

クロレラ自動計数方式におけるニューラルネットワーク学習

藪木登* 三木成彦* 鷺見育亮** 副井裕***

Learning of Neural Network on Automatic Counting of Chlorella

Noboru YABUKI Shigehiko MIKI Yasuaki SUMI Yutaka FUKUI

In this paper, an automatic counting of chlorella using neural network(NN) is described. In the culture of marine chlorella, it is necessary to count the number in order to understand the condition of increase. The automatic counting method of chlorella, using image processing and NN, was proposed. This NN is three-layered and uses Back Propagation as learning method. This paper describes the study on the influence of the differential learning data of the NN on the recognition rate of chlorella. Experiments are the first case on the increase or decrease of the number of the usual learning data, the second case on the increase or decrease of the number of the new learning data, and the third case on learning using the extracted data from the counted images in experiment.

Key words : chlorella counting, image processing, neural network, learning

1. 緒 言

鳥取県では、県の基幹産業の一つである水産業の振興を目的として、ヒラメ等の増殖・放流事業を行っている。そのため、安定的に供給できる大量の餌が必要であり、海産クロレラ等の露天培養を行うことによって供給している。海産クロレラ（学術名：ナンノクロロプシス）は、植物プランクトン的一种である。海産クロレラは、ワムシなどの動物プランクトンの餌となり、ワムシなどの動物プランクトンはヒラメの餌となる。本研究で扱うクロレラは、淡水のクロレラではなく、上述のように海産クロレラであるが、親しみやすさから単にクロレラと呼んでいる。

海産クロレラの養殖において、ヒラメの養殖にも影響する冬期には降雪・曇天の日が多く、日射量が著しく不足するため、安定した海産クロレラの生産が行えないという問題がある。そこで、人工光として、植物の成長に効果的である発光ダイオード

(Light Emitting Diode : LED) を使い、冬期の日射量不足を解消し、安定した海産クロレラの連続生産を行っている。この増殖の状況を把握するため、その数を知る必要がある。その方法としては、主力

として顕微鏡を用いて血球計算盤を利用することで、人の目によって数える方法と、補助的にコロニーカウンタやコールターカウンタを用いて計数しているのが現状である。コロニーカウンタは、画像処理による計数装置であり、計数は自動で行われる。しかし、計数するために予め画像の濃度調整などの環境設定を手動で行う必要がある上、顕微鏡設定によっても計数結果が左右されてしまう。コールターカウンタは、電極間の電気抵抗の変化を利用している細胞計測装置である。基本的には、人の目によって計数されるため、多大な労力と時間を必要としている。海産クロレラ連続生産システムにおいては、労力軽減のため、海産クロレラ計数の完全自動化が望まれている。

我々は、上記問題点を解決する手法として、ニューラルネットワークを用いたクロレラ自動計数方式を提案している^{1),2)}。

対象画像は、明るさの違いや、焦点のずれがある、多少異なる条件下で撮影された画像である。計数処理の流れについては、以降の節で述べているが、本稿では、クロレラの判定にはニューラルネットワークを使用している。クロレラのような粒子画像の分類にニューラルネットワークが適用された例として、尿中の粒子成分に含まれる、非典型的な赤血球や白血球などの分類を行っている研究が報告されている³⁾。

本研究において、ニューラルネットワークを導入する目的は、その汎化性を利用して、多少異なる撮

原稿受付 平成 14 年 8 月 30 日

* 情報工学科

** 鳥取環境大学

*** 鳥取大学工学部

影条件にも対応できる人間の判断能力を模倣するためである。つまり、学習した内容だけでなく、対象が少し変形していたり、多少の雑音が加わってきた場合等にも柔軟に対応ができる。また、学習済みニューラルネットワークによって、パターンを分離する閾値設定が不要となる。ここでいうパターンとは、クロレラとクロレラ以外である。クロレラ以外のものは、微生物、気泡、クロレラの屍骸、海水中の不純物などである。

今までの研究では、ニューラルネットワークの学習用データを固定し、中間層ユニットの数を変化しての学習、および周囲の情報を考慮した学習の検討を行った¹⁾。そこで、本研究では3層ニューラルネットワークの学習データの違いによる認識率への影響について検討する⁴⁾。

本稿では、まずクロレラ自動計数の概要、次に各画像処理、ニューラルネットワークの構造、学習データを変えての実験、実験結果に関する検討を述べている。

2. クロレラ自動計数の概要

図1にクロレラ自動計数方式の処理フローを示し、処理手順を以下に説明する。

- (1) 顕微鏡の接眼レンズからデジタルビデオカメラを用いて、クロレラを撮影し、静止画像をパーソナルコンピュータに取り込む。そのカラー画像を入力とする。
- (2) 次に、データ量を減らすためカラー入力画像をG (Green) 成分のみのモノクロ画像に変換する。G成分を用いるのは、クロレラが緑色であることに着目しているからである。今後使用するモノクロ画像は、G成分のみのモノクロ画像であり、Gモノクロ画像と表現する。
- (3) Gモノクロ画像の平滑化によりぼかす。
- (4) 判別分析法により最適閾値を自動決定し、その閾値で、ぼかしたGモノクロ画像を二値化する。
- (5) 二値画像における各連結成分を区別するため、ラベリングを行う。同時に全連結成分数も得られる。
- (6) 各連結成分の円形度を調べ、円形度不良の割合に応じた分だけ、濃度に補正を加える。その後、ぼかし・二値化・ラベリングを行う。
- (7) モーメント特徴を利用して、各連結成分の重心を算出する。
- (8) 算出した重心を中心とする正方形の範囲で、Gモノクロ画像を抽出する。
- (9) 抽出した画像がクロレラか否かを判定するため、ニューラルネットワークを用いる。抽出画像を

一次元データとして、あらかじめ学習済みニューラルネットワークに入力する。ニューラルネットワークの出力より、クロレラか否かを判定する。

この一連のプロセスを経て、最終的にクロレラの自動計数結果を得る。次の章で各行程の内容を示す。

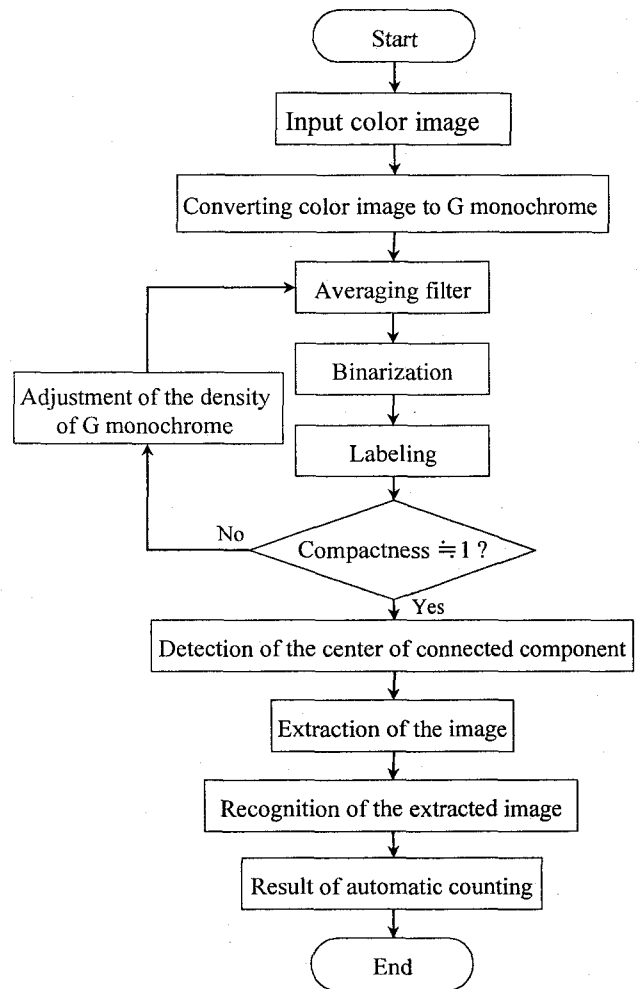


Fig.1 Algorithm of automatic counting method of chlorella.

3. 各画像処理

3.1 平滑化処理

二値化する前の前処理として画像を平滑化によりぼかす。これにより、二値化時に対象物体が分割してしまうことを防ぎ、また、エッジを滑らかにする。背景の小さな雑音も除去できる。以下のような、平滑化処理を十分なぼかし効果が得られるまで複数回行う。ここで、平滑化処理には、 $a \times a$ pixels の範囲 (正方形窓のフィルタ) の平均値フィルタを用いている。

3.2 二値化処理

画像を二値化する際の閾値は、判別分析法を利用して決定し、その閾値で二値化を行う⁵⁾。

3.3 ラベリング

次に、二値化された画像の中で複数の連結成分に対して、各々区別するためにラベリングを行う。また、このとき同時に、二値画像中の全連結成分数が得られる⁶⁾。

3.4 濃度補正

二値化による対象検出不良を抑えるため、濃度補正を行う。クロレラは緑色であるので、Gモノクロ画像を濃くすることで、クロレラを検出しやすくする。また、クロレラは、ほぼ球体であるため、二次元上では、ほぼ円であると考えられる。円形度が不良であると、対象検出不良であると判断でき、それに基づいた補正を行う。

二値画像中の各連結成分において、周囲長と面積を算出し、円形度を求める。

$$\text{円形度} = 4\pi \times (\text{面積}) / (\text{周囲長})^2 \quad (1)$$

周囲長はユークリッド距離で表している。真円であると円形度は1になる。全連結成分数に対する、円形度不良なもの個数の割合に応じて、Gモノクロ画像の濃度を濃くする。

3.5 重心算出

ラベル付けされた連結成分の重心を、次式 $M(p,q)$ のモーメント特徴により算出する³⁾。

$$M(p,q) = \sum_{(i,j)} i^p j^q f_{ij} \quad (2)$$

ここで、 $i \times j$ pixels の画像を考えており、 $\{f_{ij}\}$ は、図形内で1をとり、図形外で0をとる二値画像である。重心 (I_c, J_c) : (図形の中心位置を表す) は次式で示される。

$$I_c = M(1,0)/M(0,0) = \sum_{(i,j)} i f_{ij} / \sum_{(i,j)} f_{ij} \quad (3)$$

$$J_c = M(0,1)/M(0,0) = \sum_{(i,j)} j f_{ij} / \sum_{(i,j)} f_{ij} \quad (4)$$

3.6 画像抽出

次に、ラベリングされた連結成分において各々算出された重心から、連結成分の大きさに応じた正方形の範囲でGモノクロ画像を抽出する。

各連結成分において、重心から最外輪郭へのユークリッド距離の平均を求め、それを2倍した後に1を加えたものを、抽出正方形の辺の長さとする。これは、二次元上でクロレラが円に近い形をしていることを考慮している。図2に抽出例を示す。この場合、抽出範囲は白線内の 17×17 pixels である。




Fig.2 Example of image extraction. (a)Range of extractive region, (b)Extracted result (17×17 pixels) .

3.7 抽出画像判定

ニューラルネットワークを利用して、抽出された画像がクロレラか否かを判定する。用いるニューラルネットワークについては次節で示す。

抽出画像は、ニューラルネットワークに入力する前に、濃度正規化を行った後、大きさ正規化を行う。

濃度正規化は、撮影条件による明るさの影響をなくすために行う⁷⁾。抽出画像 (e^2 pixels) は水平ラスタ走査により一次元データとし、それをベクトルと見なし、

$$\vec{x} = [x_1, x_2, \dots, x_{e^2}]^T \quad (5)$$

と表現すると、濃度正規化後の画像は、

$$\vec{x}_d = \vec{x} / \sqrt{\sum_{i=1}^{e^2} x_i^2} \quad (6)$$

と表すことができる。

大きさ正規化は、クロレラの不均一な大きさと、撮影時の拡大率を補正するために行う。また、ニューラルネットワークを用いたパターン認識が、入力物体の大きさの不均一さに弱いため、これによる認識率の低下を抑えるためにも行っている。座標変換として最も簡単な線形変換 (アフィン変換) により、

抽出画像を拡大・縮小することで、一定の画像サイズに正規化する。以下、本稿では、この画像でクロレラであるものを「クロレラ画像」、クロレラでない画像を「非クロレラ画像」、この2つの画像をまとめて「クロレラ候補画像」と呼ぶことにする。

4. ニューラルネットワーク

抽出したGモノクロ画像がクロレラか否かを判定するために、ニューラルネットワークを使用する。

本研究で用いるニューラルネットワークは、 $n=3$ 層から構成され、隣り合う層間のユニット同士が全て結合している階層型ニューラルネットワークである。学習方法としては、バックプロパゲーション (Back Propagation: BP) 学習法を用いる^{8),9)}。パターン P を提示したとき、第 k 層の各ユニット u_j^k の入出力関係は次式のように示される。

$$o_{Pj}^k = f \left(\sum_{i=1}^{N_{k-1}} w_{i,j}^{k-1,k} o_{Pi}^{k-1} + \theta_j^k \right) \quad (7)$$

$$f(x) = \frac{1}{1 + \exp(-\varepsilon x)} \quad (8)$$

o_{Pj}^k : パターン P を提示したときの第 k 層ユニット j の出力値

$w_{i,j}^{k-1,k}$: 第 $k-1$ 層の i 番目と第 k 層の j 番目のユニット, u_i^{k-1} と u_j^k との結合荷重

θ_j^k : 第 k 層 j 番目のユニットのオフセット

N_k : 第 k 層のユニット数

ε : 入出力関数の傾き

BP 学習法では、ニューラルネットワークの学習の評価関数として、教師信号と出力層の出力値の二乗誤差和 E_p を考える。

$$E_p = \frac{1}{2} \cdot \sum_{i=1}^{N_n} (t_{Pi} - o_{Pi}^n)^2 \quad (9)$$

t_{Pi} : パターン P を提示したときの最終層 i 番目のユニット u_i^n に対する教師信号

評価関数 E_p を最小にする結合荷重の修正量 $\Delta_p w_{i,j}^{k-1,k}$ とオフセットの修正量 $\Delta_p \theta_j^k$ は、次式で計算される。オフセットは、常に 1 を出力するユニットとの結合係数として考えている。

$$\begin{cases} \Delta_p w_{i,j}^{k-1,k}(m) = \eta \delta_{Pj}^k o_{Pi}^{k-1} + \alpha \Delta_p w_{i,j}^{k-1,k}(m-1) \\ \Delta_p \theta_j^k(m) = \eta \delta_{Pj}^k + \alpha \Delta_p \theta_j^k(m-1) \end{cases} \quad (10)$$

($k = 1, 2, \dots, n$)

$$\delta_{Pj}^n = \varepsilon (t_{Pj} - o_{Pj}^n) o_{Pj}^n (1 - o_{Pj}^n) \quad (11)$$

$$\delta_{Pj}^k = \varepsilon o_{Pj}^k (1 - o_{Pj}^k) \sum_{s=1}^{N_{k+1}} (\delta_{Ps}^{k+1} w_{j,s}^{k,k+1}(m-1)) \quad (12)$$

($k = 1, 2, \dots, n-1$)

$\Delta_p w_{i,j}^{k-1,k}$: パターン P を提示したときの結合荷重 $w_{i,j}^{k-1,k}$ の修正量

$\Delta_p \theta_j^k$: パターン P を提示したときのオフセット θ_j^k の修正量

η : 学習係数

α : 慣性項の係数

m : 学習回数

学習停止条件は、以下の E の値が設定値未満になったときとする。

$$E = \frac{1}{C} \sum_P E_p = \frac{1}{2C} \sum_P \sum_{i=1}^{N_n} (t_{Pi} - o_{Pi}^n)^2 \quad (13)$$

C : 学習パターンの数

5. 実験

今までの研究では、自動計数方式のニューラルネットワークにおいて学習データを固定し、中間層ユニットの数を変化しての学習、および周囲の情報を考慮した学習の検討を行った¹⁾。そこで、本研究では、3層ニューラルネットワークの学習データの違いによる認識率への影響について検討する。ここで、認識率とは計数結果より正しく識別されたクロレラ候補画像の数を全クロレラ候補画像の数で除することによって求められる。

学習データは、従来の実験で用いていたデータ数 (クロレラ画像 25 個, 非クロレラ画像 15 個の全 40 個) を基準とする。この実験での認識率の評価は、異なる 6 枚の画像において行い、以下、本稿ではこれらの画像を計数画像と呼ぶこととする。実験としては、以下の 3 つの場合を行う。1) 計数画像以外の画像から抽出された従来学習データのうちクロレラ画像数を 20%~200% 変化させて学習したときの認識率、2) 計数画像以外の画像から抽出され、従来とは異なる学習データで従来学習データの数を基

準としクロレラ画像数を 20%~200%変化させたときの認識率, 3) 計数画像から抽出した学習データを用いた場合の認識率を求める. なお, 非クロレラ画像 15 個については, どの検討項目においてもすべて同じ学習データを用いている.

実験条件は, カラー画像サイズ 630×480pixels で, RGB (Red, Green, Blue) 成分は各 8bit である. 平滑化に適用するフィルタ窓は, 3×3pixels とし, 平滑化処理は 2 回行った. 正規化抽出画像サイズは, 11×11pixels とした. 抽出した画像がクロレラか否かを判定するニューラルネットワークには, 図 3 に示すような 3 層ニューラルネットワークを使用する.




Fig.3 Three-layerd neural networks.

ニューラルネットワークの入力層ユニット数は, 正規化抽出画像を一次元データとして入力するため, 121 である. 中間層ユニット数は, 25 とした. 最終層である出力層は, 「クロレラである」と出力するユニットの 2 ユニットとした. これにより, 出力値が大きい方を判定結果とすることができるため, パターンを分ける閾値設定が不要となる. バックプロパゲーションによる学習については, 式 (13) で示した E の値が 0.005 未満になったときを学習停止とした. 学習パラメータは, $\alpha = 0.005$, $\varepsilon = 0.750$, $\eta = 0.750$ に設定した. 結合係数とオフセットは, 0.0 から 0.02 の範囲で乱数により初期化した.

学習データは, 濃度と大きさの正規化が行われている. 学習用ニューラルネットワークに直接入力し, 学習させると学習が収束しなかったため, 各学習用画像は, 各入力画素値を 10 倍してからニューラルネットワークに学習させた. これは, 小さ過ぎた入力値を 10 倍することで学習パターンの特徴を強調し, 学習を容易にしている. なお, 自動計数の際, クロレラ判定のニューラルネットワークに入力される正規化抽出画像も 10 倍する.

クロレラの計数実験で用いるカラー入力画像 (計数画像) は 6 種類とし, 各画像の一部分を図 4(a)~(f) に示す. 画像 A は, クロレラの濃度が薄い画像で,




Fig.4 Input images (color image).

画像 B はやや薄め, 画像 C はやや濃い濃度のクロレラで, 人間でも判断し難い画像である. ここでいう濃度の濃さ薄さの基準は, 人間が見た場合を基準としている. 濃淡が現れる原因は, 撮影時の光源の影響が大きいと思われる. 画像 D と E は, ほぼ同じ画像で, 撮影時の焦点がやや異なっている. 画像 E の方がやや全体的に明るく, 焦点が少しぼけている. 焦点が変わると, 撮影時の明るさも変動する. 画像 F は, 画像 C より人間でも判断し難い画像である.

6. 学習データに関する検討

6.1 従来の学習データ

従来の学習データ 40 個 (クロレラ画像 25 個, 非クロレラ画像 15 個) のうちクロレラ画像数を 20%~200%変化させて学習したときの認識率について検討する. なお, 変化させたクロレラ画像は, 上記クロレラの画像 25 個のうちから任意に選び, 100%を越える場合は重複して学習している. また, 学習データの増減率 100%とは, クロレラ画像が従来と同じであることを表している. 図 5 は実験結果をグラフに表したものである.

図 5 より学習データの増減率が 100%を超えると

増加させた学習データは 25 個の範囲内なので認識率はやや高くなっているが、大きな影響はないことがわかる。また、学習用データを減少しすぎると認識率に大きく影響することがわかる。これは、学習したデータ数が少なくなり、対象としている画像に対応できなかつたためである。

6.2 従来と異なる学習データ

従来と異なる学習データで従来の学習データの数を基準(クロレラ画像 25 個の時, 100%)とし、クロレラ画像数を 20%~200%変化させたときの認識率について検討する。図 6 は実験結果をグラフに表したものである。

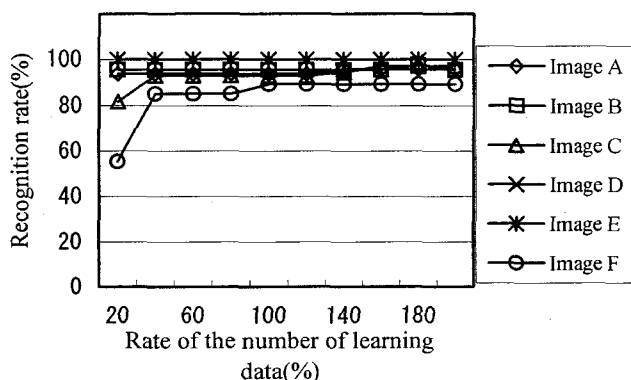


Fig.5 The case on the increase or decrease of the number of the usual learning data.

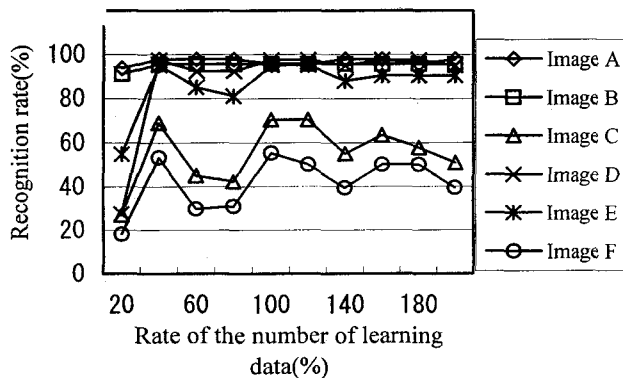


Fig.6 The case on the increase or decrease of the number of the new learning data.

図 6 より画像によって認識率が大きく異なっている。6.1 の結果と比べて、特に入力画像 C と F においては、認識率が悪くなっている。これは使用した学習データが、これらの画像には対応できていないことを示している。すなわち、学習データの選び方によって認識率に影響があることがわかる。

6.3 計数画像から抽出した学習データ

計数画像から抽出した学習データを用いて学習

したときの認識率への影響について検討する。この場合、学習データはクロレラ画像 25 個、非クロレラ画像 15 個の計 40 個で学習を行っている。これより得られたニューラルネットワークを図 4 の入力画像に適用したときの認識率を調べた。図 7 に結果を示す。

図 7 よりすべての画像において、80%以上の認識率を得ており、6.1, 6.2 では認識率の悪かった C や F 画像において、高い認識率を得ている。なお、この場合も学習用非クロレラ画像は、6.1, 6.2 と同じものを用いている。計数画像から抽出された学習データを用いているので、当然ながら、高い認識率は得られている。しかし、計数画像から抽出された学習データはすべて使用しているわけではないので、認識率 100%とはなっていないものもある。すなわち、学習において、データを変えてみることで、計数画像が変わってもより良い認識ができるネットワークを構築することは可能と考えられる。

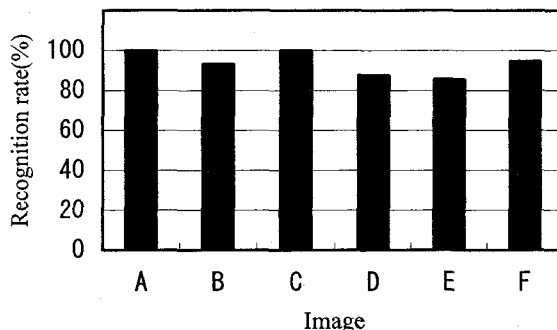


Fig.7 The case on learning using the extracted data from the counting experimental images.

7. 結 論

クロレラ自動計数方式の認識処理に用いている、3 層ニューラルネットワークの学習データの違いによる認識率への影響について検討した。6.1 より学習データを減少しすぎると認識率に大きく影響し、また同じ学習データの範囲内で学習データを重複して学習しても認識率にはあまり影響しないことがわかった。6.2 は画像によって認識率の変化が異なることが明らかとなった。6.3 より判断しにくい画像はその画像自身から学習データを抽出し学習させると高い認識率が得られ、データの設定を変えてみることで、より良い認識が可能であることが明らかとなった。以上、より高い認識率を得るネットワークを構築するためには、どの学習データを利用するかを検討が今後必要である。また、本稿では問題としなかつたが、二つ以上重なったクロレラ候補

の計数法の検討等も今後の課題である。

謝 辞

本研究に際し、実験に多大の協力を得た平成13年度本校専攻科修了生小原拓文君、情報工学科卒業生三船七奈君に深く感謝します。

参 考 文 献

- 1) 鷺見育亮, 太田誠, 藪木登, 尾保手茂樹, 副井裕, クロレラ自動計数方式の認識処理に関する検討, 回路とシステム (軽井沢) ワークショップ論文集, (2001)507-512
- 2) Y. SUMI, M. OTA, N. YABUKI, S. OBOTE, Y. MATSUDA, Y. FUKUI, The Automatic Counting of Chlorella Using Image Processing and Neural Network, IEICE TRANS, FUNDAMENTALS, E84-A, 3 (2001)794-796
- 3) 光山訓, 本池順, 松尾仁司, フィードバック学習を用いた尿沈渣画像の適応的自動分類, 電子情報通信学会論文誌 (D-II), J83-D-II, 1 (2000)237-244
- 4) 三船七奈, 藪木登, 鷺見育亮, 小原拓文, 三木成彦, 副井裕, クロレラ自動計数方式のニューラルネットワーク学習に関する検討, 回路とシステム (軽井沢) ワークショップ論文集, (2002)511-516
- 5) 大津展之, 判別および最小2乗規準に基づく自動しきい値選定法, 電子情報通信学会論文誌 (D), J63-D, 4 (1980)349-356
- 6) 田村秀行監修, コンピュータ画像処理入門, 総研出版, (1985)
- 7) 金珍祐, 岡崎耕三, 佐藤嘉伸, 田村進一, エッジ画像のボカシ処理によるパラメトリック固有空間での3次元物体姿勢推定, 電気学会論文誌, 119-C, 2 (1999)169-174
- 8) 高橋裕樹, 中嶋正之, 遺伝的アルゴリズムを用いた最適な階層型神経回路網の構造決定に関する一考察, 電子情報通信学会論文誌 (D-II), J79-D-II, 11 (1996)1920-1928
- 9) 中野馨監修, 入門と実習 ニューロコンピュータ, 技術評論社, (1989)