

平成 14 年度

学士學位論文

ニューラルネットワークを用いた米選別システムの
開発に関する研究

Research on Construction of Development of a Rice Sorter
System Using Neural Network

学籍番号：1030287 氏名：中屋任喜

指導教員：竹田史章 教授

2003 年 2 月 12 日

高知工科大学大学情報システム工学科

要旨

ニューラルネットワークを用いた米選別システムの 開発に関する研究

中屋任喜

現状の米選別機は、機構内のシュータを落下してくる米に光を照射し、センサで米の明暗を感知し、しきい値と比較して暗い部分があれば、それを被害米とみなし空気銃で除去を行っている。しかしながら、米の落下流量が数千[kg/h]を越えるような速さで米の監査を行う場合に、選別性能を保証することができないという問題がある。これまでの研究では、ニューラルネットワークを用いた選別手法を搭載したプロトタイプシステムを製作し、選別性能の向上を図ってきた。本研究では、特にシミュレーションシステムの学習部分に改良を加え、計算機実験により更なる性能の向上を得ることを目的とする。

キーワード

ニューラルネットワーク, 標準米, 被害米, 米選別, 回転補正アルゴリズム

Abstract

Research on Construction of Development of a Rice Sorter System Using Neural Network

Hideki NAKAYA

In the current rice sorter, rice fallen from a shoot, then a photo measures brightness according to rice color. If rice has a dark part compared with a threshold value, rice is rejected as damaged one by an air gun. However, the recognition performance is not enough on its recognition ability and transaction volume with a conventional rice sorter. In the previous research, the prototype system was produced what has neural network and was aiming at improvement in a sorting performance. In this research, the rice picture is enlarged in order to gather the rate of sorting. There for the compensation algorithm for rotation is introduced.

Keywords

Neural network, Normal rice, Damage rice, Rice grading, The compensation algorithm for rotation

目次

1. はじめに	p1
2. 現状の米選別機	p3
2.1 現状の米選別機の構成	p3
2.2 現状の米選別機の選別性能	p5
3. これまでの研究	p11
3.1 米選別機の基本構成	p11
3.2 プロトタイプシステム	p14
3.3 問題点	p18
4. シミュレーションシステムの改良	p19
4.1 カメラ倍率の変更	p19
4.2 画像フレームの変更	p20
4.3 擬似回転補正アルゴリズムのシミュレーション部への導入	p21
5. シミュレーション実験	p25
5.1 実験条件	p25
5.2 実験結果	p29
5.3 考察	p30
6. まとめ	p31
7. 謝辞	p32
8. 参考文献	p33
9. 付録	p36
・ニューラルネットワーク	

図目次

図 2.1	現状の米用色彩選別機の概観	p3
図 2.2	現状の米選別機の構成	p4
図 2.3	現状の米選別機の処理フロー	p5
図 2.4	供給量に対する選別率の予測図	p10
図 3.1	米選別用 NN の構成	p11
図 3.2	米選別機の基本構成	p12
図 3.3	米選別機の制御フロー	p13
図 3.4	プロトタイプシステム概観	p15
図 3.5	ラインセンサカメラで撮影した米画像	p15
図 3.6	実行画面例	p16
図 3.7	評価結果表示例	p17
図 4.1	テストピース	p19
図 4.2	216×32 フレームイメージ	p20
図 4.3	128×128 フレームイメージ	p20
図 4.4	マスク処理画面	p21
図 4.5	米切り出し時における背景比率の違い例	p22
図 4.6	米画像の閾値との比較方向と画素イメージ	p23
図 4.7	シミュレーションシステムフローチャート	p24
図 5.1	胚芽による方向の違い	p25
図 5.2	透明米を目的パターンとした場合の学習用米画像	p26
図 5.3	しらた米を目的パターンとした場合の学習用米画像	p27
図 5.4	実験 2 に用いた学習用画像	p28

表目次

表 2.1	混入率が 3%の時の選別結果 (%)	p6
表 2.2	混入率が 2%の時の選別結果 (%)	p7
表 2.3	混入率が 1%の時の選別結果 (%)	p7
表 2.4	混入率が 0.7%の時の選別結果 (%)	p7
表 2.5	混入率が 0.4%の時の選別結果 (%)	p8
表 2.6	混入率が 0.1%の時の選別結果 (%)	p8
表 2.7	供給量が 80 の時の選別感度変化による選別結果 (%)	p9
表 3.1	選別パターンの分類	p18
表 3.2	識別結果	p18
表 5.1	実験 1 結果	p30
表 5.2	実験 2 結果	p30

1. はじめに

1. はじめに

現在，ライスセンターなどの大規模な精米工場においては，米の袋詰を高速に行う必要性が急速に高まっている．従来から標準米（半透明で欠けがない米）と被害米（欠け，虫食い，変色などの被害を受けた米）を分類することは袋詰された米の品質を左右するものであるが，その自動化においては，対象が自然落下する米であり，十分な性能が得られず，有効な手段が見出されてはいない．そこで，米の大量出荷に対応できる新しい監査方法が必要とされている．

現状の米選別機においては，機構内のシュータを落下してくる米に光を照射し，センサで米の明暗を感知し，閾値と比較して暗い部分があれば，それを被害米とみなし空気銃で除去を行っている．共同研究者（企業）が実施した性能確認実験に用いた米選別機は，光の強さを調整することが可能で，光の強弱が変化するに伴い，明暗を分ける閾値も変化させる．この選別感度を高くすると，取り扱う米の落下流量が数百[kg/h]であれば，被害米の除去率は90%以上である．だが，米の落下流量が数千[kg/h]を越える場合，被害米の除去率は90%を下回る．この点のみを考慮すると，常に米の落下流量を数百[kg/h]に設定し，選別感度も高く設定しておけば，現状の選別機でも品質は保証される．しかしながら，実際の精米工場で取り扱う米の量は，最大で数十万[kg]に及ぶこともあり，取り扱う米の量を数百[kg/h]に設定すると，すべての米の選別に膨大な時間を費やすこととなる．

つまり，高い被害米除去率を維持するために落下流量を減らせば米の選別時間が長くなり，作業効率が悪くなる．逆に，落下流量を増やし，米の選別時間の短縮を行った場合，被害米の除去率が低下し，良品である標準米の中に被害米が混入する問題が生じる．

このような落下状態にある米選別に関する問題点を解決するために，本研究では，

1. はじめに

米画像を用いて現状の米選別機に非線形識別能力を有するニューラルネットワーク（以下 NN と略記）^{[1]-[2]}を用いた選別手法^{[3]-[17]}の導入を提案し，高性能な選別性能を得ることを目的としてきた^{[18]-[23]}。著者はこれまでに開発されたプロトタイプシステムの問題点を挙げ，シミュレーションシステムに改良を加えることにより性能の向上を図ることを目的とする。

これまで，米画像の撮影は実物の米に対して等倍となる焦点距離で行ってきた。しかしながら，抽出時に行われる収縮により小さめの米が消失する等の問題が生じていた。この問題を解決するため米画像を 1.6 倍となるように変更する。これは実際に流下状態にある米を撮影し処理できる範囲内の数値である。また，米画像部分の画素数が増加することにより，これまで使用してきた米画割像用のフレームに米が収まらなくなったため，画像フレームの変更を行った。さらに，流下状態で予想される一定方向をむいていない米画像の識別率向上を図るため擬似回転補正プログラム^[19]を導入する。これは，これまで画像フレームから NN への入力データを作成する際に，背景ごとマスク処理を施していたのに対して，あらかじめ定めておいた閾値以上の画素を一次元配列に収めることによって米の角度に関係無く NN への入力データを作成するものである。

以上の改良を加えシミュレーション実験を行い，米選別システムの更なる性能の向上を確認する。

2.1 現状の米選別機の構成

2. 現状の米選別機

本章では、精米工場などで使用されている現状の米選別機の機能や仕様について述べる。また、性能実験の結果を示すことにより問題点を明確にし、その改善を本研究の目的とする。

2.1 現状の米選別機の構成

現状の米選別機の概観を図 2.1 に示す。また、現状の米選別機の構成を図 2.2 に示す。現状の米選別機では、1 段階目の工程として、機構内のシュータを落下してくる米に光を照射し、センサで米の明暗を感知し、閾値のと比較を行い暗い部分があれば、それを被害米とみなし、空気銃で除去を行う。1 段階目の工程で除去された米の中には、被害米の周辺に流れてきた標準米が、空気銃の空圧で被害米と同時に吹き飛ばされるために多く含まれている。そのため、2 段階目の工程として、1 段階目の工程で除去された米をもう一度流し、同様の手順で被害米を除去する。その制御フローを図 2.3 に示す。



図 2.1 現状の米用色彩選別機の概観

2.1 現状の米選別機の構成




図 2.2 現状の米選別機の構成

2.2 現状の米選別機の選別性能

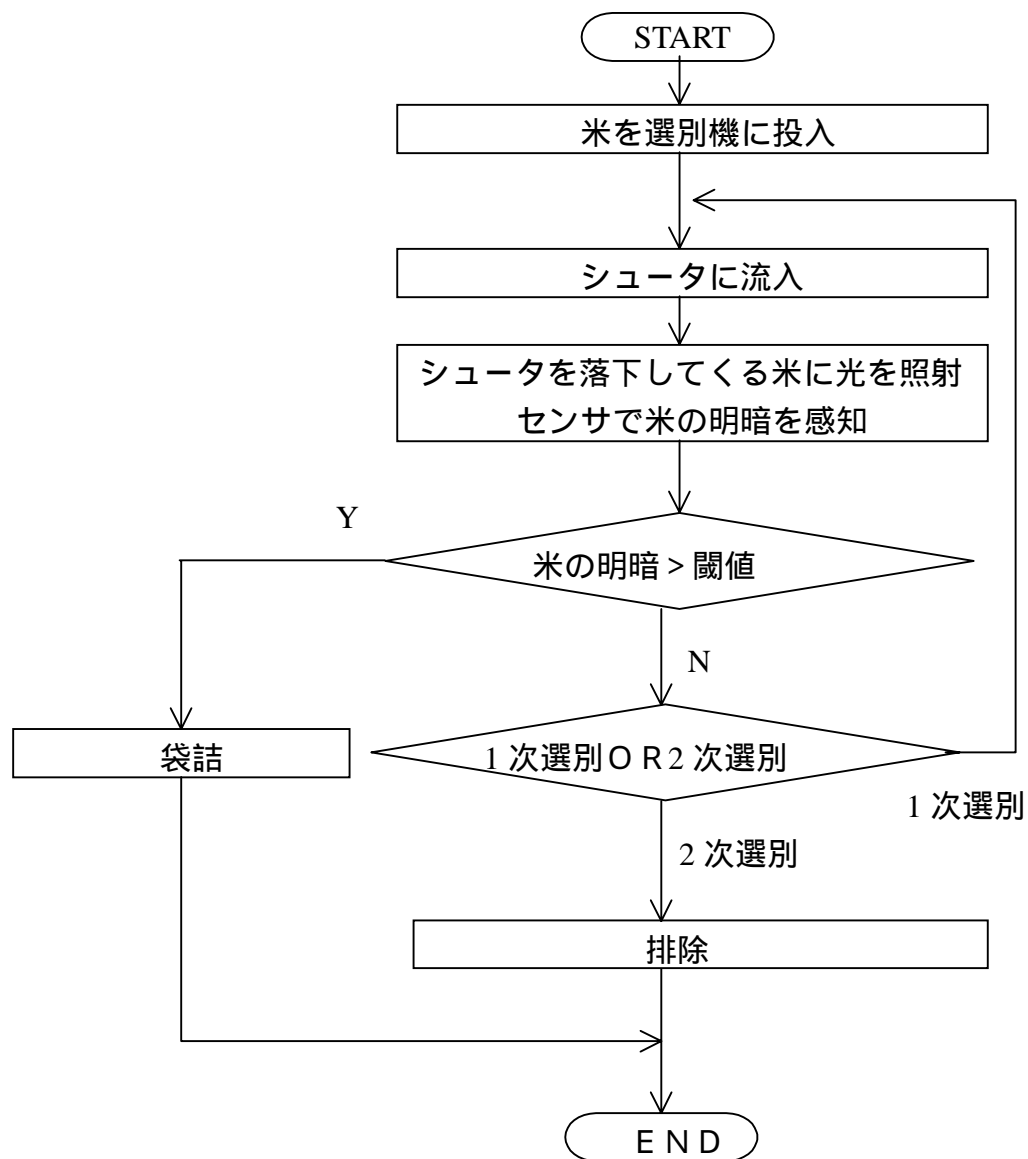


図 2.3 現状の米選別機の処理フロー

2.2 現状の米選別機の選別性能

本節では、1997年に共同研究者が実施した現状の米選別機における選別性能調査結果を示す。

2.2 現状の米選別機の選別性能

共同研究者が実施した性能確認実験に用いた米選別機は、光の強さを調整することが可能で、光の強弱が変化するに伴い、明暗を分ける閾値も変化させることが出来るものを使用している。

選別機に投入する米はジャポニカ種標準白米（白度 31.3 度）に赤色着色もみ（白度 14 度）を混入したものである。供給量は 40 から 80 まで変化させ（量は各表参照）、選別感度調整ボリュームを 20～80 まで 10 段階飛びに光の強さを調整して、それぞれの選別性能を調査した。

性能実験はもみの混入率が、3%、2%、1%、0.7%、0.4%、0.1%の場合に対して、選別感度及び供給量を変化させ、選別率の検証を行う。もみ混入量の異なる各実験に対して供給量を 40 から 80 まで変化させ、もみの除去率を測定する。各々の選別結果は混入率 3%を表 2.1 に、2%を表 2.2 に、1%を表 2.3 に、0.7%を表 2.4 に、0.4%を表 2.5 に、0.1%を表 2.6 に示す。

また、供給量が最大の 80 の時、選別感度の変化に対し、もみ混入率の違いによる選別性能の違いを表 2.7 に示す。

表 2.1 混入率が 3%の時の選別結果（%）

供給量 感度	40(105[kg/h])	50(144[kg/h])	60(224[kg/h])	70(261[kg/h])	80(349[kg/h])
20	76.5	84.0	73.0	57.0	53.5
30	96.2	95.5	91.7	85.2	80.3
40	99.0	98.5	97.4	94.8	90.8
50	99.6	98.7	98.9	97.4	96.4
60	99.2	98.6	98.7	98.5	98.2
70	99.2			98.2	97.2
80					96.5

2.2 現状の米選別機の選別性能

表 2.2 混入率が 2%の時の選別結果 (%)

供給量 感度	40(105[kg/h])	50(147[kg/h])	60(212[kg/h])	70(280[kg/h])	80(350[kg/h])
20	61.2	73.9	64.5	58.8	47.7
30	94.9	93.4	87.95	84.3	75.0
40	99.7	97.1	96.5	92.3	89.3
50	99.3	99.6	99.2	97.8	95.9
60	99.9	99.2	98.6	98.5	97.9
70	99.4	99.1	98.5	98.3	98.8
80	99.5	99.1	98.8	98.3	97.8

表 2.3 混入率が 1%の時の選別結果 (%)

供給量 感度	40(108[kg/h])	50(152[kg/h])	60(202[kg/h])	70(261[kg/h])	80(328[kg/h])
20	48.1	75.0	47.3	55.8	47.9
30	92.5	91.6	85.7	83.0	77.3
40	99.0	98.4	96.2	94.0	90.5
50	99.7	99.5	98.7	98.0	96.8
60	99.8	99.4	98.3	97.8	96.5
70	99.8	98.1	97.9	98.4	97.3
80	100	98.6	98.4	98.0	96.6

表 2.4 混入率が 0.7%の時の選別結果 (%)

供給量 感度	40(104[kg/h])	50(148[kg/h])	60(209[kg/h])	70(269[kg/h])	80(331[kg/h])
20	86.7	82.9	80.9	71.3	62.8
30	98.6	97.1	95.1	94.4	85.2
40	100	99.3	98.9	95.8	96.6
50	100	100	99.3	99.6	99.6
60	99.3	100	99.3	98.9	99.3
70	100	100	99.3	99.6	99.3
80	99.6	99.6	98.5	100	98.9

2.2 現状の米選別機の選別性能

表 2.5 混入率が 0.4%の時の選別結果 (%)

供給量 感度	40(102[kg/h])	50(145[kg/h])	60 (204[kg/h])	70(263[kg/h])	80(340[kg/h])
20	83.3	73.3	70.3	67.3	58.0
30	98.0	98.7	94.0	92.7	84.7
40	100	100	99.3	96.7	96.0
50	100	100	99.3	100	99.3
60	100	100	100	99.3	99.3
70	100	100	100	98.7	100
80	100	100	100	100	100

表 2.6 混入率が 0.1%の時の選別結果 (%)

供給量 感度	40(103[kg/h])	50(142[kg/h])	60(204[kg/h])	70(263[kg/h])	80(325[kg/h])
20	59.0	79.0	56.4	56.4	51.3
30	89.7	98.0	92.3	89.7	82.1
40	97.4	100	100	97.4	92.3
50	100	100	100	100	100
60	100	100	100	100	100
70	100	100	97.4	100	100
80	100	100	100	100	100

2.2 現状の米選別機の選別性能

表 2.7 供給量が 80 の時の選別感度変化による選別結果 (%)

もみ混入率 感度	3%	2%	1%	0.7%	0.4%	0.1%
20	53.5	47.7	47.9	62.8	58.0	51.3
30	80.3	75.0	77.3	85.2	84.7	82.1
40	90.8	89.3	90.5	96.6	96.0	92.3
50	96.4	95.9	96.8	99.6	99.3	100
60	98.2	97.9	96.5	99.3	99.3	100
70	97.2	98.8	97.3	99.3	100	100
80	96.5	97.8	96.6	98.9	100	100

実験結果より、もみ混入率の多少に関わらず、選別感度が 50 以上からもみの除去率が高くなっていることが分かる。また表 2.7 から、もみの混入率が少ないほど選別性能は良くなっていることが分かる。

もみ混入率が 3%、感度 60 の時の実測データをもとに、選別量が 1000[kg/h]の時のもみの除去率を推測すると、図 2.4 のようになる。図 2.4 より選別量が 1000[kg/h]を越えると、もみの除去率が 90%を下回ると考えられる。つまり、米の供給量を少なくした場合、高いもみの除去率を保証することができるが、監査に費やす時間が長くなり、作業効率が低下する。逆に、米の供給量を多くした場合、監査に費やす時間は短縮できるが、もみの除去率が低下するという問題が生じる。また、米を 1 粒ずつを監査することが不可能であるため、もみ・被害米と一緒に標準米も多数除去されてしまう。これらの問題点を解決するため、本研究では米 1 粒ずつを抽出し、NN を用い米 1 粒 1 粒を選別することにより供給量の増加による被害米除去率の低下の改善を目指している。

2.2 現状の米選別機の選別性能




図 2.4 供給量に対する選別率の予測図

3.1 米選別機の基本構成

3. これまでの研究

これまでの研究^{[18]-[23]}では、米選別に NN を用いた選別手法を導入し、選別性能の向上を図ってきた。

米選別用 NN の基本構成について記述する。米選別用 NN の構成は、非線形識別が可能な最小構成の 3 層階層型である。まず、米画像に 50 種類のマスク処理を施すことにより特徴抽出されたデータをスラプ値として入力するため、ユニット数は 50 とし、中間層のユニット数は 20 とした NN を用いる。また、選別するカテゴリを標準米と被害米の 2 種類に大別する場合、出力ユニット数は 2 となる。したがって、NN の構成は、 $50 \times 20 \times 2$ (入力層ユニット数 \times 中間層ユニット数 \times 出力層ユニット数) である。

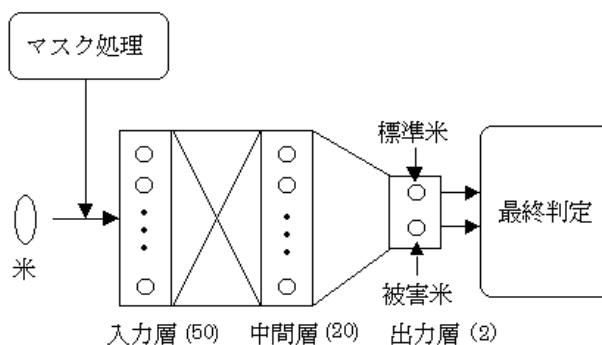


図 3.1 米選別用 NN の構成

3.1 米選別機の基本構成

米選別機の基本構成は図 3.2 に示されるように、米が流れてくるシュータ部分、ラインセンサにより米を撮影する撮影部分、NN を用いて撮影した流下米の画像から標準米と被害米を選別するための選別部分、被害米の除去を行うための空気銃で構成さ

3.1 米選別機の基本構成

れる．これまで開発されたシステムでは，ラインセンサから得られる二次元画像データより，米の選別を行う．米選別機の制御フローを図 3.3 に示す．まず，選別機内のシュータを自由落下してくる米画像をラインセンサにて取込む．ラインセンサにて取込んだ画像データ 1 フレーム（取込単位）から，選別単位となる米 1 粒の画像を抽出する．抽出した画像には位置情報を付加する．NN を用いて標準米と被害米の識別を行う．最後に，標準米と判断された米はそのまま落下し袋に詰められる．被害米と判断された米は，位置情報を基にして空気銃で圧縮空気が吹き付けられ，除去される．




図 3.2 米選別機の基本構成

3.1 米選別機の基本構成

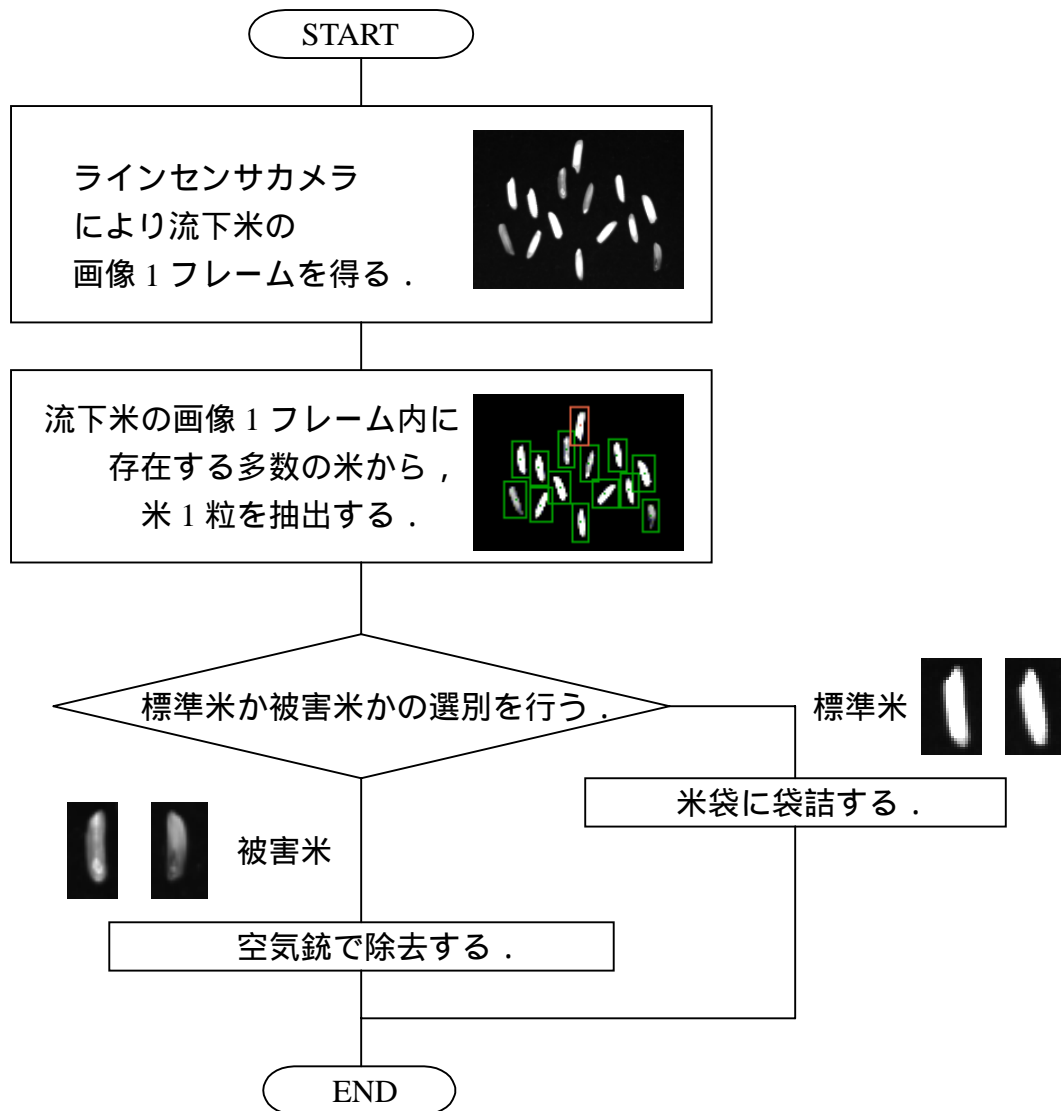


図 3.3 米選別機の制御フロー

3.2 プロトタイプシステム

本項では，3.1 で考案した選別手法^{[12]-[17]}及び抽出アルゴリズム^{[15]-[17]}を搭載し，産業応用を前提としたプロトタイプシステムについて述べる．プロトタイプシステムの概観は図 3.4(a)に示すように，撮影部，米を置くボード部，一定量の光を照射するための照明部，撮影部，選別部で構成されている．撮影にはラインセンサカメラを使用し，米を置いたボードを一定方向に動かすことにより複数米の画像を1フレームとして撮影する．実際には，図 3.4(b)に示すように，カバーを被せ外来光を遮断した状態で撮影を行う．図 3.5 にラインセンサカメラで撮影したビットマップ画像を示す．また，図 3.6 に本システムによって画像フレームの複数米から米 1 粒毎に抽出した状態と，注目した米画像の拡大図を示す．図 3.6 の位置確認画面より，注目画像の位置を確認することが可能となり，ビットマップ画像との対応付が容易である．また，1 フレーム画像からどのように米が抽出されているかを一目で確認することが可能となっている．抽出アルゴリズムの収縮回数を指定しておくことにより，米が物理的に接していても 1 粒ずつを選別することも可能である．処理制限として現段階では抽出できる米の数は 250 粒としている．さらに，本システムによる米 1 粒毎の選別結果表示例を図 3.7 に示す．選別結果を示す表には，A 欄にラベル番号，B 欄に米の中心位置の X 座標，C 欄に米の中心位置の Y 座標，D 欄に米の横幅，E 欄に米の縦幅，F 欄に判定結果，G 欄に標準米に対する反応値，H 欄に被害米に対する反応値が 1 フレーム内の米すべてに対して表示される．表の上部には，ラベル数（米の数），米の横幅拡大画素数，米の横縦拡大画素数，画像収縮回数を表示する．また，表の下部には集計結果を表示する．撮影から，選別結果の表示までの一連の処理はパソコン上のプログラムを実行し，オフライン処理を行っている．

3.2 プロトタイプシステム



(a) プロトタイプシステムの構成



(b) 撮影用カバーを設置した概観

図 3.4 プロトタイプシステム概観




図 3.5 ラインセンサカメラで撮影した米画像

3.2 プロトタイプシステム

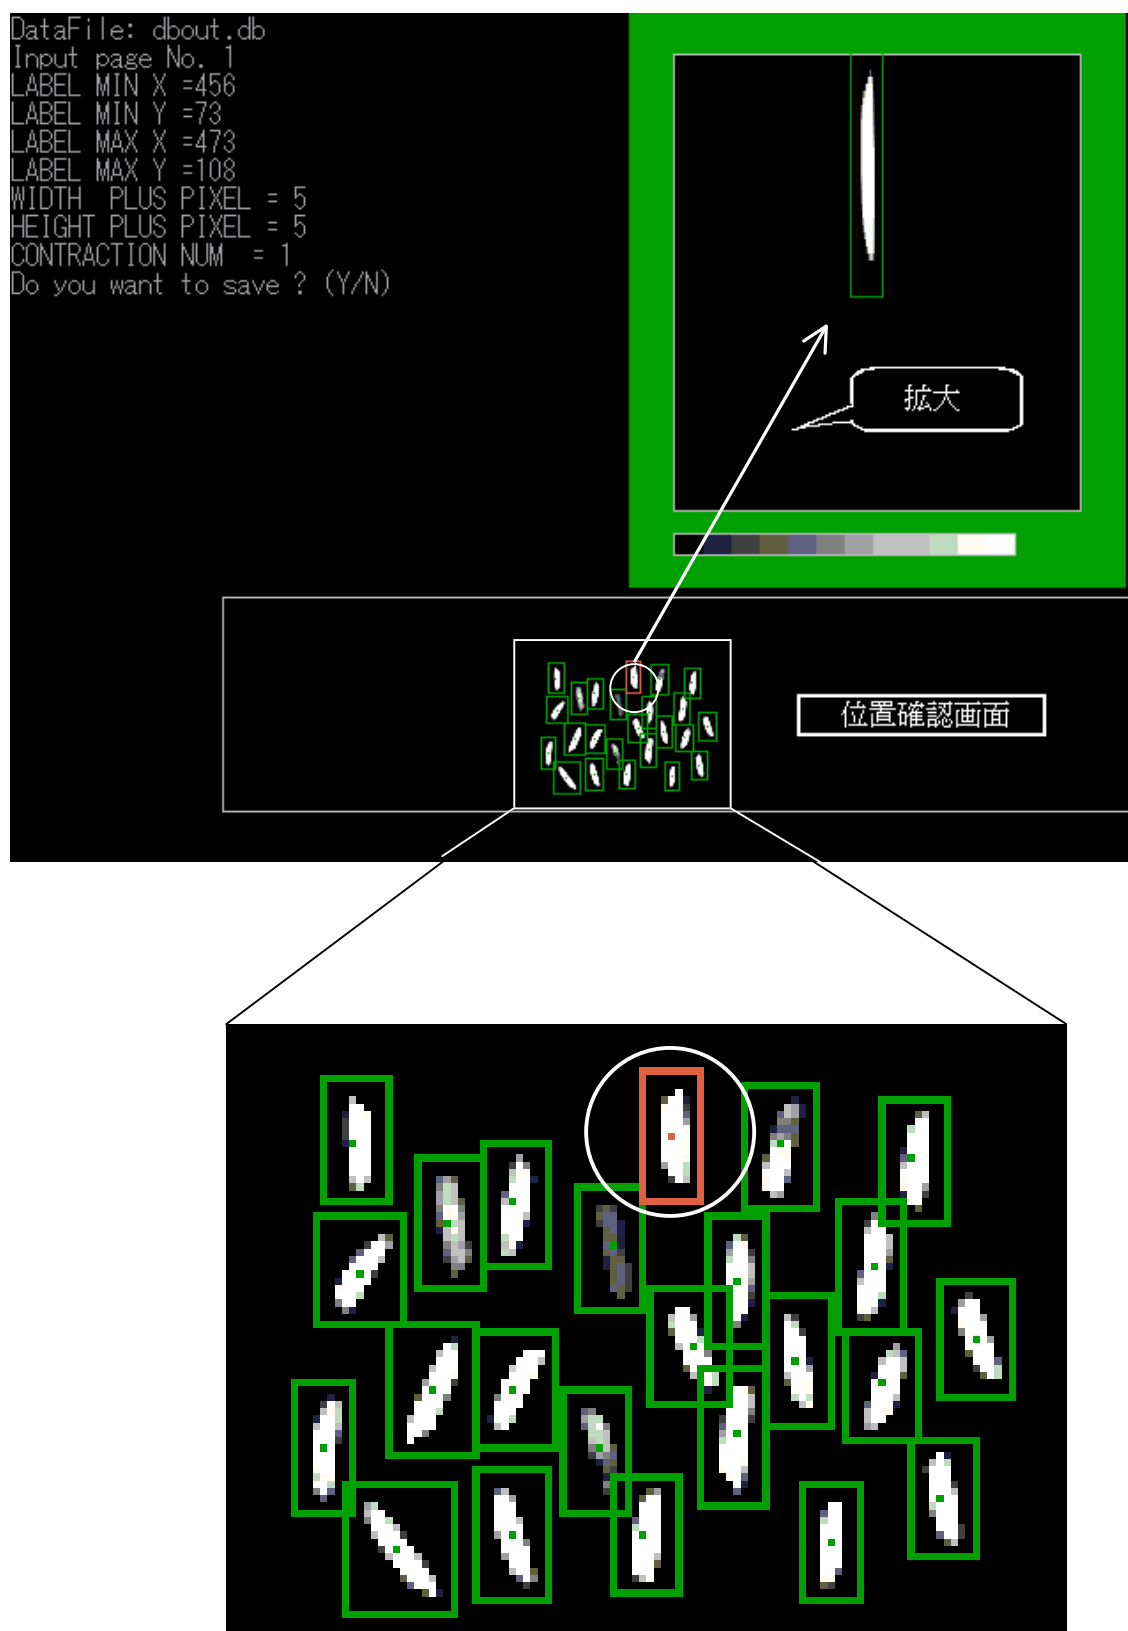


図 3.6 実行画面例

3.2 プロトタイプシステム

	A	B	C	D	E	F	G	H
1	米評価							
2								
3	ラベル数	24						
4	幅拡大画素数	5						
5	高さ拡大画素数	5						
6	画像収縮回数	1						
7								
8		中心(X)	中心(Y)	幅	高さ	結果	反応値(標)	反応値(被)
9	1	464	90	17	35	被害米	0.311726	0.749502
10	2	377	92	17	34	被害米	0.026334	0.980863
11	3	494	93	20	35	被害米	0.33309	0.74582
12	4	531	97	17	35	被害米	0.099401	0.923327
13	5	421	109	18	35	被害米	0.00411	0.99716
14	6	403	114	19	37	被害米	0.19043	0.848072
15	7	448	121	18	35	被害米	0.145803	0.87871
16	8	520	126	18	37	被害米	0.003764	0.997409
17	9	378	128	24	30	標準米	0.610801	0.433931
18	10	482	130	17	35	被害米	0.036053	0.97245
19	11	548	146	21	32	標準米	0.943773	0.071458
20	12	470	149	22	32	標準米	0.961402	0.049245
21	13	499	152	18	35	標準米	0.674825	0.396562
22	14	398	160	24	37	被害米	0.003764	0.997589
23	15	421	160	23	32	標準米	0.950865	0.066617
24	16	523	159	20	31	被害米	0.008757	0.993842
25	17	482	173	18	39	被害米	0.028675	0.977555
26	18	368	176	17	36	被害米	0.331484	0.739074
27	19	444	177	18	33	被害米	0.000696	0.999409
28	20	539	190	19	33	標準米	0.972605	0.036823
29	21	420	201	21	36	標準米	0.963473	0.050739
30	22	457	200	18	33	被害米	0.008424	0.994326
31	23	508	202	16	33	被害米	0.010655	0.992201
32	24	389	204	29	35	標準米	0.998674	0.002594
33	評価結果							
34		%	個数	全体個数				
35	標準米		33	8	24			
36	被害米		66	16	24			
37	REJECT		0	0	24			

図 3.7 評価結果表示例

このプロトタイプシステムを用いて選別性能実験を実施する。選別を行う米はインド米で、種類は標準米（透明度の高い米）、しらたに近い標準米、虫食い米、変色米である。実験条件はカメラ感度が 350、カメラ絞りが 2、照度が 8400 ルクスとなっている。カテゴリ分けとしては、透明米とそれ以外の米を分けたものとしらた米とそれ以外の米に分けたものの 2 パターンについて実験を行った。結果は平均して 65%の識

3.3 問題点

別率であった。

3.3 問題点

これまでの研究では、米の切り出し時に抽出できない場合があった。これは小さい米が収縮処理を行う際に米画像が消失することが原因であると考えられる。また、米撮影の際に米の方向をほぼ一定に定めていた。しかしながら、実際は米が流下状態にある場合、あらゆる角度においての米画像の撮影が要求される。このため、実機への搭載を考慮する場合、あらゆる米の角度に対応する必要がある。さらに、米画像にマスク処理を施したのち、NN への入力データとしているため、米画像に写り込んでいる背景の黒い部分も NN へ入力されるデータの一部となっている。このことは、米という非常に小さな対象物において、大きなノイズになっていると考えられる。そのため、今後は米画像内の背景画素を排除する必要がある。

4.1 カメラ倍率の変更

4. シミュレーションシステムの改良

本研究では、シミュレーションシステムにこれまでの問題点^{[18]-[23]}を改善する改良を加え、識別精度の向上を図ることを目的としている。本章では 3.3 で示した問題点を改善するため、カメラ倍率の変更、画像フレームの変更、擬似回転補正アルゴリズムのシミュレーション部への導入を行う。また回転補正の導入により、3.で記した米選別用 NN の構成に若干変更を加える。変更内容として、入力層を 80、中間層を 30 とする。

4.1 カメラ倍率の変更

これまでのシステムでは米の撮影を等倍で行っていた。しかしながら、抽出時に隣接した米と米の分離を行うための収縮により、小さめの米が消失する等の弊害が生じていた。この問題を解決することを目的としてカメラ倍率を変更する。米画像の倍率を上げると米一粒一粒の画素数が増加し、学習及び評価に用いるデータ量が増加するということであるため、識別率の向上にも繋がることが期待される。しかしながら、その倍率は流下状態で実際に識別が可能である範囲内でなければならない。この条件を満たす倍率の調査を行うために図 4.1 に示すようなテストピースを製作した。左端のものが実物の米に対し等倍で米を撮影した場合とほぼ同等の大きさであり、順番に縦横を 1.2 倍、1.4 倍、1.5 倍にしたものを用意し調査を行った。




図 4.1 テストピース

4.2 画像フレームの変更

用意したテストピースを隣接させ、それぞれのテストピースが切り出せるかの確認を行った。調査の結果、米画像が 1.4 倍程度あれば切り出しを行えることが確認された。実機での処理を考慮すると 1.7 倍程度までが処理可能である。そこで、これらの調査を考慮して今後は 1.6 倍にて米の撮影を行う。

4.2 画像フレームの変更

4.1 で示した撮影条件の変更により、米画像が 1.6 倍となった。そのため、これまで使用していた画像フレーム内に米が収まりきらない場合が生じることが確認された。図 4.2 に、等倍の米と 1.6 倍の米が従来の 216×32 ピクセルのフレーム上に納められるイメージを示す。図 4.2 (a) は真横の、図 4.2 (b) は真縦の各米イメージを表している。真横を向いている場合は、米が 1.6 倍になった場合でもフレーム内に収まるのに対して、縦に近づくにしがって米が 1.6 倍の場合にフレーム内に収まらない。




図 4.2 216×32 フレームイメージ

この問題を解決するために図 4.3 に示すように画像フレームを 128×128 ピクセルに変更する。この変更により米の向きに関係無く 1.6 倍に変更された米画像をフレーム内に収めることが可能である。

4.3 擬似回転補正アルゴリズムのシミュレーション部への導入




図 4.3 128 × 128 フレームイメージ

4.3 擬似回転補正アルゴリズムのシミュレーション部への導入

ここでは、米画像の識別率の向上を図るためにシミュレーション部に導入した擬似回転補正アルゴリズムについて述べる。これまでのシステムでは、撮影されたフレーム画像に、NN の入力細胞数と同数のマスク処理を、図 4.4 に示すマスク処理画面にて施したのち NN への入力データとしている。



図 4.4 マスク処理画面

4.3 擬似回転補正アルゴリズムのシミュレーション部への導入

この手法では、背景の黒い部分も NN へ入力されるデータの一部となっていた。しかしながら、米という非常に小さな対象物に対して、背景は大きなノイズになっていると考えられる。さらに図 4.5 に示すように切り出し時に背景を多く含むものとそうでないものが生じることにより、仮に全く同一の米であったとしても NN へ入力される時点で、全く別物と考えて良いデータに変換されていたということが考えられる。




図 4.5 米切り出し時における背景比率の違い例

以上の問題を解決することを目的として擬似回転補正アルゴリズムを導入する。擬似回転補正アルゴリズムではマスク処理を用いない。図 4.5 に示すような切り出しが行われた後、図 4.6 に示すように左上の画素から順に全画素についてあらかじめ決めておいた閾値との比較を行う。その際、閾値以上であればその画素を 1 次元配列に収める。表 4.1 に生成される 1 次元配列のイメージを示す。こうして作成された 1 次元配列に操作を加えることにより、NN の最大入力層数と同数のデータ数である 80 のデータに加工する。現状では、配列に収められる米一粒あたりの画素値は 1000 前後であったため、多少大きめ米が存在することも考慮し 14 画素を NN へ入力する一つのデータとした。この手法により背景の黒い画素が排除されるため、識別率の向上が期待される。また、明らかに小さな米はデータ量が少ないため、配列に空白部が生じ異常であるとの識別が可能である。ただし、1 次元配列に画素値のみを収めるようにしたことにより、撮影した物体の形状データは失われることとなった。図 4.7 に改良を加えたシミュレーションシステムのフローチャートを示す。

4.3 擬似回転補正アルゴリズムのシミュレーション部への導入

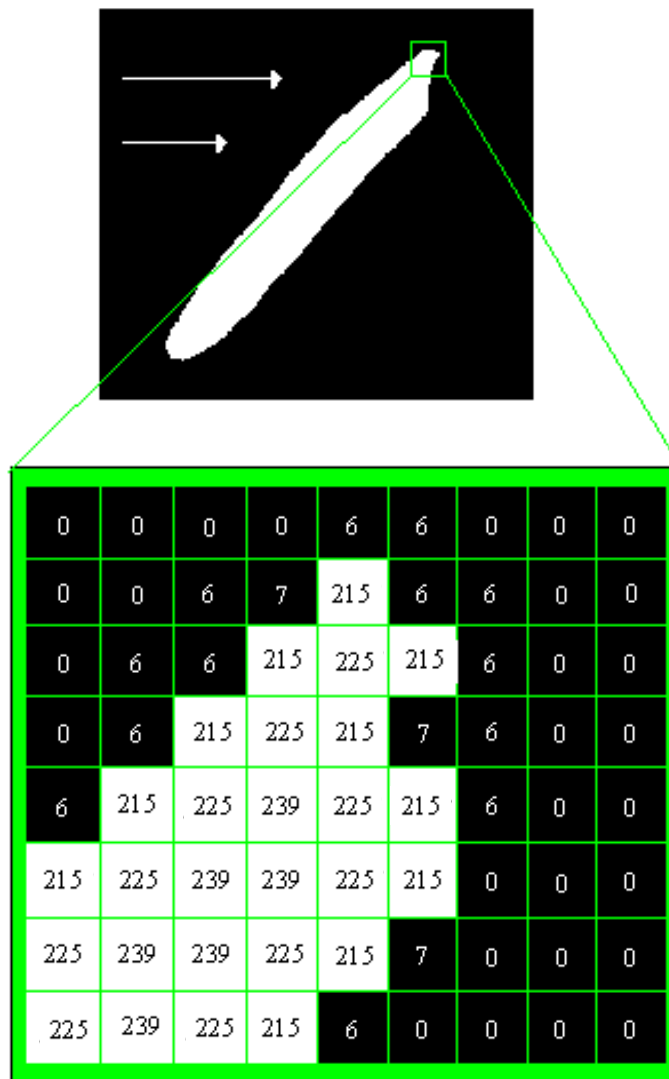


図 4.6 米画像の閾値との比較方向と画素イメージ

表 4.1 閾値を 10 程度に設定した場合の図 4.6 画像より生成される 1 次元配列

215	215	225	215	215	225	215	215	225	239	225	215	215	215	...
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

4.3 擬似回転補正アルゴリズムのシミュレーション部への導入

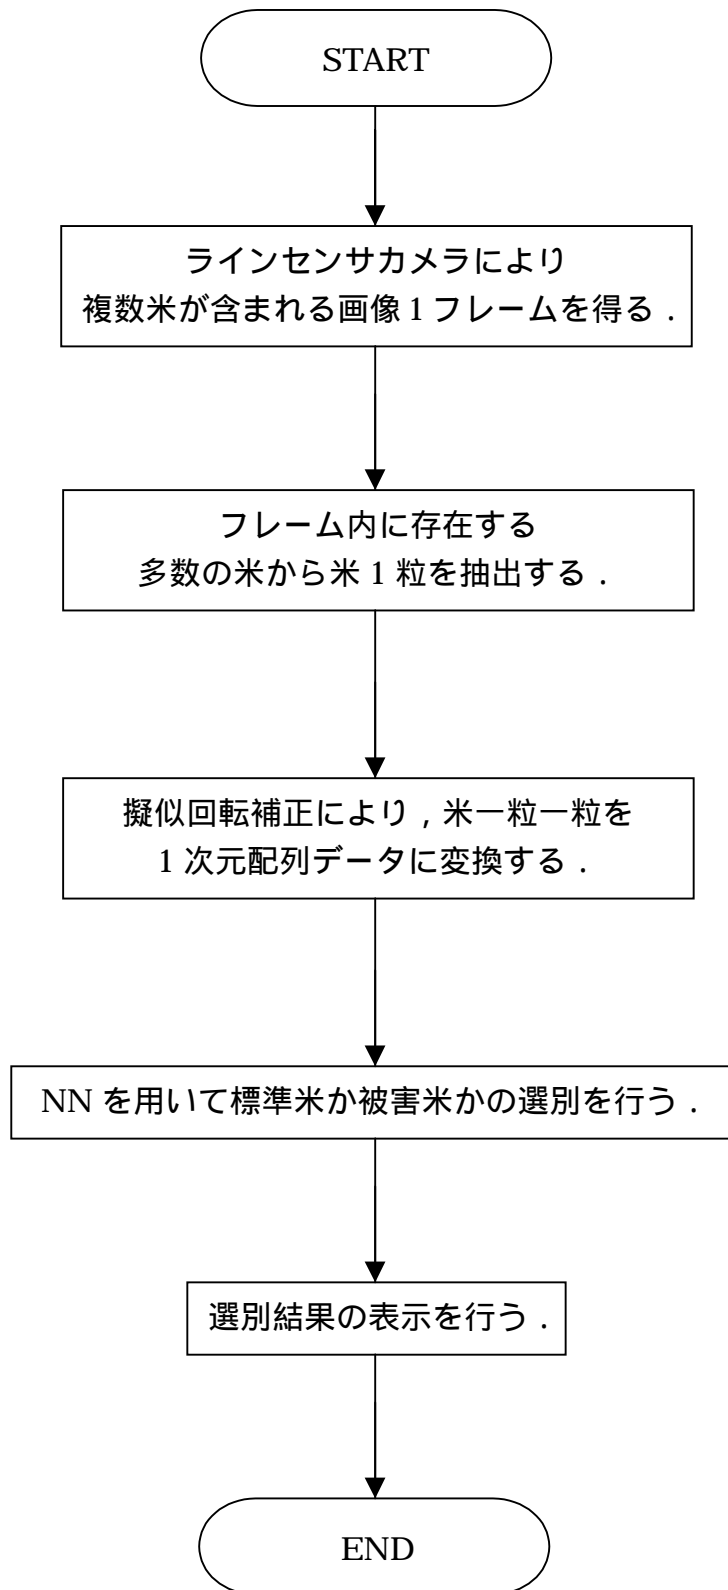


図 4.7 シミュレーションシステムフローチャート

5.1 実験条件

5. シミュレーション実験

本章では，4.で述べた改良を加えたシステムにて，その有効性を示すため，インド米を用いて2通りの実験を実施する．実験1では，これまでの実験との比較を行うため3.2で記述した実験と学習パターンを統一した実験を実施し，実験2では，NNの構成を変更し，出力細胞数を3として透明米，しらた米，被害米の3カテゴリに分類する実験を実施する．学習データは回転補正を考慮したもので，今回は実験に使用していない玄米について図5.1に示すように胚芽の方向の違いによる8方向を最低数として画像の採取を行なっているため，全種類の米について最低8粒からの学習となっている．




図 5.1 胚芽による方向の違い

5.1 実験条件

【実験1】


実験1では透明米を目的パターンとし，しらた米，虫食い米，変色米を目的外パターンとした評価と，しらた米を目的パターンとし，透明米，虫食い米，変色米を目的外パターンとした評価を実施する．学習には，目的パターン，目的外パターンともに16粒を用い，評価には透明米，しらた米，虫食い米，変色米ともに20粒を用いた．透明米を目的パターンとしたときの画像を図5.2(a)，図5.2(b)に，し

5.1 実験条件

らた米を目的パターンとしたときの画像を図 5.3 (c), 図 5.3 (d) に示す .



(a) 目的パターン米画像 (透明米)




(b) 目的外パターン米画像 (しらた米, 被害米)

図 5.2 透明米を目的パターンとした場合の学習用米画像



(a) 目的パターン米画像 (しらた米)

5.1 実験条件



(b) 目的外パターン米画像 (透明米, 被害米)

図 5.3 しらた米を目的パターンとした場合の学習用米画像

【実験 2】

実験 2 は透明米, しらた米, 被害米 (虫食い米と変色米を混合したもの) の 3 カテゴリにて学習を実施する. シミュレーションは以下に示す 3 回を実施する. 図 5.4 に学習に用いた米画像を示す.

シミュレーション 1: 学習データを透明米, しらた米, 被害米それぞれ 8 粒使用し NN の学習を行い, 透明米, しらた米, 虫食い米, 変色米についてそれぞれ評価を行う.


シミュレーション 2: シミュレーション 1 の結果, 誤って識別した米画像及び, 識別率の低い米画像をそれぞれ 5 粒ずつ選び, 学習データに追加し, 学習データを 13 粒とし追加学習を行う.

シミュレーション 3: シミュレーション 1 では正しく識別していたが, シミュレーション 2 で誤って識別した米画像をそれぞれ 5 粒選び, シミュレーション 2 で用いた学習データに追加し, 学習データを 18 粒とし追加学習を行う.


5.1 実験条件



透明米画像



しらた米画像



被害米画像（虫食い米，変色米）

図 5.4 実験 2 に用いた学習用画像

5.2 実験結果

ここでは、前述の実験 1 と実験 2 の結果を示す。実験 1 の結果を表 5.1 に、実験 2 の結果を表 5.2 に示す。なお、表 5.1 中のカテゴリ A には透明米を目的パターンとし、その他の米を目的外パターンとして学習を行い評価した結果を表し、カテゴリ B にはしらた米を目的パターンとし、その他の米を目的外パターンとして学習を行い評価した結果を表す。

表 5.1 実験 1 結果

米の種類	A	B
透明米	40%	90%
しらた米	75%	35%
虫食い米	80%	75%
変色米	75%	90%

表 5.2 実験 2 結果

米の種類	選別率		
	シミュレーション1	シミュレーション2	シミュレーション3
透明米	40%	50%	60%
しらた米	50%	50%	50%
虫食い米	90%	100%	100%
変色米	70%	70%	70%
平均	62.5%	67.5%	70%

5.3 考察

ここでは、今回改良を施したシミュレーションシステムにて実施した実験結果について、3.2 で示した旧システムでの実験結果と比較し考察を行う。実験 1 は旧システムと条件を近づけ評価を行ったものであるが、透明米を目的パターンとした場合、しらた米を目的パターンとした場合、共に目的パターンとした米画像の選別率について向上が見られる。実験 2 については、カテゴリの分類を 2 カテゴリから 3 カテゴリに変更し学習、評価を行ったものである。初期学習時には識別率が低いものの、追加学習を行うことにより識別率の向上が確認された。この実験により疑似回転補正アルゴリズム導入の有効性が示された。

6. まとめ

6. まとめ

本研究では、これまでの研究によって開発された、NNを導入し米画像を識別することにより米の選別を行う米選別プロトタイプシステムに改良を加え、シミュレーション実験を行うことによって識別率の向上を図ってきた。シミュレーション実験では、3カテゴリに分け学習を実施し、さらに追加学習を行うことによって識別率の向上を図ることが可能であると確認された。また、カテゴリを透明米、しらた米、被害米の3カテゴリに分けることは、実機への導入を想定した場合も有効であると考えられる。

今後の課題として、今回のシミュレーション実験では評価に用いる米画像が少なかったため、より多くの米画像の採取を行い継続的な学習を実施する必要がある。また、今回はインド米についてのみの実験しか行っていないが、玄米についての実験を行う必要がある。

7. 謝辞

7. 謝辞

本研究の遂行ならびに本論文の執筆にあたり的確なるご指導とご校閲を承りました高知工科大学情報システム工学科竹田史章教授に深甚なる謝意を表します。また、本研究において、米サンプル及び実験機材等をご提供いただいた(株)セイレイ工業高知工場第2開発部の皆様に厚く御礼申し上げます。本研究の進行する上でご指導いただきました(株)グローリー工業研究開発センター新事業開発部西蔭紀洋様、(株)リライアンス藤田靖専務に心から厚く御礼申し上げます。最後に本論文の執筆の機会を与えてくださった高知工科大学に心から御礼申し上げます。

8. 参考文献

8. 参考文献

- [1] 麻生秀樹, ”ニューラルネットワーク情報処理”, オーム社, pp10-18, pp50-54,1989.
- [2] Widrow.B, Winter.R.G, Baxter.R.A, ”Layered Neural Nets for Pattern Recognition”, IEEE, Transaction Acoustic,Speech & Signal processing, Vol.36, No.7, pp.1109-1118, 1988
- [3] 竹田史章, 大松繁, “マスク方式によるニューロ紙幣選別機の開発”, システム制御学会論文誌, Vol.6, pp.283-289,1993
- [4] Takeda, F., Omatu, S., “ Bank note recognition system using neural network with random masks”, Proceeding of the World Congress oN Neural Networks”, Vol.1, pp.241-244, 1993
- [5] 竹田史章, 大松繁, “ランダムマスクを前処理機構に有する小規模ニューラルネットワークによる貨幣識別技術”, 電気学会論文誌 C , Vol.113, No.10, pp87-92, 1994
- [6] Takeda, F., Omatu, S., “high speed paper currency recognition by neural networks”, IEEE Transaction on Neural Networks, Vol.6, No.1, pp.73-77, 1995
- [7] Takeda, F., Omatu, S., “A neuro-money recognition using optimized Masks by GA”, Advance in Fuzzy Logic , Neural Networks and Genetic Algorithms LNAI 1011, pp190-201, 1995Springer
- [8] Takeda, F., Omatu, S., “A neuro - system technology using bank note recognition“, Proceedings of the Japan/USA Symposium on Flexible Automation , Vol.2, pp.1511-1516, 1996
- [9] Takeda, F., Omatu, S., “A neuro-recognition technology using for paper currency using optimized masks by GA and its hardware”, proceedings of the International Conference

8. 参考文献

- on Information Systems Analysis and Synthesis, pp147-152, 1996
- [10] Takeda, F., Omatu, S., Nishikage, T., "Neural network recognition System tuned by GA and design of its Hardware by DSP", Proceedings of International Symposium on Artificial Intelligence in Real-time Control, pp356-362, 1997
- [11] 竹田史章, 西蔭紀洋, "ニューロ識別における軸対象マスクの提案とGAによる最適化および最適結果の統計的解析", システム制御情報学会論文誌, Vol.12, No.1, pp11-19, 1999
- [12] 竹田史章, 西蔭紀洋, 内田久也, 中原昌樹, "紙幣用ニューロテンプレートマッチング識別手法の開発", 第44回システム制御情報学会論文誌, Vol.13, No.4, pp415-416, 2000
- [13] 竹田史章, 西蔭紀洋, "紙幣用ニューロテンプレートマッチング識別手法の開発", 電気学会論文誌C, Vol.121, pp196-205, 2001
- [14] Ichiryu, Y., Takeda, F., Uchida, H., Nakahara, M., "Development of Neuro-Templates Matching Recognition Method for Banknotes", Proceeding of Student Conference on Research and Development, 2001
- [15] 竹田史章, 大松繁, 井上卓, 尾波宰三, 小西健一, "ニューラルネットワークを用いた高速搬送紙幣の識別", 電気学会論文誌C, Vol.112, pp249-pp258, 1992
- [16] Nagata, S., Sekiguchi, M., Asakawa, K., "Mobile Robot Control by a Structured Hierarchical Neural Network", IEEE Control System Magazine, Ap.69, 1990
- [17] Takeda, F., Nakahara, M., Ichiryu, Y., Uchida, H., "Autonomic Neuro- Recognition Board for Paper Currency", Proceeding of SPAT2000, pp85-90, 2000
- [18] 中屋任喜, 竹田史章, "ニューラルネットワークを用いた米選別機の開発", システム制御情報学会研究発表講演会講演論文集 pp505-506, 2002
- [19] 長友克介, 竹田史章, "ニューラルネットワークを用いた落下米監査システムの開発", 電気学会研究会資料産業計測制御研究会研究発表講演会講演論文集

8. 参考文献

[20] pp53-pp58

[21] 竹田史章, 一柳賀子, 内田久也, 中原昌樹, “米用色彩選別機へのニューロテンプレートマッチング識別手法の適用”, 第45回システム制御情報学会研究発表講演会論文集, pp105-pp106, 2001

[22] Ichiryu, Y., Takeda, F., Uchida, H., Nakahara, M., et.al, “Proposal of a Rice Grading System Using Neuro-Template Matching Method”, Proceeding of the Knowledge-Based Intelligent Information Engineering System & Allied Technologies, Vol2, pp.818-823, 2001

[23] 一柳賀子, 竹田史章, “ニューロテンプレートマッチング識別手法を用いた米用色彩選別機の開発”, 高速信号処理応用技術学会 2001 年秋季研究会論文集, pp81-pp86, 2001

[24] 竹田史章, 一柳賀子, “流下米の監査システムの開発と DSP ボードへの実装の検討”, 計測自動制御学会 SI 部門学術講演会, pp487-pp488, 2001

[25] 末松良一, 山田宏尚, “画像処理工学”, コロナ社, pp120-140, 2000

[26] 舟久保登, “パターン認識”, 共立出版, pp154-157, 1993

[27] 安居院猛, 長尾智晴, “C 言語による画像処理入門”, 昭晃堂, pp47-74, 2000

付録

ニューラルネットワーク

NN は、非線形識別が可能な最小構成の 3 層の階層型ネットワークである。NN の例を図 1 に示す。丸印で表しているのがニューロンである。ニューロンとは、生体内の神経細胞を意味し、ユニットとも呼ばれる。これはネットワークのノードにあたる処理要素で、入力を与えられるとそれに応じた出力を出す。各層はそれぞれ、S (Sensory) 層、A (Association) 層、R (Response) 層と示す。




図 1 NN の例

入力層を除く各層のユニットは、前の層のユニットから重み付き入力を受けて、その総和を計算し、入出力関数 f によって出力値が求められる。すなわち i^k_i, o^k_i をそれぞれ第 k 層の第 i ユニットの入力の総和、出力とし、 $w^{k-1}_{j,i}$ を第 $k-1$ 層の第 j ユニットの第 k 層の第 i ユニットの結合の強さ (ウェイト) とすると、

$$i^k_i = \sum_j w^{k-1}_{j,i} o^{k-1}_j \quad , \quad o^k_i = f(i^k_i) \quad (1)$$


となる。中間層、出力層の各ユニットの入出力関数としては、式 (2) に示すような

ロジスティック関数（シグモイド関数）を使用する．

$$f(x) = \frac{1}{1 + \exp\left(\frac{-x + \theta}{T}\right)} \quad (2)$$

式(2)において， x は各ユニットへの入力値で， $f(x)$ はそのユニットの出力値である． T はネットワークの温度と呼ばれる正の数で， T が大きくなるほどグラフはなだらかになる．本 NN では，誤差に応じて T は 1.3 から 0.7 まで変化させる． θ はユニット単位のしきい値である． $\theta = 0$ の時のシグモイド関数のグラフを図 2 に示す．

図 2 シグモイド関数 ($\theta = 0$)



学習アルゴリズム

本研究で用いる NN の学習方法には誤差逆伝播（Error Back Propagation）アルゴリズム^[1]を使用する．具体的には，いくつかの入力パターンの例（学習データ）を与え，その時の出力パターンと期待する出力パターン（教師値）との誤差が減少するようにウェイトを修正する．

ある入力パターンを与えた時の出力層の第 j ユニットの出力値を O_j ，この時の出力層の第 j ユニットの期待値（教師値）を T_j とすると，第 j ユニットの誤差 E_j は式(3)

付録

のように求める．

$$E_j = \frac{1}{2}(T_j - O_j)^2 \quad (3)$$

したがって，1つの学習パターン P における出力層の誤差 E_p は式 (4) のように求める．

$$E_p = \frac{1}{2} \sum_j (T_j - O_j)^2 \quad (4)$$

全学習パターンの誤差の総和を E とし，総合誤差と呼ぶことにする．この総合誤差に比例して，T (ネットワークの温度) を 1.3 から 0.7 まで変化させる．

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_j (T_j - O_j)^2 \quad (5)$$

式 (5) に示す総合誤差 E が最小になるように各ユニット間のウェイトを修正する．修正の方法としては最急降下法を用いる．具体的には，各学習パターン毎に，各ユニットの誤差 E_j が最小になる方向へウェイトを変更する．

第 t 回目の学習における k-1 層の第 i ユニットから k 層の第 j ユニットへのウェイト W_{ij} の修正量 $\Delta W_{ij}^{k-1,k}(t)$ は式 (6) のようにして求める．

$$\Delta W_{ij}^{k-1,k}(t) = -\varepsilon \delta_j^k O_i^{k-1} + \alpha \Delta W_{ij}^{k-1,k}(t-1) + \beta \Delta W_{ij}^{k-1,k}(t-2) \quad (6)$$

式 (6) において，“ ε ” は学習定数，“ α ” は慣性定数，“ β ” は振動定数である．また， δ_j^k は k 層の第 j ユニットの一般化誤差で，k 層が出力層の場合と中間層の場合によって算出方法が異なる．式 (7a) 及び式 (7b) に一般化誤差の算出方法を示す．

k 層が出力層の場合，

$$\delta_j^k = (T_j - O_j^k) f'(I_j^k) \quad (7a)$$

となる．ここで， I_j^k は k 層第 j ユニットの入力総和である．

K 層が中間層の場合，

$$\delta_j^k = \left(\sum_m W_{jm}^{k,k-1} \delta_m^{k-1} \right) f'(I_j^k) \quad (7b)$$

となる。ただし m は出力層のユニット番号である。

式(6)に示したウェイトの修正式における β 項は、大きな値にするとウェイトの修正量が大きくなり、学習は速くなるが、あまり大きくすると逆に学習が収束しなくなる。総合誤差が上下に振動する時は学習定数を小さくし、誤差の減少速度が小さい時は学習定数を大きくする必要がある。ユーザは学習開始時の学習定数の初期値を設定する。初期値は $(0.1 < \beta < 1.0)$ の範囲で設定する。デフォルト値は 0.5 である。

α 項は、学習の収束を加速させる働きをする。デフォルト値は 0.95 である。 γ 項は極小解から脱出させる働きをする。デフォルト値は -0.1 である。 α と γ には関連性があり、図3に示す範囲内(塗りつぶした部分)で設定する。




図3 α と β の関連性