

# 交互作用を考慮した 一般化加法ニューラルネットワークに基づく 離散選択モデル

西 智樹<sup>1</sup>・原 祐輔<sup>2,3</sup>

<sup>1</sup>非会員 豊田中央研究所 (〒 480-1192 愛知県長久手市横道 41-1)・  
E-mail: nishi@mosk.tytlabs.co.jp

<sup>2</sup>正会員 東北大学准教授 大学院情報科学研究科 (〒 980-8579 仙台市青葉区荒巻字青葉 6-6-06)  
E-mail: hara@tohoku.ac.jp

<sup>3</sup>東京大学次世代知能科学研究センター客員研究員

線形効用を仮定した多項ロジットモデルは単純なモデルは推定された係数の解釈性が高く現在でもよく利用される反面、データへの当てはまりがそれほど高くない。また説明変数間の相互作用をどのようにモデル化するかに関して分析者にゆだねられており、試行錯誤を通して発見的に決定しなければならないという課題もある。そこで本研究では、効用関数に2変数間の交互作用まで考慮した一般化加法ニューラルネットワークモデルを用いた多項ロジットモデル MNL-GAIUNet (Multinomial Logit Model based on Generalized Additive and Interactive Utility Network) を提案する。提案手法では、効用関数として一般化加法モデルを用いることで各説明変数や交互作用項の選択判断への寄与を容易に算出でき、また非線形関数としてニューラルネットワークを用いることで非線形な嗜好性も捉えられる。移動店舗に関する SP 調査データに適用し、本手法の有効性を検証する。

**Key Words:** *Discrete Choice Model, Multinomial Logit Model, Artificial Neural Network, Generalized Additive Model*

## 1. はじめに

多項ロジットモデルを代表とする離散選択モデルは、ランダム効用理論<sup>1)</sup>を基礎とする理論駆動型アプローチとして発展しながら、モデルの扱いやすさから都市計画や交通施策の検討など実務でも長年利用されてきた<sup>2)</sup>。離散選択モデル研究の主眼は、意思決定者の選択行動プロセスの理解と定式化にあり、選択行動の因果構造は行動理論に基づき陽にモデル化したり、パラメータに物理・経済的な意味を持たせるなどモデルや分析結果の解釈性が重要視されてきた<sup>3)</sup>。その一方で説明変数や交互作用項の選び方によって大きく性能が変わるが、分析者は試行錯誤を通してそれらを発見的に決定しなければならないなど課題もある<sup>3)</sup>。

理論駆動型の離散選択モデルに対して、情報分野ではデータ駆動型アプローチとして統計的機械学習の手法が盛んに研究されてきた<sup>4)</sup>。近年では機械学習は、検索システムや、音声認識、商品推薦など様々な分野の実サービスの基盤技術として活用されている。データ駆動型アプローチでは、できる限り汎用性の高いモデルや手法で未知のデータに対して高精度な予測/分類を実現することが重要視されてきた。そのため分析者が学習されたモデルや推定結果から選択行動原理を理解

したり、得られた知見を計画や施策につなげることが困難であることも多い。

そのような課題を解決するため機械学習の分野でも説明可能性に関して数多くの研究が行われてきた<sup>5)</sup>。学習結果の可視化<sup>6)</sup>や後処理による判断根拠の算出手法<sup>7),8)</sup>や解釈性が高いモデル<sup>9),10),11)</sup>など様々なアプローチ提案されている。Lou ら<sup>9)</sup>は、予測性能と解釈性を兼ね備えた手法として一般化加法モデルに交互作用項を導入した回帰及び分類モデル GA<sup>2</sup>M を提案した。また GA<sup>2</sup>M の非線形関数として勾配ブースティング木を用いた Explainable Boosting Machine (EBM)<sup>10)</sup>やニューラルネットワークを用いた GAMI-Net<sup>11)</sup>が提案されている。これらの手法は各説明変数や2変数間の交互作用項の重要度を算出することで、どの変数が回帰や分類にどれくらい寄与するかを知ることができる。

離散選択モデル分野でも2017年ごろから機械学習を用いた離散選択モデルの研究が注目されてきており、離散選択モデルと機械学習手法の良いとこどりを目指したハイブリッド手法が提案されつつある<sup>3)</sup>。Wang ら<sup>12)</sup>は、各選択肢ごとの効用関数をニューラルネットワークで学習する多項ロジットモデル ASU-DNN を提案した。この手法はニューラルネットワークを用いることでデータに対する適合が高く、各選択肢の説明変数間の

高次の交互作用を扱えるモデルを学習できる。一方で選択判断の根拠を解釈には感度分析など後処理が必要となる。また Sifringer ら<sup>13)</sup> は、線形効用を用いた多項ロジットモデルに、効用の非線形を扱うためのニューラルネットワークを融合させた手法 L-MNL を提案した。多項ロジットモデルの部分は既往研究と同様に解釈や分析できるが、ニューラルネットワークの部分は解釈性は低い。Han ら<sup>14)</sup> は、効用関数は線形モデルだが個人属性と選好の関係をニューラルネットワークで学習する手法 TasteNet-MNL を提案した。このモデルは、個人属性と選好の関係をニューラルネットワークにより学習することで、モデルの当てはまりを上げるとともに、既往研究と同様に線形効用を用いることで解釈性を担保している。しかしながら、従来の多くの離散選択モデルと同様に線形効用を用いているため、非線形な選好性を表現することはできない。

そこで本研究では、各選択肢の効用関数に 2 変数間の交互作用まで考慮した一般化加法ニューラルネットワークモデルを用いた多項ロジットモデル MNL-GAUNet (Multinomial Logit Model based on Generalized Additive and Interactive Utility Network) を提案する。提案手法では、効用関数として一般化加法モデルを用いることで各説明変数や交互作用項の選択判断への寄与を容易に算出でき、また非線形関数としてニューラルネットワークを用いることで非線形な選好性も捉えられる。移動店舗に対する選好を調査した SP 調査の結果に対して適用し、本手法の有効性を評価する。

## 2. MNL-GAIUNet

本節では線形効用関数を用いた多項ロジットモデルを概説した後、提案手法である MNL-GAIUNet について述べる。

### (1) 多項ロジットモデル

多項ロジットモデルでは、効用関数  $U$  は確定効用  $V$  とガンベル分布に従うランダム項  $\varepsilon$  の和により表されると仮定する。このような仮定を導入することにより、各選択肢の選択確率を理論的に簡潔な形で書き表すことができる。具体的には、選択肢集合を  $\mathcal{A}$ 、説明変数の集合を  $\mathbf{x}$ 、選択肢  $i$  の説明変数ベクトルを  $\mathbf{x}_i$  とした時、選択肢  $i \in \mathcal{A}$  が選択される確率  $P(i|\mathbf{x}_i)$  は、式 (3) のようになる。

$$U(\mathbf{x}_i) = V(\mathbf{x}_i) + \varepsilon_i, \quad i \in \mathcal{A}, \quad (1)$$

$$\varepsilon_i \sim \text{Gumbel}(0, \mu), \quad i \in \mathcal{A}, \quad (2)$$

$$P(i|\mathbf{x}) = \frac{\exp(V_i(\mathbf{x}_i))}{\sum_{i \in \mathcal{A}} \exp(V_i(\mathbf{x}_i))}, \quad i \in \mathcal{A}, \quad (3)$$

$$\mathbf{x} = \{\mathbf{x}_i | i \in \mathcal{A}\}, \quad (4)$$

ここで  $\varepsilon_i$  は、選択肢  $i$  に関するランダム項、 $\mu$  はガンベル分布の最頻値を表すパラメータ。上記の式は任意の確定効用  $V$  に対して成立つが、(5) のような線形効用関数を仮定したモデル (MNL-Linear) がよく用いられてきた。

$$V(\mathbf{x}_i; \omega) = \sum_{j \in \mathcal{S}_i} \omega_{ij} x_{ij}, \quad i \in \mathcal{A}, \quad (5)$$

$$P(i|\mathbf{x}; \omega) = \frac{\exp(V_i(\mathbf{x}_i; \omega))}{\sum_{i \in \mathcal{A}} \exp(V_i(\mathbf{x}_i; \omega))}, \quad i \in \mathcal{A}, \quad (6)$$

ここで、 $\mathcal{S}_i$  は選択肢  $i \in \mathcal{A}$  の説明変数の集合、 $x_{ij}$  は選択肢  $i$  の  $j$  番目の説明変数、 $\omega = \{\omega_{ij} | i \in \mathcal{A}, j \in \mathcal{S}_i\}$  は説明変数  $\{x_{ij} | i \in \mathcal{A}, j \in \mathcal{S}_i\}$  の重み係数集合を表す。MNL-Linear では、準ニュートン法などによりデータ集合  $\mathcal{D}$  に対する対数尤度が最大となる  $\omega$  を容易に推定することができる。

$$\omega = \arg \max_{\omega} \sum_{(a_k, \mathbf{x}_k) \in \mathcal{D}} \log P(i|\mathbf{x}; \omega), \quad (7)$$

ここで  $(a_k, \mathbf{x}_k)$  は  $k$  番目のデータに記録された説明変数  $\mathbf{x}_k$  と被験者が選んだ選択肢  $a_k$  のタプルを表す。

### (2) MNL-GAUNet

線形回帰モデルは説明変数の重み付き線形和  $y = \sum_{i=1}^N \omega_i x_i$  であるのに対し、一般化加法モデルは非線形関数の重み付き和  $y = g^{-1} \left( \sum_{i=1}^N \omega_i f_i(x_i) \right)$  で表されるモデルである。  $g(\cdot)$  はリンク関数と呼ばれ、  $f_i(\cdot)$  として線形関数、  $g$  としてロジット関数を用いた場合、2 選択肢の多項ロジットモデルと等価なモデルとなる。本節では関数  $f_i$  としてニューラルネットワークを用い、それらの重み付き和により各選択肢の確定効用を表した多項ロジットモデル MNL-GAUNet (Multinomial Logit Model with Generalized Additive Utility Network) を説明する。

MNL-GAUNet の確定効用関数及び各選択肢の選択確率を下記のように定義する。

$$V_i(\mathbf{x}_i; \omega, \theta) = \omega_{i0} + \sum_{j \in \mathcal{S}_i} \omega_{ij} v_{ij}(x_{ij}; \theta_{ij}), \quad i \in \mathcal{A}, \quad (8)$$

$$P(i|\mathbf{x}; \omega, \theta) = \frac{\exp(V_i(\mathbf{x}_i; \omega, \theta))}{\sum_{i \in \mathcal{A}} \exp(V_i(\mathbf{x}_i; \omega, \theta))}, \quad i \in \mathcal{A}, \quad (9)$$

ここで、 $\omega_{i0}$  は選択肢  $i$  の固有定数、 $v_{ij}$  は選択肢  $i$  に関する説明変数  $x_{ij}$  のみに依存する確定効用関数を表し、 $\theta_{ij}$  および  $\omega_{ij}$  は  $v_{ij}$  のモデルパラメータとその重み係数

を表す。  $v_{ij}(x_{ij}; \theta_{ij})$  はバイアス方向に自由度があり  $\omega_{i0}$  は一意に決まらないため、実験では  $\min(v_{ij}(x_{ij}; \theta_{ij})) = 0, i \in \mathcal{A}, j \in \mathcal{S}_i$  とした。パラメータ  $\theta$  及び  $\omega$  は、データに対する対数尤度  $LL$  (式 (10)) と  $\omega$  の  $L_1$  ノルム (式 (12)) の重み付き和を最大化することにより算出する (式 (11))。

$$LL(D; \omega, \theta) = \sum_{(a_k, \mathbf{x}_k) \in D} \log P(a_k | \mathbf{x}_k; \omega, \theta), \quad (10)$$

$$\omega, \theta = \arg \max_{\omega, \theta} (LL(D; \omega, \theta) + \alpha L_1(D; \omega)), \quad (11)$$

$$L_1(D; \omega) = \sum_{i \in \mathcal{A}} \sum_{j \in \mathcal{S}_i} |\omega_{ij}|, \quad (12)$$

ここで、 $\alpha (\leq 0)$  はどの程度  $L_1$  ノルムを考慮するかの重みパラメータである。  $L_1$  ノルムを導入は  $\omega$  ベクトルをスパース化し、自動で説明変数を選択する効果がある。またこのモデルは、各説明変数の影響が互いに独立であるため、説明変数毎の平均効用 (以後、重要度) を下記式により算出できる。

$$\text{Imp}(x_{ij}; \omega, \theta) = \frac{\int_{\min(x_{ij})}^{\max(x_{ij})} \omega_{ij} v_{ij}(x_{ij}; \theta_{ij}) dx_{ij}}{(\max(x_{ij}) - \min(x_{ij}))}, \quad i \in \mathcal{A}, j \in \mathcal{S}_i, \quad (13)$$

実験で上記式を算出する際に、積分を直接計算することは難しいため、説明変数  $x_{ij}$  を  $[\min(x_{ij}), \max(x_{ij})]$  の範囲で離散化した値を用いて算出すればよい。MNL-GAUNet では、 $v_{ij}(x_{ij})$  をニューラルネットワークにより近似する。ニューラルネットワークとして 1 層 1 ノードのネットワークを用いた場合 MNL-GAUNet は、MNL-Linear と等価であり、MNL-Linear の一般化になっていることが分かる。

### (3) MNL-GAIUNet

MNL-GAUNet に交互作用項を追加した MNL-GAIUNet (Multinomial Logit Model with Generalized Additive and Interactive Utility Network) について説明する。MNL-GAIUNet では、確定効用関数として MNL-GAUNet の確定効用関数 (式 (11)) に 2 変数の交互作用項を追加した式 (14) を用い、選択肢  $i$  を選択する確率は式 (15) で表される。

$$V(\mathbf{x}_i; \omega, \omega^l, \theta, \theta^l) = \omega_{i0} + \sum_{j \in \mathcal{S}_i} \omega_{ij} v_{ij}(x_{ij}; \theta_{ij}) + \sum_{(j,k) \in \mathcal{S}_i^l} \omega_{ijk}^l v_{ijk}(x_{ij}, x_{ik}; \theta_{ijk}^l), \quad i \in \mathcal{A}, \quad (14)$$

$$P(i | \mathbf{x}; \omega, \omega^l, \theta, \theta^l) = \frac{\exp(V_i(\mathbf{x}_i; \omega, \omega^l, \theta, \theta^l))}{\sum_{i \in \mathcal{A}} \exp(V_i(\mathbf{x}_i; \omega, \omega^l, \theta, \theta^l))}, \quad i \in \mathcal{A}, \quad (15)$$

ここで、 $\omega^l$  および  $\theta^l$  は交互作用項の重み係数とモデルパラメータ、 $\mathcal{S}_2$  は交互作用を考慮する説明変数の組合せの集合である。

MNL-GAIUNet のパラメータは、GAMI-Net<sup>11)</sup> と同様に MNL-GAUNet の目的関数に交互作用項の自動選択のための項 (式 (18)) と学習される主効果と交互作用をできるだけ直交化するための項 (式 (19)) を加えた目的関数を最大化することにより求める (式 (17))。

$$LL(D; \omega, \omega^l, \theta, \theta^l) = \sum_{(a_k, \mathbf{x}_k) \in D} \log P(a_k | \mathbf{x}_k; \omega, \omega^l, \theta, \theta^l), \quad (16)$$

$$\omega, \omega^l, \theta, \theta^l = \arg \max_{\omega, \omega^l, \theta, \theta^l} (LL(D; \omega, \omega^l, \theta, \theta^l) + \alpha L_1(D; \omega) + \alpha^l L_1^l(D; \omega^l) + \beta^l \Omega(D; \omega, \omega^l, \theta, \theta^l)), \quad (17)$$

$$L_1^l(D; \omega^l) = \sum_{i \in \mathcal{A}} \sum_{(j,k) \in \mathcal{S}_i^l} |\omega_{ijk}^l|, \quad (18)$$

$$\Omega(D; \omega, \omega^l, \theta, \theta^l) = \sum_{x_i \in D} \frac{|\sum_{(j,k) \in \mathcal{S}_i^l} v_{ij}(x_{ij}; \theta_{ij}) v_{ijk}(x_{ij}, x_{ik}; \theta_{ijk}^l)|}{|\mathcal{S}_i^l|}, \quad (19)$$

ここで  $\alpha^l (\leq 0)$  および  $\beta^l (\leq 0)$  はそれぞれ負の重みパラメータである。交互作用項に関して、下記式により交互作用項毎の重要度を算出できる。

$$\text{Imp}(x_{ij}, x_{ik}; \omega, \theta) = \frac{\int_{\min(x_{ij})}^{\max(x_{ij})} \int_{\min(x_{ik})}^{\max(x_{ik})} \omega_{ijk}^l v_{ijk}(x_{ij}, x_{ik}; \theta_{ijk}^l) dx_{ij} dx_{ik}}{(\max(x_{ij}) - \min(x_{ij}))(\max(x_{ik}) - \min(x_{ik}))}, \quad i \in \mathcal{A}, (j, k) \in \mathcal{S}_i^l, \quad (20)$$

MNL-GAIUNet において、すべての交互作用項を考えると  $|\mathcal{S}_i| C_2$  の相互作用を考える必要があるが、考慮する交互作用項の数が増えるに従いモデルの学習時間が増大するという問題がある。そこで実験では、考慮する交互作用項の集合は、重要度が閾値以上の説明変数の組合せとした。

MNL-GAIUNet を学習する具体的な手順を Algorithm 1 に示す。まず、交互作用項を考えない MNL-GAUNet のパラメータを学習し (1-2 行目)、各説明変数の重要度に基づき考慮する交互作用項の集合を決定する (3-4 行目)。次に主効果のパラメータを MNL-GAUNet のパラメータに固定し、交互作用項のパラメータのみ学習する (5 行目)。最後に、主効果、交互作用項のパラメータを調整する (6 行目)。パラメータの学習を 3 段階 (主効果の学習、交互作用項の学習、両方の学習) に分けることは、収束を早め安定化させる効果がある。

**Algorithm 1** MNL-GAIUNet

- 
- 1:  $S_i \leftarrow \{1, \dots, M\}$
  - 2:  $\omega, \theta \leftarrow \arg \max_{\omega, \theta} (\text{LL}(D; \omega, \theta) + \alpha L_1(D; \omega))$
  - 3:  $\tilde{S}_i \leftarrow \{i | \text{Imp}(x_{ij}; \omega, \theta) \geq \text{Th}_{\text{importance}}\}$
  - 4:  $S_i^l \leftarrow \{(j, k) | j \in \tilde{S}_i, k \in \tilde{S}_i, j \neq k\}$
  - 5:  $\omega^l, \theta^l \leftarrow \arg \max_{\omega^l, \theta^l} (\text{LL}(D; \omega, \omega^l, \theta, \theta^l) + \alpha L_1(D; \omega) + \alpha^l L_1^l(D; \omega^l) + \beta^l \Omega(D; \omega, \omega^l, \theta, \theta^l))$
  - 6:  $\omega, \omega^l, \theta, \theta^l \leftarrow \arg \max_{\omega, \omega^l, \theta, \theta^l} (\text{LL}(D; \omega, \omega^l, \theta, \theta^l) + \alpha L_1(D; \omega) + \alpha^l L_1^l(D; \omega^l) + \beta^l \Omega(D; \omega, \omega^l, \theta, \theta^l))$
- 

表-1 SP 調査概要

調査期間	2022/02/15 ~ 2022/02/17
調査方法	ウェブスクリーニング調査
調査会社	楽天インサイト
サンプル数	1329 名

**3. 実験**

本節では、西ら<sup>15)</sup>によって実施された移動店舗に対する SP 調査をケーススタディとして提案手法を評価した結果について述べる。

**(1) SP 調査データの概要**

評価に用いた移動店舗に関する SP 調査データの概要について説明する。データは、2022/02/15~2022/02/17 の 3 日間に楽天インサイトにより収集された 1329 名の回答を用いた。居住地、交通手段、性別および年齢のどの項目においても大きな偏りがなく被験者を抽出した。分析する際には、回答者 1 名の回答に不備があったため分析から除去し、1328 名を対象とした(表 1)。

SP 調査では、3 業種(スーパー/飲食業/フィットネスジム)について 3 店舗形態(店舗/移動店舗/オンライン店舗)の利用に関して実験計画法に基づき文脈、料金、利用頻度、設備などサービス内容を変えた設問を作成し、1 名の回答者から各業種ごと 6 つの設問、計 18 問に対する選択結果回答を収集した。

スーパーに関して考慮した活動文脈と属性を、表 4 に示す。活動文脈は、現在地/購入品目/必要な時期の 3 種、店舗属性は、店舗までの距離/品揃え/利用時間帯/品揃えへの要望可否/駐車場有無の 5 種考慮した。また各属性の水準は、店舗スーパー、移動スーパー、ネットスーパーそれぞれで 1 から 3 水準設定した。飲食業およびフィットネスジムに関して考慮した活動文脈と属性を、表 5、表 6 に示す。活動文脈について、フィットネスジムは滞在場所と利用後の予定有無の 2 種、飲食業は利用時間帯など 3 種考慮した。一方、属性に関して

表-2 MNL-GAUNet 及び MNL-GAIUNet のパラメータ

パラメータ	値
$\alpha$	$-1.0 \times 10^{-3}$
$\alpha^l$	$-1.0 \times 10^{-3}$
$\beta^l$	$-1.0 \times 10^{-3}$
$\text{Th}_{\text{importance}}$	0.1
中間層数	2
各層のノード数	5
活性化関数	tanh

表-3 MNL-Linear と提案モデルの対数尤度の比較

	スーパー	飲食業	フィットネスジム
初期対数尤度	-5473	-5456	-5477
MNL-Linear	-4426	-4706	-4456
MNL-GAUNet	-4319	<b>-4590</b>	-4275
MNL-GAIUNet	<b>-4316</b>	<b>-4590</b>	<b>-4272</b>

は、フィットネスジムおよび飲食業ともに距離や料金など 6 種考慮した。

**(2) MNL-GAUNet/GAIUNet のパラメータ設定**

表 2 に両モデルのパラメータを示す。各説明変数および交互作用項のネットワークは、中間層が 2 層で各層ノードが 5 つ、活性化関数として tanh を用いた。また  $\alpha_1$ ,  $\alpha^l$ ,  $\beta^l$  は  $-1.0 \times 10^{-3}$  を設定した(表 2)。MNL-GAUNet 及び MNL-GAIUNet では、設定を単純化するために距離などに関して共通の説明変数を用意せず、各店舗形態ごとに説明変数を用意した。

**(3) 実験結果**

移動店舗に関する SP 調査を用いて、線形効用関数を仮定した多項ロジットモデル(MNL-Linear)と提案モデル(MNL-GAUNet および MNL-GAIUNet)の比較を行った。表 3 に対数尤度を比較した結果を示す。この結果から提案モデルを用いることにより、MNL-Linear に比べ対数尤度が大幅に向上するが分かった。しかしながら交互作用項を考慮する効果については、ジム及びスーパーの SP 調査データでは少し対数尤度は向上したが、それほど大きくないという結果となった。これは、SP 調査の水準を実験計画法に基づき設計することで、交互作用の影響が入りにくい設計となっていたことが原因であると考えられる。

次に MNL-Linear と MNL-GAIUNet の解釈性について、飲食業の嗜好性に関する SP 調査データを用いて比較を行う。MNL-Linear で推定した際のパラメータを表

表-4 スーパーの活動文脈と店舗属性

活動文脈/属性	移動スーパー	店舗スーパー	ネットスーパー
現在地 購入品目 必要な時期		自宅, 帰宅途中 生鮮食品・惣菜, 飲料・酒類, 日用品 当日, 翌日以降	
店舗までの距離 [km]	0.1, 0.5, 1.0	0.1, 1.0, 5.0	—
品揃え [品目]	400	2500, 3000, 6000, 10000 以上	6000
利用可能時間	利用者都合, 業者都合	9-21 時, 24 時間	—
品揃えへの要望可否	可, 不可	—	—
駐車場の有無	なし	あり, なし	—

表-5 飲食業の活動文脈と店舗属性

活動文脈/属性	フードトラック	飲食店	フードデリバリー
利用日 時間帯 利用人数		平日, 休日 12 時, 19 時 一人, 複数人	
店舗までの距離 [km]	0.1, 0.5, 1.0	0.1, 1.0, 5.0	—
平均価格 (昼食) [1000 円]	0.5, 1, 1.5	0.5, 1, 1.5	0.75, 1.5, 2
(夕食) [1000 円]	1, 3, 5	1, 3, 5	1.5, 4, 6
待ち時間 <sup>1</sup> [分]	1, 5, 15	10, 20, 30	15, 30, 60
着席場所の有無	なし, 公共ベンチ	あり	—
メニュー数	人気上位 3 種, 全 30 種	全 30 種	人気上位 3 種, 全 30 種
駐車場の有無	あり, なし	あり, なし	—

<sup>1</sup> 店舗訪問または注文から料理提供までの待ち時間

表-6 フィットネスジムの活動文脈と店舗属性

活動文脈/属性	移動ジム	店舗ジム	オンラインジム
現在地 利用後の予定		自宅, 外出中 あり, なし	
店舗までの距離 [km]	0.1, 0.5, 1.0	0.1, 1.0, 5.0	—
料金 (個別指導なし) [万円]	0.5, 0.7, 0.9	0.7, 1.0, 1.3	—
(個別指導あり) [万円]	1.0, 2.0, 3.0	1.5, 1.8, 2.1	0.5, 1.0, 1.5
利用回数制限 [回/週]	1, 2, ∞	1, 2, ∞	1, 2, ∞
プール・サウナ	なし	あり, なし	なし
利用可能時間	9-22 時, 24 時間	9-22 時, 24 時間	9-22 時, 24 時間
駐車場の有無	—	あり, なし	—

7に示す。表の FT はフードトラック, R はレストラン, FD はフードデリバリーを表しており, 単一パラメータに複数書かれているものについてはそれらでパラメータを共有していることを表している。表の\*\*は有意水準 99.5% および\*は 95%であったことを表す。

MNL-Linear で推定した結果から, フードトラック, レストラン, フードデリバリーの選好に関して下記のような様々なことが分かる。

- フードトラックは, 平日/一人/昼食時/メニューが全 30 種/公共交通の場合に選好されやすい。
- レストランは, 三大都市圏に居住している場合に選好されやすい。
- フードトラックやレストランは待ち時間が長くなる

ほど, フードデリバリーは短いほど選好されやすい。今回フードトラックとレストランの待ち時間や距離 (優位ではない) に関して, 短いほど選好されやすいという一般によく言われることと異なる結果が得られた。

MNL-Linear に対して MNL-GAUNet 及び MNL-GAIUNet を用いて推定した結果について説明する。各説明変数と交互作用項の重み係数  $\omega$ ,  $\omega^l$  が 0 より大きな値となった説明変数および交互作用項の重要度のヒストグラムを図 1 に示す。この図から, フードトラックの選好には待ち時間・価格・人数・年齢, レストランの選好には距離・人数・居住地・主な交通手段, フードデリバリーの選好には, 待ち時間・価格・時間帯が選択に大きく寄与していることが分かった。

表-7 飲食業について MNL-Linear により推定した結果 (FT はフードトラック, R はレストラン, FD はフードデリバリー, \*\*は有意水準 99.5% および\*は 95%.)

パラメータ	値	t 値
距離 [FT, R]	0.00286	0.153
価格 [FT, R, FD]	<b>-0.353</b>	<b>-19.9**</b>
待ち時間 [FT, R]	<b>0.0217</b>	<b>6.89**</b>
メニュー (全 30 種) [FT]	<b>0.131</b>	<b>2.44*</b>
主に公共交通を利用 [FT]	<b>0.136</b>	<b>2.73*</b>
女性 [FT, R]	<b>-0.190</b>	<b>-2.69*</b>
35 歳以下 [FT]	<b>-0.136</b>	<b>-2.47*</b>
昼食時 [FT]	<b>0.607</b>	<b>10.4**</b>
平日 [FT]	<b>0.235</b>	<b>4.09**</b>
一人 [FT]	<b>0.611</b>	<b>10.8**</b>
居住地 (三大都市圏) [R]	0.133	1.93
待ち時間 [FD]	<b>-0.00689</b>	<b>-3.52**</b>
メニュー (全 30 種) [FD]	0.0992	1.40
選択肢固有定数 (レストラン)	<b>1.16</b>	<b>10.9**</b>
選択肢固有定数 (デリバリー)	<b>1.12</b>	<b>9.50**</b>
初期対数尤度	-5456.455	
最終対数尤度	-4706.313	
修正済み尤度比	0.135	




図-1-a フードトラック




図-1-b レストラン




図-1-c フードデリバリー

図-1 各選択肢の重要度スコア

次にフードトラックの重要度が上位 3 位までの各説明変数の効用関数を図 2 に示す。フードトラックの待ち時間に関して MNL-Linear を用いた分析においても正のパラメータが推定されており, MNL-GAIUNet においても待ち時間が長い方が効用が大きくなるという結果となった (図 2-a)。ただし提案手法を用いた分析では, MNL-Linear の結果が示すような長ければ長いほど選好されやすいというのとは異なり, 0~5 分程の短い待ち時間が忌避され, 6~15 分の範囲はほぼ同程度に選好される傾向があることが明らかになった (図 2-a)。価格に関しても, 従来の MNL-Linear が示していたような安ければ安いほど選好されるという結果ではなく, 3000 円程度まではほぼ同程度選好され, それ以上高い価格は徐々に選好されにくくなるということが分かった。人数については, MNL-Linear と同様 1 人が選好されやすいという結果となった。

レストランについても同様に, 重要度が上位 3 位までの各説明変数の効用関数を図 3 に示す。図 3-a からレストランを選好するかは 3km(車で約 5 分)に閾値があることが明らかとなった。また人数, 居住地, 主な交通手段については, 図 3-b, 3-c より複数人/3 大都市圏在住/公共交通機関利用/がレストランを選好しやすくなるということが分かった。

最後に, フードデリバリーについても同様の分析を行った (図 4)。待ち時間および価格に関してフードデリバリーを選好するかどうかは, MNL-Linear の結果 (表 7) が示すような線形の関係ではなく, 40 分, 1000 円に閾

値があることが明らかとなった。またフードデリバリーを利用する時間帯や性別については, 夕食時・女性が選好しやすいことが分かった。

これらの結果から MNL-GAIUNet による分析は同程度選好される範囲や, 大きく選好が変化する閾値などについても明らかにすることができ, 従来の MNL-Linear による分析に比べより詳細な分析が行えることを明らかにした。これらの情報は, これまでの MNL-Linear を用いた SP 調査の分析では見逃されてきた部分であるが, 施策を考える上では非常に重要であると考えられる。また年齢のように非線形性が強いことがよく知られているものに関しては, 従来はあらかじめ階級別ダ




図-2-a 待ち時間




図-3-a 距離




図-2-b 価格




図-3-b 人数

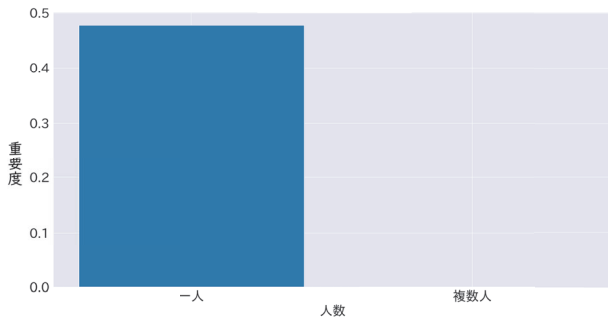


図-2-c 人数




図-3-c 居住地

図-2 フードトラックの選好に関する重要度上位 3 位までの説明変数の効用関数

図-3 レストランの選好に関する重要度上位 3 位までの説明変数の効用関数

ミー変数を導入することで対応していたため、その区分の仕方によって結果が変わる可能性があった。それに対して、MNL-GAIUNet では非線形な効用関数を直接推定することができるため、従来のような課題が発生しないことも提案法の利点の一つである。

#### 4. おわりに

本研究では、各選択肢の効用関数に 2 変数間の交互作用まで考慮した一般化加法ニューラルネットワークモデルを用いた多項ロジットモデル (MNL-GAIUNet; Multi-

nomial Logit Model based on Generalized Additive and Interactive Utility Network) を提案した。移動店舗に関する SP 調査データに提案手法を適用し、従来の線形効用を用いた多項ロジットモデルに比べ精度及び解釈性が高いことを示した。今後は提案手法を用いて移動店舗に対する施策効果の評価や交通手段選択に関する分析を行っていく予定である。

**謝辞：** 本研究は、東京大学 情報理工学系研究科 次世代知能科学研究センターと豊田中央研究所による社会連携研究部門「モビリティ知能社会デザイン」のプロ




図-4-a 待ち時間




図-4-b 価格




図-4-c 時間帯

図-4 フードデリバリの選好に関する重要度上位 3 位までの説明変数の効用関数

プロジェクトとして実施した。

参考文献

1) McFadden, D.: *Conditional logit analysis of qualitative choice behavior*, 1973.

2) 北村隆一, 森川高行, 佐々木邦明, 藤井聡, and 山本俊行: 交通行動の分析とモデリング, 技術堂出版, 2002.

3) van Cranenburgh, S., Wang, S., Vij, A., Pereira, F., and Walker, J.: Choice modelling in the age of machine learning-discussion paper, *Journal of Choice Modelling*, Vol.42, pp.100340, 2022.

4) Murphy, K. P.: *Machine learning: a probabilistic perspective*, MIT press, 2012.

5) Burkart, N. and Huber, M. F.: A survey on the explainability of supervised machine learning, *Journal of Artificial Intelligence Research*, Vol.70, pp.245–317, 2021.

6) Van der Maaten, L. and Hinton, G.: Visualizing data using t-sne., *Journal of machine learning research*, Vol.9, No.11, 2008.

7) Lundberg, S. M. and Lee, S.-I.: A unified approach to interpreting model predictions, *Advances in neural information processing systems*, Vol.30, 2017.

8) Ribeiro, M. T., Singh, S., and Guestrin, C.: ” why should i trust you?” explaining the predictions of any classifier, *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 1135–1144, 2016.

9) Lou, Y., Caruana, R., Gehrke, J., and Hooker, G.: Accurate intelligible models with pairwise interactions, *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 623–631, 2013.

10) Nori, H., Jenkins, S., Koch, P., and Caruana, R.: Interpretml: A unified framework for machine learning interpretability, *arXiv preprint arXiv:1909.09223*, 2019.

11) Yang, Z., Zhang, A., and Sudjianto, A.: Gami-net: An explainable neural network based on generalized additive models with structured interactions, *Pattern Recognition*, Vol.120, pp.108192, 2021.

12) Wang, S., Mo, B., and Zhao, J.: Deep neural networks for choice analysis: Architecture design with alternative-specific utility functions, *Transportation Research Part C: Emerging Technologies*, Vol.112, pp.234–251, 2020.

13) Sifringer, B., Lurkin, V., and Alahi, A.: Enhancing discrete choice models with representation learning, *Transportation Research Part B: Methodological*, Vol.140, pp.236–261, 2020.

14) Han, Y., Zegras, C., Pereira, F. C., and Ben-Akiva, M.: A neural-embedded choice model: Tastenet-mnl modeling taste heterogeneity with flexibility and interpretability, *arXiv preprint arXiv:2002.00922*, 2020.

15) 西智樹, 吉田広顕, 大社綾乃, and 原祐輔: 活動文脈を考慮した sp 調査に基づく移動販売店舗の選択要因分析, *土木計画学研究・講演集*, Vol.65, No.CD-ROM, 2022.

(Received 2023. 3. 6)

(Accepted 2023. 3. 6)

DISCRETE CHOICE MODELS BASED ON GENERALIZED ADDITIVE AND  
INTERACTIVE UTILITY NETWORK

Tomoki NISHI, Yusuke HARA