

ニューラルネットワークにより併合判定を行う 領域分割法

1J-2

安東孝信 賀川経夫 大城英裕 遠藤勉
大分大学工学部

1. はじめに

領域分割は画像の認識・理解のための重要な特徴抽出法の一つである。しかし、自然画像等の雑音が多く、色や明るさの変化に富むものを対象とした場合、人間が見て一つの領域であっても、通常アルゴリズムを適用すると、しばしば多くの小領域に分割されてしまう。これらの小領域はその後の処理(特徴抽出, 知識ベースとのマッチング等)の大きな障害となる。

そこで我々は、通常の領域分割の結果生じる小領域を併合し、必要な領域のみを残す手法について研究している。

本論文では階層型ニューラルネットワークを用いた小領域の併合判定法を提案する。さらに、カラーの自然画像を用いた実験を通してその効果を確かめる。

2. ニューラルネットワークの構成

2.1 ニューラルネットワーク

本実験では、誤差逆伝播学習を行う3層階層型ニューラルネットワークを使用した。ネットワークは、入力層は入力する特徴(後述)の数に合わせて14個のユニット、中間層は15個のユニット、出力層はネットワークの出力を、併合性の可否を示す値とするので1個とした。

2.2 誤差逆伝播学習則

誤差逆伝播学習則とは、入力データと共に目標出力(ターゲットデータ)を与えて、その目標出力とネットワークの実際の出力との誤差を使ってネットワーク内の重みを更新するものである。ユニット*i*とユニット*j*間の重みの更新には、次の式を用いる。

$$\Delta W_{ij}(n+1) = \varepsilon (\delta_{pj} a_{pi}) + \alpha \Delta W_{ij}(n)$$

δ : 目標出力とネットワークの出力との誤差を示すパラメータ

n : パターンの提示回数

p : 学習用のパターンの番号

(δ_{pj} : あるパターン*p*に対する誤差,

a_{pi} : ユニット*i*のパターン*p*に対する出力)

式中の a_{pi} によって示される入出力関数は、ロジスティック関数であり、また本実験では ε (学習定数)は0.5, α (慣性定数)は0.9とした。

3. 実験

この実験の目的は、隣接する2つの領域の併合性をネットワークに学習させること、そしてそのネットワークに未学習の隣接する2つの領域を提示してどのような出力が得られるかを調べることである。

ネットワークには隣接する2つの領域の特徴量(面積, 平均濃度等)の差と2つの領域の隣接数を入力し、その出力によりそれらの領域を併合するか、しないかを決定する。そのため学習時のターゲットデータとして、最終的に併合を行った後、人が存在を認める領域のみが残るような小領域の併合性の値を与える。ネットワークの出力が閾値以上であれば入力した2つの領域の組を併合し、

閾値以下であれば2つの領域の組の併合しないとする。なお本実験では、1枚の画像から取り出したいくつかの学習用画像(部分画像)について1つのネットワークで学習実験を行った。その方法と結果を以下に述べる。

3.1 ネットワークの学習実験方法

- (1) スキャナを用いてカラーの自然画像(図3-1)を512×512画素の大きさで計算機に取り込む。この画像から64×64画素の学習用部分画像(例; 図3-2)を取り出す。
- (2) 部分画像に対し、平滑化を行った後、隣接画素間の濃度差が閾値以下であれば領域を併合する領域併合型の領域分割を行う。図3-2に対する領域分割の結果を図3-3に示す。
- (3) 各領域について後述する特徴量を計算する。
- (4) 各隣接領域対(2つの隣接する領域の組み合わせ)ごとに(3)で求めた特徴量の差とそれらの隣接数(後述)を計算する。
- (5) (3), (4)で得られた値を[0, 1]の範囲に正規化する。
- (6) 各隣接領域対ごとに目標出力を用意し、学習用パターンを作成する。
- (7) ネットワークに学習させる。
- (8) 別の学習用部分画像を取り出し、(2)~(5)を行いネットワークに提示する。
- (9) 望ましくないネットワーク出力が得られた隣接領域対について正しい目標出力を与え学習用パターンに加える。
- (10) 再びネットワークに学習させる。
- (11) (8)~(11)を繰り返す。




図3-1



図3-2




図3-3




図3-4

3.2 実験に用いた特徴量

○各領域毎のデータ

1. 面積(画素数): S

2. 平均濃度:

$$f_i = \frac{1}{S} \sum f_i(x, y)$$

$f_i(x, y)$: ラベル i の濃度

3. テクスチャ性 (濃度差の平均値):

$$\frac{1}{S} \sum |f_i(x, y) - f_i|$$

2, 3 については赤, 緑, 青の画像データと色相, 明度, 彩度のデータを用いてそれぞれ6個づつ求めている。
○ 2領域間のデータ

2領域間の4近傍の連結数. 図3-5では連結数は3となる.




図3-5

3.3 学習実験の結果

本実験では3.1の(11)を2回繰り返す計3枚の画像について学習を行った. その結果240組の隣接領域対の併合判定を学習する事ができた. (全組み合わせ: 242組, 誤学習: 5組, 学習率98%) その結果の1例を図3-4に示す.

3.4 識別実験方法

学習後のネットワークに未知のデータを提示してその結果を調べる. 識別用の画像として学習時に使用した画像(図3-1)から得た未学習の部分画像を用いた実験と, 学習時に用いた画像とは別の画像から得た部分画像を用いた実験の2通りを行った.

方法:

- (1) 識別用の部分画像(64×64画素)を用意する.
- (2) 学習実験の(2)~(5)を行う.
- (3) ネットワークに提示し, その結果を調べる.

3.5 識別実験の結果

実験の結果を図3-6(識別用部分画像), 7(通常の領域分割後のラベル画像), 8(ネットワークの出力結果)に示す. なお図の(a)は学習時に使用した画像から得た部分画像を用いた実験の結果で, (b)はそれとは別の画像から得た部分画像を用いた実験の結果である.

4. 検討・考察

学習実験においてはかなり良好な結果が得られた. 識別実験においては道路と白線, 道路と山, 山と空等の割合ははっきりと差の現れる領域を分け, それぞれの領域の内部の小領域を併合することはできた. しかし, 山と山の重なり合いや, 道路から路上にこぼれた土の部分などの色の変化のなだらかな所では良好な結果は得られにくかった.


さらに学習, 識別の両実験で共通して, 領域と領域の境界部分に生じる小領域の併合判定についても良好な結果は得られなかった. これはスキャナ等の能力の影響も考えられるが領域間の境界部分には両方の領域の中間的な特徴を持つ小領域が存在するためだと思われる.

しかし, 学習時に用いた画像を使った場合と, それとは別の画像を使った場合とで識別実験の結果にあまり差がみられないことから画像の違いに対する柔軟性はあると考えられる.


また識別実験において, 学習した部分画像の個数が多い程, より良好な結果が得られていた. このことから, より多くの部分画像を学習すればもっと良好な結果が得



(a) 図3-6 (b)



(a) 図3-7 (b)



(a) 図3-8 (b)

られるのではないかとと思われる.

5. 終わりに

今回, ニューラルネットワークを用いて隣接領域の併合性を判定する実験を試みた. その結果, 完全とはいえないまでも十分な結果が得られた.

今後はまず, ネットワークの出力の精度をあげるため, 以下の点について実験的に検討する.

- ・他の有効と思われる特徴量を使用する.
- ・より多くの部分領域をネットワークに学習させる.
- ・隣接する2つの領域に限らず必要に応じて様々な組み合わせ(3つ以上の領域等)についても調べ

さらに, このネットワークの出力をどのようにして評価し利用するかについて考える. すなわち, 多少ネットワークが間違っただ判定を出力をしてもそれを吸収して最終的に必要な領域のみにしてしまうような柔軟な領域分割システムの構築を目指す.

参考文献

- (1) James L. McClelland, David E. Rumelhart: EXPLORATIONS IN PARALLEL DISTRIBUTED PROCESSING, The MIT Press(1988)
- (2) 田村 他: Spider Users' Manual, 協同システム開発株式会社(1982)
- (3) 大城, 遠藤, 岡田: "自然な情景の理解", 電気関係学会九州支部第43回連合大会講演論文集(1990)