

深層学習技術による協調学習データの 自動コーディングに向けて

安藤公彦*1, 柴田千尋*1, 稲葉竹俊*1

*1 東京工科大学

Coding Collaborative Learning Data automatically with Deep Learning Methods

Ando Kimihiko*1, Chihiro Shibata*1, Taketoshi Inaba*1

*1Tokyo University of Technology

In Computer Supported Collaborative Learning research, gaining a guideline to carry out appropriate scaffolding by analyzing mechanism of successful collaborative interaction and identifying groups where collaborative process is not going well, can be considered as a central topic. And to address this topic, different approaches have been tried. In this paper, we opt for the verbal data analysis; its advantage of this method is that it enables quantitative processing while maintaining qualitative perspective, with collaborative learning data of considerable size. However, coding large scale educational data is extremely time consuming. So, in recent years, there have also been attempts to automate complex coding by using machine learning technology. In this background, with large scale data generated in our CSCL system, we have tried to implement automation of coding utilizing deep learning methods. The results indicate that our approach with deep learning methods is promising, outperforming the machine learning baselines.

キーワード: コンピュータ支援協調学習, コーディングスキーム, 深層学習, ラーニングアナリティクス

1. はじめに

1.1 ・協調プロセスの分析

コンピュータ支援協調学習（以下 CSCL）研究の目下の最大の研究課題の一つは、グループ内でのどのような知識や意味が共有され、どのような意見の対立や同調や調整があり、どのような議論によって知識構築が行われたのか、その社会的プロセスを社会構成主義的な観点から分析することである。また、その知見を活用することで、より有効な足場掛けの方法を提案したり、協調プロセスを活性化したりするような CSCL システムやツールの開発を行うことである。

CSCL の初期の研究においては、協調するグループ内の各個人に焦点をおいて、グループのどのような特

性（グループサイズ、グループ構成、学習課題、コミュニケーションメディアなど）が個人の学習成果に有意に関与するかが主要な関心となっていた。しかし、これらの特性はお互いに複雑に関係し関連し合っているのであり、ある結果に関して因果関係を示すことはきわめて困難であることが次第に明らかになった。90年代からは、CSCL 研究の関心は、グループ内の個人の学習がどのように成立するかという問題意識から離れ、ある学習がグループで生起している場合に、そのプロセスをグループの相互作用の仔細を明らかにすることで説明しようと試みるようになる⁽¹⁾。

しかし、協調プロセスの分析を試みることは、単に研究の視点のシフトにとどまらず、その分析の方法の根本的な見直しを余儀なくされることになる。つまり、

定量的な分析から定性的な分析へのシフトを伴うこととなる。もちろん CSCL システムに保存される定量的なデータにもグループ内の発言 (contributions) 数やグループメンバごとの発言数、また場合によってはシステムのインターフェース (sentence opener) から取得される発言属性等の利用可能なデータがあるが、これらはきわめて表面的なデータにすぎない。分析のための最も重要なデータはチャットの発言、スカイプ等のツール上での映像と音声、協調学習の過程で作成される様々なアウトプットなどであり、これらの分析のためには会話分析、ビデオ分析などのエスノメソロジーが援用されてきた⁽²⁾⁽³⁾。

しかし、これらの研究はその性質上、限られた数のグループの協調活動を対象とした in-depth なケーススタディとなることが多く、ある程度一般性を持ち、他のコンテキストにおいても適用可能な指針を導出することは、決して容易ではないという弱点を持っている。そのため、一定量のヴォリュームをもった協調学習で生成される言語データを言語学的視点や協調学習活動の視点からコーディングを行って、分析を行う verbal analysis の手法を用いる研究が近年行われるようになってきている⁽⁴⁾⁽⁵⁾⁽⁶⁾。この手法の長所はかなり大規模な協調学習のデータを対象に定性的な視点を維持しつつ、定量的な処理を行える点である。しかし、コーディングを人力で行う事はきわめて時間と労力を要する作業であり、さらにデータがビッグデータになった場合は、人力では不可能になることが予想される。既存研究においても、協調学習データのコーディング支援を試みたシステムは存在している。これらの研究では、コーディング入力自体は人力によって行われるものと⁽⁷⁾⁽⁸⁾、機械学習の技術を用いて行ったものがある⁽⁹⁾⁽¹⁰⁾。これに対して、本研究では深層学習技術によって、大規模な協調学習を対象にコーディングを自動化する手法を模索する。

1.2 教育データと Learning Analytics

教育機関で教育クラウドの導入が進展することで、LMS, e ラーニング, SNS, MOOC などにおいて生成されるデータが急速に増加しており、これらの教育ビッグデータを解析し学習活動や教育活動の支援につながるような知見を得ようとする Learning Analytics

といわれる新しい研究アプローチが活性化している。学内の教育クラウドに統合された CSCL システムから取得される会話データや提出物、学習活動中の画像や音声も早晩、ビッグデータとして分析対象になることは確実であり、LA としての協調学習研究という新しい可能性を真摯に検討しなければならない時期になっていると思われる。このような背景から、本研究では 5 年前から学内サーバで稼働していた CSCL システムを学内クラウド上の LMS である Moodle 内のモジュールとして再構築し、学内で運用し、協調学習データの収集、分析が可能な環境をすでに構築している。

1.3 研究目的

本研究の最終目的は、上に述べたように大規模な協調学習データを LA の視点で解析を行い、今までのミクロレベルでのケーススタディでは得られなかった協調活動プロセスの活性化や非活性化のメカニズムを明らかにすること、さらに、その成果を踏まえて、リアルタイムでの協調プロセスのモニタリングや活性化していないグループへの足場掛け等の実際の学習、教育の場での支援を実装することである。本論文はその最終目標にむかう第一ステップとして、チャットデータのコーディングの自動化の技法の開発とその精度の検証を行うことにする。具体的には、相当量のチャットデータに手動でコーディングを行い、その一部をトレーニングデータとして機械学習の最新技術である深層学習に学習をさせ、その後、テストデータに自動コーディングを実施する。精度の評価にあたっては、機械学習による自動コーディングを実践した既存研究で用いられた機械学習アルゴリズムのベースラインとなる Naïve Bayes や Support Vector Machines との精度比較を行うことで深層学習を用いたことの有効性を評価する。

2. データとコーディングスキーム

2.1 会話データ

会話データセットは著者らが独自に開発した CSCL システム⁽¹¹⁾の 25% を大学の講義内で用いて、オンラインでの協調学習を行いシステム内のチャット機能から得られた学生間の会話である。

本 CSCL は非対面で用いるものであり、本データは

すべて大学の大教室内で離れた面識のない学生同士間でグループを組んだ際のものとなる。またシステム上での学生の名前はニックネームとなっており、知人であったとしてもそれを知ることはできないようになっている。

本研究で利用する発言データ元のCSCLの利用状況を表1に示す。表1に示されているのはこの研究で利用する発言データの元となった科目のみで、実際にはさらに多くの講義で利用されている。科目数は7科目であり、どの科目でも3-4人のグループを組んでいる。時間は科目により異なり45~90分となっている。研究対象となったデータセットは合計で11504発言に及んでいる。すべての科目のグループの合計は202グループ、参加学生は426人となっているが、1人の学生が複数の科目に参加しているため、グループ数×グループ人数よりも参加学生数が少なくなっている

表1 発言データの概要

科目数	7科目
グループ	3-4人
時間	45分~90分
グループ数	202グループ
参加学生数	426人

表2に実際のチャットの会話例を示す。これは3名による会話例となる。

表2 会話例

発言者	内容
D	どの辺を変えますか？
E	そこですよ…まず問題文は絶対かえなきゃだとは思うんですけど、推論式の方はどうしますかね
D	問題文の三行目だけを変えるのはどうですか？
D	推論式でいうと最後の ω 以降です
E	それでいいと思います
F	良いと思います。どう変えます？




図1 コーディングラベルの分布

2.2 コーディングスキーマ

著者らが作成したコード付与のためのマニュアルに従い、チャットの1発言に対し1つのコードを付与する。コードは表3に示す16種類となっており、このコードのいずれかを付与する。

発言データは講義単位で分割されており、コーダー6名が分担してコーディングを行った。その際に、各講義に対し2名のコーダーを割り当て、すべての発言についてその2名が、それぞれコーディングを行った。これらのコーディングの一致または不一致の結果を著者らで精査したところ、発言内容的に重複しているコードや、コーダーによりブレのあるコードがあることが判明したため、著者らの合議によりコードの統合および一部コードの再コーディングを行った。この結果、2名のコーダー間の一致率は82.3%でKappa係数は0.800という高い一致率となり、深層学習のトレーニングデータとして十分実用に耐えうるものとなった。図1はデータセットのラベルの分布を示したものである。これを見ると、9つのラベルが全体の90パーセント以上を占めており、それ以外のラベルがロングテール

表3 ラベルの分布

タグ	タグの意味	発言例
同意 了承	肯定的な返答	いいと思います
提案 意見	意見を伝えるまたは、YES/NO 質問	この五人で提出しませんか？
質問	YES/NO 以外の質問	タイトルどうしましょかね
報告	自身の状況を報告する	複雑の方はなおしました
挨拶	他メンバーへの挨拶	よろしく申し上げます
メタ	課題内容以外の発言 システムに対する意見 など	はやくも自分の発言が消えるバグが
確認	課題内容や作業の進め方について確認	じゃあ提出していいですか？
感謝	他メンバーへの感謝	ありがとう！

タグ	タグの意味	発言例
転換	次の課題へ進めるなど、扱う事象を変える発言	とりあえずやりますか
ジョーク	他メンバーへのジョーク	そんなの体で覚える的な？(´・ω・`)
依頼	誰かに作業を依頼する	どちらかが回答お願いします
訂正	過去の発言を訂正する	すみません児童の間違いです
不同意,拒否	否定的な返答	30分は長すぎる気がします
愚痴	課題やシステムにたいする不満など	テーマがいまいちだよね；
ノイズ	意味をなさない発言	?会?日???

ルを形成していることがわかる。

3. 深層学習を用いた自動コーディング手法

前節で述べたようなコーディングを自動的に行うために、本研究では、深層学習と呼ばれる技術を用いる。深層学習とは、近年劇的に発展した機械学習の一手法であり、数十から数百に及ぶ深いレイヤーと、しばしば数百万以上となる重みパラメータからなる巨大なニューラルネットワークを、規模の大きなデータから学習させるものである。主に、近年のデータ量の巨大化、および GPGPU に代表される並列計算技術の進展により、そのような大規模なニューラルネットワークを現実的に訓練させることが可能になり、画像認識など限定的なタスクにおいてはしばしば人間の認識率を上回ることが知られている。

本節では、よく知られているネットワーク構造を持つ深層学習の手法をいくつか適用し、自動コーディングの正解率、F 値、および κ 係数を比較する。具体的には、(1)畳み込みニューラルネットワーク(CNN)による分類モデル、(2)長短期記憶(LSTM)による分類モデル、(3)Sequence to Sequence (Seq2Seq) と呼ばれる手法に基づく分類モデル、の3つを比較する。また、古典的な機械学習の手法である SVM をベースラインとして使い、各種の深層学習の手法の適用により、個々のコーディングラベルについて、どの程度改善されるかについて述べる。

3.1 各手法における共通点

比較を行った深層学習を用いた3つの手法の詳細を述べる前に、各手法に共通する部分について記述する。一般的に、本研究における自動コーディングの学習は、チャットログデータの各発言を入力として、人手で付与されたコーディングラベルを出力するような、分類問題となる。そのため、各発言は単語の列として扱われ、ニューラルネットへと入力される。また、最終的に出力としては、各コーディングラベルの各々について、ニューラルネットが予測する確率値が出力される。

各単語は 50-100 次元程度のベクトル空間へ写像されて、ベクトルで表現される。この写像は、一般に

単語の「埋め込み」と呼ばれ、埋め込まれた単語を表すベクトルは単語ベクトルと呼ばれる。まず、発言は単語ごとに区切られる。その後、得られた単語の列 w_1, \dots, w_T を、 m 次元の単語ベクトルの列 $v(w_1), \dots, v(w_T)$ へ変換した後、ニューラルネットへと入力する。したがって、ニューラルネットに対する入力は、単語ベクトルを並べたものになるため、 $T \times m$ の行列と考えられる。

3.1.1 CNN による分類モデル

畳み込みニューラルネットワーク(CNN)はもともと画像認識のために用いられたニューラルネットワークの構造であるが⁽¹²⁾、Kim ら⁽¹³⁾によって、極性判定などのテキスト分類の問題に適用しても、高い分類精度を得ることができることが知られている。Kim らの手法に基づいたコーディングの判別のための手法を図 2 に示す。まず、事前に word2vec⁽¹⁴⁾ という手法により、Wikipedia などの大規模データから、そのなかに出現した各単語に対して、50-100 次元程度のベクトル表現を学習させる。その結果、意味の近い単語はベクトル空間内でも近いところへ写るように写像されるようになり、それらは単語ベクトルとよばれる。本研究では、単語ベクトルを、日本語 Wikipedia 全文から作成する場合と、本研究に用いたチャットログデータから作成する場合の、両方のケースにおいて適用し、比較した。得られた単語ベクトルは、Kim らの手法に従い、畳み込み層により、 $T \times ch$ の行列に写像された後(ch は CNN におけるチャンネル数とよばれる定数)、max pooling により ch 次元のベクトルに写像される。さらに、そのベクトルを全結合層に入力し、Softmax 層を経て、各ラベルに対する予測確率値を最終的に出力する。




図 2 CNN による分類モデル

3.1.2 LSTM による分類モデル

長短期記憶(LSTM)⁽¹⁵⁾とは、リカレントニューラルネットワークの一種であり、主に音声や単語列などの時系列データを分類・認識する際に用いられるニューラルネットワークの構造である。時系列中に存在する長距離の依存関係を捉えることができることが知られている。本研究では、まず、 $v(w_1), \dots, v(w_T)$ を順次、LSTM に入力してゆき、最終的に $v(w_T)$ を入力した後に得られる LSTM からの出力のベクトル o をえる。さらに o を、全結合層に入力し、Softmax 層を経て、各ラベルに対する予測確率値として出力する。なお、実際には、精度向上のために、2層に重ねた LSTM を 2 セット用意し、単語列を正順と逆順の両方向で入力していき、それら 2 セットの出力のベクトルを連結したものを、全結合層の入力とした(図 2)。

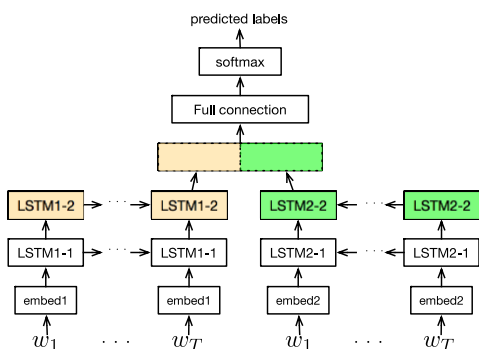


図 3 LSTM による分類モデル

3.1.3 Seq2Seq による分類モデル

各発言は会話文の一部であるから、コーディングラベルをより正確に予測するためには、会話文の文脈を考慮する必要性がしばしばある。例えば、あるユーザーによる発言 A「大化の改新って、いつ誰が起こしたか知っています？」を参照して、別のユーザーによる発言 B「大化の改新は 645 年に中大兄皇子や中臣鎌足が中心となって起こしたらしい。」が存在した場合、A と B に対する正しいコーディングラベルはそれぞれ、「質問」と「回答」である。しかし、もし発言 A とは全く関係のない文脈で発言 B があった場合、B の正しいコーディングラベルは「事実の提示」となる。このような発言間の関連性を捉えるため、本研究では、Seq2Seq とよばれるモデル⁽¹⁶⁾⁽¹⁷⁾を適用する。まず、「ソース」と「リプライ」と以降で呼ぶ、発言のペアを次のように

して作成する。(1) 発言 A が他の発言 B をシステムの機能を用いて明示的に参照している場合、B をソース、A をリプライとする。(2) 発言 A が明示的に参照している発言が存在しない場合、A の直前の発言をソース、A をリプライとする。(3) 発言 A がスレッドの最初の発言の場合、空文をソース、A をリプライとする。

作成したソース・リプライのペアに対して、一つのコーディングラベルを出力するようなニューラルネットワークを構成し学習させる。ソースの単語列を u_1, \dots, u_T 、リプライの単語列を w_1, \dots, w_T とする。本研究では Seq2seq モデルを利用するが、このモデルは、encoder および decoder と呼ばれる 2 つの異なる LSTM を持ち、encoder の状態ベクトルを decoder の状態ベクトルへ代入することにより両者を接続する。本研究では、encoder にソースの単語ベクトルの列を入力した後、decoder にリプライの単語ベクトルの列を入力する。その後、最終的な decoder の出力ベクトルを、他の手法と同様、全結合層に入力し、Softmax 層を経て、各ラベルに対する予測確率値として出力する。この手法の場合も、実際には、精度向上のために、2層に重ねた encoder と decoder のペアを 2 セット(すなわち全部で 8 個の LSTM)用意し、正順および逆順でソース及びリプライを入力して、それらの出力を連結する(Fig. 4)。




図 4 Seq2Seq による分類モデル

4. 実験と評価

4.1 実験の概要

前述のような、収集した発言および人手によるコーディングラベルをデータとして学習を行い、各モデルにおいて、どの程度コーディングが正しく予測できたかを、比較・検証する。

まず、データの前処理としては、文の形態素への分

割を MeCab を用いておこなった。また、頻度の低い単語を「unknown」と置き換えた。人手によるコーディングによって一致をした、全部で 8,015 の発言のうち、90% を訓練データ、10% をテストデータとした。

ベースラインの手法としては、ナイーブベイズ、線形 SVM、RBF カーネルを用いた SVM を適用した。また、それらの手法に使用する特徴量として、ユニグラム の出現の有無、およびバイグラムの出現有無を {0,1} で表した、2 値ベクトルを用いた。また、SVM における分類精度をあげるために、2 値ベクトルを、総和が 1 になるように正規化したのち、上記分類器に入力した。

本研究で実装した各ニューラルネットの構造を決めるためのパラメータは、次のようにとった。すべてのモデルについて、単語ベクトルの次元数を 200、最後の全結合層の出力ベクトルの次元数を 200 とした。CNN に基づいたモデルにおいては、畳み込み層のパッチサイズを 4、チャンネル数を 256 とした。LSTM および Seq2Seq を用いたモデルにおいては、全ての LSTM の出力ベクトルの次元数を 800 とした。

モデルの学習は、確率的勾配降下法 (SDG) の一種である Adam を用いた。また、すべての方法において、全結合層において、ドロップアウトを適用した。過適合をさけるため、CNN に基づいたモデルにおいては 30 世代、LSTM および Seq2Seq を用いたモデルにおいては 10 世代で、学習を終了させた。テストデータに対する正解率や F 値は、世代ごとに変動するが、その影響さけるため、最後の 5 世代によるニューラルネットの予測結果を平均した値を実験の結果として用いた。

4.2 実験結果

表 4 に前節で提案した DNN モデルと、ベースラインとなるモデルのテストデータに対する予測精度 (正解率) を示す。正解率とは、モデルが出力した予測ラベルと、人手により付与された正解ラベルとが一致する割合である。表 4 が示すように、全体として、DNN モデルの結果はベースラインモデルの結果よりも精度が高くなっていることがわかる。前述の 3 つの DNN モデルのうち、CNN を用いた手法と LSTM を用いた手法の間には、正解率にほとんど差異がないことがわ

かる(0.67-0.68)。これらの手法は、ベースラインである SVM(0.64-0.66)に比べて僅か (2-3%程度) だが正解率が高くなっている。

一方、全てのモデルの中で、Seq2Seq を用いたモデルが最も正解率が高くなっている(0.71)。SVM と比べて 5-7%、他の DNN モデルと比べても 3-4%高くなっている。

表 4 提案 DNN モデルおよびベースラインによるテストデータに対する予測精度(正解率)

Naïve Bayes		SVM(Linear)		SVM(RBF Kernel)	
unigram	uni+bigram	unigram	uni+bigram	unigram	uni+bigram
0.554	0.598	0.642	0.659	0.664	0.659
CNN		LSTM		Seq2Seq	
with wikipedia	w.o. wikipedia	single-direction	bidirection	bidirection	bidir. w. intern.
0.686	0.677	0.676	0.678	0.718	0.717

次に、ラベルの一致率の指標として一般的に用いられるカッパ係数で上記の結果を考察する。まず、LSTM を用いたモデルに対するカッパ係数は 0.63 となり、この場合でも、一致度としては十分高い(Good to fair) 結果を得ているといえる。しかし、一般的に、機械による自動コーディングの判別結果を信用に足りる形で利用するためには、カッパ係数で 0.8 以上 (Excellent) が好ましいとされており、より高い一致度が求められる。一方、Seq2Seq を用いたモデルに対するカッパ係数は 0.723 であり、0.8 には至らないものの、一致度の観点から見ても、大きく改善されていることがわかる。各発言をばらばらに捉えるのではなく、文脈の情報を何らかの形で考慮することの重要性がわかる。最後に、どのような場合に誤分類が起きるかを、各コーディングラベルに分析する。LSTM を用いたモデルに対する、各ラベルの適合率(precision)と再現率(recall) および F 値を 表 5 に示す。「挨拶(Greeting)」、「了承(Agreement)」および「質問(Question)」に対する F 値が最も高いことがわかる(それぞれ 0.94, 0.83, 0.77)。これらの結果は、発言の外形から文意を深く捉えなくても容易に判断できるケースが多いため、人間の感覚にも一致しているといえる。それに対して、「外部コメント(Outside comments)」が最も F 値が低い(0.25)。これは、意見交換すべき内容とは全く関係のない、冗談などを意図した発言が該当するが、それを判断するためには文意を深く捉える必要があるためとかがえられる。また、「返答(Reply)」でも F 値が低

い (0.53). Seq2Seq を用いたモデルにおいても、「返答(Reply)」でも F 値は若干改善するものの、依然として低いことがわかっており、混同行列(図 5) を見ても、「同意(Agreement)」や「提案(Proposal)」、「報告(Report)」などへ誤分類されていることがわかる。「応答」は「質問」に対応するものであることがほとんどであること、および「質問」の F 値は高いことから、今回用いた手法では、「ソース」と「リプライ」の発言ペアの抽出が、不十分となっていると結論できる。より適切な発言のペアを抽出する手法が今後の研究では求められる。

表 5 Precision and Recall for each label (result of bi-directional LSTM)

	Precision	Recall	F1-value
Agreement	0.85	0.81	0.83
Proposal	0.73	0.74	0.73
Question	0.75	0.8	0.77
Report	0.64	0.62	0.63
Greeting	0.94	0.94	0.94
Reply	0.62	0.46	0.53
Outside comments	0.17	0.47	0.25
Confirmation	0.58	0.74	0.65
Gratitude	0.67	0.67	0.67




図 4 Confusion matrix for the Seq2S2q model.

するための第一歩として、この論文では、深層学習技術を活用することで、きわめて煩雑で非常に時間を要するコーディング作業の自動化を行った。その結果、本研究で提案した Seq2Seq モデルは、他の方法を上回る結果となった。つまり、SVM の最高の結果より 5~6%、DNN モデルより 3~4% 良好な結果となり、今後有望な展望を得ることができたといえるだろう。また、今回のスキームが、単なる表層的な情報ではなく、各発言の文脈上の意味に依拠した 16 のラベルからなるものであり、十分に複雑性を有していたことを考慮すると、今回とは異なるスキームにおいても、このモデルを用いる事で、今回と同様の予測の精度を得ることができると思われる。

今後の研究の方向性として、2つのアプローチを追求していく。一つはコーディングスキームに関する新たな探求である。今回用いたスキームはスピーチアクトに基づく、十分に複雑性を有するものではあったが、協調プロセス全体をとらえるような包括的なものではなかった。より正確にプロセスを分析するためには、学習の相互作用や社会的認知プロセスの詳細を記述できるようなスキームを構築する必要がある。

新しいコーディングスキームとして、Weinberger らが示した多次元のコードを用いるフレームワークを参考にし(18)、本システムに適応させたスキームを考案中である。それを表 6 に示す。これら 5つの次元に下、複数のラベルが設定されることになる。今後は、この新スキームに従い人力によるコーディングを行い、最終的には DNN により高精度な自動コーディングを可能とすることを目指す。

表 6 新コーディングスキーム

次元	内容
Participation	議論への参加度合い
Epistemic	課題解決への直接的な関わり方
Argumentation	議論における主張のあり方
Social	他者の発言との関わり方
Coordination	議論を円滑に進めるための調整の仕方

5. 結論と展望

大規模な教育データから協調学習のプロセスを分析

二つ目のアプローチは DNN モデルに関するものである。さらに予測の精度を向上させるためには、DNN

モデルにアテンションモデルを導入する必要があると思われる。また、会話の文脈をさらに考慮の対象とすべきであろう。文脈をさらに正確にとられるためには、複数の先行する発言を入力ベクトルとする、より複雑なモデルを構築する必要があると思われる

謝辞

本研究は科研費（26350298 及び 16K01134）の助成を受けたものである。

参 考 文 献

- (1) Stahl, G., Koschmann, T. and Suthers D.: “Computer-supported collaborative learning”, In The Cambridge handbook of the learning science, K. Sawyer, Eds. Cambridge university press, pp.479-500 (2014)
- (2) Koschmann T.: “Understanding in action”, Journal of Pragmatics, 43, pp.435-437 (2011)
- (3) Koschmann T., Stahl G., and Zemel A.: “The video analyst’s manifesto (or The implications of Garfinkel’s policies for the development of a program of video analysis research within the learning science)”, In Video reseach in the learning sciences, Goldman, R. , Pea,R., Barron B. and Derry S. Eds. Routledge, pp.133-144 (2007)
- (4) Chi M.: “Quantifying qualitative analyses of verbal data: A practical guide ”, Journal of the Learning Science, 6(3), pp.271-315 (1997)
- (5) Meier A., Spada H., and Rummel N.: “A rating scheme for assessing the quality of computer-supported collaboration processes”, International Journal of Computer Supported Collaborative Learning, 2, pp.63-86 (2007)
- (6) Jeong H.: “Verbal data analysis for understanding interactions”, In The International Handbook of Collaborative Learning, C. Hmelo-Silver, A. M. O’Donnell, C. Chan and C. Chin, Eds. Routledge, pp.168-183 (2013)
- (7) Persico D., Pozzi, F. and Sarti L.: “Monitoring collaborative activities in computer supported learning”, Distance Education, 31(1), pp.5-22 (2010)
- (8) Lipponen L., Rahikainen M., Lamillo J., and Hakkarainen K.: “Patterns of participation and discourse in elementary students ’ computer-supported collaborative learning”, Learning and Instruction, 13, pp.487-509 (2003)
- (9) Rosé,C. et al.: “Towards an interactive assessment framework for engineering design project based learning”, In Proceedings of DETC2007 (2007)
- (10) Rosé, C. et al.: “Analyzing collaborative learning processes automatically: Exploiting the advances of computational linguistics in computer-supported collaborative learning”, International Journal of Computer Supported Collaborative Learning, 3(3), pp.237-271 (2008)
- (11) Inaba T. and Ando K.: “Development and Evaluation of CSCL System for Large Classrooms Using Question-Posing Script”, International Journal on Advances in Software, 7(3&4), pp.590-600 (2014)
- (12) LeCun,Y. Bengio, Y. and Hinton G.: “Deep learning”, Nature, 521(7553), pp.436—444 (2015)
- (13) Kim, Y.: “Convolutional neural networks for sentence classification”, arXiv preprint arXiv:1408.5882 (2014)
- (14) Zhang,X., Zhao J. and Y.LeCun: “Character-level convolutional networks for text classification”, In Proceedings of the 28th International Conference on Neural Information Processing Systems (NIPS2015), pp.649-657 (2015)
- (15) Hochreiter S. and Schmidhuber J.: “Long short-term memory”, Neural Computation, 9(8), pp.1735-1780 (1997)
- (16) Bahdanau, D., Cho, K. and Bengio, Y.: “Neural machine translation by jointly learning to align and translate”, arXiv preprint arXiv, pp.1409.0473 (2014)
- (17) Vinyals O. and Le, Q. V.: “ A Neural Conversational Mode”, arXiv preprint arXiv:1506.05869, (ICML Deep Learning Workshop 2015) (2015)
- (18) Weinberger, A. and Fischer, F.: “A frame work to analyze argumentative knowledge construction in computer-supported learning”, Computer & Education, 46(1), pp.71-95 (2006)