画像入力をもつ線形ニューラルネットワークによる ダイズ草姿判別モデル

生出真里・二宮正士

農業研究センター 〒305-8666 茨城県つくば市観音台3-1-1

要旨

育種の選抜などにおいて一貫性のある草姿評価は重要であり、そのために、これまで定量的な評価手法が開発されてきた。しかし、それらの多くは材料特有の形状特徴量を必要とし、開発された手法をそのまま新しい材料に適用することは困難だった。一方、画像を直接入力するニューラルネットワークに基づいた、形状特徴量の必要ない判別モデルが提案された。それは、ダイズ草姿評価に適用され、良好な結果が得られたが、ネットワークアーキテクチャが多層パーセプトロンであったため、最適な構造や内部パラメタの決定が難しく、学習に多大な計算コストがかかる、という問題があった。そこで、本研究では、ニューラルネットワークの構造を自動的に決定でき、学習にかかる計算コストが小さい線形ニューラルネットワークを用いて、ダイズ草姿の定量的判別を検討した。その結果、判別誤差は多層パーセプトロンの場合とほぼ同様であったが、多層パーセプトロンのもつ問題点を解決できた。線形ニューラルネットワークが、構築しやすさの点でダイズ草姿判別モデルとして優れていること、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に変異する形状に適用できることを示せた。

キーワード

画像解析, 草姿評価, ダイズ, 線形ニューラルネットワーク, 判別モデル

1. はじめに

作物の草姿は、受光態勢、ガス交換の調整、寒冷からの回避、雑草との競争の強さ、栽培管理や収穫方法に対する適応性などの面とかわり(育種ハンドブック編集委員会 1974)、収量にも大きく影響する。したがって、育種上評価すべき重要な形質である。

草姿の評価は、これまで目視に依存してきた。目視判断による草姿評価は、実際に長さや質量などの測定値から得られる評価よりも効率的であることが示されている(Jensen 1988)。しかし、作業効率が評価者の熟練度に依存したり、熟練した評価者の間でも結果が異なったりする、などの問題もある。そのため、一貫性のある評価を得て、目視判断を支援するために、これまで、定量的な評価手法の開発が行われてきた。

例えば、村井ら(1987)、山口(1982)は、それぞれイネ、カラスミギ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 *et al.* (1988, 1989)は水稻、南ら(1991)はソバ、Humphries *et al.* (1993)は切り花のテンジクアオイ、Schaufli *et al.* (1995)はシンサトウキビの苗、Franz *et al.* (1991a, 1991b)、Woebbecke *et al.* (1995a, 1995b)やZhang *et al.* (1995)、Critten (1996)、Andreasen *et al.* (1997)、Shibata *et al.* (1998)は雑草の幼苗の、それぞれ草型や草姿の評価・同定を行う手法を開発した。さらに、ニューラルネットワークを用いて、Davis (1991)、甲斐ら(1995a, 1995b)は切り花

のキク, Steinmertz *et al.* (1994) は切り花のバラの構造を解析し, 品質評価への応用を提案した. ダイズ (*Glycine max* L. Merr.) 草姿についても, 統計的手法やニューラルネットワーク, ファジィ理論に基づく定量的評価法が開発された (Ninomiya *et al.* 1991, 1994, 生出ら 1996, 二宮ら 1998).

いずれも良好な結果を得ているが, 材料特有の判別に有用な形状特徴量の探索を伴う手法であり, 手法をそのまま適用できる材料が限定されると思われる. したがって, 新しい材料の草姿を評価する手法を開発するとき, 有用な形状特徴量とその形状特徴量に適した解析法とを探索しなおさなければならない. 材料が変わるたびにこのような処理を繰り返すのは, 非効率的である.

一方で, 形状特徴量を必要としない判別モデルとして, 画像を直接入力するニューラルネットワークを基本構造としたものが提案された. Oide *et al.* (1998) は, ダイズ草姿の評価を多層パーセプトロンで行い, 学習データには典型的形状を選択して用い, その最適な構造を検討した. 形状特徴量を使用しないことを考慮すると判別結果は良好であったが, (1) 最適な構造や内部パラメタの決定が難しく, (2) 学習に多大な計算コストがかかり, (3) 典型的形状の定義が定性的で学習データの選択法も難しい, という問題があった. Oide *et al.* (2000a, 2000b) は, ダイズ葉形など植物器官の判別に, 線形ニューラルネットワークを用い, 学習データにはクラス内の平均の形状を用いた. ここでは, 判別結果が良好だっただけでなく, 材料からニューラルネットワークの構造や学習データが自動的に決定でき, 学習にかかる計算コストが小さかったという利点があった.

本研究では, 線形ニューラルネットワークのこのような利点に着目し, ダイズ草姿の判別に線形ニューラルネットワークの適用を検討することとした.

2. 材料と方法

2-1 材料

供試した材料は, 175 品種・系統のダイズ (*Glycine max* L. Merr.) 草姿 875 個体である. これは, Ninomiya *et al.* (1991) の解析で供試され, 粒肥大始期の側面草姿がビデオカメラで撮影された後, 3 人のダイズ育種家によって 3 段階 (“良”, “並”, “悪” のいずれか) に評価されたものである. 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 90 品種・系統 167 個体) を用いた.

2-2 判別問題の設定

各個体の草姿画像を入力したとき, 育種家と同じ評価, すなわち “良”, “並”, “悪” を出力するニューラルネットワークの構築を目的とする. このとき, それぞれの評価に属する草姿の集合をクラスと呼ぶ.

ここで, 選抜される “良” の草姿を “並” や “悪” の草姿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, “並” と “悪” の二つのクラスの和集合として “不良” というクラスを定義した.

本研究では, “良”, “悪” の草姿だけを材料とした2クラス判別, すべての個体に対する“良”, “並”, “悪” の3クラス判別を行った. 3クラスの判別では, “並” と “悪” とをそのまま別のクラスにした3クラスの場合と, “不良” という和集合として扱う2クラスの場合との二通りの判別誤差を求めた.

2-3 画像入力ニューラルネットワーク

線形素子からなるホップフィールドネットワーク (Hopfield *et al.* 1985) および単純パーセプトロン (Rosenblatt 1962) を用いた. 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. 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, 入力画像の画素数と同数の素子からなる (図1a). 単純パーセプトロンは, 入力層と出力層からなり, それぞれの層に素子が配置され, 異なる層の間で, 素子は完全結合される. 本研究では, 入力画像の画素数と同数の入力素子と判別するクラス数と同数の出力素子からなる (図1b). このように, 両者の構造は, 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.

(a) ホップフィールドネットワーク

(b) 単純パーセプトロン

図1. 画像入力ニューラルネットワークの構造
 n は入力画像の画素数, P は判別するクラス数である

表1. 単純パーセプトロンの目標出力

判別クラス数	目標出力ベクトル		
	“良”	“並”	“悪”
2	(+1, -1)	-	(-1, +1)
3	(+1, -1, -1)	(-1, +1, -1)	(-1, -1, +1)

2-4 訓練と判別

ホップフィールドネットワークは、連想記憶となるよう訓練した。すなわち、学習データの入力画像を入力すると、平衡状態でそれと同じ画像を出力するようにする。訓練後、未学習のデータを入力すると、平衡状態になったとき学習データ以外の画像を出力することがある。そのときは、学習データの入力画像ともっとも相関の高いクラスをホップフィールドネットワークの出力とみなす。

単純パーセプトロンは、表1のように、クラスごとに異なるベクトルを出力するように訓練する。訓練後、未学習のデータを入力すると、出力ベクトルの成分が必ずしも±1をとるとは限らない。そのときは、最大値をとる成分によって、単純パーセプトロンの出力とみなす。すなわち、出力が(+0.8, -0.5) (2クラス判別), (+0.7, -0.8, -0.9) (3クラス判別) のとき、判別はどちらも“良”である。

いずれも、学習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。学習データの入力パターンと目標出力とから、連立一次方程式を解くことによって、結合係数の値を決定できる。多層パーセプトロンと異なり、学習には緩和や設定しなければならないパラメタの必要がない。

2-5 入力画像

本研究で用いた画像入力ニューラルネットワークは、材料の大きさ、位置、向きを検出できないため、形状の標準化は不可欠である。そこで、ダイズ草姿は、二値化したのち、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：高木ら 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と一致するよう平行移動して、標準化した。各クラスの標準化した草姿の例を図2に示す。

ニューラルネットワークに入力する前に、標準化された草姿画像を16画素×16画素、32画素×32画素、64画素×64画素に縮小する。これは、ニューロコンピューティングの負荷が大きくなりすぎるのを防ぐためである。この縮小された画像は、訓練後のニューラルネットワークを評価するためのテストデータとして用いる。

3種類の大きさに縮小された画像について、各クラス“良”、“並”、“悪”ごとに、クラス内の平均の輝度をもつ画像を求め、これをニューラルネットワークを訓練するための学習データとした。ここでは、この画像の平均を形状分布と呼ぶ。各クラスの形状分布を図3に示す。

図2. 各クラスに含まれる草姿の例

図3. 各クラスの形状分布
画像のサイズは64画素×64画素である.

2-6 判別誤差

線形ニューラルネットワークによる植物器官の判別では、学習条件によって、判別誤差が異なることが指摘されている (Oide *et al.* 2000a, 2000b). そこで、本研究でも、学習条件が学習の可否や判別誤差に及ぼす影響を調べるため、Oide *et al.* (2000a, 2000b) と同様の学習条件の組合せを設定し、比較検討した. すなわち、クラス数 (“良”, “悪” の2クラス, “良”, “並”, “悪” の3クラス), 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, 単純パーセプトロン), 入力画像のサイズ (16画素×16画素, 32画素×32画素, 64画素×64画素) のすべての組合せで訓練した.

本研究で用いたニューラルネットワークでは、学習条件が一定ならば、訓練によって構築されるニューラルネットワークも一定である. そのため、訓練および判別の試行は、1回だけ行った. Oide *et al.* (1988) で記述された多層パーセプトロンでは、結合係数の初期値や訓練で提示する学習データの順序を偽似乱数で決定したため、同じ学習条件下でも訓練のたびに異なるニューラルネットワークが構築されたのとは、対照をなす.

判別誤差は、あてはめ誤差とクロスバリデーション誤差の二種類を定義した。あてはめ誤差は、訓練するクラスに含まれるすべての草姿画像を使って作成された形状分布でニューラルネットワークを訓練し、訓練されたクラスに含まれるすべての草姿画像を判別して得た。一方、クロスバリデーション誤差の場合は、判別する草姿のうち、一つをテストデータとし、残りでは形状分布を作成してニューラルネットワークを訓練した。訓練後、テストデータを入力して、正しく判別できるかどうか調べた。そして、判別すべきすべての草姿が一回ずつテストデータになるまでくり返し、判別誤差を求めた。

3. 結果

すべての学習条件で学習が成功した。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早く判別処理をすることができた。なぜなら、判別のためには、ホップフィールドネットワークでは、平衡状態に達するまでの緩和が必要であるが、単純パーセプトロンは一度信号が通過すればいいだけだからである。

学習条件ごとの判別誤差を表2に示す。あてはめ誤差は、入力画像サイズが大きいほど低く、ほとんどの場合でホップフィールドネットワークより単純パーセプトロンのほうが低かった。結局、64画素×64画素の画像を入力する単純パーセプトロンがもっとも低い判別誤差を示した。クロスバリデーション誤差では、あてはめ誤差のように最適な学習条件の組合せが見つからなかった。“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のほうが、それ以外の場合は単純パーセプトロンによる判別のほうが低く、入力画像サイズとクロスバリデーション誤差との関係は見られなかったからである。

学習しなければならないクラスが増えるほど、二種類とも判別誤差は高くなった。また、どの材料、どの学習条件の組合せにおいても、あてはめ誤差はクロスバリデーション誤差を越えなかった。

表2. 判別誤差

ネットワーク アーキテクチャ	入力画像サイズ	あてはめ誤差			クロスバリデーション誤差		
		2クラス	3クラス*	3クラス**	2クラス	3クラス*	3クラス**
ホップフィールド ネットワーク	16画素×16画素	0.185	0.196	0.353	0.189	0.252	0.439
	32画素×32画素	0.159	0.178	0.328	0.176	0.252	0.423
	64画素×64画素	0.159	0.166	0.307	0.176	0.236	0.426
単純 パーセプトロン	16画素×16画素	0.137	0.144	0.337	0.150	0.221	0.442
	32画素×32画素	0.138	0.141	0.331	0.155	0.209	0.442
	64画素×64画素	0.124	0.138	0.319	0.155	0.212	0.448

* “並”，“悪”のクラスを“不良”のクラスとしてマージした。

** “良”，“並”，“悪”をそれぞれ別のクラスとした。

64画素×64画素の画像を入力する単純パーセプトロンによる判別結果の二元表を表3に示す。個体数では、“悪”の草姿が多く、全体の判別誤差は“悪”の判別誤差に依存するところが大きかった。また、判別クラスが増えると、“良”の誤差が高くなり、逆に“不良”の誤差は低くなった。しかし、“並”と“悪”との判別が難しかったことがわかる(表3c, f)。

表3. 判別結果の二元表

(a) あてはめ (2 クラス判別; 誤差 0.124)					
		判別されたクラス		合計	
		“良”	“悪”	正	誤
正しい クラス	“良”	62	4	65	4
		94%	6%	94%	6%
	“悪”	25	142	142	25
		15	85	85	15
合計		87	146	204	29
		37	63	88	12

(b) あてはめ (3 クラス判別*; 誤差 0.138)					
		判別されたクラス		合計	
		“良”	“不良”	正	誤
正しい クラス	“良”	48	18	48	18
		73%	27%	73%	27%
	“不良”	27	233	233	27
		10	90	90	10
合計		75	251	281	45
		23	77	86	14

(c) あてはめ (3 クラス判別**; 誤差 0.319)					
		判別されたクラス			合計
		“良”	“並”	“悪”	正 誤
正しい クラス	“良”	48	17	1	48 18
		72%	26%	2%	72% 28%
	“並”	14	58	21	58 35
		15	62	23	62 38
“悪”	13	38	116	116 51	
	8	23	69	69 31	
合計		75	113	138	222 104
		23	35	42	68 32

(d) クロスバリデーション (2 クラス判別; 誤差 0.155)					
		判別されたクラス		合計	
		“良”	“並”	正	誤
正しい クラス	“良”	61	5	61	5
		92%	8%	92%	8%
	“並”	31	136	136	31
		19	81	81	19
合計		92	141	197	36
		39	61	85	15

(e) クロスバリデーション (3 クラス判別*; 誤差 0.212)					
		判別されたクラス		合計	
		“良”	“不良”	正	誤
正しい クラス	“良”	39	27	39	27
		59%	41%	59%	41%
	“不良”	42	218	218	42
		16	84	84	16
合計		81	245	257	69
		25	75	79	21

(f) クロスバリデーション (3 クラス判別**; 誤差 0.448)					
		判別されたクラス			合計
		“良”	“並”	“悪”	正 誤
正しい クラス	“良”	39	26	1	39 27
		59%	39%	2%	59% 41%
	“並”	30	34	29	34 59
		32	37	31	37 63
“悪”	12	48	107	107 60	
	7	29	64	64 36	
合計		81	108	137	180 146
		25	33	42	55 45

64画素×64画素の画像を入力する単純パーセプトロンによる判別結果を示す。枠内上段数値は頻度、下段数値は相対頻度(単位: %)を示す。

* “並”, “悪” のクラスを “不良” のクラスとしてマージした。

** “良”, “並”, “悪” をそれぞれ別のクラスとした。

4. 考察

すべての学習条件において、学習が失敗しなかったのは、決定すべき結合係数数に対してクラス数が少なく、自由度が高かったためと思われる。

あてはめ誤差、クロスバリデーション誤差ともに、学習条件による判別誤差のちがいは小さかった。Oide *et al.* (2000a, 2000b) によると、植物器官形状の判別において、あてはめ誤差は学習条件に大きく依存し、クロスバリデーション誤差も画像サイズによって異なった。本研究で、入力画像サイズとクロスバリデーション誤差との関係が見られなかったのは、葉形や粒形と草姿との形状のちがいによるものと思われる。葉形や粒形は、単一の連続領域からなり、面積に対して周囲長が短い、比較的単純な形状である。一方、草姿は、多数の不連続領域からなり、輪郭線が入り組んだ、複雑な形状である。したがって、葉形や粒形の判別では、輪郭線のちがいが主要な要因であるのに対し、草姿の判別では、輪郭を詳細に調べるとともに、背景と形状との分布を大域的な視点からおおまかにとらえることも重要であると考えられる。サイズの大きい画像では、輪郭付近の詳細な情報が得られるが、大まかな形はとらえにくく、サイズが小さい画像では、その逆である。画像サイズによるこのトレードオフによって、本研究では、サイズが大きいほどあるいは小さいほど有利というような単純な結果を生まなかったと考えられる。

“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、クロスバリデーション誤差において優れていた原因は不明である。この点は、今後の検討を要する。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と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く、判別誤差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。

判別誤りは、クラス内変異がクラス間変異を越え、他のクラスの学習データに似る形状があるとき発生したと思われる。しかし、もともと形状が複雑なこと、クラス内変異が非常に大きいことから、草姿画像とその判別結果を見てもそれを確かめることはできなかった。しかし、判別誤りが、クラス内変異の大きい“並”および“悪”のクラス間で多い(表3)ことから、それが示唆される。

全般的にクロスバリデーション誤差があてはめ誤差より大きいとか等しかったことから、常にオーバーフィットが発生したといえる。しかし、Oide *et al.* (2000b) の一連の結果に比べると、各クラスの個体数が多かったため、オーバーフィットはかなり抑えられた。

本研究と多層パーセプトロンをダイズ草姿評価に適用したOide *et al.* (1998) とでは、学習データが異なる、すなわち前者では草姿のクラス内平均を、後者ではそれぞれのクラスにおける典型的形状を用いたことから、単純には両者の結果を比較できない。ネットワークアーキテクチャによる判別効率をより正確に比較するには、同一の学習データで訓練したときの判別誤差を検討する必要がある。ただし、ネットワークアーキテクチャや構造によって、適切な学習データの設定方法が異なる可能性がある。これは、多層パーセプトロンではオーバーフィッティングが発生しやすく、単純パーセプトロンではアンダフィッティングが発生しやすいことに起因する。ここで、引き出したい情報を信号、信号に紛れ込む余分な情報を雑音と呼ぶとすると、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

表4. 多層パーセプトロンによる判別結果の二元表

		判別されたクラス		合計	
		“良”	“不良”	正	誤
正しいクラス	“良”	42	24	42	24
		64*	36*	64	36
	“不良”	54	206	206	54
		21	79	79	21
合計		96	230	248	78
		29	71	76	24

3クラスで“並”、“悪”のクラスを“不良”のクラスとしてマージした。全体の判別誤差は0.239だった。

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言う (Smith 1993)。多層パーセプトロンでオーバフィッティングを防ぐためには、学習データの入力パターンに、雑音を含めクラス内にある程度の変異をもたせることが有効な手段の一つである。したがって、典型的形状を学習データとするのは、クラス内変異が生じるという点で、多層パーセプトロンの学習データに適していると思われる。一方、本研究で用いた単純パーセプトロンと同じ構造の多層パーセプトロンでは、このような典型的形状を学習データとした場合、アンダフィッティングによって学習が失敗しやすかったと報告されている (Oide *et al.* 1998)。単純パーセプトロンでは、学習データ数が少ないほど学習しやすく、したがって、形状分布のように1枚の画像でクラス内の変異を表せるような学習データが適していると考えられる。いずれにせよ、これらの点は実際に検証すべきであろう。

このように二つのネットワークアーキテクチャの間で比較検討の余地は残っているが、線形ニューラルネットワークを用いることで、多層パーセプトロンで問題であった、構造や内部パラメタの決定の難しさ、学習の遅さ、学習データの選択の困難さを解決することができた。全体の判別誤差においても、多層パーセプトロンの場合 (表4, Oide *et al.* 1998) とほぼ同様であった。したがって、本研究では、線形ニューラルネットワークが構築しやすい点で、優れているといえる。ただし、理論的には、線形ニューラルネットワークでは線形分離による判別しか行えないが、多層パーセプトロンでは線形分離の任意の重合せができるため、複雑な判別関数を実現できる。すなわち、線形ニューラルネットワークより、多層パーセプトロンのほうが、未学習データの入力に対しても正しく出力する能力、すなわち汎化能力においては有利である。したがって、材料の形状や分布によっては、多層パーセプトロンのほうが判別効率のよいこともありえる。

本研究では、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に変異する形状にも適用できることを示せた。すなわち、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。今後は、ネットワークアーキテクチャ、学習データ、判別誤差との関係をより詳細に調べるとともに、判別誤差の改善を行うことが課題である。

5. 引用文献

- Andreasen, C., M. Rudemo and S. Sevestre (1997) Assessment of weed density at an early stage by use of image processing. *Weed Res.*, 37: 5-18.
- Critten, D. L. (1996) Fourier based techniques for the identification of plants and weeds. *J. Agr. Eng. Res.*, 64: 149-154.
- Davis, P. F. (1991) Orientation-independent recognition of chrysanthemum nodes by an artificial neural network. *Comp. Electron. Agr.*, 5: 305-314.
- Franz, E., M. R. Gebhardt and K. B. Unklesbay (1991a) Shape description of completely visible and partially occluded leaves for identifying plants in digital images. *Trans. ASAE*, 34: 673-681.
- Franz, E., M. R. Gebhardt and K. B. Unklesbay (1991b) The use of local spectral properties of leaves as an aid for identifying weed seedlings in digital images. *Trans. ASAE*, 34: 682-687.
- Hopfield, J. J. and D. W. Tank (1985) "Neural" computation of decisions in optimization problems. *Biol. Cybern.*, 52: 141-152.
- Humphries, S. and W. Simonton (1993) Identification of plant parts using color and geometric image data. *Trans. ASAE*, 36: 1493-1500.
- 育種ハンドブック編集委員会(1974)草型. 育種ハンドブック, 養賢堂, 東京: 607-613.
- Jensen, N. F. (1988) Visual Selection. In "Plant Breeding Methodology", John Wiley & Sons, New York, NY, USA: 331-354.
- 甲斐和広・近藤直・林孝洋・芝野保徳・小西国義・門田充司(1995a)スプレーギクの花房フォーメーションの評価アルゴリズムに関する研究(第1報)-着花位置を決定する特徴量の抽出-. 生調, 33: 253-259.
- 甲斐和広・近藤直・林孝洋・芝野保徳・小西国義・門田充司(1995b)スプレーギクの花房フォーメーションの評価アルゴリズムに関する研究(第2報)-画像処理を用いた評価指標の検討-. 生調, 33: 261-267.
- 南峰夫・松島克典・氏原暉男(1991)画像解析による普通ソバの草姿の評価. 信大農紀, 28: 165-173.
- 村井正之・木下俊郎・広瀬昌平(1987)イネの草型に関するダイアレル分析. 日大農獣医研報, 44: 112-122.
- Ninomiya, S., J. Ambuel, S. Morinaga and N. Takahashi (1994) Comparison of three models to evaluate soybean plant shape using shape indices given by image analysis: Statistical discriminant function, neural network, and fuzzy logic. *Proc. 7th Int. Congr. SABRAO and Int. Symp. WSAA*: 613-620.
- 二宮正士・生出真里・高橋信夫(1998)ファジィ論理によるダイズ草姿・葉形データ検索システム. 日作紀, 67: 104-108.
- Ninomiya, S. and I. Shigemori (1991) Quantitative evaluation of soybean (*Glycine max* L. MERRILL) plant shape by image analysis. *Japan J. Breed.*, 41: 485-497.
- 生出真里・森永慎介・二宮正士(1996)ダイズ草姿判別におけるニューラルネットワークモデル-学習データ選択法の検討-. システム農学, 12(1): 13-20.
- Oide, M. and S. Ninomiya (1998) Evaluation of soybean plant shape by multilayer perceptron with direct image input. *Breed. Sci.*, 48: 257-262.
- Oide, M. and S. Ninomiya (2000a) Discrimination of soybean leaflet shape by neural networks with direct image input. *Comp. Electron. Agr.*, 29: 59-72.
- Oide, M. and S. Ninomiya (2000b) Plant shape discrimination of several taxa without shape feature extraction by neural networks with image input. *Breed. Sci.* 50: 189-196.
- Oka, M. and K. Hinata (1988) An application of computer image analysis for

- characterization of plant type in rice cultivars. Japan J. Breed., 38: 449-458.
- Oka, M. and K. Hinata (1989) Comparison of plant type between new and old rice cultivars using computer image analysis. Japan J. Crop Sci. 58: 232-239.
- Rosenblatt, F. (1962) Principles of neurodynamics. Spartan Books, New York, NY, USA.
- Schaufler, D. H. and P. N. Walker (1995) Micropropagated sugarcane shoot identification using machine vision. Trans. ASAE, 38: 1919-1925.
- Shibata, Y., K. Nishizaki, Y. Yokochi, S. Fujii, A. Karaushi and K. Araki (1998) Crop recognition system for physical weeding robot. Proc. 13th Intl. Congr. Agr. Eng. Robot: 453-459.
- Smith, M. (1993) Part 3: Generalization. In "Neural networks for statistical modeling", International Thomson Computer Press, Boston, MA, USA: 111-129.
- Steinmertz, V., M. J. Delwiche, D. K. Giles and R. Evans (1994) Sorting cut roses with machine vision. Trans. ASAE, 37: 1347-1353.
- 高木幹雄・下田陽久監修(1991)形状特徴. 画像解析ハンドブック, 東京大学出版会, 東京: 578-582.
- Woebbecke, D. M., G. E. Meyer, K. Von Bargen and D. A. Mortensen (1995a) Color indices for weed identification under various soil, residue, and lighting conditions. Trans. ASAE, 38: 259-269.
- Woebbecke, D. M., G. E. Meyer, K. Von Bargen and D. A. Mortensen (1995b) Shape features for identifying young weeds using image analysis. Trans. ASAE, 38: 271-281.
- 山口裕文(1982)カラスムギ生態型の草型のクラスター分析. 雑草研究27: 77-82.
- Zhang, N. and C. Chaisattapagon (1995) Effective criteria for weed identification in wheat fields using machine vision. Trans. ASAE, 38: 965-974.

Discrimination of Soybean Plant Shape by Linear Neural Network with Image Input

Mari Oide and Seishi Ninomiya

National Agriculture Research Center, Kannondai 3-1-1, Tsukuba, Ibaraki, 305-8666, Japan

Summary

Several quantitative methods of plant shape evaluation have been developed for consistent decision. Most of them are object-specific methods that require different shape features depending on objects, and the applicability of each method to other objects is usually low. Recently, we proposed a discriminant model that did not require any shape features, adopting a multi-layer perceptron with direct image input. We applied it to the substitution of human visual judgement on soybean plant shape. This model worked fine but a few problems were also pointed out, namely that the optimal structures and parameters of multi-layer perceptron were difficult to determine

and that the computational cost to train multi-layer perceptron was high.

In this study, we examined linear neural networks for the soybean plant evaluation in stead of using multi-layer perceptron, expecting less computational cost and easier determination of the network structure. The results indicated that the above mentioned problems were all solved without loosing the discriminant power of the multi-layer perceptron model.

Keyword: Discriminant model, Image analysis, Neural network, Plant shape, Shape evaluation, Soybean