

修士論文概要書

Summary of Master's Thesis

Date of submission: 02/01/2019 (MM/DD/YYYY)

専攻名 (専門分野) Department	情報理工・ 情報通信専攻	氏名 Name	盛 舒峰	指 導 教 員 Advisor	渡辺 裕 印 Seal
研究指導名 Research guidance	オーディオビジュ アル情報処理研究	学籍番号 Student ID number	CD 5117F053-1		
研究題目 Title	コミックのセリフの感情分析 Sentiment Analysis on Text of Comics				

1. まえがき

感情分析は、自然言語処理技術の一種である。指定されたテキストを解析し、そのテキストの背景にある思考感情を分析する。具体的には、テキスト作成者の考え方がポジティブか、ネガティブか、ニュートラルかを判断する (図 1)。テキストの文字情報から作成者の感情を自動的に分析できれば、より円滑な意思疎通が得られると考えられる。

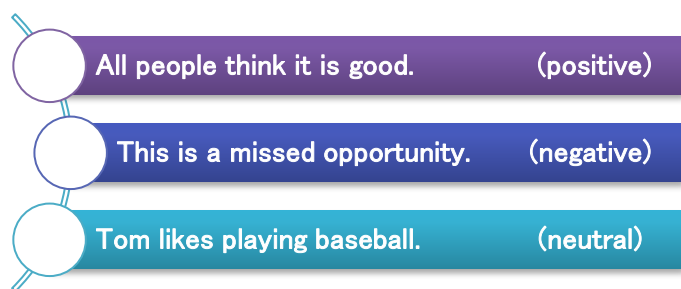


図 1 感情分析の例

近年、電子コミック市場が急速拡大し、多くの注目を集めている。電子コミックは電子書籍市場の 80% を超え、将来的にもさらに拡大する見込みである。そこで、電子化されたコミックのセリフの感情を計算機で自動的に分析することができれば、読者がコミックを読む際に、コミックの登場人物の感情を十分に把握できる。これにより、読者が作品をよりよく理解でき、電子書籍の高機能化に有効であると考えられる。以上から本研究では、コミックのセリフの感情分析を目的とする。

2. 関連研究

テキストの感情分析については、すでに多くの研究がある。dos Santos, Gatti らは、文章レベルの情報から短文の感情分析を行う新しい深層畳み込みニューラルネットワークを提案した。彼らは、映画レビューの文を含むスタンフォード感情ツリー (SSTb) と Twitter メッセージを含む Stanford Twitter Sentiment corpus (STS) という異なる二つのコーパスを利用して分析を行った。

また、Stojanovski らは、dos Santos らと違って、様々なウィンドウサイズを持つ複数のフィルタを持つ

畳み込みニューラルネットワークを使用した[1]。その下に二つの全結合層 (それぞれ Dropout と Softmax を使用) を追加した深層畳み込みニューラルネットワークを用いて、Twitter メッセージの感情分析を行った。ニューラルネットワークを適用する前に、あらかじめ単語を単語ベクトルに変換される。手動でテキストの特徴を抽出する代わりに密な単語ベクトルを利用し、ニューラルネットワークの学習と共にテキストの特徴を自動的に抽出して感情分析を行った。

3. 提案手法

3.1 データの収集

本研究では英語のコミックの感情分析と日本語の漫画の感情分析両方を行うために、それぞれのデータセットを準備した。英語のデータセットについては Snoop のコミックから 900 のセリフを収集した後、登場人物の発言順に従って整理する。それぞれのコミックのセリフの感情状態を 3 種類のパターン、積極的・中性的・消極的 (Positive/Neutral/Negative) で分類した。また、日本語のデータセットについては、Manga109[2] というデータセットを利用し、1350 の文を選択して、分析データとして利用した。

3.2 形態素解析

英語、フランス語、スペイン語のような言語は単語間に空白が入って自然に分かち書けるが、日本語は分かち書きされずに書かれる。明らかな境界が存在しない日本語のテキストに対して自然言語処理を実行するためには、単語間の境界を明確に指定する必要がある。この問題を解決するために、形態素解析技術を利用する。形態素解析とは、自然言語を一つ一つの形態素に分割する技術である。ここで形態素とは、言葉が意味を持つまとまりの単語の最小単位である。

3.3 Word2vec

ニューラルネットワークを用いて自然言語処理を行うために、自然言語で記述されたデータを数値に変換する必要がある。本実験では word2vec[3] を使用した。Word2Vec でコミックスのセリフ各単語を 100 次元の対応するベクトル表現に変換した。

3.4 VADER

VADER は、2014 年に提案された感情分析の手法である[4]。ソーシャルメディアのテキストに対して高い分析力を持っているが、VADER を用いたセリフの感情分析はまだ検討されていない。本研究では、VADER を

利用し、英語のコミックのセリフの感情分析を実行し分析を行う。

3.5 CNN

畳み込みニューラルネットワーク (CNN) は画像認識で注目されている手法である。CNN は画像を抽象化する能力を持っているため、今回の実験では CNN がテキストベクトルに対して有効かどうか検討した。

3.6 RNN

リカレントニューラルネットワーク (RNN) は可変長データをニューラルネットワークで扱う手法である。隠れ層の値を再び隠れ層に入力する構造を持つ。RNN はすでに自然言語処理に幅多く利用されている。今回使用したコミックのセリフには長い文字列が存在するため、短いシーケンスに適する単純 RNN を利用するばかりでなく、長いシーケンスの学習に適した LSTM と GRU を用いて感情分析の実験を行った。

3.7 CNN と RNN の併用

コミックの画像にはセリフが持たない情報があるため、セリフのテキストだけでなく、コミックの画像も考慮しながら、感情分析を行う手法も考えられる。今回、セリフに対応する人物の顔画像から、CNN を利用して顔画像の特徴を抽出し、その特徴ベクトルとテキストベクトル両方を RNN に入力し、感情分析を行った。

3.8 Bi-directional RNN

Bi-directional RNN は、過去の情報だけでなく、未来の情報も考慮することで予測精度を向上させるための手法である。今回の実験ではこの手法も用いてコミックのセリフの感情分析を行った。

3.9 多層 LSTM と多層 GRU

多層 LSTM は LSTM block を積み重ねて深層化したモデルであり、単純な LSTM より更に複雑な構成となる。LSTM block を GRU block に入れ替えると、多層 GRU となる。今回の実験では、感情分析における多層 LSTM と多層 GRU による分析も加えた。

4. 実験結果

今回の実験では、VADER, CNN, RNN (LSTM と GRU), CNN+RNN, Bi-directional RNN などの手法を適用して、作成したデータセットに対して感情分析を行った。その実験結果を表 1, 2 に示す。

表 1 英語のセリフの感情分析の結果

手法	精度(%)
Vader	43.33
CNN	65.56
RNN (LSTM)	72.22
RNN (GRU)	70.55
CNN+RNN	71.67
Bidirectional LSTM	72.22
多層 LSTM	73.33
多層 GRU	74.44

多層 LSTM と多層 GRU はそれぞれ 73.33% と 74.44% の精度に達した。Bidirectional LSTM も 72.22% の精度に達し、Vader, CNN より高い値を示した。また、単純に CNN を使用する場合に比べて、CNN

と RNN のマルチモーダルな併用が、精度の向上に貢献することが分かった。しかし、使用したデータが小規模であったり、セリフの感情に関連する顔画像が不十分であると CNN と RNN の併用は単純な RNN (LSTM または GRU) より精度が低いことが分かった。

日本語のテキストでも、RNN (LSTM または GRU) は CNN より精度が高い。更に、LSTM と比較してみれば、GRU の方が、精度が高いことが分かった。

表 2 日本語のセリフの感情分析の結果

手法	精度(%)
CNN	43.33
RNN (LSTM)	46.29
RNN (GRU)	52.22
Bidirectional LSTM	49.25
Bidirectional GRU	50.00
多層 LSTM	49.63
多層 GRU	50.37

5. むすび

本研究では、自然言語処理に適したニューラルネットワークを用いて、コミックのセリフの感情分析を行った。英語のコミックと日本語の漫画に含まれるセリフに対して感情分析を行った結果、すべての手法においてランダム予測に相当する 33.3% 以上が得られた。このことから、ディープラーニング手法がコミックのセリフの感情分析に有効であるといえる。

英語のコミックの感情分析の結果では、多層 LSTM と多層 GRU はそれぞれ 73.33% と 74.44% の精度に達した。RNN は時系列処理が可能なニューラルネットワーク構造のため、自然言語処理においては VADER, CNN より適すると考えられる。また、単純に CNN を使用する手法に比べて、CNN と RNN のマルチモーダルな併用が精度の向上に貢献することが分かった。

ただし、今回使用したデータセットは小規模である、多くの自然言語の特徴を学習できていない。また、トレーニングデータの特徴とテストデータの特徴も必ずしも一致していないという問題がある。今後の課題として、より多くのデータを収集し、豊富な自然言語の特徴を利用して学習する必要があると考えられる。

参考文献

- [1] D. Stojanovski, G. Strezoski, G. Madjarov, and I. Dimitrovski, "Twitter Sentiment Analysis using Deep Convolutional Neural Network," HAIS, 2015.
- [2] Y. Matsui, K. Ito, Y. Aramaki, A. Fujimoto, T. Ogawa, T. Yamasaki, K. Aizawa, "Sketch-based Manga Retrieval using Manga109 Dataset", Multimedia Tools and Applications, Springer, 2017.
- [3] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space," ICLR, 2013.
- [4] C. J. Hutto, and Gilbert, "VADER: A Parsimonious Rule-based Model for Weblogs and Social Media," ICWSM, 2014.

2018 年度 修士論文

コミックのセリフの感情分析
Sentiment Analysis on Text of Comics

提出日 2019 年 2 月 1 日

指導教員 渡辺 裕 教授

早稲田大学大学院 基幹理工学研究科

情報理工・情報通信専攻

5117F053-1

盛 舒峰

目次

1	序論	4
1.1	研究背景.....	4
1.2	研究目的.....	5
1.3	本論文の構成.....	6
2	関連研究	7
2.1	まえがき.....	7
2.2	感情分析の先行研究.....	7
2.3	VADER.....	7
2.4	むすび.....	8
3	英語のセリフの感情分析	9
3.1	まえがき.....	9
3.2	テキストデータの収集.....	9
3.3	単語のベクトル化.....	10
3.4	感情分析の手法.....	11
3.4.1	VADER.....	11
3.4.2	CNN.....	12
3.4.3	RNN.....	13
3.4.4	多層LSTM.....	14
3.4.5	Bidirectional RNN.....	14
3.4.6	CNNとRNNの併用.....	15
3.5	実験結果.....	15

3.6	むすび	17
4	日本語のセリフの感情分析	18
4.1	まえがき	18
4.2	セリフの収集	18
4.3	日本語の形態素解析	19
4.3.1	MeCab	20
4.3.2	Janome (蛇の目)	21
4.3.3	JUMAN と JUMAN++	21
4.4	日本語のベクトル化	22
4.5	感情分析の手法	22
4.6	実験結果	22
4.7	むすび	23
5	結論	24
6	謝辞	25
7	参考文献	26
8	図一覧	28
9	表一覧	29

1 序論

1.1 研究背景

人間が日常的に話し聞き、読み書きしている言語は、長い期間をかけて人々の生活の中で徐々に変化し進化してきた。このような自然的に誕生した言語は「自然言語」と呼ばれる。ここで「自然言語」とは、日本語や英語などの、人間がコミュニケーションや思考の道具として用いる言語である。プログラミング言語、マークアップ言語などの人工言語は自然言語ではない。

自然言語処理は、コンピュータプログラムを用いて自然言語を処理する技術である。自然言語処理にはテキスト編集、情報検索、機械翻訳など多くの分野がある。図 1.1 に示すような自然言語処理技術は、人々の生活を支えている[1]。



図 1.1 自然言語処理の主な分野

自然言語処理には、理論的な目的と実用的な目的がある。理論的な目的は、言葉を使う能力を解明することによって、人間の知能の仕組みを理解する手掛かりを得るという認知科学の観点に基づく。また、人工知能の観点、言語の体系自体とそれに関する計算処理のさらなる深い理解を目指す計算言語学の分野の観点がある。

一方、実用的な目的としては、データの検索や整理・保存などの基本的なデータ処理がある。更に、文章の意味の抽出や異なる言語間での翻訳、対話システム、文章の真の意味の理解など、自然言語の特性に基づく高度な処理も含む[2]。

感情分析は、自然言語処理技術の一種である。指定されたテキストを解析し、そのテキストの背景にある思考感情を分析する。具体的には、テキスト作成者の思考がポジティブか、ネガティブか、ニュートラルかを判断する(図 1.2)。テキストの文字情報から作成者

の感情を自動で分析できれば、より円滑な意思疎通が得られると考えられる。感情分析は、コンピューターサイエンスのみでなく、社会学、マーケティング、心理学、エコノミクス、政治学などの分野の問題の解決に役立つ。例えば、ブログやレビューでの利用者の全体的な意見の評価や、ある商品に対する消費者の態度の調査に感情分析の手法が適用できる。




図 1.2 感情分析の例

自然言語処理の問題を解決するために、現在、機械学習の手法、特に深層学習（ディープラーニング）が利用されている。ディープラーニングはニューラルネットワークを基盤としており、目的に応じて様々な構造のニューラルネットワークが用いられるが、最も単純なニューラルネットワークは入力層、中間層（隠れ層）、出力層の3層からなる階層型ニューラルネットワークである。他には、CNN、RNNなどのニューラルネットワークも存在している。

ディープラーニングは、多層のニューラルネットワークを用いる学習方法である。深層学習は画像認識や音声認識などのデジタルデータを入力とするタスクにおいて大きな効果を発揮する。自然言語は文字と文字列の体系であるため、画像や音声の処理とは異なり、特別な工夫が必要である。そこで、系列変換モデル、アテンション、LSTMなどの技術が提案され、機械翻訳や文書要約、対話システムなど、様々な自然言語処理タスクに応用されるようになってきている。

1.2 研究目的

近年、インターネットの普及や携帯端末の発達とともに、電子書籍の市場規模が紙による出版の市場規模を上回っている。電子書籍市場では、電子コミックの占める割合が大きい。電子コミック市場は2015年度には1845億円の規模である。2014年度より14%増加し、電子書籍市場全体の82%を占める。伸び率でも文芸・実用書・写真集などを上回っている[3]。そのため、電子コミック市場の急速拡大は多くの注目を浴びている。したがって、電子化されたコミックのセリフ感情分析を自動で行うことができれば、読者がコミックを読む際に、コミックの登場人物の感情を十分に把握でき、作品をより良く理解するこ

とに役に立つと考えられる。以上のことから本研究では、コミックのセリフの感情を分析することを目的とする。

1.3 本論文の構成

以下に本章以降の論文の構成を示す。

- 第1章 本章であり，研究背景及び研究目的について述べる。
- 第2章 関連研究に関して述べる。
- 第3章 英語のコミックの感情分析について述べる。
- 第4章 日本語のコミックの感情分析について述べる。
- 第5章 本研究のまとめを行う。

2 関連研究

2.1 まえがき

本章では、本研究での感情分析に関連する先行技術を述べる。

2.2 感情分析の先行研究

テキストの感情分析は機械学習を利用する研究が多い。Bhavitha ら[4]は、複数の機械学習の手法を組み合わせることで感情分析することによって、レビュー及び新発売される製品に対する消費者の全体的な嗜好を予測するのに有効であることを検証した。彼らは様々な機械学習の技術の精度、利点及び限界を比較し、教師なし学習手法よりも教師あり機械学習手法を使用する方が、予測精度が高いことを示した。

Cicero Nogueira dos Santos, Maira Gatti ら[5] は、文章レベルの情報から短文の感情分析を行う新しい深層畳み込みニューラルネットワークを提案した。彼ら、映画レビューを含むスタンフォード感情ツリー (SSTb) と Twitter メッセージを含む Stanford Twitter Sentiment corpus (STS) という異なる二つのコーパスを利用して分析を行った。その結果、SSTb データセット上の 2 分類感情分析の精度は 85.7%に達し、5 分類感情分析の精度は 48.3%であった。また、STS データセット上の 2 分類感情分析の精度は 86.4%に達した。この研究結果はニューラルネットワークが感情分析に有効であることを示している。

また、Dario Stojanovski, Gjorgji Strezoski ら[6] は、dos Santos らと異なり、様々なウィンドウサイズを持つ複数のフィルタを持つ畳み込みニューラルネットワークを使用した。二つの全結合層（それぞれ Dropout と Softmax を使用）を追加した深層畳み込みニューラルネットワークを用いて、Twitter メッセージの感情分析を行った。ニューラルネットワークを適用する前に、教師なし学習の手法を用いている。あらかじめ単語は単語ベクトルに変換される。手動でテキストの特徴を抽出する代わりに密な単語ベクトルを利用し、ニューラルネットワークの学習と共にテキストの特徴を自動的に抽出して感情分析を行った。その結果、SemEval 2015 データセット上の 3 分類感情分析の精度は 66.44%に達した。この結果は教師なし学習の使用が精度の向上に貢献したことを示している。

2.3 VADER

VADERはC.J. HuttoとEric Gilbert [7] がICWSM-14で提案した感情分析の手法である。彼らはTwitterやFacebookなどのソーシャルメディア上のテキストにおける感情分析を目指していた。しかしソーシャルメディアのテキストデータ自体は短く文脈も少ない。また、感情を表現するために省略形の言語慣習を使用する傾向が多いという様々な問題が存在している。

そのため、彼らは定性的方法と定量的方法を組み合わせて、ソーシャルメディア上のテキストに特化した基準となる感情辞書を作成し、それにより検証を行った。その際に sentiment word bank, LWC, ANEW, GI などさまざまな言語資源から語彙を収集し、全部で 9000 語彙を準備した。さらに、Amazon Mechanical Turk (AMT) を利用して評価者を募

集し、文の positive/negative の度合いを[-4,+4]の範囲の中で評価した。AMT を使うにあたって評価品質を揃えるため、大学レベル以上の英語読解能力を持つ人に絞り、事前にテキスト感情の採点のトレーニングなどを受けさせた。あらかじめ分布を計算した特定の単語よりかけ離れたレートをつける人のデータは使わず、大多数の人が選んだレートを重視し、無効な語彙を削るなど外れ値の除去を試みた。

次に、感情の強さを表現したり強調したりする際に、人間が使用する文法のおよび構文的な習慣を具現化する一般的な五つのルールを考慮して、感情辞書の単語の特徴を組み合わせた。

最後に、この手法を利用して複数のテキストデータセット（ソーシャルメディアのテキスト、NY Times の社説、映画のレビュー、製品のレビューなど）上の感情分析を行なった結果、従来の感情分析の研究と比較して分析精度が向上することがわかった。特に VADER はソーシャルメディアのテキストに対して非常に優れた性能を発揮する。相関係数は、VADER ($r=0.881$) が普通の人間が判断する結果（各ツイートの感情強度については、20 人の人間の評価者の結果から集計された平均値を利用した）($r=0.888$) とほぼ同じ性能を示している。分類の精度を更に調べると、4200 ツイートの感情をポジティブ、ニュートラル、またはネガティブのクラスに正しく分類する際に、VADER ($F1 = 0.96$) は、実際の人間の評価者 ($F1 = 0.84$) より高い精度に達する。

	Correlation to ground truth (mean of 20 human raters)	3-class (positive, negative, neutral) Classification Accuracy Metrics			Ordinal Rank (by F1)		Correlation to ground truth (mean of 20 human raters)	3-class (positive, negative, neutral) Classification Accuracy Metrics		
		Overall Precision	Overall Recall	Overall F1 score				Overall Precision	Overall Recall	Overall F1 score
Social Media Text (4,200 Tweets)						Movie Reviews (10,605 review snippets)				
Ind. Humans	0.888	0.95	0.76	0.84	2	1	0.899	0.95	0.90	0.92
VADER	0.881	0.99	0.94	0.96	1*	2	0.451	0.70	0.55	0.61
Hu-Liu04	0.756	0.94	0.66	0.77	3	3	0.416	0.66	0.56	0.59
SCN	0.568	0.81	0.75	0.75	4	7	0.210	0.60	0.53	0.44
GI	0.580	0.84	0.58	0.69	5	5	0.343	0.66	0.50	0.55
SWN	0.488	0.75	0.62	0.67	6	4	0.251	0.60	0.55	0.57
LIWC	0.622	0.94	0.48	0.63	7	9	0.152	0.61	0.22	0.31
ANEW	0.492	0.83	0.48	0.60	8	8	0.156	0.57	0.36	0.40
WSD	0.438	0.70	0.49	0.56	9	6	0.349	0.58	0.50	0.52
Amazon.com Product Reviews (3,708 review snippets)						NY Times Editorials (5,190 article snippets)				
Ind. Humans	0.911	0.94	0.80	0.85	1	1	0.745	0.87	0.55	0.65
VADER	0.565	0.78	0.55	0.63	2	2	0.492	0.69	0.49	0.55
Hu-Liu04	0.571	0.74	0.56	0.62	3	3	0.487	0.70	0.45	0.52
SCN	0.316	0.64	0.60	0.51	7	7	0.252	0.62	0.47	0.38
GI	0.385	0.67	0.49	0.55	5	5	0.362	0.65	0.44	0.49
SWN	0.325	0.61	0.54	0.57	4	4	0.262	0.57	0.49	0.52
LIWC	0.313	0.73	0.29	0.36	9	9	0.220	0.66	0.17	0.21
ANEW	0.257	0.69	0.33	0.39	8	8	0.202	0.59	0.32	0.35
WSD	0.324	0.60	0.51	0.55	6	6	0.218	0.55	0.45	0.47

図 2.1 VADER とほかの感情分析手法の比較

VADER は多くのテキストの感情分析に対応できると判断できる。したがって、本研究は VADER を利用してコミックのセリフの感情分析を行った。

2.4 むすび

本章では、感情分析に関連する先行研究について述べた。

3 英語のセリフの感情分析

3.1 まえがき

本章では, VADER, CNN, LSTM, GRU, CNN+RNN, Bidirectional LSTM, 多層 LSTM, 多層 GRU の 8 種類のニューラルネットワークを用いて, 英語のコミックに含まれるセリフの感情分析を行い, 実験結果について述べる.

3.2 テキストデータの収集

本章では, 英語のコミックの感情分析を目指す. まず, **Snoopy** 第 7 巻のセリフを収集し, それぞれのコミックのセリフに対して感情状態を 3 種類のパターン, 積極的・中性的・消極的 (Positive/Neutral/Negative) に分類する. さらに, セリフを話す登場人物の顔画像を手動で収集した. 最後に, 収集した全てのセリフの中から 900 文をデータセットとして利用した. これらの比率を図 3.1 に示す. またセリフの例を表 3.1 に示す.

表 3.1 コミックのセリフの例

Positive 例	I HOPE YOU HAVE A GOOD TIME
Neutral 例	HERE WE GO FOR THE FIRST HOCKEY GAME OF THE SEASON
Negative 例	HEY, STUPID! THERE'S NO ONE AROUND TODAY

今回の研究では, 収集したデータをトレーニングデータ : テストデータ = 8 : 2 の比率になるように分割した.

スキャンにより収集したセリフデータには不要なデータが混在するため, 前処理を施す必要がある. 例えば, セリフの中で無意味な符号を削除した. また, セリフの中の数字を全部 0 に変換した. 次に, 処理したテキストを空白で区切り, 一つ一つの単語に分割した. この処理は形態素解析と呼ばれる.

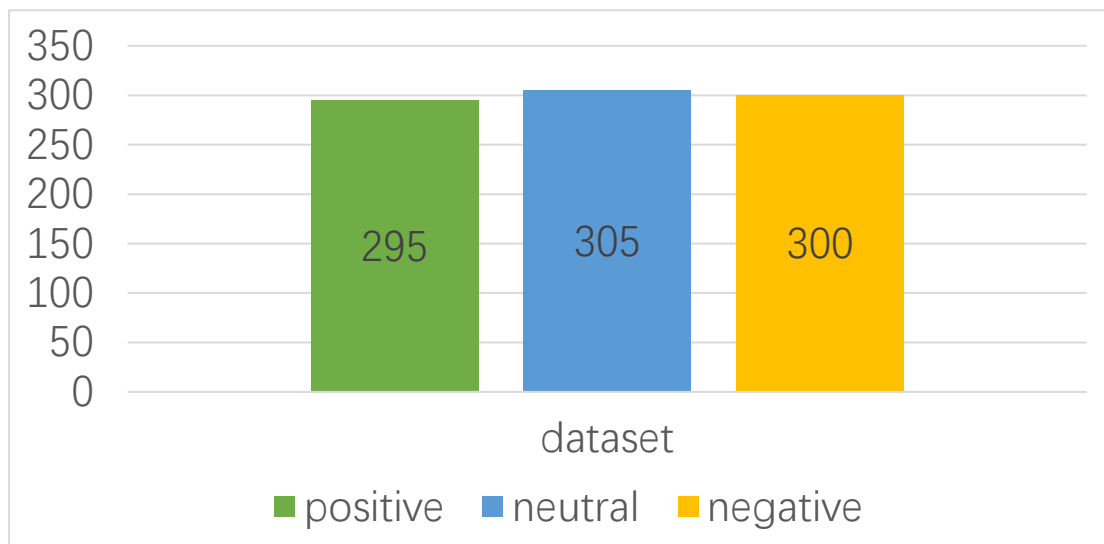


図 3.1 コミックのセリフのデータセット数

3.3 単語のベクトル化

ニューラルネットワークを用いて自然言語処理を行うために、自然言語で記述されたデータを数値に変換する必要がある。この問題を解決するために、単語の分散表現が用いられる。単語の分散表現とは、大規模なデータセットとニューラルネットワークを用いた学習によって得られる単語の意味を表すベクトルである。分散表現は数百次元と比較的に低次元のベクトルである。また、各成分が0以外の実数値を取る密ベクトルである。各単語を実ベクトル空間に埋め込むと考えることができるため、単語の分散表現は単語埋め込みとも呼ばれる。

単語の分散表現は、2013年にGoogle社のTomas Mikolov [8]が発表した論文とその内容を実装したWord2vecというツールの公開を契機として、広く注目を集めるようになった。この手法は単語間の意味的关系を高い精度で扱えるため、現在では構文解析や意味解析などの解析技術から情報検索や機械翻訳などの分野まで幅広く応用されている。

基本的なアイデアは、ある単語の意味を表すために、その単語と同じ文脈に出現する共起語を数えることの代わりに、どのような単語が共起語として出現するかを予測するようにニューラルネットワークを学習させるというものである。更に、Word2vecを利用して得られた同じ文脈に出現する共起語の分散表現と単語の分散表現の空間距離が近いという特徴がある。

本研究の実験ではWord2vecを使用した。すでに整理されたセリフのデータをWord2vecで100次元の対応するベクトル表現に変換した。Word2vecを利用する際に、様々なパラメタを調整して次元数が異なる単語ベクトルを得ることも可能である。今回の実験で調整したパラメタの値を表3.2に示す。

表 3.2 Word2vec で単語ベクトルを作成する際のパラメタ

ベクトル次元数	100
コンテキストの数	5
ベクトル最小値	0.001
単語の最小出現頻度	1

Word2vec で単語ベクトルの変換が終了すれば単語のベクトル辞書が得られる。ある単語を検索すると、出力として 100 次元のベクトルが得られる。このベクトルをニューラルネットワークの学習と予測に用いる。Word2vec で作成した単語ベクトルの例を図 3.2 に示す。

```

it_0.126487_0.134175_-0.168619_-0.587328_0.403284_
of_0.175318_0.174817_-0.215463_-0.759960_0.520261_
in_0.178858_0.176450_-0.218516_-0.786816_0.538674_
is_0.140245_0.144362_-0.179862_-0.638486_0.441717_
my_0.151654_0.164006_-0.197717_-0.701463_0.483872_
that_0.137845_0.137306_-0.172335_-0.594744_0.40971
have_0.116365_0.126230_-0.151350_-0.562089_0.38504
me_0.128603_0.139949_-0.171722_-0.593722_0.411810_
your_0.151205_0.163393_-0.191677_-0.693250_0.47736
if_0.110347_0.110866_-0.143557_-0.505148_0.345907_
for_0.150308_0.153426_-0.184533_-0.661050_0.454052
what_0.090085_0.096861_-0.115015_-0.412559_0.28409

```

図 3.2 Word2vec で作成した単語ベクトル

3.4 感情分析の手法

3.4.1 VADER

第 2 章で述べたように、VADER は感情分析に有効な手法である。ソーシャルメディアで出現するテキストに対して高い分析力を持つことが知られている。しかし、VADER を用いたコミックのセリフの感情分析はまだ実験されていない。現在、VADER が Python のモジュールに導入されており、Python の環境下で簡単に利用できる。本研究では VADER を利用し、多くのコミックのセリフ感情分析を実行し、感情分析の精度を求めた。

```
>>> vader_analyzer.polarity_scores('I am happy')
{'compound': 0.5719, 'neg': 0.0, 'neu': 0.213, 'pos': 0.787}
```

図 3.3 VADER の使用例

VADER が出力した結果の中で、「neg」、「neu」、「pos」の後にある値はテキストの感情がこの種類に分類される可能性を示している。可能性が最も高い感情種類をテキストの感情にする。VADER の使用例を図 3.3 に示す。

3.4.2 CNN

畳み込みニューラルネットワーク (CNN) は画像認識において注目されている手法である。畳み込みニューラルネットワークの畳み込み層は、入力に対して畳み込み計算を行う人工ニューロン層である。畳み込み計算とは、入力データの一部を取り出して適当な計算を行う作業を、入力データの全域にわたって繰り返す計算処理である。畳み込み計算によって、同じ計算処理を入力データ全体にわたって繰り返すことで、入力データのある特徴を強調する。

CNN は画像を抽象化する能力を持っている。そこで、今回の実験では CNN がテキストベクトルに対して有効であるかどうか検証した。

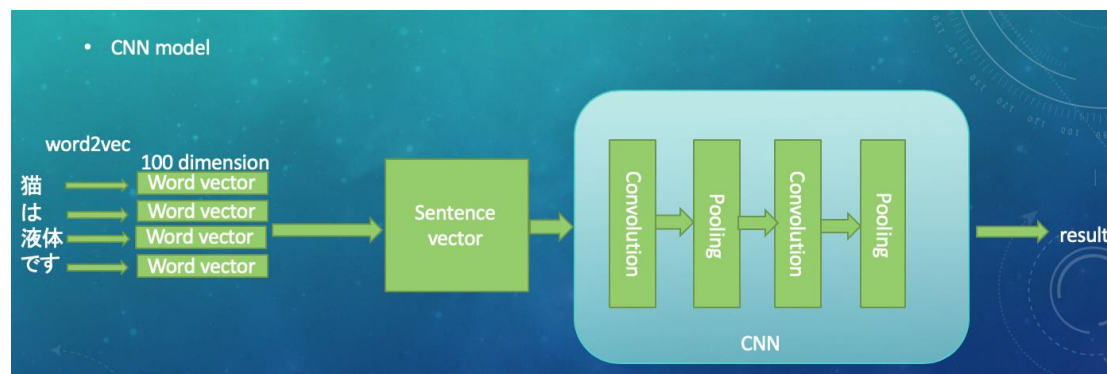


図 3.4 CNN を利用する感情分析処理

今回の実験では、まず、先に Word2vec によって得られた多くの単語のベクトルを一つの文ベクトルに組み合わせる。CNN に文ベクトルを入力する際に、文の長さを予め決定し全ての文を同じ長さにしなければならない。文の長さを 30 とした。30 個以上の単語を持つテキストは 30 番以降の単語を全部削除して、テキストの長さを揃えた。また、30 個以下の単語しか持たないテキストの場合、後ろに 100 次元の零ベクトルを詰め込み、長さを 30 まで増加させた。更にこれらの文ベクトルをニューラルネットワークに入力して、畳み込み層とプーリング層によって特徴を抽出して、最後にテキストの感情の分析結果を出力する。CNN を利用する感情分析処理を図 3.4 に示す。

3.4.3 RNN

人間は本や新聞などを読む際に、前の単語の理解に基づいて次の単語を理解する。しかし従来のニューラルネットワークは、持続性を持って学習を行うことができない。そこで、リカレントニューラルネットワーク (RNN) が提案された。リカレントニューラルネットワークは内部に伝搬処理構造を持ち、過去に入力した情報を反映させることができるネットワークである。

自然言語処理の問題を扱う際には、文脈を考慮することがかなり重要である。ニューラルネットワークでテキストの文脈を扱うためには、ある時点でニューラルネットワークに入力された単語だけでなく、過去に入力された単語に関する記憶も扱う必要がある。

リカレントニューラルネットワークは可変長データを内部で扱う。隠れ層の値を再び隠れ層に入力する構造である。リカレントニューラルネットワークは過去の入力に関する処理内容をネットワーク内部に記憶し、新たな入力データに対する処理を行う際に、過去の処理内容を加味して処理を行うことができる。RNN を利用する感情分析処理を図 3.5 に示す。

リカレントニューラルネットワークはすでに自然言語処理に幅多く利用されている。今回の実験で RNN を利用してコミックのセリフ感情分析を行った。

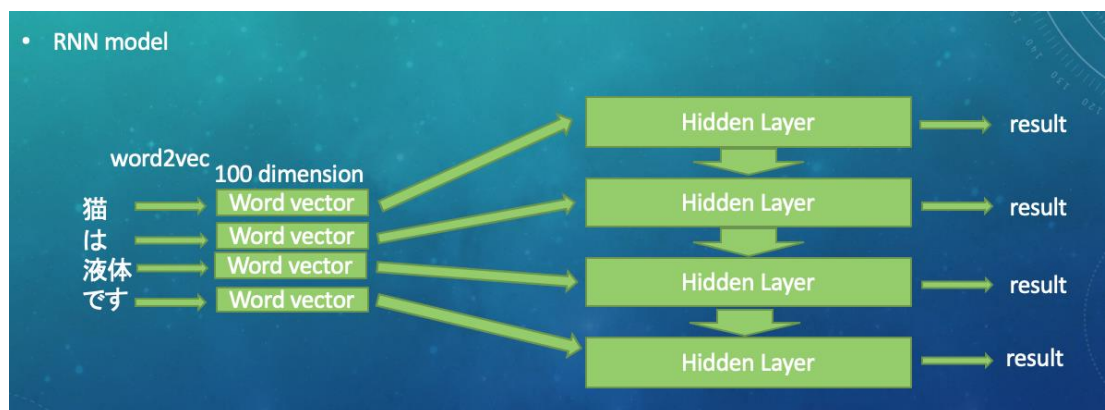


図 3.5 RNN を利用する感情分析処理

ところで単純 RNN はテキストが数十の単語しかない場合は対応可能である、長いテキストに対しては勾配消失問題が発生し、学習ができなくなる。これは、単純 RNN の長期依存性問題と呼ばれる。この問題を解決するために、Long Short Term Memory (LSTM) が考案された。LSTM は長期的な依存関係を学習することのできる RNN の特別な一種である。LSTM には、3 種類のゲートが存在して、それぞれ忘却ゲート、入力ゲートと出力ゲートである。この構造によって、LSTM は長い入力系列の学習の際に生じる勾配消失問題の緩和に成功している。

さらに、Gated Recurrent Unit (GRU) と呼ばれるニューラルネットワークも提案されている。GRU は忘却ゲートと入力ゲートを単一の更新ゲートに組み合わせる。他には様々な改善を行う。その結果、GRU は LSTM よりもっとシンプルなモデルとなり、勾配消失問題にも対応できる。

今回使用したコミックのセリフには長い文字列が存在するため、短いシーケンスに適する単純 RNN を利用するばかりではなく、LSTM と GRU を用いて感情分析を行った。

RNN を利用する感情分析処理を図 3.5 に示す.

3.4.4 多層 LSTM

また, 多層 LSTM (Stacked LSTM) は LSTM の block を多層に重ねて深層化したモデルであり, 単純な LSTM より更に複雑な構成となる. LSTM の block を GRU の block に入れ替えると, 多層 GRU となる. 今回の実験では, 感情分析における多層 LSTM と多層 GRU の分析についても検証した. 多層 LSTM を利用する感情分析処理を図 3.6 に示す.

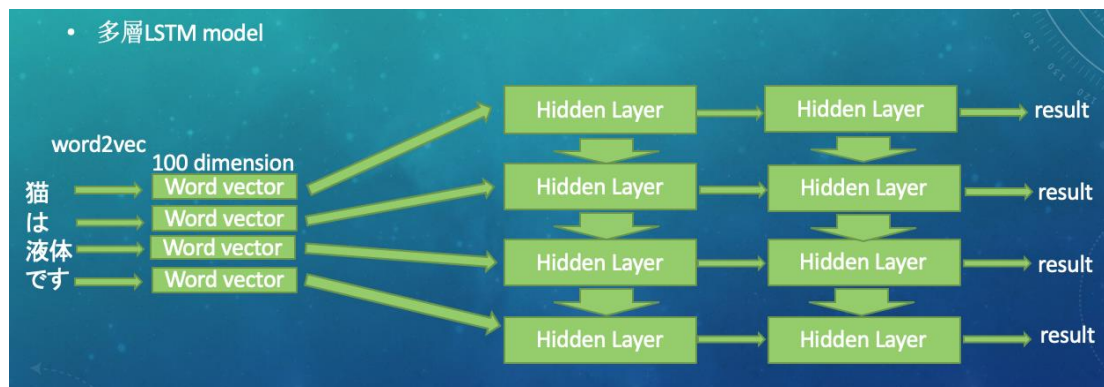


図 3.6 多層 LSTM を利用する感情分析処理

3.4.5 Bidirectional RNN

Bidirectional RNN は, RNN を基づいて提案された手法である. シーケンスの過去の情報だけでなく, 未来の情報も考慮することで予測精度を向上させる手法である. 今回の実験ではこの手法も用いて, 双方向の LSTM モデルを構築しコミックのセリフ感情分析を行った. Bidirectional RNN を利用する感情分析処理を図 3.7 に示す.



図 3.7 Bidirectional RNN を利用する感情分析処理

3.4.6 CNN と RNN の併用

コミックの画像にはセリフで表現できる以外の感情表現があると考えられる。コミックのセリフとレビューのコメントの大きな違いは、コミックは画像とセリフの併用で感情を示すのに対し、レビューではテキストのみの分析で感情が示される。したがって、セリフのテキストだけでなく、コミックの画像も考慮しながら、感情分析を行う必要があると考えられる。今回、セリフに対応する人物の顔画像から、CNN を利用して顔画像の特徴を抽出し、その特徴ベクトルとテキストベクトル両方を RNN に入力し、感情分析を行った。CNN と RNN を併用するマルチモーダル感情分析処理を図 3.8 に示す。

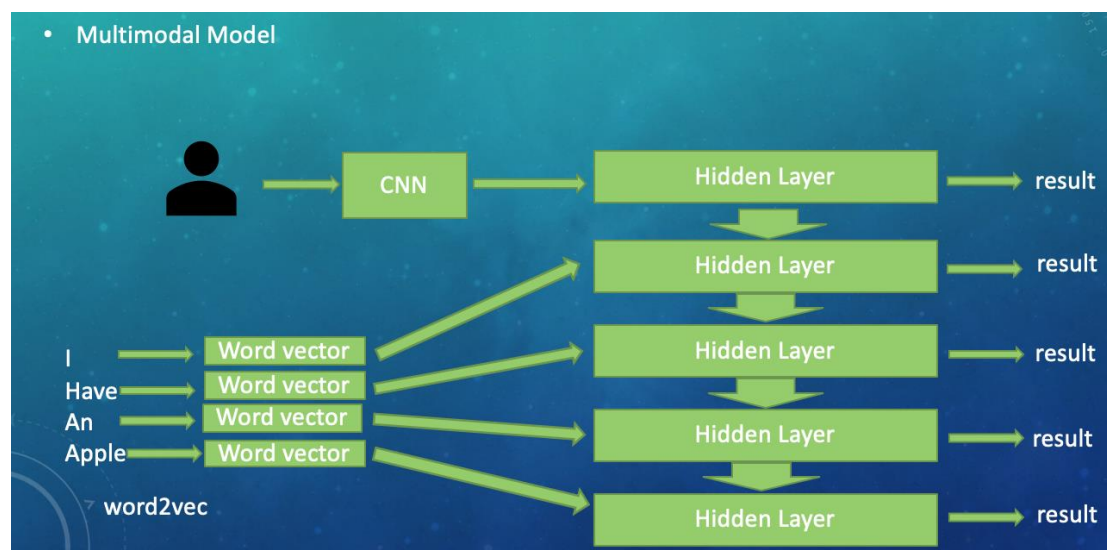


図 3.8 CNN と RNN を併用するマルチモーダル感情分析処理

3.5 実験結果

今回の実験では、VADER, CNN, LSTM, GRU, CNN+RNN, Bidirectional LSTM のなどの手法を利用して、作ったデータセット上で感情分析を行った。VADER の場合は Python の VADER パッケージをインストールして、直接利用した。他の手法の場合、Tensorflow のフレームワークを用いて、ニューラルネットワークを作り、パラメタを調整した。表 3.3-3.5 に CNN, LSTM, GRU のパラメタを示す

表 3.3 CNN のパラメタ

バッチサイズ	180
学習率	0.000001
文の長さ	30

表 3.4 LSTM のパラメタ

バッチサイズ	180
学習率	0.000001
文の長さ	30
隠れ層のユニット数	128

表 3.5 GRU のパラメタ

バッチサイズ	180
学習率	0.000001
文の長さ	30
隠れ層のユニット数	128

各手法により得られたコミックに含まれる英語のセリフの感情分析結果を表 3.6 に示す。

表 3.6 英語のセリフの感情分析の結果

手法	精度(%)
VADER	43.33
CNN	65.56
RNN (LSTM)	72.22
RNN (GRU)	70.55
CNN+RNN	71.67
Bidirectional LSTM	72.22
多層 LSTM	73.33
多層 GRU	74.44

実験の結果、すべての手法において精度はランダム予測に相当する 33.3% を超え、ある程度の有用性が確認できた。さらに、多層 LSTM と多層 GRU はそれぞれ 73.33% と 74.44% の精度に達し、Bidirectional LSTM も 72.22% の精度に達した。これらは Vader, CNN より高い値である。したがって、RNN (LSTM と GRU を含む) は、独特なニューラルネットワーク構造によって、自然言語処理プロジェクト上において、VADER, CNN より適すると考えられる。また、単純に CNN を使用するのに比べて、CNN と RNN の併用が精度の向上に貢献することが分かった。

感情分析の実験結果によると、CNN と RNN のマルチモーダル併用は単純な RNN (LSTM または GRU) より精度が低いことを示した。これは Snoopy の漫画の画風に関わると考え

られる。Snoopy の漫画に登場する人物は表情的表現が少なく，感情が異なるセリフを話す時に常に同じ表情を出す場合が多い。つまり人物の顔画像のみで人物の感情を分析することが難しくなる。さらに，今回の実験に使用したデータは小規模で，セリフの感情に関連する顔画像は不十分であることも，CNN と RNN の併用の精度に影響を与えたと考えられる。

3.6 むすび

本章では VADER, CNN, LSTM, GRU, CNN+RNN, Bidirectional LSTM, 多層 LSTM, 多層 GRU の 8 種類のニューラルネットワークを用いて，英語のコミックに含まれるセリフの感情分析を行った。その結果，多層 LSTM と多層 GRU において，それぞれ 73.33% と 74.44% の精度が得られた。

4 日本語のセリフの感情分析

4.1 まえがき

本章では, CNN, RNN (LSTM と GRU), Bidirectional RNN (LSTM と GRU) と多層 LSTM, 多層 GRU の 7 種類のニューラルネットワークを用いて, 日本語のコミックに含まれるセリフの感情分析を行う。

4.2 セリフの収集

日本語の漫画に含まれるセリフの感情分析は, 基本的に英語のコミックに含まれるセリフの感情分析と同じ手順で行う。今回の実験では, Manga109 というデータセットを利用した。

Manga109 は[9], 日本漫画のメディア処理の学術研究利用のために, 東京大学大学院情報理工学系研究科電子情報学専攻相澤・山崎研究室によりまとめられた。Manga109 は, 日本のプロ漫画家たちによって描かれた 109 冊の漫画で構成されている。それらの漫画は, 1970 年代から 2010 年代に公開されたものであり, 対象読者層やジャンルも幅広く網羅している。また, 収録されている漫画のほとんどは, マンガ図書館 Z (旧絶版漫画図書館) にて公開されている[10]。図 4.1 にこれらのリストの一部を示す。

作品名	フォルダ名	作者	年代	出版社	対象	ジャンル	ページ数	指定巻
1・2・3でキメてあげる	Count3DeKimeteAgeru	大宮 直依	1980年代	角川書店	少年	スポーツ	198	1
愛さずにはいられない	AisazuNihairarenai	よしまさこ	1980年代	集英社	少女	恋愛	187	2
あっけら貫刃帖	AkкераKanjinchou	小林 ゆき	2000年代	集英社	少年	バトル	183	1
あくはむ	Akuhamu	新居 さとし	2000年代	講談社	少年	4コマ	161	1
青すぎる春	AosugiruHaru	奥田 桃子	2000年代	集英社	女性	恋愛	210	
天晴れ! カッポレ	AppareKappore	菅野 博之	1990年代	徳間書店	少年	SF	194	1

図 4.1 Manga109 のデータ (一部)

本実験では, Manga109 の 109 冊の中で 5 冊の漫画のセリフを収集した。感情分析を行うために, すべてのセリフに 3 種類のラベル (Positive/Neutral/Negative) のいずれかを付けた。収集したセリフデータから 1350 の文を選択して, 分析データとして利用した。さらに, これらの分析データをトレーニングデータ : テストデータ = 8 : 2 の比率で分割してトレーニングデータとテストデータを得た。

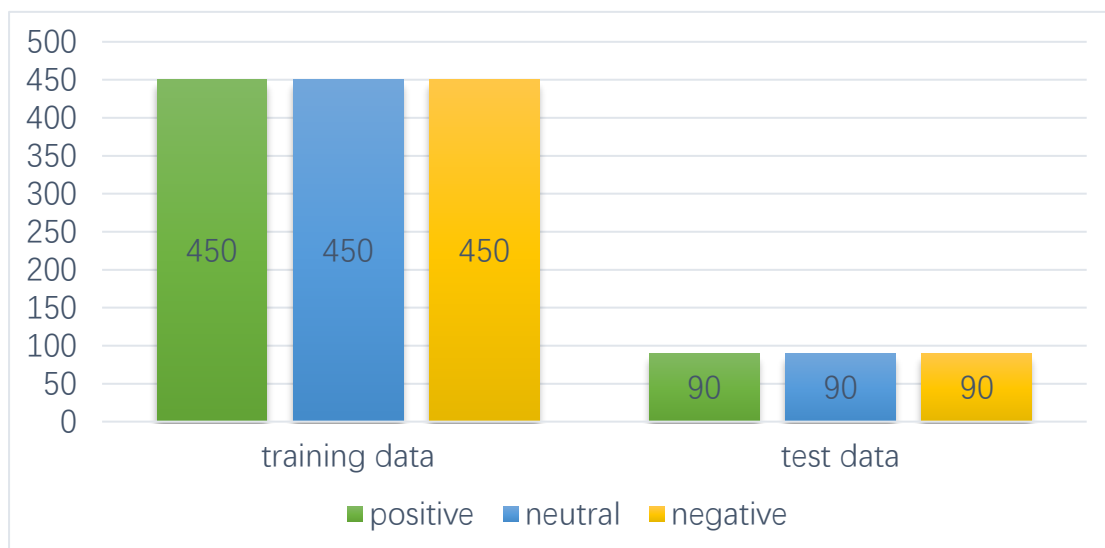


図 4.2 コミックのセリフのデータセット

4.3 日本語の形態素解析

英語、フランス語、スペイン語のような言語は単語間に空白が入るため自然に分ち書けるが、日本語は膠着語[2]と呼ばれる言語の形態的分類に入れられる。すなわち、日本語は分ち書きされずに書かれる。明らかな境界が存在しない日本語のテキストに対して自然言語処理を実行するためには、単語間の境界を明確に指定する処理が必要である[11]。この特徴は中国語やタイ語などの他の東アジアの言語についても共通する問題である。

この問題を解決するために、形態素解析技術を利用する。形態素解析とは、自然言語を一つ一つの形態素に分割する技術である。ここで形態素とは、言葉が意味を持つまとまりの単語の最小単位である。形態素解析の例として、英語の場合を図 4.3 に、日本語の場合を図 4.4 に示す。




図 4.3 英語の場合の形態素解析




図 4.4 日本語の場合の形態素解析

第3章で示したように英語テキストを扱う際には、空白を利用して簡単に形態素解析を行えるが、日本語の場合は、専用の形態素解析ツールを利用しなければならない。現在、日本語形態素解析として利用できるフリーツールには、MeCab, Janome, Juman, Juman++ などがある。

4.3.1 MeCab

MeCab[12]は、京都大学情報学研究科と日本電信電話株式会社コミュニケーション科学基礎研究所の共同研究ユニットプロジェクトを通じて開発されたオープンソース形態素解析エンジンである。言語、辞書、コーパスに依存しない汎用的な設計を基本方針としている。パラメタの推定に Conditional Random Fields (CRF) を用いて、ChaSen が採用している隠れマルコフモデルに比べ性能が向上している。また、平均的に ChaSen, JUMAN, KAKASI より高速に動作する特徴がある。MeCab を用いた形態素解析の例を図 4.5 に示す。

```
softbank060157111147:~ shengshufeng$ mecab
すもももももものうち
すもも 名詞,一般,*,*,*,すもも,スモモ,スモモ
も 助詞,係助詞,*,*,*,も,モ,モ
もも 名詞,一般,*,*,*,もも,モモ,モモ
も 助詞,係助詞,*,*,*,も,モ,モ
もも 名詞,一般,*,*,*,もも,モモ,モモ
の 助詞,連体化,*,*,*,の,ノ,ノ
うち 名詞,非自立,副詞可能,*,*,*,うち,ウチ,ウチ
EOS
```

図 4.5 MeCab を用いた形態素解析の例

4.3.2 Janome (蛇の目)

Janome[13]は、Pure Python によって書かれている辞書内包の形態素解析器である。Janome は依存ライブラリなしで簡単にインストールでき、アプリケーションに組み込みやすいシンプルな API を備える形態素解析ライブラリを目指して更新されている。MeCab の辞書を利用すれば、MeCab と同じ性能を持つようになる。Janome を用いた形態素解析の例を図 4.6 に示す。

```
>>> for token in t.tokenize('でもホントはやさしいんだよね'):
...     print(token)
...
でも     接続詞,*,*,*,*,*,でも,デモ,デモ
ホント   名詞,一般,*,*,*,*,ホント,ホント,ホント
は       助詞,係助詞,*,*,*,*,は,ハ,ワ
やさしい  形容詞,自立,*,*,形容詞・イ段,基本形,やさしい,ヤサシイ,ヤサシイ
ん       名詞,非自立,一般,*,*,*,ん,ン,ン
だ       助動詞,*,*,*,特殊・ダ,基本形,だ,ダ,ダ
よ       助詞,終助詞,*,*,*,*,よ,ヨ,ヨ
ね       助詞,終助詞,*,*,*,*,ね,ネ,ネ
```

図 4.6 Janome を用いた形態素解析の例

4.3.3 JUMAN と JUMAN++

JUMAN[14]は、計算機による日本語の解析を行う研究を目指す多くの研究者へ向けて共通に使える形態素解析ツールを提供するために開発された。その際、国語文法が計算機向きではないという問題を考慮し、使用者によって文法の定義、単語間の接続関係の定義などを容易に変更できるように配慮されている。JUMAN は、コスト最小法に基づいた日本語形態素解析に特化したツールである。JUMAN は独自の辞書とともに配布されており、MeCab で一般的に使用される IPADic と比べて付加情報が豊富なのが特徴である。例えば、単語には代表表記が付与されていたり、自動詞と他動詞の対応、尊敬と謙譲、自他、授受、反義、派生など見出し語間の意味関係なども記述されている。

JUMAN++[15]は JUMAN の強化した高性能な形態素解析システムである。言語モデルとして Recurrent Neural Network Language Model (RNNLM) を用いることにより、単語の並びの意味的な自然さを考慮して解析を行う。これにより JUMAN, MeCab に比べ大きく性能が向上している。文法・辞書・出力フォーマット等は JUMAN から引き継いだものを利用している。

今回の実験では、実装しやすく実行速度が早い Janome を利用して全てのセリフのテキストの形態素解析を行った。

4.4 日本語のベクトル化

日本語のベクトル化は第3章の英語のベクトル化と同様の処理である。形態素解析された日本語の単語は Word2vec に入力され、100次元の単語ベクトルとして生成される。表 4.1 に Word2vec で単語ベクトルを作成する際のパラメータを示す。

表 4.1 Word2vec で単語ベクトルを作成する際のパラメータ

ベクトル次元数	100
コンテキストの数	5
ベクトル最小値	0.001
単語の最小出現頻度	1

4.5 感情分析の手法

感情分析の手法も第3章の英語の手法とほぼ同様である。しかし、VADER は英語のテキストのみ処理できる手法であるため、日本語の感情分析には適用できない。また、登場人物の顔画像も収集していない、CNN と RNN のマルチモーダルな処理も実行できない。そのため、日本語の感情分析には CNN, RNN (LSTM と GRU), Bidirectional RNN (LSTM と GRU) と多層 LSTM, 多層 GRU の7種類を用いて実験した。

4.6 実験結果

今回の実験では、CNN, RNN (LSTM と GRU), Bidirectional RNN (LSTM と GRU) と多層 LSTM, 多層 GRU の7種類を用いてデータセット上で感情分析を行った。表 4.2-4.4 に CNN, LSTM, GRU のパラメータを示す。表 4.5 に日本語のセリフの感情分析の結果を示す。

表 4.5 から、どの手法もランダム予測に相当する 33.3% より高いため、ディープラーニング手法が日本語のセリフの感情分析に有効であることがわかる。また、日本語のテキストに対しても、RNN (LSTM または GRU) は CNN より精度が高く、RNN が感情分析手法として適することがわかる。

表 4.2 CNN のパラメータ

バッチサイズ	180
学習率	0.000001
文の長さ	30

表 4.3 LSTM のパラメタ

バッチサイズ	180
学習率	0.000001
文の長さ	30
隠れ層のユニット数	128

表 4.4 GRU のパラメタ

バッチサイズ	180
学習率	0.000001
文の長さ	30
隠れ層のユニット数	128

表 4.5 日本語のセリフの感情分析の結果

手法	精度(%)
CNN	43.33
RNN (LSTM)	46.29
RNN (GRU)	52.22
Bidirectional RNN (LSTM)	49.25
Bidirectional RNN (GRU)	50.00
多層 LSTM	49.63
多層 GRU	50.37

LSTM を用いる場合、Bidirectional LSTM と多層 LSTM の構造は単純な LSTM よりも複雑であるため、テキストの特徴を学習する能力が向上していると考えられる。一方、GRU を用いる際には、同じデータセットでは、単純な GRU の表現は Bidirectional GRU と多層 GRU より精度が高い。更に、GRU を LSTM と比較した場合、精度が高いという結果が得られた。

4.7 むすび

本章では CNN, RNN (LSTM と GRU), Bidirectional RNN (LSTM と GRU) と多層 LSTM, 多層 GRU の 7 種類のニューラルネットワークを用いて、日本語のコミックに含まれるセリフの感情分析を行った。その結果、単純な GRU において、52.22%の精度が得られた。

5 結論

本研究では、自然言語処理に適したニューラルネットワークを用いて、コミックのセリフの感情分析を行った。英語のコミックと日本語の漫画に含まれるセリフに対して感情分析を行った結果、すべての手法においてランダム予測に相当する 33.3% 以上が得られた。このことから、ディープラーニング手法がコミックのセリフの感情分析に有効であるといえる。

英語のコミックの感情分析の結果では、多層 LSTM と多層 GRU はそれぞれ 73.33% と 74.44% の精度に達した。RNN は時系列処理が可能なニューラルネットワーク構造のため、自然言語処理においては VADER, CNN より適すると考えられる。また、単純に CNN を使用する手法に比べて、CNN と RNN のマルチモーダルな併用が精度の向上に貢献することが分かった。しかし、使用したデータが小規模であったり、セリフの感情に関連する顔画像が不十分であると CNN と RNN の併用は単純な RNN (LSTM または GRU) より精度が低いことが分かった。

また、日本語のコミックのセリフ感情分析の結果によると、LSTM 及び GRU は CNN より精度が高いことが分かった。このことから RNN (LSTM と GRU を含む) が感情分析に適することが分かる。構造が複雑な Bidirectional LSTM と多層 LSTM が単純な LSTM より精度が高い値を示した理由は、Bidirectional LSTM と多層 LSTM の方がより多くのテキストの特徴を学習する能力を持つためであると考えられる。

英語のコミックと日本語のコミックのセリフ感情分析を行った結果を比較すると、英語のコミックの方が全体的に良い精度が得られた。これは、英語のテキストは形態素解析が簡単かつ曖昧性が小さいということが原因であると考えられる。一方、日本語のテキストは形態素解析が及ぼす影響によって感情分析の精度が下がったと考えられる。

ただし、今回使用したデータセットは小規模である、多くの自然言語の特徴を学習できていない。また、トレーニングデータの特徴とテストデータの特徴も必ずしも一致していないという問題がある。今後の課題として、より多くのデータを収集し、豊富な自然言語の特徴を利用して学習する必要があると考えられる。

6 謝辞

本論文を作成するにあたり，研究の必要機材や実験環境，快適な研究環境を与えてくださり，研究及び学生生活において素晴らしいご指導を頂いた渡辺教授に心より感謝いたします。日常の議論を通じて多くの知識や示唆を頂戴した渡辺研究室の皆様にも深く感謝いたします。最後に，私をここまで育ててくださり，生活を支えてくださっている家族に感謝いたします。

7 参考文献

- [1] 小高知宏, “自然言語処理と深層学習 - C 言語によるシミュレーション -”, オーム社, 2017
- [2] 杉本徹, 岩下志 “Java で学ぶ自然言語処理と機械学習”, オーム社, 2018
- [3] 干場達矢, 白木緑, 久野弘嗣, “電子書籍が変える読書 世界市場4年で急成長”, 日本経済新聞, <https://vdata.nikkei.com/datadiscovery/21book/> (最終確認 2019年1月24日)
- [4] B. K. Bhavitha, A. P. Rodrigues, and N. C. Chiplunkar, “Comparative Study of Machine Learning Techniques in Sentimental Analysis,” International Conference on Inventive Communication and Computational Technologies (ICICCT 2017), pp.216-221, Mar. 2017.
- [5] C. N. dos Santos, M. Gatti, “Deep Convolutional Neural Networks for Sentiment Analysis of Short Texts,” Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical Papers, pp.69-78, Aug. 2014.
- [6] Stojanovski, Dario, et al. "Twitter sentiment analysis using deep convolutional neural network." International Conference on Hybrid Artificial Intelligence Systems. Springer, Cham, 2015.
- [7] C. J. Hutto, and E. Gilbert, “VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text,” International AAAI Conference on Weblogs and Social Media (ICWSM-14). Ann Arbor, MI, June 2014.
- [8] T. Mikolov, K. Chen, G. Corrado, and J. Dean, “Efficient Estimation of Word Representations in Vector Space,” International Conference on Learning Representation (ICLR 2013), May 2013.
- [9] Y. Matsui, K. Ito, Y. Aramaki, A. Fujimoto, T. Ogawa, T. Yamasaki, and K. Aizawa, “Sketch-based Manga Retrieval using Manga109 Dataset”, Multimedia Tools and Applications, Springer, 2017.
- [10] T. Ogawa, A. Otsubo, R. Narita, Y. Matsui, T. Yamasaki, and K. Aizawa, “Object Detection for Comics using Manga109 Annotations”, arXiv:1803.08670, Mar. 2018.
- [11] Steven Bird, Ewan Klein, Edward Loper, “入門 自然言語処理”, オライリー・ジャパン, 2010
- [12] “MeCab: Yet Another Part-of-Speech and Morphological Analyzer”, <http://taku910.github.io/mecab/>
- [13] Tomoko Uchida , “Janome”, <http://mocabeta.github.io/janome/#>

[14] 京都大学大学院情報学研究科知能情報学専攻 黒橋・河原研究室, “日本語形態素解析システム JUMAN”, <http://nlp.ist.i.kyoto-u.ac.jp/index.php?JUMAN>

[15] 京都大学大学院情報学研究科知能情報学専攻 黒橋・河原研究室 “日本語形態素解析システム JUMAN++”, <http://nlp.ist.i.kyoto-u.ac.jp/index.php?JUMAN++>

8 図一覧

図 1.1	自然言語処理の主な分野.....	4
図 1.2	感情分析の例.....	5
図 2.1	VADER とほかの感情分析手法の比較.....	8
図 3.1	コミックのセリフのデータセット.....	10
図 3.2	Word2vec で作成した単語ベクトル.....	11
図 3.3	VADER の使用例.....	12
図 3.4	CNN を利用する感情分析のイメージ.....	12
図 3.5	RNN を利用する感情分析のイメージ.....	13
図 3.6	多層 LSTM を利用する感情分析のイメージ.....	14
図 3.7	Bidirectional RNN を利用する感情分析のイメージ.....	14
図 3.8	Bidirectional RNN を利用する感情分析のイメージ.....	15
図 4.1	Manga109 のデータ（一部）.....	18
図 4.2	コミックのセリフのデータセット.....	19
図 4.3	英語の場合.....	19
図 4.4	日本語の場合.....	20
図 4.5	MeCab で形態素解析を行う例.....	20
図 4.6	Janome で形態素解析を行う例.....	21

9 表一覧

表 3.1	コミックのセリフの例.....	9
表 3.2	Word2vec で単語ベクトルを作成する際のパラメータ.....	11
表 3.3	CNN のパラメータ.....	15
表 3.4	LSTM のパラメータ.....	16
表 3.5	GRU のパラメータ.....	16
表 3.6	英語のセリフの感情分析の結果.....	16
表 4.1	Word2vec で単語ベクトルを作成する際のパラメータ.....	22
表 4.2	CNN のパラメータ.....	22
表 4.3	LSTM のパラメータ.....	23
表 4.4	GRU のパラメータ.....	23
表 4.5	日本語のセリフの感情分析の結果.....	23