遺伝的アルゴリズムおよびニューラルネットワークを用いた 自然画像からの農産物の認識*

朝 倉 俊 行^{*1}, 飯 田 泰 臣^{*2}

Recognition of Agricultural Objects on Scene Image by using Genetic Algorithm and Neural-Networks

Toshiyuki ASAKURA^{*3} and Yasutomi IIDA

^{*3} Department of Human and Artificial Intelligent System, Fukui University,
3-9-1 Bunkyo, Fukui-shi, Fukui, 910-8507 Japan

As the harvesting operation is hard work for farmers, it is desired to reduce the harvesting operation in agriculture. The purpose of this study is the construction of a useful visual recognition system that is required for automation and robotization of harvesting operations. In this research, eggplants and tomatoes are taken up as examples of agricultural objects. First, they are searched in a scene image using a genetic algorithm. Second, a recognition method for agricultural objects using Neural-Networks is proposed. In these Neural-Networks, the change of luminance information has been learned as special feature of agricultural objects, which show the luminosity distribution of objects composed of curved surfaces. Finally, through experimental studies, it is verified that the new technology proposed here is effective in the recognition of agricultural objects.

Key Words: Image Processing, Image Recognition, Genetic Algorithm, Neural-Networks, Agriculture, Agricultural Object

1. 緒 言

近年、農業において農産物を自動で収穫する収穫ロボットや、品質の自動識別をするような農作業の自動化に関する研究が盛んに行われている⁽¹⁾⁻⁽³⁾。これは農作業が肉体的にも精神的にも非常に負担となる作業であり、特に収穫作業などは中腰などの無理な姿勢が長時間にわたって行われるため、作業の軽労化が強く求められているためである。

自動収穫ロボットにおいて農産物を認識し、収穫するためには、まずその位置、姿勢を認識する必要がある。ロボットの視覚認識に関する研究として、カメラから取込まれた画像から特定の農産物のみを抽出する研究⁽⁴⁾や、果物の色やつやなどの表面特性の変化を分光反射率で計測・解析し識別する研究⁽⁵⁾なども行われている。しかし、文献(4)についてはリンゴの赤い色などのように、特徴量が背景などと際立って異なる場合には有効であるが、画像中に他の赤い物体などが存在した場合には認識が困難だと考えられる。また文

献(5)については、画像から得られる RGB 値のみによる解析だけでは、細かな解析が困難であり、多次元の情報を扱うために、分光反射率を用いている。そのため、より詳細な表面特性の解析が可能となっており、等級・階級選別への応用が期待されるが、この手法は分光反射率の時間的変化の特性を利用したものであるため、収穫ロボットの視覚部への応用は難しいと考えられる。

収穫ロボットの視覚部には、まず画像上のどこに対象物が存在するかを探索し、そして探索された物体を認識することが要求される。そこで、本研究では、対象とする農産物以外にもさまざまな物体の存在する自然画像を用いて収穫作業の自動化、ロボット化の際に必要な有用な視覚認識システムの構築を目的とする。

本報告では、探索を行う農産物の例としてナスおよびミニトマトを取上げ、CCD カメラにより撮影した自然画像から遺伝的アルゴリズム (以下 GA) による探索を行うが、GA の探索結果で問題となるのが探索された物体が対象とする農産物であるかどうかということである。過去に行われてきた農産物の認識の研究は、おもに色情報、二次元的な形状情報からの特徴パラメータのみで判断がなされてきた。そのために、

* 原稿受付 2002 年 12 月 24 日。

^{*1} 正員、福井大学工学部(☎ 910-8507 福井市文京 3-9-1)。

^{*2} 福井大学大学院。

E-mail: asakura@con.his.fukui-u.ac.jp

画像中に得られる物体が例えば平面体であっても、色と形状が探索対象に似ていれば誤認識を引き起こす可能性があった。そこで、多くの農産物が曲面で構成されている立体物であることに注目し、対象とする農産物を「特定の色をした立体物」としてとらえることができれば認識手段の一つと成り得ると考えた。本研究では、立体物に投影される輝度情報の変化を学習させた、ニューラルネットワーク(以下 NN)^{(6)~(8)}を用いた農産物の認識手法を提案する。次に、提案した手法を用いた探索・認識システムの実験を行い、その有効性を示す。

2. 画像認識システムの概要

図1に今回構成したシステムの概要を示す。まず最初に、入力された画像に対してナスの探索を行う場合はナスの色領域のみを抽出し、ミニトマトの場合はミニトマトの色領域のみを抽出する。次に、二値化された探索画像を作成し、探索問題に有効とされる GA による位置探索⁽⁹⁾を行う。そして、得られた候補領域について未知パターンに対する汎化能力および並列分散処理能力をもつ NN による農産物の認識を行う。

3. GA による探索

3.1 探索画像の作成 原画像に対して色抽出を行った結果を図2に示す。通常用いられる RGB 表色系の色は、照明や影などの影響を受けやすく、自然画像においては非常に弱い表色系である。そこで、本報告では物体抽出に適しているとされる TSL 表色系⁽¹⁰⁾⁽¹¹⁾を用いて色抽出を行う。TSL 表色系とは色合い(Tint)、鮮やかさ(Saturation)、輝度(Luminance)で指定するものである。したがって、色合いを独立したデータとして扱えるため、光環境などがさまざまに変化する自然画像に対してより適した表色系といえる。図2(b)はナスの色領域のみを抽出した結果であり、図2(d)はミニトマトの領域のみを抽出した結果である。これら二値化画像を探索画像として、探索を行うものとする。

3.2 探索モデルと適応度計算 本研究で用いたミニトマトの探索モデルを図3に示す。GA により個体を進化させるには、各個体が環境に適している度合い(適応度)を評価する必要がある。ここでは、画像と探索モデルを重ね合せ、重なる点の個数を評価値とする。適応度は式(1)により計算される。

$$\text{fitness} = \frac{\sum f(x, y)}{n} \dots\dots\dots (1)$$

$f(x, y)$: Image brightness of the overlapping points

n : Number of pixel

ここで、探索画像は二値化画像を用いるため、画素の存在する部分(黒色領域)の輝度値を1、それ以外(白色領域)のときは零としている。探索モデルは、内外ともに30個の点で構成される円形モデルを用い、内側の円でミニトマトの色である黒色領域を、外側の円で背景の色である白色領域を評価する。これにより一重の円形モデルで黒色領域のみを評価した場合に比べると、ミニトマトと同じ色の他の物体や、ミニトマトの

Fig. 1 Recognition algorithm

Fig. 2 Result of color extraction

Fig. 3 Search model of tomato

内部に収束することなくミニトマトの輪郭近くに収束しやすくなる。

農産物は、その成長過程において形状がさまざまに変化する。特にナスの場合、その変化の範囲が他の農産物に比べて大きい。そこで、ナスの探索に対して形状変化に対応できる柔軟な探索モデルを提案する。本研究で用いたナスの探索モデルを図4に示す。図4(a)は探索モデルの構造を示したものである。モデルは左右対称であるため図4(b)には探索モデルの左側部のみを拡大したものとする。モデル図4(b)において、U字形の曲線をそれぞれTrace 1~7, Traceに対して垂直な直線をLine(l) ($l=1\cdots 12$)とすると、モデルの実際の構成点は、LineとTraceの交点に存在し、合計84個の点より構成される。右側についても、同様にLine(l)とTraceを設定している。提案した探索モデルは対象物の輪郭部分を図4(a)の斜線部分で評価する。この斜線部分に一定の幅をもたせることによって、対象物の形状が変化しても対応することが可能である。しかし、輪郭を認識する範囲を広くすることによって、ナス以外の物体にも収束する可能性が高くなってしまふ。そこで、本モデルは対象物の輪郭の有無を評価するだけでなく、輪郭の連続性を考慮す

ることにより、そのような誤認識の回避を行っている。つまり、滑らかな輪郭の物体の適応度を高くし、いびつな形状をした物体の適応度は低くすることにより、滑らかな輪郭をもつナスの探索を可能としている。

この場合の適応度は式(2)により計算される。 l はLine番号、 n はLine数である。 $P(l)$ の項は輪郭の評価をし、 $S(l)$ の項で輪郭の連続性を評価する。

$$\text{fitness} = \frac{\sum_{l=1}^n \{P(l) + S(l)\}}{2n} \cdots \cdots \cdots (2)$$

ここで、 $P(l)$ は次式で計算される。

$$P(l) = \begin{cases} -1 & \left(\sum_{m=1}^7 f(l, m) = 0 \text{ のとき} \right) \\ 1 & \left(0 < \sum_{m=1}^7 f(l, m) < 7 \text{ のとき} \right) \cdots (3) \\ -1 & \left(\sum_{m=1}^7 f(l, m) = 7 \text{ のとき} \right) \end{cases}$$

$f(l, m)$: Image brightness of the overlapping points
次に、 $S(l)$ は次式のように定義した。

$$S(l) = \begin{cases} 1.0 & (sub(l)=0, 1) \\ -0.2 & (sub(l)=2) \\ -0.4 & (sub(l)=3) \\ -0.6 & (sub(l)=4) \\ -0.8 & (sub(l)=5) \\ -1.0 & (sub(l)=6) \end{cases} \cdots \cdots \cdots (4)$$

$$sub(l) = |T(l) - T(l+1)| \cdots \cdots \cdots (5)$$

$T(l)$: Line(l)上で輪郭が存在するTrace番号

$S(l)$ により、Traceに沿う滑らかな輪郭の適応度は高くなり、いびつな輪郭の適応度は低くなる。したがって、 $S(l)$ は滑らかさを評価する項となる。

3.3 遺伝的アルゴリズムの設定 ナスおよびミニ

トマトの探索モデルにおいて各パラメータの最適な組合せを探索する問題に対して、まず、各個体の遺伝子形を決定する。個体集団における k 番めの個体の遺伝子形 G_k は、画像上における座標 (x_k, y_k) 、カメラと対象物の相対的な回転角度 θ_k 、カメラと対象物の物体間距離を示す拡大縮小率 M_k により、式(6)のように表される。

$$G_k = (x_k, y_k, M_k, \theta_k) \cdots \cdots \cdots (6)$$

これは、探索対象の四次元空間中の一点を表している。しかし、円形モデルの場合、回転角度 θ_k のパラメータが不要となるため、各個体 G_k は式(7)のように表すことができる。

$$G_k = (x_k, y_k, M_k) \cdots \cdots \cdots (7)$$

ミニトマトの探索に用いる円形モデルにおける各パラメータの範囲を次に示す。

Fig. 4 Search model of eggplant

$$x_k \in [0, 255] \dots\dots\dots (8)$$

$$y_k \in [0, 255] \dots\dots\dots (9)$$

$$M_k \in [12, 27] \dots\dots\dots (10)$$

$$G_k = \underbrace{001\dots\dots 0}_{8 \text{ bit}} \underbrace{101\dots\dots 1}_{8 \text{ bit}} \underbrace{0\dots\dots 1}_{4 \text{ bit}} \dots\dots\dots (11)$$

GA のパラメータ (個体数, 淘汰率, 突然変異率) を表 1 に示す。

次に, ナスの探索に用いる U 字形モデルにおける各パラメータの範囲を示す。

$$x_k \in [0, 255] \dots\dots\dots (12)$$

$$y_k \in [0, 255] \dots\dots\dots (13)$$

$$S_k = \left[120 \times \frac{\theta_k}{15} \right] \quad \theta_k \in [0, 15] \dots\dots\dots (14)$$

$$m_k = \left[1 + \frac{M_k}{15} \right] \quad M_k \in [0, 15] \dots\dots\dots (15)$$

$$G_k = \underbrace{001\dots\dots 0}_{8 \text{ bit}} \underbrace{101\dots\dots 1}_{8 \text{ bit}} \underbrace{0\dots\dots 1}_{4 \text{ bit}} \underbrace{1\dots\dots 0}_{4 \text{ bit}} \dots\dots\dots (16)$$

GA のパラメータ (個体数, 淘汰率, 突然変異率) を表 2 に示す。

ここで, 各モデルのパラメータの初期値は, 大きさ, 回転角度についてはランダムに値を決定する。しかし, 座標 (x_k, y_k) は二値化画像の結果を利用し, 図 2(b), (d) で示されるような黒い領域上の座標のみに初期個体の生成を行う。この手法により, ランダムに座標の初期値を与えるよりも, 探索の高速化が図られている。また全領域で探索をしたかどうかの判断はせず, 最も適応度の高い個体を探索結果としている。これは本研究では動画像を用いているため, 1 枚の画像で対象物を探索するのではなく, 動画像列として徐々にモデルを対象物に収束させようとする考えによるものである。

4. NN を用いた農産物の認識

本研究で用いられた GA による探索結果は, 二次元の形状情報のみに基づいたものである。多くの農産物の形状は起伏の激しい表面ではなく, 滑らかな曲面で構成されている。そこで, 探索された物体の新しい評価基準として, 探索物体が曲面で構成された立体物であるかどうかを判断するために, 物体表面の輝度分布に関する特徴量を NN の学習, 入力に用いて農産物の認識を行う。

4.1 高輝度領域からの距離と平均輝度の関係

曲面で構成された物体の場合, 光のあたっている部分

Table 1 Parameters of GA (Circle model)

Number of individual	30
Selection rate	0.5
Mutation rate	0.1

Table 2 Parameters of GA (U form model)

Number of individual	30
Selection rate	0.5
Mutation rate	0.1

から周りに離れるに従って, 徐々に輝度が減少していく。そこで, 探索物体中の最も高輝度である領域を調べ, その領域からの距離と輝度の関係を NN に学習させることにより, 農産物の認識を行う。

物体中の光が反射して光っている部分を見つける際に, 1 画素ずつ輝度値を評価すると, 光のあたっている部分ではなく, 輝度値が偶然高くなっているノイズなどの部分である場合がある。そこで, 本研究では, 抽出画像 (70×60) に対して 30 画素以上の連結成分を考え, なおかつ最大輝度をもつ領域を光の反射している部分とした。これにより, 多少のノイズが含まれていても, 光の反射部分を見つけることが可能となる。なお, 30 画素という値は異なる複数の画像から試行錯誤に決定した値である。

次に, 探索物体に対して光の反射部分の領域からの距離変換⁽¹¹⁾を行う。距離変換とは図形を構成する各画素に, 背景からそれらの画素への最小距離を与える処理である。距離変換の場合, 計算の容易さから距離値を整数値で与えることが多く 4-近傍距離⁽¹¹⁾と 8-近傍距離⁽¹¹⁾がよく利用される。本研究では背景からの距離ではなく, 光の反射部分の領域からの 8-近傍距離での距離変換を行う。図 5 は探索物体に対して, 距離変換を行った結果である。図 5(b) に示される中央の灰色領域が 30 画素以上の高輝度領域であり, 周りの輪は高輝度領域を基準とした 3 ピクセルごとの等距離線を示している。

図 6 に, 光りのあたっている部分からの距離と等距離画素の平均輝度の関係を表したグラフを示した。図 6(a) には曲面で構成された農産物のグラフを, 図 6(b) に平面で構成された物体のグラフを示す。グラフの縦軸は等距離画素の平均輝度値を 0~1 の間で表したものである。横軸は距離変換によって得られた距離を示す。また, 図 7 には実験に使用した物体の画像を示す。

図 6(a), (b) のグラフからわかるように, 平面体の場合は距離が増加しても輝度がほぼ一定であるのに

(a) Extraction image (b) Processing image

Fig. 5 Distance transformation

(a) Curved object

(b) Planer object

Fig. 6 Luminance-distance graph

対して、曲平面で構成された農産物は距離の増加とともに徐々に輝度が減少していることが確認できる。この距離ごとの輝度値の変化を NN の学習、入力に用いることにより農産物の認識を行う。

4.2 ニューラルネットワークの適用 図 8 に本研究で用いた NN の構成を示す。NN の入力層ユニット数は 15 個、中間層ユニット数は 50 個とし、農産物であるかないかのみを出力するため出力層ユニット数は 1 個である 3 層の階層形 NN とする。

具体的な学習内容としては、学習パターンとしてナスの認識を行う場合は、ナスを 20 種類、ミニトマトの認識を行う場合はミニトマト 20 種類を農産物として学習させる。次に、農産物ではないカテゴリとして、平面体の代わりに人工的に輝度を一定としたデータを 20 種類用いる。また、本 NN は教師あり学習を行う

Fig. 7 Images of experimental sample

Fig. 8 Structure of neural-networks

ため、学習パターンが農産物の場合、出力層ユニットに対して 1.0 を与え、平面体の場合は出力層ユニットに 0.0 を与える。ここで、表 3 に認識カテゴリとそれぞれの学習パターンを示す。図 9、図 11 には実際の学習に用いたナスおよびミニトマトの画像を示した。図 10、図 12 にはそれぞれの高輝度領域からの距離と等距離画素の平均輝度のグラフの例を示す。

表 4 にはナスを認識する NN を学習させる際に、各入力層ユニットに入力した輝度値の例を示す。

学習パターン 1 から 20 までは農産物の輝度値を、すなわち 20 種類のナスの輝度値を各入力ユニットに入力する。次に学習パターン 21 から 40 は平面体の代わりに人工的に輝度値を一定にしたデータを入力する。したがって、教師信号として学習パターン 1 から 20 のときは出力層ユニットに 1.0 を与え、学習パターン 21 から 40 のときは出力層ユニットに 0.0 を与える。

実際の出力値と目標出力値との自乗出力誤差和を E とすると E は式(17)のように表される。

$$E = \sum_k E_k = \frac{1}{2} \sum_k \sum_{j=1}^n (u_j^{N(k)} - \hat{u}_j^{N(k)})^2 \quad \dots\dots\dots (17)$$

ここで、 k は学習パターンの総個数、 E_k は k 番めの学習パターンに対する自乗出力誤差和、 $\hat{u}_j^{N(k)}$ はある学習パターンに対する出力素子 j が出す目標出力値、 $u_j^{N(k)}$ は実際の出力である。学習パターンの合計

Table 3 Category of learning pattern

Category	Learning Pattern
C ₁ : Agricultural object	Eggplant or Tomato
C ₂ : Non-Agricultural object	Artificial plane body

Fig. 9 Example of learning pattern of eggplant

Fig. 10 Luminance-distance graph of eggplant

Fig. 11 Example of learning pattern of tomato

Fig. 12 Luminance-distance graph of tomato

は 40 個であるため、 $k=40$ となる。また、式(17)において、 $\hat{u}_j^{N(k)}$ は教師信号であり、学習パターンが農産物の場合、出力層ユニットに対して 1.0 を与え、平面体の場合は出力層ユニットに 0.0 を与える。学習はバックプロパゲーション法により行われ、学習率 $\epsilon=$

Table 4 Example of the input value

ユニット 番号 学習 パターン	1	2	3	4	5	6	7	...	15
1	0.674	0.414	0.227	0.164	0.148	0.148	0.170	...	0.102
2	0.682	0.436	0.263	0.220	0.217	0.235	0.223	...	0.143
...	...	...	...	...	...	...	...	...	...
20	0.632	0.274	0.173	0.158	0.200	0.144	0.135	...	0.144
21	0.200	0.200	0.200	0.200	0.200	0.200	0.200	...	0.200
...	...	...	...	...	...	...	...	...	...
30	0.600	0.600	0.600	0.600	0.600	0.600	0.600	...	0.600
...	...	...	...	...	...	...	...	...	...
40	1.000	1.000	1.000	1.000	1.000	1.000	1.000	...	1.000

0.75, モーメント率 $\alpha=0.15$, シグモイド関数の傾き $\mu=1.0$ として、 E が 0.08 以下を満たすまで行われるものとする。今回、ナスの認識に用いた NN の場合 77 回の学習で $E=0.0794$, ミニトマトの場合は 95 回の学習で $E=0.0795$ となり E が 0.08 以下を満たした。本報告ではこのように学習された NN を適用して認識を行った。

5. 探索・認識実験

自然動画画像からのナスの探索・認識実験を行った。実験は 10 枚の異なる動画画像を用い、その結果の一例を図 13 に示す。それぞれの画像の U 字形の部分に認識結果である。また、システムに画像が入力されてから結果を出力するまでの処理時間はすべての動画画像に対して 80 ms 未満であった。

図 13(a) はナスに収束している画像を示し、図 13(b) は GA の探索が失敗し、影の部分に収束しているが NN でナスではないと認識している画像を示している。これはナスと影の色が似ているため、色抽出の際に偶然影がナスのような形状で抽出され、GA での探索が失敗している。しかし、影は輝度が一定であり、立体物でないため NN による認識で正しい判断が得られた。25 個の未学習データに対して、GA の個体を 200 世代進化させた結果、GA による探索の成功率が 80% であった。これは NN による認識は行わず、GA の探索結果を人間が見てナスであるかどうかを判断した結果である。次に、NN による認識率が 80% であった。これは GA による探索結果がナスであった場合に、NN がナスであると判断した確率である。ここで NN の出力値の閾値は 0.5 に設定し、出力値が 0.5 以上のものをナスと判定した。最後に GA、NN による認識率が 64% となった。これは GA によ

る探索結果がナスに収束し、なおかつ NN による認識においてもナスであるという結果が得られた確率である。64%という認識率はあまり高くはないと思われる。しかし、図 13(b)に示すような GA による探索で失敗した際に、NN の認識でナスではないと判断された場合は探索を再度繰返すようなアルゴリズムを適用すればこの認識率の増加が期待できる。このように、新たな評価基準を設定することによる大きなメリットとして、誤認識を避けることができるということが挙げられる。本手法は探索した後、NN による認識も行っているにもかかわらず、高速な処理を実現している。したがって、初めの探索で失敗してもそれが失敗であるという判断ができれば、再度探索を行い真の対象物を高速に探索することが可能である。

6. 複数個の認識

実際の収穫場面において画像内にナスが一つだけとは限らない。また、ミニトマトなどの場合はむしろ複数が集まって実っているのが普通である。したがって、収穫作業の自動化、ロボット化に必要とされる視覚認識システムの構築を考えた場合、複数個の認識が要求される。第 6 章ではミニトマトを取上げ、複数個の認識を行った結果を示す。

6・1 複数個の認識手法 図 14(a)は色抽出によりミニトマトの色領域を黒色、背景を白色に表示した二値の探索画像である。まず初めに、前述してきた GA および NN を用いた手法により一つめのミニトマトの探索を行う。次に、図 14(b)に示すように探索されたミニトマトの領域を背景である白色に塗りつぶし、次の探索を行う。したがって、一度認識されたミニトマトが再び認識されることがなく、複数個の認識が可能である。

6・2 複数個の認識実験 図 15 にミニトマトの複数認識実験の結果を示す。

図 15(a), (b)はおもに緑色をした背景に人工的にミニトマトを複数配置して実験を行った結果である。図 15(c)には実際の自然画像に対して同様の実験を行った結果を示す。それぞれの画像において円で示した部分が認識結果である。図 15(a)より一つ一つが離れた位置に存在している場合、良好にミニトマトが認識されていることが確認できる。また、図 15(b)に示すようなミニトマトに多少の重なりがあっても、認識が可能であることがわかる。この手法を自然画像に対して適用した場合でも図 15(c)に示すように複数個のミニトマトに対して認識が行えた。

現在はまだ 3 個までの認識しか行っていないが、実

Fig. 13 Recognition result

Fig. 14 Recognition procedure

Fig. 15 Recognition of plural object

際の収穫作業への適用に際して、さらに複数個の認識が必要である。しかし、3 個の場合でも画像中に存在している対象物の個数を正確に認識できない場合があった。一つめの要因として、探索されたミニトマトの領域を塗りつぶす際に、完全に領域が塗りつぶされずに残ってしまった場合、次の探索において再びその残った領域が認識されてしまう。二つめの要因としてはミニトマト同士が密接に重なったり隠れている場合である。このような場合人間の視覚探索と同様、探索は難しくなる。しかし本手法は動画像による探索であ

り、一端対象物を認識できれば以降探索可能な場合も期待できる。どの程度まで認識可能かという問題については今後の検討問題である。

7. 結 言

本研究では実際に農産物が実っている動画画像からナスおよびミニトマトの探索を行い、さらに NN を用いた農産物の認識手法について提案した。そして、認識実験を行うことにより、次のような結果を確認した。

(1) TSL 表色系を用いた色抽出により自然画像から対象物を良好に抽出できることを確認した。

(2) ナスの探索に適した探索モデルを提案し、ナスの良好な探索が行えることを示した。

(3) 農産物であるという新たな評価基準として、NN に輝度分布に関する特徴量を入力、学習させることで、曲面で構成された立体物を認識させる手法を提案した。

(4) 本手法を複数個の対象物に対して適用することにより、複数個の認識に対しても本手法が有効である可能性を示した。

以上より、GA による探索、および提案された NN による認識法が農産物の認識に対して有効であることを示した。しかし、現状の複数個の認識手法だけではいくつかの問題点が見られた。したがって、今後はこれらの問題点を解決し、より有効な複数個の認識シス

テムの構築を目指す必要がある。

文 献

- (1) 森本英嗣・村主勝彦・梅田幹雄, 画像処理による運搬車両の自律走行, 農業機械学会誌, **64**-6 (2002), 104-110.
- (2) 門田充司・近藤直・芝野保徳・毛利健太郎, トマト収穫用ハンドに関する研究第 53 回農業機械学会講演要旨, (1994), 391-392.
- (3) Morimoto, T. and Hashimoto, Y., AI approaches to identification and control of total plant production system, *Contr. Eng. Practice*, 8-5 (2000), 555-567.
- (4) Bulanon, D. M., Kataoka, T., Ota, Y. and Hiroma, T., A Color Model for Recognition of Apples by a Robotic Harvesting System, 農業機械学会誌, **64**-5 (2002), 123-133.
- (5) 久保田洋孝・眞鍋佳嗣・井口征士, 果物の光学特性の時間変化の計測と表現, 電子情報通信学会論文誌, Vol. J 82-D-II, No. 12 (1999), 2432-2434.
- (6) 朝倉俊行・青柳裕治, ニューラルネットワークを用いた速度標識の画像認識, 機論, **61**-589, C (1995), 206-212.
- (7) 松岡清利, ニューロコンピューティング, (1992), 30, 朝倉書店.
- (8) 平野広美, (1990), 15-58, C でつくるニューラルネットワーク, パーソナルメディア株式会社.
- (9) 安居院猛・長尾知晴・長崎宏, 遺伝的アルゴリズムを用いたパターンマッチング法, 信学技報, PRU 91-92, (1991), 30-40.
- (10) Temillon, J. C. and Akamatsu, S., Comparative Performance of Different Chrominance Spaces for Color Segmentation and Detection of Human Faces in Complex Scene Images, *Vision Interface '99*, 2 (1999), 180-187.
- (11) 高木幹雄・下田陽久, 画像解析ハンドブック, (1993), 485-491, 575-578, 東京大学出版会.