

ケアプラン作成支援システムのための 非負値行列因子分解に基づく特徴語補完

Terms Completion based on Nonnegative Matrix Factorization for Care Planning Support System

兵頭 幸起[†] 寺尾 勇一[§] 林 慧子[§] 佐野 貴洋[§] 竹林 奈々子[§] 濱上 知樹[†]
Koki HYODO Yuichi TERAO Chieko HAYASHI Takahiro SANO Nanako TAKEBAYASHI Tomoki HAMAGAMI

1. はじめに

日本は超高齢化社会であり、労働集約性の高い介護分野におけるケアマネジメントが重要視されている。現状ではケアマネージャーがアセスメントからケアプラン文書を作成しているが、多くの時間と労力が必要であり、主観や経験、能力に依存していることが問題となっている。本研究では過去の介護記録を基に利用者に適したケアプラン文書を推薦する、ケアプラン作成支援システムの実現を目指す。

本稿では代表的な推薦手法であるメモリベース協調フィルタリングに着目する。メモリベース協調フィルタリングではケアプランの文書構造を保持した推薦が期待される。しかし、次のような課題も存在する。

- 訓練データ間の関係が考慮されない
- アイテム（単語）間の関係が考慮されない

また、協調フィルタリング全体の課題としてスパース性の高い行列に用いる場合、適切な推薦が行われない可能性がある。文書行列に対しては主に次元削減によるスパース性軽減が行われるが、ケアプラン文書のようにコーパスが小さく短文の場合、共起関係が適切に抽出されない可能性が指摘されており [1]、大域的に特徴を捉えた推薦に対する需要が高いケアプラン作成支援システムには適切でない。

そこで、スパース性軽減のための前処理としてクエリ拡張を行う推薦手法を提案する。クエリ拡張はケアプラン文書から得られる共起関係に基づいて特徴語補完を行うため、訓練データ間やアイテム（単語）間の関係を考慮可能である。また、本稿ではクエリ拡張として、スパース性の高い行列に対しても比較的有効であるとされている非負値行列因子分解を用いる。

実験では、実データに対する推薦の評価や補完された特徴語に関する考察を行った。

2. ケアマネジメント

図1にケアマネジメントの流れを示す。図中の手順の内、アセスメントの結果からケアプラン文書を策定する作業が最も重要となる。しかし、ケアマネージャーは「初回のケアプラン文書作成」に対して「自分の能力や資質に不安がある」、「記録する書式が多く手間がかかる」と感じている [2, 3]。したがって本研究では、アセスメントからケアプラン文書を作成する作業に焦点を当



図1 ケアマネジメントの流れ

てる。

アセスメントはヒアリングにより得られる利用者情報であり、有無を問う二値項目と程度項目が存在する。

ケアプラン文書はアセスメントを基に作成される介護計画書であり、ニーズ、長期目標、短期目標、サービス内容により構成され、自然言語によって記述されている。

図2に本研究によるケアプラン作成支援システムを示す。このケアプラン作成支援システムは入力されたアセスメントに対してケアプラン文書の候補を推薦する。これにより、ケアマネージャーの業務効率化が期待される。

3. メモリベース協調フィルタリング

協調フィルタリングは、ある特定の利用者（活動利用者）の嗜好を複数の類似した他の利用者（標本利用者）の嗜好データから予測し、適合アイテムを抽出する推薦手法である。特に本研究のように新規利用者に対するアプローチはメモリベース法とモデルベース法 [4, 5] の2種類に分けられる。

メモリベース協調フィルタリングとしては最近傍法による外部情報を用いた手法 [6] が提案されており、活動利用者は類似した行動を取る利用者グループに属しているという仮定の下で評価値予測を行う。評価値予測は式 (1) に従う。

$$\mathbf{r}_q = \frac{\sum_{d \in D} \text{sim}(\mathbf{q}, \mathbf{d}) \cdot \mathbf{r}_d}{\sum_{d \in D} \text{sim}(\mathbf{q}, \mathbf{d})} \quad (1)$$

ここで、 \mathbf{r}_q は活動利用者の評価予測値、 D は標本利用者集合、 \mathbf{q} は活動利用者ベクトル（外部情報）、 \mathbf{d} は標本利用者ベクトル（外部情報）、 \mathbf{r}_d は標本利用者の評価実測値を表し、 $\text{sim}(\cdot)$ にはコサイン類似度やピアソン積率相関係数が用いられる。本研究においては \mathbf{q} と \mathbf{d} はアセスメントに対応し、 \mathbf{r}_q と \mathbf{r}_d はケアプラン文書に対応する。

このメモリベース協調フィルタリングは簡潔な手法であり広く利用されている一方で、外部情報 (\mathbf{q}, \mathbf{d}) の類似度に依存した予測であるため、 \mathbf{r}_d における訓練データ間やアイテム（単語）間の関係が考慮されないことが課題である。また、スパース性の高い行列においては利用者グループの特徴を抽出することが困難であるため平

[†] 横浜国立大学大学院理工学部

[§] リゾートトラスト株式会社メディカル本部シニアライフ運営戦略部

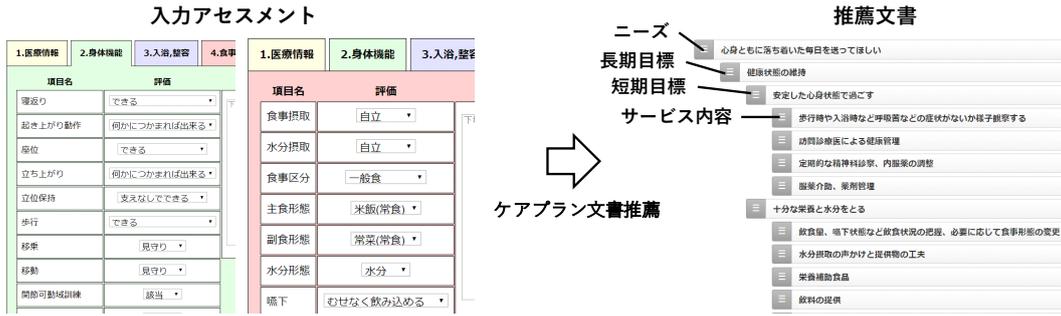


図2 ケアプラン作成支援システム

均的な推薦になってしまう可能性が懸念される。

4. 非負値行列因子分解

非負値行列因子分解 (NMF: Nonnegative Matrix Factorization [7]) は 0 以上の値を持つ行列を解析する手法である。主に文書のクラスタリングや要約などに用いられるが、推薦手法としての有効性も示されている [8, 9]。

推薦手法として利用される場合、欠損値を含む行列分解を行う。目的関数は次のとおりである。

$$\|R - UV\|^2 = \frac{1}{2} \sum_{i,j \in \mathcal{I}} \left\{ r_{ij} - \sum_k u_{ik} v_{kj} \right\}^2 \quad (2)$$

ここで、 $R \in \mathbb{R}^{I \times J}$ は評価値行列、 k は基底数、 $\mathcal{I} = \{(i_0, j_0), (i_1, j_1) \dots\}$ は欠損でない要素の組、 $U \in \mathbb{R}^{I \times k}$ と $V \in \mathbb{R}^{k \times J}$ はそれぞれ利用者 (文書) とアイテム (単語) の潜在ベクトルを表す。図3にNMFに基づく推薦の例を示す。ここでは利用者の購買履歴を用いたアイテムの推薦を表す。NMFにより得られた U, V の内積を取り、再構築を行うことで欠損値の推定が可能となる。

NMFに基づくクエリ拡張を行っている関連研究としては Relevance Feedback Matrix Factorization (RFMF) [10] が挙げられる。ここでは、代表的なクエリ拡張手法である疑似関連性フィードバックとNMFの組み合わせによってクエリ拡張を行っている。しかし、クエリと疑似関連文書のみを用いた行列分解であるため、疑似関連文書の質に依存する。したがって、コーパスが小さなケアプラン文書では適切なクエリ拡張が行われない可能性がある。

5. NMFに基づくクエリ拡張

5.1 概要

3章のメモリベース協調フィルタリングの改善手法として、ケアプラン文書推薦のためのNMFに基づくクエリ拡張を提案する。図4に提案手法の概略図を示す。図4(a)のとおり、メモリベース協調フィルタリングを用いる前処理としてケアプラン文書の特徴語補完を行う。

メモリベース協調フィルタリングは文書構造を保持した推薦が可能である一方で、スパース性の高い文書行列に対しては適用困難である。スパース性軽減のためには主に次元削減による改善が行われるが、ケアプラン文書のようにコーパスが小さく短文を多く含む場合、単語間

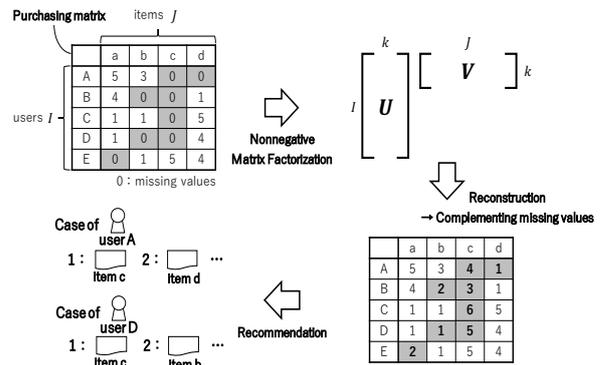


図3 NMFに基づく推薦例

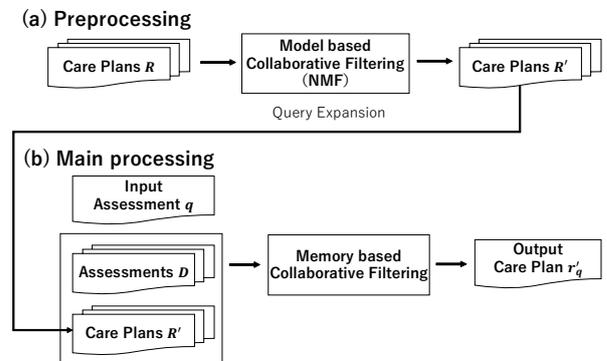


図4 提案手法 概略図

の共起関係を適切に抽出することが困難である。

そこで、NMFに基づくクエリ拡張を考える。NMFは自然言語処理の様々なタスクに利用されており、推薦手法 (モデルベース協調フィルタリング) としても用いられている。また、スパース性の高い行列に対しても比較的有効であるとされており [11]、メモリベース協調フィルタリングと併用したハイブリッド法 [12] の有効性が述べられていることから、メモリベース協調フィルタリングの改善に効果的に作用すると考えられる。本稿では推薦手法としてのNMFを利用し、ケアプラン文書の特徴語を補完する。これにより密な文書行列を作成でき、訓練データ間と単語間の関係を考慮した推薦が可能となる。

5.2 NMF に基づくクエリ拡張

ケアプラン文書行列 \mathbf{R} の各文書ベクトル \mathbf{r} は、ベクトル空間モデルにおいて式 (3) のように表現される。 $w_r(t)$ は単語 t の文書 r における単語重み、 M は語彙集合を表す。

$$\mathbf{r} = (w_r(t_1), w_r(t_2), \dots, w_r(t_M)) \in \mathbb{R}^M \quad (3)$$

ケアプラン文書行列 \mathbf{R} の文書モデルには、簡単のため Bag of Words (BOW) モデルを用いた。BOW モデルにおける単語重み $w_r(t)$ は $n_r(t)$ で表される。ここで、 $n_r(t)$ は文書 r における単語 t の出現数を表す。

次に、NMF に基づくクエリ拡張の流れを示す。

1. ケアプラン文書行列 \mathbf{R} を訓練データ \mathbf{R}_{train} とテストデータ \mathbf{R}_{test} に分割
2. \mathbf{R}_{train} を NMF により行列分解 ($\mathbf{U}_{train}, \mathbf{V}$ を更新)
3. \mathbf{R}_{test} を NMF により行列分解 (\mathbf{U}_{test} を更新)
4. 再構築 $\mathbf{R}_{train} \approx \mathbf{U}_{train} \mathbf{V}$, $\mathbf{R}_{test} \approx \mathbf{U}_{test} \mathbf{V}$
5. 評価値の高い m 単語を追加 ($\mathbf{R}'_{train}, \mathbf{R}'_{test}$ を作成)

このとき、テストデータにおける行列分解では訓練データから求めた各特徴語の潜在ベクトル \mathbf{V} は固定している。

5.3 推薦方法

5.2 節における特徴語が補完されたケアプラン文書行列 \mathbf{R}' を用いて 3 章で述べた新規利用者に対するメモリベース協調フィルタリングを行う。これによりアセスメント \mathbf{q} からケアプラン文書ベクトル \mathbf{r}'_q が生成される。このとき、アセスメントは標準化によりベクトル化し、アセスメント間の類似度算出には式 (4) のピアソン積率相関係数を用いた。

$$sim(\mathbf{q}, \mathbf{d}) = pearson_{\mathbf{q}, \mathbf{d}} = \frac{(\mathbf{q} - \bar{\mathbf{q}}) \cdot (\mathbf{d} - \bar{\mathbf{d}})}{|\mathbf{q} - \bar{\mathbf{q}}| \cdot |\mathbf{d} - \bar{\mathbf{d}}|} \quad (4)$$

また、メモリベース協調フィルタリングを適用する際のケアプラン文書行列 \mathbf{R}' の文書モデルには、Term Frequency and Inverse Document Frequency (TFIDF) モデルを用いた。TFIDF モデルにおける単語重みは式 (5) で表される。

$$w_r(t) = \frac{n_r(t)}{\sum_{t' \in M} n_r(t')} \left(\log \frac{1 + |D|}{1 + df(t)} + 1 \right) \quad (5)$$

ここで、 $df(t)$ は単語 t が出現する文書頻度を表す。

式 (1) より求められたケアプラン文書ベクトル \mathbf{r}'_q を用いて、類似度の高いケアプラン文書を訓練データから N 件検索し、推薦する。ここで、ケアプラン文書間の類似度には式 (6) のコサイン類似度を用いた。

$$sim(\mathbf{r}'_q, \mathbf{r}'_d) = \cos \theta_{\mathbf{r}'_q, \mathbf{r}'_d} = \frac{\mathbf{r}'_q \cdot \mathbf{r}'_d}{|\mathbf{r}'_q| \cdot |\mathbf{r}'_d|} \quad (6)$$

6. ケアマネジメントデータを用いた推薦実験

6.1 実験概要

提案手法と 6 種類のベースラインを用いた推薦実験を行った。入力されたアセスメントを基に複数のケアプラン文書を推薦し、その結果を評価する。提案手法の目的はクエリ拡張によるメモリベース協調フィルタリングの改善である。よって、実験では次の 2 点の確認を行う。

- スパース性の高い文書行列における提案手法の有効性
- メモリベース協調フィルタリング改善のための

クエリ拡張 (特徴語補完) としての NMF の有効性

スパース性の高い文書行列では次元削減手法が頻繁に用いられる。また、クエリ拡張手法としては共起関係や意味関係に基づく手法が存在する。したがって、次元削減手法とクエリ拡張手法のベースラインとの比較実験を行った。

6.2 実験設定

ケアマネジメントデータ (アセスメントとケアプラン文書の組み合わせ) は 1111 ケース存在し、341 名の介護記録から構成されている。アセスメントの項目数は 110 である。ケアプラン文書の詳細と実験設定を次に示す。

- 特徴語: ユニグラム
- ストップワード: 出現数 10 語以下, 出現頻度 0.8 以上
- 1 文書当たり平均特徴語数: 97.4

提案手法において NMF の基底数 k は 50 とした。この値は NMF の目的関数の減少から判断した。また、特徴語の補完数 m は文献 [13] より 25 を採用した。適合ケアプラン数 n は {5, 10, 15} とした。適合ケアプランは正解ケアプラン近傍の訓練データから定めた。実験は 10 分割交差検証によって行い、最大推薦数 N は 15 とした。ケアプラン作成支援システムでは 5 プラン程度の推薦を想定している。

6.3 ベースライン

次元削減手法のベースラインとしては、代表的な Singular Value Decomposition (SVD) [14] と NMF、文書のトピック抽出に利用される Latent Dirichlet Allocation (LDA) [15] を採用した。次元数 k は {5, 10, 15, 50, 100, 500} とした。

クエリ拡張手法のベースラインとしては、共起関係に基づく Pseudo Relevance Feedback-TFIDF (PRF-TFIDF) [16] と PRF-Relevance Model (PRF-RM) [17]、意味関係に基づく PRF-Embeddings (PRF-Emb) [18] を採用した。PRF-TFIDF における疑似関連文書数は {1, 3, 5, 9, 11}、PRF-RM と PRF-Emb におけるパラメータ λ と α は {0.1, 0.2, ..., 0.9}、特徴語の補完数 m は {10, 25} とした。

6.4 評価指標

Mean Average Precision (MAP) と Geometric Mean Average Precision (GMAP)、トップ N 正答率を用いた。

MAP は平均適合率 $AP(u)$ を利用者集合に対して算術平均をとることで算出される。推薦順位を考慮し、上位の推薦結果に大きく影響を受けるため、一部の利用者にはのみ良く適合する推薦に対しても評価が高くなる。

GMAP は $AP(u)$ を利用者集合に対して幾何平均をとることで算出される。MAP と同様に推薦順位を考慮するが、下位の推薦結果の影響も重要視されるため、より多くの利用者にある程度適合する推薦を評価する。

トップ N 正答率 (TNA) は推薦される N アイテムの内適合アイテムが含まれている割合によって評価する。

$$TNA = \frac{1}{|U|} \sum_{u \in U} f_u \quad (7)$$

$$f_u = \begin{cases} 1 & \text{利用者 } u \text{ に対する推薦アイテム } N \\ & \text{の中に適合アイテムが含まれる} \\ 0 & \text{その他} \end{cases} \quad (8)$$

表 1 MAP と GMAP ベースラインとの比較

method	# of relevant plans:5		# of relevant plans:10		# of relevant plans:15	
	MAP	GMAP	MAP	GMAP	MAP	GMAP
Conventional	.08487 ± .036	.05758 ± .029	.1271 ± .046	.09960 ± .039	.1662 ± .054	.1401 ± .049
SVD	.1028 ± .051	.06817 ± .039	.1459 ± .066	.1098 ± .057	.1897 ± .080	.1512 ± .070
NMF	.1078 ± .043	.06497 ± .026	.1551 ± .055	.1050 ± .038	.1944 ± .064	.1417 ± .049
LDA	.1090 ± .046	.06967 ± .031	.1494 ± .053	.1134 ± .039	.1896 ± .055	.1542 ± .044
PRF-TFIDF	.09722 ± .043	.06228 ± .034	.1341 ± .052	.09879 ± .043	.1710 ± .056	.1365 ± .048
PRF-Emb	.08826 ± .043	.06133 ± .033	.1255 ± .047	.1002 ± .039	.1651 ± .053	.1404 ± .047
PRF-RM	.08742 ± .026	.05550 ± .019	.1247 ± .031	.09438 ± .028	.1594 ± .038	.1302 ± .035
Proposed	.1099 ± .055	.07302 ± .045	.1489 ± .062	.1157 ± .055	.1884 ± .071	.1567 ± .064

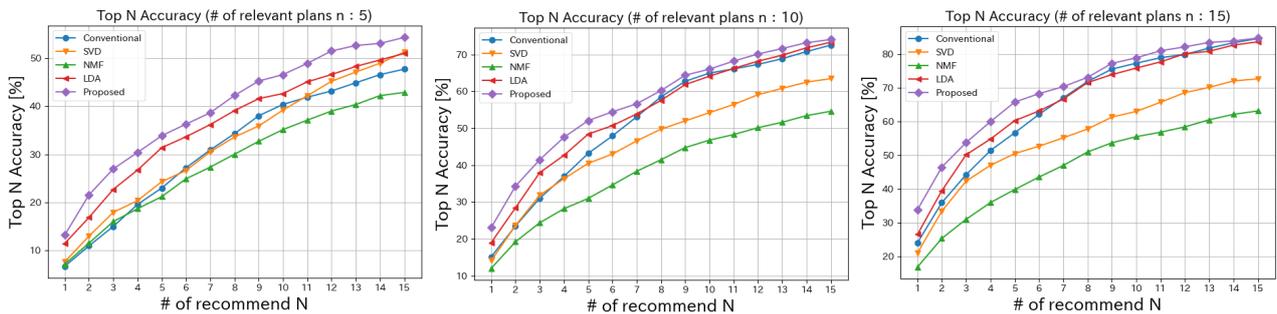


図 5 トップ N 正答率 次元削減手法のベースラインとの比較

トップ N 正答率は推薦順位は考慮せず、適合アイテムが推薦されているか否かのみを評価する。上位にて推薦されていなければ評価されないことはもちろん、一部の利用者にも適切に推薦されていても評価値の向上はなく、評価範囲としては MAP と GMAP の中間と言える。

6.5 実験結果

各ベースラインとの比較実験結果を示す。ベースラインについては、最も評価値の高い結果のみを考える。

表 1 にケアプラン文書行列 R を使用したメモリベース協調フィルタリング (Conventional) と提案手法 (Proposed)、各ベースラインの MAP と GMAP の結果を示す。

6.5.1 次元削減手法のベースラインとの比較

表 1 より、提案手法と次元削減手法はメモリベース協調フィルタリングの改善に有効であることが確認される。提案手法は MAP においては適合ケアプラン数が増加すると NMF や LDA を下回る結果となっているが、GMAP においては常に最も高い値を示している。

図 5 にトップ N 正答率の結果を示す。提案手法は推薦数によらず正答率が最も高いことが確認される。特に適合ケアプラン数が少ない場合に有効であり、 $(n, N) = (5, 5)$ のときには約 10% の改善が見られる。SVD と NMF では、Conventional よりも正答率が低下している場合が多く、推薦数が増加するにつれて顕著となる。次元削減を行った結果、ケアプラン文書間の類似度の差が小さくなり推薦が困難になっていることが原因の一つと考えられる。また、LDA の正答率の推移は提案手法と類似した結果となっており、多くの推薦数において次元削減による効果が確認される。しかし、適合ケアプラン

数と推薦数を増加させたに正答率の低下が見られる。

以上より、次元削減手法は一部の利用者に対しては少ない推薦数で適合ケアプランを推薦可能である。一方で提案手法は上位の推薦結果を維持した上で下位の推薦結果の底上げが可能であり、利用者に依存しない推薦が期待される。

6.5.2 クエリ拡張手法のベースラインとの比較

表 1 より、適合ケアプラン数によらず提案手法がクエリ拡張手法のベースラインを上回っていることから、提案手法の有効性が確認される。一方で、クエリ拡張手法は必ずしもメモリベース協調フィルタリングの改善に繋がるわけではないことが分かる。適合ケアプラン数を増加させた際の Conventional と比較すると、PRF-TFIDF では GMAP の低下、PRF-Emb では MAP の低下が確認される。

図 6 にトップ N 正答率の結果を示す。想定される推薦数が $N = 5$ プラン程度であることを考慮すると、適合ケアプラン数によらず推薦数 $N = 5$ までは各クエリ拡張手法の推移は同様である。提案手法は各クエリ拡張手法の正答率を上回っており、メモリベース協調フィルタリング改善のためのクエリ拡張としての NMF の優位性が確認される。推薦数 5 以降では、PRF-TFIDF や PRF-RM では Conventional の正答率を下回る場合が多く有効性は確認されないが、PRF-Emb は Conventional を上回っており、提案手法と類似した正答率の推移となっている。

以上より、PRF-TFIDF は利用者に依存する推薦が行われ、PRF-Emb は少ない推薦数の場合適合ケアプランの推薦が困難であると考えられる。

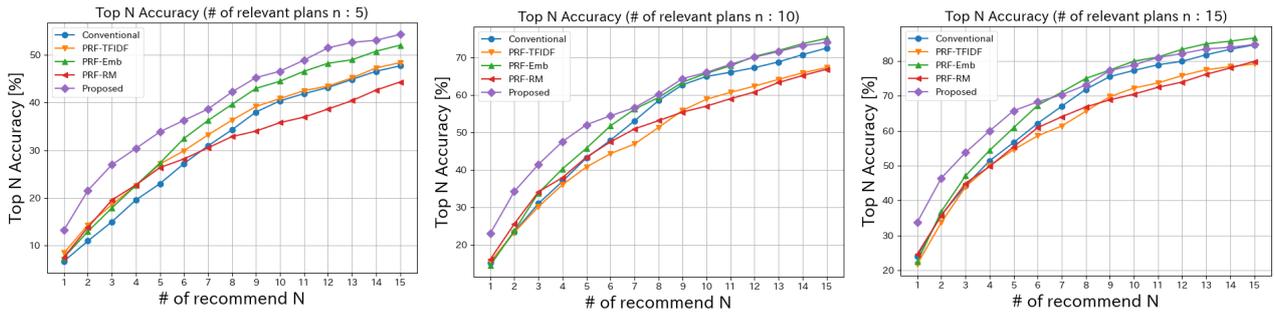


図 6 トップ N 正答率 クエリ拡張手法のベースラインとの比較

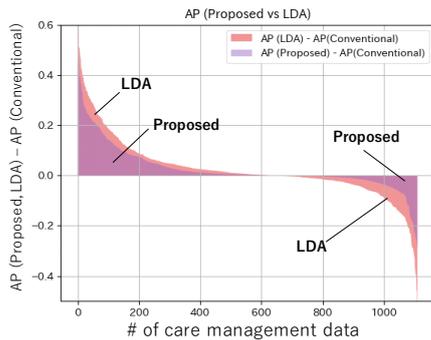


図 7 AP の改善度比較 (Proposed, LDA)

表 2 補完特徴語

Method	補完 単語 [%]	未補完 単語 [%]	既存 単語 [%]	欠損 単語 [%]
PRF-TFIDF	98.91	1.093	46.96	53.04
Proposed	80.33	19.67	37.12	62.98

6.6 Average Precision (AP) による改善度の比較

各ケースにおける $AP(u)$ の比較を行い、改善度を確認する。6.5.1 項において、最も提案手法と類似した結果となった LDA を比較対象とする。改善度 $Imp(u)$ は式 (9) のように定める。 $AP(\cdot, u)$ は各手法の AP を表す。

$$Imp(u) = AP(\cdot, u) - AP(Conventional, u) \quad (9)$$

図 7 に提案手法と LDA の改善度を示す。 $AP(u)$ が改善されたケース数には大きな差は確認されないが、LDA は $AP(u)$ の変化が大きく、改善した場合には提案手法を上回る向上が見られる。しかし、適切な次元削減が行われなかった場合、 $AP(u)$ の大きな減少が生じている。この結果は大域的に特徴を捉えているとは言えず、ケアプラン作成支援システムには適していない。したがって、より推薦結果の底上げが行われている提案手法が有効であると考えられる。

6.7 補完された特徴語に関する比較

補完された特徴語の比較を行う。一度でも補完された特徴語を補完単語、一度も補完されなかった特徴語を未補完単語とし、初期のケアプラン文書に含まれている特徴語を既存単語、含まれていない特徴語を欠損単語とする。 $n = 5$ において MAP と GMAP の値の高い PRF-TFIDF に着目し、提案手法と比較する (表 2)。 PRF-TFIDF の方がより多くの種類の特徴語を補完しており、多様性のあるクエリ拡張が実現されている。一

方で、提案手法は欠損単語を多く補完しており、クエリ拡張として有効に機能していることが確認される。

次に、特徴語補完の効果を考える。補完される特徴語には文献 [19] より次の効果があり、これらのバランスにより適切な特徴語補完が実現されると考えられる。

1. Background Words

利点 表現が特徴的な文書をケアプラン文書に近付け、推薦結果を底上げする

欠点 類似文書が増加し、推薦が困難になる

2. Topical Words

利点 重みの大きな単語であり、文書の特徴付ける

欠点 不適切な補完であった場合に悪影響を及ぼす

上記の効果を踏まえ、図 8 に各特徴語の 1 文書当たりの補完数と TFIDF 値の補完文書平均を示す。TFIDF 値の補完文書平均が大きい単語は Topical Words、小さい単語は Background Words と考えられる。

図 8 より、PRF-TFIDF は TFIDF 値の大きな特徴語を多く補完しているが、提案手法では TFIDF 値の小さな特徴語も一定数補完していることが確認される。提案手法において TFIDF 値の大きな特徴語としては、要介護度の高い利用者のケアプラン文書に見られる「排尿」や「寝たきり」、「負担」や要介護度の低い利用者の趣味に見られる「読書」などが挙げられ、これらの単語はケアプラン文書の特徴付けていると考えられる。また、「苦痛」や「回復」、「骨折」、「入院」など多くの場面で使用可能な特徴語は TFIDF 値が小さく、ケアプラン文書に含まれている可能性が高い単語であると考えられる。

提案手法は PRF-TFIDF と比較して Background Words を多く補完しており、推薦結果の底上げに繋がったと考えられる。

7. おわりに

メモリベース協調フィルタリングをケアプラン文書行列に対して用いる際の推薦性能改善のために、前処理としてクエリ拡張を行う推薦手法を提案した。ケアプラン文書行列に対して NMF に基づくクエリ拡張 (特徴語補完) を行うことで密な文書行列が作成され推薦性能を改善できることを示した。

提案手法は上位の推薦結果を維持した上で下位の推薦結果の底上げを達成でき、特定の文書の特徴付ける単語だけでなく、ケアプラン文書に含まれるべき単語も同時に補完していることを明らかにした。

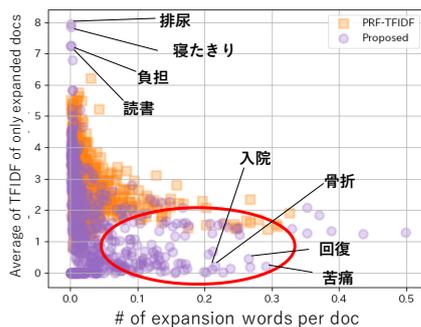


図8 各特徴語の1文書当たりの補完数とTFIDF値の補完文書平均

本稿では、特徴語の補完数とTFIDF値に関する考察を行ったが、推薦性能との相関関係に対する知見は得られていない。今後は次の検討、分析を行う必要がある。

1. 補完された特徴語の性質と評価指標の相関分析
2. 他のベースラインとの比較

参考文献

- [1] Dat Quoc Nguyen, Richard Billingsley, Lan Du, and Mark Johnson. Improving topic models with latent feature word representations. *Transactions of the Association for Computational Linguistics*, Vol. 3, pp. 299–313, 2015.
- [2] 大串葉子. 訪問介護におけるケアマネジャーのict利用実態と情報需要. *日本情報経営学会誌*, Vol. 37, No. 1, pp. 42–49, (2017).
- [3] 志村いづみほか. 日本居宅介護支援事業所の介護支援専門員が感じている介護予防ケアマネジメントの困難とその対応. *四條畷学園大学看護ジャーナル*, pp. 19–27, (2017).
- [4] Ajit Paul Singh and Geoffrey J. Gordon. Relational learning via collective matrix factorization. In *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 650–658, 2008.
- [5] Deepak Agarwal and Bee-Chung Chen. flda: matrix factorization through latent dirichlet allocation. In *Proceedings of the third ACM international conference on Web search and data mining*, pp. 91–100, 2010.
- [6] Suvash Sedhain, Scott Sanner, Darius Braziunas, Lexing Xie, and Jordan Christensen. Social collaborative filtering for cold-start recommendations. In *Proceedings of the 8th ACM Conference on Recommender systems*, pp. 345–348, 2014.
- [7] Daniel D. Lee and H. Sebastian Seung. Learning the parts of objects by non-negative matrix factorization. *Nature*, Vol. 401, No. 6755, pp. 788–791, 1999.
- [8] Yanen Li, Jia Hu, ChengXiang Zhai, and Ye Chen. Improving one-class collaborative filtering by incorporating rich user information. In *Proceedings of the 19th ACM international conference on Information and knowledge management*, pp. 959–968, 2010.
- [9] Sheng Zhang, Weihong Wang, James Ford, and Fillia Makedon. Learning from incomplete ratings using non-negative matrix factorization. In *Sixth SIAM International Conference on Data Mining*, pp. 549–553, 2006.
- [10] Hamed Zamani, Javid Dadashkarimi, Azadeh Shakery, and W. Bruce Croft. Pseudo-relevance feedback based on matrix factorization. In *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*, pp. 1483–1492, 2016.
- [11] Francesco Ricci, Lior Rokach, Bracha Shapira, and Paul B Kantor. Recommendation systems handbook. *Heidelberg (ao): Springer*, 2011.
- [12] Shyong K Lam Al Mamunur Rashid, George Karypis, and John Riedl. Clustknn: a highly scalable hybrid model-& memory-based cf algorithm. *Proceeding of WebKDD*, Vol. 2006, , 2006.
- [13] Saar Kuzi, Anna Shtok, and Oren Kurland. Query expansion using word embeddings. In *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*, pp. 1929–1932, 2016.
- [14] Nathan Halko, Per-Gunnar Martinsson, and Joel A. Tropp. Finding structure with randomness: Probabilistic algorithms for constructing approximate matrix decompositions. *Siam Review*, Vol. 53, No. 2, pp. 217–288, 2011.
- [15] David M. Blei, Andrew Y. Ng, and Michael I. Jordan. Latent dirichlet allocation. *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022, 2003.
- [16] Rodrigo Nogueira and Kyunghyun Cho. Task-oriented query reformulation with reinforcement learning. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, pp. 574–583, 2017.
- [17] Victor Lavrenko and W. Bruce Croft. Relevance-based language models. In *Proceedings of the 24th annual international ACM SIGIR conference on Research and development in information retrieval*, Vol. 51, pp. 120–127, 2001.
- [18] Dwaipayan Roy, Debjyoti Paul, Mandar Mitra, and Utpal Garain. Using word embeddings for automatic query expansion. *arXiv preprint arXiv:1606.07608*, 2016.
- [19] Chengxiang Zhai and John Lafferty. Model-based feedback in the language modeling approach to information retrieval. In *Proceedings of the tenth international conference on Information and knowledge management*, pp. 403–410. ACM, 2001.