

線形弁別特徴変換に関する研究

小倉 将義[†] 高宮 隆弘[†] 和田 俊和[†] 前田 俊二[‡] 酒井 薫[‡]

[†]和歌山大学システム工学部 〒640-8510 和歌山県和歌山市栄谷 930 番地

[‡]日立製作所 生産技術研究所 〒244-0817 神奈川県横浜市戸塚区吉田町 292 番地

E-mail: [†]{ampan,takamiya,twada}@vrl.sys.wakayama-u.ac.jp, [‡]{shunji.maeda,ap,kaoru.sakai.pp}@hitachi.com

あらまし 距離の大小に基づいて対応付けを行う手法は数多く存在する。例えばScale Invariant Feature Transform (SIFT) 特徴に基づく点の対応付けや、ステレオ画像におけるエッジボラ線上での局所画像の対応付け問題などが代表的である。これらの問題では、距離、あるいは誤差を測る尺度が先に定められているため、例え結果が好ましくなくても、より良い評価尺度を与える相手に対応付けをするしかない。しかし、ユーザにとっての、「望ましい対応付け」と「望ましくない対応付け」の2つをシステムの側にフィードバックすることにより、再学習を行い、ユーザにとってより好ましい距離尺度を得ることは可能である。これは、*metric learning* と呼ばれる問題の一種である。これまでに数多くの*metric learning*の手法が提案されてきたが、通常の問題設定では各クラスが対等に扱われてきた。本研究では、好ましい対応付けは小さい距離、好ましくない対応付けは長い距離になるように特徴を変換する弁別特徴変換を提案する。本稿では、線形な計算によって弁別特徴変換を行う方法を示すとともに、簡単な実験でその有効性を示す。

キーワード 対応付け, 距離尺度, メトリックラーニング, 線形弁別特徴変換

Linear Discriminant Feature Transform

Masayoshi OGURA[†] Takahiro TAKAMIYA[†] Toshikazu WADA[†] Shunji MAEDA[‡] and Kaoru SAKAI[‡]

[†]Faculty of Systems Engineering, Wakayama University, 930 Sakaedani, Wakayama, 640-8510 Japan

[‡]Production Engineering Research Laboratory, Hitachi, Ltd. 292 Yoshida-cho, Totuka-ku, Yokohama, 244-0817 Japan

E-mail: [†]{ampan,takamiya,twada}@vrl.sys.wakayama-u.ac.jp, [‡]{shunji.maeda,ap,kaoru.sakai.pp}@hitachi.com

Abstract SIFT feature based point correspondence and stereo matching using template matching are the examples of data correspondence algorithms, which find the optimal pairs providing minimum distances. When the resulting correspondences are not satisfactory, metric learning method can be applied to produce a better metric. Most metric learning methods treat every class evenly, however, correspondence problems require asymmetric treatment of classes, correct and incorrect correspondences. This paper proposes *Discriminant Feature Transform* (DFT) that transforms feature vectors so as to produce smaller distances for correct correspondences and bigger distances for incorrect correspondences. In this report, we present linear version of DFT and examine its effectiveness.

Keyword Data correspondence, Metric measure, etric learning, Linear Discriminant Feature Transform

1. はじめに

画像の検索や認識といった技術はセキュリティ分野やイメージ検索といった形で数多く扱われている。このような画像の検出や認識において正しい認識を行うためには、同じカテゴリに属する画像に関して、異なるカテゴリに属する画像よりも距離が短くなる必要がある。しかし、人の目で見えて似ていると判断される画像組でも距離を計算すると、似ていないと判断される画像組よりも離れている場合がある。つまり、正対応の画像組の距離が長くなり、誤対応の画像組の距離が短くなることにより、誤った対応付けや誤認識が生

じる。

本研究では、正対応の画像組の距離が誤対応の画像組の距離よりも短くなるように特徴を変換する「弁別特徴変換」を提案する。これは、

1. 正対応の画像同士の距離が、誤対応の画像との距離よりも短くなるように部分空間に射影し、
2. 正対応の画像の差が原点付近に集中するように、部分空間の軸に重みを付ける

という計算によって実現することができる。

従来、この種の問題は *metric learning* の問題として扱われてきたが、*metric learning* では、各クラスを対

等に扱う場合がほとんどであり、本研究で取り扱う対応付け問題のように正対応と誤対応を非対象に扱い、しかも射影によって次元を下げる方向での特徴変換を行う手法は調査した限り存在しない。

本稿では、弁別特徴変換の基本となる線形弁別特徴変換の枠組みを示し、実験により SIFT 特徴の正対応数が増すことを示す。

2. 関連研究

画像の検索や認識の分野では、ユーザの意図する結果をもたらすように距離尺度を学習する metric learning に関する研究が行われている。

これらの研究の中で特徴に対する多様な重みづけ計算法が提案されてきた[1]。しかしこれらの多くは計算量が多くなる点や、識別問題用に開発されてきたためクラスラベルの利用が行えないことが指摘され、近年クラスラベルの代わりに類似度を用いる metric learning の手法が検討されている。この中で、視覚監視の問題を取り扱うために提案された Relevant Component Analysis (RCA)[2]は、行列の逆行列の計算を行うだけでよいという簡便さがあり、他の手法と比較しても性能が優れていることが明らかになっている。さらに、情報理論的な観点からの最適性も示されている[3]という点で、注目を集めている。しかし、この手法では、図 1 に示すような XOR パターンの分布を変換しても、弁別性の点では何の改善もなされないことが示されている。




図 1. 画像同士の距離 (文献[4]からの引用)

この問題を解決するために、RCA の Kernel 化が行われ、上図のような点分布であっても分離性が保証でき、しかも計算上の効率でも優れた特徴変換法が示されている[4]。

これらの手法を見ると、各クラスを対等に扱っているがために、例えば上述の XOR のケースがうまく分離が行えないといった制限がある。このような制限が線形な演算の範囲で問題を扱っているために発生する問題であると考えすることは、一見、妥当そうに思えるが、metric learning という観点からみると妥当ではないことが分かる。つまり、上の XOR の分布パターンで

も、図 2 に示すように、ある軸に沿って射影を行い、一方の点分布を一か所にまとめてしまい、そこを中心に戻を描けば 2 つのクラスを分離することは可能である。




図 2. XOR の分布でも射影と metric により分離可能

3. 線形弁別特徴変換

ここでは、上記の考察を基に、線形弁別特徴変換を提案する。この手法では、

1. 二つの集合に属する特徴同士の対応付けをした結果を、正対応組と誤対応組に分ける。
 2. 射影後に正対応の特徴間の距離の平均値が、誤対応の特徴間の距離の平均値よりも小さくなるような部分空間を求める
 3. 求めた部分空間への射影を行った後に特徴間の距離計算を行う
- といった手順で特徴の変換を行う。

正対応の特徴組を $\mathbf{x}, \mathbf{y}$ とし、誤対応の特徴組を $\mathbf{x}, \mathbf{z}$ とする。ここで、

$$\|\mathbf{x} - \mathbf{y}\| > \|\mathbf{x} - \mathbf{z}\| \quad (1)$$

の関係が生じている場合正しい対応関係がとれていないことになる。 $\mathbf{x}$ を $\mathbf{z}$ よりも $\mathbf{y}$ の方に対応付けるために、

$$\|\phi(\mathbf{x}) - \phi(\mathbf{y})\| < \|\phi(\mathbf{x}) - \phi(\mathbf{z})\| \quad (2)$$

という関係が成立するように特徴を変換する。

以降、この変換された特徴を「弁別特徴」と呼び、この変換を「弁別特徴変換」と呼ぶことにする。

今、 $\mathbf{x}, \mathbf{y}, \mathbf{z}$ の具体的なサンプルが $\mathbf{x}_i, \mathbf{y}_i, \mathbf{z}_i$ という記号で与えられているものとする。このとき

$$\mathbf{Y} = \frac{1}{\sqrt{m}} [\mathbf{y}_1 - \mathbf{x}_1 \quad \mathbf{y}_2 - \mathbf{x}_2 \quad \dots \quad \mathbf{y}_m - \mathbf{x}_m] \quad (3)$$

$$\mathbf{Z} = \frac{1}{\sqrt{n}} [\mathbf{z}_1 - \mathbf{x}_1 \quad \mathbf{z}_2 - \mathbf{x}_2 \quad \dots \quad \mathbf{z}_m - \mathbf{x}_m] \quad (4)$$

と置くと、ある 1 次元ベクトル $\mathbf{u}$ への射影を行った結

果がYについては小さくZに対しては大きくなるということを保証すれば良い。

全データについてベクトル $\mathbf{u}$ への射影を行った結果は、それぞれ $\mathbf{u}^T \mathbf{Y}$, $\mathbf{u}^T \mathbf{Z}$ であり、これらは横ベクトルである。これらのベクトルの長さの2乗和の平均値はそれぞれ、 $\mathbf{u}^T \mathbf{Y} \mathbf{Y}^T \mathbf{u}$, $\mathbf{u}^T \mathbf{Z} \mathbf{Z}^T \mathbf{u}$ となる。このとき、前者は小さく後者は大きくなるように $\mathbf{u}$ を設定することが弁別特徴変換の問題になる。これは使用する行列が異なるだけで、以下に述べる線形判別分析と同じ形式の問題になる。

3.1. 線形弁別特徴変換基底の導出

線形弁別特徴変換の問題は、

$$f(\mathbf{u}) = \frac{\mathbf{u}^T \mathbf{Z} \mathbf{Z}^T \mathbf{u}}{\mathbf{u}^T \mathbf{Y} \mathbf{Y}^T \mathbf{u}} \quad (5)$$

の式を最大化する $\mathbf{u}$ を求めることに相当する。ここで、この式は $\|\mathbf{u}\|$ に対して不変であるため、分母の $\mathbf{u}^T \mathbf{Y} \mathbf{Y}^T \mathbf{u}$ を一定値に拘束したうえで、解を求める。この場合ラグランジュの未定係数法を用いて、

$$J(\mathbf{u}) = \mathbf{u}^T \mathbf{Z} \mathbf{Z}^T \mathbf{u} + \lambda(1 - \mathbf{u}^T \mathbf{Y} \mathbf{Y}^T \mathbf{u}) \quad (6)$$

を最大化すれば良い。この式を $\mathbf{u}$ で偏微分すると、

$$\frac{\partial}{\partial \mathbf{u}} J(\mathbf{u}) = 2\mathbf{Z} \mathbf{Z}^T \mathbf{u} - 2\lambda \mathbf{Y} \mathbf{Y}^T \mathbf{u} = 0 \quad (7)$$

が得られる。この結果から、

$$\mathbf{Z} \mathbf{Z}^T \mathbf{u} = \lambda \mathbf{Y} \mathbf{Y}^T \mathbf{u} \quad (8)$$

という一般固有値問題が得られる。このような一般固有

値問題は、 $\mathbf{Z} \mathbf{Z}^T$ 及び $\mathbf{Y} \mathbf{Y}^T$ が対称行列であることを利用して通常の固有値問題に変換した後に安定に解くことができる[5]。この一般固有値問題を解くことで、サンプルの次元数個だけの固有ベクトル $\mathbf{u}$ が得られる。

しかし、得られる全固有ベクトルが、 $f(\mathbf{u}) > 1$ を満足する弁別特徴となる保証はない。 $f(\mathbf{u}) > 1$ を満たさない $\mathbf{u}$ は結果的に $f(\mathbf{u})$ の期待値を下げることになり、弁別特徴変換の効果を下げることになる。したがって、 $f(\mathbf{u}) > 1$ を満足する基底ベクトル $\mathbf{u}$ のみをピックアップする。この基底ベクトルを $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d$ とし、基底ベクトルから成る行列を $\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_d]$ とする。そしてこれらの基底ベクトルの張る部分空間への射影変換が線形弁別特徴変換となる。

4. ホワイティングを用いた基底への重み付け




図 3. 原点シフトなしのデータの分布

ここまでの議論では、特徴の差異を際立たせる基底を個別に求める問題を扱ってきた。これは、差異を際立たせる部分空間を求めることと等価である。

本章では、複数基底への射影成分にどのような重みを与えれば、正対応の場合の距離が短く、誤対応の場合の距離が長くなるのかという問題を考える。これは、各基底にどのような重みを与えて距離を計算すべきか、という問題である。以下、基底にかける重みについて記述する。

特徴変換後であれば、正対応 $\mathbf{U}^T(\mathbf{y}_i - \mathbf{x}_i)$ と誤対応 $\mathbf{U}^T(\mathbf{z}_j - \mathbf{x}_j)$ のベクトルの分布は通常、図2のように、

- ・ 正対応が誤対応に囲まれているケース
- ・ 正対応からみて誤対応がある方向に分布し、一つの面を介して接しているケース

の2つに分類される。しかし、どちらの場合も原点からの距離で結果を評価する場合、正対応の分布が各軸方向に均一になっている必要がある。これは、各 $\mathbf{u}_i$ 毎に偏差を求め、この偏差の逆数を重みとするホワイトニングの計算で解決することができる。




図 4. 正対応の点分布を基準とした原点シフト

ここで、ホワイトニングを行う前の段階で、正対応の点分布が原点を中心とした分布になるように原点シフトを行うことが望ましい。したがって、

$$\overline{yx} = \frac{1}{m} \sum_i^m (y_i - x_i) \quad (9)$$

とし、これを用いて

$$Y' = \frac{1}{\sqrt{m}} \begin{bmatrix} y_1 - x_1 - \overline{yx} & y_2 - x_2 - \overline{yx} & \dots & y_m - x_m - \overline{yx} \end{bmatrix} \quad (10)$$

$$Z' = \frac{1}{\sqrt{m}} \begin{bmatrix} z_1 - x_1 - \overline{yx} & z_2 - x_2 - \overline{yx} & \dots & z_n - x_n - \overline{yx} \end{bmatrix} \quad (11)$$

とすることで、射影後の正対応データの平均値は0になる。こうした上で、

$$f'(u) = \frac{u^T Z' Z'^T u}{u^T Y' Y'^T u} \quad (12)$$

の最大化を行うことで、射影軸 $u_1, u_2, \dots, u_d$ を求めることができる。

軸に対する重みを求めるという手順で計算を行うことができる。軸に対する重み付けのホワイトニング計算は以下のように行う。

本手法では弁別特徴変換後の正対応データ $U^T(y_i - x_i - \overline{yx})$ が正規分布に従うようにホワイト

ニングを行う。ここで $U^T Y'$ は正対応のデータを原点シフトし、弁別特徴変換を行ったデータである。また、すでに原点シフトを行っているため、 $U^T Y' Y'^T U$ は変換後の共分散行列を表している。共分散行列は対称行列であるので、

$$\Sigma_Y = U^T Y' Y'^T U = V \Lambda V^T \quad (13)$$

という固有値分解を行うことができる。この分解を利用して共分散行列の逆行列を求めると、

$$\Sigma_Y^{-1} = V \Lambda^{-1} V^T \quad (14)$$

と表すことができる。これを用いてマハラノビス距離を表すと、

$$(U^T Y')^T \Sigma_Y^{-1} (U^T Y') \quad (15)$$

となり、これを通常のノルムの2乗の形で計算できるようにデータ分布自体を変換することがホワイトニングである。これは式展開することによって、

$$(U^T Y')^T V \Lambda^{-\frac{1}{2}} \Lambda^{-\frac{1}{2}} V^T (U^T Y') \quad (16)$$




図5. ホワイトニング後の点分布

と変形できるので、

$$w_i = \Lambda^{-\frac{1}{2}} V^T U^T Y' \quad (17)$$

と点分布を変換することができる。これがホワイトニングである。このようにして得られた w_i のうち、正対応データは原点を中心に等方的に分布するため、距離の大小による正対応と誤対応の区別よりも安定に行えるはずである。ここで Y' はもとのデータを原点シフトしたもので、軸への重み付けを行った弁別特徴変換は、正対応・誤対応のデータを正対応の平均値を用

いて原点シフトした後、 $\Lambda^{-\frac{1}{2}} V^T U^T$ を掛け合わせることで計算される。

5. 実験

5.1. シミュレーションデータ実験




図6. シミュレーションデータ

図6のような正規分布に従う4つの2次元データ分布を発生させ、これに対して実験を行う。原点周辺に発生させた2つの分布を誤対応データ、誤対応データを挟むように発生させた2つの分布を正対応データとクラス付けする。今、誤対応のデータは原点周辺に存在しているため、通常通り距離比較を行ったとすると、明らかに正対応の分布よりも短い距離の値をとる。これに対し特徴の変換を行い、改めて距離の評価を行う。

線形弁別特徴変換によって正対応の距離が誤対応の距離よりも短くなることを確認したい。これは、距離に対し閾値処理した際、正対応の組数が増え、誤対応の組数を減らすことでもある。

距離に対し閾値処理を行い、閾値以下の距離の値をとるデータの個数の比較を行った。




図 7. シミュレーションデータの結果

図 7 では、横軸に誤対応数、縦軸に正対応数をとっている。閾値処理を入れているため、誤対応数の増加にともない正対応も増加する結果となっている。つまり、同じ誤対応数をとる場合でも正対応が多い方がより良い結果だといえる。図 7 中には 3 本のグラフがあるが、十字で表されるグラフが特徴変換などの処理を一切行わず通常通り距離計算を行い閾値処理したもの、*で表されるグラフが図 6 で与えられるデータに対しホワイトニングの処理を行ったもの、四角で表されるグラフが提案手法である。図 7 より提案手法が最も良い結果だといえる。また、ホワイトニングだけ行った結果でも、提案手法に近い値をとっていることから、提案手法でも行われているホワイトニングの効果がかなり大きく表れていることが分かる。ただし、ホワイトニングだけ行った場合、図 6 のような分布に対して完全にデータを分離することができない。そこで一度 1 次元の軸に射影を行うことで、より効果的にデータを分離することができていることが確認できる。このように、データの分布をマハラノビス距離で比較するだけでは上手く分離できないような場合には、一度弁別特徴変換によって次元数を落とす方がより良い結果を得ることができるといえる。

5.2. 実データ実験

図のような 2 枚で 1 組の画像を用いて実験を行った。図は一部同じ景色を写している。具体的には左画像の右端と、右画像の左端である。2 枚の画像から特徴を抽出し、特徴同士の対応付けを行った。対応付けの方法について述べる (図 7 参照)。




図 6. 実験に用いた画像




図 7. 特徴の対応付けの手順

- ①. 両画像から SIFT 特徴を抽出する
- ②. 左の特徴に対し最近傍の特徴を右側の画像内から探し出す
- ③. 特徴間の距離が閾値以下であれば、その特徴は対応付けられるとする

シミュレーション実験同様、距離に対し閾値処理を行い、閾値以下の距離の値をとるデータの個数の比較を行う。誤対応数の増加率に比べ正対応数の増加率が上回っていれば適切な特徴変換が行えているといえる。実験では学習セットと同じ画像セットをテストデータとした。1 度対応付けを行ったデータに対し、「正対応・誤対応」の区別を行い、そのデータをもとに弁別特徴変換の基底を求めた。

評価基準として、閾値を変化させながら正対応数と誤対応数の大小関係の比較を行った。閾値を大きくすると対応のとれる組数も増えていく。対応がとれなくなるまで下げた閾値を最小とする。また、左画像内の全特徴が対応をとるときに閾値を最大閾値として閾値を変化させた。

下図は図 6 を用いて線形弁別特徴変換を行ったときの、「正対応数・誤対応数」の結果である。




図 8. 正対応数－誤対応数

本実験では ROC カーブを書けないため、図 8 では、横軸に誤対応数、縦軸に正対応数をとり ROC カーブの代わりとした。十字のプロットが特徴変換を行わない特徴同士の距離を計算し閾値処理を行ったもの、バツのプロットが扱う特徴に対しホワイトニングを行ったもの、四角のプロットが提案手法である。

変換前・変換後のグラフ共に、誤対応数の増加に伴い正対応数も増加していることが分かる。ここで注目すべき点は、図 8 のグラフでは同じ誤対応数をとっている場合でも、正対応数が異なるという点である。図 8 では、提案手法とホワイトニングのグラフが特徴変換を行わない通常時の結果よりも上に存在している。これは誤対応組の距離に対して、正対応組の距離が縮まったことを意味している。特に提案手法では通常に比べ、誤対応数がかなり少ない段階でほとんどの正対応が出てくる。また、図 8 ではホワイトニングだけ行った結果と提案手法にほとんど差が見られない。これは、もともとのデータ分布が初めから分離しやすい形だったためだと考えられる。このことから提案手法におけるホワイトニングの影響はかなり大きいものだと考えられる。


なお、正対応数と誤対応数の絶対値が通常と変換後で変わっている。これは、特徴変換を行うことで右画像内の最近傍の特徴が変化し、正しい対応が増え、誤まった対応が減ったためである。

誤対応数が 0 のときの正対応数の数を比較すると、通常は 17 組、提案手法では 47 組と増加していることが分かる。


以上の結果から、線形弁別特徴変換によって、正対応の距離を短く、誤対応の距離を長くすることができたといえる。

5.3. $f(u)$ の閾値に対する評価実験

3 章では評価式 $f(u) > 1$ となる基底 u のみを扱う



通常の特徴の対応付け－正対応：17 組



提案手法の特徴の対応付け－正対応：47 組

図 9. 誤対応数が 0 になるとき




図 10. $f(u)$ に対するグラフ

と記述した。本実験では $f(u) > 1$ の右辺が 1 である妥当性を調べる。そこで、右辺の値を変化させながらグラフをプロットさせた。

図 10 は今までと同様に、横軸に誤対応数、縦軸に正対応数をとっている。4 本のグラフはほぼ同様のグラフを描くため分かりづらいが、十字でプロットされるグラフが右辺 1 のとき、バツでプロットされるグラフが右辺 2、* でプロットされるグラフが右辺 3、四角でプロットされるグラフが右辺 4 としたときのものである。どれも大きな差は無いが、右辺 1 のときのグラフが最も早い段階での正対応数の大幅な向上が見られる。また閾値を最大としたときの正対応数も最も多い結果となっている。このことから $f(u) > 1$ とする基底 u を扱う結果が最も良い場合だといえる。

なお、図 11 は基底 u に対する $f(u)$ のとる値を表している。横軸は何番目の u か (u の ID)、縦軸は $f(u)$ の値を示している。ここで、ID が小さいほど大きな固有値に対応する基底である。期待値 $f(u)$ が大きい軸を使うほど弁別特徴変換の効果は大きいといえるので、




図 11. $u - f(u)$

固有値の特に大きな u , つまり ID の小さな u 数本が特に弁別特徴変換に大きな効果をもたらしているといえる. 図 10 で右辺の値に対する変化が小さいのは, $f(u)$ の値が小さく似通ったものが数多く存在するためだと考えられる.

6. 線形弁別特徴変換に失敗するケース

先ほどの例では, 対応付けの結果の向上が見られた. しかし, 中には線形弁別特徴変換を行う際に適切な部分空間の基底が求まらず, 特徴変換を行うとむしろ結果が悪化してしまうケースもある.

例えば図 12 のように際立った特徴が無く, 似たようなパターンが続くような画像セットについて考える. このような画像から特徴を抽出した場合, 似たような特徴ばかりが抽出されると考えられる.




図 12. 適切な基底が求まらないケース

これはつまり正誤のパターンが同じ箇所に混在してしまうことを意味する. 図 13 のように学習パターンが混在してしまうと, 正対応の分布と誤対応の分布を分離させられるような基底 u を求めることができない.

このように正対応の分布と誤対応の分布が初めから混在している場合には線形分離が不可能となり, 提案手法による効果を得ることができなくなる.

十字のプロットが通常通り対応付けを行った結果, 四角のプロットが提案手法である. このグラフでは最初は提案手法の結果の方が若干良い結果が得られるが,




図 13. 適切な基底が求まらないケース




図 14. 線形弁別特徴変換が失敗するケース

かなり早い段階から提案手法の結果の方が悪化している. 最初の方は低い閾値でも検出されるような特徴的な特徴が抽出されるため, パターンが混在する状況を回避し結果が向上している. しかし, 閾値を上げるにつれ似た特徴ばかり抽出され, 結果的に正対応・誤対応共に距離を縮めてしまい結果を悪化させている.

まとめ

線形弁別特徴変換を提案した. これにより, 線形分離できる学習パターンに関しては, 正対応の特徴の距離を短くし, 誤対応の特徴の距離を長くすることができた. これにより誤対応数を減らすと共に, 通常では検出されない正対応を検出することができた. 本手法を検出や認識の場面で用いることで, 誤った検出や認識を減らしたり, 通常では検出することができなかった画像を検出したりすることができると考える.

今回上手くいかなかった線形分離不可能なパターン分布に関しては, カーネル化を行って非線形分離を行うことで解決することができるのではないかと考える. また, 類似画像検索における距離尺度として利用し, その有効性をより実用的な問題で検証する必要がある.

文 献

- [1] D. Wettschereck, D.W. Aha, and T. Mohri. A review and empirical evaluation of feature weighting methods for a class of lazy learning algorithms. *Artificial Intelligence Review*, 11:273–314, 1997.
- [2] N. Shental, T. Hertz, D. Weinshall, and M. Pavel. Adjustment learning and relevant component analysis. In *Proceedings of the Seventh European Conference on Computer Vision*, volume 4, pages 776–792, Copenhagen, Denmark, 2002.
- [3] A. Bar-Hillel, T. Hertz, N. Shental, and D. Weinshall. Learning distance functions using equivalence relations. In *Proceedings of the Twentieth International Conference on Machine Learning*, pages 11–18, Washington, D.C., USA, August 2003.
- [4] I.W. Tsang, P.-M. Cheung, and J.T. Kwok, “Kernel relevant component analysis for distance metric learning,” in *Proc. of IJCNN '05*, Vol. 2, pp. 954–959, 2005
- [5] Z. Bai, J. Demmel, J. Dongarra, A. Ruhe and H. van der Vorst, editors, *Templates for the solution of Algebraic Eigenvalue Problems: A Practical Guide* . SIAM, Philadelphia, 2000
- [6] D. Nister and H. Stewenius, “Scalable Recognition with a Vocabulary Tree,” *Proc. of CVPR 2006*, pp. 2161 – 2168, 2006