

特別研究報告書

孤立した密な部分グラフの発見による
写真群からの主要人物抽出

指導教員 美濃 導彦 教授

京都大学工学部情報学科

伊奈 拓郎

平成 28 年 1 月 29 日

孤立した密な部分グラフの発見による写真群からの主要人物抽出

伊奈 拓郎

内容梗概

同じ写真に写るということは、同じ時間や場所を共有していることである。その写真は、写った人物の社会的な関係を反映したものと考えられる。例えば、旅行アルバムで頻繁に写っている人物はその旅行での同行者と考えられるし、ワークショップなどのイベントならば、一緒に参加した人物であると考えられる。関係が深いほど、頻繁に写真に写ると考えられる。この意味で、頻繁に写真に写る人物を主要人物とする。写真群の中に写っている主要な人物を抽出することは、それらの人物の社会的な関係を表す情報を抽出することであり、具体的な応用例として人物毎の写真へのインデキシングによるデータによる整理や統計データの提示による人との付き合いの定量化、可視化などがあげられる。このような応用実現に向けて、本研究では事前知識なしで写真群からの主要人物を抽出することを目的とする。

近年、写真から個々の人物の顔を検出する技術や個人識別の技術が発達している。これらの技術は写真群からの主要人物抽出に役立つけれど、主要人物が誰か、またその主要人物の人数も未知である問題がある。本研究では、互いに類似しているものを一つにまとめあげることで、写真群からの主要人物の特定を行う。

実際、写真群から顔を検出する際に偶然写ってしまった主要人物でない人物の検出や誤検出が生じるのは避けられない。これらを outlier とする。単純なクラスタリング方法を用いてデータを分類する場合、データから outlier を取り除く必要がある。また任意の 2 要素間の類似度を計算を行い、重み付隣接行列で表現でき、この隣接行列で表現できるグラフにおける密な部分グラフを発見する方法もある。この方法では、密な部分グラフを抽出するために部分グラフの密度に関するしきい値または密な部分グラフの数を定める必要がある。だが扱うデータによって、最適な部分グラフの密度に関するしきい値は変化する。そのため、理想的なしきい値を定めることができない問題がある。また、写真群に写っている主要人物の人数が未知であるため、密な部分グラフの数が未知である問題もある。

これらの問題点を対処するために、新たに発見したスペクトラルクラスタの

性質に着目した．ここで主要人物の人数を N とする． $N + 1$ のクラスタ数でスペクトラルクラスタリングを用いると， N 個の主要人物の要素で形成されるクラスタ (以下，前景クラスタと呼ぶ) と 1 個の outlier のみで形成されるクラスタ (以下，背景クラスタと呼ぶ) に分割される．

次にクラスタ数を与えて，クラスタリングの結果を評価する．評価値は以下の二つの基準を用いる．一つ目は，同一写真に写っている複数の人物がどれだけ別々に分離されているかを基準とし，二つ目は，背景クラスタがどれだけはっきりあらわれているかを基準としている．一つ目の基準は，同一写真に写っている人物が異なるクラスタに属しているかをもとにしていて，どれだけ異なるクラスタに属しているかの割合を計算している．二つ目の基準は，前景クラスタの密度と背景クラスタの密度の差異をもとに計算している．評価値が最も高いクラスタ数を選択することで，主要人物の人数を推定する．よって問題点あげられていた最適な部分グラフの密度に関するしきい値やクラスタ数などの事前知識なしで密な部分グラフの発見することができる．

主要人物の人数が多い場合でも提案手法が有用であることを検証するために主要人物の人数に対するスケラリビティの評価実験を行った．また実環境のデータに対しても提案手法が有用であることを検証するために実環境から得られたデータに対する性能の評価実験を行った．主要人物の人数推定，主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類，複数の主要人物の中での主要人物毎の分類の 3 点に着目し従来の密な部分グラフを抽出する手法と比較し評価した．主要人物の人数が多い場合では，提案手法は従来手法より主要人物の人数推定の精度は 24 ポイント以上，主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類の精度は 57 ポイント以上，主要人物毎の分類の精度は 19 ポイント以上も向上する結果を得られた．次に，実環境から得られたデータの場合でも，従来手法よりも精度が向上する結果を得られた．提案手法は，主要人物の人数が多い場合でも，また実環境から得られたデータの場合でも従来手法より有用であることが確認された．また，スペクトラルクラスタリングを用いることで主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類の精度はどのデータに対しても 62% 以上の結果を得られた．スペクトラルクラスタリングは主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類について有用であることも確認された．

Finding Isolated Dense Subgraphs for Extracting Key Persons from a Group of Photographs

Takuro Ina

Abstract

When appearing in the same photograph, people spend a time with each other. In other words, the photograph reflects a kind of social relationship. For example, a person who often appears in a travel photo album should be a companion, or a group member in a case of photo album from a workshop. The deeper a social relationship to a person is, the more often the person appears in a group of photographs. In this sense, we regard those who often appear in the photographs as key persons. Extracting key persons from a group of photographs is extracting social relationship between them. Indexing photos by each key person and visualizing statistics of the relationships are typical applications of key person extraction. We aim to extract key persons from a group of photographs without any a priori information.

Recent development in computer vision technology achieved a high accuracy in face detection and individual identification. Though these technologies facilitate key person extraction, we know neither the instructive face photograph for each key person nor the number of key persons. The challenge of this paper is to bind up similar faces without any instruction, and identify all the key persons in the given photographs.

In practice, it is inevitable to get faces of non-key persons and false positives of face detection as input data with those of key persons. Since simple clustering approaches only divides the data, we further need to eliminate those outliers. An approach is dense subgraphs finding, which consider an adjacency matrix consisting of similarity for each pair of elements. In these approaches, either a threshold for density or the number of dense subgraph must be given to extract proper dense subgraphs; however the optimal threshold will vary along with input data. The number of dense subgraph, which corresponds to the number of key persons, is also unknown.

To overcome this problem, we focus on a property of Spectral Clustering(SC) that we found. Let N be a number of key persons, a result of SC with the

number of clusters $N + 1$ gives us N clusters corresponding to key persons, namely foreground clusters, and 1 cluster of the outliers, namely the background cluster.

For a given number of clusters, we evaluate the clustering results. The number that gives the best evaluation score provides the optimal solution for key person extraction without setting any thresholds. The evaluation function counts two criteria: validity of separation for people in the same photograph and appearance of unambiguous background cluster. The first criterion is based on the fact that any two persons in the same photograph must belong to different clusters. The rate of successful separation is calculated for the evaluation. The second criterion is based on difference between the average modularity of foreground clusters and that of background one. We estimate the number of key persons by choosing the number of clusters that provide the best evaluation score, and achieves dense subgraphs finding without setting any threshold and the number of clusters.

Two experiments are conducted for evaluating the scalability of proposed method against the number of key persons, and the performance against wild data obtained from the internet. The method is evaluated in the following three aspects: accuracy in estimating the number of key persons, that in classifying inliers and outliers, and that in classifying each key person. The result for data for a large number of key persons data showed that three accuracies of the proposed method surpassed those of existing method by 24 point, 57 point, and 19 point at the minimum.

The result for wild data showed that three accuracies of the proposed method surpassed those of existing method. The result showed that the performance of the proposed method is higher accuracies than existing methods even large number of key persons data or wild data. The accuracy in classifying inliers and outliers is 62% or more by using SC. The result showed SC always gives a good separation of outliers from the clusters of key persons.

孤立した密な部分グラフの発見による写真群からの主要人物抽出

目次

第1章	序論	1
第2章	関連研究	3
第3章	密な部分グラフの発見による写真群からの主要人物抽出手法	4
3.1	outlier を含むデータに対応した密な部分グラフの発見	5
3.1.1	Normalized Cuts & スペクトラルクラスタリング	5
3.1.2	背景クラスタの生成	7
3.2	理想的なクラスタ数の特定	9
3.3	背景クラスタの特定	12
3.4	クラスタ数自動決定	13
3.4.1	クラスタ数を大きくする評価値	13
3.4.2	クラスタ数を小さくする評価値	14
3.4.3	二つの評価値によるクラスタ決定	15
第4章	実験	15
4.1	実験方法	15
4.1.1	顔検出による写真からの顔画像取得	15
4.1.2	顔間の類似度を重みとした隣接行列の作成	15
4.1.3	実験で用いる主要人物抽出手法	16
4.1.4	実験評価方法	17
4.2	主要人物の人数に対するスケーラリティの評価	19
4.2.1	対象となる仮想データセット	19
4.2.2	結果・考察	19
4.3	実環境から得られたデータに対する性能の評価	22
4.3.1	対象となる実データセット	22
4.3.2	結果・考察	23
第5章	結論	25
	謝辞	26
	参考文献	27

第1章 序論

同じ写真に写るということは、同じ時間や場所を共有していることである。その写真は、写った人物の社会的な関係を反映したものと考えられる。例えば、旅行アルバムで頻繁に写っている人物はその旅行での同行者と考えられるし、ワークショップなどのイベントならば、一緒に参加した人物であると考えられる。関係が深いほど、頻繁に写真に写ると考えられる。この意味で、頻繁に写真に写る人物を主要人物とする。個人アルバムなどの写真群の中に写っている主要人物を抽出することは、それらの人物間の社会的な関係を抽出することには他ならない。

社会的な関係を抽出することができれば、人物毎の写真へのインデキシングによる写真データの整理や統計的なデータの提示によるその人との付き合いの定量化、可視化などの応用が可能となる。このような応用の実現に向けて、写真群からの主要人物を抽出することを目的とする。

近年、写真から個々の人物の顔を検出する技術や個人識別の技術が発達している [1]。これらの技術は写真群から主要人物抽出に役立つが、誰が主要人物であるか、またその主要人物の人数も未知という問題がある。本研究では互いに類似している人物を一つにまとめあげることで、写真群から主要人物の特定を行う。互いに類似しているものを一つにまとめあげるには以下の二通りがある。

一つ目は、ユークリッド距離空間などの幾何学的な空間の中で代表点を用いて解く方法である。既存技術で検出された顔のデータが代表点に近ければ、代表点に属する集合として一つにまとめあげることができる。しかし、写真群から顔を検出する際に偶然写ってしまった主要人物ではない人物の検出や誤検出など生じるのは避けられない。これらを outlier とする。扱うデータに outlier が含まれる場合、各クラスタに outlier を含まないようにするためにクラスタ毎にしきい値を定める。そして、どこのクラスタにも属さない要素を outlier とみなして排除する必要がある。

二つ目は、ユークリッド距離空間などの特定の空間の中での代表点を仮定せず、任意の2要素間の類似度を計算し、全ての集合の中から互いに類似している要素のみで構成される部分集合を組み合わせ最適化によって選ぶ方法がある。任意の2要素間の類似度を計算することは、全結合グラフの重み付き隣接行列を求めることと同値である。互いに類似している要素のみで構成される部分集

合を発見する問題は、この隣接行列で表現できるグラフにおける密な部分グラフの発見問題と呼ばれる。本研究では、この問題に着目する。

グラフ上でどのような最適化を行うかによって、様々な密な部分グラフを発見する手法が提案されている [2,3]。これらの手法は、部分グラフの密度に関するしきい値または密な部分グラフの数を定める必要がある。最適な部分グラフの密度に関するしきい値を定めることで部分グラフ内に outlier を含まないようにすることができる。ただし、扱うデータによって最適な部分グラフの密度に関するしきい値が変化する。そのため、理想的なしきい値を定めることができない問題がある。また一方で、写真群に写っている主要人物の人数が未知であるため、密な部分グラフの数が未知である。そのため密な部分グラフの数を定めることができない問題がある。

本研究では、部分グラフ内の密度の最大化と他の部分グラフ間の連結度の最小化を同時に行う手法のスペクトラルクラスタリングを利用する [4,5]。スペクトラルクラスタリングは一般的にはクラスタリング手法の一種として知られており、outlier を含まないデータに対する分割手法として利用されている。主要人物の人数よりも一つ多いクラスタ数でスペクトラルクラスタリングを用いると、outlier が一つのクラスタとしてまとめられるという性質を発見した。分割されたクラスタの中から outlier でまとめられたクラスタを特定し除去することで outlier を含むデータに対応できる。outlier を含むデータに対応できるため、部分グラフの密度に関するしきい値を定める必要がない。

また、主要人物の人数が未知である問題に対しては、様々なクラスタ数でのクラスタリング結果を評価することで主要人物の人数推定を行う。同一写真に写る複数の人物は異なるクラスタに属しているかと outlier で形成されたクラスタがはっきりあられるかという二つの情報に基づき、評価を行う。まず、同一写真に写っている複数の人物は明らかに違う人物であることから、一つ目の評価値は同一写真に写っているペアが異なるクラスタに属しているかを利用する。次に、主要人物の要素で形成されたクラスタ内の密度は高く、outlier で形成されたクラスタ内の密度は低い。二つ目の評価値はこれらのクラスタ内の密度の差異を利用する。これらの評価値を掛け合わせたものが最も高いクラスタ数を選択することより主要人物の人数推定を行う。よって問題点であげられていた最適な部分グラフの密度に関するしきい値や密な部分グラフの数が未知の問題に対処し、密な部分グラフの発見することができる。

本稿の構成は以下の通りである．2章では，密な部分グラフを発見する問題に関する関連研究について述べる．3章では，outlier を含むデータから密な部分グラフを発見する手法について述べる．4章では，提案手法を評価するための実験の詳細について述べる．最後に5章で結論を述べる．

第2章 関連研究

密な部分グラフを発見する問題は二つの手法が存在する [6]．一つ目は部分グラフ内に張っているリンクの重み密度が大きくなるようにノードを増やしていく手法である．二つ目はクラスタ数を与え，クラスタ内の密度やクラスタ間の連結度をもとにグラフをクラスタリングする手法である．これら二つの手法について説明し，写真群からの主要人物抽出問題に対する問題点をあげる．

まず，一つ目の手法は部分グラフ内のリンクの重み密度が大きくなるように部分グラフに連結している要素を探索し，部分グラフに取り込む．上記の処理を部分グラフの密度がしきい値未満になるまで反復することで密な部分グラフを発見することができる [2, 7]．しかし，同一人物の要素を一つのクラスタにまとめ，かつ outlier を含まないようにする部分グラフの密度に関するしきい値が定める必要がある．扱うデータによって，部分グラフの密度に関するしきい値が変化する．そのため，最適な部分グラフの密度に関するしきい値を定めることができない．

二つ目の手法は，図1のように，事前にクラスタ数を与え，各クラスタがクラスタ内の密度を大きく，かつクラスタ間の連結度を小さくなるようにグラフをクラスタリングする [3]．この手法はクラスタ内の密度の最大化，かつ同時にクラスタ間の連結度の最小化を行っているので，互いに類似している要素のみで構成される部分集合を取得することができる．そのため，同一人物の要素が一つにまとまる．よって，理想的なリンクの重み密度に関するしきい値を定める必要がない．しかし，扱うデータに outlier を含んでいる場合を考慮していない．主要人物抽出問題では写真群から検出された顔に偶然写真に写り込んでしまった主要人物ではない人物の顔検出や誤検出が含まれる場合が存在する．それらは頻度が低いため，他全ての要素と類似していない．そのため，outlier として扱われる．それらの outlier が主要人物毎に対応しているクラスタに含まれることになる．また，写真群に写っている主要人物の人数が未知であるため事




図 1: クラスタ数を与え、グラフをクラスタリングする手法

前にクラスタ数を与えることができない。そのため、写真群から主要人物抽出問題に対して、そのまま利用することができない。

写真群から主要人物抽出を行うには、最適な部分グラフの密度に関するしきい値を定めるか、もしくは outlier を含むデータに対応し、主要人物の人数を推定する必要がある。

第3章 密な部分グラフの発見による写真群からの主要人物抽出手法

写真群から主要人物抽出を行うには、最適な部分グラフの密度に関するしきい値を定めるか、もしくは outlier を含むデータに対応し主要人物の人数を推定するかのどちらか必要であることを述べた。本研究では、後者の問題に対処することにする。

outlier を含むデータから、部分グラフ内の密度が高く、かつ他の部分グラフとの連結度が小さい密な部分グラフを発見する手法をとる。以下では部分グラフ内の密度が高く、かつ他の部分グラフとの連結度が小さい部分グラフを孤立した密な部分グラフと定義する。

孤立した密な部分グラフを発見するために、部分グラフ内の密度の最大化と他の部分グラフ間との連結度の最小化を同時に行う手法であるスペクトラルクラスタリングを利用する。スペクトラルクラスタリングはNP完全である Normalized Cuts の近似解を得る手法 [4,5] として広く用いられている。また、スペクトラルクラスタリングは一般的にはクラスタリング手法の一種として知られており、outlier を含まないデータに対する分割手法として利用されている。

本研究で主要人物の人数よりも一つ多いクラスタ数でスペクトラルクラスタリングを用いると, outlier が一つのクラスタにまとめられやすいことを発見した. 以下, outlier のみで形成されるクラスタを背景クラスタとし, それ以外を前景クラスタと呼ぶ. 背景クラスタを特定し, 取り除くことで outlier を含むデータに対応することができる. しかし, 主要人物の人数は未知であるためクラスタ数を事前に与えることができない. 本研究の対象データが人物写真であることを利用し, 主要人物の人数などの事前知識なしでクラスタ数の自動決定を行う.

本章ではまず 3.1 節で Normalized Cuts とスペクトラルクラスタリングの概要, 及び outlier が一つにまとまりやすく, 背景クラスタが生成されることについて述べる. 3.2 節で主要人物の人数分の前景クラスタを得るための理想的なクラスタ数を特定する. クラスタリング結果から背景クラスタの特定についてを 3.3 節で述べる. 理想的なクラスタ数自動決定についてを 3.4 節で述べる.

3.1 outlier を含むデータに対応した密な部分グラフの発見

3.1.1 Normalized Cuts & スペクトラルクラスタリング

まず, 提案手法の詳細を説明とするのに必要となる Normalized Cuts とスペクトラルクラスタリングの原理や定義を説明する. 良いデータ分割の基準にはいくつか存在するが, クラスタリングの場合は一般的にクラスタ内の密度を大きく, クラスタ間の連結度を小さくすることが望ましい. Normalized Cuts ではそのようなグラフに分割するために, 以下のような計算を行う.

まず, 重み付き隣接行列に対応したグラフを重み付き無向グラフ $G=(V, E, W)$ とおく. ここで, V は頂点集合, E は辺集合, W は重みである. W は類似度行列として表現できる.

V の各要素をクラスタ A, B に分類するときを考える. クラスタ A, B に属する頂点集合それぞれ V_A, V_B とする. クラスタ A, B 間の類似度は以下のように表現できる.

$$links(V_A, V_B) = \sum_{i \in V_A, j \in V_B} W(i, j) \quad (1)$$

ここでの $W(i, j)$ はノード i とノード j 間に張られたリンクの重みである.

また, この類似度を用いてクラスタ A, B 間の連結度は以下のように定義される.

$$Ncut(V_A, V_B) = \frac{links(V_A, V_B)}{links(V_A, V)} + \frac{links(V_A, V_B)}{links(V_B, V)} \quad (2)$$

ここでの $links(V_A, V)$ はクラスタ A のリンクの重みの総和である .

同様に , クラスタ A, B 内の密度は以下のように定義される .

$$NAssoc(V_A, V_B) = \frac{links(V_A, V_A)}{links(V_A, V)} + \frac{links(V_B, V_B)}{links(V_B, V)} \quad (3)$$

[5] の著者は K 個のクラスタに分割する場合を考え , 拡張した . K 個のクラスタを $\Gamma_V^K = \{V_1, \dots, V_K\}$ とおく . 式 (2) は式 (4) へ , 式 (3) は式 (5) へと変形できる .

$$kNcut(\Gamma_V^K) = \frac{1}{K} \sum_{l=1}^K \frac{links(V_l, \bar{V}_l)}{links(V_l, V)} \quad (4)$$

$$kAssoc(\Gamma_V^K) = \frac{1}{K} \sum_{l=1}^K \frac{links(V_l, V_l)}{links(V_l, V)} \quad (5)$$

ここでの \bar{V}_l は , V 中の V_l の補集合である .

式 (4) は K 個のクラスタ間の連結度を示すので小さい方が望ましい . 式 (5) は K 個のクラスタ内の密度を示すので大きい方が望ましい . ここで $kNcut(\Gamma_V^K) + kAssoc(\Gamma_V^K) = 1$ となるので $kNcut(\Gamma_V^K)$ のコストを最小化する問題と $kAssoc(\Gamma_V^K)$ のコストを最大化する問題は同じ問題となる [5] . そのため , Normalized Cuts はクラスタ内の密度を大きくすると同時にクラスタ間の連結度を小さくする最適化問題となっている .

Normalized Cuts の問題は , 以下の式 (6) を最小化するクラスタを特定する K 個のベクトル x を求める問題と等価である .

$$\text{minimize } kNcut = \frac{X^T(D - W)X}{X^TDX} \quad (6)$$

$$\text{subject to } x_k \in \{0, 1\}^n \quad (7)$$

$$X = [x_1, \dots, x_K] \quad (8)$$

$$X \{1\}^K = \{1\}^N \quad (9)$$

ここでの D は類似度行列 W の次数を対角成分に持った行列 , n は頂点数である .

$$D = \text{diag}(d_1, \dots, d_n), d_i = \sum_{j=1}^n W(i, j) \quad (10)$$

クラスタを特定するベクトル x は , 式 (7) で示すように n 次元の 2 値ベクトルである . 例えば , i 番目の値が 1 の場合 . 頂点 i はそのクラスタに属することを

意味している．式 (8) の各ベクトルはクラスタに対応しており，一つの頂点がいずれかの一つのクラスタに属することを意味している．

この問題を解くのは NP 完全であるが，2 値ベクトル x から実数ベクトル \tilde{x} に制約を緩和することで近似解を得ることができる [3]．式 (4) の最小化問題は，以下の固有値問題の最小固有値に対する固有ベクトル \tilde{x} が得られる．

$$D^{-\frac{1}{2}}(D - W)D^{-\frac{1}{2}}\tilde{x} = \lambda\tilde{x} \quad (11)$$

得られた固有値の大きさがカットするリンクの重みの総和となり，その固有値に対応する固有ベクトル \tilde{x} がグラフの分割を与える．ただし，最小固有値を選ぶ際には固有値が 0 になるものは除いて考える．これは固有値が 0 の場合はリンクを一つもカットしない場合に相当するためである．だが，ここで得られる固有ベクトルはまだ実数ベクトルであるので，このベクトルをクラスタと対応させる必要がある．このために固有値が下位 K 個の固有ベクトルを用いて，事前に与えたクラスタ数をもとに K-means 法 [4] や固有ベクトルの回転を利用する手法 [5] でベクトル量子化を行う手法が提案されている．本研究ではより精度の信頼性が高い手法 [5] を用いることを前提とする．

3.1.2 背景クラスタの生成

従来，スペクトラルクラスタリングは outlier を含まないデータのクラスタリング手法として用いられていた．これに対して，outlier を含む場合でも理想的なクラスタ数よりも 1 多い値でクラスタリングすれば，スペクトラルクラスタリングにより背景クラスタが現れるという性質を数学的・実験的に明らかにする．この性質は，ごく一部の文献で経験的に知られていた [8]．outlier 同士がまとまりやすいことを Normalized Cuts とスペクトラルクラスタリングの二つの観点から説明する．

outlier 同士がまとまりやすいことを Normalized Cuts の観点から説明する．本来同一のクラスタに入るべき要素間の枝の重みは高くなる．その枝を密なリンクと定義する．異なるクラスタの要素間の枝の重み，または outlier と連結する枝の重みは低くなる．それらの枝を疎なリンクと定義する．密なリンクの重みの分布を平均が定まる任意の分布 $\pi(\mu_1, \Theta_1)$ ，疎なリンクの重みの分布を平均が定まる任意の分布 $\pi(\mu_2, \Theta_2)$ と仮定する．密なリンクの重みは疎なリンクの重みよりも大きいため， $\mu_1 > \mu_2$ が成り立つ．また，枝の重みは距離空間により算出される類似度であるため， μ_1, μ_2 ともに正である．

Normalized Cuts はクラスタ内の密度が大きくなるようにグラフをカットする手法である．outlier が前景クラスタか背景クラスタがどちらに属しやすいか，クラスタ内の密度に相当する式 (3) を用いて調べる．以下，前景クラスタを V_{in} ，背景クラスタを V_{out} ，任意の outlier の要素を v_o とする．

outlier が前景クラスタ V_{in} に属した場合，クラスタ内の密度に相当する式 (3) は以下ようになる．

$$\begin{aligned}
& NAssoc(\{V_{in}, v_o\}, V_{out}) \\
&= \frac{links(\{V_{in}, v_o\}, \{V_{in}, v_o\})}{links(\{V_{in}, v_o\}, V)} + \frac{links(V_{out}, V_{out})}{links(V_{out}, V)} \\
&= \frac{links(V_{in}, V_{in}) + 2links(v_o, V_{in}) + links(v_o, v_o)}{links(V_{in}, V_{in}) + links(V_{in}, \bar{V}_{in}) + links(v_o, V)} + \frac{\mu_2 |V_{out}|^2}{\mu_2 |V_{out}| |V|} \\
&\simeq \frac{\mu_1 |V_{in}|^2 + 2\mu_2 |V_{in}|}{\mu_1 |V_{in}|^2 + \mu_2 |V_{in}|(|V| - |V_{in}|) + \mu_2 |V|} + \frac{|V_{out}|}{|V|}
\end{aligned} \tag{12}$$

一方，outlier が背景クラスタ V_{out} に属した場合，クラスタ内の密度に相当する式 (3) は以下ようになる．

$$\begin{aligned}
& NAssoc(V_{in}, \{V_{in}, v_o\}) \\
&= \frac{links(V_{in}, V_{in})}{links(V_{in}, V)} + \frac{links(\{V_{out}, v_o\}, \{V_{out}, v_o\})}{links(\{V_{out}, v_o\}, V)} \\
&= \frac{links(V_{in}, V_{in})}{links(V_{in}, V_{in}) + links(V_{in}, \bar{V}_{in})} + \frac{\mu_2 |V_{out} + 1|^2}{\mu_2 |V_{out} + 1| |V|} \\
&\simeq \frac{\mu_1 |V_{in}|^2}{\mu_1 |V_{in}|^2 + \mu_2 |V_{in}|(|V| - |V_{in}|)} + \frac{|V_{out} + 1|}{|V|}
\end{aligned} \tag{13}$$

outlier が前景クラスタ V_{in} に属するか，または背景クラスタ V_{out} に属するかでどちらの方がクラスタ内の密度が大きくなるかを調べる．

$$\begin{aligned}
& NAssoc(V_{in}, \{V_{out}, v_o\}) - NAssoc(\{V_{in}, v_o\}, V_{out}) \\
&= \frac{1}{Z} (\mu_2 |V_{in}|^2 |V| (\mu_1 - 2\mu_2) + 2\mu_2^2 |V_{in}|^3) + \frac{1}{|V|}
\end{aligned} \tag{14}$$

$$Z = (\mu_1 |V_{in}|^2 + \mu_2 |V_{in}|(|V| - |V_{in}|)) (\mu_1 |V_{in}|^2 + \mu_2 |V_{in}|(|V| - |V_{in}|) + \mu_2 |V|) \tag{15}$$

式 (14) より μ_1 が $2\mu_2$ より大きい場合，明らかに式 (12) より式 (13) が大きくなる． μ_1 は $2\mu_2$ より大きくなれば，outlier は前景クラスタよりも背景クラスタの方が属しやすい．

outlier のみからなるクラスタが形成される理由について、既に Normalized Cuts の観点から説明を行ったが、ここでは、新たにスペクトラルクラスタリングの計算方法から考える。スペクトラルクラスタリングでは、 i 番目の要素の特徴量を類似度行列 W の i 行目としており、特に [5] の手法では主成分分析により得られた固有空間を回転させ、各固有ベクトルが一つのクラスタに対応するようにデータを分類している。このとき、 i 番目の要素が outlier、すなわち他のどの要素とも類似していなければ、 W の i 行目は全ての値が小さくなる。従って、主成分分析の結果として、 i 番目の要素を含めて全ての値が小さくなる要素を代表する固有ベクトル \tilde{x}_i が現れ、 W の i 行目を各固有ベクトルの重み付き和で表現した場合に、 \tilde{x}_i に対する係数が大きい要素の集合として、outlier のみからなるクラスタが形成される。

3.2 理想的なクラスタ数の特定

outlier を含むデータに対して、前景クラスタに outlier を含まないようにするためには outlier をまとめる背景クラスタが必要である。そのためクラスタ数 K は前景クラスタの数よりも多くなければいけない。以下、理想的な前景クラスタの数を N_{in} とおく。今回の問題では主要人物の人数に相当する。 $K > N_{in}$ は成り立つが背景クラスタの数 $K - N_{in}$ が不明である。だが、背景クラスタの数が二つ以上になるよりも先に前景クラスタの過分割が生じる。それを以下で示す。

次に具体的なクラスタ数として $K = N_{in} + 2$ の場合を考える。

- (a) 前景クラスタの数が $N_{in} + 1$ 、背景クラスタの数が 1 の場合
- (b) 前景クラスタの数が N_{in} 、背景クラスタの数が 2 の場合

の二通りが考えられる。(a) の場合、本来一つのクラスタにまとまるべき要素が二つに分割されているため、クラスタリング結果が良好とは言えない。(b) の場合、二つの背景クラスタを特定することができ、取り除けばクラスタリング結果に影響は及ぼさない。

クラスタ数が $K = N_{in} + 1$ の場合、 N_{in} 個の前景クラスタと 1 個の背景クラスタに分割されていると仮定する。Normalized Cuts の指標である式 (5) を用いてどちらが生じやすいか調べる。以下では正規化密度の総和を用いて式 (5) について調べる。式 (16) の平均が式 (5) となる。

$$Sum(\Gamma_V^K) = \sum_{l=1}^K \frac{links(V_l, V_l)}{links(V_l, V)} \quad (16)$$

(a) 前景クラスタの数が $N_{in} + 1$, 背景クラスタの数が 1 の場合

(a) の場合 , 前景クラスタの数が N_{in} よりも大きいので過分割が生じている . 過分割が生じた前景クラスタを V_{in}^A, V_{in}^B とおく . クラスタ数 $K = N_{in} + 1$ でのクラスタリング結果 $\Gamma_V^{N_{in}+1}$ には $\{V_{in}^A, V_{in}^B\}$ が含まれる . クラスタ数 $K = N_{in} + 2$ でのクラスタリング結果 $\Gamma_V^{N_{in}+2}$ には V_{in}^A, V_{in}^B が含まれる .

V_{in}^A と V_{in}^B 間のリンクの重みの期待値を μ_{AB} とおく . スペクトラルクラスタリングによってクラスタ内の密度が大きく , クラスタ間の連結度が小さくなるように分割するので $\mu_{AB} < \mu_1$ が成り立つ .

前景クラスタ $\{V_{in}^A, V_{in}^B\}$ の正規化密度は式 (17) のようになる .

$$\begin{aligned} & \frac{\text{links}(\{V_{in}^A, V_{in}^B\}, \{V_{in}^A, V_{in}^B\})}{\text{links}(\{V_{in}^A, V_{in}^B\}, V)} \\ & \simeq \frac{\mu_1(|V_{in}^A| + |V_{in}^B|)}{\mu_1(|V_{in}^A| + |V_{in}^B|) + \mu_2(|V| - |V_{in}^A| - |V_{in}^B|)} \end{aligned} \quad (17)$$

ここで前景クラスタ V_{in}^A が連結しているリンクの重みの総和を $Z(V_{in}^A)$ とする .

$$\begin{aligned} Z(V_{in}^A) &= \text{links}(V_{in}^A, V) \\ &= \text{links}(V_{in}^A, V_{in}^A) + \text{links}(V_{in}^A, V_{in}^B) + \text{links}(V_{in}^A, V - V_{in}^A - V_{in}^B) \\ &\simeq \mu_1|V_{in}^A|^2 + \mu_{AB}|V_{in}^A||V_{in}^B| + \mu_2|V_{in}^A|(|V| - |V_{in}^A| - |V_{in}^B|) \\ &< \mu_1|V_{in}^A|(|V_{in}^A| + |V_{in}^B|) + \mu_2|V_{in}^A|(|V| - |V_{in}^A| - |V_{in}^B|) \end{aligned} \quad (18)$$

同様にして

$$Z(V_{in}^B) < \mu_1|V_{in}^B|(|V_{in}^A| + |V_{in}^B|) + \mu_2|V_{in}^B|(|V| - |V_{in}^A| - |V_{in}^B|) \quad (19)$$

前景クラスタ V_{in}^A と V_{in}^B の正規化密度の和は式 (20) のようになる .

$$\begin{aligned} & \frac{\text{links}(V_{in}^A, V_{in}^A)}{\text{links}(V_{in}^A, V)} + \frac{\text{links}(V_{in}^B, V_{in}^B)}{\text{links}(V_{in}^B, V)} \\ &= \frac{1}{Z(V_{in}^A)} \text{links}(V_{in}^A, V_{in}^A) + \frac{1}{Z(V_{in}^B)} \text{links}(V_{in}^B, V_{in}^B) \\ &\simeq \frac{1}{Z(V_{in}^A)} \mu_1|V_{in}^A|^2 + \frac{1}{Z(V_{in}^B)} \mu_1|V_{in}^B|^2 \\ &> \frac{\mu_1(|V_{in}^A| + |V_{in}^B|)}{\mu_1(|V_{in}^A| + |V_{in}^B|) + \mu_2(|V| - |V_{in}^A| - |V_{in}^B|)} \end{aligned} \quad (20)$$

クラスタ数が $K = N_{in}^* + 1$ のとき , 正規化密度の総和に相当する式 (16) は

$$\text{Sum}(\Gamma_V^{N_{in}+1}) = \frac{\text{links}(\{V_{in}^A, V_{in}^B\}, \{V_{in}^A, V_{in}^B\})}{\text{links}(\{V_{in}^A, V_{in}^B\}, V)} + \sum_{l=1}^{N_{in}} \frac{\text{links}(V_l, V_l)}{\text{links}(V_l, V)} \quad (21)$$

クラスタ数が $K = N_{in} + 2$ のとき，正規化密度の総和に相当する式 (16) は

$$\begin{aligned}
Sum^{(a)}(\Gamma_V^{N_{in}+2}) &= \frac{links(V_{in}^A, V_{in}^A)}{links(V_{in}^A, V)} + \frac{links(V_{in}^B, V_{in}^B)}{links(V_{in}^B, V)} + \sum_{l=1}^{N_{in}} \frac{links(V_l, V_l)}{links(V_l, V)} \\
&= \frac{links(V_{in}^A, V_{in}^A)}{links(V_{in}^A, V)} + \frac{links(V_{in}^B, V_{in}^B)}{links(V_{in}^B, V)} \\
&\quad + Sum(\Gamma_V^{N_{in}+1}) - \frac{links(\{V_{in}^A, V_{in}^B\}, \{V_{in}^A, V_{in}^B\})}{links(\{V_{in}^A, V_{in}^B\}, V)} \\
&> Sum(\Gamma_V^{N_{in}+1})
\end{aligned} \tag{22}$$

(b) 前景クラスタの数が N_{in} ，背景クラスタの数が 2 の場合

二つの背景クラスタを V_{out}^A, V_{out}^B とおく．クラスタ数 $K = N_{in} + 1$ でのクラスタリング結果 $\Gamma_V^{N_{in}+1}$ には $\{V_{out}^A, V_{out}^B\}$ が含まれる．クラスタ数 $K = N_{in} + 2$ でのクラスタリング結果 $\Gamma_V^{N_{in}+2}$ には V_{out}^A, V_{out}^B が含まれる．

V_{out}^A と V_{out}^B は outlier のみから形成されているため，疎なリンクのみ張っている．そのためクラスタ内のリンクの重みの期待値，クラスタ間のリンクの重みの期待値はともに μ_2 となる．

背景クラスタ $\{V_{out}^A, V_{out}^B\}$ の正規化密度の和は式 (23) のようになる．

$$\frac{links(\{V_{out}^A, V_{out}^B\}, \{V_{out}^A, V_{out}^B\})}{links(\{V_{out}^A, V_{out}^B\}, V)} = \frac{|V_{out}^A| + |V_{out}^B|}{|V|} \tag{23}$$

背景クラスタ V_{out}^A と V_{out}^B の正規化密度の和は式 (24) のようになる．

$$\frac{links(V_{out}^A, V_{out}^A)}{links(V_{out}^A, V)} + \frac{links(V_{out}^B, V_{out}^B)}{links(V_{out}^B, V)} = \frac{|V_{out}^A|}{|V|} + \frac{|V_{out}^B|}{|V|} \tag{24}$$

クラスタ数が $K = N_{in}^* + 1$ のとき，正規化密度の総和に相当する式 (16) は

$$Sum(\Gamma_V^{N_{in}+1}) = \frac{links(\{V_{out}^A, V_{out}^B\}, \{V_{out}^A, V_{out}^B\})}{links(\{V_{out}^A, V_{out}^B\}, V)} + \sum_{l=1}^{N_{in}} \frac{links(V_l, V_l)}{links(V_l, V)} \tag{25}$$

クラスタ数が $K = N_{in} + 2$ のとき，正規化密度の総和に相当する式 (16) は

$$\begin{aligned}
Sum^{(b)}(\Gamma_V^{N_{in}+2}) &= \frac{links(V_{out}^A, V_{out}^A)}{links(V_{out}^A, V)} + \frac{links(V_{out}^B, V_{out}^B)}{links(V_{out}^B, V)} + \sum_{l=1}^{N_{in}} \frac{links(V_l, V_l)}{links(V_l, V)} \\
&= \frac{links(V_{out}^A, V_{out}^A)}{links(V_{out}^A, V)} + \frac{links(V_{out}^B, V_{out}^B)}{links(V_{out}^B, V)} \\
&\quad + Sum(\Gamma_V^{N_{in}+1}) - \frac{links(\{V_{out}^A, V_{out}^B\}, \{V_{out}^A, V_{out}^B\})}{links(\{V_{out}^A, V_{out}^B\}, V)} \\
&= Sum(\Gamma_V^{N_{in}+1})
\end{aligned} \tag{26}$$

式 (22) と式 (26) より以下の大小関係が成り立つ .

$$\begin{aligned}
Sum^{(a)}(\Gamma_V^{N_{in}+2}) &> Sum^{(b)}(\Gamma_V^{N_{in}+2}) \\
\frac{1}{N_{in}+2} Sum^{(a)}(\Gamma_V^{N_{in}+2}) &> \frac{1}{N_{in}+2} Sum^{(b)}(\Gamma_V^{N_{in}+2}) \\
kNAssoc^{(a)}(\Gamma_V^{N_{in}+2}) &> kNAssoc^{(b)}(\Gamma_V^{N_{in}+2})
\end{aligned} \tag{27}$$

式 (27) より (a) の場合が (b) の場合よりも生じやすい . そのため , 前景クラスタの過分割が生じるため , クラスタ数 $K = N_{in} + 2$ は理想的でない . クラスタ数が $K > N_{in} + 2$ の場合も同様のことが考えられる . したがって , 理想的なクラスタ数は $K = N_{in} + 1$ と考えられる .

3.3 背景クラスタの特定

outlier をクラスタリング結果から取り除くために , 背景クラスタの特定を行う . Normalized Cuts では式 (5) の連結しているリンクの重みの総和で正規化されたリンクの重み密度を最大化を行っている . そのため , リンクの重みの総和で正規化されたリンクの重み密度では前景クラスタと背景クラスタでさほど差が現れない . 図 2 のように前景クラスタはクラスタ内に密なリンクが張っており , クラスタ間に疎なリンクが張っている . また背景クラスタはクラスタ内 , クラスタ間ともに疎なリンクが張っている . そのため , 枝の本数で正規化されたリンクの重みでは前景クラスタと背景クラスタで差が現れる . ここで枝の本数で正規化されたリンクの重みを利用する . あるクラスタに対して , クラスタ内のリンクの重みとクラスタ間のリンクの重みの差が大きく違うことを利用し , 以下のようなクラスタ毎の指標を立てる .

$$\Delta(V_i) = \frac{links(V_i, V_i)}{|E(V_i)|} - \frac{1}{K-1} \sum_{j=1, j \neq i}^K \frac{links(V_i, V_j)}{|E(V_i, V_j)|} \tag{28}$$

ここで , $E(V_i)$ はクラスタ i 内に張っているリンクの本数 , $E(V_i, V_j)$ はクラスタ i とクラスタ j 間に張っているリンクの本数 , K はクラスタ数を表す .

前景クラスタはクラスタ内のリンクの重みが大きく , クラスタ間のリンクの重みが小さいため指標の値は $\mu_1 - \mu_2$ に近くなる . 背景クラスタはクラスタ内 , クラスタ間のリンクの重みがともに小さいため指標の値は 0 に近くなる . また過分割された前景クラスタは過分割が生じていない前景クラスタよりクラスタ間のリンクの重みが大きいと考えられる . そのため , 過分割が生じていない前




図 2: リンクの重みの関係図

景クラスタより過分割された前景クラスタの方が指標の値が小さくなる。

ただし、この指標は類似度行列 W のスケールや密なリンクの重み平均 μ_1 と疎なリンクの重み平均 μ_2 の差によって値がデータ毎に変わる。このため、以下のようにして指標を正規化する。

$$\delta(V_i) = \frac{\Delta(V_i)}{\max_j \Delta(V_j)} \quad (29)$$

式 (29) が最も小さいクラスタは背景クラスタと考えられる。 $V_{i_{out}}$ は背景クラスタとみなす。

$$i_{out} = \arg \min_{0 < i \leq K} \delta(V_i) \quad (30)$$

3.4 クラスタ数自動決定

写真群から主要人物抽出は主要人物の教師データがなく、その人数が未知である問題がある。提案手法により、outlier を特定し取り除くとともに主要人物の人数つまりクラスタ数の自動決定を行う。

一般的に理想的なクラスタ数自動決定を行うにはクラスタ数を大きくする評価値とクラスタ数を小さくする評価値を組み合わせることで実現できる。クラスタ数を大きくする評価値を同一写真に写っている人物は別人であることを用いる。クラスタ数を小さくする評価値は前景クラスタと背景クラスタの密度の差異を用いる。以下では各評価値について述べる。

3.4.1 クラスタ数を大きくする評価値

図 3 のように同じ写真に写っている人物は別人であることは明らかである。同じ写真に写っている人物は親族のように似た顔であっても、それらの顔間の類似度は 0 にする。また、同じ写真に写っているペアが異なるクラスタに存在する



図 3: 同一写真に写っているペア

場合，評価値を高く，同じクラスタに存在する場合は低くなるように設定する．

$$f_{cut}(K) = \frac{|P_{cut}|}{|P_{all}|} \quad (31)$$

ここで， P_{all} は同一写真に写った全ての顔の組み合わせ数， P_{cut} はそのうち Normalized Cuts によりカットされたペアの集合である．ただし，ペアのどちらかが背景クラスタに属するものは含めない．

クラスタ数が大きくなればカットされるペアが多くなり評価値が高くなると考えられる．そのため，過分割が生じる可能性が高くなります．次に過分割が生じないようにするための評価値について説明する．

3.4.2 クラスタ数を小さくする評価値

理想的なクラスタ数でクラスタリングを行うと，主要人物の人数分の前景クラスタと一つの背景クラスタに分割されるので，その状態になるとき高くなるような評価値を提案する．与えられたクラスタ数をもとにクラスタリングを行い，各クラスタの式 (29) の指標 $\delta(V_i)$ を求める．前景クラスタと背景クラスタで指標の値の差が大きくなるので，主要人物の人数分の前景クラスタと一つの背景クラスタに分割される時は指標の最小値とその次に小さい値との差が大きくなる．その差を評価値にする．

$$f_{dif}(K) = \min_{i \neq i_{out}} |\delta(V_i) - \delta(V_{i_{out}})| \quad (32)$$

3.2 より理想的なクラスタ数よりも大きくなる場合，前景クラスタの過分割が生じる．3.3 より過分割が生じた場合，指標の値が小さくなるので評価値も小さくなる．そのため，過分割を抑える制約とみなせる．

3.4.3 二つの評価値によるクラスタ決定

上記で述べた評価値を掛け合わせたものを最終的なクラスタリング結果に対する評価値として用いる．

$$f(K) = f_{cut}(K)^\beta \times f_{dif}(K) \quad (33)$$

ここで， β は，二つの評価値の重みである．

その評価値が最大となるクラスタ数 K^* を用いたクラスタリング結果を提案手法でのクラスタリング結果とする．

$$K^* = \arg \max_K f(K) \quad (34)$$

第4章 実験

本実験では，主要人物の人数が変化しても提案手法が有用であることを検証するために4.2節で写真群に写っている主要人物の人数を変化させた仮想データセットを用いて実験を行う．また，実環境のデータに対しても提案手法が有用であることを検証するために4.3節で写真共有サイトから実際に存在する写真群を用いて実験を行う．

初めに，本実験で用いる写真群から主要人物抽出する手法の具体的な方法について述べる．次に，主要人物の人数に対するスケーラビリティの評価について述べる．最後に，実環境から得られたデータに対する性能の評価について述べる．

4.1 実験方法

4.1.1 顔検出による写真からの顔画像取得

写真から，顔検出技術によって写真に写っている人物の顔画像が得られる．顔画像は，ある人物の顔の領域が矩形で切り出されたものである．本実験では，OKAOvisionの機能の一つである顔検出 [1] を用いる．

4.1.2 顔間の類似度を重みとした隣接行列の作成

得られた顔画像から，各顔画像の特徴ベクトルが得られ，それをもとに顔間の類似度を算出できる．本実験では，OKAOvisionの機能の一つである顔認識 [1] を用いて顔間の類似度を算出する [9]．顔認識による類似度の計算は，顔の目や口の端点を特徴点として定義し，特徴点をノードとすることで顔グラフを表

現できる．そのグラフの各ノードは特徴点周辺から抽出されるガボール特徴量を持つ．ガボール特徴量は，画像とガボールフィルタの畳み込み演算を行うガボールウェーブレット変換によって抽出される．抽出したガボール特徴量と個人の顔グラフとの相関を求めることで類似度を算出している．この方法は，他の手法よりも個人識別精度が高い [10]．

4.1.3 実験で用いる主要人物抽出手法

本実験で用いる類似度には各方向とスケールをもつ高次元特徴量であるガボール特徴量を用いているため，ユークリッド距離空間などの幾何学的な空間でのクラスタリングを用いることができない．第2章であげた密な部分グラフを発見する手法には，理想的なリンクの重み密度に関するしきい値を定める問題点と outlier を含んでいることを考慮していない問題点を挙げている．それらの手法と比較し，問題点に対処できていることを確かめる．以下の4つの手法で比較することで検証する．

従来手法1 部分グラフ内に張っているリンクの重み密度がしきい値以上の部分グラフを発見する手法 [7]

従来手法2 outlier を考慮しないでクラスタ数自動決定を行いグラフをクラスタリングする手法 [11]

提案手法1 f_{dif} の評価値のみ用いた提案手法1(式(33)において $\beta=0$ とした)

提案手法2 f_{dif} の評価値に加え， f_{cut} の評価値も利用した提案手法2

比較手法1での部分グラフ内に張っているリンクの重み密度がしきい値以上の部分グラフを発見する手法は密な部分グラフに相当する擬似クリーク [7] を検出する手法を用いた．擬似クリークは，重み無し無向グラフから枝密度 $p(V_i)$ がしきい値以上となる部分グラフである．

$$p(V_i) = \frac{2|E(V_i)|}{|V_i| \times (|V_i| - 1)} \quad (35)$$

ここで $|E(V_i)|$ は V_i に属する頂点間で張っている枝の本数である． $|E(V_i)|$ から頂点数が V_i と同じクリークの枝の本数 $\frac{|V_i| \times (|V_i| - 1)}{2}$ で割ることで枝密度 $p(V_i)$ を計算している．重み付隣接行列を二値化するしきい値をリンクの重みの最大値の半分とし，擬似クリークを検出する部分グラフ内の枝密度に関するしきい値を0.9とした．検出した部分グラフのサイズが5以上のものを前景クラスタとする．従来手法2はクラスタ内の密度の最大化や他のクラスタの連結度の最小

化を目的とした Modularity の評価値 $Q(K)$ を用いてクラスタ数を求めた [11] .

$$Q(K) = \sum_{l=1}^K \left(\frac{\text{links}(V_l, V_l)}{\text{links}(V, V)} - \left(\frac{\text{links}(V_l, V)}{\text{links}(V, V)} \right)^2 \right) \quad (36)$$

提案手法 2 では, 経験的に $\beta=3$ とした .

また仮に主要人物の人数を事前に与えられていた場合, クラスタ数を与えグラフを分割する手法を用いることができる . outlier を一つのクラスタにまとまりやすい性質を利用することで, クラスタリング結果の精度が従来よりも上昇することを検証する . 検証するために, 以下の 2 つの手法を比較する . 主要人物の人数を N とする .

従来手法 (既知) クラスタ数 N を与え Normalized cuts を行う手法

提案手法 (既知) クラスタ数 $N+1$ を与え Normalized cuts を行い, 背景クラスタを取り除く手法

以上, 6 つの手法を用いて評価比較を行う .

4.1.4 実験評価方法

写真群からの主要人物抽出を行っているか調べるために以下の三点に注目して, それぞれ評価し考察する .

- 主要人物の人数推定
- 主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類
- 複数の主要人物の中での主要人物毎の分類

主要人物の人数推定

主要人物の人数推定はクラスタ数未知で生じる問題である . そのため, 従来手法 1, 2 と提案手法 1, 2 を用いて比較する .

主要人物の人数の真値と推定主要人物の人数との誤差を評価するために平均絶対誤差 (MAE) と平均絶対比率誤差 ($MAPE$) を用いた . MAE の結果から, どの人数のデータに対して推定人数の誤差が生じたかを確認する . $MAPE$ の結果から, 主要人物の人数推定の精度を確認する .

$$MAE = \frac{1}{D} \sum_{i=1}^D |\tilde{n}(i) - n(i)| \quad (37)$$

$$MAPE = \frac{1}{D} \sum_{i=1}^D \frac{|\tilde{n}(i) - n(i)|}{n(i)} \quad (38)$$

ここで、 D はデータセット数、 $\tilde{n}(i)$ は推定人数、 $n(i)$ は人数の真値である。各手法、データセット、データセットの主要人物の人数を変えて MAE と $MAPE$ を求めた。従来手法 1 は前景クラスタとみなす検出した部分グラフのサイズが 5 以上の部分グラフの数を推定人数とする。従来手法 2 は Modularity の評価値 $Q(K)$ で求めたクラスタ数を推定人数とする。提案手法 1, 2 は outlier を考慮しているため背景クラスタが存在する。そのため、提案手法で推定したクラスタ数から 1 引いたものを推定人数とする。

主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類

主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類は outlier を考慮している手法でないと 2 クラスに分類することができない。そのため、従来手法 1, 提案手法 1, 2 と提案手法 (既知) を用いて比較する。

2 クラス分類ができていないか調べるために outlier として取り除かれる要素群について調べる。密な部分グラフとして検出されたクラスタに属するノードは主要人物とし、それ以外のノードを outlier とする。従来手法 1 では、グラフ中の擬似クリークとして検出された部分グラフの補集合を背景要素と推定する。提案手法 1, 2 と提案手法 (既知) では、指標 $\delta(V_i)$ の値が最小値のクラスタに属するノードを outlier と推定する。手法ごとに outlier として取り除かれる要素群の F 値を求め比較し、評価した。F 値 ($Fmeasure$) は適合率と再現率の調和平均と定義され、式 (39) のように記述できる。

$$Fmeasure = \frac{2Recall \cdot Precision}{Recall + Precision} \quad (39)$$

適合率 ($Precision$) は、outlier として推定されたノードのうち、実際に outlier であるノードである割合とし、再現率 ($Recall$) は、実際に outlier であるノードのうち、outlier と推定されたノードの割合とする。

主要人物毎の分類

主要人物毎に分類できているかを確認するために、各クラスタについて調べる。主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類と異なり、前景クラスタは各主要人物と対応していない。この対応は以下のように自動で求めた。

まず、クラスタに属するノードで最も多く含まれる主要人物の顔をその主要人物のクラスタとする。同一人物で形成される前景クラスタが複数存在する場合は、クラスタに属するノード数が最も大きいクラスタを、その主要人物のクラスタとし、それ以外のクラスタを主要人物以外のクラスタとみなす。前景ク

クラスタが形成されない主要人物が存在すれば，その主要人物のクラスタはノードをもたないクラスタとする．

上記の手順で得た各主要人物のクラスタに対して，適合率 (*Precision*) は，ある主要人物として推定されたノードのうち，実際にその主要人物であるノードの割合とし，再現率 (*Recall*) は，実際に特定の主要人物であるノードのうち，その主要人物と推定されたノードの割合とした．式 (39) より F 値 (*Fmeasure*) を求める．ただし，ノードをもたないクラスタの場合は適合率，再現率，F 値を全て 0 とした．

outlier を考慮していない手法は主要人物のクラスタに outlier が含まれるため明らかに F 値が下がる．そのため各主要人物のクラスタの再現率で比較し，評価した．

4.2 主要人物の人数に対するスケーラリティの評価

4.2.1 対象となる仮想データセット

Web 上から著名人の顔画像を 1 万枚以上も集めた Labeled Faces in the Wild [12] のデータセットから無作為に選んだ人物で，主要人物の人数が 2, 3, 4, 5, 10, 15 人の仮想的な写真群データを作成し，ノイズとなる非顔画像を別途付加して評価用データセットを作成した．仮想データセットの詳細について表 1 で示した．

主要人物の人数	2人	3人	4人	5人	10人	15人
一人当たりの顔画像の枚数	30枚					
ノイズとなる非顔画像の枚数	30枚					
全ての顔画像の枚数	90枚	120枚	150枚	180枚	330枚	480枚
各人物と同一写真に写っている回数	5回					
同一写真に写った全ての顔の組み合わせ数	5	15	30	50	225	525
データセット数	5セット					

表 1: 仮想データセット

4.2.2 結果・考察

主要人物の人数推定の精度を検証するために，各人数のデータ毎の *MAE*，*MAPE* を求めた．表 2 に，それぞれ主要人物の人数が 2, 3, 4, 5, 10, 15 人の

データの MAE , $MAPE$ の結果を示した。提案手法 1 は, 従来手法 1, 2 より

人数データ	従来手法 1 [7]		従来手法 2 [11]		提案手法 1($\beta=0$)		提案手法 2($\beta=3$)	
	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE
2 人	0.80	0.40	1.60	0.80	0.60	0.30	0.20	0.10
3 人	1.40	0.46	1.20	0.40	0.20	0.06	0.00	0.00
4 人	1.40	0.35	0.00	0.00	1.60	0.40	0.40	0.10
5 人	2.00	0.40	1.80	0.36	1.60	0.32	0.40	0.08
10 人	4.40	0.44	6.40	0.64	5.40	0.54	3.20	0.32
15 人	5.80	0.38	11.2	0.74	14.0	0.93	2.60	0.17

表 2: 主要人物の人数推定

も 2, 3, 5 人のデータに対しては MAE , $MAPE$ とともに低い値を示した。提案手法 2 は, 従来手法 1, 2 よりも 4 人のデータ以外に対しては MAE , $MAPE$ とともに低い値を示した。主要人物の人数が 15 人のデータの場合, 提案手法 2 は従来手法 1 よりも $MAPE$ は 0.24 も減少している, また従来手法 2 よりも $MAPE$ は 0.57 も減少している。よって主要人物の人数が多い場合, 提案手法は従来手法より主要人物の人数推定の精度は 24 ポイント以上も向上することが確認できた。

また, 提案手法 1 よりも提案手法 2 が優れているため, 理想なクラスタ数を与えるためには 3.4.2 で述べた評価値だけではできず, 3.4.1 で述べた評価値を組み合わせることで実現できることが確認できた。

次に, 主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類が有効に働いているか検証するために, outlier として取り除かれた要素群の F 値を求めた。詳細な実験データは付録の表 1 に示す。図 4 で各人数のデータの F 値の平均を示した。

提案手法 1 は, どの人数のデータに対しても従来手法 1 よりも高い F 値を示している。よって従来手法 1 や outlier を考慮していない従来手法 2 よりも主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類は有用であると考えられる。提案手法 2 は, 提案手法 1 より 10, 15 人のデータに対してもより高い F 値を示した。また, 従来手法 1 と比べ 15 人のデータの場合, F 値が 0.572 も高くなっている。よって提案手法は従来の手法より主要人物 (inlier) と非主要人物 (outlier)




図 4: 主要人物 (inlier) と非主要人物 (outlier) との 2 クラス分類

の 2 クラス分類の精度が約 57.2 ポイントも向上する結果が得られた。表 2 より提案手法 2 の主要人物の人数推定の結果が良好ため、提案手法 2 と提案手法 (既知) の結果にあまり差が出なかったと考えられる。

最後に、主要人物毎の分類が有効に働いているか検証するために主要人物とみなしたクラスターの再現率を求めた。詳細な実験データを付録の表 2, 3 に示す。図 5 で各人数のデータの再現率の平均を示した。

提案手法 1 は、各人数のデータに対して従来手法 1 より高い再現率を示しているが、5, 10 人のデータ以外に対して従来手法 2 より低い再現率を示した。また、提案手法 2 は各人数のデータに対して従来手法 1 より高い再現率を示し、2 人のデータ以外に対して従来手法 2 より高い再現率を示した。2 人のデータに対して従来手法 2 と提案手法 (既知) を比較すると再現率にほぼ差がない。主要人物の人数が変化しても、理想的なクラスター数を与えることができれば提案手法 1, 2 も従来手法 1, 2 よりも主要人物毎の分類に関して、よい精度が出ることが確認できた。2, 10 人以外のデータに対しては提案手法 2 と提案手法 (既知) の再現率にあまり差が出ないことが確認された。今後、データ数を増やし 2, 10 人のデータのとき再現率に差が出る原因を特定したいと思う。

主要人物の人数が 15 人のデータに着目すると、提案手法 2 は比較手法 1 より




図 5: 主要人物毎の分類

再現率は 0.371 も高くなっている．また比較手法 2 よりも再現率は 0.528 も高くなっている．よって提案手法は従来の手法より主要人物毎の分類の精度が約 37.1 ポイント以上も向上する結果が得られた．

次にクラスタ数が既知の場合を比較する．提案手法 (既知) は従来手法 (既知) よりも 2 人のデータ以外に対して高い再現率を示した．outlier を含むデータに対しては outlier を一つのクラスタにまとまりやすい性質を利用することが有効であることが確認できた．

4.3 実環境から得られたデータに対する性能の評価

4.3.1 対象となる実データセット

ユーザが SNS 上のアルバム単位にアップロードした画像を対象とする．同一人物が複数回写っているアルバムを選択し，その中でも主要人物の人数が人の目でみて明確である旅行アルバムを選択した．写真共有サイトの一つである Flickr は，ユーザにアップロードされた写真を検索するための機能を，API として提供している．その Flickr API を用いてアルバム毎の写真群を取得する．これらの画像から検出した顔に対して人手でタグ付けを行う．実データセットの詳細について表 3 で示した．

	AlbumA	AlbumB	AlbumC	AlbumD	
写真の枚数	500 枚	422 枚	125 枚	203 枚	
主要人物の人数	2 人	2 人	4 人	5 人	
検出した顔の総数	427 個	290 個	180 個	197 個	
検出された各人物の顔	主要人物 1	161 個	59 個	27 個	25 個
	主要人物 2	57 個	60 個	54 個	34 個
	主要人物 3	-	-	36 個	19 個
	主要人物 4	-	-	44 個	46 個
	主要人物 5	-	-	-	27 個
	非主要人物	209 個	171 個	19 個	46 個

表 3: 実データセット

4.3.2 結果・考察

データの種類	従来手法 1 [7]	従来手法 2 [11]	提案手法 1($\beta=0$)	提案手法 2($\beta=3$)
AlbumA	1.00	1.00	1.00	0.00
AlbumB	3.00	1.00	1.00	0.00
AlbumC	3.00	2.00	3.00	0.00
AlbumD	2.00	2.00	3.00	2.00
MAE	2.25	1.50	2.00	0.50
MAPE	0.78	0.47	0.58	0.10

表 4: 主要人物の人数推定 (各アルバムに対する推定人数誤差と全体の誤差の MAE, MAPE)

表 4 に、各データの推定人数誤差の結果を示した。提案手法 2 は従来手法 1 と比べて *MAPE* の値が 0.68 も減少する。また従来手法 2 と比べて *MAPE* の値が 0.37 も減少する。提案手法は従来手法と比べて主要人物の人数推定の精度が 37%以上も向上することが確認された。

次に、表 5 に、outlier として取り除いた要素群の適合率、再現率、F 値を示した。表 5 より比較的推定人数の誤差が少ない AlbumA や AlbumB のデータに対して提案手法 1 は、従来手法 1 よりも高い F 値を示した。また、提案手法 2

データの種類	従来手法 1 [7]			提案手法 1($\beta=0$)			提案手法 2($\beta=3$)			提案手法 (既知)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
AlbumA	0.480	1.000	0.649	0.725	0.846	0.781	0.923	0.808	0.862	0.923	0.808	0.862
AlbumB	0.379	1.000	0.549	0.716	0.900	0.797	0.956	0.906	0.930	0.956	0.906	0.930
AlbumC	0.158	1.000	0.273	0.161	0.369	0.225	0.500	0.842	0.627	0.500	0.842	0.627
AlbumD	0.099	1.000	0.181	0.386	0.739	0.507	0.414	0.739	0.531	0.559	0.717	0.628

表 5: 主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類

は AlbumA, AlbumB, AlbumC, AlbumD のデータに対して従来手法 1 よりも F 値が 0.213, 0.281, 0.354, 0.350 も高くなった。よって提案手法 2 は従来手法より主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類の精度 21% 以上も向上することが確認された。また, 仮想データと同様に表 4 より提案手法 2 の主要人物の人数推定の結果が良好のため, 提案手法 2 と提案手法 (既知) の結果にあまり差が出なかったと考えられる。

図 4, 表 5 より提案手法 (既知) はどのデータに対しても F 値が 0.628 よりも高い結果が得られた。スペクトラルクラスタリングを用いることで主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類について有用であることも確認された。

データの種類	従来手法 1 [7]			従来手法 2 [11]			提案手法 1($\beta=0$)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
AlbumA	1.000	0.199	0.324	0.535	0.947	0.617	0.407	0.462	0.433
AlbumB	0.970	0.233	0.374	0.772	0.848	0.808	0.353	0.449	0.395
AlbumC	1.000	0.410	0.554	0.272	0.495	0.351	0.143	0.244	0.180
AlbumD	0.571	0.105	0.174	0.302	0.501	0.361	0.215	0.318	0.255

表 6: 主要人物毎の分類 (比較手法 1, 比較手法 2, 提案手法 1)

データの種類	提案手法 2($\beta=3$)			従来手法 (既知)			提案手法 (既知)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
AlbumA	0.788	0.906	0.842	0.519	0.945	0.615	0.788	0.906	0.842
AlbumB	0.789	0.848	0.817	0.481	0.907	0.595	0.789	0.848	0.817
AlbumC	0.929	0.870	0.897	0.811	0.906	0.855	0.929	0.870	0.897
AlbumD	0.414	0.442	0.426	0.635	0.760	0.661	0.804	0.755	0.771

表 7: 主要人物毎の分類 (提案手法 2, 従来手法 (既知), 提案手法 (既知))

表 6, 7 に, 主要人物毎のクラスタの適合率, 再現率, F 値の平均を示した。クラスタ数が未知の場合, 提案手法 2 は AlbumA, AlbumD のデータ以外に関して従来手法より高い再現率を実現した。AlbumA のデータに関しては提案手法 2 の再現率が従来手法 2 の再現率よりも劣っているのは outlier として取り除いた要素群の中に主要人物の要素が含まれていたためと考えられる。AlbumD のデータに関しては, 提案手法 2 の適合率, 再現率, F 値どの値も低い値を示している。表 3 よりクラスタ数自動決定の結果が良好でなかったためと考えられる。仮に AlbumD の推定人数の誤差が 0 だった場合, 提案手法 (既知) の結果から主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類に関しての F 値が 0.097 も高くなり, 主要人物毎の分類に関して再現率が 0.313 も高くなることが確認された。

クラスタ数が既知の場合, 提案手法 (既知) は従来手法 (既知) より低い再現率を示したが, 差が 0.05 未満でさほど差がない。また提案手法 (既知) は従来手法 (既知) よりも高い適合率を示し, 高い F 値を実現した。従来手法 (既知) は主要人物毎の分類に関してはよい精度を示しているが, 各クラスタに非主要人物の要素が入っていると考えられる。写真群からの主要人物抽出問題は主要人物ごとにまとめあげることが重要視されるので提案手法 (既知) の方が有効であると考えられる。

第 5 章 結論

本研究では, 写真群からの主要人物を抽出する問題を扱った。顔検出や顔認識の技術により頂点を顔画像, 辺を顔間の類似度とするグラフネットワークを作成し, 密な部分グラフを数え上げることで主要人物を抽出することができる。従来手法では最適な部分グラフの密度に関するしきい値を定めるか, もしくは outlier を含むデータに対応し, 主要人物の人数推定する必要があった。本研究では後者の問題に対処した。

新たに発見したスペクトラルクラスタリングの性質を用いて outlier を含むデータから, 部分グラフ内の密度が高く, かつ他の部分グラフとの連結度が小さい部分グラフを抽出する手法を提案した。さらに同一写真に写る人物は別人であることと背景クラスタがはっきりあらわれているかを利用することでクラスタ数を自動で決定し, 写真群からの主要人物の抽出の精度を向上を試みた。

実験では、写真群に写っている主要人物の人数を変化させた仮想データや写真共有サイトから実際に存在する写真群を用いて従来の密な部分グラフを発見する手法と比較することで主要人物の人数に対するスケーラビリティの評価や実環境から得られたデータに対する評価を行った。主要人物の人数推定、主要人物 (inlier) と非主要人物 (outlier) の2クラス分類、主要人物毎の分類の3点に着目し従来の密な部分グラフを抽出する手法と比較し評価した。主要人物の人数が多い場合では、提案手法は従来手法より主要人物の人数推定の精度は24ポイント以上、主要人物 (inlier) と背景要素 (outlier) の2クラス分類の精度は57ポイント以上、主要人物毎の分類の精度は37ポイント以上も向上する結果を得られた。次に、実環境から得られたデータの場合でも従来手法よりも精度が向上する結果を得られた。提案手法は、主要人物の人数が多い場合でも、また実環境から得られたデータの場合でも従来手法より有用であることが確認された。また、スペクトラルクラスタリングを用いることで主要人物 (inlier) と背景要素 (outlier) の2クラス分類の精度はどのデータに対しても62%以上の結果が得られ、有用であることが確認された。

今後の課題としては、主要人物の人数よりも一つ多いクラスタ数でのスペクトラルクラスタリングの有用性が確かめられたのでクラスタ数決定の精度の向上が挙げられる。評価値の重みである β の値を変化させ、実験する予定である。また、同一写真に写る人物は別人であることは写真特有の問題にしか用いることができない。これを用いずにクラスタ数の決定を行うことができれば、孤立した密な部分グラフの発見は写真群からの主要人物抽出以外にも、防犯カメラの映像を用いるとある商業施設などの頻繁に利用している人の特定や論文の共著ネットワークから研究協力コミュニティの抽出など幅広い分野で応用が可能となる。そのため、同一写真に写る人物は別人である情報を用いずにクラスタ数の決定を行うことも今後の課題として挙げられる。

謝辞

本研究を進めるにあたり、多くのご教示を賜りました美濃導彦教授、飯山将晃准教授に深く感謝いたします。また日頃より多くの助言を頂きました橋本敦史助教、森幹彦助教に厚く御礼申し上げます。またグループミーティングで多くの助言を頂きました観光講義グループの皆様、ならびに美濃研究室の皆様に深く

感謝いたします。

参考文献

- [1] OKAOVision. <http://www.omron.co.jp/ecb/products/mobile/>.
- [2] Hairong Liu, Longin Jan Latecki, and Shuicheng Yan. Fast detection of dense subgraphs with iterative shrinking and expansion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 9, September 2013.
- [3] Jianbo Shi and Jitendra Malik. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 8, August 2000.
- [4] Andrew Y. Ng, Michael I. Jordan, and Yair Weiss. On spectral clustering: Analysis and an algorithm. *In Neural Information Processing Systems*, 2002.
- [5] Stella X. Yu and Jianbo Shi. Multiclass spectral clustering. *International Conference on Computer Vision*, pp. 11–17, October 2003.
- [6] Hairong Liu, Longin Jan Latecki, and Shuicheng Yan. Dense subgraph partition of positive hypergraphs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 37, No. 3, March 2015.
- [7] Takeaki Uno. An efficient algorithm for enumerating pseudo cliques. *Algorithmica*, Vol. 56, No. 1, pp. 3–16, 2010.
- [8] Xiang Wang and Ian Davidson. Active spectral clustering. *In ICDM, IEEE*, pp. 561–568, 2010.
- [9] 岩井儀雄, 勞世, 山口修, 平山高嗣. 画像処理による顔検出と顔認識. 情報処理学会 Computer Vision and Image Media, No. 38, pp. 343–368, 2005.
- [10] P. Jonathon Phillips, Hyeonjoon Moon, Syed A. Rizvi, and Patrick J. Rauss. The feret evaluation methodology for face-recognition algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 10, pp. 1090–1104, 2000.
- [11] M.E. Newman. Modularity and community structure in networks. *Proceeding of the National Academy of Sciences*, Vol. 103, No. 23, pp. 8577–8582,

2006.

[12] Labeled Faces in the Wild. <http://vis-www.cs.umass.edu/lfw/>.

付録

人数データ	従来手法 1 [7]			提案手法 1($\beta=0$)			提案手法 2($\beta=3$)			提案手法 (既知)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
2 人	0.560	1.000	0.717	0.767	0.933	0.828	0.851	0.913	0.871	0.954	0.953	0.953
3 人	0.443	1.000	0.613	0.931	0.946	0.937	0.941	0.946	0.943	0.941	0.946	0.943
4 人	0.363	1.000	0.533	0.656	0.906	0.739	0.891	0.893	0.888	0.925	0.906	0.912
5 人	0.326	1.000	0.492	0.769	0.838	0.779	0.854	0.900	0.873	0.896	0.900	0.897
10 人	0.184	1.000	0.311	0.400	0.813	0.510	0.637	0.893	0.731	0.768	0.793	0.773
15 人	0.101	1.000	0.183	0.139	0.653	0.227	0.715	0.820	0.755	0.773	0.786	0.779

表 1: 仮想データの実験 (主要人物 (inlier) と非主要人物 (outlier) の 2 クラス分類)

人数データ	従来手法 1 [7]			従来手法 2 [11]			提案手法 1($\beta=0$)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
2 人	1.000	0.396	0.552	0.941	0.973	0.955	0.602	0.680	0.630
3 人	1.000	0.380	0.535	0.723	0.917	0.798	0.878	0.908	0.889
4 人	1.000	0.368	0.525	0.730	0.748	0.608	0.511	0.577	0.525
5 人	0.989	0.423	0.582	0.424	0.573	0.411	0.553	0.654	0.584
10 人	0.994	0.328	0.481	0.135	0.266	0.109	0.302	0.403	0.331
15 人	0.980	0.333	0.486	0.087	0.176	0.063	0.006	0.066	0.011

表 2: 仮想データの実験 (主要人物毎の分類 (比較手法 1, 比較手法 2, 提案手法 1))

人数データ	提案手法 2($\beta = 3$)			従来手法 (既知)			提案手法 (既知)		
	適合率	再現率	F 値	適合率	再現率	F 値	適合率	再現率	F 値
2 人	0.855	0.870	0.861	0.691	0.983	0.800	0.9684	0.970	0.968
3 人	0.974	0.971	0.972	0.654	0.846	0.729	0.974	0.971	0.972
4 人	0.885	0.893	0.881	0.664	0.850	0.738	0.964	0.966	0.966
5 人	0.912	0.908	0.906	0.707	0.818	0.750	0.951	0.948	0.949
10 人	0.503	0.574	0.519	0.662	0.700	0.672	0.758	0.741	0.742
15 人	0.691	0.704	0.684	0.673	0.714	0.682	0.762	0.751	0.749

表 3: 仮想データの実験 (主要人物毎の分類 (提案手法 2, 従来手法 (既知), 提案手法 (既知)))