

平成30年度 修士論文

グループラベルワークにおける  
自然言語処理技術の適用とその効果

平成31年2月12日

17350922

田中 秀弥

指導教員 三浦 元喜 准教授

九州工業大学 工学府 先端機能システム工学専攻

## 概要

KJ法をはじめとする、グループラベルワークにおいては、参加者が出されたアイデア(ラベル)を内容の類似性によってグルーピングする作業がよく行われている。グルーピング作業においては、ラベルの数が少ない場合は問題ないが、ラベルの数が多き場合は、参加者の作業負担が高まる。その結果、作業時間が増加したり、作業自体を単調に感じやすくなったりすることで、作業の質の低下に影響する可能性がある。

そこで、我々はラベル内の単語やその単語に基づく WordNet の情報でラベルのクラスタリングを行うことで、作業負担を軽減し、作業の質の低下を防いだり、思考を深める時間を確保できたりする可能性があると考えた。Wikipedia の記事から抜粋したデータセットを用いることで、一番良いクラスタリング結果が得られる組み合わせを見つけた。

# 目次

<b>第1章 導入</b>	<b>3</b>
1.1 背景 . . . . .	3
1.2 本研究の目的 . . . . .	3
<b>第2章 関連研究</b>	<b>5</b>
2.1 WordNetに基づく文書ドキュメントクラスタリング . . . . .	5
2.2 分散協調型 KJ 法におけるグループ知評価の検討 . . . . .	5
<b>第3章 複数タブレット端末を用いたグループラベルワークシステム</b>	<b>7</b>
3.1 KJ 法 . . . . .	7
3.2 提案手法 . . . . .	7
3.2.1 アイディア出しからアイディアのグルーピングへの流れ . . . . .	9
3.2.2 アイディア出し . . . . .	10
3.2.3 グルーピング . . . . .	10
3.3 評価実験 . . . . .	10
3.3.1 実験内容 . . . . .	11
3.3.2 実験方法 . . . . .	12
3.3.3 実験結果 . . . . .	13
3.3.4 アンケート . . . . .	16
3.3.5 考察 . . . . .	19
<b>第4章 コサイン類似度を用いたラベルのクラスタリング</b>	<b>20</b>
4.1 提案手法 . . . . .	20
4.1.1 MeCab . . . . .	21
4.1.2 コサイン類似度 . . . . .	22

4.2	予備実験 . . . . .	22
4.2.1	実験内容 . . . . .	23
4.2.2	評価方法 . . . . .	23
4.2.3	実験方法 . . . . .	25
4.2.4	実験結果 . . . . .	25
4.3	考察 . . . . .	26
<b>第5章</b>	<b>WordNet を用いたラベルのクラスタリング</b>	<b>27</b>
5.1	提案手法 . . . . .	27
5.1.1	WordNet . . . . .	28
5.1.2	階層的クラスタリング . . . . .	28
5.2	評価実験1 . . . . .	32
5.2.1	実験内容 . . . . .	32
5.2.2	実験方法 . . . . .	32
5.2.3	実験結果 . . . . .	33
5.3	評価実験2 . . . . .	43
5.3.1	実験内容 . . . . .	43
5.3.2	実験方法 . . . . .	44
5.3.3	実験結果 . . . . .	45
5.3.4	アンケート . . . . .	46
5.4	考察 . . . . .	49
<b>第6章</b>	<b>結論</b>	<b>50</b>
6.1	まとめ . . . . .	50
6.2	今後の展望 . . . . .	50
	<b>謝辞</b>	<b>51</b>
	<b>参考文献</b>	<b>52</b>

# 第1章 導入

本論文は、グループレベルワークにおける自然言語処理技術の適用とその効果と題して、グループレベルワークのグルーピングの際に自然言語処理技術によるラベルのクラスタリング結果を導入した時の影響について論ずるものである。第一章では、本テーマを取り巻く背景と提案手法を含めた本研究の目的を説明する。

## 1.1 背景

以前の研究では、複数タブレット端末を用いたグループレベルワークシステムについて、紙を用いた従来の手法との比較を行った。その研究の実験の際に、「ラベルを動かす時に、移動距離が長いと動かすのが大変だった」との指摘を受けた。たしかに、グループレベルワークシステムでのラベルの移動は、紙のラベルを扱っているようにはいかない。これは、ラベルの数が増えれば増えるほど、参加者の作業負担が増えることを意味する。作業負担が増えることは、グループレベルワークの質の低下に影響する可能性がある。

そこで、ラベル内の単語やその単語に基づく WordNet の情報でラベルのクラスタリングを行うことで、単調になりやすい部分を取り除き、思考を深める時間を確保できる可能性があると考えた。

## 1.2 本研究の目的

本論文では、グループレベルワークにおけるラベルのクラスタリングに自然言語処理技術を適用する方法の提案、評価を行う。今回の研究では、当初はラベル内の単語のみによるコサイン類似度でのクラスタリングを行い、後半ではラベル内の単語に基づく WordNet の情報やクラスタ間の距離を用いたクラスタリングを行う。

評価方法として、正解データとの比較をしてエントロピーや純度, F値といった尺度で評価する. また, 被験者による実際のラベルワークの実験も行い, 評価する.

## 第2章 関連研究

第2章では、グループラベルワーク時のグループ化や WordNet を用いたクラスタリングの関連研究を紹介する。

### 2.1 WordNet に基づく文書ドキュメントクラスタリング

Sedding らは、WordNet を用いることで文書ドキュメントのクラスタリングを行うことで、従来のアルゴリズムに存在した曖昧性を解消した [1]。

文書内の単語の情報を用いて、WordNet から同義語や上位語の情報を引き出し、引き出した情報でコサイン類似度を計算することで文書ドキュメントのクラスタリングを行っている。WordNet から引き出す情報の量を増やすことでクラスタリングの曖昧性を無くし、類似性を高めている。

彼らの研究は、我々の研究と同じく WordNet を用いてクラスタリングを行っている。しかし、我々のクラスタリング対象はグループラベルワーク時のラベルであり、彼らの文書ドキュメントのような情報量の多いものではないため、コサイン類似度とは別のクラスタ間の距離を測定する方法を用いている点が異なる。

### 2.2 分散協調型 KJ 法におけるグループ知評価の検討

由井園らは、発想支援グループウェアを用いて行う分散協調型 KJ 法における「グループ知」を評価する方法について検討した [2]。分散協調型 KJ 法はアイデアを出す意見入力段階、アイデアをグループ化する島作成段階、そして、それ以前の結果をもとに結論である文章を書く文章化段階の三段階からなる。

創造的な問題解決会議プロセスでは発散的思考と収束的思考のバランスが大事と言われている。そこで、由井園らは発散的思考の結果として出された意見が収束

的思考の結果である文章に反映するプロセスがよい会議につながると仮定し、それを計量するための指標を検討した。そして、自然言語処理を用いた単語の種類数による複数の指標を検討し、文章の総合満足度という尺度との相関を調べた。その結果、意見の集約量を示す指標が、文章の総合満足度と最も高い相関を取ることがわかった。

彼らの研究では、ラベルのグループ化に良い結果が出るように「グループ知」を評価するという手法を提案した。我々の研究では、ラベルのグループ化に良い結果がでるように自然言語処理技術でクラスタリングしたものを与えるという手法を提案した。



## 第3章 複数タブレット端末を用いたグループラベルワークシステム

第3章では以前の研究で行ったタブレット端末を使ったグループラベルワークシステムについて説明する。この研究では、今まで模造紙や付箋紙などの紙を使って行うグループラベルワーク (KJ法) をタブレット端末を使って行う方法を提案した。タブレット端末を使う利点は、紙を使うのに比べて編集が容易で、保存や管理もしやすく、他のグループラベルワークの参加者とのデータの共有も簡単にできることである。

### 3.1 KJ法

KJ法 [3] とは、川喜田が考案した発想法である。KJ法は、日本ではブレインストーミングと並んで広く使われていて、アイデアやデータなどの複数の情報を組み合わせ、構造化することによって新たなアイデアの発想を見つけることを目的にしている。

KJ法は、一般的に、模造紙などの大きな紙面と付箋紙をラベルとして使用する。鉛筆などの筆記用具でラベルにアイデアを記入し、紙面に貼り付けアイデアをグルーピングし、グループをペンなどの筆記用具で囲んで島を作成する。このような工程でKJ法を行う。

### 3.2 提案手法

汎用の Web の仕組みをつかい、複数のタブレット端末を連携させることで、グループラベルワークを実現した。図3.1のように、1つのタブレット端末でアイデアを追加すると、そのアイデアのデータがサーバに送られる。そのデータがデー

データベースに保存される。データが保存された後に、他のタブレット端末にデータが送られる。それぞれのタブレット端末で表示されているのは、仮想空間内に設定された広大なワークスペースの一部である。それぞれのタブレット端末は、仮想空間内の一部を表示、操作可能にしている。広大なワークスペースを設定することで、タブレット端末の数を増やしたら、増やした分だけワークスペースが広がる。この手法の利点として、保存されるデータの中にラベルの座標情報も含まれているため、1つのタブレット端末でラベルを移動すると、他のタブレット端末のラベルの位置も移動させることができる。そして、汎用の Web の仕組みを使っていることで、Web ブラウザのみで動作するため、タブレット端末の種類(機種)や、搭載されている OS に依存しない。欠点を挙げるならば、タブレット端末や Web ブラウザの種類によって、細かな動作が若干異なる状況が発生する可能性がある。

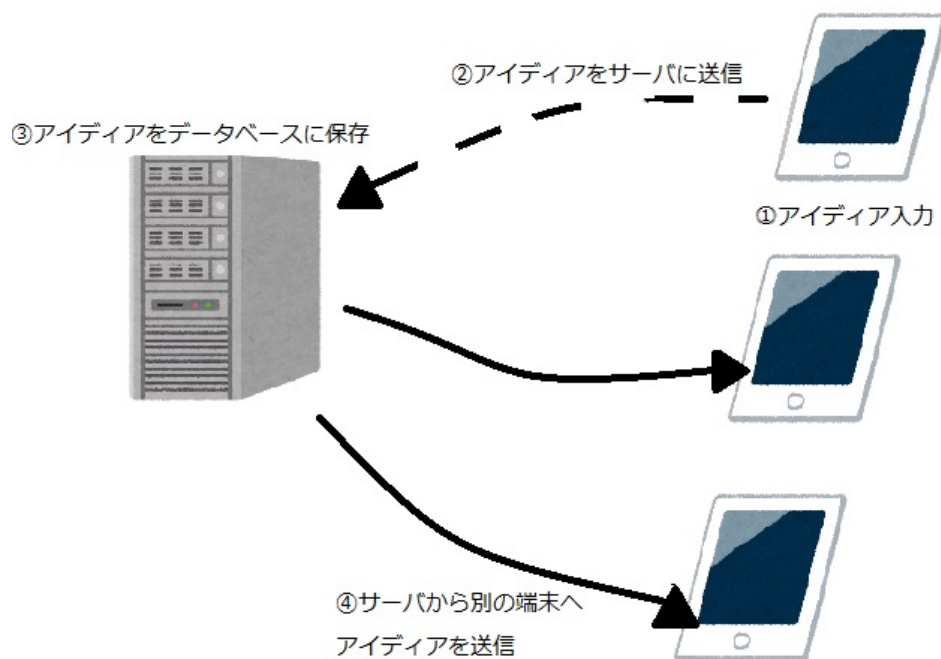


図 3.1: 仕組み

### 3.2.1 アイディア出しからアイデアのグルーピングへの流れ

我々は、図3.2のように、タブレット端末を使ってグループラベルワーク (KJ法) を再現する。参加者は、この画面でアイデアを出し合ってラベルを増やし、その後、複数のタブレット端末を並べて、参加者全員でグルーピングをする。

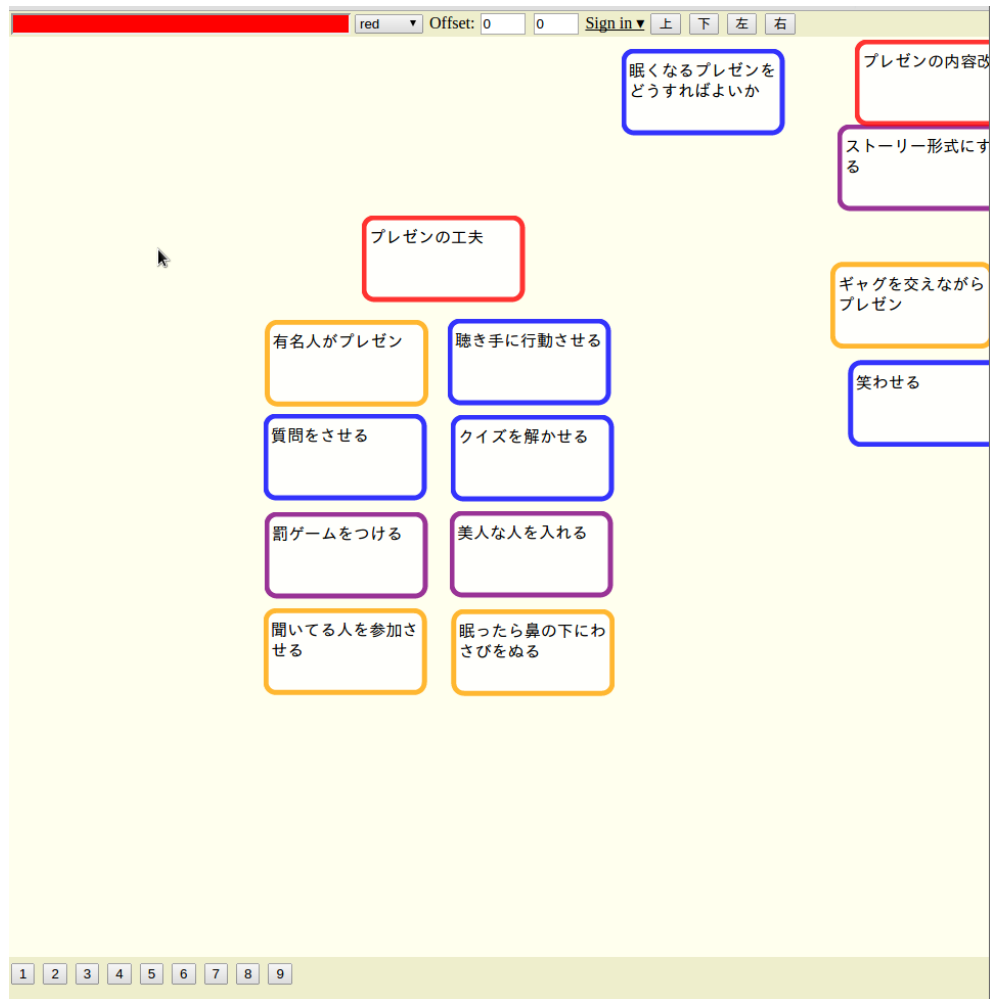


図 3.2: タブレット端末を使ってグループラベルワーク

### 3.2.2 アイディア出し

アイディア出しでは，参加者一人一人が1台ずつタブレット端末を使って行う。図3.3の下側にある1～9のボタンは，図3.4の9台のタブレットの配置に対応していて，上の段の左から右に1，2，3のボタンが，真ん中の段の左から右に4，5，6のボタンが，下の段の左から右に7，8，9のボタンが割り当てられている。それぞれのボタンを押すことで，対応した画面に切り替わる。他の画面に対応するボタンを押せば，他の参加者の意見を見ることもできる。アイディアのラベルは，図3.3の上側の赤いテキスト入力フィールドに入力することで追加できる。テキスト入力フィールドの横には，ラベルの色を変更できるドロップダウンリストがある。ラベルで長押しすると，図3.3のようにメニューが表示され，テキストの編集やラベルのコピー，削除ができる。

### 3.2.3 グループピング

アイディア出しの後には，グループピングを行う。グループピングでは，図3.2のように似ているアイディアのラベルをグループ化し，赤いラベルでグループのタイトルをつける。図3.5のように，ラベルをさわることでラベルを移動できる。グループピングの際には，複数のタブレット端末間を移動させることで似ているアイディア同士を一つのタブレット端末の画面に集める。この際に，ラベルの移動を円滑にする機能として，ラベルをフリックで飛ばすことができる機能を追加した。この機能を実現するうえでは，久野らの『「アイコン投げ」ユーザインタフェース』の論文[4]を参考に行った。

## 3.3 評価実験

タブレット端末を用いたグループラベルワーク(KJ法)システムの評価実験について述べる。

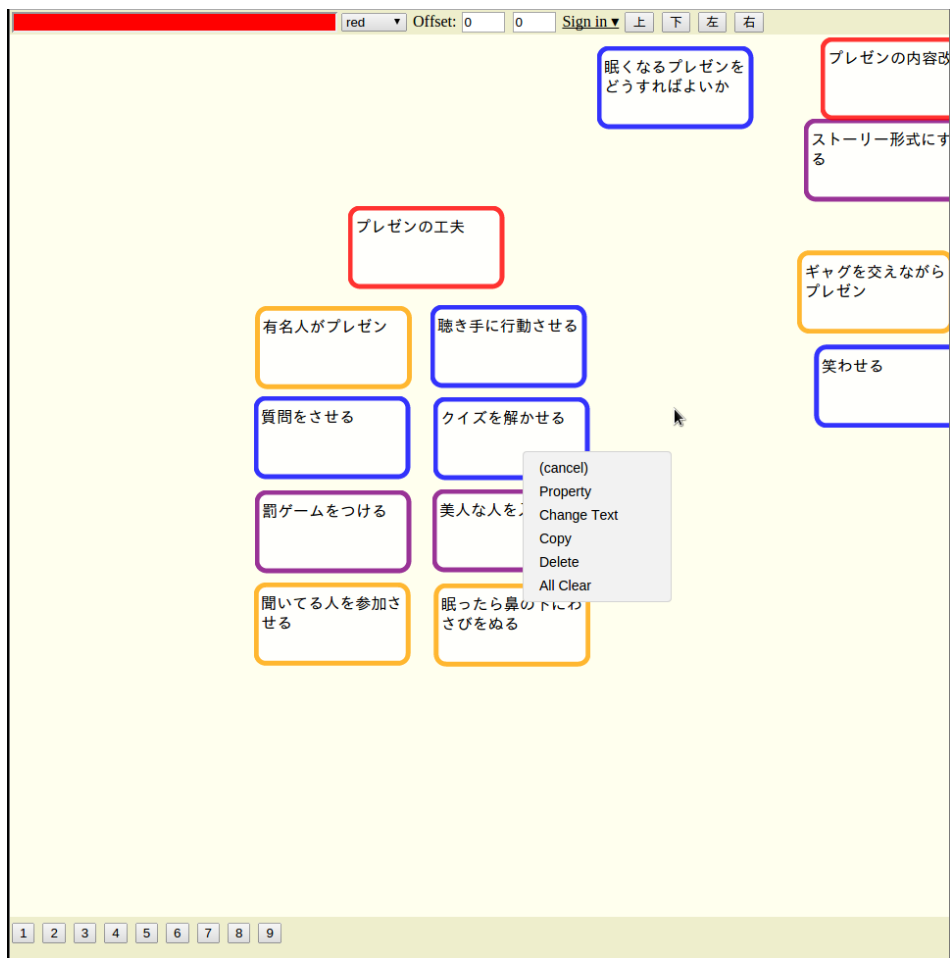


図 3.3: メニュー表示

### 3.3.1 実験内容

本論文で提案した手法と従来の手法 (模造紙と紙のラベルを使う方式) を被験者に実際に使用してもらい、それぞれの手法の結果を比較する。実験の目的として、グルーブラベルワークをするときに、タブレット端末を使うことがグルーブラベルワークの結果に影響を与えるのかを、紙を使用したときと比較して有意水準 5% において t 検定を行って評価する。




図 3.4: 複数タブレット端末を使った様子

### 使用する物, 環境

提案したグループラベルワーク (KJ 法) システムのために, タブレット端末として Apple 社の iPad2(メモリ 16GB) を 9 台使用した. 従来の手法のために, 模造紙 (788mm×1085mm), 紙のラベル (38mm×63mm) を使用した.

### 3.3.2 実験方法

被験者の人数は, 学生 12 人で 4 グループ (1 グループ 3 人) に分けた. 被験者には, 提案した手法と従来の手法の両方で, アイディア出しとグルーピングを 15 分ずつしてもらった. グループラベルワークのテーマを表 3.1 のように 2 つ用意し, 表 3.2 のようなテーマと手法の組み合わせで実験を行う. アイディアの数やアイディ




図 3.5: ラベルの移動：選択したラベルは色が変わり，移動できる

アのグループ数，会話時間をデータとして取得した。会話時間は，実験の様子をビデオカメラで撮影し，時間を計測した。両方の手法での使用感や改善点などを収集するために，実験後にアンケートを実施した。

表 3.1: テーマ

テーマ 1	ネガティブな感情を軽減するには，どうしたらいいか？
テーマ 2	ねむくなるつまらないプレゼンを楽しくするには，どうしたらいいか？

### 3.3.3 実験結果

実験をした結果，テーマ別の総アイデア数とアイデアのグループ数を表 3.3，表 3.4 に示す。両方のテーマとも，タブレット端末を使っている時より紙を使っている時のほうが若干アイデアの数が多く，紙のラベルに直接自分で書く方がアイ

表 3.2: 実験のグループのテーマと手法の組み合わせ

グループ	1回目	2回目
A グループ	テーマ 1 従来手法 (紙)	テーマ 2 提案手法 (タブレット端末)
B グループ	テーマ 1 従来手法 (タブレット端末)	テーマ 2 提案手法 (紙)
C グループ	テーマ 2 従来手法 (紙)	テーマ 1 提案手法 (タブレット端末)
D グループ	テーマ 2 従来手法 (タブレット端末)	テーマ 1 提案手法 (紙)

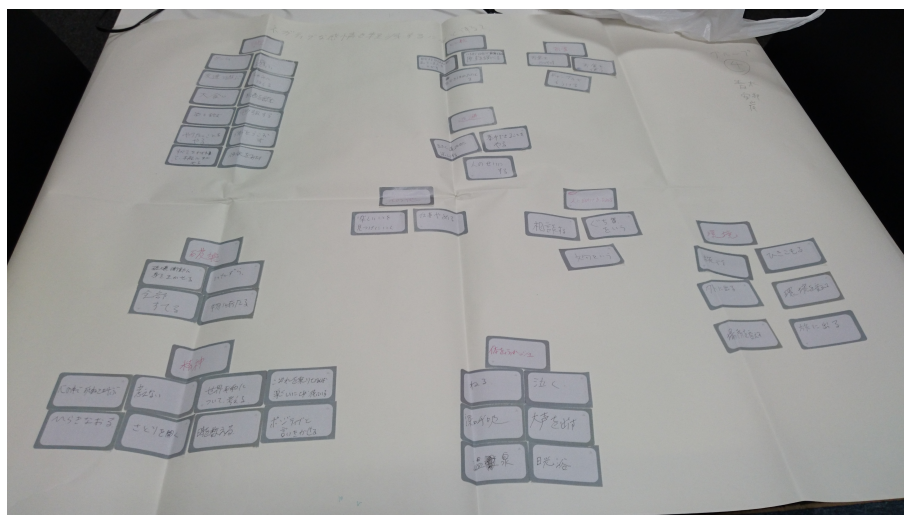


図 3.6: 紙を用いたグループラベルワーク

ディアが出やすいように見える。しかし、この2つの表のタブレット端末と紙について、有意水準5%においてt検定を行ったところ、テーマ1は0.16、テーマ2は0.30で両方とも有意差はないことがわかる。グループ別に見てみると(表3.5)、紙よりもタブレット端末を使っている時の方が多いいグループもあった。表3.5について、有意水準5%においてt検定を行ったところ、0.17で有意差はない。図3.7は、実験中の被験者の会話時間である。図3.7を見ると、紙とタブレット端末ともあまり変わらないように見える。t検定を行うとアイデア出しは0.70、グルーピングは0.71で両方とも $p > 0.1$ なので有意差はない。我々の予想では、タブレット端末の方が操作に慣れてない分、会話時間が短いのではないかと考えていたが、結



果を見ると違っていた。

表 3.3: テーマ 1 の時の総アイデア数とアイデアのグループ数

グループ	総アイデア数	アイデアのグループ数
A グループ (紙)	42	10
D グループ (紙)	50	10
B グループ (タブレット端末)	38	8
C グループ (タブレット端末)	32	6

表 3.4: テーマ 2 の時の総アイデア数とアイデアのグループ数

グループ	総アイデア数	アイデアのグループ数
B グループ (紙)	34	9
C グループ (紙)	39	5
A グループ (タブレット端末)	28	3
D グループ (タブレット端末)	34	8

表 3.5: グループ別の総アイデア数

グループ	タブレット端末	紙
A グループ	28	42
B グループ	38	34
C グループ	32	39
D グループ	34	50




図 3.7: 会話時間(分)

### 3.3.4 アンケート

提案手法(タブレット端末)と従来手法(紙)のそれぞれの実験の後、被験者にはアンケートに答えてもらった。図 3.8, 図 3.9 は、提案方法(タブレット端末)のアンケートの結果の集計である。集計を見てみると、アイデア出しの段階の操作ではあまり使いづらさは感じなかったようであるが、グループピングの段階の操作に使いづらさを感じたようである。特に複数端末間でラベルの移動をする操作がしづらかったようである。アンケートにあるフリックでのラベルの移動は、複数端末間のラベルの移動を円滑に行うためにつけた機能だが、飛ばす距離を調節するためにはコツがいるため大半の人が使いづらかったようである。この操作は、修正が必要なことがわかり、操作性の改善または新しい機能の導入が必要である。たとえば、メニューから任意の画面にラベルを移動できる機能が考えられる。被験者に聞いたところ、グループラベルワーク(KJ法)に慣れてなくアイデアがあまり出なかったという意見もあった。設定するテーマによっては、もっとアイデア

が出た可能性も考えられる。

アンケートに書かれた意見は、以下の通りである。

従来手法 (紙) に関しては、

- タブレット端末よりも簡単。
- ラベルを貼るのが面倒。
- シールを剥がすのが面倒。
- 字が汚いと、見づらい。
- 誰が出したアイデアかわかりづらい。

提案手法 (タブレット端末) に関しては、

- フリックでラベルを飛ばすのは良かった。
- 複数のタブレット端末が相互作用しているのは良かった。
- 手書きと異なり、場所にとらわれない点が良い。
- 手書きに比べて、ラベルの追加がしやすい。
- 音声入力が欲しい。
- テンキーのように場所を設定するのは良い。
- ラベルのサイズを変更する機能が欲しい。
- フリックを使って飛ばすのが難しく、端末間を飛ばすのに時間がかかる。




図 3.8: アイデア出し 使いやすさ (5段階評価)




図 3.9: グルーピング 使いやすさ (5段階評価)

### 3.3.5 考察

アンケートの結果や実験の様子を見ると、提案手法(タブレット端末)と従来手法(紙)の両方を行った被験者の意見は、紙の方は「ラベルを貼る作業が大変」というもの以外は、どちらも大差がなかった。アンケートの意見では、機能面の改善の要望が強く、今後の研究で改善していきたい。ほかの意見では、複数のタブレット端末が相互作用していて、リアルタイムで他の人のアイデアが画面上に表示されるのが良いという意見も多くあった。アイデアの数では、多少の差があったが、実験中の様子を見てみると他の人の意見をあまり見ていなくて、アイデアが重複していることがあった。アイデアがかぶることは悪いことではないが、タブレット端末ではボタン1つで他の人のアイデアが見れたからか、アイデアの重複があまりないように見えた。そのため、アイデアの数で多少の差ができたのではないかと考えられる。

被験者に聞いた意見の中にこのような意見があった。それは、「ラベルを動かす時に、移動距離が長いと動かすのが大変だった」という意見だった。たしかに、今回のシステム上でラベルを動かすのは、紙のラベルを動かすみたいにスムーズにいかない。しかも、グループラベルワークはアイデアのラベルを作れば作るほど良いため、質の高いグループラベルワークをしようとするラベルの数が多くなる。そして、ラベルの数が多くなると参加者の作業負担が高まる。参加者の作業負担が高まると、作業時間が増加するため、作業の質の低下に影響する可能性がある。これらのことから、今後の研究では、ラベルの自動グループ化を検討する。

## 第4章 コサイン類似度を用いたラベルのクラスタリング

第4章では、以前の研究を踏まえて、グループラベルワーク時のラベルのクラスタリングを自動化する方法について述べる。

以前の研究の実験の際に、「ラベルを動かす時に、移動距離が長いと動かすのが大変だった」との指摘を受けた。これは、ラベルの数が増えれば増えるほど、参加者の作業負荷が増えることを意味している。しかも、質の高いグループラベルワークをしようとする、ラベルの数が増える。そこで、似ている又は近い単語を含んだ複数のラベルだけでも同じグループに分けるために、ラベルのクラスタリングをコサイン類似度を用いて自動で行う。コサイン類似度を選んだ理由は、グループラベルワーク時のラベルの数は一般的に行うクラスタリングのデータ数よりも少ないため、初歩的なクラスタリング方法で十分にラベルのクラスタリングができるのではないかと考えたからである。

### 4.1 提案手法

今回の提案手法では、ラベルごとにラベル内の単語(名詞、動詞、形容詞、形容動詞)を抽出し、抽出した単語を基にコサイン類似度を用いて各ラベルごとの類似度を求める。

まず、はじめにラベルごとにラベル内の単語(名詞、動詞、形容詞、形容動詞)を抽出する。しかし、日本語の文章から特定の品詞の単語を選んで抽出することは、困難である。そこで、形態素解析エンジンである MeCab[5]を用いる。MeCabについては、4.1.1章で述べる。

MeCabによって抽出した単語をリスト化する。この時、後でクロス表(図4.1)を作るために、全てのラベルから抽出した単語のリストと各ラベルごとに抽出した

単語のリストを作る。このクロス表は、図 4.1 のように各ラベルに、どの単語があるかないかを調べ、ある場合は 1 を、ない場合は 0 を入れたものである。図 4.1 の上部の単語のリストは、全てのラベルから抽出した単語の語幹のリストである。

	ゲーム	遊ぶ	友達	趣味	走る	食う	酒	飲む
ラベル1	1	0	0	0	0	0	0	0
ラベル2	0	1	0	0	0	0	0	0
ラベル3	0	1	1	0	0	0	0	0
ラベル4	0	0	0	1	1	0	0	0
ラベル5	0	0	0	0	0	1	0	0
ラベル6	0	0	0	0	0	0	0	1
ラベル7	0	0	0	0	0	0	0	1
ラベル8	0	0	0	0	0	0	0	0
ラベル9	0	0	0	0	0	0	0	0
ラベル10	0	0	0	0	0	0	0	0
ラベル11	0	0	0	0	0	0	0	0
ラベル12	0	0	0	0	0	0	0	0
ラベル13	0	0	0	0	0	0	0	0
ラベル14	0	0	0	0	0	0	0	0
ラベル15	0	0	0	0	0	0	0	0
ラベル16	0	0	0	0	0	0	0	0

図 4.1: クロス表

クロス表を作成した後に、作成したクロス表を使ってコサイン類似度 (4.1.2 章) を求める。このコサイン類似度の数値を基に、閾値を設定してラベルのクラスタリングを行う。

#### 4.1.1 MeCab

MeCab[5] はオープンソースの形態素解析エンジンである。MeCab の特徴は、辞書やコーパスに依存しない汎用的な設計で条件付き確率場 (CRF) に基づく高い解析精度を誇っている。MeCab を使うと、図 4.2 のように 1 つの文章を品詞ごとに区切ることができる。MeCab を用いれば、ラベルのクラスタリングをする際に必要な情報 (名詞、動詞、形容詞、形容動詞) だけを抽出することができる。

```

% mecab
すも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 4.2: MeCab の出力例

#### 4.1.2 コサイン類似度

コサイン類似度は、ベクトル空間モデルにおいて、文書同士を比較する際に用いられる類似度計算手法である。コサイン類似度は、ベクトル同士のなす角度の近さを表現する。そのため、1 に近ければ類似しており、-1 に近ければ似てないことになる。コサイン類似度を文書に用いる時は、一般的に tf-idf 値 (tf: 単語の出現頻度, idf: 逆文書頻度) を用いて計算される。しかし、今回は文書よりも情報量の少ない文章で行うので、図 4.1 のようなクロス表を用いる。

コサイン類似度の計算式を、式 4.1 と式 4.2 に示す。

$$\cos(\vec{q}, \vec{d}) = \frac{\vec{q} \cdot \vec{d}}{|\vec{q}| |\vec{d}|} = \frac{\vec{q}}{|\vec{q}|} \cdot \frac{\vec{d}}{|\vec{d}|} = \frac{\sum_{i=1}^{|\mathcal{V}|} q_i d_i}{\sqrt{\sum_{i=1}^{|\mathcal{V}|} q_i^2} \cdot \sqrt{\sum_{i=1}^{|\mathcal{V}|} d_i^2}} \quad (4.1)$$

正規化された単位ベクトルについての計算は、以下で行う。

$$\cos(\vec{q}, \vec{d}) = \vec{q} \cdot \vec{d} = \sum_{i=1}^{|\mathcal{V}|} q_i d_i \quad (4.2)$$

## 4.2 予備実験

コサイン類似度を用いたラベルのクラスタリングの評価について述べる。



## 4.2.1 実験内容

提案した手法でラベルをクラスタリングした結果と被験者にラベルをクラスタリングしてもらった結果を比較する。実験の目的として、提案した手法でラベルをクラスタリングした結果が、被験者がグルーピングしたものに近いかどうかを、比較して評価する。評価方法は、エントロピー、純度、F値で行う [6]。詳しい内容は、4.2.2 章に記す。

## 4.2.2 評価方法

クラスタリングの結果を  $C = \{C_1, C_2, \dots, C_k\}$ 、正解となるクラスタリングを  $A = \{A_1, A_2, \dots, A_k\}$  とする。  $X_{ij}$  を  $|C_i \cap A_j|$  つまり  $C_i$  と  $A_j$  に共通に属するデータの個数とする。

### エントロピー

エントロピーは最も標準的に用いられている評価尺度である。各クラスタ  $C_i$  に対するエントロピー  $E_i$  を下式で表す。

$$E_i = - \sum_{h=1}^k P(A_h|C_i) \log P(A_h|C_i) \quad (4.3)$$

$$P(A_h|C_i) = \frac{|A_h \cap C_i|}{|C_i|} = \frac{x_{ih}}{\sum_{j=1}^K x_{ij}} \quad (4.4)$$

クラスタのデータ数による重み付き平均によって全体のエントロピーを下式で求める。(N はデータ数)

$$\sum_{i=1}^k \frac{|C_i|}{N} E_i = \sum_{i=1}^k \frac{\sum_{j=1}^k x_{ij}}{N} E_i \quad (4.5)$$

この値は0から1の値をとり、値が低いほどクラスタリングの結果が良好であることを意味する。

## 純度

純度は、エントロピーと同様、標準的な評価尺度である。クラスタ  $C_i$  が正解のクラスタ  $A_h$  のデータをどの程度含むかという指標  $P_i$  を下式で表す。

$$P_i = \frac{1}{|C_i|} \max_h |C_i \cap A_h| \quad (4.6)$$

各クラスタのデータ数  $N$  による重み付き平均をとることで純度を下式で求める。

$$\sum_{i=1}^k \frac{|C_i|}{N} P_i = \frac{1}{N} \sum_{i=1}^k \max_h |C_i \cap A_h| \quad (4.7)$$

この値は0から1の値をとり、値が高いほどクラスタリングの結果が良好であることを意味する。

## F 値

F 値は、情報検索における標準的な評価方法であり、再現率と精度の調和平均で求める。クラスタリングにおける F 値はそれを応用したものである。正解のクラスタ  $A_h$  と得られたクラスタ  $C_k$  に対する再現率  $R_{hk}$  と精度  $P_{hk}$  を下式で求める。

$$R_{hk} = \frac{|A_h \cap C_k|}{|A_h|} \quad (4.8)$$

$$P_{hk} = \frac{|A_h \cap C_k|}{|C_k|} \quad (4.9)$$

$A_h$  と  $C_k$  に対する F 値  $F_{hk}$  は、 $R_{hk}$  と  $P_{hk}$  の調和平均である。

$$F_{hk} = \frac{2R_{hk}P_{hk}}{R_{hk} + P_{hk}} \quad (4.10)$$

クラスタリング結果に対する F 値は、 $A_h$  に対して、 $F_{hk}$  が最大になるように  $k$  を求めて  $F_{hk}$  を算出し、各  $h$  に対して重み付き平均をとったものである。

$$F = \sum_{h=1}^K \frac{|A_h|}{N} \max_k F_{hk} \quad (4.11)$$

この値は0から1の値をとり、値が高いほどクラスタリングの結果が良好であることを意味する。

### 4.2.3 実験方法

実験は、学生4人に協力してもらった。被験者には、3.3で得られた2つのテーマ(表3.1)に対するラベルをグルーピングしてもらい、この結果を正解データとして扱う。その結果と比較することで、提案した手法の評価を行う。

### 4.2.4 実験結果

実験結果のエントロピーを表4.1に、純度を表4.2に、F値を表4.3に示す。エントロピーの値はテーマ2が0.16と低くて良い結果が出ている。純度の値は両テーマとも値が高く良い結果が出ている。F値は、両テーマとも0.5以下で良くない結果が出ている。これは、提案した手法で得られたクラスタの結果の大半が1つのラベルのみを持つグループだったのと、正解のクラスタの数と得られたクラスタの数に差があったことが理由として考えられる。

表 4.1: エントロピー

	テーマ 1	テーマ 2
被験者 1	0.40	0.17
被験者 2	0.46	0.19
被験者 3	0.24	0.09
被験者 4	0.38	0.18
平均	0.37	0.16

表 4.2: 純度

	テーマ 1	テーマ 2
被験者 1	0.80	0.90
被験者 2	0.75	0.88
被験者 3	0.87	0.87
被験者 4	0.80	0.87
平均	0.81	0.88

表 4.3: F 値

	テーマ 1	テーマ 2
被験者 1	0.31	0.35
被験者 2	0.51	0.38
被験者 3	0.15	0.75
被験者 4	0.29	0.50
平均	0.31	0.50

### 4.3 考察

実験の結果、エントロピーと純度を見ると良い結果のように思えるが、再現率が要素にある F 値が高くないのは、今回のクラスタリングの方法が良くなかったことを示している。さらに、提案した手法で得られたクラスタ結果のほとんどのグループが 1 つのラベルしか含まないものであったことは、提案した手法がラベルのクラスタリングを正しく行ったとは言えないと考える。このことを改善するためには、1 つずつのラベルの情報量を増やす必要があると考える。

## 第5章 WordNetを用いたラベルのクラスタリング

第5章では、第4章の実験結果を踏まえて、WordNetの情報を用いてラベルのクラスタリングをする方法について述べる。

第4章の実験では、ラベル内の単語の情報でコサイン類似度を求めて、その値を基にラベルのクラスタリングを行った。第4章で提案した手法で得られるクラスタ結果は、ほとんどのグループが1つのラベルしか含まないものだった。そのため、第4章の結果は十分にラベルのクラスタリングを行ったとは言えない。この結果を改善するためには、1つのラベルから抽出する情報の量を増やす必要がある。

この章では、1つのラベルから抽出できる情報量を増やすためにWordNetを用いる。WordNetには、各単語ごとに上位語、下位語、含意語などの情報があるため、これを使うことで1つのラベルから抽出できる情報量を増やすことができると考えた。

### 5.1 提案手法

今回の提案手法では、第3章で提案したMeCabを用いてラベルごとにラベル内の単語を抽出する手法に加えて、MeCabを用いて得たラベル内の単語を基にWordNetを使用して、各単語の上位語、下位語、含意語を取得する。MeCabとWordNetを使用して得た単語(名詞、動詞、形容詞、形容動詞)、上位語、下位語、含意語の情報を基に、階層的クラスタ分析を行う。階層的クラスタ分析は、Rを用いて行う。Rを用いた階層的クラスタ分析については、5.1.2で述べる。

### 5.1.1 WordNet

WordNet は概念辞書 (意味辞書) である。通常の WordNet は、英単語の情報が乗っているが、今回は日本語の文章の解析を行うので日本語の WordNet を用いる [7]。日本語の WordNet 情報を取得するために、今回は JAWJAW[8] を使用する。JAWJAW を使用することで、下記の上位語、下位語、含意語を取得する。

- 上位語 : 全ての  $X$  が  $Y$  の一種であるなら、 $Y$  は  $X$  の上位語である。
- 下位語 : 全ての  $Y$  が  $X$  の一種であるなら、 $Y$  は  $X$  の下位語である。
- 含意語 :  $X$  が起こる場合必然的に  $Y$  が起こるなら、 $Y$  は  $X$  に引き起こされている。

図 5.1 は、学習の上位語、下位語、含意語のリストである。1 行目が上位語、2 行目が下位語、3 行目が含意語を示している。

```
hypernyms of 学習 : [覚込む, 憶込む, 学修, 覚えこむ, 修める, 覚える, 修得, 修する, 学び取る  
hyponyms of 学習 : [受容れる, 取り込む, 受け入れる, 受入れる, 同化, 取入れる, 取込む, 取り;  
学習 entails : [紐解く, 読む, 読書, 披見, 書見, 繰く, 閲覧, 拝読, 閲読, 多読, 拝見, 手
```

図 5.1: 日本語 WordNet の例

### 5.1.2 階層的クラスタリング

我々は選んだクラスタリングの手法は、階層的クラスタリングを適用する [6]。階層的クラスタリングでは、図 5.2 のように平面的または空間的距離を基に、図の右のような樹形図 (デンドログラム) を作り、任意の距離を閾値として設定することでクラスタリングを行う。一般的に、階層的クラスタリングでは分類に用いるための対象間の距離を求めた後、求めた数値を基にクラスタ間の距離の測定を行う。




図 5.2: 階層的クラスタ ([9] より引用)

対象間の距離を求める方法として、ユークリッド距離やコサイン距離などがある。今回は、クラスタ分析に R 言語を使用しているため、R に元から実装されているユークリッド距離を用いる。ユークリッド距離は、日常で用いられる距離で最も一般的なものである。平面なら 2 点の座標が求まればピタゴラスの定理で表せる。これを  $n$  次元空間に拡張したものは、下式で表せる。

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2} \quad (5.1)$$

クラスタ間の距離の測定方法として、今回は最近隣法、最遠隣法、群平均法、重心法、ワード法を用いた。

- 最近隣法は、2つのクラスタのそれぞれの中から1個ずつサンプルを選んでサンプル間の距離を求め、それらの中で最も近いサンプル間の距離を2つのクラスタ間の距離とする方法である。(図 5.3)




図 5.3: 最近隣法のイメージ ([9] より引用)

- 最遠隣法は、最近隣法とは逆に、2つのクラスタの中のそれぞれの中から1個ずつサンプルを選んでサンプル間の距離を求め、それらの中で最も遠いサンプル間の距離を2つのクラスタ間の距離とする方法である。(図5.4)




図 5.4: 最遠隣法のイメージ ([9] より引用)

- 群平均法は、最近隣法と最遠隣法を折衷した方法で、2つのクラスタのそれぞれの中から1個ずつサンプルを選んでサンプル間の距離を求め、それらの距離の平均値を2つのクラスタ間の距離とする方法である。(図5.5)



図 5.5: 群平均法のイメージ ([9] より引用)

- 重心法は、クラスタのそれぞれの重心（例えば、平均ベクトル）を求め、その重心間の距離をクラスタの間の距離とする方法である。
- ウォード法は、2つのクラスタを融合した際に、群内の分散と群間の分散の比を最大化する基準でクラスタを形成していく方法である。(図5.6)






図 5.6: ウォード法のイメージ ([9] より引用)

これらの方法で求まるクラスタ間の距離は下式で表せる. 式中の  $d_{ij}, d_{(ij)k}, d_{ik}, d_{jk}$  は図 5.7 で,  $x_i, x_j, y, z$  はパラメータ (係数) である. パラメータと上述の方法との対応関係を表 5.1 に示す.

$$d_{(ij)k} = x_i d_{ik} + x_j d_{jk} + y d_{ij} + z |d_{ik} - d_{jk}| \quad (5.2)$$




図 5.7: クラスタ間の距離 ([10] より引用)

表 5.1: 方法とパラメータとの対応表 ( $n_i$ はクラス  $c_i$ の個体数)([10] より引用)

方法の名称	$x_i$	$x_j$	$y$	$z$
最近隣法	$\frac{1}{2}$	$\frac{1}{2}$	0	$-\frac{1}{2}$
最遠隣法	$\frac{1}{2}$	$\frac{1}{2}$	0	$\frac{1}{2}$
群平均法	$\frac{n_i}{n_i+n_j}$	$\frac{n_j}{n_i+n_j}$	0	0
重心法	$\frac{n_i}{n_i+n_j}$	$\frac{n_j}{n_i+n_j}$	$-a_i a_j$	0
ワード法	$\frac{n_i+n_k}{n_i+n_j+n_k}$	$\frac{n_j+n_k}{n_i+n_j+n_k}$	$-\frac{n_k}{n_i+n_j+n_k}$	0

これらの距離の測定方法を使うことで、樹形図を作ることができる。階層的クラスタリング分析では、クラスタの数を指定することで樹形図を切断すると個体が属するクラスが決定される。

## 5.2 評価実験 1

今回提案した手法のアルゴリズムの評価を行う。

### 5.2.1 実験内容

提案した手法でラベルのクラスタリングした結果と正解クラスタリングを比較する。実験の目的は、第 4 章で提案した手法の時に問題として挙げられたグループの中身に 1 つのラベルしか含まないという結果を起こさないかどうかと関連したラベル同士を同じグループとして正しくクラスタリングできているかどうかを評価する。評価方法は、第 4 章で用いたものと同じ、エントロピー、純度、F 値を用いる (4.2.2 章)。

### 5.2.2 実験方法

実験で用いるラベルのデータは、Wikipedia の記事から抽出する。ラベルは、10 のジャンルから記事を選び、それぞれの記事から文章を 3 つ抽出して 1 つのグループとした。実験では、10 の記事 (グループ)、30 のラベルを 1 つのデータセットとして扱う。データセットは、ジャンル 1 種類のを 4 つ、ジャンル 2 種類のを

を8つ、ジャンル5種類のを4つ、ジャンル10種類のを4つ用意した。データセットをアルゴリズムで分析した結果と正解データを比較することで、提案した手法のアルゴリズムの評価を行う。クラスタリング分析は、ラベルの単語のみ、単語と上位語、単語と下位語、単語と含意語、単語と上位語と下位語、単語と上位語と含意語、単語と下位語と含意語、全部の8種類について行う。

### 5.2.3 実験結果

実験結果における各ラベルの単語、上位語、下位語、含意語の数を表5.2に示す。各単語の平均は、ラベル内の単語が396、上位語が5438、下位語が9707、含意語が61である。各単語は被りが出ないように抽出を行う。

エントロピーを図5.8～図5.12に示す。エントロピーの値は、

- ジャンル1種類の際は、単語と下位語で最遠隣法の時と単語と下位語と含意語で最遠隣法の時、0.39で値が1番低い。
- ジャンル2種類の際は、単語と上位語でワード法の時と単語と上位語と含意語でワード法の時、0.43で値が1番低い。
- ジャンル5種類の際は、単語と上位語と下位語でワード法の時と全部でワード法の時、0.41で値が1番低い。
- ジャンル10種類の際は、単語と上位語と含意語で最遠隣法の時、0.48で値が1番低い。
- 全セットの際は、単語と上位語でワード法の時と単語と上位語と含意語でワード法の時、0.45で値が1番低い。

純度を図5.13～図5.17に示す。純度の値は、

- ジャンル1種類の際は、単語と上位語と含意語でワード法の時、0.78で値が一番高い。
- ジャンル2種類の際は、単語と上位語でワード法の時と単語と上位語と含意語でワード法の時、0.77で値が一番高い。

- ジャンル 5 種類の際は，単語と上位語と下位語でワード法の時と全部でワード法の時，0.78 で値が一番高い。
- ジャンル 10 種類の際は，単語と上位語と含意語で最遠隣法の時，0.74 で値が一番高い。
- 全セットの際は，単語と上位語でワード法の時と単語と上位語と含意語でワード法の時，0.76 で値が1 番高い。

F 値を図 5.18～図 5.22 に示す。F 値の値は，

- ジャンル 1 種類の際は，単語と上位語でワード法の時，0.78 で値が一番高い。
- ジャンル 2 種類の際は，単語と上位語でワード法の時と単語と上位語と含意語でワード法の時，0.77 で値が一番高い。
- ジャンル 5 種類の際は，単語と上位語と下位語でワード法の時と全部でワード法の時，0.78 で値が一番高い。
- ジャンル 10 種類の際は，単語と上位語と含意語で最遠隣法の時，0.74 で値が一番高い。
- 全セットの際は，単語と上位語でワード法の時と単語と上位語と含意語でワード法の時，0.76 で値が1 番高い。

これらの結果より，WordNet から抽出するデータは，上位語があれば，良いクラスタリング結果が得られることがわかる。クラスタの距離の測定方法は，ワード法が一番良く，その次に最遠隣法が良いことが分かる。したがって，ラベル内の単語と上位語のデータを使って，ワード法でクラスタ間の距離を測定する方法が適していることがわかる。

表 5.2: 各データ別の単語, 上位語, 下位語, 含意語の数

	単語	上位語	下位語	含意語
データ 1	363	4962	9360	65
データ 2	329	5341	10419	36
データ 3	362	4761	9012	36
データ 4	413	5673	9994	62
データ 5	430	6077	9536	51
データ 6	417	5797	9633	87
データ 7	425	5759	9977	72
データ 8	442	5884	9978	87
データ 9	357	4980	9788	48
データ 10	415	6005	10272	48
データ 11	430	5005	10344	69
データ 12	426	5612	10599	46
データ 13	354	5423	9734	53
データ 14	414	5608	9227	72
データ 15	391	5620	9788	57
データ 16	392	5338	9578	54
データ 17	388	5142	9316	67
データ 18	416	5595	10157	67
データ 19	380	5113	8408	68
データ 20	372	5057	9024	69
平均	396	5438	9707	61




図 5.8: エントロピー：ジャンル 1 種類




図 5.9: エントロピー：ジャンル 2 種類




図 5.10: エントロピー：ジャンル 5 種類




図 5.11: エントロピー：ジャンル 10 種類




図 5.12: エントロピー：全セット




図 5.13: 純度：ジャンル 1 種類






図 5.14: 純度：ジャンル 2 種類




図 5.15: 純度：ジャンル 5 種類




図 5.16: 純度：ジャンル 10 種類




図 5.17: 純度：全セット




図 5.18: F 値：ジャンル 1 種類




図 5.19: F 値：ジャンル 2 種類




図 5.20: F 値：ジャンル 5 種類




図 5.21: F 値：ジャンル 10 種類




図 5.22: F 値：全セット

## 5.3 評価実験 2

今回提案した手法を実際のラベルワークのグルーピングの作業の中に組み込んだ時にどのような効果が出るのかについて、実験を行う。

### 5.3.1 実験内容

第五章で提案手法を使った時と提案手法からの情報がない時の環境で、被験者に実際にグルーピングしてもらい、比較を行う。実験の目的として、ラベルワークのグルーピングの作業時に、提案手法がラベルワークのグルーピングにどのような影響を与えるのか、提案手法からの情報がない環境の時と比較して評価する。

#### 使用する物、環境

実験のラベルワークの際に、第 3 章で提案したシステムを用いるために、タブレット端末として Apple 社の iPad2(メモリ 16GB) を 4 台使用した。

### 5.3.2 実験方法

被験者の人数は、学生3人で行う。被験者には、5.2で用いたデータセットの内、ジャンル1種類のものから3つ選び、ラベルのクラスタリングをしてもらう。実験は、提案手法によるクラスタリングの情報がない場合とクラスタリングの情報をラベルの色に反映させた場合とクラスタリングの情報をラベルの色と位置に反映させた場合の3段階で行う。データと実験の段階の組み合わせを表5.3に示す。正解データとの一致率や作業時間をデータとして取得した。提案手法の使用感や改善点などを収集するために、実験後にアンケートを実施した。

表 5.3: データと手法の組み合わせ

	ラベルの色1色	ラベルの色分け	色分けと配置
被験者 1	データ 1	データ 2	データ 3
被験者 2	データ 2	データ 3	データ 1
被験者 3	データ 3	データ 1	データ 2

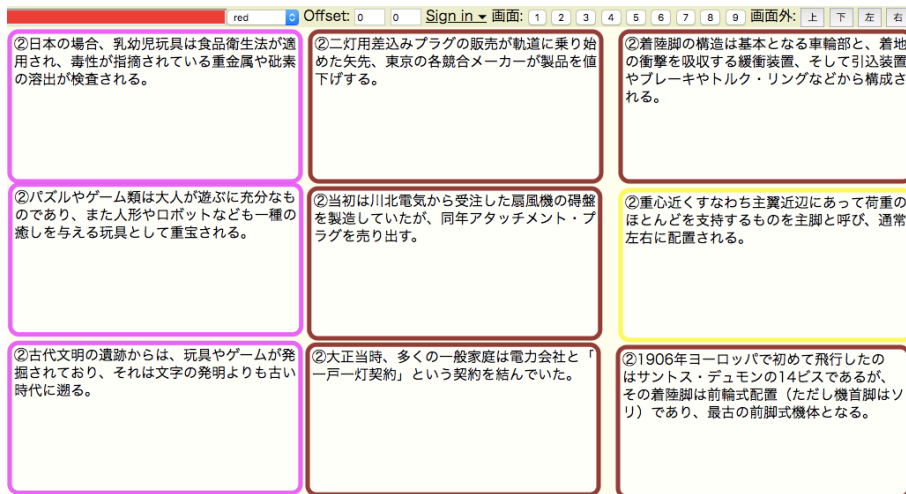


図 5.23: ラベルワークの画面

### 5.3.3 実験結果

実験をした結果として、被験者のクラスタリングの結果と正解データとのエントロピーを表 5.4 に、純度を表 5.5 に、F 値を表 5.6 に示す。被験者 1 と 2 の方は、全体的に 3 つの指標の値も良かったが、被験者 3 の方は提案手法による情報が増えると 3 つの指標の値とも良くなっている。しかし、全体的に 3 つの指標の値が良かったため、一概にどの段階がいいとは言えないと考える。実験時の作業時間を図 5.24 に示す。作業時間は、被験者によって結果がバラバラになった。そのため、作業時間からもどの段階がいいとは言えないと考える。

表 5.4: エントロピー

	ラベルの色 1 色	ラベルの色分け	色分けと配置
被験者 1	0.00	0.00	0.19
被験者 2	0.00	0.00	0.19
被験者 3	0.41	0.32	0.00
平均	0.14	0.11	0.13

表 5.5: 純度

	ラベルの色 1 色	ラベルの色分け	色分けと配置
被験者 1	1.00	1.00	0.90
被験者 2	1.00	1.00	0.90
被験者 3	0.77	0.83	1.00
平均	0.92	0.94	0.93

表 5.6: F 値

	ラベルの色 1 色	ラベルの色分け	色分けと配置
被験者 1	1.00	1.00	0.90
被験者 2	1.00	1.00	0.90
被験者 3	0.77	0.83	1.00
平均	0.92	0.94	0.93




図 5.24: 作業時間

### 5.3.4 アンケート

実験の際に、アンケートを下記の内容で行った。アンケート結果を図 5.25, 図 5.26, 図 5.27 に示す。アンケート結果を見ると、クラスタリングの結果を色と位置に反映させるよりも、色だけに反映させる方が使用者には参考になると考えられる。アンケートで書かれた意見の中には、「ラベルの色は参考になったが色を注視しすぎてラベルの内容で判断している感じにならなかった」という意見や「クラスタリング結果が正解データと違う時は悩む元になった」という意見があった。今回は、提案手法でクラスタリングする際に正解データのクラスタ数と同じ数だけクラスタしているため、このクラスタの数を変えると結果が変わる可能性も考えられる。また、「提案手法によるクラスタリングへの信用度が低いため、参考にしづらかった」という意見もあった。



アンケート内容

何もなし

- クラスタリングのやりやすさ (4段階)
- ラベルの見やすさ (4段階)

色

- クラスタリングのやりやすさ (4段階)
- ラベルの見やすさ (4段階)
- ラベルの色が参考になったか (4段階)

色と位置

- クラスタリングのやりやすさ (4段階)
- ラベルの見やすさ (4段階)
- ラベルの色が参考になったか (4段階)




図 5.25: 何もなし (4段階評価)




図 5.26: 色 (4 段階評価)




図 5.27: 色と位置 (4 段階評価)

## 5.4 考察

実験1の結果を見ると、WordNetの情報を追加したことにより第4章の手法よりも良いクラスタリングができたのではないかと考える。実験1の結果から他にわかることは、WordNetのデータをあるだけ増やすのではなく、上位語か下位語のどちらかを追加するだけの方が結果は良いとわかる。含意語は元のデータの数が多くなかったため、クラスタリングの結果に多少しか影響を与えなかった。

実験2の結果を見ると、提案手法のクラスタリングの情報は影響を多少しか与えていないように見える。被験者に意見からは、ないよりはあった方が便利という意見があった。今回は、Wikipedia記事の一部から抜粋したものであるため、KJ法などのもっと短い文章の時はもっと違う結果になる可能性があると考えられる。

## 第6章 結論

### 6.1 まとめ

本論文では，グループラベルワークにおける自然言語処理技術の適用とその効果を実験し，評価した．グループラベルワークにおける自然言語処理技術の適用として，ラベル内の単語とそれに基づく WordNet の情報でラベルのクラスタリングを行った．実験では，Wikipedia の記事の一部から抜粋したデータで提案手法を評価した．また，被験者にもラベルワークしてもらうことでも提案手法の評価を行った．実験の結果から，WordNet の情報は上位語を，クラスタ間の距離の測定にはウォード法を使うと一番良いクラスタリング結果になることが分かった．被験者の意見から，提案手法によるクラスタリングの結果が多少なりとも役に立つことがわかる．

### 6.2 今後の展望

今回の実験の際の被験者の意見から，提案手法のクラスタリング結果の信用度が低いことを指摘された．これを改善する方法は，何度も提案手法によるクラスタリングのシステムを用いてもらうことで，信用度を上げるしかないと考える．他には，今回は提案手法によるクラスタリングのクラスタの数が一定だったが，クラスタの数をグループラベルワークのグルーピングの作業中に変えられるともっと参考になる可能性があると考えられる．

## 謝辞

修士論文を完成するにあたり、ご指導ご教授くださりました三浦准教授に御礼申し上げます。また、サーベイ輪講や中間発表においてご指導やご教授を下さりました情報セクションの先生方に御礼申し上げます。加えて、本論文のデータ収集実験や評価実験において、被験者としてご参加頂き、アドバイスをくださった三浦研究室の学生と情報セクション、総合システムの学生にお礼を述べたいと思います。最後に、私の意思を尊重して下さり大学での勉学を応援して頂き、経済面や生活面において、ご支援をして頂いた家族に心から感謝申し上げます。

## 参考文献

- [1] Julian Sedding and Dimitar Kazakov. Wordnet-based text document clustering. In *ROMAND '04 Proceedings of the 3rd Workshop on RObust Methods in Analysis of Natural Language Data*, pp. 104–113, August 2004.
- [2] 由井蘭隆也, 宗森純. 分散協調型 KJ 法におけるグループ知評価の検討. 一般社団法人情報処理学会 研究報告 IPSJ SIG Technical Report, March 2014.
- [3] 川喜田二郎記念編集委員会 (編). 融然の探検-フィールドサイエンスの思潮と可能性. 清水弘文堂書房, August 2012.
- [4] 久野靖, 大木敦雄, 角田博保, 粕川正充. 「アイコン投げ」ユーザインタフェース. コンピュータソフトウェア, Vol. 13, No. 3, pp. 230–240, 1996. <http://ci.nii.ac.jp/naid/110003743920>.
- [5] MeCab. <http://taku910.github.io/mecab/>.
- [6] 新納浩幸 (編). R で学ぶクラスタ解析. オーム社, November 2007.
- [7] 日本語 WordNet. <http://compling.hss.ntu.edu.sg/wnja/>.
- [8] JAWJAW: JAva Wrapper for Japanese WordNet. <http://www.cs.cmu.edu/~hideki-software/jawjaw/index.html>.
- [9] 階層的クラスタ分析. [https://www.albert2005.co.jp/knowledge/data\\_mining/cluster/hierarchical\\_clustering](https://www.albert2005.co.jp/knowledge/data_mining/cluster/hierarchical_clustering).
- [10] R とクラスタ分析. [https://www1.doshisha.ac.jp/~mjjin/R/Chap\\_28/28.html](https://www1.doshisha.ac.jp/~mjjin/R/Chap_28/28.html).

## 発表論文リスト

- Syuuya Tanaka, Motoki Miura: Collaborative Group Label Work System based on Web Technology, 5th International Conference on Smart Computing and Artificial Intelligence, Hamamatsu, pp. 913-916, July 2017.
- Syuuya Tanaka, Motoki Miura: Collaborative Group Label Work System based on Web Technology, Information Engineering Express, International Institute of Applied Informatics, Vol. 4, No. 2, pp. 33-45, June 2018.