

コミックを対象とした質問応答システムの ための質問タイプ分類の検討

Question Type Classification for Comic QA System

山下 諒¹ 陸 鑫一² 松下 光範^{3*}
Ryo Yamashita¹ Xin-yi Lu² Mitsunori Matsushita³

¹ 関西大学大学院 総合情報学研究科

¹ Graduate School of Informatics, Kansai University

² アズワン株式会社

² As One Corporation

³ 関西大学 総合情報学部

³ Faculty of Informatics, Kansai University

Abstract:

The objective of our research is to realize a question answering (QA) system for comics. Because comic is a multi-modal contents that utilizes texts and illustrations cooperatively, question sentence that should be handled by the comic-QA system varies significantly in comparison with the conventional QA system. To meet this goal, this paper performs type classification of the question for comics as a basic examination. We classified question sentences into query types: bibliographic information type questions (5 types) and content information type questions (6 types). These types are determined by the result of previous works and question sentences collected from Web sites. We performed automatic classification based on the classification. As the result, we observed that accuracy was high in bibliographic information type question, while that in content information type question was low.

1 はじめに

近年、スマートフォンやタブレットなどの電子端末が急速に普及しつつある。それに伴い、コミックのデジタル化が急激に進んでいる。

コミックがデジタル化されることによって、紙媒体のコミックが有していた物理的な制約から開放され、従来のコミックの枠にとらわれない表現 (e.g., 話の展開に応じて内容を切り替える, コマに動きを付与する) が可能になるだけでなく、コミックの書誌情報だけでなくコンテンツそのものに対する柔軟な情報アクセス (e.g., 読み手の母語に応じて言語を切り替える, 特定のキャラクターが出現するページを検索する) も可能になると期待される。現状の電子コミックの多くは、紙媒体のコミックをページごとの画像情報として電子化したものが大半であるが、それらを対象として、コマの同定 [2, 12] や登場キャラクターの特定・抽出 [7, 13],

書誌情報やコンテンツ情報の構造化 [1] などの研究が精力的に推められており、近い将来には、コミックに対する、より柔軟な情報アクセスが可能になると考えられる [4]。

本研究では、こうした柔軟な情報アクセスが可能な状況を前提として、コミックを対象とした質問応答の実現を目指している。質問応答は現在自然言語処理分野でテキストを対象として精力的に進められている研究の一つであり [5], コミック質問応答はそれをコミックコンテンツに拡張したものである。

コミックは、テキストやイラストなどの複数の要素から構成されたマルチモーダルなコンテンツである。そのため、テキストを対象としている場合に比べて問題は飛躍的に難しくなる。例えば質問応答の場合、「ドラえもんで『もしもボックス』が初めて登場したのは何巻ですか?」という質問であれば、「小学館てんとう虫コミックス 11 巻です」とテキストで応答するのが適切であるが、「スラムダンクで『あきらめたらそこで試合終了ですよ』と安西先生が言ったコマが見たい」や

*連絡先：関西大学大学院総合情報学研究科
〒 569-1095 大阪府高槻市霊仙寺町 2-1-1
E-mail: mat@res.kutc.kansai-u.ac.jp

「名探偵コナンで主人公がスケートボードに乗っているシーンが見たい」といった質問の場合は、コミックのコマやストーリーの一部分を提示するのが適切であろう。このように、コミック質問応答を実現するためには、様々なユーザの質問に応じて、回答を生成する戦略を切り替えたり、コミックコンテンツの中から応答として適切な箇所を同定したりする技術が必要になる。

本稿では、こうしたコミック質問応答の要素技術の1つである質問文理解技術に着目し、その実現のためにコミックを対象としたコミックに関する質問を収集し、それらの質問タイプの分類を試みる。

2 関連研究

2.1 質問応答技術

質問応答技術とは、一般的な検索エンジンとは異なり、質問に対して直接回答を提示する技術を指す。質問応答の研究の歴史は古く、構造化されたデータベースを対象に、自然文で表現された質問を通じて条件を満たすデータを検索する技術の研究 [3] が 1960 年代から行われているが、近年の自然言語処理分野で盛んに研究されている質問応答は、Web などから得られるテキストデータ集合を対象として、質問に合致する情報を検索・抽出して提示する技術である [5]。以下では、後者の質問応答を Web 質問応答と記す。本研究で実現を目指すコミック質問応答は、この Web 質問応答の枠組みを延伸したものである。池野らは、一般的な Web 質問応答システムの基本的なプロセスを質問解析、情報検索、情報抽出、回答選択と整理している [10]。コミック質問応答システムの場合、Web 質問応答システムとは異なり、上述したようなマルチモーダルなコンテンツを対象とするため、必ずしもこのプロセスに当てはまるわけではない。そこで次節では、コミックを対象とした質問応答システムのプロセスについて整理する。

2.2 コミックを対象とした質問応答技術

1 章でも述べたように、コミックを対象とした質問応答システムでは、テキスト情報ではなくコミックのコマやストーリーの一部分を提示する方が適切な場面が存在する。システムがコマやストーリーの一部分を回答と認識するためには、コミックに含まれる情報 (e.g., キャラクター情報, セリフ) を構造化し、機械で計算可能にする必要がある。例えば計算が可能になることで、「名探偵コナンで主人公がスケートボードに乗っているシーンが見たい」といった要求に対して、システムは「主人公」と「スケートボード」などの情報がタグ

付けされているコマを探し出し提示することが可能になる。コミックの書誌に関する情報を構造化する取り組みは、野村ら [6] や、三原ら [9] によって行われており、Wikipedia¹ や DBpedia² を用いることで可能であるとされている。

一方、コミックの内容に関する情報は、上記の情報源からのみでは十分ではないため、コミックの各コマに記載されている各々の情報をより詳細に構造化する必要がある。水戸らは、人手でこれを行うことで、様々な質問に回答するための基盤を構築することを試みている [8]。このように構造化されたデータは質問応答システムに限らずコミックに対する新たなサービスの創出につながると期待されるが、全てのコマに対して情報を人手で付与していくのでは、非常にコストがかかってしまうため、コミックの情報を自動で抽出することが求められる。こうしたコミックの内容情報を自動抽出する方法としては画像認識の利用が見込まれる。谷らは、画像認識技術を用いてコミックの登場キャラクターを認識、識別する手法について検討を行っている [13]。現状のキャラクター識別の正解率は必ずしも高いとは言えないものの、この技術が発展することでコミック内の特定の情報 (e.g., キャラクター名, アイテム) を自動で抽出・識別し、アノテーションとしてコマに付与できると期待される。

コミック質問応答は、こうした技術が利用可能であるという前提の下で進める。当面は、水戸らの研究に倣って、構造化されたコンテンツ情報を人手で用意し、それを用いて研究を進めている [8]。

質問応答システムでは、まずユーザが入力した検索クエリが何に関する質問であるのかを判断する。一般的な質問応答のタイプ分類に関する研究は行われているものの (e.g., [14]), 1 章でも述べたようにコミックはテキスト情報と画像情報が相補的に利用されているマルチモーダルなコンテンツであるため、一般的な質問応答システムの想定する質問タイプ分類に該当しないような質問タイプが出現する可能性がある。そこで次節では、コミックを対象とした質問のタイプ分類に関する取り組みについて詳述する。

2.3 コミックを対象とした質問タイプ分類

現在、コミックに関する情報は電子書籍販売サイト (e.g., コミックシーモア³) などから獲得できる。こうしたサイトでは、一般的に、コミックの表題や著者名、出版社名といった書誌情報による検索が可能である。しかし、コミックの中の特定のシーンを探したい、コミックの内容を手がかりにして表題や著者名を探したいと

¹<http://www.wikipedia.org>

²<http://www.dbpedia.org>

³<http://www.cmoa.jp>

いう情報要求には、現状では必ずしも応えられていない [4].

こうした要求は「Yahoo! 知恵袋⁴」や「教えて! goo⁵」などのインターネット上の質問サイトなどで質問することにより、ある程度解決することが可能である。しかし、回答を得るのに時間を要したり、回答が得られない場合も少なくない。このような問題を解決するために、福田らは、2.1 節で述べた質問応答技術の枠組みを採用し、コミックコンテンツに適用するためにユーザから与えられる質問のタイプ分類について検討している [11]。具体的には、「Yahoo! 知恵袋」と「教えて! goo」から各々 30 個、コミックに関する質問を収集し、文中に出現する疑問詞や手がかり語に着目した質問タイプ分類を人手で行っている。以下に質問タイプを示す。

- 位置に関する質問
特定のシーンや話など、質問対象が収録されている巻数や話数を問う質問
- 登場人物に関する質問
登場人物の外見や所属など、コミックの設定に関する質問
- ストーリーに関する質問
作品全体や単行本 1 巻分などに関するストーリーの具体的な内容を問う質問
- 作品のタイトルに関する質問
いくつかの手がかりとなる項目を挙げて、それらを満たす作品のタイトルを問う質問
- その他に関する質問
上記のタイプに当てはまらない質問

上記の分類は、コミックに対応した質問タイプ分類ではあるが、人手で分類しているため、この質問タイプ分類が妥当であるのかを評価する必要がある。そこで、次章では、機械学習を用いてコミックの質問タイプを自動で分類することを試みる。

3 実装と事前評価

3.1 学習データの収集

福田らは、質問タイプの傾向を判断するために、「Yahoo! 知恵袋」と「教えて! goo」から計 60 個の質問文を収集し、それに基づいて質問タイプの分類を行なっ

ているが、位置に関する質問が 52 個 (86.7%) と全体に占める割合が多く、質問タイプが偏っている。

そこで本稿では、質問数のバランスをとるために「Yahoo! 知恵袋」と「教えて! goo」から合計 180 個の質問文を収集した⁶。なお、今回収集した質問文は全て正解が一意に決定する Factoid 型質問文を対象とし、正解が一意に決定しない主観による回答が求められる Non-Factoid 型質問文は収集の対象外とした。加えて、質問文に含まれる、質問の内容とは関係ない文章や単語 (e.g., “こんにちは”, “回答よろしくお願ひします”, “あまりははっきりとは覚えてないんですけど”) は、分類結果への影響を考慮して事前に取り除いた。

3.2 自動分類器を用いた検証

本稿では、質問タイプの自動分類に SVM (Support Vector Machine) を用いた。本稿では、機械学習ライブラリの scikit-learn⁷を用いて分類器を作成し、評価を行った。パラメータはデフォルト (C=1.0) のままだ。また、カーネルの種類には、線形カーネル関数を利用した。今回の実験では、収集した質問文を形態素解析器 MeCab⁸により形態素解析して得られた形態素を SVM の素性とした。

3.1 節で収集した質問文を用いて福田らの質問タイプ分類の評価を行うために、5 分割交差検定 (5-fold cross validation) を行った。分類結果の精度 (precision)、再現率 (recall)、F 値を表 1 に示す。表 1 から、位置に関する質問と作品のタイトルに関する質問に対する F 値が高い事が確認された。これは、“何巻ですか?” や “タイトルを教えてください” などといった特定の表現が多数の学習データに含まれていたからであると推測される。一方、登場人物に関する質問やストーリーに関する質問に対する F 値は低かった。これは、質問の記述形式が各々異なることが原因だと考えている。

今回、“その他”に分類された質問数は全質問文 180 個のうち 43 個であり、高い割合を占めていた。“その他”に分類された質問文の中には、コミックの発売日を問う質問や、福田らが考案した質問タイプ分類には属さないコミックの内容に関する質問 (e.g., “～はどういう意味ですか?”) などが複数確認された。このことから、福田らが考案した質問タイプでは、想定される質問を分類するには不十分であることが示唆された。そのため次節では、先行研究および今回収集した質問文をもとにして、より多様な質問タイプに適応した分類基準の検討を行う。

⁴<http://chiebukuro.yahoo.co.jp> (2014 年 5 月 20 日存在確認)

⁵<http://oshiete.goo.ne.jp> (2014 年 5 月 20 日存在確認)

⁶2013 年 11 月 1 日時点でアクセス可能な質問文を対象とした。

⁷<http://www.scikit-learn.org/stable/>

⁸<http://www.mecab.sourceforge.net>

表 1: 先行研究に基づく質問タイプの分類精度

質問タイプ	質問数	精度	再現率	F 値
位置に関する質問	60	0.76	0.87	0.81
登場人物に関する質問	20	0.47	0.45	0.46
ストーリーに関する質問	26	0.52	0.54	0.53
作品のタイトルに関する質問	31	0.79	0.74	0.77
その他に関する質問	43	0.62	0.53	0.57

3.3 質問タイプ分類の再検討

福田らは、コミックに含まれる要素と収集した質問文に含まれる要素から、書誌情報に関する要素 (e.g., 巻数, 作品名) と内容に関する要素 (e.g., キャラクタ, セリフ) の 2 つに大別している。本研究もそれに倣い、コミックの質問タイプ分類の際には、まず書誌情報型の質問タイプと内容情報型の質問タイプに分類して考える。本稿では、福田らが提案した質問タイプ分類と栗山らが提案した情報検索型の質問タイプ (サーチエンジンや図書館のレファレンス・サービスを利用して回答を探すことが可能な質問), さらに今回収集した質問のうち、これらに該当しないものを考慮して分類を再度行い、最終的に書誌情報型質問 5 タイプ, 内容情報型質問 6 タイプの計 11 タイプに分類することとした。以下にその質問タイプを示す。

- 書誌情報型質問
 - 巻数や話数に関する質問
 - 作品名や各話のタイトルに関する質問
 - 発売日に関する質問
 - 掲載誌に関する質問
 - 作者に関する質問
- 内容情報型質問
 - ストーリーの進展 (結果, 過程) に関する質問
 - ストーリーの定義や解釈に関する質問
 - ストーリーの理由, 原因に関する質問
 - キャラクタの設定に関する質問
 - オブジェクト, 道具, 技能の名称に関する質問
 - セリフに関する質問

次章では、上記の 11 個の質問タイプを用いた質問文の自動分類を行い、その分類精度の評価を行う。

表 2: 書誌情報と内容情報に分類した際の分類精度

大分類	質問数	精度	再現率	F 値
書誌情報型質問	103	0.88	0.86	0.87
内容情報型質問	77	0.84	0.82	0.83

表 3: 書誌情報型質問に関する分類精度

質問タイプ	質問数	精度	再現率	F 値
巻数や話数に関する質問	47	0.67	0.83	0.74
作品名や各話のタイトルに関する質問	40	0.56	0.60	0.58
発売日に関する質問	11	1.00	0.73	0.84
掲載誌に関する質問	3	-	-	-
作者に関する質問	2	-	-	-

4 評価と考察

本稿では、質問タイプ分類を 2 段階で行うこととした。まず、その 1 段階目として書誌情報型質問と内容情報型質問の 2 つに分類した際の精度を評価した。分類結果を表 2 に示す。結果を見てみると、精度, 再現率共に書誌情報型質問の方が高いことが確認された。また、書誌情報型質問, 内容情報型質問のどちらも F 値が高いことが確認された。

次に、書誌情報型質問の 5 分類と内容情報型質問の 6 分類の計 11 分類での分類を行った。ただし、今回の分析を評価するために 5 分割交差検定を用いたため質問数が 5 に満たない質問タイプが混在していると結果に影響を及ぼす可能性がある。そこで本稿では、質問数が 5 以下である掲載誌に関する質問と作者に関する質問を除く 9 種類の質問タイプで評価を行った。結果を表 3 と表 4 に示す。表 3 を見ると発売日に関する質問タイプの精度が良かった。これは、表 1 の結果と同様に、“～の発売日はいつですか” といった特定の文末表現が多く質問文に含まれていたのが要因であると考えられる。

一方、表 4 を見るとストーリーの定義に関する質問とオブジェクト, 道具, 技能の名称に関する質問の F 値が 0 だった。これは、各質問文に特徴的な表現が多く、加えて質問数が少なかったため、上手く分類ができなかったのが原因であると考えられる。これらの質問タイプに関しては、今後該当する質問文を増やし、再度検討を行う必要がある。

また、書誌情報型質問と比較して、内容情報型質問の精度が悪かった。その原因として、内容情報型質問の質問文中に口語表現が多く特徴的な単語の割合が高かったことが考えられる。今後は、精度を改善するために、口語的表現を文語的表現に修正したものを学習データとする手法と固有表現にタグ付けを行い、質問文中に含まれる名詞情報を質問タイプ分類の判断基準に用いる手法を採用していきたいと考えている。

表 4: 内容情報型質問に関する分類精度

質問タイプ	質問数	精度	再現率	F 値
ストーリーの進展(結果, 過程)に関する質問	20	0.36	0.45	0.40
ストーリーの定義に関する質問	7	0.00	0.00	0.00
ストーリーの理由や原因に関する質問	11	0.38	0.27	0.32
キャラクタの設定に関する質問	21	0.52	0.57	0.55
オブジェクト, 道具, 技能の名称に関する質問	10	0.00	0.00	0.00
セリフに関する質問	8	0.43	0.38	0.40

5 終わりに

本稿では, コミックの質問に対応した質問応答システムを実現するための基礎検討として, コミックに関する質問を収集し, 質問タイプ分類を試みた. 先行研究の 5 分類で事前評価を行った所, その他の質問に分類される質問が多かったため, 先行研究の質問タイプ分類と今回収集した質問文を参考にして新たな質問タイプ分類を行い評価を行った. 今後は, 話し言葉が多い質問文を書き言葉に変換する等の処理を行い, より分類精度の向上を目指す. また, 今回は, Factoid 型質問文を対象に扱ったが, 今後は, NonFactoid 型質問文も対象にして分析を行っていききたい.

6 謝辞

本研究は挑戦的萌芽研究(課題番号:24650040)の助成を受けた. 記して謝意を示す.

参考文献

- [1] A. Morozumi, S. Nomura, M. Nagamori, and S. Sugimoto. Metadata framework for manga: A multi-paradigm metadata description framework for digital comics. In *Proc. International Conference on Dublin Core and Metadata Applications 2009*, pp. 61–70, 2009.
- [2] T. Tanaka, K. Shoji, F. Toyama, and J. Miyamichi. Layout analysis of tree-structured scene frames in comic images. In *Proc. 20th International Joint Conference on Artificial Intelligence*, pp. 2885–2890, 2007.
- [3] J. Weizenbaum. A computer program for the study of natural language communication between man and machine. In *Communications of the ACM*, Vol. 9, No.1, pp. 36–45, 1966.
- [4] 松下光範. コミック工学の可能性. 第 2 回 ARG WEB インテリジェンスとインタラクショナル研究会, pp. 63–68, 2013.
- [5] 磯崎秀樹, 東中竜一郎, 長田昌明, 加藤恒昭. 質問応答システム. コロナ社, 2009.
- [6] 野村聡美, 両角彩子, 永森光晴. マンガのためのメタデータモデルを目指したマンガのアーキテクチャ分析. 第 36 回デジタル図書館ワークショップ, pp. 3–14, 2009.
- [7] 石井大祐, 山崎太一, 渡辺裕. マンガ上のキャラクター識別に関する一検討. 情報処理学会第 75 回全国大会(分冊 2), pp. 71–72, 2013.
- [8] 水戸拓実, 白井涼子, 波多野賢治, 松下光範. コミックデータ内関係抽出のためのデータ・フォーマットの提案. 第 2 回 ARG WEB インテリジェンスとインタラクショナル研究会, pp. 71–72, 2013.
- [9] 三原鉄也, 永森光晴, 杉本重雄. デジタルマンガにおけるストーリー構造とビジュアル構造を表すメタデータモデル. 情報処理学会研究報告, Vol. 2011-FI-104, No. 9, pp. 1–8, 2011.
- [10] 池野篤司. 質問応答システム 情報検索と情報抽出の頂点へ, 技術報告 2. 沖テクニカルレビュー, 2004.
- [11] 福田美沙紀, 白水菜々重, 松下光範. コミックを対象とした質問応答技術のための基礎検討. 人工知能学会ことば工学研究会資料, SIG-LSE-C003, pp. 57–62, 2012.
- [12] 野中俊一郎, 沢野拓也, 羽田典久. コミックスキャン画像からの自動コマ検出を可能とする画像処理技術「gt-scan」の開発. In *FUJIFILM RESEARCH & DEVELOPMENT*, No. 57, pp. 46–49, 2012.
- [13] 谷悠, 白水菜々重, 松下光範. コミックコンテンツにおける登場キャラクター抽出のための基礎検討. 情報処理学会第 75 回全国大会(分冊 4), pp. 889–890, 2013.
- [14] 栗山和子, 神門典子. Q&A サイトにおける質問と回答の分析. 情報処理学会研究報告, Vol. 2009-DBS-148, No. 19, pp. 1–8, 2009.