

# 言葉づかいに着目した 褒め方の上手さの推定モデルの基礎検討

大串 旭<sup>1</sup> 大西 俊輝<sup>2</sup> 山内 愛里沙<sup>2</sup> 石井 亮<sup>3</sup> 杵渕 哲也<sup>3</sup> 青野 裕司<sup>3</sup> 宮田 章裕<sup>1,a)</sup>

概要: 日常生活において, 褒める行為は大切なコミュニケーションであるが, 上手く褒めるためにどのような行動を取れば良いのか明らかにされていない. そこで我々は上手く褒めるためにどのような行動が重要であるかを明らかにし, 褒め方の上手さを評価するシステムの構築を目指す. 本稿では, 褒める際の発話内容から褒め方の上手さを推定することが可能であるか明らかにする取り組みを行なう. はじめに, 褒める際の発話内容から抽出した言語情報(単語数や品詞の出現頻度, 極性値, 抽象度)に関する特徴量を抽出した. 次に, 言語情報に関する特徴量を用いて褒め方の上手さの評価値を推定する機械学習モデルの構築を行なった. 最後に, 褒め方の上手さを推定するために重要な特徴量がどのような言語情報であるのかを分析した. その結果, 褒める際の発話内容から褒め方の上手さをある程度推定可能であることが明らかになった. また, 褒め方の上手さを推定するために重要な言語情報として, 単語数や形容詞などの特定の品詞の出現頻度が重要であることが明らかになった.

## Preliminary Study of Praising Skills Estimation Based on Wording

ASAHI OHGUSHI<sup>1</sup> TOSHIKI ONISHI<sup>2</sup> ARISA YAMAUCHI<sup>2</sup> RYO ISHII<sup>3</sup> TETSUYA KINEBUCHI<sup>3</sup>  
YUSHI AONO<sup>3</sup> AKIHIRO MIYATA<sup>1,a)</sup>

### 1. はじめに

日常生活や社会活動において, 褒める行為は大切なコミュニケーションの1つである. 褒めることで, 相手との人間関係を良好にすることや, 相手の技能を最大限発揮してもらおうことができるようになる. 褒める行為は, 対象の行動や性格に向けられた称賛を表現する言語・非言語行動と考えられている [1][2][3]. 加えて, 褒める人から褒められる人への一方的な意思の伝達ではなく, 複雑な社会的コミュニケーションであると考えられている [4]. しかし, 対話において相手を上手く褒めるためにはどのような行動が重要であるか明らかにされていない. そのため, 上手く褒めることができない人やより上手く褒めたいと考えている人が, 自身の褒め方を改善するためにはどのような点に気をつけると良いのかわからないという問題がある. この問

題を解決するために, 我々は上手く褒めるためにはどのような行動が重要であるかを明らかにし, 褒め方の上手さを評価するシステムの構築を目指す. この目標を達成するためには, 褒め方の上手さを推定することができる機械学習モデルの構築が必要である. 機械学習モデルを構築することで, 褒めている際の行動の自動的な判定・評価ができるようになり, 褒め方の上手さを評価するシステムの構築に貢献すると考えられる.

我々はこれまでに, 褒める行為における非言語行動に着目し, 褒め方の上手さを推定する機械学習モデルの構築や褒め方の上手さを評価するシステムの構築を行ってきた [5][6]. 対話における行為では, 非言語行動だけでなく言語行動も伴うと考えられるため, 本稿では言語行動である発話内容に着目する. 実際に相手を褒める際の発話内容から, 褒め方の上手さを推定することができるか明らかにするための機械学習モデルを構築する. 事前検討として, 褒める際の発話内容の品詞を分析し, 上手く褒めるために効果のある言葉づかいについて明らかにする調査を行なった [7]. 事前検討で明らかにした上手く褒めるために効果

<sup>1</sup> 日本大学文理学部

<sup>2</sup> 日本大学大学院総合基礎科学研究科

<sup>3</sup> 日本電信電話株式会社 NTT メディアインテリジェンス研究所

a) miyata.akihiro@acm.org

のある品詞の出現頻度と単語数をもとに機械学習モデルの構築を行なう。本稿の貢献は次の通りである。

- 褒める際の発話内容から褒め方の上手さを推定することができるか明らかにしたこと。
- 褒め方の上手さを推定するために、どのような言語情報が重要であるか明らかにしたこと。

## 2. 関連研究

人間の言語・非言語行動を利用して、コミュニケーションスキル、プレゼンテーションスキル、共感スキル、自己開示、話者の説得力などの行動・能力を分析する研究は数多く行なわれている。本研究は、人間の言語・非言語情報を利用して、特定のタスクやシーンにおける行動・能力を分析する研究と深く関連している。

コミュニケーションスキルを分析する研究事例として [8], [9] が挙げられる。Okada らは、コミュニケーションスキルを人事管理経験者の評価をもとに言語・非言語情報を利用して、コミュニケーションスキルの推定モデルを構築している [8]。Rasipuram らは、言語・非言語情報を抽出して機械学習をすることによって、非同期インタビューと対面インタビューでの人のコミュニケーションスキルを予測するシステムを構築している [9]。

プレゼンテーションスキルを分析する研究事例として [10], [11] が挙げられる。Ramanarayanan らは、時系列に基づいて計算された 3 つの異なる特徴量を用いて、人間が評価したプレゼンテーション能力のスコアを予測する際の比較を行なっている [10]。Yagi らは、プレゼンテーションシーンから得られる言語・非言語情報からプレゼンテーション能力を推定するモデルの構築・評価を行なっている [11]。

共感・自己開示・説得力などのスキルを分析する研究事例として [12], [13], [14], [15], [16] が挙げられる。Park らは、オンライン・ソーシャル・マルチメディア・コンテンツにおける話者の説得力を予測するために、複数のコミュニケーション・モダリティからの言語行動と非言語行動を利用したアプローチを提案し、話者の感情の部分的な事前知識を持つことが、説得力のレベルをより良く予測することに寄与していると示している [12]。Ishii らは、Davis の対人反応性指標を用いて測定した共感スキルレベルに応じて、話者交替/継続における視線行動と対話行為について分析している [13]。Tan らは、対話における言語・非言語行動を利用して、聞き手が相手の話に共感しているかを予測するモデルの構築・評価を行なっている [14]。Soleymani らは、対話中の言語・非言語行動を相関分析することで言語行動の言語内容が自己開示に関連していることを明らかにしている。加えて、自己開示のレベルを推定するために、マルチモーダルディープニューラルネットワークを構築している [15]。Naim らは、言語・非言語行動を利用して、就

職面接での社会的スキルを推定するための回帰モデルを構築している [16]。

これらの研究事例では、コーパスデータから分析の対象となるシーンの言語・非言語行動を抽出し、機械学習モデルの構築や分析を行なっている。

## 3. アプローチ

人間の言語・非言語行動を利用して、特定のタスクや多様な対話シーンにおける行動・能力を分析する研究は数多く行なわれている。これらの研究事例では、研究対象となる行動や能力を対象のシーンの全体を通して観測される人間の行動を用いて推定や分析を行なっている。一方で我々は、個人の褒め方の上手さを対話全体を通して分析するのではなく、個々のシーンに着目して分析するという点で異なっている。褒める行為は、個人内でも変異が大きいと考えられるため、対話全体での褒める行為を分析するよりも個々のシーンにおける褒める行為を分析するほうが適切であると考えられるためである。また多くの研究事例では、対話シーンにおける人間の言語・非言語行動を抽出し、機械学習モデルを構築することで、特定のタスクや多様な対話シーンにおける行動・能力を自動で推定可能であることを明らかにしている。我々は、対話における褒めるシーンに着目し、人間の言語・非言語行動から褒め方の上手さを推定することができるのか明らかにする試みを行なう。

先行研究では、非言語行動のみに着目して褒め方の上手さの推定や褒める上手さの評価システムの構築を行なった [5][6]。だが、褒める行為は単に非言語行動だけでなく言語行動も伴っている。関連研究より、特定のタスクの評価を推定する際に非言語行動のみを扱う場合と、言語行動のみを扱う場合で同程度の推定精度を得られることが明らかになっている。そこで本稿では、褒める行為において言語行動である発話内容に着目する。事前検討として、褒める際の発話内容の品詞を分析することで、上手く褒めるために効果のある言葉づかいについて明らかにする調査を行なった [7]。しかし、褒める際の発話内容から褒め方の上手さを推定することができるか明らかになっていない。そこで本稿では、褒める際の発話内容から褒め方の上手さを推定することができるのか明らかにすることを研究課題とする。研究課題を達成するためのアプローチを示す。はじめに、2 者対話の発話内容から言語情報に関する特徴量を抽出する。次に、言語情報に関する特徴量を用いて、褒め方の上手さの評価値を推定する機械学習モデルを構築する。最後に、褒め方の上手さを推定するために重要な特徴量がどのような言語情報であるのか明らかにする。

## 4. 対話コーパス

### 4.1 2 者対話の収録

対話における褒め方の上手さの評価と言語・非言語行動



図 1 2者対話の様子

の記録を含む対話コーパスの作成を行なった [5]。2者対話の参加者は、20代の大学生34名（男性28名、女性6名）であり、2名1組のペアを17組構成した。17組のうち、初対面が14組、顔見知り2組、友人同士が1組であった。対話の収録を始めるにあたり、参加者に対話材料を準備させることを意図して、いままで頑張ってきたことに関するエピソードを2つ以上用意してもらった。対話収録時は、図1のように参加者が互いに向き合って着座してもらった。このときの参加者間の距離は180cmとした。対話の収録は、各参加者の様子と2者対話全体の様子を撮影するためのビデオカメラ、各参加者の声を録音するためのマイクを用いて行なった。各組の参加者（参加者A、参加者B）は、撮影者の合図に従い、次の(1)～(3)を行なった。

- (1) 自己紹介（5分間）
- (2) 参加者Aが褒める人となり、参加者Bが褒められる人となる対話（5分間）
- (3) 参加者Bが褒める人となり、参加者Aが褒められる人となる対話（5分間）

(1)～(3)の対話を17組分、計255分間収録した。なお、(1)の自己紹介は各組の多くが初対面であり、参加者の緊張をほぐす目的で行なっているため、分析の対象外とした。(2)と(3)の対話において、褒める人には、対話相手を積極的に褒めるように指示した。しかし、一方的に褒めているだけのような不自然な対話にならないようにするために、自由に質問したり、リアクションをしたりすることを許可した。褒められる人には、事前に用意した自分がいままで頑張ってきたことに関するエピソードを話すように指示した。対話の自然さや話題の多様性を担保するために、事前に用意していないエピソードについて話すことを許可した。

#### 4.2 アノテーション

収録した映像データや音声データに対して注釈付けを行なうツールであるELAN[18]を利用して人手で発話シーンの付与を行なった。発話シーンは、沈黙時間が400ミリ秒未満の連続した音声区間である。次に、ELANを利用して人手で発話内容の書き起こしを行なった。書き起こしを行

なう際、アノテータによる書き起こし内容の表記ゆれが分析結果に影響を及ぼすことが考えられたため、表記ゆれを減らすために辞書を参照しながら作業を行なった。本研究では、UniDic 話し言葉辞書[19]に載っている感動詞とフィルターの単語を抜き出したものを辞書として扱った。このときアノテータには、発話内容の文頭が辞書内の単語の読みに近い場合は、辞書内の単語で書き起こすように指示した。たとえば、“あー”、“あ～”などは“あー”と書き起こす。なお、辞書に載っていない単語については、聞き取った単語をそのまま書き起こすように指示した。

#### 4.3 褒め方の上手さの評価

2者対話の収録に参加していない第三者のアノテータ5名が、褒め方の上手さの評価を行なった。具体的には、褒める人の正面に設置したビデオカメラから撮影した映像データと褒める人に取り付けたマイクから録音した音声データを参照し、褒める人の発話シーンごとに下記の判定・評価を行なった。

- 対話相手を褒めているシーンであるか、そうでないかの判定
- 褒めているシーンであると判定した場合、1（上手く褒められていない）～7（上手く褒められている）の7段階での褒め方の上手さの評価

本研究では、各発話シーンにおいて褒めていると判定したアノテータが3名以上であるシーンをPraiseシーンとする。Praiseシーンにおいて褒めているシーンであると判定したアノテータの評価の平均値をPraiseスコアとする。アノテータ間のPraiseスコアの一致率を評価するために、級内相関係数（ICC）[20]を利用した。まず、3～5人のアノテータのそれぞれの組み合わせごとに級内相関係数を算出した。次に、サンプル数を考慮して組み合わせごとの級内相関係数の重み付き平均を算出した。その結果、Praiseスコアの級内相関係数の平均は $ICC(2,k) = 0.571$ であった。この結果から、Praiseスコアはアノテータ間で中程度の一致率があり、信頼性のあるデータであることが示唆された。

### 5. 推定モデルの構築

褒める人の発話内容から言語情報を抽出して、褒め方の上手さを推定する機械学習モデルの構築を行なった。

#### 5.1 特徴量抽出

機械学習モデルを構築するにあたり、4.2節で書き起こした褒める人の発話内容から、単語数、品詞、極性値、抽象度を特徴量として抽出した。

**単語数・品詞** Mecab[17]を用いて各Praiseシーンにおける褒める人の発話内容に形態素解析を行ない、各単語の品詞を抽出した。抽出した品詞は、事前検討[7]において上手く褒めるために効果があると判断された13

表 1 抽出した品詞

大分類	小分類
感動詞	感動詞
形容詞	形容詞
助詞	助詞 (格助詞), 助詞 (副助詞), 助詞 (連体化)
助動詞	助動詞
動詞	動詞 (自立), 動詞 (非自立)
名詞	名詞 (サ変接続), 名詞 (数), 名詞 (接尾), 名詞 (非自立),
連体詞	連体詞

種類の品詞 (表 1) である。次に、各 Praise シーンにおける各品詞の利用数を集計した。このとき、集計した各文章の品詞の利用数を合算することで、各文章の単語数を求めた。特徴量として、各 Praise シーンで利用された品詞ごとの出現頻度を求めた。出現頻度は、各 Praise シーンから品詞ごとに利用された数をその Praise シーンの総単語数で除算することで求めた。

**極性値** 各文章がポジティブな印象であるのかネガティブな印象であるのかを褒め方の上手さに影響すると考え、文章の極性値を求めた。具体的には、単語感情極性対応表 [21][22] を利用し、Praise シーンにおける発話内容の極性値を求めた。単語感情極性対応表とは、特定の単語が良い印象であるか悪い印象であるのかという 2 値属性に対して -1 (悪い印象) ~ 1 (良い印象) の実数値を割り振った辞書である。各文章の各単語と単語感情極性対応表を機械的に比較し、単語の極性値を求めた。このとき、辞書に存在しない単語の極性値は 0 として、極性値の計算には利用しないこととした。各単語の極性値を求めたのち、その文章における単語の極性値を加算し、辞書に存在した単語数で除算することでその文章の極性値とした。極性値の値が小さいほどネガティブであり、大きいほどポジティブな文章である。

**抽象度** Praise シーンにおける発話が具体的であるかどうかを褒め方の上手さに影響すると考え、文章の抽象度を求めた。具体的には、日本語抽象度辞書 [23] を利用し、Praise シーンにおける発話内容の抽象度を求めた。日本語抽象度辞書とは、特定の単語が具体的であるか抽象的であるか 1 (具体的) ~ 5 (抽象的) の実数値を割り振った辞書である。このとき、辞書に存在しない単語の極性値は 0 として、抽象度の計算には利用しないこととした。各単語の抽象度を求めたのち、その文章における単語の抽象度を加算し、辞書に存在した単語数で除算することでその文章の抽象度とした。抽象度の値が小さいほど具体的であり、大きいほど抽象的な文章である。

合計で 16 個の特徴量を全 Praise シーンから抽出し平均値

0, 分散 1 になるように正規化を行なった。

## 5.2 モデル構築

まず、Praise シーンを Praise スコア低群、中群、高群の 3 クラスに分割した。各群に属する Praise シーン数ができるだけ均等になるように、下記のように Praise スコア低 ~ 高群を定義した\*1。

**Praise スコア低群** Praise スコアが 3.8 点以下の Praise シーン (計 82 シーン)

**Praise スコア中群** Praise スコアが 3.8 点より大きく 4.4 点未満の Praise シーン (計 65 シーン)

**Praise スコア高群** Praise スコアが 4.4 点以上の Praise シーン (計 81 シーン)

目的変数を Praise スコア低群、中群、高群とし、説明変数を 5.1 節で抽出した特徴量とする分類モデルを構築した。モデルを構築するアルゴリズムとして、各特徴量の重要度を比較することができる Random Forest[24] を用いた。決定木の木の深さや木の深さといったハイパーパラメータは Hyperopt[25] を用いて最適化した。本研究では、Leave-One-Person-Out 交差検証法を用いて、Praise シーンがどの群に属するのか推定するタスクを行なった。Leave-One-Person-Out 交差検証法とは、はじめにデータセットを参加者ごとに分割し、1 人分のデータを抜いて学習し、抜いた人のデータで推定する作業を繰り返してモデルの性能を評価する手法である。本稿では、上記のタスクを 100 回行なった。

このとき、褒め方の上手さを推定する上で、どのような言語行動を利用すると良いか確認するために、事前検討の結果を踏まえ、説明変数に用いる特徴量の組み合わせを 4 種類用意した。

- 単語数と品詞の出現頻度を用いた組み合わせ (Model A)
- 単語数と品詞の出現頻度、極性値を用いた組み合わせ (Model B)
- 単語数と品詞の出現頻度、抽象度を用いた組み合わせ (Model C)
- 単語数と品詞の出現頻度、極性値、抽象度を用いた組み合わせ (Model D)

## 5.3 褒め方の上手さの推定結果

5.2 節で構築した各モデルで利用した特徴量と推定精度の各指標の平均値を表 2 に示す。ベースライン (チャンスレベル) は、データセットにおける各群の割合にあわせて、36%, 28%, 36% の確率で Praise スコアの低、中、高群を出力するモデルを用いた。表 2 より、ベース

\*1 各群に属するシーン数は等しいことが理想ではあるが、スコアが同じシーンが多数存在したため、各群のシーン数を等しくすることができなかった。

表 2 各モデルで利用した特徴量と推定精度の各指標の平均値 (N=100)

	単語数	品詞の出現頻度	極性値	抽象度	適合率	再現率	F 値
Baseline					0.455	0.340	0.357
Model A	✓	✓			0.602	0.519	<b>0.523*</b>
Model B	✓	✓	✓		0.579	0.502	0.506*†
Model C	✓	✓		✓	0.558	0.479	0.482*†
Model D	✓	✓	✓	✓	0.545	0.478	0.480*†




図 2 Model A での特徴量の重要度上位 10 件

ラインの推定精度は F 値が 0.357 であり、精度が低いことがわかる。ベースラインと本稿で構築したモデルの間で対応のある t 検定を行ない、精度が向上しているのか確認した。Model A ( $t(99) = 18.650, p < .01$ ), Model B ( $t(99) = 13.480, p < .01$ ), Model C ( $t(99) = 15.567, p < .01$ ), Model D ( $t(99) = 13.246, p < .01$ ) となり、全てのモデルでベースラインとの間に 1%水準で有意差が確認できた。本稿で構築した各モデルの推定精度を比較すると、全てのモデルがベースラインよりも高い推定精度であることがわかる。

また、本稿で構築したモデル間に対応のある t 検定を行い、最も推定精度を向上させることができた特徴量の組み合わせを確認した。Model A と Model B 間 ( $t(99) = 9.209, p < .01$ ), Model A と Model C 間 ( $t(99) = 4.032, p < .01$ ), Model A と Model D 間 ( $t(99) = 9.708, p < .01$ ), Model B と Model C 間 ( $t(99) = 5.096, p < .01$ ), Model C と Model D 間 ( $t(99) = 5.751, p < .01$ ) において 1%水準で有意差が確認できた。その結果、Model A-D では Model A が最も精度が高く、Model D が最も精度が低いことがわかる。これより、単語数と特定の品詞の出現頻度を組み合わせると特徴量として用いることが最も推定精度を向上させることができることがわかった。上記より、褒め方の上手さを推定する上で言語行動が有効であり、ある程度褒め方の上手さを推定することが可能であることがわかった。

\* ベースラインとの間で  $p < .01$

† Model A との間で  $p < .01$

## 5.4 考察

最も推定精度の良かった Model A における重要度の高い特徴量上位 10 件を図 2 に示す。ここでの重要度は、決定木のノードがどれくらい分類されているのかを表すジニ不純度を基に算出されている。分割前と分割後のジニ不純度を比較した場合にジニ不純度をより小さくできた特徴量を、重要度の高い特徴量としている。図 2 より、特に単語数が褒め方の上手さを分類する上で重要であることがわかる。Praise スコアと単語数との相関係数を求めると  $r = 0.501$  であり、正の相関があることが確認できた。単語数が多くなるほど Praise スコアが高くなる傾向にあると考えられる。

次に、抽象度と極性値を利用した場合、推定精度が下がった原因について考える。抽象度は褒める人の発話内容に含まれる各単語の抽象度を算出し、その文章がどれくらい抽象的であるかを判断する指標である。Praise スコアと抽象度の相関係数を求めると  $r = -0.245$  であり、弱い負の相関があることが確認できた。Praise スコアが高くなると文章はより具体的な単語を用いる傾向にあると考えられる。極性値は褒める人の発話内容に含まれる各単語の極性値を算出し、その文章がポジティブネガティブどちらの印象を持つか判断する指標である。Praise スコアと極性値の相関係数を求めると  $r = -0.277$  であり弱い負の相関があることが確認できた。Praise スコアが高くなると文章はネガティブな要素が増える傾向にあると考えられる。抽象度と極性値のどちらにも Praise スコアと弱い相関があることが確認できた。相関が些か弱かったため、特徴量として使用するには不適切であり推定精度を下げる原因となったと考えられる。

そこで抽象度と極性値が正しく Praise スコアの各群に分類できるような分布であるか確認するために、それぞれの値と Praise スコアの分布を図 3, 4 を示す。図 3, 4 より、Praise スコア各群でほぼ一律な分布であることが確認できた。これより、本来の群とは誤った分類をすることが増え、推定精度が低下することに繋がったと考えられる。しかし、この傾向が普遍的であることを示すには本実験で利用したデータ数は十分でないと考えられる。今後より大規模なデータを利用して検証する必要があると考えている。



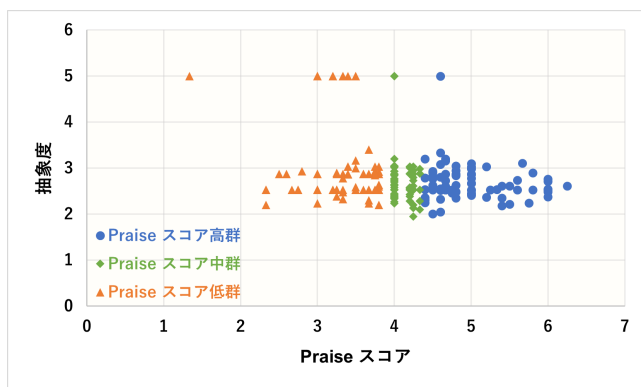


図 3 Praise スコアと抽象度との散布図




図 4 Praise スコアと極性値との散布図

## 6. おわりに

本稿では、褒める際の発話内容に着目し、褒め方の上手さを推定することができるのか明らかにする取り組みを行なった。具体的には、褒める際の発話内容から言語情報（単語数や品詞の出現頻度、極性値、抽象度）に関する特徴量を抽出し、褒め方の上手さの評価値を推定する機械学習モデルを構築した。さらに、褒め方の上手さを推定するために重要な特徴量がどのような言語情報であるのか明らかにした。その結果、ある程度褒め方の上手さを推定することが可能であることが明らかにした。また、褒め方の上手さを推定するために重要な言語情報として、単語数や形容詞などの特定の品詞の出現頻度が重要であることが明らかになった。

本稿では、褒める人の情報に着目し、褒め方の上手さを推定することができるか確認した。対話における褒めるシーンでは、褒められる人の情報も重要であると考えられる。褒められる人の情報として、褒める際の発話内容が褒められる人のエピソードの内容を含んでいるか否かなどがある。上記のような褒められる人の情報を加えることで推定精度を向上させることができるのではないかと考えている。加えて、コミュニケーション中のどのタイミングで褒めることが重要なのかという検証も必要であると考えている。さらに、本稿での成果も踏まえ、Praise シーンにおけ

る発話内容を入力とした褒め方の上手さを評価し、どのような点を改善すれば良いのかアドバイスをしてくれるシステムの開発をすることも予定している。

## 参考文献

- [1] Brophy, J.: Teacher praise: A full functional analysis, Review of Educational Research, Vol.51, No.1, pp.5-32 (1981) .
- [2] Kalis, T.M., Vannest, K.J. and Parker, R.: Praise Counts: Using Self-Monitoring to Increase Effective Teaching Practices, Preventing School Failure: Alternative Education for Children and Youth, Vol.51, No.3, pp.20-27 (2007) .
- [3] Henderlong, J. and Lepper, M. R.: The effects of praise on children's intrinsic motivation: A review and synthesis. Psychological Bulletin, Vol.128, No.5, pp.774-795 (2002).
- [4] Jenkins, L.N., Floress, M.T. and Reinke, W.: Rates and Types of Teacher Praise: A Review and Future Directions, Psychology in the Schools, Vol.52, No.5, pp.463-476 (2015) .
- [5] Onishi, T., Yamauchi, A., Ishii, R., Aono, Y. and Miyata, A.: Analyzing Nonverbal Behaviors along with Praising, Proceedings of the 22nd ACM International Conference on Multimodal Interaction (ICMI '20) , pp.609-613 (2020) .
- [6] 山内愛里沙, 大西俊輝, 武藤佑太, 石井亮, 青野裕司, 宮田章裕: 音声および視線・表情・頭部運動に基づく上手い褒め方の評価システムの検討, 情報処理学会シンポジウム論文集, マルチメディア, 分散, 協調とモバイル (DICOMO '20) , Vol.2020, pp.98-106 (2020) .
- [7] 大串旭, 大西俊輝, 山内愛里沙, 石井亮, 杵渕哲也, 青野裕司, 宮田章裕: 上手く褒めるために効果的な言葉づかいの調査. 情報処理学会インタラクシオン 2021 論文集, pp.714-718 (2021).
- [8] Okada, S., Ohtake, Y., Nakano, Y.I., Hayashi, Y., Huang, H.H., Takase, Y. and Nitta, K.: Estimating communication skills using dialogue acts and nonverbal features in multiple discussion datasets, Proceedings of the 18th ACM International Conference on Multimodal Interaction (ICMI '16) , pp.169-176 (2016) .
- [9] Rasipuram, S., Rao, P., Jayagopi, D.B.: Asynchronous video interviews vs. Face-To-face interviews for communication skill measurement: A systematic study. Proceedings of the 18th ACM International Conference on Multimodal Interaction (ICMI '16), pp.370-377 (2016).
- [10] Ramanarayanan, V., Leong, C. W., Chen, L., Feng, G. and Suendermann-Oeft, D.: Evaluating Speech, Face, Emotion and Body Movement Time-series Features for Automated Multimodal Presentation Scoring. Proceedings of the 2015 ACM on International Conference on Multimodal Interaction (ICMI '15) , pp.23-30 (2015) .
- [11] Yagi, Y., Okada, S., Shiobara, S. and Sugimura, S.: Predicting multimodal presentation skills based on instance weighting domain adaptation. Journal on Multimodal User Interfaces, pp.1-16 (2021).
- [12] Park, S., Shim, H.S., Chatterjee, M., Sagae, K. and Morency, L.P.: Computational Analysis of Persuasiveness in Social Multimedia: A Novel Dataset and Multimodal Prediction Approach, Proceedings of the 16th International Conference on Multimodal Interaction (ICMI '14) , pp.50-57 (2014) .
- [13] Ishii, R., Otsuka, K., Kumano, S., Higashinaka, R. and Tomita, J.: Analyzing Gaze Behavior and Dialogue Act

during Turn-taking for Estimating Empathy Skill Level, Proceedings of the 20th ACM International Conference on Multimodal Interaction (ICMI '18) , pp.31–39 (2018)

- [14] Tan, Z., Goel, A., Nguyen, T. and Ong, D.: A Multimodal LSTM for Predicting Listener Empathic Responses Over Time, 14th IEEE International Conference on Automatic Face and Gesture Recognition (FG '19) , pp.1–4, (2019).
- [15] Soleymani, M., Stefanov, K., Kang, H.S., Ondras, J. and Gratch, J.: Multimodal Analysis and Estimation of Intimate Self-Disclosure, Proceedings of the 21st ACM International Conference on Multimodal Interaction (ICMI '19) , pp.59–68 (2019) .
- [16] Naim, I., Tanveer ,M.I., Gildea , D. and Hoque, M. E.: Automated prediction and analysis of job interview performance: The role of what you say and how you say it, 11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG '15) , pp. 1–6 (2015) .
- [17] MeCab: Yet Another Part-of-Speech and Morphological Analyzer, 入手先 (<https://taku910.github.io/mecab/>) (参照 2021-5-10).
- [18] Brugman, H. and Russel, A.: Annotating Multimedia / Multi-modal resources with ELAN, Proceedings of the 4th International Conference on Language Resources and Language Evaluation (LREC '04), pp.2065–2068 (2004)
- [19] The UniDic Consortium : unidic-csj-3.0.1.1, 入手先 (<https://unidic.ninjal.ac.jp/>) (参照 2021-5-10).
- [20] Shrout, P. E. and Fleiss, J. L.: Intraclass correlations: uses in assessing rater reliability, Psychological bulletin, Vol.86, No.2, pp.420–428 (1979).
- [21] 高村大也 : 単語感情極性対応表, 入手先 ([http://www.lr.pi.titech.ac.jp/takamura/pndic\\_ja.html](http://www.lr.pi.titech.ac.jp/takamura/pndic_ja.html)) (参照 2021-5-10).
- [22] Takamura, H., Inui, T. and Okumura, M.: Extracting Semantic Orientations of Words using Spin Model, Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL '05) , pp.133–140 (2005).
- [23] 奈良先端科学技術大学院大学ソーシャル・コンピューティング研究室 : 日本語抽象度辞書, 入手先 (<https://sociocom.naist.jp/awd-j/>) (参照 2021-5-10).
- [24] Breiman, L.: Random Forests. Machine Learning, Vol.45, No.1, pp.5–32 (2001).
- [25] Bergstra, J., Yamins, D. and Cox, D.D.: Hyperopt: A Python Library for Optimizing the Hyperparameters of Machine Learning Algorithms. Proceedings of the 12th Python in Science Conferences (SciPy '13), pp.13–20 (2013).