

連想記憶と単純パーセプトロンによるダイズ葉形判別モデル

4H-3

生出 真里*, 二宮 正士*, 高橋 信夫**

* 農業研究センター, ** 長野県中信農業試験場

1. 目的

農業における専門家の視覚的判断は、重要な役割を果たす。このような判断は優れた結果をもたらしてきたが、経験に基づく定性的なものであり、ときとして不安定である。これまで、統計的处理あるいは非統計的处理を用いた定量的判別による視覚代替が試みられ、良好な結果が示された。たとえば、Ninomiyaら¹⁾は統計的判別関数、多層パーセプトロン、ファジイルールをダイズ草姿の評価に適用した。しかし、これらは画像から判別に有用な特徴量を探索する必要のあるアドホックな手法であり、異なる対象の形状の評価を行う場合、同じ操作を繰り返し行わなければならない。

そこで、筆者らは汎用性の高い形状判別モデルの開発を目的とし、ニューラルネットワークに画像を直接入力する試みを行っている。本報告では、ダイズ葉形による品種判別へホップフィールド型ネットワークによる連想記憶（AM）及び単純パーセプトロン（SP）の適用を検討した。

2. 材料と方法

標準化楕円フーリエ係数²⁾で表現されたダイズ個葉データ39品種375枚分から、サイズ16×16画素及び32×32画素の領域に輪郭を復元し、葉の内部を塗りつぶして二値の個葉画像を作成した。さらに、同一品種内で楕円フーリエ係数の平均から、サイズ16×16画素及び32×32画素の輪郭を復元し、二値の平均葉形画像を作成した。一方、16×16画素及び32×32画素のそれぞれのサイズについて、同一品種内で個葉画像の平均輝度値をもつグレーレベルの葉形分布画像を作成した。個葉画像




図1 個葉画像と平均葉形及び葉形分布の例

と平均葉形及び葉形分布の例を図1に示す。画素の輝度値は、二値画像では葉の内部を+1、背景を-1、グレーレベル画像では閉区間 $[-1, +1]$ の実数値とした。

AMは、入力画像の画素数 N と同数の線形素子を持ち、すべての素子が互いに完全結合される。動作式は、

$$\begin{cases} u_i(t) = \sum_{j=1}^N w_{ij} v_j(t) & (i = 1, \dots, N) \\ v_i(t+1) = u_i(t) \end{cases}$$

である。ただし、 $u_i(t)$ 、 $v_i(t)$ はそれぞれ素子 i の時刻 t における入力と出力、 w_{ij} は素子 j から素子 i への結合係数である。入力画像 μ 、 ν 間のオーバーラップ：

$$Q_{\mu\nu} = \frac{1}{N} \sum_{i=1}^N \xi_i^\mu \xi_i^\nu$$

(ξ_i^λ は入力画像 λ の i 番目の輝度)に基づいて、結合係数を決定した。すなわち、結合係数は

$$w_{ij} = \frac{1}{N} \sum_{\mu, \nu=1}^P \xi_i^\mu (Q^{-1})_{\mu\nu} \xi_j^\nu$$

で得られる。

SPは、記憶画像数 P と同数の線形素子からなり、各素子の入力数は N とした。素子 i の動作式は、

$$v_i = \sum_{j=1}^N w_{ij} u_j \quad (i = 1, \dots, P)$$

Identification model based on classification soybean leaf shape by associated memories and simple perceptrons
Mari Oide*, Seishi Ninomiya* and Nobuo Takahashi**

* National Agriculture Research Center

3-1-1 Kannondai, Tsukuba, Ibaraki 305, Japan

** Nagano Chushin Agriculture Experimental Station
Shiojiri, Nagano 399-64, Japan

ただし、 u_j は入力成分の第 j 成分、 v_i は素子 i の出力である。記憶画像 λ を入力したとき、 λ 番目の出力素子のみが発火するパターンを目標出力とした。したがって、結合係数は

$$w_{ij} = \frac{1}{N} \sum_{\mu, \nu=1}^P \zeta_i^{\mu} (\phi^{-1})_{\mu\nu} \xi_j^{\nu}$$

で得られる。ただし、 ζ_i^{λ} は目標出力パターン λ の i 番目の成分である。

39枚の平均葉形及び葉形分布のうち、互いにオーバーラップの二乗和の小さいものを選択して学習データとした。記憶できる品種数を実験するため、学習させる画像の枚数を2から順に増やした。

また、学習後のニューラルネットワークを評価するために、学習させた平均葉形及び葉形分布に対応する品種の個葉画像を入力し、個葉画像の判別率を調べた。ここで判別率とは、AMでは個葉画像から対応する品種の平均葉形又は葉形分布を復元した割合、SPでは個葉画像から対応する平均葉形又は葉形分布の品種を判別した割合である。同時に、学習データの作成方法及びネットワークアーキテクチャによる判別率の差異についても比較・検討した。

3. 結果と考察

記憶画像数と個葉画像の判別率を図2に示す。記憶画像数が15以下のとき、平均葉形及び葉形分布を学習データとして判別率を求めたが、平均葉形で学習させた場合は判別率の降下が著しかった。連続値の輝度によって個葉の形状の変位の情報が葉形分布に保持されていたことで、葉形分布で学習させたほうが判別率が高かったと思われる。記憶画像数16以上については、葉形分布のみで学習させ、判別率を求めた。

葉形分布を学習データとしたとき、AM及びSPは、39枚すべての平均葉形及び葉形分布を記憶できた。判別率は記憶画像数2のとき100%であり、記憶画像数の増加とともに低下した。また、AMよりSPが高く、16×16画像より32×32画像のほうが高い値を示した。これは、16×16画像では解像度が低




図2 品種数と判別率

く、平均葉形及び葉形分布間及び個葉画像間の類似度が高くなって判別が難しくなったこと、AMは画像の復元中に局所的最小解に到達しやすかったことが原因と考えられる。学習データ間のオーバーラップと判別率との関係や、学習データとテストデータとの類似度などを含め、判別率に差が生じた原因についてはさらに検討する必要がある。

32×32画像を入力したSPでは、判別率が常に80%以上であり、ニューラルネットワークによるダイズ葉形の記憶から、定量的な品種判別ができることが示唆された。記憶可能な画像数及び判別率向上のための手法の改善が、今後の課題である。また、ダイズ葉形以外の形状判別へのニューラルネットワークの適用も検討する予定である。

参考文献

- 1) Ninomiya S. *et al.* : Comparison of three models to evaluate soybean plant shape using shape indices given by image analysis, Proc. 7th Int. Conf. SABRAO and Int. Symp. WSAA, 613-620 (1992).
- 2) Ninomiya S. *et al.* : Evaluation of leaf and kernel shape based on principal component scores of standardized elliptic Fourier coefficients, An ASAE Meeting Presentation, Paper No. 953220(1995).