

ビジョンにおける領域認識問題へのアプローチ —領域抽出とその構造表現—

3B-5

畠山 康博 嘉数 侑昇
北海道大学 工学部

1. はじめに

領域的特徴からなる画像情報から領域あるいは物体形状を認識する場合、部分的パターンとそれらから構成される全体的パターンの構造が重要となってくる。このときどのような、そしてどのように局所的特徴量を抽出するかが問題となる。さらに、パターン全体の認識のためには、得られた局所的特徴量によって如何にその構造を表現するかが重要な問題であり、多くの研究がなされ、画像理解に向けて種々の方法が提案されてきた^{1),2)}。

本研究では、領域的特徴の構造を表現するための手法を提案する。ここでは、一般的な局所的特徴抽出を考えたうえで、局所的特徴の関係をその特徴に基づいた類似度によって定める。これによって領域全体の特徴がこれらの関係から構成される構造によって記述することができることを示す。そこでは、局所的特徴に基づいて画素をクラスタリングして、その中で画素間の結合を生成していく。この結合構造は領域全体の特徴の分布を表しており、領域あるいは物体の認識に有効な構造表現方法となりえることを以下で示していく。

2. 局所的特徴量の抽出

いま、二次元画像上の輝度を $I(x)$, $x \in X \subset \mathbb{R}^2$ とする。このとき画像全体は $I(X)$ で表すことができる。ある局所領域 ϵ に関する処理を f_ϵ とすると、 $x \in X$ における局所的な特徴量は $f_\epsilon(x)$ によって得られる。すなわち、

$$I(X) \xrightarrow{f_\epsilon} f_\epsilon(X), \quad \cdots(1)$$

となり、 f_ϵ をフィルタとした変換画像が得られる。一般に画像認識問題では f_ϵ によって得られた局所的特徴量の全体的な接続関係や分布パターンをとりだして評価することが必要となる。文字、形状認識においてこれをうまく解決しているものとしてネオコグニトロンがある。しかし、これは幾何学的形状パターンに対して有効であるが、領域的情報を抽出したり、それらを利用することは出来ない。重要なことはネオコグニトロンにも見られるように大局的特徴をとらえるために、 $I(X)$ から十分な構造的情報がとりだせるだけの種々の局所的処理が用意されていなければならないと

いうことである。このような局所的処理の集まりを以下のように表現するものとする。

$$f_\epsilon = (f_\epsilon^1, f_\epsilon^2, \dots, f_\epsilon^n), \quad \cdots(2)$$

ここで n は自然数である。例えば、局所的特徴抽出に Gabor 関数を用いるとすれば、 $n = 32$ or 48 であることが必要とされている³⁾。

3. 局所的特徴量に基づいたクラスタリング

本手法の領域的特徴の構造表現において着目するところは、局所的特徴の分布パターンである。そこでまず、同じような局所的特徴を有する画素についてその分布の様子を表現することを考える。これは f_ϵ によって得られる画素に対して特徴量に基づいたクラスタリングを行なうことによって求める。そのため、 $x, y \in X$ の 2 画素間の距離を以下のように定義する。

$$\delta(x, y) = \left(\sum_{l=1}^n (f_\epsilon^l(x) - f_\epsilon^l(y))^2 \right)^{\frac{1}{2}}. \quad \cdots(3)$$

さらに、これらの類似度を以下に定義する。

$$\sigma(x, y) = \exp\{-\delta(x, y)/T\}. \quad \cdots(4)$$

この類似度に基づいて、(5)式によって $x \in X$ に関する同類項が得られる。

$$V(x) = \{y; y \in X, \sigma(x, y) > \theta\}, \quad \cdots(5)$$

ここで、 θ はしきい値である。

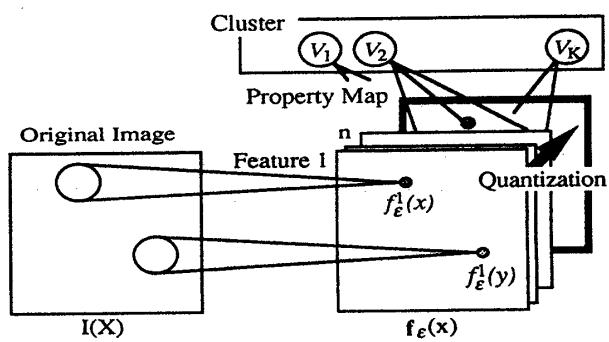


図 1. 特徴抽出からクラスタリングまでの概念図。

以上により、画像Xはその属性に基づいて分割されることになる。このとき、次式が成り立つことは明らかである。

$$X = V_1 \oplus V_2 \oplus \dots \oplus V_K. \quad \cdots(6)$$

クラスター数Kが幾つになるかはしきい値θの与え方による。

以上のことと概念的に示しているのが図1である。原画像からn個の局所的特徴についてフィルタリングされたxの局所領域εは、n次元のベクトルとして量子化され、属性値f_g(x)をもってX上に表現される。

以下では、この属性マップ上の画素間に結合を与える、属性の分布について記述することを試る。

4. ネットワーク化と特徴間関係の構造表現

領域的特徴をとらえようとするとき、一般にそこには定まった幾何学的構造がないことが多い。よってどのような部分パターンがどのように分布しているかが有用な情報となる。そこで、ここでは上述の方法で得られた同一のクラスターの画素間の関係をネットワーク構造の中に表現することを考える。

同一のクラスターに属する画素x_i, x_j ∈ V_kについてそれら画素間の結合荷重は次式で与えるものとする。

$$w_{ij} = \sigma(x_i, x_j). \quad \cdots(7)$$

上式右辺のσは(4)式で定義した類似度である。よって、2画素に関する属性が等しいとき最大の結合として1の荷重で結合される。

つぎに、このようにして得られたネットワークの構造から認識のための本質的な情報を抽出することが大きな課題となる。いまこのネットワークが表現しているのは、類似度の高い属性を持つ画素が相対的にどこに位置しているかということである。この相対的な位置関係を、すなわち分布の様子を表現するためにx_i, ∈ V_kのx_j ∈ V_kに対する関係ベクトルを(8)式で定義する。

$$v_{ij} = x_j - x_i. \quad \cdots(8)$$

図2で、クラスターV_kにおける関係ベクトルv_{ij}について、注目する画素を変えたときの2つの例を概念的に示す。

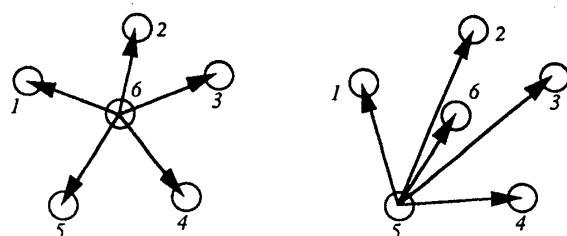


図2. クラスター内の特徴関係ベクトルの例。

5. 大局的領域特徴の構造表現

本手法によって、クラスターV_kの画素の分布パターン、すなわち類似する局所的特徴の分布パターンが、v_{ij}の集合として得られた。これら関係ベクトルの空間とその出現頻度からなる空間によって、V_kに関する大局的構造が表現できたことになる。ここで、この大局的構造をP(V_k)と書くこととする。

以上より、画像全体は以下の式のように代表的な局所的特徴の大局的な関係構造の集合として表現されることとなる。

$$I(X) \rightarrow f(X) \rightarrow P(V_k; k=1, \dots, K). \quad \cdots(9)$$

図3が示しているのは結合荷重を考慮せず関係ベクトルv_{ij}のみによって描かれたP(V_k)の概念図である。このP(V_k)に基づいて大局的な領域的特徴の認識が可能となる。

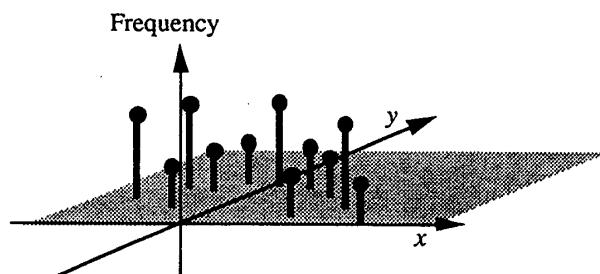


図3. 特徴関係ベクトルによる局所的特徴の分布の概念図。

6. おわりに

ここに提案した画像の特徴関係の構造表現が認識課題に対してどれほどの能力を持っているかを以下で検証する。すなわち、特徴の関係を相対的な関係ベクトルで表現することから、位置に対する不変性があることは容易に分かる。また、拡大、縮小の大きさに対する不変性に対してもその能力が期待できる⁴⁾。

画像情報を如何に特徴空間に表現するかは認識問題における大きな課題である。ここで提案している局所的特徴の構造表現は並列分散処理の要素を持ち、さらに、P(V_k)からのパターンの学習などさまざまな可能性があるといえよう。そのような認識のもとで、認識機構を如何に与えるかが今後の課題である。

【参考文献】

- 1) 高木幹雄、下田陽久: "画像解析ハンドブック," 東京大学出版(1991).
- 2) 福島邦彦: "神経回路と情報処理," 朝倉書店(1989).
- 3) Turner, M.R.: "Texture Discrimination by Gabor Functions," Biological Cybernetics 55 (1986).
- 4) 畠山康博、嘉数侑昇: "Space Recognizer構築に関する基礎研究 一大きさ不変性問題へのアプローチ," 平成3年度電気関係学会北海道支部連合大会講演論文集(1991).