

# 2色素モデルを用いた果実の良否判定

大山 航<sup>1,a)</sup> 若林 哲史<sup>1</sup> 木村 文隆<sup>1</sup>

**概要：**食品の等級による選別作業は手作業で行われる場合が多く、コスト削減などの目的から自動選別システムの開発が求められている。本研究では、自己想起ニューラルネットワーク [1] を用いた果実画像の自動良否判定システムの開発を目的とする。本研究で提案する手法では、自己想起ニューラルネットワークを用いて果実の主要な色素が形成する色の分布面を学習する。学習には複数の「良」果実画像を選択して、それぞれ個別の自己想起ニューラルネットワークに学習させる。学習された自己想起ニューラルネットワークを用いた入力果実画像の良否判定手法を提案する。本手法の有用性を評価するために、「良」果実画像 114 枚、「不良」果実画像 234 枚を用いて認識実験を行なった。実験では、「不良」から「良」への許容誤判定率を 11%、「良」から「不良」への許容誤判定率を 6%とした場合に最大で 82.8%の判定成功率が得られた。3クラス分類による良否判定の場合、自己想起ニューラルネットワークの数を増やした場合に未判定率が低減されることが分かった。

## 1. はじめに

近年、食の安全性に対する社会的関心が高まっており、品質維持のために食品加工現場においては、製品の品質検査が必ず行われている。特に野菜や果実などの農作物は生産段階における品質の均一化が困難であるため、出荷段階において選別や等級付けを行う必要がある。果実の品質に基づく選別は手作業で行われる場合が多いが、手作業による選別は人件費や選別者の教育、選別業者ごとの判定基準のばらつきといった様々な問題を抱えている。選別作業の自動化によりこれらの問題の低減と製品の質の均一化が期待できるため、機械による自動選別システムの開発が求められている。

機械による自動選別システムでは大きさをを用いた選別や、傷や色、形状などの見かけの情報を用いた選別、重量を用いた選別が行われている。特に品質による等級選別の場合、見かけによる選別が重要となる。見かけに基づく機械選別は画像処理技術を応用した様々な手法 [2] [3] が提案されている。

雨森ら [4] の手法は、ラベリングによって得られた色むらをピクセル単位で解析して、リングの等級付けを行う手法である。この手法は局所に分散した色むらが存在する果実の場合にのみ有効な手法であり、そうでない果実には適用できない。Blasco ら [5] の手法は、近赤外線や紫外線の

不可視情報を組み合わせた判定手法である。手法である。果実の異常部分の検出および識別において有効性を示しているものの、新しく計測器や光源を用意する必要がある、導入コストが高い問題がある。Leemans ら [6] の手法は k-means クラスタリングと線形判別分析を用いて異常箇所を学習し認識を行う手法であるが、異常や撮影方向によって写りこむガクには対応できない。Kılıç らの [7] 手法は、ニューラルネットワークを用いて不良箇所の面積と色を基に判別を行う手法である。RGB 値の平均値、分散、尖度の学習により高精度な分類が可能であるが、処理に時間がかかる問題がある。

我々は、果実の主要な色素が形成する色の分布面を2色素モデルとして定義し、2色素モデルからの色の外れを用いた果実（梅）の良否判定手法 [8] を提案した。果実画像から得られる各画素の色が、色空間中で平面に分布することを利用し、果実ごとに主成分分析を用いて2色素モデルを生成する手法である。

本研究では、上述の手法を拡張した果実の良否判定手法を提案する。提案手法は、5層自己想起ニューラルネットワークを用いて、色空間中で曲面分布を形成する2色素モデルを取得し、自己早期ニューラルネットワークの入力と出力の2乗距離から判定基準値を求め、良否の判定を行う。

## 2. 2色素モデルと自己想起ニューラルネットワークによるモデルの学習

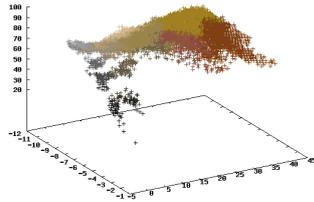
### 2.1 2色素モデル

本研究において、果実から色情報を3要素の特徴として抽出する。梅の実の基本色素は主にカロチンとアントシア

<sup>1</sup> 三重大学大学院工学研究科  
Graduate School of Engineering, Mie University, Mie 514-8507, Japan  
<sup>a)</sup> ohyama@hi.info.mie-u.ac.jp



(a) 果実画像



(b) 画素の  $L^*a^*b^*$  色空間中の分布

図 1 果実色の分布

ニンの2種類の化学物質であり、色空間中で各画素の分布は平面または曲面に分布すると予想される。本研究では、均等色空間の一つである  $L^*a^*b^*$  色空間を用いる。

図 1 に梅の実画像の各画素を  $L^*a^*b^*$  色空間上に示した例を示す。ひとつの点が果実に含まれている画素の色を表す。

## 2.2 色空間の学習

「良」果実画像 1 枚から抽出した各画素の  $L^*a^*b^*$  値を特徴ベクトル集合として、5層自己想起ニューラルネットワークを用いて近似曲面を学習する。一画像の正規化された  $L^*a^*b^*$  値を入力とし、入力と同じ値を出力するように誤差逆伝播法を用いて学習させる。

### 2.2.1 各層のニューロン数

自己想起ニューラルネットワークの各層のニューロン数は、実際のデータに則して決定する必要がある。入力層（第1層）と出力層（第5層）のニューロン数は特徴ベクトルの次元数に一致させる必要があり、中間層（第3層）のニューロン数は、変動の自由度に依存する。5層自己想起ニューラルネットワークにおいて、変動の自由度は中間層のニューロン数と等しくなる。例えば、変動の自由度が1の場合は中間層のニューロン数を1個とし、特徴ベクトルの分布を曲線で近似する。変動の自由度が2の場合は中間層のニューロン数を2個として、特徴ベクトルの分布を曲面で近似する。

本研究で扱う梅の果実の  $L^*a^*b^*$  値は曲面状に分布すると考えられる。自己想起ニューラルネットワークを用いた学習により  $L^*a^*b^*$  色空間上での曲面への近似を目指す。よって、変動の自由度を2とし、これより中間層のニューロン数を2とする。以上より、本研究で用いる自己想起ニューラルネットワークは各層のニューロン数が3,3,2,3,3の5層自己想起ニューラルネットワークである。自己想起ニューラルネットワークを図2に示す。

### 2.2.2 学習の例

ここでは、「良」果実画像 1 枚の  $L^*a^*b^*$  値を5層自己想起ニューラルネットワークで学習する実験を行った。

図3に学習の過程を示す。学習回数はそれぞれ1000,10000,100000とした。緑色のプロットが入力信号を表し、赤色のプロットが学習により生成された超曲面に

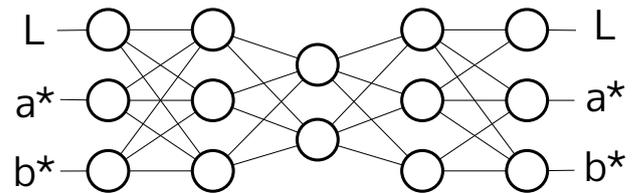


図 2 本研究で用いる自己想起ニューラルネットワーク

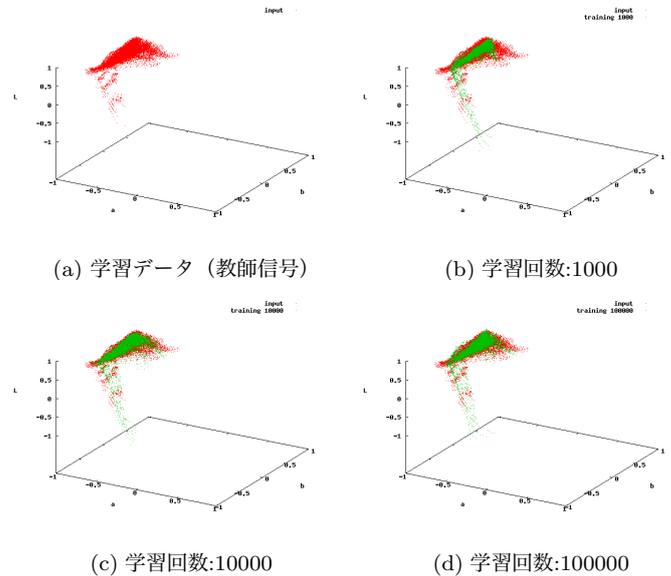


図 3 自己想起ニューラルネットワークの学習過程

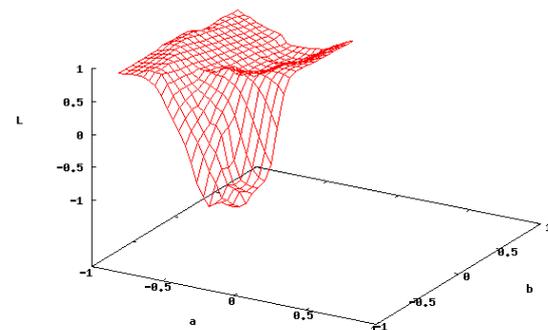


図 4 生成された近似曲面

近似された画素値を表す。図3より、学習を繰り返すことで近似値は入力信号に近づいていくことが分かる。

学習回数 100000 回により生成された超曲面を図4に示す。学習された自己想起ニューラルネットワークを用いることにより、未知の値が入力された場合には、生成された超曲面上に投影されて出力される。

## 3. 提案手法

ここでは、本研究で提案する2色素モデルを用いた良否判定手法について述べる。

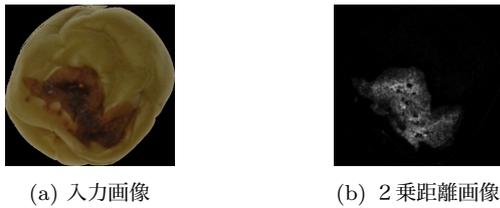


図5 画素ごとの2乗距離

### 3.1 判定基準値

「良」果実を学習した自己想起ニューラルネットを用いて得られる2乗距離のヒストグラムから判定に用いる基準値を求める。判定基準値は以下のように定める。

「良」果実の色情報が学習された自己想起ニューラルネットに評価画像の各画素のLa\*b\*値を入力する。各画素における入力と出力の差の2乗は、注目画素のカラー値と自己想起ニューラルネットが学習した色分布面との2乗距離に相当する。果実画像の画素pにおけるLa\*b\*値を $X_p = (L_p, a_p^*, b_p^*)^T$ と表し、 $X_p$ を自己想起ニューラルネットを用いて学習された曲面に投影した値を $\tilde{X}_p = (\tilde{L}_p, \tilde{a}_p^*, \tilde{b}_p^*)^T$ と表す。ここで、画素pにおける2乗距離dを次の式により定める。

$$d(p) = |X_p - \tilde{X}_p|^T |X_p - \tilde{X}_p| \quad (1)$$

果実画像の画素ごとの2乗距離を輝度値に変換した画像の例を図5に示す。

果実画像毎に得られた2乗距離から判定基準値を求める。

#### 3.1.1 平均2乗距離

画素ごとに得られた2乗距離に対し、果実領域の全画素における平均値を平均2乗距離(MSE:Mean Squared Error)とする。平均2乗距離を次式により定義する。

$$E^A(I) = \frac{1}{N} \sum_{i=1}^n d(i) \quad (2)$$

ここで、Aは学習された自己想起ニューラルネットであり、I、Nはそれぞれ果実画像とその画素数を表す。

#### 3.1.2 上位x%距離

距離値ヒストグラムの上位x%点における距離値を上位x%距離と定める。画素数Nの1画像から得られる2乗距離値のうち、昇順にソートされたi番目の値を $\hat{d}(i)$ ( $0 \leq i < N$ )とすると、上位x%距離を次の式により定義する。

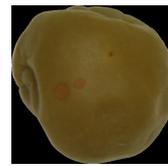
$$E^A(I) = \hat{d}(\lfloor (1 - \frac{x}{100})N \rfloor) \quad (3)$$

ここで、Aは学習された自己想起ニューラルネットであり、I、Nはそれぞれ果実画像とその画素数を表す。

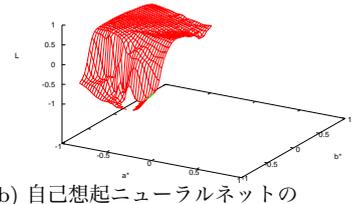
### 3.2 予備実験

良否判定を行うにあたり、予備実験として自己想起ニューラルネットを用いた出力によって「良」果実画像・「不良」果実画像にどのような差が出るか調べた。

自己想起ニューラルネットには「良」果実画像1画像



(a) 学習サンプル画像



(b) 自己想起ニューラルネットの学習により生成された曲面

図6 学習サンプル

のLa\*b\*値を学習させた。学習に用いた果実画像とそのLa\*b\*値のプロットを図6に示す。自己想起ニューラルネットを用いることで未知の値が入力された場合には学習させた曲面に近似されるように出力される。学習サンプル画像と自己想起ニューラルネットの学習により生成された近似曲面を図6(a)(b)にそれぞれ示す。この自己想起ニューラルネットに対し、判定用「良」果実画像・「不良」果実画像をそれぞれ入力し、自己想起ニューラルネットによって学習サンプルの曲面に近似された値を調べた。判定画像の入力値とその近似結果を以下の図7に示す。図7において、赤い点が入力値(判定画像のLa\*b\*値)、緑の点が自己想起ニューラルネットの出力値(曲面に近似された値)である。

図7より、虫食いや傷といった不良箇所がない「良」クラス画像は、出現する色情報が学習させた「良」クラス画像と近く、未知の色が少ないために、曲面に近似された際も誤差が小さくなっていることが分かる。対し、「不良」クラス画像の場合は、入力値と出力値の間で誤差が大きくなっていることが分かる。これは、「不良」クラス画像には学習させた「良」クラス画像には存在しない色が含まれているため、不良箇所の色が正しく近似できていないためである。表1にこの予備実験で得られた判定基準値を示す。判定基準値は平均2乗距離と上位x%距離( $1 \leq x \leq 5$ )を比較する。

予備実験より、本研究では、判定基準値には平均2乗距離と $x = 1$ の上位x%距離(上位1%距離)を用いて評価実験を行う。

### 3.3 良否判定手法

本研究では、最小判定値を用いた良否判定と階層型の良否判定の2つの良否判定手法を提案する。良否判定にはニューロン数を3,3,2,3,3とした5層自己想起ニューラルネットを用いる。自己想起ニューラルネットは学習用データセットからそれぞれ1枚の「良」果実画像を100,000回反復して学習されている。

#### 3.3.1 最小判定値を用いた良否判定

最小判定値を用いた良否判定の流れを図8に示す。学習サンプルの選択方法は3.4.1節にて詳しく述べる。

表 1 予備実験で得られた判定基準値

		平均 2 乗距離	上位 x% 距離				
			x = 1	x = 2	x = 3	x = 4	x = 5
入力画像	良	0.0027	0.0358	0.0251	0.0183	0.0141	0.0108
	不良	0.1315	1.1453	1.046	0.9642	0.9001	0.8450

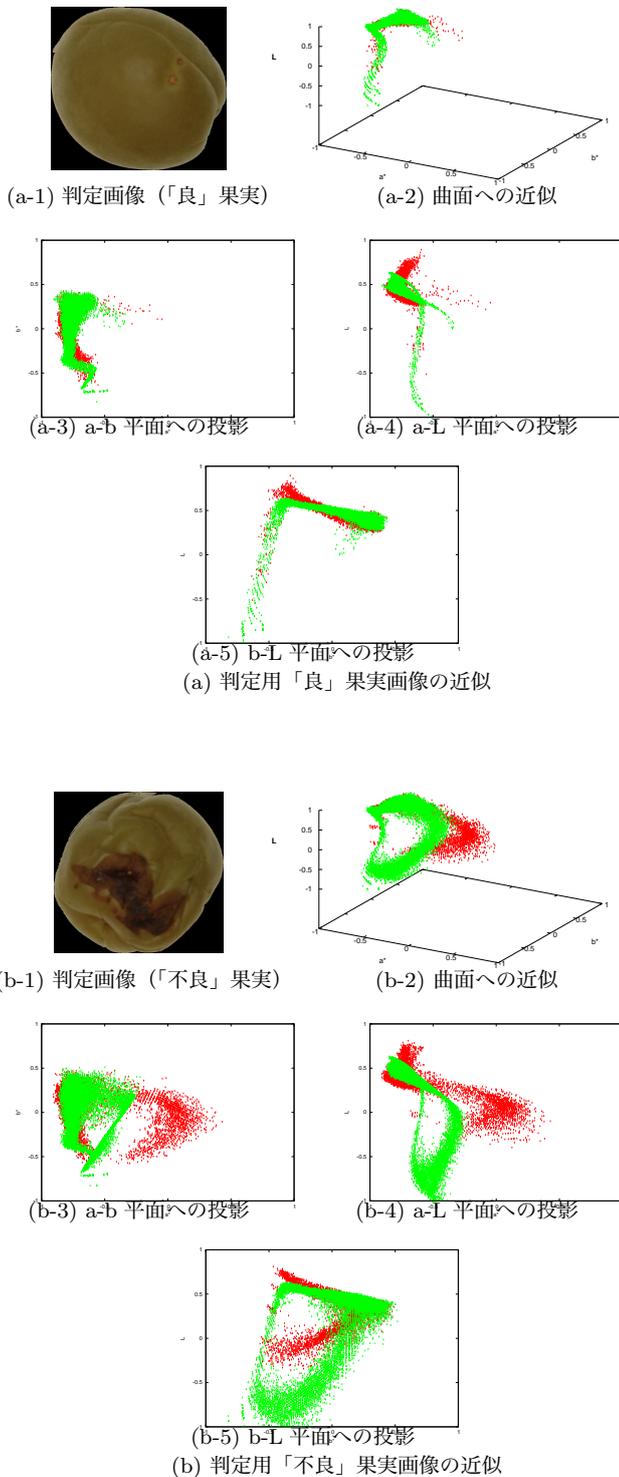


図 7 判定画像の近似結果

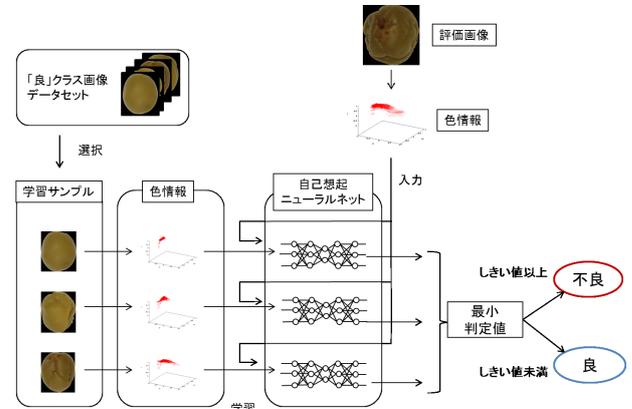


図 8 最小判定値を用いた良否判定

まず、果実画像中に含まれる画素の  $La^*b^*$  値の色空間中の分布を求める。

予め学習された自己想起ニューラルネットワークを用いて判定画像の  $La^*b^*$  値を学習サンプルの曲面に近似させる。入力値 (判定画像の  $La^*b^*$  値) と出力値 (学習サンプルの曲面に近似した値) との 2 乗誤差を画素ごとに求め、3.1 で述べた判定基準値を自己想起ニューラルネットワークごとに求める。

判定画像に対し、自己想起ニューラルネットワーク (学習サンプル) と同数の判定基準値が得られるので、その最小値を画像の特徴とする。得られた判定基準値の最小値 (最小判定値) をしきい値処理することで良否の判定を行う。得られた最小判定値がしきい値以上であった場合を「不良」とし、しきい値未満であった場合を「良」として分類する。

### 3.3.2 階層型良否判定

階層型良否判定の処理の流れを図 9 に示す。

階層型良否判定の場合も最小判定値を用いた良否判定と同様に予め複数の学習用「良」果実画像の  $La^*b^*$  値を学習サンプルとして学習し、しきい値を決定する。学習サンプルの選択方法は 3.4.2 節にて述べる。

階層型良否判定では 3 つのしきい値  $T_P$ ,  $T_N$ ,  $T_0$  を用いて階層的に良否の判定を行う。しきい値  $T_P$  は「良」判定のしきい値であり、判定基準値がしきい値  $T_P$  未満であれば果実を「良」と判定する。しきい値  $T_N$  は「不良」判定のしきい値であり、判定基準値がしきい値  $T_N$  以上であれば「不良」と判定する。しきい値  $T_P$ ,  $T_N$  双方を用いて判定できなかった果実を「未判定」とする。

しきい値はそれぞれ自己想起ニューラルネットワークにおいてしきい値処理により良否判定を行い、「良」あるいは「不良」と判定されなかった画像は「未判定」画像として次の自己

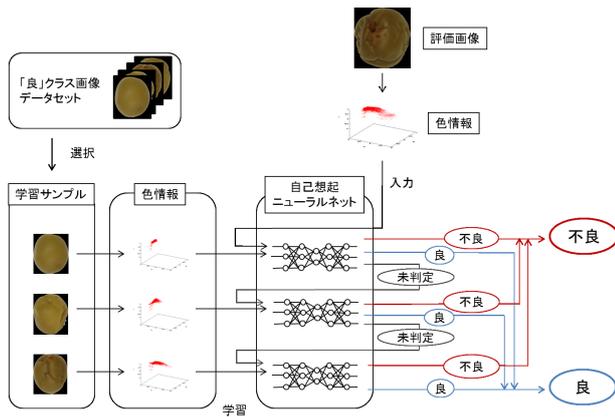


図 9 階層型良否判定

想起ニューラルネットワークを用いて同様に良否の判定をする。全ての自己想起ニューラルネットワークで「未判定」となった果実画像は、最後の自己想起ニューラルネットワークにより「良」「不良」のしきい値  $T_0$  を用いた 2 クラス分類により良否を決定する。

### 3.4 学習サンプル画像の選択

本研究において、判定に要する時間は自己想起ニューラルネットワーク数（学習サンプル画像数）に比例する。工場での自動化を想定した場合、すべての画像の学習は処理時間の肥大化に繋がるため現実的ではない。よって、より小さなコストで高精度な判定とするために適切な画像をサンプル画像として選択する必要がある。

以下の方法を用いて、学習サンプル画像を選択する。選択方法は良否判定方法によって分けて行う。

#### 3.4.1 最小判定値を用いた良否判定の学習サンプルの選択

最小判定値を用いた良否判定を行う場合、学習サンプルを以下の方法を用いて選択決定する。

**STEP 0** 予め「良」「不良」のラベルが付けられた学習用データセットから「良」果実画像を 1 画像取り出して自己想起ニューラルネットワークに学習させ、残りの学習用データセットを用いて判定成功率の算出する。ここで、学習用データセットを用いた判定成功率が 70% 未満となる画像を学習用データセットから棄却する。

**STEP 1** 学習用データセットを用いて得られた判定成功率のうち、最大であったものを 1 つめの自己想起ニューラルネットワーク  $A_1$  とする。

**STEP 2**  $n(n \geq 1)$  個の学習サンプルが既に選択されている場合、学習済みの自己想起ニューラルネットワークを用いて未学習の学習用「良」果実画像の判定基準値をそれぞれ求め、その中で最小の判定基準値を求める。その最小の判定基準値をその画像の距離値とする。その距離値が最大となった画像を次の学習サンプル画像として選択する。選択された画像を学習した自己想起ニューラルネットワークを  $A_{n+1}$  とする。学習サンプルとし

て選択された画像をデータセットから削除する。

**STEP 3** STEP 2 を繰り返して自己想起ニューラルネットワークを選択して学習サンプルに追加する。

**STEP 4** 選択された複数の自己想起ニューラルネットワークを用いて学習用データセットを評価し、最大の判定成功率を得る自己想起ニューラルネットワーク数を決定する。

#### 3.4.2 階層型良否判定の学習サンプル選択

階層型の良否判定を行う場合、学習サンプルの選択を学習用データセットを用いた階層型の良否判定成功率をもとに以下の方法を用いて行う。

**STEP 0** 予め「良」「不良」のラベルが付けられた学習用データセットから「良」果実画像を 1 画像取り出して自己想起ニューラルネットワークに学習させ、残りの学習用データセットを用いて自己想起ニューラルネットワークごとの良否判定成功率を算出する。

**STEP 1** 学習用データセットを用いて算出した判定成功率が最大であったニューラルネットワークを 1 つめの自己想起ニューラルネットワーク  $A_1$  とする。

**STEP 2**  $n(n \geq 1)$  番目の自己想起ニューラルネットワーク  $A_n$  が学習サンプルとして選択された場合、自己想起ニューラルネットワーク  $A_n$  に対して学習用データセットからしきい値  $T_P$ ,  $T_N$ ,  $T_0$  を決定する。自己想起ニューラルネットワーク  $A_n$  を用いて「良」「不良」と判定された果実画像をデータセットから除外する。残りの「未判定」画像を新しく学習用データセットとし、全ての自己想起ニューラルネットワークにおいてそれぞれ  $T_0$  による判定成功率を求める。

ここで最大の判定成功率を得た自己想起ニューラルネットワークを新たな学習サンプル  $A_{n+1}$  として選択する。

**STEP 3** STEP 2 を繰り返して自己想起ニューラルネットワークを選択して学習サンプルに追加する。

**STEP 4** 選択された複数の自己想起ニューラルネットワークを用いて学習用データセットを評価し、最大の判定成功率を得る自己想起ニューラルネットワーク数を決定する。

### 3.5 しきい値の決定

階層型良否判定の場合、自己想起ニューラルネットワークごとに以下の 3 つのしきい値を設定する必要がある。

- $T_0$ : 2 クラス分類のしきい値
- $T_P$ : 「良」を判定するしきい値
- $T_N$ : 「不良」を判定するしきい値

それぞれのしきい値は学習用データセットに則して決定される。 $T_N$  は「良」から「不良」への誤判定が 0 とすることを目的として設定する必要があるため、「良」果実画像データセットのから得られた判定基準値の最大値を基準に決定する。同様に  $T_P$  は「不良」から「良」への誤判定が 0 とすることを目的として設定する必要があるため、「不良」果実画像データセットのから得られた判定基準値の最大値

を基準に決定する。また、 $T_0$  は学習用データセットを用いて0.001刻みで「良」「不良」の2クラス分類の判定成功率を求め、その中で最大の判定成功率を得ることができるしきい値を予め決定する。

### 3.5.1 許容誤判定率

しきい値  $T_P$ ,  $T_N$  において学習用データセットにおいて一定の誤判定を許容して決定する。これを許容誤判定率  $e_{FP}$ ,  $e_{FN}$  とする。 $e_{FP}$  は「不良」から「良」へ誤判定を許容する割合である。同様に、 $e_{FN}$  「良」から「不良」へ誤判定を許容する割合である。

許容誤判定率を用いたしきい値の決定式を以下に示す。ここで、学習用データセットで得られる判定基準値を昇順にソートしたものを「良」、「不良」でそれぞれ  $\hat{E}_{good}(i)$ ,  $\hat{E}_{bad}(i)$  とする。データ数を  $n$ , データ番号を  $i$  とする。

$$T_P = \hat{E}_{bad}(\lfloor (\frac{e_{FN}}{100})n \rfloor) \quad (4)$$

$$T_N = \hat{E}_{good}(\lfloor (1 - \frac{e_{FP}}{100})n \rfloor) \quad (5)$$

## 4. 評価実験

### 4.1 実験データ

本研究で用いる果実画像の例を図10に示す。果実には事前に専門家の目視により「良」「不良」のラベルが付されている。これらの果実をホワイトボード上に複数置き、可視光下においてデジタルカメラ（ニコン社 D80）で垂直上方向から撮影した。撮影した果実画像を手動で果実部分を切り出し、果実1つに対して一枚の果実画像を生成した。

果実画像 348 枚の内訳を以下に示す。

- 「良」果実画像 114 枚
- 「不良」果実画像 234 枚

本実験では三分割交差検定により性能評価を行った。

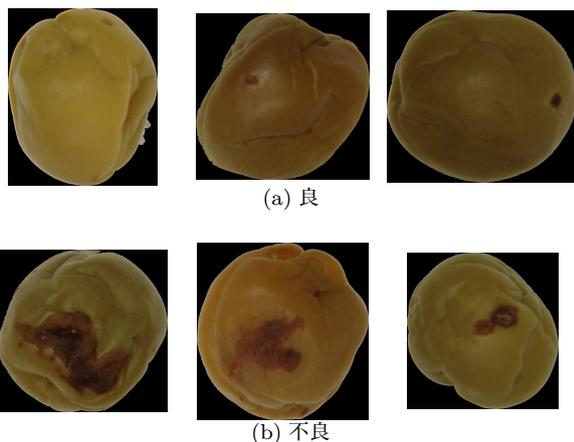


図10 果実画像例

### 4.2 実験1：2クラス分類による性能比較実験

「良」クラス、「不良」クラスの2クラス分類を行なった場合における最小判定値を用いた良否判定と階層型良否判

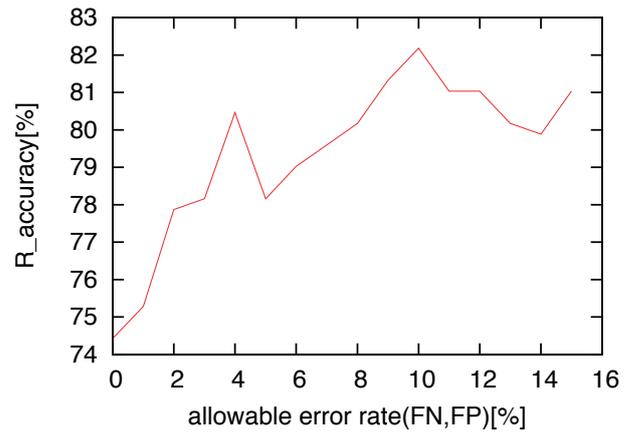


図11 許容誤判定率による判定成功率の変化 ( $e_{FP} = e_{FN}$ )

定の性能の差を調査した。判定基準値には平均2乗距離と上位1%距離を用いて比較した。

### 4.2.1 評価方法

2クラス分類における判定成功率  $R_s$  及び偽陽性率  $R_{FP}$ , 真陽性率  $R_{TP}$  を以下の式により定義する。

$$R_s = \frac{TP + TN}{TP + FN + FP + TN} \times 100[\%] \quad (6)$$

$$R_{FP} = \frac{FP}{FP + TN} \times 100[\%] \quad (7)$$

$$R_{TP} = \frac{TP}{TP + FN} \times 100[\%] \quad (8)$$

### 4.2.2 実験結果

$e_{FP} = e_{FN}$  として許容誤判定率を変動させて得られた判定成功率  $R_{accuracy}$  の結果を図11に示す。

上記の結果を踏まえ、許容誤判定率を  $8 \leq e_{FP} \leq 12$ ,  $0 \leq e_{FN} \leq e_{FP}$  で変動させた場合の判定成功率の結果を図12

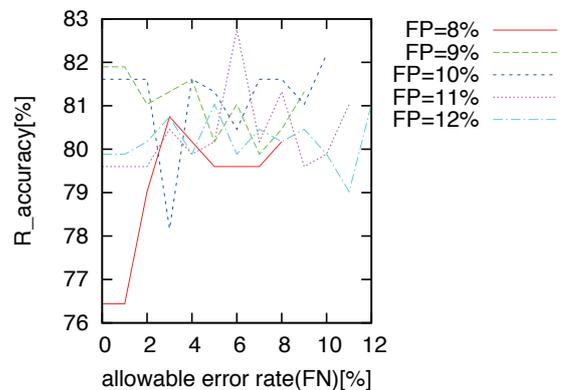


図12 許容誤判定率による判定成功率の変化 ( $8 \leq e_{FP} \leq 12$ ,  $0 \leq e_{FN} \leq e_{FP}$ )

以上より実験結果を表2を示す。比較のため、2色素モデルに基づく良否判定の結果も示す。

表 2 判定手法による判定性能比較

判定手法	判定基準値	判定成功率 $R_s$	$R_{FP}$	$R_{FN}$
最小判定値を用いた 良否判定	平均 2 乗距離	73.0%	28.2%	24.6%
	上位 1% 距離	81.6%	17.5%	20.2%
階層型良否判定 ( $e_{FP}=0, e_{FN}=0$ )	平均 2 乗距離	71.8%	10.3%	64.9%
	上位 1% 距離	74.4%	11.1%	55.3%
階層型良否判定 ( $e_{FP}=10, e_{FN}=10$ )	平均 2 乗距離	76.7%	15.4%	39.5%
	上位 1% 距離	82.2%	15.0%	23.7%
階層型良否判定 ( $e_{FP}=11, e_{FN}=6$ )	平均 2 乗距離	77.3%	19.2%	29.8%
	上位 1% 距離	82.8%	15.0%	21.9%
2 色素モデルに基づく良否判定		80.2%	/	/

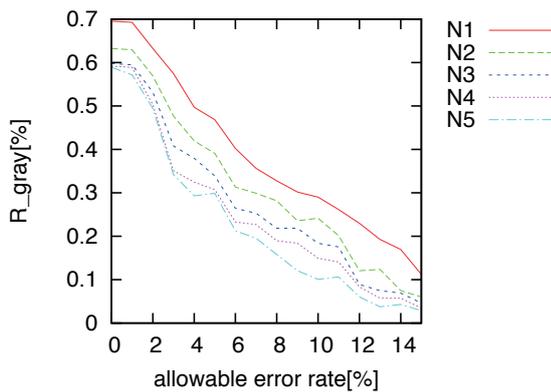


図 13 許容誤判定率による未判定率の変化

#### 4.2.3 考察

許容誤判定率を上げることにより判定成功率が上昇した理由を以下に考察する。自己想起ニューラルネット数が 1 個から 5 個に固定した場合の許容誤判定率による未判定率 (全てのニューラルネットで「良」「不良」の判定ができなかった果実の割合) の変化を図 13 に示す。

図より、許容誤判定率を上げることにより未判定率が減少していることが分かる。全ての自己想起ニューラルネットで「未判定」と判定された果実画像は、最終の自己想起ニューラルネットのしきい値  $T_0$  を用いて 2 クラス分類により良否を判定する。そのため、未判定が多く残る場合は結果が最終の回路に依存してしまうため、誤判定が多くなり、判定成功率の低下に繋がると考える。

#### 4.3 実験 2 : 「未判定」クラスを含む 3 クラス分類による良否判定実験

工場の一次選別における実用化を想定した場合、2 クラスによる分類は誤判定によるコストを増加させてしまうため現実的ではない。そのため、判定に「未判定」クラスを設定し、3 クラスによる良否判定実験を行なった。

##### 4.3.1 評価方法

未判定を含んだ 3 クラス分類による良否判定の場合、「良」あるいは「未判定」と判定された果実は二次選別に回され、「不良」と判定された果実が廃棄される。そのため、「不良」

と判定された果実の中に「良」果実が混入する割合が高くなると損失となってしまふ。また、より多くの「不良」果実を判定し、二次選別のコストを減らすことが求められる。そのため、今実験では以下の判定成功率  $R_{accuracy}$ 、未判定率  $R_{gray}$ 、真陰性率  $R_{TN}$  を用いて評価を行う。

判定成功率  $R_{accuracy}$  及び未判定率  $R_{gray}$ 、真陰性率  $R_{TN}$  を表 3 及び以下の式により定義する。

表 3 判定結果の分類

正解ラベル	判定ラベル		
	良	未判定	不良
良	a	b	c
不良	d	e	f

$$R_{accuracy} = \frac{a + f}{a + c + d + f} \times 100[\%] \quad (9)$$

$$R_{gray} = \frac{b + e}{a + b + c + d + e + f} \times 100[\%] \quad (10)$$

$$R_{TN} = \frac{f}{c + f} \times 100[\%] \quad (11)$$

ここで、しきい値  $T_P$ 、 $T_N$  を任意の変数  $\alpha$  を用いて変動させた場合の性能を比較する。許容誤判定率が共に 0 の場合のしきい値を  $T_{P0}$ 、 $T_{N0}$  とするとき、しきい値  $T_P(\alpha)$ 、 $T_N(\alpha)$  の決定式を以下に示す。

$$T_P(\alpha) = (1 - \alpha)T_0 + \alpha T_{P0} \quad (12)$$

$$T_N(\alpha) = (1 - \alpha)T_0 + \alpha T_{N0} \quad (13)$$

##### 4.3.2 実験結果

$\alpha(0 \leq \alpha < 3)$  で変化させた性能比較実験結果を以下の図 14 に示す。各グラフの横軸は未判定率  $R_{gray}$  を示し、縦軸はそれぞれ判定成功率  $R_{accuracy}$ 、真陰性率  $R_{TN}$  を示す。自己想起ニューラルネットの個数を 1 個から 5 個まで変動させた場合の結果を比較した。

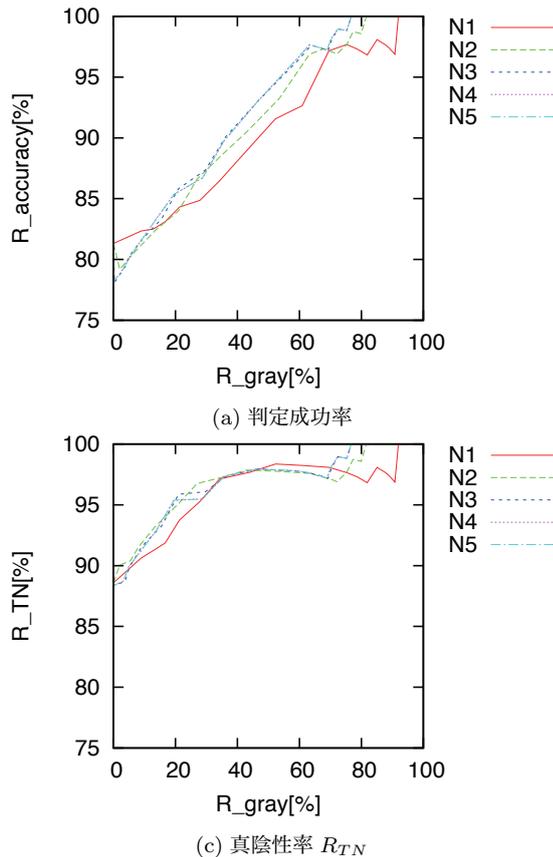


図 14  $\alpha$  による性能比較

#### 4.3.3 考察

実験結果より、自己想起ニューラルネットワーク数を大きくすることにより、 $R_{TN} = 100\%$ （「良」から「不良」への誤判定を0）とした状態での未判定率が削減できることが分かった。

本実験で用いている変数  $\alpha$  は任意に指定することのできる値である。 $\alpha = 0$  において2クラス分類と同じ判定となる。 $\alpha$  を大きくすることで未判定率は大きくなるが、判定成功率を調整することが可能である。

本研究で目的とする自動良否判定システムは、2段階ある良否判定のうちの一次選別を想定している。その際、企業側が自由に精度を設定することができるシステムが求められている。任意の変数  $\alpha$  は企業側が精度を変更できるシステムとして利用できると考える。

### 5. まとめ

本研究では、果実画像から自己想起ニューラルネットワークを用いて果実の良否を判定する手法を提案した。良否判定実験より、階層型の良否判定において許容誤判定率を  $e_{FP} = 11\%$ ,  $e_{FN} = 6\%$  とした場合に最大で82.8%の判定成功率を得ることができた。

また、未判定を含む3クラス分類においては、自己想起ニューラルネットワーク数を増やすことにより真陰性率  $R_{TN}$  を100%に保ったまま未判定率を低減できることを確認した。

### 参考文献

- [1] 井上聡, 若林哲史, 鶴岡信治, 木村文隆, 三宅康二, “自己想起ニューラルネットワークによる手書き数字認識”, 情処学論, vol.39,no.8,pp2476-2484, 1998
- [2] Tadhg Brosnan, Da-Wen Sun, Inspection and grading of agricultural and food products by computer vision systems - a review, Computers and Electronics in Agriculture 36, 193-213, 2002.
- [3] Cheng-Jin Du, Da-Wen Sun, Learning techniques used in computer vision for food quality evaluation: a review, Journal of Food Engineering 72, 39-55, 2006.
- [4] 雨森道紘, 横水伸行, 果実そ菜類の等級の新しい自動画像解析判別法, 電気学会論文誌 C 電子・情報・システム部門誌 125(9), 1476-1480, 2005.
- [5] J Blasco, N Aleixos, J Gomez, E Molto, Citrus sorting by identification of the most common defects using multispectral computer vision, Journal of Food Engineering 83, 384-393, 2007.
- [6] V. Leemans, M.-F. Destain, A real-time grading method of apples based on features extracted from defects, Journal of Food Engineering 61, 83-89, 2004.
- [7] Kıvanç Kılıç, İsmail Hakki Boyacı, Hamit Köksel, İsmail Küsmenoğlu, A classification system for beans using computer vision system and artificial neural networks, Journal of Food Engineering 78, 897-904, 2007.
- [8] 伊藤嘉純, 大山航, 若林哲史, 木村文隆: 2色素モデルに基づく果実の自動良否判定システムの開発, 信学技報 PRMU2013-80, pp. 73-77
- [9] Hassoun, M.: Fundamentals of Artificial Neural Networks. MIT Press, 1995
- [10] Cottrell, G., Munro, P., Zipser, D.: Image compression by back-propagation: An example of extensional programming. Models of Cognition: A Review of Cognitive Science, 1(1989)208-240
- [11] Cottrell, G., Munro, P., Zipser, D.: Learning internal representations from gray-scale images: An example of extensional programming. Ninth Annual Conference of the Cognitive Science Society, (1987)462-473
- [12] DeMers, D., Cottrell, G.: Non-linear dimensionality reduction. Advances in Neural Information Processing Systems 5, (1992)550-587