

# 適応的エンゲージメント促進支援ロボットの開発と評価

Yao Bowei <sup>\*1</sup>, 太田 光一 <sup>\*1</sup>, 柏原 昭博 <sup>\*2</sup>, 卯木 輝彦 <sup>\*3</sup>, 長谷川 忍 <sup>\*1</sup>

<sup>\*1</sup> 北陸先端科学技術大学院大学

<sup>\*2</sup> 電気通信大学

<sup>\*3</sup> 関西外国語大学

## Development and Evaluation of an Adaptive Engagement Support Robot

Bowei Yao <sup>\*1</sup>, Koichi Ota <sup>\*1</sup>, Akihiro Kashihara <sup>\*2</sup>, Teruhiko Unoki <sup>\*3</sup>, Shinobu Hasegawa <sup>\*1</sup>

<sup>\*1</sup> Japan Advanced Institute of Science and Technology

<sup>\*2</sup> The University of Electro-Communications

<sup>\*3</sup> Kansai Gaidai University

The purpose of this research is to develop a learning partner robot that can adapt its interaction to each learner's individual reactions to enhance learner engagement. To realize the partner robot, we implemented the engagement estimation architecture, designed a robot interaction model to update the robot's strategy according to the learner's response to the interactions. We conducted a comparative experiment with 20 graduate student participants with and without robots. The results indicated that the accuracy of engagement estimation by face images was 53.8%, the average engagement during learning was significantly higher in the with-robot condition, and the satisfaction with the robot interaction was highest in the last 1/3 of the learning period.

キーワード: エンゲージメント, 個別適応, 顔画像, Learning Companion, パートナーロボット

### 1. はじめに

新型コロナウイルスの感染拡大を契機として, 高等教育機関においてもオンライン教育/学習が注目を浴びている. オンライン教育/学習を成功させるためには, 学習者自身が認知活動を制御しながら学習目標を達成する自己調整学習<sup>(1)</sup>と, 学習にポジティブな影響を与える心的状態であるエンゲージメント<sup>(2)</sup>が重要な役割を果たす<sup>(3)</sup>. 特に, エンゲージメントは, 学習過程に没入・熱中することを通じて学習者の主体性を支える重要な要素であり, 学習者のエンゲージメントを維持・促進することは重要な課題の一つである<sup>(4)</sup>. しかしながら, オンライン教育では学習者が孤立しやすく, 学習意欲の低下や離脱につながりやすい傾向も指摘されている<sup>(5)(6)</sup>.

本研究では, これらの問題を解決するために, 学習者のエンゲージメントを維持・促進する学習パートナ

ーロボットを開発することを目指している<sup>(7)</sup>. 近年, 教育環境におけるソーシャルロボットの普及が進んでおり, 新たな学習者支援の手法として注目されている<sup>(8)</sup>. 一方で, こうしたロボットが学習者の能力や進捗を適切に推定することや, 言語的行動と非言語的行動のタイミングを調整して適切なインタラクションを選択することなど, いくつかの課題も指摘されている<sup>(9)</sup>. つまり, 学習者の個別性が強い自己調整学習過程においては, 学習者のエンゲージメントを把握・予測し, その状況に応じた支援を行う方法論およびシステムはいまだ確立されていないと言える.

本稿では, 学習者の学習活動に対する意欲や取り組み方, 理解度などを包括した概念である「エンゲージメント」を学習者の顔画像から推定し, ヒト型ロボットの振る舞いを通して学習者のエンゲージメントを促進するためのパートナーロボットの開発と初期の評価について述べる. 開発したロボットの特徴は, 特定領

域の学習を支援するのではなく、学習者のエンゲージメント状況をロボットがフィードバックすることで、自己調整学習におけるエンゲージメントの自己モニタリングを支援することである。また、学習時のエンゲージメントは、ロボットの振る舞いに対する個々の学習者の印象により変化することから、学習者のインタラクションに対する反応に適応した「学び相手：Learning Companion」の開発を目指す。

## 2. 関連研究

### 2.1 Educational Robots

Rosanda らは、教室におけるロボットの使用状況に関する調査を通じて、Educational Robots は学習者とコミュニケーションを取り、学習者との社会的相互作用を通じて学習体験を提供できると述べている<sup>(10)</sup>。彼らのまとめによると、こうしたロボットは、学習者と同じ空間に物理的に存在し親近感を与えることから、学習にポジティブな影響がある一方で、従来研究の多くは教材配信を目的としており、フィードバックや個々の学習者のニーズに合わせた学習支援などといった個別指導を目的とした研究は現時点では限られている。

Belpaeme らは関連研究のレビューを通じて、学習者との社会的相互作用を通じて学習体験を提供するソーシャルロボットが、学習者の認知的・感情的な状態を向上させる観点から、制限されたタスクではあるものの、人間のチューターと同様の成果を達成していると述べている<sup>(9)</sup>。彼らは、先行研究における Educational Robots の役割について、教師としてのロボット、ピアとしてのロボット、初心者向けのロボットに分けて論じている。本研究に関連するピアとしてのロボットについては、ロボットはより知識の豊富なピアとして提示されることが多く、学習者を簡単すぎず難しすぎない学習過程に導く役割を持っているといえる。

### 2.2 Learning Partner Robots

Lu らは、自然言語処理と感情認識を用いて、学習者に楽しい学習体験を提供する Smart Learning Partner を提案した<sup>(11)</sup>。彼らは自己決定理論を指針として、タスクを実行する際の自発性を意味する「自律性」、課題や有効性を感じる「有能性」、他者とのつながりを感じる「関連性」の観点から、Human-Robot Interaction (HRI)

を設計したが、その有効性についてはまだ十分に議論されていない。

また、Lubold らは、音響-プロソディック同調に基づく音声適応を用いた、学習コンパニオンロボットのための社会的応答型音声インタフェースを開発し、従来の社会的対話よりも提案手法の社会的存在感が有意に高いことを示した<sup>(12)</sup>。

これらの研究は、本研究のターゲットである学習者のエンゲージメント促進と密接に関連しているが、本研究は、エンゲージメントの推定とインタラクション生成を統合することで、効果的にエンゲージメントを促進する点でユニークである。

### 2.3 インタラクションロボット：Sota

本研究では、ヴイストン株式会社のインタラクションロボット Sota をベースに開発した<sup>(13)</sup>。Sota は、カメラ、マイク、スピーカ、ネットワーク機能を備え、言葉や身振り、手振りによる自然なインタラクションを実現する卓上型コミュニケーションロボットである。Sota は、Intel(R) Edison with Linux を内蔵しており、Java を利用して画像認識や音声認識、音声合成を用いたアプリケーションを簡単に開発することができる。

## 3. 提案手法

### 3.1 エンゲージメント推定

本研究ではまず、学習者の学習意欲を推定するためのモデルとして、Huynh ら<sup>(14)</sup>のモデルを選択した。彼らの研究は、Emotion Recognition in the Wild Challenge 2019 のサブチャレンジである“Wild”環境におけるエンゲージメント予測手法として提案されたものである。彼らはエンゲージメント推定における顔と視線に関連する特徴の効果を実証し、当該コンペで最高の性能を得ている。

#### 3.1.1 特徴抽出

本研究では、学習中の学習者の顔動画から以下の特徴量を抽出する。

- F1 特徴量：表情解析のためのオープンソースツールキットである OpenFace<sup>(15)</sup>によって抽出された一定間隔の動画セグメントにおける視線方向、目の座標、カメラまでの距離、頭部の姿勢に対する平均値、標準偏差、最大値、最小値で構成された 60

次元データ. F2 特徴量 : OpenFace によって抽出された顔領域に対して, MS-Celeb-1M<sup>(16)</sup> と VGGFace2<sup>(17)</sup> で事前学習した, Squeeze-and-Excitation (SE) ブロックを持つ SE-ResNet-50<sup>(18)</sup> によって抽出された 128 次元データ.

### 3.1.2 エンゲージメント回帰モデル

学習者のエンゲージメントは時間と共に変化するため, LSTM (long-short memory) 層と FC (fully connected right-front LSTM) 層を組み合わせた LSTM-FC と FCLSTM-FC (fully connected right-front LSTM) によりそれぞれの特徴セットを学習させる. アンサンブル層でこれらの結果を受け取り, 各セグメントにおいて平均化された学習者エンゲージメントを出力する.

エンゲージメントレベルは Huynh モデルに従い, Disengaged, Barely Engaged, Engaged, Highly Engaged の 4 段階で以下の通り設定した.

- 0: Disengaged :  $0 \leq \text{出力結果} < 0.4$
- 1: Barely Engaged :  $0.4 \leq \text{出力結果} < 0.6$
- 2: Engaged :  $0.6 \leq \text{出力結果} < 0.83$
- 3: Highly-Engaged :  $0.83 \leq \text{出力結果} \leq 1.00$

## 3.2 インタラクシオンネットワーク

### 3.2.1 構成要素

ロボットインタラクシオンの構成要素は, 言語的または非言語的な Sota の動作に依存する. 一般に, 言語表現は語りかける内容そのものを指し<sup>(19)</sup>, 非言語表現は語る速度, イントネーション, ロボットの姿勢やジェスチャ, 顔の表情などを含む<sup>(20)</sup>.

言語表現については, 人間の講師が学習者に用いるいくつかのフィードバック手法を参考にした. 学習者に対する「支援」「心配り」「賞賛」の言葉は, 学習者のパフォーマンスや行動にポジティブな影響を与えることが知られている<sup>(21)(22)(23)</sup>. また, Cutumisu らは, 講師の「批評」が学習者の記憶に効果的であることを示している<sup>(24)</sup>. これらを踏まえ, 表 1 に示す 4 種類の発話タイプごとに 3 つの Sota による発話内容をあらかじめ設定した.

非言語表現としては, Sota の発話意図を強調するためにジェスチャを用いることとし, Sota の自動モーション生成機能である MotionAsSotaWish クラスであらかじめ定義された「Call」「Presen」「Talk」「Bye」の 4

種類のモーションを採用した. 各モーションタイプには数秒のモーションが複数定義されており, Sota は発話と同時に動作する. また, もう一つの非言語要素として発話速度を採用し, Slow, Medium, Fast の 3 種類から選択して発話するようにした.

表 1 Sota の発話内容

タイプ	発話内容
支援	応援しているよ 負けないで いつも力になるよ
心配り	無理しないで 休憩しませんか 大変ですね
賞賛	よくできました 流石ですね このまま行きましょう
批評	このままではダメですよ いつから頑張るのですか? このまま終わっていいの?

### 3.2.2 インタラクシオンネットワークモデル

それぞれの学習者のインタラクシオンの好悪を反映した支援を行うために, 以下のようなインタラクシオンネットワークモデルを提案する. 図 1 は, 3.1 節のエンゲージメント推定結果を入力とし, インタラクシオン構成要素 (発話タイプ, ジェスチャ, 発話速度) の 4 層からなる完全連結ネットワークの初期状態である. 講師の動作や表情が学習者の感情に与える影響に関する先行研究<sup>(25)</sup>に基づき, 各パス間の初期重みを表 2 のように設定した. なお, 各ノードから次の層へのパスの重みの和は 1 である. この重みは, インタラクシオン選択を確率的に決定するために利用される. これにより, 同じ状況であっても異なるインタラクシオンを生成することが可能となる. なお, 学習者の関与が「Highly-Engaged」である場合は, Sota は学習者とインタラクシオンを行わないこととする.

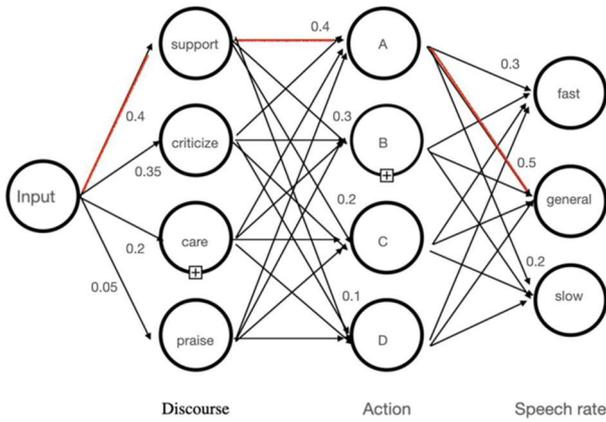


図1 インタクションネットワークモデル

表2 エンゲージメントと発話タイプの初期重み

	Disengaged	Barely Engaged	Engaged
支援	0.4	0.45	0.2
気配り	0.2	0.15	0.1
賞賛	0.05	0.1	0.7
批評	0.35	0.3	0

提案手法は、エンゲージメント推定モデルを用いて、Sota とのインタクションの前後における学習者のエンゲージメントの変化を比較する。これにより、それぞれのインタクションが対象の学習者にとって適切であったかどうかを判定し、インタクションネットワークを更新する。学習者のエンゲージメントが変化しないか減少した場合、インタクションが行われた全てのパスの重みを減らし、それ以外のパスの重みを増やして重みの和が1になるようにすることで、同様の状況が発生したときに Sota が別のインタクション戦略を実行しやすくする。図2 は具体的な変更ルールの一例である。つまり、インタクションネットワークは学習者の嗜好に合わせたインタクション体験を実現するために、最適な重みに向けて更新を続けることになる。重みの調整途中では一部好まれないインタクションが発生する可能性があるが、更新が進むにつれて改善が期待できる。

### 3.3 実装

図3 に開発したシステムの全体アーキテクチャを示す。エンゲージメント推定モジュールとインタクションネットワークモジュールは、Intel i7-9900k, 32G RAM, Nvidia GeForce RTX 2080 (6GB), ubuntu 20.04 OS,

python 3.8, TensorFlow 2.0 の PC 上に実装した。

まず、USB カメラから学習者の顔画像を入力とし、3.1 節で説明した事前学習済みのモデルを用いて 1 分間隔でエンゲージメントの強さを推定する。次に、インタクションネットワークは推定されたエンゲージメントを入力として Sota のインタクションを選択する。Sota はインタクションネットワークの出力を 1 分間隔で JSON 形式により PC から取得し、選択されたインタクションを実行する。最後に、システムは 3.2 節で説明したインタクション後の学習者のエンゲージメントの推定結果に従って、インタクションネットワークを更新する。



図2 重み更新の例

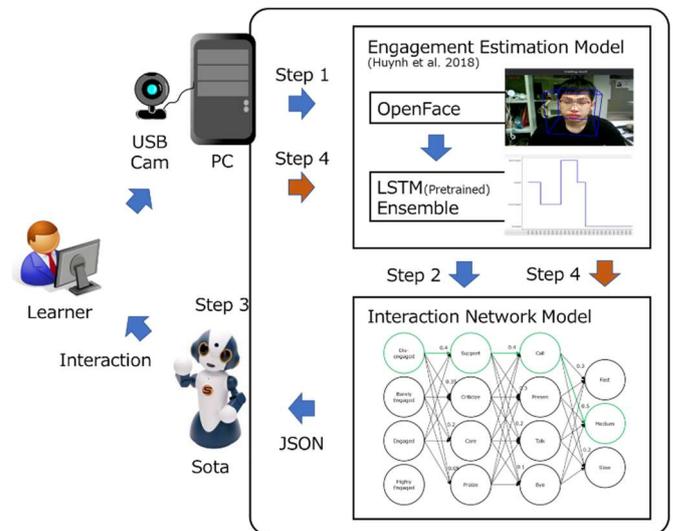


図3 システムアーキテクチャ

## 4. 評価実験

提案手法の妥当性を評価するために、20名の大学院生を対象とした被験者内計画の評価実験を行った。特に、エンゲージメントの推定精度、Sota のインタクションが学習者のエンゲージメントに与える影響、インタクションネットワーク更新アルゴリズムの効果を評価した。

本実験では、被験者は30分間の学習ビデオ(学部レベルの物理と高校レベルの化学)を、Sotaあり・なしの条件で学習した。実験の順序は、学習ビデオとSotaの有無に関して、カウンターバランスを考慮した。各ビデオの学習後、被験者は学習中の自身のビデオを見ながら、5分間毎のエンゲージメントの状態を4段階で自己評価(0: Disengaged, 1: Barely Engaged, 2: Engaged, 3: Highly Engaged)した。また、Sotaあり条件ではSotaのそれぞれのインタラクションのタイミングと内容の満足度を5段階評価(1: とても悪い, 2: 悪い, 3: どちらでもない, 4: 良い, 5: とても良い)した。

#### 4.1 エンゲージメント推定の精度

0分, 5分, 10分, 15分, 20分, 25分, 30分における被験者のエンゲージメントの自己評価と同時間におけるシステムのエンゲージメント推定結果の混同行列を表3に示す。全体の一致率は53.6%(=150/280)であり、Sotaありの場合は55.0%, Sotaなしの場合は52.1%と、Sotaのありなしで大きな差は見られなかった。また、誤差のうち86%は自己評価と推定結果の差分が1であり、推定モデルが学習者の自己評価とある程度一致していたことがわかる。

表3 自己評価と推定結果の混同行列

		自己評価			
		0	1	2	3
推定結果	0	14	7	2	1
	1	5	17	14	2
	2	8	27	73	38
	3	4	1	21	46

ただし、今回の推定モデルは学習者のエンゲージメントをやや楽観的に推定する傾向があったことに注意が必要である。エンゲージメント推定の事前学習に用いるデータセットは、エンゲージメントが低いデータが少なく、バランスが悪いことが多い<sup>(26)</sup>。これが、楽観的な推定結果の理由の一つであると考えられる。なお、このエンゲージメントの推定は、Sotaのインタラクションのタイミングや内容に影響された可能性も考えられる。

#### 4.2 Sota インタラクションの影響

Sotaありの学習者の自己評価による平均エンゲージメントは2.07 (S.D. = 0.47), Sotaなしの自己評価の平均エンゲージメントは1.71 (S.D. = 0.47)であった。t検定の結果は $t(19)=2.48, p=.022$ であり、Sotaありの条件で平均エンゲージメントが有意に高いことを示している。実験時間が短いためこの結果は十分であるとは言えないが、Sotaによるインタラクションがエンゲージメントの向上に一定の効果がある可能性が示唆された。

表4は、Sotaあり条件におけるSotaによる各インタラクションのタイミングと内容に対する満足度のアンケート結果である。インタラクションのタイミングに対する平均満足度は3.43 (S.D.=0.608), インタラクションの内容に対する平均満足度は3.24 (S.D.=0.728)であり、約半数のインタラクションが肯定的に受け入れられていることが分かる。ただし、推定自体やモデル更新のタイムラグ(1分間隔)が、満足度の低さやエンゲージメント推定モデルの精度の限界の原因になっている可能性は否定できない。

表4 インタラクションのタイミングと内容の満足度

	1	2	3	4	5
タイミング	0	22	79	79	13
内容	0	39	72	72	8

(1: とても悪い, 5: とても良い, 数字は回数)

#### 4.3 更新アルゴリズムの効果

表5は、インタラクションの内容に対する満足度を時間順で1/3に分割した場合の各被験者のアンケート結果の平均値を比較したものである。まず、Jarque-Bera検定により、データが正規分布であることを確認した。次に、3つのグループを比較するために、データを対応のないANOVAで検定したところ、 $F=18.9 (p<.00001)$ であった。各群の比較にはTukey's HSDを使用した。その結果、最初の1/3と中間の1/3の間で $Q=3.34 (p=.0498)$ , 最初の1/3と最後の1/3の間で $Q=5.22 (p=.0085)$ , 中間1/3と最後の1/3の間で $Q=8.56 (p=.0000)$ がそれぞれ示された。これらの結果から、被験者のインタラクションに対する満足度は、実験の中盤1/3では低下したが、最後の1/3の実験で重みを調整するにつれて向上したといえる。

表 6 にエンゲージメントの出力に対する発話タイプの重みの変化の絶対値をまとめたものを示す。この結果から、特定の組み合わせで重みに大きなばらつきがあることがわかる。これらの結果は、個人差の傾向を示すものであり、提案アルゴリズムの有効性と実用性を示唆するものであるといえる。

表 5 時間経過によるインタラクション満足度の変化

	件数	平均満足度	標準偏差
最初の 1/3	63	3.17	0.81
中間の 1/3	61	2.84	0.88
最後の 1/3	63	3.70	0.71

表 6 エンゲージメントと発話タイプの重みの変化

	初期値	差の絶対値
Disengaged-支援	0.4	0.03
Disengaged-気配り	0.2	0.12
Disengaged-賞賛	0.05	0.03
Disengaged-批評	0.35	0.18
Barely-Engaged-支援	0.45	0.11
Barely-Engaged-気配り	0.15	0.02
Barely-Engaged-賞賛	0.1	0.01
Barely-Engaged-批評	0.3	0.11
Engaged-支援	0.2	0.02
Engaged-気配り	0.1	0.15
Engaged-賞賛	0.7	0.11
Engaged-批評	0	0.28

## 5. おわりに

本研究では、オンライン学習における自己調整学習時の学習者のエンゲージメントを改善するために、学習者個々の反応に合わせたインタラクションを行うことができる学習パートナーロボットを実装した。また、その効果を評価するために、20名の大学院生を対象に被験者内計画による評価実験（Sota あり／なし）を実施した。

学習者の学習中のエンゲージメントの推定に関しては、Huynh らのモデルを採用した。本研究では、専門的かつ十分な規模のデータセットがなかったため、Huynh らの事前学習モデルを用いた。その結果、エン

ゲージメントの推定精度は 53.6%であった。有意な誤りの頻度は高くなかったが、Sota とのインタラクション生成時やモデル更新時にミスマッチが発生した。特に、このモデルには一定の遅延が不可避であるため、より高精度かつ高速なモデルの開発が次のステップとなる。

また、学習者のエンゲージメントを促進するインタラクションを生成するために、インタラクションネットワークを構築した。このネットワークは、学習者のエンゲージメント、Sota の発話タイプ、ジェスチャと発話速度を表す 4 つの層からなる完全連結ネットワークである。確率的な形式に変換された初期重みを設定することで、インタラクションの内容を決定できるようにした。実験の結果、Sota あり条件の方が Sota なし条件よりも、平均エンゲージメントが高くなったことがわかった。本実験では各セッションが 30 分と短く、被験者も初めて Sota とインタラクションを行ったため、長時間の学習にはさらなる実験が必要である。

加えて本研究では、インタラクション後の学習者のエンゲージメントの推定結果から、Sota が前回のインタラクションの成果を判定して、インタラクション内容を変更するインタラクション更新モデルを提案した。実験の結果、最後の 1/3 のインタラクション内容の満足度が、それ以外のインタラクション内容の満足度よりも有意に高いことが示された。現在のインタラクションネットワークは 4 層構造しかなく、インタラクションのパターンが少ないため、一部の学習者にとって満足いかないインタラクションが生成されることもあった。今後は、ネットワークの層数を増やし、発話内容やインタラクションの手法を増やすことを検討する必要がある。さらに、初期段階の重み設定は、初期の学習者インタラクションの満足度に影響し、重みの更新速度やルールは後期のインタラクションの満足度に影響する。今後の実験を通じて、最適な重みの設定や更新ルールを議論する必要がある。

## 謝辞

本研究の一部は、科研費（20H04294）の助成、および株式会社フォトロンとの共同研究の成果である。

## 参 考 文 献

- (1) B. J. Zimmerman: “Self-Regulated Learning: Theories, Measures, and Outcomes”, Second Edi., vol. 21. Elsevier, (2015)
- (2) 鹿毛雅治:“学習意欲の理論 -動機づけの教育心理学-”, 金子書房, (2013)
- (3) C.E. Schaeffer & G.D. Konetes GD: “Impact of learner engagement on attrition rates and student success in online learning”, *International Journal of Instructional Technology & Distance Learning*.7(5), pp..3-9, (2010)
- (4) 柏原昭博:“エンゲージメントを引き出す学習支援ロボット”, *コンピュータ&エデュケーション*, Vol.46, pp.30-37, (2019)
- (5) R. Pekrun, et al.: “Achievement Emotions and Academic Performance: Longitudinal Models of Reciprocal Effects”, *Child Development*, 88(5), pp.1653–1670, (2017)
- (6) D. A. Akuratiya & D. N. Meddage: “Students’ Perception of Online Learning during COVID-19 Pandemic: A Survey Study of IT Students”, *International Journal of Research and Innovation in Social Science*. 4(9), pp.755-758, (2020)
- (7) YAO Bowei, 太田 光一, 柏原 昭博, 卯木 輝彦, 長谷川 忍: “顔画像に基づく個別適応エンゲージメント促進支援ロボットの開発”, 第 47 回教育システム情報学会全国大会論文集, pp.199-200, (2022).
- (8) I. Leite, et al.: “Social robots for long-term interaction: A survey”, *International Journal of. Social Robotics*. 5, pp.291–308, (2013)
- (9) T. Belpaeme, et al.: “Social robots for education: A review”, *Science Robotics*. 3(21), (2018) DOI: 10.1126/scirobotics.aat595.
- (10) V. Rosanda, A. Istenic Starcić: “The Robot in the Classroom: A Review of a Robot Role”, In: Popescu, E., Hao, T., Hsu, TC., Xie, H., Temperini, M., Chen, W. (eds) *Emerging Technologies for Education. SETE 2019. Lecture Notes in Computer Science*, vol 11984. Springer, Cham, (2020) [https://doi.org/10.1007/978-3-030-38778-5\\_38](https://doi.org/10.1007/978-3-030-38778-5_38)
- (11) Y. Lu, et al.: “Smart Learning Partner: An Interactive Robot for Education”. In: *Artificial Intelligence in Education. AIED 2018. Lecture Notes in Computer Science*, vol 10948. Springer, Cham (2018) [https://doi.org/10.1007/978-3-319-93846-2\\_84](https://doi.org/10.1007/978-3-319-93846-2_84)
- (12) N. Lubold, et al.: “Effects of voice-adaptation and social dialogue on perceptions of a robotic learning companion”, *11th ACM/IEEE International Conference on Human-Robot Interaction (HRI)*, pp. 255-262, (2016)
- (13) ヴァイストーン株式会社: “Sota 法人向けサービスのご案内”, <https://sota.vstone.co.jp/home/> (2022.10.5 アクセス)
- (14) V. T. Huynh, et al.: “Engagement Intensity Prediction with Facial Behavior Features”, *2019 International Conference on Multimodal Interaction*, pp.567-571, (2019)
- (15) T. Baltrusaitis, et al.: “Openface 2.0: Facial behavior analysis toolkit”. In *13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018)*. pp.59-66, (2018)
- (16) Y. Guo, et al.: “Ms-celeb-1m: A dataset and benchmark for large-scale face recognition”, In *European Conference on Computer Vision*. pp.87-102, (2016)
- (17) Q. Cao, et al.: “Vggface2: A dataset for recognizing faces across pose and age”, In *13th IEEE International Conference on Automatic Face & Gesture Recognition*. pp.67-74, (2018)
- (18) J. Hu, et al.: “Squeeze-and-excitation networks”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. pp.7132-7141, (2018)
- (19) S. R. Fussell (Ed.): “The Verbal Communication of Emotion: Interdisciplinary Perspectives”, Psychology Press (2002)
- (20) N. Dael, et al.: “The Body Action and Posture coding system (BAP): Development and reliability”, *Journal of Nonverbal Behavior*. 36. pp.97-121, (2012)
- (21) J. Brophy: “Teacher praise: A functional analysis”, *Review of Educational Research*, 51(1), pp.5-32, (1981)
- (22) G. Hagenauer & S. E. Volet: ““I don’t hide my feelings, even though I try to”: insight into teacher educator emotion display”, *The Australian Educational Researcher*. 41, pp.261-281, (2014)
- (23) J. Jiang, et al.: “Teacher Beliefs and Emotion Expression in Light of Support for Student Psychological Needs: A Qualitative Study”, *Education Sciences*. 9(68), (2019)
- (24) M. Cutumisu & D. L. Schwartz: “The impact of critical feedback choice on students' revision, performance, learning, and memory”, *Computers in Human Behavior*, 78(Jan.). pp.351-367, (2018)
- (25) L. Fried: Teaching Teachers about Emotion Regulation in the Classroom. *Australian Journal of Teacher Education*, 36(3), (2011) <http://dx.doi.org/10.14221/ajte.2011v36n3.1>
- (26) X. Zheng, et al.: “Estimation of Learners’ Engagement Using Face and Body Features by Transfer Learning”, In: Degen, H., Ntoa, S. (eds) *Artificial Intelligence in HCI. HCII 2021. Lecture Notes in Computer Science*, vol 12797. Springer, Cham, (2021) [https://doi.org/10.1007/978-3-030-77772-2\\_36](https://doi.org/10.1007/978-3-030-77772-2_36)