特集論文

Fish Eye マッチング：概念体系を利用した視点抽出に基づく文書整理支援機能

Fish-Eye Matching: A Document Organizing Function Based on the Extraction of User's Viewpoint using Concept Structure

高間　康史[*]　石塚　満[*]
Yasufumi Takama　Mitsuru Ishizuka

[*] 東京大学工学部電子情報工学科
Dept. of Information & Communication Engineering, School of Engineering, University of Tokyo, Tokyo, 113-8656, Japan.

1998年4月2日　受理

Keywords: feature vector, similarity among documents, concept structure, fish-eye matching, information organization

Summary

Recent rapid growth of information environment such as the Internet makes it easy for us to get vast information. On the other hand, “information overflow” is becoming a serious problem. That is, available information resources are too much for human to utilize, and sometimes confuse human's activity. In this paper, we propose a new mechanism for discovering a similarity among documents. This mechanism is called “Fish Eye Matching”, which generates a feature vector from a text dynamically based on a concept structure derived from an electronic dictionary such as EDR. Using this concept structure, this mechanism can use semantic relations among words, which have not been considered in existing feature vector paradigms, and reorganize information space dynamically according to users' interests. This paper also presents a prototype system for supporting information organization process based on this Fish Eye Matching method.

1. まえがき

インターネットに代表される情報環境の急速な整備・拡大により，研究や仕事などに必要となる情報を収集する過程はますます容易になりつつある．その反面，入手可能な情報量が人間の情報処理能力を越え，かえって効率が低下するという，いわゆる「情報過多(information overflow)」が問題となってきている．例えば，あるテーマに関して収集された論文やニュース記事の量が増えるに従って，個々のドキュメントを「熟読」すること，言い換えれば各ドキュメントの表す事柄を正しく把握し，それらの間に成立する関係（類似，対立など）を見出すことは困難となる．

この様な事態に対し，人間の情報処理能力に関する知的増幅器（intelligent amplifier）として計算機が果たす役割は，今後ますます重要となっていくことが想定される．

我々は，インターネット等を通じて大量に収集された文書を熟読し，有効に活用するためには，各文書間の関係を整理しながら漸進的に読み進めていくことが有効であり，この過程を計算機によって効率的に支援するためには，その時点におけるユーザの興味・視点で捉えた場合の各文書間の関係を見出すことが必要であると考える．

この様な観点から，我々は **Fish Eye** マッチングと呼ぶ，概念体系を利用した新しい動的ベクトル生成・マッチング機構を提案している [高間 97]．**Fish Eye** ベクトルは，情報検索の分野で代表的なベクトル空間モデル [細野 94] の拡張モデルであり，単語間に存在す

る意味関係を利用して，ユーザの興味・視点を反映した特徴を動的に生成する．これによってベクトル空間モデルの持つ検索能力に加え，視点を外化することが可能となるため，ドキュメント間の類似性，差異を多様な視点から判断するのに有効であると考える．本稿では Fish Eye マッチングの概要および，これを基盤技術として用いた文書整理支援システムについて報告する．

続く **2** 章では，従来の特徴ベクトルと比較しながら，提案する Fish Eye マッチングの概要について説明する．Fish Eye ベクトルを構成する意味グループの自動抽出法については **3** 章で説明する．Fish Eye マッチングによる文献検索の評価実験について **4** 章 で示した後，**5** 章で文書整理支援システムへの応用について述べる．最後に **6** 章で他の研究との比較，検討を行う．

2. Fish Eye マッチング

2・1 文書整理支援

我々が論文やニュースなどを読んで考えをまとめたり，新たなアイデアを得ようとする場合，頭の中にある既存の知識と関連づけて整理していくと考えられる．この作業は，対象とする情報量が増えるにつれて困難な作業となってくるため，紙やコンピュータ上に各情報の関連を図示し，整理する事によって混乱を軽減する事が有効となる．

情報が形成する概念構造を外部に表現することは，既存の発想法 [星野 89, 川喜田 67] や発想支援システムの多くで採用されている．画面上にオブジェクトを配置・整理する過程を通じて概念の形成を支援するシステムは収束的過程支援システムと呼ばれており [國藤 93]，以下の様な効果が期待されている．

- 漠然と捉えていた自分の視点，疑問点を明確に意識することができる [遠藤 93, 篠原 93, Sugimoto 96]．
- 他者の構造との比較により，意見の相違や同意点，論点を明確にすることができる [Sumi 96, 女部田 96]．
- 図解された構造を変化させせることにより，試行錯誤や発想の飛躍などが行いやすい [高杉 96, 杉山 97]．

これは，我々の目指す文書整理支援システム，すなわち「文書の整理を通じた熟読」をユーザに促すシステムにおいても重要な点である．あるテーマ，問題に関する文書を入手してみると，比較的短時間で思った以上に多量のドキュメントが集められる．しかし，これらを片端から読んでいくことは，考えただけで気の滅入る作業であり，精神的な苦痛を感じるだけでなく，一つ一つのドキュメントを雑に読んでしまうと考えられる．

これを避けるには，ドキュメント間の関係を意識しながら読み進めることが重要であり，今までに読み進めて来たドキュメント群が形成する概念構造から，現在自分が持っている興味・視点を把握しつつ，次に読むドキュメントを決定したり，構造に追加していくことにより，個々のドキュメントをより熟読できると考える．

しかし，ユーザの持つ視点・興味や，それに基づくドキュメント群の概念構造は最初からはっきり決まっているわけではなく，ドキュメントを読み進めていくうちに，変化しつつ，徐々に明確になってくるはずである．その時点での興味の変化に伴い，今までに形成された概念構造も変化するし，次に読むべきドキュメントも異なってくるはずである．

ここで必要となるのは，視点により変化するドキュメント間の関係を捉える手法である．従来よく用いられて来たベクトル空間モデル（VSM）では，適合フィードバック [長尾 96] などを用いて，ユーザの興味・視点を反映したクエリーベクトルを作成し，これと各ドキュメントから求めた特徴ベクトル（ドキュメントベクトル）との類似度（内積）を計算する手法が一般的である．しかしこの方法ではユーザの興味がブラックボックスで扱われるため，自分の興味・視点が何であるかをユーザが明示的に知る事は難しい．

また，ベクトル空間モデルでは，各軸（単語）間の直交性が仮定されるが，実際には各単語間には類義語，反義語や上位・下位関係といった意味的な関係が存在するため，この仮定が満たされないという問題点が指摘されている．従って，ある視点から見て共通の特徴とみなせる単語群も，常に別々に扱われてしまうという問題がある．例えば「車」という単語を含む記事と「自転車」という単語をそれぞれ特徴として持つドキュメントがある場合，乗物に関する記事という点では関連があるにも関わらず，ベクトル空間上では両ドキュメント間の関係を見出す事はできない．

以上の様な問題点を扱うため，本稿で提案する **Fish Eye** マッチングでは，電子化辞書の概念体系から抽出した意味の類似した単語グループ（意味グループ）を元に，視点に合わせた特徴を動的に生成してベクトルを構成し，マッチングを行う．詳細については以下に記す．

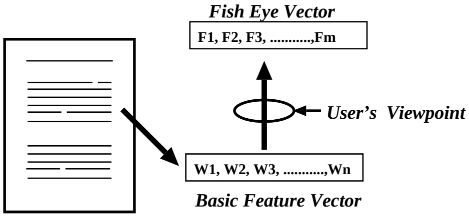

図 1　Fish Eye ベクトル生成のイメージ

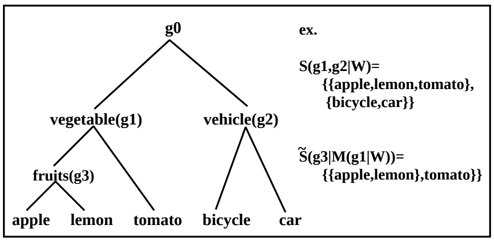

図 2　概念グループの例

2・2　Fish Eye マッチングの定義

Fish Eye マッチングでは，ユーザの視点を反映したドキュメントベクトルを生成するために，通常の特徴ベクトルに対して単語の意味的関係を考慮した拡張を施して特徴ベクトルを動的に生成する．すなわち，ドキュメント中に含まれる単語をそのまま特徴として用いた基本特徴ベクトル（**Basic Feature Vector**）から，ユーザの視点において同様とみなせる単語は一つの特徴に縮退したり，その視点に関係のある単語のみを選択したりといった操作を加えることにより，ユーザの視点・興味が変化する毎に，それに応じた特徴ベクトル空間を動的に再構成する（図 1）．この，ユーザの視点を反映して動的に生成される特徴ベクトルのことを **Fish Eye** ベクトルと呼ぶ．

視点については「そのドキュメントを読む際に仮定する，その属する話題，分野」であると考える．一つのドキュメントの属する話題が一意に決まるということは稀であり，たいていは複数の視点から読む事が可能であると考えられる．また，ある種の話題間には包含関係が存在するため，同じ角度からの視点であっても，専門的な狭い話題として捉えたり，より一般的な，広い枠組で捉えたりする事も可能である．

話題としてどういったものを考えるかであるが，本研究では EDR 電子化辞書の概念体系を利用する．すなわち，全ての話題には対応する概念が電子化辞書中に存在するものとし，その概念の範疇に含まれる単語を，特徴を構成する要素として採用する．

例として，図 2について考えてみよう．ここでは 5 つのキーワードが存在しているが，概念体系に基づいて階層化すると，apple と lemon は fruits（果物）という概念の範疇に含まれ，これに tomato を加えた三つの単語は vegetable（野菜）という概念に含まれる．これらとは別に，bicycle と car は vehicle（乗り物）という概念の範疇に含まれている[*1]．ここで，野菜に関する話題か，あるいは乗物に関する話題のどちらに属するかが区別できればいい程度の粗い視点であれば，apple，lemon，tomato を一つの特徴 vegetable に縮退し，car，bicycle も一つの特徴 vehicle に縮退して Fish Eye ベクトルを生成すれば良い．反対に，野菜の話題に集中し，野菜と果物に関する話題を区別して扱いたい場合には，apple，lemon を一つの特徴 fruits に縮退し，これと tomato を直交する特徴として用いれば良い．

話題に関係ある特徴のみをそのままとりだし，関係ない特徴を切り捨てる事は，概念体系のうちの興味ある部分だけをルーペで拡大してみることに相当する．従って，Fish Eye ベクトルは，基本特徴ベクトルに縮退（**Shrink**）と拡大（**Magnify**）という二つの操作を施して計算される．

単語集合を $W = \{w_1, w_2, \ldots, w_n\}$ とすると，これから Shrink，Magnify の各操作によって得られる Fish Eye ベクトルの特徴集合 $S(g_1, \ldots, g_m|W)$，$M(g_1, \ldots, g_m|W)$ はそれぞれ次式のように定義される．

$$\begin{aligned} S(g_1,\cdots,g_m|W) &= \\ &\{f_i|f_i=\{w_j|w_j \in g_i \land W\}, 1\leq i\leq m\} \quad (1) \\ M(g_1,\cdots,g_m|W) &= \\ &\{w_i|w_i \in (g_1\lor\cdots\lor g_m) \land W, \\ &\quad 1\leq i\leq |(g_1 \lor\cdots\lor g_m) \land W|\} \quad (2) \\ \widetilde{S}(g_1,\cdots,g_m|W) &= \\ &S(g_1,\cdots,g_m|W) \cup \overline{M}(g_1,\cdots,g_m|W) \quad (3) \\ \overline{M}(g_1,\cdots,g_m|W) &= \\ &\{w_i|w_i \in W \land \overline{g_1 \lor\cdots\lor g_m}, \\ &\quad 1\leq i\leq |W \land \overline{g_1 \lor\cdots\lor g_m}|\} \quad (4) \end{aligned}$$

ここで，g_i はある話題に関する単語のグループ（意味グループ）を表しており，特徴生成の際に背景知識

[*1] ここで例示している概念体系は例のためのものであり，EDR 概念体系辞書から実際に抽出したものではない

の役割を果たすといえる．意味グループの計算方法については次章に記す．また，$\widetilde{S}(g_1,\cdots,g_m|W)$ は，Shrink 操作の対象とならなかった W 中の単語についてはそのまま特徴として用いる操作であり，4 章以降で利用するため便宜上定義した．前述の例に関する各操作について，図 2に記してある．この時，$W=\{apple, lemon, tomato, bicycle, car\}$ としている．

以上の操作により求められた特徴に基づいて，基本特徴ベクトル $O_d(v_1,\cdots,v_n)$ から Fish Eye ベクトルを計算する際には，特徴 f に属する単語の，O_d における値の総和を対応する値 v_f とする．ここで，O_d の各要素の値については，TFIDF[長尾 96] などにより求められているものとする．

$$v_f = \sum_{w_i \in f} v_i \qquad (5)$$

また，Fish Eye ベクトルに基づきマッチングを行う際には，通常の特徴ベクトルにおける場合と同様の指標を用いることができる．例えば，ドキュメント d_i の話題に対する関連度 $Mag(d_i)$ は対応する Fish Eye ベクトルの長さ，ドキュメント d_i, d_j 間の類似度 $Sim(d_i, d_j)$ は両ドキュメントに対する Fish Eye ベクトルの内積によって計算することができる．すなわち，ドキュメント d_i, d_j に対する Fish Eye ベクトルをそれぞれ $F_i(v_{i1},\cdots,v_{im})$，$F_j(v_{j1},\cdots,v_{jm})$ とすると，次式の様に表される．

$$Mag(d_i) = \sqrt{\sum_{j=1}^{m} v_{ij}^2} \qquad (6)$$

$$Sim(d_i, d_j) = \frac{\sum_{k=1}^{m} v_{ik} \cdot v_{jk}}{Mag(d_i) \cdot Mag(d_j)} \qquad (7)$$

3. 意味グループの抽出

3・1 概念体系辞書からの意味グループの計算

本研究で使用している EDR 電子化辞書では，概念に関する辞書として，概念間の上下関係を規定する概念体系辞書と，概念間のそれ以外の関係を規定する概念記述辞書，および各概念を言葉で説明する概念見出し辞書が用意されている．このうち，本研究では概念体系辞書から意味グループを計算している．概念体系辞書によって整理される概念体系は，一般のシソーラスなどと同様に，各概念をノードとし，上下関係のあるものをノードで結んだ木構造の形に体系化される[2]．前述したように，Fish Eye ベクトル生成演算子の引数として指定できる話題は，対応する概念が EDR 電子化辞書中に存在するとする．基本特徴ベクトルを構成する全単語について，概念体系を下層から上層へ辿りつつ，各概念ノードに対応する単語集合を求め，単語数が 2 から 256 の範囲に納まる概念ノードを意味グループとして用いている．この処理により，どの意味グループにも属さない単語が存在する可能性があるが，この場合には例外的に，単語数が 1 の意味グループとして扱う．

電子化辞書に記述された概念体系は，我々の常識を体系化したものと考えることができるので，話題に応じた特徴を生成するために単語をグループ化する際の制約として適していると考えられる．

3・2 視点を表す意味グループ抽出アルゴリズム

前節で定義した二つの演算子 Magnify，Shrink は，表裏の関係にあるといえる．すなわち，同じ意味グループに対し，ドキュメント間の大まかな関係を概略視するには Shrink，ある視点・興味のみについて詳細に比較したい場合には Magnify を行えばよいと考えられる [高間 97]．従って，引数とすべき意味グループは，Shrink 操作を元にした以下のアルゴリズムで求めることができる．

ここで，ユーザの興味・視点に関連するドキュメント集合を D_P，関連しないドキュメント集合を D_N とする．これらは，今までに読んだドキュメント集合に対するユーザの分類といった形で得ることができる．また，初期化として，基本特徴ベクトル空間を構成する全単語をリスト $Wlist$ に登録する．以下で，v_{ji} はドキュメント d_j に対する基本特徴ベクトル O_{d_j} 中の，単語 $word_i$ に対応する要素の値とする．

(1) $Wlist$ 中の各単語 $word_i$ について，適合フィードバック [長尾 96] と同様の式により重み w_i を計算[3]．

$$w_i = \alpha \frac{1}{|D_P|} \sum_{d_j \in D_P} v_{ji} - \frac{1}{|D_N|} \sum_{d_j \in D_N} v_{ji} \qquad (8)$$

(2) $Wlist$ 中より，正かつ最大の重み w_k を持つ単語 $word_k$ を取り出す．なければ終了．

(3) 意味グループ集合 $G_k = \{g_i \mid (word_k \in g_i) \wedge (\forall word_j \in g_i, word_j \in Wlist) \wedge (\forall word_j \in g_i, w_j \geq 0)\}$ を求める．これは，$word_k$ を含むグループのうち，すでに抽出された他のグループと単語を一つも共有せず，かつグループ中に負の重みを持つ単語を含まないものを選択している．

---

[2] 多重継承を許すため，厳密には木構造にならない

[3] α は，正例，負例のバランスをとる適当な係数である

(4)　(3) で求めた G_k 中の各グループ g_i について，重み W_{g_i} を次式にしたがって計算する．$G_k = \emptyset$ の場合には (6) へ．

$$W_{g_i} = \frac{1}{|g_i|} \sum_{word_j \in g_i} w_j \tag{9}$$

(5)　G_k 中で，重みが最大のグループ g_l を抽出．$\{Wlist\} = \{Wlist\} - \{word_i | word_i \in g_l\}$ として (2) へ．

(6)　$\{Wlist\} = \{Wlist\} - \{word_k\}$ として(2)へ．

ここで式 (9) により，各グループに属する単語の重みの平均をグループの評価値（重み）としている．これは，ベクトル空間モデルにおける「ユーザの興味に従った分類において，有効な指標となる重要な単語の重みは大きくなる」という仮定を拡張した「ユーザの興味を表す概念には，重要な（重みの大きい）単語が多く属している」との仮定に基づいている．すなわち平均値をとることにより，重要でない（重みの小さい）単語が多く集まった意味グループより，少数でも重要な単語のみが集まった意味グループを優先して抽出している．

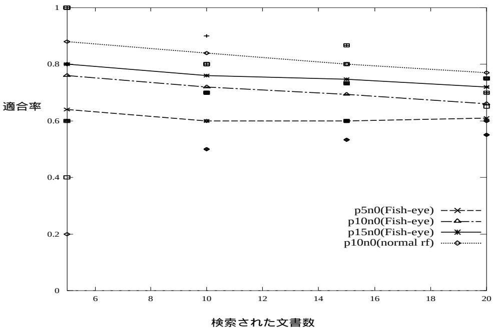

図 **3**　実験結果 (1)：負例 0，正例 5–15

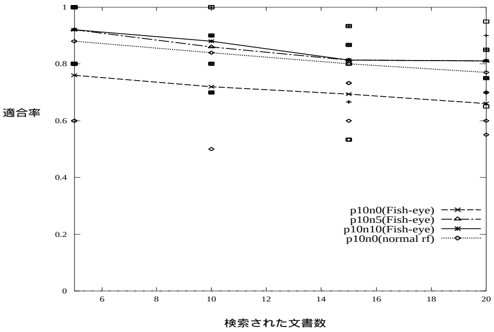

図 **4**　実験結果 (2)：正例 10，負例 0–10

4. 評価実験

4・1 実験設定

本稿で提案した Fish Eye マッチングについて評価実験を行った結果を記す．この実験の目的は，Fish Eye マッチングが，通常の特徴ベクトルと同程度の検索精度を維持しつつ，視点の外化を行える事の検証である．このため，インターネット上で公開されている，英語で記述されたオンラインニュース記事の中から，医学に関する記事を検索するタスクを行い，その適合率（Precision）について調べるとともに，抽出された意味グループについて考察した．なお，ニュース記事が医学に関するかどうかの判定基準としては，その記事が公開されているニュースサイトにおける分類に従った．適合率 P は次式で与えられる[*4]．

$$P = \frac{\text{検索文書中の該当文書数}}{\text{検索された文書数}} \tag{10}$$

検索方法であるが，正例および負例となるニュース記事をいくつか与え，**3・2** 節に示したアルゴリズムにおいて抽出された意味グループ集合を引数として $\widetilde{S}(g_1, \cdots, g_n|W)$ 操作を行い，Fish Eye ベクトルを生成するとともに，抽出段階で得られた各グループに対する重み W_{g_i}（単語は式 (8) の値）を各要素の値としたものをクエリーベクトルとし，ドキュメント検索を行った．

対象としたニュース記事の総数は 218 であり，そのうち該当文書である医学に関するニュース記事は 100 含まれている．これらの記事に含まれる単語からストップワードを除去し，EDR 英単語辞書に名詞の意味で登録されている単語を基本特徴ベクトルの構成要素として抽出したところ，1588 単語が抽出された．さらに，得られた単語集合から **3・1** 節で示した様にして意味グループを計算したところ，655 グループが得られた．

4・2 実験結果

テスト例として，正例のみ 5 から 15 記事まで変化させて与えた場合と，正例は一定数（10）に固定し，負例を 0 から 10 記事まで変化させて与えた場合の適合率に関するグラフを図 3，図 4 にそれぞれ示す．グラフ中に示してある直線は，各条件における平均値を示している．また，横軸は検索された文書数，縦軸は適合率をとってある．また，比較のため，正例 10 記事，負例なしの条件で通常の適合フィードバックを用いてクエリーベ

[*4] 適合率と再現率の両指標を用いるのが一般的であるが，本章の目的は通常の適合フィードバックとの検索精度の比較であり，検索文書数に大きく左右される再現率での比較は不要であると判断した．

クトルを作成し，検索した場合を “p10n0(normal rf)” として両グラフに示している．また，システムの応答速度に関してであるが，Sun Ultra2（メモリ 320MB）上で実験を行った結果，意味グループの抽出および文献検索までを含めても 5 秒以内であった．

図 3より，通常の適合フィードバックより適合率は若干落ちるものの，正例を増やすにつれて適合度は上昇し，適合フィードバックの性能に近づいていくことがわかる．この時，正例の増加に連れて抽出される意味グループ数は増加していくのに対し，意味グループ当たりの平均所属単語数は減少していくことが確認された．この事は，正例の増加に伴い，式 (8) によって計算される単語の重みがユーザの興味を正しく反映するようになるだけでなく，抽出される意味グループが，一般化しすぎたものから適度な粒度のものに分割され，精度向上に貢献する事を表していると考えられる．これより，概念体系から抽出された意味グループの，特徴生成に関する制約としての妥当性，および **3・2** 節で示したアルゴリズムの有効性が確認できる．

適合フィードバックより性能が劣る理由として主に考えられるのは，次の二点である．

(1)　不適切な意味グループを特徴として抽出してしまったための誤差（意味グループによるノイズ）

(2)　意味グループ内に，不適切な単語が含まれてしまったための誤差（単語によるノイズ）．

（１）に関しては，EDR 電子化辞書から抽出された意味グループ中に適切なものが存在しなかった場合も考えられるが，それ以外の要因として，単語を意味グループに縮退する際に，一般化へのバイアスの方が強いことが考えられる．そこで負例を追加したところ，図 4に示した通り適合率が上昇し，負例なしの場合の適合フィードバックより性能がよくなることが確認された．この時，意味グループ当たりの平均所属単語数については，正例を増やした場合と同様に，負例の増加につれて減少したが，今回は抽出される意味グループ数も減少することが確認された．これより，負例の増加による適合率の上昇は，意味グループの過度な一般化が抑制される効果に加え，**3・2** 節のステップ (3) において不適切なグループが排除される効果も反映されたものと考えることができよう．後述するように，文書整理支援システムの基盤技術として Fish Eye マッチングを用いた場合には，負例が与えられるという前提は妥当であると考えられる．

残る（２）に関しては，単語の持つ意味の曖昧さや品詞の違い，単語それ自体の意味と，複合語（フレーズ）として使用された場合との意味の違いなどが原因であると考えられる．これについては，複合語を特徴として考慮したり，基本特徴ベクトルの計算時に構文解析などの技術を用い，品詞の区別をして抽出するなどの対策が考えられる．この点に関連して，[猪股 98] では日本語ドキュメントへ対応するための改良が報告されているが，これは形態素解析を利用しているため上述の問題点がある程度解消されている事が期待できる．

表 **1**　医学関係の記事から抽出された意味グループの例

概念 ID	説明	所属単語
3f98b3	健康状態の値	condit diseas sickne death health . . .
444506	生体構成物質	protei immuno choles dna
30f6da	臓器	eye brain heart lung muscle knee . . .
3f969e	病気	sympto syndro aids cancer cold . . .
44479c	医薬品	drug medica medici laxati acid . . .
30f6f7	医療器具	bandag cathet glasse contac patch

また，本実験において高頻度で抽出された意味グループの一部について，その見出し情報と，それに属する単語の一部を表 1に示す[*5]．これからも，**3・2** 節で示したアルゴリズムの有効性が確認できる．また，抽出された見出し情報や単語集合をユーザに提示することにより，現在，どの様な視点・話題によってドキュメント間の関係を捉えようとしているかを知る手がかりをユーザに提供することができる．これは，後述する文書整理支援システムへの応用を考えた際に，Fish Eye マッチングの持つ非常に大きなメリットであると言えよう．

5.　**Fish Eye** マッチングの文書整理への応用

5・1　**Fish Eye** マッチングの特徴

本稿で提案した Fish Eye マッチングの特徴を整理すると次のようになる．

- 概念体系をトップダウンの制約として，少数例から視点・興味を抽出することができる
- 視点・話題として抽出される意味グループの見出し情報や単語集合を見ることにより，現在の視点を明示的に知ることができる
- 抽出された意味グループを削除したり，追加することによる Fish Eye ベクトルの変更や修正が容易である
- 意味グループ間には階層が存在するため，視点の粒度を変更することができる
- 各ドキュメントからのベクトル生成時に動的に視点を考慮するため，2 文書間の関係を視点に合わせて動的に評価することが可能である

[*5] ステマ後の単語の語幹を示している

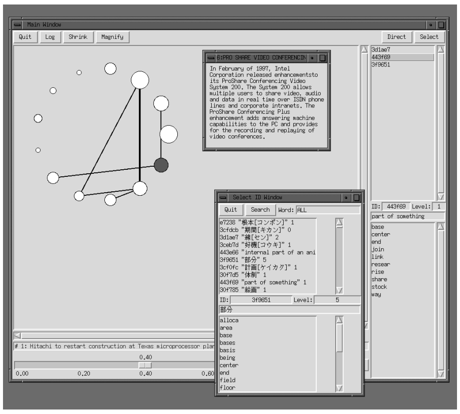

6:PRO SHARE VIDEO CONFERENCIN

In February of 1997, Intel Corporation released enhancementsto its ProShare Conferencing Video System 200. The System 200 allows multiple users to share video, audio and data in real time over ISDN phone lines and corporate intranets. The ProShare Conferencing Plus enhancement adds answering machine capabilities to the PC and provides for the recording and replaying of video conferences.

```
e7238 "根本[コンポン]" 1
3cfdcb "期間[キカン]" 0
3d1ae7 "線[セン]" 2
3ceb7d "好機[コウキ]" 1
443e66 "internal part of an ani
3f9651 "部分" 5
3cf0fc "計画[ケイカク]" 1
30f7d5 "体制" 1
443f69 "part of something" 1
30f785 "絵画" 1
ID: 3f9651 Level: 5
部分
alloca
area
base
bases
basis
being
center
end
field
floor
```

```
3d1ae7
443f69
3f9651
ID: 443f69 Level: 1
part of something
base
center
end
join
link
resear
rise
share
stock
way
```

```
# 1: Hitachi to restart construction at Texas microprocessor plan
0.40
0.00 0.20 0.40 0.60
```

図 5　文書整理支援システムの概観

これらの特徴により，**2·1** 節で説明したような文書整理支援システムの基盤技術として， Fish Eye マッチングは適していると考えられる．

5・2　**Fish Eye** マッチングを用いた文書整理プロセス

我々は， Fish Eye マッチングを基盤技術として用いた文書整理支援システムのプロトタイプを開発中である（図 5）．

メインウィンドウ（一番大きなウィンドウ）の左上部にはドキュメント間の関係がマッピングされており，各ノードがドキュメントを表している．ノードの大きさは式（6）で計算される値に基づいており，類似度（式（7））の値に応じて，各ノード間を太さの異なるリンクで結んでいる．中央下部に表示されているウィンドウは，意味グループに関する情報を表示しており，このウィンドウから手動で意味グループを選択することも可能となっている．また，現在特徴として使用されている意味グループに関してはメインウィンドウ右側に表示されており，メインウィンドウ上部にあるボタンをクリックすることによって，選択されている意味グループに基づいた Fish Eye マッチングが行われ，ウィンドウ内のレイアウトが変更される．

このツールを用いて文書整理を行うプロセスについて，簡単な例をあげて説明する．実際の画面を用いたのでは紙面上でわかりづらいと思われるので，以下では簡略化した図によりそのプロセスを紹介することとする．以降の図では，ノードのサイズは大，中，小の 3 種類で，リンクは類似度が 0.2 以上のものについては細線で，0.4 以上のものについては太線で表示している．

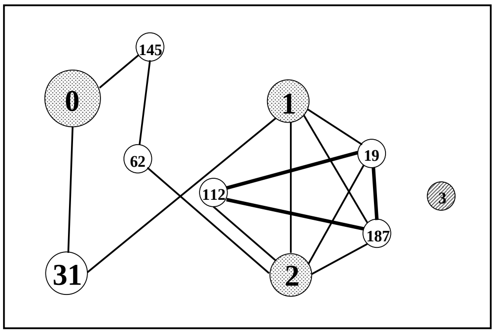

図 6　1 回目の検索終了後

まずはじめに，**4** 章で用いた総数 218 のニュース記事のうち，ある日付に配布された 5 記事を読んだとする．このうちの 3 つ（図 6中で 0，1，2）がインターネットに関する記事であったため，これらを正例，残り（3, 4）を負例として Shrink 操作による Fish Eye マッチングを行った結果，現在の視点において正例と関係があると思われる新たなドキュメントが検索され，それらの関係がリンクで表現された（図 6）[*6]

この図において新たに登場したドキュメントの中で，もっともノードサイズが大きいドキュメント 31 は「資産管理ソフトとウェブサイトの統合について」の記事である．正例であるドキュメント 0 は「インターネット上で広告を見るたびにお金が入るサービス」の話であり，インターネット関係であるという以外にも，経済の話でも関連しているといえよう．

また，ドキュメント 19, 112，187 はいずれも，車に関する記事である．これらの記事が検索された理由の一つとして，Fish Eye ベクトル生成に使用された意味グループに不適切なものがあったことがあげられる．すなわち，単語 driver と guide が「指導者」という見出しを持つ意味グループにまとめられてしまっていた．この結果，ドキュメント 2 は「インターネット上でウェブサイトをガイドする」ことについての記事であるため，車関係の記事と関係があると判断されたのであろう．しかし，他の意味グループとしては「証書」や「情報処理関係の属性」といった見出しを持った，視点に関する意味グループが抽出されている．

ここで，興味が車関係の記事に移り，ドキュメント 19，112，187，3 を正例にし，ドキュメント 0，1，2，4，31，62，145 を負例として新たに Fish Eye マッチングを行ってみた結果を図 7に示す．

この結果を見ると，ドキュメント 0 と 31 の関係が

[*6] 正例，負例は色により区別している．簡略化のため，負例の一部については省略している．

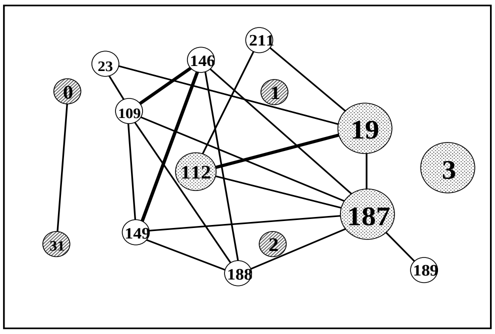

図 7　2 回目の検索終了後

そのまま保たれていることがわかる．これは前述したように，インターネットと経済の両側面で関連しているためであろう．

また，ドキュメント 146 は，ドキュメント 109，149 とそれぞれ太いリンクで結ばれているが，これらは全て，「新しい乗物（146）」や「全地形車（149）」，「新車（トラック）情報（109）」など，特徴ある車両についての記事である．また，ドキュメント 19 は「居眠り運転防止デバイス」，112 は「3D ドライビング・シミュレータ」，23 は「車内電子機器を制御する音声認識装置」の話であり，車そのものでなく関連製品・装置と言う点で関係しているといえよう．これら以外にも，ドキュメント 187，188，189 はそれぞれ，新型車や輸入車などのランキングに関する記事であり，その関係がリンクにより表現されているといえよう．

意味グループとしては，「大通り」や「vehicle」といった車に関するものや，「音声」など，新しい視点に対応するものが抽出されている．また，情報処理関係の意味グループについても，図 6の段階では 16 単語を含むグループが一つだけ抽出されたのに対し，図 7ではそれぞれ 4，5，10 個の単語を含む 3 つのグループが抽出されている．これは全体的な傾向であり，2 回目の Fish Eye ベクトルの方が，意味グループ数は増加しているのにも関わらず全体の次元数も増加している．これは，抽出された意味グループが小規模なものになったことを表しており，正例・負例数の増加によって一般化へのバイアスが抑えられたためと考えられる．

6. 他の研究との比較

本稿で提案している Fish Eye マッチングについて，関連研究との比較検討を行う．

ユーザの視点を抽出し，可視化すると言う点では，多次元尺度構成法 [角 94] やバネモデル [高杉 96] などを用いて，画面配置上の位置関係の形で表現する方法がある．これらの方法は，本来多次元であるはずのドキュメント間の関係を，二次元空間での距離に変換する際に，その誤差が極小となる様に配置する．ここで，ユーザの初期配置によって最終的に達する局所解（配置）が異なる，という性質を利用することにより，ユーザの視点を画面配置上に反映している．この方式は，ドキュメント数が増えると画面上が繁雑になりわかりづらいという欠点を持つのに対し，Fish Eye マッチングを用いた場合では，画面上での配置だけでなく，Fish Eye ベクトル生成時に使用された意味グループからも視点を読みとることが可能であるといった利点がある．

また，[Wulfekuler 96] で提案されている特徴クラスタリングでは，カテゴリが既知のドキュメント群に対し，各ドキュメントを次元とする空間において，K 平均分割クラスタリングによって特徴（単語）をグループ化し，特徴空間を低次元化することが報告されている．このアプローチは Fish Eye マッチングの Shrink 操作と非常に類似しているが，純粋に統計的な操作であるため，ほとんど全ての単語を含むグループができてしまうなどの問題がある．この点でも，Fish Eye マッチングで用いる意味グループは人間にとって理解可能な概念に対応しているため，グループ計算時に概念体系がトップダウンな制約として有効に機能するだけでなく，得られた意味グループからユーザが意味を把握しやすいといったメリットがある．

7. む　す　び

本稿では，ユーザの興味・視点を反映した動的ベクトル生成／マッチング機構である Fish Eye マッチングについて提案し，これを基盤技術として用いた文書整理支援システムについて記した．インターネットなどを通じて多量の情報が容易に入手可能となった現在，これらの情報を有効に活用するためには，その時点での視点・興味に基づき，情報間の関係を整理・構造化しながら漸進的に読み進めて行くことが重要である．概念体系を用いてユーザに可読な形で視点を抽出する Fish Eye マッチングは，この様な過程の支援に有効であると考えられる．Fish Eye マッチングは文献を単語あるいはそれらの集合体（意味グループ）の集合として表現する以上，ある話題における，著者の立場（賛成，反対）の違いなどは捉えることは困難であるが，ユーザが文献を整理し，漸進的に読み進めて行く上で，有

効なガイドとなる情報は提供できると言えよう．

現在開発中のツールは，非常にシンプルなものであり，文書間の複雑な構造を扱うことができない．今後は階層構造を許すなどの改良を加え，より扱いやすくする予定である．また，Fish Eye マッチングでは背景知識として用いる意味グループの質が重要であるため，EDR 電子化辞書からただ抽出するだけでなく，不要なグループを削除したり，新たな単語，グループを追加するなどの意味グループ集合の洗練化が有効であり，今後の課題であると考えている．

◇ 参考文献 ◇

[遠藤 93] 遠藤 聡志, 大内 東：統合型発想支援システム：FISM, 人工知能学会誌, Vol. 8, No. 5, pp. 611–618(1993).

[星野 89] 星野 匡： 発想法入門, 日本経済新聞社 (1989).

[細野 94] D. ELLIS (細野 公男監訳)： 情報検索論：認知的アプローチへの展望, 丸善 (1994).

[猪股 98] 猪股 健太郎, 高間 康史, 石塚 満：概念体系に基づく情報整理支援ツールの日本語化, 第 56 回情処全大講演論文集, pp. 3-102–103(1998).

[川喜田 67] 川喜田 二郎：発想法, 中央公論社 (1967).

[國藤 93] 國藤 進：発想支援システムの研究開発動向とその課題, 人工知能学会誌, Vol. 8, No. 5, pp. 552–559(1993).

[長尾 96] 長尾 真：11. 情報の構造化と検索, 自然言語処理, 岩波書店 (1996).

[女部田 96] 女部田 武史, 國藤 進：複数の KJ 法図解の差異や共通部を可視化する思考支援システムの実現と評価, 人工知能学会研資 SIG-J-9602-6, pp. 28–33(1996).

[篠原 93] 篠原 靖志：知識整理支援システム CONSIST-Ⅱ, 人工知能学会誌, Vol. 8, No. 5, pp. 593–600(1993).

[杉山 97] 杉山 公造: 発想支援ツール：ツール群の開発と統合化の試み – 創発メディア環境 – , 第 11 回人工知能学会全大チュートリアル (1997).

[Sugimoto 96] Sugimoto, M., Hori, K. and Ohsuga, S. : A system to visualize different viewpoints for supporting researchers' creativity, Knowledge-Based Systems, Vol. 9, No. 6, pp. 369–376(1996).

[角 94] 角 康之, 堀 浩一, 大須賀 節雄：テキストオブジェクトを空間配置することによる思考支援システム, 人工知能学会誌, Vol. 9, No. 1, pp. 139–147(1994).

[Sumi 96] Sumi, Y., Nishimoto, K. and Mase, K. : Facilitating Human Communications in Personalized Information Spaces, AAAI-96 Workshop on Internet-Based Information Systems, pp. 123–129(1996).

[高間 97] 高間 康史, 石塚 満： 概念体系を用いた Fish Eye ベクトルの情報整理支援ツールへの応用, 人工知能学会研資 SIG-FAI-9702, pp. 97–102(1997).

[高杉 96] 高杉 耕一, 國藤 進：ばねモデルを用いたアイデア触発システムの構築について, 人工知能学会研資 SIG-J-9602-7, pp. 34–39(1996).

[Wulfekuler 96] Wulfekuhler, M., R. and Punch, W., F. : Finding Salient Features for Personal Web Page Categories, 6th Int'l WWW Conference, http://www6.nttlabs.com/HyperNews/get/PAPER118.html.

著者紹介

高間 康史（学生会員）

1994 年東京大学工学部電子工学科卒業．1996 年同大学院修士課程終了．現在，同大学大学院博士課程 3 年在籍中．AI 的アプローチを採用した，知的増幅器としてのヒューマンインタフェースの研究に興味を持つ．情報処理学会会員．

⟨takama@miv.t.u-tokyo.ac.jp⟩

石塚 満（正会員）

1971 年東京大学工学部電子卒業． 1976 年同大学院博士課程終了．工学博士．同年 NTT 入社，横須賀研究所． 1978 年東京大学生産技術研究所助教授，同教授を経て， 1992 年より工学部電子情報工学科教授．研究分野は人工知能，仮説推論メカニズム，マルチモーダル擬人化エージェント，ネットワーク化知能情報環境．IEEE，AAAI，情報処理学会，電子情報通信学会，映像情報メディア学会，画像電子学会等の会員． ⟨ishizuka@miv.t.u-tokyo.ac.jp⟩