

テクニカルノート

ユーザのシチュエーションと振舞いに基づく 見逃しコンテンツリーダーとその評価

樽見 彰仁^{1,†1,a)} 北山 大輔^{1,b)}

受付日 2021年3月10日, 採録日 2021年4月22日

概要: Web クリップアプリ, ニュースフィードアプリには, コンテンツ一覧を表示したり, コンテンツを保存できる機能がある. そのコンテンツの中で保存し忘れたものや, そのときのユーザがコンテンツを読むことができない状況である場合, コンテンツは埋もれたままになり, 再びアクセスすることは容易ではない. 本研究では, この問題を解決するために, 過去に閲覧した, ユーザの興味があるようなコンテンツとして, そのコンテンツの内容とシチュエーション (時間, 場所) を用いて学習し, ユーザモデルを作成する. 作成したユーザモデルを用いて, ユーザの現在のシチュエーションにおける, コンテンツの適切さを判定し, 過去に見落としていたであろう未閲覧のコンテンツを推薦するシステムを構築した. 実験として, 実際のコンテンツ閲覧ログを用いて作成したユーザモデルに対し, クラウドワーカーを用いて推薦コンテンツの評価を行った. その結果, シチュエーションを加えたモデルでは, 他のモデルに比べて適切に見逃しコンテンツを推薦できていることを示した.

キーワード: ニュース推薦, 推薦システム, SVR, 振舞い, シチュエーション

Overlooked Content Reader and its Evaluation Based on User Situations and Behaviors

AKIHITO TARUMI^{1,†1,a)} DAISUKE KITAYAMA^{1,b)}

Received: March 10, 2021, Accepted: April 22, 2021

Abstract: Web clip applications and news feed applications have functions to display a list of contents and to save contents. If the user forgets to save the content, or if the user is not able to read the content at the time, the content remains buried and is not easy to access again. In order to solve this problem, we create a user model by learning the contents and situations (time, place) of the contents that the user is interested in, which were viewed in the past. Using the created user model, we constructed a system that determines the appropriateness of contents in the user's current situation and recommends unviewed contents that may have been overlooked in the past. As an experiment, we used a cloud worker to evaluate the recommended content for a user model created using actual content browsing logs. As a result, we showed that the model with situations was able to recommend overlooked contents more appropriately than the other models.

Keywords: news recommendation, recommender system, SVR, user behavior, situations

1. はじめに

私たちは, 記憶を補助する目的で, コンテンツやタスク

を保存するアプリを利用している. コンテンツを保存するためのアプリとして, ユーザが後で閲覧したい Web ページを保存する Pocket ^{*1}などの Web クリップアプリや, ユーザがフォローしたニュースサイトの新着記事を取得・保存が可能な Feedly ^{*2}などがある. また, タスク管理をする

¹ 工学院大学

Kogakuin University, Shinjuku, Tokyo 163-8677, Japan

^{†1} 現在, 合同会社 ArsHub 共同設立者, 日本モノバンドル株式会社 CTO

^{a)} em19010@g.kogakuin.jp

^{b)} kitayama@cc.kogakuin.ac.jp

^{*1} <https://getpocket.com/>

^{*2} <https://feedly.com>

ためのアプリとして、期日になったときタスクをリマインドする Todoist^{*3}, Trello^{*4}などがある。これらの Web クリップアプリ、ニュースフィードアプリ、リマインダアプリには、コンテンツの一覧を表示する機能、コンテンツを保存する機能がある。しかし、これらのアプリには、ユーザが見落とししたり、保存し忘れていたりしたコンテンツや、その状況で閲覧することができなかつたコンテンツなどに再びアクセスすることは容易ではないという問題がある。たとえば、朝の通勤時における興味があるが時間がかかりそうなコンテンツや、リビングでリラックスしているときの仕事に関係ありそうな興味深いコンテンツはその場では見過ごされることが考えられる。このように、コンテンツが埋没する場面には、時間や場所が関係していると考えられる。本研究の目的は、このようなコンテンツを、ユーザに適切なタイミングで推薦し、ユーザの知識獲得を支援して、この問題を解決することである。

そこで本研究では、ユーザが見落とししたり、保存したことで自体を忘れたコンテンツを、ユーザに適切なタイミングで推薦することによって、ユーザの知識獲得を支援することは可能であるかを研究課題とする。ユーザに推薦する適切なタイミングは、過去に閲覧したユーザが興味があるようなコンテンツとして、そのコンテンツの内容とシチュエーション（時間、場所）を用いて学習し、ユーザモデルを作成する。作成したユーザモデルを用いて、ユーザの現在のシチュエーションにおける、コンテンツの適切さを判定し、適切である場合に、過去に見落とししていたであろう未閲覧のコンテンツを推薦する。本研究では、コンテンツとして、ニュース記事を取り扱う。

2. 関連研究

ユーザの行動や、位置情報などのコンテキストを用いたモデル作成や、作成したモデルを用いた推薦システムについての研究が行われている。土岐ら [1] は、SNS のストリーム閲覧時のユーザの行動から、ユーザプロフィールを構成する手法の提案した。スクロール動作からツイートの滞留時間を推定したものと、TF-IDF の組合せより興味単語を抽出し、TF-IDF に比べ高い精度でプロフィールを構成できることを示した。Liu ら [2] は、ニュース推薦とアクティブタイム予測を組み合わせた DNN モデルを提案した。ユーザのアクティブタイムを予測することによって既存の手法よりも高い精度で推薦が行えることをニュース推薦のためのデータセット Adressa [3] を用いた検証で示した。小林ら [4] は、Twitter 上の噂の元ツイートを RT したユーザのプロフィールと過去ツイートを時系列化した伝播経路を用いて、早期検出を行った。プロフィールと過去ツイート両方を学習することによってプロフィールのみの従

来手法 [5] より高い精度で噂を検出できることを示した。奥ら [6] は、ユーザの時系列的な行動パターンがそのときのユーザコンテキストによって変化することを考慮にした、情報推薦方式を提案した。中村ら [7] は、ユーザの複数の興味・関心が混在している Web 上の行動履歴を、事前に分類の基準を策定せず分類し、より適応範囲の広い超個人特化プロフィールを生成するための分析を行った。各要素の比率を決めるためさまざまな距離関数を作成し、クラスタリング結果を分析した。その結果、閲覧時刻とリファラーに関しては均等にするほうが適していることを示した。Constantinides ら [8] は、ユーザのインタラクション、位置情報から、ルール [9] を作成し、ユーザがどのようにニュースを閲覧するのか、どのようにニュース記事を選択するのか、どこで記事を閲覧するかモデル化を行ったが、ルールベースの提案手法より、RandomForest を用いた手法が優れていることを示した。

また、位置情報や加速度センサなどを用いて、屋内環境でユーザの位置を推定する研究が行われている。Bolal ら [10] は、屋内環境での、ユーザの行動と場所のコンテキストからユーザのプロフィールを推定するフレームワークを提案した。ユーザの行動は腕につけたスマートフォンの加速度センサデータを DeepSense [11] を用いて分類し、場所についてのコンテキストはあらかじめ屋内マップを作成し GPS と WiFi から判定し、限られた環境で高い精度で分類が可能であることを示した。Watanabe ら [12] は、止まっている、歩いている、車に乗っているなどのスマートフォンユーザの行動を位置情報から分類を行い、高い精度で分類が可能であることを示した。Ashbrook ら [13] は、シングルユーザ、マルチユーザ両方で、重要な場所を、ユーザ行動した GPS データから取得する手法を提案した。笹井ら [14] は、滞在場所の検出、行動にタスクやコメントを付与できるライフログ FLAG を提案した。滞在場所の検出についての有用性を実験で示した。

本研究は、ニュース推薦のためのユーザモデルの作成において、実空間上のユーザの記事を閲覧した場所と、現時点でのユーザのいる場所を考慮している点が従来手法と異なる。また、コンテンツを閲覧している場所をセンサデータなどを利用せずに、ユーザのシチュエーションとして学習させる点が従来手法と異なる。

3. 見逃しコンテンツリーダー

提案手法はユーザの行動ログの収集、ユーザモデルの作成、コンテンツ推薦からなる。はじめに、ユーザの閲覧行動をログとして保存する。次に、取得したログデータから、目的変数をユーザが過去にコンテンツを閲覧したかどうか、説明変数をコンテンツ内容、ユーザのシチュエーションとして、Support Vector Regression (SVR) を用いて、ユーザモデルを作成する。最後に、作成したユーザモデル

*3 <https://todoist.com/>

*4 <https://trello.com/>

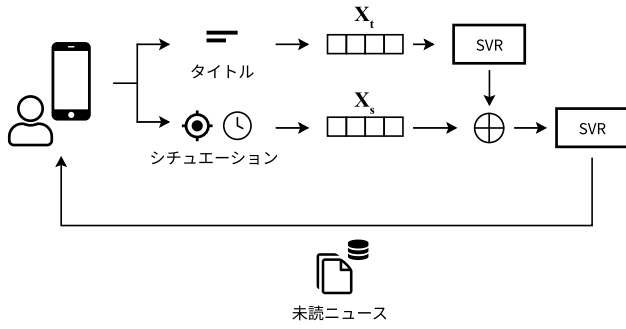


図 1 提案手法

Fig. 1 Proposed method.

表 1 モデル作成に使用するログデータ
Table 1 Log data for model creation.

キー	型	説明
title	String	ニュース記事のタイトル
location	String	閲覧した場所
isOpened	Bool	要約文を開いたか
isOpenedInBrowser	Bool	全文を開いたか
createdAt	Datetime	ニュースの取得時間

を用いて、ユーザの現在閲覧しているコンテンツとシチュエーションから、過去に取得したことのあるコンテンツをユーザに推薦する。提案手法の概要を図 1 に示す。

3.1 ログデータ収集

本システムではユーザの行動を取得し、データベースに保存することができる。ログとして保存するデータの中で、モデル作成に利用するデータを表 1 に示す。location の値に関しては、本稿では、ユーザが手動で入力し、private, home, work, public のいずれかの値になるものとする。private は自室などプライベートな空間に 1 人であることを示し、home は自宅などプライベートではあるが他者もいる空間を示す。work は職場であり、public は公共の場にいることを示している。

3.2 目的変数

ユーザがコンテンツ C_i を閲覧する可能性 y_i を目的変数 Y (式 (1)) とする。学習時の y_i は、 C_i のログデータから、記事の要約文を開いた場合 0.5、記事の全文を開いた場合 1.0、それ以外の場合 0.0 とする (式 (2))。なお、後述する仕様により、要約文はアプリ内で開くことができるが、全文は別途ブラウザが立ち上がりそこで閲覧を行う。 n はユーザが過去に取得した記事の総数である。

$$Y = [y_0, y_1, \dots, y_n] \quad (1)$$

$$y_i = \begin{cases} 0.5 & \text{if isOpened} \\ 1.0 & \text{if isOpenedInBrowser} \\ 0.0 & \text{Otherwise} \end{cases} \quad (2)$$

3.3 説明変数

3.3.1 コンテンツ内容

コンテンツ内容の説明変数 X_t として、ニュース記事のタイトルを 300 次元で分散表現したものを用いる。分散表現のモデルは、2020 年 11 月 02 日 02:57 時点での、Wikipedia のダンプデータ*5 を MeCab [15] (辞書: mecab-ipadic-NEologd 2020-08-20) で分かち書きしたものを fastText [16] で 300 次元で学習したものを用いた。作成した分散表現モデルを用いて、fastText の get_sentence_vector() 関数にニュース記事のタイトルを入力し、コンテンツ内容の説明変数として利用する。

3.3.2 ユーザのシチュエーション

ユーザのシチュエーションの説明変数 X_s として、ユーザがニュース記事を閲覧した時刻 $\sin(\pi t)$, $\cos(\pi t)$, 場所 x_{l_0}, \dots, x_{l_3} を用いる (式 (3))。 $\sin(\pi t)$, $\cos(\pi t)$ はログデータの “createdAt” の時刻 H , 分 M , 秒 S から 24 時間を円周上の座標として表現したものである。 x_{l_0}, \dots, x_{l_3} は、ログデータの “location” をダミー変数化したものである、

$$X_s = [x_0, x_1, \dots, x_n] \quad (3)$$

$$x_i = [\sin(\pi t), \cos(\pi t), x_{l_0}, \dots, x_{l_3}] \quad (4)$$

$$t = (H \times 3600 + M \times 60 + S) / 86400 \quad (5)$$

3.4 回帰モデルの学習

非線形回帰手法として SVR を用いる (式 (6))。 $K(x_i, x)$ はカーネル関数である。

$$f(x) = \sum_{i=0}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b$$

$$b = y_i - \sum_{i=0}^n (\alpha_i - \alpha_i^*) K(x_i, x) + \epsilon \quad (6)$$

$$\sum_{i=0}^n (\alpha_i - \alpha_i^*) = 0 \text{ and } \alpha_i, \alpha_i^* \in [0, C]$$

SVR の実装は、scikit-learn *6 の SVR() クラスを利用した。

3.5 実装

提案手法を実装したアプリケーションについて解説する。アプリケーションの画面を図 2 に示す。アプリケーションを起動すると場所を入力するモーダルが表示される。場所のボタンをタップするとホーム画面へ遷移する。ホーム画面では、Feedly API から取得した各ニュースタイトルと、ユーザの現在地を変更できるボタンが表示される。ニュースタイトルをタップすると、ニュースのタイトル、ニュースサイトの URL、公開日時、要約文が表示され、ニュース記事をブラウザで開く、“続きを読む” ボタンと、記事を保

*5 <https://ja.wikipedia.org/wiki/Wikipedia:データベースダウンロード>

*6 <https://scikit-learn.org/stable/>

表 2 各手法とパラメータ
Table 2 Each method and parameter.

説明変数	説明	Kernel	Degree	C	ϵ	R^2
1. \mathbf{X}_t	タイトルのみ	poly	3	1.0	0.01	0.0261
2. \mathbf{X}_{st}	シチュエーション (時間) のみ	poly	5	0.001	0.1	-0.0245
3. \mathbf{X}_s	シチュエーション (時間, 場所) のみ	poly	5	1.0	0.01	0.1244
4. $\mathbf{X}_t \oplus \mathbf{X}_{st}$	タイトル \oplus シチュエーション (時間)	poly	3	1.0	0.01	0.0268
5. $\mathbf{X}_t \oplus \mathbf{X}_s$	タイトル \oplus シチュエーション (時間, 場所)	poly	3	1.0	0.01	0.0279
6. $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	1. の結果 \oplus シチュエーション (時間)	poly	1	0.1	0.1	0.5592
7. $f(\mathbf{X}_t) \oplus \mathbf{X}_s$	1. の結果 \oplus シチュエーション (時間, 場所)	rbf	-	1.0	0.01	0.5816

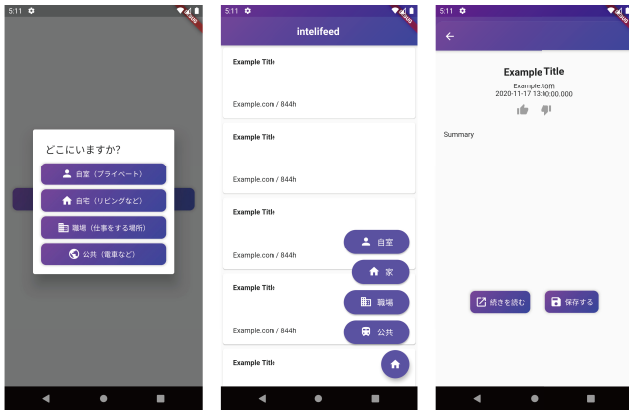


図 2 プロトタイプシステム (左: 場所選択画面, 中央: ホーム画面, 右: 記事表示画面)

Fig. 2 Prototype System. Left: Selecting location, Center: Home menu, Right: Displaying article.

存できる“保存する”ボタンが表示される。ここで、ニュース記事が推薦記事である場合、公開日時の下に評価ボタンが表示される。ユーザはこの評価ボタンで推薦が適切であるかどうかを評価することができる。推薦記事は、Feedlyから取得した記事3件ごとに挿入し、最大5件挿入される。

また、アプリケーションは、Web, Android, iOS上で動作するようFlutter*7でアプリケーションを作成した。ログ(表1)はユーザアカウントごとにFirebase*8のFirestoreデータベースに保存される。また、このアプリケーションを利用する際は、ユーザは事前にFeedly APIと連携する必要がある。

4. パラメータの決定

説明変数の組合せごとに7つの手法を比較する。学習データとテストデータとして、著者自身がアプリケーション(図2)を利用して収集したデータ(ニュース472件分)を利用した。学習データのテストデータはそれぞれ75%と25%の割合でランダムに分割し、平均0,分散1で標準化したものを利用した。グリッドサーチによる交差検証でパラメータの探索を行った。分割数は3,カーネルはrbf(ガウスカーネル),poly(多項式カーネル) C, ϵ については

*7 <https://flutter.dev/>
*8 <https://firebase.google.com/>

[0.001, 0.01, 0.1, 1]の範囲で値で探索した。評価指数として決定係数 R^2 を利用した。

説明変数の組合せと、学習時の交差検証の結果、最も優れていたパラメータを表2に示す。1.は説明変数として、タイトルから得られた \mathbf{X}_t のみを用いた。2.はユーザのシチュエーション \mathbf{X}_s のうち、閲覧時の時間のみ $\mathbf{X}_{st} = [\sin(\pi t), \cos(\pi t)]$ を用いた。3.はユーザのシチュエーション \mathbf{X}_s のみを用いた。4.はタイトル \mathbf{X}_t と時間のみユーザのシチュエーション \mathbf{X}_{st} を結合したものをを用いた。5.はタイトル \mathbf{X}_t とユーザのシチュエーション \mathbf{X}_s を結合したものをを用いた。6.は1.により出力された予測値 $f(\mathbf{X}_t)$ と時間のみユーザのシチュエーション \mathbf{X}_{st} を結合したものを説明変数として用いた。提案手法である7.は1.により出力された予測値 $f(\mathbf{X}_t)$ とユーザのシチュエーション \mathbf{X}_s を結合したものを説明変数として用いた。決定係数 R^2 を見ると $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ が最も高い値となり、次点で $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}, \mathbf{X}_s$ と続いている。 $\mathbf{X}_t, \mathbf{X}_{st}, \mathbf{X}_t \oplus \mathbf{X}_{st}, \mathbf{X}_t \oplus \mathbf{X}_s$ については、決定係数 R^2 が低く、学習が失敗している可能性がある。

5. 評価実験

作成したユーザモデルの評価実験を行う。実際に図2の実装したアプリケーションをテストユーザに5日間利用してもらい、ログデータを収集する。収集したログデータをもとにクラウドソーシングにて定量的評価を行う。

5.1 ログデータ収集

テストユーザに図2のアプリケーションを利用してもらい、各手法での推薦精度の評価のためのデータ収集を行う。対象は20代の日常的にインターネットを使用する8人を対象として、アプリケーションをインストールしてもらい、5日間の実験を実施した。

テストユーザには事前にFeedlyに10サイト以上のニュースサイトをフォローしてもらい、実験期間中でも、新たにニュースサイトをフォローしてもよいと指示した。学習データを収集するため、期間中1日3回以上アプリケーション上でニュースを確認するよう指示し、リマインドのため11時, 15時, 23時にプッシュ通知を送信し、ニュー

表 3 収集データ

Table 3 Collected data from test users.

ユーザ	手法	記事取得数	要約文開封数	全文開封数
A	$f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	503	34	27
B	\mathbf{X}_t	834	9	1
C	$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	974	24	16
D	Random	701	4	3
E	\mathbf{X}_t	419	32	22
F	Random	326	21	20
G	$f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	204	14	7
H	$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	807	46	28

スを確認するよう促した。

推薦手法は、表 2 の \mathbf{X}_t , $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$, $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ の 3 つ、ベースラインとしてテストユーザが表示した記事の中から、未読の記事をランダムに提示する Random の合計 4 手法を用いた。各手法のモデル作成は午前 0 時と午後 0 時に行い、推薦記事は、テストユーザが期間中、記事を 150 件以上表示した場合のみ、予測値が 0.1 以上の上位最大 5 件を提示した。テストユーザごとに推薦手法をランダムに割り当て (各手法 2 人)、実験期間中、推薦手法は変更しない。収集したデータを表 3 に示す。

5.2 定量的評価

収集したログデータをもとに定量的評価を行う。はじめに、被験者に、あるテストユーザの閲覧ログを確認してもらう。その後、自宅 (home) 15:00 における Random, \mathbf{X}_t , $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$, $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ 各手法の結果上位 2 件、合計 8 件提示し、被験者が閲覧ログのユーザであると仮定し、読みたいと思うかどうかを 5 段階で評価してもらった。

テストユーザごとの閲覧ログは、要約文を開いた記事の中からランダムで選択した 4 件提示する。また、このようなランダム抽出を 1 人のテストユーザあたり 5 回行い、5 種類の閲覧ログを生成した。なお表 3 のユーザ D については要約文開封数が 4 のため閲覧ログは 1 種類のみである。被験者は 20 代の学生 11 名とクラウドソーシングサービスである CrowdWorks^{*9} で募集した。被験者はあるユーザに関する 1 種類の閲覧ログに対応するフォームに回答してもらう。

5.3 結果と考察

各手法の平均値と分散を表 4 に示す。平均値は、 $f(\mathbf{X}_t) \oplus \mathbf{X}_s$, \mathbf{X}_t , $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$, Random の順に高いことが確認できた。また、学生とクラウドソーシングの被検者間で、平均値の大小関係の違いはなかったため、区別せずに扱う。

続いて、分散分析を行った。有意水準 0.05 において、One-way ANOVA の結果、 $p = 6.722 \times 10^{-7}$ となり、有意

*9 <https://crowdworks.jp/>

表 4 各手法の平均値と分散

Table 4 Mean and variance for each method.

手法	平均	分散
Random	2.831	0.218
\mathbf{X}_t	2.949	0.442
$f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	2.910	0.613
$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	3.092	0.244

表 5 Tukey HSD 結果

Table 5 Results of Tukey HSD.

group 1	group 2	p
Random	\mathbf{X}_t	0.024
Random	$f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	0.868
Random	$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	0.001
\mathbf{X}_t	$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	0.102
$f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$	$f(\mathbf{X}_t) \oplus \mathbf{X}_s$	0.001

差が確認できた。また、Tukey HSD の結果 (表 5), Random と \mathbf{X}_t 間では、 $p = 0.024$ と有意差が確認できた。Random と $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ 間では、 $p = 0.001$ と有意差が確認できた。 $f(\mathbf{X}_t) \oplus \mathbf{X}_{st}$ と $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ 間では、 $p = 0.001$ と有意差が確認できた。Random と各手法の平均値の差が小さいのは、Feedly の特性上、ユーザが好みのニュースサイトからのみ記事を表示することが原因であると考えられる。 $f(\mathbf{X}_t) \oplus \mathbf{X}_s$ において、 \mathbf{X}_t との有意差は確認できなかったが、平均値が上回っているため、SVR の説明変数として、ユーザが記事を閲覧した場所を用いることで推薦精度が向上する可能性があると考えられる。

テストユーザの閲覧ログを用いた定量的評価の結果、SVR を用いたユーザモデル作成においてユーザのシチュエーションとして、ユーザのコンテンツを閲覧した場所、コンテンツの内容としてニュース記事のタイトルを目的変数として利用することが効果的であることが示唆された。

6. おわりに

Web クリップアプリ、ニュースフィードアプリなどでユーザが見落とししたり、保存したこと自体を忘れたコンテンツをユーザに適切なタイミングで、推薦することによって、ユーザの知識獲得を支援することは可能であるかを研究課題とし、本研究では、コンテンツ推薦に必要なユーザモデルの作成を行った。ユーザモデルは、ニュースタイトルの分散表現を SVR で学習した結果と、ユーザのシチュエーション (時間、場所) を結合したベクトルを説明変数、ユーザの閲覧行動を目的変数として、SVR で学習し、評価を行った。また、作成したユーザモデルを用いて、ユーザの現在のシチュエーションで、コンテンツを閲覧するには適切かを判定し、適切である場合に、過去に取得したユーザの興味あると予測された未閲覧のコンテンツを提示した。実際のユーザの閲覧ログを用いた定量的評価の結果、SVR

を用いたユーザモデル作成において、ユーザのシチュエーションとして、ユーザのコンテンツを閲覧した場所、コンテンツの内容としてニュース記事のタイトルを目的変数として利用することが効果的であることが示唆された。

今後の課題として、提案システムを実装したシステムの長期的な評価実験による評価と、ユーザの閲覧場所の自動推定があげられる。さらに、ユーザの記事の閲覧順序や閲覧時間などのコンテキスト考慮した手法や、アプリケーションの起動タイミングと起動時間などを元に、ユーザが記事を閲覧することができるような提示方法について検討する。また、コンテンツとして今回ニュース記事を用いたが、動画コンテンツなどの閲覧する際にシチュエーションによる制限が多いコンテンツなどに適用する手法について検討する。

謝辞 本研究の一部は、2020年度科研費基盤研究(C) (課題番号:18K11551) および2021年度科研費基盤研究(C) (課題番号:21K12147) によるものです。ここに記して謝意を表すものとします。

参考文献

- [1] 土岐真里奈, 牛尼剛聡: ソーシャルストリーム閲覧時の振舞いを利用したユーザプロフィール構成手法, 情報処理学会論文誌データベース (TOD), Vol.6, No.4, pp.35-45 (2013).
- [2] Liu, R., Peng, H., Chen, Y. and Zhang, D.: HyperNews: Simultaneous News Recommendation and Active-Time Prediction via a Double-Task Deep Neural Network, pp.3459-3465 (online), DOI: 10.24963/ijcai.2020/478 (2020).
- [3] Gulla, J., Zhang, L., Liu, P., Özgöbek, Ö. and Su, X.: The Adressa dataset for news recommendation, pp.1042-1048 (online), DOI: 10.1145/3106426.3109436 (2017).
- [4] 小林 鼓, 藤田桂英: ユーザの過去ツイートをを用いた噂の早期検出, 研究報告知能システム (ICS), Vol.2020-ICS-199, No.9 (2020).
- [5] Liu, Y. and Wu, Y.-F.: Early Detection of Fake News on Social Media Through Propagation Path Classification with Recurrent and Convolutional Networks (2018).
- [6] 奥 健太, 中島伸介, 宮崎 純, 植村俊亮, 加藤博一: ユーザの時系列コンテキストを考慮した情報推薦方式の提案, 情報処理学会研究報告データベース・システム研究会報告, Vol.146, pp.121-126 (オンライン), 入手先 <<https://ci.nii.ac.jp/naid/110006980283/>> (2008).
- [7] 中村明順, 西尾信彦: 超個人化プロフィール生成のための Web ライフログの分類分析, 電子情報通信学会技術研究報告 MoMuC, モバイルマルチメディア通信, Vol.111, No.476, pp.135-142 (2012) (オンライン), 入手先 <<https://ci.nii.ac.jp/naid/110009545109/>>.
- [8] Constantinides, M. and Dowell, J.: A Framework for Interaction-Driven User Modeling of Mobile News Reading Behaviour, *Proc. 26th Conference on User Modeling, Adaptation and Personalization, UMAP '18*, pp.33-41, Association for Computing Machinery (online), DOI: 10.1145/3209219.3209229 (2018).
- [9] Constantinides, M., Germanakos, P., Samaras, G. and Dowell, J.: Your Digital News Reading Habits Reflect Your Personality, *Adjunct Publication of the 26th Conference on User Modeling, Adaptation and Personalization, UMAP '18*, pp.45-48, Association for Computing Machinery (online), DOI: 10.1145/3213586.3226191 (2018).
- [10] Bolat, A., Kim, D. and Li, K.-J.: Discovering User-Context in Indoor Space, *Proc. 9th ACM SIGSPATIAL International Workshop on Indoor Spatial Awareness, ISA '18*, pp.1-6, Association for Computing Machinery (online), DOI: 10.1145/3282461.3282463 (2018).
- [11] Yao, S., Hu, S., Zhao, Y., Zhang, A. and Abdelzaher, T.F.: DeepSense: A Unified Deep Learning Framework for Time-Series Mobile Sensing Data Processing, *CoRR*, Vol.abs/1611.01942 (online), available from <<http://arxiv.org/abs/1611.01942>> (2016).
- [12] Watanabe, Y., Suzumura, R., Matsuno, S. and Ohyama, M.: Investigation of Context-aware System Using Activity Recognition, *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, pp.287-291 (online), DOI: 10.1109/ICAIC.2019.8669035 (2019).
- [13] Ashbrook, D. and Starner, T.: Starner, T.: Using GPS to learn significant locations and predict movement across multiple users, *Personal and Ubiquitous Computing*, Vol.7, No.5, pp.275-286 (online), DOI: 10.1007/s00779-003-0240-0 (2003).
- [14] 笠井昭範, 原 直, 阿部匡伸: FLAG: 位置情報を基軸としたライフログ集約システム (サービスコンピューティング), 電子情報通信学会技術研究報告, Vol.114, No.157, pp.29-34 (2014) (オンライン), 入手先 <<https://ci.nii.ac.jp/naid/110009808458/>>.
- [15] KUDO, T.: MeCab: Yet Another Part-of-Speech and Morphological Analyzer, <http://mecab.sourceforge.net/> (2005) (online), available from <<https://ci.nii.ac.jp/naid/10019716933/>>.
- [16] Mikolov, T., Grave, E., Bojanowski, P., Puhusch, C. and Joulin, A.: Advances in Pre-Training Distributed Word Representations, *Proc. International Conference on Language Resources and Evaluation (LREC 2018)* (2018).



樽見 彰仁

2019年工学院大学情報学部コンピュータ科学科卒業。2021年同大学大学院修士課程修了。同年合同会社 ArsHub 共同設立者, 日本モノバンドル株式会社 CTO。ユーザインタラクションと情報推薦に興味を持つ。



北山 大輔 (正会員)

2009年兵庫県立大学大学院博士後期課程修了。同年日本学術振興会特別研究員 PD。2011年兵庫県立大学環境人間学部特任助教。2012年工学院大学情報学部助教。2016年同大学准教授，現在に至る。博士（環境人間学）。

Web 情報，地理情報の検索および推薦に関する研究に従事。日本データベース学会，ACM 各会員。

(担当編集委員 宇津呂 武仁)