ReLU DNN のパラメータの二値化と表現能力

長瀬 准平 [1]
[1] 電気通信大学データ教育センター
e-mail : jnagase@uec.ac.jp

1　深層ニューラルネットワークモデルについて

深層学習は近年注目されている機械学習や人工知能技術の手法の一種であり，深層ニューラルネットワークモデル（以下，DNN）と呼ばれる大量の学習パラメータのあるモデルを大量のデータから同定（学習）するという特徴をもつ．深層ニューラルネットワークモデルは，多次元の入力ベクトル x に対し，層と呼ばれる線型変換（厳密にはアフィン変換）と非線型変換を繰り返すことにより構成される．線型変換を行う層は係数行列と切片ベクトルを学習パラメータにもち，期待される構造に応じて呼び名と制約が異なる．よく知られる層としては，全結合層（Fully-Connected Layer）や，畳み込み層（Convolutional Layer）などがあるが，本発表では最も制約のない全結合層を対象とする．全結合層はその名の通り，入力と出力が全て結合するように線型変換を行う層であり，特に制約のない任意の行列をパラメータとする．非線型変換を行う層は，一般に活性化層と呼ばれることが多く，モデル自体の出力や重み付けなどの特殊なものを除き，基本的に要素ごとの非線型変換を行うものが一般的である．近年では様々な非線型変換が活性化関数として提案されており，中でも ReLU 関数（Rectified Linear Unit）と呼ばれる区分的な線型関数；$\mathrm{ReLU(x)} := \max(x, 0)$ をベースとして，その派生の関数が広く用いられている．全結合層と活性化層を繰り返すことで構成されるフィードフォワードな DNN は多層パーセプトロンと呼ばれることが多い．本発表では活性化関数に ReLU 関数を仮定した多層パーセプトロンを対象とした結果を紹介する．

2　ReLU DNN の表現能力に関するこれまでの成果

DNN は学習パラメータをもつため，その学習パラメータを変化させることによる様々な関数を近似することが可能である．実際，十分に大きな数のパラメータをもつ DNN は任意の関数を任意の精度で近似することができるという万能近似定理がよく知られており，様々な条件設定での証明が示されている．万能近似性による DNN の各モデルの特徴付けは学習の収束性能などを調べることができる一方で，有限の学習パラメータを用いて実装されている現実のモデル同士の対応を明らかにするものではない．そこで，著者らはモデルの表現能力を次のように定義し，その包含関係によってモデルの比較を行った．

定義 1 (表現能力)**.** ある学習モデル M が学習パラメータ $\theta \in \Theta$ によって関数 f を定めるものとする．学習パラメータが $\tilde{\Theta} \subset \Theta$ の範囲内を動くとしたときに学習モデル M が取りうる関数の集合；

$$\mathcal{R}(M, \tilde{\Theta}) := \left\{ M(\theta) | \theta \in \tilde{\Theta} \right\}$$

を学習モデル M の $\tilde{\Theta}$ における表現能力と呼ぶ．また，ある関数 g について $g \in \mathcal{R}(M, \tilde{\Theta})$ が成り立つとき，g は M によって $\tilde{\Theta}$ において設計可能であるという．また，$\tilde{\Theta} = \Theta$ であるとき，$\mathcal{R}(M, \Theta)$ を単に学習モデル M の表現能力といい，g は M によって設計可能であるという．

ReLU DNN の表現能力について，著者らの次の結果が知られている．

定理 2 ([1])**.** ReLU 関数とアフィン関数の連結，加算，合成によって設計される任意の関数は多層パーセプトロンによって設計可能である．

定理 3 ([2])**.** $\mathbb{R}$ 上で定義される連続な区分線型関数のうち，少なくとも *2* つ以上の傾きの関数をもつ区間がある関数の集合を G とする．ある連続区分線型関数 $g \in G$ を活性化関数とした多層パーセプトロンおよび，ReLU 関数を活性化関数とした多層パーセプトロン MLP を

$$\mathrm{MLP}(\boldsymbol{x}; L, \theta, g) = \boldsymbol{g}\left(A_L \cdots \boldsymbol{g}\left(A_1 \boldsymbol{g}\left(A_0 \boldsymbol{x} + b_0\right) + b_1\right) \cdots + b_L\right)$$
$$\mathrm{MLP}(\boldsymbol{x}; L, \theta, \mathrm{ReLU}) = \boldsymbol{f}\left(A_L \cdots \boldsymbol{f}\left(A_1 \boldsymbol{f}\left(A_0 \boldsymbol{x} + b_0\right) + b_1\right) \cdots + b_L\right)$$

とする．ただし，$\boldsymbol{g}$ は要素ごとに変換 g を適用する関数，$\boldsymbol{f}$ は要素ごとに ReLU 関数を適用する関数である．このとき，$\mathrm{MLP}(\boldsymbol{x}; L, \theta, g)$ と $\mathrm{MLP}(\boldsymbol{x}; L, \theta, \mathrm{ReLU})$ は互いに設計可能である．

また，このようにして得られた ReLU 関数とアフィン関数を繰り返して多層化することによって ReLU 多層パーセプトロンが構成できるため，区分線形関数を活性化関数にもつ多層パーセプトロンは ReLU 多層パーセプトロンを構成でき，ReLU 関数とアフィン関数の連結と合成と加算によって設計される任意の関数を構成することもできる．

3 ReLU DNN の二値化

前節で紹介した結果は特にパラメータに制約のない一般的な結果であるが，広い DNN の表現能力に関する対応関係を示すものである．そこで本発表では，アフィン関数のパラメータを $-1, 1$ の二値に制約した場合の DNN と一般の DNN の対応関係として次の定理を示す．簡単のため，線型変換 3 層と ReLU 関数 2 層の合成を考える（任意の層数のアフィン変換への一般化も可能である）．

定理 4. $\mathrm{ReLU}_{[N]}$ は N 次元に ReLU 関数を適用する関数，$\mathbb{B} = \{-1, 1\}$ とする．任意のパラメータ $A_0 \in \mathbb{R}^{m\times n}$, $A_1 \in \mathbb{R}^{l\times m}$, $A_2 \in \mathbb{R}^{k\times l}$ と任意の入力 $\boldsymbol{x}$ について，

$$A_2 \mathrm{ReLU}_{[l]}\left(A_1 \mathrm{ReLU}_{[m]}\left(A_0 \boldsymbol{x}\right)\right) = B_2 \mathrm{ReLU}_{[kl]}\left(B_1 \mathrm{ReLU}_{[klm]}\left(A^* \boldsymbol{x}\right)\right)$$

をみたす $A^* \in \mathbb{R}^{klm\times n}$, $B_1 \in \mathbb{B}^{kl\times klm}$, $B_2 \in \mathbb{B}^{k\times kl}$ が存在する．

すなわち，十分なパラメータ数を持つ二値パラメータの ReLU 多層パーセプトロンは入力に適切な線型変換を施すことで実数パラメータの ReLU 多層パーセプトロンを設計可能であり，逆に，任意の ReLU 多層パーセプトロンは全体のパラメータ数を $\frac{klmn}{kl+lm+mn}$ 倍した線型変換を用いることで，$kl^2 + k^2l^2m$ 個の二値パラメータをもつ多層パーセプトロンに帰着できる．また，本定理の証明は構成的であり，パラメータを具体的に書き下すことができる．発表では，証明の概略として，ReLU 関数の特徴的な性質によってこの定理が導かれることと，その他の活性化関数の場合への一般化について議論し，実際の DNN のパラメータを二値化する手順と応用可能性について議論する．

参考文献

[1] Jumpei Nagase. Mathematical analysis of finite parameter deep neural network models with skip connections from the viewpoint of representation sets. *Japan Journal of Industrial and Applied Mathematics*, Sep 2022.

[2] 長瀬准平, 石渡哲哉. 連続区分線型関数を活性化関数にもつ深層ニューラルネットワークモデルの等価性. 2022 年度秋季総合分科会. 一般社団法人 日本数学会, 2022.

同時群同変モデルの統一的かつ構成的な普遍近似定理

園田 翔 [1], 橋本 悠香 [2,1], 石川 勲 [3,1], 池田 正弘 [1]
[1] 理化学研究所, [2] 日本電信電話株式会社, [3] 愛媛大
e-mail : sho.sonoda@riken.jp

1 概要

群表現論に基づいて，同時群同変な学習モデルに対して統一的かつ構成的な普遍近似定理を示す．構成的とは，パラメータの分布が閉形式（リッジレット変換）で与えられることを指す．同時群同変モデルは非常に広いクラスである．これまで，深い学習モデルの表現力はケースバイケースで解析されてきたが，本研究により包括的に扱えるようになった．重要な具体例として，浅い全結合ニューラルネットや深い全結合ニューラルネット，群同変ネットワークなどを含む（[1] 参照).

2 主結果

G を局所コンパクト群，X, Y, Ξ を集合，$\mathcal{H}$ を可分 Hilbert 空間とする．X, Y, Ξ にはそれぞれ G が作用しているとする．また $\mathcal{H}$ は G のユニタリ表現とする．また X, Ξ への G-作用は推移的とし，G の左不変測度 $\mathrm{d}g$ を X, Ξ に誘導したものをそれぞれ $\mathrm{d}x, \mathrm{d}\xi$ と書く．

2.1 同時群同変特徴量

入力空間 X とパラメータ空間 Ξ から出力空間 Y への写像 $\phi : X \times \Xi \to Y$ を特徴量写像と呼ぶ．

定義 1 特徴量写像 $\phi : X \times \Xi \to Y$ が次の条件を満たすとき，同時群同変 (joint group equivariant) であるという．

$$\phi(g \cdot x, g \cdot \xi) = g \cdot \phi(x, \xi), \quad \text{for all } (x, \xi) \in X \times \Xi,\ g \in G. \tag{1}$$

同時群同変性は，幾何学的深層学習で用いられる群同変ネットワークの条件を一般化したものである．つまり，パラメータへの作用が自明な場合（$g \cdot \xi = \xi$）に，同時群同変性は通常の群同変性（$\phi(g \cdot x, \xi) = g \cdot \phi(x)$）に帰着する．2 つの同時群同変写像 $\phi_2 : X_2 \times \Xi_2 \to Y, \phi_1 : X_1 \times \Xi_1 \to X_2$ の合成写像 $\phi_2(\phi_1(\bullet, \bullet), \bullet) : X_1 \times (\Xi_1 \times \Xi_2) \to Y$ は再び同時群同変であり，深層ニューラルネットのように合成写像を含む特徴量写像の解析において有用な性質である．

2.2 同時群同変ネットワーク

定義 2 $\mathcal{H}$ に値をとる同時群同変特徴量 $\phi, \psi : X \times \Xi \to \mathcal{H}$ を固定する．$\gamma : \Xi \to \mathbb{R}$ をパラメータ分布とする同時群同変ネットワーク $\mathtt{NN}$ と，ベクトル値関数 $f : X \to \mathcal{H}$ のリッジレット変換をそれぞれ次のように定義する

$$\mathtt{NN}_\phi[\gamma](x) := \int_\Xi \gamma(\xi)\phi(x, \xi)\mathrm{d}\xi, \quad x \in X, \qquad \mathtt{R}_\psi[f](\xi) := \int_X \langle f(x), \psi(x, \xi)\rangle_{\mathcal{H}} \mathrm{d}x, \quad \xi \in \Xi.$$

ただし $\mathtt{NN}$ の積分は Bochner 積分（ベクトル値関数の成分毎の積分）である．$\mathtt{NN}$ は可能な特徴量 $\{\phi(\bullet, \xi) \mid \xi \in \Xi\}$ を全て γ によって重み付けて総和した混合モデルである．特徴量として特にニューラルネットをとると，無限幅のニューラルネットが得られるため，「ネットワーク」と呼んでいる．

2.3 誘導表現

ベクトル値二乗可積分関数 $f \in L^2(X;\mathcal{H})$ に対し，G の誘導表現 π を $\pi_g[f](x) := g \cdot f(g^{-1} \cdot x)$ とおく．π はユニタリ表現である．表現 π が既約（irreducible）であるとは，π-不変部分空間（$\pi W \subset W$ となる部分空間 $W \subset L^2(X;\mathcal{H})$）が自明なもの（零空間と全空間）に限ることをいう．

2.4 主定理（再構成公式）

定理 3 誘導表現 π は既約とする．このとき ϕ, ψ の双線形形式 $(\!(\phi, \psi)\!)$ が存在して，任意のベクトル値二乗可積分関数 $f \in L^2(X;\mathcal{H})$ に対して以下が成り立つ

$$\mathtt{NN}_\phi \circ \mathtt{R}_\psi[f] = \int_\Xi \mathtt{R}_\psi[f](\xi)\phi(\bullet, \xi)\mathrm{d}\xi = (\!(\phi, \psi)\!) f. \tag{2}$$

つまり，$(\!(\phi, \psi)\!) \neq 0$ のとき，リッジレット変換 $\mathtt{R}[f]$ を重み関数とするニューラルネット $\mathtt{NN} \circ \mathtt{R}[f]$ はベクトル値関数 f を再生することを現わしている．f の選び方は任意だったので，これは $\mathtt{NN}$ が任意のベクトル値二乗可積分を表現できることを意味している．積分を有限和近似することで，L^2-普遍近似定理の構成的証明が得られる．

具体例は参考文献 [1] 参照．主定理は深層ニューラルネットを含む広いクラスの学習機械を包括する．入力空間 X は多様体とは限らず，言語のような離散的なデータに対しても成り立つ．定理の一般性にも関わらず，証明も簡潔である．証明は誘導測度 $\mathrm{d}x, \mathrm{d}\xi$ の群不変性，特徴量 ϕ, ψ の同時群同変性，および Schur の補題を用いる．

定理 4（Schur の補題） G の $\mathcal{H}$ 上のユニタリ表現 π が既約であることは，次の条件と同値: π と可換な有界作用素 $T : \mathcal{H} \to \mathcal{H}$ は恒等作用素の定数倍に限る．

証明 $T := \mathtt{NN} \circ \mathtt{R} : L^2(X;\mathcal{H}) \to L^2(X;\mathcal{H})$ が G と交換することを直接計算によって示す．任意の $g \in G$ に対し，

$$\mathtt{R}[\pi_g[f]](\xi) = \int_X \langle g \cdot f(g^{-1} \cdot x), \psi(x, \xi)\rangle_{\mathcal{H}} \mathrm{d}x = \int_X \langle f(x), \psi(x, g^{-1} \cdot \xi)\rangle_{\mathcal{H}} \mathrm{d}x = \widehat{\pi}_g[\mathtt{R}_\psi[f]](\xi),$$

$$\mathtt{NN}[\widehat{\pi}_g[\gamma]](x) = \int_\Xi \gamma(g^{-1} \cdot \xi)\phi(x, \xi)\mathrm{d}\xi = \int_\Xi \gamma(\xi)\left(g \cdot \phi(g^{-1} \cdot x, \xi)\right)\mathrm{d}\xi = \pi_g[\mathtt{NN}_\phi[\gamma]](x).$$

つまり $\mathtt{NN} \circ \mathtt{R} \circ \pi_g = \mathtt{NN} \circ \widehat{\pi}_g \circ \mathtt{R} = \pi_g \circ \mathtt{NN} \circ \mathtt{R}$ が成り立つ．よって Schur の補題によりある定数 $c_{\phi,\psi} \in \mathbb{C}$ が存在し，$\mathtt{NN}_\phi \circ \mathtt{R}_\psi = c_{\phi,\psi} \, \mathrm{Id}_{L^2(X;\mathcal{H})}$．作り方から $c_{\phi,\psi}$ は双線形形式である．

謝辞 本研究は JSPS 科研費 20K03657, JST さきがけ JPMJPR2125, JST CREST JPMJCR2015・JPMJCR1913, および JST ACTX JPMJAX2004 の助成を受けたものです．

参考文献

[1] S. Sonoda, Y. Hashimoto, I. Ishikawa, M. Ikeda, "Constructive Universal Approximation Theorems for Deep Joint-Equivariant Networks by Schur's Lemma", arXiv preprint: 2405.13682, (2024).

ファッションの解釈性向上のための機械学習モデルの検討

斎藤 侑輝 [1]
[1]ZOZO Research
e-mail : yuki.saito@zozo.com

1　概要

電子商取引（EC）サービスにおいてはユーザーの購買行動を支援するため，アイテムの素性や使用される認識モデルの解釈性を向上させることが課題となる．本発表ではファッション EC を題材として，画像データとタグのペアを用いた潜在的表現獲得の方法論や，集合関数のための一貫性のある寄与率推定に関する研究などに言及し，近年の解釈性向上のための研究の進展について報告する．

2　はじめに

インターネット上でファッションアイテムを販売する EC サイトの興隆を始めとして，近年におけるファッションの商業的発展は目覚ましいものがある．日本のファッション EC サイトの一つである ZOZOTOWN [1] においては常時 95 万点以上の取り扱い商品情報や，1,100 万人を超える年間購入者の購買データなどが蓄積され，ビッグデータの波が押し寄せている．その他にも，ファッションコーディネート（コーデ）写真を共有する SNS である WEAR [2] においては 1,300 万件以上のコーデが投稿され，アイテム単体だけではなく流行に応じた服の組み合わせに関する情報が多量に取得可能な状況にある．このように，購買や消費の観点からファッションを統計科学的に検証可能なデータ基盤が整いつつある．こうしたファッションデータ基盤を利用して，コーデをアイテムの集合であると考えることで，コーデの調和性を判定する集合マッチングモデル [3] や，コーデの集合を階層的に認識するモデル [4] の検討が行われてきた．

一方で，ファッションは **似合う** や **可愛い** といった人間の感性に根差す概念を含むものであり，一般的なコンセンサスが得られやすい画像認識タスク（一般物体認識など）が扱う対象に比べて，一般消費者が理解するには困難がつきまとう．そこで本稿では，コーデそのものや認識処理結果の解釈性を向上させるための研究として，画像とタグのペアを用いた潜在的表現獲得の方法論 [5] や，集合関数のための一貫性のある寄与率推定手法に関する研究 [6] の進展について報告する．

3　Fashion Intelligence System: 画像とタグのペアによる潜在的表現獲得

本研究が対象とするデータセットは，複数のタグが付与された全身服装画像によって構成される．また，タグの中には，“ジーンズ”，“T シャツ”，“ホワイト” といった具体的な表現だけでなく，“カジュアル”，“オフィスカジュアル”，“ フォーマル” といった曖昧な表現が多く含まれる．そこで，畳み込みニューラルネットワークなどのバックボーンモデルとグリッド重みマップに基づく変換によって，各画像とタグを同一射影空間に写像するようなニューラルネットワークモデルを構築し，学習を行う（図 1）．この射影空間における画像とタグの表現の位置座標 (埋め込み表現) を活用することで，ユーザからの曖昧で難度の高い様々な問いに対する回答を獲得できることが確認された．

4　一貫性制約を満たす集合関数の局所説明法

本研究では，集合関数の説明可能性を向上させる汎用的なアプローチとして，集合関数がブラックボックスな場合であっても個々の予測を説明できる，モデル非依存の説明法を用いる．集合関数に

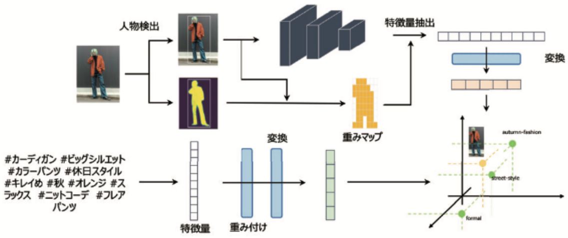

図 1. Fashion Intelligence System

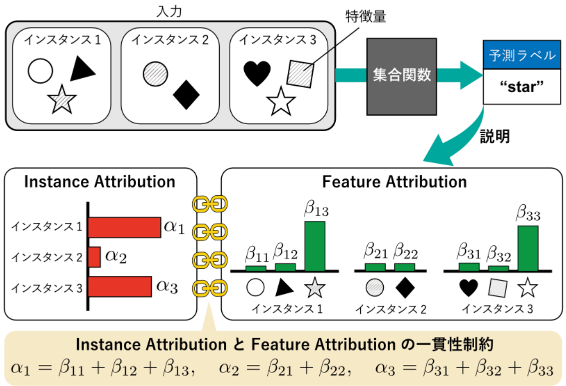

図 2. 一貫性制約を満たす集合関数の局所説明法

対しては，Instance Attribution (IA) と Feature Attribution (FA) の異なるレベルの 2 種類の説明が考えられる (図 2). IA は集合の各インスタンスが集合関数の予測にどのように寄与するかを表し，FA はインスタンスの各特徴が予測にどのように寄与するかを表す. 例えば画像分類では，IA はラベルの予測にどの画像（インスタンス）が寄与しているかを明らかにするのに役立ち，FA は各画像のどの領域（特徴）が予測に強く寄与しているかを明らかにできる. このとき，IA と FA の一貫性を満たすような説明を得ることが課題となる.

本研究により，例えばアイテム集合としてのコーデの認識処理において，どのアイテムや画像領域がコーデの認識において重要であったかを説明することが期待できる.

5 おわりに

ファッションコーデや認識処理結果の解釈性を向上させる方法として Fashion Intelligence System および一貫性制約を満たす集合関数の局所説明法について触れた．今後はさらに解釈性を向上させるため，画像やタグ以外の要素を取り入れた研究について取り組む予定である.

参考文献

[1] ZOZOTOWN, `https://zozo.jp/`.

[2] WEAR, `https://wear.jp/`.

[3] Y. Saito, T. Nakamura, H. Hachiya and K. Fukumizu, Exchangeable Deep Neural Networks for Set-to-Set Matching and Learning, European Conference on Computer Vision, 2020, 626–646.

[4] 長瀬 准平, 斎藤 侑輝, 石渡 哲哉, ファッション推薦問題に向けた階層的集合マッチングモデルの検討, MIRU, 2022.

[5] R. Shimizu, Y. Saito, M. Matsutani, and M. Goto, Fashion intelligence system: An outfit interpretation utilizing images and rich abstract tags, Expert Systems with Applications, 2022.

[6] 吉川 友也, 木村 正成, 清水 良太郎, 斎藤 侑輝, Instance Attribution と Feature Attribution の一貫性制約を満たす集合関数の局所説明法, 2024 年度人工知能学会全国大会（第 38 回）, 2024.

グルメサービス Retty の推薦システム開発プロジェクトの事例紹介

岩永 二郎 [1,2]
[1] 株式会社エルデシュ，[2] 電気通信大学
e-mail : iwanaga@erdos-the-book.com

1　はじめに

推薦システムの研究には, 内容ベース推薦システム, 協調フィルタリング推薦システム, 知識ベース推薦システム [1] などの従来の推薦手法に加え, 機械学習を用いた手法や数理最適化を用いた手法 [2, 3] がある．これらの推薦アルゴリズムをサービスに実装するためにはいくつもの課題を解決する必要があり, 一般的にチームを組んでプロジェクトを立ち上げる．例えば, EC(Electronic Commerce) サイト上でユーザーが商品を推薦するシステムを実装する場合には, ユーザーが商品探索に対してどのような不満があるかを分析した上で, 課題解決の手段として推薦システムの実装を企画する．推薦システムの設計には, 課題解決に繋がる UI/UX[4] の検討に加え, 取得可能なデータの制約がある．さらに推薦アルゴリズムの実装については, システムの開発を行う開発環境と実際にサービスをユーザーに提供する本番環境それぞれにおいて制約を受ける。これらの制約に加えて、実装者の技術力に依存するため, パフォーマンス、スケーラビリティ、安全性などのさまざまな要因を考慮し、最適な設計と実装を行う必要がある．また, 企画した複数の推薦アルゴリズムから最良のアルゴリズムを絞り込むため, 実験と評価を繰り返し, 科学的にプロジェクトを推進することが重要である．本発表は, 推薦アルゴリズムを社会実装するに当たって必要な考え方をプロジェクトの紹介を通して解説するのが目的である．

2　対象サービスとプロジェクトの構成

本発表では, Retty 株式会社が運営する実名型グルメサービス Retty[5] におけるレストラン推薦システムの開発プロジェクトについて紹介する．Retty の Web ページは, 主にトップページ, お店リストページ, お店詳細ページから構成されており, 本発表ではお店詳細ページに推薦システムを実装した事例を解説する．推薦システムのコンセプトは、ユーザーがお店詳細ページで、特定のお店に対して「ちょっと違うな」と感じているときに, 気の利いたお店を推薦することである。

プロジェクトは 2017 年 11 月から 2018 年 7 月にかけて 3 つのフェーズに分けて推進した．フェーズ 1 では推薦ロジックの設計と実装を行った．具体的には類似店舗推薦, 人気店推薦, 協調フィルタリング推薦, ランダム推薦を実装し, オフラインによる定性評価を経てサービスに実装され, CTR(Click Through Rate) による定量評価を行なった．フェーズ 2 ではデザインの改善を行った．推薦時の UI/UX に着目し, 情報の取捨選択, 推薦理由の付与を行い, CTR による定量評価を行なった．フェーズ 3 では配信最適化を行った．具体的には、Elastic Net 回帰を用いて各店舗と各推薦アルゴリズムに対する CTR を予測し, バンディットアルゴリズムを用いて配信割合を最適化し, CTR による定量評価を行なった．

3　フェーズ 1 における推薦ロジックの設計

本章では、以下の 3 つの推薦ロジックの紹介をする．

類似店舗の推薦では, ユーザー視点でお店間の類似度を定量化する必要がある. スマートフォンを利用して現地でお店を探している場合, 閲覧しているお店と「カテゴリ」や「利用シーン」が一致しているお店ほど、ユーザーは似ていると感じる. また, 「価格帯」や 「距離」も近いほどユーザーの需要に近いと考えられる. それぞれの観点で類似度を個別に定義し, その重み付き線形和をお店間の類似度としてお店の推薦に利用した.

人気店舗の推薦には, PageRank[6] アルゴリズムを利用した. Retty の投稿から得られるレイティングは Excellent, Good, Average の 3 種類であり, Average をつけるユーザーが少ないのが特徴的で欠損のメカニズムに注意する必要がある. また, ユーザーがお店にかける金額の違いや評価の個人差が大きいため、単純な平均点で人気度を表現すると、有識者の直感と異なり、ユーザーに受け入れられないことが定性評価からわかっている. そこで, 各ユーザーが投稿したお店の 3 種類の評価を利用してお店間の選好グラフを作成する. 例えば, Good と評価したお店から Excellent と評価したお店に向けて選好関係を表すエッジをはることができる. そして, 対象地域の全てのお店から選好グラフを作成し, その PageRank を計算することでお店の人気度を算出し、お店の推薦に利用した.

協調フィルタリング推薦では, 評価値行列を非負値行列分解する方法と評価値行列のコサイン類似度を計算する 2 つの方法を実装した。一般的に精度が高いとされる非負値行列分解は意外性 (Serendipity) が強すぎたため納得性に欠けるという定性評価を受けた。その結果、評価値行列からコサイン類似度を計算する方法を採用してお店の推薦をすることとなった.

4　おわりに

本稿では, フェーズ 1 における推薦ロジックの設計部分について紹介した. 当日はフェーズ 1 の推薦ロジックの評価結果に加え, アーキテクチャやワークフローについても紹介する。また、フェーズ 2, フェーズ 3 についての解説も行う。

謝辞　本研究の遂行にあたり, Retty 株式会社在籍時に得られた経験と知識を公開することに関して, 同社から許可、および多大な支援を受けたことに感謝の意を表します.

参考文献

[1] 奥健太, 基礎から学ぶ推薦システム―情報技術で嗜好を予測する, コロナ社, 2022.

[2] J. Iwanaga, N. Nishimura, N. Sukegawa and Y. Takano, Estimating Product-choice Probabilities from Recency and Frequency of Page Views, Knowledge-Based Systems, Vol.99(2016),pp. 157–167.

[3] J. Iwanaga, N. Nishimura, N. Sukegawa and Y. Takano, Improving Collaborative Filtering Recommendations by Estimating User Preferences from Clickstream Data, Electronic Commerce Research and Applications, Vol.37(2019), pp. 100877.

[4] 風間正弘, 飯塚洸二郎, 松村優也, 推薦システム実践入門―仕事で使える導入ガイド, オライリージャパン, 2022.

[5] Retty Web Page, `https://retty.me/`.

[6] Amy N.Langville, Carl D.Meyer, 岩野和生 (翻訳), 黒川利明 (翻訳), 黒川洋 (翻訳), Google PageRank の数理 ―最強検索エンジンのランキング手法を求めて, 共立出版, 2009