

緒言

背景

植物育種や遺伝資源の特性調査において、個体間あるいは集団間の形質の変異を知るために、植物の葉形、粒形、草姿など各種形状が評価されている。このような植物形状の評価は、目視判断に頼ることが多い。本節では、本研究の背景として、はじめに植物形状評価の重要性について述べ、次に植物形状評価のための目視判断の問題点を指摘し、最後にその問題点を解決するための手段として目視判断の定量化の概念を説明し、その意義を論じる。

植物形状評価の重要性

植物育種における形態評価やそれに基づく選抜、あるいは遺伝資源の特性調査では、植物の葉形、粒形、草姿など植物の各種形状に基づいた評価が行われ、形質の変異を知るうえで重要な役割を担っている。

植物育種の目的は、農業生産において有益で優良かつ均質な特性を遺伝的にもつ栽培作物を創り出すこと、すなわち、栽培が容易で、収量が多く安定的で、品質がよく、収益の高い作物を創り出すことである。作物の各種形状は、この優良性に直接または間接にかかわっている。収穫される葉、果実、種子などの器官の形状は、流通機構からの要求や消費者の嗜好などに基づいて評価される外観品質の一つである (Cheng *et al.*, 1996)。草型・草姿も、受光態勢、ガス交換の調整、耐寒性、耐倒伏性、雑草との競争の強さなどの面から、収量や栽培管理・収穫方法に対する適応性に密接な関連をもち (Ud-Din *et al.*, 1993)、重要な評価対象となっている。これらの形状の変異は、その植物が遺伝的にもっている特性と、気象、土壌、栽培方法、他の生物との相互作用などの生育環境に対する反応とが絡み合った結果として現れる。このなかから、遺伝的背景をもつ変異の優良性を知るには、的確な評価が必要となる (角田と中川, 1974; 松尾, 1978)。

また、遺伝資源の探索・収集は、系統関係を推定したり、栽培植物の起源や伝播の道筋を推測したり、あるいは育種の目的に適合した新しい有用な変異を導入したりすることを目的に行われる。これらの各作業においても、遺伝と環境の二つの背景からの作用がいらまじった変異のなかから、遺伝的な特性を見きわめる必要がある。そのために、さまざまなアプローチがとられており、たとえば、細胞遺伝学的方法、ゲノム・核型・遺伝子の分析、生化学的方法などがある。そのなかで、

もっとも最初にとられる方法が、即時性があり、多くの場合対象を非破壊のまま扱える形状に基づく手法である（田中ら，1989）。

このように、植物の形状の的確な評価は、植物育種や遺伝資源の特性評価において、個体間や集団間の変異を知るうえで、きわめて重要な役割を果たす。

植物形状評価のための目視判断

これまで、植物形状の評価には、目視判断が不可欠だった。実際、熟練者の目視判断は、長さや重さなどの物理量を測定するよりも省力的で効率がよく（Peterson *et al.*, 1989）、その正当性が信頼できる（Stuthman and Steidl, 1976 ; Salmon and Larter, 1978 ; Ram *et al.* 1998）と報告されている。

しかし、Jensen（1988）は、熟練者の目視判断を完全に代替できる手段はないと結論しながらも、目視判断に問題があることを指摘し、その解決策を提案した。その問題点とは次の事項である：

- (1)-1 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)-2 熟練者と非熟練者との間だけでなく、熟練者の間でも、評価者によって評価が揺らぐ、
- (1)-3 量的形質を、遺伝的変異と環境変異とに分離することは難しい、
- (1)-4 複数の形質を、一度に総合的に評価することは難しい、
- (1)-5 熟練者が行う、比較による相対的な評価は正確であるが、比較対象のない絶対的な評価は精度が十分でない。

上記問題に対して提案された解決策は、次の事項である：

- (2)-1 独立した複数の評価者が同じ材料を評価し、その結果を統合して判断を行う、
- (2)-2 異なる生育環境からサンプルを収集するため、複数の地点・年次で同じ材料を栽培する、
- (2)-3 複数の形質を総合的に評価する手法を導入する、
- (2)-4 評価者が、評価の標準を常に参照する。

そして、自分自身の目視判断の長所と短所を理解し、評価に偏見をなくし、客観的な判断が行えるよう、評価者が常に自分を試験し訓練する必要があることに言及している。Davenport（1907）もまた、判断が一貫するよう、評価基準を明確にすべきであると述べた。

しかし、(2)-1～(2)-4 の解決策は、(1)-1～(1)-5 の問題を緩和するだけであり、根本的な解決とはいえない。逆に、目視判断における解決困難な問題点：

- (3)-1 観察、評価、判断の一連の過程における各段階の具体的方法や相互関係のすべてを客観

的に記述することができるわけではなく、記述できない部分については継承が困難であり、目視判断に熟練するのは容易ではないこと、

(3)-2 熟練者でさえ、正しい評価のためには、絶え間ない努力が必要であること、

(3)-3 評価者が支援を必要とするとき、熟練者の主観以外に頼るものがないこと、

を示していると思われる。さらに、目視判断の問題として指摘されている、大きさなどからの作用により、形状に対して誤った判断を下す可能性があることも、考慮する必要がある。

植物形状における目視判断の定量化の意義

植物育種や遺伝資源の特性評価では、植物の遺伝的変異を把握するために、植物の各種形状を的確に評価する必要があるにもかかわらず、そのための目視判断には、

(1)-1 作業効率や精度が評価者の熟練度に依存する、

(1)-2 目視判断に熟練するのは容易ではない、

(1)-3 熟練者による判断でも精度、一貫性や客観性が常に保証されているわけではない、

(1)-4 複数の形質を独立に評価して、総合的な判断を行うのは、困難である。とくに、大きさの影響を受けて、形状を見誤ることがある、

という問題がある。熟練者の観察から判断までの視覚情報処理過程を完全に解明できれば、その過程を忠実に再現したシステムで目視判断を代替することにより、目視判断におけるこれら問題点がすべて解決されるだろう。

しかし、そのような視覚心理学的あるいは認知科学的な問題解決へのアプローチは、当面は現実的ではない。より現実的な解決手段は、観察の対象から導かれた客観的な判断を行い、目視判断を支援・代替するシステムを構築することである。これにより、

(2)-1 目視判断の作業効率や精度が一定し、一貫性や客観性が保たれ、

(2)-2 非熟練者でも、効率よくかつ精度よく判断できるようになる。

同時に、次の利点も生じる：

(2)-3 各形質を分離して独立に評価できる。また、それぞれの評価を統合して、総合的な判断が行える、

(2)-4 植物形状の評価に関する知識が記述でき、知識の蓄積や共有・継承が可能になる。

ここで、客観的な判断とは、観察の対象である植物形状から抽出した数値データの処理によって

導かれた判断を意味する。植物形状と正しい判断との組の集合が与えられたとき、判断を要求されている植物形状から、数値データの処理に基づいて目視判断と同じ結果を導けるようにするには、データ処理法は次の手順に従って開発される：

- (3)-1 植物形状を計量して、数値データを得る、
- (3)-2 判断の結果が数量でない場合、たとえば分類群である場合は、分類群に番号を付すなどして、あらかじめ判断の結果も数値で表現できるようにしておく、
- (3)-3 植物形状から抽出した数値データを入力したとき、正しい目視判断と同じ結果を出力するようなアルゴリズムを求める、

本研究では、このように、観察の対象から判断の結果への対応関係を示すアルゴリズムを求めることを、植物形状からの数値データ抽出の手続きも含め、目視判断の定量化と呼ぶ。

本研究では、目視判断のうち、植物育種や遺伝資源の特性評価における植物形状の判別に焦点を当てる。判別とは、材料がどの分類群に属するのがふさわしいかを見わけることを意味する。以下、目視判断の定量化によって得られる、植物形状を判別する一連の手法を、判別モデルと呼ぶ。判別モデルは、目視判断を支援・代替するシステムの根幹をなす。判別モデルの概念図を図1に示す。

判別モデルの開発によって、さらに、次のような新たな知見の発見やその応用が期待できる：

- (4)-1 評価されている特性とその基準が明らかになる、
- (4)-2 これまで評価されていなかった判別要因が発見される、
- (4)-3 従来の評価方法に改善を加える、
- (4)-4 まったく新しい評価方法を提案する、

以上をまとめると、植物育種や遺伝資源の特性評価における植物の葉形、粒形、草姿など各種形状の判別のための目視判断には、精度、一貫性、客観性が十分でないなどの問題がある。それを解決するには、植物形状から数値データを抽出して処理し、客観的で精度の高い判別を行う、目視判断を支援・代替するシステムの構築が不可欠である。そして、このシステムの構築を実現するには、目視判断を定量化し、性能のよい判別モデルを開発する必要がある。

目的

前節では、植物育種や遺伝資源の特性評価における植物の葉形、粒形、草姿など各種形状の判別のための目視判断には、精度、一貫性、客観性が十分でないなどの問題があることを述べ、それを

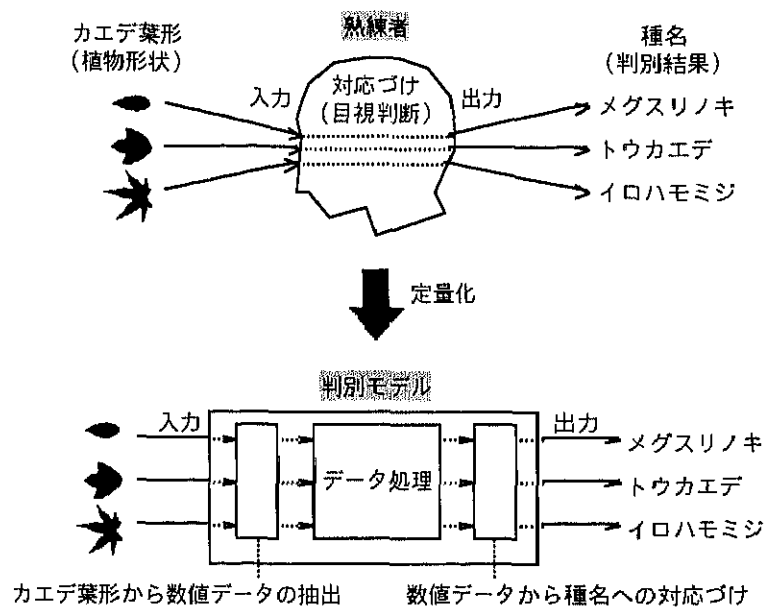


図1 カエデ葉形による種判別を例とした判別モデルの概念図

カエデ葉形から種を判別する熟練者の目視判断を定量化した判別モデルは、カエデ葉形が入力として与えられると、熟練者が判別したのと同じ種名を出力する。

解決するには、目視判断を定量化して判別モデルを構築し、判別モデルを使って植物形状から抽出した数値データに基づいた判別をする必要があることを述べた。これまでも判別モデルの開発は試みられてきたが、その多くは非効率的で精度の安定性に問題を含んでいる。そこで、本研究では、これまで提案されてきた判別モデルの問題を解決するために、新しい判別モデルを開発することを目的とする。本節では、はじめにこれまでの判別モデルに関する研究を概観し、次にその問題点を挙げ、最後に本研究における判別モデルの開発と検証の方法について述べる。

これまでの目視判断の定量化

目視判断の定量化の重要性は、システムを構築して、目視判断を支援・代替することにある。これまでも、目視判断を定量化する試みは盛んに行われており、ますますこの分野の研究の需要が高まると思われる。

これまで開発された判別モデルの多くは、植物形状からの数値データ抽出、数値データの処理、データ処理系の出力から分類群への対応づけからなる（図2）。

植物形状からの数値データ抽出は、材料から形状特徴量として物理量（長さ、面積など）を実測したり（図2①）、材料を撮像して（図2②）画像情報を抜き出したり（図2③～④）して行われる。画像を取得した場合、画像中から形状のシルエットなど必要な領域を切り出し（図2③）、そのシルエットから面積、周囲長、縦横比、円さ、輪郭情報などの形状特徴量の抽出を行う（図2④）。抽出された形状特徴量を、そのままデータ処理系の入力とする場合（図2⑤）と、さらに選択・抽出を繰り返す場合がある（図2⑥～⑧）。形状特徴量を選択するには、分散分析が多く用いられる（図2⑥）。形状特徴量からさらに、平均や分散などの統計量を抽出したり（図2⑦）、主成分を抽出して（図2⑧）そのなかからいくつかを選択したりすることもある（図2⑨）。形状特徴量または形状特徴量から抽出した数値データは、判別モデルにふさわしいアルゴリズムを求めるために用いられる。

データ処理系を設計する前に、あらかじめ、判断の結果である分類群を数量化しておく（図2⑩）必要があるが、適当に連番をふるなどして対応することが多い。この手法は、これまでほとんど検討されていない。データ処理系には、線形判別関数による判別分析、しきい値処理やファジィ論理を記述した判別ルール、クラスタ分析が主に利用されている（図2⑪）。

図2①～⑨で植物形状から抽出される数値データの流れに着目すると、面積、長さなどの大きさに関する情報と、縦横比、円さなど形状に関する情報とが混在したまま、同列に扱われることが多い。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.*

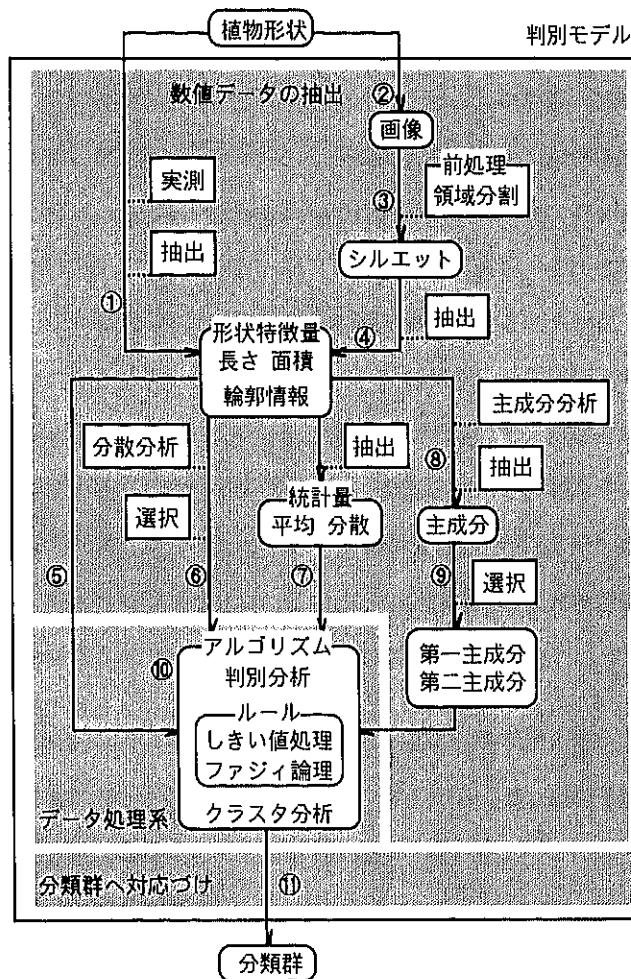


図2 植物形状からの数値データ抽出，数値データの処理，分類群への対応づけからなる判別モデル


①物理量の実測，②撮像，③シルエットの切出し，④形状特徴量の抽出，⑤形状特徴量の選択・抽出なし，⑥形状特徴量の選択，⑦統計量の抽出，⑧主成分の抽出，⑨主成分の選択，⑩データ処理，⑪分類群への対応づけ。

(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. これらの研究では, 形状情報, 大きさ情報ともに重要な判別要因であることを明らかにした.


しかし, 分類群間で大きさが著しく異なるとき, 形状情報が十分に評価されない恐れがある. たとえば, 図 3a に示した種間で大きさの異なる 2 種のカエデ葉形で, 相対的な大小関係を保ったまま種判別を行うことを考えると, 葉形も種間で大きく異なるにもかかわらず, 判別が大きさ情報に強く依存することになる. さらに, 大きさの種内変異が大きい (図 3b) ため, 大きさに強く依存した判別モデルでは, 精度が保証できない. このように, 形状情報と大きさ情報とが同列に扱われる判別では, これらの情報が相互に作用し, 正しい結果が得られないという問題がある.

図 2①~⑨で示した植物形状から数値データを抽出するまでの手続きを見ると, 植物形状の変異を定量的に記述する手法に等しい. 提案された判別モデルの多くは, 植物形状の変異の定量的な記述から, 分類群の境界を抽出することによって得られている. そこで, ここでは, 植物形状の変異を定量的に記述する手法について述べる.

植物形状から抽出される形状特徴量は, 材料の性質や判別目的によって, 各様に提案されている. たとえば, 単純に縦横比だけでも, 葉形や種子形状の変異を表現できることが示されている (Travis and Draper, 1985; Sawada, 1992; Takeuchi *et al.*, 1992; Wu, 1994). 種子形状の記述では, 面積, 長さ, 幅, モーメントも頻繁に利用され (Rigney and Bruswitz, 1993), 細胞の形状の記述でもほぼ同様である (Molvray and Kores, 1995; Cho *et al.*, 1997). 欠刻のある葉形では, 標識点間の位置関係がしばしば形状評価に利用された (Ingrouille and Laird, 1986; Carneiro and Lima, 1987; Dickinson *et al.*, 1987; Jensen, 1990; McLellan, 1990; Ray, 1992). 果実などの形状の記述では, 円さや曲がりに着目された (松田ら, 1991). 草型・草姿の変異の場合, 種子形状や細胞形状と同じように面積, 長さ, 幅, モーメントを中心にした形状特徴量に基づく記述 (南ら, 1991; Woebbecke *et al.*, 1995a-b) ばかりでなく, 茎, 葉, 花の各器官



(a) 2種のカエデの平均的な葉形と平均的な大きさ



(b) 葉形と大きさの種内変異

図3 大きさを含んだカエデ葉形の例

(a), (b) 上段はフランスモミジ, 下段はメクスリノキの葉形である.

の形状とともに相互の接続構造に立ち入った研究（山口, 1982 ; Oka and Hinata, 1988, 1989 ; Humphries and Simonton, 1993）もなされてきた。

以上の研究では、植物形状からの形状特徴量抽出によって、

- (1)-1 従来の定性的な形質の評価と形状特徴量との関連が明らかにされたこと、
- (1)-2 種や品種・系統の間、あるいは生息地の間などでの形状の変異を、数量で比較できたこと、
- (1)-3 形状の分類や判別への形状特徴量の応用の可能性を示唆できたこと、

などの有益さがもたらされることが示された。

画像から抽出した形状特徴量は、そのまま変異を記述するために用いられることがある（Jensen, 1990 ; Ray, 1992）。一方で、分散分析や主成分分析の結果から、形状特徴量の一部を選択して次元を落とすことが試みられた（Carneiro and Lima, 1987 ; McLellan, 1990 ; Rigney and Brusewitz, 1993 ; Wu, 1994 ; Woebbecke *et al.*, 1995a-b）。また、形状特徴量から新たな特徴を抽出することも検討され、たとえば、形状特徴量から平均、分散などの統計量を抽出したり（Gerber and Les, 1994 ; Cho *et al.*, 1997）、第一および第二主成分を選択したりした（Dickinson *et al.*, 1987）。Ingrouille and Laird (1986) は、コナラ属 (*Quercus*) の葉形による種判別において、標識点間の距離などを形状特徴量として、それらの選択・抽出法をいくつか比較検討し、形状特徴量の主成分を用いるのがもっとも変異の記述に有効であると結論した。

これらの研究では、形状特徴量をそのまま利用して、形状の変異の記述を効率的に行えることを示した。また、形状特徴量のなかから一部を選択したり、形状特徴量を加工して新しい特徴を抽出したりすることによって、変異の記述に有用な成分を見いだせることを示した。

以上のように、植物形状から抽出した形状特徴量に基づく変異の記述は、そこから目視判断の主要な要因を推定することができ、可読性が高く、計算コストも比較的少なくてすむ。植物形状の変異の記述には、形状特徴量が大いに貢献したことがわかる。一方、

- (2)-1 どのような植物形状を、どのような分類群で比較するかによって、変異の記述に利用する知識は異なる。したがって、材料となる植物形状やその分類群に依存して、人間がデータを解析して、記述に有用な形状特徴量を探索し、それを適確に利用できるようなアルゴリズムを開発する必要がある。したがって、開発された手法は、最初に与えられた材料の与えられた分類群間での比較にしか適用できない。新しい材料や分類群に対して、変異の記述が必要になったとき、再び手法開発の作業を繰り返さなければならず、非効

率的である,

- (2)-2 形状特徴量として抽出されなかった情報の中にも, 変異の要因が含まれる可能性がある.
それにもかかわらず, 抽出されなかった情報は捨てられ, 判別精度を改善するために有効に利用されることがない,

などにより, さまざまな対象に適用できる汎用性や判別精度の安定性に問題があった.

植物形状の変異を定量的に記述する手法の開発を目的とした研究でも, 判別モデルへの発展を考慮して, データ処理を行った研究がある. たとえば, 共分散分析 (Gerber and Les, 1994), クラスタ分析 (山口, 1982 ; Carneiro and Lima, 1987), しきい値処理やファジィ論理に基づく判別ルール作成 (Travis and Draper, 1985 ; Dickinson *et al.*, 1987 ; McLellan, 1990 ; Sawada, 1992 ; Wu, 1994), 標準との適合度による分類 (Jensen, 1990 ; Ray, 1992) が行われてきた. これらの研究では, 供試した植物形状が対応する分類群に精度よく分類されたと結論された. しかし, 未知の植物形状に対して, 同様に精度よく分類できるか否かについては, 検討されていない.

次に, 判別モデルを提案し, 未知の形状に対する判別精度の検討まで行った研究について述べる. これら判別モデルには, 植物形状の変異の定量的な記述から, 分類群間の境界を見いだせるようなアルゴリズムを求め, データ処理系からの出力と分類群への対応づけを行う手続きを付加して作成されたものが多い.

判別モデル構築のために植物形状から抽出された形状特徴量は, 上述の植物形状の変異を記述するために抽出されたものとほぼ同様である. たとえば, Chen *et al.* (1989), Zayas *et al.* (1989), Zayas *et al.* (1996), Ni *et al.* (1997), Travis *et al.* (1996) は, 種子や細胞の形状の判別に, 面積, 長さ, 幅, モーメントなどを利用した. Im *et al.* (1998) は, カエデ葉形判別において, 標識点間の位置関係を利用した. 福沢と早田 (1994), Heinemann *et al.* (1994), Singh and Delwiche (1994), Panigrahi *et al.* (1998) は, 果実などの形状判別で, 円さや曲がり具合に着目した. 草型・草姿の場合では, 面積, 長さ, 幅, モーメントを中心にした形状特徴量に基づく判別 (Ninomiya and Shigemori, 1991 ; Zhang and Chaisattapagon, 1995 ; Ambuel *et al.*, 1997) ばかりでなく, 上部から撮影した植物の画像を葉の集合体として葉形解析に帰着させた研究 (Guyer *et al.*, 1993 ; Franz *et al.*, 1991a-b) もあった.

画像から抽出した形状特徴量は, そのままデータ処理系の設計のための入力になることが多い (Chen *et al.*, 1989 ; Zayas *et al.*, 1989 ; Franz *et al.*, 1991a ; Guyer *et al.*, 1993 ; Heinemann *et al.*, 1994 ; Singh and Delwiche, 1994 ; Zhang and Chaisattapagon, 1995 ; Zayas *et al.*,

1996 ; Travis *et al.*, 1996 ; Ni *et al.*, 1997 ; Warren, 1997 ; Zhang *et al.*, 1997 ; Im *et al.*, 1998 ; Panigrahi *et al.*, 1998). 植物形状の変異を記述する手法を設計するときと同様に, 形状特徴量から平均, 分散などの統計量を抽出し (Franz *et al.*, 1991b ; Shibata *et al.*, 1998), 抽出した新しい特徴をデータ処理系の設計に利用した研究もなされた.

以上のような判別モデルは, 形状特徴量に基づいているため, 上述の植物形状を定量的に記述する手法と同様の利点と問題点とをもつ. 利点は, 目視判断の主要な要因を推定することができること, 可読性が高いこと, 計算コストが少ないことである. 判別精度も高く, 0.1 以下という低い誤判別率を達成した判別モデルも少なくない. 問題点は, (2)-1~(2)-2 で述べた, 対象ごとに開発しなおさなければならないこと, 形状特徴量として抽出されなかった情報が欠落することである.

形状特徴量を処理するアルゴリズムに着目すると, 線形判別関数を中心とした判別分析 (Chen *et al.*, 1989 ; Zayas *et al.*, 1989 ; Franz *et al.*, 1991b ; Ninomiya and Shigemori, 1991 ; Singh and Delwiche, 1994 ; Zhang and Chaisattapagon, 1995 ; Travis *et al.*, 1996 ; Zayas *et al.*, 1996), クラスタ分析 (Zhang *et al.*, 1997 ; Panigrahi *et al.*, 1998), しきい値処理やファジィ論理に基づく判別ルール (Guyer *et al.*, 1993 ; Heinemann *et al.*, 1994 ; Ambuel *et al.*, 1997 ; Ni *et al.*, 1997 ; Warren, 1997 ; Shibata *et al.*, 1998), 標準との適合度によって分類する手法 (Franz *et al.*, 1991a ; Im *et al.*, 1998) などが用いられた. これらの研究では, 形状特徴量の導入とともに, ふさわしいアルゴリズムの採用が, 判別効率を高めると結論された.

これらのアルゴリズムには, 利点がある一方で, 同時に欠点ももちあわせている. 線形判別関数は, 客観性が高く, データ処理の内部構造がわかりやすく, 設計が容易である. しかし, 判別するデータの分布を仮定しなければならない. 分類群の境界は超平面に限定され, 境界の数は必然的に分類群数より 1 小さい数に限定され, 柔軟性に乏しい. また, 判別モデルの精度を維持するためには, 入力変数とサンプルの大きさとのバランスを考慮する必要がある (浜本, 1994).

クラスタ分析では, 判別するデータの分布に仮定を必要とせず, 分類の基準を自由に設定できる利点がある. しかし, 分類群数や分類群間の距離などの設定を適切に行わないと, 満足な結果が得られないこと, また, 形成された分類群が, 必ずしも判別の目的と合致するとはかぎらないことが問題である.

しきい値処理やファジィ論理に基づく判別ルールは, データ処理の構造や機能の可読性が非常に高い. データの性質をよく反映した適切な判別ルールが構築できれば, 判別誤りをごく少なく抑えることができる. しかし, 判別ルールの設計は発見的かつ場当たりので, 最適な判別ルールを作るのは困難であり, 判別ルール作成に主観の入り込む余地が大きい. また, 判別ルールが一度できあ

がってしまうと、アルゴリズムの拡張や変更が困難であるという問題もある。

標準との適合度に基づく処理は、直感的に、目視判断に近い方法である。標準や適合度の評価関数の設計は、場当たりのに行わなければならない。それらを統計的に設定しようとするれば、判別分析やクラスタ分析に帰着せざるを得ないと思われる。

目視判断の定量化の新しい方向性

前項で述べたように、これまで提案された判別モデルには、解決しなければならない問題がある。そのなかで最初に考慮すべきものは、形状情報と大きさ情報とが相互に作用し、正しく判別できない問題である。この問題を解決するには、形状情報のみを抽出して評価する処理系と、大きさ情報のみを抽出して評価する処理系、両者から出力された結果を統合する処理系により、判別を行う必要がある（図4）。

形状情報と大きさ情報とから総合的に判別を行う判別モデルを開発するには、次の二つの段階に分けて考えることができる：

- (1)-1 もとの植物形状から形状情報のみを抽出し、評価する判別モデルを開発する、
- (1)-2 上記 (1)-1 の判別モデルによる形状情報の評価に、もとの植物形状から大きさ情報のみを抽出して評価した結果を組み合わせ、総合的な判別を行えるよう (1)-1 の判別モデルを拡張する。

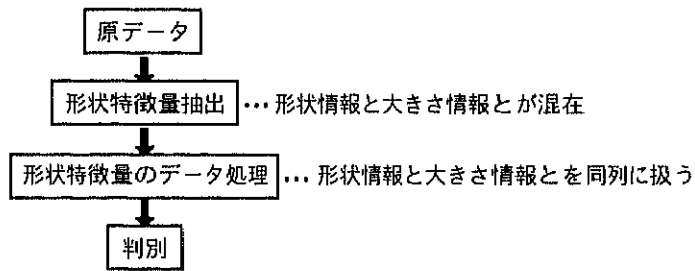
はじめに、形状情報のみを評価する判別モデルの構築方法について考える。

判別モデルに形状情報のみを評価させるには、原データである植物形状を、あらかじめ大きさに不変となるよう変換して正規化しておけばよい。さらに、色、表面のきめなどの情報も落とした二次元のシルエットとして扱うことにし、大きさと同様、向きや位置を正規化する必要もある。

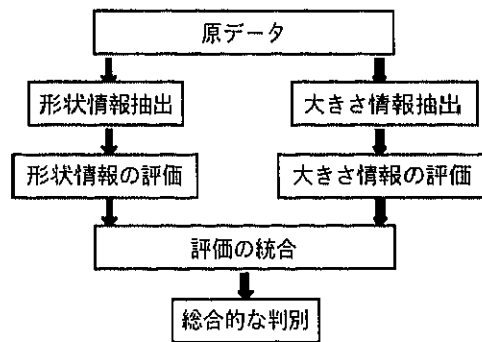
そのうえで、前項の (2)-1 および (2)-2 で述べた、判別の対象ごとに新しい判別モデルを開発しなおさなければならない問題、形状情報が欠落する問題を解決する。そのためには、判別モデルに次の条件：

- (2)-1 判別対象に依存することなく、多種多様な対象に適用できる汎用性をもつこと、
- (2)-2 形状のもつ情報全体が扱えること

が要求される。この二つの条件の実現は、対象や分類群に依存する知識である形状特徴量の必要性をなくすことにある。そのためには、植物形状の画像を直接判別モデルに入力すればよい。それによって、形状全体の情報を判別モデルに投入することもできる。



(a) 従来の判別モデル



(b) 本研究で提案する判別モデル

図4 植物形状判別モデルにおける形状情報と大きさ情報の扱いかたの比較

(a) 従来の判別モデルでは、形状情報と大きさ情報が混在し、同列に扱われ、形状情報を正しく評価することができなかった、(b) 本研究で提案する判別モデルでは、形状情報と大きさ情報を分離して独立に評価したうえで統合し、総合的な判別を行う。

しかし、画像は情報量が膨大であるため、サンプルの大きさのわりには入力変数が多い。これを線形判別関数などによって処理しようとするれば、十分な精度が得られず（浜本，1994），満足な結果が期待できない。あわせて、前項で述べた，柔軟性の欠如や設計の困難さなど，これまでの判別モデルに採用されたアルゴリズムの問題を考慮すると，新しい判別モデルは次の要求：

- (3)-1 入力変数に対して教師データ数が少なくても，精度を保つことができること，
- (3)-2 分類群の境界を自由に容易に設定できること，
- (3)-3 客観性があること，
- (3)-4 修正・更新，拡張が容易であること

を満たす必要がある。これらの要求に応えるために，ニューラルネットワークを利用することとした。

ここで，ニューラルネットワークの基礎概念について述べる（Dayhoff，1992；上坂，1994a；阿部，1995a；山田，1999a-c；佐藤と山田，1999，2000）。

(i) ニューラルネットワークの概要

ニューラルネットワークとは，神経細胞の機能を単純化して模倣した素子で構成される回路網であり，パタン認識など脳が行う複雑な処理を電子計算機に実行させることを目的としたシステムである。ニューラルネットワークが扱うデータは数値であり，その主な機能は，素子に定義される関数の合成によって，入力から出力を推測する関数近似を行うことである。与えられた数値データに基づき，学習により自動的に目的のニューラルネットワークを構築できる。

1950年代に，少数の素子で構成されたごく単純なニューラルネットワークであるパーセプトロン（perceptron）が学習により判別能力をもつことがわかり，それを原型として，素子を層状に配置した多層パーセプトロン（multilayer perceptron）が提案された（阿部，1995a）。多層パーセプトロンの典型的な学習法である誤差逆伝播法（backpropagation；Rumelhart *et al.*，1986）が1986年に発明されてからは，注目を浴び，現在の代表的なニューラルネットワークとなった。一方，パーセプトロンとはまったく異なる構成をもち，統計力学と関連づけられたニューラルネットワークが1982年ホップフィールド（Hopfield）によって考案され，ホップフィールドネットワークと名付けられた（Hopfield and Tank，1985）。

現在，ニューラルネットワークは，もともとなった生物的な概念とは切り放された，広範な応用が考えられている。たとえば，音声合成・認識，画像処理，適応制御，情報の圧縮・符号化，工業欠陥の診断などである。

(ii) 神経回路網の定量化

神経細胞が信号を受け取ってから内部で処理して信号を出すまでの機能を、一つの素子として定式化する。ここでは、基本的な考えかたについて述べる。

神経細胞を模式的に表すと、図5のように、 n 個の入力と1個の出力からなる。 v_i ($i=1, \dots, n$) は他の素子や外部からの入力信号、 w_i ($i=1, \dots, n$) は入力信号の強められたり弱められたりする度合いで、結合係数と呼ぶ。素子の出力 u は、入力信号と結合係数との積和のしきい値処理の関数：

$$u = f\left(\sum_{i=1}^n w_i v_i - \theta\right) \quad (\text{数式1})$$

として定義される。ここで、 $f()$ には、単調増加関数が用いられることが多い。それぞれの素子は単純な関数でも、それらの相互結合によって、ニューラルネットワークというシステムは複雑な関数を合成することができる。

ニューラルネットワークを構成する素子には、システム外部から入力信号を受け取る入力素子や、システム外部へ出力信号を送り出す出力素子がある(図6)。ニューラルネットワーク内の他の素子とだけ信号を授受する素子は、外部との接点をもたないので、隠れ素子と呼ばれる。このような外部とのインタフェースをもつ素子やもたない素子の数、それらの間の結合の有無の状態を、本研究ではニューラルネットワークの構造と呼ぶ。

(iii) ニューラルネットワークの学習と訓練

ニューラルネットワークにパターン(一つ以上の数値データの集合)を入力すると、一つ以上の出力変数が得られる。ニューラルネットワークは、入力パターンから出力変数への関数を構成する。ある結合係数を与えれば、出力変数のとる値によって、入力パターンの属するパターン集合(パターンクラスと呼ぶ。以下、略してクラスと呼ぶ)を決定すること、すなわち、パターン判別ができる。

逆に、いくつかのクラスが与えられたとき、それらを判別できるような結合係数を求めるという問題を設定することができる。しかし、個々の問題を解決するための固有のプログラムは必要なく、ふつうはニューラルネットワークの学習によって自動的に結合係数が決定される。ニューラルネットワークに学習させる手続きを訓練と呼ぶ。

本研究で取り上げる学習の方法は、入力パターンとそれに対応する正しい出力変数の値(以下、目標出力と呼ぶ)の組をニューラルネットワークに提示し、各入力パターンに対して正しい出力値を生じるように結合係数を調整することである。入力パターンとともに目標出力をニューラルネットワークに与える学習を、教師つき学習と呼び、学習時に与える入力パターンと目標出力の組の集合を、教




図5 ニューラルネットワークの素子の構造

v_i ($i=1, \dots, n$; n は入力数) は入力信号, w_i は結合係数, θ はしきい値, u は出力信号である.




図6 ニューラルネットワークの構成

素子には、システム外部から入力信号を受け取る入力素子、システム外部へ出力信号を送り出す出力素子がある。外部との接点をもたない、ニューラルネットワーク内の他の素子とだけ信号を授受する素子は、隠れ素子と呼ばれる。

師データと呼ぶ。線形素子だけからなる単純な構造のニューラルネットワークでは、入出力の関係から方程式を立て、解析的に結合係数の値を求めることができる。一方、複雑な構造あるいは非線形素子をもつニューラルネットワークでは、結合係数の厳密解を求めるのは困難または不可能である。したがって、結合係数に適切な初期値を与え、弛緩計算で近似解を求めることになる。ここで、初期値から近似解に至るまでの速さを決定する定数を、学習係数と呼ぶ。学習係数が大きいほど、学習は高速になるが、近似解付近での近似解への接近は不安定になる。このような学習の典型的な計算方法が、誤差逆伝播法（付録参照）である。これは、ニューラルネットワークの出力値と目標出力との誤差を、信号の流れとは逆の向きに伝播させ、結合係数を修正する方法である（図7）。

学習が完了すると、学習に使われなかった入力パターンに対しても、それが教師データの入力パターンの内挿点に該当すれば、ニューラルネットワークは正しく出力することができるようになる。この能力を、ニューラルネットワークの汎化能力と呼ぶ。学習が終了した後、ニューラルネットワークの汎化能力を試すために入力するパターン（通常は、未学習のパターン）をテストデータと呼ぶ。

他の関数近似の手法と同様に、ニューラルネットワークでもアンダフィッティングとオーバフィッティングが起こることがある（Smith, 1993 ; Sarle, 1997）。引き出したい情報を信号、信号に紛れ込んできた余分な情報を雑音と呼ぶことにすると、アンダフィッティングとは、ニューラルネットワークの構造が単純すぎて、信号を検出できないこと、オーバフィッティングとは、ニューラルネットワークの構造が複雑すぎて、雑音にまで適合することをいう。すなわち、アンダフィッティングが発生すれば、学習に失敗し、オーバフィッティングが発生すれば、汎化能力の低下を招く。アンダフィッティングは、ニューラルネットワークを訓練しても教師データにうまく適合しないことから、容易に見つけることができる。しかし、オーバフィッティングの判定は難しい。アンダフィッティングとオーバフィッティングの双方を回避し、ニューラルネットワークに優れた汎化能力を獲得させる方法がいくつか提案されている（阿部, 1995b）。

このように、ニューラルネットワークは、

- (3)-1 入力変数が多く教師データが限定される場合にも適用できる（浜本, 1994）、
- (3)-2 判別モデルの修正や拡張が容易にできる、
- (3)-3 画像とその分類群を与えれば、自動的に学習によって判別能力を獲得できる。すなわち、教師データを更新した場合、学習しなおすだけで、判別モデルを更新できる、
- (3)-4 非線形関数の合成によって複雑な計算も可能である、

という利点をもつ。




図7 誤差逆伝播法

結合係数に適切な初期値を与え、ニューラルネットワークの出力値と目標出力との誤差を、信号の流れとは逆の向きに伝播させ、弛緩的に結合係数を修正する。

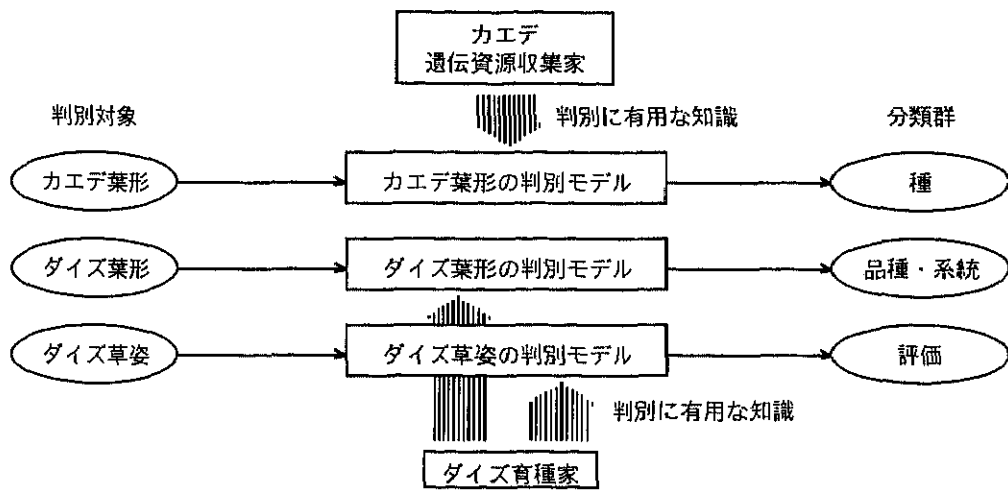
画像を直接入力するニューラルネットワークは、形状特徴量に基づく判別モデルの問題点を解決できると予想される。すなわち、本研究で提案する判別モデルは、さまざまな対象に適用できる汎用性をもち（図 8）、安定した精度で判別を行うことができる（図 9）。以下、画像を入力するニューラルネットワークを、画像入力ニューラルネットワークと呼ぶ。画像入力ニューラルネットワークに基づく植物形状の判別モデルの概念図を図 10 に示す。

ニューラルネットワークは植物形状の判別モデルとしても、すでに利用されている。たとえば、Liao *et al.* (1993) は、トウモロコシ (*Zea mays* L.) 穀粒の破損の検出を、Ding and Gunasekaran (1994) と Ghazanfari *et al.* (1996) は、それぞれトウモロコシとピスタチオ (*Pistacia vera* L.) の粒形の分類を、永田ら (1996)、曹ら (1996)、曹と永田 (1997) は、オランダイチゴ (*Fragaria grandiflora* Ehrh.) やトウガラシ (*Capsicum annuum* L.) の果形の評価を、Yang (1993) は、リンゴ (*Malus pumila* Mill.) 果実の傷の検出を、Davis (1991) は、キク (*Chrysanthemum morifolium* Hemsl.) の節の検出を、Steinmertz *et al.* (1994) は、切り花のバラ (*Rosa* spp.) の器官構造を解析して品質評価を、甲斐ら (1995a-b) は、切り花のスプレーギクの着花位置の検出を、それぞれ行い、ニューラルネットワークが植物形状の判別に優れた能力をもつことを明らかにした。


また、ニューラルネットワークとそれ以外のアルゴリズムに基づく判別モデルとを比較した研究も報告されている。Ninomiya *et al.* (1994)、生出ら (1996) は、Ninomiya and Shigemori (1991) と同じダイズ (*Glycine max* L. Merr.) 草姿の判別に、線形判別関数、ファジィ論理、ニューラルネットワークを適用し、いずれも誤判別率は同程度だったことを示した。Chtioui *et al.* (1996) は、カラスムギ属 (*Avena*)、ソラマメ属 (*Vicia*)、ウマゴヤシ属 (*Medicago*) などの種子の判別において、判別モデルとして判別分析とニューラルネットワークとを比較し、ニューラルネットワークのほうが優れたことを示した。

いずれの場合も、ニューラルネットワークが判別モデルとして有効に働いたことを示している。しかし、その入力には形状特徴量を用いており、特定の対象にしか適用できないなど、形状特徴量を用いた判別モデルの問題点を抱えている。画像を直接入力することにより、ニューラルネットワークに基づく判別モデルの有効性を保ちながら、さまざまな対象に適用できる汎用性をも高め、目視判断を支援・代替するシステムを構築できる判別モデルを開発することが強く望まれる。

画像を入力するニューラルネットワークは、文字認識や医用画像診断などの工学分野ですでに積極的に導入されているが、植物形状は形状そのものが複雑であるうえに多様な変異を含んでおり、これらをそのまま植物形状の判別に適用できない。



(a) 従来の判別モデル



(b) 本研究で提案する判別モデル

図8 植物形状判別モデルにおける判別対象に対する汎用性の比較

(a) 従来の判別モデルは、判別に有用な知識が必要であるため、対象に依存した、(b) 本研究で提案する判別モデルは、さまざまな対象に適用できる汎用性をもつ。

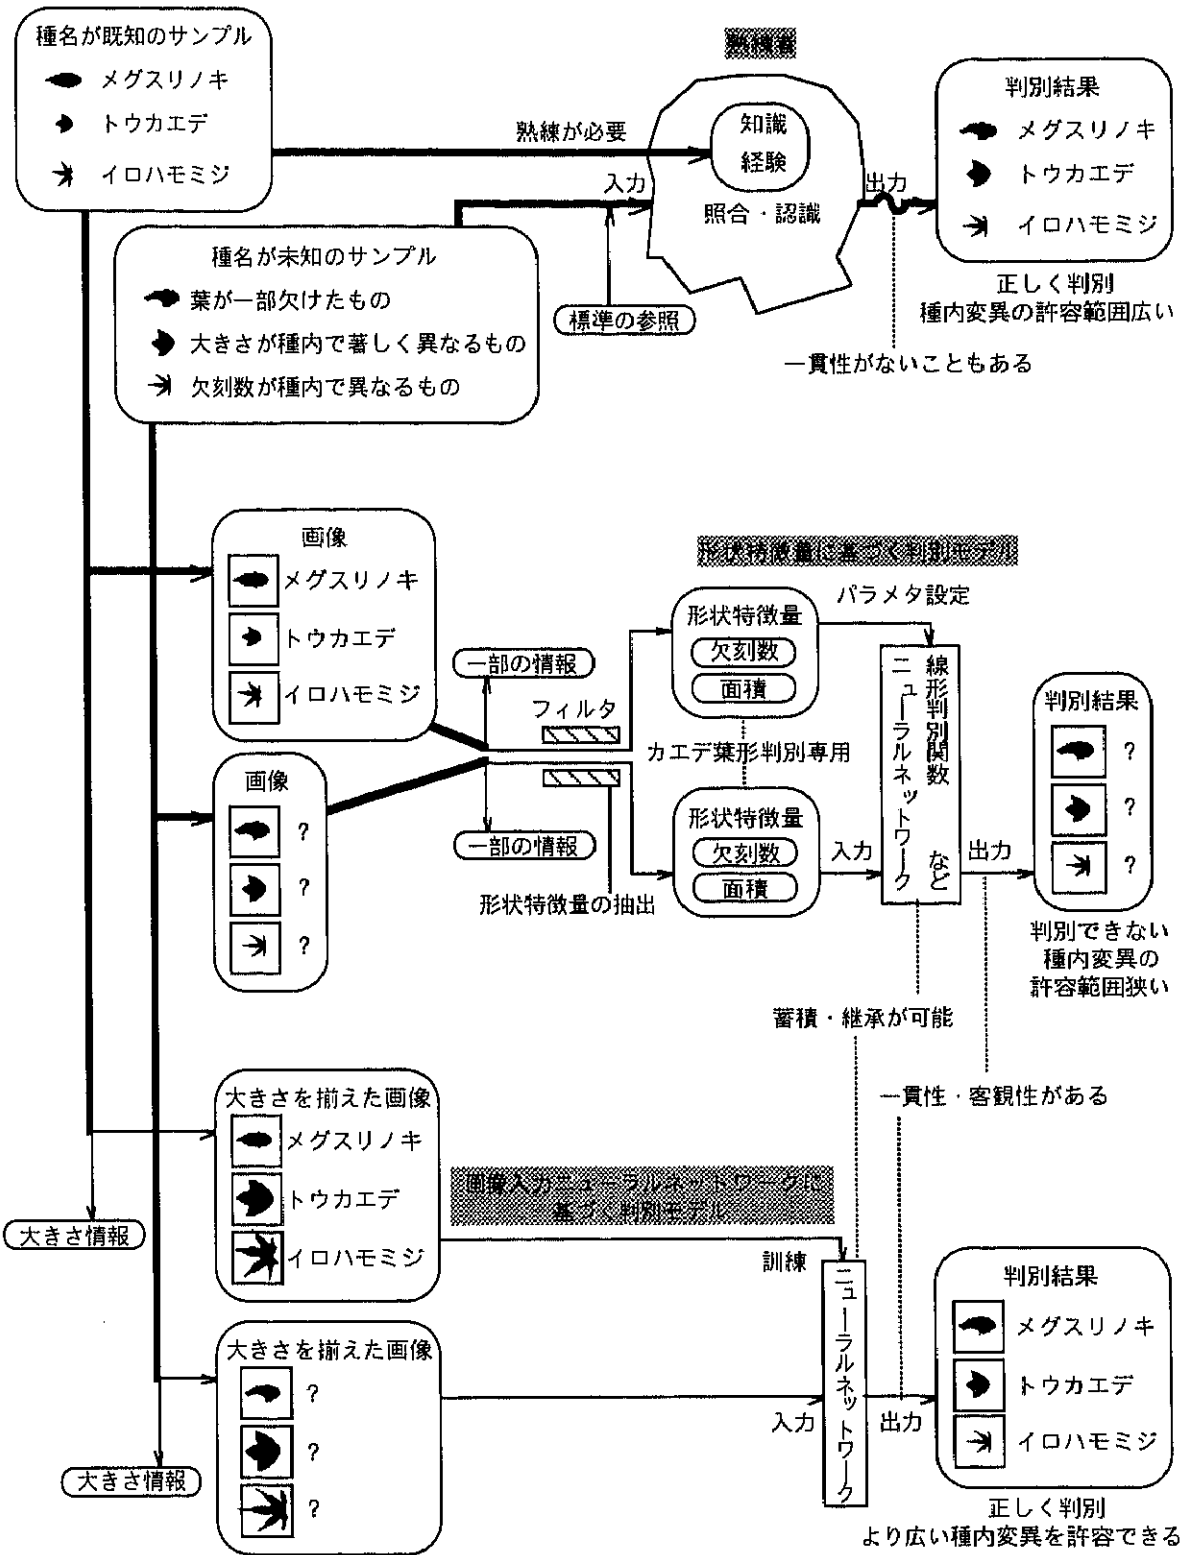


図9 カエデ葉形による種判別を例とした、目視判断の熟練者、形状特徴量に基づく判別モデル、画像入力ニューラルネットワークに基づく判別モデルの比較

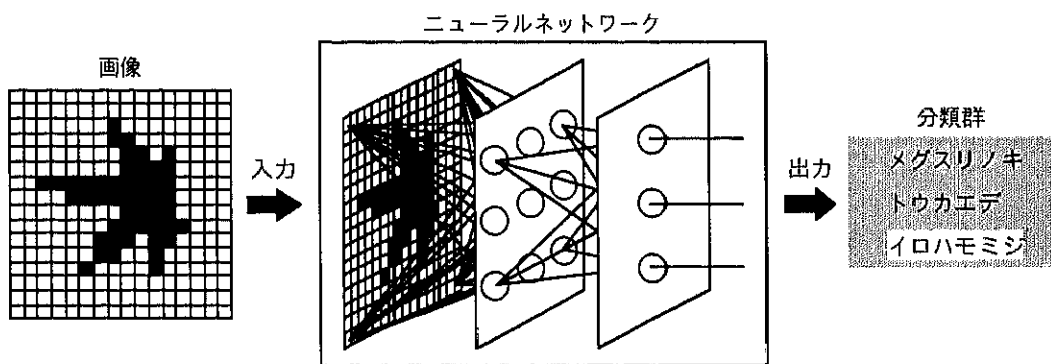


図10 植物形状画像を直接入力しその分類群を出力する画像入力ニューラルネットワーク

画像を入力するニューラルネットワークの農学分野での応用も、若干提案されている。たとえば、Dytch and Wied (1990) は、細胞画像をニューラルネットワークに入力して病理学的診断に用い、Fujita *et al.* (1992) は、雄牛の目の画像をニューラルネットワークに入力して、眼病診断を行った。池田と斉藤 (1993) は、トウガラシの形状と大きさを評価するために、ニューラルネットワークを用い、その入力として、画像、楕円フーリエ記述子、形状特徴量で比較した。これらの研究では、ニューラルネットワークによって画像の判別が可能であることを示したが、画像をニューラルネットワークに入力した理由の記載はなく、ニューラルネットワークによる画像の学習可能性や、画像をニューラルネットワークに入力することの利点あるいは欠点についても議論がない。このように、形状特徴量の必要性をなくすために、積極的に画像入力やニューラルネットワークを導入した判別モデルは、これまでなかった。

次に、形状のみ評価する判別モデルの、大きさ情報との組み合わせによる拡張について考える。

ここでも、判別モデルの汎用性を失わず、計算や労力などのコストを最小限にとどめ、判別処理の効率化に留意すべきである。そのために、計測が容易で、かつ、対象に対する予備知識が必要ない一般的な測度やアルゴリズムを採用する必要がある。

Ding and Gunasekaran (1994) が提案した判別モデルでは、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、その輪郭形状を的確に評価できることを示した。しかし、大きさ情報が形状情報とならぶ判別要因であるにもかかわらず、大きさ情報は欠落したままであり、その利用方法については考慮していない。このように、形状情報と大きさ情報とを分離し、それぞれ独立に評価したうえで、改めて双方を統合して判別を行う試みはこれまでなかった。

本研究の目的と方針

これまで述べてきたように、植物育種における形態評価やそれに基づく選抜、あるいは遺伝資源の特性調査における、植物の葉形、粒形、草姿など植物の各種形状の目視判断を支援・代替するシステムの構築のためには、その根底をなす判別モデルの構築が必要である。本研究では、形状情報

と大きさ情報とを独立に評価するという、まったく新しい試みとして判別モデルを開発することを目的とする。そのために、まず、形状情報のみを評価する処理系として、画像入力とニューラルネットワークとを組み合わせた新たな判別モデルを構築し、本判別モデルの有効性と汎用性とを明らかにする。次に、大きさ情報を形状情報とは独立に評価したうえで統合的に判別するために、判別モデルを拡張し、その有効性および汎用性を明らかにする。さらに、形状情報と大きさ情報とを分離して評価すること、判別モデルに画像を直接入力することやニューラルネットワークを用いることの意義について考察する。

具体的には、次の5項目について研究を行う。

第1章では、判別モデルの中核となる画像入力ニューラルネットワークをソフトウェア上で実装し、カエデ葉形による種判別を例として、形状情報のみを評価する判別モデルを構築する。このとき、異なるネットワークアーキテクチャをもつニューラルネットワークを用い、その構造や教師データの作成方法を含めて、学習可能性および汎化能力を比較検討するものとする。

第2章では、第1章で得られた判別モデルを、植物器官形状による種や品種・系統の判別へ適用し、その汎用性と有効性を実証する。供試材料は、葉形判別ではクワ、ダイズ、カラシナ、粒形判別ではソバ、ダツタンソバ、雑草種子、果形判別ではセイヨウナシである。第1章と同様、異なるネットワークアーキテクチャをもつニューラルネットワークを用い、その構造や教師データの作成方法を含めて、学習可能性および汎化能力を比較検討するものとする。

第3章では、第1章で得られた判別モデルを、育種家によって選抜のために3段階の評価を与えられたダイズ草姿の判別へ適用する。第1章と同様、異なるネットワークアーキテクチャをもつニューラルネットワークを用い、その構造や教師データの作成方法を含めて、学習可能性および汎化能力を比較検討するものとする。

第4章では、カエデ葉形による種判別を再び例として、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、本判別モデルを拡張する。そして、拡張した判別モデルの有効性を検討する。

第5章では、第4章で拡張した判別モデルを、クワ葉形、ダイズ葉形、カラシナ葉形、ソバ粒形、雑草種子粒形、セイヨウナシ果形、ダイズ草姿の判別へ適用し、その有効性と汎用性とを検討する。

最後に、第6章では、以上の検討を踏まえ、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、植物育種や遺伝資源の特性評価への貢献やさらなる発展など展望を考察する。