

テキスト感情分類コーパスの半自動生成と 音声発話の感情分類での評価

増田 京祐^{1,a)} 西崎 博光^{1,b)}

概要: 深層学習に基づく感情分類を行う場合、大規模な感情ラベル付きコーパスが必要となるが、これを人手で用意・整備するためには非常にコストがかかってしまう。そこで、本研究では、深層学習に基づく繰り返し精練手法によってほとんど労力をかけずに半自動的にテキスト感情分類コーパスを構築する方法を提案する。また、音声認識誤りに対して頑健な分類モデルを学習するための方法についても提案する。これらを用いて学習した感情分類モデルを用いて、音声発話の感情分類を行ったことについて報告する。

1. はじめに

近年、自動音声認識 (ASR) 技術は、家庭環境でも使用され始めている。例えば、Amazon Inc. や Google Inc. では、ASR 技術を使用したスマートスピーカーを開発し、スマートスピーカーデバイスで簡単な対話による家電製品の制御を可能にしている。今後、これらのスマートスピーカーを含む家庭用ロボットはさらに普及し、簡単な対話だけではなく人間同士に見られるレベルの会話が求められるようになると考えられる。その中で会話ロボットは、人間と自然な会話をするために人間の感情状態を推定・認識する必要がある。

話者の発話の感情分類を行うための研究のアプローチとしては大きく分けて2種類が存在する。一つは韻律情報などの音響特徴量に着目したものと、もう一つは発話内容に着目したものである。音声の感情分類の研究において、その大部分の研究は、音声感情分類のための音響特徴抽出と、発話の感情を特定するための認識・分類モデルの開発に焦点を当てている。特に、近年では深層学習ベースのアプローチが研究されており、高い分類精度を達成している [1], [2]。音響特徴量は感情分類に有用であるが、音響特徴量のみですべての発話に対して正確な感情を推定することはできない。正確な感情判別ができない例として、話し手が落ち着いて話しているにもかかわらず、話している内容に着目すると実は怒っているといった場合もある。このような場合に

は、発話に含まれる言語情報を用いる必要がある。

一方で、Twitter などのソーシャル・ネットワーク・サービスで用いられる短いテキストメッセージの感情分類の研究も盛んに行われている。テキストメッセージの感情分類に関する研究のほとんどは、メッセージ中の単語などの言語情報を使用したものである [3], [4]。これらの言語情報は、音声発話の感情認識にも非常に有効であることは知られている [5]。深層学習を用いたテキスト感情分類では、学習テキスト (これは文の単位であることが多い) に対して感情ラベルが付与されたデータを用いて、ニューラルネットワークを学習することが多い [6], [7]。このような枠組みで感情分類器を構築するには、大量のラベル付き学習コーパスが必要である。ツイートの感情分類の研究では、例えば、[8] のようなコーパスが使われている。日本語の場合は、栗原らが Yahoo!クラウドソーシングを用いて Twitter のツイートを元にデータセットを作成している [9]。このように人間によるラベリング作業が必要であり、コストがかかってしまう問題がある。

我々も以前に、Twitter を対象とした、深層学習に基づく感情分類手法の検討を行ってきた [10], [11]。学習に用いる感情コーパスを構築するために、人手によって僅かなシード感情語を用意し、この感情語を用いることで、半自動的に感情ラベル付きコーパスを構築していた。しかし、この手法では、当然ながら間違った感情ラベルを多く含んでいるため、深層学習モデルによる分類精度が低下するという問題があった。

そこで、本研究では、繰り返しコーパス精練手順によって、あまり労力をかけずに半自動的に正しいと推察される感情ラベルが付与された感情コーパスの自動生成方法を提

¹ 山梨大学大学院医工学農学総合教育部工学専攻
Department of Mechatronics, Integrated Graduate School of
Medicine, Engineering, and Agricultural Sciences, University
of Yamanashi, 4-3-11 Takeda, Kofu, 400-8511 Japan

a) kyosuke@alps-lab.org

b) hnishi@yamanashi.ac.jp

案する。加えて、言語情報のみで音声発話の感情分類を考
える場合、音声発話を音声認識すると、どうしても音声認
識誤りが発生してしまうおそれがあるため、その対策が必要
である。以前の我々の報告において [15], 音声認識結果
を利用したほうが（誤りのない）テキストをそのまま入力
するよりも、感情分類精度が高くなることを紹介した。そ
の際には、音声認識結果がある程度高ければ、単語の表記揺
れが少なくなり、テキストを使うよりも良い結果がもたら
されるのではないかとのことであった。しかし、音声認
識誤りがあることで精度低下を招くことに対する明確な
解決策は示していない。そこで、本研究では、音声認識誤
り、特に脱落誤りの対策のため、まずは試行的な方法とし
て、感情分類器を学習する際に入力する単語をドロップア
ウトする方法を検討した。

感情分類実験の結果、提案手法であるコーパス精錬に基
づくコーパスの半自動生成の有効性を確認したこと、学
習時に意図的に単語をドロップアウトすることで認識誤り
に頑健な感情分類器を学習できることが分かった。

2. 感情分類コーパスの構築

本研究では、感情カテゴリとして Plutchik の感情の輪 [12]
に基づく、「予期」、「怒り」、「嫌悪」、「悲しみ」、「驚き」、
「恐怖」、「信頼」、「喜び」の 8 種類の感情をラベルとして用
いる。

コーパス半自動生成の基本的な流れは次のとおりである。

- (1) 感情分類辞典 [13] に掲載されている 124 種類の感情語
をシード語として設定する。このシード語は必ず 1 つ
の感情カテゴリに属していると仮定する。人手の作業
はこの作業のみである。
- (2) (1) のシード語を用いてツイートを検索する。シード
語が含まれているテキストに、そのシード語が属する
感情カテゴリのラベルを付与する。よって感情ラベル
が間違っ付与されることがある（感情ラベルに誤り
を多く含むノイズな感情ラベルコーパスが生成）。
先行研究 [10] ではこのコーパスを利用していた。
- (3) (2) の学習データセットを用いて、分類器を学習する。
- (4) (3) の分類器を用いて、学習データの感情ラベルを更
新する。
- (5) (3) と (4) を繰り返す。

この手順によって、半自動的（ほぼ自動的に）に学習デー
タに付与されている感情ラベルを精錬していく。感情分類
タスクにおいては、データ拡張などを適用するのが難しい
ため、本研究では繰り返し学習によって、できるだけ正し
いと思われる感情ラベルを自動的に付与できる枠組みを提
供する。

2.1 初期学習コーパスの半自動作成

初期の感情分類器学習用コーパスは、柳瀬ら [10] と齋藤

表 1 感情カテゴリ毎の感情語

感情カテゴリ	感情語（シード語）
喜	喜ばしい、面白い、嬉しい、ありがたい 誇らしい、楽しい、幸せ、好き 愛しい、てれくさい、ありがたき、恋しい お祝い、わくわく、うきうき、照れる
信頼	和やか、安らか、冷静、気軽 気楽、頼もしい、好き、懐かしい 愛しい、安心、よろしく、歓迎 恋しい、どうぞ、尊敬、リラックス
怖	気味悪い、心許ない、不気味、気味が悪い 怖い、恐ろしい、不安、心細い ひやひや、気がかり、薄暗い、奇妙 不審、ビビる
驚	心外、意外、憎い、びっくり 感動、感激、失望、驚く ショック、ハッと、素晴らしい、感謝 うとうと、まさか、不意打ち、がっかり
悲	かわいそう、やるせない、悲しい、嘆かわしい 寂しい、虚しい、残念、切ない 後悔、失望、がっかり、一人ぼっち 虚しい
嫌	名残惜しい、鬱陶しい、切ない、嫌 不快、気まずい、物足りない、やりきれない つらい、苦しい、女々しい、だるい ねむい、しつこい、いちいち
怒	腹立たしい、憎い、むかむか、いらいら 苛立つ、むかつく、むしゃくしゃ、恨む ムカつく、イライラ、いちいち、ぶんぶん うるさい、もやもや、ねむい、だるい 腹立つ
予期	歯がゆい、じれったい、もどかしい、不安 心細い、心配、期待、緊張 興奮、そわそわ、待ち遠しい、いよいよ うきうき、どきどき、ドキドキ、わくわく

ら [11] が作成したものを使用している。この構築手順を次
に示す。

- (1) 話し言葉として近い Twitter からツイートデータの取
集を行う。
- (2) 感情語を遠藤ら [14] のルールを参考にして感情表現辞
典から拾い出す。
- (3) Plutchik の分類 [12] に当てはめる形で、各感情語を表
1 のように対応付けを行う。
- (4) 形態素解析エンジン MeCab によって形態素分析を
行う。
- (5) 表 1 のような対応付けを元に感情キーワードが含まれ
る文を収集したツイートデータから 8 感情に分類する。
- (6) 分類された各感情から 1 万行を選び出し、初期の学習
コーパスとする。

本研究では、初期学習コーパスは、1 感情につき 10,000
ツイート（文）、合計で 80,000 ツイート（単語種類数は
36,153）とした。上記の学習用コーパスの半自動生成では、




図 1 初期学習コーパスの精錬処理の流れ

人手による手間はほとんどかからず、表 1 のような表を作成するだけで、ほぼ自動で感情ラベルコーパスが生成できる。しかし、自動で各文に感情ラベルを付与しているため、多くの文に対して間違っただ感情ラベルが付与される可能性が高い。そのため、このようなアノテーション誤りの多いコーパスで感情分類器を学習したとしても、高い分類精度を期待できないおそれがある。そこで、次節において、初期学習コーパスにおいて、感情ラベルが誤っていると想定される文を検出し、それを取り除いていくことで、学習コーパスを精錬していく方法を説明する。

2.2 学習コーパスの精錬

感情分類器の学習コーパスの精錬方法について説明する。図 1 に、初期学習コーパスに対してアノテーション誤りを取り除き、ノイズの少ない学習コーパスを精錬していく流れを示す。

学習コーパスの精錬処理は 3 つのステップから成る。

- (1) まず、初期学習コーパスに対してニューラルネットワークベースの感情分類モデルを学習する (モデルの詳細は 3 節で述べる)。
- (2) 次に、学習セット中の各文に対して、学習した感情分類モデルを適用し、既に各文に付与されている感情ラベルを新しく判定された感情ラベルで更新しなおす (再ラベリング)。
- (3) 最後に、初期学習コーパスから感情ラベルが誤っているような文を取り除く。

(1) の学習では、最大で 20 エポックの学習を行うが、バリデーションセットを用いて、最も良いエポックのモデルを選択するようにしている。(2) の処理において、 l 回目の繰り返しによって再ラベリングし終わった学習コーパスを l 番目の学習コーパスとする。(1) と (2) の処理を L 回繰り返し行うことで、 L 個の学習コーパスが生成できる。 L 個の学習コーパスすべてに同じ文が含まれているが、文の感情ラベルは l の繰り返し回数によって異なることがある。例えば、ある文に着目したとき、そこに付与されている感情ラベルが l 回毎に変化していくようなものは、感情分類器の学習に悪影響があると考え、初期の感情ラベルが誤っていると見なした。 L 回の繰り返しの中で、ある文に対して、1 回でも初期の感情ラベルと異なるラベルが付与されたとすると、本研究では感情ラベルが誤った文として学習

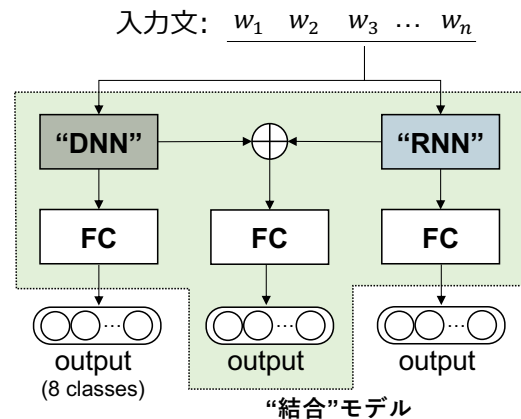


図 2 感情分類モデルの概要図 (結合モデル)

コーパスから取り除く。これによって、コーパス精錬を行い、この精錬後コーパスを用いて感情分類器の学習を行う。

3. 分類モデル

本研究では、感情分類モデルとして、ニューラルネットワークに基づくモデルを用いる。分類モデルの概要図を図 2 に示す。

図 2 に示すように、本稿で扱う分類モデルは、全結合層のみからなるモデル (これを DNN モデルと記す) と再帰層 (今回は LSTM を利用) を用いたモデル (これを RNN モデルと記す) から構成されており、これらの 2 つのモデルの出力を統合した結果に基づいて、感情分類が行われるようになっている (これを結合モデルと記す)。DNN モデルと RNN のモデルの詳細をそれぞれ図 3 と図 4 に示す。なお、これらのモデルの学習はマルチタスク学習を行っている。すなわち、DNN モデルの出力、RNN モデルの出力、結合モデルの出力の損失を計算し、誤差逆伝搬している。以前の我々の研究 [11] によって、DNN モデルと RNN モデルは得意な感情ラベルがあることが分かった。そのため、本稿では、この特徴を活かすために、このようなマルチタスク学習を導入している。

3.1 DNN モデル

図 3 に、分類モデル全体における DNN モデルの部分を示す。入力文であり、エンベッド層では入力された文内の各単語を 128 次元のベクトル表現に変換している。単語ベクトル表現は全結合層に入力し、出力を文ごとに平均化

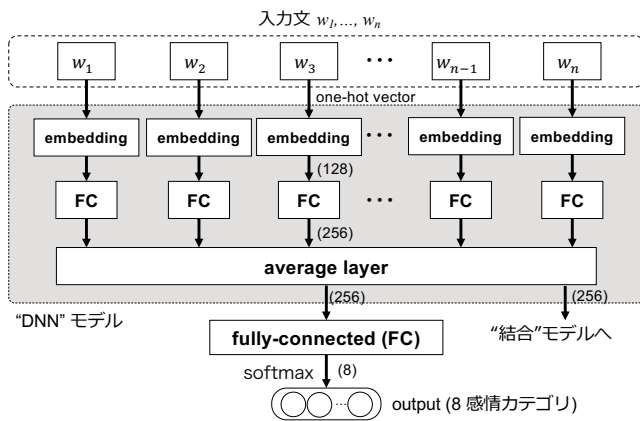


図 3 DNN モデルの概要

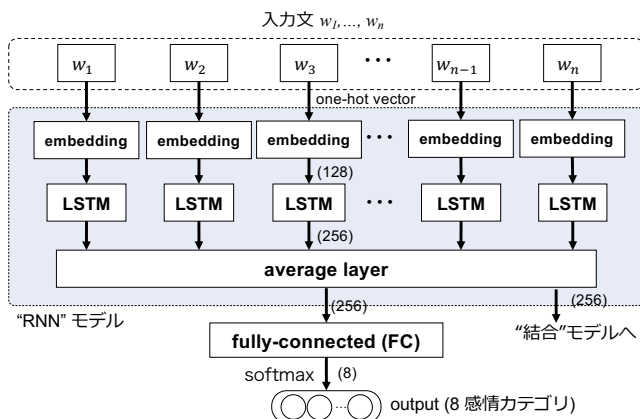


図 4 RNN モデルの概要

する。これにより文の特徴ベクトルへと変換している。全結合出力時には次元は 256 次元に変換を行っている。

3.2 RNN モデル

図 4 に、分類モデル全体における RNN モデルの部分を示す。DNN モデルと同様にベクトル表現に変換する。RNN モデルでは単語ベクトル表現に変換した文を LSTM 層に入力する。LSTM を用いることによって時系列情報を利用することにより精度向上を狙うものである。DNN モデル同様に出力を文ごとに平均化する。

3.3 結合モデル

図 2 に、分類モデル全体図を示す。DNN モデルと RNN モデルから、それぞれの 256 次元の出力を連結した 512 次元のベクトルを全結合層に入力する。最後に全結合層の出力に対してソフトマックスを計算し、交差エントロピー誤差を使用して損失を計算している。全結合層の活性化関数には ReLU を用いており、最適化関数には Adam を用いた。

なお、DNN モデル、RNN モデルの出力もそれぞれソフトマックス交差エントロピーによって損失を計算している。したがって、3つの損失値を考慮して誤差逆伝搬を行っている。

表 2 結合モデルの学習パラメータ

エンベッド次元数	128
出力層	ノード数: 8
中間層	2 層 ノード数: 256
活性化関数	ReLU
損失関数	ソフトマックス交差エントロピー
最適化関数	Adam (初期学習率:0.001)
dropout	0.2 (中間層)
ミニバッチサイズ	128
epoch	20

3.4 最良モデル選択

2.2 節の学習コーパスの精練だけでも、感情分類精度の改善が期待できるが、図 1 と同じ枠組みを使って、さらなるラベルの精練と、分類精度が高くなりそうなモデルの選択を行った。図 5 にその方法を示す。

概ね処理の流れは図 1 と同じであるが、繰り返しごとに全部で L 個のモデルを持っておき、バリデーションセットによって最良のモデルを 1 つ選択する。これを感情分類器としてテストセットで評価する。

3.5 音声認識誤りへの対応

音声認識結果をそのまま感情分類モデルに入力することを考えた場合、音声認識誤りが分類に悪影響を与えてしまうことが想定される。そこで、分類モデルを学習する際に、予め音声認識誤りを想定した学習を行うことで、音声認識誤りに頑健なモデルが学習できるのではないかと考えた。音声認識誤りには、置換・挿入・脱落誤りがあるが、本稿では影響が大きそうな脱落誤りを考慮することとした。

脱落誤り対策として、本稿ではシンプルな方法を採用する。モデル学習時に、入力する単語列をエンベッド層に入力する前に一定の確率でドロップアウトさせ、学習に使わないようにした。これによって擬似的に脱落が起きている状況を作り出しモデルの学習を行った。なお、この脱落対応モデルには図 2 の結合モデルを用いず、図 4 の RNN モデルのみを採用した。入力単語をドロップアウトさせると、マルチタスク学習では学習が上手く進まずモデルが学習できなかったためである。

4. 感情分類実験

提案手法（学習コーパスの精練と音声認識誤り対応モデル）の評価を行った。まず、実験条件を述べたあとに、コーパス精練と音声認識結果に対する実験について述べる。

4.1 実験条件

提案手法を Twitter から取得した感情分類コーパスを利用して評価する。感情カテゴリは Plutchik の感情の輪を基準とした 8 感情カテゴリとしている。前述したように、感情カテゴリごとに 10,000 のツイート文を収集し、初期学習

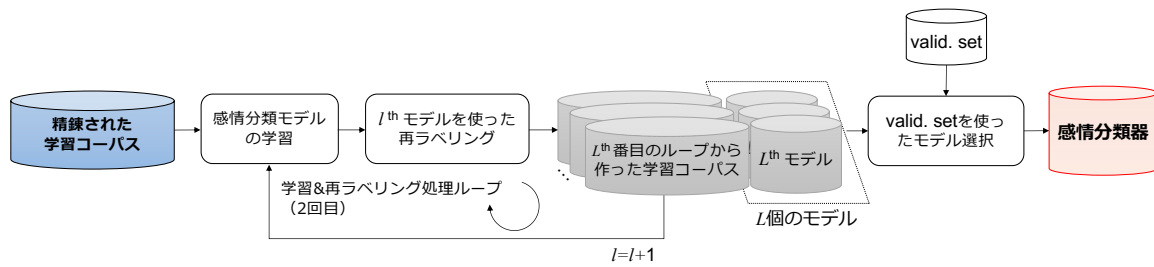


図 5 最良モデルの選択処理の流れ

コーパスは 80,000 文を用意した。

これとは別に、480 のツイート文を用意し、人間によって手動の感情ラベリングを付与した。ラベラーは各文あたり 6 名であり、3 人以上が共通で付与した感情ラベルを正解ラベルとして採用した。480 文中にラベル付与できなかったもの (52 文) を除き、残りの 221 文をバリデーションセット、207 文をテストセットとして用いることとした。バリデーションセットは、図 1 におけるエポック選択と図 5 の最良モデルの選択に用いる。提案手法の評価はテストセットを用いる。モデルの学習時ハイパーパラメータは表 2 に示すとおりである。

音声認識結果を利用する実験では、テキストの感情分類と同様の 207 文のテストセットを用いる。各文を男女各 2 名の 4 名の話者が読み上げた合計 828 発話を音声認識した結果を用いる。音声認識システムには Kaldi を用いた。音響モデルは Kaldi の CSJ レシピを使用したトライフォンモデル、言語モデルは約 10GB の Twitter データから学習した単語トライグラムである。音声認識によってテキスト変換した文字列をそのまま感情分類器へ入力した。

4.2 結果：コーパス精練

分類器への入力テキストである。表 3 に各種モデルに対する感情分類結果を示す。また図 6 に、精練処理の繰り返しごとの分類精度のグラフを示す。

表 3 の「ベースライン」は、初期学習コーパスを使って学習した感情分類器のテストセットに対する分類精度である。「精練コーパス利用」は、図 1 の方法で精練した精練学習コーパスを用いて学習した感情分類器で評価した結果である。「最良モデル自動選択」は、精練学習コーパスを素に、図 5 の方法で選択モデルを選択した場合、最後の「理想モデル」は、バリデーションセットを用いずに最も良いモデルが選ばれた場合の結果である。

ベースライン、すなわち精練処理を一切行わない場合が最も悪い結果となっている。これは、2.1 節で述べた半自動作成の初期学習コーパスに、多くのアノテーション誤りが含まれているからだと推察できる。初期学習コーパスからランダムに 100 文を選択し、人間が感情ラベルを評価したところ、ラベル正解率は 83% であり、多くのラベルミスがあることが分かった。これに対して、精練処理を行うこと

表 3 コーパス精練の効果

モデル	分類精度 [%]
ベースライン (初期学習コーパス)	44.9
精練コーパス利用	55.1
最良モデル自動選択	54.6
理想モデル	58.5

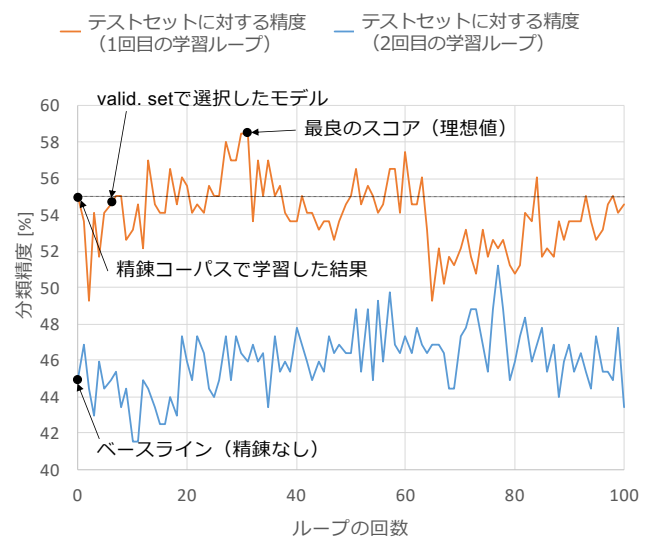


図 6 精練処理の繰り返し毎の分類精度の変化

で、正解率が 87% に改善していることから、精練後のコーパスのラベルの精度が高まっていることが分かった。その結果、精練コーパスを利用して学習した分類器を用いると分類精度が 55.1% となり、ベースラインと比べて分類精度が大幅に向上した。

一方で、最良モデルの自動選択は、それを行わない場合と比べて、若干の精度低下 (54.6%) となった。1 回目の精練処理ループによってある程度の精練ができてしまったと考えられ、2 回目の精練ループでは初期の段階でバリデーションセットに対しては最良の結果が得られてしまったと思われる。しかし、図 6 を見ると、最初の 30 の繰り返しまでは順調に右肩上がりであり、理想的な選択ができれば、最大で 58.5% までは精度の改善が見込まれる。そのため最適なモデル選択基準を求めることができれば、モデル選択によっても感情分類精度を高めることができると考えられる。

表 4 音声認識誤り対応モデルの結果 (分類精度 [%])

	初期コーパス	精練コーパス
ドロップアウト無	49.8	46.4
ドロップアウト有	52.9	54.8

4.3 結果：音声認識誤り（脱落）対応モデル

感情分類器への入力は、音声認識結果のテキストである。表4に、脱落誤りに対応した場合（ドロップアウト有）と対応していない場合（ドロップアウト無）の実験結果を示す。精練処理有無の2種類の学習コーパスに対して、学習時のドロップアウトの有無で評価した。なお今回は、ドロップアウト率は0.15としている。

まず、ドロップアウトの有無に関しては、ドロップアウト処理を入れたほうが分類精度が改善していることが分かる。初期コーパスを使った場合で、49.8%から52.9%へと改善しており、初期コーパスを使った場合でも効果が見られた。精練コーパスを学習に使った場合においても、ドロップアウトを用いたほうが良く、精練コーパスを使った場合も、精練していない初期コーパスを使うよりもさらに改善していることが分かる。このことから、モデルの学習段階で、何かしらの音声認識誤り対策を施しておくことは有効なのではないかと考えられる。今回は、脱落誤りに対応するためにシンプルにドロップアウト処理を入れた。ただ、これは、脱落以外の誤りもカバーされていると考えられる。我々が採用した分類モデルは、図4に示すように入力単語毎に取り出した特徴量を平均化する処理が入っており、この時点で音声認識誤りには頑健である。平均処理が入ることで、置換や挿入誤りが含まれていたとしてもその影響を薄めることができていると考えられるからである。入力単語のドロップアウトは、音声認識の脱落誤りを意図的に生成していると考えられる一方で、ドロップアウトによって様々なバリエーションの文を生成することができているため、この効果も頑健なモデル学習に寄与していたものと考えている。

5. おわりに

本稿では、労力をかけずに半自動的に感情ラベル付き感情分類コーパスを構築する方法を提案した。提案手法では、人間が選んだ感情キーワードから半自動で初期学習コーパスを生成し、このアノテーション誤りを多く含む初期学習コーパスを繰り返し処理によってアノテーション誤りを取り除いていくことでコーパスを精練していく。また、最良モデルを選択する方法も提案した。加えて、音声認識結果を入力とする場合に、認識誤りを考慮する必要があるが、ドロップアウトに基づく脱落誤り対策モデルを提案した。

実験の結果、提案手法による繰り返し精練方法によって、初期学習コーパスから精練コーパスを生成し、これから感情分類器を学習することで、感情分類精度が大きく改善す

ることを示した。一方で、精練手法と同様の最良モデル選択手法は改善しなかったが、潜在的な改善の余地は大きく残っていることも分かった。また、音声認識結果を入力とする感情分類実験においては、提案した脱落誤り対策モデルによって、音声認識結果に対して感情分類精度が改善できることも示した。

今後は、最良モデル選択の方法を検討すること、他の音声認識誤りの種類（置換や挿入）にも対応できるような頑健な感情分類モデルを学習することを考えている。

謝辞 本研究はJSPS 科研費17H01977の助成を受けたものです。

参考文献

- [1] M. Neumann, et al., "Attentive Convolutional Neural Network based Speech Emotion Recognition: A Study on the Impact of Input Features, Signal Length, and Acted Speech," arXiv:1706.00612, 2017.
- [2] W. Lim et al., "Speech emotion recognition using convolutional and Recurrent Neural Networks," Proc. of AP-SIPA ASC 2016, 4 pages, 2016.
- [3] E. Kouloumpis, et al., "Twitter Sentiment Analysis: The Good the Bad and the OMG!," Proc. of the Fifth International AAAI Conference on Weblogs and Social Media, pp.538-541, 2011.
- [4] Y. Ren et al., "Context-Sensitive Twitter Sentiment Classification Using Neural Network," Proc. of AAAI-16, pp.215-222, 2016.
- [5] B. Schuller, et al., "Speech emotion recognition combining acoustic features and linguistic information in a hybrid support vector machine-belief network architecture," Proc. of ICASSP 2014, Vol.I, pp. 577-580, 2004.
- [6] N. Kant, R. Puri, N. Yakovenko, B. Catanzaro, "Practical Text Classification With Large Pre-Trained Language Models," arXiv:1812.01207, 2018.
- [7] C. Baziotis, et al., "NTUA-SLP at SemEval-2018 Task 1: Predicting Affective Content in Tweets with Deep Attentive RNNs and Transfer Learning," Proc. of the 12th International Workshop on Semantic Evaluation, pp.245-255, 2018.
- [8] S. Mohammad, et al., "SemEval-2018 Task 1: Affect in Tweets," Proc. of the 12th International Workshop on Semantic Evaluation, pp.1-17, 2018.
- [9] 栗原理聡, 水本智也, 乾健太郎, "Twitter による評判分析を目的とした評価対象-評価表現データセット作成", 言語処理学会第24回年次大会, pp.344-347, 2018.
- [10] 柳瀬恵里, 西崎博光, "発話内容に着目した音声の感情分類の試行と分析", 日本音響学会春季研究発表会, 1-R-19, pp.141-144, 2016.
- [11] 齋藤友菜, 西崎博光, "音声中の検索語検出を用いた発話内容に着目した音声感情分類", 日本音響学会春季研究発表会, 2-Q-5, pp.145-148, 2018.
- [12] The Nature of Emotions by Plutchik, (online), <<http://www.fractal.org/Bewustzijns-Besturings-Model/Nature-of-emotions.htm>>, (2020-1-20)
- [13] 中村明, 感情表現辞典, 東京堂出版, 1993.5
- [14] 遠藤大介, 齋藤真実, 山本和英, 係り受けを利用した感情生起表現の抽出, 言語処理学会第12回年次大会, P8-8, pp.947-950, 2006.
- [15] 西崎博光, 齋藤友菜, "音声発話の感情分類における音声認識結果を利用する利点", 日本音響学会秋季研究発表会, 1-R-13, pp.985-988, 2018.