

第1章 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 モデルの構築

緒言では、植物形状の判別における目視判断を支援・代替するには精度の高い判別モデルを構築する必要があることを述べ、形状情報と大きさ情報とを独立に評価する判別モデルを提案した。その部品として、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はじめに開発する。この判別モデルが、さまざまな対象に適用できる汎用性をもち、形状のもつ情報全体を利用できるようにするために、本研究で提案する判別モデルでは、画像そのものを直接判別モデルに入力する。そして、画像を入力データとして扱うために、①判別に有利なアルゴリズムを対象ごとに開発する必要がなく、入力として植物形状の画像を、出力としてその分類群を提示するだけで、形状を判別できるよう自動的に内部状態を調整する仕組みをもつ、②画像のような膨大なデータを容易に扱える、などの条件を備えた、神経回路網を模した計算方式であるニューラルネットワークで判別モデルを構成する。本章では、カエデ葉形による種判別を例にとり、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構築について述べる。緒言で述べたように、育種における選抜作業や遺伝資源の特性評価などを効率的に行ううえで、葉形は重要な評価形質の一つである。

1.2では、供試材料と実験方法の共通事項について述べる。1.3では、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判別モデルの有効性を検討する。多層パーセプトロンは、パターン認識問題などでもっとも頻繁に用いられているので、本章で最初に取り上げる。1.3での結果を踏まえて、1.4では、線形でより単純な構造をもつ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検討する。1.5では、1.3および1.4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。

1.1 はじめに

緒言で述べたように、育種における選抜作業や遺伝資源の特性評価などを効率的に行ううえで、葉形は重要な形質の一つであり、葉形による種や品種・系統などの判別モデルの研究開発は、これまでもさかに行われてきた。葉形指数（縦横比）を用いる方法（Sawada, 1992 ; Wu, 1994）、葉の輪郭の曲率に基づく方法（Franz *et al.*, 1991a-b）、複数の形状特徴量（面積、長さ、縦横比、円さなど）に基づく方法（Ingrouille and Laird, 1986 ; Gerber and Les, 1994 ; Warren, 1997 ; Zhang *et al.*, 1997）、標識点（landmark : 葉の裂片の先端および基部に該当する点）の数や位

置関係に基づく方法 (Carneiro and Lima, 1987; Dickinson *et al.*, 1987; Jensen, 1990; McLellan, 1990; Ray, 1992; Im *et al.*, 1998) などが挙げられる。一方で、植物材料を限定せずに、各種の葉形を類型に分類する研究もなされた (Guyer *et al.*, 1993; Yonekawa *et al.*, 1996)。これらの研究では、形状特徴量が判別に有効であることを示した。

上述した判別モデルには、形状情報と大きさ情報と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形状情報の評価が大きさ情報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、判別モデルを構築するには、まず、形状情報と大きさ情報とを分離して、大きさ情報は独立に形状情報のみを評価する必要があることを緒言で述べた。本研究では、判別モデルに入力する画像中の対象の大きさを揃えることで、この問題を解決する。また、この判別モデルが、さまざまな対象に適用できる汎用性を持ち、形状のもつ情報全体を利用できるようにする必要性も緒言で述べた。そのために、本研究では、画像そのものを直接判別モデルに入力する。そして、画像を入力データとして扱うために、ニューラルネットワークで判別モデルを構成する。本章では、カエデ葉形による種判別を例にとり、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構築と有効性の検証とについて述べる。

1.2 材料と方法

1.2.1では、供試材料を、1.2.2では、1.3および1.4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。

1.2.1 材料

供試した材料は、14種のカエデ (*Acer spp.*) 278個葉であり (表 1-1)、種判別を行う。したがって、種がクラスとなる。

1.2.2 判別処理の流れ

1.3および1.4で検討する判別処理の流れとして、葉形の正規化 (1.2.2.1参照)、各種葉形画像の復元 (1.2.2.2参照)、画像入力ニューラルネットワークによる判別モデルの構成 (1.2.2.3参照)、判別する種の選択 (1.2.2.4参照)、誤判別率の定義 (1.2.2.5参照) の各方法について述べる。

表1-1 葉形による種判別に供試したカエデ

種名 (和名)	種名 (学名)	葉数
メクスリノキ	<i>Acer nikoense</i> Maxim.	20
ミツデカエデ	<i>Acer cissifolium</i> (Sieb. et Zucc.) K. Koch	20
カラコギカエデ	<i>Acer ginnala</i> Maxim.	20
ネグンドカエデ	<i>Acer negundo</i> Linn.	20
ヒトツバカエデ	<i>Acer distylum</i> Sieb. et Zucc.	18
トウカエデ	<i>Acer buergerianum</i> Miq.	20
コブカエデ	<i>Acer compestre</i> Linn.	20
カジカエデ	<i>Acer diabolicum</i> Blume, ex Koch	20
ハナノキ	<i>Acer pycnathum</i> K. Koch	20
オオモミジ	<i>Acer palmatum</i> Thunb. var. <i>amoenum</i> (Carr.) Ohwi	20
ウリハダカエデ	<i>Acer rufinerve</i> Sieb. et Zucc.	20
イロハモミジ	<i>Acer palmatum</i> Thunb.	20
サトウカエデ	<i>Acer saccharum</i> Marsh	20
フランスモミジ	<i>Acer monspessulanm</i> Linn.	20

1 個体から無作為に1 枝を採取し、その枝から展開した葉を無作為に採取した。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。

1.2.2.1 葉形の正規化

採取した葉を紙に複写した後、ビデオカメラで撮影し、カエデ葉形の画像を取得した。これら葉形を二値化し、輪郭を抽出してチェーンコードで記述した後、標準化楕円フーリエ記述子 (Kuhl and Giardina, 1982 ; Furuta *et al.*, 1995) に変換し、相似変換、回転、平行移動、計測開始点に不変とした。ここでは、第一楕円の長軸の長さおよび向きで正規化された。楕円フーリエ係数の調和数は 20 である。これら一連の処理に使用したソフトウェアは二宮 (未発表) による。

1.2.2.2 葉形画像の復元

個葉画像の復元方法を図 1-1 に示す。標準化楕円フーリエ係数から十分にサイズの大きい画像 (本研究では 256 画素×256 画素) へ輪郭点を復元し (Kuhl and Giardina, 1982 ; Furuta *et al.*, 1995), 輪郭の内部を塗りつぶして、二値の個葉画像を作成した。このとき、葉形内部の輝度を +1, 背景を -1 と設定した。このままでは、画像サイズが大きく、計算負荷が大きいため、16 画素×16 画素, 32 画素×32 画素, 64 画素×64 画素に縮小した。これら個葉画像は、訓練後の画像入力ニューラルネットワークに入力するテストデータとして使用する。

学習可能性と汎化能力に優れた判別モデルを構築するための教師データを比較・検討するために、画像入力ニューラルネットワークの教師データの入力パターンとして、葉形分布と平均葉形の二つを定義した。葉形分布とは、16 画素×16 画素, 32 画素×32 画素, 64 画素×64 画素に縮小した後の個葉画像の種内平均である。平均葉形とは標準化楕円フーリエ係数の種内平均から輪郭を復元し、輪郭の内部を塗りつぶして、16 画素×16 画素, 32 画素×32 画素, 64 画素×64 画素に縮小した画像である。したがって、葉形分布は、濃淡画像で輝度は閉区間 [-1, +1] の実数値をとり、平均葉形は個葉画像と同様に二値画像である。葉形分布と平均葉形の作成方法を図 1-2 に示す。種ごとの葉形分布を図 1-3 に示す。図 1-4 に葉形の種内変異の例を示す。

1.2.2.3 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構成

本研究で開発した画像入力ニューラルネットワークの基本アーキテクチャは、非線形素子からなる多層パーセプトロン (上坂, 1994b) と、線形素子からなるホップフィールドネットワーク (Hertz *et al.*, 1991a) および単純パーセプトロン (Hertz *et al.*, 1991b) である。これらニューラルネットワークの基幹である学習および判別のための基本的な信号処理はそのまま利用した。そして、植物形状の判別処理に適合するよう、ニューラルネットワークの入出力の前後にデータを変換する処理を追加した (図 1-5)。入力の前処理は、画像を一次元の数値列に変換してニューラルネットワー

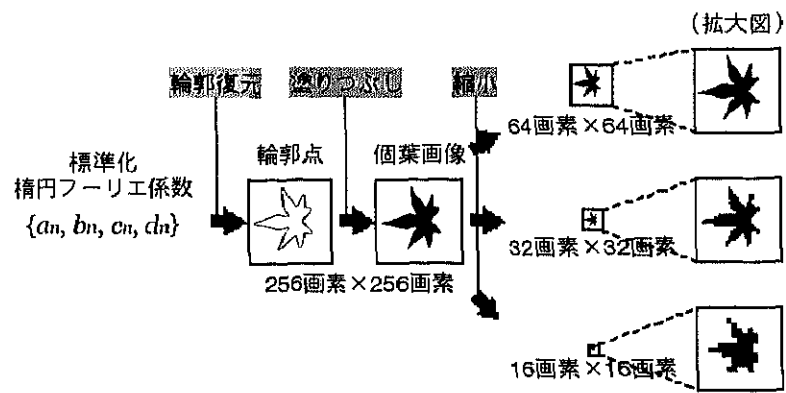
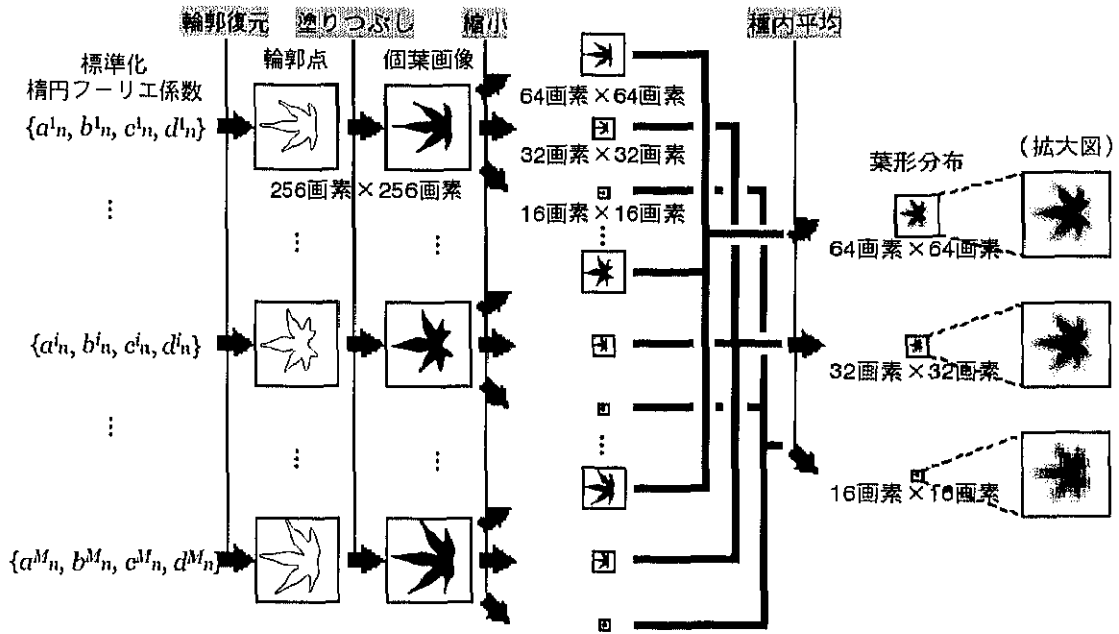
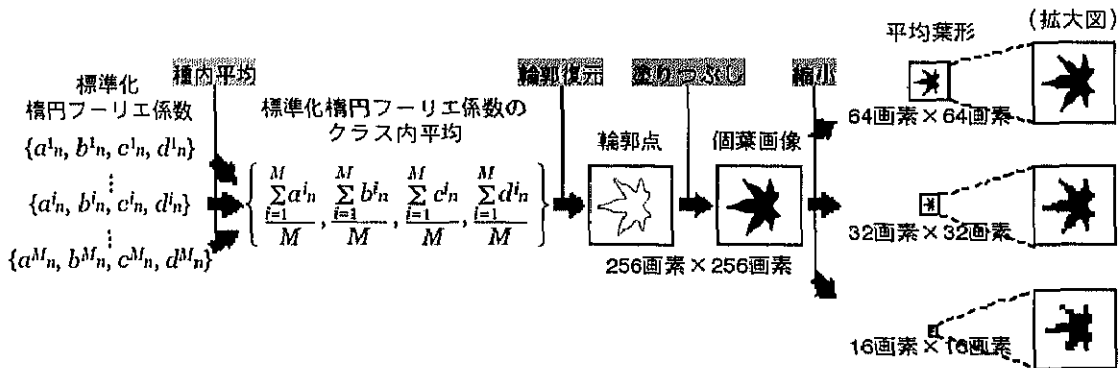


図1-1 個葉画像の復元

標準化楕円フーリエ係数から 256 画素×256 画素の画像へ輪郭点を復元し、輪郭の内部を塗りつぶして、二値の個葉画像を作成し、16 画素×16 画素、32 画素×32 画素、64 画素×64 画素に縮小した。 $\{a_n, b_n, c_n, d_n\}$ ($n=1, \dots, 20$) は標準化楕円フーリエ係数である。



(a) 葉形分布の作成



(b) 平均葉形の作成

図1-2 葉形分布と平均葉形の定義

$\{a_i^n, b_i^n, c_i^n, d_i^n\}$ ($n=1, \dots, 20$) は種内で i 番目 ($i=1, \dots, M$; M は種内の個葉数) の個葉の標準化楕円フーリエ係数である; (a) 葉形分布とは、16画素×16画素、32画素×32画素、64画素×64画素に縮小された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、(b) 平均葉形とは、標準化楕円フーリエ係数の種内平均から輪郭を復元し、輪郭の内部を塗りつぶして、16画素×16画素、32画素×32画素、64画素×64画素に縮小した画像である。




図1-3 カエデの葉形分布

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1-4 カエデの葉形分布と種内変異の例

左端の濃淡画像は葉形分布、右5枚の二値画像は個葉の形状である。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。



(a) 既存のニューラルネットワーク



(b) 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

図1-5 既存のニューラルネットワークの入出力の前後にデータ変換を行う処理を追加して構築された画像入力ニューラルネットワークの構成

ニューラルネットワークの基幹部分は共通である；(a) 既存のニューラルネットワークは、外部入力、外部出力ともに数値データである、(b) 入力の前処理は、画像の各画素の輝度を一次元の数値列に変換してニューラルネットワークの外部入力とし、ニューラルネットワークからの外部出力は、出力の後処理によって対象植物の分類群に対応づけられる。

クの外部入力とし、ニューラルネットワークの外部出力は、出力の後処理によって分類群に対応づけられる。

画像を一次元の数値列に変換する入力の前処理については、水平方向のサイズが N_x 、垂直方向のサイズが N_y の画像 ξ があるとき、座標 (x, y) ($x=0, \dots, N_x-1, y=0, \dots, N_y-1$) の画素の輝度を ξ_{xy} と表す。この2次元の輝度分布を1次元に展開して、画像 ξ の画素の輝度を ξ_i ($i=0, \dots, n-1$) と表記する。ただし、

$$i = x + N_x y \quad (x=0, \dots, N_x-1, y=0, \dots, N_y-1) \quad (\text{数式1-1})$$

$$n = N_x N_y \quad (\text{数式1-2})$$

である。

本研究では、

- (1) 画像を入力するための大容量のメモリ、
- (2) 高速に演算を行うためのごく基本的な機能だけの実行、
- (3) 将来の応用に備えた自由な各種パラメタなどの設定、

を必要としたため、C言語でニューラルネットワークのソフトウェアのシミュレータを作成した。ニューロコンピューティングに使用した電子計算機は、HP/CONVEX Exemplar SPP1600/XA-32 (HEWLETT-PACKARD Inc., Palo Alto, CA, USA), SX-4B/2 (日本電気(株), 東京), HP9000 K460 (HEWLETT-PACKARD Inc., Palo Alto, CA, USA) である。

1.2.2.4 判別種の選択

画像入力ニューラルネットワークの性能の一つの評価基準として、学習できる種数を検討した。そのために、訓練は2種から始め、5, 10, 14 と増やした。このとき、互いに葉形がもっとも異なる種を選択した。種間の葉形の非類似度は、標準化楕円フーリエ係数の第一主成分の種内平均の差と定義し、 P 種を選択するとき、この差の二乗和を最大にする組み合わせを選択した。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 (Furuta *et al.*, 1995)。図1-6に訓練する種数ごと選択された種の葉形分布を示す。

1.2.2.5 誤判別率の定義

画像入力ニューラルネットワークの性能のもう一つの評価基準は、汎化能力、すなわち未学習のデータに対する誤判別率である。学習が完了した画像入力ニューラルネットワークに、訓練した種

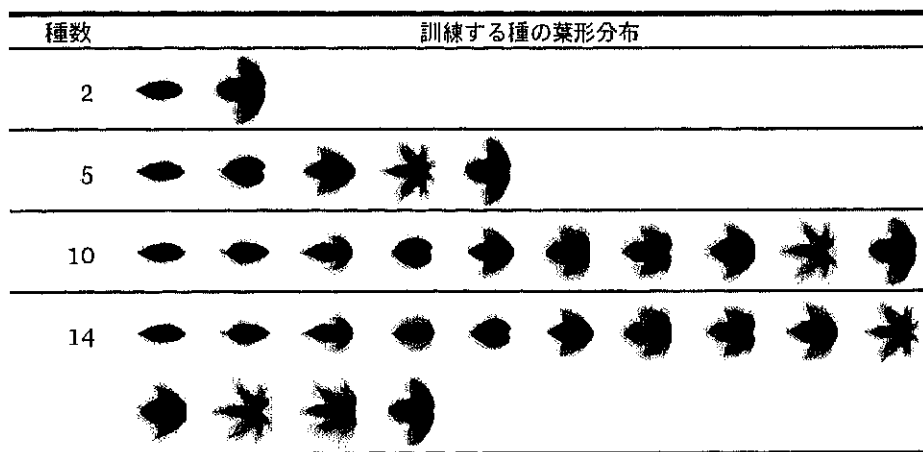


図1-6 種数ごとのカエデ葉形の訓練する種の葉形分布

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。

の個葉画像をテストデータとして与えて、誤判別率を得た。誤判別率を求めるために、再代入法 (resubstitution 法) および一つ抜き法 (leave-one-out 法) (浜本, 1994) を採用した。

再代入法とは、訓練する種に含まれる全データで作成した葉形分布および平均葉形と目標出力とを組み合わせて教師データとし、画像入力ニューラルネットワークを訓練する。その後、訓練した種の個葉画像全体をテストデータとして誤判別率を得る方法である。

再代入法による誤判別率では、教師データはテストデータとして用いられるサンプルから作られるため、誤判別率を過小評価するおそれがある。そこで、一つ抜き法により画像入力ニューラルネットワークの予測性を検討することとした。一つ抜き法では、訓練する種に含まれるデータ全体から、テストデータ用に一つ除き、残り教師データの葉形分布および平均葉形を作成する。この教師データで画像入力ニューラルネットワークを訓練した後、除いておいた一つのテストデータを入力し、それが正しく判別されるかどうかを調べる。すべての個葉画像が1回ずつテストデータになるまで、この手続きを繰り返す。

1.3 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構築

本節では、カエデ葉形による種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を検討する。多層パーセプトロンは、パタン認識などでもっとも一般的に用いられる強力なネットワークアーキテクチャであり、本章で最初に採用する。ここで、構造や教師データと、多層パーセプトロンの学習可能性や汎化能力との関連を調べる。1.3.1では、本研究で用いた多層パーセプトロンの構造や動作原理、各種設定について述べ、1.3.2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、1.3.3では、設定ごとに判別の結果を示し、1.3.4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を考察する。

1.3.1 多層パーセプトロンによる画像解析

本研究における多層パーセプトロンの構造、動作について説明する。

多層パーセプトロンの素子は、複数の層の上に配置され、隣接する層間だけで素子が完全結合し、層をまたがる結合はない。これらの結合は、フィードバックループを形成しない (図1-7)。入力素子のある層を入力層、出力素子のある層を出力層と呼ぶ。入力素子は外部からの入力、出力素子は

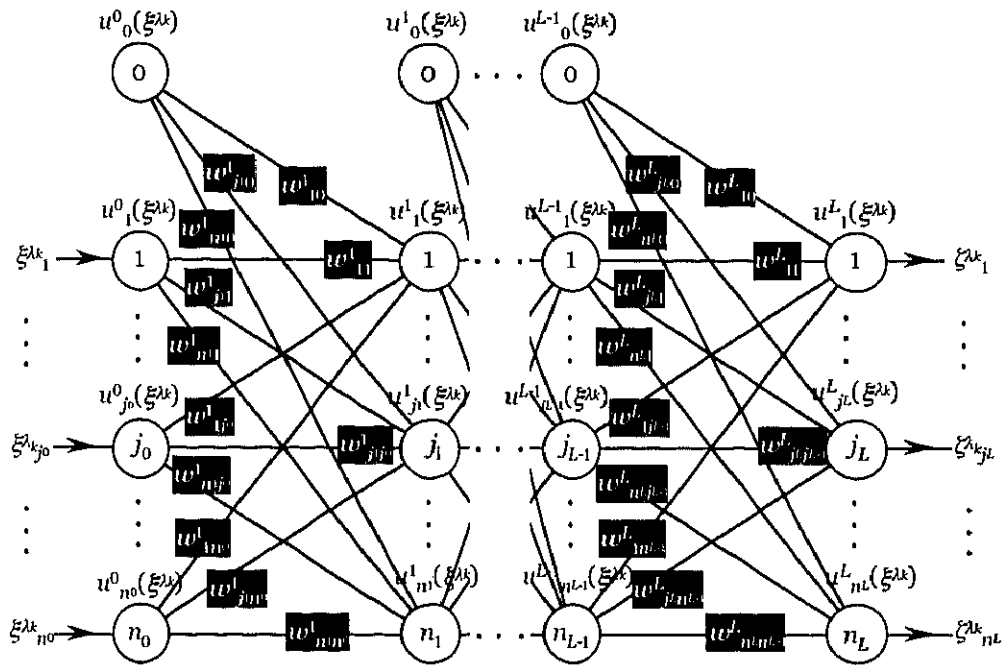


図1-7 多層パーセプトロンの構造

誤差が0で学習が完了したときの入出力関係を示す。 n_l は、第 l 層（入力層を第0層、隠れ層を第1層から第 $(L-1)$ 層、出力層を第 L 層とする）の素子数、 ξ^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、 ξ^{k_i} ($i=1, \dots, n_0$) は、 ξ^k の第 i 画素の輝度、 $u^l_i(\xi^k)$ ($l=0, \dots, L, i=0, \dots, n_l$) は、 ξ^k を入力したときの第 l 層の第 i 素子の出力、 w^l_{ij} ($l=1, \dots, L, i=1, \dots, n_l, j=0, \dots, n_{l-1}$) 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_i} は、第 λ クラスに属する第 k 教師データの目標出力ベクトル、 ζ^{k_i} ($i=1, \dots, n_L$) は、 ζ^{k_i} の第 i 成分である。

外部への出力のインタフェースをもつ。入力層と出力層の間の層を隠れ層と呼び、入力層に近い側から、第1隠れ層、第2隠れ層、…と呼ぶ。多層パーセプトロンの層の数は、1隠れ層、2隠れ層のように、隠れ層の数で指定することとする。たとえば、1隠れ層の多層パーセプトロンは、入力層、出力層および1層の隠れ層をもつ。

本研究では、教師データは各クラスに1個以上あり、第 λ クラスに属する教師データ数を m_λ とおく。素子はすべて非線形とした。入力素子数は入力画像の素子数 n と同数、出力素子数はクラス数 P の倍数とし、隠れ素子数は、任意に設定した。(L-1)隠れ層の多層パーセプトロンの動作式を次のように定義した：

$$u_i^0(\xi^{\lambda k}) = \xi_i^{\lambda k} \quad (i=1, \dots, n_0, \lambda=1, \dots, P, k=1, \dots, m_\lambda) \quad (\text{数式1-3})$$

$$u_0^l(\xi^{\lambda k}) = 1 \quad (l=0, \dots, L-1, \lambda=1, \dots, P, k=1, \dots, m_\lambda) \quad (\text{数式1-4})$$

$$u_i^l(\xi^{\lambda k}) = \sigma \left(\sum_{j=0}^{n_{l-1}} w_{ij}^l u_j^{l-1}(\xi^{\lambda k}) \right) \quad (l=1, \dots, L, i=1, \dots, n_l, \lambda=1, \dots, P, k=1, \dots, m_\lambda) \quad (\text{数式1-5})$$

ただし、

$$n_0 = n \quad (\text{数式1-6})$$

$$n_L = cP \quad (\text{数式1-7})$$

である。ここで、 n_l は、第 l 層((L-1)隠れ層の多層パーセプトロンでは、入力層を第0層、隠れ層を第1層から第(L-1)層、出力層を第L層とする)の素子数、 $u_i^l(\xi^{\lambda k})$ は、第 λ クラスに属する第 k 教師データの入力画像 $\xi^{\lambda k}$ を入力したときの第 l 層の第 i 素子の出力、 $\xi_i^{\lambda k}$ は、 $\xi^{\lambda k}$ の第 i 画素の輝度、 w_{ij}^l 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、 c は自然数の定数である。 $\sigma()$ はシグモイド(sigmoid; S字)関数であり

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (\text{数式1-8})$$

と定義した。

多層パーセプトロンは、教師データの入力画像が目標出力への写像となるように訓練される。第 λ クラスに属する第 k 教師データの目標出力 $\xi^{\lambda k}$ は、 cP 次元のベクトルであり、その第 i 成分 $\xi_i^{\lambda k}$ を

$$\xi_i^{\lambda k} = \begin{cases} +1 & (d(\lambda-1) < i \leq c\lambda) \\ -1 & (\text{otherwise}) \end{cases} \quad (i=1, \dots, n_L, \lambda=1, \dots, P, k=1, \dots, m_\lambda) \quad (\text{数式1-9})$$

とした。教師データの入力画像と目標出力ベクトルとの関係は、多層パーセプトロンのすべての素子の関数の合成関数として、

$$\begin{aligned}
 \xi_{j_L}^{\lambda k} &= u_{j_L}^L(\xi^{\lambda k}) \\
 &= \sigma \left(\sum_{j_{L-1}=0}^{n_{L-1}} w_{j_L j_{L-1}}^L u_{j_{L-1}}^{L-1}(\xi^{\lambda k}) \right) \\
 &= \sigma \left(\sum_{j_{L-1}=0}^{n_{L-1}} w_{j_L j_{L-1}}^L \sigma \left(\dots \sigma \left(w_{j_1 0}^1 + \sum_{j_0=1}^{n_0} w_{j_1 j_0}^1 \xi_{j_0}^{\lambda k} \right) \right) \right) \\
 &\quad (j_L=1, \dots, n_L, \lambda=1, \dots, P, k=1, \dots, m_\lambda)
 \end{aligned} \tag{数式1-10}$$

で表される。数式1-10が w_{ij}^l ($l=1, \dots, L, i=1, \dots, n_l, j=0, \dots, n_{l-1}$) について解ければ、目標出力が入力画像の写像となる。しかし、非線形演算を含んでいることから、 w_{ij}^l の厳密解を得ることはできないため、近似解を求める。そこで、多層パーセプトロンの学習アルゴリズムに誤差逆伝播法（緒言、付録A参照）を用いた。なお、誤差 E は

$$E = \frac{1}{2 \sum_{\lambda=1}^P m_\lambda} \sum_{\lambda=1}^P \sum_{k=1}^{m_\lambda} \sum_{i=1}^{n_L} \left(u_i^L(\xi^{\lambda k}) - \xi_i^{\lambda k} \right)^2 \tag{数式1-11}$$

と定義した。

訓練された多層パーセプトロンにテストデータを入力すると、多層パーセプトロンは cP 個の出力変数を出力する。このとき、出力変数の値から、入力画像のクラスを決定する。しかし、出力変数の値は、常に目標出力のうちのどれか一つに一致するとは限らない。そこで、第 k テスト画像($k=1, \dots, M$; M はテスト画像数)を入力したときの第 i 出力素子の出力を ψ_i ($i=1, \dots, cP$) とすると、 ψ_i が $c(K-1) < i \leq cK$ ($1 \leq K \leq P$) なる i で最大になるとき、第 k テスト画像は多層パーセプトロンによって教師データの第 K クラスに判別されたとした。

1.3.2 判別処理の設定

1.2.1で述べたカエデ葉形に対し、1.3.1で述べた画像入力をもつ非線形が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。1.3.2.1では、教師データとテストデータについて、1.3.2.2では、判別処理に使用する3層の多層パーセプトロンの構造を、1.3.2.3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、1.3.2.4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。

1.3.2.1 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、葉形分布と平均葉形（1.2.2.2参照）を用いた。教師データ数は、訓練する種数 P (2, 5, 10, 14) と同数である。訓練する種数ごとの教師データの葉形分布は、図 1-6 に示したとおりである。目標出力は、値-1 および+1 を成分とする P 次元ベクトルとする。

テストデータには、訓練した種の個葉画像（1.2.2.2参照）を与えた。

1.3.2.2 多層パーセプトロンの構造の設定

本節で用いる多層パーセプトロン（1.3.1参照）は、一つの隠れ層をもち、入力素子数 n_0 は入力画像の画素数 n と同数 (16×16, 32×32, 64×64)、出力素子数 n_2 は訓練する種数 P と同数とした (図 1-8)。隠れ素子数 n_1 は、 n と P との相乗平均：

$$n_1 = \sqrt{nP} \quad (\text{数式1-12})$$

と経験的に定めた (小数点以下は切捨て)。たとえば、10 種の判別の場合、入力画像サイズが 16 画素×16 画素、32 画素×32 画素、64 画素×64 画素のときの隠れ素子数は、それぞれ、50, 101, 202 である。

1.3.2.3 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 この誤差から、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、 $8P$ 以上ならば、最近の $8P$ 回の修正における誤差の平均二乗和および最大値を計算する。そうでなければ、②へ。
- ⑦ 誤差の平均二乗和の正の根が 0.1 未満、かつ最大値が 0.2 未満ならば、学習が収束したと見なし、手続きを終了する。そうでなければ、②へ。

100,000 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

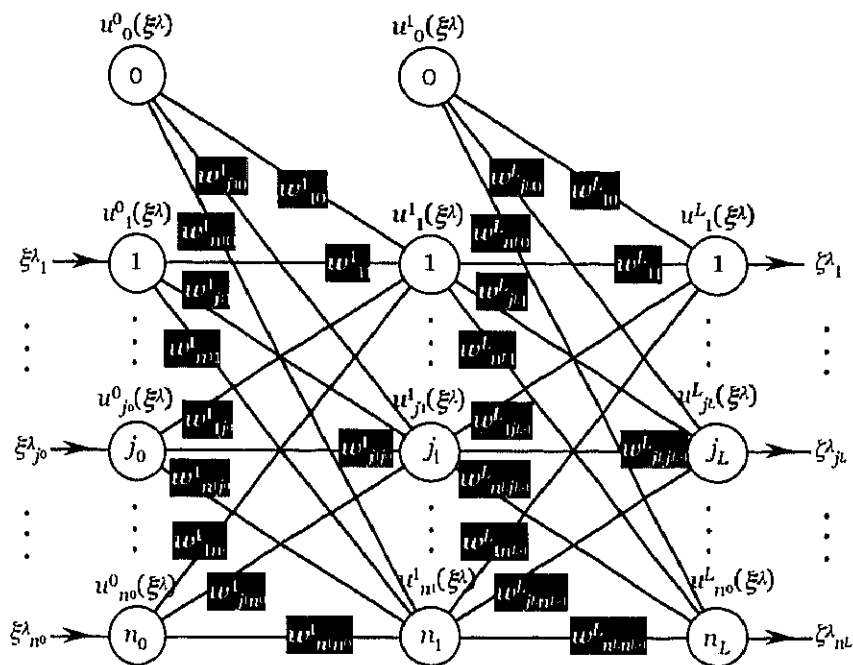


図1-8 多層パーセプトロンの構造

1 層の隠れ層をもつ. n_l を第 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) の素子数とすると, 入力素子数 n_0 は入力画像の画素数 n と同数, 出力素子数 n_2 は訓練する種数 P と同数である. 隠れ素子数 n_1 は, n と P との相乗平均とした. ξ^λ ($\lambda=1, \dots, P$) は第 λ 種の教師データの入力画像, ξ_i^λ ($i=1, \dots, n_0$) は ξ^λ の第 i 画素の輝度, $u_l^i(\xi^\lambda)$ ($l=0, 1, 2, i=1, \dots, n_l$) は ξ^λ を入力したときの第 l 層の第 i 素子の出力, w_{ij}^l ($l=1, 2, i=1, \dots, n_l, j=0, \dots, n_{l-1}$) 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^λ は第 λ 種の目標出力ベクトル, ζ_i^λ ($i=1, \dots, n_2$) は ζ^λ の第 i 成分である.

切だったと判断し、①へ戻って、新しい結合係数の初期値で訓練を再び始めた。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ジョブあたりの最大許容CPU時間(1週間)の間、学習が1度も収束しなかったとき、学習できないと判断し、手続きを終了した。

本節で設定した数値は、すべて経験的に決定したものである。学習の収束を速める、誤判別率を改善するなどの目的で、これらの数値を調整することは行わなかった。このような調整には、決定的な方法がなく、場当たり的に行わなければならないからである。

1.3.2.4 誤判別率の計算方法

本節では、画像入力をもつ多層パーセプトロンから再代入法および一つ抜き法による誤判別率(1.2.2.5参照)を求めた。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、10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をとった。

学習条件が学習可能性や汎化能力に及ぼす影響を調べるため、それぞれの材料に対して、訓練する種数(2, 5, 10, 14)、教師データ(葉形分布と平均葉形)、入力画像サイズ(16画素×16画素, 32画素×32画素, 64画素×64画素)のすべての組み合わせで訓練し、比較検討した。

1.3.3 結果

表1-2に、学習が収束しなかった学習条件の組み合わせを示す。これによると、入力画像サイズが大きい場合や、訓練した種数が多い場合、学習が収束せずに打ち切られた。平均葉形が葉形分布より学習が収束しやすかったことがわかる。

誤判別率の種数にともなう変化を、入力画像サイズごと、教師データの入力パターンごとに図1-9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。判別結果の二元表が図1-10である。

誤判別率は再代入法、一つ抜き法ともに、葉形分布を入力パターンとする教師データで訓練した場合が、平均葉形を入力パターンとする教師データで訓練した場合より低かった。入力画像サイズは、16画素×16画素がもっとも低い誤判別率を与えた。また、学習しなければならない種が増えるほど、双方の誤判別率は高くなった(図1-9)。

判別結果の二元表(図1-10)を見ると、隣り合う、すなわち、葉形の縦横比が似ている種の間には判別誤りが集中したことがわかる。また、欠刻の深い葉形をもつ種は、判別誤りが分布する範囲が広く、縦横比が似ていない種への誤判別もあった。欠刻の数が同じ種間での判別誤りも目立った。


表1-2 学習が収束しなかった学習条件の組み合わせ

(a) 再代入法

材料	入力画像サイズ	教師データ	種数
カエデ葉形	64 画素 × 64 画素	葉形分布	10 以上

(b) 一つ抜き法

材料	入力画像サイズ	教師データ	種数
カエデ葉形	32 画素 × 32 画素	葉形分布	10 以上
		平均葉形	
	64 × 64	葉形分布	5 以上
		平均葉形	10 以上



(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1-9 入力画像サイズごとの多層パーセプトロンによるカエデ葉形の誤判別率の種数にともなう変化の教師データの入力パターンによる比較

	判別された種										合計			
	●	●	●	●	●	●	●	●	●	●	正	誤		
正	20.0	0.0	0.0	0.0	0.0	0.0	20.0	0.0	100%	0%	0%	0%	20.0	0.0
し	1.0	16.9	0.1	0.0	0.0	0.0	16.9	1.1	6	93	1	0	93	7
い	0.0	1.7	18.2	0.0	0.1	18.2	1.8	0	9	90	0	1	90	10
種	0.0	1.0	0.0	19.0	0.0	19.0	1.0	0	5	0	95	0	95	5
	0.0	0.0	0.0	0.0	20.0	20.0	0.0	0	0	0	0	100	100	0
合計	21.0	19.6	18.3	19.0	20.1	94.1	3.9	21	20	19	19	21	96	4

(a) 再代入法
(5種; 誤判別率 0.040)

	判別された種										合計			
	●	●	●	●	●	●	●	●	●	●	正	誤		
正	20.0	0.0	0.0	0.0	0.0	0.0	20.0	0.0	100%	0%	0%	0%	20.0	0.0
し	1.0	16.4	0.6	0.0	0.0	0.0	16.4	1.6	6	91	3	0	91	9
い	0.0	1.8	18.2	0.0	0.0	18.2	1.8	0	9	91	0	0	91	9
種	0.0	0.9	0.0	19.0	0.1	19.0	1.0	0	5	0	94	1	94	6
	0.0	0.0	0.0	0.0	20.0	20.0	0.0	0	0	0	100	0	100	0
合計	21.0	19.1	18.8	19.0	20.1	93.6	4.4	22	19	19	19	21	96	4

(c) 一つ抜き法
(5種; 誤判別率 0.045)

	判別された種															合計								
	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	正	誤							
正	18.1	1.9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18.1	1.9	90%	10%	0%	0%	18.1	1.9					
し	2.8	17.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	17.1	2.9	14	85	0	1	85	15					
い	1.9	0.1	15.8	1.0	1.2	0.0	0.0	0.0	0.0	0.0	0.0	15.8	4.2	10	1	78	5	78	22					
種	1.0	0.0	0.0	17.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	17.0	1.0	6	0	0	94	94	6					
正	0.0	0.0	0.0	1.1	17.8	0.1	0.2	0.8	0.0	0.0	0.0	17.8	2.2	0	0	0	6	88	12					
し	0.0	0.0	0.0	1.0	1.4	14.3	1.6	0.5	0.0	1.2	14.3	5.7	0	0	0	0	5	7	29					
い	0.0	0.0	0.0	0.0	2.7	15.4	1.9	0.0	0.0	15.4	4.6	0	0	0	0	0	14	76	24					
種	0.0	0.0	0.0	0.7	0.0	0.8	18.1	0.0	0.4	18.1	1.9	0	0	0	0	0	4	90	10					
	0.1	0.0	0.9	0.0	0.0	0.0	1.1	0.4	17.5	0.0	17.5	2.5	1	0	5	0	0	5	13					
	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	20.0	20.0	0.0	0	0	0	0	0	100	0					
合計	23.9	19.1	16.7	20.2	21.1	17.1	19.1	21.7	17.5	21.6	17.1	126.9	12	10	8	10	11	9	10	11	9	11	86	14

(b) 再代入法
(10種; 誤判別率 0.136)

	判別された種															合計								
	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	正	誤							
正	16.3	3.6	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	16.3	3.7	81%	18%	0%	0%	16.3	3.7					
し	3.8	14.5	0.0	1.7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	14.5	5.5	19	72	0	9	72	28					
い	2.0	0.0	15.0	1.1	1.9	0.0	0.0	0.0	0.0	0.0	0.0	15.0	5.0	10	0	74	6	10	26					
種	1.0	0.0	0.0	16.7	0.0	0.3	0.0	0.0	0.0	0.0	0.0	16.7	1.3	6	0	0	92	92	8					
正	0.0	0.1	0.6	1.0	15.9	0.2	0.5	1.7	0.0	0.0	15.9	4.1	0	1	3	5	79	1	21					
し	0.0	0.0	0.0	1.3	1.3	10.1	4.7	0.9	0.0	1.7	10.1	9.9	0	0	0	0	7	7	50					
い	0.0	0.0	0.0	0.0	0.4	8.6	8.6	2.4	0.0	0.0	8.6	11.4	0	0	0	0	2	43	57					
種	0.0	0.0	0.0	0.0	2.3	0.0	1.3	15.4	0.0	1.0	15.4	4.6	0	0	0	0	12	0	24					
	0.0	0.0	0.9	0.2	0.0	0.1	2.5	0.7	15.5	0.1	15.5	4.5	0	0	5	1	0	1	24					
	0.0	0.0	0.0	0.0	0.0	0.2	0.0	0.0	0.0	19.8	19.8	0.2	0	0	0	0	1	0	99					
合計	23.1	18.2	16.5	22.1	21.8	19.5	17.6	21.1	15.5	22.6	147.8	50.2	12	9	8	11	11	10	9	11	8	11	75	25

(d) 一つ抜き法
(10種; 誤判別率 0.254)

図1-10 16画素×16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多層パーセプトロンによるカエデ葉形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。

1.3.4 考察

表 1-2に示した学習条件では、学習に失敗した。その原因は、弛緩計算に費やせる時間や電子計算機の処理速度が不足しただけでなく、

- (1) 結合係数の初期値が不適切である、
 - (2) 学習係数（緒言参照）の設定が不適切である、
 - (3) 学習の打ち切り条件（1.3.2.3参照）が不適切である、
 - (4) 与えられた教師データに対して、多層パーセプトロンがアンダフィット（緒言参照）した、
- なども考えられる。このような内部パラメタや構造の改善には、結合係数の修正手続き中における、多層パーセプトロンの誤差の変動を観察したうえで、対処する必要がある。

判別誤りは、種内変異が種間変異を越え、他の種の教師データに似る個葉に発生した。したがって、誤判別率は種間変異に対する相対的な種内変異に依存する。判別する種数の増加にともなって誤判別率も増加したが、これは、相対的な種内変異が大きくなったことが原因と考えられる。判別する種は、互いに葉形がもっとも異なるよう選択しており（1.2.2.4参照）、判別する種数が増えると、隣接する種間変異が小さくなる。

学習条件と学習可能性との関連を考えると、教師データの入力パターンでは、平均葉形が有利であった。入力変数の数、すなわち画像サイズが同じならば、理論上は、保持する情報量は葉形分布と平均葉形とで差はない。しかし、実質的には、平均葉形のほうが情報量が少なく、アンダフィッティングが発生しにくかったと考えられる。入力画像サイズにおいては、小さいほど学習が収束しやすかった。一般には、サイズが大きいほど、ニューラルネットワークは教師データに適合しやすくなるはずであるが、ここでは計算コストが高すぎて学習が収束に至らなかったと考えられる。種数と学習可能性との関連を見ると、種数の増加にともない、学習は収束しにくくなった。種数が多い場合、教師データの種間変異が、絶対的にも小さくなる。類似した入力パターンに対しては、画像入力ニューラルネットワークの出力も近い値にならざるをえない。そのため、種間変異が小さい教師データを与えられると、画像入力ニューラルネットワークの誤差を規定された範囲に収めることが困難または不可能になるのである。教師データ数の増加にともなう計算コストの増大も、学習の収束を妨げた原因である。

次に、学習条件と汎化能力との関連を考えると、教師データの入力パターンでは、学習可能性との関連とは逆に、葉形分布が優れていた。葉形分布では、連続的な輝度が種内変異を表現するのに適していたと考えられる。入力画像サイズにおいては、小さいほど誤判別率が低く抑えられた。これ

は、サイズの大きい画像ではオーバーフィッティングが起きたことが原因と考えられる。種数と汎化能力との関連を見ると、上で述べたとおり、種数の増加にともない、誤判別率が増加した。種内変異が、種間変異を越えやすくなったことが原因である。

学習可能性と汎化能力との両方を考慮すると、今回の実験の結果だけからは、最適な構造や教師データを決定できない。多層パーセプトロンの隠れ層数や隠れ素子数を増やせば、入力画像サイズの大きい葉形分布を入力パターンとする教師データでも、アンダフィッティングが解消され、学習が可能になる。しかし、そのような隠れ素子の多い多層パーセプトロンを、小さい入力画像サイズの平均葉形を入力パターンとする教師データで訓練しようとするとき、多層パーセプトロンがオーバーフィットし、汎化能力が下がると思われる。このように、一つの学習条件を変化させれば、それにふさわしい他の学習条件も異なってくる。すべての学習条件にさまざまな設定を与え、実際に判別実験を行わなければ、最適な構造と教師データを決定できない。

多層パーセプトロンの結合数や訓練した種数が多いとき、学習に長時間を要し、さらに、訓練した種数が多いときには、高い汎化能力が得られなかった。この二点が、解決すべき問題として残された。電子計算機の処理速度やデータ処理に費やせる時間が有限であるなかで、学習の収束を速め、そして、汎化能力をさらに改善するには、構造や学習のための各種の内部パラメタ（学習係数、結合係数の初期値など）について、比較検討し、最適なものを見いだす必要がある。これら設定は、材料によって異なるため、場当たりのに行わなければならない。画像入力ニューラルネットワークを導入した本来の目的から外れてしまうおそれがある。学習が速く完了し、かつ最適な構造や各種の内部パラメタが容易に決定できるようなネットワークアーキテクチャを採用することが、目的に即応した解決策といえよう。

解決すべき問題が残されたが、画像入力をもつ多層パーセプトロンから、十分低い誤判別率が得られた。このように、画像入力をもつ多層パーセプトロンは、カエデ葉形に基づく種判別に有効に働くと考えられる。

1.3.5 むすび

本節では、カエデ葉形による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を検討した。構造や教師データと、多層パーセプトロンの学習可能性や汎化能力との関連を調べたところ、小さいサイズの画像を教師データの入力パターンとしたとき、学習可能性・汎化能力ともに優れていた。そのとき、25.4%の誤判別率で10種の判別が行え、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

がカエデ葉形を精度よく判別できる有効性をもつことを示せた。ただし、学習の収束が遅いこと、適切な構造や学習のための内部パラメタの決定が容易でないことが、解決すべき問題として残された。

1.4 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構築

前節で、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は、カエデ葉形の判別モデルとして有効であることを示したが、学習の収束が遅く、適切な構造や学習のための内部パラメタの決定が容易でないことが問題だった。そこで、本節では、構造の決定が容易で、学習のための内部パラメタの必要なしに学習が速く完了する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を、カエデ葉形判別に適用し、その有効性を検討する。前節と同様、ネットワークアーキテクチャ・構造や教師データと、線形ニューラルネットワークの学習可能性や汎化能力との関連を調べる。1.4.1 および1.4.2では、本研究で用いた線形ニューラルネットワークの構造や動作原理、各種設定について述べ、1.4.3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、1.4.4では、設定ごとに判別の結果を示し、1.4.5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を考察する。

1.4.1 ホップフィールドネットワークによる画像解析

本研究におけるホップフィールドネットワークの構造、動作について説明する。

ホップフィールドネットワークは、素子が相互に完全結合されたニューラルネットワークである(図1-11)。それぞれの素子は、外部からの入力、外部への出力のインタフェースをもつ。

本研究では、教師データは各クラスに一つずつ、合計でクラス数と同数とした(1.4.3.1参照)。また、ホップフィールドネットワークは、入力画像の画素数 n と同数の線形素子をもつこととした。動作式は、次のように定義した：

$$u_i^t(\xi^\lambda) = \xi_i^\lambda \quad (i=1, \dots, n, \lambda=1, \dots, P, t=0) \quad (\text{数式1-13})$$

$$u_i^t(\xi^\lambda) = \sum_{j=1}^n w_{ij} u_j^{t-1}(\xi^\lambda) \quad (i=1, \dots, n, \lambda=1, \dots, P, t=1, 2, \dots) \quad (\text{数式1-14})$$




図1-11 ホップフィールドネットワークの構造

学習完了後の入出力関係を示す。 n は、入力画像の画素数、 ξ^λ ($\lambda=1, \dots, P$; P はクラス数) は、第 λ クラスの教師データの入力画像、 ξ^λ_i ($i=1, \dots, n$) は、 ξ^λ の第 i 画素の輝度、 $u_i(\xi^\lambda)$ は、 ξ^λ を入力したときの第 i 素子の出力、 w_{ij} ($j=1, \dots, n$) は、第 j 素子から第 i 素子への結合係数、 ζ^λ は、第 λ クラスの教師データの目標出力、 ζ^λ_i は、 ζ^λ の第 i 成分である。

ここで、 P は、クラス数、 $w_i(\xi^\lambda)$ は、第 λ クラスの教師データの入力画像 ξ^λ を入力したときの時刻 t における第 i 素子の出力、 ξ_i^λ は、 ξ^λ の第 i 画素の輝度、 w_{ij} は、第 j 素子から第 i 素子への結合係数である。

ホップフィールドネットワークが連想記憶として働くよう、すなわち、あるパタンを入力すると、記憶したパタンのうち、それともっともよく似たパタンを復元するよう、第 λ クラスの教師データの目標出力 ξ_i^λ を、対応する入力画像 ξ^λ と同じ画像とした。したがって、

$$\xi_i^\lambda = \xi_i^\lambda \quad (i=1, \dots, n, \lambda=1, \dots, P) \quad (\text{数式1-15})$$

である。ここで、 ξ_i^λ は、 ξ^λ の第 i 画素の輝度である。教師データの入力画像と目標出力との関係は、

$$\xi_i^\lambda = \sum_{j=1}^n w_{ij} \xi_j^\lambda \quad (i=1, \dots, n, \lambda=1, \dots, P) \quad (\text{数式1-16})$$

となり、これを w_{ij} ($i, j=1, \dots, n$) について解くと、

$$w_{ij} = \frac{1}{n} \sum_{\mu=1}^P \sum_{\nu=1}^P \xi_i^\mu (Q^{-1})_{\mu\nu} \xi_j^\nu \quad (i, j=1, \dots, n) \quad (\text{数式1-17})$$

が得られる。ここで、 Q は、 P 行 P 列のオーバラップ行列であり、 μ 行 ν 列の成分 $Q_{\mu\nu}$ は、

$$Q_{\mu\nu} = \frac{1}{n} \sum_{i=1}^n \xi_i^\mu \xi_i^\nu \quad (\mu, \nu=1, \dots, P) \quad (\text{数式1-18})$$

と定義される。

訓練後のホップフィールドネットワークに、初期値としてテストデータを入力すると、数式1-14を繰り返し計算し、やがて時刻によらずすべての素子の出力が変化しない状態である平衡状態に到達する。このとき計算を打ち切り、出力値から入力画像のクラスを決定する。しかし、平衡状態で想起された画像は、教師データの入力画像のいずれか一つと一致する可能性は低く、ふつうはそれらの線形和になる。したがって、連想された画像から単純にそのクラスを決定することはできない。このような場合、第 κ テスト画像 ($\kappa=1, \dots, M$; M はテスト画像数) を入力したときに想起された画像を ψ とすると、教師データの入力画像のうち、第 λ クラスの教師データの入力画像が ψ との相関がもっとも高いとき、第 κ テスト画像はホップフィールドネットワークによって第 λ クラスに判別されたとした。

1.4.2 単純パーセプトロンによる画像解析

本研究における単純パーセプトロンの構造、動作について説明する。

単純パーセプトロンは、入力層と出力層とからなり、それぞれの層に素子が配置される。異なる層の間で、素子は完全結合される（図 1-12）。入力素子は外部からの入力、出力素子は外部への出力のインタフェースをもつ。

本研究では、教師データは各クラスの一つずつ、合計でクラス数と同数とした（1.4.3.1参照）。また、単純パーセプトロンの素子はすべて線形とした。入力素子数は入力画像の素子数 n と、出力素子数はクラス数 P と、それぞれ同数とした。動作式は次のように定義した：

$$u_i^0(\xi^\lambda) = \xi_i^\lambda \quad (i=1, \dots, n, \lambda=1, \dots, P) \quad (\text{数式1-19})$$

$$u_i^1(\xi^\lambda) = \sum_{j=1}^n w_{ij} u_j^0(\xi^\lambda) \quad (i, \lambda=1, \dots, P) \quad (\text{数式1-20})$$

ここで、 $u_i^0(\xi^\lambda)$ 、 $u_i^1(\xi^\lambda)$ は、それぞれ、第 λ クラスの教師データの入力画像 ξ^λ を入力したときの第 i 入力素子、第 i 出力素子の出力、 ξ_i^λ は、 ξ^λ の第 i 画素の輝度、 w_{ij} は、第 j 入力素子から第 i 出力素子への結合係数である。単純パーセプトロンは、教師データの入力画像が目標出力への写像となるように訓練される。 ξ^λ を第 λ クラスの教師データの目標出力とすると、 ξ^λ は、 P 次元のベクトルであり、その第 i 成分 ξ_i^λ を

$$\xi_i^\lambda = \begin{cases} +1 & (i=\lambda) \\ -1 & (i \neq \lambda) \end{cases} \quad (i, \lambda=1, \dots, P) \quad (\text{数式1-21})$$

とした。したがって、教師データの入力画像と目標出力変数との関係は、

$$\xi_i^\lambda = \sum_{j=1}^n w_{ij} \xi_j^\lambda \quad (i, \lambda=1, \dots, P) \quad (\text{数式1-22})$$

となり、これを w_{ij} ($i=1, \dots, P, j=1, \dots, n$) について解くと次の値が得られる：

$$w_{ij} = \frac{1}{n} \sum_{\lambda=1}^P \sum_{\mu=1}^P \xi_i^\mu (Q^{-1})_{\mu\nu} \xi_j^\nu \quad (i=1, \dots, P, j=1, \dots, n) \quad (\text{数式1-23})$$

ここで、 Q は数式 1-18 で定義したオーバラップ行列である。

訓練された単純パーセプトロンにテストデータを入力すると、単純パーセプトロンは P 個の出力変数を出力する。このとき、出力変数の値から、入力画像のクラスを決定する。しかし、出力変数の値は、目標出力のうちのどれか一つに一致する可能性は低い。そこで、第 k テスト画像 ($k=1, \dots, M$; M はテスト画像数) を入力したときの第 i 出力素子の出力を ψ_i^k ($i=1, \dots, P$) とすると、 ψ_i^k が $i=K$ ($1 \leq K \leq P$) で最大になるとき、第 k テスト画像は単純パーセプトロンによって教師データの第 K




図1-12 単純パーセプトロンの構造

学習完了後の入出力関係を示す。 n は、入力画像の画素数、 P は、クラス数、 ξ^λ ($\lambda=1, \dots, P$) は、第 λ クラスの教師データの入力画像、 ξ_j^λ ($j=1, \dots, n$) は、 ξ^λ の第 j 画素の輝度、 $u^0_j(\xi^\lambda)$ 、 $u^2_i(\xi^\lambda)$ ($i=1, \dots, P$) は、それぞれ、 ξ^λ を入力したときの第 j 入力素子、第 i 出力素子の出力、 w_{ij} は、第 j 入力素子から第 i 出力素子への結合係数、 ζ^λ は、第 λ クラスの教師データの目標出力ベクトル、 ζ_i^λ は、 ζ^λ の第 i 成分である。

クラスに判別されたとした。

1.4.3 判別処理の設定

1.2.1で述べたカエデ葉形に対し、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説明する。1.4.3.1では、判別処理に使用する線形ニューラルネットワークの構造を、1.4.3.2では、線形ニューラルネットワークの訓練の手法を、1.4.3.3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。教師データとテストデータの設定は、多層パーセプトロンによる判別実験と同様であるので説明は省略する(1.3.2.1参照)。

1.4.3.1 線形ニューラルネットワークの構造の設定

1.4.1で述べたホップフィールドネットワークおよび1.4.2で述べた単純パーセプトロンをそのまま用いた。両者の構造は、入力画像サイズと訓練する種数とから自動的に定まる。

1.4.3.2 線形ニューラルネットワークの訓練の設定

1.4.1および1.4.2で述べた方法で訓練する。学習のために設定しなければならない各種の内部パラメタは、存在しない。

1.4.3.3 誤判別率の計算方法

本節では、画像入力をもつ線形ニューラルネットワークから再代入法および一つ抜き法による誤判別率を求めた。ここでは、ニューラルネットワークの訓練に弛緩的計算が入らないため、訓練における教師データと判別におけるテストデータが等しければ、常に等しい判別結果が得られる。したがって、訓練および判別の試行は、1回だけ行った。

学習条件が学習可能性や汎化能力に及ぼす影響を調べるため、それぞれの材料に対して、種数(2, 5, 10, 14)、ネットワークアーキテクチャ(ホップフィールドネットワークと単純パーセプトロン)、教師データ(葉形分布と平均葉形)、入力画像サイズ(16画素×16画素, 32画素×32画素, 64画素×64画素)のすべての組み合わせで訓練し、比較検討した。

1.4.4 結果

入力画像サイズが16画素×16画素で、訓練した種数が10以上の場合を除いて、すべての学習条件の組み合わせで学習が終了した(表1-3)。学習ができなかった原因は、教師データが一次独立性

表1-3 学習が収束しなかった学習条件の組み合わせ

材料	画像サイズ	教師データ	種数
カエデ葉形	16 画素 × 16 画素	平均葉形	10 以上

ここに示した組み合わせは、再代入法と一つ抜き法で共通である。

を保てなくなり、その結果、連立一次方程式から結合係数を決められなくなったからである。

単純パーセプトロンは、ホップフィールドネットワークよりも速く判別処理をすることができた。なぜなら、単純パーセプトロンでの判別はデータが一度通過すれば終わるのに対し、ホップフィールドネットワークでの判別は、平衡状態に達するまで弛緩的な計算が必要だからである。

材料ごと、入力画像サイズごとの誤判別率を図1-13に示す。学習が失敗した場合は、プロットされていない。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による判別結果の二元表が図1-14である。

再代入法による誤判別率は、学習条件の組み合わせによって異なった。入力画像サイズは32画素×32画素や64画素×64画素が16画素×16画素よりよく、ネットワークアーキテクチャは単純パーセプトロンがホップフィールドネットワークよりよく（16画素×16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場合は例外）、教師データの入力パターンは葉形分布が平均葉形よりよかった。結局、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が、もっとも低い再代入法による誤判別率を示した。一つ抜き法による誤判別率は、入力画像サイズが大きくなるにつれて低くなったが、他の学習条件による差は小さく、また、系統的なちがいも見いだせなかった。

学習しなければならぬ種が増えるほど、誤判別率は高くなった。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1-14で判別誤りの発生の分布を見ると、近隣の種間、すなわち葉形の縦横比が似た種間で判別誤りが集中したことがわかる。

1.4.5 考察

1.3.4で検討した多層パーセプトロンと同様、判別誤りは、種内変異が種間変異を越え、他の種の教師データに似る個葉があるとき発生した。また、判別誤りが、葉形の縦横比が似た種間で多い（図1-14）ことから、それが示唆される。

全般的に、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いか等しかったことから、常にオーバーフィッティングが発生したといえる。

学習条件と学習可能性との関連について考えると、学習が失敗したのは、16画素×16画素の平均葉形を入力パターンとする教師データによる訓練である（表1-3）。このことから、学習に関しては、種数が多い場合、32画素×32画素以上の十分大きい画像サイズをもつ葉形分布が、教師データの入力パターンとして有利であることがわかった。サイズの大きい画像が葉形を細部まで表現できるこ



(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1-13 入力画像サイズごとの線形ニューラルネットワークによるカエデ葉形の誤判別率の種数ともなう変化のネットワークアーキテクチャおよび教師データの入力パターンによる比較

		判別された種					合計	
		●	◐	◑	◒	◓	正	誤
	●	20	0	0	0	0	20	0
		100%	0%	0%	0%	0%	100%	0%
正	◐	1	17	0	0	0	17	1
		6	94	0	0	0	94	6
しい	◑	0	1	19	0	0	19	1
		0	5	95	0	0	95	5
種	◒	0	1	0	19	0	19	1
		0	5	0	95	0	95	5
	◓	0	0	0	0	20	20	0
		0	0	0	0	100	100	0
合計		21	19	19	19	20	95	3
		22	19	19	19	21	97	3

(a) 再代入法
(5種；誤判別率0.031)

		判別された種					合計	
		●	◐	◑	◒	◓	正	誤
	●	20	0	0	0	0	20	0
		100%	0%	0%	0%	0%	100%	0%
正	◐	1	17	0	0	0	17	1
		6	94	0	0	0	94	6
しい	◑	0	1	19	0	0	19	1
		0	5	95	0	0	95	5
種	◒	0	1	0	19	0	19	1
		0	5	0	95	0	95	5
	◓	0	0	0	0	20	20	0
		0	0	0	0	100	100	0
合計		21	19	19	19	20	95	3
		22	19	19	19	21	97	3

(c) 一つ抜き法
(5種；誤判別率0.031)

		判別された種										合計		
		●	◐	◑	◒	◓	◔	◕	◖	◗	◘	◙	正	誤
	●	20	0	0	0	0	0	0	0	0	0	20	0	
		100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	
	◐	0	20	0	0	0	0	0	0	0	0	20	0	
		0	100	0	0	0	0	0	0	0	0	100	0	
	◑	2	0	16	1	1	0	0	0	0	0	16	4	
		10	0	80	5	5	0	0	0	0	0	80	20	
	◒	0	1	0	17	0	0	0	0	0	0	17	1	
		0	6	0	94	0	0	0	0	0	0	94	6	
正しい	◓	0	0	1	0	19	0	0	0	0	0	19	1	
		0	0	5	0	95	0	0	0	0	0	95	5	
種	◔	0	0	2	0	1	15	2	0	0	0	15	5	
		0	0	10	0	5	75	10	0	0	0	75	25	
	◕	0	0	0	0	0	2	17	1	0	0	17	3	
		0	0	0	0	0	10	85	5	0	0	85	15	
	◖	0	0	0	0	0	0	2	18	0	0	18	2	
		0	0	0	0	0	10	90	0	0	0	90	10	
	◗	0	0	1	0	0	0	2	1	16	0	16	4	
		0	0	5	0	0	0	10	5	80	0	80	20	
	◘	0	0	0	0	0	3	0	0	0	0	17	3	
		0	0	0	0	0	15	0	0	0	85	85	15	
合計		22	21	20	18	21	20	23	20	16	17	175	23	
		11	11	10	9	11	10	11	10	8	9	88	12	

(b) 再代入法
(10種；誤判別率0.116)

		判別された種										合計		
		●	◐	◑	◒	◓	◔	◕	◖	◗	◘	◙	正	誤
	●	18	2	0	0	0	0	0	0	0	0	18	2	
		90%	10%	0%	0%	0%	0%	0%	0%	0%	0%	90%	10%	
	◐	0	20	0	0	0	0	0	0	0	0	20	0	
		0	100	0	0	0	0	0	0	0	0	100	0	
	◑	2	0	15	1	2	0	0	0	0	0	15	5	
		10	0	75	5	10	0	0	0	0	0	75	25	
	◒	0	0	0	17	0	1	0	0	0	0	17	1	
		0	0	0	94	0	6	0	0	0	0	94	6	
正しい	◓	0	0	1	0	19	0	0	0	0	0	19	1	
		0	0	5	0	95	0	0	0	0	0	95	5	
種	◔	0	0	1	0	1	11	6	0	0	1	11	9	
		0	0	5	0	5	55	30	0	0	5	55	45	
	◕	0	3	0	0	0	6	10	1	0	0	10	10	
		0	15	0	0	0	30	50	5	0	0	50	50	
	◖	0	1	0	0	0	2	17	0	0	0	17	3	
		0	5	0	0	0	10	85	0	0	0	85	15	
	◗	0	0	1	0	0	2	2	1	14	0	14	6	
		0	0	5	0	0	10	10	5	70	0	70	30	
	◘	0	0	0	0	0	3	0	0	0	0	17	3	
		0	0	0	0	0	15	0	0	0	85	85	15	
合計		20	26	18	18	22	23	20	19	14	18	158	40	
		10	13	9	9	11	12	10	10	7	9	80	20	

(d) 一つ抜き法
(10種；誤判別率0.202)

図1-14 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によるカエデ葉形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。

と、葉形分布のもつ連続的な輝度が種間の葉形のちがいをより詳細まで表現できることが、教師データの入力パタンの一次独立性を保つのに、貢献したと考えられる。

次に、学習条件と汎化能力との関連について考える。まず、再代入法による誤判別率については、大きい画像サイズと葉形分布のもつ連続的な輝度とが、判別にも有利に働いたと考えられる。さらに、葉形分布は、種内変異を記述することができたため、平均葉形を入力パターンとする教師データで訓練した場合より低い誤判別率が得られたと考えられる。多くの場合、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も高い誤判別率を与えた原因は、不明である。この問題は、今後の検討を要する。

一方、一つ抜き法による誤判別率について、入力画像サイズによるちがいが見られたものの、他の条件では比較的差が小さかった。この原因は、不明であり、今後、解明することが課題である。ただし、ホップフィールドネットワークと単純パーセプトロンで判別に要する計算コストを比較すると、単純パーセプトロンのほうが格段に小さい。誤判別率が同じならば、単純パーセプトロンのほうが優れているといえる。学習可能性と汎化能力の両方の観点をあわせてみると、再代入法による判別と同様、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という組み合わせが、もっともよいことになる。

画像入力をもつ線形ニューラルネットワークから、十分低い誤判別率が得られた。さらに、多層パーセプトロンで問題となっていた、学習の収束が遅いこと、適切な構造や学習のための内部パラメタの決定が容易でないことを解決できた。このように、画像入力をもつ線形ニューラルネットワークは、カエデ葉形に基づく種判別に有効に働くと考えられる。

1.4.6 むすび

本節では、カエデ葉形による種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を検討した。ネットワークアーキテクチャ・構造や教師データと、線形ニューラルネットワークの学習可能性や汎化能力との関連を調べたところ、大きいサイズの画像を教師データの入力パターンとしたときの単純パーセプトロンが、学習可能性・汎化能力ともに優れていた。そのとき、20.3%の誤判別率で10種の判別が行え、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がカエデ葉形を精度よく判別できる有効性をもつことを示せた。さらに、多層パーセプトロンで問題となっていた、学習の収束が遅いこと、適切な構造や学習のための内部パラメタの決定が容易でないことを解決できた。

1.5 考察

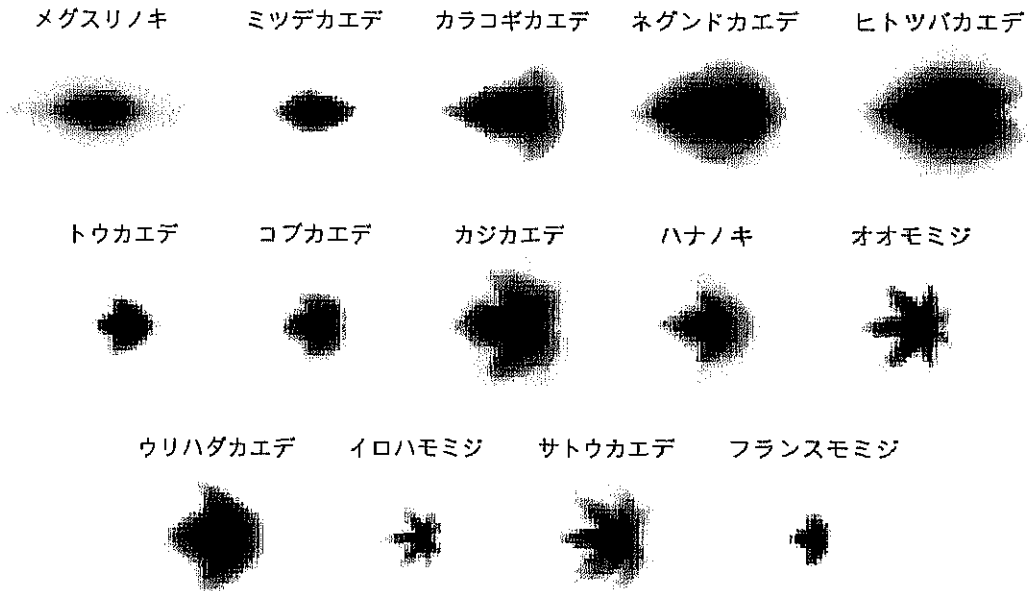
前節までで、カエデ葉形による種判別に、非線形および線形の画像入力ニューラルネットワークを適用した結果から、それら判別モデルの有効性が示された。本節では、教師データの入力パターンおよびネットワークアーキテクチャの観点から両者を比較する（1.5.1, 1.5.2参照）とともに、その有効性と汎用性について（1.5.3参照）考察する。

1.5.1 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

線形ニューラルネットワークでは、学習可能性と汎化能力の双方において、サイズの大きい葉形分布が優れていた。葉形分布では、連続的な輝度が種内変異と種間変異との双方を表現するのに適し、サイズの大きい画像では、葉形を細部まで表現できたからであると考えられる。一方、多層パーセプトロンでは、学習には平均葉形が有利であったが、誤判別率の低さでは、葉形分布が優れていた。そして、学習における計算コストを減らすためと、オーバフィッティングを回避するためには、入力画像サイズは小さいほうがよかった。

比較のために、相対的な大小関係を保持した葉形を用い、その葉形分布（図1-15a）を入力パターンとする教師データで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を訓練し、個葉画像（図1-15b）を判別させたときの誤判別率を図1-16に、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場合の判別結果の二元表を図1-17に示す。2種判別における誤判別率でさえ0.1程度であり、10種判別では、再代入法による誤判別率は0.217、一つ抜き法による誤判別率は0.313であり、双方とも大きさを揃えた葉形による判別の誤判別率よりも約0.1高い。種間で葉の大きさが著しく異なり、判別モデルが大きさ情報からの影響を強く受け、形状情報を十分に評価できなかったことが原因と考えられる。また、小さい葉をもつ種では、葉形を表すのに十分な解像度が得られず、欠刻の深さなどが表現できなかったことも原因である。そして、種内の大きさの変異もまた大きかったことが、誤判別率をより高くしたのだろう。このように、大きさ情報を含めた葉形を、画像入力ニューラルネットワークで精度よく判別するのは困難である。すなわち、標準化楕円フーリエ係数による形状の正規化により、画像入力ニューラルネットワークは大きさ情報に惑わされず、純粋に形状情報だけを評価でき、判別効率を上げたといえる。

一方で、種間で大きさの変異が大きいことから、種数が多い場合に誤判別率を改善するために、大きさ情報を用いることは有効であると予想できる。ただし、本研究で用いたニューラルネットワークは、画像中の対象の向きや位置を検出できないので、これら判別要因にはなりえない情報に




(a) 葉形分布



(b) 個葉画像の例

図1-15 相対的大小関係を保持したカエデ葉形の葉形分布と個葉画像の例

(a) 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、(b) 上段はメグスリノキ、下段はフランスモミジの個葉である。



...○... 単純パーセプトロン, 葉形分布

図1-16 入力画像サイズごとの線形ニューラルネットワークによる大きさを含むカエデ葉形の誤判別率の種数にもなう変化

		判別された種					合計	
							正	誤
正 しい 種		15	2	0	0	3	15	5
		0	15	0	3	0	15	3
		0	83	0	17	0	83	17
		0	0	18	0	2	18	2
		0	0	90	0	10	90	10
		0	0	2	18	0	18	2
		0	0	10	90	0	90	10
		0	0	2	0	18	18	2
		0	0	10	0	90	90	10
合計		15	17	22	21	23	84	14
		15	17	23	21	24	86	14

(a) 再代入法
(5種；誤判率 0.143)

		判別された種					合計	
							正	誤
正 しい 種		15	2	0	0	3	15	5
		5	11	2	0	0	11	7
		28	61	11	0	0	61	39
		0	0	17	1	2	17	3
		0	0	85	5	10	85	15
		0	0	2	18	0	18	2
		0	0	10	90	0	90	10
		0	0	3	0	17	17	3
		0	0	15	0	85	85	15
合計		20	13	24	19	22	78	20
		20	13	25	19	23	80	20

(c) 一つ抜き法
(5種；誤判率 0.204)

		判別された種										合計	
												正	誤
正 しい 種		11	8	0	0	0	0	0	0	1	0	11	9
		0	20	0	0	0	0	0	0	0	0	20	0
		0	100	0	0	0	0	0	0	0	0	100	0
		3	0	12	0	0	3	0	2	0	0	12	8
		15	0	60	0	0	15	0	10	0	0	60	40
		0	0	3	12	0	0	0	3	0	0	12	6
		0	0	17	67	0	0	0	17	0	0	67	33
		0	0	0	0	18	0	0	0	0	2	18	2
		0	0	0	0	90	0	0	0	0	10	90	10
		0	1	0	0	2	15	0	0	0	2	15	5
		0	5	0	0	10	75	0	0	10	75	25	
		0	0	0	0	0	4	13	3	0	13	7	
		0	0	0	0	0	20	65	15	0	65	35	
		0	0	0	0	0	4	0	16	0	16	4	
		0	0	0	0	0	20	0	80	0	80	20	
		0	0	0	0	0	0	0	19	1	19	1	
		0	0	0	0	0	0	0	0	95	5	95	
		0	0	0	0	1	0	0	0	19	19	1	
		0	0	0	0	5	0	0	0	95	95	5	
合計		14	29	15	12	21	26	13	24	20	24	155	43
		7	15	8	6	11	13	7	12	10	12	78	22

(b) 再代入法
(10種；誤判率 0.217)

		判別された種										合計	
												正	誤
正 しい 種		6	13	1	0	0	0	0	0	0	0	6	14
		0	19	0	0	0	0	0	0	0	0	19	1
		0	95	0	0	0	0	0	0	0	0	95	5
		3	0	12	0	0	4	0	1	0	0	12	8
		15	0	60	0	0	20	0	5	0	0	60	40
		0	0	3	11	0	0	0	4	0	0	11	7
		0	0	17	61	0	0	0	22	0	0	61	39
		0	0	0	0	16	2	0	0	0	2	16	4
		0	0	0	0	80	10	0	0	0	10	80	20
		0	1	0	0	4	13	0	0	0	2	13	7
		0	5	0	0	20	65	0	0	10	65	35	
		0	1	0	2	0	4	10	3	0	10	10	
		0	5	0	10	0	20	50	15	0	50	50	
		0	0	0	0	0	5	1	14	0	14	6	
		0	0	0	0	0	25	5	70	0	70	30	
		0	0	0	0	0	2	0	0	17	17	3	
		0	0	0	0	0	10	0	0	85	85	15	
		0	0	0	0	2	0	0	0	0	18	18	
		0	0	0	0	10	0	0	0	90	90	10	
合計		9	34	16	13	22	30	11	22	17	24	136	62
		5	16	8	7	11	15	6	11	9	12	69	31

(d) 一つ抜き法
(10種；誤判率 0.313)

図1-17 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による大きさを含むカエデ葉形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。

については、常に正規化する必要がある。

1.5.2 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

本章の判別実験では、線形のニューラルネットワークが、非線形が多層パーセプトロンより高い汎化能力を与えた (1.3.4, 1.4.5参照)。

線形で単純な構造のニューラルネットワークには、さらに、次の二つの利点がある：

- (1) 入力画像サイズと種数とから、自動的に構造が決定できる。多層パーセプトロンでは、入出力素子数を入力画像サイズと種数とから自動的に決定できたとしても、隠れ層数や隠れ素子数、内部パラメタの適切な設定が困難で、場当たりのにならざるをえない。
- (2) 学習は、連立一次方程式を解くのと同値であり、非常に高速である。多層パーセプトロンでは、学習が収束するまで弛緩的に結合係数を修正しなければならず、結合数や種数が多い場合、計算コストが高い。

線形のニューラルネットワークのなかでは、 64×64 の入力素子をもつ単純パーセプトロンが、学習・判別の処理がともに速く完了し、誤判別率ももっとも低かったため、本章の判別実験においては最適なネットワークアーキテクチャであった。

一方で、多層パーセプトロンにも利点がある。それは、アンダフィッティングが発生しにくいことである。線形のニューラルネットワークでは、教師データの入力パターンが一次従属になると、学習が不可能になるため、サイズの小さい平均葉形を入力パターンとした教師データの場合、種数が多いときには学習できなかった。しかし、多層パーセプトロンは、それらの条件下で、必ず学習が完了している。しかも、 $16 \text{画素} \times 16 \text{画素}$ の平均葉形を入力パターンとした教師データで訓練したとき、多層パーセプトロンと線形のニューラルネットワークとでは、ほぼ同程度の誤判別率が得られている。したがって、解像度の低い個葉画像を扱う状況下では、多くの種を判別するには多層パーセプトロンが有利といえる。

1.5.3 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

画像入力ニューラルネットワークの学習可能性を調べるため、訓練する種数が総数の 14 より小さいとき、互いに形状がもっとも類似していない種を選び、判別問題を簡単にした。したがって、 P 種判別において得られた誤判別率は、任意の P 種の組み合わせによる判別からの誤判別率よりも、

低い値となる。訓練する P 種を無作為に選択したとき、誤判別率の分布がどのようになるかは予想できない。この点については、今後の検討を要する。

しかし、欠刻のある複雑な葉形であるにもかかわらず、十分低い誤判別率が得られ、カエデ葉形判別に対する画像入力ニューラルネットワークの有効性が示されたといえる。

画像そのものを直接判別モデルに入力したことによって、形状特徴量の必要性がなくなり、形状のもつ情報全体を利用できるようになった。そして、ニューラルネットワークを採用したことで、判別に有利なアルゴリズムを対象ごとに開発する必要がなくなり、画像を入力データとして扱うことが可能になった。したがって、画像入力ニューラルネットワークは、形状特徴量を必要としないので、さまざまな対象に汎用的に適用できると期待される。さらに、形状のもつ情報全体を使うので、さまざまな形状に対し安定的な精度を与えると期待される。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さまざまな対象に適用し、その有効性と汎用性を実証する必要がある。遺伝資源の特性評価のように、多くの種のさまざまな植物器官形状を判別しなければならない局面では、判別モデルのこのような汎用性は非常に重要であり、汎用性が実証されれば、画像入力ニューラルネットワークは有用で強力な判別モデルになる。

1.6 まとめ

本章では、形状情報と大きさ情報とを独立に評価する判別モデルの部品として、カエデ葉形による種判別を例にとり、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構築した。画像そのものを直接判別モデルに入力したことによって、形状特徴量の必要性がなくなり、形状のもつ情報全体を利用できるようになった。そして、ニューラルネットワークを採用したことで、①判別に有利なアルゴリズムを対象ごとに開発する必要がなく、入力として植物形状の画像を、出力としてその分類群を提示するだけで、形状を判別できるよう自動的に内部状態を調整する仕組みをもち、②画像のような膨大なデータを容易に扱える、などの条件を備えているために、画像を入力データとして扱うことを可能にした。したがって、同一モデルをそのまま広範囲にわたる植物種にかかわる判別問題に活用することが可能となった。

また、カエデ葉形による種判別では、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20.2%の誤判別率で10種の判別が行えたことから、判別モデルの有効性が示された。