

サーベイ:事例ベースパターン認識、コンピュータビジョン

和田俊和 (和歌山大)

あらまし 本サーベイでは、事例に基づくパターン認識、コンピュータビジョンの研究を、異常検出、識別、非線形写像学習、正則化およびこれらの基礎となる最近傍探索技術、確率密度推定に分け、これまでの歴史を振り返り、近年の研究動向を分析する。

Survey: Example based Pattern Recognition and Computer Vision

Toshikazu Wada (Wakayama University)

Abstract This paper reviews and surveys example based techniques in the fields of Pattern Recognition and Computer Vision, from the viewpoints of abnormality detection, classification, non-linear mapping learning, regularization, and basics: nearest neighbor search and non-parametric probability density estimation.

1. はじめに

近年、ヨーロッパおよび北米での事例ベース処理・推論[1]の考え方に基づくコンピュータビジョンの研究が増えているように見受けられる。代表的なものとしては米CMUにおける事例ベース超解像処理(Hallucination)[37]、イスラエル ワイズマン工科大における irregularity detection[17]、英オックスフォード大学における Video Google[41]など多岐に渡っている。

本稿で述べる事例とは、画像データおよび画像データから特定の方法で特徴抽出を行った結果得られる固定次元ベクトルを指す。また、事例ベースの方法論とは、事例からあらかじめ用意しておいたモデルのパラメータを推定するといった事例の利用法ではなく、事例そのものの、あるいは事例を補間して出来上がる多様体を利用して、入力データに対する処理を行うものを指すと考える。事例そのものを用いるか、それらを補間した多様体を用いるかは別として、その処理としては以下のようものが考えられる。

検出:事例にマッチするものあるいはマッチしないものを検出する問題

識別:入力と複数のクラスに属する事例とを比較して、最も類似したクラスに入力を分類する問題

写像:複数の入力と出力の関係を事例として記憶しておき、未知の入力に対して出力を求める問題

正則化:不良設定問題を解くために必要な正則化項を事例から求め、解を安定化する問題

もちろん、これら以外にも様々な可能性はあるが、本稿ではこれらに限って説明を行なう。また、これらの技術

の中で主要な役割を果たす最近傍探索技術と確率密度推定に関しては第2章基本技術で紹介する。

2. 基本技術

この章では事例ベース処理において最も基本的な最近傍探索技術とノンパラメトリック確率密度推定法について述べ、その本質的な考え方を整理する。

2.1. 最近傍探索法

最近傍探索は、事例に基づく検出、識別、写像学習にとって不可欠な処理であり、理論的に見ても非常に奥深い内容を持っている。特に、高速性を謳う最近傍探索法の殆ど全てが高次元空間において全探索になってしまいういう事実は、その背後に支配定理が存在しうることを示唆しているが、未だこれは明らかにされていない。

最近傍探索法は基本的に、1) 距離計算回数を減らす方法、2) 距離計算過程で現れる和演算を打ち切る方法、の2つの種類に分類できる。但し、識別に用いる場合には、CondensingやEditingを用いることによっても計算が高速化できる。

2.1.1. 距離計算回数の削減

この方法は、入力データ(クエリ)に対して距離を計算する事例の数を減らす方法である。これは、数個の事例との距離を測ることであらかじめ分析しておいた事例間の関係を利用して、最近傍とはなりえない事例を候補から除外する方法である。この事例間の関係としては、事例間の距離をあらかじめ調べておき三角不等式を用いて候補を絞り込む方法(AESA[2], LAESA[3])、入力空間を分割する方法(k-d tree[4], VP-tree[6])、

MVP-tree[7], Gnat[5])などがある。このうち, k-d tree は座標軸に直交する面を持つ直方体で空間を区切るため, 事例との距離計算は行わず, 直方体の面に対して入力がどちら側に存在するかを調べるだけで, 最近傍候補が絞り込めるため, 三角不等式は一切用いられない。これに対し, VP-tree では 2 個以上の Vintage Point を中心とする超球の交わりによって空間を分割し, MVP-tree ではさらに三角不等式を利用して候補の絞込みが行なわれる。Gnat ではいくつかの点を中心とするクラスタリングによって空間を階層的に分割し, これと三角不等式を組み合わせて候補の絞込みが行なわれる。

事例間の距離をあらかじめ計算しておく AESA や LAESA では距離計算の回数は減少するが, 表を走査するための計算時間が膨大となるため, 距離計算回数と探索時間の関係は間に線形にはならない。

木構造を用いる最近傍探索では, 真の最近傍解を見逃す可能性があるため, 1)最近傍になる可能性がある事例について, 木探索の後に再度チェックする, 2)可能性がある解については全て並列に探索を行う, という処理の何れかが必要である。

これらの方法は, 高次元の事例の分布(一様分布であれば, 30 次元程度)に対しては効果が無く, 全ての事例との距離計算を行わなければならなくなるという問題がある。

2.1.2. 距離計算の打ち切り

通常, 最近傍探索に用いられる距離尺度 $d_p(x, y)$ は L_p ノルムを用いて次式のように定義される。

$$d_p(x, y) = \sqrt[p]{D_p(x, y)}, D_p(x, y) = \sum_{i=1}^N |x_i - y_i|^p$$

ただし, x, y は N 次元ベクトルとして表現される事例である。ここで, 最近傍を求めることが目的であるため, 三角不等式を利用しないのであれば, $d_p(x, y)$ ではなく, $D_p(x, y)$ を用いて, この値が最小になる事例を探せばよい。 $D_p(x, y)$ は上式のように非負の値を足し合わせて求めるため, 入力 q について $D_p(x, q)$ の計算を M 次元で打ち切った $\sum_{i=1}^M |x_i - q_i|^p$ の方がすでに求められている暫定的な最近傍候補 x' までの $D_p(x', q)$ よりも大きかった場合, 事例 x は最近傍にはなり得ず, 和の計算は M 次元で打ち切れれば良い。これが距離計算の打ち切りである。

この方法は高次元の空間でもうまく機能するが,

- 1) 小さい $D_p(x', q)$ を早い段階で求めること,
 - 2) $\sum_{i=1}^M |x_i - q_i|^p$ が, 小さな M に対しても, $D_p(x, q)$ の良い近似になるようにすること
- の 2 つが実現できれば高速な最近傍探索が行える。
- 1) の問題を解決した例としては, ANN[8][10][10] が挙げられる。これは, k-d tree の二分探索によって暫定最近傍候補 x' を求め, これを用いて距離計算の打ち切りを行いながら真の最近傍解になりうるものだけを再チェックするという方式である。この手法では, 高次元分布の場合に全事例との距離計算を行わなければならなくなつたとしても, 距離計算の打ち切りが働くため, かなり効率が良い。さらに, こういった方式と 2) の問題を解決するため, 累積寄与率が少ない基底でも大きくなりやすく高速演算が可能な DCT を組み合わせた方法も提案されている。

このように完全な最近傍探索を行うことは計算量の観点から見てみると, 特に高次元分布の場合, かなり効率が悪い処理である。この問題を回避するには, 多少の誤差を許容し, その代わりに計算速度を向上させるというアプローチが採られる。先に述べた ANN は, 二分探索の後に行われる最探索処理をアホックに行うことによって処理の効率を上げている。また, グラフ構造を用いた連続的な最近傍探索において, Delaunay グラフではなく, NFTG という特殊なグラフ構造を用いることによって計算を高速化する方法も提案されている。さらに, 最近では LSH[11][12] と呼ばれるハッシュ関数を用いた高速探索法も提案されている。LSH は記憶された事例集合の近くにクエリが与えられれば, 絶大な効果が得られるが, 事例集合から多少離れた位置にクエリが与えられると, ハッシュ関数がヒットしなくなり, 全探索を行わなければならなくなるという問題点がある。

2.2. 事例を用いた確率密度推定

後述するように, 事例を用いた識別には, 最も近い事例に付けられたクラスラベルに基づいて識別を行う「1-最近傍識別」と, 複数の最近傍事例に基づいて識別を行う「k-最近傍識別」がある。これらは, 一見類似しているようにも見受けられるが, 根本的に全く違った考え方に基づくものである。つまり, 事例間の距離を重視するか, 事例の密度を重視するか, という考え方の違いである。例えば, 1-最近傍識別器や SVM は距離重視の手法であり, k-最近傍識別や Parzen Window[14] を用いた識別は密度重視の識別法である。この状況は, 異常検出において用いられる 1-class SVM[15] でも同様であり, 密度に基づいて異常検出を行うとどのようになるかとい

うことに関する報告[16]も行なわれている。

事例の密度を重視する立場は、確率密度の推定という整備された理論的枠組みと整合するため、多くの研究者の支持を得ているだけでなく、二者択一的な識別や検出の結果ではなく「度合い」が欲しい場合にも確率密度が計算できるため応用範囲は広い。

確率密度分布モデルの当てはめを行わない場合、ノンパラメトリックな密度推定が行なわれる。これは単位体積 V 中の事例の個数 k を計測することによって計算を行う方法である。具体的には、全事例数を n とし、ある領域中に k 個の事例が存在したとすると、その領域中に k/n の確率で事例が含まれることになる。ここで求めたいのは、確率密度であるので、領域の体積でこの確率を除した式 $(k/n)/V$ が確率密度となる。実際には、以下に述べるような方法で点 x の確率密度が推定される。

k -最近傍による確率密度推定[13]

これは、 k を固定し、 V を可変とする密度推定法である。すなわち、点 x に対して k 個の最近傍事例を求め、最遠点を半径とする超球の体積 V から $(k/n)/V$ を求める方法である。これを、多クラスの識別問題に用いる際には、

- 1) 異なるクラス間で体積 V が同じ
- 2) 各クラスで事例数 n が等しい

と仮定することによって、探索された k -最近傍の事例に付けられたクラスラベルの多数決によって確率密度の大小を比較することができる。これが k -最近傍識別の妥当性の根拠であるが、この方法は上述の無理な仮定が入っていることと、 x と各事例との距離を使っていないという 2 点から、識別境界付近での識別精度は高くはないと言える。

Parzen Window を用いた確率密度推定[14]

これは、 V を固定し、 k を可変とする密度推定法である。すなわち、点 x を中心としたウインドウ内で事例を収集し、その個数 k とウインドウの体積 V から $(k/n)/V$ を求める方法である。実際には単位立方体窓や、Gaussian 窓がよく用いられる。Gaussian 窓は体積が 1 であり、窓に応じた重みを各事例にかけて計算を行う方法である。 n 個の全事例を x_i で表すと、確率密度は次式で表される。

$$p(x) = \frac{1}{n} \sum_{i=1}^n g(x - x_i), \text{ 但し } g(x) \text{ は Gaussian.}$$

これは結局事例と窓関数のコンボリューションであり、非常に効率の悪い計算なので、実際のインプリメントでは立方体あるいは球形のウインドウを用いて切り出した事例に対して上式が計算されることが多い。しかし、有限サイズのウインドウを用いる方法では事例の少ない部分で確率密度が 0 になってしまうこともある。このことが問題になるのは、多クラスの識別のために事後確率を計算するときに、事例の少ない部分では計算できないことがある。このような問題点があるものの、Gaussian 窓を用いた Parzen Window は一般には k -最近傍の密度推定よりも優れている。

3. 検出

ここで述べる検出とは、正事例の集合のみを与えて、入力とその集合との距離、あるいは類似度を計測することにより、

- 1) 正事例を検出する、
 - 2) 正事例とは見なせない異常な事例を検出する
- という問題である。

まず、ある事例と事例の集合との距離を求める問題について考えてみる。事例のサンプリングが一律で十分な密度がある場合は、最近傍探索を行えばよいが、そうでない場合には、何らかの方法で内挿計算を行う必要がある。このような例としてパラメトリック固有空間法や、先に述べたノンパラメトリック確率密度推定法を用いる方法がある。

このような検出を用いた研究事例はかなり多い。例えば、背景画像の画素値をヒストグラムとして記憶しておき、許容できる変化から逸脱した部分を異常として検出する手法などは事例ベースの検出と見なすことができる。また、昨年のICCVで発表された Irregularity Detection[17] は、既知の「正常」と見なすことができる画像を小ブロックに断片化して事例として蓄積し、入力画像もまた断片化し、それぞれのブロックについて最近傍探索をする。これによって十分に類似したパターンが見つかった部分は「正常」と見なされ、見つからなかった部分は「異常」と見なされるというものである。これまでにも「異常」をなんとかして定義しようとする試みは数多くあったが、この研究のように非常にシンプルに異常を定義し、それがうまく動くことを示した研究はなかったことが Honorable Mention を獲得した理由として挙げられる。この方法は、データベースに蓄積されるデータを(クエリを除外した)入力画像そのものから作成することで、顕著性

(saliency) マップを作成することができるという拡張もできる。このように、何を基準にして何を検出するかを僅かに変更するだけで得られる結果が全く異なるという点も聴衆の関心を大いに集めた。

最近では、1-Class SVM[15]が提案され、これに対して密度解析の立場からの異常検出法[16]も提案されている。このように統計的手法においても異常検出のための理論的枠組みの整備が進んでいる。この1-Class SVMを提案した Shölkopf は 1-Class SVM の学習が高次元空間での凸包の計算と等価であることを指摘している。このことからも分かるように、正事例を囲む凸包を用いて異常検出を行なうことも不可能ではない。

但し、凸包以外の方法で検出を行なう際には後述する識別問題のように他クラスの汎化圧によって自らの汎化を止めるといったことはできないため、何らかの閾値あるいはパラメータを用いることになる。

4. 識別

パターン認識の初期、Cover と Hart は複数のクラスラベル付き事例の中から入力データに最も近い事例を探し、見つかった最近傍事例に付けられたクラスラベルに基づいて識別を行う 1-最近傍識別器[18]を提案した。この識別器は大量の事例が与えられたとき Bayes 誤り確率の 2 倍未満が達成できるという優れたものであり、多くの研究者の興味を惹いた。その後も

- 少ない事例でも低い誤り確率が達成できる k-最近傍識別器
- 識別に影響を与えない事例を削減する Condensing[19]
- 誤った事例を除去し汎化性能を高める Editing[20]-[25]
- 識別速度の向上

などの研究が続けられたが、速度や消費メモリなどの条件が当時の計算機には適合しておらず、現実の場面ではあまり用いられなかった。この間、主に利用された識別方法は個々のクラスの分布を表現するモデルを事例にあてはめて尤度の大小を比較する「分布あてはめ型」の識別方法であった。

しかし、その後サポートベクターマシン(SVM) や ADA Boosting の登場により、各クラスの分布を推定するのではなく、クラス間の識別境界付近に存在する特殊事例を用いるだけで高精度な識別が行えるという考えが徐々に広まった。これは、最近傍識別器における Condensing や Editing と本質的に同じ考え方である。実際に、Delaunay グラフの部分グラフである Gabriel グ

ラフ[19]を用いて Editing を行なった結果の事例集合と SVM によって求められるサポートベクターがよく一致するということを指摘する研究者もいる。

分布の端に存在する特殊事例によって識別面が決定される最近傍識別器から数十年を経て、同じく分布の端にある事例によってクラスを記述する SVM や ADA Boosting に戻ってきたことは、歴史は巡るということの好例である。

分布あてはめ型の識別器と特殊事例を重視した識別器を比較してみると、いくつかの特性の違いが見えてくる。この中でも、顔と非顔のように、「ある条件を満足するデータ」と「その条件を満足しないデータ」を区別する特殊な 2 クラスの識別問題に、分布推定型の識別器は適さないが、特殊事例重視型の識別器は適している、という事実は特に重要である。本来、このタイプの問題に対しては正事例のみを与えてマッチングに基づく検出を行っていた。しかし、正事例と負事例を対照するクラスとした識別問題とした方が、一方の汎化圧によつても一方の汎化が抑制され、識別境界を細かくコントロールできるため、より精度の高い検出が行える。この問題に分布推定型の識別器が適さない理由は、例えば顔データはある特定の分布に従うかもしれないが、非顔データは顔以外の全てであり、これを単一の分布で表現することはできないためである。

のことからも分かるように、昨今の顔検出ブームと ADA Boosting の登場は無関係ではない。つまり、従来は正事例のみを用いたマッチング問題として定式化していた問題が、正事例と負事例を用いた識別問題として扱えるようになり、その結果高性能化が進んだ背景には、特殊事例重視型識別器の台頭があつたためだと解釈できる。この状況は歩行者検出や背景差分等でも同様である。

また、概念学習という観点から見た場合でも、あるクラスの事例に対して分布をあてはめるという方法でクラス概念が獲得できることには問題がある。例えば、自転車の事例に対して分布の当てはめを行った場合、おそらく自動二輪車は自転車と判断されてしまうであろう。つまり、どこまで汎化を行なえるかは、他のクラスの分布を見なければ分からず、あるクラスから見て正負両方の事例を与えてはじめて正確な概念獲得が行えると考えるべきである。この点から見ても、分布当てはめ型の学習方法よりも特殊事例重視型の方が理にかなっていると判断できる。

5. 写像学習

画像から対象物体のカメラに対する向きを推定するといった計算は、基本的に写像学習の問題としてとらえられる。従来から用いられているモデルベースの方法としては、GMDH[26]やニューラルネットワークなどが挙げられる。一方、純然たる事例ベースの方法としては、

「 k 個の最近傍事例を探索し、それらの事例に直接対応付けられた k 個の出力ベクトルを入力ベクトルに応じて内挿することにより出力ベクトルを得る」という方法がある。本稿ではこれを k -最近傍内挿法と呼ぶことにする。この手法は、特別な学習計算が不要であるため、動的に事例が追加される環境下でも利用することが可能である。一方問題点は大量のメモリを消費することである。

これ以外の方法は、あらかじめ事例を内挿しておき写像を求める以下のような方法である。

- パラメトリック固有空間法[30]: この方法は、固有空間（入力空間）内に出力を表す多様体を埋め込む方法である。先にも述べたが、パラメトリック固有空間法は非線形写像だけでなく、回路の欠陥検査などの対象検出や、対象を任意の方向から撮影した画像から識別を行う対照認識などに用いることができ、幅広い応用範囲を持っている。
- ISOMAP[31], LLE[32], spectral embedding[33]: これらの方法は、高次元パターン空間に低次元多様体を埋め込む手法であり、主にデータの可視化の手法として提案された。
- RBFnet[27], NGnet[28]: 入力空間に対して Gauss 関数を当てはめ、各 Gauss 関数の支配領域に対して局所的な写像を計算する方法である。なめらかな写像が計算できるが、ネットワークの構造を決定するためのパラメータを予め設定しなければならず、複雑な写像を学習する場合、ネットワークの初期重み係数値を適切に設定しないと学習が収束しないという問題がある。
- 回帰木[34]: この方法は入力空間と出力空間を分離し、入力空間から出力空間に対する写像を学習する方法である。線形回帰木[35]では、線形回帰計算の誤差を小さくするように入力空間を分割し、それを木構造で表し、葉の部分に回帰係数を格納する。特長としては、1) 1 対多以外のあらゆるタイプの写像の学習が行なえる、2) スケーラビリティがあり、100次元以上の空間相互の写像も計算できる、3) 写像計算の速度が高速である、などの特性を持っている。

パラメトリック固有空間法、ISOMAP、LLE Spectral

embedding では入力空間に出力を表す多様体が埋め込まれるため、入力の次元数よりも出力の次元数を上げることはできない。これに対して、RBFnet、NGnet、回帰木や k -最近傍内挿法などでは入力と出力が分離されているため、入力の次元よりも高次元の空間への写像が学習できる。一方、線形回帰木は、1) ノイズの多いデータに対する写像計算を行おうとすると、入力空間の分割が細かくなりすぎ汎化性能が損なわれやすい、2) 入力空間を分割した周辺で写像結果が不連続になる、といった問題点がある。

写像学習における本質的な問題は、汎化性能と柔軟性のバランスをどのように調整するかということであるが、この問い合わせに対する答えはまだ得られていない。

事例を用いた非線形写像の応用例としては、事例を用いた超解像処理 Hallucination[37]が挙げられる。デジタル信号処理の理論に従えば、単一の静止画像から超解像処理を行うには、サンプリング周波数以上の高周波数成分を推定する必要があるため、1 枚の静止画像からの超解像処理は不可能であると考えられてきた。しかし、大量の事例を用いれば、そこに内在する低周波数成分と高周波数成分の相関関係を間接的に利用することができ、超解像処理が行えるのである。この事実は、画像の多様性はそれが表現されている高次元空間の広がりからすればごく僅かであり、意味のある画像の集合はかなり偏った多様体を形成しているためだと考えられる。具体的に Hallucination では、事例となる大量の低解像度画像を用意し、個々の画像に対して、画像そのもの、Gaussian によるぼかし、 x, y 方向の1次微分、ラプラスアンなどの処理を施して得た画像を用意する。これらの画像をブロック状に分割し、上述の各処理の結果得られた各画素の特徴を画像ブロックの特徴ベクトルと見なし、データベースに登録すると同時に対応する高解像度画像へのリンクを張っておく。入力画像の各ブロックに対しても同じ特徴ベクトルを用意し、最近傍探索を行い、対応する高解像度画像ブロックを見つける。この高解像度画像ブロックをちりばめることによって高解像度画像を得ることができる。

しかし、この方法だけではできあがる高解像度画像にはブロック状のノイズが入り、なめらかで自然な画像は得られない。このため、空間的な共起性を利用して自然な画像を生成する方法や、動画像を利用して時間的な連続性を確保する方法が提案されている[38]。

他にも、関ら[36]は画像を小ブロックに分割して背景画像の共起性を調べた上で、周辺ブロックに着目して k -最近傍内挿法によって背景画像を推定して背景差分

を行う方法を提案している。

6. 正則化

条件数が不足した問題を解くためには、何らかの制約条件を導入することによって解を安定化する必要がある。例えば、單一視点から撮影した画像を用いて多関節物体の3次元関節位置を求める問題を考えてみる。この問題に対する解は、各関節間の距離が分かっているものと仮定して逆運動学を適用しても安定にはならない。これは解を得るために条件数が不足している不良設定問題になっているためである。

このような問題を解く場合、過去の事例を内挿することによって各関節の2次元位置に対する3次元位置の関係を多様体として表現し、画像データから得られる3次元関節位置の多様体との距離を最小にする解を求めるといった方策が講じられる[39]。しかし、このポーズパラメータの個数が増加した場合、多様体を形成するために必要となる事例の個数が急激に増加するため、内挿方法を工夫することで事例数を削減するなどの研究が行われている[40]。

7. まとめ

事例ベースのパターン認識、コンピュータビジョンの研究を、検出、識別、写像学習、正則化の観点から概観した。この中で、Hallucinationや正則化の研究の一部は事例を積極的に用いることによって、従来解けなかつた問題が解けるようになったと言う意味で、重要な研究事例であるということができる。

また、Irregularity Detectionはこれまで多くの研究者が検出しようとしてできなかつた「異常」を事例によってシンプルに定義できることを示し、非常に意義深い研究であるということができる。

画像を対象とした事例ベースの研究の一部では、ブロック状に分割した画像を利用した画像処理的な内容のものがあるが、こういった研究では、空間的あるいは尺度軸上のマルコフランダムフィールドを併用することによって不連続性や誤りの修正が行なえることが分かっている。しかし、こういった文脈を考慮した処理(つまりはある部分の処理結果が全体に波及していく処理)を実現するための理論的枠組みはまだ十分整備されていない。特に、コンテキストによって変化する距離尺度を用いた最近傍探索・識別のアルゴリズムは今後その必要性が増すものと考えられる。

また、距離を基準とした最近傍探索は固定次元ベクトルにしか用いることができず、距離尺度自体が対称性

を満足しなければならないといった比較的強い制約条件がある。例えば、画像間のレジストレーションによく用いられるChamferマッチングでの相違性尺度は対称性の条件を満足しないため、従来の最近傍探索の枠組みにうまく乗らない。こういった制約を外し、メディア固有の性質に依拠した類似性・相違性の尺度を用いた類似パターンの高速検索アルゴリズムの理論的枠組みも今後発展するものと思われる。

さらに、事例ベース処理において一番の問題になるのは、事例の収集である。この問題に関してはGoogleなどの検索エンジンを用いる方法が提案されているが、これも元は別の方法で収集した事例であるので、本質的な問題の解決にはなっていない。例えば、正事例のみを収集しておき、正事例として識別できなかつたものを不事例として利用するという方法も考えられるが、これだけでは不事例に正事例が混入してしまう可能性もあるため、人間によるチェックが不可欠である。別の方法としてはクラスラベルの付けられた少数の事例を用意しておき、ラベルの付けられていない大量のデータを用いてラベリングを行なうという手法も提案されており、有用性も高い。いずれにしても、事例の自動収集という点では教示は不可欠であり、研究のポイントは如何にして教示を最小限に留めるかということになる。

最後に、事例ベースでの処理だけではメモリが足りなくなることは明らかである。CondensingやEditingのように事例を削減する処理か、もしくは大量の事例からモデルやルールを導出し、よりコンパクトな知識へと変換する処理はいずれにしても必要になる。それにもかかわらず、今この時期に事例を用いた処理が重要であるということを訴える理由は、1)モデルを用いて一足飛びにゴールを目指そうとする研究が台頭した結果、モデルに乗らない研究が多く残されてしまった、2)問題に合致したモデルを求めることが自体が研究になってしまい、本当の知能を実現することにあまり関心が寄せられなくなってしまった、といったことである。知能というものが形成される根底には、事例があり、それにスポットを当てることによって、これまでに実現できなかつた事が実現されつつある。こういったことを念頭に置き、事例で解決できるものはその解法を明らかにし、その上で、事例のよりコンパクトな表現を求めるという意味でのモデルベースへの回帰が起こるべきであると考える。

参考文献

事例ベース推論

- [1] Aha, D.W., "Case Based Learning Algorithms," Proc. of Case based Reasoning Workshop, pp.147-158, 1991

AESA

- [2] Vidal, R., "An algorithm for finding nearest neighbor in (approximately) constant average time," Pattern Recognition Letters, No. 4, pp. 145-158, 1986

LAESA

- [3] Mico, L., Oncina, J., and Vidal, E., "A new version of the nearest-neighbor approximating and eliminating search algorithm (AESA) with linear preprocessing time and memory requirements," Pattern Recognition Letters, No. 15, pp. 9-17, 1994

k-d tree

- [4] Bentley, J.L., "Multidimensional binary search trees used for associative searching," Communications of the ACM, Vol.18, No.9, 1975

GNAT

- [5] Brin, S., "Near neighbor search in large metric spaces," in Proc. of 21st Conf. on very large database , Zurich, Switzerland, pp. 574-584, 1995

VP-tree

- [6] Yianilos, P. Y., "Data structures and algorithms for nearest neighbor search in general metric spaces," in Proc. of the Fourth Annual ACM-SIAM Symp. on Discrete Algorithms, Austin, TX, pp. 311-321, 1993

MVP-tree

- [7] Bozkaya, T. and Ozsoyoglu, M.. Distance-based indexing for high dimensional metric spaces. In Proceedings of the 1997 ACM SIGMOD, pages 357-368. ACM, 1997

ANN

- [8] S. Arya, D. M. Mount, N. S. Netanyahu, R. Silverman, and A. Wu. "An optimal algorithm for approximate nearest neighbor searching," In Proc. 5th ACM-SIAM Sympos. Discrete Algorithms, pp. 573-582, 1994.

- [9] Arya, S., Mount, D.M., Netanyahu, N. S., Silverman, R., and Wu, A. Y., "An optimal algorithm for approximate nearest neighbor searching," Journal of the ACM, Vol.45, pp. 891-923, 1998

- [10] ANN: Library for Approximate Nearest Neighbor Searching (<http://www.cs.umd.edu/~mount/ANN/>)

LSH

- [11] P. Indyk, R. Motwani, P. Raghavan, and S. Vempala. Locality-preserving hashing in multidimensional

spaces. In Proceedings of the 29th ACM Symposium on Theory of Computing, pages 618--625, 1997.

- [12] M. Datar, N. Immorlica, P. Indyk, and V. Mirrokni. Locality-sensitive hashing scheme based on p-stable distributions. In Proc. of the 20th ACM Symposium on Computational Geometry, pp. 253-262, 2004.
- [13] E. A. Patric and F. P. Fischer, III., "A generalized k-nearest neighbor rule," Information and Control, 16(2), pp. 128-152, 1970
- [14] E. Parzen, "On estimation of a probability density function and mode," Ann. Math. Stat. 33, pp. 1065-1076. (1962)

One-class SVM

- [15] B. Scholkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola and R. C. Williamson: "Estimating the support of a high-dimensional distribution", Neural Computation 13, pp.1443-1471, 2001.

Density level detection

- [16] I. Steinwart, D. Hush, and C. Scovel, Density Level Detection is Classification. In Neural Information Processing Systems 17, pp. 1337-1344, (2005).

Irregularity detection

- [17] O. Boiman, M. Irani: Detecting Irregularities in Images and in Video. Proc. of ICCV 2005, pp. 462-469, 2005, Beijing

最近傍識別器

- [18] Cover, T.M., and Hart, P.E., "Nearest neighbor pattern classification," IEEE Transactions on Information Theory, Vol. IT-13, No.1, pp.21-27, 1967

Condensing

- [19] Bhattacharya, B. K., Poulsen, R. S., Toussaint, G. T., "Application of Proximity Graphs to Editing Nearest Neighbor Decision Rule," International Symposium on Information Theory, Santa Monica, 1981

Editing

- [20] Dasarathy, B.V., "Minimal consistent set (MCS) identification for optimal nearest neighbor decision systems design," IEEE Transactions on Systems, Man and Cybernetics, Vol. 24, No. 3, pp.511-517, 1994

- [21] Hart, P.E., "The condensed nearest-neighbor rule," IEEE Transactions on Information Theory, Vol. IT-4, No. 5, pp.515-516, 1968

- [22] Gates, G. W., "The Reduced Nearest Neighbor Rule," IEEE Trans. on Information Theory, Vol. IT-18, No. 3, pp.431-433, 1972

- [23] Ritter, G.L., Woodruff, H.B., Lowry, S.R., and Isenhour, T.L., "An algorithm for a selective nearest

- neighbor decision rule," IEEE Trans. on Information Theory, Vol. 21, pp. 665-669, 1975
- [24] Tomek, I., "A generalization of the k-nn rule," IEEE Trans. on Systems, Man and Cybernetics, Vol. 6, pp. 121-126, 1976
- [25] Aha, D.W., and Kibler, D., "Noise-Tolerant Instance-Based Learning Algorithms," Proc. of 11th IJCAI, pp.794-799, 1989
- 非線形写像**
- GMDH
- [26] A. G. Ivakhnenko, "Polynomial theory of complex systems," EEE Transactions on Systems, Man, and Cybernetics, pp. 364-378, 1971.
- RBFinet
- [27] T. Poggio and F. Girosi.: "Networks for approximation and learning," Proceedings of the IEEE, 78(9), pp.1481--1497, September 1990.
- NGnet
- [28] L. Xu, M. I. Jordan, and G. E. Hinton.: "An alternative model for mixtures of experts," In Advances in Neural Information Processing Systems 7, pp. 633-640, The MIT Press, 1995.
- k-NN 内挿
- [29] C. G. Atkeson, A. W. Moore, and S. Schaal: "Locally Weighted Learning," Artificial Intelligence Review 11, pp.11-73, 1997.
- Eigen-space Method
- [30] Hiroshi Murase and Shree K. Nayar, Visual learning and recognition of 3-D objects from appearance, International Journal of Computer Vision, Vol. 14, pp.5-24, 1995
- ISOMAP
- [31] J.B. Tenenbaum, V. de Silva, and J.C. Langford. A global geometric framework for nonlinear dimensionality reduction. Science, 290 (5500) , pp. 2319-2323, 2000.
- LLE
- [32] S. Roweis and L. Saul. Nonlinear dimensionality reduction by locally linear embedding. Science, 290:2323-2326, 2000.
- Spectral Embedding
- [33] M. Belkin and P. Niyogi. Laplacian eigenmaps and spectral techniques for embedding and clustering. NIPS 14, pp. 585-591.
- Regression Trees
- [34] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone: "Classification and Regression Trees," Chapman & Hall, New York, 1984.
- [35] J. R. Quinlan: "Learning with continuous classes," In Proc. of 5th Australian Joint Conference on Artificial Intelligence. pp. 343-348, 1992.
- k-NN に基づく背景推定
- [36] M. Seki, T. Wada, H. Fujiwara, K. Sumi, "Background Subtraction based on Cooccurrence of Image Variations," Proc. of CVPR, Vol. II, pp.65-72, 2003
- Hallucination
- [37] S. Baker and T. Kanade, "Limits on Super-Resolution and How to Break Them", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 24, No. 9, September 2002, pp. 1167-1183.
- Hallucination 時空間インタラクション
- [38] G. Dedeoglu, T. Kanade, and J. August, "High-Zoom Video Hallucination by Exploiting Spatio-Temporal Regularities," Proc. of CVPR '04, Vol. 2, pp. 151 - 158, June, 2004
- 姿勢推定への多様体の利用
- [39] N. R. Howe, M. E. Leventon, and W. T. Freeman, "Bayesian reconstructions of 3D human motion from single-camera video" NIPS 12, pp. 281-288, MIT Press, 1999.
- [40] R. Urtasun, D. J. Fleet, A. Hertzmann, and P. Fua, "Priors for People Tracking from Small Training Sets," Proc. of ICCV 2005, pp. 403-410, 2005
- 事例のテキスト検索
- [41] J. Sivic and A. Zisserman, "Video Google: A Text Retrieval Approach to Object Matching in Videos," Proceedings of the International Conference on Computer Vision (2003)