

## 第4章 大きさ情報を組み合わせた植物形状判別モデルの拡張

第1章で構築した画像入力ニューラルネットワークに基づく判別モデルは、①形状特徴量を必要としないために、さまざまな植物形状に広く適用でき、②形状のもつ情報全体を使ったために、多様な変異を有する複雑な形状に対しても安定的な判別精度を与えることを、第2章および第3章で実証した。このことから、形状情報のみ評価する判別モデルを構築できたといえる。本章では、画像入力ニューラルネットワークによる形状情報の評価に、独立に評価した大きさ情報を組み合わせ、総合的な判別を行うよう本判別モデルを拡張し、カエデ葉形による種判別を例にとって、その有効性を検証する。

4.2では、大きさ情報を含んだ供試材料を提示し、判別モデルを拡張する方法について述べ、4.3では、形状情報のみを評価した判別結果と比較しながら、大きさ情報との組み合わせによる判別結果を示す。4.4では、得られた結果から判別モデルの拡張の有効性について考察する。

### 4.1 はじめに

画像入力ニューラルネットワークに基づく判別モデルが、植物器官形状による種や品種・系統の判別や育種家の評価による草姿の判別に広く適用できて有効であることは、第1章～第3章で示したとおりである。このとき、画像入力ニューラルネットワークによる判別が大きさ情報に惑わされないように、入力された形状は、相似変換、回転、平行移動、計測開始点について不変となるよう正規化され、大きさ情報を含んでいなかった。Ding and Gunasekaran (1994) が提案した判別モデルも同様で、トウモロコシ (*Zea mays* L.) 粒、アーモンド (*Prunus dulcis* (Mill.) D.A. Webb) 核、クラッカーを形状に基づいて判別する問題で、前処理として、垂直・水平の各方向の標準偏差が一定になるように形状を相似変換した。また、標準化楕円フーリエ記述子に基づいた形状評価を提案した一連の研究(二宮ら, 1994; Furuta *et al.*, 1995; Yoshida *et al.*, 1995; Hadipoentiyanti *et al.*, 1996; 北浦ら, 1997; Ohsawa *et al.*, 1998) では、材料の形状の大きさ、位置、向きを最初に揃えた。これらの研究では、原データから大きさ情報を除くことによって、輪郭形状を的確に評価できることを示した。

一方で、形状特徴量に基づく植物形状の判別モデルでは、ふつう、使用する形状特徴量に面積、周囲長、最大長、幅などの大きさ情報が含まれる。たとえば、大きさ情報を含む形状特徴量を用いて、Travis and Draper (1985), Chen *et al.* (1989), Zayas *et al.* (1989), Liao *et al.* (1994),

Chtioui *et al.* (1996), Ghazanfari *et al.* (1996), Zayas *et al.* (1996) は種子粒形の判別を, Molvray and Kores (1995), Cho *et al.* (1997) は細胞の形状の判別を, それぞれ行った. Ingrouille and Laird (1986), Carneiro and Lima (1987), McLellan (1990), Im *et al.* (1998) は, 標識点 (landmark ; 葉の裂片の先端および基部に該当する点) 間の距離を利用して, 欠刻のある葉形を解析した. Guyer *et al.* (1993) と Warren (1997) は, 大きさ情報を含む形状特徴量から, いくつかの種の葉形を類型に分類した. さらに, 大きさ情報を含む形状特徴量を用いて, Heinemann *et al.* (1994) はマッシュルームの判別を, 南ら (1991), Ninomiya and Shigemori (1991), Ninomiya *et al.* (1994), Woebbecke *et al.* (1995a-b), Ambuel *et al.* (1997) は草型・草姿の判別を, それぞれ行った. このように, 大きさ情報は有用な判別要因となることが示唆されている.

しかし, 1.5.1 で示した大きさ情報を含んだカエデ葉形による種判別が失敗したように, これらの研究では, 形状情報と大きさ情報とを同列に扱っているために, 形状情報の評価が大きさ情報に惑わされている可能性が否定できない.

そこで本研究では, 形状情報と大きさ情報とを分離して, 独立に評価することとし, これまで形状情報のみを評価する判別モデルについて論じてきた. 本章では, 形状情報とは独立に評価した大きさ情報を加えた判別モデルの拡張を考える.

上に挙げた研究では, 対象の長さを計測するときには, 標識点のように生物学的に意味のある点を抽出し, その2点間の距離を用いたものが多い. そのため, 大きさ情報を抽出・選択するために, 生物学的背景としての知識が必要であり, また判別モデルの対象が限定される. さらに, 大きさ情報を計測する処理に人の介入を要し, 自動化を難しくすることもある. そこで, 本研究では, 判別モデルの汎用性を保つためにも, 対象によらず普遍的でかつ計測が容易にできるもの, すなわち生物学的背景に基づく予備的知識の必要のない大きさ情報を使用することに留意した.

## 4.2 材料と方法

本節では, 大きさ情報を含めて供試材料を再度提示し, 判別モデルを拡張する方法について詳細を述べる. 4.2.1では, 供試材料を提示し, 4.2.2では, 判別モデルの拡張方法と本章における拡張した判別モデルの各種設定について述べる.

#### 4.2.1 材料

供試した材料は、14種のカエデ278個葉である。これは第1章で供試した材料であり(1.2.1参照)、種判別を行った。図4-1に、種間の相対的な大小関係に合わせて拡大・縮小した葉形分布(1.2.2.2参照)を示す。

#### 4.2.2 植物形状判別モデルの拡張と判別処理の設定

本項では、大きさ情報と組み合わせた判別モデルの拡張方法と、本章における拡張した判別モデルの各種設定について述べる。全体の処理は、形状情報の抽出・評価(4.2.2.1参照)、大きさ情報の抽出・評価(4.2.2.2参照)、両者の評価の統合(4.2.2.3参照)からなる(図4-2)。なお、訓練する種の選択、誤判別率の評価法については、形状情報のみ評価したカエデ葉形による種判別と同様であるので、説明を省略する(1.2.2.4, 1.2.2.5参照)。

##### 4.2.2.1 形状情報の抽出・評価の手法と設定

まず、第2章と同様にして、個葉画像を画像入力ニューラルネットワークによって評価する。ここでは、もっともよい結果を示した、64画素×64画素の葉形分布を入力パターンとする教師データで訓練した単純パーセプトロン(1.4.2参照)を用いた。

次に、形状評価に関する $P$ 個( $P$ は訓練した種数)の出力変数を得る。出力変数には、上記単純パーセプトロンの出力値をそのまま代入した。第 $k$ 個葉画像( $k=1, \dots, M$ ;  $M$ は個葉画像数)を入力としたときの第 $i$ 出力変数を $\psi_i$  ( $i=1, \dots, P$ ) とすると、 $\psi_i$ が大きいほど、第 $k$ 個葉画像は第 $i$ 種に属する確信度が高いことになる。

##### 4.2.2.2 大きさ情報の抽出・評価の手法と設定

簡単に抽出できる大きさ情報として、二値化された葉形の面積、周囲長、絶対最大長、幅(単位はすべて画素)の四つを用いることにした。これら大きさ情報は、画像解析装置(nexus9000, ㈱ネクサス, 東京)を用いて計測した。大きさ情報の定義は、

- (1) 面積：図形の画素数,
- (2) 周囲長：図形の周囲長,
- (3) 絶対最大長：図形の任意の2点間の距離のうち最大の長さ,
- (4) 幅：絶対最大長に平行な2本の直線で図形を挟んだときの2直線の距離

である(高木と下田, 1991)(図4-3)。




図4-1 カエデ葉形の種間の相対的大小関係に合わせて拡大・縮小した葉形分布

葉形分布は、二値の個葉画像の種内平均である。黒い画素は、それぞれの種の個葉画像すべてにおいて葉の領域に含まれることを示し、白い画素は、背景の領域に含まれることを示す。灰色の画素は、一部の個葉画像で葉の領域に含まれることを示す。標準化楕円フーリエ係数の第一主成分の種内平均値でソートして配置した。標準化楕円フーリエ係数の第一主成分は、葉形の縦横比にほぼ該当する。

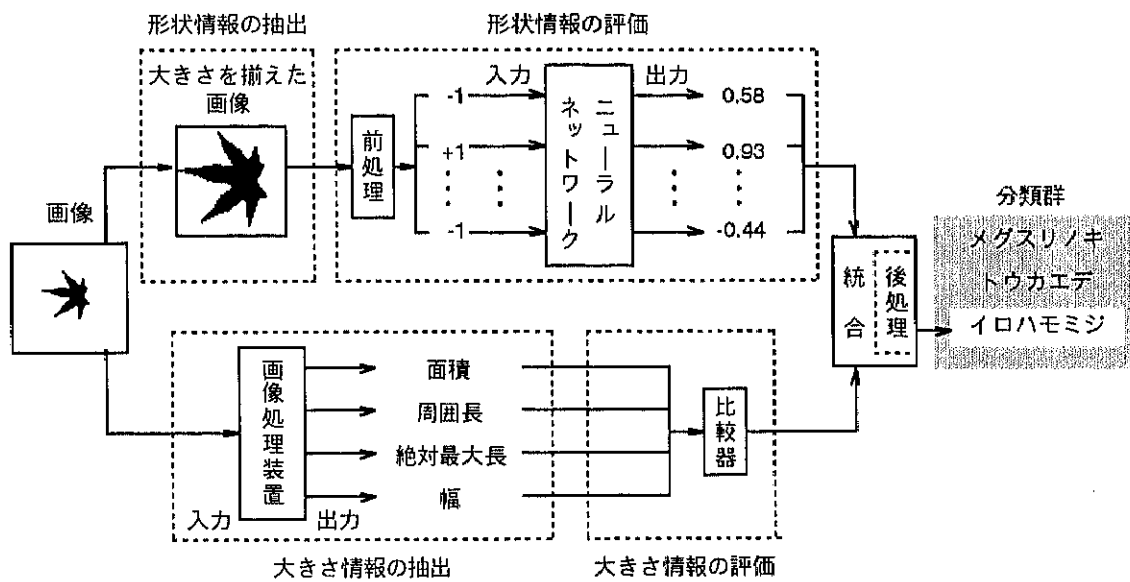


図4-2 形状情報と大きさ情報とを独立に評価したうえで統合する判別モデル

全体の処理は、形状情報の抽出、画像入力ニューラルネットワークによる形状情報の評価、大きさ情報の抽出・評価、両者の評価結果の統合からなる。

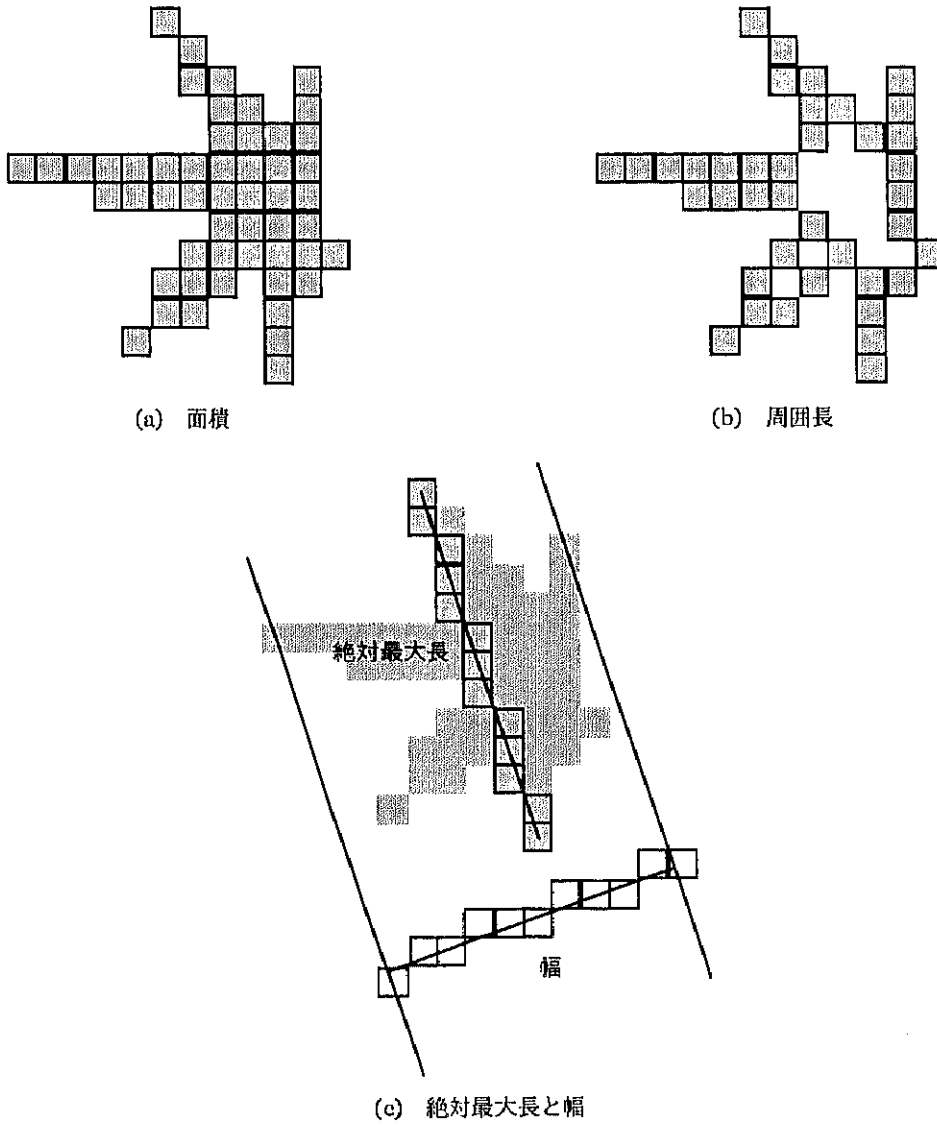


図4-3 大きさ情報の定義

上記図形の面積は52画素，周囲長は39画素，絶対最大長は13画素，幅は11画素である。

4.2.2.1で教師データに使用した個葉画像から、これら四つの大きさ情報を計測する。面積には画素当たりの長さの二乗、その他の大きさ情報には画素当たりの長さを乗じて、実面積および実長を求める。

$s^{\lambda k}$  ( $j=1, \dots, 4, \lambda=1, \dots, P, k=1, \dots, m_\lambda$ ;  $m_\lambda$ は第 $\lambda$ 種の教師データに使った個葉画像数) を、第 $\lambda$ 種の第 $k$ 個葉画像から計測された第 $j$ 大きさ情報とする。これらの種内平均および標準偏差を求める。第 $\lambda$ 種の第 $j$ 大きさ情報の種内平均および標準偏差を、それぞれ ${}^j\mu_\lambda, {}^j\sigma_\lambda$ とする。

テストデータの各個葉画像についても、四つの大きさ情報を計測する。ここで、 $s^{\kappa j}$  ( $j=1, \dots, 4, \kappa=1, \dots, M$ ) を、第 $\kappa$ 個葉画像から計測された第 $j$ 大きさ情報とする。これら大きさ情報から各個葉画像の評価を導き、 $P$ 個の出力変数によって表す。第 $\kappa$ 個葉画像の大きさ情報による評価の出力変数を $d_i^\kappa$ とすると、これを、種内標準偏差 ${}^j\sigma_\lambda$ で正規化した $s^{\kappa j}$ と種内平均 ${}^j\mu_\lambda$ との相対距離：

$${}^j d_i^\kappa = \frac{{}^j s^{\kappa j} - {}^j \mu_\lambda}{{}^j \sigma_\lambda} \quad (i=1, \dots, P, j=1, \dots, 4, \kappa=1, \dots, M) \quad (\text{数式4-1})$$

の最大値と定義する。すなわち、

$$d_i^\kappa = \max_j {}^j d_i^\kappa \quad (i=1, \dots, P, j=1, \dots, 4, \kappa=1, \dots, M) \quad (\text{数式4-2})$$

である。 $d_i^\kappa$ が小さいほど、第 $\kappa$ 個葉画像は第 $i$ 種に属する確信度が高いことになる。

#### 4.2.2.3 評価結果の統合の手法と設定

第 $\kappa$ 個葉画像に対する形状情報の評価の第 $i$ 出力変数である $\psi_i^\kappa$  (4.2.2.1参照) および第 $\kappa$ 個葉画像に対する大きさ情報の評価の第 $i$ 出力変数である $d_i^\kappa$  (4.2.2.2参照) の二種類の出力変数を統合し、拡張された判別モデルにおける最終的な出力変数 $\eta_i^\kappa$ を

$$\eta_i^\kappa = (1-\alpha)\psi_i^\kappa - \alpha d_i^\kappa \quad (i=1, \dots, P, \kappa=1, \dots, M) \quad (\text{数式4-3})$$

と定義する。ただし、 $\alpha$ は、形状情報と大きさ情報との相対的強さを決定する定数で、

$$0 \leq \alpha \leq 1 \quad (\text{数式4-4})$$

とし、閉区間 $[0, 1]$ の値を0.01刻みで与えた。 $\eta_i^\kappa$ が大きいほど、第 $\kappa$ 個葉画像は第 $i$ 種に属する確信度が高いことになる。したがって、 $\eta_i^\kappa$ が $i=K$  ( $1 \leq K \leq P$ )で最大になるとき、第 $\kappa$ 個葉画像は、拡張された判別モデルにより、教師データの第 $K$ 種に判別されたとした。

### 4.3 結果

$\alpha$  値による誤判別率の変化を図 4-4 に示す。 $\alpha=0$  のときの誤判別率は、形状情報のみの評価による判別結果、 $\alpha=1$  のときの誤判別率は、大きさ情報のみの評価による判別結果となる。 $\alpha$  値を 0 から 1 へ変化させると、誤判別率は、細かい変動を繰り返しながら減少し、 $\alpha=0.5$  前後で最小点を通過したあと増加に転じた。誤判別率は、 $\alpha=1$  において最大値をとった。

図 4-5 に、誤判別率を最小にする  $\alpha$  値における判別結果の二元表を示す。10 種判別における再代入法による誤判別率は 0.116 から 0.040 へ、一つ抜き法による誤判別率は 0.202 から 0.096 へと低化した。いずれも形状情報のみの評価からの判別より誤判別率が改善された。

同じ  $\alpha$  値においては、種数の増大にしたがって誤判別率も大きくなった (図 4-4)。再代入法による誤判別率が、一つ抜き法による誤判別率を超えることはなかった。

### 4.4 考察

$\alpha$  値は、形状情報のみの評価と大きさ情報のみの評価とを、どのような比率で組み合わせるかを決定する因数である。したがって、 $\alpha$  値と誤判別率との関係から、判別における形状情報と大きさ情報との相対的重要度が推測できる。 $\alpha$  値が 1 に近いとき誤判別率が最大となった (図 4-4) ので、カエデ葉形においては相対的に形状情報が大きさ情報よりも重要な判別要因である。いずれにせよ、形状情報か大きさ情報の一方のみを評価して判別するより、両者を組み合わせたほうが誤判別率を低く抑えられることが明らかになった。

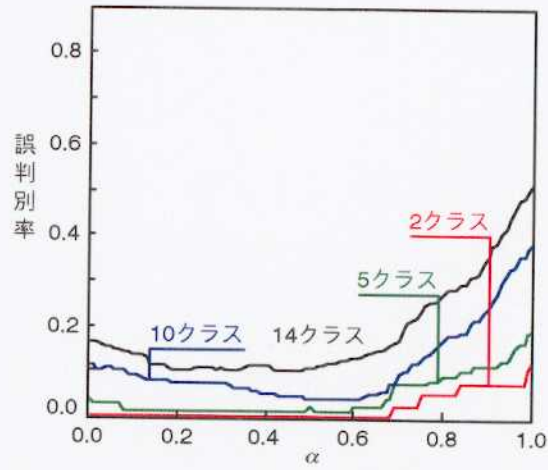
形状情報のみの評価による判別の誤りは、葉形が似た種、すなわち、縦横比が似た種や欠刻数が等しい種間で多く見られたが、これらの間で大きさが異なるとき、誤判別率が大きく改善された。

訓練する種を選択するとき、葉形のみを基準にしたため、大きさ情報が考慮されていなかった。したがって、大きさの異なる種が偶然選ばれたときに、誤判別率は大きく改善された。種数が増えるにつれ、そのような偶然性の影響が小さくなり、種数による誤判別率の差は減少したと思われる。

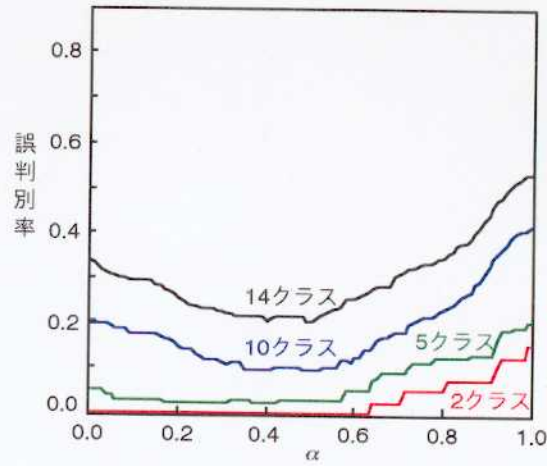
一つ抜き法による誤判別率が、再代入法による誤判別率を越えなかったことから、オーバーフィッティングが発生したことがわかる。しかし、形状情報のみの評価による判別に比べ、二つの誤判別率の差が小さくなった。大きさ情報との組み合わせは、オーバーフィッティングを抑制する効果もあることがわかった。

大きさ情報を形状情報と同等に扱わず、それぞれの評価を分離して独立に行った。そして、両者を統合して最終的な判別結果を導く方針をとった。これにより、大きさの観点から候補になりえな





(a) 再代入法による誤判別率



(b) 一つ抜き法による誤判別率

図4-4 カエデ葉形の誤判別率の  $\alpha$  値にともなう変化の種数による比較



い種を確実に除くことができ、誤判別率を改善できた。1.5.1 で述べたように、大きさ情報を含んだ状態でカエデ葉形を評価したところ、判別に失敗した。形状情報と大きさ情報とを区別しなければ、どちらも正しく評価できないと考えられる。このことから、熟練者による目視判断でも、同様に、大きさ情報からまず種を限定し、そのうえで形状情報を評価し、最終的に観察の対象が属する種を判別しているものと類推できる。すなわち、目視判断では、大きさ情報が形状情報の評価に影響を及ぼす可能性が残っているものの、熟練者は大きさ情報と形状情報を分離して評価し、その結果を的確に融合する能力を有すると考えられる。

このように形状情報の評価に大きさ情報の評価を独立に組み合わせることは、判別精度の改善に貢献するが、大きさ情報の評価を導入するにあたり、注意すべき点がある。たとえば葉形判別では、葉齢や葉位によって同一個体内でも大きさが著しく異なることがある。このとき、大きさ情報を組み合わせることによって、逆に判別を誤ることを考慮しなければならない。したがって、材料の種類や収集方法によっては、大きさ情報を除いて、形状情報のみ評価する必要がある。本研究で開発した判別モデルならば、最初から形状情報と大きさ情報とを分離して扱うため、いずれか片方の評価から判別結果を得ることも、双方の評価を統合化して判別結果を得ることもできる。

大きさ情報以外に独立に評価すべき項目、たとえば、色や表面のきめなどの情報が新たに加わったとき、それらの評価結果も同じように統合するよう、判別モデルを拡張できる。その拡張によって、誤判別率をさらに改善できると予想される。

本章で提案した判別モデルでは、誤判別率の動きを調べるために定数  $\alpha$  を導入した。上で述べたように、誤判別率を最小にする  $\alpha$  値は、使用した大きさ情報の判別における重要さを示す一つの指標である。 $\alpha$  値の変化にともなう誤判別率の変化から、大きさ情報は判別に有効であるが、大きさ情報に基づく評価だけでは誤判別率が高くなり、形状情報の評価と組み合わせるのが効果的であることがわかった。

誤判別率を最大限改善するには、 $\alpha$  値の設定が重要である。しかし、最適な  $\alpha$  値は、種数、大きさ情報の種内および種間変異などに応じて異なり、正確に求めるのは困難である。今後は、自動的に  $\alpha$  の最適値を定めるアルゴリズムの開発が必要である。クロスバリデーション、あるいはニューラルネットワークや遺伝的アルゴリズムを利用するなどの工夫が考えられる。

大きさ情報の選びかたには、普遍性や計測の手に間に配慮し、生物学的な背景や知識が必要なく、簡単に計測できるものを選択した。ゆえに、多大な計算コストを必要とせずに拡張でき、本章で拡張した判別モデルも対象によらず、汎用的に利用できるものであるといえる。

本章で拡張した判別モデルは、種数が多いときには改善の効果が出にくく、また適当な  $\alpha$  値を決

定するのが困難であるが、もとの画像入力ニューラルネットワークに手を加えることなく、その出力に大きさ情報の評価を合成したことで、誤判別率を大きく改善でき、その有効性を示せた。そして、形状情報と大きさ情報とを独立に扱うことが、植物形状判別における目視判断をより正確に行ううえで重要であることが明らかになった。

## 4.5 まとめ

本章では、カエデ葉形による種判別を例にとり、形状情報と大きさ情報とを独立に評価して総合的な判別を行うよう、第1章で構築した形状情報のみ評価する画像入力ニューラルネットワークに基づく判別モデルを拡張した。その結果、たとえば10種の判別では20.2%から9.6%へと誤判別率を大きく改善でき、形状情報とは独立に評価することによって大きさ情報が判別に有利に働いたこと、形状情報と大きさ情報とを独立に評価することの重要性とがわかった。使用した大きさ情報は、対象によらず普遍的であり、かつ計測が容易にできるため、画像入力ニューラルネットワークに基づく判別モデルが有していた汎用性は失われていないと考えられる。そして、本章で提案した判別モデルの拡張によって、画像入力ニューラルネットワークを基本とした、統合的な判別システム構築の可能性が示唆された。