

# 競合ニューラルネットによる野草の特徴認識 Recognition of Features of Wild Grass by Competitive Neural Nets

西田 健 (PY), 北森 智成, 黒木 秀一

Nishida Takeshi(PY), KITAMORI Tomonari and Kurogi Shuichi

nishida@cntl.kyutech.ac.jp

kitamori@teras.cntl.kyutech.ac.jp

kuro@cntl.kyutech.ac.jp

九州工業大学 工学部 機械知能工学科

Department of Control Engineering, Faculty of Eng., Kyushu Institute of Technology

## Abstract

The purpose of this paper is to examine the basic image processing method for recognition of the specific wild grasses in a field. In this paper, we show the method of a preprocessing of extracting wild grass from color images, and the finding method of the features of them by pattern matching using the competitive neural networks. Moreover we show in the simulations that the extraction of the features of specific wild grass is possible by presented method.

## 1 はじめに

現在, 農業工学分野において, 農薬の使用量を削減することを目的とした雑草の自動認識やそれらの自動除去手法が数多く研究されている [1, 2]. これらの研究は, 雑草の群生している領域への限定的な農薬散布や, 計画的に整備された農地における自律移動ロボットのマニピュレーションによる雑草個体の除去を最終的な目標としている. いずれの研究においても, 植物の個体差や自然環境の変化に不変な野草の認識システムの構築が重要な課題である.

自然環境下での野草の認識のための実用的な手法として, 植物の葉の近赤外線反射率の違いにより雑草とトウモロコシを識別し, 群生する雑草に農薬を散布するという手法が提案されている [3]. しかしこの研究は雑草個体の認識やその位置計測は扱っておらず, 目的とする雑草の群生しているおおよその場所の特定を行うに過ぎない. さらに, 他の雑草もしくは野草の認識手法 [1, 2, 4] のいずれも, 整った葉の形が比較的容易に切り出せるよう, 鉛直方向から撮影した野草のカメラ画像に対する画像処理と葉の形状認識を扱っており, 視点の変化に不変な野草の特徴認識を扱う研究は少ない. そこで本研究では, 視点の変化や個体差による野草の葉や茎の形状や大きさの変化にかかわらず, 自然の状態ですべて生じている野草の特定の部位の認識を競合ニューラルネット [5] を用いて行う手法を提案する. 以下では, 野草の特定部位の認識までの各処理について, 流れに沿って順番に述べる.

## 2 前処理

### 2.1 色に基づく野草領域の抽出

まず, 本研究で認識対象とする野草 (セイタカアワダチソウ) の画像の例を図 1(a) に示す. これは  $499 \times 372$  画素から成り, 各画素が 24bit の RGB 値からなるカラー画像である. 本研究では, この画像から色に基づいた野草領域の抽出のために, 最も容易かつ高速に処理可能な以下の手法を用いる. すなわち, 対象の野草の葉や茎は緑色に近い色を持つため, 各画素の RGB 値の中で G の値が最大となる画素はその画素の値を G の値で代表し, それ以外の画素は全て白色とする. これにより, 元のカラー画像はこの処理の後, 8bit のグレースケール画像で表現される. ただし実際の応用においては, 天候の変化などの環境の変化によって生ずる撮影画像中の植物の色の変化に対して色抽出の頑健性を向上させるために, YIQ 変換や HSI 変換など他の色の記述法の必要性やカメラの自動露光システムなどを考慮する必要がある. 図 1(a) に対して上述の処理を施した結果を図 1(b) に示す. この図より, この処理によって画像中の対象の野草を含む領域が抽出されることがわかる.

### 2.2 ノイズ除去


次に, 上述の処理で得られた図 1(b) の画像から細かなノイズを除去するために, 図 2 に示すようなフィ



(a) 野草を含む画像の例 .



(b) 緑色を抽出した画像 .



(c) ノイズを除去した画像 .

図 1: 野草を含む画像に対する前処理 .

ルタを用いる . すなわち , 注目する画素の周囲  $d$  画素の平均値を計算し , その値がある一定の閾値  $c_{th}$  以上であればその画素が持つ値はノイズであると判断し白色に置き換える . ノイズとして除去される領域の大きさと画素の濃度レベルは , それぞれ  $d$  と  $c_{th}$  で調節される . 本研究ではこれらの値を  $d = 3$  ,  $c_{th} = 240$  としてノイズ除去フィルタを施した . 図 1(b) に対して上述の処理を施した結果を図 1(c) に示す . これによって , 画像中からある程度のノイズが除去されることがわかる .

### 3 野草の特徴の発見

#### 3.1 競合ニューラルネットの構成

視点によって形状が変化する葉や茎を画像中から発見するために , 図 3 に示す競合ニューラルネットを用い




図 2: ノイズ除去フィルタ .  $d$  と  $h$  はそれぞれノイズ除去の範囲と画像の水平方向の画素数を示す .

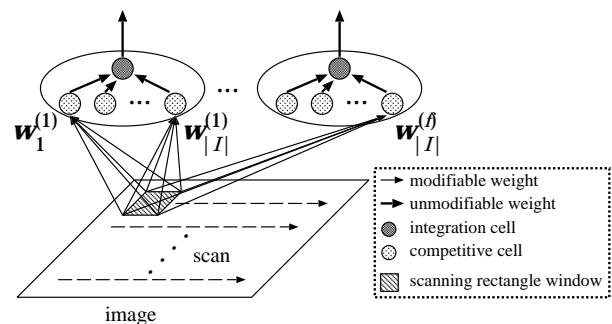


図 3: 野草の特徴を認識する競合ニューラルネットの構成 .

る . このネットは複数のクラスタから構成され , 各クラスタは一つの統合セル (integration cell) と  $k$  次元の荷重ベクトル  $w_i^{(f)} \in \mathbb{R}^k$  ( $i \in I = \{1, 2, \dots, |I|\}$  ,  $f = \{1, 2, \dots\}$ ) を持つ複数の競合セル (competitive cell) から構成される . ここで  $i$  は競合セルの添字を表し ,  $f$  は各クラスタが担当する野草の特徴の添字を表す .

まず , ネットの訓練は以下のように行われる . まず , テンプレートパターン  $p^{(f)}$  に回転や平行移動 , 拡大縮小などの一定の座標変換群  $G$  に属する座標変換  $g$  を施して正規化したパターン  $g(p^{(f)}) / \|g(p^{(f)})\|$  を多数生成し , これらのパターンを用いて各競合セルを訓練する . 訓練のアルゴリズムについては 3.2 で述べる . ここで , テンプレートパターンは葉や茎などの野草の特徴を模擬したパターンであり , 本研究では図 4(a),(b) に示すような 2 種類のテンプレートを用意した . 一方は対象の野草の葉の形を , もう一方は茎の形を模擬した  $60 \times 60$  画素の 8bit グレースケールパターンである . 認識しようとする野草の種類によって , 異なるテンプレートパターンを用意する必要がある . さらにこの訓練の後 , 各荷重ベクトルに対してマスクパターンを生成し , 各セルはそれらを荷重ベクトルと同様に保持する . マスクパターンとは , 荷重ベクトルを二次元平面上のパターンとして (例えば図 6(a),(b)) ,




図 4: 葉の特徴を模擬したテンプレートパターン .

それらに拡大変換を施し二値化処理を施したパターンである .

以上の訓練の後, ネットは野草の特徴認識を以下のように行う . まず, このネットへの入力ベクトル  $\mathbf{x}_n \in \mathbb{R}^k$  ( $n = 1, 2, \dots$ ) は, 前処理画像 (例えば図 1(c)) から  $\sqrt{k} \times \sqrt{k}$  画素の矩形の窓を移動させることにより順次切り出して生成する . ただし後述の処理の計算コスト削減のため, 切り出された矩形領域の中心付近の画素が白色である場合や, 白色でない画素の総数が少ない場合には入力ベクトルとして扱わない . 次に, 生成された入力ベクトルが順次ネットに入力されると, 各クラスタにおける各競合セルは, 以下のように内積の最大値を計算する .

$$\begin{aligned}
 y_f(\mathbf{x}_n) &= \max_i \{ \hat{\mathbf{x}}_n^{(f)} \mathbf{w}_i^{(f)} \} \\
 &= \max_i \left\{ \frac{\mathbf{x}_n * \mathbf{m}_i^{(f)}}{\|\mathbf{x}_n * \mathbf{m}_i^{(f)}\|} \mathbf{w}_i^{(f)} \right\} \\
 &\simeq \max_{\mathbf{g} \in G} \left\{ \frac{\mathbf{x}_n * \mathbf{m}_i^{(f)}}{\|\mathbf{x}_n * \mathbf{m}_i^{(f)}\|} \frac{\mathbf{g}(\mathbf{p}^{(f)})}{\|\mathbf{g}(\mathbf{p}^{(f)})\|} \right\} \quad (1)
 \end{aligned}$$

ただし,  $\mathbf{m}_i^{(f)}$  は, 第  $f$  クラスタ内の第  $i$  セルのマスクパターンであり, マスクパターンにより修正された入力ベクトル  $\hat{\mathbf{x}}_n$  は,

$$\hat{\mathbf{x}}_n^{(f)} = \frac{\mathbf{x}_n * \mathbf{m}_i^{(f)}}{\|\mathbf{x}_n * \mathbf{m}_i^{(f)}\|} \quad (2)$$

と表される . また, 演算子  $*$  はベクトルの各要素ごとの内積,  $(a_1, a_2) * (b_1, b_2) = (a_1 \cdot b_1, a_2 \cdot b_2)$  を表し,  $\|\cdot\|$  はベクトルのノルムを表す . すなわち, マスクパターンによって, 荷重ベクトルに保持されている特徴パターンの領域に限定したパターンマッチングを行う . この概念図を図 5 に示す . したがって, 第  $f$  番目のクラスタの出力  $y_f(\mathbf{x}_n)$  は, マスクパターンにより修正された入力ベクトル  $\hat{\mathbf{x}}_n$  と第  $f$  クラスタに訓練された特徴パターンとの類似度を表し,  $\hat{\mathbf{x}}_n$  が  $\mathbf{g}(\mathbf{p}^{(f)})$  のみから構成される場合に内積が最大値 1 をとる . 本研究では, この類似度に以下のような閾値を設定し,




図 5: マスクパターンを用いるパターンマッチングの概念 . (a) 入力パターン  $\mathbf{x}_n$  の例, (b) マスクパターン  $\mathbf{m}_i^{(f)}$ , (c) マスクパターンを乗じた入力パターン  $\hat{\mathbf{x}}_n^{(f)}$  .

入力パターンとの特徴のマッチングを行う .

$$y_f(\mathbf{x}_n) \geq s_{th} \quad (3)$$

後述するシミュレーションでは  $s_{th} = 0.7$  とした . この値は, 類似した野草の識別が必要な場合などには, より高い値で設定する必要がある . また, マスクパターンは各競合セルの荷重ベクトルパターンの 1.3 倍の拡大パターンを生成し二値化して生成した .

### 3.2 競合ニューラルネットの学習

提案する競合ニューラルネットは, 訓練に用いたパターンに内在する座標変換に対して不変認識能力を獲得するという性質を持つ [5] . ネットは不変認識能力を獲得しようとする座標変換群に含まれる様々な座標変換を施したパターンを用いて事前に訓練される . このとき, このネットの訓練には, 有限の記憶容量で無限に存在する座標変換を効率良く学習することができる CRL(Competitive Reinitialization Learning) アルゴリズム [6] を用いる . CRL アルゴリズムは, 収束が迅速であり局所解に陥りにくく, 設定パラメタが少ないという特徴を持つ . 本研究における以下のシミュレーションでは, CRL の設定パラメタを文献 [6] に示された  $\tau = 300$ ,  $I_{th} = 0.95$ ,  $d_{th} = 1.4$  を用いた . CRL の詳細は文献 [6] を参照のこと .

この CRL アルゴリズムにより訓練を行った後の各競合セルの荷重ベクトルの様子を図 6(a),(b) に示す . これらは, 図 4(a),(b) のテンプレートに  $0^\circ \sim 90^\circ$  の回転変換と  $0.6 \sim 1.0$  倍の縮小変換をランダムに施しながらネットワークに 1000 回の訓練を行った結果である .

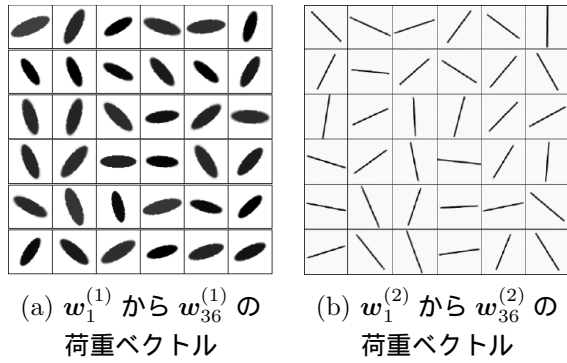


図 6: 訓練後の競合セルの荷重ベクトル .

### 3.3 テンプレートマッチング

上述の訓練の後，ネットを画像のテンプレートマッチングに用いる．前処理画像である図 1(c) から雑草の葉と茎の特徴部分を発見するために，本研究では以下の二段階のパターンマッチングを行う．すなわち，第一段階として，葉の特徴部分をパターンマッチングによって発見し，その部分を画像から削除する．次に第二段階として，茎の形状を持つテンプレートによるパターンマッチングにより茎の特徴部分の発見を行う．結果を図 7(b) に示す．この結果より，提案する画像処理手法は対象とする野草の茎の領域を画像から発見することができる事が分かる．

## 4 むすび

本研究で提案した手法により，雑草の葉や茎の部位が比較的高速に発見できることが確かめられた．また，茎や葉などの野草の特徴部分を含む複数の画像が提案手法で得られると，それらの方の対応関係の計算によって 3 次元位置の算出も可能であると考えられ，3 次元位置計測の計算コストを大幅に削減できる可能性がある．ただし，実際に生息する草の認識においては，認識しようとする雑草が群生している場合の画像処理や，天候によって変化する明るさに対する適応などの予測される問題に対応する必要がある．

## 参考文献

[1] L. Tang, L. F. Tian, B. L. Steward and J. F. Reid, "Texture-Based Weed Classification Using Gabor Wavelets and Neural Network for Real-




図 7: 競合ネットよりテンプレートマッチングを行った結果 .

time Selective Herbicide Applications," ASAE Paper No. 991151 (UILU No. 99-7035),1999.

- [2] L. Tian, and D. C. Slaughter, "Environmentally adaptive segmentation algorithms for outdoor machine vision systems," Journal of Computers and Electronics in Agriculture. Vol. 21 (3), pp. 153-168, 1998.
- [3] M. Chapron, L. Martin-Chefson, "A Multiresolution Weed Recognition Method Based on Multispectral Image Processing," Proc. of The 11th Scandinavian Conference on Image Analysis, pp. 529-534, 1999.
- [4] 斎藤剛史, 金子豊久, "花と葉による野草の自動認識," 信学論 (D-II), Vol. J84-D-II, No.7, pp.1419-1429, 2001.
- [5] 西田健, 黒木秀一, "多層競合ネットによる座標変換に不変なパターン認識," 日本神経回路学会誌, 7(4):106-114, 2000.
- [6] T. Nishida, S. Kurogi and T. Saeki, "Adaptive vector quantization using re-initialization method," IEICE(D-II), Vol. J84-D-II, No.7, pp.1503-1511, 2001.