

主題と文章構造の解析に基づくスライドの自動生成

柴田 知秀 河原 大輔 黒橋 禎夫
 東京大学大学院情報理工学系研究科

{shibata,kawahara,kuro}@kc.t.u-tokyo.ac.jp

1 はじめに

計算機とネットワークの爆発的普及により、電子掲示板への投稿、日記、講義録など、有用な知識の断片が電子的に大量に存在するようになった。これらの情報は多くの場合、数文から数十文のテキストという単位で存在している。

一方、人間にとって最も刺激される知識創造の場は、人間同士の会話の場である。そこで、上記のような電子的知識断片をエージェントが読み上げる(音声化する)という形で会話の場に取り込もうとする研究が進められている [1]。

このような知識断片の活用を考えた場合、もとのテキストを音声化すると同時に、そのテキストの要約を作成して視覚的に提示するという方法を考えることができる。このような背景から、本稿では、数文から数十文の意味的まとまりを持つテキスト(以降、これを知識カードとよぶ)を対象として、要約スライドを自動生成する手法を提案する。知識カードと自動生成された要約スライドの例を図1に示す。

要約スライドの作成は、知識カードの文章構造の解析、主題や重要な説明表現の抽出、それらの適切配置によって実現される。以下の各節でこれらについて詳しく述べる。

2 文章構造解析

スライドを作成するには、知識カードの文章構造を捉える必要がある*。文章構造のモデルとして、一文をノードとし、それらがある結束関係を持ってリンクされた木構造を採用した [2]。文と文の結束関係としては、次のものを考える。

並列、対比、主題連鎖、焦点主題連鎖、詳細化、理由、原因結果、変化、例提示、例説明、質問応答

*入力文はあらかじめ JUMAN で形態素に分け、KNP で構文解析しておく。

エージェントプラットフォームはエージェントを構築実行するためのソフトウェアプラットフォームである。いくつかのエージェントプラットフォームはモバイルエージェント機能を提供している。モバイルエージェントはコンピュータ間を移動可能な能動的なプログラムである。モバイルエージェントはネットワーク上のホストからホストへと移動して処理を行なう。モバイルエージェントが移動するとき、プログラムのコードだけでなくプログラム内の変数内容といった実行状態も移動先に転送され、移動先コンピュータでは移動前の実行状態から継続した処理が行なわれる。

エージェントプラットフォーム

- エージェントを構築実行するためのソフトウェアプラットフォーム
- モバイルエージェント機能を提供
 - モバイルエージェント
 - コンピュータ間を移動可能な能動的なプログラム
 - ネットワーク上のホストからホストへと移動して処理を行なう

図1: 知識カードとスライドの例

例えば、図1の例文の文章構造は図2のようになる。各文頭のカッコの中は親との結束関係を示している。

文章構造解析は、種々の表層の手がかりをもとに、各入力文に対して、関係をもつ以前の文(接続文)とその間の結束関係を逐次的に求める。以下に示すような基準によって、さまざまな接続可能文との間のさまざまな結束関係を考慮し、最終的に最も高い合計点を得た関係を採用する。

● 表層的な手がかり

表層的な手がかりを元にし、ルールを作成した。談話構造解析のルールの例を表1に示す。

適用範囲とは、入力文と前の文がどれだけ離れた文までを考えるか、接続可能文、入力文のパターンは、表層表現のパターンであり、これらのルー

- #0
 (初期化) #1 エージェントプラットフォームはエージェントを構築実行するためのソフトウェアプラットフォームである。
 (主題連鎖) #2 いくつかのエージェントプラットフォームはモバイルエージェント機能を提供している。
 (焦点主題連鎖) #3 モバイルエージェントはコンピュータ間を移動可能な能動的なプログラムである。
 (主題連鎖) #4 モバイルエージェントはネットワーク上のホストからホストへと移動して処理を行なう。
 (焦点主題連鎖) #5 モバイルエージェントが移動するとき、プログラムのコードだけでなくプログラム内の変数内容といった実行状態も移動先に転送され、移動先コンピュータでは移動前の実行状態から継続した処理が行なわれる。

図 2: 文章構造の例

表 1: 談話構造解析のルールの例

結束関係	スコア	適用範囲	接続可能文	入力文
並列	5	1	～	そして～
並列	40	*	[並列]	～さらに～
対比	30	1	～	むしろ～
詳細化	30	1	～	すなわち～
理由	30	1	～	～からだ

ルとマッチすると、接続文との間の結束関係にスコアを与える。

● 語連鎖

各文において、焦点と主題を考え、2文間で、主題と主題、焦点と主題に連鎖があるときは、それぞれ、主題連鎖、焦点主題連鎖という結束関係とする。語の連鎖は、完全一致と部分一致を考え、完全一致の時は部分一致の時よりも、高いスコアを与える。

● 2文間の類似度

2文が並列または対比の関係にあるときは、それらの文は、ある程度類似していると考え、類似度が高いものには、対比、および、並列にスコアを与えた。品詞の一致、語の一致、シソーラス辞書上の語の近さなどによって計算された文節間の類似度を組み合わせることにより、任意の文節列間の類似度は計算される [3]。

文章構造解析の単位(ノード)は1文を基本とするが、1文内に大きな並列があるときは、分割してそれぞれ別のノードとして扱う。

3 見出し語、重要説明表現の抽出

次に、各文から主題(以下、見出し語と呼ぶ)と、主題を説明するような表現(以下、重要説明表現と呼ぶ)を取り出す。

見出し語の抽出

見出し語は、次のような手がかり表現によって抽出する。1文中にこれらの手がかり表現が複数存在する場合は、そのうち一番前にあるものからだけ抽出する。

- ～とは
- ～という
- ～は
- …する { の/とき } は～{ だ/になる }

ただし、一文目は特に重要であると考え、以下のようなものも見出し語として抽出する。

- ～では
- ～について
- 「」でくくられた語

重要説明表現の抽出

重要説明表現は次のようなパターンで抽出する。

1. **見出し語**{ は/とは/では/というの }…
 例) グループウェアとは、共通の作業や目標を持つ人々のグループを支援し、共通の環境へのインタフェースを支援するシステムである。
2. **見出し語**…、**主節**。
 例) 日本的図法というものを考えると、絵巻物のように、場がずっと向こうまで見通せるけれど、奥には入っていないという特徴があります。
3. …する { の/とき } は、**見出し語**{ だ/になる }。
 例) スマートハウスの世界 A と世界 B の分離を可能とするのは TAP と呼ばれる装置です。
4. …が重要だ。
 例) 人間が機械にあわせるのではなく、機械のほうで調節可能にするという発想が重要です。

(二重線が見出し語、一重線が重要説明表現)

見出し語の文節に、提題助詞「は」がある時は、その文節の係り先の節を重要説明表現として抽出する(1)。提題助詞「は」がないときは、その文の主節を抽出する(2)。(3)のようなパターンで見出し語が抽出された場合は、網掛け部分の節を重要説明表現とする。見出し語がなく、表2にあげるような用言がある場合は、それぞれの格の語句を抽出する(4)。

- #0
- └ (初期化) #1 アウェアネスとは、自分の活動に影響し得る文脈情報を提供するような他人の活動の理解である。
 - └ (主題連鎖) #2 同期型の作業環境では、相手の様子、相手が何をしているか、表情はどうか、今仕事に集中しているか、こちらの話を真剣に聞いているか、会話を開始してもよいかといった情報によってアウェアネスが実現される。
 - └ (詳細化) #3 特に視線によって生じる視線アウェアネスが重要である。
 - └ (対比) #4 非同期型作業では、作業履歴や共有オブジェクトの変更履歴などによるパートナーの作業状況に関わる情報によってアウェアネスが実現される。

アウェアネス

- 自分の活動に影響し得る文脈情報を提供
- 同期型の作業環境
 - こちらの話を真剣に聞いているか会話を開始してもよいかといった情報によって実現
 - 特に視線によって生じる視線アウェアネスが重要
- 非同期型作業
 - 作業履歴や共有オブジェクトの変更履歴などによるパートナーの作業状況に関わる情報によって実現

図 3: 出力例 1

表 2: 重要説明表現

格	用言
ガ格	重要だ、本質をつく、エッセンスだ、ポイント、望ましい、鍵だ、大切だ、有益だ、必要だ
ヲ格	重視する、重要視する、明らかにする、明確にする、取り上げる
ニ格	着目する、重点を置く、注目する

4 スライドの出力

2章で解析したカードの文章構造に基づいて、3章で抽出した見出し語、重要説明表現を次のような基準でスライドに配置する。

- 文章中の一番最初の見出し語をスライドのタイトルとして出力する。
- 見出し語があれば出力し、次の行に、インデントを一つ下げて重要説明表現を出力する。見出し語がなければ、重要説明表現だけを出力する。
- 1枚のスライドに表示される量が多くなりすぎないように、文章構造木の深さ2までの文を出力対象とする(一般に、文章構造の根に近い方が重要であると考えることができるからである)。
- 親との結束関係に応じて、以下のように処理する。
 - 対比または並列: 親に対してインデントをそのままにして出力する。
 - 主題連鎖: 見出し語が親と同じ場合は、インデントを下げずに重要説明表現だけを出力する。見出し語が異なっている場合は、インデントを下げて、見出し語と重要説明表現を出力する。
 - 焦点主題連鎖: 主題が変わったので、インデントを0に戻して出力する。

- 例提示、例説明: 何も出力しない。
- それ以外: 親に対してインデントを一つ下げて出力する。

5 出力例と考察

5.1 出力例

知識カードに対する文章構造解析結果とスライドの生成例を、図3、4に示す。“●”が見出し語、“-”が重要説明表現であることを示す。

出力例1では、1文目の見出し語である「アウェアネス」がタイトルとなり、次の行に重要説明表現が出力されている。さらに、2文目と4文目の対比の構造が正しく解析されており、それぞれの見出し語である「同期型の作業環境」と「非同期型作業」が同じインデントで出力され、各見出し語に対して重要説明表現が出力されている。また、3文目は、「～が重要」というパターンで抽出された重要説明表現が出力されている。

出力例2では、1文目の見出し語である「社会ネットワーク」がタイトルとなり、重要説明表現が出力されている。3文目は例説明のため、出力されてない。4文目で、「基本的な社会的関係」に主題が移ったため、インデントが0になり見出し語が出力されている。また、7文目の「無効グラフ」と「有効グラフ」の対比が解析され、一文が分割されている。

5.2 考察

サンプルとして用いた知識カードのように、論理的で、手がかり表現が十分あるものについては、このように自動生成したスライドでも、知識カードの要点をおさえることができている。並列や対比があると、知識カードの全体的構成をうまくスライド化することが

#0

- └ (初期化) #1 社会ネットワークとは、人間どうしのあいだの社会的なつながりをグラフ構造として表現したものである。
- └ (主題連鎖) #2 社会ネットワーク分析では、このグラフ構造の分析をして、社会現象を解明する。
 - └ (例説明) #3 例えば、電子会議室のやりとりのコメントチェーンを分析することによって、議論の中心になっている人、影響力のある人、近い考えを持つ人の集まりなどを見つけ出そうというものである。
 - └ (主題連鎖) #4 一般に、社会ネットワークは、人がノード、人と人との間の社会的関係がエッジとなるグラフである。
- └ (初期化) #5 どのような社会的関係を選ぶかに依存して、さまざまなグラフが考えられる。
 - └ (焦点主題連鎖) #6 基本的な社会的関係は、「誰が誰を知っているか?」、「誰が何を知っているか?」、という情報によって決まるものである。
- └ (初期化) #7 同僚関係や友人関係のように対称性が仮定できるときは、社会ネットワークは無向グラフになるが、引用関係や信頼関係のように対称性が仮定できないときは有向グラフになる。
 - └ (並列) #8 また、社会的関係の強さを考慮に入れて、重み付きグラフを用いることもある。
- └ (初期化) #9 ネットワーク分析は、社会関係の分析だけでなく、より広範なネットワークの分析に適用可能であるが、ここでは社会関係に限定しておく。

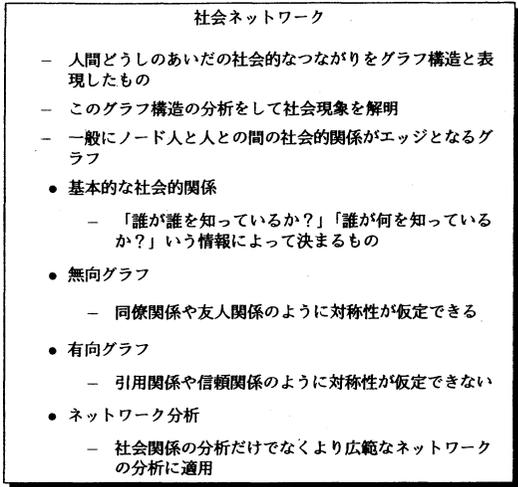


図 4: 出力例 2

できる。

問題点: 今後の課題などは次のようにまとめられる。

- 各文の主題と焦点を捉えるのが十分でない。例えば、出力例 2 の 4 文目と 5 文目には、「社会的関係」、「グラフ」といった語連鎖があるが捉えることができず、5 文目を初期化している。
- 語連鎖を考えるときに、完全一致または部分一致しか連鎖としていないが、表現のずれも考慮に入れて、連鎖を考えるべきである。
- 出力されるものが、他の文と高い類似度があり、詳細化されている場合には、出力しないといったことを考えることができる。図 1 の例で、“コンピュータ間を移動可能な能動的なプログラム”と、“ネットワーク上のホストからホストへと移動して処理を行なう”には高い類似度があり、これら一つにまとめるということが必要である。
- 現段階では、箇条書きによる方法のみであるが、強調表示や矢印を使った表現などを用いればよりスライドらしくなり、文章をより理解したということになるであろう。

関連研究として、GDA(Global Document Annotation) タグのついた文書からスライドを生成するものがある [4]。GDA タグとは、文書に意味論的構造や語用論的構造を与えるもので、人手で付与する。共参照を示すタグから文章構造をボトムアップに決定し、重要なトピックを抽出し、各トピックに対して関連する

文を集め、それらを箇条書きにして一枚のスライドを生成する。GDA タグを用いることにより、ある程度長い文章についても文章構造を解析し、スライドを生成することができる。しかし、GDA タグを付与するコストは大きなものとなる。これに対して、本研究で対象としている知識カードなどは、自動解析によってもスライドを生成することが可能である。さらに、スライドの使用目的を音声合成によって読み上げる際の補助的役割とするならば、このような自動生成スライドでも十分に有効であると考えられる。

6 おわりに

本稿では、知識カードから、一枚の要約スライドを自動生成する方法について述べた。今後は、会話エージェントなどのアプリケーションに取り入れ、評価を行う予定である。

参考文献

- [1] 久保田秀和, 黒橋禎夫, 西田豊明. 知識カードを用いた分身エージェント. エージェント合同シンポジウム (JAWS2002) 講演論文集, pp. 220-227, 2002.
- [2] 黒橋禎夫, 長尾眞. 表層表現中の情報に基づく文章構造の自動抽出. 自然言語処理, Vol. 1, No. 1, pp. 3-20, 10 1994.
- [3] 黒橋禎夫, 長尾眞. 長い日本語文における並列構造の推定. 情報処理学会論文誌, Vol. 33, No. 8, pp. 1022-1031, 8 1992.
- [4] 内山将夫, 橋田浩一. GDA 文書からのスライド生成. 言語資源の共有と利用シンポジウム, 1999.