画像検索と機械学習を組み合わせたビデオ映像認識システム

非会員 堤 富士雄 ((財)電力中央研究所)

正員 中 島 慶 人 ((財)電力中央研究所)

Combined System using Image Retrieval and Machine Learning
for Highly Precise Object Recognition

Tsutsumi Fujio, Non-member, Nakajima Chikahito, Member (CRIEPI)

Video database and object recognition have been treated as separate problems in the past. Recent retrieval applications achieved rapid indexing and robust retrieval capabilities, but the precision of recognizing objects in video images is lower than object recognition using machine learning. In contrast with video retrieval, machine learning needs vast computational training time in advance and cannot handle similarity easily. To solve these problems, we present an image-based video recognition framework combined with video retrieval and object recognition. To develop an effective combination, we evaluated several retrieval methods and the support vector machine(SVM), which is one of the most popular supervised learning techniques. From experimental results, we found that the combination of extended color-pair retrieval and SVM using color location is the most effective pair for high precision and rapid indexing of video recognition system.

キーワード：物体認識，画像検索，機械学習，色ヒストグラム，ビデオデータベース

Keywords: Object Recognition, Image Retrieval, Machine Learning, Color Histogram, Video Database

1. はじめに

ビデオ映像の撮影・記録が容易になったことから、様々な利用シーンで多量のビデオ映像が生成・蓄積されつつある。電気事業をはじめとする設備産業では、ビデオ映像を設備監視、保守、巡視点検などに活用している。これらのビデオ映像がデータベース化されその場で容易に利用できるようになれば、問題の早期発見、迅速な対処に役立つ。

このようなビデオ映像の広範な利用を背景にして、ビデオデータの解析、索引付けおよび検索技術が盛んに開発されている⁽⁴⁾⁽¹⁵⁾⁽¹⁶⁾。そして現在までに映像のシーン分割、迅速な索引付けや類似映像の検索などが提案され効果が示されている。ただし上述したビデオデータベース構築の鍵となる、ビデオ映像中の物体の認識精度は、従来から専門に研究されてきた物体認識技術、特に最近多数提案されている機械学習を用いた手法ほどの精度は達成されていない⁽⁸⁾⁽¹¹⁾。

一方、機械学習による物体認識を利用するには、正確にラベリングされた多数の教師データが必要であり、さらに学習のために多量の計算時間が必要である⁽⁷⁾。これらの利用条件から、ビデオで撮影された新たな対象をその場で認識するといった利用は困難となり、利用範囲が制限されている。

本論文ではこれら二つの技術、画像検索と機械学習を組

み合わせ、互いの欠点を補い合うビデオ認識システムを提案する。

提案システムでは、画像検索技術をデータの登録に用い、登録されたデータがある程度溜まったら、それをもとに機械学習を行い、学習結果に基づいて物体を認識する。画像検索は一般に索引の作成速度が速く、かつ類似検索が容易なため、登録時にユーザに適切な候補をその場で提示できる。そして登録された十分な量のデータがあれば、機械学習を行うことで、高速かつ正確な物体認識が可能となる。

我々は、このシステムを効果的に構成するために、代表的な画像検索手法および、機械学習を用いた物体認識手法を、100個の物体を撮影した総数7200枚の画像ライブラリを使って評価実験した。その結果、色対検索⁽⁵⁾⁽⁶⁾を拡張した画像検索手法と、色配置情報を用いたサポートベクタマシン (Support Vector Machine, SVM)⁽¹⁴⁾による機械学習を組み合わせることで、登録が容易で、登録データの多少に関わらず高精度なビデオ認識システムを構成できることが分かった。

本論文の構成は以下の通りである。まず評価を行った画像検索手法について次章で述べる。実験に用いたクラスタリング手法(機械学習を含む)について3章で述べ、4章で実験の説明および実験結果を述べる。そして実験結果をもとにビデオ認識システムを5章で提案し、開発したプロト

タイプシステムについて同じ章で述べる。

2. ビデオ映像認識のための画像検索技術

〈2・1〉色ヒストグラム 画像検索の分野で提案されている多数の手法の中から、我々は評価対象として色ヒストグラムおよびその拡張手法を用いた。色ヒストグラムは、画像検索や物体認識で標準的に用いられており、画像の回転や平行移動に不変な特徴量である⁽³⁾⁽⁸⁾⁽¹²⁾。

〈2・2〉色パターン検索 色ヒストグラムには多数の拡張された手法がある。今回その中からビデオ映像中の物体認識用に提案され、ビデオ認識システムの構成要素として適切と考えられる「色対による指定物体のフルビデオ検索」⁽⁶⁾(以下、色対検索と呼ぶ)を評価に用いた。

色対検索は、画像中から近傍の画素の組み合わせを取り出して検索に用いる手法であり、背景を含む様々な画像からの物体検索に有効と報告されている。この手法は文献(5)で、色対を集計したヒストグラムを用いた検索手法として整理、拡張されているが、色対の生成方法は文献(6)を引き継いでおり、この生成方法にはいくつかの根拠の薄いパラメータが含まれている。本稿では色対検索を、色パターン(要素数が1以上)のヒストグラムによる検索手法として整理し(色パターン検索と命名)、その上で評価のために二つのバリエーションを提案する。

色パターン検索を、画像からの色パターン生成ルール R と、抽出された色パターンを集計したヒストグラム同士を比較する類似関数 sim の組み合わせと定義する。類似関数については次章で述べる。文献(5)の色パターン生成ルールは、以下のように要約できる。

R1 (ブロック化色対, blocked color-pair): 画像を 30×30 の升目状のブロックに分割する。各ブロックの色ヒストグラムを計算し、縦横斜めに隣接するブロック間での高頻度の色値、およびブロック内の色値を組み合わせ、色対を生成する。

今回、色パターン検索の可能性を調べるために、以下に示す二つの単純な色パターン生成ルールを実験に用いた。

R2 (単純色対, simple color-pair): 画像中の全画素に対して縦横斜めに隣接する画素との組み合わせで色対を生成する。

R3 (L色パターン, L triangle color-pattern): 画像中の全画素 $p_{x,y}$ に対し、以下の四つの色パターンを生成する(図1):

$$(p_{x,y}, p_{x+1,y}, p_{x+1,y+1}), (p_{x+1,y}, p_{x+1,y+1}, p_{x,y+1}), \\ (p_{x+1,y+1}, p_{x,y+1}, p_{x,y}), (p_{x,y+1}, p_{x,y}, p_{x+1,y}).$$

3. クラスタリング

〈3・1〉類似関数と K 最近隣法 色ヒストグラムおよび色パターンヒストグラムの比較に用いる類似関数として、最も代表的なヒストグラム交差 (histogram intersec-

図 1 L 色パターン

Fig. 1. L triangle color-pattern

tion)⁽¹²⁾を実験で使用した。ヒストグラム $h1$ とヒストグラム $h2$ のヒストグラム交差 sim は以下の通りである。

$$sim(h1, h2) = \sum_{k=1}^n \min(h1_k, h2_k) \dots\dots\dots (1)$$

ここで $h1_k$ は $h1$ の k 番目の要素、ヒストグラムの要素数を n とする。

画像検索では類似関数に基づいて、キー画像への類似度で整列された画像リストが生成される。この画像リストから認識対象の物体を判定する方法として、最も古典的かつ有効とされている K 最近隣法⁽¹⁾(K nearest neighbor, K-NN)を用いた。なお実験では、 $K=1, 3$ または 5 とした。ただし登録されている画像枚数が極端に少ない場合に、K-NN は効果的に機能しない。そのため我々は、登録画像のヒストグラムを合算して用いる方法を考案し(合成ヒストグラム法: compound histogram method と命名)、評価に加えた。合成ヒストグラムを用いた場合の、ある画像のヒストグラム h と、物体 O との類似関数 sim を以下に示す。

$$sim(h, O) = \sum_{k=1}^n \min(h_k, \sum_{\forall i \in I(O)} h_{i,k}) \dots\dots\dots (2)$$

ここで $h_{i,k}$ は、物体 O を撮影した画像 i のヒストグラムの k 番目の要素、ヒストグラムの要素数を n 、 $I(O)$ を物体 O を撮影した画像の集合とする。

〈3・2〉サポートベクタマシン 評価に用いる機械学習手法として、統計的学習理論の中で明確に定義され、文字認識や物体認識などの応用で高認識率を達成している SVM⁽¹⁴⁾を採用した。

SVM は、二つのクラスから成る訓練データに対して、クラス間のマージン(境界面間の距離)が最大となるような超平面を求める学習法である。線形 SVM⁽¹¹⁾⁽¹⁴⁾(Linear SVM)の場合は、超平面として $w \cdot x + b$ を決定する。ここで w は重みベクタ、 x は特徴ベクタ、 b はある定数である。この場合のマージンは $2/\|w\|$ となる。この考えは非線形 SVM に拡張されている。

SVM を用いて多クラス (multi-class) の分類を行う方法として、最近提案された決定木を用いる多クラス分類戦略⁽¹⁰⁾を用いた。図2は、4 クラス (A, B, C, D) の分類問題を扱う決定木を表す。それぞれのノードはクラスの対を分類する SVM を表している。分類対象の入力データは決定木のトップノード (A/D) から決定木に沿って評価される。

SVM で用いる特徴ベクタとして我々は色ヒストグラム

図 2 多クラス分類戦略
Fig. 2. Strategy of multi-class classifiers

図 3 COIL 画像のサンプル
Fig. 3. Sample of COIL images

と、色配置情報を用いた。色配置情報とは、画像中の画素の値を位置とともにそのままベクタの要素とするものである。色ヒストグラムを用いた SVM による手法は文献 (3) (8) に、また色配置情報 (グレースケール) を用いた SVM による手法は文献 (11) で提案されている。なお特徴ベクタの次元数は機械学習における重要なパラメータである。本実験では、色ヒストグラムを用いる場合は次章で述べるように 125 次元に固定し、色配置情報の場合には $m \times m$ 次元 (画像サイズが $m \times m$ 画素の場合) とした。なお色配置情報の SVM は実験環境の制限から最大 32×32 画素の画像までを用いた。

4. 実験

〈4・1〉 実験条件

〈4・1・1〉 実験対象画像 我々は評価実験の対象画像としてコロンビア大学の物体画像ライブラリ (Columbia Object Image Library, COIL) を用いた⁽⁹⁾。COIL は日用品を中心に 100 個の物体の画像を、それぞれ 72 枚づつ、総数 7200 枚で構成され、画像認識の分野でしばしば評価に用いられる画像群である。対象物体はターンテーブル上で 5 度刻みに回転して撮影されており、非対称の物体や表裏がある物体の場合は撮影角度によって見た目が大きく異なっている。図 3 にサンプルを示す。我々は全画像の約 5%, 10%, 20% または 30% を訓練画像とし、残りをテスト画像として用いた。以下、訓練画像の枚数に応じて 5% テストおよび 10% テスト、20% テスト、30% テストと呼ぶことにする。訓練画像とテスト画像の枚数を表 1 にまとめる。

〈4・1・2〉 色空間 これまでに提案されている多数の色空間の中から、最も基本的であり、我々の予備実験 (RGB, HSV, 正規化 rg を比較) から最も効果的であった RGB を採用した。また色空間の量子化数を決めるために、我々は RGB

表 1 訓練画像とテスト画像の枚数

Table 1. Number of training images and test images

Name of test	5% test	10% test	20% test	30% test
number of training images	400	800	1500	2200
number of test images	6800	6400	5700	5000
training images per object	4	8	15	22
test images per object	68	64	57	50

表 2 各手法の略称

Table 2. Abbreviations of methods

Abbreviation	Explanation
hist-1NN	1 nearest neighbor for single color histogram
cp-comp	compound histogram of simple color-pair
cp-1NN	1 nearest neighbor for simple color-pair
cp-30	1 nearest neighbor for blocked color-pair
L-comp	compound histogram of L triangle color-pattern
L-1NN	1 nearest neighbor for L triangle color-pattern
hist-SVM	Linear SVM using color histogram
loc-SVM	Linear SVM using color location

各チャンネルの量子化数を 3 から 10 まで段階的に変えて予備実験を行った。その結果、量子化数が 3 から 5 までは大きく変化するが、量子化数 5 と 10 の認識率の間は 1% 程度の差であったため、今回は量子化数を 5、つまり色空間全体の量子化数を $5^3 = 125$ に固定して実験を行った。

〈4・1・3〉 画像サイズ 処理時間および認識率は、用いる画像のサイズに影響を受ける。実験では COIL 画像のオリジナルのサイズ (128×128 画素) と、それを平均化により縮小した画像 (8×8 , 16×16 , 32×32 , 64×64 画素) を用いた。

〈4・2〉 実験結果 図 4~7 に、5% テストから 30% テストまでの結果をそれぞれ示す。Y 軸は全テスト画像での認識率を、X 軸は画像のサイズを表す。表 2 に図 4~7 で用いた略称をまとめる。

5% テストでは、図 4 に示すように、L 色パターンを合成ヒストグラムとともに用いた手法 (L-comp) が最も高い認識率であった。特に小さなサイズの画像での結果が他より良いのが特徴的である。また単純色対を合成ヒストグラムとともに用いた手法 (cp-comp) も比較的高い認識率を達成した。ただしブロック化色対を用いる手法 (cp-30) は、この実験では良い結果を示さなかった。なおブロック化色対は 30×30 ブロックへの分割が前提なので、縦横 64 画素と 128 画素の画像でのみ実験した。

10% テスト (図 5) では、L 色パターンと合成ヒストグラムによる手法 (L-comp)、色配置情報での SVM (loc-SVM)、L 色パターンと K-NN による手法 (L-1NN) の 3 手法は 95% 以上を達成した。

20% テスト (図 6) では、さらに認識率が向上し、多数の手法が 95% 以上を達成している。ここでは色配置情報での SVM (loc-SVM) が、画像サイズが縦横 32 画素の場合に 99.3% を達成し最も認識率が高かった。SVM 以外では L 色パターンを用いた K-NN (L-1NN)、および L 色パターンを用いた合成ヒストグラム (L-comp) がいずれも 98.4% を

図 4 5%テストでの認識率
Fig. 4. Recognition rate in 5% test

図 5 10%テストでの認識率
Fig. 5. Recognition rate in 10% test

達成し、最も認識率が高かった。また合成ヒストグラムを用いる手法では、画像のサイズが大きくなるとサイズが小さい場合よりも認識率が下がった。認識率が90%に及ばなかった手法の結果は省略している。

30%テスト(図7)では、いくつかの手法が98%以上の認識率であった。中でも色配置情報を用いたSVMは、ただか縦横16画素の画像を使って、99.84%の認識率を達成した(テスト画像5000枚中、8枚のみを誤認識)。SVM以外ではL色パターンを用いたK-NN(L-1NN)が最も高い認識率(99.1%)を示した。また合成ヒストグラムを用いたL色パターン(L-comp)は、20%テストの場合よりも、認識率が最大で0.9%下がった。認識率が95%を越えなかった手法の結果は示していない。

本実験では、 $K=3$ および5でのK-NNを使ったすべての結果は、 $K=1$ の場合の結果に及ばなかった。また多項式カーネル(2次)を使ったSVM(Polynomial SVM)での

図 6 20%テストでの認識率
Fig. 6. Recognition rate in 20% test

図 7 30%テストでの認識率
Fig. 7. Recognition rate in 30% test

結果は線形SVMでの結果とほぼ同じであったため、線形SVMの結果のみを示している。

R-trees⁽²⁾などの一般的な多次元索引を用いた場合、索引付けの速度は、画像から取り出して比較に用いる特徴量数に依存する。色ヒストグラムでは125に固定だが、色パターン検索では画素の組み合わせを用いるので、画像サイズによって変化する。例えば縦横16画素の画像から原理的に生成される単純色対の数は最大で1860個、L色パターンは最大で2700個になる。ただし多くのパターンが重複しているので、実際に生成される数は少ない。2200枚、縦横16画素のCOIL画像から、単純色対の場合で平均87個(標準偏差29)、L色パターンの場合で平均217個(標準偏差67)の色パターンが生成された。

〈4・3〉実験結果の考察 全体として色ヒストグラムよりも、色パターン検索や色配置情報でのSVMなど、なんらかの配置情報を用いる方が効果的であった。ただしSVMにおいて、色配置情報を用いた結果が色ヒストグラムでの

図 8 登録が容易で高精度なビデオ認識システム
Fig.8. Rapid indexing and highly precise video recognition system

結果をすべて上回ったのに対し、色パターン検索の場合は組み合わせ方によって結果が分かれた。

まずブロック化色対を用いた手法は、単純色対に比べて良い結果を示さなかった。ブロック化色対では、ブロック内の画素間の距離を捨象し、ブロック内の色対もブロック間の色対も区別せずに照合に用いる。そのため物体の形状的特徴に相当する全体的な色対と、テクスチャの特徴に相当する細かな色対を同じレベルで比較することになる。それに対し単純色対では、同じ解像度の画像から得られた色対同士を比較する。この違いが原因ではないかと考えられる。

次に単純色対よりも L 色パターンの方が全体として良い結果を示した。そのため COIL 画像の認識では、画素間の配置を重視する方が効果的であったと言える。ただしクラスタリング法として K-NN を用いた場合の差は小さく、合成ヒストグラムを用いた場合は大きな差となった。これについて一つの仮説を以下に提示する。

色空間を 125 次元に固定したので、単純色対は 125^2 の組み合わせの可能性を持ち、L 色パターンは 125^3 の可能性を持つ。前節で述べたように、一枚の画像から平均して取り出される色パターン数に大差がないので、L 色パターンはその可能性の空間の中で疎に分布し、色対は比較的密に分布することになる。合成ヒストグラムは、各画像の情報を捨象して、全体を色パターンの集まりとして扱うものである。そのため密に分布したものを合成すると各画像の特徴が失われることになり、疎に分布している場合は各画像の特徴を保存した上で、照合の可能性を増やす効果があると考えられる。合成ヒストグラムを用いた手法が、大きなサイズの画像や、訓練画像枚数が多い場合に、認識率が上がらない現象は、この仮説を裏付けている。

5. 画像検索と機械学習の組み合わせによるビデオ認識システム

〈5・1〉 組み合わせ方法 本章では実験結果に基づいて、登録が容易で、登録データの多少に関わらず高精度なビデオ認識システムを提案する。

提案するシステムの構成を図 8 に示す。説明のために 3

図 9 登録インターフェース
Fig.9. Registration interface of prototype

つの利用ステージ (登録ステージ、学習ステージ、認識ステージ) を設定し、以下ステージ毎に述べる。

まず登録ステージでは、新しいビデオ映像がビデオカメラから入力され、検索エンジンによって索引付けられると同時に、類似候補が検索されユーザに提示される。利用者は適切な候補が提示されるので、インタラクティブに新しいデータを登録することができる。このステージで重要なのは迅速な索引付けと検索である。また、この登録ステージで入力されるビデオ映像は各々断片的で、登録対象の全体をカバーすることは難しい。

実験では、L 色パターンを合成ヒストグラムとともに用いた手法 (L-comp) と、同じく L 色パターンを K-NN とともに用いた手法 (L-1NN) が、画像検索として最も高い認識率を達成した。我々は、断片的な映像を効果的に扱えるという理由から、少量の訓練画像に対しても効果的であった L 色パターンと合成ヒストグラムによる手法を、このステージに採用した。

学習ステージでは、システムは登録されたデータを自動的に学習する。学習後にシステムは認識ステージでビデオ映像を高速かつ高精度に認識する。登録ステージでシステムが効果的に機能することを前提にすれば、学習ステージでは十分な量のラベリングされた登録データがあることになる。したがってここで重要なのは認識ステージでいかに高精度の認識を実現できるかであり、実験で多量の訓練画像に対して最も高精度であった色配置情報を用いる SVM を、学習 認識ステージに採用した。

〈5・2〉 プロトタイプシステム sgi Octane ワークステーション (dual R10000/250MHz) 上に、プロトタイプシステムを開発した。COIL 画像に対してこのシステム上で実際に索引付けを行った場合の、平均索引作成速度は、1 枚あたり 94 ミリ秒であった (L 色パターン、縦横 16 画素の画像、2200 枚)。また同じ 2200 枚の画像に対して、SVM の学習速度は 31 分であり (色配置情報利用、100 クラス)、学習後の認識速度は 1 枚あたり 24 ミリ秒であった。

図 10 認識インタフェース
Fig. 10. Recognition interface of prototype

図 9 にプロトタイプシステムでの登録インタフェース、図 10 に認識インタフェースを示す。本システムでは、文献(13)のシーンカット技術を用いて、ビデオカメラの映像を、カメラの動きやカメラ視野内への侵入物を検知して、シーンに分割する(図 9 中段が分割されたシーン履歴)。分割された画像群はその場で索引付けられ、同時に類似シーンが検索される(図 9 下段が上位 3 位の検索結果)。プロトタイプシステムはこれらの処理を平均 8 フレーム毎秒で実行できる。ユーザの作業は、新規の認識対象へのプロファイル入力と、示される類似候補が不適切であった場合のインタフェース操作である。登録されたデータは SVM によって学習され、学習後には認識エンジンがビデオレートでの認識を行い、関連情報を画面に表示する。図 10 はバルブを認識し、左下に名称を表示した様子を示している。

6. む す び

本論文では新しいデータの登録が容易で高精度なビデオ認識システムを提案した。100 個の物体に関する総数 7200 枚の画像ライブラリを用いた評価実験の結果、新規登録時などデータベースへの登録画像数が少ない場合に、色対検索を拡張した手法を使い、登録画像数が多くなった場合に色配置情報を用いた SVM を使うことで、登録画像数の多少に関わらず高精度な認識システムが構成できることがわかった。実用的な環境でのシステム評価が今後の課題である。

(平成 13 年 1 月 25 日受付)

文 献

- (1) 画像処理ハンドブック編集委員会編:「画像処理ハンドブック」, 昭見堂 (1987)
- (2) A. Guttman: "R-trees: A dynamic index structure for spatial searching," *Proc. of ACM SIGMOD*, pp. 47-57 (1984)
- (3) P. Haffner O. Chapell and V. N. Vapnik: "Support vector machines for histogram-based image classification," *IEEE Transactions on Neural Networks*, vol. 10, no. 5, pp. 1055-1064 (1999)
- (4) R. Leienhart, S. Pfeiffer, and W. Effelsberg: "Video Abstracting," *Communications of the ACM, Decemer*, Vol. 40, No.12, pp.55-62 (1997).
- (5) Swee-Kiew Lim, Tat-Seng Chua and Hung-Keng Pung: "Content-based retrieval of segmented images," *Proc. of*

- ACM Multimedia 94*, pp. 211-218 (1994)
- (6) 長坂 見朗, 田中 謙:「カラービデオ映像における自動索引付け法と物体探索法」, 情処学論, Vol.33, No.4, (1992)
- (7) 永田 昌明, 平 博順:「テキスト分類—学習理論の「見本市」—」, 情報処理, Vol. 42, No. 1, pp. 32-37 (2001)
- (8) C. Nakajima, M. Pontil, and T. Poggio: "People recognition and pose estimation in image sequences," *Proc. of International Joint Conference on Neural Networks*, vol. 4, pp. 189-194 (2000)
- (9) S. A. Nene, S. K. Nayar, and H. Murase: "Columbia Object Image Library (COIL-100)," Technical Report CUCS-006-96 (1996)
- (10) J. Platt, N. Cristianini, and J. Shawe-Taylor: "Large margin DAGs for multiclass classification," *Advances in Neural Information Processing Systems*, pp. 547-553 (2000)
- (11) M. Pontil and A. Verri: "Support vector machines for 3-d object recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 637-646 (1998)
- (12) M. Swain and D. Ballard: "Color indexing," *International Journal of Computer Vision*, vol. 7, no. 1, pp. 11-32 (1991)
- (13) Fujio Tsutsumi: "Real Time Storage and Simultaneous Retrieval for Surveillance and Patrol Video," *Proc. of IEEE International Conference on Multimedia and Exposition* (2000)
- (14) V. Vapnik: *Statistical learning Theory*, John Wiley & Sons inc. (1998)
- (15) B.-L. Yeo and M. M. Yeung: "Retrieving and Visualizing Video," *Communications of the ACM*, Vol.40, No.12, pp.43-52 (1997-12)
- (16) H. Zhang, C. Y. Low, S. W. Smoliar, and J. Wu: "Video Parsing, Retrieval and Browsing: An Integrated and Content-Based Solution," *Intelligent Multimedia Information Retrieval*, AAAI Press/The MIT Press, pp.139-158 (1997)

堤 富士雄 (非会員) 1988 年 3 月九州大学工学部情報工学科卒業。1990 年 3 月同大学大学院工学研究科情報工学専攻修士課程修了。1990 年 4 月(財)電力中央研究所入所, 現在に至る。主として情報検索システムのユーザインタフェースに関する研究に従事。電子情報通信学会, 人工知能学会, 情報処理学会, 日本ソフトウェア科学会各会員。

中 島 慶 人 (正員) 1989 年 3 月東京電機大学大学院理工学研究科修士課程修了。同年 4 月(財)電力中央研究所入所。1999 年~2000 年 MIT にて画像処理と学習の研究に従事。主として視覚画像処理に関する研究に従事。電子情報通信学会, 人工知能学会, 情報処理学会, IEEE 各会員。