Vol.2019-ICS-195 No.8
2019/3/18

自動ファシリテーターのIBIS構造抽出のための系列ラベリング

芳野 魁[1,a)]　西田 智裕[1]　山口 直子[1]　柴田 大地[1]　鈴木 祥太[1]　平石 健太郎[1]　伊藤 孝行[1]

概要：本稿では，多人数参加型議論のテキストから議論構造を抽出するためのモデルを提示する．多様な意見を開かれた形で集めることができるため，オンライン議論が注目されている．議論においてファシリテーターは重要な役割を果たしているが議論の規模が大きくなるに連れて人間のファシリテーターが把握するのは時間的及び情報量的に困難となる．従ってファシリテーターを自動化することが求められているが，自動化のためには議論構造の把握が不可欠である．そこで私達は議論中の発言を入力として時系列順に入力し，新たに投稿された発言に含まれている議論的な要素を取り出すニューラルネットワークモデルを提案する．評価実験では大規模合意形成システム D-Agree で行われた議論のアノテーション済みテキストデータに対して議論構造の抽出を行った．実験の結果，提案するモデルが良い性能を獲得できることを示した．

Sequence labeling for extraction of Issue-Based Information System Structures for Automated Facilitator Agent

Abstract: In this paper, we propose a model for parsing discussion structures in online discussions that are composed of a set of submissions posted by multiple participants. Since various opinions can be gathered in an opened form, online discussions have attracted attention. While facilitators play an important role in discussion, it becomes difficult for human facilitators to grasp whole discussion as time goes and information volume as the scale of discussion grows. In this regard, we set creating automated software agents that can function as facilitators in a facilitator-based online discussion system as our goal. Towards this end, it is essential to understand the discussion structures. We extracted the discussion structures based on issue-based information system(IBIS) from the online discussions that consist of submissions posted by various participants. In addition, we proposed a new model for extraction. The proposed extraction model receives a number of submissions, including the newly posted submissions in online discussions along with their time sequences as inputs. Then, the proposed model predicts the probability that each morpheme in the newly posted submissions belongs to each IBIS category. The proposed model passes the summarized information of past submissions to help understanding the context of the discussion. We evaluated the proposed model using the discussion texts that are collected from the online discussions created in intelligent crowd decision-making support system, D-Agree. The evaluation results demonstrated that the proposed model can extract the correct information with high precision.

1. はじめに

議論は異なる複数の立場における受容性を増減させること，あるいは決定を下すことを目的として行われる．近年，オンラインの議論支援システムは次世代の公的且つ民主的な市民フォーラムの 1 つとなる可能性が高いと考えられており，多くの調査が行われている．フォーラムは効率的に合意形成を行い，アイデアを合理的に統合し，そして炎上を防ぐことができる体系的な方法論を必要とする．上記の点に関して，ファシリテーター支援機能を有する大規模意見集約システムが開発され，いくつかの実世界のオンライン議論サポートフォーラムのために展開されて来た [2], [3], [4], [5]．また，Ito ら [18] はファシリテーターベースのオンライン議論支援システムの最終目標はファシリテーターとして機能することができる自動化されたソフ

[1] 名古屋工業大学
Nagoya Institute of Technology, Gokiso, Showaku, Nagoya, 466-8555, Japan
[a)] yoshino.kai@itolab.nitech.ac.jp

ⓒ 2019 Information Processing Society of Japan

トウェアエージェントを作成することだと結論付けた．例えば，実社会のワークショップやタウンミーティングでは人間のファシリテーターは強力な議論支援の技能を発揮する．だが一方で，プロである人間のファシリテーターがIto らの実験に参加したとしても，100 人を超える人々が関わるインターネット上での議論を制御することは困難な経験だった [5]．上記の事実に基づいて考えると，参加者の数が 1,000 人から 10,000 人に及ぶ大規模なオンライン議論を人間のファシリテーターが制御することは不可能となる．従って，大規模なオンライン議論を管理するには人間のファシリテーターではなく，自動ファシリテーターエージェントが必要である．オンライン議論をファシリテートするために，エージェントは議論構造を動的に抽出して解析を行う．ファシリテーターはリアルタイムな議論構造を使用して議論を管理し，議論のトピックがポジティブかネガティブか，どの単語が注目されているのか，そしてどの単語が重要であるのかを理解する．大規模意見集約システムは上記の要件を満たすためのファシリテーター支援機能を有するが，自動ファシリテーターエージェントが議論構造の知識無しに機能を使用することは困難である．従って，自動ファシリテーターエージェントが議論構造を認識できるようにするためのアプローチが必要である．議論構造の抽出を達成するために，ノード抽出とリンク抽出という 2 つのステップを考える．ノード抽出は，オンライン議論の投稿から重要なポイントを抽出することを意味する．リンク抽出は，抽出されたノード間の関係を抽出することを意味する．最終的に，我々は重要なポイントとポイント同士の関係から構成される木構造の議論構造を得ることができる．上記の問題を解決するために，我々はノード抽出に注目して時系列データの処理を目的とした回帰型ニューラルネットワーク（RNN）と条件付き確率場（CRF）モデルを適用することにより，議論構造を抽出するためのディープラーニングアプローチを提案する．議論支援システム D-Agree[19] から収集されたデータに対して行われた我々の実験の結果は，提案手法が議論構造を抽出するために効率的であることを示している．

本論文の構成を以下に示す．2 章では，関連研究を紹介する．3 章では自動ファシリテーターエージェントとオンライン議論の概要を説明し，4 章では議論構造を抽出するための提案モデルを紹介する．そして，5 章では評価実験で使用するデータについて説明を行い，6 章では評価実験の設定及び結果について述べて考察を行う．最後に 7 では本論文のまとめと今後の課題について示す．

2. 関連研究

既存の議論マイニングに関する研究は幅広いタスクを扱っている．そして，我々の研究に最も関連するものは自然言語テキストから議論構造を抽出する研究である．Moens ら [12] は新聞及び法律文書中の文を議論的な文とそうでないものに分類した．Moens らは様々な特徴量を作成し，単語ペア，文章統計 (文書長，平均単語長及び句読点の数)，動詞の有無，重要単語の有無の特徴を使用した場合に 73.8%の適合率を獲得した．Moens らと我々の研究の主たる違いは扱う文章のサイズである．
Stab ら [6] は CRF と SVM を用い，Nguyen ら [7] は LDA を用いて評論文から議論構造の抽出を行った．Stab ら及び Nguyen らと我々の違いは抽出対象及び目標である．Stab ら及び Nguyen らは 1 人の筆者によって書かれた評論文から抽出を行っているのに対し，我々の研究では複数の参加者によって作成された議論文から抽出を行っている．また，Stab らの抽出では Major claim，Claim，Premise の 3 種類が抽出目標であるのに対し，我々の研究では IBIS[8] に基づいた 4 種類が抽出目標である．Goudas ら [11] はソーシャルメディアの文章から，議論の構成要素をを取り出すために 2 段階手法を使用した．第 1 段階では Goudas らは文章を議論的な文とそうでないものに分類し，77.4%の適合率を獲得した．第 2 段階では議論的な文に対して CRF を使用して議論的な部分とそうでないものに分類するラベリングを行うことで文を区切り，最高で 42.4%の適合率を獲得した．Goudas らの研究は我々の研究に非常に近いが，Goudas らと我々の研究の違いとして処理の数が挙げられる．Goudas らの提案手法では文の分類と単語の分類という 2 回の分類を行うことで議論の構成要素を取り出している．一方，我々の提案手法では議論の構成要素は元の文章から 1 度の処理で行われている．我々の研究では実際にウェブ上の大規模オンライン議論でリアルタイムに動作することを目指しており，処理にかかる時間を短縮することは重要である．上記の違いから既存のモデルはウェブ上で行われる議論からの議論構造抽出には適していないことが分かる．自然言語処理の観点から述べると，我々の研究は”文章抽出”問題に該当しており近年の文章抽出に関する研究は主としてキーフレーズ抽出に注目が集まっている．キーフレーズは 1 つもしくは 1 つ以上の単語から構成される文章のことで，我々の研究で扱うサイズよりも抽出される文章の大きさは小さい．Wang ら [10] は単語の分散表現を用いてキーフレーズ抽出を行った．Wang らの研究では抽出はグラフランキング問題として扱われ，単語の分散表現はグラフの辺を作成するために使われた．

3. 自動ファシリテーターエージェントと IBIS

3.1 自動ファシリテーターエージェント

自動ファシリテーターエージェントを開発する目的は大規模オンライン議論を抑制する自律ソフトウェアを作ることである．エージェントを開発する試みが現在までに何度も行われてきた．Ito らは [18] は人間の議論をファシリ

テートできる知能ソフトウェアを実装している．Ito らは人間のファシリテーターがウェブ上での議論において議論参加者が議論内容を認識する上での負荷を軽減するために行う行動の選択原理を明らかにしなければならないと主張している．Ito らはファシリテーターが行動を選択する際，ファシリテーター自身の意図と一致する結果が得られる確率が最も高まるように行動を選択していると推測している．Ikeda ら [21] は議論参加者の抽出された意見からファシリテーターの質問文を生成する手法を提案した．ファシリテーターの質問文は抽出された意見内の述語の格構造を使用して，パターンマッチングルールで生成される．上記の手法を用いることによって，表層的な格構造で適切な種類の質問を選択できると考えられる．

3.2 IBIS structure

Issue-Based Information System（IBIS）は，議論を構造化するアプローチである． IBIS は，複雑な問題に取り組むための議論ベースアプローチとして，Kunz と Rittel により開発された．IBIS は，政治的な意思決定プロセスの調整と計画を支援することを目的としている．IBIS は，問題解決グループが提起した問題の特定，構造化，および解決を導き，グループの論議に関連する情報を提供する．IBIS の要素は，答える必要がある「Issues(問題)」である．それぞれの問題は，実現可能な答えである代替の「Ideas(アイデア)」に関連付けられている．Ideas は与えられた答えに対して支持もしくは反対を行う「Arguments(論議)」に関連付けられている．我々の研究では，Idea を支持する Argument を指すために「Pros(長所)」という用語を使用し，Idea に反対する Argument を指すために「Cons(短所)」を使用した．また，Issue，Idea，Pros，Cons を引用するために「ノード」という用語を使用し，ノード間の関係を引用するために「リンク」を使用した．Issue に対処しようとする際に，新しい Issue が発生することがありますが，新しい Issue に対しても同様に対処する．図 1 では各種類のノード間の関係をリンクを用いて表現している．

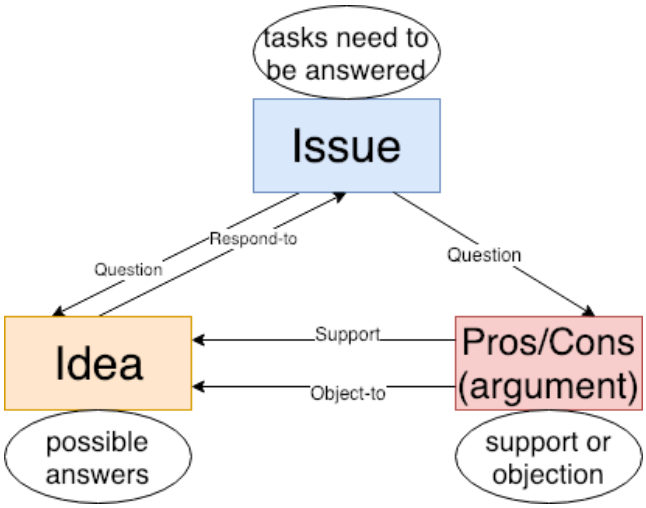

図 1　IBIS におけるノードとリンク

4. 深層学習を用いた IBIS 構造抽出

本節では我々が提案する IBIS 構造に基づくノード抽出のための手法について解説する．

4.1 ノード抽出

ノード抽出に関する問題は以下の様に記述できる．自然言語の形式で議論中のスレッド情報 $X = \{x_1, x_2, \ldots, x_n\}$ が与えられたとする．ここで x_i は i 番目の投稿を表す．それぞれの投稿は文 $x_i = \{x_{i1}, x_{i2}, \ldots, x_{im}\}$ から構成されている．ここで x_{ij} は投稿 x_i の j 番目の文である．また，いくつかの投稿は他の投稿への返答である．すなわち，いくつかの投稿は「親投稿」を持ち，親子関係は何重になることもあり得る．我々は投稿 x_1 の i 番目の親投稿を x_1^{Pi} と記述する．提案するモデルはそれぞれの投稿からノードを抽出を行う．ノードは単語から構成されている．図 2 は投稿である「情報技術により『災害に強いまち』を作るには，どの様な方法があるでしょうか？」から Issue ノード「情報技術により『災害に強いまち』」，そして投稿「掲示板は良いですね．大人数がアクセスしても大丈夫なサーバーにしてほしいです.」から Pros ノード「掲示板は良い」及び Idea ノード「大人数がアクセスしても大丈夫なサーバーにしてほしい」がそれぞれ取り出されていることを表している．

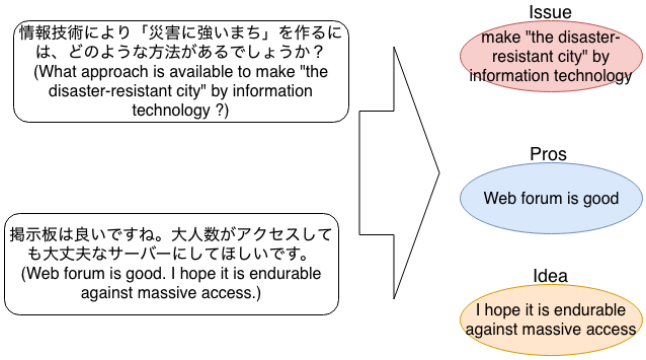

図 2　Node extraction

上記のノード抽出問題を解決するために，我々は単語を 5 つのカテゴリ (Issue, Idea, Pros, Cons, Other) に分類する．モデルの入力はトークン化された単語から構成される議論中の投稿 x_i，親投稿である x_i, x_i^{P1} と x_i^{P2}，x_i が属するスレッドの最初の発言である x_{head}，そして議論中の最初の発言である x_{root} の合計 5 つのものから構成される．ここで x_{root} は議論開始時に自動で作成されるもので議論のテーマを説明するものである．前述のモデル入力を作成するために，我々は 3 段階のプロセスを実装した．まず，オンライン議論では，テキストにノイズとなるものが含ま

れていることがあるため，文からノイズを削除する．ノイズ削除に関して，我々はノイズを除去するために頻繁に現れるノイズのパターンを観察し，正規表現を使用して削除した．例えば，日本語のテキストでは句読点のようないくつかの単語は，半角文字と全角文字の両方で表すことができ，そうした曖昧なものは異なる単語として扱われるため，正規表現を使用して曖昧な単語を統一した．次に，トークン化を行うために文章の形態素解析を行う．日本語のテキストをトークン化する場合，日本語のテキストは単語の間にスペースを空けて書かれていないので，単語に分けるために形態素解析を実行しなければならない．形態素解析を行うために我々は京都大学および NTT の Kudo ら [20] によって開発されたオープンソースの日本語形態素解析エンジンである MeCab を使用する．最後に，単語をトークン化するために我々は wikipedia のコーパスで訓練済みの fasttext[9] モデルを使用した．また fasttext モデルはモデル内部で単語をベクトル化する際にも使用した．
そして，出力は形態素が各タイプに属する確率をそれぞれ表す正規化された確率ベクトルで構成される行列である．各形態素を確率に基づいて分類し，ノードとして抽出する．

4.2 Cross multiple Time series Input bi-LSTM

人間の観点から述べると，議論の文脈を理解するためには投稿の概要を時系列順に保持そして記憶することが重要である．それゆえ，我々は x_i に加えて x_i，x_i^{P1}，x_i^{P2}，x_{head} そして x_{root} を入力として用いた．以前の投稿情報を次の投稿まで保持するために，2 つの LSTM と全結合層で構成される RNN モデルの一種である「Cross multiple Time series Input bi-LSTM（CTI bi-LSTM）」を作成した．CTI bi-LSTM は，議論における投稿やチャットテキストなど，互いに時系列の関係を持ち，なおかつそれぞれが意味を持つコンポーネントから構成されるデータを処理するのに適しているように設計されている．CTI bi-LSTM では，forward-LSTM と backward-LSTM の両方の出力が連結される．既存の bi-LSTM(双方向 LSTM) は以前の forward-LSTM と backward-LSTM の両方から要約された情報である内部状態を受け取り，更に状態を次の層に渡すのには適していなかったため，我々は 2 つの LSTM の出力を連結することで状態の受け渡しを可能にした．図 3 は CTI bi-LSTM の処理フローを図示している．また，CTI bi-LSTM のアルゴリズムは Algorithm 1 に記述されている．Algorithm 1 works は以下に示す様に動作する．
既存の bi-LSTM と同様に最初に入力 x_{in} が LSTM に順方向および逆方向に渡され，次にシークエンス出力，内部状態を構成する隠れ状態とセルが両方の LSTM から結果として得られる (行 6，7)．取得された出力はそれぞれ連結され (行 8 から 10 まで)，次の CTI bi-LSTM の初期状態として使うことができるように隠れ状態を連結してセルを

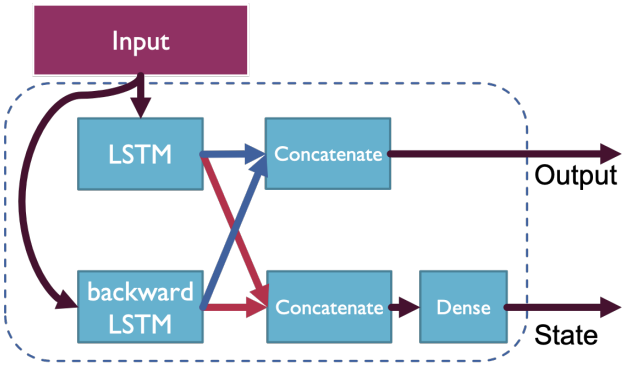

図 3　CTI bi-LSTM

Algorithm 1 CTI bi-LSTM

1: Input1 x_{in}:ベクトル化された単語から構成される投稿
2: Input2 s_{in}:内部状態
3: Output1 x_{out}:CTI bi-LSTM 内部にある 2 つの LSTM の出力を結合したもの．
4: Output2 s_{out}:CTI bi-LSTM 内部にある 2 つの LSTM の内部状態を結合したもの．
5: **procedure** CTI BI-LSTM(x_{in}, s_{in})
6: $sequence_f$,$hidden_f$,$cell_f$ = LSTM(x_{in})
7: $sequence_b$,$hidden_b$,$cell_b$ = LSTM(x_{in})
8: x_{out} = Concatenate($sequence_f$,$sequence_b$)
9: $hidden_c$ = Concatenate($hidden_f$,$hidden_b$)
10: $cell_c$ = Concatenate($cell_f$,$cell_b$)
11: $hidden_{out}$ = Dense($hidden_c$)
12: $cell_{out}$ = Dense($cell_{out}$)
13: s_{out} = [$hidden_{out}$, $cell_{out}$]
14: **return** x_{out},s_{out}

全結合層によって次元削減することでサイズを調整を行う (行 11，12)．

4.3 抽出モデル

時系列に投稿の要約を維持することを実装するために，我々は複数の CTI bi-LSTM 層を接続し，ノード抽出モデルを作成した．図 4 にノード抽出モデルの入出力の例を含んだ概観を示す．

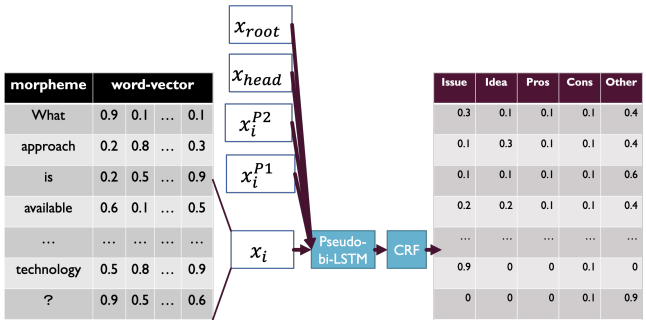

図 4　Node-extraction model architecture

また，図 5 には詳しいモデル構造を示す．提案モデルでは x_{root} から x_i までのトークン化された発言を 1 つの共有埋め込み層によって分散表現ベクトルに変換する．そして，

CTI bi-LSTM 層によって作成された過去投稿の要約情報が x_{root} から x_{head} に，x_{head} から x_i^{P2} の様に時系列に前の層から次の層へと渡されていく．最後の CTI bi-LSTM 層と CRF 層の間では内部状態ではなく，通常出力が渡される．また，それぞれの単語の重要性を効率よく学習するために，我々は 1-dimensional spatialDropout[13] 層を埋め込み層と CTI bi-LSTM 層の間に入れている．モデルの最後にある CRF 層では単語ごとのラベリングが発言での文脈情報を用いて行われる．bi-LSTM の出力を CRF の入力として用いることが Named Entitiy Recognition(NER) を始めとする系列ラベリング問題において有効であることが示されてきていることから [15],[16] [17]，本研究でも採用を決めた．モデルの処理手順を Algorithm 2 に示す．最初の

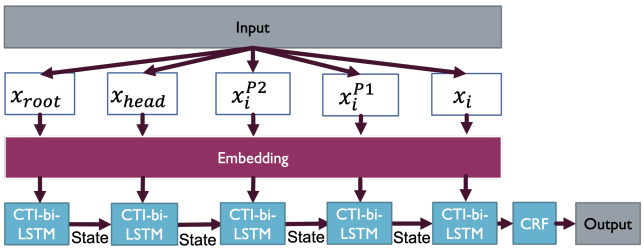

図 5　Node-extraction model architecture detail

Algorithm 2 Node-extraction model

Input1,2,3,4,5 $x_{current}, x_{root}, x_{head}, x_{anc1}, x_{anc2}$:embedding vectors of submission
2: *Output* :
procedure NODE-EXTRACTION MODEL(R)
4: **for** x_{in} in $\{x_{root}, x_{head}, x_{anc1}, x_{anc2}, x_{current}\}$ **do**
if this layer is first layer **then**
6: s_t=zero vector
x_{out}, s_{t+1} = CTI bi-LSTM$\{x_t, s_t\}$
8: label = CRF(x_{out})
return label

層を除いて (行 5 から 6 まで)，それぞれの CTI bi-LSTM 層は 1 つ前の CTI bi-LSTM 層の内部状態を初期状態として使用し，新しい内部状態と出力を作成する (行 4 から 7 まで)．

5. データセット

D-Agree は大規模意思決定支援知能システムである． 図 6 はファシリテーターと議論参加者の療法が使用している典型的なユーザーインターフェイスを示している．D-Agree は効率的な情報収集のためのインセンティブメカニズムを持っている．

我々は D-Agree 上で行われた議論から発言のデータを集めた．本研究でデータを集める対象となったのは 29 個の議論である．我々は全データの中から 10%(150 投稿) の発言をテストデータとして取り出し，残りの 90%(1365 発言)

図 6　D-Agree user-interface

で学習を行った．図 7 はデータセット中の投稿に含まれている単語数のヒストグラムを示している．

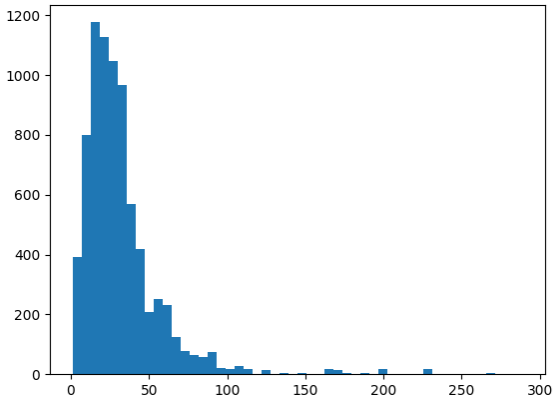

図 7　Histogram of submission length

図 7 から大半の発言は 100 個以下の単語から構成されていること，そして 100 個以下の単語から構成される発言の内半分以上が 50 個以下の単語から構成されていること，すなわち殆どの発言が短いものであることが分かる．また，投稿に含まれる単語数は最大でも 280 語程度であることも分かる．データセットの中で各要素に属する単語の分布が図 1 に示されている．議論構造として分類されていない 414229 個の単語からなる Other を除いて ideas が最も多い要素であり，残りは数の多い順に pros，cons，issues となっている．

表 1 Number of morpheme in each argument component type

	number of morpheme
issues	3825
ideas	10739
pros	5149
cons	4471
Other	414229

6. 評価実験

6.1 設定

我々は提案モデルのノード抽出性能を評価する実験を行った．正解データと予測されたデータのラベリングを 2 種類の尺度で比較した．

1. 要素検出: 投稿に含まれているノードの検出性能を評価するために，単語の位置に関係なく，投稿に IBIS の各要素が含まれているかどうかを比較する．

2. 抽出: 投稿からのノード抽出性能を評価するために，各単語に正しい要素のラベリングが行われているかどうかを比較する．

評価指標としては適合率，再現率そして F1 スコアを用いた．また，我々は 2 種類の入力を比較した． 1 つ入力では投稿をそのまま入力として使用し，もう 1 つの入力では冗長な情報を削除することで精度が上昇するか確認するために，入力される投稿の単語数を 50 語以下に制限した．50 語という長さは 5 節での考察に基づいて決定した．

最良の結果を得るために，実験を通して使用するのいくつかのパラメータを設定した．学習パラメータの値は実験を通して最も性能の良かったものに決定した．埋め込み層内のベクトルの次元サイズは 300，全 CTI bi-LSTM 内のベクトルの次元サイズは 300，全 spatialDropout のドロップアウト率は 0.1 に，学習におけるバッチサイズは 16 に設定した．上記のパラメーターをまとめたものを表 2 に示す．

表 2 Parameter Settings

Parameter	Meaning	Value
embedSize	埋め込みベクトルの次元サイズ	300
stateSize	CTI bi-LSTM の次元サイズ	300
dropRate	spatialDropout のドロップアウト率	0.1
batchSize	学習中のバッチサイズ	16

6.2 実験結果 1

入力される投稿の単語数を 50 語以下に制限した条件下での要素検出の実験結果を表 3 に示す．各行は，各要素ごとの分類の適合率，再現率，および F1 スコアを表す．表 3 に示されているように，提案モデルは全ての要素において 0.6 以上の再現率を示し，F1 スコアも全て 0.5 以上を示している．また，同じく入力される投稿の単語数を 50 語以下に制限した条件下でのノード抽出の実験結果を表 4 に示す．表 4 において，提案モデルは issues の抽出で 0.667 の F1 スコアを達成し，大半の要素において 0.6 以上の高い精度で抽出できていることが分かる．表 3 と表 4 の結果を比較することで，要素検出から抽出にかけて ideas，pros，そして cons の値が全体的に下がっていることが確認できる．issues のみが値が上昇し，最も高い F1 スコアを獲得している．上記の要素ごとの違いは単語の場所も含めたラベリングの性能に由来する．単語数を 50 語以下に制限した条件下で，issues が他の要素よりも単語の場所も含めて適切に分類されていることを確認できる．

表 3 Experimental results of type find (restricted)

	Precision	Recall	F1
issues	0.516	0.64	0.571
ideas	0.761	0.77	0.765
pros	0.5	0.61	0.55
cons	0.48	0.72	0.58

表 4 Experimental results of node extraction (restricted)

	Precision	Recall	F1
issues	0.732	0.61	0.667
ideas	0.679	0.55	0.609
pros	0.363	0.449	0.401
cons	0.695	0.219	0.333

単語ラベリングの性能における上記の違いは，各要素の出現位置に要因があると考えることができる．表 1 に示されているように，issue に分類される単語は他のどのタイプよりも少ないが，提案モデルでは issue の分類において最も良い性能を示した ．単語数を 50 語以下に制限した条件下であることを踏まえると，issue の要素が一般的に投稿の前の方に現れる傾向があるという仮説を立てることができる．

6.3 実験結果 2

続いて，単語数を制限しないという条件下での実験結果を述べていく．単語数を制限しないという条件下での要素検出の実験結果を表 5 に，抽出の実験結果を表**??**に示す．表 5 に示されているように，提案モデルは issue を除いて依然として高い適合率と 0.5 以上の F1 スコアを達成している．

表 5 Experimental results of type find(not restricted)

	Precision	Recall	F1
issues	0.118	1.0	0.211
ideas	0.831	0.907	0.867
pros	0.538	0.477	0.506
cons	0.729	0.658	0.692

また，表 6 では提案されたモデルが issue と idea において

依然として比較的高い適合率，再現率，および問題の F1 スコアを達成していることが示されている．表 5 と表 6 での

表 6 Experimental results of node extraction(not restricted)

	Precision	Recall	F1
issues	0.504	0.575	0.537
ideas	0.557	0.611	0.583
pros	0.393	0.332	0.359
cons	0.49	0.445	0.467

結果を比較すると?節で単語数を制限した場合の結果と同様に要素検出から抽出にかけて ideas，pros，そして cons の値が全体的に下がっていることと issue の値のみが大きく上昇していることが確認できる．上記の違いも，issues が他の要素よりも単語の場所も含めて適切に分類されていることに起因すると考えられる．

6.4 考察

ここで我々は単語数に制限をかけた場合とかけなかった場合とで得られた結果を比較する．我々は単語数に制限をかけた場合からかけなかった場合にかけて分類性能の値が低下することを確認したが，値の低下は議論を構成する要素が投稿の前の方に現れる傾向があるためだと想定される．少ないデータ数にもかかわらず，提案モデルは良い性能を示した．それゆえ実験結果から我々の提案手法が IBIS 構造を抽出するのに効率的であることが伺える．

7. おわりに

本論文では複数の参加者によって作成された議論文を基に議論構造を作成するためのモデルを提案した．以前の研究にはいくつかの制限が存在する．既存のモデルの多くは 1 人の筆者によって書かれた評論文のみに焦点を当てており，抽出は IBIS に基づいていない．したがって，既存のモデルは Web フォーラムでの大規模議論の議論構造解析には適していない．

我々は議論での投稿から IBIS に基づく議論構造を抽出するために，Cross multiple Time series Input bi-LSTM（CTI bi-LSTM）と CRF を使用して，議論での投稿に系列ラベリングを行うモデルを提案した．我々は，CTI bi-LSTM によって作成された過去投稿の要約情報を使用することがラベリングの結果を改善することを示した．

謝辞 研究内容は，JST CREST「エージェント技術に基づく大規模合意形成支援システムの創成：代表伊藤孝行」（グラント番号 JPMJCR15E1）に支援を受けている研究の一部である．

参考文献

[1] Fundamentals of argumentation theory: A handbook of historical backgrounds and contemporary developments, Van Eemeren, Frans H and Grootendorst, Rob and Johnson, Ralph H and Plantin, Christian and Willard, Charles A, 2013 Routledge.
[2] Discussion tree for managing large-scale internet-based discussions, Sengoku, Akihisa and Ito, Takayuki and Takahashi, Kazumasa and Shiramatsu, Shun and Ito, Takanori and Hideshima, Eizo and Fujita, Katsuhide, Collective Intelligence, 2016, 2016.
[3] Incentive mechanism based on qualit of opinion for Large-Scale discussion support, Takahashi, Kazumasa and Ito, Takayuki and Ito, Takanori and Hideshima, Eizo and Shiramatsu, Shun and Sengoku, Akihisa and Fujita, Katsuhide, Collective Intelligence, 2016, 16, 2016
[4] Incentive mechanism for managing large-scale internet-based discussions on collagree, Ito, Takayuki and Imi, Yuma and Sato, Motoki and Ito, Takanori and Hideshima, Eizo, Collective Intelligence, 2015, 2015.
[5] COLLAGREE: A faciliator-mediated large-scale consensus support system, Ito, Takayuki and Imi, Yuma and Ito, Takanori and Hideshima, Eizo, Collective Intelligence 2014, 2014.
[6] Parsing argumentation structures in persuasive essays, Stab, Christian and Gurevych, Iryna, Computational Linguistics, 43, 3, 619–659, 2017, MIT Press.
[7] Extracting argument and domain words for identifying argument components in texts, Nguyen, Huy and Litman, Diane, Proceedings of the 2nd Workshop on Argumentation Mining, 22–28, 2015
[8] Issues as elements of information systems, Kunz, Werner and Rittel, Horst WJ 131, 1970, Citeseer
[9] Enriching word vectors with subword information, Bojanowski, Piotr and Grave, Edouard and Joulin, Armand and Mikolov, Tomas, Transactions of the Association for Computational Linguistics, 5, 135–146, 2017, MIT Press
[10] Corpus-independent generic keyphrase extraction using word embedding vectors, Wang, Rui and Liu, Wei and McDonald, Chris, Software Engineering Research Conference 39, 2014
[11] Argument extraction from news, blogs, and social media, Goudas, Theodosis and Louizos, Christos and Petasis, Georgios and Karkaletsis, Vangelis, Hellenic Conference on Artificial Intelligence, 287–299, 2014, Springer
[12] Automatic detection of arguments in legal texts, Moens, Marie-Francine and Boiy, Erik and Palau, Raquel Mochales and Reed, Chris, Proceedings of the 11th international conference on Artificial intelligence and law, 225–230, 2007, ACM
[13] Efficient object localization using convolutional networks, Tompson, Jonathan and Goroshin, Ross and Jain, Arjun and LeCun, Yann and Bregler, Christoph, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 648–656, 2015
[14] Conditional random fields: Probabilistic models for segmenting and labeling sequence data, Lafferty, John and McCallum, Andrew and Pereira, Fernando CN, 2001
[15] Bidirectional LSTM-CRF models for sequence tagging, Huang, Zhiheng and Xu, Wei and Yu, Kai, arXiv preprint arXiv:1508.01991, 2015
[16] Neural architectures for named entity recognition, Lample, Guillaume and Ballesteros, Miguel and Subramanian, Sandeep and Kawakami, Kazuya and Dyer, Chris, arXiv preprint arXiv:1603.01360, 2016
[17] Character-based Bidirectional LSTM-CRF with words and characters for Japanese Named Entity Recognition, Misawa, Shotaro and Taniguchi, Motoki and Miura, Ya-

suhide and Ohkuma, Tomoko, Proceedings of the First Workshop on Subword and Character Level Models in NLP, 97–102, 2017

[18] Ito, Takayuki 2018, 01, Towards Agent-based Large-scale Decision Support System: The Effect of Facilitator, 10.24251/HICSS.2018.047

[19] A Method for Online Discussion Design and Discussion Data Analysis, Yamaguchi, Naoko and Ito, Takayuki and Nishida, Tomohiro

[20] Applying conditional random fields to Japanese morphological analysis, Kudo, Taku and Yamamoto, Kaoru and Matsumoto, Yuji, Proceedings of the 2004 conference on empirical methods in natural language processing, 2004

[21] Generating questions asked by facilitator agents using preceding context in web-based discussion, Ikeda, Yuto and Shiramatsu, Shun, 2017 IEEE International Conference on Agents (ICA), 127–132, 2017, IEEE

ⓒ 2019 Information Processing Society of Japan