押し出し造粒プラント制御のための視覚品質推定[†]

田中 恭治*・白上 貞三*・中村 誠**

堺 敏明**・鳥岡 豊士***

The Quality Estimation Applied Computer Vision for The Control of A Granulating Process

Kyoji TANAKA*, Teizho SHIRAGAMI*, Makoto NAKAMURA*,
Toshiaki SAKAI** and Toyoshi TORIOKA***

The products extruded from a granulating machine are easily smashed to powder by their physical characteristic, and their hydrous rate is changeable. So contact style quality analysis and batch analysis are difficult. Moreover, completely understanding quantitative relationship between many production factors and quality is never easy. On the other hand, production operator previously evaluated visually by knowledge based on his experience. So if a control system is considered, it seems to be effective to apply the computer vision methods on the quality estimation procedure. In this research, for the estimation, a texture is extracted from the product's surface, and each region of the product is recognized with extracting the contour using the steerable filter, simultaneously. And the classify to each quality is performed using a neuro-classifier, which learned from the teaching data of the operator's judgement on the quality.

Key Words: quality estimation, control of a granulating process, texture analysis, neuro-classifier

1. はじめに

押し出し造粒は工業用薬品や医薬品、農薬品、飼肥料などを製造する工程においてよく用いられる。押し出し造粒においては原材料は粉体（固体粒子）であり、造粒の基本は押し出し、圧縮などの操作により固体粒子間に接近の機会を与え、凝縮・付着の要因のもとで効果的に造粒物をつくりだすこと¹⁾とされている。この工程においては原料粉体の粒子形状、粒度分布、含有水分などの要因に対する影響を抑えることが重要である。このため、原料に可塑性を与えて造粒を容易にするとともに、造粒物の型くずれを防いで一定の硬度を保つための制御が必要である^{2), 3)}。これを自動で行う場合、従来オペレータが行っている手順をシステム化することになり、粒子の状態を計測、推定することが必要となる。状態の1つとして形状を計測する手法はこれまでに提案されてい

る（たとえば文献4）が、オペレータが行っている視覚的処理を模倣したものは報告されていない。本稿では、造粒系を制御することを目的とし、画像処理により表面のテクスチャを抽出し、オペレータの知識をもとに品質を推定する。

さて、押し出し造粒は原材料と添加剤とを練合し丸形の小穴から押し出すもので、有機ゴムの加硫促進剤（以下、ペレットと称す）を生産する工程においても盛んに用いられている。ペレット製造の全工程は、反応系を除くと、貯蔵、定量供給、添加剤添加、混練、造粒、乾燥、ふるい分け、小分け包装などからなる。造粒直後の製品はヌードル状であり、ヌードル状から自重または他重により裁断されペレット状になる。このペレットの成形には混練から乾燥までが最も影響を与えたとされており、現場のオペレータはペレット状になった段階で目視により品質を評価している。そして、この評価結果をもとに高品質となるように添加剤の量を調節している。この目視による評価は、オペレータが経験に基づき”みかけ”の状態から行っているもので、これに換わる自動的視覚的品質評価と制御のシステムが望まれている。従来、自動化が進んでいない理由としては、製品がもろく接触式の分析が難しいこと、造粒後比較的早く自然乾燥してしまうためバッチ処理式の分析が難しいことなどがある。また、出来具合は添加剤や原材料の種類によって異なり、原材料の粒度分布にも大きく影響される⁵⁾。このため、この製造プラントを定量的なモデルで記述することは難しい。布重⁷⁾が指摘しているように、造粒工程はノウハウの集まりでありオペレータの経験が重要であ

[†] 1995 年度電気・情報関連学会中国支部連合大会で発表 (1995-10)

* 山口県工業技術センター 山口市朝田湯垣 585-1

** 三新化学工業(株) 柳井市古開作 52-1

*** 山口大学工学部 宇部市常盤台 2557

☆ 現在、水産大学校

* Industrial Technology Institute Yamaguchi Prefecture Government, Yamaguchi

** Sanshin Chemical Industry Co. Ltd., Yanai

*** Faculty of Engineering, Yamaguchi University, Ube
(Received April 12, 1996)

(Revised December 5, 1996)

ることから、自動化においてはこの経験を活用することが有効と思われる。

対象とするペレットは品質の良いものほど表面がなめらかで、悪いものほど亀裂やざらつきが多い。そこで、表面のなめらかさを抽出し、抽出結果から品質を推定する。この推定においてはオペレータの判定結果を教師信号とする学習を行う。このような視覚情報を基にする認識としてはコンピュータビジョンの手法が有効である。物体表面の状態の把握はテクスチャ解析として知られ、画像が一般的なテクスチャである場合についてはこれまでもいくつかの手法が提案されている^{8)~10)}。これらで扱われている問題は異なる材質の分類であり、本研究で扱うような1つの品種を品質ごとに分類する問題とは異なっているものの、解析については各対象が持つ周波数成分をもとにしており、表面の状態を把握する有効な手段と考える。本研究でも1画像中にある複数ペレットのそれぞれの領域を識別した上で、各領域の持つ周波数成分を抽出する。品質の推定は、品質各クラスへのクラス分け問題としてとらえ、教師付き学習によるニューラルネットワークを用いる。このクラス分け器へ抽出した周波数成分の輝度分布を入力し、品質を推定する。

以降では、提案するシステムについて述べる。まず、2.ではテクスチャの抽出について述べ、3.では品質の推定について述べる。また、4.ではシミュレーション実験と工場設置後の実験を行ったので報告する。

2. テクスチャの抽出

Figs. 1, 2に対象の例を示す。図からもわかるように、造粒機出口の対象は互いに交差しており、奥にある対象は輝度が低く、また焦点も合っていない。このため、このように直接撮像した画像を用いると複雑な処理となる。また、品質が変化していく過渡状態のように高品質なものと低品質なものとが混在する場合、混在度合いがわかれば造粒の状況が把握できるが、このためにはペレットの領域を識別する必要がある。そこで、まずペレットを機械的に整列させ撮像し、画像処理により対象の領域を識別する。

つぎに、領域を識別したペレットごとに特定の空間周波数帯域を抽出し、輝度の分布を求める。

2.1 ペレットのサンプリング

Fig. 3は開発した撮像用のサンプリング機構で、造粒スクリーンに近接設置される。スクリーンから押し出されているペレットは**Fig. 3**のsampling plateにて捉えられ、vibratorによって振動しているshooterを滑降し、forward feederにより焦点位置まで運搬される。ペレットを採取する時は、air cylinderによりshooterとsampling plateが上下に運動する。また、forward feeder上面は並行な溝加工が施してある。これらの機構によりペレットは焦点位置まで運搬され、**Fig. 4**のように整列される。

2.2 輪郭の抽出と領域の識別

サンプリング機構によりペレットは互いに極端な交差や重

Fig. 1 Original image of high grade products.

Fig. 2 Original image of low grade products.

Fig. 3 Schematic of the sampling mechanism

Fig. 4 Lined up objects using the developed mechanism

なりを起こすことなく撮像されるが、ペレットの含水率が高い場合や表面が粗い場合、運搬時に摩擦による抵抗が大きく滞留がおき、接触することがある。このため、領域を識別するための前処理として接触部分を画像上で切り離しながら輪郭を識別する。本研究ではSteerableフィルタ^{11)~13)}を用いて、抽出したエッジから輪郭を推定する。Steerableフィルタはエッジをその方向により選択的に抽出でき、しかもフィルタカーネルは少数で実現できるため、高速処理を必要とする場合有効である。

Steerableフィルタによれば、向き θ のエッジを強調する

Fig. 5 Steerable filter system block diagram¹²⁾

フィルタは、ガウシアン関数 $G(x, y)$ の N 次導関数 $G_N(x, y)$ を用いて、

$$G_N^\theta = \sum_{j=1}^M k_j(\theta) G_N^{\theta_j} \quad (1)$$

で実現できる。Fig. 5 はこの構成を示したものである。

たとえば 2 次導関数まで用いた場合、

$$G_2^\theta = k_1(\theta) G_2^{0^\circ} + k_2(\theta) G_2^{60^\circ} + k_3(\theta) G_2^{120^\circ} \quad (2)$$

で表される。この場合、 k_j は

$$k_j = \frac{1}{3} (1 + 2 \cos(2(\theta - \theta_j))) \quad (3)$$

で与える係数であり、抽出したい向きに対応して選ぶ。このフィルタは G_N^θ を x と y について可分な構成にすることが可能である。また、 G_N^θ とはヒルベルト変換対であるフィルタ H_N^θ を用いることで、各出力からエッジの持つエネルギーが演算できる。

入力画像 $I(x, y)$ を式 (1) とそのヒルベルト変換対からなる Steerable フィルタに通す。ここで、 θ はフィルタの角度分解能に応じて決定される離散値 $\theta_m (0^\circ \leq \theta_m \leq 360^\circ)$ とする。各フィルタ出力から、エネルギー E^{θ_m} を

$$E^{\theta_m} = \frac{1}{2} ((I * G^{\theta_m})^2 + (I * H^{\theta_m})^2) \quad (4)$$

により計算する。ここで、 $*$ は畳み込み積分を示す。文献¹²⁾においては 2 つのしきい値 (低いしきい値と高いしきい値) を設け、ヒステリシス特性を持ったエッジ抽出が行われている。この手法では、エッジエネルギーが一樣でなく局所的にエネルギーが低い画素もエッジとして抽出できる。このため耐ノイズ特性が良く、本研究においてもこの手法を参考する。しきい値は全ての画素、全ての θ_m における E^{θ_m} から決定するものとする。以下では低いしきい値を th_1 、高いしきい値を th_2 とする。

まず、しきい値 th_1 以上の輝度を持つ画素をエッジ候補点とする。エッジならば局所的にある向きにエネルギーが集中しているため、エッジ候補点から向き θ_e 上の画素のエネルギーは大きい値となる。しかし、Steerable フィルタは高域通過フィルタであり、局所的なノイズに敏感である。また、 θ_m は離散値しかとりえないため、 θ_e は真の向きに誤差を含んだものとなる。そこで、これらの誤差を低減させるため、Fig. 6 のような向き θ_m を中心軸とする近傍領域 W_h においてエネ

Fig. 6 Horizontal window W_h for detecting each tilted edge and estimating the tile. Fig. 7 Vertical window W_v for the edge

ギー集中度 $S(\theta_m)$ を式 (5) により求め、 S が最大となる θ_m をエッジ候補点の推定向き θ_e とする。 W_h は、曲線を小領域内で直線に近似した時の向きを与えるためのマスクであり、ここでは二等辺三角形とする。

$$S(\theta_m) = \int_{W_h} E^{\theta_m} dx dy \quad (5)$$

つぎに、 θ_e に垂直な向き $\theta_\perp$ について、Fig. 7 のような向き $\theta_\perp$ を中心軸とする近傍領域 W_v においてエネルギーが局所最大でかつしきい値 th_1 以上であればエッジ点とする。つぎに、求めたエッジ点から輪郭を抽出する。

向き θ_e における各画素毎の空間位相 ϕ^{θ_e} は

$$\phi^{\theta_e} = \tan^{-1} (I * H^{\theta_e} / I * G^{\theta_e}) \quad (6)$$

により計算できる。 ϕ^{θ_e} がほぼ $\pi/2$ rad. か $3\pi/2$ rad. ならばステップ状のエッジ、ほぼ 0 rad. と π rad. ならばパルス状のエッジである。エッジがステップ状であり、 $S(\theta_e)$ が十分大きければ輪郭である可能性は高いが、対象同士の接触部分は輪郭であってもパルス状となることがある。そこで、パルス状の場合、 E^{θ_e} が th_2 以上でかつ $S(\theta_e)$ が十分大きく、さらに向き $\theta_\perp$ に存在する最も近いエッジとの距離が一定の値 L_D 以上であれば輪郭とする。ここで、 L_D は対象の形状により設定する距離のしきい値であり、対象の幅より少し小さな値とする。なお、以上の条件を満足しないエッジは対象表面の凹凸とみなす。

さて、互いに接触する境界領域ではコントラストが弱くエッジとして抽出されないことがある。このため、輪郭でない画素であっても、その周辺の輪郭からの連続性を調べることで擬似の輪郭として求める。ここでは、向き θ_m の領域 W_h についてその両側に輪郭点があり、向きの平均値が $\theta_m \pm \delta\theta$ であればその画素をエッジとみなし、エッジに垂直な向き $\theta_\perp$ についてその中心にあるエッジを疑似輪郭とする。

つぎに、式 (7) に示す指向性を持つゲイン関数を疑似輪郭を含む輪郭点とその周辺に乘じ、この画像を新たな $I(x, y)$

Fig. 8 Illustration of the brightness distribution

とする。

以上の演算を、抽出される輪郭点の個数が収束するまで適当な回数繰り返す。

$$w(x, y) = \exp(-(x'/\sigma_x)^2 - (y'/\sigma_y)^2) \quad (7)$$

$$x' = x \cos \theta_m + y \sin \theta_m, y' = -x \sin \theta_m + y \cos \theta_m$$

ここでのゲイン関数の分散 σ_x , σ_y は実験的に求める。

求めた輪郭から、輪郭点とその周辺領域の画素を消去することで対象領域を分離し、Rosenfeldらの画素の連結性によるラベル付けを行う。ここでは輪郭は全て対象の境界と見なし、式(8)により得られる画像 $I'(x, y)$ から適当なしきい値により求めた2値画像において、ある画素とその8近傍が値1のとき同一のラベルを付ける。また、ラベル付けの順番は画像の左上から下に向かって探索し右下まで行う。

$$I'(x, y) = \begin{cases} 0 & \text{when } I(x, y) \text{ is a contour} \\ I(x, y) & \text{otherwise} \end{cases} \quad (8)$$

2.3 テクスチャの抽出

オペレータが視覚的に把握しうる情報としてはペレット表面のテクスチャ、形状、造粒時の垂れ具合、色などが考えられる。このうちペレット表面のなめらかさと品質とは、前実験に基づく相関分析の結果から、特に高い相関を持つ^{5), 6)}。そこで、テクスチャとしてはなめらかさを抽出することとし、ペレット表面の持つ空間周波数成分のうち特定の周波数帯域を抽出する。Fig. 8に示すように、表面がなめらかならば画像の持つ周波数成分は低域に集中しているため、特定の周波数帯域を抽出した画像においては輝度分布の分散は小さくなり、粗い表面ならば含まれる周波数は広域に渡るため輝度分布の分散は大きくなることが予想される。

ここでは、高速に処理するため水平方向と垂直方向とを可分に構成したフィルタを用いる。

$$h(x, y) = h(x) * h(y) \quad (9)$$

$$h(x) = h(y) = \int_{-\infty}^{\infty} F(\omega) \exp(j\omega x) d\omega \quad (10)$$

$F(\omega)$ は $h(x)$ のフーリエ変換であり直流を含まない帯域通過特性を持つように設定する。この通過帯域は、表面のなめらかさの違いによって、フィルタ通過後の輝度分布が最も大きく異なるように選ぶ必要があり、ここでは次のようにして得る。

まず、オペレータの評価により最も高品質とされるペレットの画像をフィルタに通し、全ての対象領域から求まる輝度分布を α_{hi} とする。また、最も低品質とされるものからの輝度分布を α_{lo} とする。ここでは F は中心周波数 ω_c 、帯域巾 $\delta\omega$ の理想特性とする。これらの輝度分布について相互相関 $\text{corr}[\alpha_{hi}, \alpha_{lo}]$ が最小となるように、 ω_c と $\delta\omega$ を数値解として得る。つぎに、求めた F から $h(x)$, $h(y)$ を逆フーリエ変換により求める。なお、実際の $h(x)$, $h(y)$ は有限長であり、そのフーリエ変換は F とは異なるものであるがテクスチャを抽出する上でのフィルタとしては問題はない。

つぎに、フィルタを通過した画像において各ラベル領域 l ごとに輝度分布 i_l を求める。この場合、輝度分布は帯域通過フィルタを通過しているため直流分は無く、正負に分布する。

3. 品質の推定

求めた輝度分布を入力として品質の推定を行う。ここではオペレータが従来からの経験により持つ判定基準を有効に活用するため、この推定を教師付きの品質ランクへのクラス分け問題として捉える。クラス分け器としては、事前のモデル化を必要とせず、学習が現場においても容易に行え、また、パターンの各クラスの分類境界が非線形であっても教師信号さえ与えれば比較的容易に構築できるため、多層ニューラルネットワーク（以下、NNと称す）を用いる。ここでの品質の推定は、1枚の画像から識別されたラベル数を L とし、ラベル毎の輝度分布 i_l から次式により求まる平均輝度分布 i

$$i = \sum_L i_l / L \quad (11)$$

についてクラスを求める問題である。

輝度分布 i を入力パターンとし、出力を品質の各クラスの確からしさ $c(i)$ とする。また、輝度分布 i のもととなる原画像 f をオペレータに提示したときの品質の判定結果を $ct(f)$ とする。ただし、 $ct(f)$ はオペレータが判定したクラスを1.0、それ以外のクラスは0.0とする。この時学習は、 $ct(f)$ を教師パターンとし、 $c(i)$ と $ct(f)$ との距離 d が最小となるように行う。

$$d(w) = \sum_F \sum_C \|c(i) - ct(f)\|^2 \quad (12)$$

ここで、 w はクラス分け器の変数であり、ニューロ各層間の重みベクトルである。 C は全クラス集合、 F は画像集合を表す。

Fig. 9に示すような階層内結合を持たない n 層からなるNNにおいては、第 k 層($k = 2, 3, \dots, n$)の i 番目のニューロンユニット u_i^k の入力 x_i^k と出力 y_i^k との関係は式(13)、(14)により表される。

$$y_i^k = z(x_i^k) \quad (13)$$

$$x_i^k = \sum_j \omega^{k-1,k}_{j,i} y_j^{k-1} + \theta_i^k \quad (14)$$

ここで、 $\omega^{k-1,k}_{j,i}$ は第 $k-1$ 層の j 番目のユニットと第 k 層

Fig. 9 Constructure of the multilayer neuralnetwork

の i 番目のユニット間の結合重み, θ_i^k は第 k 層の i 番目のユニットのバイアス値である. また, z は入出力関数である.

学習においては, 式 (15) に示すような慣性項付きの重み更新を誤差逆伝搬法で行う.

$$\omega_{j,i}(t+1) = \omega_{j,i}(t) + \Delta\omega_{j,i}(t) + \alpha(\omega_{j,i}(t) - \omega_{j,i}(t-1)) \quad (15)$$

学習に用いる画像 f としてはオペレータが各クラスとして典型的であると判断したものを選択し, 画像 f についての輝度分布 i を入力とする.

4. 実験

4.1 テクスチャの抽出

撮像はカメラ (東芝 (株) 製 IK-M41MF) に像倍率が 0.67 の接写レンズ (東芝 (株) 製 JK-L25M2) を取り付けて行った. 入力画像は 512×400 の大きさで 256 階調とした. Steerable フィルタは $N=2$ とし, θ_m は Fig. 6 と同じものを用いた. th_1 は $(E^{\theta_m})^{1/2}$ の平均値の $1/2$, th_2 は $(E^{\theta_m})^{1/2}$ の平均値とした. また, 領域 W_h と W_v の形状は頂角が $\pi/4$, 高さが 4pixel の二等辺三角形の対とした.

まず, Fig. 4 に示した画像を例として輪郭とその周辺領域を抽出した結果を Fig. 10 に示す. この図から明らかなように, Fig. 4 の原画像では各対象は接触しているが, 抽出処理により各対象は分離されている. 図中下部の対象が分離できていないのは, 接触部分においてコントラストが低すぎるためである.

つぎに, Fig. 11 にテクスチャを抽出した結果を示す. 同図では, 帯域通過フィルタにより直流が除去された画像は負値を持つため, オフセット値として 128 を加え輝度値 0 を中間調で示している.

各対象領域における輝度分布 i_l を各対象領域の面積で正規化したものを Fig. 12 に示す. ただし, 小さい対象は品質推定の対象外とし Fig. 12 からは除いてある. ラベルは Fig. 12 の左上から右に行くほど大きく右下が最も大きい. ここで比較のため Fig. 4 より表面が粗いものからの輝度分布の例を Fig. 13 に示す. これらから明らかなように, Fig. 12 の各輝度分布は Fig. 13 に比べ急峻である.

Fig. 10 After recognizing the contour

Fig. 11 Extracted texture

Fig. 12 Brightness distribution of each object in Fig. 4

Fig. 13 Sample of the low grade brightness distribution

Table 1 Result of quality estimation from Fig. 12

Class	1	2	3	4	5
Avg. of NN output	0.05	0.16	0.43	0.28	0.13

Table 2 Result of total evaluation

Criterion	Coincidence
criterion A	63%
criterion B	96%

4.2 品質の推定

NN により輝度分布から品質を推定する実験を行った. 輝度分布を入力とするため入力ユニット数は 256 である. 出力ユニット数は, オペレータが画像から品質を分類する上で 5

Fig. 14 Diagram of the developed auto-estimation system

クラスへの分類が限界とされることから、出力各ユニットを各クラスに対応させユニット数5とした。また、学習において式(12)の値を提示パターン数で正規化した値が 10^{-3} に収束するように調整した結果、4層構造で第1中間層のユニット数は15、第2中間層のユニット数は10とした。なお、3層構造では4層と同程度のユニット数で 10^{-3} 程度にまで収束させることは困難であった。

Fig. 4の原画像をもとに各ラベルごとにニューロが出力した確からしさを各クラスごとに平均した結果をTable 1に例として示す、この場合、クラス3が最も高く判定されている。

Fig. 12から明らかのように、ラベル毎の輝度分布 i_l の包絡線はなめらかとは言いがたい。これは各ラベル領域の画素数が少ないことが原因である。一方、学習時の平均輝度分布 i はなめらかな包絡線を持ち、この形状の違いからTable 1のように各クラスの確からしさは分散して現れている。

つぎに、品質推定の性能を確認するため、500個の未学習データを用いて実験を行った。Table 2はオペレータが判定した結果との一致度を示したものである。表中、criterion Aとは、オペレータが分類したクラスに対して、NNが推定した最も高い出力を示すクラスが一致していることを規範とするものである。criterion Aでは、未学習データに対しては一致度が低い。1枚の画像をオペレータに複数回提示した時、オペレータは全ての提示において同じ分類結果を示さず、異なるクラスに分類することもある。このことから、一致度が低くなる要因としては、オペレータの判定基準が変化し判定結果にばらつきを生じ、教師データが曖昧になっているためと考える。すなわち、この規範では、本手法によって品質が正しく推定されている場合でも一致度が低くなる。そこで、教師データの曖昧性を考慮して評価するための規範として

criterion Bを導入する。criterion Bは、オペレータが分類したクラスに対して、NNが推定した最も高い値を示すクラスが隣接クラスの場合も正解とみなすものである。

5. 開発した装置の概要

Fig. 14に研究の対象とした押し出し造粒プラントの造粒機と開発した装置の構成を示す。図中、サンプリング機構は押し出されているペレットを採取できるように造粒機に接近して設置される。サンプリング機構で撮像された画像はコンピュータに画像信号として伝送され、3.までに述べた手法により処理される。品質の推定結果はコンピュータ画面に表示され、同時にプラント制御部へも伝送される。なお、制御盤はコンピュータから指令されるサンプリング機構各部の稼働/停止を同機構へ送る電気的インターフェイスを司る。

この構成においてコンピュータにPC9821-Xa Pentium100MHz（株）NEC製）を用いた場合の画像処理から品質の推定までの処理時間は、一画像中で対象が占める領域の面積によってラベリングに掛かる時間は変動するが、2分以内である。また、採取開始から品質の推定までの周期は約5分である。

6. おわりに

押し出し造粒プラントを自動で制御するため、従来、工場のオペレータが視覚的情報をもとに行ってきた造粒製品の品質評価に代替しうる自動化手法を提案した。本手法では、まず、押し出されるペレットを機械的に採取、整列させて撮像し、Steerableフィルタを適用した輪郭の抽出を行い、コントラストの低い輪郭を強調しながら各ペレットの領域を識別した。つぎに、特定の空間周波数を抽出し識別した各領域ご

とに輝度分布を求めた。この輝度分布を入力とし品質についてのクラス分けを行った。ここでの学習はオペレータの判定した品質クラスをもとに教師付き学習を行った。

実験では実画像を用いてクラス分けの性能を検証した。この結果によれば、オペレータの判定結果との一致度は高く充分実用化が図れることを検証した。

今後は、テクスチャ抽出をより高速に行う手法の検討、曖昧な教師信号のもとでの誤認識率の低減などが課題である。後者はクラス中心から離れた入力に対する、いわゆる汎化問題^{14),15)}とも関連が深い。また、オンラインで学習を行う上では高速学習の手法¹⁶⁾も興味深い課題である。

最後に、装置化にあたり多大なご協力をいただいた新立電機(株)岡田豊氏と(株)常盤商会の谷口規久夫氏に厚く御礼申し上げます。また、コンピュータビジョンについて日頃から御指導を頂く大阪大学工学部白井良明教授に深謝します。

参 考 文 献

- 1) 関口 勲: 造粒基礎技術の研究動向, 化学工業, 41, 2, 73/78 (1977)
- 2) 藤本哲磨: 押出造粒装置, 化学装置, 10, 26, 48/53 (1984)
- 3) 西井, 伊藤: 造粒技術, 化学装置, 3, 36, 60/67 (1994)
- 4) 清水, 亀丸, 山本, 土屋: 粒子群の形状, 寸法別2次元空間分布の測定法, 計測自動制御学会論文集, 28-4, 419/425 (1992)
- 5) 堺, 小泉, 田中, 中村, 鳥岡, 酒井: 押し出し造粒プロセスのインテリジェント化の検討, 第12回製剤と粒子設計シンポジウム講演要旨集, 123/127 (1995)
- 6) 中村, 堺, 田中, 白上, 小泉, 酒井: ペレット造粒プラントのためのファジィ制御システムについて, 第11回ファジィシステムシンポジウム講演論文集, 日本ファジィ学会, 87/90 (1995)
- 7) 布重 徹: アグロ製剤の製造に関する現状と問題点, 化学装置, 35, 7, 140/145 (1993)
- 8) A. Laine and J. Fan: Texture Classification by Wavelet Packet Signatures, IEEE Trans., PAMI-15, 1186/1191 (1993)
- 9) H. Greenspan, R. Goodman, R. Chellappa and C. H. Anderson: Learning Texture Discrimination Rules in a Multiresolution System, IEEE Trans., PAMI-16, 894/901 (1994)
- 10) J. L. Chen and A. Kundu: Rotation and Gray Scale Transform Invariant Texture Identification Using Wavelet Decomposition and Hidden Markov Model, IEEE Trans., PAMI-16, 208/214 (1994)
- 11) W. T. Freeman and E. H. Adelson: Steerable filters for Early Vision, Image Analysis, and Wavelet Decomposition, IEEE Computer Society, 3rd ICCV, 406/415 (1990)
- 12) W. T. Freeman and E. H. Adelson: The Design and Use of Steerable Filters, IEEE Trans., PAMI-13, 891/906 (1991)
- 13) W. Beil: Steerable filters and invariance theory, Pattern Recognition Letters, 15, 453/460 (1994)
- 14) 小川英光: パターン認識・理解の諸問題, 信学誌, 76-6, 615/631 (1994)
- 15) 浜本義彦: パターン認識理論の最近の動向, 信学誌, 77-8, 853/864 (1994)
- 16) 渡辺, 清水: パターン分類問題に対する階層型ニューラルネットワークの学習時間低減化アルゴリズム, 計測自動制御学会論文集, 31-3, 374/381 (1995)

[著 者 紹 介]

田 中 恭 治 (正会員)

1982年, 山口大学工学部電子工学科卒, (株)日本製鋼所, 日本アビオニクス(株)を経て, 88年山口県技術吏員, 山口県工業技術センター勤務, 現在に至る(専門研究員)。画像信号処理を中心とするシステム化研究に従事, コンピュータビジョンに興味を持つ。電子情報通信学会, 日本ロボット学会, IEEEなどの会員。

白 上 貞 三

1969年, 福岡大学工学部機械工学科卒, 同年山口県技術吏員, 山口県工業技術センター勤務, 現在に至る(電子応用室長)。計測・制御システムの研究に従事。日本機械学会, 精密工学会, 人工知能学会などの会員。

中 村 誠 (正会員)

1979年, 山口大学工学部電子工学科卒, 同年小野田セメント(株)勤務, 83年山口県技術吏員, 山口県工業技術センター勤務, 96年山口大学大学院博士課程修了, 現在に至る(専門研究員)。知的制御システムの研究に従事。電子情報通信学会, 日本ファジィ学会などの会員(工学博士)。

堺 敏 明

1979年, 千葉工業大学工業化学科卒, 同年三新化学工業(株)勤務, 現在に至る。同社研究所にて高分子添加剤の研究に従事(研究所高分子課主任)。日本ゴム協会, 粉体工学会などの会員。

鳥 岡 豊 士

1967年, 山口大学工学部電気工学科卒。69年同大学院修士課程了。同年同大・工業短期大学助手。講師, 助教授, 教授を経て, 90年同大工学部知能情報システム工学科教授, 現在に至る。自己組織系, 連想記憶, ファジィに関する研究に従事。電子情報通信学会などの会員(工学博士)。