

ユーザ行動の時系列予測モデルを利用したレコメンドエンジンの開発

サービスイノベーション部
 伊藤 拓 佐々木 祐理
 田中 茂樹

近年、WebにおけるBtoCサービスにおいて商品・コンテンツのレコメンド機能の提供が主流となっている。レコメンドエンジンはさまざまな種類があるが、多くは人気ランキングに基づいたものであり、これらはユーザのサービス利用の文脈を正しく理解できていなかった。ユーザの興味を惹くレコメンドを提示するためには、レコメンドエンジンがユーザ文脈を理解し、次に興味をもつコンテンツを予測する必要がある。そこでドコモでは、購買してもらう確率を上げることを目的に、行動を時系列で解釈して予測を行う深層学習アルゴリズムを活用したレコメンドエンジンを開発し、社内サービスに適用した。これにより、高精度なレコメンド提供が可能となった。

1. まえがき

近年、EC (Electronic Commerce) サービス^{*1}や動画配信などのBtoC (Business to Consumer) サービスでは、商品のレコメンド^{*2}を行うことが主流となっている。ドコモサービスの多くについても、「ユーザへのおすすめ」としてレコメンド機能が提供されている。レコメンド手法においては、人気ラン

キングを基にした単純な手法から、機械学習^{*3}を用いた手法まで幅広く提案されており、特にここ数年では市中で簡便に利用できる機械学習ライブラリ^{*4}が配布されているほか、クラウドサービス^{*5}を用いたレコメンドサービスが提供され始めている。

レコメンド機能は数年前より提供されているが、既存では、人気ランキング^{*6}をベースとしたレコメンドが多く行われていた。人気ランキングベースは、

©2022 NTT DOCOMO, INC.

本誌掲載記事の無断転載を禁じます。

本誌に掲載されている社名、製品およびソフトウェア、サービスなどの名称は、各社の商標または登録商標。

*1 ECサービス：ネットを通じて物の売買を行うサービスのこと。

*2 レコメンド：ユーザに合わせて、商品やコンテンツを推薦すること。

*3 機械学習：入力されたデータを基にパターンを学習し、何らかのタスクを実行するコンピュータアルゴリズムのこと。

大多数のユーザの嗜好を捉えているため一定のクリック率を稼げるが、異なるユーザ間で同一の商品がレコメンドされるため、人気コンテンツを好まないユーザには響かず、加えて出ているコンテンツが固定化されるため、他の多くの商品はレコメンドされず、ユーザが新しい商品を発見しにくいという課題があった。また、ユーザは通常、一連のWeb回遊の中で欲しい商品をクリックするという手順を踏むため、レコメンドサービスにおいては、趣味嗜好よりも直前にどのようなコンテンツをクリックしたかという時系列のデータが重要になる。例えば、ポータルサイトで食料品を探しているユーザには、普段の趣味嗜好に関わらず、Web回遊をしている場面では食料品が提示されることが望ましい。生鮮食品を直前にクリックしているユーザには、続けて生鮮食品を提示することでユーザ所望のコンテンツを推薦することができるようになる。

そこでドコモでは、時系列予測のアルゴリズムであるRNN (Recurrent Neural Network) をレコメンドに適用し、ユーザの長期・短期での興味の推移を

捉えることを可能とした。本技術では、直近の興味のあるジャンルを主にレコメンドするほか、定常的に興味があるジャンルも共にレコメンドすることで、パーソナライズしつつ状況に合わせたレコメンドの提示が可能となり、クリック率向上に寄与した。本稿では、実際に適用したレコメンドアルゴリズムとサービスでの効果検証について解説する。

2. RNNのレコメンドへの活用

2.1 RNN概要

RNNは、再帰型ニューラルネットワーク^{*7}と呼ばれ、時系列データ^{*8}などの連続的なデータのパターンを認識するように設計されたニューラルネットワークのモデルである [1]。従来の一般的なニューラルネットワークモデルでは、固定長の入力層、出力層とその間に中間層が与えられる (図1)。例えば画像認識タスクでは、実際の画像を画素単位で分割し、画素値を入力層として与え、出力層では分類対象のカテゴリを出力する。この場合、入力層

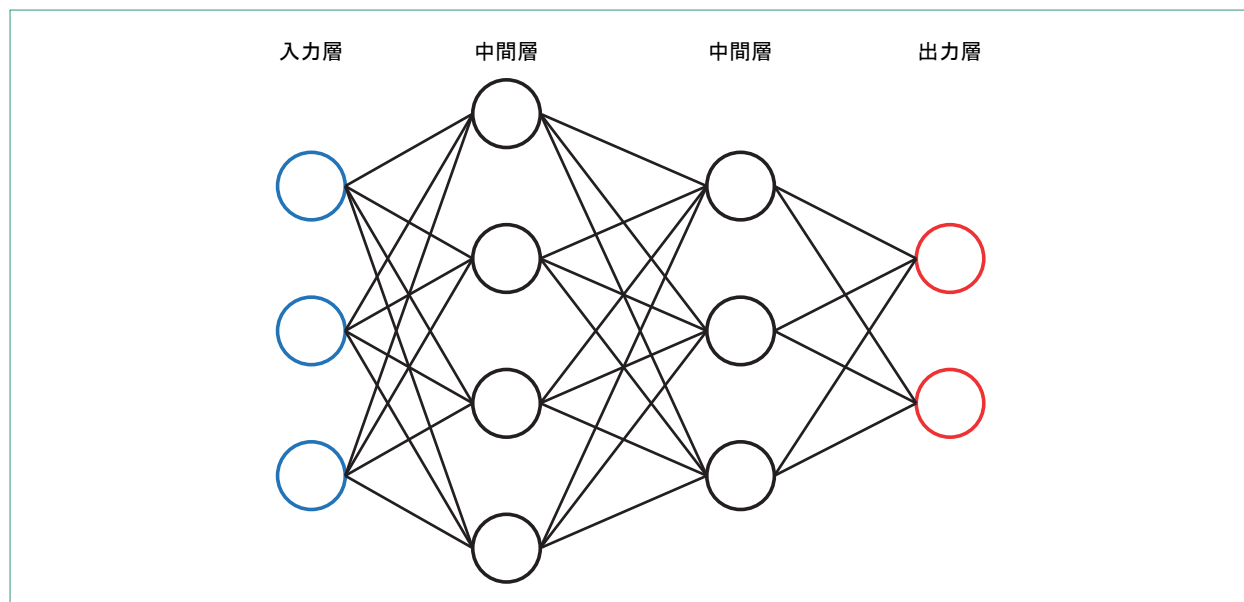


図1 一般的なニューラルネットワーク

*4 ライブラリ：汎用性の高い複数のプログラムを、再利用可能な形でひとまとまりにしたもの。
 *5 クラウドサービス：利用者の手元にあるコンピュータ上ではなく、遠隔のサーバ上で動いているサービスをネットワーク経由で利用者に提供するもの。
 *6 ランキング：サービス全体でクリック・購買が多い順に商品・

コンテンツを並べたもの。最も基本的なレコメンドアルゴリズムの1つ。
 *7 ニューラルネットワーク：人間の脳内の神経回路網を数式モデルで表したもの。入力層、中間層、出力層から構成される。
 *8 時系列データ：値が時間的に変化した情報をもつデータのこと。

は画素数、出力層は分類パターン数となり、それぞれ1つの値となるため、各ノード^{*9}は固定長として与える必要がある。

一方で、現実のデータは必ずしも固定長で与えられるわけではない。例えば、文書予測などのタスクの場合、入力としては文章が与えられることになるが、画像のような固定長でないため、上記のようなモデルでは表現することができない。そこで、可変長のデータを取り扱えるように改良されたモデルがRNNである。RNNでは、可変長データの各地点を時系列として扱い、内部（中間層）に状態という変数を保持する（図2）。入力データに応じて状態が変化していき、その状態が次の時系列ステップに伝搬していく。そして、状態に応じた値が出力層に提示される。このように、状態が時系列で伝搬していくというモデルとすることで、可変長データを入力とする対象に対してニューラルネットワークを適用することができる。

2.2 RNNのレコメンドへの適用

上記RNNは、文章認識^{*10}や機械翻訳^{*11}などの文

章をターゲットとするタスク、および音声認識などの音声をターゲットとするタスクに利用されることが多い。与えられた入力値に対してどのような出力値が与えられるべきか、というデータをネットワークに学習させることで、新しい文章・音声に対して所望の出力値を得ることができる。このような特性から、RNNは時系列予測にも用いることができる。入力と出力の値を同一にして学習させることで、特定の入力を与えられたとき、次にどのような値が来るかを予測させるモデルを構築することができる [2]。

近年では、RNNの時系列予測タスクをレコメンドに適用する事例が増えている。1つ当りの入力値を商品クリック・動画視聴といったユーザ行動として定義し、出力値を同様にユーザ行動として与えることで、ある商品・動画に興味をもったユーザが、次にどのような商品・動画に興味をもつのかユーザの興味（状態）の遷移を予測することができる（図3）。加えて、その時のユーザ状態に合わせたレコメンドが可能となるため、最新のユーザ行動をモデルに入力することにより、常に最新化された

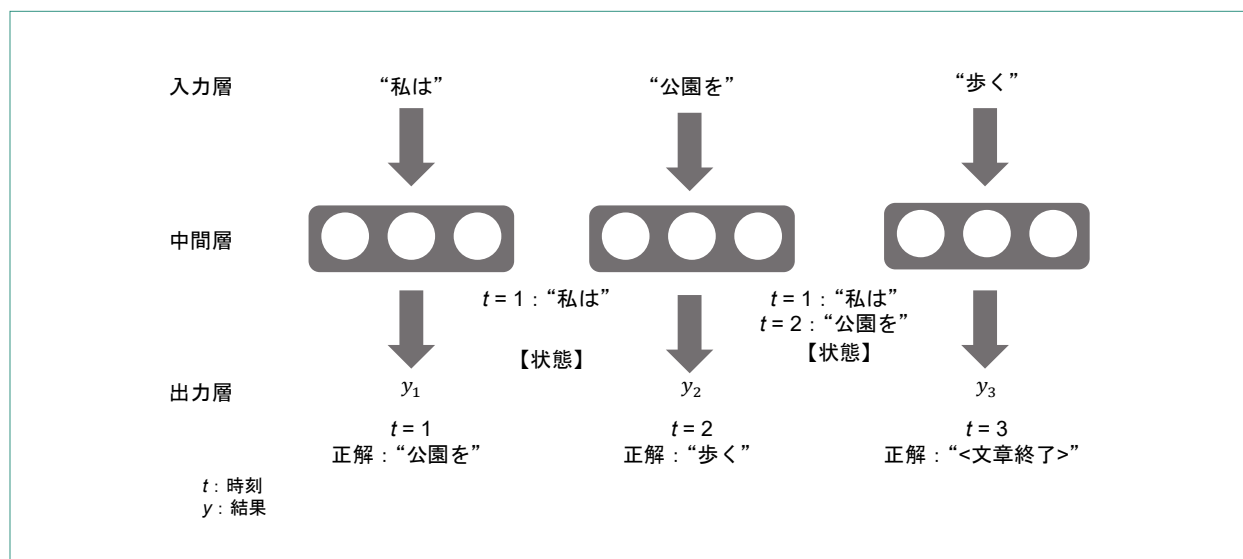


図2 RNNの模式図

^{*9} ノード：ネットワークにおいて、入力から受け取った値を伝搬する点のこと。
^{*10} 文章認識：ある文章がどのようなカテゴリの文章かを判定するタスク。
^{*11} 機械翻訳：ある言語の文章を、別の言語の文章に、コンピュータを用いて自動的に翻訳するタスク。

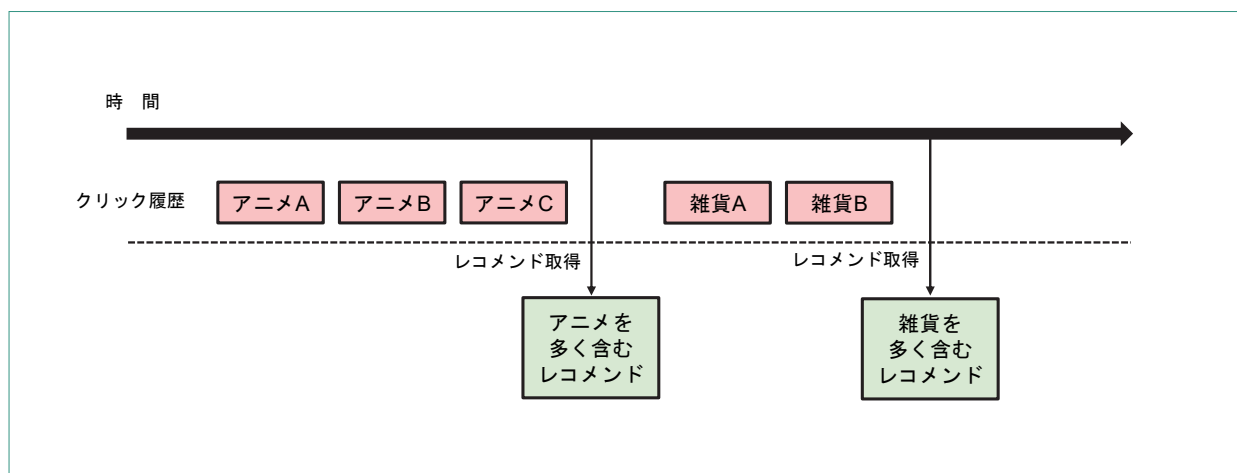


図3 RNNのレコメンド利用概要

レコメンドをリアルタイムに提供することができるようになる。

3. 提案手法

3.1 概要

RNNをレコメンドに適用する際、何点かサービスドメインに合わせた改良を行い、さらにユーザの直近の興味に適したレコメンドが出力されるような工夫を行っている。具体的には、①階層型RNNを用いた長期予測モデルと短期予測モデルを組み合わせたレコメンド、②異なる情報を用いた複数のRNNを組み合わせたレコメンド、の構築を行った。以下、各モデルについて解説する。

3.2 階層型RNNを用いた長期短期予測モデル

ユーザの興味は一定の周期で移り変わるわけではなく、長期的な興味遷移と短期的な興味遷移があると考えられる [3]。例えば、インストール履歴ベースでユーザにスマートフォンアプリケーション（以下、アプリ）をレコメンドするシステムにおいて、ユーザが X 日にSNSアプリを検索しているが、 $X+1$ 日には動画配信アプリを検索しているという場合

が考えられる。その場合、 X 日にはSNSアプリをレコメンドし、 $X+1$ 日には動画配信アプリをレコメンドすることが望ましい。しかし、単純なRNNでは X 日と $X+1$ 日の違いを考慮することができないため、 X 日の履歴を基に $X+1$ 日にもSNSアプリをレコメンドしてしまう可能性がある。そのため、 X 日の中では当日のインストール履歴を基にSNSアプリをレコメンドし、日をまたいだ場合はより長期的な興味遷移を予測してレコメンドする必要がある。なお、長期的な興味遷移とは、SNSアプリを検索した次の日には動画配信アプリを検索するなどの例を指している。

上記の長期・短期でのユーザ興味を捉えたレコメンドを実現するために、階層型RNNを提案する（図4）。前日までの履歴からレコメンドする内容を決定する日別RNNと、前日と当日の履歴を基に決定する同日RNNの二階層に分けることで、前述の課題を解決することができる。

3.3 異なる情報を用いた複数RNNを組み合わせたレコメンドモデル

商品・動画をレコメンドする際には、それらの内容を踏まえて考える必要がある。一方で、RNNで

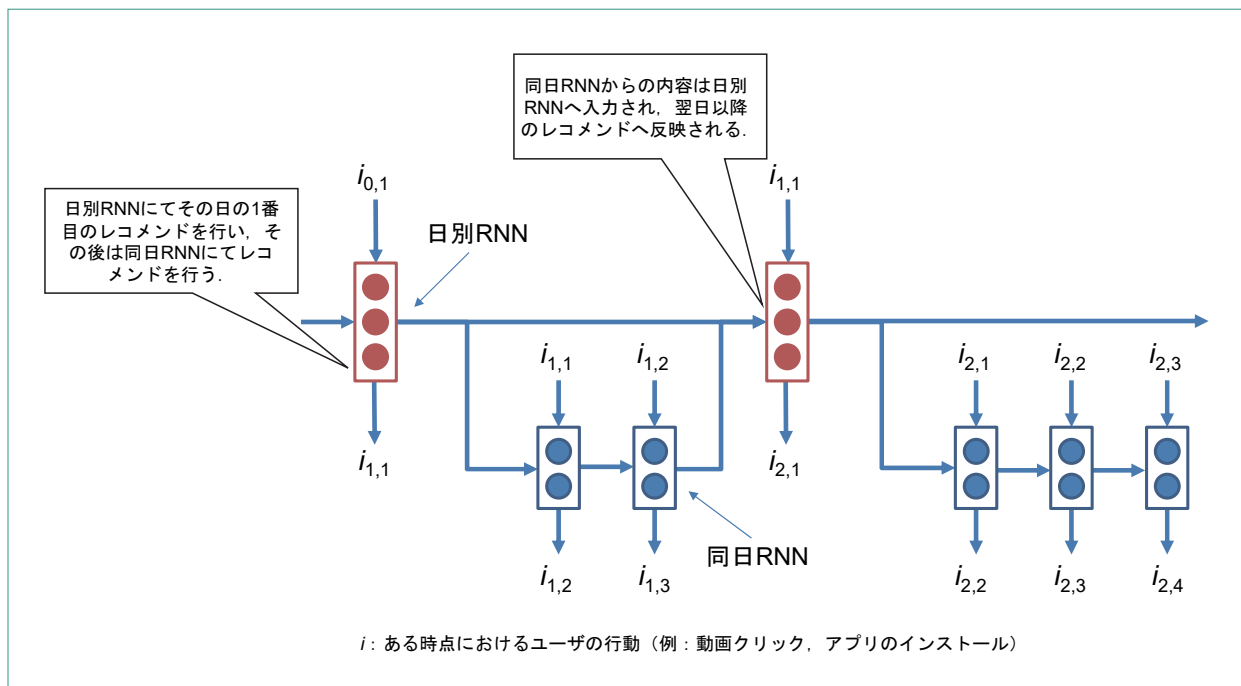


図4 階層型RNNの模式図

扱うデータは数値であり、商品や動画を数値データとして扱う必要がある。一般的に、商品や動画にはコンテンツIDが割り振られており、RNNではこのIDという数値データの時系列遷移を予測する。この手法では、コンテンツID単位での予測となるが、同一のコンテンツが過去の履歴に存在していない場合、予測を行うことができない。しかし、コンテンツIDが異なる場合でも、類似のコンテンツであれば同じような時系列推移になると考えられるため、商品や動画の内容(カテゴリ)の考慮を行う必要がある。例えば、飲食カテゴリの商品をクリックしたユーザは続けて飲食カテゴリの商品をクリックする可能性が高いと考えられるため、コンテンツID単位での時系列だけでなく、カテゴリ単位の時系列も併せて予測することが望ましい。

上記のレコメンドを実現するために、複数RNNを組み合わせたレコメンドモデルを提案する(図5)。異なる階層のデータを独立して時系列予測するRNN

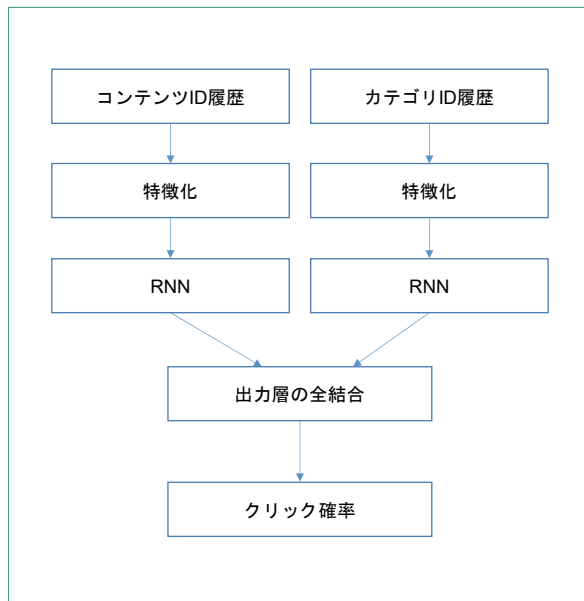


図5 複数RNNの模式図

を組み合わせることにより、コンテンツ単位での細かなレコメンドと、カテゴリ単位での大まかなレコ

メンドを両方実現できることになり、精度とカバレッジ*12の向上を両方実現できるようになる。

4. ドコモサービスへの適用

上記技術を、実際のドコモサービスに適用して効果検証を行った。適用したサービスは、ユーザに対してアプリをレコメンドする「おすすめアプリ」と、ドコモが運営する、BtoCサービスの商品をレコメンドするポータルサイト「dマーケット」の2つである。おすすめアプリには「階層型RNNを用いたレコメンド」、dマーケットには「複数RNNを用いたレコメンド」をそれぞれ適用している。それぞれのサービス概要と、効果検証結果について解説する。

4.1 おすすめアプリ

サービス画面を図6に示す。ユーザのアプリインストール履歴を基に、ユーザにとって有用と思われるアプリを提示するサービスである。提示したアプリをより多くインストールしてもらうことを目的と

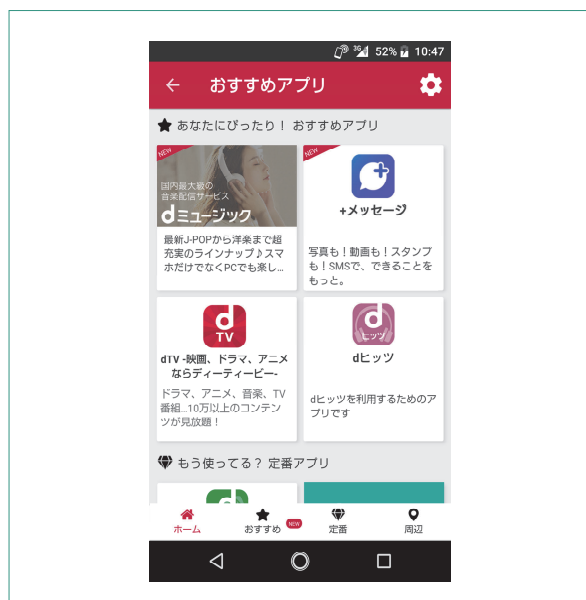


図6 おすすめアプリのサービス画面

し、前述の階層型RNNを用いたレコメンドの効果検証を、実際にユーザに対して行った。2020年9月より本技術と、履歴によるユーザ特徴量*13を用いた既存のレコメンドアルゴリズムとのA/Bテスト*14を実施し、既存のアルゴリズムと比較してインストール率*15 2.7倍を達成した。高いインストール率が出た理由としては、時系列を考慮することにより、例えばTwitterとカメラアプリを連続でインストールしたユーザにはInstagramをレコメンドするなど、直前のユーザの行動からユーザが求めるアプリの特性を推論することができたためであると考えられる。

4.2 dマーケット

サービス画面を図7に示す。図に示すとおり、「お買い物」「グルメ」など16種類のタブで分類された

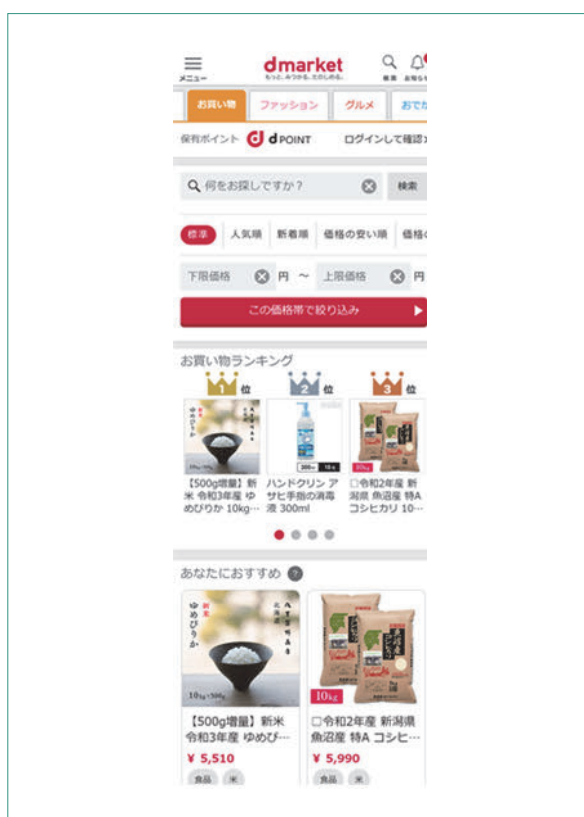


図7 dマーケットのサービス画面

*12 カバレッジ：全ユーザにレコメンドされる延べコンテンツ数が、全体のコンテンツ数に占める割合。カバレッジが高いということは、幅広いコンテンツがレコメンドされていることを示す。
*13 特徴量：データから抽出される、そのデータの特徴付ける量（数値）のこと。

*14 A/Bテスト：2つのアルゴリズムについて、どちらの方が効果を発揮するか比較するためのテストのこと。
*15 インストール率：レコメンド機能が提示したアプリの中で、実際にユーザがインストールに至ったアプリの割合。

領域において、ユーザへのおすすめコンテンツをサービス横断で表示するサービスである。複数のサービスにまたがって、ユーザがコンテンツに興味をもち、クリックしてもらうことを目的としてレコメンドを表示しており、また、Web回遊の中で、常にユーザに興味をもってもらえるよう、表示するたびにレコメンド内容を変化させている。前述の複数RNNを組み合わせたレコメンドの効果検証を実ユーザに対して実施した。本技術と既存の人気ランキングベースでのレコメンドアルゴリズムとのA/Bテストを行い、2.0%のCTR (Click Through Rate)^{*16}向上を達成した。CTRが向上した理由としては、カテゴリIDを考慮したことにより、異なるサービス間のコンテンツの共通要素を抽出できたためであると考えられる。例えば、グルメタブの人気ランキングでは食料品が多くレコメンドされるが、dマガジン^{*17}を多く利用しているユーザにはグルメ雑誌を多くレコメンドするなど、同じグルメであってもそのユーザに適したサービスのコンテンツをレコメンドすることができていた。

5. あとがき

本稿では、RNNを拡張したレコメンドアルゴリ

ズムについて解説した。サービスドメインの特性に合わせ、長期・短期双方でのユーザ興味推移をとらえるための階層型RNNを用いたレコメンドと、コンテンツの複数の特徴を活用した複数RNNを組み合わせたレコメンドについて述べた。両方のアルゴリズムについて実際のドコモサービス上で効果検証を行い、既存のアルゴリズムと比べての精度向上に繋がることを確認した。ドコモは、レコメンドアルゴリズムについて、今後も最新技術を追求し、サービスの提供価値向上に向けた取組みを進めていきたい。

文 献

- [1] J. Li, L. Deng, R. H-Umbach and Y. Gong: "Robust Automatic Speech Recognition: A Bridge to Practical Applications," Academic Press, Oct. 2015.
- [2] D. Wierstra, J. Schmidhuber, and F. Gomez: "Evolino: Hybrid Neuroevolution/Optimal Linear Search for Sequence Learning," Proc. of the 19th International Joint Conference on Artificial Intelligence (IJCAI), Edinburgh, PP.853-858, Jul. 2005.
- [3] B. Hidasi, A. Karatzoglou, L. Baltrunas and D. Tikk: "Session-based recommendations with recurrent neural networks," arXiv preprint arXiv: 1511.06939, Nov. 2015.

^{*16} CTR: レコメンド機能がコンテンツを表示した回数に対して、ユーザが実際にコンテンツをクリックした回数の割合。

^{*17} dマガジン: ドコモが提供するサブスクリプション型の雑誌配信サービスのこと。