

第6章 総合考察

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形状特微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えるために、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た。したがって、形状情報のみを評価する植物形状判別モデルが構築できたといえる。さらに、形状情報とは独立に評価した大きさ情報と組み合わせて、総合的な判別を行うよう拡張した判別モデルは、さまざまな対象に適用できる汎用性を失わずに、誤判別率を改善できる有効性をもつ。したがって、植物育種における形態評価や遺伝資源における特性調査での、植物形状に対する目視判断を支援・代替するシステムの根幹をなす判別モデルが構築できたと結論できる。

6.1では、植物形状の判別問題へのニューラルネットワークの応用の是非について、これまでの結果をまとめながら考察する。**6.2**では、**6.1**の考察を踏まえて、本判別モデルの有効性と汎用性について論じ、**6.3**では、判別における形状情報と大きさ情報とのかかわりについて、**6.4**では、本判別モデルの実用化による目視判断への効果を、問題点を含めて考察し、**6.5**では、目視判断が行われる現場だけでなく、目視判断に関する研究における本判別モデルの展望を述べる。

6.1 植物形状の判別問題へのニューラルネットワークの応用

ニューラルネットワークの応用を実用化するには、

- (1)-1 注目している問題がニューラルネットワークで解けるか確かめること、
- (1)-2 その問題にふさわしいニューラルネットワークの諸設定を見いだすこと、

の二つの段階が必要であり (Dayhoff, 1992)，それらは区別されるべきである。(1)-1 の事項は、学習可能性と深くかかわり、本研究では、適当な学習条件を設定すれば、判別可能であるという結果を得た。条件つきではあるが、植物形状の判別問題は、ニューラルネットワークで解けることがわかった。(1)-2 の事項については、汎化能力にかかわり、誤判別率と学習条件との関連を調べることによって評価した。植物形状判別のための画像入力ニューラルネットワークにおけるふさわしい諸設定については、次のような知見が得られた。

教師データの入力パターンについては、正規化された形状から作成された形状分布 (**1.2.2.2**, **3.4.1.1** 参照) が、すべての判別実験を通じて汎化能力において (線形ニューラルネットワークに対しては学習可能性においても), 教師データの入力パターンとして優れていた。入力画像サイズは、

ネットワークアーキテクチャによって、適切な大きさが異なった。線形のニューラルネットワーク（**1.4.1**, **1.4.2** 参照）においては、64 画素×64 画素が、非線形の多層パーセプトロン（**1.3.1** 参照）においては、16 画素×16 画素が、最適であった。入力画像サイズは、ネットワークアーキテクチャの特性によって設定すべきであろう。

ニューラルネットワークのアーキテクチャおよび構造については、植物器官形状による判別では、すべての材料で 64×64 の入力素子をもつ単純パーセプトロンが最適と判断された。その根拠は、学習や判別処理の速さ、汎化能力の高さだけでなく、構造の決定しやすさ、内部パラメタ決定の必要性である。ただし、草姿の判別では、汎化能力からは、最適なネットワークアーキテクチャや構造を決定することはできなかった。しかし、学習や判別処理の速さ、構造の決定しやすさ、内部パラメタ決定の必要性から、単純パーセプトロンが最適であると判断した。

本研究でとりあげた以外にも、さまざまなアーキテクチャや学習則をもつニューラルネットワークが提案されている（阿部, 1995c）。たとえば、教師なし学習を行うもの、クラス数を自動的に決定するもの、帰還回路をもつ非線形構造、複数のニューラルネットワークを縦列または並列に接続したアーキテクチャなどであり、植物形状の判別をはじめとして広範な応用が期待される。今後、このようなネットワークアーキテクチャの植物形状判別への適用を検討すべきであろう。

誤判別率については、植物器官形状による判別では、最適な学習条件（64 画素×64 画素の形状分布を教師データの入力パターンとした単純パーセプトロン）のもとで、良好な結果が得られた。そのとき、一つ抜き法による 10 クラスの誤判別率は、雑草種子粒形では 0.063、カエデ葉形では 0.202 だった。ここに大きさ情報を組み合わせると、それぞれの一つ抜き法による誤判別率は、0.033, 0.096 に改善された。ダイズ草姿の判別では、複雑な変異を有する形状であるにもかかわらず、上と同じ学習条件で、3 クラス（“並”と“悪”とを合わせて“不良”のクラスとした場合）の判別で、0.212 という十分低い一つ抜き法による誤判別率を達成できた。さらに、大きさ情報を組み合わせると、0.147 に改善された。

いずれの判別実験においても、画像入力ニューラルネットワークの教師データへのオーバフィッティングは、常に考慮しなければならない重要な問題であった。したがって、オーバフィッティングを防ぐために、ネットワークアーキテクチャや構造の決定方法、学習方法に工夫が必要である（Sarle, 1997）。

6.2 画像入力ニューラルネットワークに基づく植物形状判別モデルの有効性と汎用性

6.1で述べた結果と考察とを踏まえて、本節では、画像入力ニューラルネットワークの有効性と汎用性、問題点について考察する。6.2.1では、まず、植物形状から抽出された数値データに基づいて植物形状を判別することの本質的問題について、6.2.2では、画像を入力する判別モデルの有効性と汎用性とを、6.2.3では、ニューラルネットワークに基づく判別モデルの有効性と汎用性とを、それぞれ問題点も挙げながら論じる。

6.2.1 植物形状の判別における本質的問題

形状特微量にせよ画像にせよ、植物形状がいくつかの変数で表されているのならば、一つの植物形状は、変数である形状特微量や各画素の輝度を軸とする超空間（以下、この超空間をパタン空間と呼ぶ）のなかで一つの点として表される。通常は、変数の間に相関があるので、パタン空間は、それぞれの植物形状を表現するのに冗長である。パタン空間のなかで、形状の類似度に応じて、相対的な位置関係を保つような部分空間を見つけることが、この判別問題を解くことと同値である（小川、1994）。

このように考えると、判別モデルには、パタン空間から判別問題の解である部分空間を切り出すために、変数変換して新しい軸を生成する規則が含まれているといえる。本研究では、そのような部分空間が存在すると暗黙のうちに仮定して、判別モデルの開発に取り組んできた。しかし、実際には、この仮定が成立して初めて、判別モデルが意味をなす。第1章～第3章で論じてきた学習可能性について顧みれば、教師データを判別できるような部分空間を判別モデルによって記述できたときに、学習が可能であったのである。

6.2.2 画像を入力する植物形状判別モデルの有効性と汎用性

本判別モデルの最大の特徴は、形状特微量を必要としないことである。

植物形状を完全に表現するための超空間があるとすれば、それは無限の次元をもつと考えられる。判別モデルを組み立てるには、無限の次元は扱えないため、有限次元の数値データを抽出しなければならない。このとき、形状特微量を抽出すれば、構築されるパタン空間の次元は形状特微量数と等しくなり、画像を取得すれば、画素数と等しくなる。そして、判別に適する部分空間の探索は、それぞれ抽出された次元のパタン空間の内部で行われる。すなわち、形状特微量に基づく判別モ

ルでは、少ない次元のなかで部分空間を探索しなければならないため、おのずと判別モデルの性能にも限界が生じる。一方、観察の対象のもつパタン空間をできるだけ忠実に保った画像ならば、求めるべき部分空間の探索範囲を狭めることができなく、よりふさわしい部分空間を見いだせる可能性が広がる。したがって、判別問題を解くという本質に迫るには、形状特微量を抽出・選択するよりはむしろ、画像、あるいはそれに代わる形状を忠実に表現できる変数の集合を扱う必要がある。

判別モデルのもつ標準の形状と判別モデルに入力された形状とが、わずかしかちがわなくとも、そのちがいが形状特微量に大きく響いた場合を例にとると、この必要性を具体的に示せる。欠刻のある葉形では、植物体のどの位置にあるかによって、欠刻数が異なる現象はしばしば見られる。このようなとき、標識点 (landmark ; 葉の裂片の先端および基部に該当する点) に基づく、欠刻のある葉形の判別モデル (Carneiro and Lima, 1987; McLellan, 1990; Im *et al.*, 1998; Dickinson *et al.*, 1987) では、対処できないか、まったく誤った結果を示す。このように、形状の小さな変異が形状特微量に大きく影響したとき、形状特微量に基づく判別モデルでは適合できない場合がある。一方、第1章および第2章で示したように、画像入力ニューラルネットワークでは、同一クラス内で欠刻数や切れ込みの入りかたが不規則に変化するカエデ葉形、クワ葉形、カラシナ葉形にも、適用できた。このように、画像を入力する判別モデルは、形状のもつ情報をできるだけ多く利用することによって、植物形状のクラス内変異に対して頑健になりえた。

また、画像を入力する判別モデルが構築されれば、形状のもつ情報のほぼ全体を扱う仕組みをもつため、その内部構造を解析することによって、新たな判別要因が発見できる可能性があり、新しい判別方法を提案するという発展が期待できる。ただし、判別モデルが理論的には解析可能であっても、情報を引き出す作業は、現段階では構造の複雑さや膨大なパラメタによってきわめて困難である。

一般的に、画像のように、教師データ数に対して入力変数が多すぎる場合、判別モデルの性能は落ちる。形状特微量を抽出するなど、入力変数の次元を落とすことは、計算コストの低減、判別モデルの簡素化や可読性などの面から有利なだけではなく、判別モデルそのものの性能を上げる効果があると報告されている (浜本, 1994)。さらに、形状特微量を利用した植物形状の判別モデルでは、必ず、事前にデータ解析を行って判別精度がよくなるように形状特微量を抽出・選択している。それゆえ、良好な判別結果を導くことを可能とした。実際、0.1 以下という小さい誤判別率を達成した報告も少なくない (Chen *et al.*, 1989; Zayas *et al.*, 1989; Liao *et al.*, 1993; Rigney and Brusewitz, 1993; Ding and Gunasekaran, 1994; Liao *et al.*, 1994; Chtioui *et al.*, 1996; Ghazanfari *et al.*, 1996; Zayas *et al.*, 1996)。画像入力ニューラルネットワークからの誤判別

率は、それらと比較すれば、低くはない。画像は有用でない情報、すなわち雑音を含む可能性が大きい。変数選択を行っていないことを考慮すれば、入力変数の多さや含まれている可能性のある雑音の影響で、判別精度を上げにくいのは、当然の結果であるといえるだろう。

上述したように、形状特徴量を用いることによって、データ処理が簡素化され、判別モデルの可読性が高められることがある。たとえば、Travis and Draper (1985) は、面積と尖り度 (thinness ratio) のわずか二変数で、いくつかの作物および雑草の種子を分離できることを示唆した。すなわち、種子粒形の判別問題を、二変数によって表現される平面上での判別問題に帰着させたことになる。逆に、画像を入力する判別モデルは、内部構造がブラックボックス化しやすく、その中間プロセスや判別要因などが不明瞭になりがちであることが問題視されることがある（池田と齊藤、1993）。しかし、判別モデルがブラックボックス化する点については、判別問題を解くという本質においては、考慮しなくてもよいことであると考える。判別問題の最適解である部分空間を見つければ、それを記述するために適當な軸を設定する必要があるが、軸のとりかたは無限にある（小川、1994）。軸を、人間にとて直感的にわかりやすい尺度に一致させるか否かは、判別問題を解くうえで本質ではない。

このように、入力変数の次元を落とした形状特徴量には、判別モデルの性能を向上させるという利点がある。しかし、植物形状の判別を行う問題の本質に接近することを考慮すると、形状のもつ情報をできるだけ保持するような数値データを扱うことが必要である。画像は、その条件を満たした、数値データによる植物形状の記述方法であり、本研究では、その画像をニューラルネットワークを用いて、適確に扱えたと結論できる。

そもそも、形状特徴量に基づいて開発された判別モデルは、筆者の知る限り、形状特徴量を用いて形状の変異を記述する手法の延長にすぎないため、形状特徴量を用いて形状をどのように記述するかが中心の問題となる。したがって、上述の最適解である部分空間を見つけるという判別問題とは、性質がまったく異なると考えられる。これら二つの問題は、区別して考えるべきである。

植物形状を判別する問題と、形状特徴量を用いて植物形状を記述する問題とをすり替えている限り、形状特徴量に基づく判別モデルのもつ、対象ごとに新しい判別モデルを開発しなおさなければならぬ問題は解決しないと思われる。なぜなら、植物形状の記述に有効な形状特徴量は、対象によって異なるからである。たとえば、ダイズ葉形の判別には、縦横比が主な要因であり (Sawada, 1992)，欠刻のあるカエデ葉形の判別では、標識点を結ぶ線分の長さや角度に注目することになる (Im *et al.*, 1998)。すなわち、形状特徴量の選択は、対象や分類群に依存して、場当たり的に行わなければならない。また、用いる形状特徴量が異なると、それらをうまく利用するためのアルゴ

リズムも異なってくる。たとえば、Gerber and Les (1994) は、面積などの形状特微量を線形判別関数で扱えたのに対し、Jensen (1990) や Ray (1992) は、標識点特有の解析方法を開発した。このように、異なる対象には、異なるアルゴリズムを場当たり的に用意しなければならない。したがって、形状特微量で形状を記述し、それをもとに判別モデルを開発することは、非効率的である。

一方で、画像入力をもつ判別モデルは、形状特微量を必要としないため、そして、形状特微量で形状を記述することを放棄したために、一つのモデルでさまざまな応用が可能であるという汎用性をもつことができた。このことは、画像入力ニューラルネットワークがさまざまな植物器官や草姿の判別に適用できたことから、立証されている。そもそも、形状特微量の必要性をなくし、形状のもつ情報全体を利用するため、画像を入力する判別モデルを設計した。しかし、植物形状の判別という問題の本質を考察したとき、画像を入力する判別モデルの開発はその本質へも接近できる方法の一つであることが明らかになった。

6.2.3 ニューラルネットワークに基づく植物形状判別モデルの有効性と汎用性

ニューラルネットワークが各種植物形状の判別モデルとして有効に働くことは、Davis (1991), Liao *et al.* (1993), Yang (1993), Ding and Gunasekaran (1994), Steinmertz *et al.* (1994), 甲斐ら (1995a-b), 曹ら (1996), Ghazanfari *et al.* (1996), 永田ら (1996), 曹と永田 (1997) が実証した。Ninomiya *et al.* (1994), Chtoui *et al.* (1996), 生出ら (1996) は、線形判別関数やファジィ論理に基づく判別ルールとの比較を行っており、ニューラルネットワークが前者に比べて優れているか同程度の性能をもつと結論した。これらの研究で、ニューラルネットワークについて議論された点は、次のとおりである：

- (2)-1 入力データに分布を仮定する必要がない,
- (2)-2 教師データ数のわりに入力変数が多い場合にも適用できる,
- (2)-3 学習によって判別能力を獲得できるため、ファジィ論理に基づく判別ルールのような特定のアルゴリズムを入手で開発する必要がない,
- (2)-4 構造の拡張が容易で、教師データの変更にともなう内部パラメタの修正も容易である,
- (2)-5 非線形計算ができ、クラス境界の設定に関して制約が少ない,
- (2)-6 オーバフィッティングとアンダフィッティングとを同時に回避する構造を決定するのが難しい,
- (2)-7 汎化能力を高めるための教師データの選択方法が難しい,
- (2)-8 ブラックボックス化しやすい,

(2)-9 計算コストが大きい。

ニューラルネットワークそのものに関しては、本研究でもこれ以上の知見は得られなかった。

しかし、本研究で最適な学習条件をもつ画像入力ニューラルネットワーク（形状分布を教師データの入力パターンとした単純パーセプトロン）は、上記(2)-6～(2)-9の問題点を解決している。すなわち、ニューラルネットワークの構造は、入力画像サイズとクラス数とから自動的に定めることができる。学習も判別処理も線形計算であり、動作が明瞭であるばかりでなく、双方の処理における計算コストは十分低い。(2)-6, (2)-8, (2)-9については、カエデ葉形による種判別の結果から**1.5.2**で述べたとおりであり、ここでの詳しい説明は省略する。

ここでは、(2)-7の汎化能力を高める教師データの作成方法について論じる。教師データとして利用できるサンプルが無限にあり、それを学習できるニューラルネットワークが存在すれば、汎化能力の無限に高いニューラルネットワークを構築できるだろう。しかし、現実には、教師データ数は有限であり、外れ値であるデータを検出できないこともありえる。教師データから雑音を完全に除くことができない以上、教師データ数の増加にともなって、学習は難しくなる一方である。このような状況で、どのように教師データを選択すべきかは、ニューラルネットワークの設計に當つまとう問題である。ここで筆者の結論を先に述べると、教師データを選択する必要はなく、各クラスごとに形状分布（**1.2.2.2**, **3.4.1.1** 参照）を作成すればよい。

形状分布も平均形状（**1.2.2.2** 参照）も、定義は異なるがどちらももとの形状から作成された画像である。一方、ダイズ草姿の判別に教師データとして用いた典型的形状（**3.3.1.1** 参照）は、もとの形状そのままである。

画像入力ニューラルネットワークに高い汎化能力を与えるには、教師データが、判別される実際の形状をよく反映する必要がある。教師データとテストデータの性質が異なれば、汎化能力は低いと見なされる。

したがって、もとの形状の画像を教師データの入力パターンとした訓練によって高い汎化能力を得るならば、各クラスの特徴をよく表す典型的な形状か、教師データ数をできるだけ多くとるかしなければならない。しかし、典型的な形状を的確に選択するのは困難である。教師データ数を多くすると、とくに線形ニューラルネットワークでは、学習の収束が悪くなる。そして、外れ値の形状が教師データに選択されてしまうと、画像入力ニューラルネットワークの汎化能力が著しく低くなる。

一方、クラス内平均の形状は、平均をとることによって外れ値からの影響が緩和され、かつ、判別される形状をよく反映した教師データとなりえる。教師データ数も判別クラス数と同数ですむ。したがって、教師データの入力パターンにクラス内平均を用いるのは、学習可能性の向上とともに、

汎化能力の高い画像入力ニューラルネットワークの構築に役立つと考えられる。

クラス内平均がニューラルネットワークの教師データにふさわしいという議論は、判別モデルへの入力が画像であるからこそできる。入力が形状特徴量の場合、クラス内平均をとると、それはパターン空間においてクラスの代表点に簡約されてしまう。すなわち、入力変数のクラス内の分布の情報は平均値だけになり、分布の範囲の広さや歪み具合などの情報は切り捨てられる。したがって、形状特徴量のクラス平均を教師データに採用するとき、この教師データがクラスの特徴を十分に反映しているとは考えにくい。一方、判別モデルへの入力が画像の場合を考えると、形状分布ならば、パターン空間においてはやはりクラスの代表である一点にすぎないが、クラス内変異を表現できるという点で、クラス内のデータの特徴が反映されているといえる。このように、優れた教師データを作成し利用できるという側面においても、画像入力ニューラルネットワークは有利である。

さて、植物器官形状を正規化するために使用した標準化橢円フーリエ係数は、さまざまな葉形や粒形の変異を定量的に表現できる輪郭形状の記述子として提案され応用された（二宮ら, 1994; Furuta *et al.*, 1995; Yoshida *et al.*, 1995; Hadipoentyanti *et al.*, 1996; 北浦ら, 1997; Ohsawa *et al.*, 1998）。標準化橢円フーリエ係数で記述された輪郭形状は、形状に関する情報を取捨選択しておらず、その性質は、形状特徴量よりはむしろ画像に近いといえる。その意味では、標準化橢円フーリエ記述子を入力とする判別モデルを構築すれば、画像入力ニューラルネットワーク同様、汎用性の高いものとなることが期待できる。

しかし、判別効率を上げるための教師データの作成方法を考えると、標準化橢円フーリエ係数の場合にも、形状特徴量の場合と同様、クラス内の特徴をよく反映する教師データを作成あるいは選択するのは容易ではない。この点において、判別モデルの入力として、画像が標準化橢円フーリエ記述より優れていると考えられる。

6.3 判別モデルにおける形状情報と大きさ情報とを独立に評価する重要性

本研究では、形状情報と大きさ情報を独立に評価した。この両者を独立に評価する意義については、第5章で論じたが、ここで簡単にまとめる。

大きさ情報は、形状情報とならんで判別の重要な手がかりとなる。たとえば, Travis and Draper (1985), Ingrouille and Laird (1986), Carneiro and Lima (1987), Chen *et al.* (1989), Zayas *et al.* (1989), McLellan (1990), 南ら (1991), Ninomiya and Shigemori (1991), Guyer *et al.* (1993), Heinemann *et al.* (1994), Liao *et al.* (1994), Ninomiya *et al.* (1994),

Molvray and Kores (1995), Woebbecke *et al.* (1995a-b), Chtioui *et al.* (1996), Ghazanfari *et al.* (1996), Zayas *et al.* (1996), Ambuel *et al.* (1997), Cho *et al.* (1997), Warren (1997), Im *et al.* (1998) は、各種植物形状の判別を行い、大きさ情報の判別に対する重要性を示した。

しかし、**1.5.1** で述べた大きさを含むカエデ葉形の判別の結果からわかるように、画像入力ニューラルネットワークに基づく判別モデルでは、大きさ情報を含んだままの画像を精度よく判別できない。クラス間での大きさの変異が大きい場合、画像入力ニューラルネットワークは、主に大きさに依存してクラスの境界を設定してしまう。したがって、クラス内の大きさの変異がクラス間の変異を越えるとき、判別を誤ることになる。上で挙げたの研究でも、形状情報と大きさ情報を混在させたまま扱っている以上、形状情報を正しく評価できてはいないと思われる。

したがって、本研究では、形状情報を正しく評価し、さらに大きさ情報の判別における重要性を活かすために、形状情報と大きさ情報を独立に評価して判別を行った。そのために、安定した判別精度が得られたと考えられる。ただし、**4.4** で述べたように、大きさ情報の評価を導入すべき場合とそうでない場合があり、注意を要する。

なお、**1.5.1** で例示したカエデ葉形の 2 種判別について再び考えると、画像入力ニューラルネットワークに基づく判別モデルでは約 1 割の葉形の判別を誤ったが、同じ 2 種を、たとえカエデの専門家でないとしても人間が判別すれば、まず誤ることはないと予想できる。このように、形状情報と大きさ情報を分離できずに同時に目に入ってきたときも、人間の目には、大きさからの影響を除いて形状を評価し、正しく判断する優れた機能があると思われる。

6.4 画像入力ニューラルネットワークに基づく植物形状判別モデルの実用化

画像入力ニューラルネットワークに基づく植物形状の判別モデルの実用化の具体的な事例については、**2.6**, **3.7**, **4.5** で述べた。ここでは、これらを通じて論じることとする。

本研究で提案した判別モデルが実用化されれば、Davenport (1907), Jensen (1988) が、目視判断による形状評価において指摘した次の問題点：

- (1)-1 評価者によって評価が揺らぐ,
- (1)-2 非熟練者の目視判断の正当性は、必ずしも信頼できない,
- (1)-3 多くの形質を、一度に総合的に評価することは難しい,
- (1)-4 比較対象のない絶対的な評価は精度が十分でない,

が解決される。そして、一貫性・信頼性のある判別結果が得られ、評価のノウハウを客観的に記述

でき、その蓄積・継承が可能になり、熟練者の支援や非熟練者の教育にも役立つ。また、判別モデルを開発することによって、目視判断のメカニズムに関する新たな知見の得られる可能性がある。ただし、熟練者の目視判断の即時性・省力性をも代替するのは、現存の技術では困難であると考えられる。**2.6** や**3.7** で述べたように、当面は、評価者の目視と判別モデルとの協調によって、より的確な判断を得るのが現実的であろう。このとき、両者の判別結果を比較検討することによって、目視と判別モデルとのそれぞれがどの点で優位に立ち、どの点を補完しあうべきかを知ることができ、さらに、判別モデルがどうあるべきか、どのように改善されるべきかが明らかになる。評価者側も、植物形状の判別における自らの長所と短所とを把握することができる。

実用化に関する、画像入力ニューラルネットワークに基づく判別モデルの今後の課題としては、

- (2)-1 学習していないクラスの植物形状が入力されたときは、それを確実にはじき出す。既存の分類群に判別すべきではない、
- (2)-2 判別の結果に対して、信頼性を自ら評価し、支援する評価者に示す仕組みが必要である、
- (2)-3 植物形状が判別のために入力されるたびに、画像入力ニューラルネットワークが自動的に学習できるようにする。教師データ集合を作成するためにわざわざデータ収集を行わなくても、自然とデータを蓄積する、

などがある。また、本研究では、目視判断における観察から判別までの一連の処理だけに焦点を当ててきた。しかし、本来は、その一連の処理が何度も繰り返されるだろうことを想定し、観察対象の認識や判断の後に起こされる行動などを含めて全体を見渡す能力が、判別モデルの設計者には必要であると考えられる。今後、判別モデルが必要とされる場面や評価者に対する役割を的確に見定め、評価者や他の機械が行う処理との連関を考慮すれば、画像入力ニューラルネットワークに基づく判別モデルのさらなる発展が期待できる。

6.5 画像入力ニューラルネットワークに基づく植物形状判別モデルの展望

画像入力ニューラルネットワークに基づく判別モデルの最大の利点は、形状特徴量を必要としないため、①対象ごとに判別モデルを構築しなければならないという問題を回避して、さまざまな対象にも汎用的に適用でき、②頑健性があり、安定した判別精度を提供することである。また、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、植物形状の判別問題の本質に接近するための一つの手段でもある。したがって、この判別モデルの適用範囲は、植物育種や遺伝資源の特性評価にとどまらず、作物の外観品質評価・検査、生育・病害診断、雑草の判別など広範な分野に拡張で

きると考えられる。さらに、判別モデルの拡張が容易である点にも着目すべきである。大きさ情報との組み合わせによって、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汎用性を失わずに判別精度を改善できたことを考えると、三次元形状や時系列的な各生育ステージごとの形状など多次元のデータへの応用や、材料の収集時期など形状以外の情報とも組み合わせ、データベースと統合化された判別システムへの発展も考えられる。このようなシステムの構築は、これまで目視判断に依存してきた作業の効率化・省力化を促進するだけでなく、評価者とシステムとが補完し合い、役割を分担する方法を見いだす。一方で、評価者の目視判断のメカニズムを解明するという、新たな問題を提起すると同時に、その解決への糸口をも示すだろう。

画像入力ニューラルネットワークに基づく植物形状の判別モデルには、解決すべき問題が残されている。しかし、本研究では、植物形状の目視判断の定量化の基礎を築き、人間と判別モデルとが互いに能力を補完するための方向性を見い出せたといえる。これは、植物育種や遺伝資源の特性評価をはじめとする農業・農学の多方面の分野において、目視判断に頼らざるを得なかった植物形状の判別方法に大きな発展をもたらすと考えられる。