

## 短期間の食事記録データからの個人の食習慣の予測 Eating Habits Prediction Using Short-Term Food Recording

椿田 晃大<sup>†</sup>      天野 宗佑<sup>†</sup>      相澤 清晴<sup>†</sup>      小川 誠<sup>‡</sup>  
Akihiro Tsubakida    Sosuke Amano    Kiyoharu Aizawa    Makoto Ogawa

### 1. まえがき

スマートフォンやウェアラブルデバイスの普及により運動、睡眠、食事などの日々の生活状況を記録することが容易になってきた [1, 2]。ライフスタイルを記録、管理することは肥満や糖尿病などの病気を予防することにも繋がるため、重要な事柄である [3]。例えば、栄養管理士はユーザのライフスタイルの情報をもとに、個人に特化した食事のアドバイスを行うことで、健康促進を促している。そのためには個人の食習慣を把握することが求められている。だが、食事を長期的に記録することは容易ではなく、食習慣の把握が難しい。そこで本研究では、短期間の食事記録データから個人が将来食べるであろう食事の予測を行うことで個人の食習慣を把握することを目的とする。予測の手法として、推薦システムで用いられる手法を応用し、その予測精度について示す。

### 2. 関連研究

Netflix prize[4]でも取り上げられているように推薦システムの領域において協調フィルタリングは盛んに研究されてるトピックである。協調フィルタリングでは一般に、入力ユーザの、アイテムに対する評価値を要素とするユーザ、アイテム行列(評価値行列)  $\mathbf{R}$  である。ユーザのアイテムに対する評価値は明示的な嗜好データ (explicit feedback) もしくは暗黙的な嗜好データ (implicit feedback) から成る。明示的な嗜好データはそのアイテムを好きであるか、嫌いであるかをユーザが直接評価したデータである。暗黙的な嗜好データはそのアイテムを消費した回数などのユーザの行動に基づいたデータであり、ユーザがアイテムに対して直接評価していないデータである。推薦システムではユーザの嗜好データに基づいて、ユーザが未評価のアイテムを提示することを目的としている。

本研究で扱う食事記録データは、ユーザが食べた食事の回数を記録したデータであり、これは暗黙的な嗜好データに当てはまる。また、一般的な推薦システムではユーザが未評価であるアイテムを提示対象としているが、本研究は推薦手法を用いた予測であるので、未評価アイテムのみではなく、評価済みのアイテムも提示対象とする。さらに、本研究では食事記録の期間(例えば、1日間、7日間、28日間など)に着目し、予測対象ユーザの食事記録データの期間による予測精度の違いを検証する。また、扱う食事として食品目とカテゴリの2つの粒度で実験を行う。

### 3. 問題設定

本研究では、ユーザが頻繁に食べる食事を順に並べたリストをユーザの食習慣と定義することにする。そして、最大で直近1か月の食事記録データを用いて、直後1か月の食習慣を予測する問題を扱う。

### 4. 手法

食習慣の予測手法として、Global popularity-based, Personal popularity-based, Matrix Factorization(MF)の3つの手法を用いた。

Global popularity-basedの手法は全ユーザが過去に消費した数が多いアイテムほど、対象ユーザは将来そのアイテムを消費しやすいだろうと予測する手法である。予測は個人に特化されず、どのユーザにも同じ予測結果を返す。この手法では予測に用いる評価値は、入力された評価値行列  $\mathbf{R}$  の評価値をそのまま利用し、アイテムの順位を予測する。

Personal popularity-basedの手法は対象ユーザが過去に消費した数が多いアイテムほど、対象ユーザは将来そのアイテムを消費しやすいだろうと予測する手法である。予測は個人に特化し、この手法では予測に用いる評価値は、入力された評価値行列  $\mathbf{R}$  の評価値のうち、対象ユーザのみの評価値をそのまま利用し、アイテムの順位を予測する。

MFは対象ユーザのアイテムの消費傾向と他のユーザの消費傾向の両方を考慮して、そのユーザが将来消費しやすいアイテムを予測する手法であり、他人と個人の両方を考慮した上で、個人に特化した予測が可能となる。MFはユーザ、アイテムの評価値行列  $\mathbf{R}$  の次元を圧縮し、2つの行列に分解し、新しい評価値行列  $\hat{\mathbf{R}}$  を推定する。推定された新しい評価値行列  $\hat{\mathbf{R}}$  のユーザ  $u$  に対するアイテム  $i$  の評価値  $\hat{r}_{ui}$  を用いて、アイテムの順位を予測を行う。本研究では、暗黙的な嗜好データに対応したMFを用いる [5]。

### 5. 実験

#### 5.1. データセット

本実験ではFoodLog<sup>§</sup>に蓄積された食事記録データを用いる。FoodLogのデータベースにはデフォルトで登録されている食食品目が全部で1870種類存在する。また、FoodLogアプリケーションではユーザが新しく食食品目を登録する機能も備わっている。このFoodLogに蓄積されている食食品目の数は膨大であるため、本実験では頻繁に現れる食食品目であるデフォルトで登録されている食食品目1870種類のみを扱うことにする。この食食品目1870種類をデータセット1とする。また、各食食品目にはカテゴリ(ご飯・炊き込みご飯、

<sup>†</sup> 東京大学 情報理工学系研究科 電子情報学専攻

<sup>‡</sup> foo.log 株式会社

<sup>§</sup> <http://www.foodlog.jp/>




図 1: 予測に用いる学習データとテストデータの期間

丼, パスタ, 炒めもの・フライパン焼き, ケーキ・ゼリー・パフェ類など)が割り振られており, 全部で 91 種類のカテゴリが存在する. このカテゴリ 91 種類をデータセット 2 とし, カテゴリについても実験を行う.

## 5.2. 実験設定

FoodLog データセットのうち 2015 年 7 月 1 日から 2015 年 8 月 26 日までの 56 日間に食事を記録したユーザに対して, 記録した回数が, 7 月 1 日から 7 月 21 日の間に 30 回以上, かつ, 7 月 22 日から 7 月 28 日の間に 10 回以上, かつ, 7 月 29 日から 8 月 26 日の間に 40 回以上であるユーザを検索したところ, 261 人のユーザが該当し, このユーザ 261 人のユーザを実験対象とした. ここで記録回数とは, 記録した食事の種類の数とする. 例えば, ある日の朝食にご飯, 目玉焼きを食べた場合, そのときの記録回数は 2 回となる. さらに同じ日の昼食にご飯, ハンバーグを, 夕食にご飯, サラダ, ブリの照り焼きを食べた場合, その日の記録回数は 7 回となる. また, 実験対象ユーザ 261 人が記録した食食品目は全部で 1645 種類であった. よって今回入力とする評価値行列  $\mathbf{R}$  は  $261 \times 1645$  の行列となる. 同様な条件でカテゴリについても予測を行う. カテゴリは全部で 91 種類存在し, 実験対象ユーザ 261 人が, 前述した期間において記録した食食品目の属するカテゴリの種類の総数は 91 種類であった. したがって, カテゴリにおける評価値行列  $\mathbf{R}$  は  $261 \times 91$  の行列となる.

また, 予測を行う際に用いる食事記録データの期間による結果の違いを調べるため, 7 月 29 日 0 時を境に, (i) 直前 1 日である 7 月 28 日, (ii) 直前 7 日である 7 月 22 日から 7 月 28 日, (iii) 直前 28 日である 7 月 1 日から 7 月 28 日の予測対象ユーザの食事記録データと, その他 260 人の 7 月 1 日から 7 月 28 日の 1 ヶ月の食事記録データを学習データとして, 直後 28 日間で食べる食事の予測を, 3 つの期間それぞれで行った (図 1). 例えば, (i) の場合, 予測対象ユーザは 1 日分のみを, 残り 260 人のユーザは 28 日分すべての学習データを用いて予測し, これを 261 人分繰り返す, 予測精度の平均をとったものを実験結果とする. (ii), (iii) の場合も同様に 261 人分繰り返す, 平均をとった.

表 1 は学習データである 7 月 1 日から 7 月 28 日に実験対象ユーザ 261 人に食べられた食食品目上位 20 である. ご飯が他の食事に比べ圧倒的に記録された回数が

表 1: 7 月 1 日~7 月 28 日において, 実験対象ユーザ 261 人に食べられた食食品目上位 20

上位N	食食品目	記録回数
1	ご飯	3595
2	納豆	960
3	グリーンサラダ	943
4	バナナ	775
5	冷やっこ	700
6	ヨーグルト	671
7	ブラックコーヒー	604
8	プレーンヨーグルト	566
9	トマト	514
10	味噌汁(わかめと豆腐)	411
11	ミニトマト	408
12	味噌汁(わかめとねぎ)	404
13	生野菜サラダ	395
14	ソーセージ(ウインナーソーセージ)	383
15	野菜ジュース	382
16	鶏のから揚げ	380
17	キャベツの千切り	376
18	生ビール	372
19	ビール 缶 (350ml)	337
20	牛乳(グラス)	313

多いことが確認できる.

## 5.3. 評価方法

本実験では次の 2 つの指標 [6, 7] で予測精度の評価を行う.

$$\text{precision} @N = \frac{1}{|U|} \sum_{u \in U} \frac{\#hits}{N} \quad (1)$$

$$\text{MPR} = \frac{\sum_{ui} r_{ui} \text{rank}_{ui}}{\sum_{ui} r_{ui}} \quad (2)$$

ここで  $U$  はユーザの集合,  $\#hits$  は予測したアイテム上位  $N$  個のうち, テストデータで消費されたアイテムの数,  $r_{ui}$  はテストデータでユーザ  $u$  がアイテム  $i$  を消費した回数,  $\text{rank}_{ui}$  はユーザ  $u$  へのアイテム  $i$  の予測順位である.  $\text{precision}$  は予測したアイテム上位  $N$  のうち, テストデータで実際に消費したアイテムの割合を表す. Mean Percentage Ranking(MPR) は予測したアイテムの順位に加え, テストデータで実際に消費した回数も考慮に入れた評価指標である. テストデータで消費した回数の多いアイテムを上位に予測するほど, MPR の精度は上がる. 逆に, テストデータで消費した回数の多いアイテムが下位に予測されると MPR の精度は下がる.  $\text{precision}$  は高いほど, MPR は低いほど, 精度がよい.

本研究では, ユーザがよく食べる食事を上位 1 から順に並べた食事のリストをそのユーザの食習慣と定義している. 本実験では, ユーザ  $u$  が食事  $i$  を食べた回数が評価値  $r_{ui}$  であり, この評価値  $r_{ui}$ , あるいは評価値  $r_{ui}$  から新たに生成した評価値  $\hat{r}_{ui}$  に基づいて, 食事の順位を予測し, 上位 1 から上位  $M$  まで並べる. そして, テストデータである直後 1 ヶ月間に予測した食事を食べたか食べないかの 2 値での評価を  $\text{precision}$ , 順

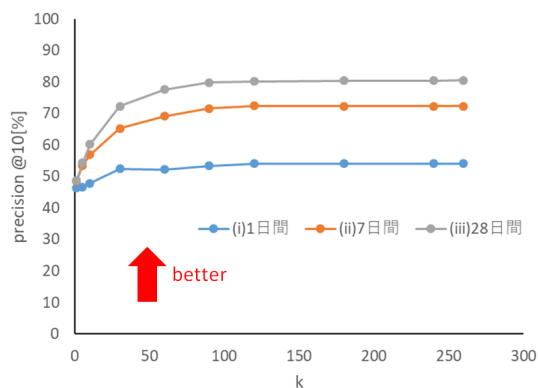


図 2:  $k$  の値を変化させたときの MF の予測精度 (precision @10%)




図 3:  $k$  の値を変化させたときの MF の予測精度 (MPR)

位と実際に食べられた回数も考慮した評価を MPR で行う。

#### 5.4. 食物品目 (データセット 1) での実験

##### 5.4.1. MF で用いる $k$ の値の選定

一般に MF ではパラメータ  $k$  の値が大きくなると、行列を分解した後のユーザ、アイテムの特徴行列の特徴の表現力が増えるため、精度がよくなる傾向がある。だが、その分計算コストがかかるため、状況に応じて  $k$  を選択する必要がある。他の手法と比較する前に、まず MF で用いるパラメータ  $k$  を決める必要がある。そこで、 $k = 1, 5, 10, 30, 60, 90, 120, 180, 240, 260$  として、実験を行い、精度のよい  $k$  の値を以降の実験で用いることにする。MF において、(i), (ii), (iii) それぞれの学習データについて  $k$  の値を変えて、予測した結果を図 2, 3 に示す。

図 2 より、precision については  $k$  の値が大きくなるにつれて精度が上がった。図 3 より、MPR は学習データの少ない (i) 以外は  $k$  の値によって精度はほとんど変わらない、もしくは少し精度が上がった。(i) を除けば、 $k$  の値が大きくなるにつれ、精度が上がる傾向が確認できたことと、 $k = 120$  を超えると精度はほとんど変わらなかったことを踏まえ、以後の実験では  $k = 120$  と




図 4: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて、precision による 3 つの手法の比較




図 5: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて、MPR による 3 つの手法の比較

して実験を行った。

##### 5.4.2. 食習慣の予測

予測に用いる学習データの期間による予測精度の結果を図 4, 5 に示す。

図 4 より、precision については (i),(ii),(iii) 全ての学習データにおいて、MF の精度が最もよかった。また、図 5 より、MPR についても、個人に特化した予測を行う Personal popularity-based と MF とでは MF の方が精度がよいことが確認できた。これより、個人の食習慣を予測するために今回提案した MF はうまく食習慣を予測できていることが確認できた。また、7 日間の食事記録データがあれば、直後 1 ヶ月に食べる食事を precision@10 で約 70% の精度で予測できることが確認できた。ここで予測結果の具体例を表 2, 3 に示す。

##### 5.4.3. 記録回数の多いユーザのみの食習慣の予測

5.4.2 では実験対象ユーザの数が極端に少なくならないよう、実験対象とするユーザを選ぶ際、記録回数の条件を緩くしていた。そこで、5.4.2 における実験対象

表 2: あるユーザが学習データ (ii) の 7 日間で食べた食食品目上位 10 (左) とテストデータ 28 日間で食べた食食品目上位 10 (右)

上位N	学習データ (7日間)		テストデータ (28日間)	
	食食品目	記録回数	食食品目	記録回数
1	ご飯	10	ご飯	17
2	キャベツの千切り	7	発泡酒 缶 (350ml)	15
3	フランスパン	6	めだま焼き	14
4	アイスブラックコーヒー	5	アイスブラックコーヒー	14
5	グリーンサラダ	5	フランスパン	12
6	めだま焼き	5	麦茶	9
7	発泡酒 缶 (350ml)	5	はるさめのスープ	6
8	味噌汁 (わかめとねぎ)	4	味噌汁 (わかめとねぎ)	6
9	はるさめのスープ	4	焼酎 (お湯割り)	6
10	刺し身三種盛り合わせ	3	五目炊き込みご飯	5

表 3: あるユーザの 7 日間の食事記録データから, 3 つの手法で食習慣を予測した結果の例

上位N	Global pop	Personal pop	MF(k=120)
1	ご飯	ご飯	ご飯
2	納豆	キャベツの千切り	グリーンサラダ
3	グリーンサラダ	フランスパン	キャベツの千切り
4	バナナ	アイスブラックコーヒー	ソーセージ (ウィンナーソーセージ)
5	冷やっこ	グリーンサラダ	冷やっこ
6	ヨーグルト	めだま焼き	めだま焼き
7	ブラックコーヒー	発泡酒 缶 (350ml)	味噌汁 (わかめとねぎ)
8	プレーンヨーグルト	味噌汁 (わかめとねぎ)	鶏のから揚げ
9	トマト	はるさめのスープ	フランスパン
10	味噌汁 (わかめと豆腐)	刺し身三種盛り合わせ	アイスブラックコーヒー

ユーザ 261 人のうち, 直前 7 日間に継続して毎日 6 回以上食事を記録しているユーザに対してのみ, 食習慣の予測を行うことで, 少なくとも直前 1 週間だけは毎日しっかり食事を記録した場合, どの程度食習慣を予測することが可能であるかの確認を行った。

上記の条件でユーザを検索したところ, 261 人中 25 人が該当した。その他の実験設定は 5.4.2 と同様とし, 261 人の学習データを用い, 該当ユーザ 25 人のみの食習慣の予測を行い, 平均をとった。結果を図 6, 7 に示す。

図より, 261 人に対して食習慣の予測を行った場合と全体の傾向は概ね同じになった。一方, precision の精度については, 7 日間毎日 6 回以上しっかり食事を記録するユーザに対しては, 直後 1 ヶ月に食べる食事を precision@10 で 85% 以上の精度で予測できることが確認でき, 条件の緩い 261 人の場合と比べ, 約 15% の精度向上が確認できた。

#### 5.4.4. 他の月での食習慣の予測

5.4.2 では 7 月の食事記録データを用いて, 8 月に食べるであろう食事の予測を行った。そこで 2015 年の他の月においても同様の実験を行い, 季節によって予測のしやすさが変わるのかを確認する。ここでは, 7 月




図 6: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて, precision による 3 つの手法の比較 (25 人のみ)

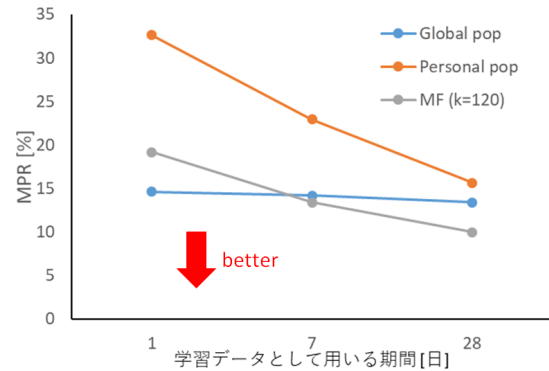


図 7: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて, MPR による 3 つの手法の比較 (25 人のみ)

から 8 月の予測に加え, 1 月から 2 月の予測, 4 月から 5 月の予測, 10 月から 11 月の予測の実験を行い, それぞれの予測精度を比較する。さらに, 直後 1 カ月の食習慣の予測ではなく, 月をまたいだ数ヵ月後の 1 ヶ月間の食習慣を予測した場合の予測精度についても確認する。

まず, 5.2 で述べた条件と同様にして, ユーザを検索したところ, 各季節におけるユーザ数と食食品目数は表 4 ようになった。そして, 予測対象ユーザの学習データの期間が 7 日間のときの, 各季節における予測結果は図 8,9 となった。

図 8,9 より, 他の季節においても同様に予測対象ユーザの 7 日間の食事記録データがあれば, 直後 1 ヶ月に

表 4: 各季節におけるユーザ数と食食品目数

学習	テスト	ユーザ数	食食品目数
1 月	2 月	300	1662
4 月	5 月	289	1673
7 月	8 月	261	1645
10 月	11 月	268	1664




図 8: 各季節ごとの予測結果 (precision)

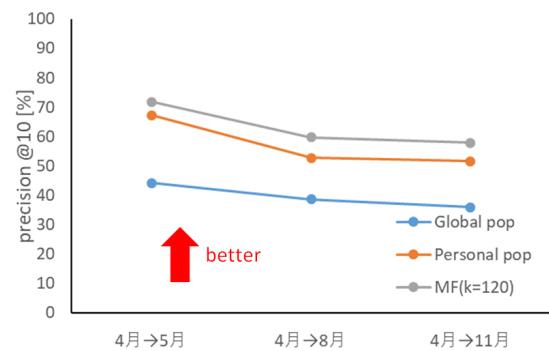


図 10: 4月の食事記録データを用いて、5月、8月、11月の食習慣の予測をしたときの precision の比較

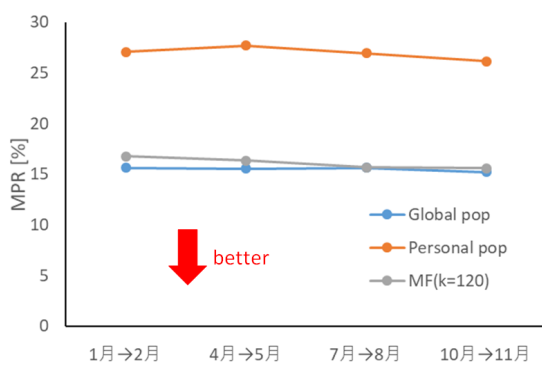


図 9: 各季節ごとの予測結果 (MPR)

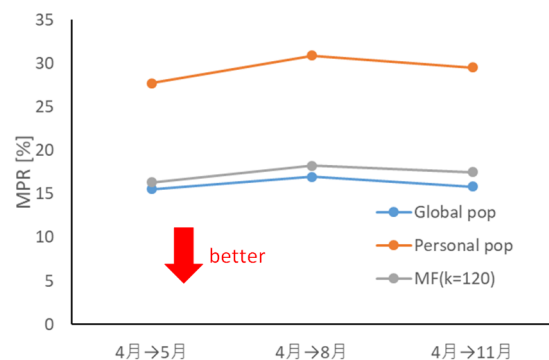


図 11: 4月の食事記録データを用いて、5月、8月、11月の食習慣の予測をしたときの MPR の比較

食べる食事を precision@10 で約 70%の精度で予測できることが確認できた。

また、4月の食事記録データを用いて、5月の食習慣を予測することに加え、4月の食事記録データを用いて8月、11月の食習慣の予測を行った。学習データ(ii)の7日間におけるその比較結果を図10,11に示す。

図10,11より、直後1ヵ月の食習慣の予測に比べ、月をまたいで食習慣を予測すると、precision,MPRの精度はともに下がった。これは季節ごとによく食べられる食事が変わったことや個人の食習慣が変わったことが原因として考えられる。どちらの要因が大きな影響を与えているのかは今後調査する必要がある。

### 5.5. カテゴリ (データセット2) での実験

#### 5.5.1. MF で用いる $k$ の値の選定

5.4.1と同様にカテゴリについて、MFのパラメータ  $k$  を決めるために、 $k = 1, 5, 10, 20, 30, 60, 90$  として実験を行った。precision,MPRともに  $k = 60$  を超えると、精度が上がらなかったため、以後の実験では  $k = 60$  として実験を行った。

#### 5.5.2. 食習慣の予測

食食品目の場合と同様に、カテゴリでも実験を行った。結果を図12,13に示す。

図12,13より、カテゴリについても、MFにより個人の食習慣の予測がうまくできていることが確認できた。また、カテゴリの予測については、予測対象ユーザの食事記録データが7日間あれば、28日間の食事記録データがあった場合と同等の精度 (precision@10で90%程度) で予測が可能であることが確認できた。これはカテゴリの粒度であれば、短期間の食事記録データから個人の食習慣の予測が可能であることを示唆していると考えられる。

#### 5.5.3. 他の月での食習慣の予測

食食品目の場合と同様に、カテゴリについても他の月での食習慣の予測を行った。7月から8月の予測に加え、1月から2月の予測、4月から5月の予測、10月から11月の予測の実験を行い、それぞれの予測精度を比較した。precision@10の結果を図14に示す。

図14より、他の季節においても同様に予測対象ユーザの7日間の食事記録データがあれば、直後1ヵ月に食べる食事を precision@10 で90%程度の精度で予測できることが確認できた。

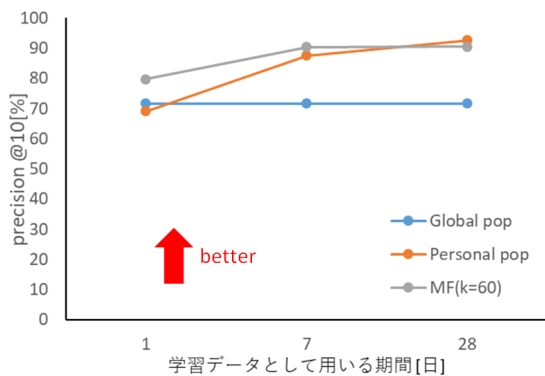


図 12: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて, precision による 3 つの手法の比較 (カテゴリ)

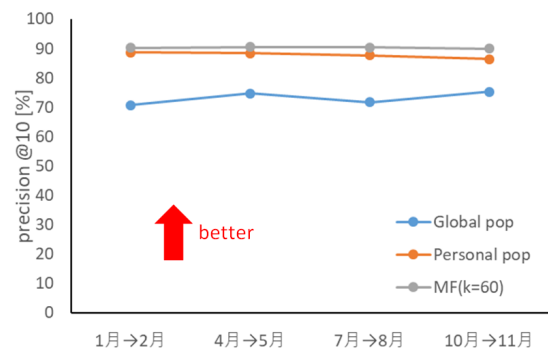


図 14: 各季節ごとの予測結果 (precision) (カテゴリ)

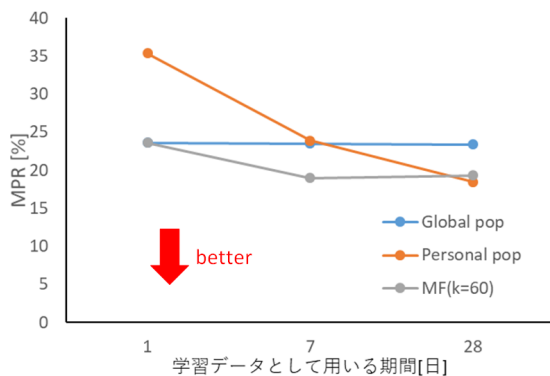


図 13: 食事記録データの量 (i)1 日間,(ii)7 日間,(iii)28 日間それぞれについて, MPR による 3 つの手法の比較 (カテゴリ)

## 6. まとめと今後の課題

本稿では短期間の食事記録データから個人の食習慣の予測を行った。Global popularity-based, Personal popularity-based, Matrix Factorization の 3 つの手法で予測を行った。食習慣を知りたいユーザの 7 日間毎日記録した食事記録データがあれば, 食食品目については MF により precision@10 で約 90% の精度で食習慣を予測することができた。また, カテゴリについては, 7 日間の食事記録データがあれば, 28 日間と同等の精度で食習慣を予測できることが分かった。今後は, 長期的, 短期的な個人の食習慣の変化や季節による食習慣の変化などを分析し, それらを考慮した上で食習慣の予測をしていきたい。また, 食習慣の定義や評価方法についても再度検討したい。

## 参考文献

[1] Felicia Cordeiro, Elizabeth Bales, Erin Cherry, and James Fogarty. Rethinking the mobile food journal: Exploring opportunities for lightweight photo-based capture. In *Proceedings of the 33rd Annual ACM Conference on Human Factors in*

*Computing Systems*, pp. 3207–3216. ACM, 2015.

- [2] Frank Bentley and Konrad Tollmar. The power of mobile notifications to increase wellbeing logging behavior. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 1095–1098. ACM, 2013.
- [3] Yoojung Kim, Sookyoung Ji, Hyunjeong Lee, Jeong-Whun Kim, Sooyoung Yoo, and Joongseek Lee. My doctor is keeping an eye on me!: Exploring the clinical applicability of a mobile food logger. In *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*, pp. 5620–5631. ACM, 2016.
- [4] James Bennett, Stan Lanning, et al. The netflix prize. In *Proceedings of KDD cup and workshop*, Vol. 2007, p. 35. New York, NY, USA, 2007.
- [5] Yifan Hu, Yehuda Koren, and Chris Volinsky. Collaborative filtering for implicit feedback datasets. In *Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on*, pp. 263–272. Ieee, 2008.
- [6] Paolo Cremonesi, Yehuda Koren, and Roberto Turrin. Performance of recommender algorithms on top-n recommendation tasks. In *Proceedings of the fourth ACM conference on Recommender systems*, pp. 39–46. ACM, 2010.
- [7] Christopher C Johnson. Logistic matrix factorization for implicit feedback data. *Advances in Neural Information Processing Systems*, Vol. 27, , 2014.