

カテゴリを用いた Wikipedia における著者の質推定手法

岩井 一晃[†] 鈴木 優[‡] 石川 佳治^{‡,†,*}

[†] 名古屋大学大学院情報科学研究科 [‡] 名古屋大学情報基盤センター * 国立情報学研究所

{iwai,suzuki,ishikawa}@db.itc.nagoya-u.ac.jp

概要 本研究では、カテゴリを用いた Wikipedia における著者の質を推定する手法の提案を行う。著者の質とは、ある著者が行った削除や追加、残存という編集の質を指す。これらが良質であるかどうかは、自動的に判定することが困難である。従来手法として著者が記事で行った編集の種類ごとに編集の質推定を行った。本研究ではカテゴリの情報を用いることによって、ページごとにおける著者の質をより高精度に推定する。カテゴリを用いることによって、著者の編集を複数ページの編集から評価することができる。カテゴリ内で高い評価を受けている著者はそれらの記事について詳しい著者であると考えられるため、記事で行った編集をより高く評価する。一方で、低い評価を受けている著者は詳しくない著者と考えられるため評価をより低く評価する。このようにカテゴリを考慮した著者の質再評価を行うことによって、より高精度に著者の質を推定が可能である。

キーワード Wikipedia, 著者の質, データマイニング, カテゴリ

1 はじめに

Wikipedia とは利用者によって生成されるウェブ上の百科事典である。利用者であれば、誰でも編集することが出来、広い分野の情報を取得することが可能である。著者も各分野の専門家から、各分野に精通していない人まで様々な人が存在する。それらの著者が、新しい情報を記述、間違っている記述は削除し、正しい記述は残存を行う。これらの編集を経て、Wikipedia の記事は構成されている。編集の質は著者に依存し、良質な、または悪質な編集を行う著者を推定、提示することによって、Wikipedia を閲覧、編集する際の利用者支援を行うことができる。従来手法 [1] として、記事ごとに著者が行った編集の質推定を行った。著者の編集は、編集を行った著者から編集が行われた著者への評価と考える。削除という編集は、記述が間違っていると著者が考えたために行われる。これは、編集を行った著者が記述内容が誤っているという評価を、編集が行われた文章を記述した著者に対して行っていると考えられる。同様に、残存という編集は、記述が正しいと著者が考えたために行われ、編集を行った著者が記述内容が正しいという評価を、編集が行われた文章を記述した著者に対して行っていると考えられる。ただし、この削除や残存という編集が必ずしも正しいとは限らない。誤った文章を記述する著者が記述した文章を残存する著者が行う残存は誤っている可能性が高い。また同様に、正しい文章を記述する著者が記述した文章を削除する著者が行う削除は誤っている可能性が高い。従来手法ではこのように削除、残存の質を考慮した記述の質推定及び、記述の質を考慮した削除、残存の質推定を行った。これら

の編集に対し、それぞれが良質か悪質かを推定した。良質な編集とは、その編集によって、記事内容が以前の状態よりも向上したと考えられる編集とする。同様に悪質な編集とは、その編集によって、記事内容が以前の状態よりも低下したと考える編集とする。

しかし、従来手法では記事ごとに著者の質推定を行った。そのため著者が他の記事で行った編集情報を考慮できていないことが問題であった。そこで本研究ではカテゴリの情報を用いる。カテゴリとは、関連がある文書群であり、Wikipedia に存在するカテゴリを利用する。カテゴリには記事と下位カテゴリとして別のカテゴリが含まれることがある。本研究ではカテゴリ内に含まれる下位カテゴリ内の記事もカテゴリに属する記事として扱う。カテゴリ内の多くの記事で高い評価を受けている著者ならば、それらの記事について詳しい著者であると考えられる。また、低い評価を受けている著者ならば詳しくない著者と考えられる。これらよりカテゴリに詳しい著者ならば、カテゴリ内の記事における評価を他の著者よりも高くすべきであり、一方、詳しくない著者ならば低くすべきである。このようにカテゴリを用い、著者の質を再評価することによって、記事ごとの編集の質をより高精度に推定することが可能となる。

本研究では著者があるカテゴリにおいてどれだけ精通しているかを、著者がカテゴリに属する記事において著者が受けた評価と著者が編集を行ったカテゴリに属する記事数を用いて判別する。著者がカテゴリに精通している度合いをカテゴリ評価値として、著者ごとに算出する。

戦車というカテゴリにおいて図1のような結果が出た。著者3人の著者が編集を行ったカテゴリ内の記事での編集評価と著者がカテゴリ内の記事を編集した数からカテゴリ評価値を算出する。これらの数値はどちらか一方が

カテゴリ：戦車		
著者:Baku13	著者:伊達正宗	著者:曾禰越後守
カテゴリ内の編集評価順位		
200位	413位	723位
カテゴリ内の記事編集数順位		
1位	250位	22位
カテゴリ評価値順位		
1位	219位	25位

図1 カテゴリ評価値

高いだけではカテゴリ評価値が高くなり、総合して高い値を持つ著者が高いカテゴリ評価値を持つ。このカテゴリ評価値を従来手法で算出した著者の質に対して反映することによって、より高精度な著者の質推定を行う。

2 関連研究

Wikipedia の情報から特徴量を抽出し有用に扱う研究は多く存在している。例えば、Wilkinson ら [2] が行った研究では、著者が行った平均の編集回数を用いてページの質を算出している。また Kittur ら [3] は Wikipedia における著者の編集回数、編集文字数について分析を行った。少数の著者が記事を大量に編集しており、これらの著者も時間の経過とともに編集回数が減る特徴があることが分かった。Predhorsky ら [4] は破壊活動が行われた記事を閲覧された回数から、その編集が与えた影響を算出した。さらにその破壊活動について七つの特徴付けを行っている。本研究では著者の編集履歴を用いて、著者の質を推定している。著者が編集を行った文章はどの著者が記述した文章であるかという著者間の編集における関わりを考慮している点異なる。

Ulrik ら [5] は著者の編集履歴から編集ネットワークを作成し、著者がどのような編集を行う著者かの分析と編集ネットワークの可視化を行った。編集ネットワークとは、著者と著者の編集における関わりを可視化したネットワークである。同様に Kittur ら [6] が行った研究では著者が行った編集から対立する構造を発見し、著者間における対立構造の可視化を行っている。また Vuong ら [7] が行った研究では記事と著者の対立構造を発見している。対立構造を発見することによって、著者に特徴付けを行うことが可能である。本研究でも編集履歴から著者と著者の編集における関わりをグラフ化し、それらの分析を行っている。さらに本研究では著者の質を考慮して、その著者と関与している著者の質を推定している。Suzuki ら [8] は文章の質を文章の残存率と著者の質から算出する手法を提案している。文章の残存率から文章の

質を算出、算出した文章の質から著者の質を算出する。さらに文章の質を著者の質から、著者の質を文章の質から相互的に算出を行う。これを行うことによって、著者の質を考慮した文章の質算出が可能となる。本研究でも同様に、著者の質を相互的に推定している。これにより編集による関わりを持つ著者同士が持つ著者の質を考慮した著者の質推定が可能である。また、本研究では削除に関してだけでなく、著者の記述、著者の残存に関するも着目しているが異なる。

Wikipedia のカテゴリを有用な情報源として利用、評価している研究も多く存在する。Holloway ら [9] はカテゴリの共起情報を用いて、カテゴリのネットワークを示すセマンティックマップを作成した。このセマンティックマップによって編集が行われた時間、著者が編集を行う範囲を示した。Hu ら [10] は Wikipedia の情報を文書クラスタリングに利用した。この中でカテゴリは類似した記事内容の集合と考えられ、文書の関連性を判定するために利用されている。Schonhoven ら [11] も同様にカテゴリのネットワークを用いて文書の分類を行った。カテゴリごとにどの単語が属しているかという重みを算出し、文章がどのカテゴリであるかを判別した。また Kittur ら [12] は Wikipedia においてカテゴリは利用者が作り上げたトピックの分類であると考えた。Wikipedia の記事は複数のカテゴリに属することが可能であるため、グラフとして考える。このグラフのエッジ数や、深さを用いて木構造に変換することによって、トピック分布を考慮し、カテゴリをより利用しやすくした。本研究でもカテゴリは利用者によって作成されたトピックの分類と考え、あるカテゴリに詳しい著者ならば、そのカテゴリに含まれる記事においてより良質な編集を行っていると考えた。よって、このカテゴリを用いて著者が行った編集の質を再評価することは有用であると考えられる。

3 提案手法

本手法では、従来手法で算出した著者の評価値を用いて、著者がカテゴリにどれだけ精通しているかを推定する。このカテゴリにおける著者の評価値をカテゴリ評価値と呼ぶ。カテゴリ評価値を用いて、編集の質を再計算し、著者の質推定を行う。

システムの流れは図2のようにになっている。始めに利用者が入力したカテゴリ名を用いて、Wikipedia からカテゴリに属する記事の編集履歴を取得する。取得した編集履歴を用いて①にて従来手法を行う。従来手法によって、記事ごとにおける著者が行った編集の質推定を行う。次に、②にてカテゴリに属している記事における著者の編集情報を用いて、カテゴリ評価値を算出する。カテゴリにおける著者の評価値はカテゴリ精度値、カテゴリ網

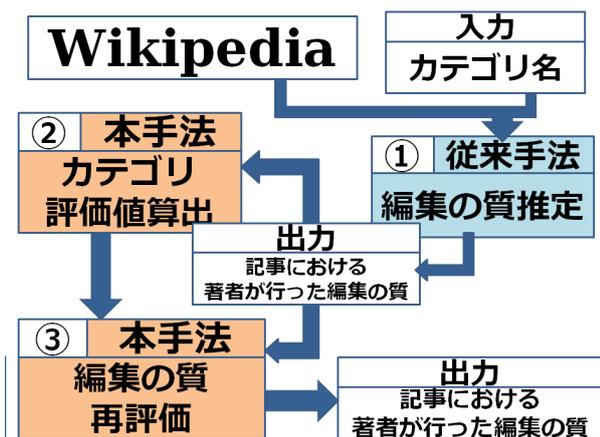


図2 本研究システムの流れ

羅値から算出を行う。カテゴリ精度値はカテゴリに属する記事で行った編集の評価が高ければ高い値となる値である。編集の評価は①において算出した編集の評価を用いる。この値は著者がその記事について詳しいかどうかを示す値である。一方、カテゴリ網羅値は著者がカテゴリに属する記事を編集すればするほど高い値となる値である。これは著者がそのカテゴリについてどれだけ幅広く編集しているかを示す値である。カテゴリ精度値とカテゴリ網羅値を用いてカテゴリ評価値の算出を行う。最後に③にて、②で算出したカテゴリ評価値を用いて、①で算出した編集の質を再評価する。そして再評価した編集の質を利用者に出力する。

3.1 著者の評価値算出

著者は編集を行い、Wikipediaの記事を更新する。本研究では従来手法と同じように、文章の削除と残存、記述を編集と考える。これらの編集について、以下の仮定が成り立つものとする。

1. 著者は記述内容が誤っていると考えられる文章を削除
2. 著者は記述内容が正しいと考えられる文章を残存

これらより編集は著者から、編集対象となる文章への評価と考えることができる。また記述した文章内容が正しいか、誤っているかは文章記述者に依存すると考えられる。よって、文章への評価は同様に、文章を記述した著者への評価とも考えることができる。このように本研究では、編集を著者から著者へ対する評価と考える。さらに削除、残存を行った著者の削除、残存に関する質も考慮する。編集をグラフにすることによって、著者がどの著者からどれだけ評価されているか、また同様に著者がどの著者をどれだけ評価するかを知ることが出来る。構築したグラフに対し、リンク構造解析を行うことによって、削除、残存といった編集の質を考慮にいたした著

者が行った編集の質を推定する。

3.2 カテゴリ評価値の算出

3.1 説で算出した著者が行った編集の質を用いて、カテゴリ評価値を算出する。カテゴリ評価値とは著者がカテゴリにどの程度詳しいかを示す度合いとなっている。この数値が高ければ高いほど著者はそのカテゴリに詳しい著者といえる。カテゴリに詳しい著者ならば、カテゴリに属している記事における編集の質は高いものが期待できる。よってカテゴリ評価値を用いて、著者が行った編集の質を再評価することによって、より高精度な編集の質推定を行う。本研究ではWikipediaの記事につけられている既存のカテゴリを用いる。カテゴリに含まれる下位カテゴリに属する記事もカテゴリに服荒れる記事として扱う。記事は複数のカテゴリに属することができ、またカテゴリの重複もありうる。このカテゴリは著者の編集によって作成され、項目ごとに類似した記事が同じカテゴリに属する。

カテゴリ評価値は以下の条件を用いて算出する。

1. カテゴリに属する記事で行った編集の評価
2. カテゴリに属する記事の編集記事数

本研究ではカテゴリ評価値算出のために、カテゴリ精度値、カテゴリ網羅値の算出を行う。カテゴリ精度値は、カテゴリに属している記事で著者が行った編集がどれだけ高い評価を受けているかの値である。この値が高いほど、カテゴリに属している記事において著者の編集が良質であると考えられる。一方、カテゴリ網羅値は著者がカテゴリに属している記事に対し、どれだけの数を編集しているかの値である。この値が高いほど、著者はカテゴリに属している記事について編集していると考えられる。

これらの算出式は以下に従う。

$$Pr(C_i, u_f) = \frac{\sum_{k=1}^K S(u_f, P_k)}{E(C_i, u_f)} \quad (1)$$

$$Re(C_i, u_f) = \frac{E(C_i, u_f)}{|K|} \quad (2)$$

C はカテゴリ名、 u は著者、 P は記事名を表す。またこれらはそれぞれ、 i, f, k で表されるIDを持つ。 K はあるカテゴリに属している記事数である。ある記事 P_k における、著者 u_f の編集評価値を $S(u_f, P_k)$ によって算出する。このカテゴリ内での合計を、そのカテゴリで著者が編集した記事数である $E(C_i, u_f)$ で平均する。これによって算出される $Pr(C_i, u_f)$ はカテゴリ C_i における著者 u_f のカテゴリ精度値を示す。またカテゴリ C_i で著者 u_f が編集した記事数をカテゴリに属している記事

数 K で割った物をカテゴリ網羅値とする。このカテゴリ網羅値を $Re(C_i, u_f)$ と示す。

図1のように記事編集が行われたとする。カテゴリ内の著者は全部で2809人である。Baku13はカテゴリ内の記事を最も多く編集しており、カテゴリ内の編集評価順位は200位である。また伊達正宗はそれぞれの順位が413位、250位である。さらに曾禰越後守は22位、723位である。Baku13の記事編集数は216記事である。カテゴリ戦車に属する記事は312記事であるため式(2)を適用すると、Baku13のカテゴリ網羅値は0.69となる。またカテゴリ精度値は、これら216記事についての著者の編集評価値を用い、式(1)を適用すると、0.23となる。同様に伊達正宗、曾禰越後守についてもこれらの式を適用するとこの図におけるカテゴリ精度値、カテゴリ網羅値は表1のようになる。この数値をそれぞれの編集における著者ごとについて算出する。

3.3 編集の質再評価

3.2節で算出を行ったカテゴリ精度値、カテゴリ網羅値を用いて著者ごとにカテゴリ評価値を算出する。カテゴリ精度値は著者が編集を行った記事における著者が行った編集の質である。一方、カテゴリ網羅値はカテゴリに属している記事のうち、著者が編集した記事の割合である。これらはトレードオフの関係にあり、カテゴリ精度値が高くなればなるほど、カテゴリ網羅値は低くなる傾向がある。同様に、カテゴリ網羅値が高くなればなるほど、カテゴリ精度値は低くなる傾向がある。著者がカテゴリに詳しい場合、これらの値が総合的に高い著者がカテゴリに詳しいといえることができる。カテゴリ評価値は以下の算出式によって算出する。

$$F(C_i, u_f) = \frac{2Re(C_i, u_f)Pr(C_i, u_f)}{Re(C_i, u_f) + Pr(C_i, u_f)} \quad (3)$$

$F(C_i, u_f)$ はカテゴリ C_i における著者 u_f のカテゴリ評価値である。これはカテゴリ精度値を示す $Pr(C_i, u_f)$ と、カテゴリ網羅値を示す $Re(C_i, u_f)$ の調和平均である。

図1についてカテゴリ評価値を算出する。Baku13はカテゴリ精度値が0.23、カテゴリ網羅値が0.69より、カテゴリ評価値は0.36となる。同様に伊達正宗のカテゴリ評価値は0.09、曾禰越後守は0.41となる。これらの値をカテゴリに属する記事を編集した全ての著者につい

表1 図1におけるカテゴリ精度値、網羅値

著者名	カテゴリ精度値	カテゴリ網羅値
Baku13	0.23	0.692
伊達正宗	0.19	0.022
曾禰越後守	0.17	0.014

て算出する。

またカテゴリ評価値に対して最大のを1、最小のを0にするような正規化を行う。正規化を行ったカテゴリ評価値を用いて、編集の質を再評価する。編集の質再評価は以下の算出式に従う。

$$Sn(u_f, P_k) = S(u_f, P_k)Fn(C_i, u_f) \quad (4)$$

$Sn(u_f, P_k)$ は再評価されたカテゴリ C_i に含まれる記事 P_k における、著者 u_f の編集評価値である。著者 u_f の記事 P_k における編集評価値である $S(u_f, P_k)$ に対し、正規化を行ったカテゴリ評価値 $Fn(C_i, u_f)$ をかけることにより算出する。これにより、著者がカテゴリにどれだけ精通しているかを考慮した著者が行った編集の質評価が可能となる。

4 実験

本研究では従来手法で推定を行った著者の質と、本手法を用いて推定を行った著者の質を比較する。従来手法と本手法での精度の違いからカテゴリ評価値を用いて、著者の質を再評価した影響を調査する。本実験では、著者の編集評価値が上位10名、下位10名にある著者を良質な推定を行う著者、または悪質な編集を行う著者とする。正解セットと推定結果が一致していれば正解、そうでなければ不正解とする。これらの正解数を精度とし、カテゴリ評価値を用いた再評価によって精度がどのように変化したかを観測する。また本実験では同じカテゴリに属している著者数、編集回数が大きく違う記事を実験対象とし、それらの違いによってどのような変化が起きるかを比較する。

また本実験ではBOTを評価対象著者としない。BOTとはプログラムに応じてリンク等の追加を行う著者である。BOTはカテゴリ等に捉われず、多くの記事で編集を行う。BOTはカテゴリに属する記事を多く編集するが、カテゴリの内容に詳しい訳ではなく、機械的に編集を行っているためどれだけ高いカテゴリ評価値であってもカテゴリに詳しい著者ではないと考えたため、実験結果からBOTのデータを排除している。

4.1 実験データ

本研究ではWikipediaにおける2012年3月15日時点でのデータを用いて実験を行う。本手法をカテゴリに適用し、著者が行った編集の質推定を行う。使用したカテゴリはWikipediaにおける戦車というカテゴリを利用した。カテゴリは312記事から成り立っている。また、これらのカテゴリは2809人の著者が編集しており、この内、119人はBOTと呼ばれる自動編集を行うアカウントである。

本実験ではこれらのカテゴリに属する記事の戦車、九

四式軽装甲車について扱う。戦車は 289 人の著者が編集しており、582 回の編集が行われた記事である。一方、九四式軽装甲車は 33 人の著者が編集しており、86 回の編集が行われた記事である。

4.2 実験結果

本研究の実験結果は表 2、表 3 のようになった。従来手法と本手法の欄は正解人数を示している。著者の順位はほとんどの結果で変動しており、従来手法と本手法の結果が同じ精度でも著者は異なる。戦車の記事については大部分で精度の向上が見られた。一方、九四式軽装甲車については大きな変化が見られず、一部では精度の減少が見られた。

カテゴリ戦車において高いカテゴリ評価値を持つある著者に注目する。記述に関してはカテゴリ内の著者で記述を行った 2601 人中 1 位であり、同様に削除に関しても 2510 人中 58 位、残存に関しても 2809 人中 11 位である。この著者は戦車の記事において、残存から推定される記述、削除について、また九四式軽装甲車において、残存について従来手法では上位 10 位に入っていなかった著者である。しかし、これらの記事において良質な編集をしていると人手で判断されていた。これが本手法を適用したところ、戦車の記事における残存から推定される記述については 3 位、また削除については 7 位となった。また同様に九四式軽装甲車の記事においては 7 位となった。また他の編集において既に 10 位以内に入っていた場合でも順位が上に上がるという結果が見られた。

4.3 考察

本実験では著者が行った編集の質を同じカテゴリに属する著者数、記事の編集回数が異なる記事について調査した。どちらの記事においても、カテゴリ評価値の高い著者がより上位に、カテゴリ評価値の低い著者がより下位の編集評価値を持つ著者と判定された。これにより、従来手法に比べ、本手法の結果について精度向上が見られた。

また著者数、記事の編集回数が多い記事のほうがより

精度が向上した。この原因として考えられるのはまず著者数の違いである。本実験ではそれぞれの編集について編集評価値が上位 10 名、下位 10 名の著者を対象とし、これらの著者を良質な編集、または悪質な編集を行う著者として考えた。しかし、戦車の記事には著者が 289 人いるのに対し、九四式軽装甲車の記事には著者が 33 名しか存在しない。記事によって著者数は大きく異なるため、同様に良質な編集を行う著者、悪質な編集を行う著者数は大きく異なると考えられる。よって、九四式軽装甲車の記事では良質とも悪質とも取れない著者が編集評価値の上位 10 名、または下位 10 名に入ってしまったため、精度の向上が戦車の記事に比べ低いものとなった。著者数の変動に対し、適した人数の良質な編集を行う著者、悪質な編集を行う著者を提示する必要があると考える。

また、従来手法は編集回数が少ない記事について、精度が低いことが挙げられる。これにより、カテゴリ評価値を用いた編集結果の再評価が誤った数値になることが考えられる。カテゴリ評価値の算出においてもカテゴリに属する全ての記事についての編集評価値を用いて行っているため、編集回数が少ない記事についての従来手法の改良が必要であると考えられる。

5 おわりに

本稿では Wikipedia の既存カテゴリを用いて、記事ごとにおける著者が行った編集の質評価を行った。カテゴリに属する記事について著者が行った編集を従来手法を用いて評価する。これらの評価からカテゴリについて著者がどの程度詳しいかという値であるカテゴリ評価値の算出を行う。このカテゴリ評価値が高い著者ほど、カテゴリに詳しい著者ということが出来る。カテゴリに詳しい著者となる条件として、カテゴリに属する多くの記事を編集する著者であり、それらの編集が高い評価を受けている著者ならばカテゴリに詳しい著者であると考えられる。カテゴリ評価値を用いて、記事ごとに著者が行った

表 2 記事戦車の実験結果

編集内容	質	従来手法	本手法
残存	良質	9	9
	悪質	7	7
残存から推定される記述	良質	7	8
	悪質	4	7
削除	良質	6	7
	悪質	4	6
削除から推定される記述	良質	5	6
	悪質	4	7

表 3 九四式軽装甲車の実験結果

編集内容	質	従来手法	本手法
残存	良質	10	10
	悪質	3	4
残存から推定される記述	良質	6	7
	悪質	4	5
削除	良質	8	8
	悪質	5	5
削除から推定される記述	良質	5	3
	悪質	5	5

編集の質を再評価することによって、以前行った研究よりも高い精度を得ることが出来た。

今後の課題として、記事によって著者数、記事編集数が違うことを考慮した記事ごとに適した良質、悪質な編集を行う著者の提示が必要であると考えた。また記事編集数が少ない記事については従来手法の精度が低いという問題があり、これが本研究にも影響を与えている。そのため、記事編集数が少ない記事について高い精度で編集の評価を行うことが必要であると考えた。

in wikipedia? mapping topics and conflict using socially annotated category structure. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 2009.

参考文献

- [1] 岩井一晃, 鈴木優, 石川佳治. Wikipedia における著者の役割推定. 情報処理学会研究報告, Vol. 2012-DBS-154, No. 2 および Vol. 2012-IFAT-107, No. 2, 2012.
- [2] D. M. Wilkinson and B. A. Huberman. Cooperation and quality in wikipedia. In *Proceedings of International Symposium on Wikis (WikisSym '07)*, pp. 157–164, 2007.
- [3] A. Kittur, E. Chi, B. A. Pendleton, B. Suh, and T. Mytkwicz. Power of the few vs. wisdom of the crowd:wikipedia and the rise of the bourgeoisie. In *Alt.CHI at CHI 2007*, 2007.
- [4] R. Priedhorsky, J. Chen, S. T. K. Lam, K. Panciera, L. Terveen, and J. Riedl. Creating, destroying, and restoring value in wikipedia. In *GROUP '07 Proceedings of the 2007 International ACM Conference on Supporting Group Work*, pp. 259–268, 2007.
- [5] Ulrik Brandes, Patrick Kenis, Jurgen Lerner, and Denise van Raaij. Network analysis of collaboration structure in wikipedia. In *In Proceedings of the 18th International Conference on World Wide Web(WWW '09)*, pp. 731–740, 2009.
- [6] A. Kittur, B. Suh, B. A. Pendleton, and E. H. Chi. He says,she says:conflict and coordination in wikipedia. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 453–462, 2007.
- [7] Ba-Quy Voung, Ee-Peng Lim, Aixin Sun, Minh-Tam Le, Hady Wirwan Lauw, and Kuiyu Chang. On ranking controversies in wikipedia: Models and evaluation. In *In Proceedings of the International Conference on Web Search and Web Data Mining*, pp. 171–182, 2008.
- [8] Y. Suzuki and M. Yoshikawa. Mutual evaluation of editors and texts for assessing quality of wikipedia articles. In *Proceedings of the 8th International Symposium on Wikis and Open Collaboration (WikiSym 2012)*, 2012.
- [9] Todd Holloway, Miran Bozicevic, and Katy Bomer. Analyzing and visualizing the semantic coverage of wikipedia and its authors. In *Computing Research Repository*, 2005.
- [10] Xiaohua Hu, Xiaodan Zhang, Caimei Lu, E.K. Park, and Xiaohua Zhou. Exploiting wikipedia as external knowledge for document clustering. In *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2009.
- [11] Identifying document topics using the Wikipedia category network. Peter schehofen. In *Proceedings of Web Intelligence and Agent Systems*, 2006.
- [12] Aniket Kittur, Ed H. Chi, and Bongwon Suh. What's