

第3章 育種家の評価による草姿判別への植物形状判別モデルの適用

第1章では、形状情報のみを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構築し、第2章では、植物器官形状による判別において、その判別モデルがさまざまな形状に対して汎用的に適用でき、安定した精度で判別できることを示した。ここでは、種や品種・系統の判別を扱ったが、本章では、さらに本判別モデルの有効性と汎用性を検討するために、主観的に順序のみが定められた分類群への判別問題に取り組む。その一例として、育種家が選抜のために行った評価によるダイズ草姿の判別を検討する。

3.2では、供試材料と判別処理の共通事項について述べる。3.3では、多様な構造に対して、非線形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を検討する。3.4および3.5では、第1章と同様に、それぞれ、非線形、線形の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を検討する。3.6では、3.3~3.5を通じて、ニューラルネットワークの学習条件と誤判別率との関連を考察する。

3.1 はじめに

緒言で述べたように、草型・草姿は受光態勢、ガス交換の調整、寒冷からの回避、雑草との競争、栽培管理や収穫方法に対する適応性などの面とかわり、収量にも大きく影響するため、育種上選抜すべき重要な形質となっている。そのため、草型・草姿の判別モデルに関する研究は、これまでもさかんに行われてきた。村井ら(1987)はイネ(*Oryza sativa* L.)の、山口(1982)はカラスムギ(*Avena fatua* L.)の、それぞれの草型を定量的に評価する手法を提案した。また画像解析を用いて、Oka and Hinata(1988, 1989)はイネ、南ら(1991)はソバ(*Fagopyrum esculentum* Moench)、Steinmertz *et al.*(1994)は切り花のバラ(*Rosa* spp.)、甲斐ら(1995a-b)は切り花のスプレーギク(*Chrysanthemum morifolium* Hemsl.)、Schaufler and Walker(1995)はサトウキビ(*Saccharum officinarum* L.)の苗、Woebbecke *et al.*(1995a-b)やZhang and Chaisattapagon(1995)、Critten(1996)、Andreasen *et al.*(1997)は雑草の幼苗の草型や草姿の評価・同定を行うための判別モデルを開発した。これらの研究では、形状特徴量などを用いて、定量的に草型・草姿を判別できることを示唆した。

ダイズ(*Glycine max* L. Merr.)の草型・草姿も、収量や栽培特性と大いにかかわっていること

が明らかにされている（橋本，1980；小島，1987；国分，1988）。これまでのダイズ草姿の判別モデルの研究では，Ninomiya and Shigemori（1991）が形状特徴量から線形判別関数を使って，育種家による判断を定量化し，Ambuel *et al.*（1997）は，同じデータを供試してファジィ論理に基づく判別モデルを提案し，Ninomiya *et al.*（1994）は，同じデータを供試し，判別結果を線形判別関数，多層パーセプトロン，ファジィ論理に基づく判別ルールとの間で比較した。さらに，生出ら（1996）は，多層パーセプトロンによるダイズ草姿の判別モデルにおいて，教師データの選択法を検討し，二宮ら（1998）は，数値データと定性的評価とを結びつけて，ダイズ草姿を検索する手法を提案した。これらの研究では，主茎位置などの形状特徴量が，ダイズ草姿評価に有効であることを明らかにし，判別に応用した。

上述した判別モデルには，形状情報と大きさ情報が混在する形状特徴量に依存するため，①対象ごとに判別モデルを開発しなければならないこと，②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，③形状の評価が大きさに惑わされる，ことなどから，非効率的で判別の安定性や精度に問題がある。

そこで，第1章および第2章では，これらの問題を解決するた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を新たに構築し，それが各種植物器官形状による種や品種・系統の判別に有効であることを示した。本章では，この判別モデルを育種家の評価による草姿の判別に適用し，その有効性と汎用性とを検証する。供試材料は，Ninomiya and Shigemori（1991）で供試されたダイズである。

3.2 材料と方法

3.2.1では，供試材料を，3.2.2では，3.3～3.5で検討する判別実験において共通する判別処理の流れについて述べる。

3.2.1 材料

供試材料は，3段階（“良”，“並”，“悪”のいずれか）に評価された175品種・系統のダイズ（*Glycine max* L. Merr.）875個体である。これらは，Ninomiya and Shigemori（1991）が供試した粒肥大始期のダイズであり，基部から切り取られ，水平に置かれた状態で側面草姿を上からビデオカメラで撮影され，二値化の後，3人のダイズ育種家によって評価された。このうち，評価の客観性を保持するため，3人の育種家の判断が一致した155品種・系統326個体（“良”は52品種・系統

66 個体，“並”は76 品種・系統93 個体，“悪”は89 品種・系統167 個体）を用いた（表3-1）。“良”，“並”，“悪”の育種家の評価を判別すべきクラスとし，そして“並”と“悪”とを合わせた新しいクラス“不良”を定義する。

3.2.2 判別処理の流れ

3.3～3.5で検討する判別処理の流れとして，草姿の正規化（3.2.2.1参照），草姿画像の復元（3.2.2.2参照），判別クラスの選択（3.2.2.3参照），誤判別率の定義（3.2.2.4参照）の各方法を述べる。

3.2.2.1 草姿の正規化

ダイズ草姿の絶対最大長（図形の任意の2点間の距離のうち最大の長さ；高木・下田，1991）が256画素になるよう拡大または縮小し，絶対最大長軸が垂直かつ基部が下向きになるよう回転し，絶対最大長軸が画像の中央に位置するよう平行移動して，正規化した。各クラスの草姿の例を図3-1に示す。

3.2.2.2 草姿画像の復元

テストデータの各個体の草姿画像は，計算の負荷が大きくなりすぎるのを防ぐため，3.2.2.1で述べた正規化された草姿画像を8画素×8画素（3.3における実験のみ），16画素×16画素，32画素×32画素，64画素×64画素に縮小して作成する。

教師データの入力パタンの作成方法については，各節で述べる。

3.2.2.3 判別クラスの選択

3.3では，“良”，“並”，“悪”の3クラス，3.4および3.5では，それに加えて“良”，“悪”の2クラス判別も扱う。

3.2.2.4 誤判別率の定義

選抜される“良”の草姿をもつ個体を“並”や“悪”から確実に判別することが，“並”と“悪”とを判別するよりも，重要であると考えた。そこで，判別モデルで“良”，“並”，“悪”の3クラスで判別処理を行った場合，誤判別率を求める段階で，“並”と“悪”とを合わせて“不良”のクラスとした。

表3-1 草姿による判別に供試したダイズ

(a) “良”の草姿

品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数
タマムスメ	1	フクナガハ	1	農林2	2	Peking	2	ふくせんなり	1
アキセンゴク	1	コマムスメ	1	スズユタカ	1	Adams	1	NA 144	1
ヒゴムスメ	1	カルマイ	2	エンレイ	1	Kirin 5	1	サヨヒメ	1
ムツメジロ	1	ワセコガネ	1	タマホマレ	1	銀嶺19	1	十勝長葉	1
ワセシロメ	1	キタムスメ	1	ナツシロメ	2	Calland	1	大谷地2	1
ナンブシロメ	1	ヒメユタカ	1	シロユタカ	1	S-100	1	農林1	1
タチコガネ	1	トヨムスメ	1	小倉大豆	1	Hill	2	農林4	1
ワセスズナリ	2	ホウレイ	1	佐渡豆	1	Dorchsoy 31	1	あぜみのり	2
フクシロメ	1	タンレイ	2	ヤマベダイズ	1	Dorchsoy 67	2		
スズカリ	2	コケシジロ	1	Davis	1	Jackson	1		
東北85	2	タチナガハ	4	信濃青豆	1	Clark	1		

(b) “並”の草姿

品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数
タマムスメ	1	コマムスメ	1	東吉	1	S-100	2	白八石	1
アソマサリ	2	ツルコガネ	1	スズユタカ	1	Lee	2	ダルママサリ	2
アソムスメ	1	ホッカイハダカ	1	ナツシロメ	1	Arksoy	2	吉岡大粒	2
フジムスメ	1	シンセイ	1	タマヒカリ	1	Jackson	1	農林1	1
ヒゴムスメ	1	トヨスズ	1	シロユタカ	1	Marshall	1	農林3	1
オリヒメ	1	キタコマチ	2	中鉄砲	1	NA 793	1	ライコウ	1
ヒュウガ	1	トカチクロ	1	ミスズダイズ	1	サヨヒメ	2	あぜみのり	2
ウゴダイズ	2	トヨムスメ	1	佐渡豆	1	白莢1	1	フジオトメ	1
ネマシラズ	1	千代姫	1	改良革新	1	細莢1	2	岩手野起1	1
ムツメジロ	1	コガネダイズ	1	信濃青豆	1	新3	2	白毛9	1
ワセシロメ	1	ホウレイ	1	Traverse	1	かたざや	1	五葉黒豆	1
タチコガネ	1	コケシジロ	1	Prize	1	生娘茨城1	1	アイサ	1
ワセスズナリ	1	農林2	2	Kirin 5	2	ライデン	1		
スズカリ	1	シンメジロ	1	Amsoy	1	ナガハジロ	1		
東北80	1	ワセシロゲ	3	Williams	1	白鶴の子	1		
東北85	1	加茂在来	1	水原75	2	信濃緑	1		

(c) “悪”の草姿

品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数	品種・系統名	個体数
アソムスメ	1	シンメジロ	2	Beeson	1	細莢1	2	フジオトメ	2
フジムスメ	1	房成	1	集体2	2	新2	3	岩手野起1	1
フクユタカ	5	加茂在来	2	奉天白眉	1	新3	1	オクシロメ	4
トヨシロメ	2	東吉	2	Dorman	3	生娘茨城1	1	金剛	3
ウゴダイズ	2	ハツカリ	2	Lee	1	ライデン	1	白毛9	1
ナンブシロメ	3	スズユタカ	1	PI90406	5	信濃緑	2	地塚	1
ユウヒメ	1	革新1	5	Rokusun	3	長葉裸1	1	出来過1	1
フクナガハ	1	ミヤギシロメ	3	Jackson	1	白八石	1	兄	4
コマムスメ	1	ミヤギオオジロ	1	光教	1	ダルママサリ	1	奥羽3	4
ワセコガネ	1	赤莢	1	White bilox	4	茨城豆	4	奥羽13	1
ホウライ	1	シロユタカ	1	Clark	2	農林3	1	しなのめじろ	2
トヨスズ	1	ナカセンナリ	2	NA 144	1	農林5	3	早生朝日	1
キタホマレ	1	中鉄砲	2	サヨヒメ	1	ライコウ	2	玉揃	1
千代姫	1	アキシロメ	1	白莢1	1	高柿在来(黒莢)	2	北相木在来1	1
アキヨシ	3	佐渡豆	2	はつこがね	1	高柿在来(赤莢)	3	北相木在来3	4
ホウレイ	1	改良革新	1	河田白	3	あぜみのり	1	北相木在来4	1
コケシジロ	1	ヤマベダイズ	1	十勝裸	2	陸羽27	4	白豆	3
小系在来	1	NCI-2-2	2	早生裸	2	早生裸	4		

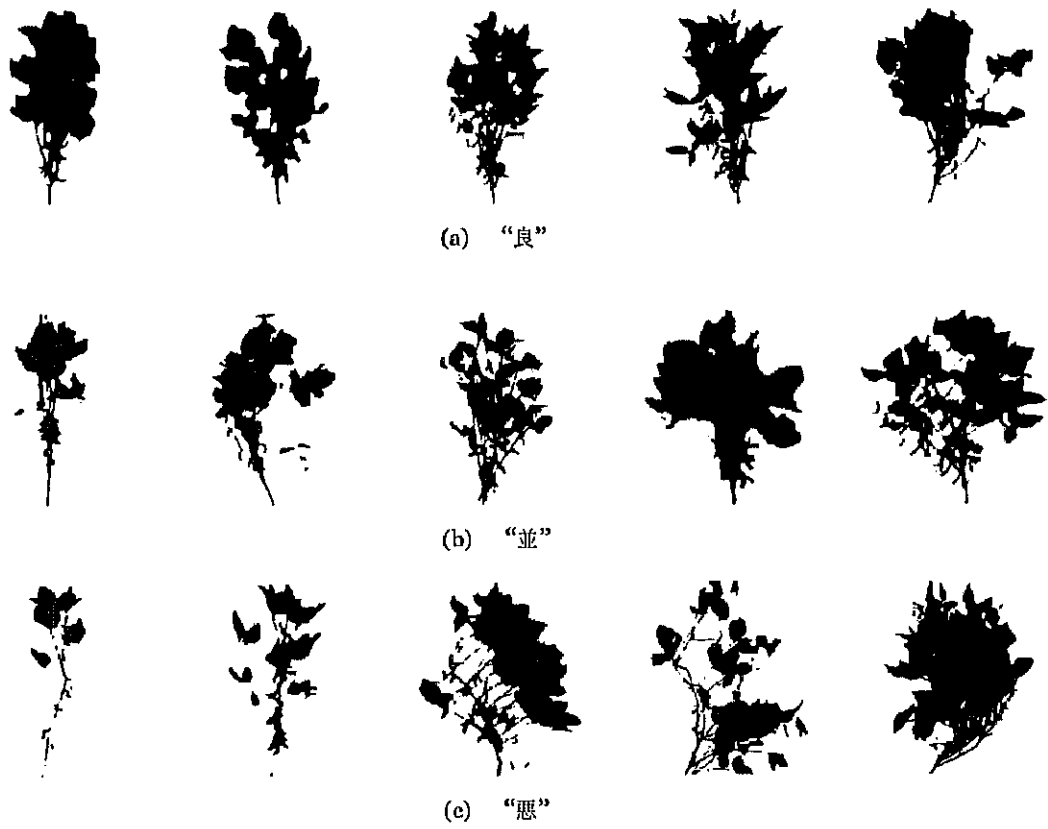


図3-1 各クラスに含まれる正規化した草姿の例

3.3 では、テストデータ全体の誤判別率を求め、さらに、“良”と“不良”のクラスごとの誤判別率も求めた。3.4 および 3.5 では、テストデータ全体の誤判別率だけを求めた。ただし、3 クラス判別では、“並”と“悪”とを合わせて“不良”のクラスとした場合と、“並”と“悪”とを別のクラスとした場合との 2 種類の誤判別率を求めた。

3.3 植物形状判別のための非線形ニューラルネットワークの構造の検討

本節では、育種家の評価によるダイズ草姿の判別モデルとしての、非線形ニューラルネットワークである多層パーセプトロン (1.3.1 参照) に基づく画像入力ニューラルネットワークの有効性と汎用性を検討する。アンダフィッティングとオーバフィッティングの発生を回避し、よりよい汎化能力を実現するための必要条件の一つが構造であり (Sarle, 1997)、とくに各種構造と学習可能性や汎化能力との関連を検討する (Oide and Ninomiya, 1998)。教師データには、各クラスから典型的な草姿を選択して使用する。3.3.1 では、多層パーセプトロンで判別処理を行うにあたって、多層パーセプトロンの構造や教師データの各種設定について説明し、3.3.2 では、設定ごとに判別の結果を示し、3.3.3 では、結果に基づいて、適切な多層パーセプトロンの構造や教師データ、多層パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性を考察する。

3.3.1 判別処理の設定

3.2.1 で述べたダイズ草姿に対し、非線形の画像入力をもつ多層パーセプトロンによる判別実験を行うための設定について説明する。3.3.1.1 では、教師データとテストデータについて、3.3.1.2 では、判別処理に使用する多層パーセプトロンの構造を、3.3.1.3 では、誤差逆伝播法 (緒言、付録参照) に基づく多層パーセプトロンの訓練の具体的手法を、3.3.1.4 では、誤判別率の評価方法を述べる。

3.3.1.1 教師データとテストデータの設定

教師データの入力パターンには、典型的な 26 個体の草姿 (“良” 7 個体、“並” 9 個体、“悪” 10 個体) を選択して用いた。教師データに選択された個体の草姿を、図 3-2 に示す。

テストデータは、教師データに選ばれなかったすべての草姿画像とした。したがって、テストデータは、“良” 59 個体、“並” 84 個体、“悪” 157 個体の計 300 個体である。

教師データの入力パターンおよびテストデータに用いた画像のサイズには、16 画素×16 画素、32

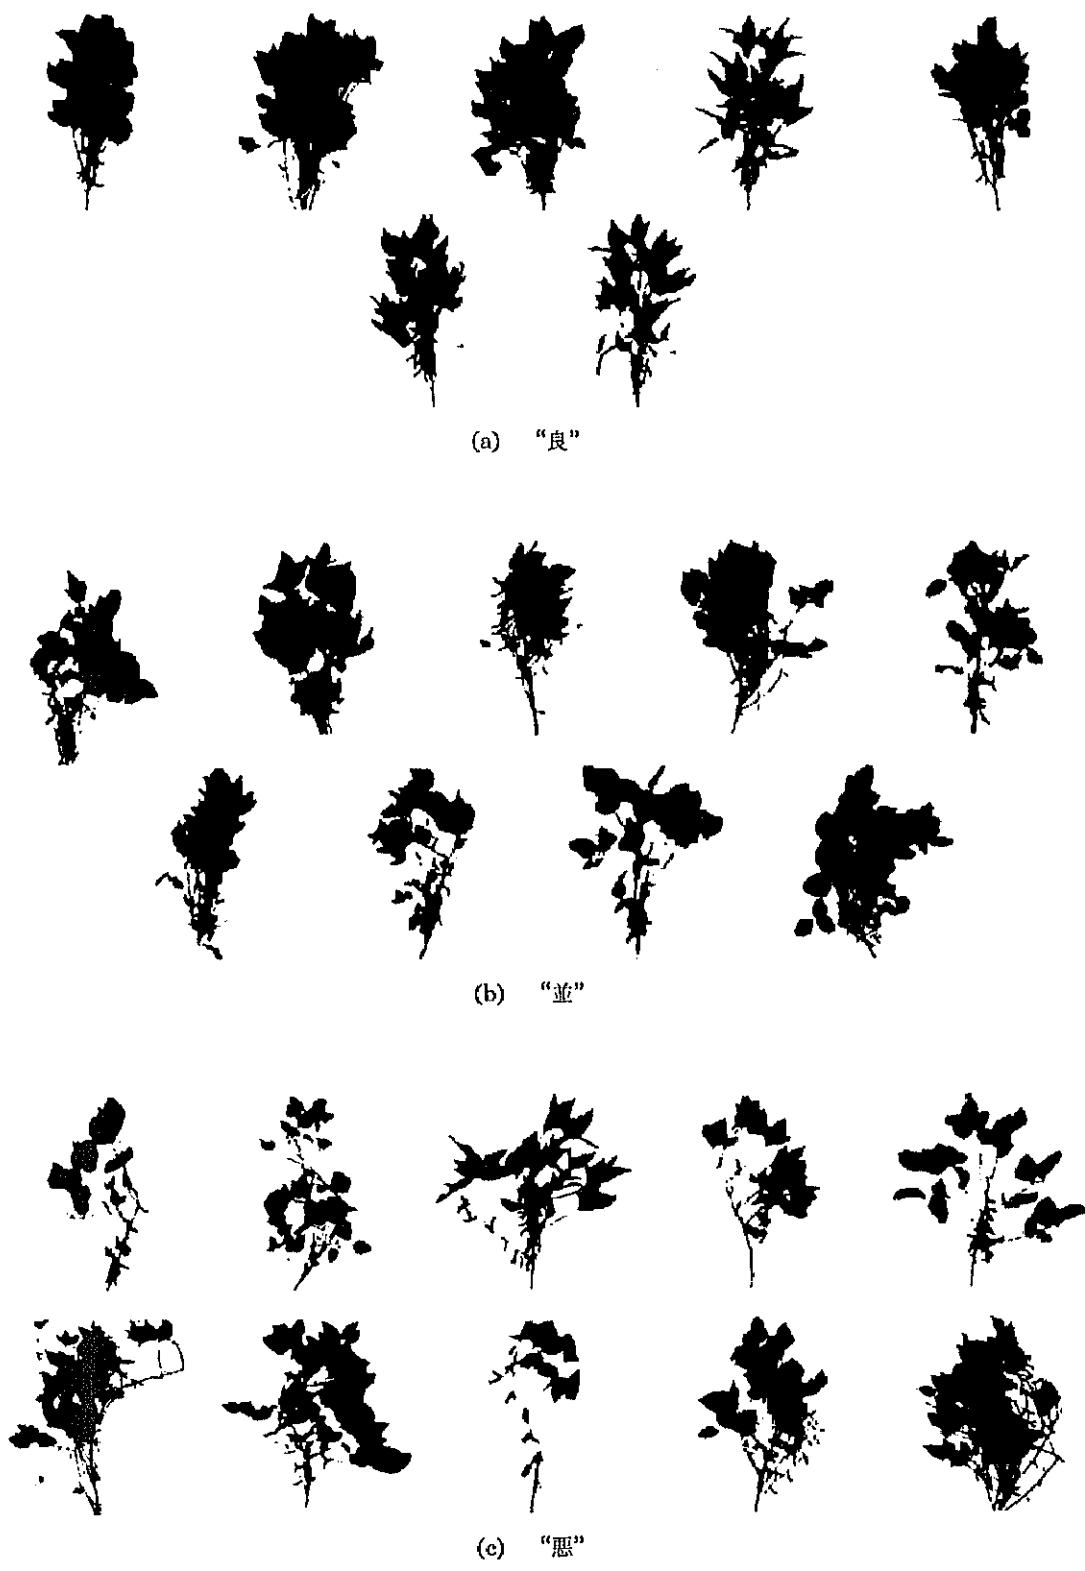


図3-2 教師データに選択された個体の草姿
 教師データの入力パターンには、典型的な26個体の草姿を選択した。

画素×32画素，64画素×64画素に縮小したものに加え，8画素×8画素も判別実験に取り入れた。

3.3.1.2 多層パーセプトロンの構造の設定

本節では，隠れ層数，入力素子数，隠れ素子数，出力素子数，結合数の異なる175の多層パーセプトロンの構造について実験した。実験した構造の一覧を，表3-2に示す。次の三つの事項に分けて構造の検討を行った：

- (1) 最初に，構造と学習可能性や汎化能力との関連を把握するために，各種の構造を検討した（表3-2上3段）。隠れ層数は，0，1，2のいずれかとした。入力素子数は，入力画像の画素数と同数（8×8，16×16，32×32，64×64のいずれか），出力素子数はクラス数3と同数またはその2倍の6とした。第一隠れ素子数は，8，16，32，64のいずれか（隠れ層数が1または2の場合），第二隠れ素子数は，第一隠れ素子数の1/2，同数，2倍のいずれか（隠れ層数が2の場合）とした。これらすべての組み合わせを用いた。
- (2) 1隠れ層の構造について，出力素子数を増やした（表3-2下から2段目，図3-3）。隠れ層と出力層との間の結合係数の初期値のうち，いくつかの設定が不適切だったとしても，適切な初期値を与えられたその他の結合でそれらを補うことができ，安定した誤判別率が得られると予想した。そこで，多くの出力素子をもつ構造を検討した。
- (3) 1隠れ層の構造について，隠れ層と出力層との結合を減らした（表3-2最下段，図3-4）。入力層と隠れ層との間の結合の学習が，異なるクラス間で干渉・競合せず，学習・判別においてよい結果をもたらすと予想した。そこで，結合数の少ない構造を検討した。

3.3.1.3 多層パーセプトロンの訓練の設定

1回の学習の収束が達成されるまでの弛緩的手続きを，下記①～⑦のように設定した。学習係数（緒言参照）は，0.2とした。

- ① 結合係数を初期化する。初期値は，偽似乱数により無作為に-0.3から+0.3の間の値をとる。
- ② 教師データを一つ選択する。選択は，偽似乱数により無作為に行う。
- ③ 選択された教師データの入力パターンから，多層パーセプトロンの出力を計算する。
- ④ 多層パーセプトロンからの出力と，選択された教師データの目標出力とを比較し，誤差を求める。
- ⑤ 誤差から，誤差逆伝播法（緒言，付録参照）により，結合係数を修正する。
- ⑥ 結合係数の修正回数が，100回以上ならば，最近の100回の修正における誤差の平均二乗和

表3-2 実験した多層パーセプトロンの構造

隠れ層数	入力素子数	第一隠れ素子数	第二隠れ素子数	出力素子数
0	8×8, 16×16, 32×32, 64×64	-	-	3, 6
1	8×8, 16×16, 32×32, 64×64	8, 16, 32, 64	-	3, 6
2	8×8, 16×16, 32×32, 64×64	8, 16, 32, 64	第一隠れ素子数 ×1/2, 1, 2	3, 6
1	8×8, 16×16, 32×32	入力素子数 ×1/2, 1, 2	-	入力素子数の正の平方根 ×3, 6, 12
1	8×8, 16×16, 32×32	8×3, 16×3, 32×3, 64×3 ¹⁾	-	3

各段で記載された素子数のすべての組み合わせの構造を実験した；¹⁾ 隠れ層と出力層との結合を減らした。各隠れ素子は、一つの出力素子とのみ結合し、各出力素子は三つずつの隠れ素子と結合した。その他の場合は、隠れ素子は出力素子と完全結合する。

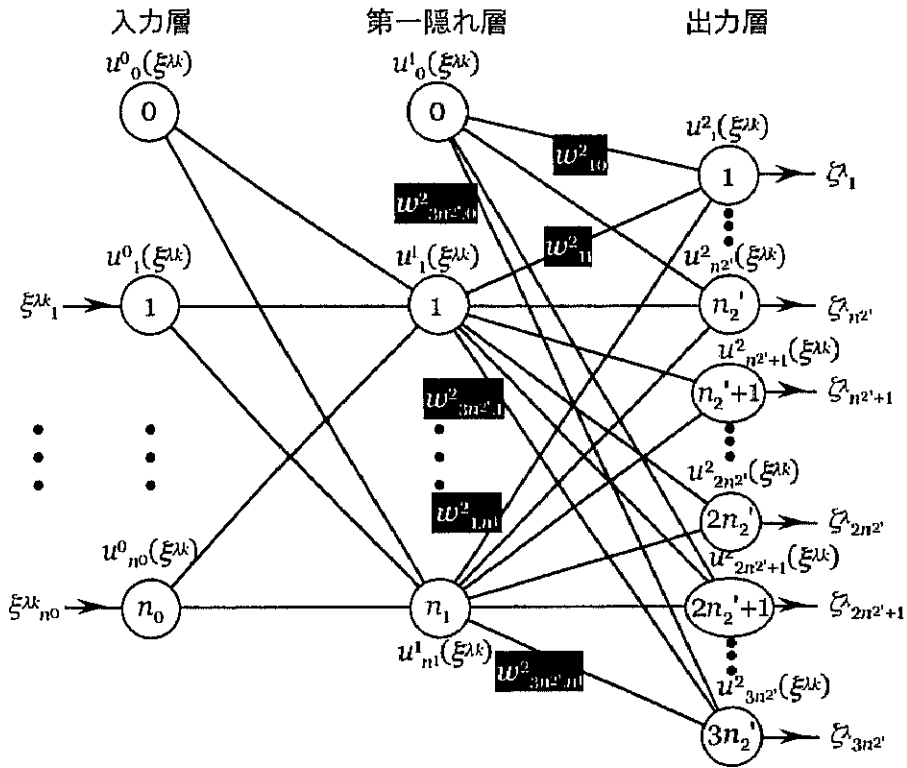


図3-3 出力素子数を増やした多層パーセプトロンの構造

出力素子を増やした. n_l は第 l 層 (入力層を第 0 層, 隠れ層を第 1 層, 出力層を第 2 層とする) の素子数, ξ^{k_1} ($\lambda=1, \dots, P, k=1, \dots, m_\lambda; P$ はクラス数, m_λ は第 λ クラスに属する教師データ数) は第 λ クラスに属する第 k 教師データの入力画像, $\xi^{k_1}_i$ ($i=1, \dots, n_0$) は ξ^{k_1} の第 i 画素の輝度, $u^l_i(\xi^{k_1})$ ($l=0, 1, 2, i=0, \dots, n_l$) は ξ^{k_1} を入力したときの第 l 層の第 i 素子の出力, w^l_{ij} ($l=1, 2, i=1, \dots, n_l, j=0, \dots, n_{l-1}$) は第 $(l-1)$ 層の第 j 素子から第 l 層の第 i 素子への結合係数, ζ^k は第 λ クラスの目標出力ベクトル, ζ^k_i ($i=1, \dots, n_2$) は ζ^k の第 i 成分である. ここで, $n_2'=n_2/3$ とした.

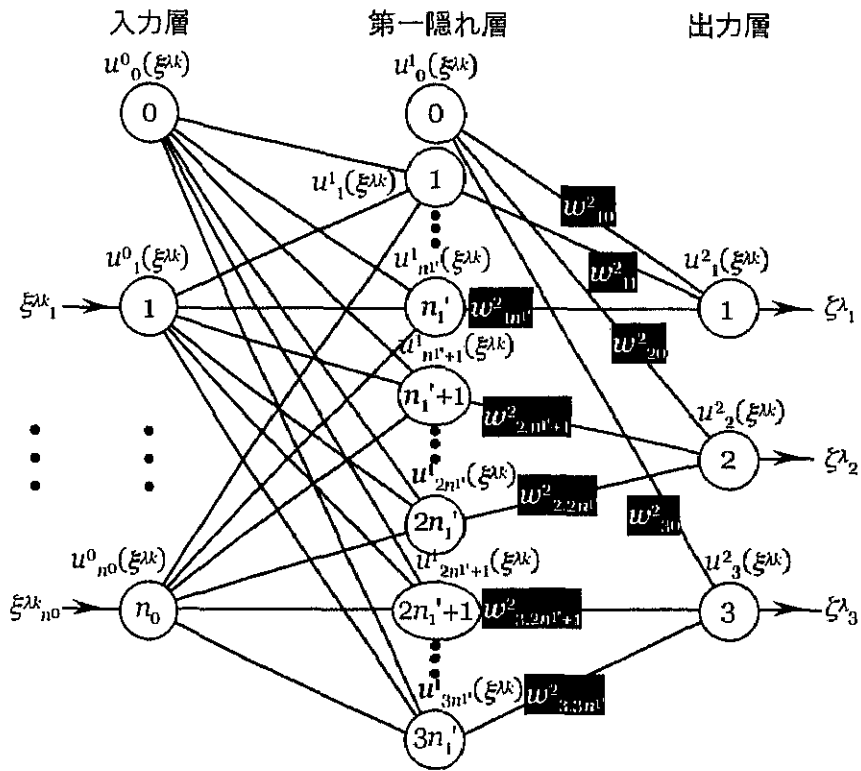


図3-4 隠れ層と出力層との間の結合を減らした多層パーセプトロンの構造

隠れ層と出力層との結合を減らした。隠れ素子は、一つの出力素子とのみ結合し、各出力素子は三つずつの隠れ素子と結合する。 n_l は第 l 層 (入力層を第 0 層, 隠れ層を第 1 層, 出力層を第 2 層とする) の素子数, $\xi^{\lambda k}$ ($\lambda=1, \dots, P, k=1, \dots, m_\lambda$; P はクラス数, m_λ は第 λ クラスに属する教師データ数) は第 λ クラスに属する第 k 教師データの入力画像, $\xi^{\lambda k}_i$ ($i=1, \dots, n_0$) は $\xi^{\lambda k}$ の第 i 画素の輝度, $u^l_i(\xi^{\lambda k})$ ($l=0, 1, 2, i=0, \dots, n_l$) は $\xi^{\lambda k}$ を入力したときの第 l 層の第 i 素子の出力, w^l_{ij} ($l=1, 2, i=1, \dots, n_l, j=0, \dots, n_{l-1}$) は第 $(l-1)$ 層の第 j 素子から第 l 層の第 i 素子への結合係数, ξ^{λ} は第 λ クラスの目標出力ベクトル, ξ^{λ}_i ($i=1, \dots, n_2$) は ξ^{λ} の第 i 成分である。ここで, $n_1' = n_1/3$ とした。

を計算する。そうでなければ、②へ。

- ⑦ 誤差の平均二乗和の正の根が 0.2 未満ならば、学習が収束したと見なして、手続きを終了する。そうでなければ、②へ。

50,000 回の結合係数の修正を行っても学習が収束しないとき、結合係数の初期値の設定が不適切だったと判断し、①へ戻って、訓練を新しい結合係数の初期値で再び始めた。電子計算機 HP/CONVEX Exemplar SPP1600/XA-32 (Hewlett-Packard Co. Ltd., Palo Alto, CA, USA) (1.2.2.3 参照) の 1 ジョブ当たりの最大許容 CPU 時間 (1 週間) の間、学習が 1 度も収束しなかったとき、学習に失敗したと判断し、手続きを終了した。

本節で設定した数値は、1.3.2.3 と同様、すべて経験的に決定したものである。

3.3.1.4 誤判別率の計算方法

本節における誤判別率は、分割法 (holdout 法; 浜本, 1994) によって求めた。すなわち、訓練した多層パーセプトロンに、教師データ以外の 300 個体の草姿画像をテストデータとして入力し、3 クラスの判別問題として出力を得た後、次の三種類の誤判別率を求める：

- (1) 全体の誤判別率：育種家が“良”と判別した草姿のうち、多層パーセプトロンが“並”または“悪”と判別した草姿、および育種家が“並”または“悪”と判別した草姿のうち、多層パーセプトロンが“良”と判別した草姿の割合、
- (2) “良”の誤判別率：育種家が“良”と判別した草姿のうち、多層パーセプトロンが“並”または“悪”と判別した草姿の割合、
- (3) “不良”の誤判別率：育種家が“並”または“悪”と判別した草姿のうち、多層パーセプトロンが“良”と判別した草姿の割合。

構造ごとに誤判別率を求め、多層パーセプトロンの構造が学習可能性や汎化能力に及ぼす影響を構造間で比較した。ただし、結合係数の初期値によって判別結果が異なるため、結合係数の初期値を偽似乱数により無作為に変えながら 100 回多層パーセプトロンの訓練を繰り返し、それぞれの訓練で構築された多層パーセプトロンから得た誤判別率の平均および標準偏差をとった。

3.3.2 結果

3.3.1.2 で述べた (1) の判別実験では、一部のネットワーク構造を除いて、学習は収束した。収束しなかった構造を表 3-3 に示す。隠れ素子が多い構造ほど、学習は速く収束する傾向があった。

表3-3 学習に失敗した構造


隠れ層数	入力素子数	第一隠れ素子数	第二隠れ素子数	出力素子数
0	32×32, 64×64	-	-	3, 6
1	8×8	128	-	48, 96
1	16×16	128	-	48
1	32×32	512, 2048	-	96, 192, 384
1	32×32	1024	-	384

各欄の記入してある素子数のすべての組み合わせの構造で、学習に失敗した。


図 3-5～図 3-8に隠れ層数，入力素子数，第一隠れ素子数，出力素子数による誤判別率の比較を示す。外れ値（四分位点から四分位点間距離以上離れた点）を除いた後の全体，“良”，“不良”の誤判別率の平均は，それぞれ 0.218～0.288，0.279～0.519，0.171～0.247，標準偏差は，それぞれ 0.021～0.102，0.071～0.263，0.038～0.176 に分布した。“良”の誤判別率は，“不良”の誤判別率に比べ，平均が高く，標準偏差も大きかった。“不良”の画像がテストデータ中で多くを占めた（テストデータは，241 の“不良”と 59 の“良”の草姿からなる）ため，全体の誤判別率の分布は，“不良”の誤判別率の分布と似た。図 3-11に，一つの構造における全体，“良”，“不良”の誤判別率の分布例を示す。このように，“良”または“不良”のいずれか一方の誤判別率が低いとき，もう一方はそのぶん高くなった。したがって，“良”の誤判別率の標準偏差が大きいつき，“不良”の誤判別率の標準偏差も同時に大きくなり，結果として全体の誤判別率の標準偏差も大きくなった。

隠れ層数，入力素子数，第一隠れ素子数，出力素子数，結合数による学習可能性および汎化能力を比較したところ，次の結果を得た：


- (1) 隠れ層数：隠れ層がない多層パーセプトロンでは，学習が収束しにくく，とくに，入力素子が多い（ 32×32 および 64×64 ）構造では収束しなかった。誤判別率の標準偏差が極端に大きいのは，いずれも隠れ層数が 2 の場合であった（図 3-5）。
- (2) 入力素子数：入力素子数が 32×32 以上のときは，収束が遅かった。誤判別率の標準偏差が極端に大きいのは，いずれも入力素子数が 64×64 の場合であった。誤判別率は，入力素子数が少ないほど低くなった（図 3-6）。
- (3) 隠れ素子数：第一隠れ素子が存在しない構造では，学習の収束が悪かった。誤判別率の標準偏差が極端に大きいのは，いずれも第一隠れ素子数が 8 の構造である。第一隠れ素子数が多くなるにつれて，“良”の誤判別率は小さくなり，逆に“不良”の誤判別率は大きくなった。おおむね，入力素子が隠れ素子の 100 倍以上ある構造では，100 回の収束を得るまでにより多くの試行を必要とし，誤判別率の標準偏差が高かった（図 3-7）。
- (4) 出力素子数：誤判別率の標準偏差が極端に大きいのは，いずれも出力素子数が 6 の場合であった。それ以外は，誤判別率と出力素子数との明瞭な関連は見られなかった（図 3-8）。
- (5) 出力素子数：3.3.1.2で述べた (2) の判別実験では，もともと学習が収束しやすい構造（隠れ層数は 1，入力素子数は 8×8 ， 16×16 ， 32×32 のいずれか，隠れ素子数は 8，16，32，64 のいずれか，出力素子数は 3；これらのすべての組み合わせ）をもとに出力素子数を増やしたにもかかわらず，収束しない構造が多かった（表 3-3 下 4 段）。このときの誤判別率を図 3-9に示す。平均が極端に高く，かつ標準偏差が極端に大きい誤判別率を与えた構造



(a) 全体の誤判別率



(b) “良”の誤判別率




(c) “不良”の誤判別率


◆ 隠れ層数：0 ● 隠れ層数：1 × 隠れ層数：2

図3-5 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の隠れ層数による比較

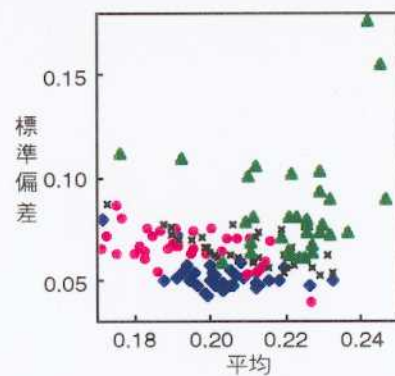
学習に失敗した構造の誤判別率は、プロットされていない。



(a) 全体の誤判別率



(b) “良”の誤判別率




(c) “不良”の誤判別率




図3-6 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の入力素子数による比較


学習に失敗した構造の誤判別率は、プロットされていない。



(a) 全体の誤判別率



(b) “良”の誤判別率



(c) “不良”の誤判別率






図3-7 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の第一隠れ素子数による比較


学習に失敗した構造の誤判別率は、プロットされていない。



(a) 全体の誤判別率



(b) “良”の誤判別率




(c) “不良”の誤判別率

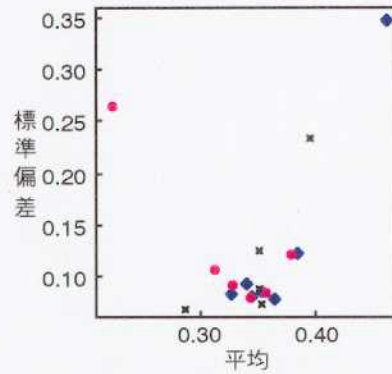
◆ 出力素子数：3 ● 出力素子数：6

図3-8 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の出力素子数による比較


学習に失敗した構造の誤判別率は、プロットされていない。



(a) 全体の誤判別率



(b) “良”の誤判別率



(c) “不良”の誤判別率

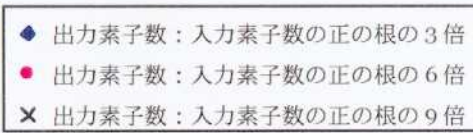




図3-9 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の出力素子数による比較


学習に失敗した構造の誤判別率は、プロットされていない。図3-5～図3-8、図3-10とは縦軸・横軸ともにスケールが異なることに注意。



(a) 全体の誤判別率



(b) “良”の誤判別率



(c) “不良”の誤判別率

◆ 結合数：完全結合 ● 結合数：完全結合の1/3

図3-10 クラスごとの100回の訓練・判別処理からの誤判別率の平均および標準偏差の結合数による比較

学習に失敗した構造の誤判別率は、プロットされていない。結合を減らした構造のもとになった完全結合をもつ構造の誤判別率も、同時にプロットした。

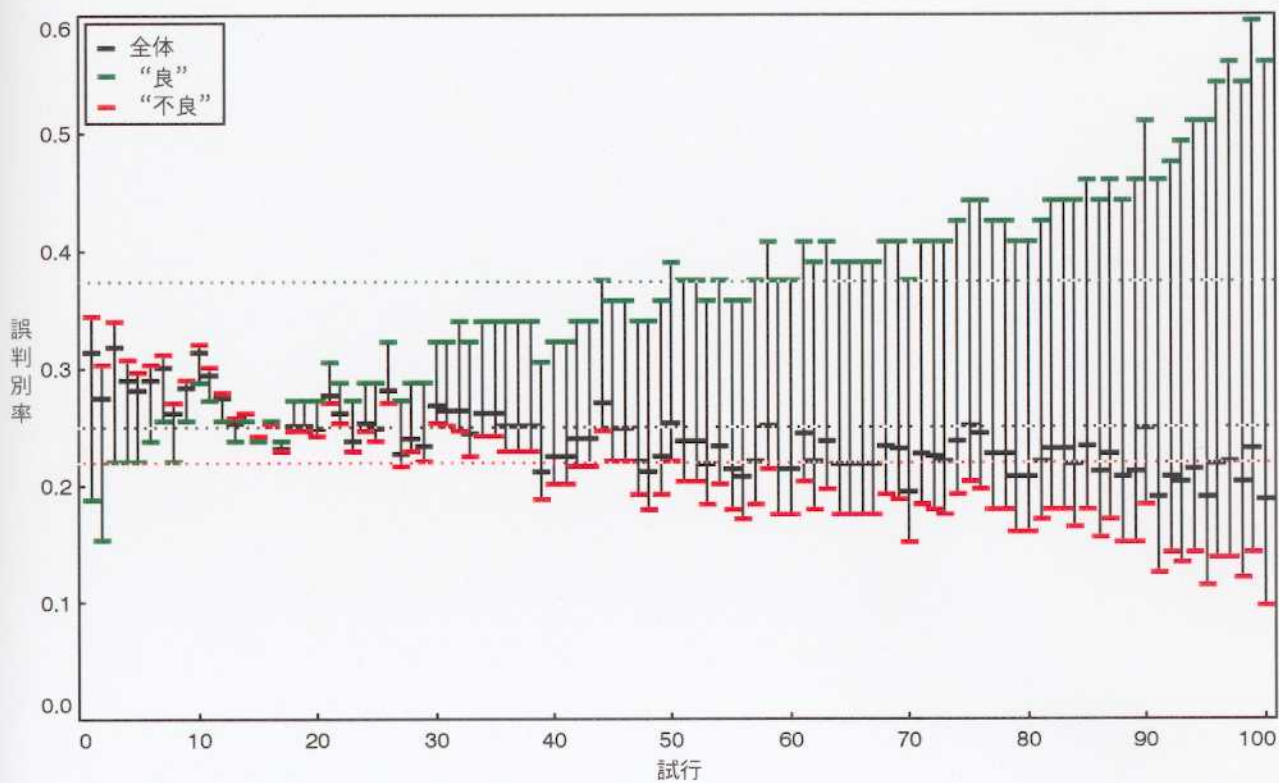


図3-11 最適な構造（隠れ層数1，入力素子数 8×8 ，隠れ素子数16，出力素子数3）の誤判別率の分布

横軸は、100回の訓練・判別処理からの“良”と“不良”との二つの誤判別率の差で昇順に整列した。破線は、上から順に“良”，全体，“不良”の誤判別率の平均値である。

もあった。それ以外の構造でも、出力素子を増やす前に比べ、誤判別率は改善されなかった。

- (6) 出力素子数：3.3.1.2で述べた(2)の判別実験では、もともと学習が収束しやすい構造（隠れ層数は1，入力素子数は 8×8 ， 16×16 ， 32×32 のいずれか，隠れ素子数は8，16，32，64のいずれか，出力素子数は3；これらのすべての組み合わせ）をもとに出力素子数を増やしたにもかかわらず、収束しない構造が多かった（表3-3下4段）。このときの誤判別率を図3-9に示す。平均が極端に高く、かつ標準偏差が極端に大きい誤判別率を与えた構造もあった。それ以外の構造でも、出力素子を増やす前に比べ、誤判別率は改善されなかった。
- (7) 結合数：3.3.1.2で述べた(3)の判別実験では、学習が収束しない構造はなかった。結合数を減らした構造、およびそれらのもとになった構造（隠れ層数は1，入力素子数は 8×8 ， 16×16 ， 32×32 のいずれか，隠れ素子数は8，16，32，64のいずれか，出力素子数は3；これらのすべての組み合わせ）の誤判別率を、図3-10に示す。結合数と誤判別率との明確な関係も、見つけられなかった。

3.3.3 考察

構造間で学習可能性および誤判別率を比較した結果から、学習が収束しやすく安定した高い汎化能力を与える構造について、次のことがいえる：

- (1) 隠れ層数は1がよい。入力素子数が 32×32 以上のとき、隠れ層のない構造では収束せず、また、2隠れ層の構造は、標準偏差の大きい誤判別率を与えることがあったからである。この結論は、阿部（1995b）の隠れ層数に関する議論の結論と一致する。
- (2) もっとも低い誤判別率が得られたため、入力素子数は、 8×8 が最適である。結合が少ないので、オーバーフィッティングも発生しにくく、また計算コストも低い。
- (3) 隠れ素子数については、入力素子数に対する相対数が少なすぎれば（おおよそ入力素子の1/100以下）学習が収束しにくくなることがわかったものの、決定的な方法が見つからなかった。阿部（1995b）の隠れ素子数に関する議論では、隠れ素子数の決定的な設定方法はなく、妥当な数を発見的に探索する妥協的な方法が提案されている。本節において導ける結論も、オーバーフィッティングを回避するため、計算コストを下げるために、学習可能性に支障を来さない程度に、隠れ素子数を減らすことの一点である。
- (4) 出力素子数はクラス数と同数の3がよい。出力素子数の増加は効果がないばかりでなく、

誤判別率の増大や不安定さを招き、計算コストを増やす。

(5) 隠れ素子と出力素子との間の結合を減らす必要性はない。

以上をまとめると、隠れ層数1、入力素子数 8×8 、出力素子数3の構造が、学習可能性と汎化能力の高さや安定性において優れていた。このとき、入力素子数が少ないため、隠れ素子数も少なくてよい。今回の実験の範囲では、16の隠れ素子をもつ構造がもっともよい性能を示した。その全体、“良”、“不良”の誤判別率の平均はそれぞれ0.239、0.362、0.208、標準偏差はそれぞれ0.028、0.089、0.052だった。この構造の誤判別率の分布を、図3-11に示す。このように、本節では、多層パーセプトロンの構造と学習可能性および汎化能力との関連を詳細に調べ、素子数の少ない、比較的単純な構造が最適であることを明らかにした。

教師データには、典型的な形状を選択して多層パーセプトロンに与えた。各クラスから無作為に選ぶよりは、低い誤判別率を示したからである。教師データとして用いる草姿の選択法は、多層パーセプトロンの汎化能力に重大な影響を及ぼす。しかしながら、「典型的な形状」の適切な定義が難しく、また、教師データの選択に目視判断を必要とする。教師データの選択も、定量的かつ簡略に行えるのが望ましい。

本節における草姿判別は、実質的には2クラスの判別問題であり、クラス数の少なさを考慮すると、誤判別率はやや高く、また“良”の判別では安定性も十分であるとはいえない。しかし、26個体と少ない教師データから、複雑で変異の大きい未知の300個体の判別を行ったことを考えると、良好な結果であるといえる。そして、テストデータには、未学習の草姿画像を使用したため、構築された多層パーセプトロンの予測性は高いと予想される。すなわち、訓練後の多層パーセプトロンを新しいグイズ草姿画像に適用すると、本節で示した程度の誤判別率で判別できると期待できる。

上記のように、いくつかの解決しなければならない問題はありますが、画像入力をもつ多層パーセプトロンは、複雑な変異を有するグイズ草姿にもそのまま適用することができたことから、さまざまな対象に適用できるという汎用性の新たな確証が得られた。

3.3.4 むすび

本節では、育種家の評価によるグイズ草姿の判別モデルとしての、非線形ニューラルネットワークである多層パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性を検討した。その結果、グイズ草姿に判別モデルを変更することなく適用でき、23.9%という十分低い誤判別率を得た。したがって、多層パーセプトロンに基づく画像入力ニューラルネットワークの、精度よく判別できる有効性とさまざまな形状に適用できる汎用性が明らかになった。ただし、形

状の典型性に基づいた教師データの選択が難しいことが、解決すべき問題として残された。

3.4 非線形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の検討

前節で、多層パーセプトロン (1.3.1 参照) に基づく画像入力ニューラルネットワークは、育種家の評価によるダイズ草姿の判別モデルとして有効であることを示したが、形状の典型性に基づいた教師データの選択が難しいことが問題だった。そこで、本節では、教師データに各クラスの平均的な草姿を定義して使用し、再び非線形ニューラルネットワークである多層パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性とを検討する。3.4.1では、多層パーセプトロンで判別処理を行うにあたって、多層パーセプトロンの構造や教師データの各種設定について説明し、3.4.2では、設定ごとに判別の結果を示し、3.4.3では、結果に基づいて、適切な多層パーセプトロンの構造や教師データ、多層パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性とを考察する。

3.4.1 判別処理の設定

3.2.1で述べたダイズ草姿に対し、非線形の画像入力をもつ多層パーセプトロンによる判別実験を行うための設定について説明する。3.4.1.1では、教師データとテストデータについて、3.4.1.2では、再代入法および一つ抜き法 (1.2.2.5 参照) による誤判別率の評価方法を述べる。なお、多層パーセプトロンの構造および訓練の方法については、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 (1.3.2.2, 1.3.2.3 参照)。

3.4.1.1 教師データとテストデータの設定

教師データの入力パターンには、形状分布 (1.2.2.2 参照) を用いた。256 画素×256 画素に正規化 (3.2.2.1参照) したダイズ草姿画像を 16 画素×16 画素、32 画素×32 画素、64 画素×64 画素に縮小し、本節では、それらのクラス内平均を形状分布と定義する。ダイズ草姿の輪郭は、標準化楕円フーリエ記述子では表現できないため、平均形状は定義できない。本節では、“良”と“悪”の2クラス、および“良”、“並”、“悪”の3クラスの判別を検討する。各クラスの形状分布を、図 3-12に示す。

テストデータは、訓練したクラスの草姿画像とした (3.2.2.2参照)。



(a) “良”



(b) “並”



(c) “悪”

図3-12 ダイズ草姿の各クラスの形状分布

形状分布は、二値の形状画像のクラス内平均である。黒い画素は、それぞれのクラスの形状画像すべてにおいて形状内部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、一部の画像で形状内部の領域に含まれることを示す。

3.4.1.2 誤判別率の計算方法

カエデ葉形による種判別と同様にして、再代入法および一つ抜き法による誤判別率を求めた(1.2.2.5 参照)。ただし、クラス数3のときは、“並”と“悪”とを合わせて“不良”のクラスとした場合と、“並”と“悪”とを別のクラスにした場合の、二種類について誤判別率を求めた。

3.4.2 結果

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3クラスの訓練以外では、すべての学習条件で学習が収束した。

入力画像サイズごとの誤判別率を図3-13に示す。学習が収束しなかった場合は、プロットされていない。16画素×16画素の形状分布を入力パターンとする教師データで訓練した場合の判別結果の二元表を、図3-14に示す。

入力画像サイズが64画素×64画素の場合、他の画像サイズに比べて誤判別率が高く、16画素×16画素と32画素×32画素とでは、誤判別率にはほとんど差がなかった。16画素×16画素の形状分布を教師データの入力パターンとしたとき、再代入法による誤判別率は2クラスでは0.148、3クラスでは“並”と“悪”とを合わせて“不良”のクラスとした場合は0.148、“並”と“悪”とを別のクラスとした場合は0.335、一つ抜き法による誤判別率は上と同じ順にそれぞれ、0.167、0.193、0.404だった。また、クラス数が増えると、誤判別率は高くなった。一つ抜き法による誤判別率は、再代入法による誤判別率より高かった(図3-13)。

図3-14で判別結果の二元表を見ると、“並”と“悪”との判別が難しかったことがわかる。

3.4.3 考察

3クラス判別において、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とき、学習が収束しなかった。このときの多層パーセプトロンの構造は、隠れ層数1、入力素子数64×64、隠れ素子数110、出力素子数3と、隠れ層数と出力素子数は、3.3の実験から得られた知見からは適切な範囲にあり、入力素子数に対する隠れ素子数も十分である。教師データが多層パーセプトロンにアンダフィットしたと思われるが、構造上に大きな問題はなく、学習係数など内部パラメタや学習方法の見直しが必要と思われる。

“並”と“悪”のクラス内変異は大きいため、このクラス間での判別誤りの頻度は高くなった(図3-14)。しかし、“良”と“不良”との間の判別誤りの相対値は、2クラス判別と3クラス判別とで、大きな差はなかった。




図3-13 入力画像サイズごとの形状分布で訓練した多層パーセプトロンによるダイズ草姿の誤判別率のクラス数ともなう変化

クラス数3のとき、下方にプロットしてある点は“並”と“悪”とを合わせて“不良”のクラスとした場合、上方にプロットしてある点は“並”と“悪”とを別のクラスとした場合である。

	判別されたクラス		合計	
			正	誤
正しいクラス	62.1 94%	3.9 6%	62.1 94%	3.9 6%
いクラス	30.7 18	136.3 82	136.3 82	30.7 18
合計	92.8 40	140.2 60	198.4 85	34.6 15

(a) 再代入法
(2クラス；誤判別率 0.148)

	判別されたクラス			合計	
				正	誤
正しいクラス	53.1 80%	12.9 20%		53.1 80%	12.9 20%
いクラス	35.5 14	224.5 86		224.5 86	35.5 14
合計	88.6 27	237.4 73		277.6 85	48.4 15

(b) 再代入法
(3クラス¹⁾；誤判別率 0.148)

	判別されたクラス			合計	
				正	誤
正しいクラス	53.1 81%	10.1 15%	2.8 4%	53.1 81%	12.9 19%
いクラス	22.8 25	48.0 51	22.2 24	48.0 51	45.0 49
ラ	12.7 8	38.6 23	115.7 69	115.7 69	51.3 31
合計	88.6 27	96.7 30	140.7 43	216.8 67	109.2 33

(c) 再代入法
(3クラス²⁾；誤判別率 0.335)

	判別されたクラス		合計	
			正	誤
正しいクラス	60.3 91%	5.7 9%	60.3 91%	5.7 9%
いクラス	33.2 20	133.8 80	133.8 80	33.2 20
合計	93.5 40	139.5 60	194.1 83	38.9 17

(d) 一つ抜き法
(2クラス；誤判別率 0.167)

	判別されたクラス			合計	
				正	誤
正しいクラス	47.9 73%	18.1 27%		47.9 73%	18.1 27%
いクラス	44.8 17	215.2 83		215.2 83	44.8 17
合計	92.7 28	233.3 72		263.1 81	62.9 19

(e) 一つ抜き法
(3クラス¹⁾；誤判別率 0.193)

	判別されたクラス			合計	
				正	誤
正しいクラス	47.9 73%	14.7 22%	3.4 5%	47.9 73%	18.1 27%
いクラス	31.3 34	32.1 34	29.6 32	32.1 34	60.9 66
ラ	13.5 8	39.3 24	114.2 68	114.2 68	52.8 32
合計	92.7 28	86.1 26	147.2 46	194.2 60	131.8 40

(f) 一つ抜き法
(3クラス²⁾；誤判別率 0.404)

図3-14 16画素×16画素の形状分布を入力パターンとする教師データで訓練した多層パーセプトロンによるダイス草姿の判別結果の二元表

枠内上段数値は頻度 (10回の訓練の平均)、下段数値は相対値 (単位：%)を示す；¹⁾ “並”と“悪”とを合わせて“不良”のクラスとした、²⁾ “並”と“悪”とを別のクラスとした。

一つ抜き法による誤判別率が、再代入法による誤判別率より大きかったことから、多層パーセプトロンが教師データにオーバーフィットしたことがうかがえる。しかし、双方の誤判別率の差は小さく、これは各クラスの個体数が多かったためと考えられる。したがって、本節で構築された多層パーセプトロンに基づく画像入力ニューラルネットワークは、まったく未知のサイズ草姿に対しても、今回の判別実験と同程度の誤判別率で判別可能であると予想される。

学習可能性と汎化能力の両方の観点から、本節で実験した構造のなかでは、64画素×64画素の形状分布を入力パターンとする教師データは、適当でないといえる。計算コストを減らし、アンダフィッティングおよびオーバーフィッティングを回避するには、16画素×16画素の形状分布を、教師データの入力パターンに選択するのがよい。

教師データの入力パターンを、典型的形状から形状分布へと変更したため、教師データ選択にともなう困難さを解決できた。汎化能力を高めるためには、教師データに使用するサンプルの大きさを増やすことが重要であるが、前者では、教師データ数を増やしたとき、訓練に費やす計算コストがそれにしただけで増大する。しかし、後者では、サンプルの大きさにかかわらず、教師データ数はクラス数と一致し、訓練のための計算コストを最小限に抑えることができる。さらに、前者の誤判別率と後者の一つ抜き法による誤判別率とを比較すると、後者のほうが低く、形状分布は教師データの入力パターンとして性質がよいことがわかった。ただし、前者では26個体だけを用いて訓練し、後者では325個体を用いて訓練しているため、厳密には、汎化能力を比較できない。

検討事項は残されているが、画像入力をもつ多層パーセプトロンは、構造や学習のための各種の内部パラメタが固定されていたにもかかわらず、それらを変更することなく、複雑な変異を有するサイズ草姿にそのまま適用できたことから、さまざまな対象に適用できる汎用性の新たな確証が得られた。

3.4.4 むすび

本節では、育種家の評価によるサイズ草姿の判別モデルとしての、非線形ニューラルネットワークである多層パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性を検討した。その結果、サイズ草姿に判別モデルを変更することなく適用でき、19.3%という十分低い誤判別率を得た。したがって、多層パーセプトロンに基づく画像入力ニューラルネットワークの、精度よく判別できる有効性とさまざまな形状に適用できる汎用性が明らかになった。さらに、形状の典型性に基づいた教師データの選択の困難さを、教師データを各クラスの平均的な形状としたことで解決できた。

3.5 線形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の検討

本節では、育種家の評価によるダイズ草姿の判別モデルとしての、線形のホップフィールドネットワーク (1.4.1 参照) および単純パーセプトロン (1.4.2 参照) に基づく画像入力ニューラルネットワークの有効性と汎用性を検討する。3.5.1では、線形ニューラルネットワークで判別処理を行うにあたって、線形ニューラルネットワークの構造や教師データの各種設定について説明し、3.5.2では、設定ごとに判別の結果を示し、3.5.3では、結果に基づいて、適切な線形ニューラルネットワークのアーキテクチャ・構造や教師データ、線形ニューラルネットワークに基づく画像入力ニューラルネットワークの有効性と汎用性を考察する (生出と二宮, 2000)。

3.5.1 判別処理の設定


3.2.1で述べたダイズ草姿に対し、線形の画像入力ニューラルネットワークによる判別実験を行うための設定については、教師データとテストデータおよび誤判別率の評価方法については、前節の多層パーセプトロンによる判別と同様 (3.4.1.1, 3.4.1.2参照)、線形ニューラルネットワークの構造および訓練の方法については、カエデ葉形による種判別と同様である (1.4.3.1, 1.4.3.2 参照) ので、説明を省略する。

3.5.2 結果

すべての学習条件の組み合わせで学習が終了した。すなわち、すべての組み合わせで教師データが一次独立だった。

入力画像サイズごとの誤判別率を、図 3-15に示す。64 画素×64 画素の形状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がもっともよい結果を示したため、この判別結果の二元表を図 3-16に示す。

誤判別率は、入力画像サイズが大きいくほど低くなった (図 3-15)。ネットワークアーキテクチャで比較すると、画像入力サイズが 32 画素×32 画素以上で、“並”と“悪”とを別のクラスとしたときの 3 クラス判別の場合はホップフィールドネットワークが若干よく、それ以外の場合は単純パーセプトロンがよかった。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とき、再代入法による誤判別率は 2 クラスでは 0.124、3 クラスでは“並”と“悪”とを合わせて“不良”のクラスとした場合は 0.138、“並”と“悪”とを別のクラスとした場合は 0.319、一つ抜き法によ







(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






—□— ホップフィールドネットワーク, 形状分布
 …○… 単純パーセプトロン, 形状分布

図3-15 入力画像サイズごとの形状分布で訓練した線形ニューラルネットワークによる
 ガイズ草姿の誤判別率のクラス数にともなう変化のネットワークアーキテクチャによる
 比較







クラス数3のとき, 下方にプロットしてある点は“並”と“悪”とを合わせて“不良”のクラスとした場合,
 上方にプロットしてある点は“並”と“悪”とを別のクラスとした場合である。

	判別されたクラス		合計		
			正	誤	
正しいクラス		62 94%	4 6%	62 94%	4 6%
		25 15	142 85	142 85	25 15
合計	87 37	146 63	204 88	29 12	



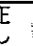
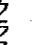
(a) 再代入法
(2クラス; 誤判別率 0.124)

	判別されたクラス			合計	
				正	誤
正しいクラス		48 73%	18 27%	48 73%	18 27%
		27 10	233 90	233 90	27 10
合計	75 23	251 77	281 86	45 14	






(b) 再代入法
(3クラス¹⁾; 誤判別率 0.138)

	判別されたクラス			合計		
				正	誤	
正しいクラス		48 72%	17 26%	1 2%	48 72%	18 28%
		14 15	58 62	21 23	58 62	35 38
クラス		13 8	38 23	116 69	116 69	51 31
	合計	75 23	113 35	138 42	222 68	104 32






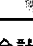
(c) 再代入法
(3クラス²⁾; 誤判別率 0.319)

	判別されたクラス		合計		
			正	誤	
正しいクラス		61 92%	5 8%	61 92%	5 8%
		31 19	136 81	136 81	31 19
合計	92 39	141 61	197 85	36 15	

(d) 一つ抜き法
(2クラス; 誤判別率 0.155)

	判別されたクラス			合計	
				正	誤
正しいクラス		39 59%	27 41%	39 59%	27 41%
		42 16	218 84	218 84	42 16
合計	81 25	245 75	257 79	69 21	

(e) 一つ抜き法
(3クラス¹⁾; 誤判別率 0.212)

	判別されたクラス			合計		
				正	誤	
正しいクラス		39 59%	26 39%	1 2%	39 59%	27 41%
		30 32	34 37	29 31	34 37	59 63
クラス		12 7	48 29	107 64	107 64	60 36
	合計	81 25	108 33	137 42	180 55	146 45

(f) 一つ抜き法
(3クラス²⁾; 誤判別率 0.448)

図3-16 64画素×64画素の形状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によるグイズ草姿の判別結果の二元表

枠内上段数値は頻度, 下段数値は相対値(単位: %)を示す; ¹⁾ “並”と“悪”とを合わせて“不良”のクラスとした, ²⁾ “並”と“悪”とを別のクラスとした.

る誤判別率は上と同じ順にそれぞれ、0.155, 0.212, 0.448 だった。どの学習条件の組み合わせにおいても、再代入法による誤判別率は、一つ抜き法による誤判別率を越えなかった。

図3-16で判別結果の二元表を見ると、多層パーセプトロンによる判別と同様“並”と“悪”との判別が難しかったことがわかる(3.4.2参照)。また、本節の判別実験では、3クラスの場合、“良”を“不良”と誤る頻度が高かったのが特徴である。

3.5.3 考察

すべての学習条件で、学習が失敗しなかった。それは、クラス数が少ないこと、形状そのものが複雑で変異に富み、形状分布が互いに一次従属にはならなかったためと思われる。

32画素×32画素以上で、“並”と“悪”とを別のクラスとしたときの3クラス判別の場合、ホップフィールドネットワークが、単純パーセプトロンより汎化能力において優れていたが、この原因は不明である。今後の検討を要する。汎化能力と判別処理の速さの点からは、最適な学習条件の組み合わせは、教師データの入力パタンの画像サイズは32画素×32画素または64画素×64画素、ネットワークアーキテクチャは単純パーセプトロンであると判断される。

線形ニューラルネットワークを用いることで、誤判別率において、多層パーセプトロンの場合より悪くなることはなかった。したがって、構造の決定の容易さと学習の速さことから、線形ニューラルネットワークが、多層パーセプトロンより優れているといえる。ただし、3クラス判別の場合の“良”の一つ抜き法による誤判別率が0.409と、多層パーセプトロンより0.135高い点に注意すべきである。

画像入力をもつ線形ニューラルネットワークは、その構造が単純であるにもかかわらず、ダイズ草姿のような複雑な変異を有する形状にも適用できることを示せた。植物器官形状による判別における最適な学習条件の組み合わせ(64画素×64画素の形状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; 2.5参照)は、ダイズ草姿にもあてはまり、画像入力をもつ線形ニューラルネットワークの適用範囲の広さを示すこととなった。

3.5.4 むすび

本節では、育種家の評価によるダイズ草姿の判別モデルとしての、線形のホップフィールドネットワークおよび単純パーセプトロンに基づく画像入力ニューラルネットワークの有効性と汎用性を検討した。その結果、ダイズ草姿に判別モデルを変更することなく適用でき、21.2%という十分低い誤判別率を得た。したがって、線形ニューラルネットワークに基づく画像入力ニューラルネ

ットワークの、精度よく判別できる有効性とさまざまな形状に適用できる汎用性が明らかとなった。

3.6 考察

前節までで、育種家の評価に従った草姿による判別に、非線形および線形の画像入力ニューラルネットワークを適用した結果から、いずれも育種家の評価を模倣できることが明らかとなり、それら判別モデルの有効性と汎用性が示された。本節では、教師データの入力パターンおよびネットワークアーキテクチャの観点から両者を比較する（3.6.1および3.6.2参照）とともに、その有効性と汎用性について（3.6.3参照）再度考察する。

3.6.1 画像入力ニューラルネットワークの性能を高めるための教師データの入力パターンに関する考察

多層パーセプトロンを使用したとき、教師データの入力パターンとして、典型的形状（3.3参照）と形状分布（3.4参照）とが汎化能力に及ぼす影響について、再び考察する。教師データ選択の困難さがなく、誤判別率が低い点で、形状分布が優れていることは、3.4.3で述べた。しかし、厳密に汎化能力を比較するには、

- (1) 326 個体全部または1 個体を除いた 325 個体を教師データとして、多層パーセプトロンを訓練し、学習が収束したら再代入法および一つ抜き法による誤判別率を求める、
- (2) 典型的形状として教師データに選ばれた 26 個体を使って各クラスの形状分布を作成し、それを教師データの入力パターンとして多層パーセプトロンを訓練し、残り 300 個体をテストデータとして誤判別率を求める、

のように、教師データのサンプルを揃える必要がある。しかし、(1) では、教師データが多く、多層パーセプトロンの学習が収束しない可能性が高い。したがって、汎化能力による両者の比較はまず不可能であり、学習可能性において、形状分布が有利であるという結果が得られるだろう。(2) の方法で、両者の汎化能力を比較するのが妥当である。

しかし、典型的形状で訓練した場合の誤判別率も、形状分布を入力パターンとする教師データで訓練した場合の3クラス判別における一つ抜き法による誤判別率も、いずれも未学習の草姿画像をテストデータとしているため、両者の誤判別率が比較可能であると仮定すると、形状分布による訓練では、とくに“良”の誤判別率が0.362から0.277へと大幅に改善されている。全体の誤判別率は、

0.239 から 0.193 へ，“不良”の誤判別率は 0.208 から 0.172 へ改善された。“良”の草姿をもつ個体の確実な選抜を目的とすれば，“良”の誤判別率の大幅な改善は，重要な意味をもつ。したがって，多層パーセプトロンにおいては，教師データの入力パターンには形状分布が優れていると結論できる。

3.6.2 画像入力ニューラルネットワークの性能を高めるためのアーキテクチャに関する考察

本章におけるダイズ草姿の判別実験では，非線形が多層パーセプトロンと線形のホップフィールドネットワークや単純パーセプトロンとでは，汎化能力の点からは大きな差はなく，最適なネットワークアーキテクチャを選ぶことができなかった。しかし，1.5.2 で述べた線形ニューラルネットワークのもつ二つの利点：

- (1) 入力画像サイズとクラス数とから，容易に構造が決定できること，
- (2) 学習が非常に高速であること，

を考慮すると，本章でも，線形ニューラルネットワークのほうが優れていると判断される。

線形のニューラルネットワークのなかでは，2.5 で最適と考えられた 64 画素×64 画素の形状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は，学習や判別の処理がともに速く完了し，本章の判別実験においても最適なネットワークアーキテクチャ・構造であった。

ただし，第 2 章では 9 サンプルの材料で判別実験を行って，その学習条件が最適であるという結論を導いたが，本章で供試したのはダイズ 1 サンプルだけである。材料によって，ネットワークアーキテクチャを使い分ける場面が出てくることもあるかもしれない。できるだけ多くの材料を供試して実験を行い，最適な画像入力ニューラルネットワークの構造について検証すべきである。

3.6.3 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に関する考察

クラス数が少ないことを考えると，第 1 章および第 2 章で得られた結果と比較すれば，誤判別率は低いとはいえない。しかし，ダイズ草姿は，形状そのものが複雑であり，クラス内の変異も非常に大きく，判別の難しい材料である。したがって，0.2 前後の誤判別率が得られたことは，十分満足できる結果と思われる。

供試した 876 個体のうち，3 人の育種家の判別が一致したのがわずか 326 個体だったことから，各個体の評価が育種家共通とはいえない部分が多い。すなわち，草姿と評価との安定した対応づ

けを見いだすことは困難である。この点は、供試データの信頼性に大いにかかわり、構築した判別モデルの信頼性は、教師データの信頼性に左右される。ここでは、教師データの信頼性について議論できないが、本研究で構築した判別モデルは、ダイズ草姿における育種家の判断の8割近くを模倣できた。したがって、信頼性のより高いデータが得られたならば、それに対しても、8割程度の模倣が可能であると考えられる。

誤判別率の改善についてはまだ課題が残されているが、画像入力ニューラルネットワークが、ダイズ草姿のように複雑な変異を有する対象に、そのまま適用できることを示せた。同時に、人間の行った評価に基づく順序だけが定められた分類群への判別も行えることが明らかとなった。最適な学習条件の組み合わせ（64画素×64画素の形状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）は、本章においてももっともよい結果を生み、他の対象にも同じように使える可能性があるという植物器官形状による判別結果からの予想（2.5参照）を支持することとなった。より複雑な形状を判別するときや、人間が設定した価値基準に適合した判別を行うときにも、画像入力ニューラルネットワークは有用で強力な形状の判別モデルになると期待される。

3.7 まとめ

第2章では、植物器官形状による種や品種・系統の判別において、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が、さまざまな対象に適用でき、安定した精度で判別できることを示した。本章では、さらに本判別モデルの有効性と汎用性を検討するために、主観的に順序のみが定められた分類群への判別問題に取り組んだ。その結果、育種家が選抜のために行ったダイズ草姿評価による判別へも判別モデルを変更することなく適用でき、また、草姿という多様な変異を有する複雑な形状に対しても、20%程度の誤判別率を達成して、安定した精度で判別できたことから、本判別モデルの有効性と汎用性が示された。これは、形状特徴量の必要性をなくしたために、判別モデルが対象に依存せず、形状のもつ情報全体を使えたためである。

本研究で提案した判別モデルの実際の育種現場や遺伝資源の特性評価への応用について考えると、植物器官形状による判別結果から考察したように、当面は、最終的な判断は評価者に委ねることにするのが妥当である(2.6参照)。そして、最終決定までの過程のなかで、判別モデルが代替できる部分を担当するように、役割を分担すべきだろう。たとえば、判別モデルによって選抜すべき個体の候補の数を半数まで減らせるとすれば、評価者の労力がそれだけ減じられるだけでなく、評価者が少ない材料の判別に集中できることにより、評価の信頼性を向上させる効果もあると思われる。また、評価者と判別モデルが同じ材料を判別し、結果を照合することで、独立した評価者が複数で同じ材料の判別を行うのと同じ効果が得られる。このように、評価者の判断を判別モデルが補完することによって、省力的かつ効率的な判別を行うことができるようになる。

本研究では、刈り取って水平に置いた状態で上方から草姿を撮影したため、裏表の二通りのパターンだけが観察できることになる。しかし、育種現場では、植物体を刈り取ることはできないため、圃場で生育している状態で画像を取得し、判別を行わなければならない。このとき、視点の位置や角度によって、草姿が異なって見える。このような場合、本判別モデルで対応するには、ある一定の位置や角度で撮像するようにするか、3次元座標を得るかして、対応しなければならないだろう。しかし、これらは、データ採取時の技術的な問題であって、判別モデルそのものはそのまま使用できると考えられる。

本章では、1個体の草姿の選抜における評価を検討した。実際の育種の現場では、個々の草姿の評価とともに、群落としての総合的な評価も必要になる。このとき、本判別モデルを利用するには、たとえば、一つの群落からいくつかの個体を選択し、群落内で草姿の形状分布をとってそれを判別

モデルに判別させる。そうすれば、群落ごとの草姿の評価に対応できると考えられる。また、各個体の判別結果の平均や多数決をとるなどのアプローチも考えられる。

本章では、判別モデルに選抜のための育種家の評価を模倣させるだけにとどまったが、受光体勢、耐倒伏性など個々の項目ごとの草姿の評価や、収量など別の規準による評価から作られた分類群への判別にも適用でき、安定的な判別精度が得られると思われる。今後の展開としては、このような新しい分類群への判別も考えていくべきである。

判別モデルへ入力する画像を取得することによって、副次的な効果が得られる。取得された画像は、複数の個体の草姿を比較して観察するのに役に立つ。これまでの目視判断では、通常、材料を移動させることができないため、ごく近隣の個体同士でしか比較ができず、しかも、草姿の時間的変化を追うことも不可能であるという条件に拘束されていた。しかし、草姿の画像を蓄積することによって、任意の地点や時点の個体を選択し、それらを一覧表示して比較することが可能になる。拘束がなくなることによって、評価者は判別能力を最大限生かすことができ、より一貫性のある判断が下せるだろう。また、取得された画像を解析することによって、形状や大きさなどに関する各種の定量データを抽出・蓄積することができる。Ninomiya and Shigemori (1991) や南ら (1991) は、画像解析によって得られた情報と生体重や葉面積指数との間に正の相関があることを報告しているが、このように画像情報と他の形質との相関が見いだせれば、画像情報を指標としてその他の形質を推定することもできる。このように、判別モデルには、画像や画像情報のデータベースや推論機構と統合することにより、より有効かつ広範な応用が考えられる。