

自動ファシリテーションエージェントのための Gated Attention Networkを用いたノード分類

酒井 敦也^{1,a)} ファム ユイ^{1,b)} 鈴木 祥太^{1,c)} 佐藤 拓実^{1,d)} 川村 直輝^{1,e)} 伊藤 孝行^{2,f)}

概要:近年、Web 上での大規模議論が注目を集めている。そのような中、大規模オンライン合意形成支援システムの研究が盛んに行われている。大規模な議論では意見が数百、数千と投稿され、一日中議論が開かれていることもあるため人間がファシリテータの役割を担うことは困難である。自動ファシリテーションエージェントの開発のため、議論をグラフ構造として抽出する先行研究が存在するが、本研究は議論構造抽出のタスクの一つであるノード分類を高精度で行うことを目的とする。提案する手法には、Bidirectional Encoder Representations from Transformers (BERT), Gated Attention Network (GaAN) を使い、議論構造には Issue-Based Information System (IBIS) 構造を採用する。実験の結果、先行研究や他の一般的な分類手法よりも高い精度で意見を分類できることを示すことができた。

Node Classification Using Gated Attention Network for Automated Facilitation Agent

1. はじめに

近年、Web 上での大規模議論が注目を集めている。Web の発達や通信技術の発展により、時間や空間的な制限を受けずに Web 上での大規模な議論を行うことが容易となり、Web 上での大規模な議論を活用した意見集約・合意形成に期待が高まっている。そこで、Web 上で効率的に意見集約・合意形成を促す議論プラットフォームについて多くの研究が進められてきた。その例として、大規模オンライン議論支援システム COLLAGREE [1], [2] や D-Agree [3], [4] といったシステムが開発されており、中でも D-Agree では、自動ファシリテーションエージェントと呼ばれるエージェントによってリアルタイムでの議論の分析が行われている。具体的には、Web 議論に投稿されたテキストデータに対して自然言語処理を用い、議論構造の抽出を自動的

行なっている [5], [6]。COLLAGREE, D-Agree を利用した社会実験は既に多数行われており、高い有効性が示されている [7], [8], [9], [10], [11], [12], [13], [14]。

本研究では、議論における意見のことをノードと呼び、意見間の関係のことをリンクと呼ぶ。議論構造の抽出はノード分類とリンク予測の2つのサブタスクからなる。ノード分類では、意見が定義したクラスのどのクラスに属するかの分類をし、リンク予測では、各ノードのリンク関係を定義した議論構造に従って予測する。本研究では、議論構造に Issue-Based Information System (IBIS) [15] を採用する。IBIS 構造を図 1 に示す。議論における意見は、解決すべき問題である Issue、Issue に対する解決案である Position、Position に対する利点および欠点である Argument に分類される。IBIS 構造は図 1 のように、Issue は全てのノードに接続することができ、Position は Issue にのみ、Argument は Position に対してのみ接続することができる。IBIS 構造に基づいて議論を行うと議論は図 2 のようなツリー構造になる。自動ファシリテーションエージェントは抽出された議論構造を利用して議論を分析し、適切なファシリテートを可能としている。

我々は、自動ファシリテーションエージェントがより適切にリアルタイム議論分析を行い、Web 上の議論にお

¹ 名古屋工業大学
Nagoya Institute of Technology

² 京都大学
Kyoto University

a) sakai.atsuya@itolab.nitech.ac.jp

b) pham.duy@itolab.nitech.ac.jp

c) suzuki.shota@itolab.nitech.ac.jp

d) sato.takumi@itolab.nitech.ac.jp

e) kawamura.naoki@itolab.nitech.ac.jp

f) ito@i.kyoto-u.ac.jp




図 1 IBIS 構造のリンク関係

る意見集約・合意形成をより促すことができる議論支援を目指している。本論文では、高精度な議論構造抽出のために、Gated Attention Network に基づき、サブタスクの一つである高精度なノード分類手法を提案する。

先行研究には鈴木ら [6] のノード分類がある。鈴木らは議論構造をグラフとして捉え、Graph Attention Network (GAT) [16] を用いグラフ構造を直接学習するアプローチを提案している。GAT はニューラルネットワークモデルを用いてグラフ構造を直接符号化する。更に GAT では注意機構を利用しているため、異なるグラフ構造を扱うことが可能である [17]。この鈴木らの手法は既に、ノード分類問題において高い有効性を示している。私たちは GAT の各注意機構の重要度を制御することができないという部分に着目をし、GAT の発展である Gated Attention Network (GaAN) [18] を鈴木らの手法に応用することで精度の向上を目指した。GaAN では各注意機構の重要度を適切な重要度に制御することができ、分類問題において GAT より優れた有効性が示されている。

本稿の構成は次の通りである。まず、2 章で議論構造抽出の関連研究や先行研究について述べる。次に、3 章で Gated Attention Network を用いたノード分類の提案手法に関して述べる。さらに、4 章で議論におけるノード分類の評価実験の設定について述べ、5 章で評価実験の結果および考察に関して述べる。最後に、6 章で本稿のまとめを示す。

2. 関連研究

2.1 Argumentation Mining

Argumentation mining とは、主に機械学習を用いて文章の論理構造を推定することを指す。Argumentation mining における論理構造は論理要素と呼ばれる論理に関する文や節から成り立つ。論理要素は筆者の立場を示す主張 (claim) と主張を支持、反証する前提 (premise) に分けられる。多くの argumentation mining の研究では、それぞれの要素をノードとみなし、ノード間に有向エッジを引くことで支

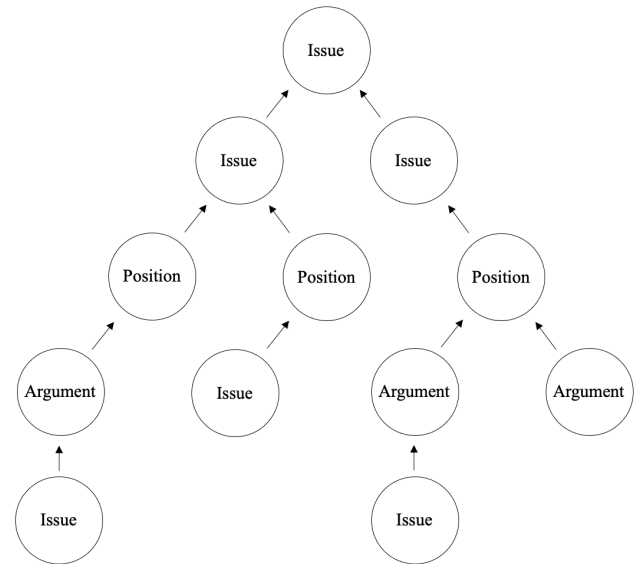


図 2 IBIS 構造に基づく議論ツリー

持、反証しているという因果関係を示すことによってグラフとして論理構造を推定している。

Argumentation mining には、文章中の論理要素に関する文や節を抽出する要素抽出、論理要素が論理構造の中でどのような役割を果たしているか特定する要素分類、各論理要素間の因果関係を特定する関係分類、最終的な出力となる論理構造を決定する構造推定などのサブタスクがある。Stab ら [19] は要素抽出、要素分類、関係分類、構造推定を機械学習を用いて解き、4 つのサブタスクを統合することで論理構造を抽出する手法を提案している。

2.2 Graph Attention Network (GAT)

Graph Attention Network (GAT) [16] は、グラフ構造を直接学習する方法の一つである。グラフ構造を直接学習する先行研究である Graph Convolution Network (GCN) [20] は学習されたフィルタがグラフラプラシアン固有ベクトルに依存するため、異なるグラフ構造に対応することができない。そこで、フィルタがグラフ構造に依存しないような注意機構に基づく GAT が提案された。

GAT の各ノードに対する注意機構を使用した特徴量の更新式は、注目ノード i の特徴量を \vec{h}_i 、得られる出力を \vec{h}'_i 、注目ノード i の隣接ノードの集合を \mathcal{N}_i 、重み行列を \mathbf{W} とおくと式 (1) によって表される。

$$\vec{h}'_i = \sigma \left(\sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W} \vec{h}_j \right) \quad (1)$$

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\vec{\mathbf{a}}^T [\mathbf{W} \vec{h}_i \parallel \mathbf{W} \vec{h}_j]))}{\sum_{k \in \mathcal{N}_i} \exp(\text{LeakyReLU}(\vec{\mathbf{a}}^T [\mathbf{W} \vec{h}_i \parallel \mathbf{W} \vec{h}_k]))} \quad (2)$$

ここで、 α_{ij} は式 (2) で表され、 $\vec{\mathbf{a}}$ は重みベクトルを表す。活性化関数には $\alpha = 0.2$ の LeakyReLU が用いられる。

式 (1) を結合し、その特徴量 K 個の平均を取る事によつ

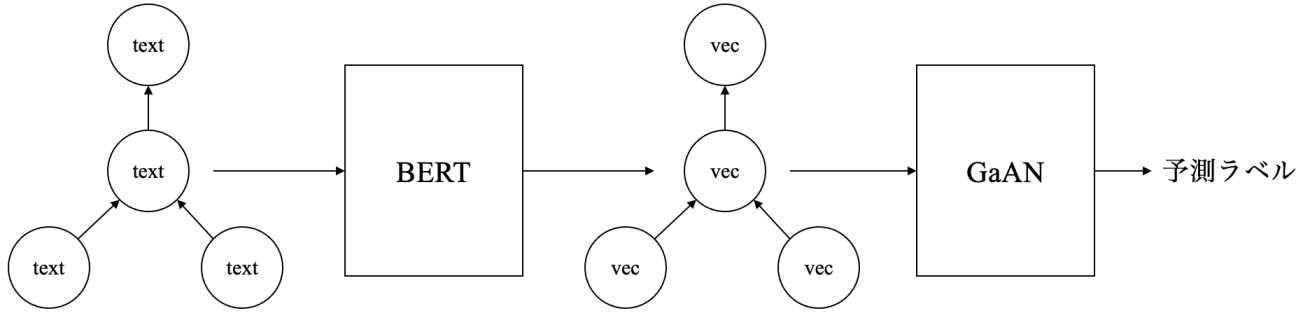


図 3 GaAN を用いたノード分類手法の概要図

て、GAT の最終的な出力は計算される。 K は注意機構の数を表す。GAT の最終的な出力は、次式によって表される。

$$\vec{h}'_i = \sigma \left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in \mathcal{N}_i} \alpha_{ij}^k \mathbf{w}^k \vec{h}_j \right).$$

リアルタイムで進行する議論では、議論のグラフ構造が頻繁に変化する。したがって、GAT のように異なるグラフ構造を直接学習する方法は、グラフ構造が頻繁に変化する可能性のある議論構造の抽出において、有効な手法であると推定される。

2.3 オンライン議論における議論構造抽出のためのノード分類

鈴木ら [6] は、議論構造におけるノード分類を GAT を利用し行なった。

以下に示す特徴を使用し、グラフ構造中の各ノードを分散表現として表している。

- 語彙の特徴量：見出語化されたユニグラムおよび出現頻度が上位 2000 以上の単語のペアから構成される
- 指標の特徴量：前方指標，後方指標，論的指標，反証指標，一人称を表す指標を含むか否かを表す
- 埋め込みの特徴量：Bidirectional Encoder Representations from Transformers (BERT) [21] による単語のベクトル表現から構成される

本論文との相違は、鈴木 [6] らの GAT を用いた手法ではなく、GaAN を用いた手法を提案し、さらに精度を向上できる点である。

3. 提案手法

3.1 Gated Attention Network (GaAN)

GaAN は 2018 年に Zhang ら [18] によって公開された大規模時空間的なグラフを学習するモデルである。Gated Attention Network では Gated Attention Aggregator という Aggregator を用いている。Aggregator とは、グラフにおけるグラフ情報やノードの特徴量などの複数の入力から

単一の出力を計算するものを意味する。Gated Attention Aggregator は注目ノードと隣接ノードの間の複数の表現空間を探索する能力を持っており、かつ、各ヘッドに重要度を割り当て、重要な情報を強く、重要ではない情報を弱く計算する。注目ノードと隣接ノードの間の表現空間の重要度はどれも等しいわけではないためである。重要度が低い表現空間を使用する注意機構を用いて出力を計算すると、モデルの最終的な予測結果の精度が低下する可能性がある。

したがって、Gated Attention Aggregator では各ヘッドに重要度を割り当てるために、0 (重要度が低い) から 1 (重要度が高い) までの追加のソフトゲートを計算する。注目ノード i の入力ベクトルと出力ベクトルをそれぞれ \mathbf{x}_i と \mathbf{y}_i 、隣接ノード j のベクトルを \mathbf{z}_j 、隣接ノードの集合を \mathcal{N}_i 、隣接ノードのベクトルの集合を $\mathbf{z}_{\mathcal{N}_i} = \{\mathbf{z}_j | j \in \mathcal{N}_i\}$ とおくと、以下の式 (3) のようになる。

$$\mathbf{y}_i = FC_{\theta_o}(\mathbf{x}_i \oplus \parallel_{k=1}^K (g_i^{(k)} \sum_{j \in \mathcal{N}_i} w_{i,j}^{(k)} FC_{\theta_v}^h(\mathbf{z}_j))) \quad (3)$$

$$\mathbf{g}_i = [g_i^{(1)}, \dots, g_i^{(K)}] = \psi_g(\mathbf{x}_i, \mathbf{z}_{\mathcal{N}_i})$$

ここで、 K は注意機構数、 $\parallel_{k=1}^K$ は x_1 から x_K まで順に連結演算を行うことを表し、 $w_{i,j}^{(k)}$ は注目ノード i と近隣ノード j 間の k 個目の注意係数、 $FC_{\theta}^{\alpha}(x) = \alpha(\mathbf{W}x + b)$ はパラメータ $\theta = \{\mathbf{W}, b\}$ 、非線形活性化関数 $\alpha(\cdot)$ を持つ単一の全結合層を表す。 $g_i^{(k)}$ はスカラーで、ノード i の k 個目の注意機構のゲートの値である。

ゲート ψ_g は隣接ノードの average pooling と max pooling を結合して構成したものを採用している。(式 (4))。

$$\mathbf{g}_i = FC_{\theta_g}^{\sigma}(\mathbf{x}_i \oplus \max_{j \in \mathcal{N}_i} \{FC_{\theta_m}(\mathbf{z}_j)\}) \oplus \frac{\sum_{j \in \mathcal{N}_i} \mathbf{z}_j}{|\mathcal{N}_i|} \quad (4)$$

ここで、 θ_m は近隣ノードの特徴量を次元 d_m のベクトルへ変換し、 θ_g は結合した特徴を最後の K ゲートへ変換するものである。 d_m を小さく設定することで、ゲートを計算するためのサブネットワークの計算量が少なくなる。

表 1 英語評論のコーパス [19] を IBIS 構造に変換したコーパスの例

Issue1	What do you think about same sex marriage?
Position1	Same sex marriage should be legal.
Argument1	There is absolutely no legal, logical, or governing reason that same sex couples cannot be wed.
Issue2	What do you think about same sex marriage getting made seem inferior to heterosexual marriage?
Position2	It's unfair.
Argument2	It is hypocritical to deny the full rights and opportunities of citizenship which includes the access to an institution as basic as matrimony.
Argument3	It is no different.

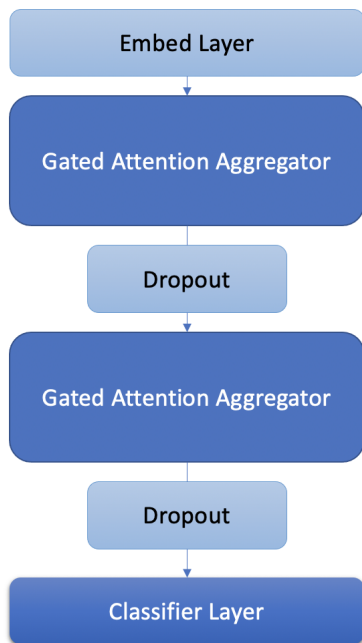


図 4 GaAN モデルの構成

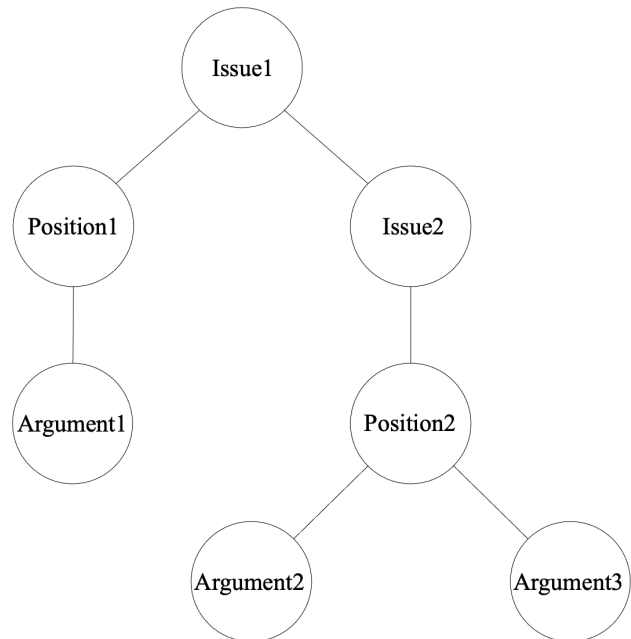


図 5 表 1 をグラフ構造に変換した例

3.2 Gated Attention Network を用いたノード分類

提案手法の概要図を図 3 に示す. text はテキストデータのことを指し, vec はベクトルのことを指す.

まず, 議論であるテキストデータをグラフに変換する. 議論内の意見をノードとし, ノード間の関係をリンクとして有向グラフを作成する. リンクは IBIS 構造に則るよう作成する. 有向グラフを作成するとき, すべてのノードに対して, 自分自身のノードへのリンクである self-loop を作成しない. 実験で使用する Stab ら [19] が提供した英語評論のコーパスを IBIS[15] 構造に変換したコーパスの一例を表 1 に, 表 1 をグラフ構造にした場合の図を図 5 に示す. 表 1 ではリンク関係 E が $E = \{(Issue1, Position1), (Position1, Argument1), (Issue1, Issue2), (Issue2, Position2), (Position2, Argument2), (Position2, Argument3)\}$ となり, グラフ構造にすると図 5 のようになる.

次に, テキストデータから変換したグラフにおけるノードの特徴量を生成する. 本研究では, ノードの特徴量は Bidirectional Encoder Representations from Transformers (BERT)[21] の事前学習モデルによる分散表現とする. ま

た, ノードの文章における大文字と小文字を区別する. したがって, 前処理として英単語をすべて小文字化しない BERT-Base Cased という事前学習モデル [21] を使用する. BERT の最終隠れ層の出力より, 最後の隠れ層 4 層を結合し, 全ての単語ベクトルの各次元の平均値をとったものをノードの特徴量とする. また, BERT の事前学習モデルでは文の長さが 512 以下である必要があるため, 入力文の長さが 512 以上である場合, 入力文を最大長が 512 となる複数の部分へ分割し, それぞれの分割に対する特徴量を生成する.

そして, グラフにおけるすべてのノードの特徴量を生成した後, グラフ構造とノードの特徴量の情報を GaAN モデルに入力する.

本研究では, Zhang ら [18] と同様に, 2つの Graph Aggregator を用いて, GaAN モデルを構築する. GaAN モデルの構成を図 4 に示す. まず, 入力したノードの特徴量を Embed Layer によりダウンサンプリングする. 入力したノードの特徴量の次元が大きすぎる場合, モデルのサイズが膨大になるため, Embed Layer を導入することでこの

表 2 Gated Attention Aggregator の各層のパラメータ設定

パラメータの種類	説明	値
embed_feature_dim	Embed Layer の出力ベクトルの次元	256
out_units	Graph Aggregator の出力ベクトルの次元 (d_o)	256
attend_units	注意機構の出力ベクトルの次元 (d_a)	64
value_units	バリューベクトルの次元 (d_v)	256
context_units	ゲートを計算するための結合層の出力次元 (d_g)	256
context_layer_num	ゲートを計算するための結合層の数	1
K	注意機構の数	4
dropout	ドロップアウト率	0.5

表 3 学習関連のパラメータ設定

パラメータの種類	説明	値
GaAN layers	GaAN layer の数	2
feature_dim	ノードの特徴量の次元数	768
batch_size	一度に学習するノードの数	512
epochs	最大エポック数	200
learning_rate	学習率	0.001

問題を回避することが可能になる。次に、ダウンサンプリングしたノードの特徴量とグラフ構造を Gated Attention Aggregator に入力して、ノードの特徴量を更新する。そして、グラフ構造を考慮したノードの特徴量をドロップアウト層に入力する。ノードの特徴量の更新とドロップアウトを 2 回繰り返す。最後に、活性化関数にソフトマックス関数を使用し Classifier Layer に接続することで、ノードの各ラベルの正規化した確率が得られる。

提案手法の Gated Attention Aggregator で用いたパラメータを表 2 に、学習のために用いたパラメータを表 3 に示す。損失関数には交差エントロピー誤差を採用する。学習ではエポックごとに検証データに対する F 値を算出する。10 エポック内に検証データに対する F 値の向上がなければ、学習を早期終了させる。

4. 評価実験の設定

提案手法を評価するために、本研究では Stab ら [19] が提供した英語評論のコーパスを IBIS[15] 構造に変換したコーパスを用いる。コーパスには 90 編の評論、2,071 文、25,584 単語が含まれている。要素の内訳は Issue が 519 文、Position が 519 文、Argument が 1033 文となっている。

実験は以下の 2 種類行う。

実験 1：特徴量による精度比較

特徴量による精度比較実験を行うために特徴量を鈴木ら [6] と同じ以下のものにした場合と BERT の分散表現のみの場合を比較する。モデルはどちらも提案手法で示した GaAN を用いる。

- 語彙の特徴量：見出語化されたユニグラムおよび出現頻度が上位 2000 以上の単語のペア
- 指標の特徴量：前方指標、後方指標、論的指標、反証指標、一人称を表す指標を含むか否か

- 埋め込みの特徴量：BERT による単語のベクトル表現

実験 2：他の機械学習手法と精度比較

他の機械学習手法と精度比較のため、Support Vector Machine (SVM) [22], Random Forest (RF) [23], Gradient Boosting (GB) [24] といった 3 種類の機械学習を用いた手法と鈴木ら [6] の手法、計 4 種類の手法と比較する。SVM, RF, GB では分類対象のみのノードの分散表現を、鈴木ら [6] の手法と提案手法ではグラフを入力とする。

検証方法は実験 1 と実験 2 どちらもホールドアウト法を用いる。実験 2 で鈴木ら [6] の先行研究と比較するために、鈴木ら [6] と同様に、90 編の英語評論のうち、54 編を訓練データ、18 編を検証データ、残りの 18 編をテストデータとする。評価指標には F 値 [25] を用いる。

5. 実験結果および考察

5.1 実験 1：特徴量による精度比較

語彙の特徴量、指標の特徴量、埋め込みの特徴量の 3 種類の特徴量で実験した結果と BERT による埋め込みの特徴量のみの場合で実験した結果の比較を表 4 に示す。また、3 種類の特徴量で実験した結果の混同行列を図 6 に、BERT による埋め込みの特徴量のみで実験した結果の混同行列を図 7 に示す。表 4 を見ると、BERT による埋め込みの特徴量のみの場合の方が Issue と Position の F 値は高く、Argument の F 値は同等という結果になっている。それぞれの混同行列である図 6 と図 7 を比較すると、誤分類された文が 3 種類の特徴量の場合は 4 文、BERT による埋め込みの特徴量のみの場合は 3 文となっている。

BERT による埋め込みの特徴量のみの方が 3 クラス中 2 クラスで高い F 値を示しており、また、誤分類された文の総数も少ないため、特徴量は BERT による埋め込みの特徴量のみで十分だと考えられる。実験 2 では BERT による埋め込みの特徴量のみを用いた GaAN モデルで実験を行う。

5.2 実験 2：他の機械学習手法と精度比較

提案手法と Support Vector Machine (SVM), Random Forest (RF), Gradient Boosting (GB) および先行研究である鈴木ら [6] による実験結果の F 値を表 5 に示す。また、

表 4 特徴量による比較実験結果

特徴量	F 値		
	Issue	Position	Argument
語彙, 指標, 埋め込みの特徴量	0.984	0.978	0.998
BERT による埋め込みの特徴量のみ	0.989	0.984	0.998

表 5 他の機械学習手法と精度比較実験結果

手法	F 値		
	Issue	Position	Argument
Support Vector Machine	0.894	0.372	0.844
Random Forest	0.978	0.613	0.890
Gradient Boosting	0.989	0.764	0.913
Graph Attention Network (鈴木ら [6] による手法)	0.935	0.876	0.976
Gated Attention Network (提案手法)	0.989	0.984	0.998

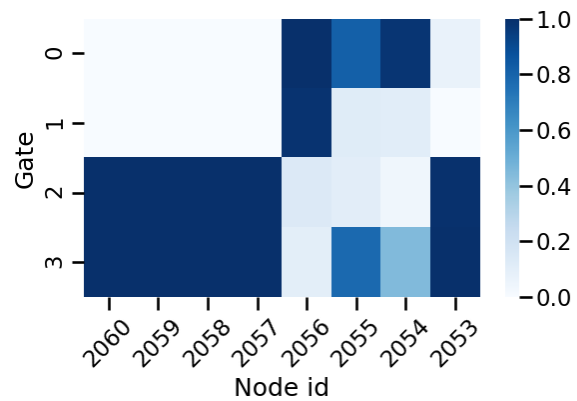



図 6 特徴量が語彙の特徴量, 指標の特徴量, 埋め込みの特徴量の場合の GaAN による評価実験の混同行列

図 8 8 データに対する 4 ゲート値の可視化例

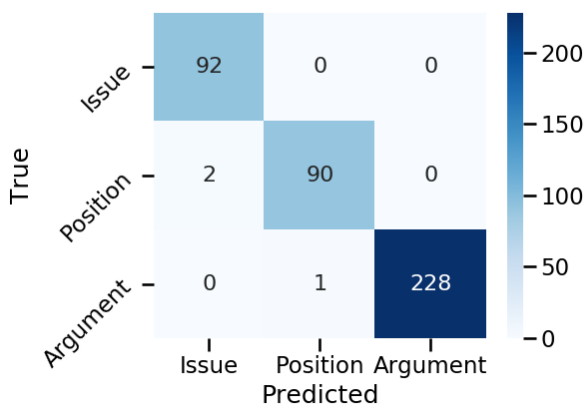


図 7 特徴量が BERT の分散表現のみの場合の GaAN による評価実験の混同行列

いることが確認できる。そして、表 5 に示す通り、3つの機械学習を用いた手法 (SVM, RF, および GB) よりも、提案手法の方が高い分類精度を示した。また、ゲート値の可視化のため、例として 8 データに対する 4 ゲートの値を可視化した図を図 8 に示す。図 8 から、ゲートの値がそれぞれ異なっていることが分かる。

考察として、入力に重要度を割り当てることができることが精度が向上した要因として考えられる。図 8 から分かる通り、ゲートの値がそれぞれ異なっている。GAT と GaAN の大きな違いは入力に重要度を割り当てることができるかできないかであるため、この要因が精度を向上させた要因と考えられる。実験結果から、ノード単体での入力よりもグラフとして入力した方が精度が向上し、グラフにおけるノードの重要度も入力に含めることで、より精度が向上するということが示された。

本実験で得られた知見は以下の通りである。

- 特徴量に関して、語彙, 指標, 埋め込みの 3 種類の特徴量を用いるより、埋め込みの特徴量のみを用いた方がノード分類において高い精度を示した。
- ノード分類において、提案手法が鈴木ら [6] の先行研

提案手法による評価実験の混同行列を図 7 に示す。まず、鈴木ら [6] によるモデルを使用した場合との分類精度を比較する。表 5 の F 値を比較すると、各ラベルについて提案手法が一番高いスコアを示しているため、鈴木ら [6] によるモデルよりも提案手法の方がノード分類をうまく行えて

究や他の一般的な機械学習手法よりも高い精度を示した。

- GaANを用いることで、隣接ノードの情報を重要度を含めて計算できるため、重要とされる隣接ノードの情報を強く計算することにより、適切にノード分類を行うことができると考えられる。

6. まとめ

本稿では議論構造の抽出のためのサブタスクの一つであるノード分類に Gated Attention Network (GaAN) を用いることを提案した。提案手法の評価のために、評論を IBIS 構造に変換したデータセットを利用した。実験の結果、提案手法が他の手法と同等以上の F 値を示し、最も適切にノード分類を行うことができると示すことができた。グラフにおける隣接ノードの重要度も計算に含めることで精度の向上を達成することができた。

今後は柔軟に様々な種類の議論を分析するために、IBIS 構造に構造化された議論以外の議論に対しても応用することを目指す。

謝辞 本研究は JST CREST 研究課題番号 JP-MJCR15E1 の助成を受けている。

参考文献

- [1] Ito, T., Imi, Y., Ito, T. and Hideshima, E.: COLLAGREE: A facilitator-mediated large-scale consensus support system, *Collective Intelligence 2014* (2014).
- [2] Ito, T., Imi, Y., Sato, M., Ito, T. and Hideshima, E.: Incentive mechanism for managing large-scale internet-based discussions on collagree, *Collective Intelligence*, Vol. 2015 (2015).
- [3] Ito, T.: Discussion and Negotiation Support for Crowd-Scale Consensus, *Handbook of Group Decision and Negotiation* (Kilgour, Marc, D., Eden and Colin, eds.), Springer (2021).
- [4] Ito, T., Suzuki, S., Yamaguchi, N., Nishida, T., Hiraishi, K. and Yoshino, K.: D-agree: Crowd Discussion Support System based on Automated Facilitation Agent, *Proceedings of 35th AAAI conference*, Vol. 2020 (2020).
- [5] Suzuki, S., Yamaguchi, N., Nishida, T., Moustafa, A., Shibata, D., Yoshino, K., Hiraishi, K. and Ito, T.: Extraction of Online Discussion Structures for Automated Facilitation Agent, *JSAI International Sessions Proceedings*, Vol. JSAI2019, pp. 2F1E302–2F1E302 (2019).
- [6] Suzuki, S., Ito, T., Moustafa, A. and Hadfi, R.: A Node Classification Approach for Dynamically Extracting the Structures of Online Discussions, *人工知能学会全国大会論文集*, Vol. JSAI2020, pp. 2G5ES302–2G5ES302 (online), DOI: 10.11517/pjsai.JSAI2020.0.2G5ES302 (2020).
- [7] Hadfi, R., Haqbeen, J., Sahab, S. and Ito, T.: Argumentative Conversational Agents for Online Discussions, *Journal of Systems Science and Systems Engineering. Special Issue on AI-enabled System Simulation and Modelling* (2020).
- [8] Hadfi, R. and Ito, T.: Exploring Interaction Hierarchies in Collaborative Editing using Integrated Information, *The 8th ACM Collective Intelligence 2020, Boston-Copenhagen* (2020).
- [9] Haqbeen, J., Ito, T., Hadfi, R., Nishida, T., Sahab, Z., Sahab, S., Roghmal, S. and Amiryar, R.: Promoting Discussion with AI-based Facilitation: Urban Dialogue with Kabul City, *The 8th ACM Collective Intelligence 2020, Boston-Copenhagen* (2020).
- [10] Haqbeen, J., Ito, T., Sahab, S., Hadfi, R., Okuhara, S., Saba, N., Hofaini, M. and Baregzai, U.: A Contribution to COVID-19 Prevention through Crowd Collaboration using Conversational AI & Social Platforms, *IJCAI 2019 Workshop on AI for Social Good* (2020).
- [11] Haqbeen, J., Ito, T., Hadfi, R., Nishida, T., Sahab, Z., Sahab, S., Roghmal, S. and Amiryar, R.: Agent that Facilitates Crowd Discussion, *Proceedings of ACM Collective Intelligence*, Vol. 2019 (2019).
- [12] Ito, T.: Towards Agent-based Large-scale Decision Support System: The Effect of Facilitator, *The 51st Hawaii International Conference on System Sciences (HICSS2018)* (2018).
- [13] Nishida, T., Ito, T. and Ito, T.: Verification of Effects Using Consensus-Building Support System in Continuous Workshops for City Development, *Journal of the Science of Design* (2018).
- [14] Kawase, S., Ito, T., Otsuka, T., Sengoku, A., Shiramatsu, S., Matsuo, T., Oishi, T., Fujita, R., Fukuta, N. and Fujita, K.: Cyber-physical hybrid environment using a largescale discussion system enhances audiences' participation and satisfaction in the panel discussion, *The IEICE Transactions on Information and Systems*, Vol. E101.D, No. 4, pp. 847–855 (2018).
- [15] Kunz, W. and Rittel, H. W.: *Issues as elements of information systems*, Vol. 131, Citeseer (1970).
- [16] Veličković, P., Cucurull, G., Casanova, A., Romero, A., Lio, P. and Bengio, Y.: Graph attention networks, *arXiv preprint arXiv:1710.10903* (2017).
- [17] Bahdanau, D., Cho, K. and Bengio, Y.: Neural machine translation by jointly learning to align and translate, *arXiv preprint arXiv:1409.0473* (2014).
- [18] Zhang, J., Shi, X., Xie, J., Ma, H., King, I. and Yeung, D.-Y.: Gaan: Gated attention networks for learning on large and spatiotemporal graphs, *arXiv preprint arXiv:1803.07294* (2018).
- [19] Stab, C. and Gurevych, I.: Parsing Argumentation Structures in Persuasive Essays, *Computational Linguistics*, Vol. 43, No. 3, pp. 619–659 (online), DOI: 10.1162/COLL.a.00295 (2017).
- [20] Kipf, T. N. and Welling, M.: Semi-Supervised Classification with Graph Convolutional Networks (2017).
- [21] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: Bert: Pre-training of deep bidirectional transformers for language understanding, *arXiv preprint arXiv:1810.04805* (2018).
- [22] Cortes, C. and Vapnik, V.: Support-vector networks, *Machine learning*, Vol. 20, No. 3, pp. 273–297 (1995).
- [23] Liaw, A., Wiener, M. et al.: Classification and regression by randomForest, *R news*, Vol. 2, No. 3, pp. 18–22 (2002).
- [24] Friedman, J. H.: Greedy function approximation: a gradient boosting machine, *Annals of statistics*, pp. 1189–1232 (2001).
- [25] Powers, D. M.: Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation, *arXiv preprint arXiv:2010.16061* (2020).