

適合性分布が異なる情報源を用いたランキング学習

数原良彦^{†1} 宮原伸二^{†1} 植松幸生^{†2}
金田有二^{†3} 藤野昭典^{†4} 片岡良治^{†1}

情報検索において、機械学習の枠組みでランキング関数の最適化を行うランキング学習が重要な課題である。従来のランキング学習手法では人手による適合性評価、もしくはクリックログから得られる訓練データを利用してきた。我々は、これらの複数情報源を適切に利用し、より高精度なランキング学習を達成することを目標とする。我々は複数情報源から得られる訓練データは、適合性分布が異なると考えた。そのため、訓練データの適合性分布が同一であることを仮定している従来の教師あり学習に基づくランキング学習手法では、複数情報源を用いたランキング学習の実現が困難だと考えられる。そこで我々は、分布が異なる訓練データを用いて転移学習の枠組みに着目し、転移学習をランキング学習に適用することによって適合性分布が異なる複数の情報源を用いたランキング学習の実現を試みる。本稿では、転移学習の枠組みに基づくランキング学習手法 TRankBoost を提案し、商用モバイルウェブ検索エンジンの実データを用いた評価実験によって有効性を検証した。評価実験により、TRankBoost によって、従来手法である RankingSVM, RankBoost と比べて NDCG@5, 10 の値で上回る精度のランキングを実現することを示した。

Learning to Rank from Multiple Sources of Different Relevance Distributions

YOSHIHIKO SUHARA,^{†1} SHINJI MIYAHARA,^{†1}
YUKIO UEMATSU,^{†2} YUJI KANEDA,^{†3} AKINORI FUJINO^{†4}
and RYOJI KATAOKA^{†1}

Learning to rank has become a hot research topic in recent years. Conventional learning-to-rank algorithms use human relevance judgments or click-through logs as training data. We consider that human relevance judgments can perform better by complementing with the other sources such as click-through logs. We assume that these datasets, click-through logs and human relevance judgments, have different relevance level distributions. Thus, it is difficult to gain better performance by combining them in a simple manner because con-

ventional learning-to-rank algorithms based on supervised learning assume that training data are sampled from identical distributions. In this paper, we propose a general learning-to-rank framework, based on the transfer learning framework, that resolves this problem. We also propose a novel learning-to-rank algorithm called TRankBoost. To verify its efficiency, we conducted the experiments using real dataset from the commercial mobile web search engine. Our experiments show that TRankBoost outperforms the conventional methods of RankingSVM and RankBoost on NDCG@5 and 10.

1. はじめに

情報検索システムにおいて、ユーザに適切な検索結果を提示するためのランキングアルゴリズムは重要な要因である。近代的なウェブ検索システムは、入力されたクエリと文書の類似度である BM25²⁶⁾ スコアや、リンク解析に基づいたページ重要度である PageRank²⁾ スコアのようなランキング素性（以下、素性）を多数利用して適切なランキングを実現している。一般には、これらの素性をランキング関数に入力し、その出力となる値をもとに検索結果の順序を決定する。そのため、適切なランキング関数を設定することは重要な課題である。

最近では、機械学習を用いてランキング関数を自動的に生成するランキング学習（learning to rank）と呼ばれる研究が注目されている。一般的なランキング学習手法では訓練データとして、クエリ、クエリに対応する検索結果、検索結果に対する適合性評価を用いる。通常は、複数人の被験者によって検索結果の評価を行い、適合性評価を作成する。

また、検索システム利用の際に、ユーザが入力したクエリと、クリックした検索結果の位置情報を格納したクリックログ（click-through log）を訓練データとして用いることができる。通常、ユーザは自分の検索要求を満たすような検索結果をクリックするため、ユーザのクリック行為は、暗黙的な適合性評価と見なすことができる。これにより、クリックログを用いて人手による適合性評価と同じ枠組みでランキング学習が可能である^{1),5),7),11),15),18)–20),25)}。

^{†1} 日本電信電話株式会社 NTT サイバーソリューション研究所
NTT Cyber Solutions Laboratories, NTT Corporation

^{†2} NTT コミュニケーションズ株式会社先端 IP アーキテクチャセンター
Innovative IP Architecture Center, NTT Communications Corporation

^{†3} NTT レゾナント株式会社
NTT Resonant Inc.

^{†4} 日本電信電話株式会社 NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, NTT Corporation

Dou ら¹¹⁾ は、人手による適合性評価を用いた場合と、クリックログを用いた場合のランキング学習の性能比較を行った。実験結果より、クリックログを訓練データに用いることで、より高性能のランキング学習が可能であることを示した。また、Dou らは人手による適合性評価が劣る理由として、訓練データ数の不足を理由にあげている。このように、訓練データ数の不足などの原因により、与えられた訓練データに対して過剰に適合したモデルを学習してしまい、未知のデータに対して汎化性能を示すことができない現象を過学習 (over fitting) と呼ぶ。過学習は、機械学習を適用する際にしばしば問題となる。

ランキングの有効性を表す評価指標は、人手による適合性評価を用いて計算されるため、目標とすべき適合性評価の分布 (適合性分布) は人手による適合性評価における適合性分布である。我々は、人手による適合性評価が十分多量に用意されれば、過学習の問題が解消され、高精度なランキング学習が可能であると考えている。しかしながら、訓練データの作成コストは非常に高いため、十分な量の適合性評価を人手で用意することは困難である。我々は、人手による適合性評価に加えて、クリックログなどの情報源から得られる訓練データを適切に活用することにより、高性能なランキング関数が実現可能だと考えた。

クリックログはユーザのクリック行為に基づく暗黙的な適合性評価のため、人手によって作成された明示的な適合性評価とは異なる適合性分布であることが予想される。既存の教師あり機械学習の枠組みでは、訓練データに含まれる各事例が同じ適合性分布から得られるという仮定をおいているため、クリックログから得られた訓練データを単純に混ぜる方法では適切に学習ができないと考えられる。したがって、人手による適合性評価に適合性分布が異なる訓練データを加えてランキング学習を行うために、適合性分布の異なりを考慮しなければならない。

そこで我々は、目標となる分布の訓練データに分布が異なる訓練データを加えて高精度な学習を行う転移学習の枠組みをランキング学習に適用することで、本課題の解決を目指す。本稿では、転移学習を用いたランキング学習手法である TRankBoost を提案し、実データを用いた評価実験を通じて提案手法の有効性を検証する。

本稿の貢献は以下のとおりである。

- (1) 転移学習を適用することによって、適合性分布が異なる複数の訓練データを用いたランキング学習の枠組みを提案する。
- (2) 転移学習に基づく新しいランキング学習手法である TRankBoost を提案する。
- (3) 評価実験を通じて提案手法の有効性を検証する。また、適合性分布が異なる訓練データに対して従来手法がうまく働かないことを検証する。

本稿の構成を以下に示す。2 章では関連研究を述べる。3 章では複数情報源を用いたランキング学習の枠組みと、転移学習を用いたランキング学習について述べ、提案手法の詳細について述べる。4 章では、評価実験の内容と結果を述べ、5 章で結果をふまえた考察を述べる。最後に本稿のまとめと今後の課題について述べる。

2. 関連研究

情報検索においてランキング学習の研究はさかんに行われている。既存のランキング学習手法は学習モデルの定式化の観点から 3 種類に分けることができる。ポイントワイズ手法²³⁾ は、分類や回帰の問題としてランキング学習を実現する。ペアワイズ手法^{4),5),13),16)} は文書ペアの順序に対して誤差関数を設定し、これを最適化することでランキング学習を実現する。リストワイズ手法^{6),27),29)-31)} は、検索ランキングのリストに対して設定された誤差関数の最適化を行う。

人手による適合性評価とクリックログを直接比較した研究は少ない¹¹⁾。Dou ら¹¹⁾ は、人手による適合性評価とクリックログから得られた訓練データを用いたランキング学習の性能を比較している。クリックログを用いたランキング学習により、人手による適合性評価を上回る性能が得られることを示し、クリックログは大量の訓練データが得られるためこのような結果が得られたと考察している。Kamps ら²¹⁾ は、人手による適合性評価とクリックログの相関を分析し、弱い相関とある程度の一致があると結論付けている。

半教師あり学習の枠組みでランキング学習を行う研究もある^{12),22),28)}。半教師あり学習では、ラベルなしデータに着目する。たとえば Duh ら¹²⁾ は、ランキング対象のテストデータを用いることで、当該データをランキングするのに適切な素性を選択してランキング学習を行うトランスファクティブ手法を提案している。我々の手法は追加データに付与されたラベル情報を用いる点で半教師あり学習の枠組みとは異なる。

複数の訓練データを用いて、ドメイン適応 (domain adaptation) の枠組みによって高い精度のランキング関数を生成する試みもある。Chen ら⁹⁾ は、別の国など異なるドメインから得られる訓練データを用いることを提案している。Chen らの方法では、まず別ドメインの訓練データを用いて Gradient Boosting Tree (GBT) を構築し、目標ドメインの訓練データを用いて GBT の更新を行う。別の Chen ら⁸⁾ は、設定された効用関数によって、別ドメインの訓練データの中から目標ドメインの学習に適切なクエリを選択し、訓練データに加える TransRank と呼ばれる手法を提案している。これらの研究はいずれも素性空間における訓練データの分布の違いを考慮しているものの、適合性分布の違いを考慮していない。

クリックログから適切な適合性評価を抽出する研究がある^{1),7),15),18)-20),25)}。Joachims¹⁸⁾の方法では、クリックログにおけるクリック位置に着目し、ランキング2位の文書をクリックせずに3位の文書をクリックした場合、3位の文書が2位の文書よりも好まれるという情報を抽出する。Gaoら¹⁵⁾は、人手による適合性評価を用いることで大量のクリックログからランキングバイアスを取り除くスムージング手法を提案している。これらの研究では、クリックログのみを用いてランキング学習を行っている。

3. 複数情報源を用いたランキング学習

本章では、複数情報源を用いたランキング学習の動機と課題について述べ、転移学習を用いたランキング学習を提案する。最後に提案手法である TRankBoost について詳しく述べる。

3.1 動機と課題

本節では、複数情報源を用いる動機と課題について述べる。

1章で述べたように、人手による適合性評価は、目標となる適合性分布の情報を保持しており、訓練データを十分に用意することで、高精度なランキング学習を実現できると考えられる。

そこで、追加情報源を用いて人手による適合性評価を補完することによって性能を向上させることを試みる。ここで追加情報源とは、クリックログやソーシャルブックマークのような潜在的に目標の適合性分布を含む情報源を対象とする。本稿では、先行研究を通じて適合性分布が類似していることから、追加情報源としてクリックログを対象とする。

最も簡単には、人手による適合性評価とクリックログを混合し、1つの訓練データと見なして、既存のランキング学習手法を用いる方法が考えられる。しかしながら、既存のランキング学習手法に用いられる教師あり機械学習では、訓練データが同一分布から得られることを仮定しているため、単純に混合された訓練データを用いて適切に学習できないことが予想される。

実際に人手による適合性評価とクリックログ間における適合性分布の異なりを確認するため、あるクエリの検索結果に対して付与された人手による4段階の適合性評価と、同じ文書に対するクリックログを用意した。クリックログは Dou らの方法¹¹⁾を用いて適合性評価に変換し、人手による適合性評価と合わせるために、4段階への正規化を行った。人手による適合性評価とクリックログそれぞれについて、BM25スコア、入力リンク数という2次元の素性空間上に文書の評価点数をプロットしたものを図1に示す。図1(a)と(b)を比較する




図1 同一クエリに対する適合性分布：(a) 人手による適合性評価、(b) クリックログ
Fig. 1 Plots of documents for the same query in human relevance judgments (a) and click-through logs (b) (y-axis = inlink number, x-axis = BM25 score). Relevance levels are represented by the dots. Note that human relevance judgments and click-through logs have different relevance levels for the same plot, implying that these data have different relevance level distributions.

と、人手による適合性評価において、ほぼすべての文書に対する評価点数が3点であるのに対して、クリックログでは評価点数に散らばりがある。これより、人手による適合性評価とクリックログから得られた適合性評価の分布が異なることが分かる。

もし人手による適合性評価とクリックログが完全な相関を示した場合（すなわち、図1の(a)と(b)が完全に一致する場合）、これらの訓練データを混合したものに対して教師あり機械学習を利用することで効果が得られることが予想できる。一方、これらの間に相関が見られない場合には、人手による適合性評価にクリックログを加えても効果が得られないと考えられる。先行研究^{11),21)}によって、人手による適合性評価とクリックログの間には弱い相関があることが示されている。これより、クリックログは適合性分布が目標分布と異なるものの、部分的に目標分布の情報を保持していると考えられる。

また、本稿で用いるデータセットに含まれる49クエリ分の文書群のうち、人手による適合性評価とクリックログが両方付与された部分集合における Kendall の順位相関係数 τ を文献11)に従って計算した。具体的には、人手による適合性評価に基づいて順序付けたりストと、クリック数に基づいて順序付けたりストの順位相関係数を求めた。その結果、全クエリの平均順位相関係数 $\tau = 0.128$ が得られた。Dou ら¹¹⁾が用いたデータセットにおける相関係数に比べて値が小さいことから、本稿で用いるデータセットにおいては、人手による適合性評価とクリックログの適合性分布が異なることが分かる。

以上より、本稿における複数情報源を用いたランキング学習の課題は、人手による適合性評価に加えて、クリックログなどの適合性分布が異なる訓練データを用いて、より高精度なランキング学習を実現することである。

3.2 転移学習によるランキング学習

はじめに転移学習の説明を行った後に、本稿で提案する転移学習によるランキング学習の枠組みについて述べる。

転移学習とは、目標分布の訓練データが不十分、かつ分布が異なるデータが大量に存在する場合に、それらの訓練データを用いて分類器を学習する問題である²⁴⁾。ここで、目標分布の訓練データは、テストデータと同じ分布であると仮定する。本稿では、分布が異なるデータのことを別分布の訓練データと呼ぶ。

X_t を目標分布の事例空間、 X_d を別分布の事例空間とする。 $Y = \{0, 1\}$ を、分類問題におけるクラスラベルとする。テストデータを $S = \{(x_i^s)\}_{i=1}^k$ (ただし $x_i^s \in X_t$) で表される。訓練データ集合 $T \subseteq \{X \times Y\}$ は、目標分布の訓練データ T_t と別分布の訓練データ T_d の2つに分けられる。目標分布の訓練データは $T_t = \{(x_i^t, y_i^t)\}_{i=1}^{n_t}$ (ただし $x_i^t \in X_t$)、別分布の訓練データは、 $T_d = \{(x_j^d, y_j^d)\}_{j=1}^{m_d}$ (ただし $x_j^d \in X_d$) である。解くべき問題は、 T_t, T_d と S が与えられた際に、分類器 $\hat{c}: X \rightarrow Y$ (ただし $X = X_s \cup X_d$) を学習することである。

この問題をランキング学習の問題に適用する。 $Q_t = \{q_1^t, q_2^t, \dots, q_n^t\}$ と $Q_d = \{q_1^d, q_2^d, \dots, q_m^d\}$ が与えられたとする。ここで、 Q_t は、目標分布のクエリ集合、 Q_d は別分布のクエリ集合である。各クエリ q_i^t と q_j^d に対する文書集合を、 $\mathbf{d}_i^t = (d_{i,1}^t, d_{i,2}^t, \dots, d_{1,n_i^t}^t)$ と、 $\mathbf{d}_j^d = (d_{j,1}^d, d_{j,2}^d, \dots, d_{1,n_j^d}^d)$ (ただし n_i^t は q_i^t における文書番号、 n_j^d は q_j^d に対する文書番号を表している) とする。すると訓練データは、 $T_t = \{(q_i^t, \mathbf{d}_i^t, y_i^t)\}_{i=1}^{n_t}$ と $T_d = \{(q_j^d, \mathbf{d}_j^d, y_j^d)\}_{j=1}^{m_d}$ で表現することができる。ここで $x_i^t = (q_i^t, \mathbf{d}_i^t)$ 、 $x_j^d = (q_j^d, \mathbf{d}_j^d)$ と考えると、ランキング学習の課題は転移学習の問題と見なすことができる。

本稿においては、目標分布の訓練データ T_t は人手による適合性評価、別分布の訓練データ T_d はクリックログを表している。

たとえば、Douらによる方法¹¹⁾のように、クリック頻度を評価点数と見なす場合、検索結果の適合性評価における尺度は、クリック頻度の異なり数だけ存在することになる。人手による適合性評価は、あらかじめ設定された多段階評価であるため、クリックログから得られた訓練データを活用するためには、適合性評価の尺度の違いをどのように補正するか、という課題が導かれる。この課題に対して、我々はペアワイズ手法のランキング学習に事例転

移を適用することにより、この問題を解消しつつ、適合性分布が異なる訓練データを用いた転移学習によるランキング学習を実現する。

我々の提案の特長は2つあげられる。まず、ペアワイズ手法を用いることにより、絶対的な適合性評価を相対的な順序に落とし込むため、適合性評価のスケールの違いを緩和することが可能である。2つ目に、我々は転移学習の中から事例転移のアプローチを用いる。別分布の訓練データの中から適切な事例集合を目標分布の学習に用いる事例転移アプローチ²⁴⁾を用いることにより、人手による適合性評価による順序ペアと矛盾するような順序ペアを排除しながら学習することが可能となる。

3.3 TRankBoost

本稿では、転移学習に基づくランキング学習を実現するため、ブースティングに基づく転移学習手法である TrAdaBoost¹⁰⁾ をもとに、新しいランキング学習手法 TRankBoost を提案する。まず手法の基本となる TrAdaBoost について述べたのちに、ランキング学習への適用した TRankBoost の詳細を述べる。

TrAdaBoost は、少量の目標分布の訓練データと大量の別分布の訓練データが与えられた際に、事例転移の枠組みで目標分布の事例に対して高い性能を持った2値分類器を学習するブースティング手法¹⁴⁾ である。ブースティング手法は、重み付き訓練データから弱学習器を多数生成し、最終的に生成された弱学習器の多数決で分類を行う学習手法である。

TrAdaBoost は以下の3つの点で AdaBoost¹⁴⁾ と異なる。1つ目に、TrAdaBoost は目標分布と別分布の事例に対して、異なる重み変更方法を行う。TrAdaBoost の各試行において、生成された弱学習器によって誤分類された目標分布の事例の重みは AdaBoost と同様に増加する。しかし、誤分類された別分布の事例については、逆に重みを小さくする。これは、目標分布を予測するモデルを構築するうえでノイズとなるような事例の影響を小さくするという解釈をすることができる。2つ目は、最終的な分類器を構築するうえで各弱学習器の重みとなる重要度の推定方法に特徴がある。AdaBoost は、全事例の誤り率をもとに弱学習器の重要度を決定しているが、TrAdaBoost は、目標分布の事例のみを用いて重要度を決定する。最後に、生成された弱学習器の後半のみを用いて分類器を構築する。

以上の枠組みにより、TrAdaBoost では目標分布の予測誤差と、別分布の事例による訓練誤差を同時に最小化することを理論的に保証する。しかしながら、TrAdaBoost は別分布の事例の性質に敏感であることが報告されている¹⁰⁾。これは、誤分類された別分布の事例に対して重みを大きくすることがないため、別分布の事例をうまく分類できなかった場合には、追加データによる学習効果があまり得られず、目標分布の訓練データに過学習してしま

うためだと考えられる。

3.2 節で述べたように, TrAdaBoost の枠組みは容易にペアワイズ手法のランキング学習手法に適用することができる。具体的には RankBoost と同様にランキング学習を実現する。RankBoost では, 順序ペアを事例と見なし, すべての順序ペアに対して重み分布を保持し, 各試行において重み付け順序誤差を最小にするような弱学習器を生成する。重みの更新方法は基本的に AdaBoost と同様に行われ, 最終的なランキング関数は, 弱学習器の重み和で実現される。各弱学習器の重みは, それぞれの重要度を表しており, 当該弱学習器によって訓練データ中に含まれる順序ペアに対する正解率をもとに計算される。

我々は, TrAdaBoost が別分布の事例の性質に敏感であることに着目し, あえて理論的妥当性を捨てて, より一般的な転移学習によるランキング学習手法への変更を行う。TrAdaBoost では, 理論的に別分布の訓練誤差を最小化するために, 誤分類された別分布の事例に対して大きく重みの減少を行う。また, 生成された弱学習器の後半しか利用しないため, 別分布の訓練データの学習効果が得られていると考えられる前半の弱学習器を捨ててしまう。このため, TrAdaBoost における別分布の訓練データの学習効果が得られないという問題を防ぐために, アルゴリズムを改善する必要があると考えた。

具体的には, 以下に示す 3 つの点を調整可能なモデルパラメータとすることで, 別分布の訓練データの学習効果が得られないという問題の回避を試みる。

- (a) TRankBoost は, N 回の試行で生成された弱学習器のうち, M から N の弱学習器を用いて最終的なランキング関数を構築する。すなわち, RankBoost は $M = 1$, TrAdaBoost は $M = \lceil N/2 \rceil$ と見なすことができる。
- (b) 別分布の事例の重み更新には β を用いる。
- (c) α_t の計算に目標分布の順序ペア x^t のみを用いるか, またはすべての順序ペアを用いる。

最終的な TRankBoost のアルゴリズムを図 2 に示す。各試行において, 現在の順序ペアの重みを用いて構築された弱学習器 h_t によって各文書のスコアを出力し, スコアに基づいて順序付けを行う。この際, h_t の構築には, 任意の教師あり機械学習手法を用いることができる。たとえば, RankBoost を提案した Freund ら¹³⁾ は, 重み付け誤り率が最小になるような素性と閾値を選択し, 閾値によって $\{0, 1\}$ を出力するような WeakLearn アルゴリズムを弱学習器生成に用いている。この際, 弱学習器の重み α_t は

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1+r}{1-r} \right), \quad r = \sum_{x_0, x_1} D(x_0, x_1) (h_t(x_1) - h_t(x_0)) \quad (1)$$

によって計算される¹³⁾。

Algorithm TRankBoost

Input Data sets x^d, x^t , weak learn algorithm **Learner** and iteration number N

Initialize $D_1 = (1, 1, \dots, 1)$, β

For $t = 1, \dots, N$:

1. $D_t(x_0, x_1) = D_t(x_0, x_1) / \sum_{x_0, x_1 \in x^t \cup x^d} D_t(x_0, x_1)$
2. Train weak learner with **Learner** using distribution D_t .
4. Set α_t (Eq. 1).
5. Update the new weight vector:

$$D_{t+1}(x_0, x_1) = \begin{cases} D(x_0, x_1) \beta & x_0, x_1 \in x^d \wedge h_t(x_0) - h_t(x_1) < 0 \\ D(x_0, x_1) e^{\alpha_t (h_t(x_0) - h_t(x_1))} & \text{otherwise} \end{cases}$$

Output $H(x) = \sum_{t=M}^N \alpha_t h_t(x)$


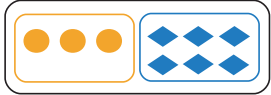



図 2 TRankBoost アルゴリズム

Fig. 2 TRankBoost algorithm.

本研究では, 最初のステップとして, TRankBoost の 2 つの実装を用意した。与えられたデータセットによって, 適切なモデルパラメータを設定することは重要な課題ではあるが, 本研究ではモデルパラメータの推定方法は取り扱わない。

1 つ目の手法は, TrAdaBoost と同じモデルパラメータを利用する。すなわち, $M = \lceil N/2 \rceil$, $\beta = 1/(1 + \sqrt{2 \ln m/N})$ (ただし N は試行回数, m は別分布の順序ペア総数である) とし, 目標分布の順序ペア x^t のみを用いて α_t を計算する。これ以降, この手法を TRankBoostI (TRB_1) と呼ぶ。

2 つ目の手法は, 追加された別分布の訓練データを重要視する。たとえばクリックログのように, 目標分布と類似性が高いと考えられる訓練データからの学習効果を得るため, より目標分布に近いデータと見なすように設定を行う。具体的には, $M = 1$, $\beta = 1$ とし, α_t を計算するために x^t と x^d の両方を用いるようにする。そのため, RankBoost に非常に近いアルゴリズムになっている。ここで, $\beta = 1$ は, 別分布の順序ペアが誤ってランキングされた際に, 重みを変更せずに今の重みを維持することを表している。この設定により, 弱学習器が誤ってランキングした別分布の順序ペアの重みを小さくしないため, TrAdaBoost が持つ問題点を解消し, 別分布の訓練データからも学習効果が得られることを期待する。この手法を TRankBoostII (TRB_2) と呼ぶ。RankBoost に別分布, 目標分布の訓練データを

	RankBoost	TRankBoost I	TRankBoost II
training data			
update parameter for diff-distribution	—	$\frac{1}{1 + \sqrt{2 \ln m / N}}$	1
how to calculate α_i	use 	use 	use 
weak learner used for ranking function	1 to N	N/2 to N	1 to N

● instance in the target-distribution
 ◆ instance in the diff-distribution

図3 RankBoost, TRankBoostI, TRankBoostII の比較

Fig.3 Comparative table of RankBoost, TRankBoostI and TRankBoostII.

与えた場合、目標分布、別分布の区別なく誤ってランキングした順序ペアの重みを大きくするため、この点において TRB.2 は RankBoost と異なる。

RankBoost (RB), TRB.2, TRB.2 の違いを図3に示す。3つの手法について、上から順番に比較している。目標分布と別分布の訓練データを用いた場合の訓練データの利用方法、別分布に対する重み変更パラメータ β の値、弱学習器に対する重要度の計算方法、最終的に利用する弱学習器の個数を表している。

4. 評価

提案手法の有効性を検証するため、2つの評価実験を通じて提案手法と既存のランキング学習手法との比較を行った。ベースラインとしては、ペアワイズ手法である RankingSVM (RSVM), RankBoost (RB) を用いた。RSVMの実装には、`svm_rank*1`を用いた。RSVMのカーネルは線形カーネルを用いた。RBは文献13)に従い、C++で実装した。RBとTRBの弱学習器には WeakLearn アルゴリズム¹³⁾を用いた。また、転移学習手法のベースラインとして、2つの訓練データを用いて独立に学習したRBの線形和をとる手法 (RB.comb)

の比較も行った。

4.1 実験条件

4.1.1 データセット

ランキング学習の有効性を評価するため、商用モバイルウェブ検索エンジンのインデックスをもとに2つのデータセットを作成した。

1つ目は人手による適合性評価データセット (human) である。あらかじめ用意された49クエリそれぞれについて得られた約300件の検索結果に対して、3人の評価者によって (非常に適合, やや適合, 部分適合, 不適合) の4段階の評価を付与した。この際、評価不能という判定が付与された文書は取り除いた。この結果、4段階の評価文書の割合は (0.3%, 18.1%, 68.4%, 13.2%) となった。評価に用いた49クエリは、Broder³⁾の分類における informational クエリが10件、navigational クエリが32件、transactional クエリが7件で構成されている。

2つ目はクリックログデータセット (click) である。同じ検索エンジンの3カ月分のクリックログの中から5,000クエリを選択した。テストデータを学習してしまうことを防ぐため、humanに含まれるクエリは含まない。文献11)に従い、クリック情報をクエリ-文書ペアのクリック頻度という情報に集約し、これを適合性評価とする訓練データを作成した。

これらの2つのデータセットの訓練データを用いて学習させたRSVM, RBと比較することで提案法を評価した。まず、human, clickのいずれか一方の訓練データで学習させたRSVM (RSVM_human, RSVM_click), RB (RB_human, RB_click) と比較した。また、humanとclickの訓練データを単純に混合し、1つの訓練データと見なして学習を行うRSVM_both, RB_bothとの比較も行った。さらに、上述のRB_combとの比較も行った。RB_combはRB_humanとRB_clickのランキング関数の重み付き線形和で得られるものであり、その重みを検証用データで最適になるように選択した。

RB_combと提案手法は、2つの異なる訓練データを同時に利用するため、humanとclickを用いた。

データセットの概要を表1に示す。#queryは、クエリ数、#doc/#queryはクエリあたりの文書数、#pairは、訓練データから生成される順序ペアの数を表している。各クエリ-文書ペアについて、12個の素性を抽出した。抽出した素性を表2に示す。

4.1.2 パラメータ選択

RBとTRBは試行回数のパラメータ N , RSVMはモデルの複雑さと訓練誤差のトレードオフを表すパラメータ c を持っている。実験では、それぞれのパラメータについて、

*1 http://www.cs.cornell.edu/People/tj/svm_light/svm_rank.html

表 1 データセットの概要
Table 1 Summary of datasets.

dataset	#query	#doc/#query	#pair
human	49	331.9	1,192,707
click	5,000	21.8	704,188

表 2 実験に用いた素性集合
Table 2 Feature set.

Feature	Description
BM25	Okapi BM25 score ²⁶⁾
BM25_log	log of Okapi BM25 score
within_site_inlink	inlink number from inside the site
between_site_inlink	inlink number from outside the site
refer_num	inlink number
refer_num_log	log of inlink number
PageRank	PageRank score ²⁾
URL_length	URL length
URL_slash_num	slash number in URL
title_length	title length
query_in_title	query is in title
is_index	is index page

$N \in \{10, 20, 30, 40, 50\}$, $c \in \{0.01, 0.05, 0.1, 0.5, 1.0\}$ の中から検証用データにおいて誤差を最小にする値を選択した。RB.comb については、試行回数パラメータ N と、2つのモデルを線形結合するための重み係数 $w \in \{0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0\}$ の中から検証用データを用いて最適値を選択した。

4.1.3 評価指標

ランキング学習の有効性を検証するため、情報検索において評価指標として広く用いられている Normalized Discounted Cumulative Gain¹⁷⁾ (NDCG) を用いた。NDCG は検索結果上位 k 位において、理想的なランキングへの近さを表す評価指標と解釈することができる。 k 位における NDCG の値は、

$$\text{NDCG}_q@k = Z_q \left(\text{rel}_1 + \sum_{i=2}^k \frac{\text{rel}_i}{\log_2 i} \right) \quad (2)$$

によって求められる。 rel_i は、 i 位における評価点数を表しており、 Z_q は、クエリ q に対する理想的なランキングにおいて NDCG の値が 1 となるように設定された正規化項である。

表 3 実験 1 の結果
Table 3 Results of experiment 1.

method	NDCG@5	NDCG@10
RSVM_human	.6161	.6186
RSVM_click	.7060	.6956
RSVM_both	.7072	.7075
RB_human	.6407	.6385
RB_click	.7104	.7188
RB_both	.6957	.7129
RB_comb	.6798	.6721
TRB_1	.6789	.6642
TRB_2	.7223	.7217

モバイルや PC ウェブ検索エンジンでは、検索結果を 5 件または 10 件表示するものが一般的であるため、評価実験では $k = 5, 10$ を用いて手法の有効性の検証を行った。また、それぞれの手法の特徴を把握するため、各手法における $k = 1, 2, \dots, 50$ の NDCG 値の比較も行った。

4.2 実験 1: 未知クエリに対する有効性評価

未知のクエリに対する有効性評価の検証を行うため、データセットをクエリで分割し、5 分割交差検定を行った。49 クエリの訓練データをクエリで 5 分割し、3 ブロックを訓練データ、1 ブロックをパラメータの設定に用いる検証用データ、残りの 1 ブロックを評価に用いるテストデータに利用した。

4.2.1 結果

表 3 に、3 つのデータセットを用いた 2 つのベースライン手法と提案手法の NDCG@5, 10 の値を示す。表 3 より、以下の結果を確認した。

- すべての手法において TRB_2 が NDCG@5, 10 において最良の結果を示した。
 - TRB_1 は、RSVM_human, RB_human を上回る精度を示したものの、その他の手法に比べて低い NDCG 値を示した。
 - RSVM_human と RSVM_click, RB_human と RB_click を比較すると、同じランキング学習手法においては、click が human よりも高い値を示した。
 - RSVM においては RSVM.both が最大の値を示しており、RB においては RB.both が RB.click に比べて低い値を示した。
- t 検定により、各手法の NDCG@5, 10 の値の差を評価したところ、TRB_2 と RSVM_human の間に有意差が確認された (p 値 < 0.05)。しかしながら、それ以外の




図 4 実験 1 における NDCG@k 値の比較結果：(a) 提案手法と human, (b) 提案手法と click, (c) 提案手法と both, RB_comb

Fig. 4 Results of experiment 1: RankingSVM (RSVM), RankBoost (RB) ranking performance across three dataset (human, click, both) and TRankBoostI (TRB_1), TRankBoostII (TRB_2) ranking performance. (a) Proposed methods and baseline methods with human dataset, (b) Proposed methods and baseline methods with click dataset and (c) Proposed methods, baseline methods with both dataset and RB_comb (y-axis = NDCG@k value, x-axis = k value).

組合せについては有意差が見られなかった。

また、図 4 に NDCG@k ($k = 1, 2, \dots, 50$) の結果を示す。図 4 より、以下の結果を確認した。

- TRB_2 は、ベースライン手法の click に対して NDCG@k ($k = 4, \dots, 50$) において上回る精度, both に対して NDCG@k ($k = 3, \dots, 50$) において上回る精度を示した。
- click を用いたベースライン手法は、検索結果上位 ($k = 1, 2, 3$) における NDCG 値が高く、それ以降で急激に値が小さくなっていることが確認できた。

4.3 実験 2：未知文書に対する有効性評価

49 クエリ分の訓練データを用いて学習したモデルに対して、同一クエリの未知文書に対する有効性の検証を行った。訓練データにおける同一クエリの文書集合を 5 分割し、1 ブロックを訓練データ、1 ブロックを検証用データ、3 ブロックをテストデータに利用した。

4.3.1 結果

表 4 にベースライン手法と提案手法の NDCG@5, 10 の値を示す。表 4 より、以下の結果を確認した。

表 4 実験 2 の結果

Table 4 Results of experiment 2.

method	NDCG@5	NDCG@10
RSVM_human	.7477	.7528
RSVM_click	.7169	.7229
RSVM_both	.7150	.7228
RB_human	.7393	.7566
RB_click	.7511	.7512
RB_both	.7509	.7540
RB_comb	.7523	.7530
TRB_1	.6968	.7040
TRB_2	.7590	.7639

- すべての手法が実験 1 における結果と比べて高い NDCG@5, 10 を示した。
- すべての手法において、TRB_2 が NDCG@5, 10 において最良の結果を示した。
- human と click を比較すると、RSVM では human の方が高い NDCG@5, 10, RB では NDCG@10 において human が高い値を示している。




図5 実験2におけるNDCG@ k 値の比較結果：(e)提案手法とhuman, (f)提案手法とclick, (g)提案手法とboth, RB_comb
 Fig.5 Results of experiment 2: RankingSVM (RSVM), RankBoost (RB) ranking performance across three dataset (human, click, both) and TRankBoostI (TRB_1), TRankBoostII (TRB_2) ranking performance. (e) Proposed methods and baseline methods with human dataset, (f) Proposed methods and baseline methods with click dataset and (g) Proposed methods, baseline methods with both dataset and RB_comb (y -axis = NDCG@ k value, x -axis = k value).

なお、各手法の性能差を t 検定により評価したところ、NDCG@5, 10 のいずれにおいても、有意な差を確認することができなかった。

また、図5にNDCG@ k ($k = 1, 2, \dots, 50$)の結果を示す。図5より、以下の結果を確認した。

- human を用いたベースライン手法に比べて、TRB_2が、NDCG@ k ($k = 1, \dots, 13$)において、高い値を示した。

5. 考察

本章では、4.2.1項と4.3.1項から得られた結果の考察を行う。本実験においてTRB_1が低い精度を示した理由については5.1節で述べる。

表3の実験結果より、NDCG@5, 10においてすべての手法において最大の値を示していることから、TRB_2の有効性を検証することができた。ここで、単純な混合であるbothに比べて高い精度のランキング学習を実現していることから、目標分布が少数であること

に起因する過学習を防ぎ、適切に別分布の訓練データを活用して汎化性能の高いランキング関数を生成していることが分かる。また、その他のNDCG値を比べると、TRB_2は、NDCG@1, 2, 3においてRSVM_clickとRB_clickに劣る以外は、すべての手法に対して高い値を示しており、ランキング下位の精度向上にも効果があることが分かる。以上より、適合性分布が異なるデータセットを用いる提案手法が有効に働いていることが分かる。

bothの結果より、単純に混合した訓練データを用いて従来のランキング学習手法では、精度を向上させることが難しいことが示唆された。RSVMにおいてわずかに精度が向上している理由としては、clickが単純な混合でもある程度過学習を抑えることが可能なほど、分布が類似していることが考えられる。RBに関しては、単純な混合でclickを用いた場合に比べて低い精度を示しており、手法によって傾向が異なることが分かる。

ベースライン手法において、単体の訓練データを用いた方法では、clickがhumanに比べて高い精度を示し、Douら¹¹⁾による実験と同様の傾向が得られた。これは、人手による適合性評価が十分ではなく、humanでは訓練データ不足により、汎化性能が低いモデルを学

習しているためだと考えられる。本実験においては5分割交差検定を用いたため、訓練データにはおよそ30クエリ分の訓練データしか含まれない。この結果より、訓練データに含まれるクエリ数が汎化性能に影響を与えていることが分かる。また、clickが高い精度を示したことにより、本データセットにおいて、クリックログから得られた適合性分布は、目標分布である人手による適合性分布に類似していることがうかがえる。

図4の結果から、clickがNDCG@1, 2, 3において高い精度を示す理由としては、クリックログ自体が検索結果上位を中心に付与されていることがあげられる。このため、クリックログから得られる訓練データに含まれる適合性評価が、検索結果上位における順序の差を重視することになり、NDCG上位に反映されたと考えられる。

実験1において、RB_combが単一の訓練データhuman, clickを用いた手法に比べて精度が低い原因は、以下の理由が考えられる。RB_combでは、独立に学習したモデルを重み係数によって線形結合し、ランキングに用いるスコアを出力する。この重み係数は検証用データに対して最適な重み係数が設定されている。そのため、実験1では検証用データを用いて設定された重み係数がテストデータに対して適切な値ではなかったことが推測される。一方で、実験2においてはRB_combによって、human, clickよりも高いNDCG値を示しており、この場合には、RB_combが適切に学習できていることが分かる。

表3と表4を比較すると、すべての手法において実験1に比べて実験2におけるNDCG値が高いことが分かる。この結果は、学習済みクエリに対する新規追加文書のランキング精度が、未知のクエリにおけるランキング精度よりも高いという直感的な予想と一致する。

実験1においては、humanを用いた手法に比べてclickを用いた手法の方がNDCGの値が高い。これは、未知クエリに対する予測問題においては、少量のクエリに関する訓練データを持つhumanを用いた手法に比べて、大量のクエリに関する訓練データを持つclickを用いた手法の方が有効に働いているものだと考えられる。

また、実験2においては反対にclickを用いた手法に比べてhumanを用いた手法の方がNDCGの値が高い傾向を示した。これは、未知文書に対する予測問題においては、当該クエリを訓練データに含み、かつクエリあたりの文書数も多いhumanを用いた手法の方が良いモデルを学習するという直感に合う結果である。

以上より、適合性分布が異なる複数情報源を訓練データとして用いる場合には、従来手法では実現が困難であることが示唆され、提案手法の枠組みによって効果的なランキング学習が実現可能なことを検証した。

5.1 TRankBoostIの性能が低い原因

TRB.1が低い精度を示した原因は2つ考えられる。1つ目に、利用する弱学習器の数が影響していると考えられる。TRB.1の各試行における α_t の値を眺めたところ、試行ごとにほぼ単調減少していることを確認した。TRB.1では、試行全体の後半の弱学習器のみを用いてランキング関数を実現するため、効果的な弱学習器を捨ててしまっていることが分かる。しかしながら、実際にTRB.1のMのパラメータを1に変更した手法の評価を行ったところ、大きな変化は見られなかった。これより、TRB.1の性能についてはM以外の影響が大きいことが推測できる。

そこで2つ目の原因として、誤った別分布の順序ペアに対する重み変更のパラメータ β の値が大きいということが推測される。TrAdaBoostでは、誤ってランキングした順序ペアについて、一定の割合で重みを小さくする。各試行において別分布の順序ペアが一定の割合で誤ると仮定すると、試行を繰り返すごとに別分布の訓練データの影響がなくなり、最終的には目標分布の訓練データが弱学習器を生成する際の支配的な要因となる。さらにTrAdaBoostでは後半の弱学習器のみを用いるため、目標分布の訓練データに対して過学習した弱学習器をより多く利用することになる。そのため、試行回数を適切に設定しなければ、先述した過学習の問題を解決できない。humanよりも高い精度を示しているものの、bothに劣るのはこのためだと考えられる。TRB.2では $\beta = 1$ かつ $M = 1$ に設定することで、別分布の訓練データに対してより適合するようなランキング関数を生成する。評価実験において最良の結果を得ていることから、人手による適合性評価の過学習することなく、より高い汎化性能を持ったランキング関数を生成していることが分かる。

6. おわりに

本稿では、転移学習の枠組みを用いることにより、適合性分布が異なる訓練データを用いてランキング関数を生成するランキング学習手法の枠組みを提案した。具体的には、学習に役立つ事例を選択的に用いる事例転移の方法とペアワイズ手法を組み合わせることによって転移学習によるランキング学習を実現する。我々は、この枠組みを用いた新しいランキング学習手法であるTRankBoostを提案した。

RankingSVMやRankBoostのような従来のランキング学習手法では、教師あり機械学習の枠組みを用いるため、文書ペアが同一の分布から抽出されるという仮定をおいているため、適合性分布が異なる訓練データを単純に混合するだけでは、従来法によって適切にランキング学習ができないと考えた。

商用モバイル検索エンジンのインデクスとクリックログをもとに作成されたデータセットを用いた2つの評価実験を通じて、提案手法 TRankBoostII によって、NDCG@5, 10 の値でベースライン法を上回る精度でランキング学習が可能であることを確認した。また、ベースライン手法については、単純な混合では精度を向上させることが困難であることが示唆された。これにより、提案手法を用いることにより、従来手法では達成が困難であった目標分布と適合性分布が異なる訓練データを同時に用いて、高精度なランキング学習が実現可能なことを示した。

今後は以下の課題を検討したい。

- 他のデータセットを用いて実験を行う必要があると考えている。人手による適合性評価が多いとき、追加する別分布の訓練データの類似度によっても結果が変わるため、TRankBoostI, TRankBoostII の有効性の検証を通じてロバスト性の評価を行いたい。
- TRankBoost のモデルパラメータ (α_t, β, M) を自動的に推定する方法について検討したい。
- 本研究では適合性分布が異なる追加情報源としてクリックログを用いたが、クリックログ以外に暗黙的な適合性評価を含むデータセットに対して本手法の適用と評価を行いたい。
- 本研究では、適合性分布の尺度の違いを補正するために、ペアワイズ手法に着目した。それ以外のポイントワイズ手法やリストワイズ手法にも転移学習を適用したい。

複数情報源を用いたランキング学習はまだ発展途上の研究テーマである。新たな手法の検討も含め、提案法のさらなる改善に取り組みたい。

参 考 文 献

- 1) Agrawal, R., Halverson, A., Kenthapadi, K., Mishra, N. and Tsaparas, P.: Generating labels from clicks, *WSDM '09: Proc. 2nd ACM International Conference on Web Search and Data Mining*, pp.172–181, ACM (2009).
- 2) Brin, S. and Page, L.: The anatomy of a large-scale hypertextual Web search engine, *WWW7: Proc. 7th International Conference on World Wide Web 7*, pp.107–117, Elsevier Science Publishers B.V. (1998).
- 3) Broder, A.: A taxonomy of web search, *SIGIR Forum*, Vol.36, No.2, pp.3–10 (2002).
- 4) Burges, C., Shaked, T., Renshaw, E., Lazier, A., Deeds, M., Hamilton, N. and Hullender, G.: Learning to rank using gradient descent, *ICML '05: Proc. 22nd International Conference on Machine Learning*, pp.89–96, ACM (2005).
- 5) Cao, Y., Xu, J., Liu, T.-Y., Li, H., Huang, Y. and Hon, H.-W.: Adapting ranking SVM to document retrieval, *SIGIR '06: Proc. 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.186–193, ACM (2006).
- 6) Cao, Z., Qin, T., Liu, T.-Y., Tsai, M.-F. and Li, H.: Learning to rank: From pairwise approach to listwise approach, *ICML '07: Proc. 24th International Conference on Machine Learning*, pp.129–136, ACM (2007).
- 7) Carterette, B. and Jones, R.: Evaluating search engines by modeling the relationship between relevance and clicks, *NIPS '07: Proc. Conference on Neural Information Processing Systems*, pp.217–224, MIT Press (2007).
- 8) Chen, D., Yan, J., Wang, G., Xiong, Y., Fan, W. and Chen, Z.: TransRank: A Novel Algorithm for Transfer of Rank Learning, *Proc. 8th IEEE International Conference on Data Mining Workshops*, pp.106–115, IEEE Computer Society (2008).
- 9) Chen, K., Lu, R., Wong, C.K., Sun, G., Heck, L. and Tseng, B.: Trada: Tree based ranking function adaptation, *CIKM '08: Proc. 17th ACM Conference on Information and Knowledge Management*, pp.1143–1152, ACM (2008).
- 10) Dai, W., Yang, Q., Xue, G.-R. and Yu, Y.: Boosting for transfer learning, *ICML '07: Proc. 24th International Conference on Machine Learning*, pp.193–200, ACM (2007).
- 11) Dou, Z., Song, R., Yuan, X. and Wen, J.-R.: Are click-through data adequate for learning web search rankings?, *CIKM '08: Proc. 17th ACM Conference on Information and Knowledge Management*, pp.73–82, ACM (2008).
- 12) Duh, K. and Kirchhoff, K.: Learning to rank with partially-labeled data, *SIGIR '08: Proc. 31st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.251–258, ACM (2008).
- 13) Freund, Y., Iyer, R., Schapire, R.E. and Singer, Y.: An efficient boosting algorithm for combining preferences, *J. Mach. Learn. Res.*, Vol.4, pp.933–969 (2003).
- 14) Freund, Y. and Schapire, R.E.: A decision-theoretic generalization of on-line learning and an application to boosting, *J. Comput. Syst. Sci.*, Vol.55, No.1, pp.119–139 (1997).
- 15) Gao, J., Yuan, W., Li, X., Deng, K. and Nie, J.-Y.: Smoothing clickthrough data for web search ranking, *SIGIR '09: Proc. 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.355–362, ACM (2009).
- 16) Herbrich, R., Graepel, T. and Obermayer, K.: Large Margin Rank Boundaries for Ordinal Regression, *Advances in Large Margin Classifiers*, Smola, A., Bartlett, P., Schölkopf, B. and Schuurmans, D. (Eds.), pp.115–132, MIT Press (2000).
- 17) Järvelin, K. and Kekäläinen, J.: Cumulated gain-based evaluation of IR techniques,

- ACM Trans. Inf. Syst.*, Vol.20, No.4, pp.422–446 (2002).
- 18) Joachims, T.: Optimizing search engines using clickthrough data, *KDD '02: Proc. 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.133–142, ACM Press (2002).
- 19) Joachims, T., Granka, L., Pan, B., Hembrooke, H. and Gay, G.: Accurately interpreting clickthrough data as implicit feedback, *SIGIR '05: Proc. 28th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.154–161, ACM (2005).
- 20) Joachims, T., Granka, L., Pan, B., Hembrooke, H., Radlinski, F. and Gay, G.: Evaluating the accuracy of implicit feedback from clicks and query reformulations in Web search, *ACM Trans. Inf. Syst.*, Vol.25, No.2, p.7 (2007).
- 21) Kamps, J., Koolen, M. and Trotman, A.: Comparative analysis of clicks and judgments for IR evaluation, *WSCD '09: Proc. 2009 Workshop on Web Search Click Data*, pp.80–87, ACM (2009).
- 22) Kim, K.-H. and Choi, S.: Incremental learning to rank with partially-labeled data, *WSDC '09: Proc. 2009 Workshop on Web Search Click Data*, pp.20–27, ACM (2009).
- 23) Li, P., Burges, C.J.C. and Wu, Q.: McRank: Learning to Rank Using Multiple Classification and Gradient Boosting, *NIPS '07: Proc. 21st Annual Conference on Neural Information Processing Systems* (2007).
- 24) Pan, S.J. and Yang, Q.: A Survey on Transfer Learning, Technical Report HKUST-CS08-08, Department of Computer Science and Engineering, Hong Kong University of Science and Technology, Hong Kong, China (2008).
- 25) Radlinski, F., Kurup, M. and Joachims, T.: How does clickthrough data reflect retrieval quality?, *CIKM '08: Proc. 17th ACM Conference on Information and Knowledge Management*, pp.43–52, ACM (2008).
- 26) Robertson, S., Walker, S., Jones, S., Hancock-Beaulieu, M. and Gatford, M.: Okapi at TREC-3, *Proc. 3rd Text REtrieval Conference (TREC-3)*, pp.109–126 (1994).
- 27) Tsai, M.-F., Liu, T.-Y., Qin, T., Chen, H.-H. and Ma, W.-Y.: FRank: A ranking method with fidelity loss, *SIGIR '07: Proc. 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.383–390, ACM (2007).
- 28) Usunier, N., Truong, V., Amini, M.R. and Gallinari, P.: Ranking with Unlabeled Data: A First Study, *NIPS2005 Workshop: Learning to Rank* (2005).
- 29) Valizadegan, H., Jin, R., Zhang, R. and Mao, J.: Learning to Rank by Optimizing NDCG Measure, *Advances in Neural Information Processing Systems 22*, Bengio, Y., Schuurmans, D., Lafferty, J., Williams, C.K.I. and Culotta, A. (Eds.), pp.1883–1891 (2009).
- 30) Xu, J., Liu, T.-Y., Lu, M., Li, H. and Ma, W.-Y.: Directly optimizing evaluation measures in learning to rank, *SIGIR '08: Proc. 31st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.107–114, ACM (2008).
- 31) Yue, Y., Finley, T., Radlinski, F. and Joachims, T.: A support vector method for optimizing average precision, *SIGIR '07: Proc. 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.271–278, ACM (2007).

(平成 22 年 3 月 20 日受付)

(平成 22 年 7 月 6 日採録)

(担当編集委員 小山 聡)



数原 良彦 (正会員)

2006 年慶應義塾大学理工学部管理工学科卒業。2008 年同大学大学院理工学研究科開放環境科学専攻修士課程修了。同年日本電信電話株式会社入社。現在, NTT サイバーソリューション研究所所属。情報検索の研究に従事。人工知能学会, ACM 各会員。



宮原 伸二

2000 年大阪大学大学院工学研究科システム工学専攻前期博士課程修了。同年日本電信電話株式会社入社。現在, NTT サイバーソリューション研究所所属。情報可視化, 情報検索の研究開発に従事。



植松 幸生

2001年東京理科大学工学部卒業。2003年同大学大学院理工学研究科修士課程修了。2008年同大学院理工学研究科博士課程修了。2003年日本電信電話株式会社入社。現在、NTTコミュニケーションズ株式会社先端IPアーキテクチャセンタ所属。東京理科大学工学部経営工学科非常勤講師。情報検索、情報推薦、データマイニング等に興味を持つ。博士(工学)。

人工知能学会，日本データベース学会各会員。



金田 有二

2000年東京大学工学部計数工学科卒業。2002年同大学大学院修士課程修了。同年日本電信電話株式会社入社。NTTコミュニケーション科学基礎研究所入所。現在、NTTレゾナント株式会社サーチ事業部所属。検索システム，検索エンジンの開発に従事。



藤野 昭典(正会員)

1995年京都大学工学部精密工学科卒業。1997年同大学大学院工学研究科精密工学専攻修士課程修了。同年日本電信電話株式会社入社。現在、NTTコミュニケーション科学基礎研究所所属。機械学習，テキスト処理等の研究に従事。博士(情報学)。2004年度電子情報通信学会PRMU研究奨励賞，2005年FIT論文賞等受賞。電子情報通信学会，IEEE各会員。



片岡 良治(正会員)

1987年千葉大学大学院電子工学専攻修士課程修了。同年日本電信電話株式会社に入社。以来、トランザクションの並行処理制御方式の研究，マルチメディア情報システムの研究，ポータルサービスシステムの研究開発に従事。現在、NTTサイバーソリューション研究所所属。