人間の主観評価を加味した目の形態分類 ニューラルネットの検討

磯 俊 樹[†], 崎 田 一 貴[†]
正会員 大 塚 作 一^{††}, 正会員 小 杉 信^{†††}

A Neural Network Approach for Classifying Eye Shape by Features Obtained from the Subjective Evaluation Standard

Toshiki Iso[†], Kazutaka Sakita[†],
Sakuichi Ohtsuka^{††} and Makoto Kosugi^{†††}

Abstract A neural net approach is proposed to classify the eye shape with the respect to the three dominant features obtained from the subjective evaluation standard. The neural network is composed of eighteen physical features of the eye used as input data and the three features in the subjective tests used as output data. From the experiments, it can be concluded that these features combined can best represent various subjective impressions of human eyes. It can also be shown that unknown data can be classified by using k-neighbor interpolation training, where neighboring data are chosen based on the criterion of absolute standard of learning data.

1. ま え が き

人間の顔を分類する技術は、犯罪捜査における容疑者検索システム等のセキュリティ分野のみならず、マルチメディアサービスへの応用にも広くその利用が期待される。個人同定を行う顔認識技術とは異なり、顔分類技術は、膨大なデータベースから、あるカテゴリ

一の範疇に入っている幾つかのデータを抽出するといった検索支援システムに应用できればよいので、その実用が期待される。しかし、顔分類技術の研究は古くから行われているにもかかわらず、まだ有効な手法が確立されていない。

顔分類技術の課題のひとつとして、顔の個人内の変動や未登録の顔に対する柔軟な分類の実現が挙げられ

キーワード：ニューラルネット，顔，主観評価，形態分類量， k 近傍内挿学習，目
1990年12月14日，電子情報通信学会技術報告，パターン認識・理解研究会で発表
1994年12月10日受付，1995年5月15日最終受付

[†] NTT ヒューマンインタフェース研究所 (〒238-03 横須賀市武 1-2356, TEL 0468-59-2874)

^{††} ATR 人間情報通信研究所 (〒619-02 京都府相楽郡精華町光台 2-2, TEL 0774-95-1061)

^{†††} 武蔵工業大学 (〒158 東京都世田谷区玉堤 1-28-1, TEL 03-3703-3111)

[†] NTT Human Interface Laboratories (1-2356, Take, Yokosuka-shi, Kanagawa 238-03, Japan)

^{††} ATR Human Information Processing Laboratories (2-2, Hikaridai, Seika-cho, Souraku-gun, Kyoto 619-02, Japan)

^{†††} Musashi Institute of Technology (1-28-1, Tamazutsumi, Setagaya-Ku, Tokyo 158, Japan)

図 1 階層化による顔分類システムの一例
Example of hierachic system for facial classification.

る。従来手法では、顔分類の際に用いる判定基準が物理的特徴量のみに基づいたものであり、人間の主観評価を加味したものではなかった。そのため、分類結果は、人間が実際に行う評価結果と必ずしも一致しなかった。

そこで我々は、人間の主観評価基準を加味した顔分類システムを提案する。提案するシステムの一例を図 1 に示す。このシステムでは、顔の分類を行うにあたって顔を顔部品（目、鼻、口など）と顔部分（目と眉あるいは鼻と口で構成される目元や口元）に分けて考えており、各々の形態分類を行うモジュールを階層的に組合せることで顔全体の分類を行う。各分類モジュールでは、その分類結果を人間の主観評価に基づいて得られた分類特徴量（以下、形態分類量と呼ぶ）で表現している。そして、各分類モジュールが階層化しているため、モジュールで得られた形態分類量が、今度は顔全体を分類するための特徴量となる。この形態分類量は、従来用いられていた物理的な特徴量に代わる新しい特徴量になり得る。このように、人間の主観評価に基づいた形態分類量を階層化された顔の分類システムに用いることで、物理的特徴量のみを用いた従来の手法と異なり、より人間の感覚に近い分類システムを実現できる可能性がある。

また、このシステムを構成している各モジュールをニューラルネットを用いて構築する。これは、登録されたデータ以外の対応が難しかった多変量解析を用いた従来手法に比べ、汎用性のあるシステムを構築できる可能性があるからである。

今回は、このシステムを構築するための第一段階として、人間の顔の中で最も個性が強く表れる顔部品といわれる目について着目し、目の形態を分類するモジュールについて以下の検討を行った。

(1) 主観評価実験に基づく目の形態分類量の抽出。

(2) 目の形態分類ニューラルネットの構築とその汎化性の検討。

(1)では、主観評価実験結果を主成分分析することで、シンボリックな表現でない目の形態分類量を明らかにする。

(2)では、学習データ（登録データ）だけではなく、未学習データ（未登録データ）に対しても目の形態分類が行えるように、 k 近傍内挿学習法を用いて汎化能力を有するニューラルネットの構築を行う。

その結果、汎化能力を有する目の形態分類ニューラルネットを構築することができたので報告する。

2. 主観評価実験に基づく目の形態分類

人間が顔画像を認識する際、目の情報が重要であることはすでに明らかにされている³⁾が、目に関してどのような特徴が心理的に大きな要因であるかについては充分検討されていない。そこで、人間がどのような観点から目を識別しているかを心理実験により調べ、その結果に基づいて目に関する形態分類量を抽出した²⁾。

2.1 顔写真の主観評価実験

目の特徴に対する直感的な判断を端的な言葉で表現

することは困難である．そこで，形容詞群を用いて主観評価実験を行い，主成分分析により目の特徴に関する心理要因を抽出した．

(1) 目に関する形容詞の抽出

目に関する形容詞群を網羅する必要がある．そこで，形容語辞典，分類用語辞典，人相学の本³⁾から目に関する形容詞（色関係を除く）の抽出を行った．その結果，次に示す 45 種類の形容詞を選択した．

- 1.上目 2.下目 3.伏目
- 4.上がり目 5.下がり目 6.垂れ目
- 7.吊り目 8.出目 9.大目玉
- 10.どんぐり目 11.くぼんだ目 12.細目
- 13.切れ長の目 14.二重瞼 15.とろんとした目
- 16.ぱっちりした目 17.ぎょろぎょろした目
- 18.淫らな目 19.陰湿な目 20.きらめく目
- 21.虚ろな目 22.優しい目 23.みずみずしい目
- 24.暗い目 25.鋭い目 26.張り裂けそうな目
- 27.涼しい目 28.卑しそうな目 29.和やかな目
- 30.血走っている目 31.熱心な目 32.無邪気な目
- 33.威厳のある目 34.すがすがしい目
- 35.神秘的な目 36.瞳が大きい目 37.瞳のはっきり目
- 38.大きい目 39.三角形の目 40.上瞼のゆるんだ目
- 41.たるんだ目 42.狼のような目
- 43.丸目 44.小さい目 45.こせついた目

(2) 主観評価実験

目の形態に関して平均的な主観評価を得るために，10名の被験者(20代の女性)で主観評価実験を行った．

被写体：男女(20～40代)の白黒写真102枚を用いた．目の物理的特徴量が正確に抽出できるように目・眉が髪の毛等で隠れていないものを選んだ．また，顔全体の造りが目の主観評価に影響することを考慮し，目元だけではなく顔の全体像を選んだ．なお，用いた102枚の白黒写真は同一の照明条件で撮影されたものである．

実験用容：目の形態に関する形容詞群それぞれについて，“よくあてはまる”，“ややあてはまる”，“あてはまらない”の3段階で評価を行った．被験者数は10名とし，評価時間は無制限とした．10人の被験者の評点を平均した後，主成分分析を行った．

実験結果と考察：主成分分析の結果を表1に示す．表1における因子負荷量とは，主成分分析で得られた主成分と各形容詞との相関係数を表している．したがって，因子負荷量の絶対値が大きい形容詞ほど各主成分に対して影響を与えていることになる．そして正負の符号違いは，相関を与える効果が反対であることを

表 1 主成分分析結果
Results in principal component analysis.

	変数名	因子負荷量	変数名	因子負荷量	寄与率
第1主成分	こせついた目	0.76	瞳のはっきりした目	-0.92	31.2%
	暗い目	0.74	瞳が大きい目	-0.90	
	陰湿な目	0.74	ぱっちり目	-0.90	
	小さい目	0.66	大きい目	-0.86	
	卑しそうな目	0.60	きらめく目	-0.82	
	淫らな目	0.54	どんぐり目	-0.80	
			丸目	-0.77	
			大目玉	-0.77	
			みずみずしい目	-0.74	
			ぎょろぎょろした目	-0.62	
			すがすがしい目	-0.60	
			二重まぶた	-0.60	
			優しい目	-0.58	
			和やかな目	-0.58	
			無邪気な目	-0.53	
第2主成分	上がり目	0.72	下がり目	-0.81	15.2%
	吊り目	0.68	垂れ目	-0.78	
	鋭い目	0.64	とろんとした目	-0.78	
	狼のような目	0.59	たるんでる目	-0.66	
			上まぶたのゆるんだ目	-0.60	
			虚ろな目	-0.55	
			和やかな目	-0.53	
第3主成分	ぎょろぎょろした目	0.59			8.8%
	出目	0.53			

意味する．

また，各主成分 $PV_n(n=1, 2, 3)$ は以下のように表される．

$$PV_n = \sum_{i=1}^{45} C_{ni} \cdot sc_i \quad (1)$$

ここで， C_{ni} は第 n 主成分と i 番目の形容詞との相関係数を，そして sc_i は i 番目の形容詞に対する評点を表す．

本主観評価実験での主成分分析の結果，表1に示すように3種類の有意な主成分 $PV_n(n=1, 2, 3)$ が求められた．

[第1主成分 PV_1] “ぱっちりした目”，“どんぐり目”といったような目の大きさ・丸さを表す要素が多く，またこれらは“すがすがしい目”，“陰湿な目”といった目に対する“好感度”を表すものと強く関係があると考えられる．また，目の周囲部の状態を表す“二重瞼”と目の全体の状態を表す“目の大きさ・丸さ”が同時に表されていることから，両者が強く関わって

いることが示唆される。

[第2主成分 PV_2] “吊り目”に代表されるように目の“鋭さの度合い”を表していると考えられる。

[第3主成分 PV_3] “ぎょろぎょろ目”, “出目”に代表されるように目の“迫力度合い”を表していると考えられる。

また, 上記3主成分を比較すると, 第1主成分の寄与率が他の2成分に比べて2倍以上大きく, 好感度が目に対する形態印象に強い影響を与えていることがわかる。一方で, 主成分分析によって得られた各主成分の寄与率があまり大きな値でないことから, 人間は言葉では表現できないような特徴で目の形態を分類していると考えられる。

また, これら3つの主成分による累積寄与率は55%であった。ここで, 分類を行う立場から累積寄与率の大きさの意味を考える。例えば, 100人の目の形態を最も厳密に分類する場合を例に挙げる。この場合, 当然個々の目の形態は異なるので, 100種類に分けられることになる。すなわち, 最も厳密な分類とは, まさに個人識別を意味することになる。そして, そのためには100人の目の形態特徴を完全に表現する必要がある。目の形態特徴を表している主成分の累積寄与率は100%であることが要求される。しかし, 100人の目の形態を10種類程度に分類したい場合などは, 各主成分を用いて目の形態特徴を完全に表現する必要はない。特に, 膨大な目のデータを数種類のカテゴリーに絞り込めば良い場合などにおいては, 必ずしも極めて高い累積寄与率が必要にはならない。ここで, 本実験で得られた3つの主成分の累積寄与率が55%であることを考えてみる。これは, “100種類の目の形態を約55種類に分けられる程度に3つの主成分が目の形態特徴を表現している”ことを意味している。したがって, 先に述べた見地からすれば, 分類に用いるには充分適用可能である。また, 前章で提案した顔分類方法のように, 鼻, 口などの他の顔部品や目元, 口元などの顔部分の分類結果と合わせることで, 顔全体の形態を分類する能力が高まる可能性も考えられる。

以上の結果に基づき, 主成分分析が得られた上位3つまでの主成分を, 目の形態分類を行う際に人間が着目する特徴量, すなわち形態分類量であるとして扱うこととする。

3. ニューラルネットによる目の形態分類

本章では, 目の物理的特徴量を入力とし, 人間の主観評価量より得られる形態分類量を出力するようなニューラルネットの構築を行った⁶⁾。

3.1 目の形態分類ニューラルネットの構築

(1) 入力要素となる物理的特徴量の抽出

顔画像データから顔の特徴量を画像処理により自動抽出する手法は確立されていない。そこで本実験では, 目の形態を画像上で近似的に再構成するのに最低限必要とされる18種類の物理的特徴量 Fe_m を用いることとする(図2)。そして, これらの物理的特徴量 Fe_m は, 図2に示す目の特徴点をマニュアルで顔画像から抽出し, その特徴点に基づいて算出した。なお, 目の特徴点のマニュアルによる採取方法は以下のように行った。

- ① 512 pixel×480 pixelの画像中にある顔の目元部分を5倍に拡大。
- ② 1つの特徴点に対して, マウス操作により指定した点の座標を3回抽出。
- ③ そこで得られた3つの座標の平均点を特徴点として抽出。

また, 特徴点は以下に示す定義に基づいて採取した。

- P_0 : 目頭の点
- P_1 : 上まぶたと黒目が鼻側で交差する点
- P_2 : 上まぶたの最高点
- P_3 : 上まぶたと黒目が耳側で交差する点
- P_4 : 目尻の点
- P_5 : 目のしわの端点

図2 目の特徴点
Eye's feature points and physical features.

- P_6 : P_4 , P_7 と合わせた3点で曲率計算が可能となる下まぶたの点
 P_7 : 下まぶたと黒目が耳側で交差する点
 P_8 : 下まぶたの最低点
 P_9 : 下まぶたと黒目が鼻側で交差する点
 P_{10} : P_9 , P_0 と合わせた3点で曲率計算が可能となる下まぶたの点
 P_{11} : 黒目上にあり最も鼻側にある点
 P_{13} : 黒目上にあり最も耳側にある点
 P_M : P_{11} と P_{12} の中点
 P_H : P_0 と P_{11} の中点
 P_T : P_{12} と P_4 の中点
 Q_0 : 左目の目頭
 Q_1 : 左目の目尻を耳側の水平方向に延長し、顔の輪郭と交差する点
 Q_2 : 左目の目尻
 Q_3 : 右目の目尻を耳側の水平方向に延長し、顔の輪郭と交差する点

[A] 目の線画表現に対応する物理的特徴量

- Fe_1 : 目の長さ $\frac{|P_0P_4|}{|Q_2Q_1|}$
 Fe_2 : 目の幅 $\frac{|P_2P_8|}{|Q_3Q_1|}$
 Fe_3 : 目の縦横比 Fe_1 と Fe_2 の比
 Fe_4 : 目全体の面積 P_0 , P_2 , P_4 , P_8 で囲まれる閉曲線内の画素数
 Fe_5 : 黒目の面積 P_2 , P_{12} , P_8 , P_{11} で囲まれる閉曲線内の画素数
 Fe_6 : 黒目と白目の面積比 Fe_4 と Fe_5 の比
 Fe_7 : 目の傾き $\cos^{-1}\left(\frac{P_0P_4 \cdot Q_0Q_2}{|P_0P_4||Q_0Q_2|}\right)/\pi$
 Fe_8 : 黒目の位置 $\frac{|P_MP_0|}{|Q_3Q_1|}$
 Fe_9 : 目尻の傾き $\cos^{-1}\left(\frac{P_4P_5 \cdot Q_0P_0}{|P_4P_5||Q_0P_0|}\right)/\pi$
 Fe_{10} : 目尻の長さ $\frac{|P_4P_5|}{|Q_3Q_1|}$
 Fe_{11} : 上左目蓋の曲率 P_0 , P_1 , P_2 でできる曲率半径
 Fe_{12} : 上右目蓋の曲率 P_2 , P_3 , P_4 でできる曲率半径
 Fe_{13} : 下目蓋の曲率 P_4 , P_8 , P_0 でできる曲率半径

[B] 目の濃淡表現に対応する物理的特徴量

- Fe_{14} : 黒目の平均濃度 P_M の近傍濃度の平均
 Fe_{15} : 白目の平均濃度 P_H , P_T 各々の近傍濃度の平均

Fe_{16} : 上目蓋の平均濃度 P_0 , P_1 , P_2 , P_3 , P_4 各々の近傍濃度の平均

Fe_{17} : 下目蓋の平均濃度 P_4 , P_6 , P_8 , P_{10} , P_0 各々の近傍濃度の平均

Fe_{18} : 黒目と白目の平均濃度比 Fe_{14} と Fe_{15} の比
 なお、物理的特徴量は次の通り規格化して用いた。

・顔全体の大きさの影響を加味し、長さはすべて顔幅で規格化。

・面積は上記で定義した領域の面積で規格化。

・傾きの角度はすべて π で規格化。

曲率、濃度とも各々の中で、最大のものを0.9、最小のものを0.1として規格化。

(2) ニューラルネットの構成

3層のニューラルネットを以下のように構成し、学習則にはバックプロパゲーション⁷⁾を用いた(図3)。

入力層	$Fe_m(m=1, 2, \dots, 18)$ 物理的特徴量 18個
中間層	H_u 中間ユニット 1~20個
出力層	$PV_n(n=1, 2, 3)$ 形態分類量(主成分得点) 3主成分
学習ステップ	$\alpha=0.4$
慣性係数	$\eta=0.9$
データ数	学習データ D_L 20~105個, 未学習データ D_u 20個
収束条件	100回ごとにデータ1個当たりの二乗誤差の平方根を算出し、その値の変化量が閾値 $Th(Th=0.005)$ 以下になったら収束したものとする。(収束判定のための閾値 Th は、主成分値の有効桁が小数点以下2桁であるため上記の値に設定した)

そして、ここでの学習データ、未学習データの選別は、ウォード法⁴⁾を用いたクラスター分析の結果に基づいており、母集団の性質をよく表すものを学習データとして用いた。

(3) 最適なニューラルネット構成を測るための尺度

今回、構成したニューラルネットは、出力誤差が少ないことはもちろんのこと、学習データに特化しない汎化性を有すること、すなわち、学習データ、未学習データに対する誤差の差も少ないことも望まれる。これは、あらゆる種類の目のデータを採取することは困難であるし、また、目の形態に関する主観評価量を膨大な数だけ得ることも難しいからである。そこで、出力誤差も少なく、未学習データにも対応できる汎化能力を有していることを測る尺度として、以下に示す総

図 3 目の形態分類ニューラルネットの構成
Neural network for classifying eye's shape.

合誤差量 TC を定義する.

$$TC = \sqrt{(E_u - E_l)^2 + (E_u + E_l)^2} \quad (2)$$

$$(\quad = \sqrt{2(E_u^2 + E_l^2)})$$

なお, E_l は学習データに対する誤差を, そして E_u は未学習データに対する誤差を表す.

(2)式の第1項は学習データと未学習データとの誤差の差分を表し, 第2項は学習データと未学習データの誤差の和を表している. したがって, 最適なニューラルネットであるためには, 両項とも小さいこと, すなわち総合誤差量 TC が小さくなる必要がある. 以後の実験においては, この総合誤差量 TC を最適なニューラルネットを測る尺度として用いることとする.

(4) 最適な中間ユニット数の決定

実験内容: 入力に物理的特徴量 F_{em} 18 個, 出力に形態分類量 PV_n 3 個を用いた場合について, 最適な中間ユニット数を決定する. 実際に, 中間ユニット H_u の数を 2, 5, 10, 20 個と変えて学習させ検討を行った.

実験結果と考察: どの場合も約 2000 回までの学習で収束条件を満たし, 物理的特徴量 F_{em} と形態分類量 PV_n との対応付けができた(なお, 学習回数は, 学習データを一通り学習して 1 回とする). 図 4 より, 中間ユニット H_u の数が 8 個の時, 総合誤差量 $TC = 0.253$ となり, 最小になる. しかし, 中間ユニット H_u が 2 個の時の総合誤差量 $TC = 0.258$ とほとんど差がない. 中間ユニット数が少ないほど低い計算コストですむことを考えて, 中間ユニット数が 2 個の場合を選ぶこととする. これより, “入力ユニット数 18 個,

図 4 中間ユニット数を変化させた場合の総合誤差量
Total errors in case of varying number of hidden units.

中間ユニット数 2 個, 出力ユニット数 3 個”の構成でこれ以降の検討を進めることにする.

3.2 目の形態分類ニューラルネットの汎化能力の検討

ニューラルネットで汎化性を持った分類を行うためには, やはり対象の性質をよく表す学習データの数が多く必要になる. 本実験では, 約 80 個(本ネットのリンク総数の約 2 倍の数)の学習データ D_l を選ぶことで充分学習を行うことができた. しかし, 本研究で教師信号として用いた形態分類量は主観評価量であり, 統計的に信頼できるものを大量に得ることが難しいものである. また, データがあまり多く得られない場合には, データの母集団の性質を表すような学習データを選んでも, 汎化性を備えた分類を学習することは難

しい。したがって、学習データ数が沢山取れない場合に汎性を向上させるために何らかの工夫が必要となる。そのための手法として、今回は k 近傍内挿学習法⁹⁾を取り上げることとした。

(1) k 近傍内挿学習法 (k NIT 法) を用いた学習

従来の BP 学習法は、点から点への写像を学習する。すなわち、各サンプルデータ間の途中の点における写像がどうなるか全く保証がない。この問題を改善するために、各サンプル点と k 個の近傍点を結ぶ k 本の線分について近傍内挿学習を行う k 近傍内挿学習法が提案されている⁹⁾。この学習則は、網構造から網構造への写像を学習させる。このため過学習がおこりにくい。

また、実際に k NIT 法を用いることによる従来の一般化 δ ルールとの相違点は

$$\delta = -\frac{\partial E}{\partial o_j} o_j (1 - o_j) \quad (3)$$

における $\frac{\partial E}{\partial o_j}$ が

$$\frac{\partial E}{\partial o_j} = -(s_{0j} - b_{0j}) + \left(s'_{1j} - \frac{\partial f}{\partial a} (a_{0j}) a'_{1j} \right) \quad (4)$$

となり、従来法と比べて (4) 式における右辺第 2 項分が加わるだけである。ここで

$$a'_{1j} = \lambda (a_{1j} - a_{0j})$$

$$s'_{1j} = \lambda (s_{1j} - s_{0j})$$

である。ここで、 a_{0j} , a_{1j} は入力空間内の a_0 , a_1 の、 b_{0j} , b_{1j} は出力空間内の点 b_0 , b_1 の各々第 j 成分を表し、 s_{0j} , s_{1j} は、 b_0 , b_1 の各々に対する教師信号 s_0 , s_1 の第 j 成分を表す。また、 E は誤差関数、 o_j は素子 j の出力 (したがって、ここでは b_j と等価)、さらに $f(\cdot)$ は入出力関数、そして λ は直線パラメータである。

従来の NN 学習法

点から点への写像を学習

k -近傍内挿学習

網構造から網構造への写像を学習

図 5 k 近傍内挿学習法 の概念

The conception of k -neighborhood interpolation training.

一方、近傍選択距離尺度 d_{total} は

$$d_{total} = (1-w)d_{in} + wd_{out} \quad (5)$$

で定義され、あるサンプル点の近傍として d_{total} が小さいものから k 個だけ選択される。ここで、 w は近傍の選択において教師信号をどのくらい反映させるかの比重を表し、 d_{in} は入力空間におけるデータ点間距離を、 d_{out} は出力空間におけるデータ点間距離を表す。しかし、学習データが密にない場合、この選択方法を用いると、かなり異なるデータを近傍とする可能性がある。そこで今回では近傍を選ぶ尺度を、近いものから選ぶといった相対的基準ではなく、絶対的尺度 (近傍選択距離尺度の閾値 $d_{threshold}$ 以下のデータを近傍とするといったもの) を用いて行った。

実験内容: 学習データ D_L 20 個に対して、 k NIT 法を用いて学習させ、学習データ D_L 105 個で学習させた場合のニューラルネットに、どの程度近づけることができるかを調べる。

また、近傍選択距離尺度 d_{total} が閾値 $d_{threshold}$ 以下となる場合の点を近傍として選択した。なお、 $d_{threshold}$ は 0.05, 0.10, 0.15, 0.20, 0.30 に、近傍選択において教師信号を反映させる比重 w を 0.2, 0.5, 0.8 と変えて行った。

実験結果と考察: 図 6 より、 $d_{threshold} = 0.15$, $w = 0.5$ の場合が総合誤差量 $TC = 0.286$ で最小となった。これ以外の値の時ではあまり有効な結果が得られなかった。これは、学習データ数が少ない場合、近傍として選ぶ基準を適切に決めないと、本来、近傍とは成り得ない点まで近傍にしてしまう危険があることを示している。したがって、今回のようなケースでは、各サンプル点ごとに近いもの順に個数分の近傍点を選ぶとい

図 6 k NIT 法を用いた場合の総合誤差量
Total errors in case of k NIT method.

図7 各手法を用いた場合の総合誤差量
Total errors in case of some method.

った相対的な基準ではなく、絶対的な基準を設けて、それを満たすものを近傍点として選んだ方が有効であることを確認した。

また、比較のため、目の物理的特徴量 Fe_m と形態分類量 PV_n との対応づけを、同じ条件（学習データ D_L が20個）で重回帰分析を用いて、目の形態分類を行った。図7より、 k NIT法を用いて学習させた ($d_{threshold}=0.15, w=0.5$) 場合が、今回試した方法の中で最も汎化能力を有したもの、すなわち、105個の学習データを用いて学習させたニューラルネットに最も近い分類を行うものとなった。

4. む す び

人間の主観評価を加味した目の形態分類モジュールの検討を行った。実際に、主観評価実験で得られた形態分類量を教師信号、そして、目の形状に関する物理的特徴量を入力とする、目の形態分類ニューラルネットの構築を行うことができた。また、従来の手法では対応が難しかった未登録データ（未学習データ）に対しても、絶対基準に基づいて近傍点を選択する k 近傍内挿学習法を用いることで、重回帰分析を用いた手法に比べて汎化能力を有する目の形態分類を実現することができた。

今回、物理的特徴量を算出する際に用いた特徴点は、マニュアルにより採取した。一般にこのような特徴点は、端点や複数のエッジが交わった交差点である場合が多い。今後は、一撃的交差形状解析法¹⁰⁾を利用するなどして、顔の特徴点抽出の自動化についても検討していく。また、目以外の鼻、口といった顔部品の形態を分類するモジュールについても検討を行い、

最終的には人間の主観評価を加味した顔全体の形態分類システムについても検討をしていく。

本研究の機会を与えて下さった元 NTT ヒューマンインタフェース研究所視覚情報研究部 小林幸雄部長（現千葉工業大学教授）に感謝致します。また、本論文をまとめるに際し、日頃から御指導頂いている NTT 基礎研究所情報科学部 石井健一郎部長、NTT ヒューマンインタフェース研究所第六プロジェクト 伴野明リーダーに感謝致します。

【参 考 文 献】

- 萩原, 増田: “パターンマッチングを主体にした顔画像による個人ID”, 信学技報 PRU, 88-46, pp. 53-60 (1988)
- 磯, 大塚, 小杉: “目の特徴表現に関する心理要因の検討”, 信学春季全大, D-543 (1990)
- 南: “顔の識別技術”, 計測と制御, 25, 8, pp. 707-713 (1987)
- 柳井, 高木: “多変量解析ハンドブック, 現代数学社 (1988)
- 小笠原: 人相・手相・姓名判断, 新星出版 (1984)
- 磯, 崎田, 小杉: “ニューラルネットを用いた目の形状分類に関する検討”, 信学秋季全大, D-406 (1990)
- J. L. McClelland, D. E. Rumelhart, et al: “Parallel Distributed Processing”, Volume 1, 2, The MIT Press (1986)
- 立石, 山崎: “手書き数字認識における階層型ニューラルネットワークの中間層に関する考察”, 情処学論, 30, 10, pp. 1281-1288 (1989)
- 川端: “ k -近傍内挿学習による音韻認識”, 音響学講演論誌, 2-P-21 (1990)
- 磯俊樹, 志沢雅彦: “局所微分情報に基づく交差形状解析—低次微分フィルタによるL, T, X交差検出”, 信学論, J76-D-II, 12, pp. 2529-2536 (1993)

磯 昭樹 昭和63年、早稲田大学大学院修士課程修了。同年、NTTに入社。以来、同ヒューマンインタフェース研究所、ATR視覚情報機構研究所、ATR人間情報通信研究所にて視覚情報処理の研究に従事。平成6年、NTTヒューマンインタフェース研究所に復帰。

崎田 一貴 昭和50年、横浜国立大学工学部電気工学科卒業。同年、NTTに入社。以来、主に公衆利用形通信端末の開発に従事するが、視覚における形状知覚のモデル化検討にも従事。現在、ヒューマンインタフェース研究所主任研究員。

大塚 作一 昭和53年、金沢大学工学部電子工学科卒業。昭和55年、同大学院修士課程修了。同年、NTTに入社。以来、画像通信、画質評価および視覚情報処理の研究に従事。平成5年より、(株)ATR人間情報通信研究所に出勤中。工学博士。正会員。

小杉 信 昭和45年、東京工業大学大学院修士課程修了。同年、NTTに入社。図形処理・画像処理の研究ならびにファクシミリ通信網等の実用化に従事。平成6年、武蔵工業大学電気電子工学科教授。顔画像や景観画像の研究に従事。正会員。