

推薦論文

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

兵頭 幸起¹ 濱上 知樹^{1,a)}

受付日 2020年3月5日, 採録日 2020年10月6日

概要: 超高齢化と労働人口減が進む日本において、機械学習による介護分野の支援に期待が高まっている。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メモリベース協調フィルタリングを用いて推薦する「ケアプラン作成支援システム」の実現を目指す。メモリベース協調フィルタリングでは文書構造を保持した推薦が期待される。しかし、訓練データ間、単語間の関係が考慮されないことやスパース性の高い文書行列に対して適用困難であることが課題となる。そこで、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、ケアプラン文書に対して非負値行列因子分解 (NMF) に基づくクエリ拡張を行う推薦手法を提案する。実験では、実際のケアマネジメントデータを用いた推薦を行うことで提案手法による推薦性能改善を確認した。また、補完される特徴語の性質を考察することにより、提案手法は、上位の推薦精度を維持した上で下位の推薦精度の向上を達成可能であることを明らかにした。

キーワード: 協調フィルタリング, クエリ拡張, 非負値行列因子分解, 推薦システム, ケアマネジメント

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

KOKI HYODO¹ TOMOKI HAMAGAMI^{1,a)}

Received: March 5, 2020, Accepted: October 6, 2020

Abstract: In Japan's rapidly aging society, there are high expectations for machine learning to support the nursing care sector. This study aims to develop a "care planning support system" that recommends care plan documents based on past care records using memory-based collaborative filtering. This method is expected to recommend keeping the document structure. However, it is a issue that relationships between training data and between words are not taken into consideration, and it is difficult to apply matrices with high sparsity. In consideration of these problems, we perform query expansion based on nonnegative matrix factorization for care plan documents as preprocessing to apply memory-based collaborative filtering. In the experiments, we confirmed the performance improvement by the proposed method using the real care management data. In addition, we examined complementary feature words and clarified their properties.

Keywords: collaborative filtering, query expansion, nonnegative matrix factorization, recommendation system, care management

1. はじめに

世界に類をみない超高齢社会の到来とともに、介護を必要とする「要介護高齢者」に対するケアマネジメントの重

要性が増している。ケアマネジメントの根幹をなすケアプランはケアマネージャによって作成される。ケアマネージャの役割は、利用者の状態・所見であるアセスメントから介護度を維持または改善するケアプランを作成することである。優れたケアプランは介護の質を上げるために重

¹ 横浜国立大学大学院理工学府
Graduate School of Engineering Science, Yokohama National University, Yokohama, Kanagawa 240-8501, Japan

^{a)} hamagami@ynu.ac.jp

本論文の内容は2019年9月のFIT2019第18回情報科学技術フォーラムにて報告され、同プログラム委員長により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

要であるが、そのようなケアプランを作成できる経験豊かなケアマネージャは不足している。また、ケアプランの作成には多くの時間と労力が必要であり、その質は経験・能力に大きく依存する。したがって、ケアマネージャの負担増加やケアプランの質のばらつきも問題である。今後の高齢者の増加とケアマネージャの不足をふまえると、ケアマネージャの負担軽減と、ケアプランの質の向上・平準化のための自動化が必要である。過去の多くのアセスメントと優れたケアプランの関係を機械学習によって学習させることで、この目的に資することが期待できる。本研究では、このような機械学習に基づく「ケアプラン作成支援システム」の実現を目指している。

本研究では、アセスメントとケアプランの関係を対応づける手段として、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を用いる。メモリベース協調フィルタリングは近傍法に基づく手法であり、大量のデータが存在しない場合でも入力に依存せずケアプラン文書らしさを失うことがない。また、既存のケアプラン文書の単語構成がベースとなるため、ケアプランの文書構造を保持した推薦が期待でき、極端な誤りを防ぐことが可能である。このような利点から、メモリベース協調フィルタリングによる推薦はケアマネージャがケアプランを作成する支援に有効と考えられる。一方で、次のような課題も存在する。

- (1) 訓練データ間の関係が考慮されない
- (2) 単語間の関係が考慮されない
- (3) 学習データがスパースな場合に精度が低下する

特に、本研究で扱うケアプランの文書行列は、文書数に対して語彙数が多く1文書に含まれる特徴語数は少ない。その結果、文書行列はスパースとなり精度の低下が問題になる。スパース性軽減のためには、文書行列に対して次元削減を行うことが有効であるが、ケアプラン文書のようにコーパスサイズ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いる [1]。

そこで本論文では、前処理としてケアプラン文書に対してクエリ拡張を行う推薦手法を提案する。クエリ拡張には、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。ケアプラン文書をクエリとし、共起関係に基づく特徴語補完を行うことで、訓練データ間や単語間の関係を考慮した文書表現が得られる。また、ケアプラン文書のスパース性軽減に加え、ケアマネージャによるケアプラン文書の質のばらつきの軽減も期待できる。

以下、2章ではケアマネジメントについて述べる。3章では協調フィルタリングの従来手法について述べる。4章ではクエリ拡張として利用する非負値行列因子分解について述べる。5章ではクエリ拡張に基づく文書表現によるケアプラン文書推薦について述べる。6章では実データを用いた推薦実験の結果を示す。

2. ケアマネジメント

2.1 ケアマネジメントデータ

図1にケアマネジメントの流れを示す。図中の手順のうち、アセスメントの結果からケアニーズを読み取り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、多くの時間と労力が必要であり、その質は経験・能力に依存する。その結果、ケアマネージャの負担増加や、ケアプラン文書の質のばらつき、介護結果のフィードバックが反映されにくいことが問題となっている。

表1にケアマネジメントに関する用語の説明を示す。アセスメントには、1. 医療情報、2. 身体機能、3. 入浴・整容、4. 食事・水分摂取、5. 排泄、6. 内服・金銭・電話・環境整備・視力・聴力・意思疎通、7. 記憶・理解・見当識・周辺症状の7種類の内容が含まれる。項目としては、二値項目と選択項目が存在する。二値項目では眼鏡使用などの有無を問う。選択項目では、食事摂取などについて自立・見守り・一部介助・全介助の程度を問う。ケアプラン文書は自然言語で記述されており、ニーズ、長期目標、短期目標、サービス内容により構成されている。

2.2 ケアプラン作成支援システム

図2に本研究におけるケアプラン作成支援システムを示す。システムは、ケアマネージャのケアプラン設計を支援するために、入力された活動利用者のアセスメント（図2左）に対してケアプラン文書の候補を推薦する（図2右）。

ケアプラン文書の候補の推薦にあたり最も単純な方法は、活動利用者と標本利用者のアセスメント間の類似度を基に、類似した標本利用者のケアプラン文書を流用することである。しかし、ケアプラン文書のように個人情報も多く含む場合には、アセスメントの近傍空間とケアプランの




図1 ケアマネジメントの流れ

Fig. 1 Workflow of a care management.

表1 ケアマネジメントの用語

Table 1 The terms in the care management.

用語	説明
アセスメント	ヒアリングにより得られる利用者情報
ケアプラン文書	アセスメントを基に作成される介護計画書
標本利用者	ケアマネジメントデータが登録されている介護対象者
活動利用者	新規の介護対象者

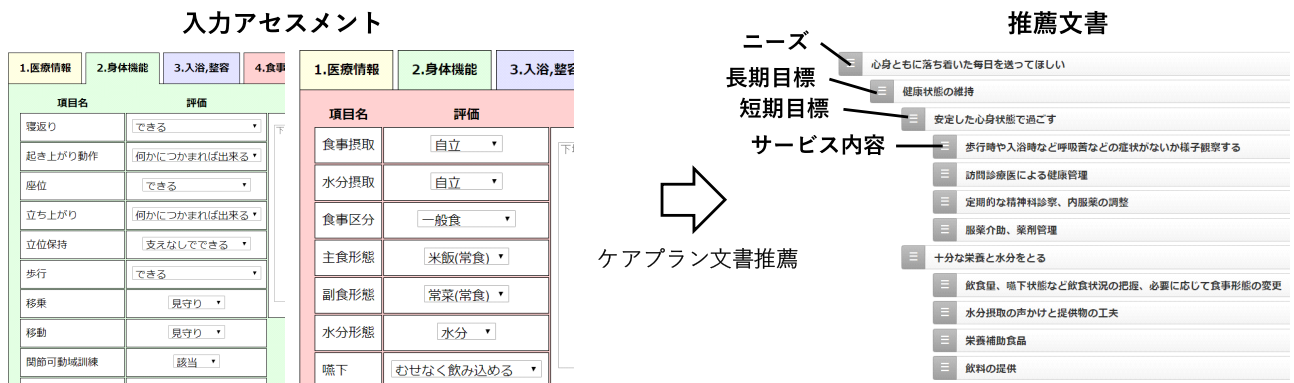


図 2 ケアプラン作成支援システム
Fig. 2 The care planning support system.

近傍空間が対応づいているとは限らず、単純な類似に基づく候補選択は多くのノイズを含むことになる。

また、活動利用者固有の情報に基づく詳細なケアプランを後から追加することを前提とすると、本システムが提案すべきケアプランの候補は、ケアプランの骨格をなす典型的な活動の組合せなどを示す長中期目標とサービスの項目までにすることが望まれる。本論文では、図 2 右に示すようなケアプランの大域的なアウトラインを示すことで、ケアマネージャの作業を支援する。

3. ケアプラン文書の推薦

3.1 協調フィルタリング

協調フィルタリングは代表的な推薦手法の 1 つである。複数の類似した行動をとる標本利用者の嗜好データから特定の活動利用者の関心の有無や評価値を予測し、推薦すべきアイテムを抽出する。特に本研究のように新規利用者に対する推薦は、メモリベース法とモデルベース法 [2], [3] の大きく 2 種類のアプローチに分けられる。

メモリベース協調フィルタリングは近傍法に基づく手法であり、大量のデータが存在しない場合でも入力に依存せずケアプラン文書らしさを失うことがない。また、既存のケアプラン文書の単語構成がベースとなるため、ケアプランの文書構造を保持した推薦が期待される。このような推薦は極端な誤りを防ぐことが期待される。

モデルベース協調フィルタリングは一般的にメモリベース協調フィルタリングよりも高い推薦精度が期待される。一方でパラメータ数が多くチューニングが困難であり、また、大量のデータが存在しない場合には過学習に陥りやすい。

以上より、システムに求められる要件とケアマネジメントデータの特性から、本研究ではメモリベース協調フィルタリングに着目する。

3.2 メモリベース協調フィルタリング

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 [4] が提案されており、活動利用者は類似した行動をと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。

$$r_q = \frac{\sum_{d \in D} \text{sim}(q, d) \cdot r_d}{\sum_{d \in D} \text{sim}(q, d)} \quad (1)$$

本研究においては q と d はアセスメントに、 r_q と r_d はケアプラン文書に対応し、 r_q は活動利用者のケアプラン文書ベクトル、 D は標本利用者集合、 q は活動利用者のアセスメントベクトル (外部情報)、 d は標本利用者のアセスメントベクトル (外部情報)、 r_d は標本利用者のケアプラン文書ベクトルを表し、 $\text{sim}(\cdot)$ 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。

メモリベース協調フィルタリングは、極端な誤りを防ぐことが期待されシステムの要件を満たす。一方で、外部情報 (q, d) の類似度に依存した予測であるため、 r_d における訓練データ間や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抽出が困難であることが懸念される。

4. 非負値行列因子分解

非負値行列因子分解 (NMF: Nonnegative Matrix Factorization [5]) は 0 以上の値を持つ行列を解析する手法である。主に信号処理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 [6], [7]。

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、 $R \in \mathbb{R}^{I \times J}$ は文書行列、 I は文書数、 J は語彙数、 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 $V \in \mathbb{R}^{k \times J}$ はそれぞれ文書と特徴語の潜在ベクトルを表す。式 (2) を二乗誤差最小化問題として扱い、得られた U, V の内積をとり、再構築を行うことで欠損値の推定が可能となる。例として、図 3 に NMF に基づ

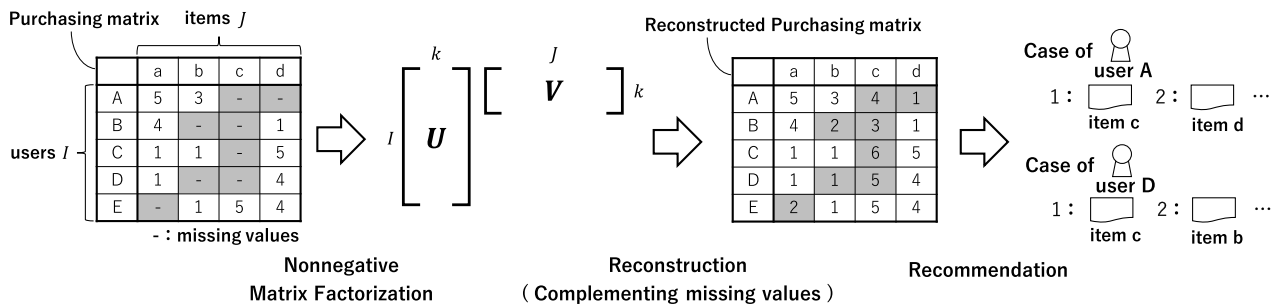


図 3 NMF に基づく購買履歴を用いたアイテム推薦の事例

Fig. 3 Example of item recommendation using purchase history based on NMF.

く購買履歴を用いたアイテム推薦の事例を示す。ここではユーザの購買履歴を用いたアイテムの推薦を表している。NMFによりユーザとアイテムの潜在ベクトルを求め、購買行列の再構築を行うことで欠損値を補完する。その後、再構築結果を基に各ユーザへアイテムの推薦を行う。本研究においては、図 3 におけるユーザがケアプラン文書、アイテムが特徴語に対応している。ケアプラン文書行列の欠損値を補完し、クエリ拡張を行う。

NMFに基づくクエリ拡張の関連研究としては RFMF [8] があげられる。RFMF 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 の組合せによってクエリ拡張を行っている。疑似関連性フィードバックでは、文書ベクトル間の類似度を基に初期クエリ近傍の文書を疑似的に関連文書と見なす。これを疑似関連文書と呼び、疑似関連文書を用いてクエリ拡張を行う。クエリ拡張には大規模コーパスが用いられることが多く、一般的に疑似関連文書数はクエリに依存せず一定の値が設定される。しかし、コーパスサイズが小さなケアプラン文書では、クエリと類似度が低い文書が疑似関連文書として扱われてしまい、適切なクエリ拡張が行われない可能性がある。したがってこのような場合には、クエリの近傍文書だけではなくコーパス全体を用いたクエリ拡張が適切であると考えられる。これにより極端に不適切な特徴語補完を防ぐことが可能となる。

5. クエリ拡張に基づく文書表現を用いたケアプラン文書推薦

5.1 概要

3.2 節のメモリベース協調フィルタリングの改善手法として、クエリ拡張に基づく文書表現を用いたケアプラン文書推薦を提案する。図 4 に提案手法の概略図を示す。

図 4 (a) では、前処理としてケアプラン文書の特徴語補完を行う。ここでアセスメントは、二値項目と選択項目で構成されている。一方、ケアプラン文書は、自然言語で記述され自由度が高い。そのため、ケアプラン文書の方がケアマネージャによる差が生じやすく、特徴をとらえることが困難である。そこで、ケアプラン文書に対して NMF に

よる特徴語補完を行う。

図 4 (b) では、メモリベース協調フィルタリングを行う。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、訓練データ間や単語間の関係を考慮することができず、スパース性の高い行列に対しては向いていない。この課題に対して、NMF は効果的に作用すると考えられる。密な文書行列を作成することで、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。NMF は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 [9]、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 [10] の有効性も述べられている。

5.2 NMF に基づくクエリ拡張

図 4 (a) Preprocess の詳細を述べる。ケアプラン文書行列 R の各文書ベクトル 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。 $w_r(t)$ は特徴語 t の文書 r における単語重み、 M は語彙集合を表す。

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

ケアプラン文書行列 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 における特徴語 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。クエリ拡張前の訓練データ R_{train} からクエリ拡張後の訓練データ R'_{train} を作成する。ここでは、4 章で述べたようにコーパス全体を用いたクエリ拡張を行う。

- (1) 訓練データ R_{train} を NMF により行列分解 (U_{train}, V を更新)
- (2) 再構築 $R_{train} \approx U_{train}V$
- (3) 再構築結果を基に補完された欠損値のうち、推定値の高い m 単語を追加 (R'_{train} を作成)

5.3 推薦方法

図 4 (b) Main process の詳細を述べる。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 R'_{train} を用いて 3.2 節で述べた新規利用者に対するメモリベース協調フィ

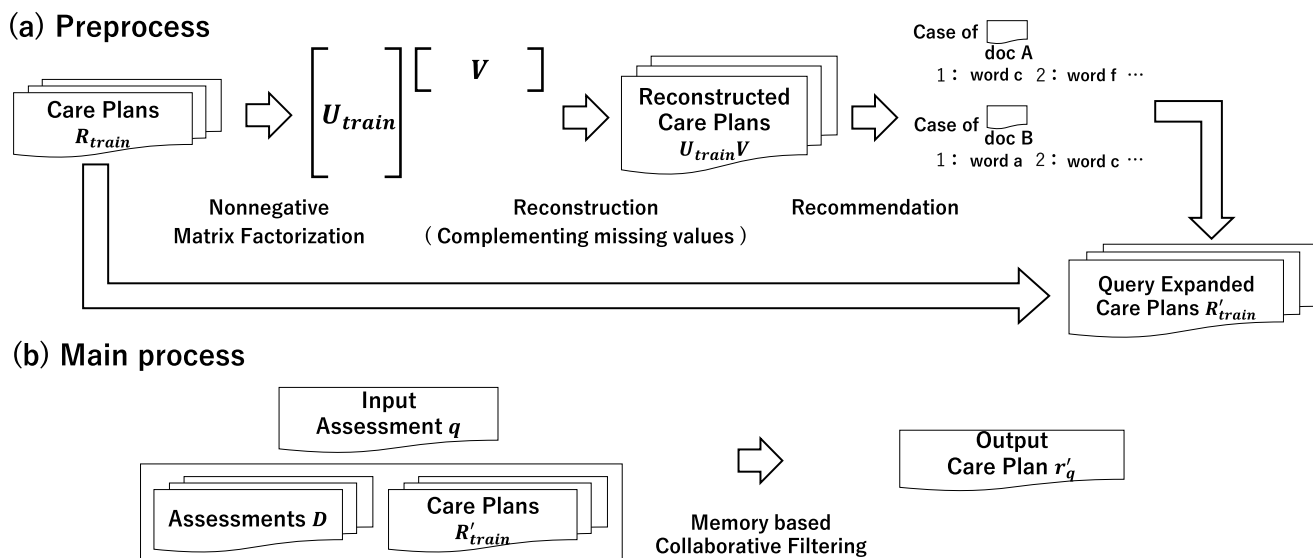


図 4 クエリ拡張に基づく文書表現を用いたケアプラン文書推薦 概略図 (a) NMF に基づくクエリ拡張, (b) メモリベース協調フィルタリングに基づく文書推薦

Fig. 4 Schematic of care plan document recommendations using document representation based on query expansion. (a) Query expansion based on NMF. (b) Document recommendation based on memory-based collaborative filtering.

ルタリングを行う。これによりアセスメント q からケアプラン文書ベクトル 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。

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

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の文書モデルには、自然言語処理で広く用いられている Term Frequency and Inverse Document Frequency (TFIDF) モデルを採用した。TFIDF モデルを用いることで特徴的な単語を強調することができ、推薦性能向上が期待される。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、 $df(t)$ は特徴語 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 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。式 (4) と構造上同様であるが、TFIDF モデルで表される文書ベクトルに対しては中心化を行う処理に意味はないため、コサイン類似度を採用した。

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

5.4 ケアプラン文書における特徴語補完の効果

補完される特徴語には次の効果があることが知られてい

る [11]。これらのバランスにより適切な特徴語補完を行う。

(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、推薦結果の精度を向上させる

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

提案手法ではコーパス全体を用いて補完する特徴語を決定するため、Background Words が多く補完されると考えられる。すなわち、ケアプラン文書における Background Words の補完は次のような効果が期待される。

- 多くの適切なケアプラン文書が上位に推薦される
- 多くの利用者に対して適切なケアプラン文書が推薦される

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合せ）は 1,111 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 ($df(t) \leq 10$)，出現頻度 0.8 以上 ($\frac{df(t)}{|D|} \geq 0.8$)
- 1 文書あたり平均特徴語数：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 [12] より 25 を採用した。適合ケアプラン数 n は {5, 10, 15} とした。本論文における適合ケアプランは、正解ケアプラン近傍の訓練データから定めた疑似的な正解ケアプランである。ここで、正解ケアプランはアセスメントから実際に作成されたケアプランを表す。また、適合ケアプランは k -近傍法により定め、距離関数にはコサイン類似度を用いた。実験では、各アセスメントに対応する適合ケアプランが推薦されることを評価する。実験は 10 分割交差検証によって行い、推薦数 N の最大値は 15 とした。ケアプラン作成支援システムでは $N = 5$ 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) [13] と NMF、文書のトピック抽出に利用される Latent Dirichlet Allocation (LDA) [14] を採用した。次元数 k は {5, 10, 15, 50, 100, 500} とした。次元削減手法は、クエリ拡張を行わずケアプラン文書行列 R の文書モデルに TFIDF モデルを用いた文書ベクトルに対して次元削減を行った。また、NMF による次元削減とは、式 (2) において欠損値を 0 で補完して行列分解を行った際に得られる U を表す。

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) [15] と PRF-Relevance Model (PRF-RM) [16]、意味関係に基づく PRF-Embeddings (PRF-Emb) [17] 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)，Top N Accuracy (TNA) を用いた。

MAP は平均適合率 AP 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、一部の利用者にのみよく適合する推薦に対しても評価が高くなる。

$$\text{MAP} = \frac{1}{|R|} \sum_{a \in R} AP(a) \quad (7)$$

$$AP(a) = \frac{\sum_{e=1}^N \text{Precision}@e \cdot f_e}{\# \text{ of relevant items}} \quad (8)$$

$$f_e = \begin{cases} 1 & \text{if } x_{a,e} \in \mathcal{Y}_a \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

ここで、 $x_{a,e}$ は活動利用者 a に対して e 番目に推薦されたケアプラン文書、 \mathcal{Y}_a は活動利用者 a に対する適合ケアプラン集合を表す。

GMAP は平均適合率 AP 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広く適合する推薦を評価する。

$$\text{GMAP} = \exp \left(\frac{1}{|R|} \sum_{a \in R} \ln (AP(a) + \epsilon) \right) - \epsilon \quad (10)$$

ここで、 ϵ は十分に小さい値を表しており、実験では 10^{-5} とした。

TNA は式 (11) で表される。推薦される N 個のケアプランのうち適合ケアプランが含まれている割合を評価するため、MAP や GMAP と異なり推薦順位を考慮しない。

$$\text{TNA} = \frac{1}{|R|} \sum_{a \in R} g_{a,N} \quad (11)$$

$$g_{a,N} = \begin{cases} 1 & \text{if } \mathcal{X}_{a,N} \cap \mathcal{Y}_a \neq \phi \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

ここで、 $\mathcal{X}_{a,N}$ は活動利用者 a に対して推薦された N 個のケアプラン集合を表す。

実際のシステムにおける推薦数は $N = 5$ 程度と想定されている。ここで、MAP と GMAP は適合ケアプランが推薦された時点をそれぞれ考慮するため、MAP と GMAP における評価では、推薦数 $N = 5$ において適合ケアプランが推薦されているか否かは判断できない。そこで、TNA により各推薦数 N において、適合ケアプランが 1 つでも推薦されているか否かを確認する。ケアプラン作成支援システムは大域的な推薦が目的であるため、より多くの利用者に広く適合する推薦を評価する GMAP が最も重要視すべき評価指標となる。

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 2 にケアプラン文書行列 R を使用したメモリベース協

表 2 MAP と GMAP ベースラインとの比較

Table 2 MAP and GMAP (comparison with baseline method).

method	# of relevant plans:5		# of relevant plans:10		# of relevant plans:15	
	MAP	GMAP	MAP	GMAP	MAP	GMAP
Conventional	0.0849 ± 0.0355	0.0576 ± 0.0292	0.127 ± 0.0460	0.0996 ± 0.0392	0.166 ± 0.0544	0.140 ± 0.0486
SVD	0.103 ± 0.0505	0.0682 ± 0.0387	0.146 ± 0.0660	0.110 ± 0.0569	0.190 ± 0.0803	0.151 ± 0.0703
NMF	0.108 ± 0.0425	0.0650 ± 0.0259	0.155 ± 0.0554	0.105 ± 0.0384	0.194 ± 0.0642	0.142 ± 0.0487
LDA	0.109 ± 0.0464	0.0697 ± 0.0311	0.149 ± 0.0527	0.113 ± 0.0387	0.190 ± 0.0546	0.154 ± 0.0437
PRF-TFIDF	0.0972 ± 0.0429	0.0623 ± 0.0344	0.134 ± 0.0515	0.0988 ± 0.0429	0.171 ± 0.0559	0.137 ± 0.0482
PRF-Emb	0.0883 ± 0.0426	0.0613 ± 0.0330	0.126 ± 0.0474	0.100 ± 0.0394	0.165 ± 0.0533	0.140 ± 0.0472
PRF-RM	0.0874 ± 0.0257	0.0555 ± 0.0194	0.125 ± 0.0314	0.0944 ± 0.0281	0.159 ± 0.0380	0.130 ± 0.0349
Proposed	0.110 ± 0.0551	0.0730 ± 0.0445	0.149 ± 0.0617	0.116 ± 0.0553	0.188 ± 0.0711	0.157 ± 0.0641




図 5 Top N Accuracy 次元削減手法のベースラインとの比較

Fig. 5 Top N Accuracy (comparison with baseline of dimensional reduction method).

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 2 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 においてはつねに最も高い値を示している。これは, 多くの適合ケアプランが上位に推薦されていることを表している。

図 5 に Top N Accuracy の結果を示す。横軸は推薦数 N , 縦軸は正答率 TNA を表す。推薦数 N を変化させたときの正答率 TNA の推移を示す。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 1 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とき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

手法は上位の推薦精度を維持したうえで下位の推薦精度の向上が可能であり, 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 2 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。特に GMAP における評価値向上が顕著であり広く適合する推薦が達成されている。ベースラインの中では PRF-TFIDF が MAP, GMAP とともに最も高い評価結果となっている。一方で, クエリ拡張手法が必ずしもメモリベース協調フィルタリングの改善につながるわけではないことが分かる。

図 6 に Top N Accuracy の結果を示す。図 5 同様に, 推薦数 N を変化させたときの正答率 TNA の推移を示す。提案手法はベースライン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。クエリ拡張では一般的に, 初期クエリの近傍文書集合を用いて補完単語を決定する。一方, 提案手法ではコーパス全体を用いて補完単語を決定するためケアプラン文書に含まれるべき特徴語が多く補完され, ケアプランのように収集が困難なデータに対しても適切な補完が行われたと考えられる。ベースラインの推移は $N = 5$ までは同様である。想定される推薦数が $N = 5$ 程度であることを考慮すると, クエリ拡張手法の有効性が確認される。 $N = 5$ 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




図 6 Top N Accuracy クエリ拡張手法のベースラインとの比較

Fig. 6 Top N Accuracy (comparison with baseline of query expansion method).

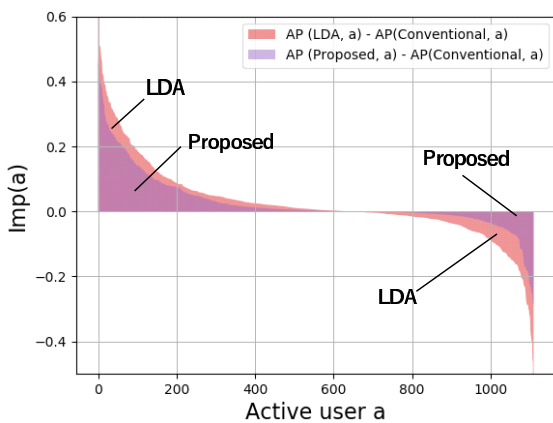


図 7 AP の改善度比較 (Proposed, LDA)

Fig. 7 The comparison of the improvement of AP (Proposed vs. LDA).

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。

6.6 Average Precision (AP) による改善度の比較

各ケースにおける AP の比較を行い、改善度を確認する。6.5.1 項において、最も GMAP における評価結果が高く、提案手法と類似した結果となった LDA を比較対象とする。適合ケアプラン数 $n = 5$ の結果を用いる。改善度 $Imp(a)$ を式 (13) のように定める。 $AP(\cdot, a)$ は利用者 a の各手法の AP を表す。 $AP(Conventional, a)$ は利用者 a の Conventional における AP を表す。

$$Imp(a) = AP(\cdot, a) - AP(Conventional, a) \quad (13)$$

図 7 に提案手法と LDA の改善度を示す。横軸は利用者 a 、縦軸は改善度 $Imp(a)$ を表す。この図は、各利用者の改善度を大きい順にソートした結果である。AP 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 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、負の値を取る領域に着目すると、LDA

は提案手法と比較して結果が悪くなるケースが多くその度合いも大きい。この結果は大域的に特徴をとらえていないとはいえず、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、AP の値の変化が小さく広く適合する推薦が行われている提案手法が有効であると考えられる。

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。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、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、大域的に特徴をとらえた推薦を達成した。これにより、より多くの利用者に対して広く適合する推薦が実現され、また、単語の重要度を確認できることから解釈性も損なうことがない。したがって、本研究におけるケアプラン作成支援システムの導入により、ケアマネージャの業務効率化が期待できる。

本論文ではケアプラン文書を文書行列として扱い、スパース性軽減のために特徴語を補完した。したがって提案手法は、自然言語のようにスパース性の高いデータの推薦においては同様な効果が得られると考えられる。

一方、本論文では特徴語補完と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

謝辞 推薦実験に用いたケアマネジメントデータの収集にご協力いただいた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の寺尾勇一氏、林慧子氏、佐野貴洋氏、竹林奈々子氏に感謝の意を表します。

参考文献

[1] Nguyen, D.Q., Billingsley, R., Du, L. and Johnson,

- M.: Improving Topic Models with Latent Feature Word Representations, *Trans. Association for Computational Linguistics*, Vol.3, pp.299–313 (2015).
- [2] Singh, A.P. and Gordon, G.J.: Relational learning via collective matrix factorization, *Proc. 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.650–658 (2008).
- [3] Agarwal, D. and Chen, B.-C.: fLDA: matrix factorization through latent dirichlet allocation, *Proc. 3rd ACM International Conference on Web Search and Data Mining*, pp.91–100 (2010).
- [4] Sedhain, S., Sanner, S., Braziunas, D., Xie, L. and Christensen, J.: Social collaborative filtering for cold-start recommendations, *Proc. 8th ACM Conference on Recommender systems*, pp.345–348 (2014).
- [5] Lee, D.D. and Seung, H.S.: Learning the parts of objects by non-negative matrix factorization, *Nature*, Vol.401, No.6755, pp.788–791 (1999).
- [6] Li, Y., Hu, J., Zhai, C. and Chen, Y.: Improving one-class collaborative filtering by incorporating rich user information, *Proc. 19th ACM International Conference on Information and Knowledge Management*, pp.959–968 (2010).
- [7] Zhang, S., Wang, W., Ford, J. and Makedon, F.: Learning from Incomplete Ratings Using Non-negative Matrix Factorization, *6th SIAM International Conference on Data Mining*, pp.549–553 (2006).
- [8] Zamani, H., Dadashkarimi, J., Shakery, A. and Croft, W.B.: Pseudo-Relevance Feedback Based on Matrix Factorization, *Proc. 25th ACM International Conference on Information and Knowledge Management*, pp.1483–1492 (2016).
- [9] Ricci, F., Rokach, L., Shapira, B. and Kantor, P.B.: Recommendation systems handbook, Heidelberg (ao): Springer (2011).
- [10] Rashid, A.M., Lam, S.K., Karypis, G. and Riedl, J.: ClustKNN: A highly scalable hybrid model-& memory-based CF algorithm, *Proc. WebKDD*, Vol.2006 (2006).
- [11] Zhai, C. and Lafferty, J.: Model-based feedback in the language modeling approach to information retrieval, *Proc. 10th International Conference on Information and Knowledge Management*, pp.403–410, ACM (2001).
- [12] Kuzi, S., Shtok, A. and Kurland, O.: Query Expansion Using Word Embeddings, *Proc. 25th ACM International Conference on Information and Knowledge Management*, pp.1929–1932 (2016).
- [13] Halko, N., Martinsson, P.-G. and Tropp, J.A.: Finding Structure with Randomness: Probabilistic Algorithms for Constructing Approximate Matrix Decompositions, *SIAM Review*, Vol.53, No.2, pp.217–288 (2011).
- [14] Blei, D.M., Ng, A.Y. and Jordan, M.I.: Latent dirichlet allocation, *Journal of Machine Learning Research*, Vol.3, pp.993–1022 (2003).
- [15] Nogueira, R. and Cho, K.: Task-Oriented Query Reformulation with Reinforcement Learning, *Proc. 2017 Conference on Empirical Methods in Natural Language Processing*, pp.574–583 (2017).
- [16] Lavrenko, V. and Croft, W.B.: Relevance-Based Language Models, *Proc. 24th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, Vol.51, No.2, pp.120–127 (2001).
- [17] Roy, D., Paul, D., Mitra, M. and Garain, U.: Using Word Embeddings for Automatic Query Expansion, arXiv preprint arXiv:1606.07608 (2016).

推薦文

高齢化社会の進行にともない介護の効率化と質的な充実がますます求められている。個人に寄り添った介護が求められているなか、介護のケアプラン作成は非常に重要なタスクであるが、限られた人材を有効に活用するためにも省力化が必須である。本論文はケアプランの推薦の問題を対象として、代表的な推薦手法である協調フィルタリングを採用したうえで、ケアプラン文書の特徴に合わせて特徴語を補完する手法を提案している。従来手法との綿密な比較も行って、上位の推薦結果を維持したうえで、下位の推薦結果の底上げを達成できたことを確認し、性能向上に効果的なファクターの解析も行い有効性を示している。これらの点から、論文誌への推薦論文に値すると認める。

(FIT2019 第 18 回情報科学技術フォーラムプログラム
委員長 柏野邦夫)



兵頭 幸起 (正会員)

2018年横浜国立大学理工学部数物・電子情報系学科卒業。2020年同大学大学院理工学府博士課程(前期)修了。機械学習, 自然言語処理, ケアプラン作成支援システムの研究に従事。



濱上 知樹 (正会員)

1999年千葉大学大学院自然科学研究科後期課程修了。2001年同助手。2004年横浜国立大学大学院工学研究院助教授。2008年10月同教授。知能システム, 機械学習, 強化学習, 医療支援システム, 社会システムへの応用研究に従事。博士(工学)。計測自動制御学会, 電気学会, 電子情報通信学会, IEEE 各会員。