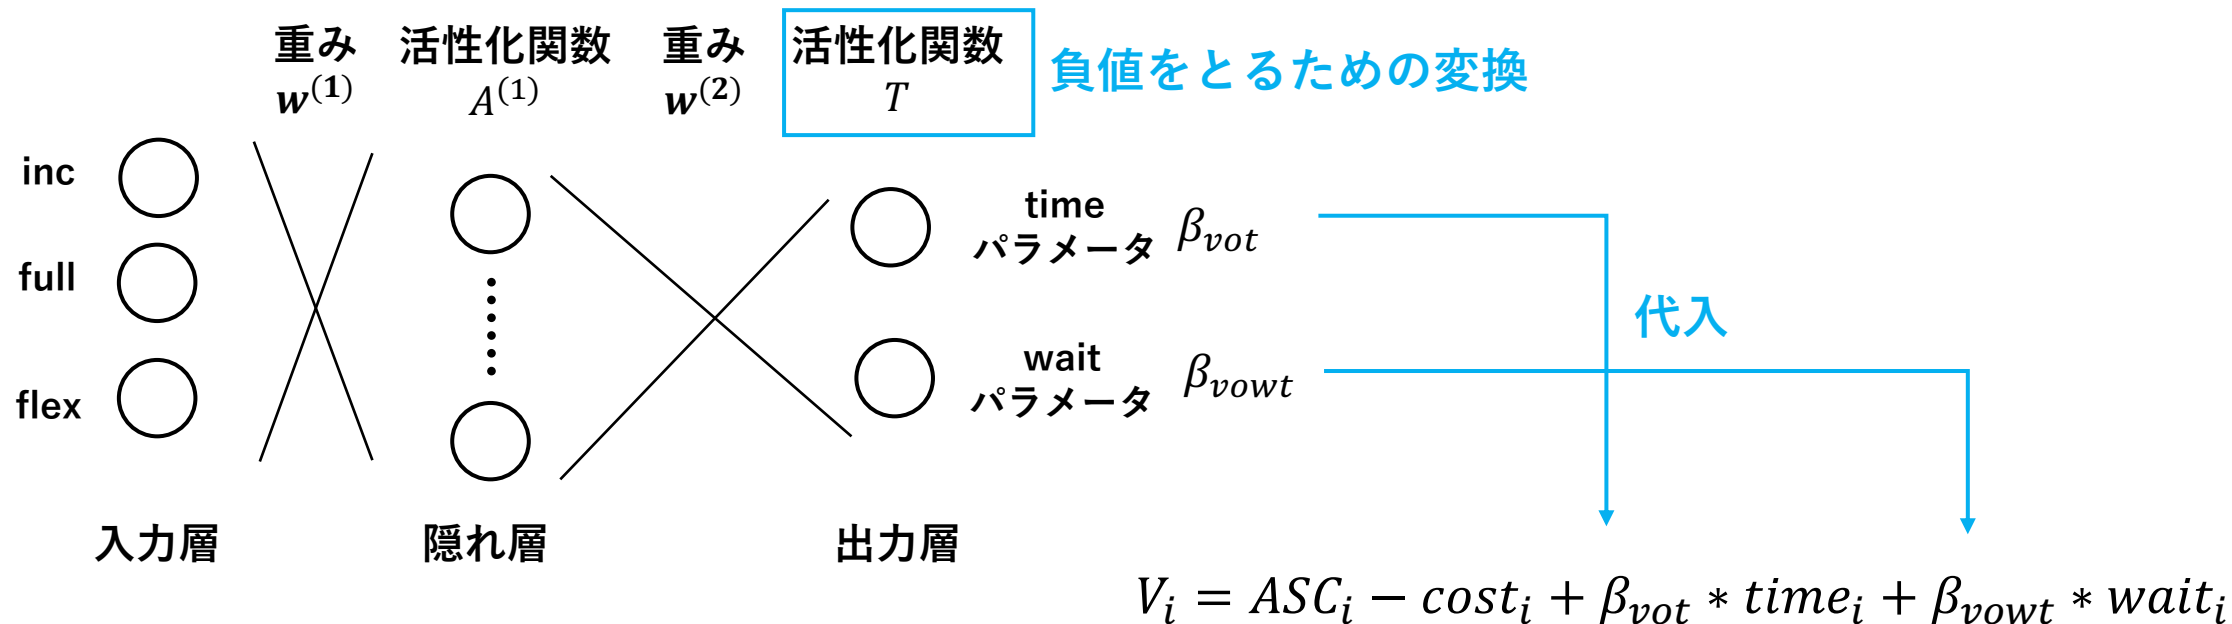
**MNL-II**：二次の相互作用を一部含むモデル

$$V_i^{MNL-II} = ASC_i - cost_i + (b_0 + b_1 inc + b_2 full + b_3 flex + b_{12} inc * full) * time_i \\ + (c_0 + c_1 inc + c_2 full + c_3 flex + c_{12} inc * full) * wait_i$$

**MNL-TRUE**：真の効用関数と同じ形式のモデル

# 数値実験：TasteNet-MNL

TasteNet-MNL：効用関数パラメータの値をNNの出力とするモデル



ハイパーパラメータ(隠れ層のサイズ, 正則化のペナルティ, 活性化関数)の決定

訓練データを用いて様々なハイパーパラメータの組み合わせのもと学習

→検証データを用いて最も目的関数を小さくするものを選択



# 結果：予測精度

## TOY\_UNCORREL(相関なし)

Model	負の対数尤度			予測精度		
	NLL_train	NLL_dev	NLL_test	ACC_train	ACC_dev	ACC_test
MNL-I	0.59775	0.57773	0.57866	0.712	0.725	0.739
MNL-II	0.50618	0.47657	0.49603	0.755	0.768	0.760
TasteNet-MNL						
best run	0.46523	0.44193	0.44293	0.777	0.785	0.789
mean	0.46688	0.44494	<u>0.44536</u>	0.775	0.787	<u>0.785</u>
std	(0.00159)	(0.00141)	(0.00225)	(0.002)	(0.002)	(0.003)
MNL-TRUE	0.46424	0.44028	<u>0.44669</u>	0.777	0.786	<u>0.784</u>
Ground-truth	0.46460	0.44120	0.44655	0.775	0.786	0.788

TasteNet-MNLは真のモデル(MNL-TRUE)と同等の予測性能を示した。

# 結果：予測精度

## TOY\_CORREL(相関あり)

Model	負の対数尤度			予測精度		
	NLL_train	NLL_dev	NLL_test	ACC_train	ACC_dev	ACC_test
MNL-I	0.67756	0.62325	0.66171	0.698	0.706	0.705
MNL-II	0.53260	0.52495	0.53488	0.748	0.741	0.750
TasteNet-MNL						
best run	0.46261	0.46671	0.45345	0.777	0.773	0.776
mean	0.46125	0.47171	<u>0.45332</u>	0.777	0.768	<u>0.776</u>
std	(0.00198)	(0.00216)	(0.00275)	(0.002)	(0.003)	(0.003)
MNL-TRUE	0.45839	0.47018	<u>0.45228</u>	0.779	0.768	<u>0.778</u>
Ground-truth	0.45945	0.46845	0.45110	0.777	0.767	0.781

TasteNet-MNLは真のモデル(MNL-TRUE)と同等の予測性能を示した。

# 結果：効用関数パラメータ推定

効用関数パラメータ $\beta$ をNNの結果からきちんと復元できるかを検証

NNから出てきた $\beta_{vot}, \beta_{vowt}$ を

$$\beta_{vot} = b_0 + b_1 inc + b_2 full + b_3 flex + b_4 inc * full + b_5 inc * flex + b_6 full * flex$$

$$\beta_{vowt} = c_0 + c_1 inc + c_2 full + c_3 flex + c_4 inc * full + c_5 inc * flex + c_6 full * flex$$

によって回帰して効用関数パラメータを推定する

# 結果：パラメータ推定の誤差

## TOY\_UNCORREL(相関なし)

Table 3

Parameter estimates by MNLs and TasteNet-MNL (Uncorrelated Data).

Coef	MNL-I	MNL-II	MNL-TRUE	TasteNet-MNL (best run)	TasteNet-MNL (100 runs: mean, std)	Truth
RMSE	0.0911	0.2787	0.0238	0.0298	0.0520 (0.0203)	
MAE	0.0524	0.1615	0.0158	0.0204	0.0379 (0.0141)	
MAPE	0.3146	1.3172	0.0805	0.1320	0.2359 (0.0849)	

$$RMSE = \sqrt{\frac{1}{n} \sum_i (\beta_i - \hat{\beta}_i)^2}, MAE = \frac{1}{n} \sum_i |\beta_i - \hat{\beta}_i|, MAPE = \frac{1}{n} \sum_i \left| \frac{\beta_i - \hat{\beta}_i}{\beta_i} \right|$$

どれも予測誤差を評価する指標で、小さいほど良い

TasteNet-MNLは比較モデルより遥かにバイアスが小さい

# 結果：MNL-I とMNL-II の比較

## 予測精度

Table 1

Average Negative Log-likelihood (NLL) and Prediction Accuracy (ACC) for synthetic data with uncorrelated alternative attributes.

Model	NLL_train	NLL_dev	NLL_test	ACC_train	ACC_dev	ACC_test
MNL-I	0.59775	0.57773	0.57866	0.712	0.725	0.739
MNL-II	0.50618	0.47657	0.49603	0.755	0.768	0.760

予測精度

## パラメータバイアス

Table 3

Parameter estimates by MNLs and TasteNet-MNL (Uncorrelated Data).

Coef	MNL-I	MNL-II	MNL-TRUE	TasteNet-MNL (best run)	TasteNet-MNL (100 runs: mean, std)	Truth
RMSE	0.0911	0.2787	0.0238	0.0298	0.0520 (0.0203)	
MAE	0.0524	0.1615	0.0158	0.0204	0.0379 (0.0141)	
MAPE	0.3146	1.3172	0.0805	0.1320	0.2359 (0.0849)	

パラメータバイアス

MNL-I (二次相互作用なし)よりもMNL-II (二次相互作用あり)の方が予測精度は向上しているが、効用関数パラメータのバイアスが大きい

→効用関数の指定が正しくない限り、予測可能性が高くてもバイアスが発生する

# 結果：パラメータ推定の誤差

## TOY\_CORREL(相関あり)

Table 4  
Parameter estimates by MNLs and TasteNet-MNL (Correlated Data).

Coef	MNL-I	MNL-II	MNL-TRUE	TasteNet-MNL best run	TasteNet-MNL 100 runs: mean (std)	Truth
RMSE	0.1065	0.2988	0.0469	0.0220	0.0545 (0.0197)	
MAE	0.0622	0.1751	0.0261	0.0177	0.0391 (0.0130)	
MAPE	0.3537	1.4445	0.1121	0.1571	0.2428 (0.0706)	

RMSE: Root Mean Squared Error; MAE: Mean Absolute Error; MAPE: Mean Absolute Percentage Error

MNL-TRUEのバイアスは増大したが、TasteNetの精度はあまり下がらない


→MNLは線形的な構造に制約されるため入力分布の変化に対応しにくいですが、NNを用いると柔軟に対応できる

# 結果：個人特性を変化させたときのパラメータの変化


所得(inc), フルタイム雇用ダミー(full), フレキシブルワークダミー(flex)が一様に分布したデータセットを作成. incを変化させたときの $\beta_{vot}, \beta_{vowt}$ の変化を分析.

## MNL-I (二次相互作用なし)の場合の $\beta_{vowt}$ の変化

相関なし



相関あり



相互作用を考慮していないため、傾きはfull, flexによらず常に同じ




# 結果：個人特性を変化させたときのパラメータの変化

MNL-II (二次相互作用一部あり)の場合の $\beta_{vowt}$ の変化

正解の値

相関なし

相関あり




二次の相互作用を考えたグループとそうでないグループでの傾きの違いが大きい




# 結果：個人特性を変化させたときのパラメータの変化

MNL-TRUE(真の効用関数形式)の場合の $\beta_{vowt}$ の変化

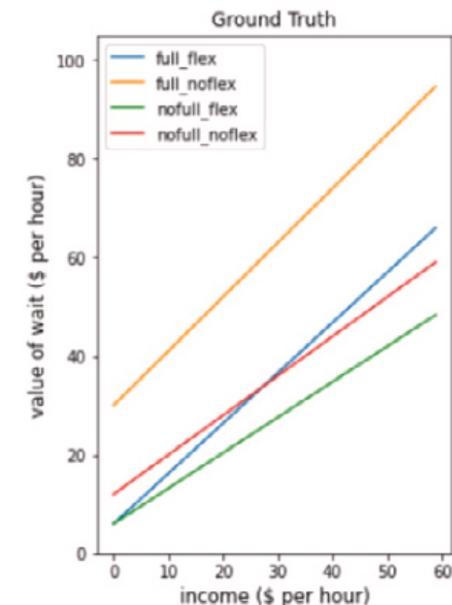
相関なし



相関あり



正解の値




相関がない場合は近い値を出すすが相関がある場合は値が歪む


# 結果：個人特性を変化させたときのパラメータの変化

TasteNet-NNの場合の $\beta_{v_{owt}}$ の変化


相関なし



相関あり



正解の値

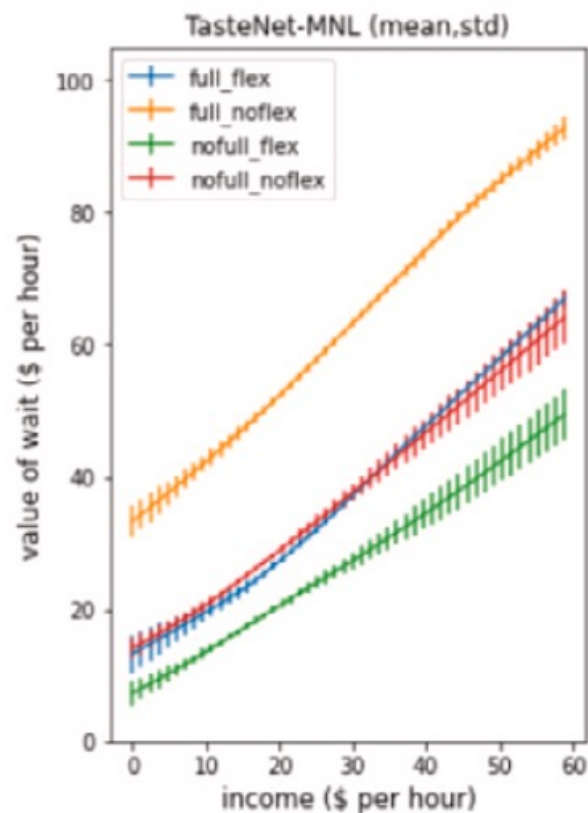


非線形だが全体として真の形に近い

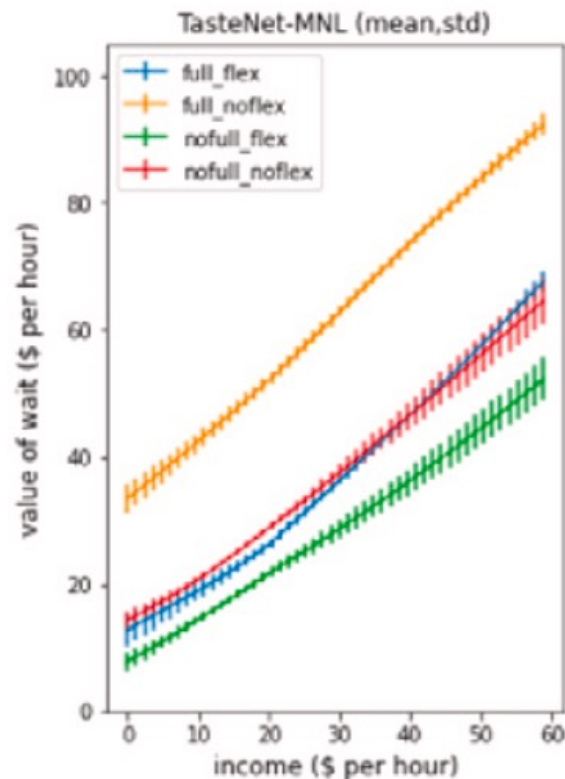
# 結果：個人特性を変化させたときのパラメータの変化

TasteNet-NNの場合の $\beta_{v_{owt}}$ の変化(平均と分散を可視化)


相関なし



相関あり



正解の値

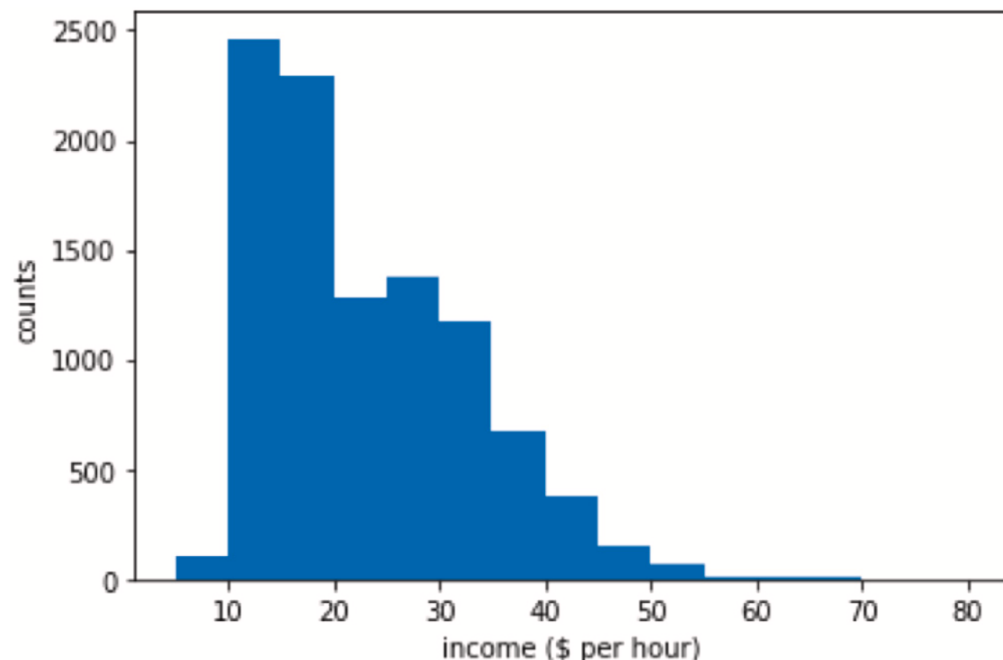


incomeが極端に高いor低い場合で分散・バイアスが大きいの

# 結果：個人特性を変化させたときのパラメータの変化

TasteNet-NNの場合の $\beta_{vowt}$ の変化(平均と分散を可視化)

学習データのincomeの分布



incomeが極端に高いor低い場合で分散・バイアスが大き

→incomeが極端に高いor低い場合の学習データが少ないため

→TasteNet-MNLは分布外のサンプルの一般化は得意ではない

# 実データ分析：スイスメトロの需要調査

**対象データ**：スイスメトロの需要評価のためのSP調査

**選択構造**：鉄道(Train), スイスメトロ(SM), 自動車(Car)から1つを選択

## 選択肢属性

Train：時間(time)・運行間隔(headway)・費用(cost)

SM：時間・運行間隔・配置(seats)・費用

CAR：時間・費用

## 個人特性

- 年齢(age)
- 性別(male)
- 収入(income)

など

# 比較モデル

比較モデルとして3種類のMNLと1種類のmixed logitを採用

## MNL-Aの形式と推定結果

Table 7

Estimated coefficients of MNL-A.

Variable description	Train	Swissmetro	Car
Constant	0.1227	0.5726	
Travel time (min)	-1.3376	-1.4011	-1.0177
Headway (min)	-0.4509	-0.8171	
Seats (airline seating = 1)		0.1720	
Cost (CHF)	-1 (fixed)	-1 (fixed)	-1 (fixed)
GA (annual ticket = 1)	2.0656	0.5319	
Age			
1: 24 < age ≤ 30	-0.7548		
2: 39 < age ≤ 54	-0.9457		
3: 54 < age ≤ 65	-0.4859		
4: 65 ≤ age	0.6995		
Luggage			
1:one piece			-0.1538
2:several pieces			-0.9230

- 通常のMNLモデル
- 個人特性と選択肢属性の相互作用は考慮していない
- Costの係数を-1に固定(これによりすべての効用関数パラメータがwillingness to payと解釈できる)

# 比較モデル

比較モデルとして3種類のMNLと1種類のmixed logitを採用

## MNL-Aの形式

- 通常のMNLモデル
- 個人特性と選択肢属性の相互作用は考慮していない
- Costの係数を-1に固定(これによりすべての効用関数パラメータがwillingness to payと解釈できる)

## MNL-Bの形式

- MNL-Aに一部の相互作用を追加したモデル(時間\*年齢, 時間\*所得, 時間\*目的)

## MNL-Cの形式

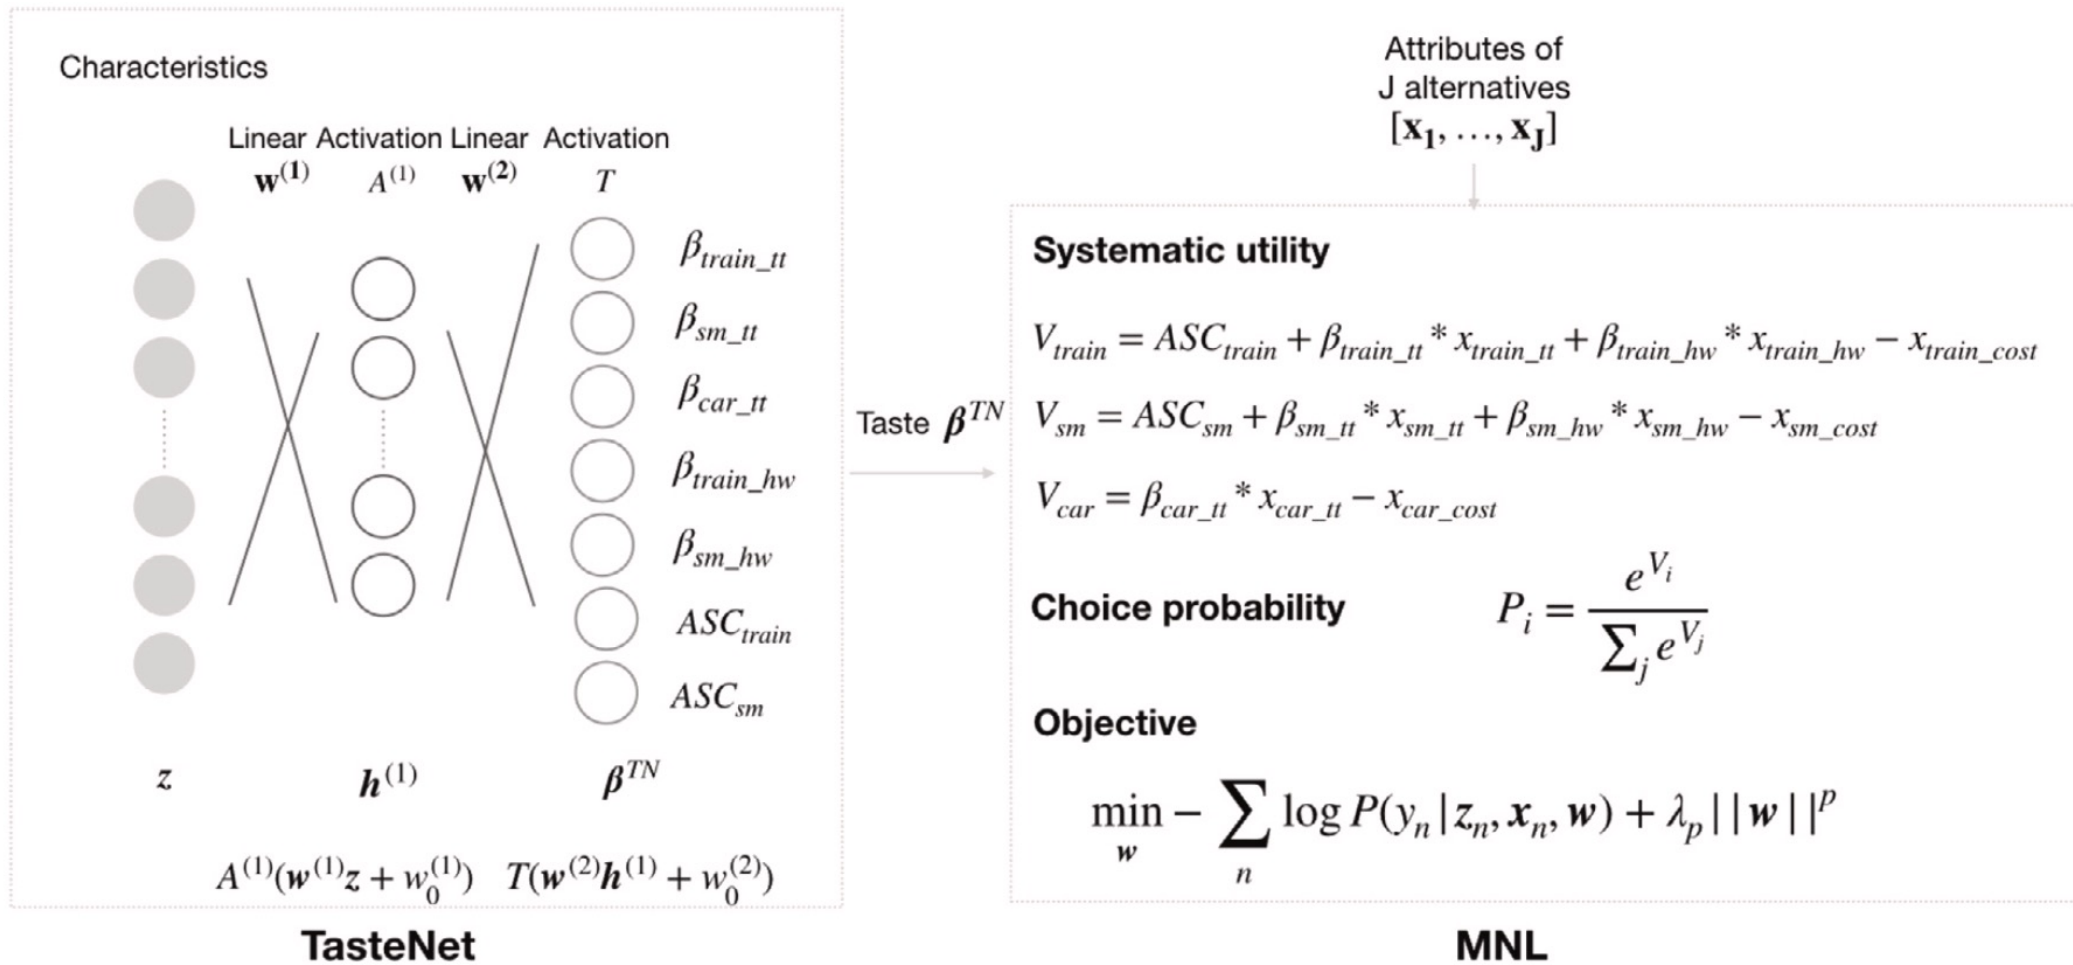
- MNL-Aに全ての一次相互作用を追加したモデル

## mixed logitの形式

- MNL-Aに時間に関する一次相互作用を加えている
- 各選択肢の時間係数が正規分布に基づき変動する

# TransNet-MNL

個人特性からNNで $\beta^{TN}$ を推定し，効用関数に代入





# 結果：予測精度

Table 12

負の対数尤度

予測精度

F1スコア

Average Negative Log-likelihood (NLL), Prediction Accuracy (ACC) and F1 score by model.

Model	NLL			ACC			F1		
	train	dev	test	train	dev	test	train	dev	test
MNL-A	0.762	0.728	0.755	0.662	0.691	0.66	0.535	0.557	0.534
MNL-B	0.73	0.708	0.72	0.678	0.69	0.678	0.578	0.585	0.573
MNL-C	0.704	0.691	0.698	0.685	0.706	0.678	0.588	0.611	0.574
Mixed-Logit	0.712	0.699	0.703	0.681	0.701	0.686	0.588	0.606	0.586
TasteNet (no2)	0.607	0.646	0.645	0.737	0.718	0.703	0.668	0.634	0.620
TasteNet (100 runs)	0.605	0.650	0.652	0.735	0.718	0.703	0.674	0.645	0.621
mean (std)	(0.0182)	(0.0055)	(0.008)	(0.0094)	(0.0047)	(0.0055)	(0.016)	(0.009)	(0.010)

TasteNetの使用により対数尤度，予測精度，F1スコアともに改善される

# 結果：解釈可能性

TasteNet-MNLとMNLのパラメータから読み取れる解釈の違いを考える。

選択肢属性のパラメータの平均値を比較

**Table 13**

Average tastes estimated by different models.

Mode	Taste	MNL-A	MNL-B	MNL-C	TasteNet (vs MNL-C)	TasteNet mean (std)
TRAIN	TT	-1.338	-1.710	-1.846	-2.327 (26%)	-2.376 (0.179)
	HE	-0.451	-0.616	-0.880	-1.102 (25%)	-1.161 (0.077)
	ASC	-0.198	0.234	0.368	0.801 (117%)	0.824 (0.135)
SM	TT	-1.401	-1.514	-1.505	-1.764 (17%)	-1.905 (0.135)
	HE	-0.817	-0.701	-1.039	-1.733 (67%)	-1.709 (0.131)
	SEATS	0.172	0.189	0.420	0.266 (-37%)	0.270 (0.079)
	ASC	0.648	0.510	0.512	0.669 (31%)	0.675 (0.064)
CAR	TT	-1.018	-1.251	-1.354	-1.685 (24%)	-1.713 (0.101)

TT: time. HE: headway. ASC: alternative specific constant.


MNLの場合、時間価値(青色)は相互作用項が多いほど高い(運行間隔(赤色)に対しても同様)

TransNet-MNLの場合は時間価値、運行間隔に対する時間価値は他のMNLモデルよりも高くなる

# 結果：解釈可能性

TransNet-MNLを用いるとが時間価値が高くなるのはなぜか？

それぞれのモデルにおけるTrainの移動時間価値のヒストグラムを比較



- 相互作用を増やすほど時間価値の違いを捉えられる
- TransNet-MNLは他のモデルよりもさらに柔軟で、大きな時間価値(青枠)を検出できている  
→モデルを柔軟にすることで個人特性の違いによる時間価値の違いを正確に捉えられた


# 結果：行動パラメータの可視化

TransNet-MNLがover fittingを起こしている可能性がある。

→ベンチマークとなるMNLと比較して、妥当な範囲の結果を出力するか確認

個人特性 $\mathbf{z}$ のうち1つを動かして、他を固定した時の**時間価値の変化**を観察。

## スイスメトロの旅行時間に対する時間価値の場合



TasteNet-MNLは他のMNLと比較して極端に異なる値を取らない

# 結果：弾力性

TransNet-MNLがover fittingを起こしている可能性がある。

→ベンチマークとなるMNLと比較して、妥当な範囲の結果を出力するか確認

**弾力性**(ある選択肢の属性 $x_{kin}$ が変化した際の同じ選択肢の選択確率の変化)を比較

## スイスメトロの旅行時間に対する弾力性

Table 15

Aggregate choice elasticity of swissmetro w.r.t travel time by income group.

	INCOME0	INCOME1	INCOME2
MNL-A	-0.3765	-0.4297	-0.4706
MNL-B	-0.3975	-0.3923	-0.5329
MNL-C	-0.3759	-0.3706	-0.4653
TasteNet-MNL	-0.4200	-0.3982	-0.4810

TasteNet-MNLは他のMNLと比較して極端に異なる値を取らない

# 結論

## 成果

- NNとMNLを結合することで、予測精度が高く、異質性を考慮した、解釈可能なモデルを構築
- MNLでは、効用の形式を誤ると予測精度は上昇してもパラメータに大きなバイアスが生じることを明らかに

## 今後の課題

- パラメータのランダム性に起因する違いを考慮したモデルの構築
- 個人属性の非線形効果を反映したモデルの構築

# 所感

- 機械学習と今までのMNLの流れをかなりスッキリとくっつけた論文で、いろいろな範囲に応用可能性がありそうだと感じる。
- ある施策が施策を受けた人の効用関数を変化させる、という因果推論の仮定を置いた場合、効用関数のうち施策の効果に関わらない場所はできるだけ精度良く当てることが正しい因果効果の推定につながる。本手法を用いることでMNL型の立式のまま精度を上げることができそう。

# 参考文献

- Han, Yafei, et al. "A neural-embedded discrete choice model: Learning taste representation with strengthened interpretability." *Transportation Research Part B: Methodological* 163 (2022): 166-186.
- Sifringer, Brian, Virginie Lurkin, and Alexandre Alahi. "Enhancing discrete choice models with representation learning." *Transportation Research Part B: Methodological* 140 (2020): 236-261.



# 補足：スイスメトロの説明変数

**対象データ**：スイスメトロの需要評価のためのSP調査

**選択構造**：鉄道(Train), スイスメトロ(SM), 自動車(Car)から1つを選択

## 選択肢属性

Train：時間(time)・運行間隔  
(headway)・費用(cost)

SM：時間・運行間隔・配置(seats)・  
費用

CAR：時間・費用

## 個人特性

年齢(age)・性別(male)・収入(income)

ファーストクラストラベラーかどうか(first)

Swiss annual season ticket の有無(GA)

目的(purpose)

支払いをするのは誰か(who)

荷物の個数(luggage)

# 補足：比較モデルの推定結果

比較モデルとして3種類のMNLと1種類のmixed logitを採用

## MNL-Bの形式と推定結果

Table 8

Estimated coefficients of MNL-B.

Variable description	Train	Swissmetro	Car
Constant	0.0056	0.4674	
Travel time (min)	-0.5006	-0.4010	-0.5600
Travel time * Age			
0: age ≤ 24			
1: 24 < age ≤ 39	-0.6354	-0.3307	-0.5696
2: 39 < age ≤ 54	-0.8475	-0.6101	-0.6105
3: 54 < age ≤ 65	-0.1566	0.1419	-0.0915
4: 65 < age	0.3265	-0.243	-0.0234
Travel time * Income			
0: under 50			
1: 50 to 100	-0.2688	0.1739	0.1623
2: over 100	-1.0181	-0.436	-0.4093
3: unknown	0.0852	0.2828	-0.0923
Travel time * Purpose			
0: Commute			
1: Shopping	-0.2081	-0.6192	-0.6062
2: Business	-0.1574	-0.8688	-0.1833
3: Leisure	-0.59	-0.9706	-0.0162
Headway (min)	-0.6158	-0.7011	
Seats (airline seating = 1)		0.189	
Cost (CHF)	-1 (fixed)	-1 (fixed)	-1 (fixed)
GA (annual ticket = 1)	1.6162	0.2988	
Luggage			
1:one piece			-0.1714
2:several pieces			-0.6718

- MNL-Aに一部の相互作用を追加したモデル(時間\*年齢, 時間\*所得, 時間\*目的)

# 補足：比較モデルの推定結果

比較モデルとして3種類のMNLと1種類のmixed logitを採用

## MNL-Cの形式と推定結果

Table 9  
Estimated coefficients of MNL-C.

z (characteristics)	Coefficients for alternative attributes							
	TRAIN_TT	SM_TT	CAR_TT	TRAIN_HE	SM_HE	SM_SEATS	TRAIN_ASC	SM_ASC
Intercept	-0.0671	0.1455	0.0059	0.1713	0.0646	0.3064	0.2953	0.2067
Male	-0.1526	-0.0477	0.0742	-0.2384	0.0706	-0.1016	0.0671	0.149
Age								
1: (24,39]	-0.0965	-0.2422	-0.1093	0.0044	0.5682	0.0517	-0.1634	0.4285
2: (39,54]	-0.1467	-0.2022	-0.195	-0.2397	-0.0105	-0.2135	-0.2692	0.0959
3: (54,65]	0.0256	0.1201	0.0251	-0.2379	-0.0807	0.1619	-0.0861	-0.0344
4: (65,)	-0.1712	0.1435	0.1105	0.6032	-0.1488	-0.1529	0.618	-0.351
Income								
1: 50-100	0.0494	-0.039	0.0098	-0.1884	-0.2972	0.2349	-0.1776	0.1944
2: over 100	-0.2825	-0.1697	-0.2662	0.1393	0.0372	0.5288	-0.0406	-0.0789
3: unknown	0.0289	0.1467	-0.2037	0.1484	-0.0721	-0.4196	0.1621	-0.0459
First class	-0.1927	-0.0807	-0.3297	-0.4768	0.1183	0.1302	0.2228	-0.2085
Who pay								
1: employer	-0.2154	-0.1668	0.1231	0.028	-0.0045	0.0882	0.1191	0.3986
2: half-half	0.1537	0.4771	0.4391	-0.0311	0.3917	0.3114	-0.2414	-0.0332
Purpose								
1:Shopping	0.2339	-0.219	0.19	0.1509	0.0493	0.1994	0.4238	0.6996
2:Business	-0.0872	-0.3524	-0.181	-0.0544	-0.0195	-0.0647	0.0605	-0.2941
3:Leisure	-0.2678	-0.2778	-0.0043	0.3245	-0.4552	-0.0289	-0.302	-0.4739
Luggage								
1:one piece	-0.0375	0.0861	0.2525	0.58	-0.1993	0.0413	0.3364	0.3239
2:several pieces	0.022	-0.1785	-0.2731	-0.2946	0.0814	-0.1225	-0.0041	0.2158
Annual ticket	0.5912	-0.0075	-0.3181	0.2652	-0.2032	-0.5815	0.3576	0.1351

- MNL-Aに全ての一次相互作用を追加したモデル

# 補足：比較モデルの推定結果

比較モデルとして3種類のMNLと1種類のmixed logitを採用

## mixed logitの形式と推定結果

Table 10  
Estimated coefficients of Mixed Logit Model.

Variable description	Train	Swissmetro	Car
Constant		-0.763	-1.453
Travel time (min)	-1.691	-0.265	-0.897
Travel time Std (min)	1.329	0.621	0.351
Travel time * Male	-0.537	-0.149	-0.009
Travel time * Age			
0: age ≤ 24			
1: 24 < age ≤ 39	-1.429	-1.345	-0.949
2: 39 < age ≤ 54	-1.420	-1.533	-0.893
3: 54 < age ≤ 65	-0.730	-0.876	-0.411
4: 65 < age	0.432	-0.549	0.140
Travel time * Income			
0: under 50			
1: 50 to 100	0.052	0.808	0.582
2: over 100	-0.391	0.452	0.209
3: unknown	0.899	1.359	0.633
Travel time * Purpose			
0: Commute			
1: Shopping	-0.754	-1.676	-1.312
2: Business	-0.135	-1.114	-0.258
3: Leisure	-1.062	-1.477	-0.196
Travel time * Luggage			
1: One piece	0.658	0.714	0.496
2: Several pieces	-0.922	-1.477	-1.597
Travel time * Annual Ticket	1.542	-0.301	-0.788
Headway (min)	-0.969	-1.365	
Seats (airline seating = 1)		0.559	
Cost (CHF)	-1 (fixed)	-1 (fixed)	-1 (fixed)

- MNL-Aに時間に関する一次相互作用を加えている
- 各選択肢の時間係数が正規分布に基づき変動する