

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA DE CAMPINAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Este exemplar corresponde a redação
final da tese defendida por Bernardo
Oscar Andres Barraza Sotomayor e
aprovada pela comissão julgadora em
21/12/84.



RECONHECIMENTO DE PADRÕES
PARA APLICAÇÕES EM CAD/CAM

Bernardo Oscar Andres Barraza Sotomayor

Orientador : Prof. Dr. Clésio Luis Tozzi

Tese apresentada à Faculdade de
Engenharia da Universidade
Estadual de Campinas - UNICAMP -
como parte dos requisitos
exigidos para a obtenção do título
de MESTRE EM ENGENHARIA ELÉTRICA.

UNICAMP
BIBLIOTECA CENTRAL

À minha esposa e meus
filhos.

A mis padres, por el
cariño e formación que
siempre me dieron.

AGRADECIMENTOS

Agradeço:

- Ao Clésio, pela amizade, pela ajuda e dedicada orientação neste período.
- Aos professores da FEC, em especial Jino, Léo, Márcio e José Raimundo.
- Aos meus amigos que me acompanharam durante o curso, em especial Jorge e Aron pelas sugestões no meu trabalho.
- Ao pessoal da CPG-FEC e aos meus amigos da CCPG, em especial Cida.
- À Universidad de Tarapacá-Chile e UNICAMP, pelo apoio e oportunidade para a realização do curso de Mestrado.
- À Cecilia, Alejandro, Marianne e Renato que souberam ter tanta paciência.
- Aqueles amigos e pessoas que me deram afetuosa acolhida em Campinas, e com os quais mantive uma convivência agradável.

A todos voces minha eterna gratidão.

ÍNDICE

CAPITULO I	- INTRODUÇÃO	1.1.
CAPITULO II	- SEGMENTAÇÃO	2.1.
2.1.	Segmentação por detecção de borda.	2.2.
2.1.1.	Detecção de bordas usando o método do gradiente.	2.3.
2.1.2.	Detecção de bordas usando o método do Laplaciano ou segundas diferenças.	2.5.
2.1.3.	Detecção de bordas através de máscaras de convolução.	2.6.
2.2.	Segmentação por limiar ou 'thresholding'.	2.10.
2.3.	Enfraquecimento. ('Thinning')	2.12.
2.4.	Armazenamento.	2.16.
2.4.1.	Armazenamento por traço	2.16.
2.4.2.	Armazenamento pela regra da cadeia. ('Boundary Chain Code')	2.19.
CAPITULO III	- EXTRAÇÃO DE ATRIBUTOS.	3.1.
3.1.	Representação gráfica dos atributos de um objeto.	3.3.
3.2.	Métodos para a medida de atributos.	3.7.
3.2.1.	Área.	3.7.
3.2.1.1.	Área.	3.7.
3.2.1.2.	Determinação da área pela BCC.	3.8.
3.2.1.3.	Determinação da área pelo método Pick.	3.8.
3.2.2.	Perímetro	3.9.
3.2.2.1.	Determinação do perímetro a partir da BCC.	3.9.
3.2.2.2.	Determinação do perímetro a partir dos elementos da envoltória da figura.	3.10.
3.2.2.3.	Cálculo do perímetro numa representação BCC de 4 elementos.	3.11.
3.2.3.	Circularidade.	3.13.

3.2.4. Funções geradoras de momentos.	3.13.
3.2.5. Energia da fronteira.	3.16.
3.2.6. Fator G.	3.17.
3.2.7. Número de Euler modificado.	3.18.
3.2.8. Determinação da orientação da figura.	3.19.
 CAPITULO IV - CLASSIFICAÇÃO.	 4.1.
4.1. Princípios básicos de classificação.	4.1.
4.2. Método matemático ou técnica de decisão teórica.	4.5.
4.2.1. Classificador por distância mínima.	4.6.
4.2.2. Classificador por função de discriminação linear.	4.9.
4.2.3. Classificadores estatísticos.	4.12.
4.3. Considerações sobre as amostras para treinamento e desempenho do classificador.	4.14.
4.3.1. Considerações sobre as amostras de treinamento.	4.14.
4.3.2. Considerações sobre desempenho do classificador.	4.15.
 CAPITULO V - FUNCIONAMENTO DO SISTEMA DE RECONHECIMENTO E UMA APLICAÇÃO.	 5.1.
5.1. Funcionamento do sistema.	5.1.
5.2. Uma aplicação em engenharia	5.2.
5.2.1. Introdução.	5.2.
5.2.2. Um sistema de entrada de dados para um simulador digital.	5.4.
5.2.2.1. Aquisição e a separação da cena.	5.4.
5.2.2.2. Segmentação e extração de atributos da cena que contém os componentes.	5.4.
5.2.2.3. Extração de atributos para a geração das regras de decisão.	5.5.
5.2.2.4. Classificação de um elemento.	5.15
5.2.2.5. Determinação das ligações.	5.17.
 CAPITULO VI - CONCLUSÕES.	 6.1.

R E S U M O

Este trabalho apresenta uma metodologia para o reconhecimento de figuras aplicáveis em visão de computadores. São discutidas as diferentes etapas do processo de reconhecimento, bem suas implicações. Como exemplo de aplicação é feito o reconhecimento de portas lógicas e as ligações entre elas, mostrando a utilização das técnicas de reconhecimento em aplicações de CAD. É discutida a viabilidade da utilização das técnicas desenvolvidas em outras áreas da engenharia, tais com CAD/CAM e Robótica.

I INTRODUÇÃO

Nos últimos anos tem ocorrido o crescente desenvolvimento de técnicas cuja finalidade é a maior eficiência na entrada de dados em sistemas computacionais.

A entrada de dados é feita usualmente através de sistemas tradicionais como o teclado. Com o aumento da quantidade de dados a serem processados torna-se necessária uma automação do processo de entrada de dados. Esta necessidade levou ao desenvolvimento de técnicas de visão de computadores que permitem maior rapidez na obtenção dos dados e também uma maior segurança quanto à correção dos mesmos.

A visão de computadores que, por sua vez, tem como base a área de reconhecimento de padrões, é utilizada em aplicações como CAD, Robótica e Automação Industrial, que demandam uma grande capacidade de aquisição de dados.

A classificação de um padrão é realizada através das seguintes fases./1/

- Pré-processamento
- Segmentação
- Extração de atributos
- Classificação

Descrevem-se neste trabalho as diferentes fases do reconhecimento e mostra-se uma aplicação na área de CAD.

No Capítulo II, descreve-se a fase de segmentação, que consiste na separação dos diferentes objetos que compõem a cena; abordam-se as técnicas de segmentação por limiar e segmentação por detecção de bordas. Descrevem-se também métodos para o armazenamento das figuras a serem reconhecidas e os respectivos algoritmos.

No Capítulo III, descreve-se a fase de extração de atributos, ou seja, a obtenção das propriedades mais relevantes da figura, as que serão usadas para a classificação. Descrevem-se alguns atributos convencionais e os métodos para a sua medida. É apresentado um novo método para a medida do perímetro de um objeto.

No Capítulo IV, descrevem-se os métodos de classificação, que consistem em associação das figuras com as

classes existentes na aplicação. São descritos métodos matemáticos também conhecidos como técnicas de decisão teórica e métodos estatísticos. Faz-se uma descrição de cada um deles e de sua forma de aplicação.

No Capítulo V, descreve-se o uso das técnicas discutidas anteriormente em uma aplicação para CAD. A aplicação descrita consiste na entrada automática de dados em um sistema de simulação de circuitos digitais; são apresentados os resultados de cada uma das etapas da classificação dos componentes e determinam-se as ligações existentes entre eles.

II SEGMENTAÇÃO DE IMAGEM

Após a etapa de pré-processamento a cena física é representada de um modo apropriado ao seu tratamento pelo computador. Isto é, a cena é descrita numa matriz composta de $N \times M$ elementos, onde cada elemento representa o nível de cinza relativo ao pixel. O valor correspondente ao nível de cinza é obtido na fase de quantização.

Na matriz citada, é possível identificar-se conjuntos de pontos com níveis de cinza similares, e a estes conjuntos de pontos associam-se os diversos objetos contidos na cena.

O reconhecimento de um padrão é realizado pela classificação do objeto em classes definidas da aplicação; esta classificação é feita através da extração de atributos de cada objeto, sendo necessária a separação dos objetos num processo denominado segmentação da imagem.

Define-se segmentação como " a divisão de uma imagem em objetos isolados, onde o objeto é um conjunto de pixels que possuem níveis de cinza similares e com o conjunto possuindo algum significado para o usuário ".

A figura 2.1 mostra a segmentação de uma imagem e a definição de sub-conjuntos de pixels similares correspondentes aos objetos. A segmentação de uma imagem consiste portanto, na determinação para cada objeto de uma fronteira, uma região ligada a esta fronteira e um rótulo que identifica este objeto.




Fig. 2.1. Segmentação de uma imagem

Para facilitar a descrição que se segue, os seguintes conceitos são definidos:

Cena : Uma imagem formada por mais de um objeto.
Objeto : Uma entidade física que possui características como comprimento, largura, área, etc.
Entidade : Algo que existe e é distinguível.
Modelagem : Escolha do conjunto de entidades associadas à aplicação.
Atributos : Definem as propriedades de uma entidade. A cada atributo é associado um valor.
Chaves : Atributo ou conjuntos de atributos, cujos valores identificam unicamente cada entidade num conjunto de entidades.

O processo de segmentação de uma imagem está baseado nos princípios básicos de descontinuidade e similaridade do nível de cinza, sendo as seguintes as técnicas utilizadas :

Descontinuidade : 1.- Segmentação por detecção de borda.
Similaridade : 2.- Segmentação por limiar.
(' thresholding ')

e que são descritas a seguir./1,2,3/

2.1. Segmentação por detecção de borda.

A segmentação por detecção de borda baseia-se no fato de que uma borda é definida por uma mudança abrupta no nível de cinza, ou seja, existem níveis de cinza relativamente consistentes em cada uma das duas regiões e uma mudança sensível do nível de cinza no limite das duas regiões.

A figura 2.2 ilustra as variações do nível de cinza nas bordas de um objeto. Para uma reta horizontal traçada sobre o objeto o gráfico resultante do nível de cinza em função do deslocamento sobre esta reta seria, no caso ideal, um degrau figura 2.2.b. Para o caso real, obtém-se o gráfico mostrado na figura 2.2.c.




Fig. 2.2. Cena contendo objeto A e os gráficos para nível de cinza.

A detecção de borda baseia-se no fato acima mostrado e é realizada com o uso de operadores de diferença, que consideram os níveis de cinza do ponto (x,y), e seus vizinhos. Pode-se classificar estes operadores em operadores de Gradiente, Laplacianos e máscaras de convolução em geral. /2/

2.1.1. Detecção de bordas usando o método do gradiente.

Este processo utiliza o operador derivativo de duas dimensões.

Seja $f(x,y)$ o nível de cinza no ponto (x,y). As derivadas parciais $\partial f/\partial x$ e $\partial f/\partial y$, medem a razão de mudança nos níveis de cinza, onde $\partial f/\partial x$ é sensível às mudanças horizontais e $\partial f/\partial y$ sensível às mudanças verticais.

O módulo do gradiente, cuja fórmula é :

$$G = ((\partial f/\partial x)^2 + (\partial f/\partial y)^2)^{1/2} \quad (2.1)$$

define um operador de gradiente que é sensível às mudanças descritas acima.

Para imagens digitais, ao invés da derivada primeira utiliza-se a primeira diferença, obtendo-se um gradiente digital. (equações 2.2)

$$\begin{aligned} \Delta_x f(x,y) &= f(x,y) - f(x+1,y) \\ \Delta_y f(x,y) &= f(x,y) - f(x,y+1) \end{aligned} \quad (2.2)$$

$$G_{xy} = | \Delta_x f(x,y) + \Delta_y f(x,y) |$$

As equações anteriores podem ser representadas na forma de máscaras, as quais são mostradas na figura 2.3.; cada operador é uma máscara de 1x2 e 2x1 respectivamente, aplicada no ponto (x,y).




Fig. 2.3. Máscaras equivalentes ao gradiente. (equação 2.2)

As equações 2.2 acima descritas, são equivalentes às seguintes equações que são obtidas a partir dos pontos $x-1$, $y-1$ e do ponto central (x,y) .

$$\begin{aligned} \Delta_x f(x,y) &= |f(x,y) - f(x-1,y)| \\ \Delta_y f(x,y) &= |f(x,y) - f(x,y-1)| \end{aligned} \quad (2.3)$$

$$G_{xy} = \Delta_x f(x,y) + \Delta_y f(x,y)$$

A figura 2.4 mostra as máscaras referentes aos operadores descritos e sua aplicação no ponto (x,y) da imagem.




Fig. 2.4. Representação do operador de gradiente.

Outro operador de gradiente é o operador de diferenças centrais, onde o valor do gradiente não depende do valor do ponto central (x,y) , mas sim de seus vizinhos nas direções 'x' e 'y'.

$$\begin{aligned} \Delta_{2x} f(x,y) &= |f(x+1,y) - f(x-1,y)| \\ \Delta_{2y} f(x,y) &= |f(x,y+1) - f(x,y-1)| \end{aligned} \quad (2.4)$$

$$G_{2x \ 2y} = \Delta_{2x} + \Delta_{2y}$$




Fig. 2.5. Representação na forma de máscaras dos operadores de diferenças centrais.

Um outro operador que mede as mudanças nas diagonais a 45° e 135° é conhecido como operador de Robert. As equações que descrevem esta função são:

$$\Delta_+ f(x,y) = |f(x+1,y+1) - f(x,y)|$$

$$\Delta_- f(x,y) = |f(x,y+1) - f(x+1,y)| \quad (2.5)$$

$$G_{+-} = \Delta_+ + \Delta_-$$




Fig. 2.6. Representação na forma de máscaras do operador de Robert.

2.1.2. Detecção de bordas usando o método do Laplaciano ou segundas diferenças.

Uma alternativa ao método do gradiente é o uso do Laplaciano, para detecção de bordas. Este método tem como característica principal uma maior sensibilidade na detecção de linhas, cantos e pontos isolados.

O Laplaciano é definido por:

$$\nabla^2 f = d^2 f / dx^2 + d^2 f / dy^2$$

Para imagens digitais, utiliza-se a forma baseada em diferenças :

$$\nabla^2 f(x,y) = \Delta_x^2 f(x,y) + \Delta_y^2 f(x,y)$$

$$\Delta_x f(x,y) = f(x+1,y) - f(x,y)$$

$$\Delta_x^2 f(x,y) = (f(x+1,y) - f(x,y)) - (f(x,y) - f(x-1,y))$$

$$\Delta_x^2 f(x,y) = f(x+1,y) + f(x-1,y) - 2f(x,y) \quad (2.6)$$

$$\Delta_y f(x,y) = f(x,y+1) - f(x,y)$$

$$\Delta_y^2 f(x,y) = (f(x,y+1) - f(x,y)) - (f(x,y) - f(x,y-1))$$

$$\Delta_y^2 f(x,y) = f(x,y+1) + f(x,y-1) - 2f(x,y) \quad (2.7)$$

$$\nabla^2 f(x,y) = |f(x+1,y) + f(x-1,y) + f(x,y+1) + f(x,y-1) - 4*f(x,y)| \quad (2.8)$$

A figura 2.7 mostra a representação do Laplaciano e sua aplicação no ponto (x,y).



Fig. 2.7. Operador Laplaciano e sua aplicação no ponto (x,y).

A equação 2.8 mostra que o Laplaciano é a somatória da diferença entre o ponto (x,y) e os seus quatro vizinhos nas direções horizontal e vertical.

2.1.3. Detecção de borda através de máscaras de convolução.

Máscaras de convolução são operadores de gradiente para a detecção de bordas, nas quais são considerados os pixels, tanto na direção vertical e horizontal como nas direções diagonais (±45° e ±135°).

Seu princípio é a movimentação de uma máscara sobre a área da cena, por meio de uma varredura computando-se para cada pixel o valor da área que se encontra embaixo da máscara. Estas máscaras produzem uma medida do gradiente no ponto e uma medida da direção da borda.




Fig. 2.8. Representação do processo de convolução.

Para resaltar diferentes características de um objeto é possível a utilização de diferentes máscaras. Uma das máscaras mais utilizadas foi determinada por Sobel, e é apresentada a seguir.

Para um conjunto de pixels identificados por a, b, c, d, e, f, g, h, i, e dispostos do seguinte modo:

a	b	c
d	e	f
g	h	i

Define-se:

- Um gradiente na direção 'x'

$$G_x = |((f(g) + 2f(h) + f(i)) - (f(a) + 2f(b) + f(c)))|$$

- Um gradiente na direção 'y'

$$G_y = |((f(c) + 2f(f) + f(i)) - (f(a) + 2f(d) + f(g)))|$$

$$G(e) = G_x + G_y$$

Assim:

$$G(e) = |(f(g) + 2f(h) + f(i)) - (f(a) + 2f(b) + f(c)) + (f(c) + 2f(f) + f(i)) - (f(a) + 2f(d) + f(g))|$$

As equações acima definem as seguintes máscaras:

-1	-2	-1
0	0	0
1	2	1

H₁

-1	0	1
-2	0	2
-1	0	1

H₂

Estas máscaras são chamadas operadores de Sobel e para uma imagem binária, o máximo valor deste gradiente é 6 e corresponde a um canto ou borda diagonal; para uma borda horizontal ou vertical o valor do gradiente é igual a 4.

Existem outros algoritmos que se utilizam de máscaras para a detecção de bordas e que consideram as variações das intensidades em todas as direções. Para cada ponto são calculados 8 valores de gradiente, o valor máximo obtido determina o gradiente final nesse ponto e a direção da borda.

A figura 2.9. mostra diferentes tipos de máscaras que podem ser usadas neste processo. /4/

Direção da borda	Direção gradiente	Kirsch	Prewitt	3-nivel	5-nivel
0	Norte	5 5 5	1 1 1	1 1 1	1 2 1
		3 0 -3	1 -2 1	0 0 0	0 0 0
		3 -3 -3	-1 -1 -1	-1 -1 -1	-1 -2 -1
1	Noroeste	5 5 -3	1 1 1	1 1 0	2 1 0
		5 0 -3	1 -2 -1	1 0 -1	1 0 -1
		3 -3 -3	1 -1 -1	0 -1 -1	0 -1 -2
2	Oeste	5 -3 -3	1 1 -1	1 0 -1	1 0 -1
		5 0 -3	1 -2 -1	1 0 -1	2 0 -2
		5 -3 -3	1 1 -1	1 0 -1	1 0 -1
3	Sudoeste	-3 -3 -3	1 -1 -1	0 -1 -1	0 -1 -2
		5 0 -3	1 -2 -1	1 0 -1	1 0 -1
		5 5 -3	1 1 1	1 1 0	2 1 0
4	Sul	-3 -3 -3	-1 -1 -1	-1 -1 -1	-2 -1 0
		-3 0 -3	1 -2 -1	0 0 0	0 0 0
		5 5 5	1 1 1	1 1 1	1 2 1
5	Sudeste	-3 -3 -3	-1 -1 1	-1 -1 0	-2 -1 0
		-3 0 -5	1 1 1	0 1 1	0 1 2
		-3 5 5	1 1 1	0 1 1	0 1 2
6	Leste	-3 -3 5	-1 1 1	-1 0 1	-1 0 1
		-3 0 5	-1 -2 1	-1 0 1	-2 0 2
		-3 -3 5	-1 1 1	-1 0 1	-1 0 1
7	Nordeste	-3 5 5	1 1 1	0 1 1	0 1 2
		-3 0 5	-1 -2 1	-1 0 1	-1 0 1
		-3 -3 -3	-1 -1 1	-1 -1 0	2 -1 0

Fig. 2.9. Definição de máscaras para detecção de bordas.

As figuras 2.10. mostram um exemplo de detecção de borda simulado em computador.


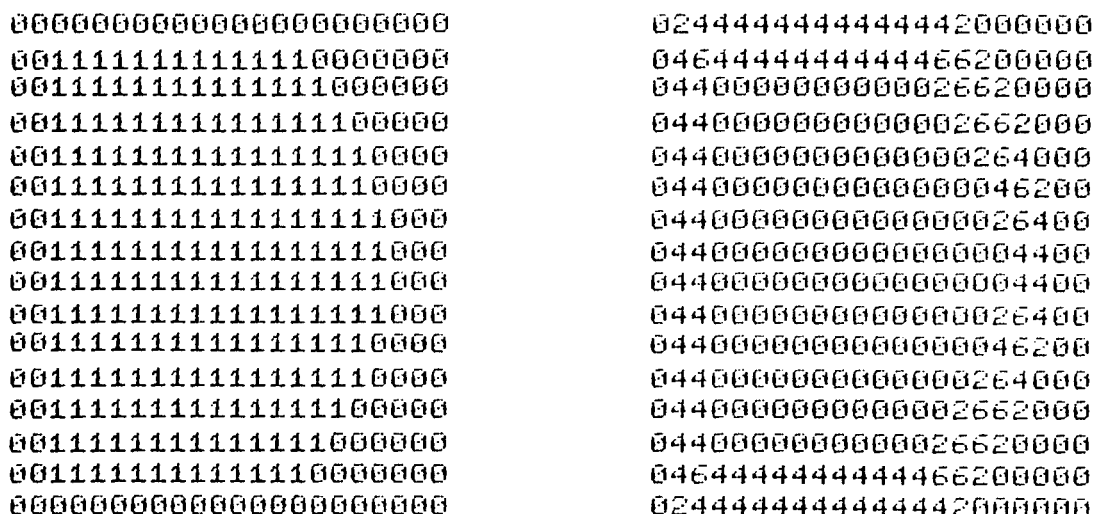


FIGURA DE ENTRADA



PADRAO DE ENTRADA

IMAGEM CONVOLUIDA




IMAGEM OBTIDA POR
DETECCAO DE BORDA

FIGURA OBTIDA
POR DETECCAO DE BORDA

Fig. 2.10. Processo de detecção de bordas simulado em computador.

2.2. Segmentação por limiar ou 'thresholding'

O método do limiar é o mais usado para a obtenção da segmentação. /5/

Consiste em escolher um nível de cinza T tal que todos os pixels com nível de cinza acima deste valor T, são considerados objetos (nível 1) e os pixels com valores menores que T são considerados fundo da cena (nível 0).

Este método é efetivo se existe uma diferença nos níveis de cinza dos objetos a analisar.

Um operador de limiar pode ser definido pela seguinte equação.

$$T = f(x,y,N(x,y),f(x,y))$$

onde:

x,y coordenadas do pixel
f(x,y) é o nível de cinza no ponto x,y
N(x,y) característica ou propriedade do ponto x,y
ex: A média dos níveis de cinza dos vizinhos

Para obter-se uma imagem binária g(x,y), a partir da imagem original, aplica-se o seguinte critério:

$$g(x,y) = \begin{cases} 1 \text{ (Objeto)} & \text{se } f(x,y) > \text{valor do limiar} \\ 0 \text{ (Fundo)} & \text{caso contrário} \end{cases}$$

Se T depende :

- só de f(x,y), o limiar é chamado de global.
- de f(x,y) e N(x,y), o limiar é chamado de local
- das coordenadas x,y, de N(x,y) e f(x,y) o limiar é chamado dinâmico

O valor do limiar T é obtido de um histograma que relaciona os níveis de cinza com o número de ocorrências destes níveis na imagem.

A figura 2.11 mostra um exemplo de uma imagem e o histograma obtido para esta imagem.





Fig. 2.11. Imagem e respectivo histograma para os níveis de cinza.

Considerando a figura 2.11 o valor de T é selecionado, para que T₁ corresponda ao fundo da imagem e T₂ aos objetos.

Um exemplo que mostra a determinação do valor do limiar e os resultados obtidos a partir deste valor é apresentado na figura 2.12.

```

PATTERN DE ENTRADA
222222233333311111122222211111
22222233333344444422222255555
55555333333344444412222255555
5555333333334444422222255555
555333333333444442222225555
5533333666633355222222222255
533333666333553377777772222
333333666633353377777772222
333333666633353377777774444
333333666633353377777774444
333333666633353377777774444
333333666633353377777774444
555533366633353377777774444
55533366633353337777777444
555333633335335333533333333

```

```

PROCESSAMENTO
00000000000000000000000000000
00000000000000000000000011111
11111000000000000000000011111
11110000000000000000000001111
11100000000000000000000000111
11000010000000000000000000111
10000011000000000000000000111
100000110000000011111111000
000000111000000000111111000
0000001111000000111111000
0000001111000000111111000
0000001111000000111111000
0000001110000000111111000
1111000110000000111111000
1110000100000000111111000
11100001000000000000000000000

```

Fig. 2.12. Processo de limiar simulado em computador.

2.3. Enfraquecimento (Thinning)

Uma imagem do tipo mostrado na figura 2.13.a., ao ser processada, isto é, adquirida e discretizada, gera uma figura como a mostrada em 2.13.b., cujas bordas possuem alguns pixels de largura. Isto ocorre em função do sistema usado para aquisição da mesma.

Ao aplicar-se a técnica de segmentação por detecção de borda, encontra-se o tipo de figura representado na figura 2.13.c., que produzirá erros na fase de extração de atributos.




Fig. 2.13. Problema apresentado.

Este problema pode ser solucionado, usando-se a técnica denominada de enfraquecimento, na qual é obtido um esqueleto da figura original com largura de só um pixel. A figura 2.14 mostra o resultado do enfraquecimento aplicado à figura anterior.






Fig. 2.14. Enfraquecimento de uma figura.

O algoritmo de enfraquecimento considera que uma figura está composta de pixels de contorno e pixels de imagem final ou pixels de esqueleto. Pixels de contorno são todos aqueles pertencentes à figura e pixels finais são os resultantes do processo de enfraquecimento./6/

As condições ou definição dos pixels de contorno são apresentados nas máscaras da figura 2.15.a. Os pontos finais ou pontos de esqueleto são definidos pelas máscaras da figura 2.15.b., as quais mostram que deve existir uma conectividade dos possíveis pixels de esqueleto.



a) Máscaras de pontos de contorno.



b) Máscaras de pontos finais ou esqueleto

Fig. 2.15. Representação dos pixels de contorno e finais por meio de máscaras.

São os seguintes os passos de um algoritmo para enfraquecimento de um objeto, considerando as máscaras definidas na figura 2.15.

- 1.- Determina-se os pontos de contorno na figura utilizando as máscaras a_1 e a_2
- 2.- Determina-se com o uso das máscara b_1, \dots, b_8 , se os pontos de contorno anteriormente obtidos são pontos de esqueleto.
- 3.- Eliminam-se os pontos de contorno que não são de esqueleto.
- 4.- Repete-se o passo 1, utilizando as máscaras a_3 e a_4
- 5.- Volta-se ao passo 1 se os passos anteriores eliminaram qualquer ponto de contorno, caso contrário, os pontos obtidos são os pontos de esqueleto ou finais da figura.

As figuras 2.16 e 2.17 mostram um exemplo, no qual é realizado o processo de detecção de borda para uma figura inicial 2.16.a., e o enfraquecimento da mesma figura.


```

.....
*****
*****
*****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
****          ****
*****
*****
*****
*****
.....

```

FIGURA DE ENTRADA

```

00000000000000000000000000000000
001111111111111100000000
001111111111111110000000
001111111111111111000000
001111000000001111100000
001111000000000111100000
001111000000000011110000
0011110000000000011110000
00111100000000000011110000
001111000000000000011110000
0011110000000000000011110000
00111100000000000000011110000
00111111111111111111100000
00111111111111111111100000
00111111111111111111100000
0000000000000000000000000000

```

PADRAO DE ENTRADA

```

.....
*****
**          *
*          *
*          *
*          *
*          *
*          *
*          *
*          **
*          *
*          ***
*****
.....

```

PONTOS APAGADOS

```

.....
-----
--#####--
-##-----#-
-#-----#-
-#-----#-
-#-----#-
-#-----#-
-#-----#-
-#-----#-
-#-----##-
-#-----##-
-#-----###-
--#####--
-----

```

ENFRAQUECIMENTO

```

00000000000000000000000000000000
00000000000000000000000000000000
00001111111111110000000000000000
00011000000000100000000000000000
00010000000000010000000000000000
00010000000000000100000000000000
00010000000000000010000000000000
00010000000000000001000000000000
00010000000000000000100000000000
00010000000000000000010000000000
00010000000000000000001000000000
00010000000000000000000100000000
00010000000000000000000010000000
00001111111111110000000000000000
00000000000000000000000000000000
00000000000000000000000000000000

```

PADRAO DE SAIDA

```

.....
.....
*****
**          *
*          *
*          *
*          *
*          *
*          *
*          **
*          *
*          ***
*****
.....
.....

```

FIGURA DE SAIDA

Fig. 2.17. Enfraquecimento de uma figura simulado em computador.

2.4. Armazenamento.

Feita a segmentação da imagem, o processo seguinte é o da extração de atributos de cada figura contida na cena. Anteriormente a isto, porém, é necessário armazenar a figura. O armazenamento da figura apresenta as seguintes vantagens:

- Finalização do processo de segmentação.
- O armazenamento por figura isolada, significa uma redução na quantidade de memória usada, já que só a informação relevante é armazenada.
- A reconstrução da imagem a partir dos arquivos é possível, e não existe perda de informação.

A seguir são discutidos dois métodos de armazenamento que se aplicam aos tipos de figuras obtidas na segmentação./7/

- 1.- Armazenamento por traço, aplicado a figuras obtidas na segmentação por limiar.
- 2.- Armazenamento por regra da cadeia, aplicado a figuras obtidas na segmentação por detecção de borda e enfraquecimento.

2.4.1. Armazenamento por traço.

Neste método é realizada uma varredura através de linhas horizontais; para cada linha é armazenado o valor das coordenadas do pixel do começo e final de cada traço. Na figura 2.18 está representado graficamente o processo de armazenamento.





Fig.2.18. Processo de armazenamento.

Da figura observa-se que:

- na linha 1, é gerado o arquivo A
- na linha 2, são gerados os arquivos B e C
- da linha 3, verifica-se que os arquivos A e B pertencem a mesma figura.
- ao término do processo temos só dois arquivos A B e C.

As condições que devem ser obedecidas, para que o traço da linha analisada tenha uma relação com o traço da linha anterior, isto é, pertençam à mesma figura são:



Seja: X_1, X_2 coordenadas x, do traço da linha i
 XT_1, XT_2 coordenadas x, do traço da linha i+1

Se $(XT_2+1 \leq X_1)$.OR. $(XT_1-1 \geq X_2)$

então os traços não pertencem à mesma figura.

O armazenamento por traço, é obtido através dos seguintes passos:

- 1.- Faça uma varredura da linha i(i=1). Determine os valores das coordenadas dos traços e armazene os pares de coordenadas na linha i, em K arquivos.
- 2.- Na linha i+1, determine os diferentes traços existentes.
- 3.- Aplique o critério de verificação de relação entre traço para cada traço obtido em 2, verificando se pertencem a figuras cujos arquivos foram criados anteriormente.
- 4.- Se pertence, armazene o traço no arquivo respectivo. Volte ao passo 2.
- 5.- Se não pertence, crie um novo arquivo e armazene no mesmo as coordenadas correspondentes. Volte ao passo 2.
- 6.- Faça uma comparação dos arquivos criados para as possíveis figuras, faça uma comparação e determine se existem elementos comuns. Em caso positivo faça o ordenamento das figuras finais.

A figura 2.19. mostra um exemplo de armazenamento por traço.

CENA DE ENTRADA

```

.....
***. *. *.
*****.
*. *. *.
*. *.
*****.
.....
*****.
.....
***.
.....
***.
.....
*. *.
***.
.....
*****.
***.
.....
*****.
.....
*****.
.....

```

IMAGEM BINARIA

```

0000000000000000
0111011011000000
11111111101110
110000111000110
110000000000110
1111100011000000
0000000011110000
0000111000000000
0000111000000000
000000000100011
111000000111110
1110000011110000
0011100000000000
0000001111000000
0000011110000000

```

POSSIVEIS FIGURAS = 10

FIGURAS FINAIS = 7

ML(L)	MF(L)
12	0
12	0
16	1
6	1
4	1
4	1
6	0
8	1
6	1
4	1
0	0
0	0

COORD. MI(ML(L),L) = (I, FIGURA)

2	2	2	3	6	6	10	10	11	14	0	0
3	3	2	4	7	9	11	10	12	15	0	0
4	4	2	5	0	0	12	11	13	0	0	0
4	4	1	0	0	0	0	12	0	0	0	0
5	5	4	0	0	0	0	0	0	0	0	0
6	6	4	0	0	0	0	0	0	0	0	0
0	0	5	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0

COORD. MJ(ML(L),L) = (J, FIGURA)

2	6	2	12	9	5	10	10	1	7	0	0
4	7	4	14	10	7	10	10	3	10	0	0
1	1	6	13	9	5	10	14	1	6	0	0
10	10	7	14	12	7	14	15	3	9	0	0
1	1	9	13	0	0	9	10	3	0	0	0
2	2	10	14	0	0	12	14	5	0	0	0
7	7	1	0	0	0	0	9	0	0	0	0
9	9	10	0	0	0	0	12	0	0	0	0
1	1	1	0	0	0	0	0	0	0	0	0
2	2	2	0	0	0	0	0	0	0	0	0
1	1	7	0	0	0	0	0	0	0	0	0
5	5	9	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0	0	0
0	0	2	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0	0	0
0	0	5	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0

Fig. 2.19. Armazenamento de uma cena pelo metodo do traço.

2.4.2. Armazenamento pela regra da cadeia.
('Boundary Chain Code - BCC')


A regra da cadeia é uma forma de representação para figuras descritas pelo seu contorno, e que resultam normalmente da segmentação por detecção de borda ou enfraquecimento.

A regra da cadeia baseia-se no fato de que muitos objetos podem ser definidos pelo seu contorno, não sendo necessário o armazenamento dos pontos interiores da figura, assim, o código da cadeia é uma representação compacta do contorno fechado de uma figura, sendo a cadeia uma sequência ordenada de elementos $a_1, a_2, a_3, \dots, a_n$, juntamente com as coordenadas do pixel de início da cadeia.


Existem duas convenções para representar uma cadeia. Uma considera que um pixel central é associado ou tem ligação com os vizinhos nas direções horizontal e vertical, e é denominado de 4-vizinhos. A outra considera que um pixel central está associado ou tem ligação com os vizinhos nas direções horizontal, vertical e diagonal, e é denominado de 8-vizinhos.

A figura 2.20 mostra a representação de um pixel central e o código usado no caso de cada convenção. Os pixels na direção vertical e horizontal são denominados de vizinhos diretos e os pixels na diagonal de vizinhos indiretos.

A justificativa para o uso de duas representações vem do fato que para algumas aplicações o contorno é definido só por pixels nas direções horizontais e verticais, sendo este o caso de figuras obtidas por detecção de borda. Em outros casos, tem-se que para alguns pixels da figura não existe uma conectividade nas direções horizontal e vertical, e portanto deve-se usar a convenção de 8-vizinhos, sendo este o caso de figuras obtidas por alguns algoritmos de enfraquecimento.




a) 4-vizinhos
diretos (0-1-3-4)



b) 8-vizinhos
diretos (0-2-4-6)
indiretos (1-3-5-7)

Fig. 2.20. Representação da convenção usada na cadeia.

A figura 2.21., mostra a representação de uma cadeia e a figura 2.22. uma aplicação da regra de armazenamento.



- x_i, y_i coordenadas de início.
- $a_1, a_2, a_3, \dots, a_n$ convenção que representa o contorno.
- existe conectividade de a_1 e a_n

Fig. 2.21. Representação de uma cadeia.




Fig. 2.22. Aplicação da regra da cadeia.

A regra da cadeia permite uma compressão dos dados, além de possibilitar a obtenção de características tais como perímetro, área, número de cruzes (número de Euler modificado), que serão utilizados na extração de atributos e classificação.

Ao contrário do armazenamento por traço, o armazenamento da figura pela cadeia é feito num só arquivo, sem necessidade de ordenamento, e consistindo este arquivo de:

- coordenadas do pixel de início.
- sequência de elementos da cadeia.

Um exemplo da representação pela regra da cadeia é apresentado na figura 2.23.

CENA DE ENTRADA

```

.....
***.*.
*.*.*.
*.*.*.
*.*.*.
***.*.
.....
****.
*.*.
*.***.
.....

```

CENA DIGITALIZADA

```

0000000000
0011100100
0100101010
0100101010
0011001010
0000001100
0111100000
0100010000
0011110000
0000000000

```

.EX CAD. TES
LINK: LOADING
(LNKXCT CAD EXECUTION)

LF = 1

VALOR (I, J) = 2 - 3

LF = 2

VALOR (I, J) = 2 - 6

LF = 3

VALOR (I, J) = 7 - 2

NAO TEM MAIS FIGURAS

ARQUIVO DE SAIDA

2	2	7
3	8	2
5	5	6
6	6	7
7	6	0
0	6	0
1	0	0
2	1	2
2	2	3
4	2	4
4	3	4
		4

Fig. 2.23. Armazenamento de uma cena pelo método da cadeia.

III EXTRAÇÃO DE ATRIBUTOS.

Tendo sido isolados os diferentes objetos de uma cena, é necessária uma classificação destes objetos segundo padrões definidos.

A classificação destes objetos é feita considerando que cada objeto possui características próprias, que recebem o nome de atributos ou descritores, e a seleção apropriada destes atributos permitirá a classificação do objeto. Como visto, um objeto é definido como uma entidade física, que possui características próprias tais como comprimento, largura, peso, área, etc. /8/

A partir destas características um sistema de medida de atributos calcula parâmetros relacionados com qualidades específicas associadas a objetos conhecidos. Este sistema de medida de atributos recebe o nome de 'extrator de atributos'.

Um extrator de atributos, pode ser considerado como um analisador que converte um padrão de entrada num conjunto de valores $x_1, x_2, x_3, \dots, x_k$ que caracterizam o padrão. Este conjunto de valores é normalmente representado como um vetor de dimensionalidade K.

$$X = (x_1, x_2, x_3, x_4, \dots, x_k)^T$$




Fig. 3.1. Representação de um extrator.

O objetivo do extrator é a obtenção de um sub-conjunto de K atributos do conjunto total de atributos do objeto, a partir do qual pode ser feita a classificação.

O número de K atributos depende da exatidão desejada na classificação e do tempo de processamento necessário para a obtenção destes K atributos. A seleção dos atributos implica, portanto num compromisso entre exatidão de classificação e tempo de processamento.

Não existe atualmente teoria que defina quais atributos de um objeto devem ser considerados para a classificação do mesmo, isto é um assunto subjetivo que depende da situação prática como: possibilidades de medida, custo da medida, relevância, etc.

Os requisitos que o conjunto de atributos deve preencher são:

- Baixa dimensionalidade: Os atributos que definem um padrão devem ser reduzidos em número.
- Relevantes: Os atributos devem permitir uma discriminação real entre os diferentes objetos.
- Suficiente informação: Os atributos selecionados devem reter suficiente informação para permitir o reconhecimento do modelo desejado.
- Invariantes: Para objetos da mesma classe, os atributos devem ser invariantes para posição, tamanho e rotação do objeto.

Os atributos de um objeto podem ser classificados nas tres categorias seguintes:

- Física: Ex. cor, odor, textura.
- Estruturais: Ex. forma, propriedades geométricas.
- Matemáticas: Ex. coeficientes de correlação.

Assim, temos que para aplicações industriais (por exemplo, visão do robô ou aplicações PAC) os objetos são normalmente reconhecidos pela sua forma.

A análise da forma dos objetos pode ser feita de dois modos:

- Análise orientada globalmente por sua região
- Análise orientada por seu contorno

A tabela 3.1. apresenta possíveis atributos relacionados com cada modo de análise.

Análise orientada pela região do objeto	{	- Determinação dos eixos principais - Funções geradoras de momentos - Descritores geométricos - Densidade óptica, etc.
Análise orientada pelo contorno do objeto	{	- Descritores de Fourier - Código da cadeia, etc.

Tabela 3.1. Relação de atributos e o modo de análise.


Um conjunto de possíveis atributos de um objeto é resumido na Tabela 3.2. e uma representação gráfica dos mesmos é apresentada no item 3.1. /1,9,10/

Forma	<ul style="list-style-type: none">- Área- Perímetro- Circularidade- Retângularidade- Fator G- Retângulo envolvente- IOD, densidade óptica integrada- Funções de momento invariantes- Número de Euler, etc.
Posição	<ul style="list-style-type: none">- Centro de gravidade do retangulo envolvente- Centro de gravidade do objeto- Eixos principais do objeto- Ângulos entre eixos principais do objeto e eixos de referência do sistema, etc.


Tabela 3.2. Alguns atributos definidos na sua forma e posição

3.1. Representação gráfica dos atributos de um objeto.

1.- Área. (A)



2.- Perímetro. (P)




3.- Circularidade.(C)

$$C = P^2 / 4\pi A$$

P = Perímetro do objeto
A = Área

4.- Dimensões do retângulo envolvente (Ferret box)




5.- Retângularidade. (R)


$$R = A_o / A_R$$

A = Área do objeto
A_R = Área do retângulo envolvente


6.- Eixos principais do objeto.



7.- Razão da área do objeto à área dos furos.




8.- Relação entre elementos de uma aproximação poligonal



9.- Fator G. Relação da distância do pixel ao contorno.

0	0	0	0	0	0	0	0
0	1	1	1	1	1	1	0
0	1	2	2	2	2	1	0
0	1	2	3	3	2	1	0
0	1	2	3	3	2	1	0
0	1	2	2	2	2	1	0
0	1	1	1	1	1	1	0
0	0	0	0	0	0	0	0

10.- Coordenadas do centro de gravidade do objeto.




$$C.G. x = \sum_{i=1}^N x_i$$

$$C.G. y = \sum_{i=1}^N y_i$$


N: total de pixels do objeto
 x,y: Coordenadas do pixel

11.- Coordenadas do centro do retângulo envolvente




$$C.R.E. = \left(\frac{a}{2}, \frac{b}{2} \right)$$

12.- Relação entre eixos principais do objeto e eixos de referência do sistema.




x',y' eixos do objeto
 x ,y eixos de referência do sistema raster.

13.- Vetor de maior comprimento que liga dois pontos sobre o contorno do objeto.



14.- Vetor ligando o centro de gravidade do objeto com o ponto mais distante e ponto mais próximo sobre o contorno do objeto.



15.- Determinação do ângulo de orientação da figura.



0°



180°



90°




270°

16.- Número de Euler.


$$E = C - H$$

C: contorno

H: número de furos




E = 1



E = 1



E = -1



E = 0

3.2. Métodos para a medida de atributos.

Após a fase de segmentação realizada com o uso das técnicas de limiar, detecção de borda ou enfraquecimento, é feito o armazenamento do objeto, obtendo-se uma representação da figura em forma isolada, a partir da qual é feita a medida ou extração de atributos.


A seguir são apresentados em detalhes alguns métodos para extração de atributos. Alguns desses métodos, devido a suas características são mais facilmente aplicáveis na fase de segmentação. Incluem-se nesse caso atributos tais como: área, perímetro, etc.

3.2.1. Área.

3.2.1.1. Área

A área de um objeto como o representado na figura 3.2., é obtida após o processo de digitalização, quantização e separação do objeto desejado da cena.

Assumindo que se obteve uma imagem binária, o objeto é representado por uma matriz com $M \times N$ elementos, onde cada pixel p_{ij} do objeto é representado pelo elemento a_{xy} da matriz e os elementos a_{ij} só assumem valores 0 ou 1.



$$x = 1, 2, \dots, N$$

$$y = 1, 2, \dots, M$$

Fig. 3.2. Representação da figura por uma matriz $M \times N$.

Se cada pixel corresponde a um retângulo com lados de comprimento A e B , respectivamente, a área da figura é dada por:

$$\text{Área} = A \cdot B \sum_{x=1}^M \sum_{y=1}^N f(x,y) \quad f(x,y) \begin{cases} = 1 & \text{Objeto} \\ = 0 & \text{não objeto} \end{cases}$$

No caso particular de pixel de forma quadrada a área será dada por:

$$\text{Área} = A^2 \sum_{x=1}^M \sum_{y=1}^N f(x,y)$$

3.2.1.2. Determinação da área pela BCC.

Outro procedimento para a obtenção da área baseia-se na utilização de uma B.C.C. (Boundary Chain Code), que representa o contorno do objeto, e consiste de um conjunto de elementos a_1, a_2, \dots, a_n , onde a_i é um elemento linear que pode assumir os valores mostrados na figura 2.20., e das coordenadas do primeiro elemento da cadeia ou pixel de início. /7/

A área para uma figura representada por uma BCC, é dada pela seguinte equação.

onde:

$$\text{Área} = \left| \sum_{i=1}^N \Delta X (Y_{i-1} + 1/2 Y_i) \right|$$

ΔX e ΔY são definidos da seguinte maneira.

$$\begin{aligned} \Delta X &= X_i - X_{i-1} \\ \Delta Y &= Y_i - Y_{i-1} \\ X_i &= f(a_i, X_{i-1}) \\ Y_i &= f(a_i, Y_{i-1}) \end{aligned} \quad \begin{array}{l} a_i \in \text{B.C.C.} \\ X_0, Y_0 \text{ coordenadas do} \\ \text{início da cadeia} \end{array}$$

A equação representa uma integração da função expressa pela cadeia, em relação ao eixo X

3.2.1.3. Determinação da área, pelo método Pick.

Um terceiro método para a determinação de área para figuras segmentadas por limiar é obtido a partir do Teorema de Pick, cujo enunciado é o seguinte:

' A área de um polígono arbitrário com os pontos correspondentes a um sistema de varredura raster, é dado pela soma dos pontos varridos que são interiores ao polígono mais a metade dos pontos que se encontram sobre o polígono menos um'

$$\text{Área} = i + 1/2 b - 1$$

ou

$$\text{Área} = S - 1/2 b - 1$$

onde:

- i: número dos pontos interiores do polígono ou objeto
- b: número dos pontos do contorno
- S: número dos pontos totais do polígono

Para uma figura com furos, a área obtida será: a área do objeto sem considerar os furos menos a soma das áreas dos polígonos relativos aos furos' /11/

$$\text{Área} = i_0 + 1/2 b_0 - 1 - \sum_{i=1}^N (i f_k + 1/2 b f_k - 1)$$

$$i_o = i + \sum_{k=1}^N b f_k + i f_k$$

então:

$$\text{Área} = i + 1/2 b + n - 1$$

onde:

- i : número dos pontos interiores do objeto
- b : número dos pontos do contorno-objeto mais pontos contorno-furo
- n : número dos furos.

A figura 3.3 mostra uma figura e a área obtida usando o método mencionado




Fig. 3.3. Obtenção da área pelo método descrito em 3.2.1.3.

3.2.2. Perímetro.

3.2.2.1. Determinação do perímetro a partir da BCC

Conhecida a BCC, é possível obter-se o perímetro de uma figura considerando os elementos que formam esta cadeia.

O perímetro será dado por:

$$\text{Per.} = A \cdot (P + Q\sqrt{2})$$

- P, Q função dos valores a da cadeia
- P=1 se a_i 0,2,4,6 - vizinhos mais próximos
- Q=1 se a_i 1,3,5,7 - vizinhos na diagonal
- A comprimento do pixel
- P, Q : valores a da cadeia

3.2.2.2. Medida do perímetro a partir dos elementos da envoltória da figura

A seguir discute-se um método desenvolvido pelo autor e que representa uma contribuição à área de processamento de imagem e reconhecimento de padrões.

Durante a etapa de segmentação é possível determinar-se o perímetro de um objeto como descrito a seguir.

Aplicando-se operadores de máscara, por exemplo Sobel, na segmentação de uma figura discretizada binariamente, são obtidos valores específicos para cada pixel na envoltória da figura, os quais podem ser usados para a determinação do perímetro.

Fazendo-se uma convolução sobre a figura com máscaras do seguinte tipo:

$$\begin{array}{ccc} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{array} \quad \begin{array}{ccc} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{array}$$

resultam valores iguais a 2, 4, 6, para os pixels do objeto e para os pixels na envoltória. O perímetro no método proposto pode ser obtido pela utilização da seguinte equação.

$$P = N + IABS \left| N_6 - N_2 \right|$$

- N : número total de elementos do contorno
- N_6 : número de '6' externos obtidos (envoltoria)
- N_2 : número de '2' externos obtidos (envoltoria)

Os valores de N_6 e N_2 correspondem aos pixels que estão envolvendo o contorno final da figura, e que são obtidos da fase de segmentação por detecção de borda.

A figura 3.4 mostra, de forma geral, o processo de segmentação e onde são obtidos os valores anteriormente analisados. A importância deste método reside no fato de que não existe custo de processamento na fase de extração de atributos, já que os valores necessários são determinados na etapa de segmentação.

A figura 3.5 mostra alguns exemplos de obtenção do perímetro pelo método proposto.




Fig.3.4. Representação do esquema utilizado para a obtenção dos valores no algoritmo proposto.

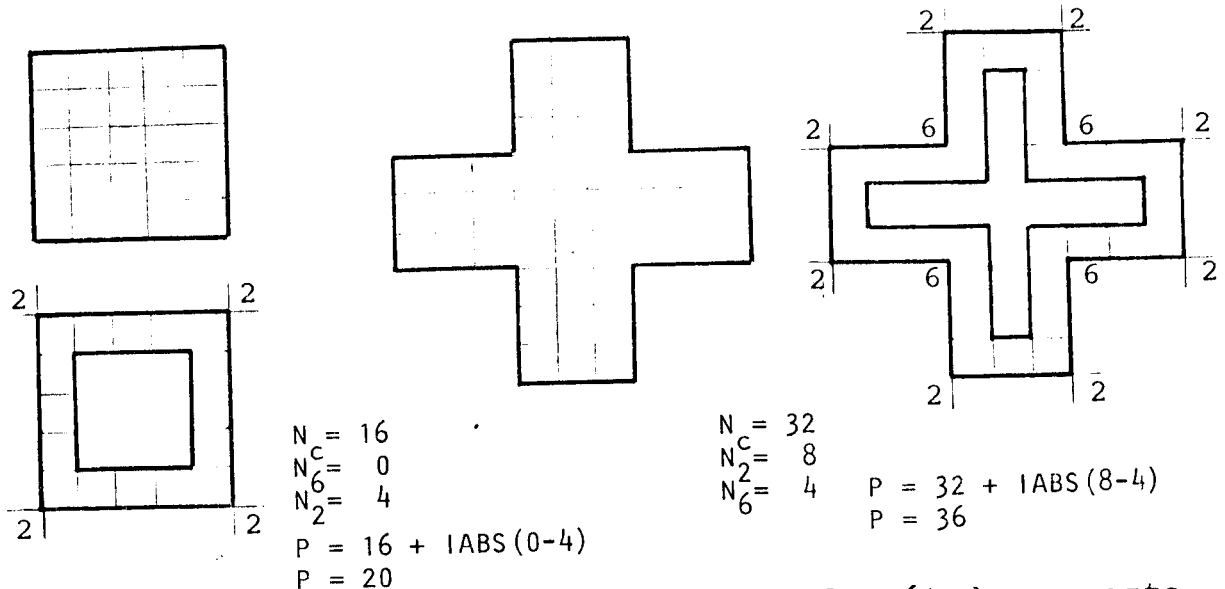


Fig. 3.5. Valores de perímetro medidos pelo método proposto.

3.2.2.3. Cálculo do perímetro numa representação BCC de 4 elementos.

O cálculo do perímetro para um objeto numa representação de BCC de 4 elementos é dado pela seguinte equação:

$$P = A \cdot N \qquad A = \text{tamanho do pixel}$$

Onde A representa a área de um pixel e N é determinado pela ocorrência de cantos internos e externos do contorno de uma objeto, e definidos na figura 3.6. /12/




Fig. 3.6. Representação de uma figura e os cantos externos e internos considerados no algoritmo.

Da análise da figura é possível verificar a existência de cantos internos e externos, representados por 'i' e 'e' respectivamente,

- Os valores interiores "i" não contribuem para o perímetro, portanto, estes valores não deverão ser considerados no cálculo do perímetro.
- Os valores exteriores "e" contribuem para o perímetro duas vezes.

assim, a cada valor interno representado na cadeia, se deverá subtrair um, e a cada valor externo, deverá somar-se 1 ao perímetro.

Os valores 'i' e 'e', podem ser obtidos facilmente da representação da cadeia da seguinte forma:

- a) Cantos interiores "i" são determinados pelo seguinte conjunto de valores na cadeia:

30, 23, 12, 01

- b) Cantos externos "e" são determinados pelo seguinte conjunto de valores na cadeia.

10, 03, 32, 21

Assim

O valor de N, estará determinado por:

$$N = N - N_i + N_e$$

- N : número de elementos da cadeia
- N_i : número de cantos internos
- N_e : número de cantos externos

Então a equação 3.5. , pode ser reescrita como:

$$P = A \cdot (N_t - N_i + N_e)$$

Uma aproximação melhor para perímetro é obtida fazendo-se um ajuste do erro cometido ao aproximar-se uma provável diagonal entre os cantos.

Este valor de aproximação está definido por:

$$D = (2 \cdot A - A \sqrt{2})$$

E o perímetro resulta em:

$$P = N \cdot A - N_i \cdot B = N \cdot A - N_i (2 A - A \sqrt{2})$$

3.2.3. Circularidade

Uma vez obtida a área e o perímetro do objeto é possível determinar sua circularidade, a qual é definida pela seguinte equação:

$$C = P^2 / 4 \cdot \pi \cdot A$$

- Para um círculo de raio r, a circularidade é igual a 1

$$C = (2 \cdot \pi \cdot r)^2 / 4 \cdot \pi \cdot \pi \cdot r^2 = 1$$

- Para um quadrado de lado r, o valor da circularidade é

$$C = 4 \cdot \pi / 4 \cdot \pi \cdot r = 1.2732$$

Estes dois exemplos mostram a diferença do valor da circularidade obtida para elementos de forma geométrica diferentes, sendo este atributo de grande utilidade para a classificação do objeto.

3.2.4. Funções geradoras de momentos.

Funções de momento são atributos invariantes, isto é são independentes da posição, tamanho e orientação do objeto.

Os fundamentos matemáticos para a determinação desta independência são encontrados na teoria de invariantes algébricos, na qual certas funções permanecem inalteradas sob certas condições de transformação. /13,14/

Pela definição dos momentos, tem-se que:

Os momentos de ordem (p,q), são dados pela equação:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x,y) dx dy$$

em que $f(x,y)$, é uma função de distribuição de densidade em duas dimensões x e y .

Ao assumir p,q valores não negativos é possível obter-se um conjunto infinito de soluções ou momentos de ordem pq , o qual especificará a função $f(x,y)$ completamente.

O exposto acima é provado pelo teorema:

' A sequência de momentos (m_{pq}) é unicamente determinada por $f(x,y)$ e consequentemente $f(x,y)$ é unicamente determinada por (m_{pq})'

Sendo p,q a ordem do momento, para $p,q=0$, existe um único momento de ordem 0

$$m_{00} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) dx dy$$

este valor corresponde à área do objeto.

Para uma imagem discreta a equação anterior toma a forma:

$$m_{pq} = \sum_x^N \sum_y^M f(x,y)$$

onde, M e N determinam a dimensão de retângulo que envolve o objeto.

Os momentos centrais são definidos como:

$$U_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x,y) dx dy$$

onde: $\bar{x} = m_{10} / m_{00}$ $\bar{y} = m_{01} / m_{00}$

x e y , são as coordenadas do centro de gravidade do objeto e representam uma normalização em relação à posição.

No caso de um objeto representado por uma matriz de dimensões $M \times N$, a equação anterior é representada por:

$$U_{pq} = \sum_{x=1}^N \sum_{y=1}^M (x - \bar{x})^p (y - \bar{y})^q f(x,y)$$

Os momentos centrais normalizados são definidos por:

$$FN_{pq} = \frac{U_{pq}}{U_{00}^z}$$

$$z = \frac{p + q}{2} + 1$$

A partir dos momentos centrais normalizados, um conjunto de funções de momentos invariantes pode ser definido.

As seguintes equações representam funções baseadas nos momentos de segunda e terceira ordem.

$$FM_1 = FN_{20} + FN_{02}$$

$$FM_2 = (FN_{20} - FN_{02})^2 + 4FN_{11}$$

$$FM_3 = (FN_{30} - 3FN_{12})^2 + (3FN_{21} - FN_{03})^2$$

$$FM_4 = (FN_{30} - FN_{12})^2 + (FN_{21} + FN_{03})^2$$

$$FM_5 = (FN_{30} - 3FN_{12})(FN_{30} + FN_{12})((FN_{30} + FN_{12})^2 - 3(FN_{21} + FN_{03})^2) + (3FN_{21} - FN_{03})(FN_{21} + FN_{03})(3(FN_{30} + FN_{12})^2 - (FN_{21} + FN_{03})^2)$$

$$FM_6 = (FN_{20} - FN_{02})((FN_{30} + FN_{12})^2 - (FN_{21} + FN_{03})^2) + 4FN_{11}(FN_{30} + FN_{12})(FN_{21} + FN_{03})$$

$$FM_7 = (3FN_{12} - FN_{30})(FN_{30} + FN_{12})((FN_{30} + FN_{12})^2 - 3(FN_{21} + FN_{03})^2) + (3FN_{12} - FN_{03})(FN_{21} + FN_{03})(3(FN_{30} + FN_{12})^2 - (FN_{21} + FN_{03})^2)$$

O uso de apenas algumas destas funções como descritores ou atributos, permite a classificação do objeto, não sendo necessário a utilização de todas elas.

O método dos momentos permite a determinação dos eixos principais do objeto x' , y' . Estes valores são obtidos usando a equação seguinte, onde o valor de θ que satisfaz a equação indica a rotação dos eixos principais da figura, em relação aos eixos do sistema absoluto de coordenadas.

$$\operatorname{tg} 2\theta = \frac{2U_{11}}{U_{20} - U_{02}}$$

Eventuais indeterminações podem ser eliminadas especificando-se $U_{20} > U_{02}$ e $U_{30} > 0$.

3.2.5. Energia da fronteira

Outro atributo que se pode considerar é a chamada energia da fronteira que baseia-se na energia associada ao contorno de uma figura. /15/

Num objeto de perímetro P, para qualquer ponto do seu contorno, pode ser definido uma função de curvatura K(p), que é função do raio do círculo tangente à borda do objeto no ponto p e representado por r(p).

$$K(p) = \frac{1}{r(p)}$$

Definindo uma energia normalizada por:

$$E = \int_0^P |K(p)|^2 dp \quad \text{onde } P = \text{perímetro,}$$

para um objeto, de contorno fechado, onde a função K(p) é uma função periódica, a energia média de contorno é:

$$E = \frac{1}{P} \int_0^P |K(p)|^2 dp \quad P = \text{perímetro}$$

Esta propriedade é útil quando se tem uma figura representada pela regra da cadeia. Neste caso a curvatura K(p) do contorno pode ser obtida a partir dos elementos da cadeia, dado que estes elementos indicam uma direção. A curvatura K(p), neste caso é dada pela seguinte equação.

$$K(p) = d\theta/dp = \Delta\theta(n)/\Delta p(n) = D(n)/\Delta p(n)$$

onde:

- D(n) : representa a variação da tangente à curva no ponto.

$$D(n) = a_n - a_{n-1}$$

a_n representa um elemento da cadeia.

- p(n) é o comprimento ao redor do ponto e é definido por

$$p(n) = L(a_n) + L(a_{n-1})$$

onde:

$$\begin{aligned} L(a_i) &= 1/2 & a_i &: \text{par} \\ L(a_i) &= \sqrt{2}/2 & a_i &: \text{impar} \end{aligned}$$

O valor da energia da fronteira, para um objeto discretizado binariamente é dado pela seguinte equação:

$$E = \frac{1}{P} \sum_{i=1}^p \frac{a_{n+1} - a_n}{L(a_{n+1}) + L(a_n)}$$

P = elementos da cadeia

3.2.6. Fator G

O fator G, é também um atributo utilizado na classificação de padrões. É definido como uma função da área do objeto e da média das distâncias mínimas dos pixels do objeto ao contorno deste. /16/

A média das distâncias mínimas é dada por:

$$\bar{d} = \frac{1}{N} \sum_{i=1}^N d_i$$

d : distância mínima do ponto i ao contorno
 N : número total de pontos do objeto.

O fator G é definido pela seguinte equação:

$$F. G. = \frac{A}{\bar{d}^2} = \frac{A}{\frac{1}{N^2} \left[\sum_{i=1}^N d_i \right]^2}$$

A figura 3.7. mostra um exemplo da determinação do fator G, para um objeto.

0 0 0	0 0 0	0 0 0 0 0 0 0 0 0 0
0 1 0	0 1 0	0 1 1 1 1 1 1 1 1 0
0 1 0 0 0 0 0 1 0		0 1 2 2 2 2 2 2 1 0
0 1 1 1 1 1 1 1 0		0 1 2 3 3 3 3 2 1 0
0 1 1 1 1 1 1 1 0		0 1 2 3 4 4 3 2 1 0
0 1 0 0 0 0 0 1 0		0 1 2 3 3 3 3 2 1 0
0 1 0	0 1 0	0 1 2 2 2 2 2 2 1 0
0 0 0	0 0 0	0 1 1 1 1 1 1 1 0
		0 0 0 0 0 0 0 0 0 0
A = N = 60		A = N = 90
d = 22		d = 100
F. G. = 446.28		F. G. = 72.9

Fig. 3.7. Determinação do fator G.

3.2.7. Número de Euler modificado.

O número de Euler, é a medida de um atributo que descreve a topologia do objeto, estabelecendo uma relação da conectividade existente no objeto e o numero de furos existente nele. Diz-se que uma região possui conectividade, se existe uma curva fechada que liga toda esta região./17/

O número de Euler, considerando o exposto anteriormente, é definido pela seguinte equação:

$$E = \text{numero de regiões conexas} - \text{número de furos}$$

A figura 3.8. mostra um exemplo de alguns objetos e o número de Euler relacionados com os mesmos.




Fig. 3.8. Número de Euler para diferentes figuras.

Fazendo uma analogia com o exposto acima, define-se o número de Euler modificado que é utilizado na aplicação descrita no capítulo 5.

O número de Euler modificado considera que existe uma região representada pelo seu contorno e o número de furos está determinado pelo número de interseções que ocorrem neste contorno. Assim, a figura 3.9. mostra alguns objetos e o respectivo número de Euler modificado obtido. Os valores de interseções e a representação do contorno é feito pela BCC.




Fig. 3.9. Número de Euler modificado.

3.2.8. Determinação da orientação da figura.

O atributo descrito a seguir, determina a orientação do objeto dentro da cena. Ele pode ser considerado como uma simplificação da medida do ângulo de orientação, uma vez que só quatro orientações são possíveis, 0° , 90° , 180° , 270° , sendo as demais orientações aproximadas para uma das citadas. A figura 3.10 mostra a orientação de uma porta OR.




Fig. 3.10. Uma porta OR e suas possíveis orientações.

O atributo mencionado não é usado na classificação propriamente dita, mas contém informação sobre a figura. Por exemplo, no caso de símbolos de portas lógicas, indicam se as ligações correspondem a entradas ou saídas da porta.

O algoritmo para determinação deste atributo possui os seguintes passos:

- A partir do centro de gravidade da figura traçam-se a uma distância apropriada deste centro duas retas paralelas ao eixo x e duas retas paralelas ao eixo y que cortam o contorno da figura. (ver figura 3.11.)

- Se os segmentos de retas, delimitados pela figura na direção paralela ao eixo x, são de comprimento similar, então pode-se considerar que a figura está orientada a 0° ou 180° .

- A ambiguidade resultante (0° e 180°) é solucionada considerando-se uma reta perpendicular ao eixo x, que realiza uma varredura da esquerda para a direita, e as medidas dos segmentos da reta determinados pelo contorno do objeto. Os gráficos da figura 3.12 mostram a relação entre o comprimento do segmento em função da varredura.

- Se as retas na direção paralela ao eixo y são de comprimento similar, então pode-se considerar que a figura está orientada a 90° ou 270° .

- A ambiguidade é solucionada de modo análogo ao anterior considerando-se agora uma varredura por uma reta paralela ao eixo x. A solução é representada na figura 3.13.




Fig. 3.11. Determinação da orientação de uma figura




Fig. 3.12. Determinação da orientação na direção horizontal. Comprimento do traço versus varredura X.




Fig. 3.13. Determinação da orientação na direção vertical. Comprimento do traço versus varredura Y.

IV CLASSIFICAÇÃO

4.1. Princípios básicos de classificação.

O objetivo de um sistema de reconhecimento de padrões é a classificação ou descrição de um padrão submetido à entrada do sistema.

O conceito de classe indica o agrupamento de eventos, figuras, etc, que possuem propriedades comuns, e são estas propriedades que permitem fazer a classificação do padrão entre as diferentes classes existentes na aplicação.

As propriedades de um padrão são denominados atributos ou descritores, e o conjunto de K-atributos formam um vetor X que representa o padrão.

$$X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_k \end{bmatrix} = (x_1, x_2, x_3, \dots, x_k)^T$$

i : 1, 2, 3, 4,M ; M = número de classes
K : número de atributos

Um conjunto de padrões similares formam uma classe, e o conjunto de classes de uma aplicação é representado por W_i , $i=1,2, \dots,M$. Assim, por exemplo, no reconhecimento de números decimais, o conjunto W será formado pelos símbolos 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, num total de 10 classes. Então, tem-se:

Número de classes :10, M=10

Número de atributos : K, função dos atributos necessários para uma classificação desejada com mínimo erro.

Portanto, o problema de classificação consiste em determinar-se o conjunto de medidas que descrevem o padrão e que permitam com o menor erro possível a associação do padrão a uma das classes da aplicação.

Classificar é decidir, baseado nas informações obtidas no processo de análise, se existe alguma correspondência ou não, com medidas representativas do protótipo, e associar uma e só uma classe a cada padrão.

A figura 4.1. mostra um sistema básico de classificação.




Fig. 4.1. Sistema de classificação.

O processo de classificação é feito pela formulação de regras ou funções de decisão. Assim temos que nos seres humanos o processo de classificação é precedido por um processo de aprendizado onde são geradas as regras de decisão. Estas regras de decisão são constantemente melhoradas através de experiências passadas ou treinamento./18,19/

Se não é possível a classificação de um padrão, isto significa que as medidas obtidas na etapa de extração não são suficientes para uma definição a partir das regras existentes ou as regras existentes não definem o padrão.

Deste modo, um sistema de reconhecimento de padrões deverá incluir uma etapa de aprendizado e uma etapa de classificação; em alguns casos, o processo de aprendizado pode ser iterativo.

A figura 4.2. mostra um diagrama de blocos que define as etapas do processo de aprendizado e classificação, num sistema de reconhecimento de padrões.

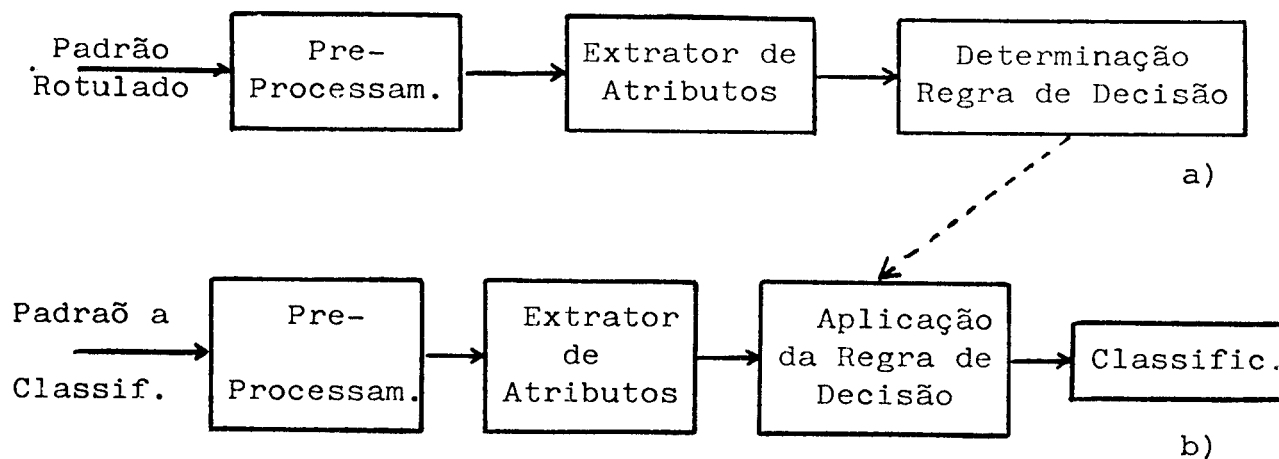


Fig. 4.2. Processo de aprendizado e classificação.

No processo de aprendizado (parte a. da figura 4.2), são examinados padrões conhecidos e rotulados obtendo-se valores para os atributos que caracterizam este padrão.

O conjunto de atributos dos padrões da mesma classe, determinam uma regra de decisão. Obtém-se deste modo um conjunto de regras que definem unicamente uma das classes.

No processo de classificação (parte b. da figura 4.2), com as regras já definidas, são apresentados ao sistema um conjunto de padrões de teste: estes padrões são processados e classificados com as regras de decisão obtida no ponto a)

Se o resultado da classificação não for o desejado, isto significa que as regras obtidas não são corretas e que a partição do espaço de atributos nas diferentes classes não está bem definida, sendo possivelmente necessário considerar-se uma maior quantidade de atributos para uma perfeita separação entre as classes.

O processo descrito pode ser sistematizado do seguinte modo:

- Existe um espaço Euclidiano de dimensão K (K : número de atributos), no qual estão representadas M possíveis classes, $W_1, W_2, W_3, \dots, W_M$
- Um padrão da classe W_i é descrito pelo vetor X , no qual estão contidos os K -atributos
- Existe um processo de ajuste, denominado de aprendizado, que define um método de classificação: este método otimiza a separação das classes da aplicação ou a determinação da fronteira entre regiões. O processo de aprendizado é realizado a partir de um conjunto de padrões rotulados, gerando um procedimento de classificação o qual é denominado 'Regras de Classificação' (decisão ou discriminação). Portanto, o procedimento de aprendizado consiste na divisão do espaço Euclidiano em N regiões, cada uma associada com uma classe. No caso de incorporação de novas classes estas regras são geralmente modificadas
- O processo de reconhecimento, é basicamente o uso do procedimento de classificação para a associação do padrão desconhecido a uma das classes existente (rotulação).

A figura 4.3 mostra graficamente os conceitos de atributos, classe e classificação definidos anteriormente.




Fig. 4.3. Representação gráfica dos conceitos de atributos, classes e classificação.

Na figura 4.3. estão representadas duas classes W_1 e W_2 formadas por padrões que possuem como atributos x_1 e x_2 . Para se classificar o padrão "*" a partir da figura, deve-se determinar uma fronteira para a separação das duas classes. Deste modo o padrão representado por "*", poderá ser classificado como pertencente a classe W_1 , por existir uma maior proximidade da classe ou pelo fato do padrão encontrar-se acima da reta de fronteira.

A maioria dos classificadores de padrões baseiam-se numa das seguintes metodologias:/9,19/

- Técnica de decisão teórica ou matemática.
- Técnica estrutural ou sintática.

Os métodos matemáticos de classificação são baseados na determinação de regras ou funções de decisão e podem ser divididos em duas categorias:

- determinísticos
- estatísticos

No método estatístico, a função de decisão baseia-se numa função de densidade de probabilidade, uma probabilidade de ocorrência definida a priori e uma função de perda ou custo.

Por outro lado, os métodos determinísticos baseiam-se numa partição do espaço de atributos em regiões mutuamente excludentes que representam os domínios das classes e a definição destas áreas numa forma matemática.

O método sintático ou estrutural, baseia-se na descrição do padrão em forma estrutural. Cada padrão é descrito a partir de sub-padrões e estes sub-padrões por sua vez são formados por estruturas primárias.

A tabela 4.1., mostra a relação entre as duas metodologias citadas.

	Representação	Reconhecimento
Decisão teórica	Por vetores $X=(x_1,x_2,\dots x_k)$	Partição do espaço em regiões, obtendo-se regras de decisão.
Estrutural ou Sintática	Por símbolos formando - cadeias - árvores - grafos	Padrões são considerados formados por primitivas e relacionados por sentenças.

Tabela 4.1. Relações entre as metodologias e o modo de representação e reconhecimento de um padrão.

4.2. Método matemático ou técnica de decisão teórica

A técnica de decisão teórica é baseada na determinação de regras de decisão usando propriedades que permitem uma separação dos padrões em classes.

Seja:

$X = (x_1, x_2, \dots, x_k)$, um vetor coluna que representa um objeto ou figura, x_i representa o i -ésimo atributo da figura e K o número total de atributos. Os elementos de X assumem valores reais. Para uma aplicação com classes W_1, W_2, \dots, W_M , o problema básico nesta técnica consiste na geração de M funções de decisão $d_1(X), d_2(X), \dots, d_M(X)$, que, para qualquer padrão $X \in W_i$, $i=1,2,\dots,M$, satisfaçam a equação.

$$d_i(X) > d_j(X) \quad i=j ; j=1,2,3,\dots,M \quad (4.1)$$

Deste modo, o processo de classificação pode ser representado pelo diagrama da figura 4.4., onde cada bloco da esquerda representa o cálculo do valor $d_i(X)$ para $i=1,2,\dots,M$, e o bloco da direita representa a seleção do maior valor de d_i e a associação à classe i .




Fig. 4.4. Representação da classificação por um diagrama.

Dois métodos para a geração das funções de discriminação, denominados:

- Classificador por distância mínima, e
 - Classificador por função de discriminação linear
- são discutidos a seguir.

4.2.1. Classificador por distância mínima.

O classificador por distância mínima é um algoritmo de classificação eficiente e de fácil implementação. Usa como critério de classificação a distância entre o vetor definido pelos valores dos atributos extraídos do padrão a ser reconhecido e o conjunto de vetores obtidos da fase de aprendizado.

Teoria de classificação.

Assumindo que:

- Existe um sistema de medida e este produz uma descrição do padrão na forma de um vetor X , formado por K elementos.

$$X = (x_1, x_2, \dots, x_k)$$

- Existe um conjunto de Q -padrões de amostras rotuladas e sua correspondente associação às classes $W_1, W_2, W_3, \dots, W_M$

- Para cada classe é gerado um vetor P , cujos elementos representam a média dos valores dos atributos correspondentes às amostras rotuladas.

$$P_i = (\bar{m}_{i1}, \bar{m}_{i2}, \bar{m}_{i3}, \dots, \bar{m}_{ik})$$

$$\bar{m}_{ij} = \frac{1}{Q} \sum_{p=1}^Q m_{ijp} \quad (4.2)$$

$p=1, 2, \dots, q$
 $i=1, 2, \dots, M$

Então

- Existem M vetores de referência representados pelo símbolo P, onde P_i está associado à classe W_i

A classificação de um ponto arbitrário ou padrão X, com relação às classes existentes M, pelo classificador de distância mínima é definido por:

$$d_i = \left(\sum_{j=1}^k (P_{ij} - X_j)^2 \right)^{1/2} \quad \begin{matrix} i=1,2,3,\dots,M \\ j=1,2,3,\dots,k \end{matrix} \quad (4.3)$$

O classificador associa o padrão X à classe i, se a distância entre X e P_i é a menor dentre todas as distâncias obtidas. (valor mínimo)

$$X \in W$$

se

$$d_i \geq d_j \quad \text{para } i \neq j \quad ; \quad j=1,2,\dots,M$$

A equação 4.3. pode ser representada na seguinte forma:

$$d_i^2(X) = \sum_{j=1}^k m_{ij}^2 - 2 \sum_{j=1}^k m_{ij} x_j + \sum_{j=1}^k x_j^2 \quad (4.3.a)$$

que, por sua vez para efeito de comparação de distâncias, pode ser reduzida à seguinte forma:

$$d_i(X) = \sum_{j=1}^k m_{ij} - 2 \sum_{j=1}^k m_{ij} X_j \quad (4.4) \quad \text{(valor mínimo)}$$

Isto devido a que o valor de x é um valor constante que esta somado a todas as distâncias d.

A expressão anterior representa o valor mínimo da distância. O valor máximo para atender a equação 4.1. é:

$$d_i(\hat{X}) = \sum_{j=1}^k X_j P_{ij} - \sum_{j=1}^k P_{ij} \quad (4.5.) \quad \text{(valor máximo)}$$

Portanto, existirá um conjunto de funções de discriminação d_M, que permite associar o padrão de entrada X à classe i, se para todo i, i=1,2,...M e i≠j

$$d_i(X) > d_j(x)$$

Para o uso e facilidade no computador, definiremos o seguinte conceito de distância:

considerando que qualquer função de distância $d(x,y)$ deve satisfazer as seguintes condições:

$$\begin{aligned} d(x,x) &= 0 \\ d(x,y) &\geq 0 \quad x \neq y \\ d(x,y) &= d(y,x) \\ d(x,y) + d(y,z) &= d(x,z) \end{aligned}$$

pode-se definir distância como:

$$d_i = \sum_{j=1}^k |\bar{m}_{ij} - x_j| \quad (4.6)$$

Esta função demanda menor esforço de computação, do que a equação 4.3. e é de mais fácil implementação.

A equação 4.6., considera todos os atributos com igual peso na determinação da distância. Porém, isto não é satisfatório uma vez que alguns atributos podem ter maior importância na classificação do objeto.

Esta maior importância do atributo pode ser obtida se anteriormente ao cálculo da distância considera-se uma normalização dos atributos. /18/

Os seguintes métodos podem ser usados para se obter uma normalização dos atributos:

a) Normalização por valores máximos e mínimos.

O método consiste em obter os valores máximos e mínimos para os K atributos da amostra de treinamento, e determinar o valor de a_{ij} , definido por:

$$a_{ij} = \max (P_{1j} , P_{2j} , \dots , P_{Qj}) - \min (P_{1j} , P_{2j} , \dots , P_{Qj}) \quad (4.7)$$

portanto a variável normalizada será definida por:

$$x_{Nj} = x_j / a_{ij} \quad j=1,2,3,\dots,K$$

Considerando a normalização pelo método proposto a expressão 4.6., pode ser reescrita como:

$$d_i = \sum_{j=1}^k \left| \frac{\bar{m}_{ij} - x_j}{a_{ij}} \right| \quad i=1,2,\dots,M \quad (4.8)$$

b) Normalização pela variância.

Este método considera a variância dos K atributos das amostras de treinamento da classe i, obtendo-se um fator de ponderação

$$x_{n_{ij}} = x_{ij} / \sigma_{ij}$$

Assim, a expressão pode ser reescrita como:

$$d_i = \sum_{j=1}^k \left| \frac{\bar{m}_{ij} - x_j}{\sigma_{ij}} \right| \quad (4.9)$$

c) Normalização pelo valor médio.

Neste método, o valor médio \bar{m}_{ij} , é tomado como fator de ponderação e a equação 4.6. pode ser reescrita como:

$$d_i = \sum_{j=1}^k \left| \frac{\bar{m}_{ij} - x_j}{\bar{m}_{ij}} \right| \quad (4.10)$$

Deve-se observar que a utilização dos diferentes métodos propostos para ponderação ou normalização, podem acarretar na classificação de um mesmo padrão em diferentes classes. Portanto, a escolha do método de ponderação deve ser feita pelo usuário dentro de cada aplicação.

4.2.2. Classificação por função de discriminação linear.

O classificador por função de discriminação linear consiste na geração de funções que são uma combinação linear dos atributos medidos das amostras de treinamento. /19/

A equação de discriminação para um classificador linear é representada na forma:

$$d_i(X) = A_i X + C \quad (4.11)$$

onde A é o vetor coluna formado por a_1, a_2, \dots, a_n , e C é igual ao elemento a_{k+1}

$$d_i(X) = \sum_{j=1}^k a_{ij} x_j + a_{i,k+1} \quad (4.12)$$

A filosofia do classificador é definir uma superfície $S(x)$ que separa os padrões pertencentes a uma classe dos pertencentes às demais classes da aplicação. A função de discriminação linear é determinada na fase de aprendizado a partir das amostras rotuladas, ou seja, determinados os coeficientes a_i

Uma representação gráfica do classificador para o caso de duas classes é apresentada na figura 4.5. O gráfico desta figura é obtido a partir das amostras rotuladas de treinamento.




Fig. 4.5. Processo de classificação por função de discriminação linear para duas classes.

Na fase de classificação de um padrão, os valores dos atributos de X são substituídos na função de discriminação linear e se o resultado é positivo o padrão é associado à classe w_i , no caso contrário é associado à classe w_j .

$$\begin{aligned} x \in w_i & \quad \text{se } d(X) > 0 \\ x \in w_j & \quad \text{se } d(x) < 0 \end{aligned}$$

No caso de apenas duas classes é possível determinar graficamente uma função de discriminação linear aproximada. Para o caso de mais classes que implica na necessidade de se usar um maior número de atributos, a determinação dos coeficientes a deve ser feita analiticamente, obtendo-se M funções de discriminação que descrevem as M classes, sendo o critério de classificação o seguinte:

$$\begin{aligned} \text{se } d_i(X) > 0 & \quad x \in w_i \\ d_i(X) < 0 & \quad x \in \bar{w}_i \end{aligned} \quad i=1,2,\dots,M$$

Uma representação gráfica para o caso de 3 classes é apresentado na figura 4.6.




Fig. 4.6. Representação gráfica para a classificação de tres classes, usando dois atributos.

A determinação dos coeficientes a_i só é possível se as classes são linearmente separáveis pelos atributos escolhidos.

Para a obtenção dos valores a_i são utilizados algoritmos do tipo 'perceptron', os quais geram uma função de discriminação linear para cada classe. A determinação dos valores a_i é feita em forma iterativa até que se obtenha uma classificação para padrões rotulados e conseqüentemente a obtenção das funções de discriminação linear para as classes.

A determinação dos valores a_i que descrevem a função de discriminação linear é feito do seguinte modo:

A função de decisão é definida por:

$$d_i = B_i \cdot X$$

$$B = (b_{i1}, b_{i2}, \dots, b_{ik}, b_{i,k+1})$$

$$X = (x_1, x_2, x_3, \dots, x_k, 1)$$

O algoritmo considera que o vetor B_i inicialmente classifica a classe i .

- se para a n -ésima amostra

$$x \in w_i \quad \text{e} \quad d_i < d_j$$

será necessário ajustar o vetor B_i do seguinte modo:

$$B_{i+1} = B_i + D X \tag{4.13}$$

e os vetores B_j , $j=1,2,3,\dots,M$ $i \neq j$

$$B_{j+1} = B_j - D \cdot X \quad (4.14)$$

D valor constante positivo

4.2.3. Classificadores estatísticos.

Os classificadores estatísticos geram funções de discriminação, considerando propriedades estatísticas e procurando minimizar a possibilidade de classificação errada./19/

Sua utilização é possível quando as seguintes informações são disponíveis.

- A probabilidade a priori $p(w_i)$ de ocorrer um padrão X de uma das classes w_i
- Uma função de densidade de probabilidade condicional $p(x/w_i)$
- Uma função de perda ou custo $E(w_i, w_j)$ que define o custo da associação do padrão à classe w_i quando de fato ele pertence à classe w_j

Um classificador que considera as condições acima é denominado de Bayes ou ótimo, já que minimiza as perdas totais esperadas na classificação.

A função de perda condicional, que supõe que uma decisão D classifica o padrão na classe w_j , dado que ele pertence à classe w_i é

$$r(x) = \sum_{i=1}^M E(w_i, w_j) p(x/w_i) \quad (4.15)$$

(p/w_i) = probabilidade de x pertencer à classe w_i

Para um conjunto de probabilidades a priori $P=(p(w_1), p(w_2), \dots, p(w_M))$, a perda média de uma decisão D, sob todas as classes é

$$r(x) = \frac{1}{P(x)} \sum_{i=1}^k E(w_i, w_j) p(x/w_i) p(w_i) \quad (4.16)$$

$i=1,2,\dots,M$

O classificador escolhe a decisão que minimiza a perda média esperada, obtendo com isto que a decisão tomada tenha um custo menor que qualquer outra decisão D.

A utilização da equação 4.16 permite uma classificação ótima para qualquer situação, porém esta relação é difícil de aplicação devido:

- $p(X/w_i)$ e $p(w_i)$ não são sempre conhecidas
- $E(w_i, w_j)$ é difícil de avaliar realisticamente

Portanto, uma implementação prática do classificador de Bayes é:

- Assumir que não existe perda associada com uma classificação correta e uma perda igual para qualquer classificação errada.

então

$$E(w_i, w_j) \begin{cases} = 0 & i = j \\ = 1 & i \neq j \end{cases} \quad i=1,2,\dots,M \quad (4.17)$$

e o classificador de Bayes resulta na seleção da classe i que satisfaz

$$p(w_i) p(X/w_i) > p(w_j) p(X, w_j) \quad (4.18)$$

É possível a obtenção de um classificador básico a partir da expressão 4.18., assumindo que a probabilidade a priori $p(w_i)$ é igual para todas as classes, obtendo-se a seguinte função de classificação.

$$\begin{aligned} g_i(X) &= p(X/w_i) \\ \text{se } p(X/w_i) &> p(X/w_j) \quad i \neq j \\ x &\in w_i \quad i=1,2,\dots,M \end{aligned} \quad (4.19)$$

A associação do padrão à classe i é determinado pelo máximo valor da função $g_i(X)$, derivada da densidade de probabilidade condicional. O classificador deste tipo é denominado classificador por máxima probabilidade (Likelihood) ou máxima verossimilhança.

A figura 4.7. mostra a densidade de probabilidade para duas classes e a figura 4.8. um exemplo de um classificador do tipo citado acima.




Fig. 4.7. Função de densidade de probabilidade.

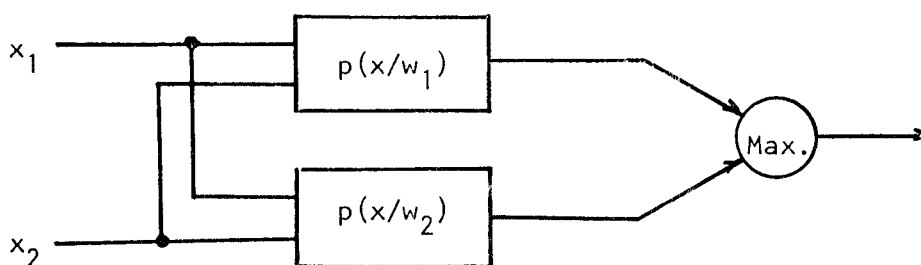


Fig. 4.8. Classificação por máxima verossimilhança.

4.3. Considerações sobre as amostras para treinamento e desempenho do classificador.

Como observado dos itens anteriores, é necessária uma fase de aprendizado na qual são geradas as regras de classificação a partir de amostras rotuladas.

A seguir apresentam-se algumas considerações sobre as amostras de treinamento e a avaliação da efetividade do classificador obtido.

4.3.1. Considerações sobre as amostras de treinamento.

As amostras de treinamento usadas para definir o classificador ou regras de decisão devem satisfazer os seguintes requisitos.

- As amostras de treinamento rotuladas a usar, devem ser representativas da aplicação, já que a inclusão de amostras distorcidas levam à geração de regras de classificação sub-ótimas, com conseqüente diminuição do desempenho do classificador.

- O conjunto de amostras de treinamento deve ser o maior possível com a finalidade de prover a cobertura máxima de padrões da mesma classe.
- Das amostras de treinamento deve ser possível a extração dos atributos mais significativos.

4.3.2. Considerações sobre desempenho do classificador.

A avaliação do desempenho do classificador, do mesmo modo que a geração das regras de decisão é feita a partir de amostras rotuladas. As condições para a avaliação do desempenho do classificador são:

- A validação da regra de decisão deve basear-se no mínimo erro. É suposto que os valores de medida de desempenho obtidos na fase de validação correspondem ao desempenho do classificador.
- Não se deve usar para a validação o mesmo conjunto de padrões rotulados que foram utilizados na fase de aprendizado, neste caso o resultado obtido no desempenho do classificador leva a 100% de reconhecimento, resultando num valor incorreto para a medida do desempenho. Deve-se então separar o conjunto de padrões rotulados em amostras para gerar a regra de classificação e amostras para a estimação do desempenho do classificador.
- Se o desempenho do classificador não é o desejado, deverão ser geradas novas regras de decisão considerando-se atributos mais representativos.

V FUNCIONAMENTO DO SISTEMA DE RECONHECIMENTO E UMA APLICAÇÃO.

Nos capítulos anteriores foram apresentadas as diferentes etapas de um sistema de reconhecimento para a classificação de uma figura apresentada na entrada do sistema.

Neste capítulo são discutidas as características globais de um sistema de reconhecimento e são feitas considerações para uma aplicação.

5.1. Funcionamento do sistema.

Algoritmo de processamento.

Uma imagem é apresentada a um sistema de aquisição com diferentes níveis de luminância, e o problema consiste no reconhecimento das figuras que formam a imagem.

A aquisição da imagem pode ser feita usando uma câmera vidicon, um arranjo de diodos, ou ainda um tablet. Para a câmera de vidicon é necessária uma conversão analógica-digital, resultando uma discretização da imagem em diferentes níveis de cinza; para os demais dispositivos a discretização é obtida com apenas dois valores que indicam a presença ou ausência de luz.

Em muitas etapas segue-se uma etapa de filtragem e melhoramento da imagem, como por exemplo, realçamento, restauração, redução do ruído, etc.

Nas três etapas seguintes são realizadas a segmentação, que consiste na separação da cena em figuras isoladas, extração de atributos que consiste na medida de características da figura e classificação que consiste na associação de figuras a uma classe da aplicação.

A segmentação de uma cena pode ser feita com as técnicas discutidas no capítulo 2, assim, a técnica de segmentação por limiar é aplicável em cenas com diferentes níveis de cinza e a escolha apropriada de um valor de limiar permite uma separação ideal entre figuras e fundo da cena ou mesmo entre figuras.

Para a segmentação de cenas que possuem figuras representadas por área é necessário a obtenção das bordas destas figuras, e neste caso deve-se usar as técnicas de detecção de

borda.

Em casos de figuras representadas por contorno e que possuam este contorno com largura maior de que um pixel, deve-se aplicar a técnica de enfraquecimento.

Após a segmentação das figuras por limiar, embora as figuras estejam isoladas, elas permanecem na forma de uma matriz e para o processamento na fase de extração de atributos é necessário o armazenamento de cada figura em forma individual em N arquivos que representam as N figuras da cena.

A geração destes arquivos representam a finalização do processo de segmentação e determinam o começo do processo de extração de atributos.

Nesta fase são extraídos os atributos que interessam para a classificação e que foram definidos na etapa de aprendizado.

Passa-se à fase de classificação, a partir de regras geradas na etapa de aprendizado. Estas regras podem ser baseadas em métodos matemáticos que podem ser determinísticos ou estatísticos, ou em métodos estruturais.


Nos métodos matemáticos determinísticos usam-se classificadores como o de mínima distância ou geração de funções lineares. A utilização de uma árvore binária onde cada nó representa uma regra de decisão, e cada folha uma classe da aplicação, permite a utilização de um menor número de regras de decisão, com um menor tempo de processamento.

5.2. Uma aplicação em engenharia.


5.2.1. Introdução.

Muitas são as aplicações de reconhecimento de padrões em engenharia, em especial pode-se citar a utilização deste sistema como auxílio a 'entrada de dados' num sistema de simulação de circuitos digitais, ou em sistema de produção automática de documentação a partir de desenhos manuais. /20/


A figura 5.1. mostra o diagrama de blocos para sistemas de auxílio como o descrito no parágrafo anterior e os resultados obtidos do seu uso.





a)



b)



2)



IN	1.1
	1.2
OUT.....	2.6
	3.4
	4.9
Ligações	1.3--3.3
	2.4--4.8
	3.4--4.7
	1.2--2.5

Fig. 5.1. Aplicação do sistema de reconhecimento de padrões para entrada de dados nos exemplos citados.

5.2.2. Um sistema de entrada de dados para um simulador digital.

Esta aplicação consiste no reconhecimento de figuras de uso comum em projeto de circuitos digitais.

São definidas as seguintes classe para a aplicação.

Classe 1 : AND
Classe 2 : OR
Classe 3 : N-INV
Classe 4 : NÓ
Classe 5 : NAND
Classe 6 : NOR
Classe 7 : INV

O problema a ser abordado é dividido em duas fases:

- O reconhecimento dos componentes
- A determinação das ligações entre eles

O algoritmo utilizado possui as seguintes etapas.

5.2.2.1. Aquisição e a separação das cenas.

1.- Aquisição da cena

Dada a impossibilidade do uso de uma câmera de televisão em nosso laboratório, as cenas são introduzidas no computador pelo teclado, sendo cada pixel representado por um número inteiro. Pixels correspondentes ao fundo da cena, componentes e ligações foram representados pelos valores zero, um e dois respectivamente.

2.- Segmentação.

Usando a técnica de segmentação por limiar obtém-se duas cenas que contem:

- a.1. As figuras a classificar (componentes).
- a.2. As ligações entre componentes.

5.2.2.2. Segmentação e extração de atributos da cena que contém os componentes.

1.1. Como as figuras estão representadas por sua região, é feita a detecção de borda utilizando-se máscaras de Sobel.

1.2. Armazena-se as figuras utilizando-se a regra da cadeia

- 1.3. Para facilitar a extração de alguns atributos a figura é armazenada tal qual pelo método do traço.
2. São medidos os atributos, definidos na fase de aprendizado, que são necessários para a classificação. (circunferência, fator C, função geradora de momentos, área, perímetro, centro de gravidade, número de Euler modificado, ângulo de orientação).

5.2.2.3. Extração de atributos para a geração das regras de decisão.

A seguir são apresentados os valores dos atributos medidos das amostras rotuladas, com a finalidade da definição de uma regra de decisão. Os atributos medidos correspondem àqueles descritos no capítulo 3 e são:

- Área
- Perímetro
- Valores de N_2 e N_6
- Circularidade
- Fator G
- Função de momentos

As tabelas 5.1.1. a 5.1.6. apresentam para as classes 1,2 e 3, definidas na aplicação, os valores de área, contorno, N_2 , N_6 , perímetro, circularidade, fator G, FM_1 , FM_2 , FM_3 , FM_4 , obtidos das amostras apresentadas na figura 5.2.

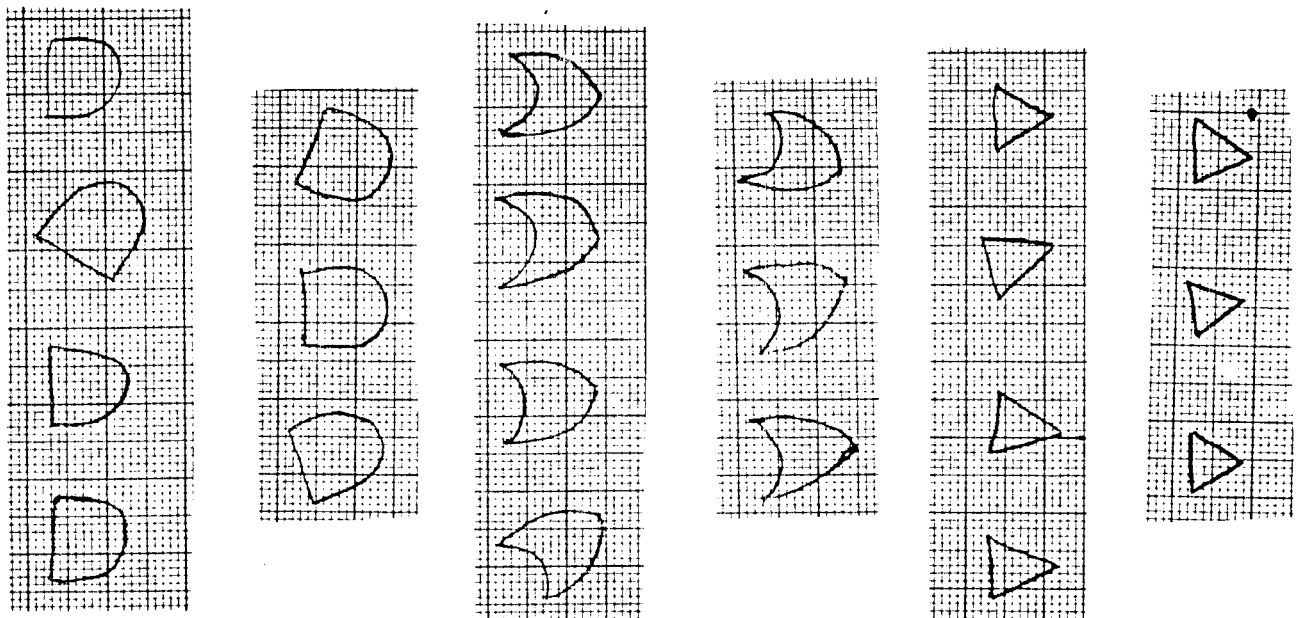


Fig. 5.2. Algumas das amostras usadas para a extração dos atributos indicados nas Tabelas 5.1.

	Área	Cont	N ₆	N ₂	Perim. Circular.	Fator G.	
ANDO	88	38	11	7	42	1.595163	484
AND1	87	39	15	10	44	1.770823	473
AND2	74	37	16	11	42	1.896900	608
AND3	75	34	9	5	38	1.532128	351
AND4	87	36	10	6	40	1.463490	302
AND5	93	38	9	5	42	1.509401	540
AND6	84	37	12	7	42	1.671123	441
AND7	87	36	9	5	40	1.463490	473
AND8	89	39	11	9	41	1.503027	495
AND9	111	42	12	8	46	1.516987	484

Tabela 5.1.1. Medidas dos atributos de padrões classe 1 (AND)

	Área	Cont.	N ₆	N ₂	Perim. Circular.	Fator G	
ORO	64	38	16	10	44	2.407213	455
OR1	60	38	16	12	42	2.339572	225
OR2	59	37	20	13	44	2.611214	386
OR3	71	39	12	9	42	1.977103	560
OR4	58	36	16	9	43	2.536869	373
OR5	57	39	19	12	46	2.954132	812
OR6	78	45	16	13	48	2.350591	380
OR7	81	45	20	16	49	2.358828	729
OR8	84	46	22	16	52	2.561631	784
OR9	84	46	20	14	52	2.561631	784

Tabela 5.1.2. Medidas dos atributos de padrões classe 2 (OR)

	Área	Cont.	N ₆	N ₂	Perim. Circular.	Fator G	
INVO	34	25	8	7	28	1.582184	72
INV1	32	23	11	6	28	1.949644	64
INV2	35	26	14	8	32	2.328204	76
INV3	38	26	14	8	32	2.144398	160
INV4	37	28	13	7	34	2.486252	85
INV5	33	24	13	7	30	2.170290	121
INV6	41	29	12	7	34	2.243691	186
INV7	41	29	15	8	36	2.515419	105
INV8	31	26	17	8	35	3.144586	106
INV9	47	32	14	9	37	2.317900	138

Tabela 5.1.3. Medidas dos atributos de padrões classe 3 (N-INV)

	F.Mom1	F.Mom2	F.Mom3	F.Mom4
ANDO	.165857	2228E-7	4932E-7	1962E-7
AND1	.164537	6979E-7	2001E-7	2626E-7
AND2	.165501	1321E-7	2937E-7	2519E-7
AND3	.167135	3326E-7	7118E-7	3920E-7
AND4	.162891	5669E-7	1795E-7	2134E-7
AND5	.168773	1438E-6	2476E-7	3424E-7
AND6	.167865	7120E-8	8237E-7	3338E-7
AND7	.166648	7732E-7	4598E-7	6834E-6
AND8	.165063	7919E-7	1836E-7	5351E-7
AND9	.163247	1825E-7	3411E-7	2549E-7

Tabela 5.1.4. Medidas dos atributos de padrões classe 1 (AND)

	F.Mom1	F.Mom2	F.Mom3	F.Mom4
ORO	.194805	1270E-6	2700E-6	1253E-5
OR1	.195773	8121E-7	2977E-6	9568E-6
OR2	.190360	7559E-7	2654E-6	9092E-6
OR3	.187343	9118E-7	2683E-6	6204E-6
OR4	.189061	3128E-6	1694E-6	2972E-6
OR5	.214263	2319E-6	3904E-6	2553E-5
OR6	.205788	1776E-6	3644E-6	2719E-5
OR7	.183670	9940E-8	1703E-6	5559E-6
OR8	.191674	2745E-7	2431E-6	1698E-5
OR9	.206847	1426E-6	3699E-6	3515E-5

Tabela 5.1.5. Medidas dos atributos de padrões Classe 2 (OR)

	F.Mom1	F.Mom2	F.Mom3	F.Mom4
INVO	.195222	1324E-6	4720E-6	8654E-7
INV1	.178100	7149E-7	2391E-6	8604E-7
INV2	.187755	7810E-7	3594E-6	6930E-7
INV3	.185559	1430E-6	3060E-6	1362E-6
INV4	.204450	1372E-6	5820E-6	1488E-7
INV5	.185936	2449E-7	3749E-6	3502E-7
INV6	.194861	1335E-6	4445E-6	2518E-6
INV7	.202783	1496E-6	6204E-6	5130E-6
INV8	.204760	2572E-7	6025E-6	3357E-7
INV9	.195487	8101E-7	4763E-6	1978E-6

Tabela 5.1.6. Medidas dos atributos de padrões classe 3 (N-INV)

A partir dos atributos das amostras (Q=10) de cada classe (Tabelas 5.1) são obtidos os valores de valor médio, variância, valor máximo e valor mínimo dos atributos de cada classe, os quais são apresentados nas Tabelas 5.2. e são utilizados na ponderação dos atributos na fase de classificação.

	Variância	Valor médio	Val. Max.	Val. Min
Circul.	.144770	1.52450	1.89700	1.46300
FatorG	87.1300	478.500	608.000	302.000
F.Mom1	1908E-6	1656E-4	1687E-4	1628E-4
F.Mom2	4221E-7	4497E-7	1438E-6	7120E-8
F.Mom3	2266E-7	3174E-7	8237E-7	1795E-7
F.Mom4	2065E-6	3007E-7	6834E-6	1962E-7

Tabela 5.2.1 Valores de variância, valor médio, valor máximo e mínimo para cada atributo da classe 1 (AND)

	Variância	Valor médio	Val. Max.	Val. Min.
Circul.	.250760	2.47200	2.95410	1.97710
FatorG	213.970	507.500	812.000	225.000
F.Mom1	9855E-6	1932E-4	2143E-4	1836E-4
F.Mom2	9307E-7	1090E-6	3127E-6	9940E-8
F.Mom3	7730E-7	2691E-6	3904E-6	1694E-6
F.Mom4	7699E-5	1105E-5	2553E-4	2972E-6

Tabela 5.2.2. Valores de variância, valor médio, valor máximo e mínimo para cada atributo da classe 2 (OR)

	Variância	Valor Médio	Val. Max.	Val. Min.
Circul.	.405020	2.28080	3.14460	1.58220
FatorG	40.2020	105.500	186.000	64.0000
F.Mom1	9018E-6	1950E-4	2047E-4	1781E-4
F.Mom2	4794E-7	1067E-6	1496E-6	2449E-7
F.Mom3	1294E-6	4582E-6	6204E-6	2390E-7
F.Mom4	1582E-6	8604E-7	5130E-6	1488E-7

Tabela 5.2.3. Valores de variância, valor médio, valor máximo e valor mínimo para cada atributo da classe 3.(INV)




Fig. 5.3 Gráfico dos atributos Fator G e FM₂ para as classes OR e N-INV.




Fig. 5.4. Gráfico dos atributos FM₁ e FM₄ para as classes OR e AND.




Fig. 5.5. Gráfico dos atributos Circularidade e Fator G para as classes OR e AND.




Fig. 5.6. Gráfico dos atributos Circularidade e FM1 para as classes OR e N-INV.




Fig. 5.7. Gráfico dos atributos FM_2 e FM_3 para as classes OR e AND.




Fig. 5.8. Gráfico dos atributos Fator G e Circularidade Para as classe N-INV e OR.




Fig. 5.9. Gráfico dos atributos Circularidade e FM₁ para as classes OR e AND.




Fig. 5.10. Gráfico dos atributos Fator G e FM₁ para as


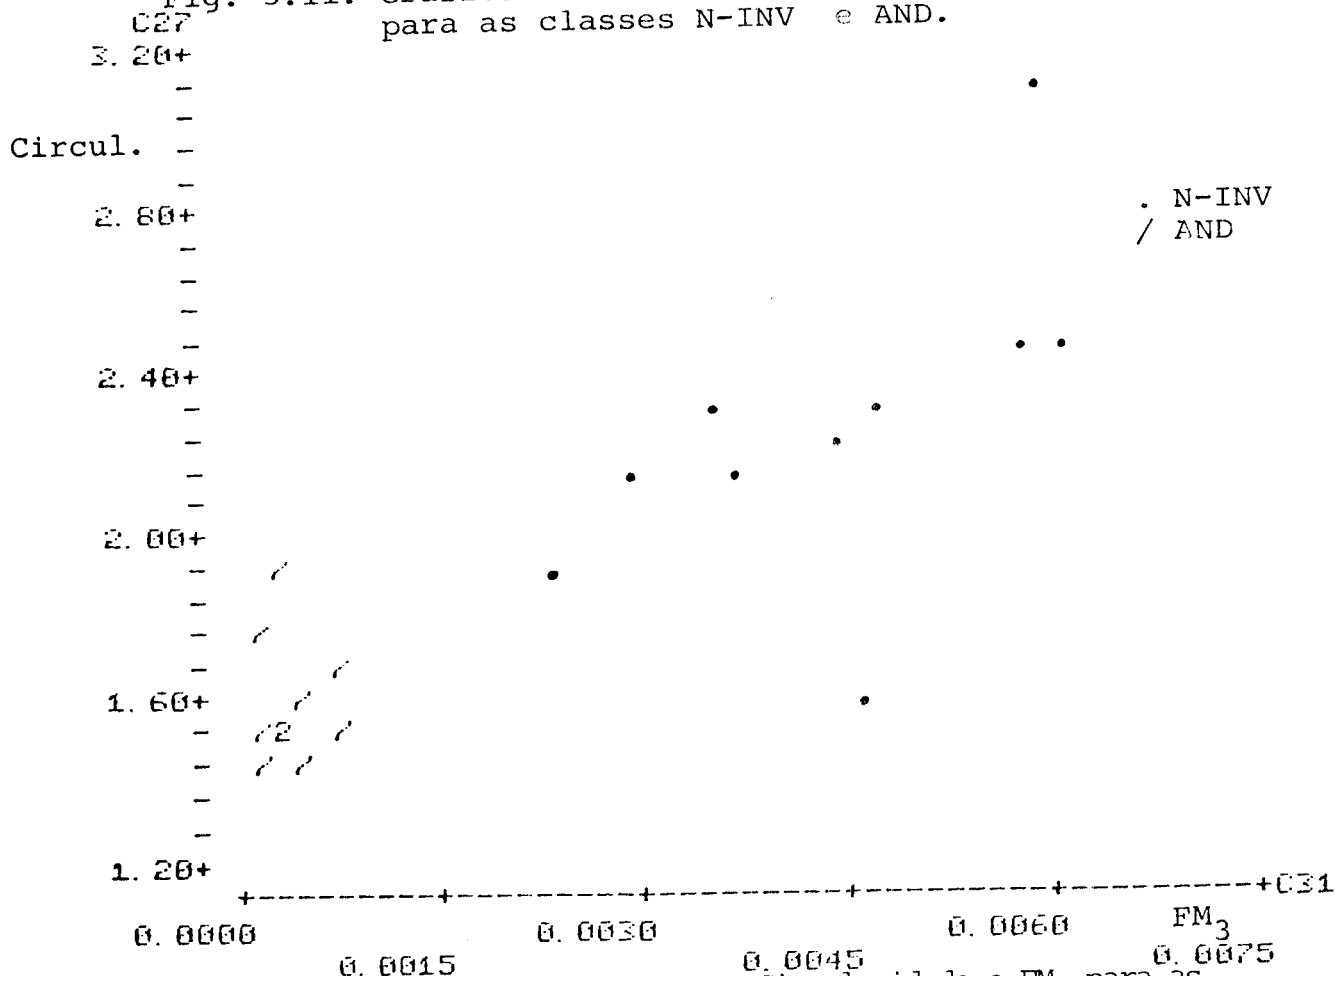


Fig. 5.11. Gráfico dos atributos Circularidade e FM₂ para as classes N-INV e AND.



Os gráficos apresentados mostram algumas das possibilidades de combinação de atributos para a determinação das regras de decisão.

Nota-se dos gráficos das figuras 5.4, 5.5, 5.7, 5.9, 5.10, 5.12, que existe uma boa separação das classes a partir dos atributos tomados, enquanto que nos demais gráficos a separação não é suficiente para a discriminação entre regiões. Portanto, a utilização dos gráficos com boa separação entre classe permite a determinação dos atributos a serem utilizados na classificação, bem como as regras de decisão.

Para a classificação num primeiro nível utiliza-se o método da árvore binária, deste modo é suficiente o uso de 1 atributo para a decisão em cada ramo de árvore. A separação entre as classes 1, 2, 3, 4 e 5, 6, 7, é obtida através da determinação da existência de cruzamentos nos contornos da figura.

Obtidos os dois primeiros grupos, a separação das classes de cada grupo é obtida através da utilização dos demais atributos, e usando como função de classificação a mínima distância. A figura 5.11. mostra o diagrama em blocos dos passos de classificação.

Deve-se ressaltar, que optou-se aqui pelo uso do classificador por mínima distância como exemplificação, e que o processo completo de classificação poderia ser executado através do uso de uma árvore binária de decisões.

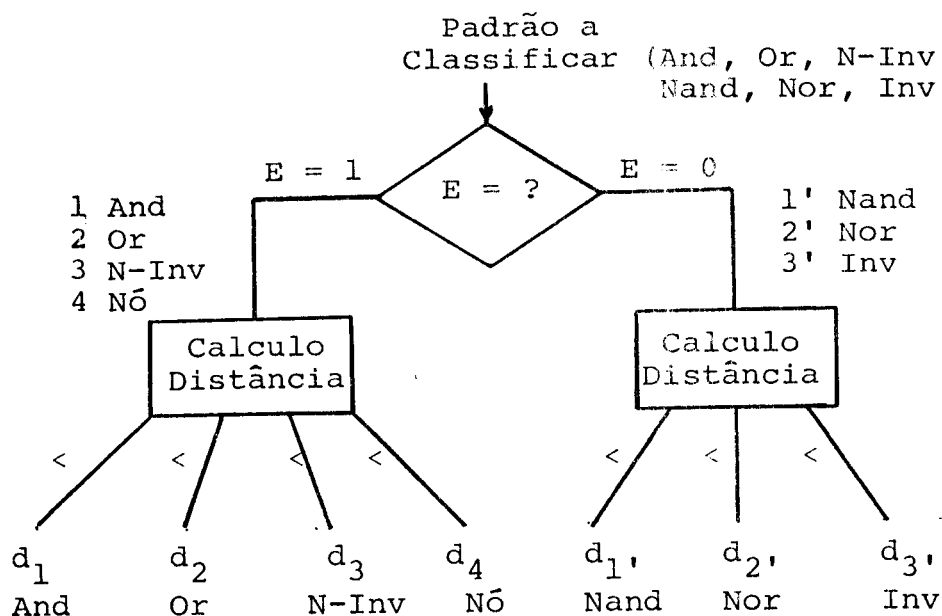



Fig. 5.11. Representação do esquema de classificação.

5.2.2.4. Classificação de um elemento.

Os resultados a seguir referem-se a classificação de alguns padrões apresentados ao sistema de reconhecimento.



Padrões a serem apresentados para classificação.

P A D R Ã O 1
AREN CONT NP2 RP6 PERIM CIRC
79 36 12 8 40 1.611692

VALOR FATOR α = 0.490.0000

AREA= 79

C. G. X. = 6.75 C. G. Y. = 8.77

FM1= 0.1645306
FM2= 0.0000518
FM3= 0.0005614
FM4= 0.0000593

VALORES DE DISTANCIA DO PADRÃO A CADA CLASSE

CLASSE 1 DISTANCIA = 1.11297

CLASSE 2 DISTANCIA = 1.797

CLASSE 3 DISTANCIA = 2.68771

O PADRÃO DE ENTRADA É ASSOCIADO A CLASSE 1

DISTANCIA MINIMA OBTIDA DO PADRÃO CLASSIFICADO= 1.11297

P A D R Ã O 2

AREA	CONT	NP2	NP6	PERIM	CIRC
47	26	18	11	43	3.130604

VALOR FATOR G = 052.0000

AREA= 47

C. G. X. = 6.64 C. G. Y. = 7.34

FM1= 0.2124963

FM2= 0.0007123

FM3= 0.0067065

FM4= 0.0112116

VALORES DE DISTANCIA DO PADRAO A CADA CLASSE

CLASSE 1 DISTANCIA = 21.61928

CLASSE 2 DISTANCIA = 1.945411

CLASSE 3 DISTANCIA = 5.157732

O PADRAO DE ENTRADA E ASSOCIADO A CLASSE 2

DISTANCIA MINIMA OBTIDA DO PADRAO CLASSIFICADO= 1.945411

P A D R Ã O 3

AREA	CONT	NP2	NP6	PERIM	CIRC
81	45	20	16	49	2.058828

VALOR FATOR G = 729.0000

AREA= 81

C. G. X. = 9.86 C. G. Y. = 7.59

FM1= 0.1836704

FM2= 0.0000094

FM3= 0.0017026

FM4= 0.0055597

VALORES DE DISTANCIA DO PADRAO A CADA CLASSE

CLASSE 1 DISTANCIA = 5.543601

CLASSE 2 DISTANCIA = 0.8991940

CLASSE 3 DISTANCIA = 6.630936

O PADRAO DE ENTRADA E ASSOCIADO A CLASSE 2

DISTANCIA MINIMA OBTIDA DO PADRAO CLASSIFICADO= 0.8991940

P A D R ã O 4
AREA CONT NP2 NP6 PERIM CIRC
34 25 8 7 26 1.582184

VALOR FATOR G = 72.00000

AREA= 34

C. G. X. = 4.82 C. G. Y. = 5.09

FM1= 0.1952219
FM2= 0.0013241
FM3= 0.0047203
FM4= 0.0008654

VALORES DE DISTANCIA DO PADRAO A CADA CLASSE

CLASSE 1 DISTANCIA = 14.94736
CLASSE 2 DISTANCIA = 1.982049
CLASSE 3 DISTANCIA = 0.6547698

O PADRAO DE ENTRADA E ASSOCIADO A CLASSE 3

DISTANCIA MINIMA OBTIDA DO PADRAO CLASSIFICADO= 0.6547698

5.2.2.5. Determinação das ligações.

No item anterior foram determinados os componentes que formam o circuito lógico, faltando determinar a associação existente entre eles, e que é determinada através das ligações. As conexões entre componentes podem ser dos seguintes tipos: ligações de entrada, ligações de saída e ligações entre portas.

Na fase de segmentação, pela aplicação da técnica do limiar, foram obtidas duas cenas, uma correspondente aos componentes e a outra ao conjunto de ligações.

A cena correspondente aos componentes foi tratada como já descrito, e a cada arquivo está associado uma porta com o conjunto de atributos que definem a mesma. †.

A cena que contém as conexões deve ser agora tratada de modo a se determinar os seus segmentos, os quais correspondem as ligações do circuito. Assim, também as ligações serão representadas por arquivos com idêntica formulação da regra da cadeia.

A segmentação das conexões é obtida pelo seguinte algoritmo:

- 1.- Faça uma varredura, a partir da linha 1, na cena que decorre as ligações. Ache o primeiro elemento da cena e crie um arquivo para este elemento.
- 2.- Criado o arquivo armazene a coordenada inicial, e a sequência de elementos da cadeia até alcançar seu elemento final e a coordenada do elemento final. A cada elemento armazenado da cadeia, eliminar o elemento da tela. No caso da ocorrência de um cruzamento entre ligações deve-se considerar como direção a seguir a mesma direção utilizada para atingir-se o ponto. Após a determinação do ponto posterior, restituir o ponto de cruzamento para permitir o tratamento da outra conexão.
- 3.- Volte ao ponto 1, até que todas as conexões tenham sido arquivadas.

Para a determinação das ligações entre componentes os seguintes atributos são utilizados:

- Centro de gravidade da figura
- Distância maior que existe do centro de gravidade ao contorno do objeto.
- Orientação da figura

O seguinte algoritmo é usado na determinação das conexões.

- 1.- Do arquivo de conexões obtenha os valores de todas as coordenadas de início e fim do segmento formando uma lista.
- 2.- Obtenha para os elementos o centro de gravidade e a distância do centro de gravidade ao contorno e forme uma tabela com os mesmos.
- 3.- Faça uma busca na tabela de elementos e identifique um nó.
 - 3.1. Com a coordenada do C.G. do nó determine um elemento na tabela de conexão que corresponda ao nó.
 - 3.2. Verifique na tabela de elementos se a outra coordenada corresponde a um elemento da saída, usando a Tabela 5.3.

- 3.3. Se é elemento de saída, associe o nó a este elemento. Elimine o par de coordenadas correspondente da tabela de conexão, e vá ao passo 3.4. Se não é elemento de saída vá ao passo 3.1.
- 3.4. Volte ao passo 3, até que todos os nós tenham sido associados a elementos.
- 4.- Tome o primeiro par de coordenadas da tabela de ligações e determine, a partir do círculo formado pelo centro de gravidade e distância do centro de gravidade à borda, os elementos associados a esta ligação.
- 4.1. Usando a Tabela 5.3. determine o elemento correspondente a entrada e saída.
Se o elemento é um nó, a associação é imediata, correspondendo à saída do elemento definido para o nó durante o passo 3.
- 4.2. Se apenas uma das coordenadas foi associada ao elemento, a outra corresponde a entrada ou saída externa do circuito, e sua característica é determinada pela outra extremidade.
- 4.3. Elimine o par de coordenadas da tabela.
- 4.4. Volte ao passo 4, enquanto existirem elementos na tabela de ligações.

Orientação	$X_L > X_G$	$X_L < X_G$	$Y_L > Y_G$	$Y_L < Y_G$
0°	Out	In		
90°			In	Out
180°	In	Out		
270°		Out	In	

Tabela 5.3. Determinação para entrada e saída de portas.

VI CONCLUSÕES

Foram estudadas e discutidas técnicas de reconhecimento de padrões; e uma aplicação destas técnicas à classificação de portas lógicas e conexões de diagramas lógicas foi desenvolvida.

Dos resultados obtidos para a aplicação desenvolvida conclui-se que a escolha dos atributos permitiu a classificação adequada dos padrões. Em casos em que a classificação correta não foi obtida a incorporação de novos atributos foi necessária.

Para uma maior abrangência da aplicação deveriam ser incluídas novas classes para descrição de outros símbolos lógicos, tais como Flip-Flop, Contadores, etc, bem como a possibilidade de reconhecimento de caracteres alfanuméricos para permitir a identificação de componentes e ligações.

No trabalho não são discutidas as condições de melhoramento do sinal considerando que o mesmo é obtido de um ambiente de características controladas. Técnicas de filtragem, realçamento, etc. devem ser usadas em imagens obtidas de ambientes que não possuam as características citadas.

O trabalho desenvolvido pode ser usado em outras aplicações, dado que qualquer reconhecimento baseia-se nos mesmos princípios, variando apenas os atributos tomados para definição das regras de decisão. Uma área potencial para aplicação do estudo desenvolvido é a de visão de robôs.

Sugerem-se os seguintes temas de pesquisa como seqüência deste trabalho:

- Implementação do sistema de entrada de dados com uso de uma câmera de TV;

- Desenvolvimento de sistemas multi-microprocessadores para aplicações de reconhecimento em tempo real;

- Reconhecimento em robótica.

BIBLIOGRAFIA

- /1/ R.C.Gonzalez and R.Safabakhsh, "Computer Vision Techniques for Industrial Applications and Robot Control," Computer, December 1982, 17-32.
- /2/ A.Rosenfeld and A.C.Kak, Digital Picture Processing, Academic Press, N.Y., 1976.
- /3/ I.E.Abdou and W.K.Pratt, "Quantitative Design and Evaluation of Enhancement/Thresholding Edge Detectors," Proceeding of the IEEE, Vol.67, No5, May 1979.
- /4/ G.P.Robinson, "Edge Detection by Compass Gradient Mask," CGIP., 6, 492-501 (1977).
- /5/ J.S.Weszka, "A Survey of Threshold Selection Techniques," CGIP., 7, 259-265 (1978).
- /6/ R.Stefanelli and R.Rosenfeld, "Some Parallel Thinning Algorithms for Digital Pictures," JACM, 18, 255-264 (1971).
- /7/ K.Castleman, Digital Image Processing, Prentice-Hall, N.J, 1979.
- /8/ R.O.Duda and P.E.Hart, Pattern Classification and Scene Analysis, John Wiley & Sons, Inc., N.Y., 1973.
- /9/ Mascarenhas N.D.A., "Processamento de Imagens, Classificação de Padrões e Visão Robótica," Tutoriais CONAI 1983.
- /10/ M.D.Levine, "Feature Extraction: A Survey," Proceeding of the IEEE, V.57, No8, August 1969, 1391-1407.
- /11/ Z.Kulpa, "Area and Perimeter Measurement of Blobs in Discrete Binary Picture," CGIP., 6, 434-451 (1977).
- /12/ H.Wechsler, "An New and Fast Algorithm for Estimating the Perimeter of Objects for Industrial Vision Tasks," CGIP., 17, 375-385 (1985).
- /13/ R.Y.Wong, "Scene Matching with Invariant Moments," CGIP., 8, 16-24 (1978).
- /14/ M.Hu, "Visual Pattern Recognition by Moment Invariant," IRE Trans. On Inf. Theory, IT-8, February 1972.
- /15/ I.T.Young, J.E.Walker and J.E.Bowie, "An Analysis Technique for Biological Shape," Information and Control 25, 357-370 (1974).
- /16/ P.E.Danielson, "A New Shape Factor," CGIP., 7, 292-299, 1978.
- /17/ D.H.Ballard and C.M.Brown, Computer Vision, Prentice-Hall, 1982.
- /18/ W.Meisel, Computer-Oriented Approaches to Pattern Recognition, Academic Press, New York, 1972.
- /19/ J.T.Tou and R.C.Gonzalez, Pattern Recognition Principles, Addison-Wesley, Mass., 1974.
- /20/ W.C.Lin and J.H.Pun, "Machine Recognition and Plotting of Hand-Sketched Line Figures," IEEE SMC-8(1), 52, 1978.