

スカイライン演算を用いたユーザ嗜好を考慮した 情報推薦のランキング手法の精度改善について

岸田 脩平[†] 櫻 惇志^{††} 宮崎 純^{††}

[†] 東京工業大学工学部情報工学科 〒152-8550 東京都目黒区大岡山2丁目12-1

^{††} 東京工業大学情報理工学研究科 〒152-8550 東京都目黒区大岡山2丁目12-1

E-mail: †{kishida,keyaki}@lsc.cs.titech.ac.jp, ††miyazaki@cs.titech.ac.jp

あらまし 本稿では、情報推薦において、スカイライン演算で推薦するアイテムとなる候補を絞った後にランキングする手法として、ユーザの潜在的な嗜好を反映させる手法やアイテムの密度を考慮した手法を新たに提案する。これまで、膨大なアイテムからユーザの思考に合致したアイテムを推薦するため、協調フィルタリングをはじめとする情報推薦技術が利用されてきた。これらのユーザの嗜好に合致したアイテムを提示する情報推薦技術は有用であるものの、膨大なアイテム全てに対して情報推薦技術を適用した場合の推薦コストは極めて大きい。このような問題を回避するため、スカイライン演算によって、大量のデータからユーザにとって有用となる可能性の高いアイテムのみを取り出し、ユーザの嗜好に沿ってスコアリングする手法が提案され、限られた実験環境においては手法の有用性が確認された。本稿においてより大規模なユーザスタディを行った結果、ユーザの嗜好の優先度と、意思決定における重要度は必ずしも一致しないという問題が明らかになったため、これらを解決すべくユーザフィードバックを用いた手法や、アイテムが密集した箇所においてスコアを均一化する手法を考案した。評価実験の結果、提案手法は従来手法に比べてより高精度な推薦が可能であることを示した。

キーワード 情報推薦, スカイライン演算, スコアリング, リランキング

1. はじめに

近年、計算機の処理技術の発達やインターネットの普及等により、人々が扱うことのできる情報は爆発的に増加している。そのような大規模なデータから、ユーザにとって有益な情報やアイテムを提供する情報推薦技術が重要になり、様々な手法が研究されている。最も一般的な技術の一つとして協調フィルタリング[1]が挙げられる。協調フィルタリングはユーザの行動履歴や嗜好情報を利用しアイテムを推薦する技術で、ユーザベースの手法とアイテムベースの手法がある。例えば、ユーザベースフィルタリング[2]では、推薦対象ユーザと行動履歴の似ているユーザを探し、そのユーザの情報をもとにアイテムを推薦する。対して、アイテムベースフィルタリング[3]では、ユーザ間の類似度ではなくアイテム間の類似度を利用し、推薦対象ユーザが好むアイテムに似ているアイテムを推薦する。しかし、ユーザの数、アイテムの数が膨大になってくると、類似度計算のコストが極めて大きくなる。そこで、膨大なデータから推薦される可能性のある優秀なデータのみを取り出し、その中からユーザの嗜好に合ったデータを推薦することで、計算コストを削減することができると期待される。

大規模なデータベースから優秀なデータのみを効率的に抽出する技術として、Börzsönyiらがスカイライン演算[4]を提案した。なお、優秀なデータとは、データの持つすべての属性において、他のデータよりも優れているか同等の値を持ち、少なくとも一つの属性では他のデータよりも優れているアイテムのことである。優秀なデータは劣っているデータを支配すると表

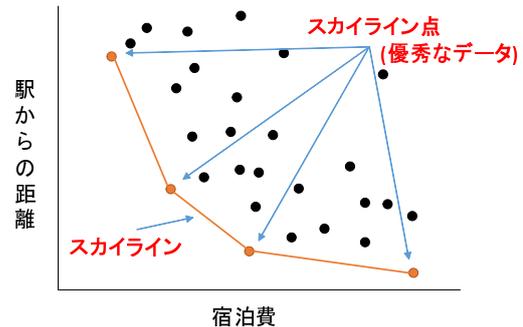


図1 スカイラインとスカイライン点

現する。例として、図1に駅からの距離と宿泊費を軸としたホテルデータの散布図を示す。駅からの距離は軸の上に行くほど長くなり、宿泊費は軸の右に行くほど高くなっている。二次元の場合、ホテルにおける宿泊費や駅からの距離など、小さいほうがより良いとされる軸で考えると、図1のオレンジの点のような、アイテム自身よりも左下に他のアイテムが無いアイテムが優秀であると言える。オレンジの点のことをスカイライン点と呼び、それらをつなげた線をスカイラインと呼ぶ。

スカイライン演算により膨大なデータの中から効率的に優秀なデータを取り出すことが可能になったが、取り出されたデータの優劣はあまり議論されていなかったものの、情報推薦に適用する上では、データの順位付けは必須である。そこで、植田らはユーザの嗜好情報をもとにスカイライン演算で抽出したアイテムに対する、ユーザの嗜好に基づいたランキング付けを行

う手法を提案した [6]。植田らの行った評価実験では、スカイライン演算を行っても推薦精度は低下せず、また、ユーザの嗜好を利用したスコアリングを行うことでより高精度にアイテムを推薦できることが報告されている。実験はホテルを推薦することを想定しており、ユーザの嗜好は、価格や駅からの距離、食事の質など複数の要素（本稿においては軸と呼称する）から成っていると仮定して、上位二つの軸を用いて推薦を行った。また、実験より第一軸に大きな重みを与えた場合に高い推薦精度を達成できるという結果が得られたものの、個別の軸の影響度を考慮されていなかったため、より詳細なユーザスタディを行う必要があった。さらに、実験参加者が少数であったために、より確からしい知見を得るためには、より大人数における評価を行う必要がある。

本研究において実施した詳細なユーザスタディの結果、ユーザの嗜好の優先度と、意思決定における重要度は必ずしも一致しないという問題が明らかになった。これらを踏まえて、本稿では、ユーザの嗜好上位三軸を用いた情報推薦において、スカイライン演算後のランキング手法としてユーザのフィードバックを用いた手法や密集したアイテムにおいてスコアを均一化する手法の提案を行う。また、被験者 30 名での評価実験を行い推薦精度を測定し、従来手法との比較を行った結果、密度を考慮する手法がより高精度な推薦が可能であることを示す。

2. 関連研究

本節ではスカイライン演算に関する先行研究について述べる。

2.1 Block Nested Loop アルゴリズム

スカイライン演算を処理する方法として、Block Nested Loop アルゴリズム（以下 BNL）[4] がある。BNL は、その時点で優秀であるようなデータ集合であるスカイライン候補集合と、各アイテムの支配関係を調べることでスカイライン集合を得ることができるアルゴリズムである。アイテム p がアイテム q にすべての軸において優れているか同等の値を持ち、少なくとも一つの軸において優れているとき、アイテム p はアイテム q を支配すると表現する。BNL の詳細な手順を下記に示す。

- (1) 候補集合内すべてのアイテムに支配されず、また支配しない場合、そのアイテムを候補集合に追加する
- (2) 候補集合内のアイテムに支配される場合、その後の候補集合内のアイテムとは比較せず、次のアイテムの比較に移る
- (3) 候補集合内のアイテムをいくつか支配する場合、そのアイテムを候補集合に追加し、支配されたアイテムはすべて取り除く。なお、はじめのアイテムは無条件で候補集合に追加するものとする。

例として、表 1 のホテルデータベースについて考える。ホテルの属性には、宿泊費と最寄り駅からの距離があり、それぞれ値が小さいほどより優れているとする。これらのホテルデータに対して BNL を適用すると、まずホテル 1 が無条件でスカイライン候補集合に追加される。次にホテル 2 がスカイライン候補集合中のホテル 1 と比較されるが、ホテル 1 とホテル 2 はお互いに支配しないので、ホテル 2 もスカイライン候補集合に追加される。その後、ホテル 3 がスカイライン候補集合内のアイ

テムと比較されるが、ホテル 3 はホテル 1 に宿泊費においても最寄り駅からの距離においても劣っており支配されるので、スカイライン候補集合には追加されない。この場合にはその後のホテル 2 との比較は行われず直ちに次のアイテムに処理は移行する。最後にホテル 4 は、ホテル 1 を支配せず支配もされないが、ホテル 2 を支配するのでホテル 2 とホテル 4 を置換する。したがって、最終的にホテル 1, 4 がスカイライン集合に含まれる。

表 1 ホテルデータ

ホテル ID	宿泊費	最寄り駅からの距離
ホテル 1	5000 円	0.5km
ホテル 2	4500 円	2.0km
ホテル 3	7000 円	2.5km
ホテル 4	3500 円	1.5km

2.2 ユーザ嗜好を考慮したランキング手法

過去に、スカイライン演算を情報推薦に適用した例は存在するが、スカイライン演算で取得されたアイテムに対して、単に支配するアイテム数の降順にランキングを行っているのみに留まっており [5]、情報推薦において重要なユーザの嗜好情報が十分に反映されていない。そこで植田らはスカイライン演算で得られたアイテムを、ユーザの嗜好を考慮してランキングする手法 [6] を提案した。植田らが行った実験では、ホテル選びをしようとしているユーザにホテルを推薦することを想定している。ホテル選びの際、ユーザは価格や食事の質、立地、駅からの距離など複数の項目（本稿においては軸と呼称する）を考慮しながら候補を絞り、その中から実際に宿泊するホテルを決定すると考えられる。実験では、被験者にホテルを選ぶ際に重要視する上位二つの軸を選んでもらい、その情報をもとに推薦されたホテル群について、一つ一つホテル選びの候補に入れるか入れないかの二択で質問して、精度を計測している。

以下にランキングの手順を説明する。まず、ユーザが重要視する上位二つの軸でスカイライン演算を行い、優秀であるアイテムを抽出する。次に、軸間で比較が行えるように、ユーザが選んだ軸に対して、軸ごとに正規化する。続いて、ユーザの嗜好の優先順位をもとに、正規化した値の重み付け和を取りスコアとする。最後に、スコアのソートを行い、高いものからランキングする。正規化が一番優れている値が 1.0、一番劣っている値が 0.0 になるように行った。例として、重み付けとして宿泊費に 0.8、距離に 0.2 を設定した場合のスコアを表 2 に載せる。実際にホテル 2 の総合スコアを計算してみると、

$$0.8 \times 0.8 + 0.5 \times 0.2 = 0.74$$

となる。

植田らの実験では、軸ごとの重みは第一軸に 0.9 以上、第二軸に 0.1 以下とした場合が最も精度が良いという結果になった。

3. 予備実験

本節では学生 30 人に対して行った予備実験について説明する。

表 2 スコア

ホテル ID	宿泊費	宿泊費スコア	距離	距離スコア	総合スコア
ホテル 1	6000 円	0.5	2.5km	0.0	0.4
ホテル 2	4500 円	0.8	1.5km	0.5	0.74
ホテル 3	8500 円	0.0	0.5km	1.0	0.2
ホテル 4	3500 円	1.0	2.0km	0.25	0.85

3.1 実験目的

植田らの実験 [6] では上位二軸でのランキングしか行われなかったため、上位三軸でのランキングを試みた。また、より妥当な実験結果を取得するため、より大人数での実験、評価を行った。加えて、第一軸に極めて大きな重みを与えた場合に最も高精度な推薦を行うことが可能であるという結果が得られたものの、被験者のうちの大多数が同一の軸、すなわち、価格の軸を第一軸として選択していた。いずれの軸を第一軸として設定した場合においてもこのような傾向が見られるのかどうかを検証するため、本実験においては価格は選択肢から除外して再実験を行った。

3.2 データセット

使用したホテルデータは、楽天データセットのうち楽天トラベルのデータを利用し、東京 23 区内のホテルデータ 692 件を用いた。各ホテルは、価格、サービスレビュー、施設レビュー、部屋レビュー、立地レビュー、風呂レビュー、食事レビュー、最寄り駅からの距離の情報を持つ。価格は、そのホテル一泊の宿泊費の中央値となっている。レビューの値は、そのホテルを評価した全ユーザの 1~5 の 5 段階評価の平均値である。評価されていない場合は 0 となる。最寄り駅からの距離は、ホテルと最寄り駅の直線距離となっている。

3.3 比較する手法

実験で比較する手法について述べる。

- Skyline : スカイライン集合のアイテムのみならずスカイライン周辺のアイテムも優れていると考えられるので、一度のスカイライン演算の実行によって取り出されたアイテムだけでは、ユーザにとって有用であるアイテムを網羅的に抽出できていない可能性がある。そのため、スカイライン演算を行った後、スカイライン点を取り除き、複数回スカイライン演算を行う。スカイライン実行回数は、スカイライン演算を繰り返して、抽出したアイテム数が閾値を超えた時点で終了するものとする。今回の実験における閾値は 120 とした。スカイライン演算を複数回実行した後、各判断軸の重み付け和をスコアとする (植田らの提案手法 [6] と同様)。ホテル i の各判断軸で正規化した値を v_1^i, v_2^i, v_3^i とし、各判断軸の重みを w_1, w_2, w_3 とすると、ホテル i のスコア S_i は以下の式 (1) で求まる。

$$S_i = w_1 v_1^i + w_2 v_2^i + w_3 v_3^i \quad (1)$$

- Linear : スカイライン演算を行わず、上記式 (1) を全ホテルデータに対して計算しスコアとする。
- Sorting : 第一軸の値でソートを行う。

3.4 実験手順

まず、サービス、施設、部屋、立地、風呂、食事、最寄り駅からの距離の内から、ユーザがホテルを選ぶ際に重要視する上位三つの判断軸について質問した。前述の通り価格を軸とした

ときに大きな影響力を持つ可能性があるため、価格は選択肢から除外する。次に、複数のランキング手法によって得られたそれぞれ上位 30 件のホテルを一件ずつ実験参加者にそのホテルを宿泊するホテルの候補に入れるか入れないかの二択で質問した。最後に、ホテルを評価する際に、選択した三軸を実際にどの程度重要視したかの割合を質問して、ユーザが三軸をどのような比率で重要と考えるかの傾向を調査した。重み付け計算を行う際の各軸の重みのパターンは植田らの実験に準拠して 3 種類設定した。重みパラメータを表 3 に示す。

表 3 軸の重みパラメータ

	第一軸	第二軸	第三軸
p1	0.5	0.5	0.0
p2	0.9	0.05	0.05
p3	0.33	0.33	0.33

3.5 評価尺度

実験で使用した評価尺度について説明する。

R-measure [7] は推薦されたアイテムのうち、正しく推薦出来たアイテムの割合を調べる尺度である。推薦されたアイテムの総数を r 、その中で正しく推薦されたアイテムの数を h とした時、推薦された r 件のアイテムの R-measure P_r は以下の式 (2) で求まる。

$$P_r = \frac{h}{r} \quad (2)$$

次に nDCG (normalized Discounted Cumulative Gain) [7] について説明する。nDCG はランキングの結果がユーザの嗜好にどの程度沿っているかを測る尺度である。ユーザによる評価値が高いアイテムがランキングの上位にあるほど値が大きくなる尺度である DCG を、理想のランキングのときの DCG、すなわち iDCG (ideal DCG) で割り正規化したものが nDCG である。上位 k 件の DCG は以下の式 (3) で表される。ただし、順位 i 位の評価値を R_i とする。今回の実験では、ユーザが提示されたホテルをホテル選びの考慮に入れた場合評価値は 1、入れないとした場合評価値は 0 とした。

$$DCG_k = R_1 + \sum_{i=2}^k \frac{R_i}{\log_2 i} \quad (3)$$

上位 k 件の nDCG は以下の式 (4) で求まる。

$$nDCG_k = \frac{DCG_k}{iDCG_k} \quad (4)$$

iDCG は順位 k 位までの評価値を降順にソートしたときの DCG である。nDCG は 0 から 1 の間の値を取り、値が 1 に近いほどヒットするアイテムがランキングの上位にあり、精度が高いことを表す。

3.6 実験結果

被験者 30 人での実験結果を表 4 に示す。評価尺度は R-measure と nDCG を用いた。p3, p1, p2 の順に高い推薦精度になっており、一番精度が高かった軸ごとの重み付けは、各軸に 0.33 の重みをつけた p3 のパターンであった。先行研究とは大きく異なった結果が示されたが、軸の選択肢から価格を抜いた

表 4 予備実験結果

手法	$nDCG_{30}$	手法	precision@30
p3-Skyline	0.951	p3-Linear	0.850
p3-Linear	0.951	p3-Skyline	0.850
p1-Linear	0.931	p1-Linear	0.821
p1-Skyline	0.931	p1-Skyline	0.820
Sorting	0.913	p2-Linear	0.733
p2-Linear	0.895	p2-Skyline	0.732
p2-Skyline	0.895	Sorting	0.503

表 5 各軸を重要視した割合

user	第一軸	第二軸	第三軸	user	第一軸	第二軸	第三軸
user2	0.7	0.2	0.1	user1	0.15	0.15	0.7
user4	0.4	0.3	0.3	user3	0.3	0.4	0.3
user6	0.4	0.35	0.25	user5	0.3	0.4	0.3
user7	0.4	0.3	0.3	user9	0.2	0.7	0.1
user8	0.6	0.2	0.2	user13	0.5	0.1	0.4
user10	0.4	0.3	0.3	user16	0.5	0.2	0.3
user11	0.8	0.15	0.05	user17	0.3	0.2	0.5
user12	0.5	0.3	0.2	user19	0.1	0.3	0.6
user14	0.5	0.4	0.1	user20	0.3	0.3	0.4
user15	0.7	0.15	0.15	user23	0.3	0.6	0.1
user18	0.54	0.38	0.08	user24	0.3	0.2	0.5
user21	0.52	0.29	0.19	user27	0.2	0.4	0.4
user22	0.4	0.3	0.3	user28	0	1	0
user25	0.41	0.36	0.23	user29	0.05	0.2	0.75
user26	0.5	0.25	0.25	user30	0.2	0.2	0.6

ことが原因であると考えられる。

また被験者の半数が、実験開始時に選択した軸の優先度の順序と、実験後に回答した軸の優先度の順序が異なるという結果が得られた。被験者に優先する順序が翻った理由を質問したところ、各ホテルデータの、当初優先度を高く設定した軸の値に差がなかったためであるという回答が多く得られた。表 5 にユーザが回答した各軸を重要視した割合を示す。表の左側が軸の優先度の順序が変化しなかったユーザのグループであり、表の右側が軸の優先度の順序が翻ったユーザのグループである。

また、ユーザが回答した各軸の重要視した割合を軸の重みに設定しランキングし直したところ、精度の上昇は見られなかったことから、仮にユーザ自身で軸の優先度を設定したとしても、適切な重みを設定できるとは限らないという結果が得られた。

これらの実験結果から、ユーザの嗜好の優先度と、意思決定における重要度は必ずしも一致しないということが示唆された。

4. 提案手法

予備実験で、ユーザの持つ嗜好の優先度と、意思決定における重要度は異なる可能性があり、データの分布による影響によって意思決定の方針が変化したり、ユーザ自身も適切な重みを設定できるとは限らないということが判明した。そこで本稿では、ユーザの評価から潜在的なユーザの要求を反映させるユーザフィードバックアプローチと、データの分布を考慮したアプローチを提案する。データの分布に関して、より具体的には、ある軸において近似した値のアイテムが密集して出現する場合には、その軸における各アイテムの優劣は大きな意味をな

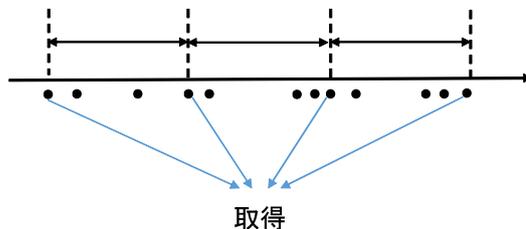


図 2 ユーザフィードバック用アイテムの取得

さなくなると考えられるため、それらの値を均一化する。

4.1 ユーザフィードバックを用いたランキング手法

ユーザフィードバックを用いて、ユーザの潜在的な要求を最も満たすようなアイテムを取得し、そのアイテムに類似するアイテムを推薦する。アイテム間の類似度を計算する点において、本手法はアイテムベースの情報推薦であると言える。

まず、スカイライン演算で得られたアイテムを、図 2 のようにユーザの重要視する軸ごとに三等分し、最大で、軸の数 \times 4 件のアイテムを取得する。それらのアイテムからユーザに一番嗜好に合致するホテルを選択してもらい、選択されたホテルに類似している順にスカイライン演算で取得されたホテルをランキングする。類似度はコサイン類似度を使用した。

コサイン類似度は二つの n 次元ベクトルがなす角度に基づき計算され、0 から 1 の値を取り、1 に近いほど類似していることを示す。アイテム a, b がそれぞれベクトル \vec{a}, \vec{b} に対応するとすると、アイテム a, b 間のコサイン類似度は式 (5) で定義される。

$$\text{sim}(a, b) = \frac{\vec{a} \cdot \vec{b}}{|\vec{a}| |\vec{b}|} \quad (5)$$

類似度の計算に使用する軸は、価格、サービス、施設、部屋、立地、風呂、食事、最寄り駅からの距離の 8 軸のうち、ユーザが指定した第一軸のみを使用する場合、第一軸と第二軸と第三軸を使用する場合、8 軸すべてを使用する場合の 3 パターンで計測した。一次元でコサイン類似度を計算すると、二つのベクトルの値が 0 でない時、常に 1 となるので、使用する軸がユーザが指定した第一軸のみの場合は、値の差の絶対値が小さいほど類似しているとしてランキングした。

4.2 軸ごとの密度を考慮したランキング手法

スカイライン演算で抽出されたアイテムが、各軸においては非常に密集している箇所が存在する場合が考えられる。そのような場合、密集した部分ではその軸においてアイテム間の優劣に差があまり無いため、ユーザは他の軸をより重要視することが予測される。そこで、各軸ごとに、密度が閾値を超えている、すなわち高密度のアイテム集合を一定の値と見なしスコアを均一化することで、他の軸での値の差により重きを置いたスコアリングを行う。密度の閾値を決めるにあたり、スカイライン演算で取得されるアイテムの密度をカーネル密度推定 [8] を用いて調査した。スカイライン演算を行う三軸を変更しつつ繰り返し調査したところ、各軸ごとの密度曲線の形は概ね等しかった。価格の密度曲線は鋭い山を描いているのに対して、価格以外の軸の密度曲線は価格に比べると緩やかな山を描いていた。価格と立地の密度分布を図 3 と図 4 に示す。横軸がその軸で正規化

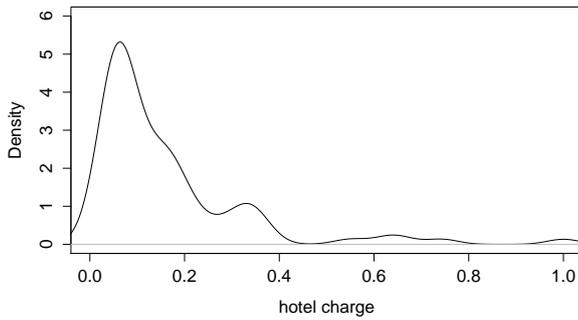


図3 価格のカーネル密度分布

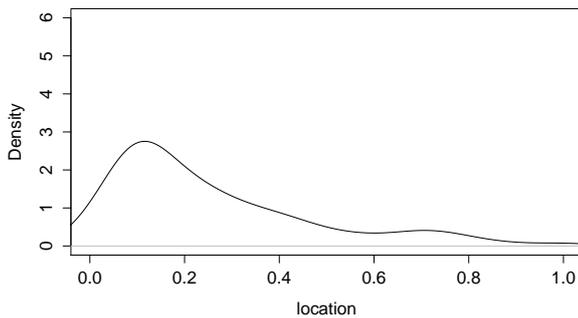


図4 立地のカーネル密度分布

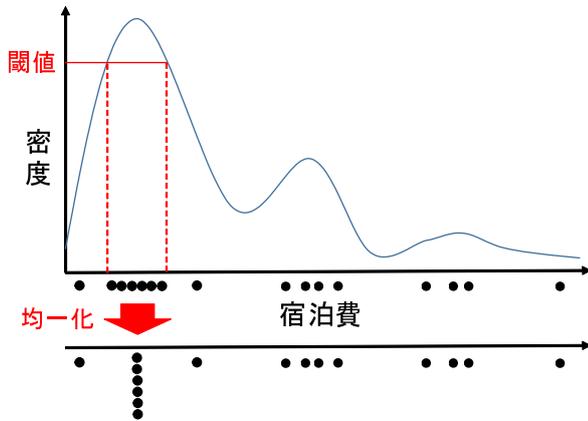


図5 スコア均一化の例

した値で、縦軸が密度である。適切な閾値が未知であるため、本実験では、閾値は1から5まで1刻みで計測して推薦精度を計測した。図5に宿泊費の軸で実際にスコアの均一化をする例を示す。縦軸が密度を表しており、密度が閾値を超えた区域のアイテム集合のスコアを均一化する。均一化の際に用いる値は、密集したアイテムの持ついずれかの値を採用することが考えられるが、本研究では集合の平均値とした。均一化した後は、従来の手法と同様に各軸の重み付和をスコアとする。

5. 評価実験

本節では30人の学生に対して行った被験者実験の内容について述べる。

5.1 実験目的

提案手法と従来手法の推薦精度の比較を目的とする。また、予備実験より、意思決定において価格を軸として含む場合と含まない場合において大きく傾向が異なることが判明したため、三つの判断軸に価格を入れない場合と入れる場合の二通りで実験を行った。価格情報を事前に知ることができないように、先に判断軸に価格を入れないパターン、その後に入れるパターンの順で実験を行った。

5.2 比較する手法

実験で比較する手法を示す。

- Feedback : 4.1節のユーザフィードバックを用いた手法
- Density : 4.2節の軸ごとの密度を考慮し、高密度区間のアイテム集合のスコアの均一化を図る手法

以下の三つの手法については3.3節の内容と同じである。

- Skyline
- Linear
- Sorting

5.3 実験手順

データセットは予備実験と同じく3.2節のものを利用した。実験ではまず、選択肢から価格を除いた状態で、ユーザがホテルを選ぶ際に重要視する上位三つの判断軸について質問した。次に、複数のランキング手法によって得られたそれぞれ上位30件のホテルを統合し、一件ずつ実験参加者にそのホテルを宿泊するホテルの候補に入れるか入れないかの二択で質問した。その後、三つの判断軸のいずれかに必ず価格を入れてもらい、同様に実験を行った。重み付け計算を行う際の各軸の重みのパターンは表3の3種類を使用した。

5.4 実験結果

軸に価格を除いた場合の実験結果を表6に、軸に価格を含んだ場合の実験結果を表7に示す。評価尺度は予備実験と同様にR-measureとnDCGを用いた。Density手法はその重みパラメータの中で一番精度の良かった密度閾値での値を表示しており、末尾にある数字が密度閾値の値である。Feedback手法の末尾の数字は、いくつの軸でアイテム間の類似度計算を行ったかを表している。

表6を見ると、軸に価格を盛り込まない場合の実験だと、p3,p1,p2の順に高い推薦精度になっており、予備実験の結果と似た傾向が見られる。価格ほど強く意思決定に影響を与える軸が無い場合、三軸を均等に反映させる場合により適切な推薦結果を提示することが可能であると考えられる。p3においてはLinear手法に僅かに劣っているものの、p1,p2においてはDensity手法の精度が高いことが確認できる。Feedback手法はnDCGにおいては8軸で比較、3軸で比較、1軸で比較の順に高い推薦精度になっており、precision@30においては3軸で比較、8軸で比較、1軸で比較の順に高い推薦精度になっていた。

表7より、軸に価格を含む場合、Density手法が最も精度の良い手法であった。ホテルの価格軸の密度が高かったために、Density手法のスコアを均一化する工夫が上手く機能したと考えられる。推薦したホテルの適合率であるprecision@30において、p1-Skyline手法がp2,p3のDensity手法に優っているのに

もかわらず、nDCG においては逆転しているのは、Density 手法のランキング上位によりユーザの嗜好に適合するホテルが多かったためである。Feedback 手法はユーザが指定する三軸に価格を入れた場合においても、nDCG においては 8 軸で比較、1 軸で比較、3 軸で比較の順に高い推薦精度になっており、precision@30 においては 3 軸で比較、8 軸で比較、1 軸で比較の順に高い推薦精度になっている。

以上の結果より、軸ごとの密度を考慮する Density 手法が、評価軸に価格を入れない場合にもおいても、価格を入れる場合においても安定して精度が高く推薦できることを示した。また、軸ごとの重みに関しては、価格のように意思決定において重要で決定的な軸がある場合、その軸に高い重みを付ければ良く、決定的な軸がない場合は、各軸に均等に重みを付ければ良いという結果が得られた。

表 6 実験結果 (三軸に価格なし)

手法	nDCG ₃₀	手法	precision@30
p3-Linear	0.990	p3-Linear	0.900
p3-Skyline	0.990	p3-Skyline	0.897
p3-Density-3	0.988	p3-Density-2	0.892
p1-Density-3	0.962	p1-Density-2	0.876
p1-Skyline	0.960	p1-Skyline	0.861
p1-Linear	0.956	p1-Linear	0.850
Feedback-8	0.945	p2-Density-1	0.850
p2-Density-2	0.940	p2-Skyline	0.808
p2-Skyline	0.932	Feedback-3	0.778
p2-Linear	0.926	Feedback-8	0.772
Feedback-3	0.912	p2-Linear	0.763
Feedback-1	0.892	Feedback-1	0.729
Sorting	0.851	Sorting	0.646

表 7 実験結果 (三軸に価格あり)

手法	nDCG ₃₀	手法	precision@30
p2-Density-5	0.918	p1-Density-5	0.759
Feedback-8	0.916	p1-Skyline	0.750
Feedback-3	0.909	p2-Density-4	0.746
p3-Density-5	0.901	Feedback-3	0.737
p1-Density-5	0.895	p3-Density-4	0.712
p1-Skyline	0.888	Feedback-8	0.704
p1-Linear	0.878	p1-Linear	0.688
p2-Skyline	0.877	p3-Skyline	0.676
p2-Linear	0.876	p3-Linear	0.671
p3-Skyline	0.866	p2-Linear	0.668
p3-Linear	0.863	p2-Skyline	0.647
Feedback-1	0.848	Feedback-1	0.628
Sorting	0.565	Sorting	0.368

6. まとめ

本研究では、情報推薦において、スカイライン演算で推薦するアイテムとなる候補を絞った後にランキングする手法の推薦精度の向上を試みた。植田らの先行研究の検証のために行った予備実験で、ユーザの嗜好の優先度と、意思決定における重要

度は必ずしも一致しないということが示唆された。その結果から、ユーザフィードバックを用いてコサイン類似度を調べる手法や、軸ごとの密度を考慮して密集している部分においてスコアを均一化する手法を提案した。被験者 30 人による実験の結果、軸ごとの密度を考慮する手法が安定して精度が高く推薦することが可能であることを示した。また、価格のような意思決定に強い影響を与える軸が明確な場合にはその軸に強い重みを与え、不明確な場合には各軸に均等に重みを与えれば精度良く推薦できることを示した。

今回、ユーザフィードバックを用いた手法ではユーザの嗜好に合うアイテムを 1 件だけ取得し、そのアイテムをもとに推薦を行ったが、ユーザフィードバックによってユーザの嗜好に合うアイテムを複数取得すれば、よりユーザの嗜好を反映したアイテムを推薦することで精度を改善できる可能性がある。また、Density 手法では密度推定を行って密度の閾値を複数設定したが、自動的に設定する方法の検討が必要である。さらに、ホテル以外のデータセットに対しても本研究の提案手法が適用できるか検証が必要である。

謝 辞

ホテルのデータセットを提供して頂いた楽天株式会社に感謝致します。本研究の一部は、科研費基盤研究 (B)(課題番号:15H02701)、基盤研究 (B)(課題番号:26280115) の支援による。ここに記して謝意を表します。

文 献

- [1] 土方嘉徳, “嗜好抽出と情報推薦技術,” 情報処理, vol.48, no. 9, pp. 957-965, 2007.
- [2] Resnick, Paul and Iacovou, Neophytos and Suchak, Mitesh and Bergstrom, Peter and Riedl, John., “GroupLens: an open architecture for collaborative filtering of netnews”, Proceedings of the 1994 ACM conference on Computer supported cooperative work, pp.175-184, 1994
- [3] Badrul Sarwar, George Karypis, Joseph Konstan, John Riedl, “Item-based collaborative filtering recommendation algorithms”, Proceedings of the 10th international conference on World Wide Web, pp.285-295, ACM Press, 2001
- [4] Stephan Börzsönyi, Donald Kossmann, Konrad Stocker “The Skyline Operator” In Proceeding of the 17th International Conference on Data Engineering, pp.421-430, 2001.
- [5] Hsin-Hsien Lee; Wei-Guang Teng, “Incorporating Multi-Criteria Ratings in Recommendation Systems,” in Information Reuse and Integration, 2007. IRI 2007. pp.273-278, 13-15 Aug. 2007 doi: 10.1109/IRI.2007.4296633
- [6] 植田 聖司, 櫻 惇志, 宮崎 純: “スカイライン演算を用いたユーザ嗜好を考慮した情報推薦のランキング手法の提案”, DEIM 2015 Proceedings, B3-4, 福島, March 2015.
- [7] Christopher D. Manning, Prabhakar Raghavan, Hinrich Schuetze, “Introduction to Information Retrieval”, Cambridge University Press. 2008.
- [8] Silverman Bernard W, “Density estimation for statistics and data analysis”, CRC press, 1986.