



Universidade Estadual de Campinas  
Faculdade de Engenharia Elétrica e de Computação  
Departamento de Engenharia de Computação e  
Automação Industrial



# ABORDAGEM NEURO-GENÉTICA PARA RECUPERAÇÃO DE PADRÕES. CASO DE ESTUDO: RECONHECIMENTO DE GESTOS EM AMBIENTES INTELIGENTES

**Autora: Ana Beatriz Alvarez Mamani**

Orientador: Prof. Dr. José Raimundo de Oliveira

**Tese de Doutorado** apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Engenharia de Computação.

## Banca Examinadora

Prof. Dr. José Raimundo de Oliveira (presidente) — DCA/FEEC/UNICAMP

Prof. Dr. André Ferreira — CT/UFES

Prof. Dr. Maurício Araújo Dias — DMEC/FCT/UNESP

Prof. Dr. Marconi Kolm Madrid — DSCE/FEEC/UNICAMP

Prof. Dr. Yuzo Iano — DECOM/FEEC/UNICAMP

Campinas – SP  
27 de Outubro de 2011

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

M31a Mamani, Ana Beatriz Alvarez  
Abordagem neuro-genética para recuperação de padrões. caso de estudo: reconhecimento de gestos em ambientes inteligentes / Ana Beatriz Alvarez Mamani. --Campinas, SP: [s.n.], 2011.

Orientador: José Raimundo de Oliveira.  
Tese de Doutorado - Universidade Estadual de Campinas,  
Faculdade de Engenharia Elétrica e de Computação.

1. Redes neurais híbridas. 2. Algoritmos genéticos. 3. Reconhecimento de padrões. 4. Interação homem-máquina. I. Oliveira, José Raimundo de. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

Título em Inglês: Neural-genetic approach for patterns recall. case of study: gesture recognition in intelligent environments

Palavras-chave em Inglês: Hybrid neural networks, Genetic algorithms, Pattern ecognition, Human-machine interaction

Área de concentração: Engenharia de Computação

Titulação: Doutor em Engenharia Elétrica

Banca examinadora: André Ferreira, Maurício Araújo Dias, Marconi Kolm Madrid, Yuzo Iano

Data da defesa: 27/10/2011

Programa de Pós Graduação: Engenharia Elétrica

## COMISSÃO JULGADORA - TESE DE DOUTORADO

**Candidata:** Ana Beatriz Alvarez Mamani

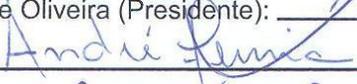
**Data da Defesa:** 27 de outubro de 2011

**Título da Tese:** "Abordagem Neuro-Genética para Recuperação de Padrões. Caso de estudo: Reconhecimento de Gestos em Ambientes Inteligentes"

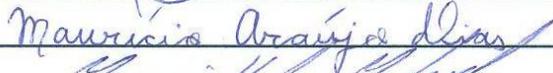
Prof. Dr. José Raimundo de Oliveira (Presidente):



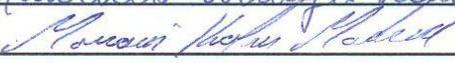
Prof. Dr. Andre Ferreira:



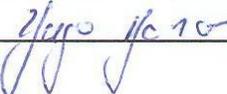
Prof. Dr. Mauricio Araujo Dias:



Prof. Dr. Marconi Kolm Madrid:



Prof. Dr. Yuzo Iano:



# Resumo

Esta tese apresenta uma nova e efetiva abordagem neuro-genética denominada MAAM-GA constituída por um algoritmo genético e uma rede neural associativa morfológica para a solução de problemas de reconhecimento de padrões. Especificamente, uma rede neural associativa morfológica é combinada com um algoritmo genético que é utilizado na construção da rede neural com a finalidade de aumentar a eficiência e robustez no reconhecimento de padrões. Um estudo detalhado do desempenho da abordagem é apresentado, utilizando imagens em níveis de cinza como padrões. Resultados numéricos e visuais da recuperação dos padrões são apresentados e o desempenho alcançado é comparado com outros modelos neurais associativos morfológicos relevantes para padrões de valor real, mostrando a eficiência e a robustez da abordagem proposta na recordação de imagens em níveis de cinza.

Esta abordagem faz parte do desenvolvimento dos sistemas inteligentes que impulsionam o avanço de outras áreas. Pensando em uma potencial aplicação, a proposta neuro-genética é utilizada para resolver o problema de reconhecimento de gestos da mão. O reconhecimento de gestos é um caminho natural de interação humano-computador, e considerando a diversidade e a diferença manifestada pelo ser humano, para muitas pessoas que possuem deficiência física e sensorial, os gestos da mão são o meio principal de comunicação. Várias tecnologias têm sido propostas para trazer benefícios às pessoas com limitações de comunicação. Os ambientes inteligentes surgiram com o principal propósito de melhorar a qualidade de vida do ser humano baseados em ferramentas computacionais, facilitando o desenvolvimento de processos e ações de nosso cotidiano. O reconhecimento de gestos da mão é uma função do ambiente inteligente. Assim, para pessoas portadoras de deficiências físicas que limitem a sua comunicação oral, o reconhecimento de gestos em um

ambiente inteligente poderá lhes trazer múltiplos benefícios na comunicação, interação e acessibilidade, permitindo a sua integração com o ambiente. Embora preocupados com pessoas portadoras de deficiências físicas, o sistema de reconhecimento de gestos da mão como parte de um ambiente inteligente destina-se, sobretudo a beneficiar todo e qualquer cidadão que dele tenha acesso.

Assim, nesta tese é apresentado um estudo de um sistema de reconhecimento de gestos da mão baseado em visão artificial capaz de reconhecer gestos estáticos específicos da mão. Este sistema foi dividido em três módulos, módulo de detecção e segmentação, módulo de extração de características e o módulo de identificação e reconhecimento propriamente dito que utiliza a abordagem neuro-genética proposta. Métodos utilizados no pré-processamento das imagens para segmentação e caracterização também são apresentados.

Resultados alcançados com a abordagem proposta são muito incentivadores e sugerem que a proposta possa ser considerada como uma ferramenta eficiente e robusta para recuperação e identificação a ser usada em diversas aplicações relacionadas à interface natural humano-computador. O ótimo desempenho do sistema é um passo para continuar na busca de novas tecnologias para criar um ambiente inteligente que dê suporte às necessidades de pessoas com deficiência visual, auditiva ou motora lhes dando certo nível de autonomia, capacidade de controle do entorno e de comunicação.

**Palavras-chave:** *Memórias Associativas, Memórias Associativas Morfológicas, Recuperação de Padrões, Reconhecimento de Padrões, Interação Humano-Computador.*

# Abstract

This thesis presents an innovative approach to solving problems of pattern recognition using a neural-genetic combination. Specifically, a morphological associative neural network is combined with a genetic algorithm that is used in the construction of the neural network for increasing the efficiency and robustness of pattern recall. A detailed study about the performance of the approach is presented, using grayscale images as patterns. Numerical and visual results are presented and the performance achieved is compared with other morphological associative neural models showing its effectiveness and robustness in the grayscale images recall.

Thinking about a potential application, the proposed approach is used to solve the problem of hand gestures recognition. The hand gestures recognition is a natural way of human-computer interaction and considering the diversity and difference manifested by the human, for many people who have physical and sensory disabilities, the hand gestures is the primary means of communication. Several technologies have been proposed to bring benefits to people with limited communication. The intelligent environments emerged with the main purpose of improving the quality of human life based in computational tools facilitating the development of processes and actions of everyday life. The hand gestures recognition is a function of intelligent environments. So, for people with physical disabilities that limit their oral communication,

gesture recognition in an intelligent environment can take many benefits in communication, interaction and accessibility allowing its integration with the environment. Although concerned about people with disabilities, the hand gestures recognition system is mainly intended to benefit every people who has access to the environment.

Thus, this thesis presents a study of a hand gestures recognition system. The system is able to recognize static hand gestures using the proposed Neural-Genetic Approach. Methods used in the image preprocessing and characterization are also presented. Results achieved with the proposed approach are very encouraging and suggest that the proposal can be considered as an efficient and robust tool for recovery and identification to be used in various applications related to natural human-computer interface. The optimal system performance is a big step to continue the search for new technologies to create an intelligent environment that supports the needs of people with visual, hearing or motor disability.

**Keywords:** *Associative memories, Morphological associative memories, Pattern recall, Pattern recognition, Human-computer interaction.*

*Aos meus pais Juan e Néida como um sinal humilde da minha gratidão.  
Pelo seu amor, seus sacrifícios por mim e por apoiar os meus caminhos incondicionalmente.*

# Agradecimentos

Este trabalho não ia ficar pronto se não fosse pela ajuda direta e indireta de muitas pessoas que compartilharam comigo sua inspiração, tempo, conselhos e muitos outros itens especiais para comigo. No entanto eu gostaria de agradecer em especial:

Ao meu orientador o Prof. José Raimundo que me instruiu com sabedoria e me deu apoio em cada decisão para a realização deste trabalho. Obrigada pela confiança nas minhas capacidades e por todos os ensinamentos brindados em todos estes anos na FEEC.

Aos Profs. Manuel Mazo e Juan Carlos García do *Departamento de Electrónica* da *Universidad de Alcalá de Henares* na Espanha pelos pensamentos críticos na parte aplicativa deste trabalho e por todo o apoio brindado durante a minha maravilhosa estadia na Espanha.

Ao Prof. Hugo Figueroa que contribuiu na minha vida acadêmica/profissional com seus significativos ensinamentos em inúmeros aspectos e situações.

O meu agradecimento profundo e sincero vai para:

Meu maior tesouro Gabizinha por ser minha fonte de energia e inspiração, pela compreensão e paciência quando mamai não podia brincar por que estava “estudando”, pelas suas lindas historinhas contadas quando me sentia cansada e por ser uma filha-amiga estupenda em todas as circunstancias.

Meu companheiro incondicional Baldo pelo apoio, paciência e amor durante esta jornada, pelas suas palavras motivadores e confiantes e por todos estes anos de vida juntos.

Meus pais Juan e Nélide por ser um exemplo de vida a seguir, pelo constante incentivo no meu crescimento acadêmico, profissional, pessoal e por todo o apoio e amor incondicional brindado em cada etapa da minha vida.

Gracias.

# Sumário

LISTA DE FIGURAS.....	XII
LISTA DE TABELAS.....	XIV
LISTA DE ABREVIACÕES.....	XV
CAPÍTULO 1.....	16
INTRODUÇÃO.....	16
1.1 OBJETIVOS E JUSTIFICATIVA DA TESE.....	17
1.1.1 Objetivos fundamentais .....	17
1.1.2 Objetivos específicos .....	17
1.1.3 Justificativa .....	17
1.2 DESENVOLVIMENTO DO CASO DE ESTUDO .....	18
1.3 ORGANIZAÇÃO DA TESE .....	19
1.4 CONTEXTO HISTÓRICO.....	21
1.4.1 Memórias Associativas Morfológicas .....	21
1.4.2 Algoritmos Genéticos .....	23
CAPÍTULO 2.....	28
MEMÓRIAS ASSOCIATIVAS MORFOLÓGICAS E ALGORITMOS GENÉTICOS.....	28
2.1 MEMÓRIAS ASSOCIATIVAS.....	28
2.2 MEMÓRIAS HETERO-ASSOCIATIVAS MORFOLÓGICAS .....	30
2.2.1 Fase de Aprendizado .....	32
2.2.2 Fase de Recuperação.....	33
2.3 MEMÓRIAS AUTO-ASSOCIATIVAS MORFOLÓGICAS .....	33

---

2.3.1	Fase de Aprendizado .....	34
2.3.2	Fase Recuperação.....	34
2.4	MEMÓRIA AUTO-ASSOCIATIVA MORFOLÓGICA MODIFICADA.....	39
2.5	ALGORITMOS GENÉTICOS .....	46
2.5.1	Parâmetros de um Algoritmo Genético .....	47
<b>CAPÍTULO 3.....</b>		<b>55</b>
<b>ABORDAGEM NEURO-GENÉTICA.....</b>		<b>55</b>
3.1	ALGORITMOS GENÉTICOS NAS MEMÓRIAS AUTO-ASSOCIATIVAS MORFOLÓGICAS (MAAM-GA) .....	55
3.2	EXPERIMENTOS E RESULTADOS DA MAAM-GA NA RECUPERAÇÃO DE PADRÕES.....	59
3.3	DISCUSSÃO DE RESULTADOS.....	66
<b>CAPÍTULO 4.....</b>		<b>71</b>
<b>CASO DE ESTUDO: RECONHECIMENTO DE GESTOS PARA INTERAGIR EM AMBIENTES INTELIGENTES .....</b>		<b>71</b>
4.1	O SISTEMA DE RECONHECIMENTO DE GESTOS .....	71
4.1.1	Captura e processamento de imagens.....	74
4.1.2	Extração de características.....	76
4.1.3	Técnica de Treinamento e Reconhecimento.....	79
4.2	RESULTADOS OBTIDOS NO SISTEMA DE RECONHECIMENTO DE GESTOS .....	80
<b>CAPÍTULO 5.....</b>		<b>83</b>
<b>DISCUSSÕES, CONCLUSÕES E TRABALHOS FUTUROS .....</b>		<b>83</b>
5.1	APLICAÇÃO DE GAS EM MAAMS.....	83
5.2	CARACTERÍSTICAS PRÁTICAS DE APLICAÇÃO DE GAS .....	84
5.3	LIMITAÇÕES DO SISTEMA DE RECONHECIMENTO DE GESTOS .....	85
5.4	CONCLUSÕES E TRABALHOS FUTUROS.....	85
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>		<b>88</b>
<b>APÊNDICE A.....</b>		<b>93</b>
<b>PRODUÇÃO CIENTÍFICA .....</b>		<b>93</b>

# Lista de Figuras

Figura 2.1 – Exemplo de funcionamento de uma memória associativa. a) Fase de aprendizado. b) Fase de recuperação de padrões. ....	31
Figura 2.2 – Padrões fundamentais $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_5$ .....	35
Figura 2.3 – Padrões alterados com ruído subtrativo. ....	36
Figura 2.4 – Padrões recordados pela MAAM $\mathbf{WXX}$ quando apresentados padrões alterados com ruído subtrativo como entrada. ....	37
Figura 2.5 – Padrões alterados com ruído aditivo. ....	38
Figura 2.6 – Padrões recordados pela MAAM $\mathbf{MXX}$ quando apresentados os padrões alterados com ruído aditivo como entrada. ....	38
Figura 2.7 –Padrões alterados contendo ruído aleatório uniformemente distribuído com média zero.....	41
Figura 2.8 –Padrões recordados pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ quando são apresentados na entrada padrões alterados com ruído aleatório uniformemente distribuído com média zero. ....	41
Figura 2.9 –Padrões alterados contendo ruído gaussiano com média zero. ....	42
Figura 2.10 – Padrões recordados pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ quando são apresentados na entrada padrões alterados com ruído gaussiano com média zero. ....	43
Figura 2.11 –Padrões alterados contendo ruído misto.....	44
Figura 2.12 – Padrões recordados pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ quando são apresentados na entrada padrões alterados com ruído misto. ....	45
Figura 2.13 –Diagrama de fluxo de um algoritmo genético.....	47
Figura 2.14 –Exemplo de mecanismos de seleção com $n = 14$ e $\lambda = 7$ . a) Método da Roleta. b) Amostragem Universal Estocástica. ....	50
Figura 2.15 –Exemplo de mecanismo de seleção por torneio com $n = 5$ e $\lambda = 4$ . ....	51
Figura 2.16 –Exemplo de recombinação simples.....	53
Figura 2.17 –Exemplo de recombinação aritmética.....	53
Figura 2.18 –Exemplo de recombinação heurística. ....	53
Figura 2.19 –Exemplo de mutação uniforme. ....	54
Figura 3.1 –Esquema de recombinação simples em matriz gene. ....	58
Figura 3.2 – Padrões recordados pela memória MAAM-GA usando como entrada os padrões fundamentais originais visualizados na figura 2.2.....	61
Figura 3.3 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído subtrativo com distribuição uniforme como entrada. ....	61

Figura 3.4 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído aditivo com distribuição uniforme como entrada.....	62
Figura 3.5 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído aleatório uniformemente distribuído com média zero como entrada. ....	63
Figura 3.6 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído gaussiano com média zero como entrada.....	64
Figura 3.7 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído misto como entrada.....	65
Figura 3.8 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído subtrativo.....	67
Figura 3.9 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído aditivo. ....	68
Figura 3.10 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído aleatório uniformemente distribuído. ....	68
Figura 3.11 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído gaussiano.....	69
Figura 3.12 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído misto. ....	69
Figura 4.1 – Fluxo do Sistema de Reconhecimento de Gestos usando a MAAM-GA.....	75
Figura 4.2 – Imagens de gestos das mãos segmentadas correspondentes aos sinais “A”, “B”, “C” e “W” do ASL ( <i>American Sign Language</i> ), respectivamente.....	75
Figura 4.3 – Imagens de gestos das mãos segmentadas correspondentes ao sinal “A” (a) Imagem plana (b) Superfície da imagem evidenciando algumas imperfeições. ....	76
Figura 4.4 – Imagens de gestos das mãos segmentadas correspondentes aos sinais “A”, “B”, “C” e “W” tratadas morfologicamente. ....	76
Figura 4.5 – Imagens de gestos das mãos segmentadas e tratadas morfologicamente correspondentes ao sinal “A”..	79
Figura 4.6 – Subconjunto de sinais do ASL selecionadas para teste.....	80

# Lista de Tabelas

Tabela I – EQMNs produzidos pela MAAM $\mathbf{WXX}$ na apresentação de padrões alterados com ruído subtrativo com distribuição uniforme e diferentes probabilidades. ....	37
Tabela II – EQMNs produzidos pela MAAM $\mathbf{MXX}$ na apresentação de padrões alterados com ruído aditivo com distribuição uniforme com diferentes probabilidades. ....	38
Tabela III – EQMNs produzidos pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ na apresentação de padrões alterados com ruído aleatório uniformemente distribuído com média zero. ....	42
Tabela IV – EQMNs produzidos pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ na apresentação de padrões alterados com ruído gaussiano com média zero. ....	43
Tabela V – EQMNs produzidos pelas MAAMs $\mathbf{M} + \mu$ e $\mathbf{W} + \nu$ na apresentação de padrões alterados com ruído misto. ....	44
Tabela VI – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído subtrativo com distribuição uniforme e diferentes probabilidades. ....	62
Tabela VII – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído aditivo com distribuição uniforme com diferentes probabilidades. ....	63
Tabela VIII – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído aleatório uniformemente distribuído com média zero. ....	64
Tabela IX – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído gaussiano com média zero. ....	65
Tabela X – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com diferentes porcentagens de ruído misto. ....	66
Tabela XI – Vetores característicos de gestos correspondentes a sinais diferentes mostrados na figura 4.4. ....	78
Tabela XII – Vetores característicos de gestos correspondentes ao sinal “A” mostrados na figura 4.5. ....	79
Tabela XIII – Desempenho da MAAM-GA no reconhecimento de gestos estáticos. ....	81
Tabela XIV – Comparação de desempenho da MAAM e MAAM-GA no reconhecimento de gestos. ....	82

# Lista de Abreviações

AM – *Associative Memory*

ASL – *American Sign Language*

CVG – *Computer Vision Group da Universidad de Granada – Espanha.*

DEPECA – *Departamento de Electrónica da Universidad de Alcalá de Henares – Espanha.*

EQMN – *Erro Quadrático Médio Normalizado.*

GA – *Genetic Algorithm.*

MAAM – *Morphological Auto-Associative Memories.*

MAAM-GA – *Morphological Auto-associative Memory and Genetic Algorithms.*

MAM – *Morphological Associative Memories.*

MHAM – *Morphological Hetero-Associative Memories.*

# Capítulo 1

## Introdução

Nosso interesse pelas técnicas computacionais baseadas na biologia iniciou-se há alguns anos e, desde então, foram realizados estudos utilizando como técnica as redes neurais artificiais, resultando em alguns trabalhos: na área de identificação e controle de sistemas dinâmicos e no reconhecimento de caracteres alfanuméricos para identificação de placas de veículos utilizando redes neurais associativas. Neste último trabalho as características associativas da rede neural chamaram a nossa atenção. E surgiu a pergunta: por que não utilizar este tipo de rede para outros tipos de padrões? Por que não aplicar esta abordagem em um sistema inteligente de identificação no qual possamos aproveitar mais de nossa expressividade e as nossas capacidades físicas para oferecer maneiras novas e vantajosas para nos comunicarmos com computadores? Perguntas que são a motivação para a realização desta tese de doutorado.

Junto com as redes neurais, tivemos o interesse de integrar técnicas inspiradas na biologia investigando os algoritmos genéticos como um processo evolutivo robusto, genérico e facilmente adaptável na otimização dos parâmetros de uma rede neural associativa que permita à memória associativa resolver e alcançar os objetivos do problema a ser tratado.

## 1.1 Objetivos e Justificativa da Tese

### 1.1.1 OBJETIVOS FUNDAMENTAIS

- ↻ Implementar em um sistema computacional inteligente um processamento híbrido de informação que é uma combinação de informações genéticas e informações adquiridas através do aprendizado, e assim superar algumas limitações de técnicas inteligentes aplicadas individualmente.
- ↻ Contribuir para o mosaico de modalidades de interface humano-computador disponível, replicando o comportamento associativo humano de recuperar informação em resposta a estímulos associados.
- ↻ Nos ambientes inteligentes, propiciar uma interação dos habitantes do ambiente com o contexto de uma forma mais natural e personalizada.

### 1.1.2 OBJETIVOS ESPECÍFICOS

- ↻ Desenvolvimento de uma abordagem inteligente híbrida, a qual é constituída por uma rede neural associativa e por um algoritmo genético, que possa enfrentar de forma robusta e eficiente os diferentes tipos de ruído misto alcançando altos índices de reconhecimento, oferecendo confiabilidade e exatidão no reconhecimento de padrões. E, que possua características atraentes para sua implementação futura.
- ↻ Caso de estudo: Propor uma nova técnica robusta e eficiente para o reconhecimento e identificação de gestos da mão para ser incorporada em um ambiente inteligente que dê suporte às necessidades de pessoas que possuem deficiência física lhes dando certo nível de autonomia, capacidade de controle do entorno e de comunicação.

### 1.1.3 JUSTIFICATIVA

A abordagem híbrida desenvolvida nesta tese propõe a combinação de uma rede neural associativa, mais especificamente da Memória Auto-Associativa Morfológica canônica, com um Algoritmo Genético, resultando em uma memória denominada MAAM-GA (do termo em inglês *Morphological Auto-associative Memory and Genetic Algorithms*). Nesta proposta a Memória Auto-

associativa Morfológica possui a função de satisfazer as restrições presentes no problema de reconhecimento de padrões e o Algoritmo Genético é responsável por otimizar o processo de construção da memória, aumentando sua robustez no processo de recuperação dos padrões armazenados na memória.

As Memórias Auto-Associativas Morfológicas em comparação com outras Memórias Associativas convencionais possuem notáveis características (ver seção 1.4.1) e dentro delas a principal vantagem é o baixo custo computacional na recordação dos padrões armazenados devido ao processo de recuperação ser realizado em uma única iteração, um produto matricial, o que pode permitir uma conveniente implementação em hardware. Porém, os modelos mais promissores ainda possuem algumas limitações quando os padrões a serem recuperados e identificados são alterados ou contêm distúrbios aleatórios mistos inesperados (ver seção 2.4).

A abordagem híbrida proposta MAAM-GA recobra a vantagem computacional inerente das Memórias Auto-associativas Morfológicas e estende sua funcionalidade para lidar com ruídos mistos aleatórios.

Com uma abordagem que apresenta motivação biológica, algoritmos que tem comportamento robusto no reconhecimento de padrões na presença de ruídos mistos aleatórios e que diminuam o custo computacional alto que as redes neurais normalmente utilizam, podemos estar a caminho de obter um sistema robusto de reconhecimento de padrões de valor real preciso e eficiente em termos de tempo de processamento.

Atualmente, são vários os problemas reais onde a abordagem proposta pode ter aplicabilidade, por exemplo: classificação de vozes, reconhecimento de objetos, identificação de gestos, entre outros. A proposta também pode ser estendida à reconstrução de imagens *true-color* construindo uma memória para cada canal de cor e em seguida combinando a informação recuperada por cada memória para finalmente recuperar a imagem *true-color*.

## 1.2 Desenvolvimento do Caso de Estudo

Dentro das aplicações práticas da proposta, é de nosso interesse a interpretação de gestos padrões como comandos para realizar determinadas ações. Para pessoas com algum tipo de

deficiência física que utilizam a linguagem dos sinais como primeira língua, a interpretação dos gestos padrões realizados será a alternativa mais apropriada de comunicação permitindo sua interação com diferentes ambientes dotados de redes de câmeras.

Assim, a abordagem neuro-genética proposta foi utilizada em um sistema de reconhecimentos de gestos da mão baseado em visão artificial como método de reconhecimento propriamente dito. Primeiramente foi realizada a captura das imagens. Da imagem estática a região da mão foi detectada, isolada e segmentada usando uma técnica de injeção de cor no espaço RGB o que resulta em imagens segmentadas com pouco ruído independentemente da variação de cor da pele e das condições de iluminação. O estágio que diz respeito à extração de características das imagens das mãos baseou-se nos momentos descritivos de Hu e formam o vetor de características descritivas invariantes à escala, posição e orientação de cada sinal descrito por um gesto. Após o armazenamento de vetores característicos de imagens dos sinais padrões, o sistema ficou pronto para ser usado no reconhecimento dos gestos capturados a diferentes condições ambientais e tamanhos.

O desenvolvimento da proposta foi realizado parcialmente nos laboratórios do DEPECA (*Departamento de Electrónica da Universidad de Alcalá* na Espanha) onde o sistema de reconhecimento de gestos foi implementado em tempo real por pesquisadores do DEPECA que possuem experiência na aplicação abordada. O estudo apresentado nesta tese utiliza na captura e pré-processamento das imagens algoritmos desenvolvidos por pesquisadores do DEPECA.

### 1.3 Organização da Tese

Esta tese está dividida em 5 capítulos, os quais são organizados como segue:

No capítulo 2, são dados os fundamentos matemáticos das metodologias utilizadas no desenvolvimento da abordagem híbrida proposta, Memórias Associativas Morfológicas e Algoritmos Genéticos, descrevendo os conceitos fundamentais e especificando a notação e a nomenclatura que é usada em todo o texto da tese. Experimentos computacionais visuais são utilizados para mostrar as vantagens e limitantes de cada modelo associativo na recuperação de padrões de valor real.

No capítulo 3, a abordagem neuro-genética desenvolvida é detalhada. Parâmetros e características são descritas e mediante experimentos computacionais visuais é apresentado um estudo do desempenho da técnica proposta no armazenamento de padrões de valor real e recuperação dos mesmos corrompidos por diversos tipos de ruído.

O capítulo 4 apresenta a aplicação estudada, um sistema de reconhecimento de gestos para o qual é utilizada a abordagem neuro-genética para a solução do problema de recuperação de padrões. Neste capítulo, cada etapa do sistema de reconhecimento de gestos é explicada detalhadamente, enfatizando-se a utilização da abordagem híbrida proposta.

Finalmente, no capítulo 5, apresentam-se conclusões e trabalhos futuros.

O sistema de reconhecimento de gestos da mão em tempo real foi desenvolvido em linguagem C, não ainda que os vários experimentos computacionais realizados nesta tese para avaliação do desempenho da abordagem proposta foram conduzidos no software MATLAB. As imagens utilizadas nos experimentos computacionais visuais dos capítulos 2 e 3 podem ser encontradas no portal do grupo CVG (*Computer Vision Group*) da *Universidad de Granada* da Espanha e disponível em <http://decsai.ugr.es/cvg/index2.php>. As imagens originais foram convertidas em imagens menores de dimensão 64x64 pixels usando o comando `imresize` do MATLAB com o método de interpolação padrão. Foi escolhido a dimensão 64x64 para facilitar a reprodução dos experimentos relatados em Sussner&Valle (2006) e apresentados na seção 2.4. Para o processamento e armazenamento das imagens, cada imagem foi transformada num vetor coluna com 4096 componentes usando o comando `reshape` do MATLAB.

Na próxima seção são descritas características e antecedentes das memórias associativas morfológicas e dos algoritmos genéticos. Os leitores que possuam conhecimentos sobre estas duas metodologias de processamento inteligente podem ir direto ao capítulo 2 sem perda da sequência do trabalho.

## 1.4 Contexto Histórico

### 1.4.1 MEMÓRIAS ASSOCIATIVAS MORFOLÓGICAS

As redes neurais associativas conhecidas como memórias associativas morfológicas (*Morphological Associative Memories, MAM*) foram introduzidas por Ritter como um novo paradigma de armazenamento e recordação de associação de padrões em Ritter&Sussner (1996). Estas memórias são redes neurais *feedforward* totalmente conectadas onde os pesos de interconexão entre neurônios de entrada e saída seguem uma regra de aprendizado adequadamente definida. A maioria dos modelos de memória associativa de tipo correlação (armazenamento por Hebb) utiliza nas fases de aprendizado e recuperação a álgebra convencional, enquanto nas MAMs os cálculos são baseados na teoria matemática da álgebra *minimax* desenvolvida por Cuninghame-Green (1979). Uma vez que a álgebra de matrizes *minimax* standard é uma instancia específica da estrutura algébrica de Lattice, MAMs também são chamadas de Memórias Associativas de Lattice. Se um conjunto de pares de padrões exemplares é armazenado na rede neural associativa, então se espera que o dispositivo de memória apresente uma determinada capacidade de recordar a associação correta quando é apresentado à memória um padrão exemplar (entrada perfeita) ou uma versão alterada do mesmo (entrada não perfeita). É importante ressaltar que a recordação para ambos os casos de entrada possui um problema de robustez difícil para qualquer modelo de memória associativa. Para entradas perfeitas, Ritter et al. (1998) provaram que a memória morfológica auto-associativa (*Morphological Auto-Associative Memories, MAAM*) tem capacidade de armazenamento de padrões elevada e convergência absoluta em um passo só, possui recuperação perfeita para todos os padrões exemplares, e é robusta exclusivamente para ruídos subtrativos ou aditivos. Baseados em fortes hipóteses, semelhantes resultados foram estabelecidos para memórias hetero-associativas morfológicas (*Morphological Hetero-Associative Memories, MHAM*). Embora o foco das pesquisas sobre MAMs tenha sido o caso auto-associativo para padrões binários, Ritter mostra que uma série de notáveis características das MAAMs, tais como a capacidade de armazenamento ideal e convergência absoluta em um passo só podem ser mantidas para o caso geral de padrões de valor real. Mais importante ainda, esses

resultados continuam válidos para padrões de valor inteiro desde que a MAM possa ser aplicada neste cenário sem qualquer erro de arredondamento. Como vantagem adicional, MAM pode ser facilmente implementada em hardware como mostra Stright et al. (1998).

Para lidar com entradas alteradas por ruído misto, isto é, tanto ruído subtrativo e aditivo combinados, Sussner (2000a) desenvolveu o método de *Kernel* para padrões binários e Ritter et al. (2003) para padrões de valor real. Além disso, diferentes abordagens computacionais ou extensões de modelo foram desenvolvidos para aumentar a sua capacidade de recordação ou aplicabilidade em problemas de reconhecimento de padrões. Uma técnica rápida para encontrar *Kernels* e o uso de múltiplos *Kernels* de padrões binários foi proposta por Hattori et al. (2002) e Hashiguchi&Hattori (2003), variações do método do *Kernel* e dual *Kernel* e o uso das teorias de conjuntos *fuzzy* para MAMs para o caso binário foi estabelecido por Sussner (2003a, 2003b). Urcid&Ritter (2003) propuseram um algoritmo baseado na forte independência morfológica induzida sobre um conjunto de padrões exemplares de valor real, e Wang&Chen (2005) propuseram uma MAM *fuzzy* que utiliza um mapa empírico que também foi testado com padrões de valor real. Nas duas últimas técnicas, entradas alteradas com ruído misto aleatório foram consideradas. Para aplicações do mundo real, Graña et al. (2003, 2005) obtiveram sucesso na aplicação das MAMs e o critério de independência morfológica de um conjunto de padrões para encontrar membros finais em imagens hiper-espectrais. Com uma orientação mais teórica, algébrica e geométrica, e considerando desenvolvimentos técnicos e aplicações, Sussner (2000b) e Ritter&Gader (2006) estabelecem um conhecimento mais profundo que proporciona resultados úteis sobre o conjunto de pontos fixos da MAM e, portanto, uma caracterização completa de suas respostas para entradas arbitrárias. Desde este ponto de vista, exemplos numéricos e discussões práticas são dados por Ritter&Gader (2006), e uma comparação das MAMs com outras redes neurais associativas reforçadas para recuperação de padrões de valor real aparece no trabalho de Sussner (2005) embora apenas para ruído subtrativo e aditivo. Mais recentemente, Sussner&Valle (2006) caracterizaram o *Gray-scale* MAM para trabalhar com padrões de valor real e a modificaram adicionando um fator constante à memória recuperada para alcançar uma considerável correção de erro para entradas alteradas com ruído misto aleatório.

Destaca-se o fato relevante que os pontos fortes e fracos das memórias associativas usando a álgebra *minimax* têm impulsionado o desenvolvimento de diferentes abordagens baseadas em MAMs como brevemente descrito nos parágrafos anteriores. A falha na recordação da MAM *min* para entradas alteradas com ruído aditivo e similarmente, o fraco desempenho da MAM *max* para entradas alteradas com ruído subtrativo, e conseqüentemente, sua não aplicabilidade para lidar com o ruído misto aleatório foi exposto repetidamente desde a sua introdução em Ritter et al. (1998), nos resultados teóricos mais recentes descobertos sobre eles, Ritter&Gader (2006) e por Sussner&Valle (2006), e no desenvolvimento dos novos modelos de Memória Associativa Dentrítica baseado em Lattice de Ritter et al. (2004) e Memoria Fuzzy de Wang&Chen (2005).

Nesta tese, é proposta uma solução completa pragmática ao problema de recordação de padrões alterados com ruído misto aleatório usando apenas uma MAM canônica e um algoritmo genético. Portanto, apesar das limitações das MAMs, são preservadas sua capacidade de armazenamento absoluta ótima e sua convergência em um passo só, e sua funcionalidade é estendida para lidar com qualquer tipo em quantidade considerável de ruído misto aleatório.

#### 1.4.2 ALGORITMOS GENÉTICOS

Os algoritmos genéticos (*Genetic Algorithm, GA*) foram propostos por Holland e seus alunos da Universidade de Michigan na década de 1970. Em contraste com outros algoritmos evolutivos como as estratégias evolutivas de Back et al. (1991) e a programação evolutiva de Fogel et al. (1966), o objetivo original de Holland não era projetar algoritmos para solucionar problemas específicos, mas abstrair e rigorosamente explicar o fenômeno da adaptação dos seres vivos na natureza. Holland estudou a evolução natural considerando-o um processo robusto, simples e poderoso que poderia ser adaptado para obtenção de soluções computacionais eficientes para problemas de otimização. Segundo Goldberg (1989), o conceito de robustez relaciona-se ao fato de os algoritmos genéticos, independentemente da escolha dos parâmetros iniciais, em geral, produzirem soluções de qualidade. A utilização de dois operadores genéticos, mutação e recombinação, equilibram dois objetivos aparentemente conflitantes: o aproveitamento das melhores soluções e a exploração do espaço de busca. O processo de busca

é, portanto, multidimensional, preservando soluções candidatas e provocando a troca de informação entre as soluções exploradas.

Nos GAs clássicos as soluções candidatas são codificadas em cadeias binárias de tamanho fixo. A motivação para o uso de codificação binária é oriunda da Teoria dos Esquemas proposta por Holland (1975, 1992) utilizada com sucesso para explicar por que os GAs funcionam. Holland argumenta que seria benéfico para o desempenho do algoritmo maximizar o paralelismo implícito inerente ao GA e apresenta uma análise qualitativa baseada no Teorema dos Esquemas de que um alfabeto binário poderia maximizar esse paralelismo.

Entretanto, em diversas aplicações práticas a utilização de codificação binária leva a um desempenho insatisfatório. Segundo Michalewicz (1996) a representação binária apresenta desempenho pobre se aplicada a problemas numéricos com dimensões elevadas ou se alta precisão numérica é requerida. Além disso, Janikow&Michalewicz (1991) descrevem simulações computacionais comparando o desempenho de GAs com codificação binária e com ponto flutuante. Os resultados apresentados mostram uma clara superioridade da codificação em ponto flutuante para os problemas estudados.

Em contra partida, Fogel (1994) argumenta que o espaço de busca por si só (sem levar em consideração a escolha da representação) não determina a eficiência do GA. Espaços de busca de dimensão elevada podem às vezes ser explorados eficientemente, enquanto que espaços de busca de dimensões reduzidas podem apresentar dificuldades significativas. Concorde, entretanto, que a maximização do paralelismo implícito nem sempre produz um desempenho ótimo.

#### **1.4.2.1 Funcionamento**

Inspirado na maneira como o Darwinismo explica o processo de evolução das espécies, Holland decompôs o funcionamento dos GAs em etapas.

Basicamente, um GA cria uma população de possíveis respostas para o problema a ser tratado (etapa de inicialização) para depois submetê-la ao processo de evolução, constituído pelas seguintes etapas:

**avaliação:** avalia-se a aptidão das soluções (indivíduos da população) — é feita uma análise para que se estabeleça quão bem elas respondem ao problema proposto;

**seleção:** indivíduos são selecionados para a reprodução. A probabilidade de uma dada solução  $i$  ser selecionada é proporcional à sua aptidão;

**recombinação:** características das soluções escolhidas são recombinadas, gerando novos indivíduos;

**mutação:** características dos indivíduos resultantes do processo de reprodução são alteradas, acrescentando assim variedade à população;

**atualização:** os indivíduos criados nesta geração são inseridos na população;

**finalização:** verifica se as condições de encerramento da evolução foram atingidas, retornando para a etapa de avaliação em caso negativo e encerrando a execução em caso positivo.

#### 1.4.2.2 *Características*

Por causa da maneira particular do funcionamento dos GAs, e com base em Goldberg (1989), Holland (1992) e Michalewicz (1996) pode-se destacar as seguintes características:

**busca codificada:** os GAs não operam sobre o domínio do problema, mas sim sobre representações de seus elementos. Tal fator impõe ao seu uso uma restrição: para resolver um problema é necessário que o conjunto de soluções viáveis para ele possa ser codificado de alguma forma em uma população de indivíduos;

**generalidade:** os algoritmos genéticos simulam a natureza em um de seus mais fortes atributos: a adaptabilidade. Visto que a representação e a avaliação das possíveis soluções são as únicas partes (de um considerável conjunto de operações utilizadas em seu funcionamento) que obrigatoriamente requisitam conhecimento dependente do domínio do problema abordado, basta a alteração destas para portá-los para outros casos. A preocupação de um programador de GAs não é então de que forma chegar a uma solução, mas sim com o que ela deveria se parecer;

**paralelismo explícito:** o alto grau de paralelismo intrínseco aos GAs pode ser facilmente verificado se for considerado o fato de que cada indivíduo da população existe como um

ente isolado e é avaliado de forma independente. Se na natureza todo processo de seleção ocorre de forma concorrente, nos GAs essa característica se repete;

**busca estocástica:** ao contrário de outros métodos de busca de valores ótimos, os GAs não apresentam um comportamento determinístico. Não seria correto, no entanto, afirmar que tal busca se dá de forma completamente aleatória. As probabilidades de aplicação dos operadores genéticos fazem com que estes operem de forma previsível estatisticamente, apesar de não permitirem que se determine com exatidão absoluta o comportamento do sistema;

**busca cega:** um GA tradicional opera ignorando o significado das estruturas que manipula e qual a melhor maneira de trabalhar sobre estas. Tal característica lhe confere o atributo de não se valer de conhecimento específico ao domínio do problema, o que lhe traz generalidade por um lado, mas uma tendência a uma menor eficiência por outro;

**eficiência mediana:** por constituir um método de busca cega, um GA tradicional tende a apresentar um desempenho menos adequado que alguns tipos de busca heurística orientadas ao problema. Para resolver tal desvantagem, a tática mais utilizada é a hibridização, onde heurísticas provenientes de outras técnicas são incorporadas;

**paralelismo implícito:** a partir do teorema dos esquemas de Holland, tem-se que ao fazer uma busca por populações, a evolução de um GA tende a favorecer indivíduos que compartilhem determinadas características, sendo assim capaz de avaliar implicitamente determinadas combinações ou esquemas como mais ou menos desejáveis, efetuando o que é chamado de uma busca por hiperplanos de natureza paralela, Goldberg (1989);

**facilidade no uso de restrições:** ao contrário de muitos outros métodos de busca, os GAs facilitam a codificação de problemas com diversos tipos de restrição, mesmo que elas apresentem graus diferentes de importância. Neste caso, se dois indivíduos violam restrições, é considerado mais apto aquele que viola as mais flexíveis (*soft constraints*) em detrimento do que viola as mais graves (*hard constraints*);

Também os GAs se mostram particularmente apropriados para resolver problemas computacionais que têm descrições genéricas da solução através de funções objetivo, por tanto as funções objetivo são não diferenciáveis e há necessidade de encontrar-se soluções somente utilizando o valor da função objetivo.

Devido a todas estas características os GAs tornam-se muito atrativos para lidar com o problema de encontrar um conjunto de parâmetros ótimos para uma rede neural associativa que lhe permita alcançar um determinado objetivo, pois o problema pode ser visto como um problema de otimização de parâmetros e modelado como um problema de busca em um determinado espaço.

# Capítulo 2

## Memórias Associativas Morfológicas e Algoritmos Genéticos

**E**ste capítulo apresenta os fundamentos matemáticos das Memórias Associativas Morfológicas e dos Algoritmos Genéticos, especificando a notação e a nomenclatura que será usada ao longo do texto da tese. Na seção 2.1, são apresentados os conceitos básicos das Memórias Associativas. A seção 2.2 descreve as Memórias Associativas Morfológicas para o caso geral Hetero-associativo e, na seção 2.3, se discutem as Memórias Associativas Morfológicas para o caso Auto-associativo. A seção 2.4 descreve as características e desempenho da *Gray-scale* Memórias Associativas Morfológicas, memória condicionada para melhorar a tolerância da recuperação de padrões na presença de ruídos aleatórios. O capítulo termina com a seção 2.5 descrevendo os princípios básicos e parâmetros dos Algoritmos Genéticos.

### 2.1 Memórias Associativas

Uma memória associativa (*Associative Memory, AM*) representa um modelo de entrada-saída projetado para armazenar vários pares de padrões  $(\mathbf{x}, \mathbf{y})$ , onde  $\mathbf{x} \in \mathbb{R}^n$  e  $\mathbf{y} \in \mathbb{R}^m$ . Numa memória associativa é criado um mapeamento entre a entrada e a saída dado por  $\mathbf{y} = G(\mathbf{x})$ , onde  $G: \mathbb{R}^n \rightarrow \mathbb{R}^m$  é o mapeamento associativo da memória. Cada par entrada-saída  $(\mathbf{x}, \mathbf{y})$  armazenado

na memória é dito uma associação. A entrada do sistema  $\mathbf{x}$  é conhecida como padrão chave e a saída  $\mathbf{y}$  como padrão recordado.

Matematicamente, um problema de memória associativa baseado em Hassoun (1993) pode ser descrito como: dado um conjunto finito de pares de entrada e saída  $\{(\mathbf{x}^\xi, \mathbf{y}^\xi) | \xi = 1, 2, \dots, k\}$  a ser armazenado, determine uma função  $G$  tal que  $G(\mathbf{x}^\xi) = \mathbf{y}^\xi \forall \xi = 1, 2, \dots, k$ . Além disso, a função  $G$  deve possuir certa tolerância ao ruído (capacidade de correção de erros). Assim, se  $\tilde{\mathbf{x}}^\xi$  é uma versão ruidosa de  $\mathbf{x}^\xi$ ,  $G(\tilde{\mathbf{x}}^\xi) = \tilde{\mathbf{y}}^\xi$  e  $\tilde{\mathbf{y}}^\xi = \mathbf{y}^\xi$ .

O conjunto dos pares de entrada e saída  $\{(\mathbf{x}^\xi, \mathbf{y}^\xi) | \xi = 1, 2, \dots, k\}$  é chamado conjunto das memórias fundamentais e cada par  $(\mathbf{x}^\xi, \mathbf{y}^\xi)$  neste conjunto é uma memória fundamental. Cada padrão  $\mathbf{x}^\xi$  deste conjunto é uma chave fundamental e cada padrão  $\mathbf{y}^\xi$  deste conjunto é uma recordação fundamental. Diz-se que uma memória associativa armazena corretamente o conjunto das memórias fundamentais se  $G(\mathbf{x}^\xi) = \mathbf{y}^\xi \forall \xi = 1, 2, \dots, k$ . Em particular, uma memória fundamental  $(\mathbf{x}^\xi, \mathbf{y}^\xi)$  é armazenada corretamente se  $G(\mathbf{x}^\xi) = \mathbf{y}^\xi$ . A capacidade absoluta de armazenamento refere-se ao número de pares de entrada e saída do conjunto das memórias fundamentais que foram armazenadas corretamente.

Quando  $\mathbf{x}^\xi = \mathbf{y}^\xi \forall \xi = 1, 2, \dots, k$  se diz que esta é uma memória auto-associativa. No caso geral, quando esta igualdade não existe se diz que a memória é hetero-associativa e o padrão de saída  $\mathbf{y}^\xi$  pode ter uma natureza completamente diferente do padrão de entrada  $\mathbf{x}^\xi$ .

O processo usado para determinar  $G$  é conhecido como fase de aprendizado. Haykin (1999) afirma que um dos principais objetivos numa memória associativa é criar um mapeamento com uma grande capacidade de armazenamento, isto é, uma vasta quantidade de memórias fundamentais pode ser armazenada. Um problema muito comum na construção de uma memória associativa é a criação involuntária de associações que não pertencem ao conjunto das memórias fundamentais. Estas associações armazenadas indevidamente são as chamadas memórias espúrias.

Quando a fase de aprendizado está completa, inicia-se a fase de recuperação. Nesta fase uma memória pode ser testada para verificar se as memórias fundamentais foram corretamente armazenadas e a capacidade de correção de erro pode ser medida apresentando as chaves

fundamentais alteradas por vários tipos de ruído e comparando os padrões recordados com as recordações fundamentais correspondentes.

Uma rede neural associativa é um modelo de memória associativa onde é utilizada uma rede neural artificial para representar o mapeamento associativo  $G$  e a fase de aprendizado reduz-se a determinar a matriz dos pesos sinápticos da rede neural artificial. Na figura 2.1 pode-se observar um exemplo que ilustra as duas fases de funcionamento de uma memória associativa.

## 2.2 Memórias Hetero-associativas Morfológicas

As memórias associativas morfológicas (*Morphological Associative Memories, MAM*) são redes neurais associativas descritas pelo modelo neural morfológico e foram introduzidas por Ritter&Sussner (1996).

A base matemática para as MAMs proposta por Ritter é baseada na estrutura algébrica de Lattice  $(\mathbb{R}, \wedge, \vee, +)$  onde os símbolos  $\wedge$  e  $\vee$  denotam os produtos mínimo e máximo, respectivamente. Nos modelos morfológicos o mapeamento associativo da memória  $G: \mathbb{R}^n \rightarrow \mathbb{R}^m$  é descrito pela matriz  $\mathbf{W} \in \mathbb{R}^{m \times n}$  ou  $\mathbf{M} \in \mathbb{R}^{m \times n}$  e o produto-mínimo e produto-máximo.

Por definição, o produto-mínimo e produto-máximo entre dois vetores  $\mathbf{x} = (x_1, x_2, \dots, x_n)^t \in \mathbb{R}^n$  e  $\mathbf{y} = (y_1, y_2, \dots, y_m)^t \in \mathbb{R}^m$  são matrizes de tamanho  $m \times n$  e dadas respectivamente pelas seguintes equações:

$$\mathbf{y} \square \wedge (-\mathbf{x})^t = \bigwedge_{\xi=1}^k [\mathbf{y}^\xi \times (-\mathbf{x}^\xi)^t] = \begin{pmatrix} y_1 - x_1 & \cdots & y_1 - x_n \\ \vdots & \ddots & \vdots \\ y_m - x_1 & \cdots & y_m - x_n \end{pmatrix} \quad (2.1)$$

$$\mathbf{y} \square \vee (-\mathbf{x})^t = \bigvee_{\xi=1}^k [\mathbf{y}^\xi \times (-\mathbf{x}^\xi)^t] = \begin{pmatrix} y_1 - x_1 & \cdots & y_1 - x_n \\ \vdots & \ddots & \vdots \\ y_m - x_1 & \cdots & y_m - x_n \end{pmatrix} \quad (2.2)$$

Onde  $\mathbf{y}^\xi \times (-\mathbf{x}^\xi)^t$  denota o produto vetorial entre  $\mathbf{y}^\xi$  e  $(-\mathbf{x}^\xi)^t$ .

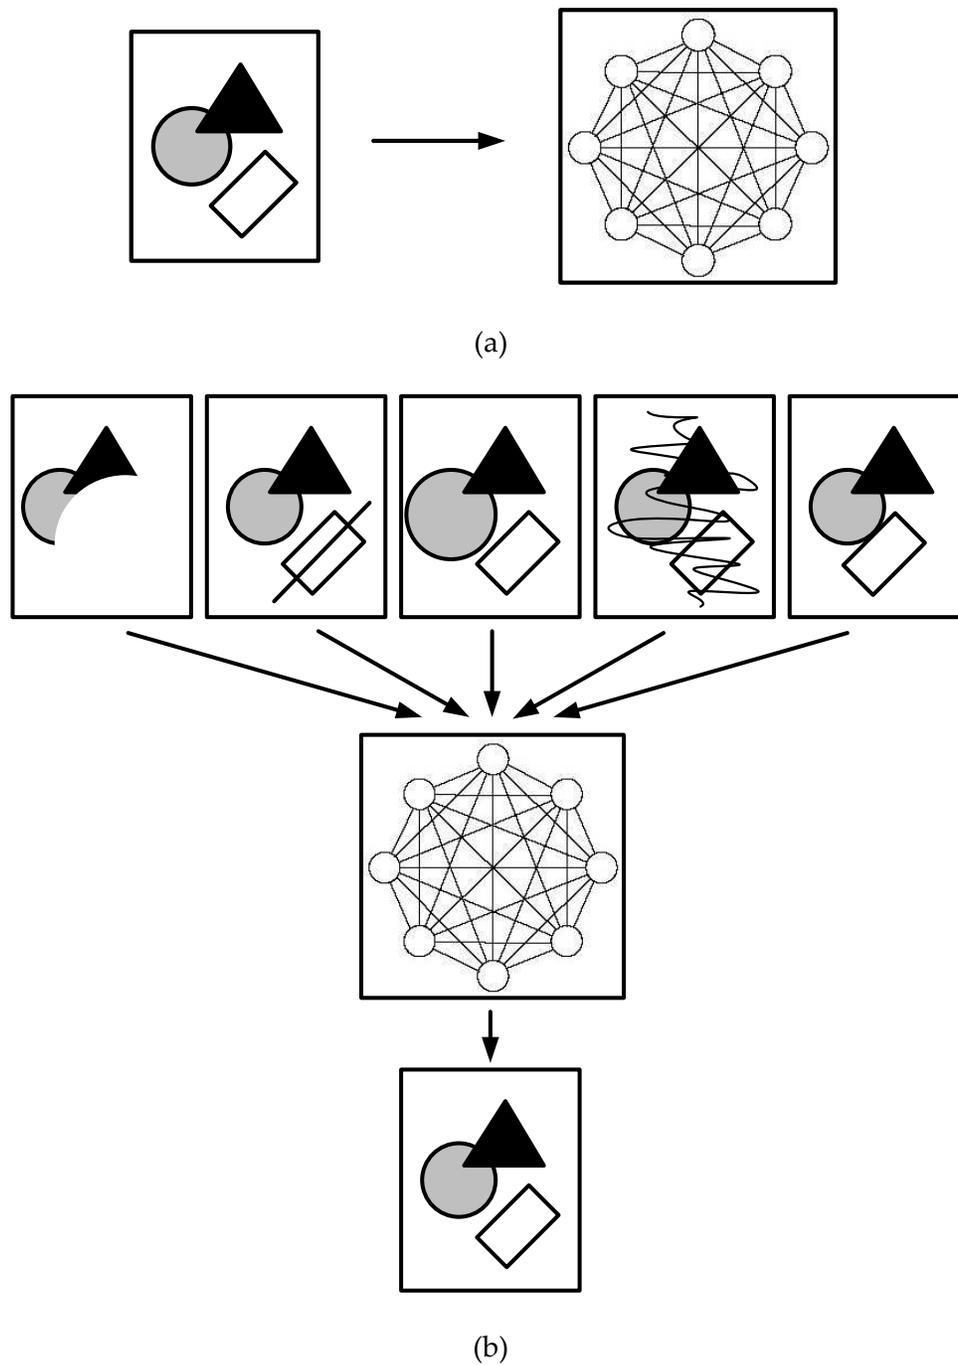


Figura 2.1 – Exemplo de funcionamento de uma memória associativa. a) Fase de aprendizado. b) Fase de recuperação de padrões.

Note que as equações 2.1 e 2.2 são iguais por se tratar de um único par de vetores  $(\mathbf{x}, \mathbf{y})$ ,  $\mathbf{k} = 1$ . Devido a estas duas operações os modelos morfológicos apresentam um comportamento não linear.

### 2.2.1 FASE DE APRENDIZADO

Sejam  $(\mathbf{x}^1, \mathbf{y}^1), \dots, (\mathbf{x}^k, \mathbf{y}^k)$   $k$  pares de vetores com  $\mathbf{x}^\xi = (x_1^\xi, \dots, x_n^\xi)^t \in \mathbb{R}^n$  e  $\mathbf{y}^\xi = (y_1^\xi, \dots, y_m^\xi)^t \in \mathbb{R}^m$  para  $\xi = 1, \dots, k$ . Para o conjunto de associações de padrões  $\{(\mathbf{x}^\xi, \mathbf{y}^\xi): \xi = 1, \dots, k\}$  é definido um par de matrizes padrão  $(\mathbf{X}, \mathbf{Y})$ , onde  $\mathbf{X} = [\mathbf{x}^1, \dots, \mathbf{x}^k]$  e  $\mathbf{Y} = [\mathbf{y}^1, \dots, \mathbf{y}^k]$ . Assim a matriz  $\mathbf{X}$  é de dimensão  $n \times k$  com componente  $ij$ -ésima  $x_i^j$  e  $\mathbf{Y}$  de dimensão  $m \times k$  com componente  $ij$ -ésima  $y_i^j$ .

Para armazenamento dos padrões  $\{(\mathbf{x}^\xi, \mathbf{y}^\xi): \xi = 1, \dots, k\}$  em uma memória associativa morfológica de tamanho  $m \times n$  é usada uma abordagem similar às usadas para as associações em uma memória linear substituindo o produto externo pelo produto-mínimo e produto-máximo como descrito por Ritter&Sussner (1997).

Assim, as memórias morfológicas  $\mathbf{W}_{XY}$  e  $\mathbf{M}_{XY}$ , ambas de tamanho  $m \times n$ , que armazenam um conjunto de associações de padrões  $(\mathbf{X}, \mathbf{Y})$  e que permitem a recordação do padrão  $\mathbf{y}^\xi$  a partir de um padrão chave  $\mathbf{x}^\xi$ , são construídas respectivamente pelas seguintes expressões:

$$\mathbf{W}_{XY} = \mathbf{Y} \square \mathbf{X}^* = \bigwedge_{\xi=1}^k [\mathbf{y}^\xi \times (-\mathbf{x}^\xi)^t]; \quad w_{ij} = \bigwedge_{\xi=1}^k (y_i^\xi - x_j^\xi) \quad (2.3)$$

$$\mathbf{M}_{XY} = \mathbf{Y} \square \mathbf{X}^* = \bigvee_{\xi=1}^k [\mathbf{y}^\xi \times (-\mathbf{x}^\xi)^t]; \quad m_{ij} = \bigvee_{\xi=1}^k (y_i^\xi - x_j^\xi) \quad (2.4)$$

Se  $\mathbf{X} = \mathbf{Y}$ , isto é,  $\mathbf{x}^\xi = \mathbf{y}^\xi$  para  $\xi = 1, \dots, k$ , diz-se que  $\mathbf{W}_{XX}$  e  $\mathbf{M}_{XX}$  são memórias associativas morfológicas do caso auto-associativo (*Morphological Auto-Associative Memories, MAAM*) e se  $\mathbf{X} \neq \mathbf{Y}$  então são memórias associativas morfológicas do caso hetero-associativo (*Morphological Hetero-Associative Memories, MHAM*).

A expressão à esquerda de cada equação (2.3) e (2.4) é da forma matricial e a expressão à direita é a componente  $ij$ -ésima de cada memória. No contexto das redes neurais, as componentes  $w_{ij}$  e  $m_{ij}$  podem ser vistas como a sinapse da rede neural.

Pelas expressões (2.3) e (2.4) se segue que  $\mathbf{W}_{XY} \leq \mathbf{y}^\xi \sqcap (-\mathbf{x}^\xi)^t = \mathbf{y}^\xi \sqcup (-\mathbf{x}^\xi)^t \leq \mathbf{M}_{XY}$  para todo  $\xi = 1, \dots, k$  desigualdade que implica em  $\mathbf{W}_{XY} \sqcup \mathbf{x}^\xi \leq [\mathbf{y}^\xi \sqcap (-\mathbf{x}^\xi)^t] \sqcup \mathbf{x}^\xi = \mathbf{y}^\xi = [\mathbf{y}^\xi \sqcup (-\mathbf{x}^\xi)^t] \sqcap \mathbf{x}^\xi \leq \mathbf{M}_{XY} \sqcap \mathbf{x}^\xi$  para  $\xi = 1, \dots, k$ , ou equivalentemente  $\mathbf{W}_{XY} \sqcup \mathbf{X} \leq \mathbf{Y} \leq \mathbf{M}_{XY} \sqcap \mathbf{X}$ .

Se  $\mathbf{A}$  é  $\sqcup$ - perfeita e  $\mathbf{B}$  é  $\sqcap$ - perfeita para  $(\mathbf{x}^\xi, \mathbf{y}^\xi)$ , isto é,  $\mathbf{A} \sqcup \mathbf{x}^\xi = \mathbf{y}^\xi$  e  $\mathbf{B} \sqcap \mathbf{x}^\xi = \mathbf{y}^\xi$  para todo  $\xi = 1, \dots, k$ , então  $\mathbf{A} \leq \mathbf{W}_{XY} \leq \mathbf{M}_{XY} \leq \mathbf{B}$  e  $\mathbf{W}_{XY} \sqcup \mathbf{X} = \mathbf{Y} = \mathbf{M}_{XY} \sqcap \mathbf{X}$ .

### 2.2.2 FASE DE RECUPERAÇÃO

A recordação dos padrões  $\mathbf{y}^\xi$  a partir dos padrões chave  $\mathbf{x}^\xi$  pode ser expressa pelo esquema de um passo só:  $\mathbf{x}^\xi \rightarrow \{\mathbf{W}_{XY} | \mathbf{M}_{XY}\} \rightarrow \mathbf{y}^\xi$  onde, a barra vertical significa que  $\mathbf{W}_{XY}$  ou  $\mathbf{M}_{XY}$  pode ser usado. Assim, dado um padrão chave  $\mathbf{x}^\xi \in \mathbb{R}^n$ , pode-se encontrar o padrão recordado  $\mathbf{y}^\xi \in \mathbb{R}^m$  através de uma das seguintes equações:

$$\mathbf{y}^\xi = \mathbf{W}_{XY} \sqcup \mathbf{x}^\xi \quad (2.5)$$

$$\mathbf{y}^\xi = \mathbf{M}_{XY} \sqcap \mathbf{x}^\xi \quad (2.6)$$

Um conjunto completo de teoremas e suas correspondentes provas a respeito da qualidade de armazenamento, capacidade de armazenamento e recuperação das memórias fundamentais realizada pelas MHAM são encontradas em Ritter et al. (1998) e Mesquita (2005).

## 2.3 Memórias Auto-associativas Morfológicas

Nesta seção é considerado o caso auto-associativo das MAMs, isto é  $\mathbf{Y} = \mathbf{X}$ . Uma discussão detalhada sobre este tipo de memórias para padrões binários e de valor real encontra-se em Sussner(2005) e Mesquita(2005).

### 2.3.1 FASE DE APRENDIZADO

Na fase de aprendizado, as memórias  $\mathbf{W}_{XX}$  e  $\mathbf{M}_{XX}$  podem ser definidas por:

$$\mathbf{W}_{XX} = \mathbf{X} \boxed{\wedge} \mathbf{X}^*; w_{ij} = \bigwedge_{\xi=1}^k (x_i^\xi - x_j^\xi) \quad (2.7)$$

$$\mathbf{M}_{XX} = \mathbf{X} \boxed{\vee} \mathbf{X}^*; m_{ij} = \bigvee_{\xi=1}^k (x_i^\xi - x_j^\xi) \quad (2.8)$$

Em cada equação (2.7) e (2.8), a expressão à esquerda é da forma matricial e a expressão à direita é a componente  $ij$ -ésima de cada memória.

### 2.3.2 FASE RECUPERAÇÃO

A fase de recuperação das MAAMs pode ser descrita exatamente em termos de seus pontos fixos e regiões de recordação (Ritter&Gader 2006).

Seja  $\mathbf{X} = [\mathbf{x}^1, \dots, \mathbf{x}^k] \in \mathbb{R}^{n \times k}$ , os vetores  $\mathbf{x}^\xi$  para  $\xi = 1, \dots, k$  são o conjunto de pontos fixos do estado estável de  $\mathbf{W}_{XX}$  se e somente se:

$$\mathbf{W}_{XX} \boxed{\vee} \mathbf{x}^\xi = \mathbf{x}^\xi \quad (2.9)$$

Analogamente, todo  $\mathbf{x}^\xi$  é um ponto fixo de  $\mathbf{M}_{XX}$  se e somente se:

$$\mathbf{M}_{XX} \boxed{\wedge} \mathbf{x}^\xi = \mathbf{x}^\xi \quad (2.10)$$

Alem disso, se  $\mathbf{x}^\xi$  para  $\xi = 1, \dots, k$  é o padrão recordado por  $\mathbf{W}_{XX}$  após apresentado um padrão chave  $\mathbf{x}^\zeta$ , então  $\mathbf{x}^\zeta \leq \mathbf{x}^\xi$ . E, se for utilizada a memória  $\mathbf{M}_{XX}$  para recordação, então  $\mathbf{x}^\zeta \geq \mathbf{x}^\xi$ .

Por outro lado, uma versão ruidosa  $\tilde{\mathbf{x}}$  de um padrão chave  $\mathbf{x}$  diz-se uma versão subtrativa de  $\mathbf{x}$  quando  $\tilde{\mathbf{x}} \leq \mathbf{x}$  e é uma versão aditiva de  $\mathbf{x}$  quando  $\tilde{\mathbf{x}} \geq \mathbf{x}$ . Usando esta terminologia, se  $\mathbf{W}_{\text{XX}} \sqcap \tilde{\mathbf{x}}^\xi = \mathbf{x}^\xi$ , então  $\tilde{\mathbf{x}}^\xi \leq \mathbf{x}^\xi$ , e  $\tilde{\mathbf{x}}^\xi$  deve ser uma versão subtrativa de  $\mathbf{x}^\xi$ . Analogamente, se  $\mathbf{M}_{\text{XX}} \sqcup \tilde{\mathbf{x}}^\xi = \mathbf{x}^\xi$  então  $\tilde{\mathbf{x}}^\xi \geq \mathbf{x}^\xi$ , e  $\tilde{\mathbf{x}}^\xi$  deve ser uma versão aditiva de  $\mathbf{x}^\xi$ .

Portanto, uma versão  $\tilde{\mathbf{x}}$  contendo ruído aditivo não pode ser recordada usando  $\mathbf{W}_{\text{XX}}$ , pois pelas definições acima, se  $\tilde{x}_i^\xi > x_i^\xi$  para algum  $i$ , então  $\mathbf{W}_{\text{XX}} \sqcap \tilde{\mathbf{x}}^\xi > \mathbf{x}^\xi$ , isto é, o padrão  $\mathbf{x}^\xi$  não será recordado satisfatoriamente. Analogamente, uma versão  $\tilde{\mathbf{x}}$  contendo ruído subtrativo não pode ser recordada usando  $\mathbf{M}_{\text{XX}}$ , pois se  $\tilde{x}_i^\xi < x_i^\xi$  para algum  $i$ , então  $\mathbf{M}_{\text{XX}} \sqcup \tilde{\mathbf{x}}^\xi < \mathbf{x}^\xi$ .

Um conjunto completo de teoremas que garantem que as memórias auto-associativas morfológicas têm capacidade de armazenamento elevada e provêm recuperação perfeita do padrão e suas correspondentes provas são encontradas nos trabalhos de Ritter&Sussner (1996) e Mesquita (2005). Ritter *et al.* (1998) mostra diversos exemplos numéricos do funcionamento das MAAMs e exemplos com padrões de valor binário.

A seguir estão apresentados alguns experimentos computacionais visuais com imagens em níveis de cinza que demonstram as características de tolerância ao ruído das MAAMs com padrões de valor real. A figura 2.2 mostra as imagens utilizadas, imagens de tamanho  $64 \times 64$  com 256 níveis de cinza que transformadas em vetores com 4096 de comprimento formam o conjunto dos padrões fundamentais  $\mathbf{x}^\xi$  para  $\xi = 1, \dots, 5$ .

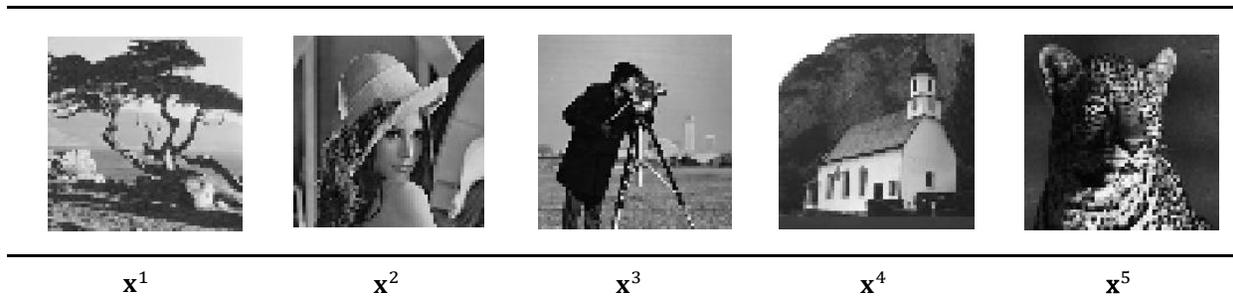


Figura 2.2 – Padrões fundamentais  $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5$ .

Na fase de recuperação, para medir a diferença entre o padrão recordado e a recordação fundamental é usado o erro quadrático médio normalizado (EQMN) calculado para  $\mathbf{W}_{\text{XX}}$  e  $\mathbf{M}_{\text{XX}}$  pelas expressões (2.11) e (2.12), respectivamente.

$$EQMN_W = \frac{\|\mathbf{x}^\xi - \mathbf{W}_{XX} \lfloor \mathbf{x}^\xi \rfloor\|}{\|\mathbf{x}^\xi\|} \quad (2.11)$$

$$EQMN_M = \frac{\|\mathbf{x}^\xi - \mathbf{M}_{XX} \lceil \mathbf{x}^\xi \rceil\|}{\|\mathbf{x}^\xi\|} \quad (2.12)$$

A fim de obter valores mais confiáveis do desempenho cada experimento foi repetido 100 vezes. Assim, os valores de EQMN apresentados nas tabelas são as médias dos resultados encontrados.

*Exemplo 2.1.* Tolerância da MAAM  $\mathbf{W}_{XX}$  ao ruído subtrativo.

Considerando os padrões fundamentais  $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5$  mostrados na figura 2.2 e usando a equação (2.7) fica construída a MAAM  $\mathbf{W}_{XX}$ . Armazenados os padrões fundamentais na memória, são geradas as suas versões alteradas  $\tilde{\mathbf{x}}^1, \tilde{\mathbf{x}}^2, \tilde{\mathbf{x}}^3, \tilde{\mathbf{x}}^4, \tilde{\mathbf{x}}^5$  introduzindo ruído *pepper*(subtrativo) com distribuição uniforme e probabilidade 0,3 ou 0,5. Nas figuras 2.3 e 2.4 são apresentados os padrões alterados e os padrões recordados pela MAAM  $\mathbf{W}_{XX}$  após serem apresentados os padrões alterados como entrada, respectivamente. Os valores de EQMNs calculados através da equação (2.11) estão listados na tabela I e indicam uma excelente tolerância da MAAM  $\mathbf{W}_{XX}$  a este tipo de ruído.

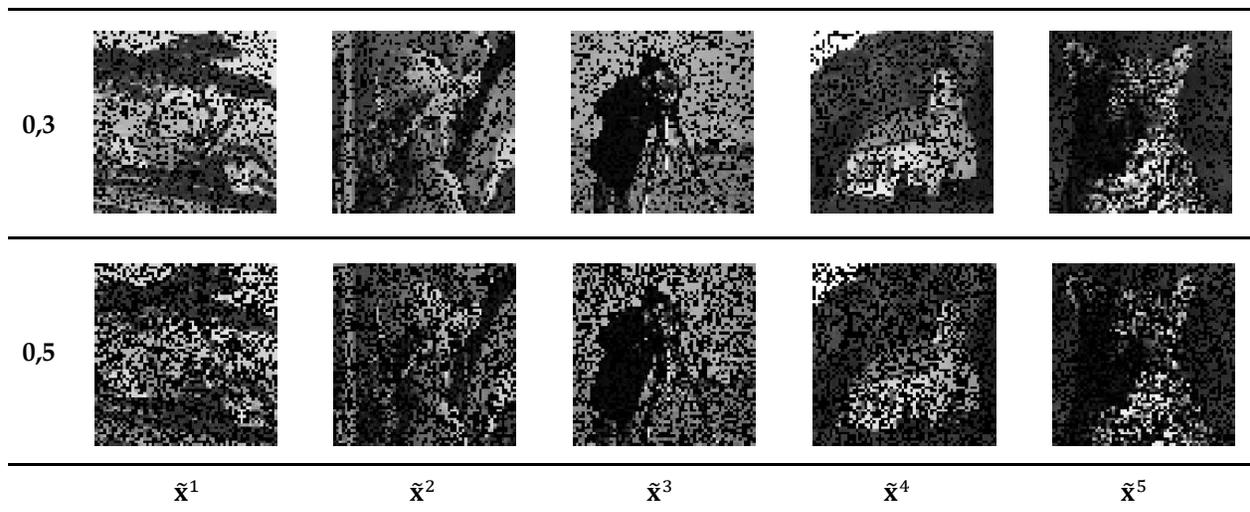


Figura 2.3 – Padrões alterados com ruído subtrativo.

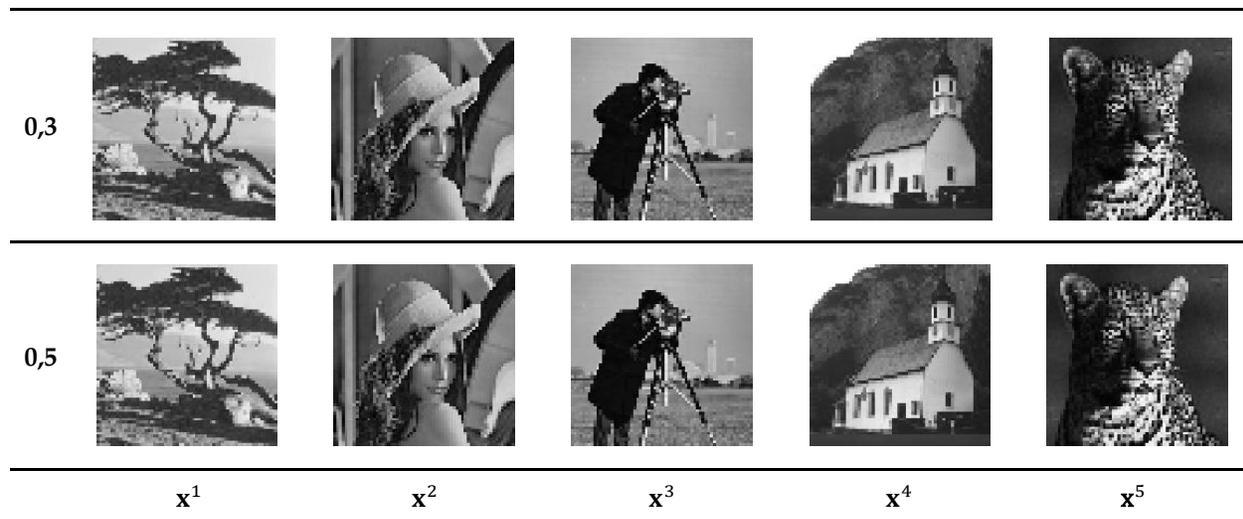


Figura 2.4 – Padrões recordados pela MAAM  $W_{XX}$  quando apresentados padrões alterados com ruído subtrativo como entrada.

Tabela I – EQMNs produzidos pela MAAM  $W_{XX}$  na apresentação de padrões alterados com ruído subtrativo com distribuição uniforme e diferentes probabilidades.

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
<b>0,3</b>	1.335461e-005	6.086948e-006	1.865135e-005	7.517899e-005	1.956408e-005
<b>0,5</b>	3.493436e-005	1.597089e-005	5.299147e-005	1.081827e-004	4.044883e-005

**Exemplo 2.2.** Tolerância da MAAM  $M_{XX}$  ao ruído aditivo.

Um experimento análogo ao anterior é realizado utilizando a MAAM  $M_{XX}$ . Desta vez os padrões são alterados com ruído *salt*(aditivo) com distribuição uniforme e probabilidade de 0,3 ou 0,5, apresentados na figura 2.5. A figura 2.6 mostra os padrões recordados pela MAAM  $M_{XX}$  após apresentados os padrões alterados na entrada, todos os padrões foram recuperados satisfatoriamente. Os valores de EQMN calculados através da equação (2.12) estão listados na tabela II e indicam um ótimo desempenho da MAAM  $M_{XX}$ .

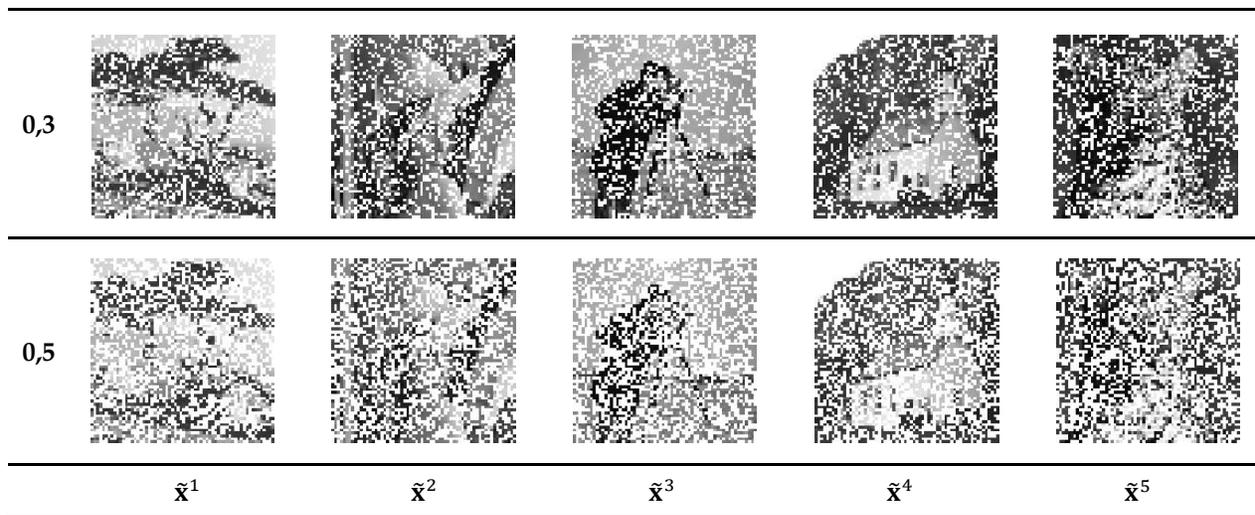


Figura 2.5 – Padrões alterados com ruído aditivo.

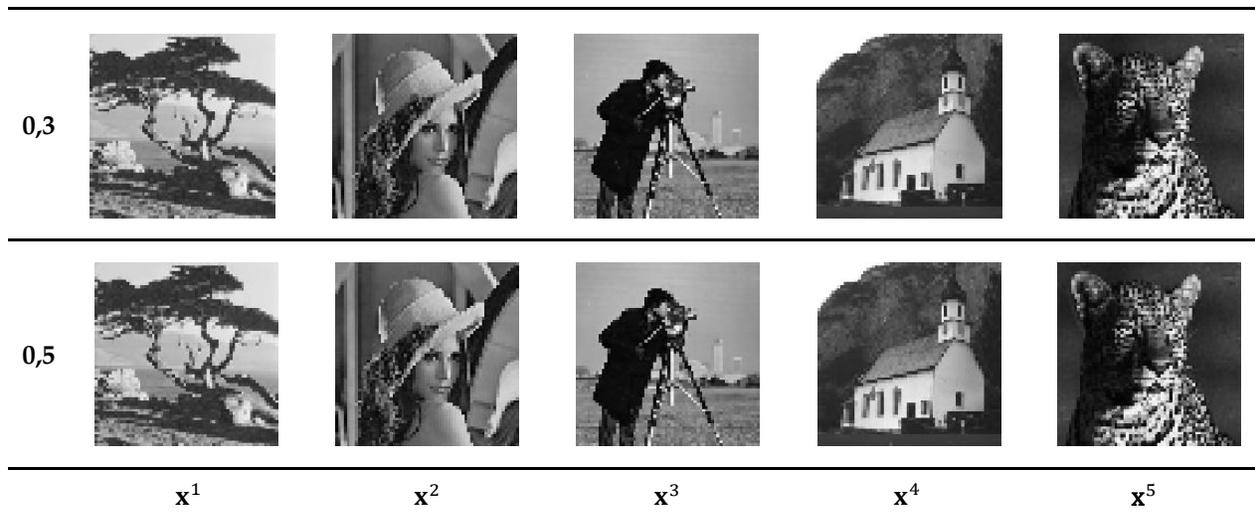


Figura 2.6 – Padrões recordados pela MAAM  $M_{xx}$  quando apresentados os padrões alterados com ruído aditivo como entrada.

Tabela II – EQMNs produzidos pela MAAM  $M_{xx}$  na apresentação de padrões alterados com ruído aditivo com distribuição uniforme com diferentes probabilidades.

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
0,3	1.762919e-005	3.557503e-005	8.957705e-005	8.247912e-005	7.510570e-005
0,5	4.118345e-005	1.135754e-004	2.910975e-004	2.451858e-004	2.088633e-004

Nestes dois exemplos percebe-se claramente a capacidade de recuperação e tolerância ao ruído subtrativo e aditivo das memórias MAAMs  $\mathbf{W}_{XX}$  e  $\mathbf{M}_{XX}$  quando são apresentadas versões contendo ruído subtrativo e aditivo na sua entrada, respectivamente. Nas tabelas I e II podem ser observados valores de erro pequenos resultantes na recuperação dos padrões o que pode ser comprovado visualmente nas figuras 2.4 e 2.6. Os resultados obtidos nestes exemplos serão utilizados para efeitos de comparação com a abordagem proposta no capítulo 3.

## 2.4 Memória Auto-Associativa Morfológica Modificada

A *Gray-scale* MAAM realiza uma caracterização das MAAM para o aprendizado e recuperação de padrões de valor real e foi introduzida em Sussner&Valle (2006). Para resolver o problema das MAAM na recuperação de padrões exclusivamente alterados com ruído aditivo ou subtrativo, Sussner&Valle modificaram a MAAM e habilitaram a *Gray-scale* MAAM para lidar com padrões arbitrariamente alterados.

A idéia utilizada para superar a limitação de exclusividade na tolerância aos ruídos é modificar a fase de recuperação de uma MAAM introduzindo um fator  $\mu$  depois da aplicação da MAAM  $\mathbf{M}_{XX}$ . Especificamente depois de calcular o padrão recordado  $\mathbf{x}^\xi$  a partir de uma versão ruidosa arbitrária  $\tilde{\mathbf{x}}^\xi$  mediante  $\mathbf{M}_{XX} \sqcap \tilde{\mathbf{x}}^\xi = \mathbf{x}^\xi$ , é adicionado o fator  $\mu$  ao padrão recordado. Onde  $\mu$  é calculado pela seguinte expressão:

$$\mu = \frac{[(\mathbf{M}_{XX} \sqcap \mathbf{x}^\xi) \sqcup \mathbf{x}^\xi]}{2} \quad (2.13)$$

Assim para cada padrão chave  $\mathbf{x}^\xi = (x_1^\xi, \dots, x_n^\xi)^t \in \mathbb{R}^n$  para  $\xi = 1, \dots, k$  o padrão recordado será encontrado mediante:

$$\mathbf{x}^\xi = (\mathbf{M}_{XX} \sqcap \tilde{\mathbf{x}}^\xi) + \mu \quad (2.14)$$

Analogamente, para a MAAM  $\mathbf{W}_{XX}$  há o fator  $\nu$ , e o padrão é recordado pelas equações:

$$v = \frac{[(\mathbf{W}_{XX} \boxminus \mathbf{x}^\xi) \boxplus \mathbf{x}^\xi]}{2} \quad (2.15)$$

$$\mathbf{x}^\xi = (\mathbf{W}_{XX} \boxminus \tilde{\mathbf{x}}^\xi) + v \quad (2.16)$$

Teoremas que garantem que esta modificação na fase de recuperação do padrão não altera os pontos fixos de  $\mathbf{M}_{XX}$  e  $\mathbf{W}_{XX}$  e mantêm as características de armazenamento ótimo absoluto e a convergência é obtida em um passo só, conforme pode ser comprovado em Sussner&Valle (2006).

A seguir, são apresentados alguns experimentos computacionais visuais utilizando a *Gray-scale* MAAM para a recuperação de imagens em níveis de cinza a partir de suas versões alteradas arbitrariamente. Por praticidade, as memórias *Gray-scale* MAAM  $\mathbf{M}_{XX}$  e  $\mathbf{W}_{XX}$  são denotadas como  $\mathbf{M} + \mu$  e  $\mathbf{W} + v$ . As imagens utilizadas como padrões fundamentais são as mostradas na figura 2.2. Cada experimento foi realizado 100 vezes e o EQMN foi calculado pelas equações (2.11) e (2.12).

**Exemplo 2.3.** Tolerância da *Gray-scale* MAAM ao ruído aleatório uniformemente distribuído.

Considerando os padrões fundamentais  $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5$ , as memórias  $\mathbf{M}_{XX}$  e  $\mathbf{W}_{XX}$  são construídas. A partir dos padrões fundamentais são geradas as suas versões alteradas  $\tilde{\mathbf{x}}^1, \tilde{\mathbf{x}}^2, \tilde{\mathbf{x}}^3, \tilde{\mathbf{x}}^4, \tilde{\mathbf{x}}^5$  introduzindo ruído aleatório uniformemente distribuído com média 0 e variância 0,03 0,12 ou 0,25. Estas versões alteradas são apresentadas na entrada da memória e os padrões recuperados por  $\mathbf{M} + \mu$  e  $\mathbf{W} + v$  são encontrados. A figura 2.7 mostra os padrões alterados, a figura 2.8 apresenta os resultados deste experimento, e a tabela III apresenta o desempenho das duas memórias em termos dos seus EQMNs.

$\sigma^2 = 0,03$					
$\sigma^2 = 0,12$					
$\sigma^2 = 0,25$					
	$\tilde{x}^1$	$\tilde{x}^2$	$\tilde{x}^3$	$\tilde{x}^4$	$\tilde{x}^5$

Figura 2.7 –Padrões alterados contendo ruído aleatório uniformemente distribuído com média zero.

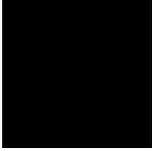
$M + \mu$	0,03					
	0,12					
	0,25					
$W + v$	0,03					
	0,12					
	0,25					
		$x^1$	$x^2$	$x^3$	$x^4$	$x^5$

Figura 2.8 –Padrões recordados pelas MAAMs  $M + \mu$  e  $W + v$  quando são apresentados na entrada padrões alterados com ruído aleatório uniformemente distribuído com média zero.

Tabela III – EQMNs produzidos pelas MAAMs  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  na apresentação de padrões alterados com ruído aleatório uniformemente distribuído com média zero.

		$\mathbf{x}^1$	$\mathbf{x}^2$	$\mathbf{x}^3$	$\mathbf{x}^4$	$\mathbf{x}^5$
$\mathbf{M} + \mu$	0,03	5.832306e-002	6.318700e-002	1.142374e-001	6.343833e-002	2.296574e-001
	0,12	2.602332e-001	1.666531e-001	4.522192e-001	2.452902e-001	1.261473e-001
	0,25	5.038811e-001	3.157950e-001	9.669890e-001	8.742345e-001	2.690972e-001
$\mathbf{W} + \nu$	0,03	1.305834e-002	3.543897e-001	1.950592e-001	2.076132e-001	8.666284e-001
	0,12	1.014121e-001	8.856238e-001	7.409802e-001	9.905374e-001	1.936044e+000
	0,25	1.879204e-001	1.595877e+000	1.228275e+000	1.568856e+000	2.863964e+000

*Exemplo 2.4.* Tolerância da *Gray-scale* MAAM ao ruído gaussiano.

Este experimento é similar ao anterior. As versões alteradas  $\tilde{\mathbf{x}}^1, \tilde{\mathbf{x}}^2, \tilde{\mathbf{x}}^3, \tilde{\mathbf{x}}^4, \tilde{\mathbf{x}}^5$  são geradas introduzindo ruído gaussiano com média zero e variância 0,03 0,12 ou 0,25 e apresentadas às memórias. As figuras 2.9 e 2.10 ilustram visualmente este experimento, onde são mostrados os padrões alterados e os padrões recuperados pela MAAM-GA, respectivamente. A tabela IV informa as médias dos EQMNs de 100 experimentos para cada padrão.

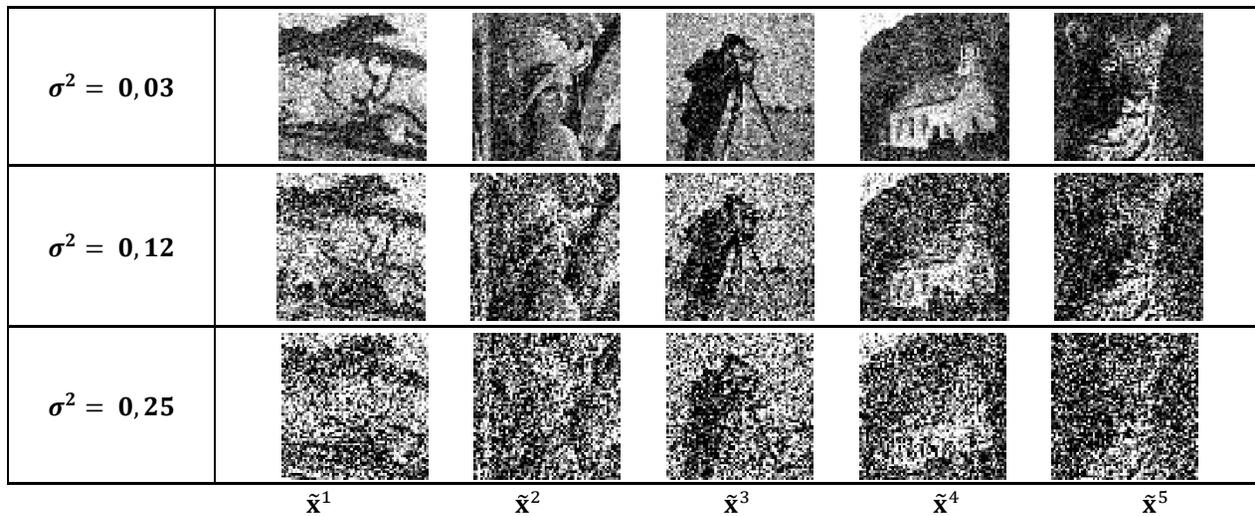


Figura 2.9 – Padrões alterados contendo ruído gaussiano com média zero.

<b>M + μ</b>	0,03					
	0,12					
	0,25					
<b>W + ν</b>	0,03					
	0,12					
	0,25					
		<b>x<sup>1</sup></b>	<b>x<sup>2</sup></b>	<b>x<sup>3</sup></b>	<b>x<sup>4</sup></b>	<b>x<sup>5</sup></b>

Figura 2.10 – Padrões recordados pelas MAAMs **M + μ** e **W + ν** quando são apresentados na entrada padrões alterados com ruído gaussiano com média zero.

Tabela IV – EQMNs produzidos pelas MAAMs **M + μ** e **W + ν** na apresentação de padrões alterados com ruído gaussiano com média zero.

		<b>x<sup>1</sup></b>	<b>x<sup>2</sup></b>	<b>x<sup>3</sup></b>	<b>x<sup>4</sup></b>	<b>x<sup>5</sup></b>
<b>M + μ</b>	0,03	2.973282e-002	7.066080e-002	9.826941e-002	1.122104e-001	2.221030e-001
	0,12	4.418112e-002	1.695661e-001	1.825258e-001	1.732347e-001	2.439407e-001
	0,25	6.375740e-002	1.870422e-001	2.292364e-001	1.932852e-001	2.791952e-001
<b>W + ν</b>	0,03	1.931889e-002	2.339845e-001	2.303874e-001	1.700458e-001	7.306365e-001
	0,12	9.429747e-002	3.489003e-001	2.879791e-001	3.204792e-001	1.319929e+000
	0,25	1.113402e-001	2.968518e-001	4.638488e-001	2.818527e-001	8.418194e-001

**Exemplo 2.5.** Tolerância da *Gray-scale* MAAM ao ruído misto.

Neste experimento, ruído misto em diferentes porcentagens foi adicionado aos padrões fundamentais para formar as entradas alteradas  $\tilde{x}^1, \tilde{x}^2, \tilde{x}^3, \tilde{x}^4, \tilde{x}^5$  mostradas na figura 2.11. A figura 2.12 ilustra o desempenho das memórias  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  na recuperação dos padrões armazenados. EQMNs obtidos estão listados na tabela V.

Tabela V – EQMNs produzidos pelas MAAMs  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  na apresentação de padrões alterados com ruído misto.

		$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
$\mathbf{M} + \mu$	20%	8.700288e-002	2.227529e-001	2.668203e-001	2.589813e-001	3.230663e-001
	35%	8.697939e-002	2.206928e-001	2.567961e-001	2.430633e-001	3.096239e-001
	50%	8.765837e-002	2.107839e-001	2.462853e-001	2.053322e-001	2.910628e-001
$\mathbf{W} + \nu$	20%	1.402923e-001	4.456628e-001	7.040542e-001	3.531830e-001	1.738514e+000
	35%	1.181849e-001	5.001542e-001	5.204769e-001	4.087056e-001	1.242660e+000
	50%	1.292987e-001	2.394488e-001	5.233614e-001	3.132529e-001	1.240636e+000

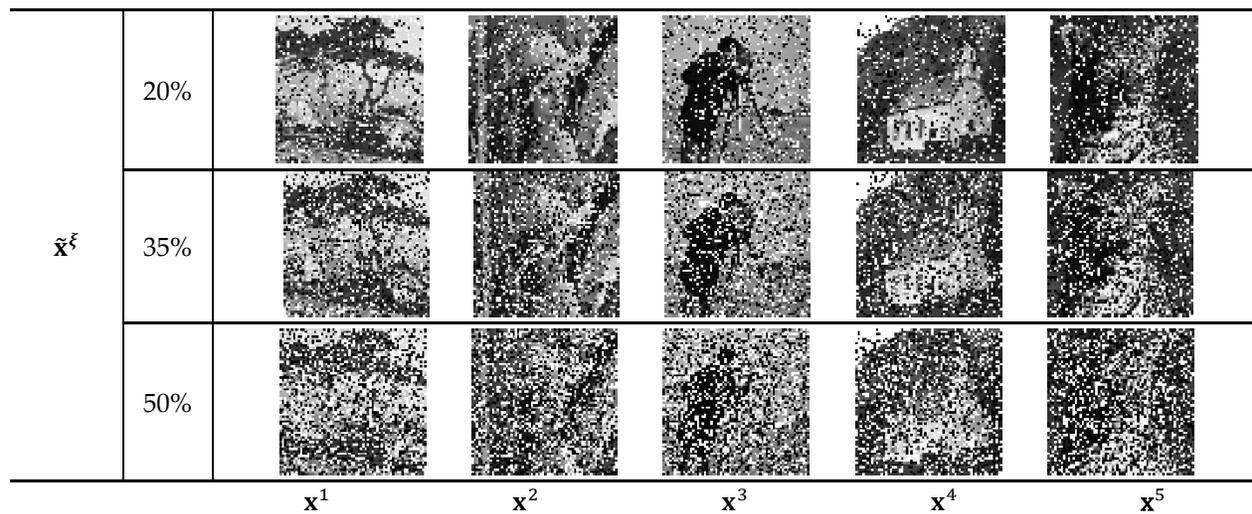


Figura 2.11 – Padrões alterados contendo ruído misto.

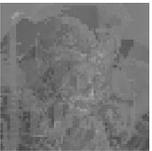
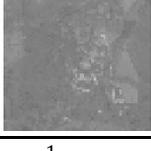
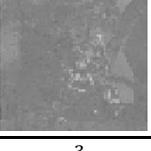
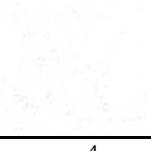
$\mathbf{M} + \mu$	20%					
	35%					
	50%					
$\mathbf{W} + \nu$	20%					
	35%					
	50%					
		$\mathbf{x}^1$	$\mathbf{x}^2$	$\mathbf{x}^3$	$\mathbf{x}^4$	$\mathbf{x}^5$

Figura 2.12 – Padrões recordados pelas MAAMs  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  quando são apresentados na entrada padrões alterados com ruído misto.

Nestes três exemplos pode-se observar e avaliar o desempenho das MAAMs  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  quando são expostas ao reconhecimento de padrões alterados carregando ruídos arbitrários. Para os três tipos de ruídos testados: ruído aleatório uniformemente distribuído, ruído gaussiano e ruído misto, os padrões recordados têm uma porcentagem de erro da ordem de  $10^{-1}$  o que representa um erro significativo para reconhecimento e pode ser comprovado observando os resultados visuais nas figuras 2.8, 2.10 e 2.12. Assim, as MAAMs  $\mathbf{M} + \mu$  e  $\mathbf{W} + \nu$  podem comprometer o reconhecimento por possuir uma robustez ainda limitada quando se tratar com padrões que contenham ruídos arbitrários. Os resultados obtidos nestes exemplos serão utilizados para efeitos de comparação no capítulo 3.

## 2.5 Algoritmos Genéticos

A estrutura matemática dos Algoritmos Genéticos (*Genetic Algorithm, GA*) tornou-se bem popular através do trabalho pioneiro de John Holland “*Adaptation in Natural and Artificial Systems*” (1975; 1992). O GA introduzido por Holland é um método em que uma população de representações abstratas de solução é selecionada em busca de soluções melhores. Assim, a unidade fundamental de um GA são os indivíduos, eles são codificações de possíveis soluções para o problema a ser tratado e é através de sua manipulação (evolução) que respostas são encontradas. Cada indivíduo da população é representado como uma cadeia de genes chamado cromossomo. As características mais importantes de um indivíduo são seu genótipo, fenótipo e o grau de adaptação: o genótipo consiste na informação presente na estrutura de dados que engloba os genes de um indivíduo, já o fenótipo é o resultado do processo de decodificação da estrutura de dados de um indivíduo, por último, o grau de adaptação representa o quão bem a resposta representada pelo indivíduo soluciona o problema proposto.

A evolução é um processo realizado por gerações, opera em cromossomos e geralmente se inicia a partir de um conjunto de soluções criado aleatoriamente. A cada geração a adaptação de cada indivíduo na população é avaliada, alguns são selecionados para serem alterados (reproduzidos) mediante operadores genéticos e formar uma nova população. A nova população então é utilizada como entrada para a próxima geração do algoritmo, e assim sucessivamente.

Em se tratando de propósitos computacionais, um GA simples possui uma estrutura conforme o fluxo mostrado na figura 2.13.

Durante a iteração  $t$ , o GA mantém uma população de cromossomos  $P(t)$  que são as soluções candidatas. Cada cromossomo é avaliado para medir a qualidade da solução do problema representada por este cromossomo, parâmetro chamado de *fitness*. Os indivíduos mais aptos são selecionados e uma população intermediária é formada. Membros desta nova população sofrerão alterações devido à ação dos operadores genéticos de recombinação e mutação gerando novos cromossomos que farão parte da população, muitas vezes substituindo

os cromossomos menos qualificados da população. O GA termina quando um critério de parada predeterminado é satisfeito, como por exemplo, uma solução ótima é alcançada.

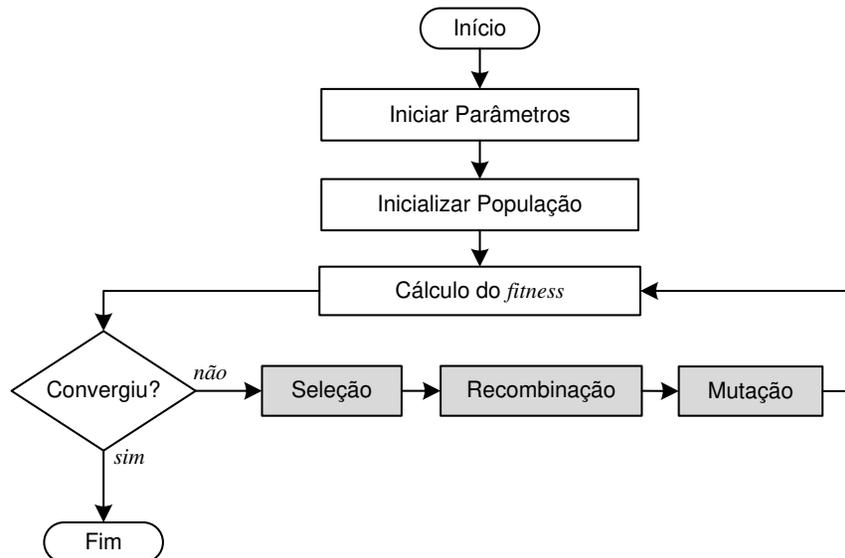


Figura 2.13 –Diagrama de fluxo de um algoritmo genético.

## 2.5.1 PARÂMETROS DE UM ALGORITMO GENÉTICO

Para a implementação de um GA primeiramente devem ser definidos alguns aspectos importantes, tais como, a representação genética para as soluções do problema, população inicial das soluções, tamanho da população, função de avaliação, métodos de seleção dos indivíduos, operadores genéticos para alterar cromossomos e um critério de parada. Dependendo da classe de problema a ser tratado cada um destes aspectos terá um índice de influência no desempenho do algoritmo.

### 2.5.1.1 Representação Genética

Nos GAs, destacam-se dois tipos de representações: a binária e a real ou inteira. A representação binária foi amplamente usada nos GAs clássicos pela facilidade de manipulação e análise simples. Contudo, a representação binária deixou de ser utilizada pelo complexo espaço de busca resultante, quando aplicados a problemas multidimensionais e problemas numéricos

de alta precisão. Sendo que a codificação real é a mais apta nestes casos por possuir um maior grau de representatividade.

### **2.5.1.2 População Inicial**

Uma busca rápida e uma boa cobertura do espaço de busca são essenciais para a resolução de problemas utilizando GAs. Sendo assim, a geração da população inicial torna-se um aspecto importante no processo genético.

Com o objetivo de acelerar o processo de busca, pode-se inserir na população inicial algum conhecimento prévio que indique regiões promissoras do espaço de busca. Em relação à cobertura do espaço, a escolha de uma população inicial maior que a população a ser utilizada nas gerações subsequentes pode melhorar a representação do espaço de busca. Se uma população inicial pequena for gerada aleatoriamente, provavelmente algumas regiões do espaço de busca não serão representadas. Geralmente, utiliza-se um tamanho da população proporcional ao tamanho do cromossomo, isto é, quanto maior for o cromossomo maior deverá ser o tamanho da população a fim de manter uma diversidade razoável.

### **2.5.1.3 Função de Avaliação**

A qualidade dos indivíduos para a solução de um determinado problema é dada por meio dos seus valores de *fitness*. Este valor é calculado por uma função de avaliação, a qual assume de forma análoga papel do ambiente, ou seja, os indivíduos mais bem adaptados a um determinado meio terão valores de *fitness* melhores do que os indivíduos menos adaptados.

### **2.5.1.4 Método de Seleção**

Dada uma população em que a cada indivíduo foi atribuído um valor de *fitness*, existem vários métodos para selecionar os indivíduos pais sobre os quais serão aplicados os operadores genéticos de recombinação e mutação para gerar os indivíduos filhos. Os indivíduos pais selecionados formarão a população intermediária. Os métodos de seleção, na sua grande maioria, são projetados para escolher preferencialmente indivíduos com maiores ou menores valores de *fitness*, embora não exclusivamente, a fim de manter a diversidade da população.

Com base em Michalewicz (1996) alguns destes métodos são apresentados a seguir.

✓ Seleção pelo Método da Roleta

Baseado em Goldberg (1989), este método é aplicado para selecionar  $\lambda$  indivíduos a partir de uma população com  $n$  indivíduos através de um sorteio da roleta. Cada indivíduo da população é representado na roleta proporcionalmente ao seu *fitness*. Assim, os indivíduos com alta aptidão possuem uma porção maior da roleta. A roleta é girada  $\lambda$  vezes e são escolhidos como indivíduos pais que participarão da população intermediária aqueles sorteados na roleta. A aplicação deste procedimento permite a perda do melhor indivíduo e também permite que um indivíduo seja selecionado mais do que uma vez.

Numa implementação comum deste algoritmo os indivíduos são selecionados com probabilidade igual a:

$$P_i = \frac{f_i}{\sum_{j=1}^n f_j} \quad (2.17)$$

Onde  $f_i$  é a adaptabilidade absoluta do indivíduo  $i$ , baseada no *fitness*, mas não necessariamente tem o mesmo valor, e  $\sum f_j$  é a soma das adaptabilidades absolutas de todos os indivíduos da população.

Na figura 2.14a, é ilustrado um exemplo de funcionamento do mecanismo de seleção da roleta com  $n = 14$ .

✓ Seleção por Amostragem Universal Estocástica

Para visualizar este método, considere um círculo dividido em  $n$  regiões (tamanho da população), onde a área de cada região é proporcional ao *fitness*. Colocam-se sobre este círculo uma “roleta” com  $\lambda$  cursores, igualmente espaçados, girando-a uma só vez. Evidentemente, os indivíduos cujas regiões possuem maior área, terão maior probabilidade de serem selecionados, mais de uma vez inclusive. Como consequência, a seleção de indivíduos pode conter várias

cópias de um mesmo indivíduo enquanto outros podem desaparecer. Este tipo de seleção é mais rápido que a Roleta, pois em uma só rodada já são selecionados os  $\lambda$  indivíduos pais. O comportamento deste mecanismo de seleção é ilustrado na figura 2.14b, onde  $n = 14$  e  $\lambda = 7$ .

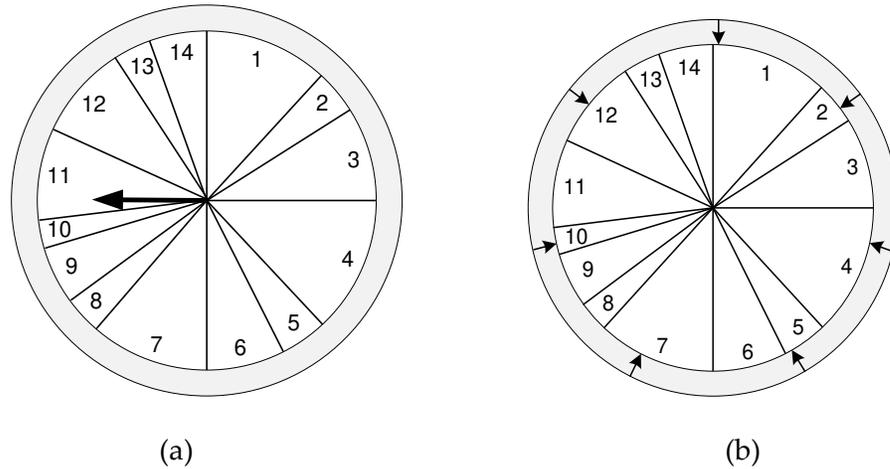


Figura 2.14 –Exemplo de mecanismos de seleção com  $n = 14$  e  $\lambda = 7$ . a) Método da Roleta. b) Amostragem Universal Estocástica.

#### ✓ Seleção por Torneio

Neste mecanismo de seleção, um subconjunto da população com  $k$  indivíduos é sorteado e os melhores indivíduos desse grupo são selecionados para decidir qual irá se reproduzir. Em geral se utiliza  $k = 3$ , isto é, três indivíduos selecionados aleatoriamente da população competem entre si e o ganhador (o de melhor *fitness*) torna-se um dos indivíduos pais que participará da população intermediária. Uma importante propriedade deste mecanismo de seleção é que não leva em consideração a posição que o indivíduo ocupa na população quando ordenado de acordo com o *fitness*, permitindo uma seleção com menos tendências. A figura 2.15 mostra um exemplo do funcionamento deste mecanismo para  $n = 5$  e  $\lambda = 4$ .

#### ✓ Seleção Elitista

Baseado em Fogel (1994), este mecanismo de seleção força o GA a reter um determinado número de melhores indivíduos em cada geração. A aplicação do elitismo previne que tais indivíduos sejam destruídos pela aplicação dos operadores de recombinação ou mutação.

Devido ao seu comportamento, a seleção elitista é sempre utilizada em conjunto com algum outro método de seleção.

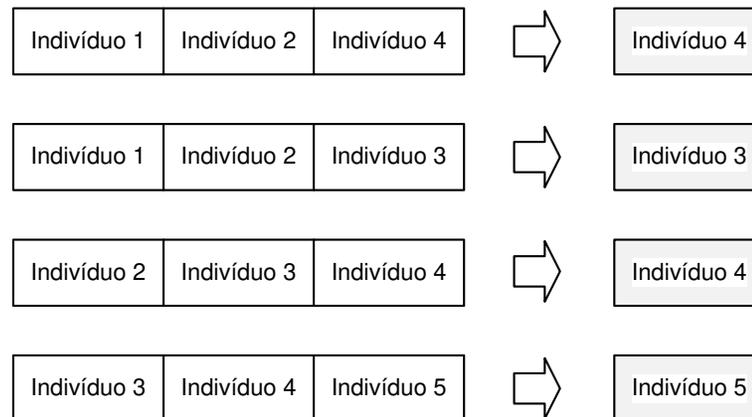


Figura 2.15 –Exemplo de mecanismo de seleção por torneio com  $n = 5$  e  $\lambda = 4$ .

### 2.5.1.5 Operadores Genéticos

São dois os operadores genéticos clássicos que provocam alterações em uma população: a recombinação e a mutação. O operador de recombinação é o mecanismo de obtenção de novos indivíduos pela troca ou combinação dos genes de dois ou mais indivíduos. É o principal operador de reprodução dos GAs (Goldberg, 1989). Fragmento das características de um indivíduo são trocados por um fragmento equivalente oriundo de outro indivíduo. O resultado desta operação é um indivíduo que combina características potencialmente melhores dos pais. O operador de recombinação é aplicado aos cromossomos de acordo com uma probabilidade conhecida como taxa de recombinação. Quanto maior for essa taxa, maior número de indivíduos descendentes formados serão introduzidos na população. Mas se esta for muito alta, a maior parte da população será substituída e poderá ocorrer a perda de indivíduos com alto *fitness*. Com um valor baixo, o algoritmo pode se tornar muito lento. A mutação é necessária para a introdução e manutenção da diversidade genética da população, alterando arbitrariamente um ou mais indivíduos, evitando assim, a estagnação do processo de busca em um subespaço do espaço original de busca. O operador de mutação é realizado invertendo cada gene dos cromossomos com uma probabilidade dada pela taxa de mutação. Uma baixa taxa de mutação

pode assegurar a diversidade na população, mas ao contrário pode destruir toda a informação contida no indivíduo que foi adquirida durante as gerações passadas.

Assim, as taxas de recombinação e mutação devem ser definidas empiricamente para cada domínio de problema, levando em conta as considerações mencionadas. A maior parte da literatura recomenda uma taxa de recombinação entre 75% e 95% e uma taxa de mutação entre 0,5% e 1%.

A escolha dos operadores genéticos está intimamente ligada à codificação adotada para a representação genética, ou seja, existe uma variação no comportamento dos operadores relacionado à codificação empregada nos cromossomos, binária, real ou inteira.

Baseados em Janikow&Michalewicz (1991), a seguir são apresentados alguns dos operadores genéticos mais utilizados para codificação real ou inteira, uma vez que a codificação real é utilizada nesta tese.

✓ Recombinação Simples

O operador genético de recombinação simples é definido da seguinte forma: se os cromossomos  $C_1 = (x_1, \dots, x_q)$  e  $C_2 = (y_1, \dots, y_q)$  são recombinados a partir da  $T$ -ésima posição, os descendentes serão  $C'_1 = (x_1, \dots, x_T, y_{T+1}, \dots, y_q)$  e  $C'_2 = (y_1, \dots, y_T, x_{T+1}, \dots, x_q)$ . Tal operador pode produzir descendentes fora do domínio em questão. Para evitar-se que isso ocorra, pode-se usar a propriedade do espaço convexo, onde  $a \in [0,1]$  tal que:

$$C'_1 = \left( x_1, \dots, x_k, y_{T+1} \cdot a + x_{T+1} \cdot (1 - a), \dots, y_q \cdot a + x_q \cdot (1 - a) \right) \quad (2.18)$$

$$C'_2 = \left( y_1, \dots, y_T, x_{T+1} \cdot a + y_{T+1} \cdot (1 - a), \dots, x_q \cdot a + y_q \cdot (1 - a) \right) \quad (2.19)$$

A figura 2.16 mostra um exemplo do funcionamento de uma recombinação simples com ponto de corte “T” definido e sendo  $a = 0,7$ .

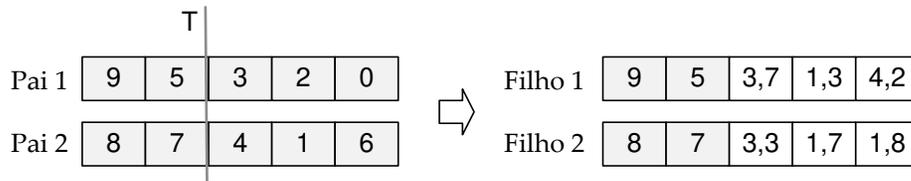


Figura 2.16 –Exemplo de recombinação simples.

✓ Recombinação Aritmética

A recombinação aritmética é definida com uma combinação linear de dois vetores. Se  $C_1$  e  $C_2$  são recombinados, os descendentes são  $C'_1 = a.C_1 + (1 - a).C_2$  e  $C'_2 = a.C_2 + (1 - a).C_1$  onde  $a$  é um número aleatório pertencente ao intervalo  $[0,1]$ , para garantir que  $C'_1$  e  $C'_2$  estejam dentro do domínio de  $C_1$  e  $C_2$ . Na figura 2.17 é ilustrado um exemplo do funcionamento deste operador, onde  $a = 0,7$ .

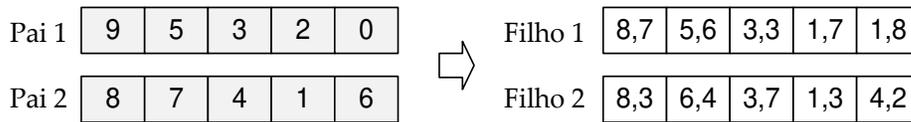


Figura 2.17 –Exemplo de recombinação aritmética.

✓ Recombinação Heurística

A recombinação heurística utiliza valores da função de *fitness* na determinação da direção de busca, gerando apenas um ou nenhum descendente. O cromossomo descendente  $C_3$  é gerado a partir de dois cromossomos pais  $C_1$  e  $C_2$  de acordo com  $C_3 = r(C_2 - C_1) + C_2$ , onde  $f(C_2) > f(C_1)$  e  $r$  é um número aleatório pertencente ao intervalo  $[0,1]$ . A figura 2.18 ilustra o comportamento deste operador, onde  $r = 0,8$ .

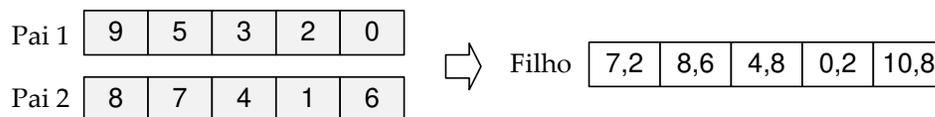


Figura 2.18 –Exemplo de recombinação heurística.

✓ Mutação Uniforme

Este operador seleciona um gene aleatório  $k \in \{1, 2, \dots, q\}$  do cromossomo  $C = (x_1, \dots, x_T, \dots, x_q)$  e produz  $C' = (x_1, \dots, x'_T, \dots, x_q)$  onde  $x'_T$  é um valor aleatório do intervalo do intervalo  $[e(T), d(T)]$ , onde  $e(T)$  e  $d(T)$  são os limites inferior e superior do intervalo que representa o domínio do gene  $x_k$ , respectivamente. Um exemplo é dado na figura 2.19, onde  $q = 5$  e  $T = 4$ .



Figura 2.19 –Exemplo de mutação uniforme.

### 2.5.1.6 Critério de parada

Os critérios de parada de um GA variam de acordo com a aplicação em questão. A finalização da execução pode ocorrer após um número predefinido de gerações, pode ser baseada na repetição sucessiva do melhor indivíduo durante as gerações, pode ser efetuada através da observância de que a média ou desvio padrão do valor de aptidão não sofre alteração no decorrer das gerações, ou simplesmente pára ao encontrar a solução ótima, caso ela seja conhecida.

# Capítulo 3

## Abordagem Neuro-Genética

**E**ste capítulo apresenta a abordagem Neuro-Genética desenvolvida. Na seção 3.1, descreve-se com detalhe a construção da Memória Auto-Associativa utilizando os Algoritmos Genéticos, formando assim a MAAM-GA. Na seção 3.2, é apresentado um estudo detalhado do desempenho da MAAM-GA, quando é utilizado para resolver problemas de recuperação de padrões. Os resultados alcançados são descritos e discutidos na seção 3.3.

### **3.1 Algoritmos Genéticos nas Memórias Auto-associativas Morfológicas (MAAM-GA)**

As Memórias Auto-associativas Morfológicas canônicas, apesar de terem notáveis características para sua utilização e implementação, têm uma robustez exclusiva a específicos tipos de perturbações nos padrões de entrada, limitando sua utilização em problemas reais. Com o propósito de contornar tais limitações, propõe-se a construção de uma Memória Auto-Associativa Morfológica mediante Algoritmos Genéticos para otimizar o processo de sua construção com a finalidade de elevar a robustez na recuperação dos padrões nela armazenados e mantendo suas características computacionais na recuperação. Para a construção da memória, o objetivo do GA é buscar uma matriz de pesos que armazene todos os padrões fundamentais como pontos fixos.

O GA possui muitos parâmetros e métodos que podem ser experimentados na tentativa de melhorar o desempenho do algoritmo. Após um estudo da relação entre essas variáveis, seus efeitos sobre o desempenho final do GA e testes realizados para sua aplicação no problema de reconhecimento de padrões, os detalhes específicos das operações do GA foram definidos como:

Seja  $\mathbf{X} = [\mathbf{x}^1, \dots, \mathbf{x}^k]$  com  $\mathbf{x}^\xi = (x_1^\xi, \dots, x_n^\xi)^t \in \mathbb{R}^n$  um conjunto de  $k$  padrões dado como estado inicial à memória. O cromossomo é uma matriz de valor real de tamanho  $n \times n$ , que representa o conjunto de conexões dos neurônios da MAAM, isto é:

$$\begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{nn} \end{bmatrix} \quad (3.1)$$

A população inicial é formada por indivíduos gerados a partir de  $\mathbf{W}$  e  $\mathbf{M}$  que são as matrizes dos pesos calculados pelo método de aprendizagem da MAAM canônica. Para formar o conjunto completo de indivíduos da população inicial, são inseridas pequenas perturbações aleatórias nas componentes de  $\mathbf{W}$  e  $\mathbf{M}$ . Assim, se  $w_{ij}$  é a  $ij$ -ésima componente de  $\mathbf{W}$ , a perturbação será dada por  $w_{ij} \pm \eta_{ij}$ , onde  $\eta_{ij}$  é uma variável aleatória Gaussiana com média zero e variância pequena. O tamanho da população é mantido constante durante a construção da memória.

Quando um conjunto de  $k$  padrões é dado como estado inicial à memória, o estado dos neurônios varia de iteração a iteração (a menos que seja um ponto fixo do estado estável da rede neural). Para a rede funcionar como uma memória associativa, o estado da rede deverá ser semelhante ao padrão de entrada. Assim, utilizando a matriz MAAM  $\mathbf{W}$ , a similaridade entre o padrão de entrada  $\mathbf{x}^\xi$  e o estado da rede  $\mathbf{W}_{XX} \square \tilde{\mathbf{x}}^\xi$  na iteração  $t$ , para  $\xi = 1, \dots, k$ , é definido como o desvio do padrão  $\xi$  recuperado na iteração  $t$  e determinado por:

$$\boldsymbol{\varepsilon}^\xi(t) = \mathbf{x}^\xi - \mathbf{W}_{XX} \square \tilde{\mathbf{x}}^\xi \quad (3.2)$$

A função utilizada para avaliação da adaptação de cada indivíduo denominada também de valor *fitness* baseou-se na soma dos valores médios quadráticos dos desvios dos  $k$  padrões recuperados na iteração  $t$  e é definida pela equação (3.3).

$$fitness = 1 - \frac{1}{k} \sum_{\xi=1}^k \varepsilon_{rms}^{\xi} \quad (3.3)$$

onde  $\varepsilon_{rms}^{\xi}$  é a raiz média quadrática do vetor  $\varepsilon^{\xi}$  na iteração  $t$  definida por:

$$\varepsilon_{rms}^{\xi} = \sqrt{\frac{\sum_{l=1}^n (\varepsilon_l^{\xi})^2}{n}} \quad (3.4)$$

onde  $\varepsilon_l^{\xi}$  é a  $l$ -ésima componente do vetor  $\varepsilon^{\xi}$ , para  $\xi = 1, \dots, k$ .

Assim, os indivíduos mais bem adaptados terão valores de *fitness* maiores do que os indivíduos menos adaptados. Note que um *fitness* igual a 1 implica que os  $k$  padrões são armazenados como pontos fixos do estado estável da rede, enquanto todos os demais casos terão um *fitness* menor do que 1.

O método de seleção dos indivíduos para reprodução se baseia no método do torneio com elitismo, isto é, três indivíduos selecionados aleatoriamente da população atual competem entre si e o ganhador (o de melhor *fitness*) torna-se um dos indivíduos pais que participarão da reprodução, mecanismo que é repetido até completar o tamanho da população intermediária, definido normalmente em 95% do tamanho da população atual. Os melhores indivíduos da população atual, ou 5% da população atual, são mantidos e fazem parte da nova população. O método de seleção por torneio com elitismo foi comparada com o método da roleta, dando ao GA um desempenho melhor ao alcançar uma solução em menor número de iterações.

O operador de recombinação de dois indivíduos pais para a obtenção de dois novos indivíduos tem como fundamento o método simples para valores reais (ver seção 2.5.1.5) com uma pequena adaptação para a estrutura do cromossomo, isto é, em duas matrizes da população intermediária é selecionada aleatoriamente uma  $T$ -ésima posição de coluna entre 1 e

$n - 1$ , então são geradas duas novas matrizes genes realizando as equações 2.18 e 2.19 em cada fila da matriz. A figura 3.1 mostra o esquema de recombinação.

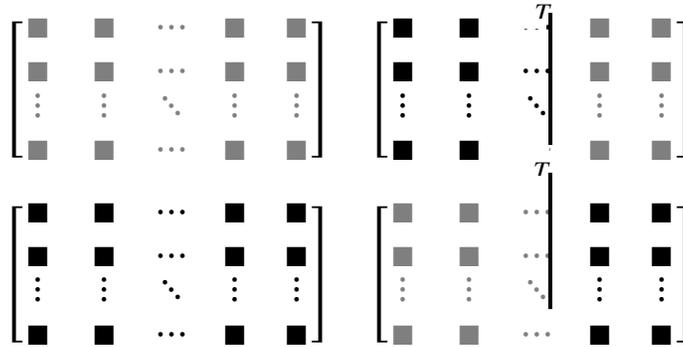


Figura 3.1 –Esquema de recombinação simples em matriz gene.

O operador de mutação do indivíduo tem como princípio a mutação uniforme (ver seção 2.5.1.5) que será aplicado na matriz gene que possua o melhor *fitness*. A coluna  $T$  será escolhida aleatoriamente e as componentes sofrerão mudanças aleatórias com probabilidade  $p_m$ . As mudanças aleatórias são dadas por pequenas perturbações  $\Delta w_{ij} \times \delta$  da componente  $w_{ij}$ , onde  $\Delta w_{ij}$  define o intervalo da mutação para a variável  $w_{ij}$  e  $\delta$  é calculado a partir de uma distribuição que calcula pequenos valores. Baseados no esquema de mutação proposto por Muhlenbein et.al (1994)  $\delta$  é calculado como:

$$\delta = \alpha_0 + \frac{1}{2} \alpha_1 + \frac{1}{2^2} \alpha_2 + \dots + \frac{1}{2^{15}} \alpha_{15} \quad (3.5)$$

onde  $\alpha_0, \dots, \alpha_{15}$  têm valor igual a 1 com uma probabilidade  $1/16$ , em outro caso o valor é 0. Assim, a nova componente é calculada como:

$$w_{ij} \pm \Delta w_{ij} \times \delta \quad (3.6)$$

onde o sinal + ou - é selecionado com igual probabilidade.

O operador de mutação pelo menos deve mudar uma componente da coluna selecionada, assim valores de  $p_m$  podem ser definidos como  $1/n$ . O intervalo de mutação  $\Delta w_{ij}$  é definido em função do domínio da variável  $w_{ij}$ .

Este procedimento sequencial é aplicado até que o número máximo de operações seja atingido ou algum outro critério de parada adotado seja alcançado.

### 3.2 Experimentos e Resultados da MAAM-GA na Recuperação de Padrões

Recuperação e reconhecimento de padrões podem ser vistos como a habilidade de reconhecer objetos provenientes de certas classes a partir de observações obtidas. O reconhecimento robusto deve ser capaz de lidar com pequenas diferenças ou alterações no objeto a ser reconhecido.

Nesta seção é apresentado um estudo do desempenho da abordagem híbrida proposta MAAM-GA quando é utilizado para resolver um problema de recuperação de padrões de valor real com entradas não negativas, isto é, para um padrão de entrada  $\mathbf{x}^\xi = (x_1^\xi, \dots, x_n^\xi)^t \in \mathbb{R}^n$ , então  $x_i^\xi \geq 0$  para todo  $i, \xi$ .

A fase de aprendizado e armazenamento dos padrões na MAAM-GA é realizada seguindo o procedimento descrito na seção 3.1 utilizando os padrões fundamentais  $\mathbf{x}^\xi$  e considerando os seguintes parâmetros: tamanho da população fixa em 300 indivíduos, o intervalo de mutação  $\Delta w_{ij}$  definido em 0,001 vezes o intervalo de busca da variável, isto é, 65.5, a taxa de mutação  $p_m$  é definida em  $100/n = 100/4096$ . O procedimento de busca é realizado no máximo até 10000 gerações, a menos que uma solução seja encontrada.

Uma vez que a memória tenha sido construída, então se inicia a fase de recuperação realizada pelo procedimento descrito na seção 2.3.2 e para medir a diferença entre o padrão recordado e a recordação fundamental, para isto é usado o erro quadrático médio normalizado (EQMN).

O processo de avaliação da MAAM-GA é realizado mediante seis experimentos computacionais. O primeiro verifica a capacidade de armazenamento do conjunto completo de padrões fundamentais. A exatidão da memória armazenada é determinada contabilizando a porcentagem dos pixels corretamente armazenados, e o EQMN dos padrões recuperados quando são apresentados os padrões fundamentais na entrada. No restante dos experimentos, é verificada a robustez da MAAM-GA na recordação dos padrões fundamentais a partir de suas versões alteradas com diferentes tipos de ruído. A tolerância ao ruído na recuperação de padrões é avaliada com base no EQMN que calcula a diferença entre o padrão fundamental armazenado e o padrão recuperado após a apresentação das versões alteradas na entrada da memória.

Durante o conjunto de experimentos computacionais realizados, imagens com 256 níveis de cinza foram considerados padrões. As imagens escolhidas possuem tamanho  $64 \times 64$  e foram transformadas em vetores de 4096 de comprimento formando o conjunto dos padrões fundamentais  $\mathbf{x}^\xi$  para  $\xi = 1, \dots, 5$  mostrados na figura 2.1.

Para garantir a confiabilidade dos resultados, cada experimento foi realizado 100 vezes. Assim, cada valor de EQMN apresentado nas tabelas é a média aritmética simples dos EQMNs encontrados.

### *Experimento 3.1.* Capacidade de armazenamento da MAAM-GA

Neste primeiro experimento verificou-se o armazenamento dos padrões fundamentais como pontos fixos da rede. Os padrões fundamentais  $\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5$  mostrados na figura 2.2 foram utilizados para a construção da memória. Tendo a MAAM-GA formada, foi apresentado na entrada da memória o mesmo conjunto de padrões fundamentais originais e foram encontrados os padrões recordados mostrados na figura 3.2, com uma porcentagem média de pixels corretamente recuperados de 97,7% e um EQMN médio dos padrões recuperados de  $2,7 \times 10^{-6}$ .

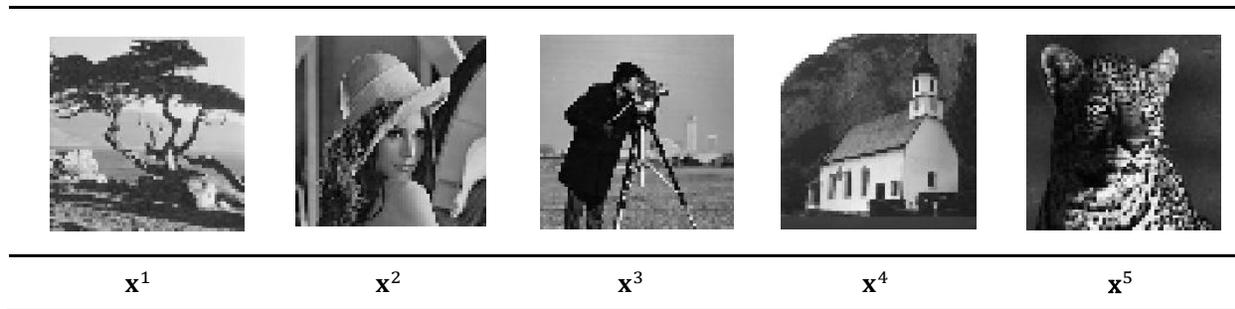


Figura 3.2 – Padrões recordados pela memória MAAM-GA usando como entrada os padrões fundamentais originais visualizados na figura 2.2.

**Experimento 3.2.** Tolerância da MAAM-GA ao ruído subtrativo.

Neste experimento, verifica-se a robustez da memória proposta na recordação dos padrões fundamentais a partir de suas versões alteradas com ruído subtrativo. Com base nos padrões fundamentais  $x^1, x^2, x^3, x^4, x^5$  são geradas as suas versões alteradas  $\tilde{x}^1, \tilde{x}^2, \tilde{x}^3, \tilde{x}^4, \tilde{x}^5$  introduzindo ruído *pepper*(subtrativo) com distribuição uniforme e probabilidade 0,3 ou 0,5. Na figura 2.3 podem ser visualizadas as versões alteradas dos padrões fundamentais, cada versão alterada foi apresentada na entrada da memória e foi calculado o EQMN da recuperação do respectivo padrão. A tabela VI lista os EQMNs encontrados na fase de recuperação dos padrões. Os padrões recuperados podem ser visualizados na figura 3.3.

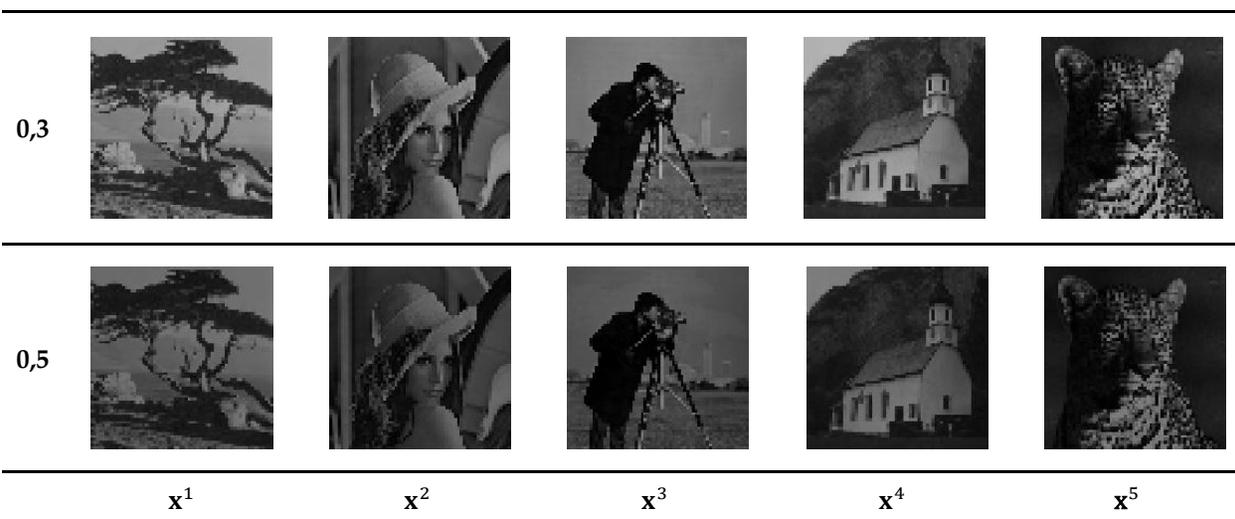


Figura 3.3 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído subtrativo com distribuição uniforme como entrada.

Tabela VI – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído subtrativo com distribuição uniforme e diferentes probabilidades.

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
0,3	1.268021e-002	9.035998e-002	9.282274e-002	8.882474e-002	9.272369e-002
0,5	3.050134e-002	2.479687e-001	2.530383e-001	2.503522e-001	2.581804e-001

**Experimento 3.3.** Tolerância da MAAM-GA ao ruído aditivo.

Um experimento análogo ao anterior é realizado. Neste experimento, verifica-se a robustez na memória proposta quando as versões alteradas carregam ruído aditivo. A partir de  $x^1, x^2, x^3, x^4, x^5$  são gerados  $\tilde{x}^1, \tilde{x}^2, \tilde{x}^3, \tilde{x}^4, \tilde{x}^5$  que são versões alteradas com ruído *salt*(aditivo) com distribuição uniforme e probabilidade de 0,3 ou 0,5. A figura 2.5 mostra as versões alteradas dos padrões fundamentais. Os padrões recordados pela MAAM-GA após apresentarmos as versões alteradas na entrada podem ser visualizados na figura 3.4. Valores de EQMN encontrados são listados na tabela VII e indicam uma boa tolerância da MAAM-GA ao ruído aditivo.

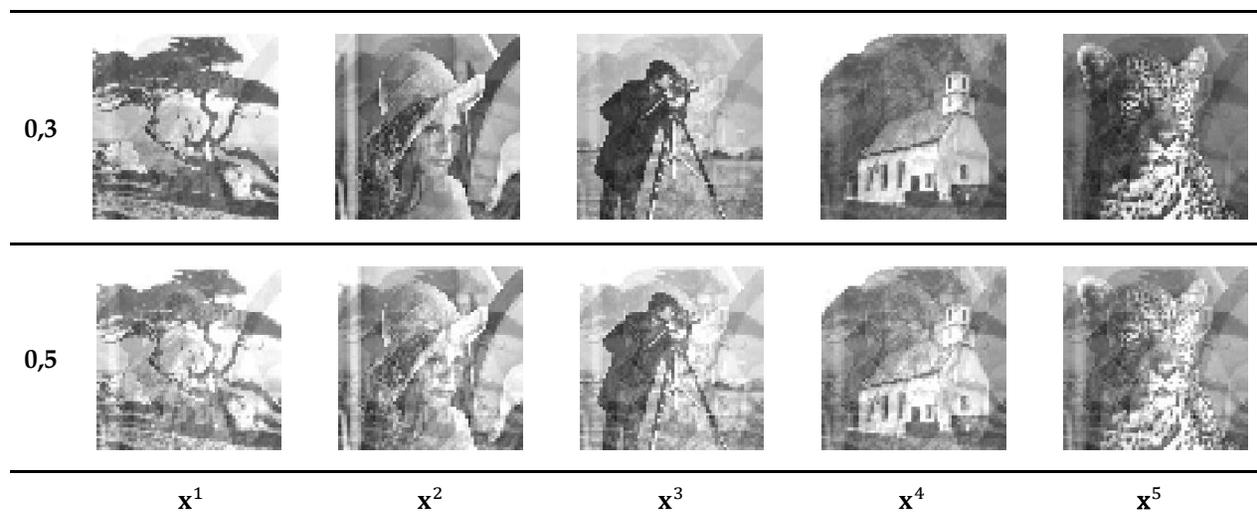


Figura 3.4 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído aditivo com distribuição uniforme como entrada.

Tabela VII – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído aditivo com distribuição uniforme com diferentes probabilidades.

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
0,3	4.524813e-002	6.112112e-002	1.690907e-001	9.280883e-002	1.567155e-001
0,5	1.293222e-001	1.884416e-001	4.605950e-001	2.550900e-001	4.280779e-001

*Experimento 3.4.* Tolerância da MAAM-GA ao ruído aleatório uniformemente distribuído.

Consideremos a MAAM-GA construída com os padrões fundamentais  $x^1, x^2, x^3, x^4, x^5$ . Estes padrões são alterados introduzindo ruído aleatório uniformemente distribuído com média zero e variância 0,03 0,12 ou 0,25 gerando  $\tilde{x}^1, \tilde{x}^2, \tilde{x}^3, \tilde{x}^4, \tilde{x}^5$  mostrados na figura 2.7. Os padrões alterados são apresentados como entradas à memória MAAM-GA e uma interpretação visual dos padrões recuperados é dada na figura 3.5. A tabela VIII mostra os resultados EQMNs obtidos na recordação.

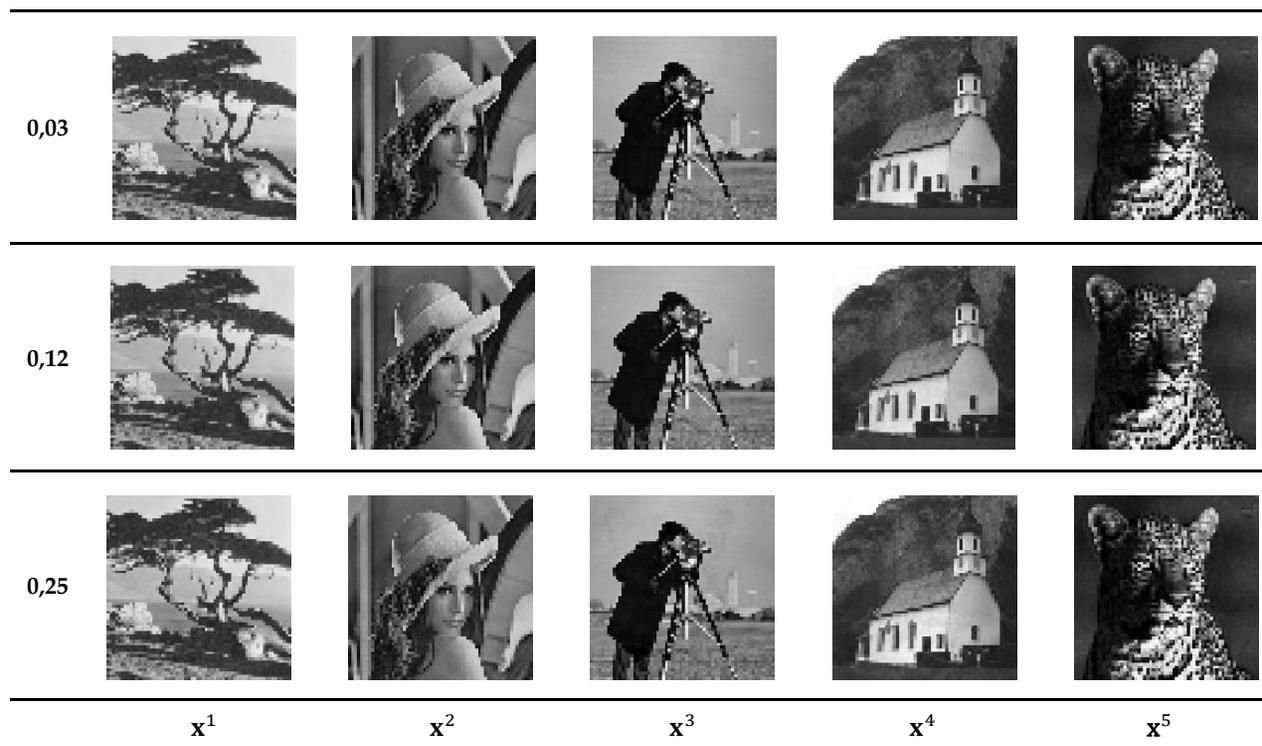


Figura 3.5 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído aleatório uniformemente distribuído com média zero como entrada.

Tabela VIII – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído aleatório uniformemente distribuído com média zero

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
<b>0,03</b>	5.240310e-005	8.724643e-005	1.714501e-004	1.510490e-004	2.074048e-004
<b>0,12</b>	1.835318e-004	4.257665e-004	8.370349e-004	6.023367e-004	7.215770e-004
<b>0,25</b>	2.959063e-004	7.461036e-004	1.581562e-003	8.366631e-004	2.192766e-003

*Experimento 3.5.* Tolerância da MAAM-GA ao ruído gaussiano.

Experimento similar ao anterior, após a construção da MAAM-GA as versões alteradas  $\tilde{x}^1, \tilde{x}^2, \tilde{x}^3, \tilde{x}^4, \tilde{x}^5$  são geradas introduzindo ruído gaussiano com média zero e variância 0,03 0,12 ou 0,25, mostradas na figura 2.9, e apresentadas à MAAM-GA. A figura 3.6 ilustra os resultados visuais da recuperação dos padrões e exibe a capacidade de recordação da proposta. A tabela IX mostra o desempenho da MAAM-GA baseado nos EQMNs obtidos na recordação.

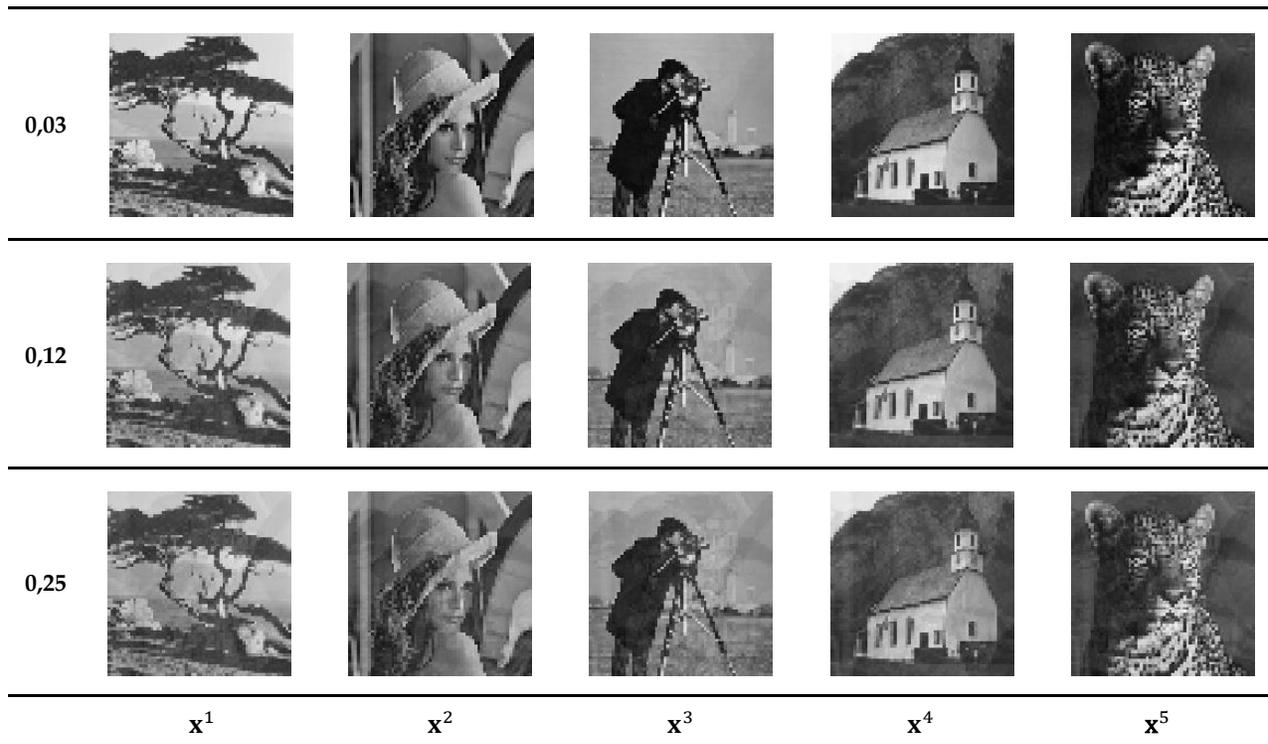


Figura 3.6 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído gaussiano com média zero como entrada.

Tabela IX – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com ruído gaussiano com média zero

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
<b>0,03</b>	4.137323e-004	3.426979e-004	9.132427e-004	1.074432e-003	1.240721e-003
<b>0,12</b>	4.406424e-003	6.686050e-003	9.737151e-003	9.105598e-003	1.300749e-002
<b>0,25</b>	1.152018e-002	1.922748e-002	2.673545e-002	2.170596e-002	3.343591e-002

*Experimento 3.6. Tolerância da MAAM-GA ao ruído misto.*

Neste experimento final, é verificada a tolerância do modelo quando padrões alterados com ruído misto são apresentados à memória. Os padrões alterados com diferentes porcentagens de ruído misto (subtrativo e aditivo) são mostrados na figura 2.11. A figura 3.7 ilustra o desempenho da MAAM-GA na recuperação dos padrões armazenados na presença dos padrões alterados. EQMNs obtidos são listados na tabela X e indicam um ótimo desempenho da recordação de todas as memórias fundamentais.

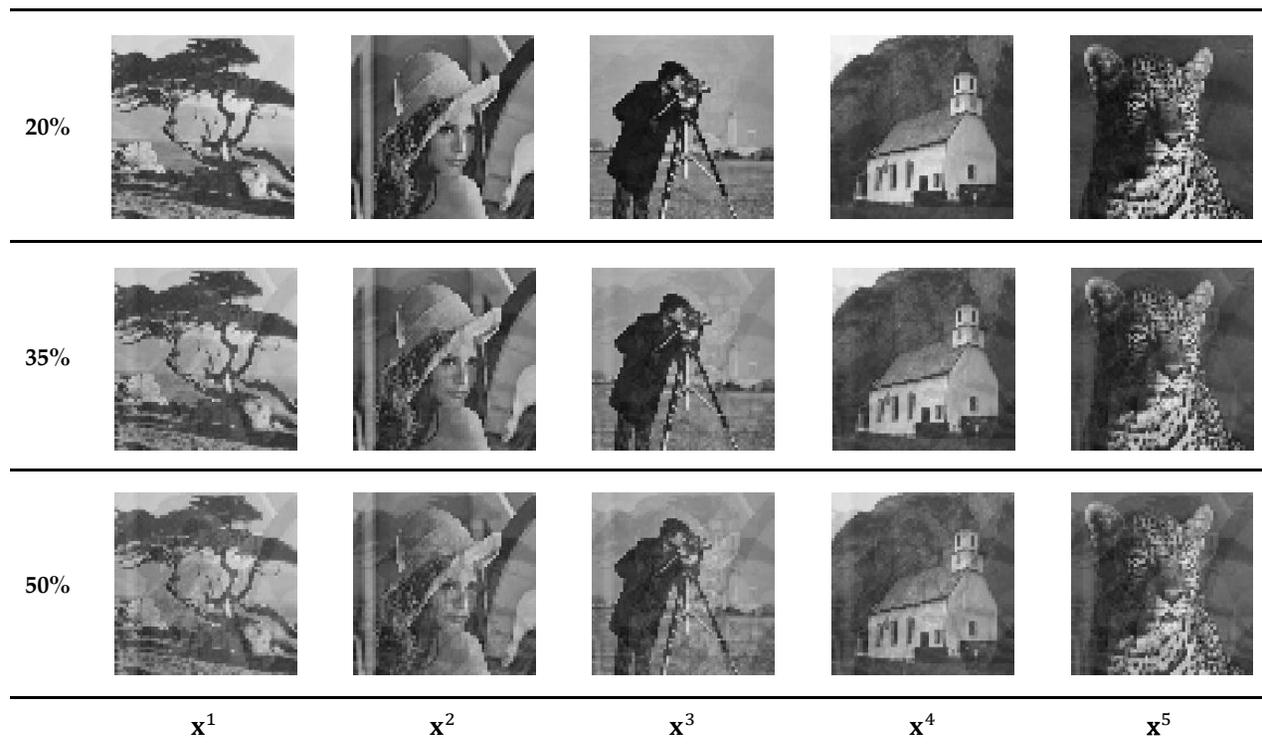


Figura 3.7 – Padrões recordados pela MAAM-GA quando apresentamos os padrões alterados com ruído misto como entrada.

Tabela X – EQMNs produzidos pela MAAM-GA na apresentação de padrões alterados com diferentes porcentagens de ruído misto.

	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$
20%	3.908996e-003	6.497904e-003	7.857466e-003	6.195710e-003	8.652828e-003
35%	1.099667e-002	2.012017e-002	2.571993e-002	2.103260e-002	3.479155e-002
50%	2.250104e-002	4.021135e-002	4.732385e-002	4.288207e-002	6.562400e-002

### 3.3 Discussão de Resultados

No experimento 3.1 para cinco padrões de valor real de tamanho 4096 é verificado que a MAAM-GA armazena com sucesso todos os padrões como pontos fixos e é capaz de realizar o armazenamento com exatidão.

Nos experimentos 3.2 a 3.6 é possível verificar a robustez da MAAM-GA quando é exposta a padrões desconhecidos na entrada. Os padrões desconhecidos são versões ruidosas dos padrões fundamentais e foram geradas introduzindo diversos tipos de ruído: subtrativo, aditivo, aleatório uniformemente distribuído, gaussiano e misto com diversas probabilidades.

Nas figuras 3.3 a 3.7 podem-se observar os resultados alcançados na recuperação dos padrões fundamentais quando são apresentados como entrada padrões alterados mostrados nas figuras 2.2, 2.4, 2.6, 2.8 e 2.10, respectivamente.

Resultados alcançados com a MAAM-GA são comparados com os obtidos por modelos associativos morfológicos mais relevantes para padrões de valor real, MAAM e *Gray-scale* MAAM, especificamente quando os padrões são imagens em níveis de cinza. Para realizar as comparações da maneira mais justa possível, foram consideradas as mesmas condições de teste, os mesmos padrões fundamentais para armazenamento e as mesmas alterações para a geração dos padrões desconhecidos na entrada. Com base nos valores de EQMNs encontrados na recuperação dos padrões fundamentais a partir dos padrões alterados com os diferentes tipos de ruído e listados nas tabelas VI a X são gerados os gráficos apresentados nas figuras 3.8 a 3.12.

A figura 3.8 mostra uma comparação dos EQMNs resultantes da recuperação de padrões quando os modelos MAAM W e MAAM-GA são utilizados para recuperar padrões

fundamentais a partir de padrões alterados com ruído *pepper*(subtrativo) com distribuição uniforme e probabilidade 0,3 ou 0,5. Valores alcançados pelo modelo MAAM W são consideravelmente mais baixos, e em consequência melhores, do que os alcançados pela abordagem híbrida proposta. Porém, resultados visuais alcançados pela abordagem proposta e mostrados na figura 3.3 sugerem que a recuperação dos padrões pode ser considerada aceitável.

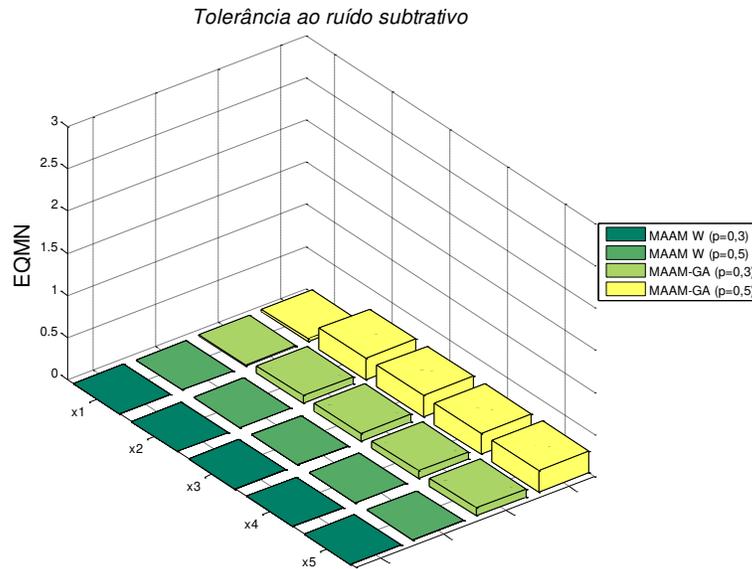


Figura 3.8 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído subtrativo.

Um resultado similar é obtido quando os valores de EQMNs encontrados são comparados entre a abordagem proposta MAAM-GA e o modelo MAAM M na presença de ruído aditivo. As comparações mostradas na figura 3.9 sugerem que a abordagem híbrida proposta consegue uma boa recuperação, que pode ser confirmada visualmente na figura 3.4, porém percebe-se claramente que o poder de recuperação e tolerância ao ruído aditivo é menor ao alcançado com a MAAM M.

Nos experimentos 3.4, 3.5 e 3.6 os resultados obtidos com a abordagem proposta sugerem uma vantagem no reconhecimento frente aos resultados alcançados com o modelo *Gray-scale* MAAM. Ao comparar valores de EQMNs das tabelas VIII, IX e X com os das tabelas III, IV e V respectivamente, percebe-se claramente a superioridade da abordagem proposta na recuperação perfeita e robusta dos padrões alterados para os diferentes índices de alteração e

para os diversos tipos de ruído. As comparações dos valores de EQMN entre as duas metodologias e para as diferentes alterações são ilustradas nas figuras 3.10, 3.11 e 3.12.

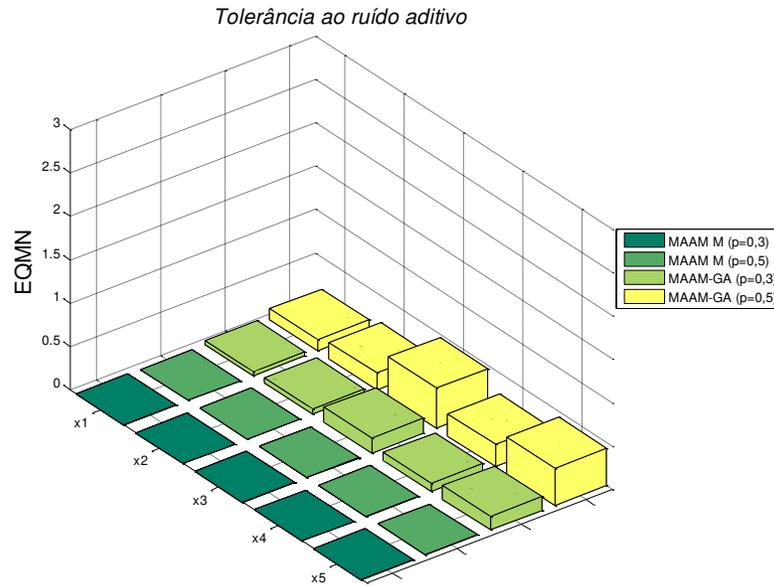


Figura 3.9 –Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído aditivo.

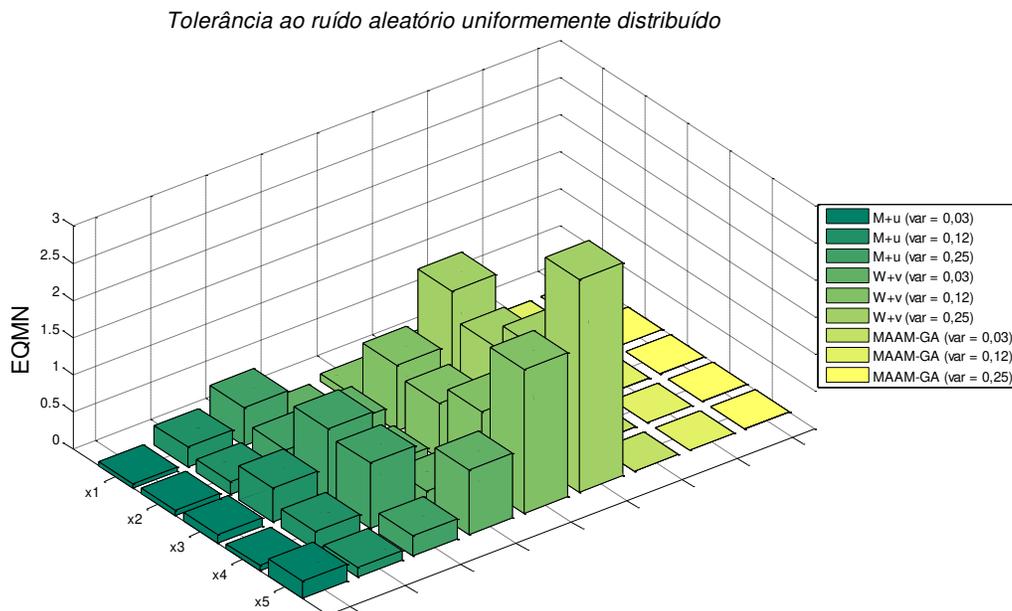


Figura 3.10 –Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído aleatório uniformemente distribuído.

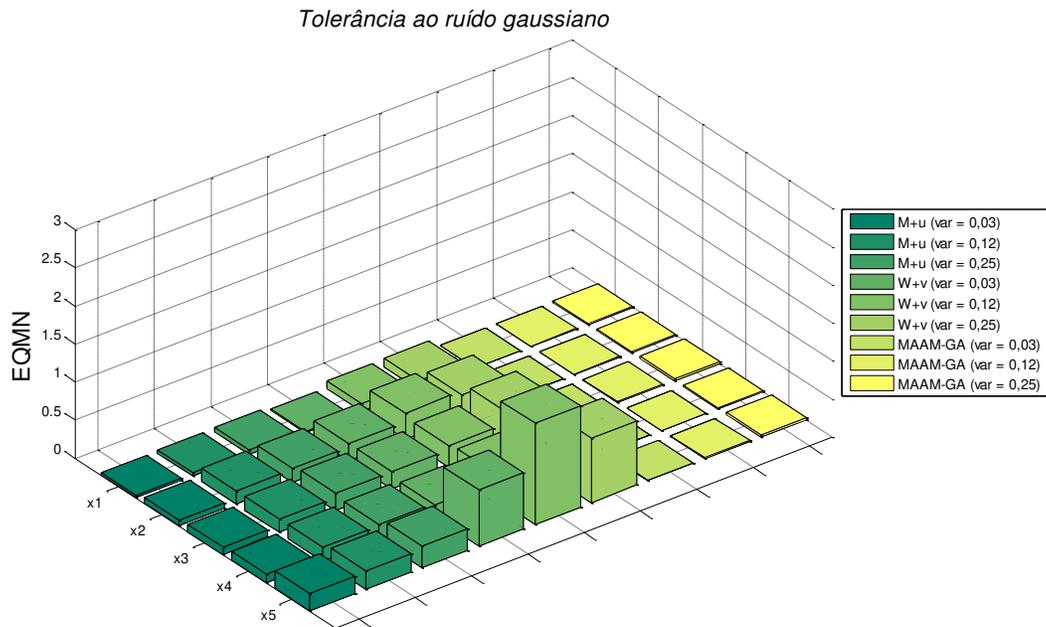


Figura 3.11 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído gaussiano.

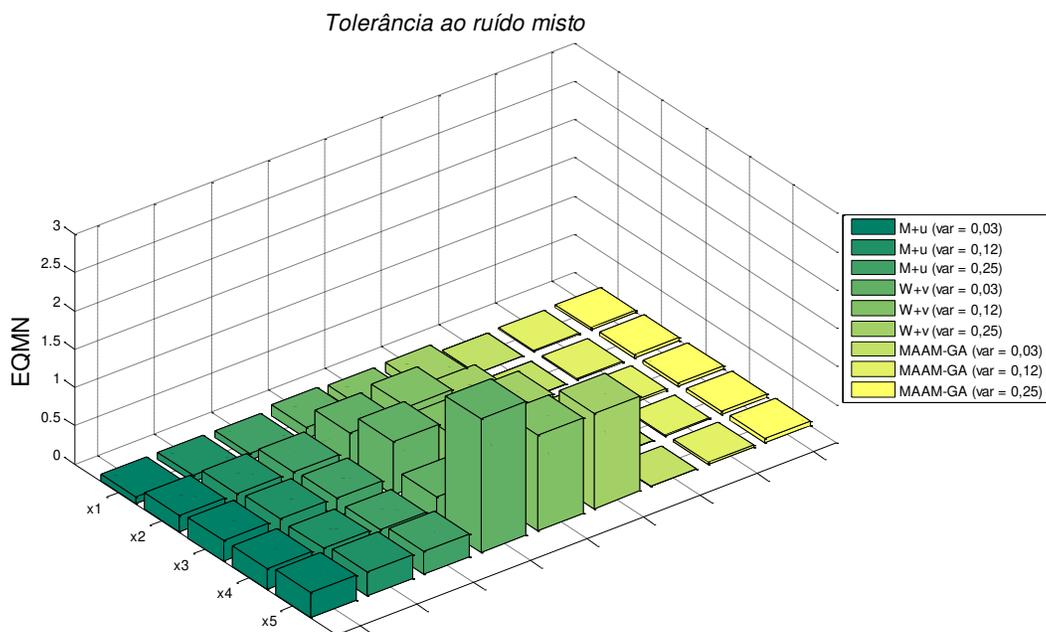


Figura 3.12 – Comparação dos valores de EQMNs resultantes da recuperação de padrões na presença de ruído misto.

Os resultados obtidos e apresentados neste capítulo são muito incentivadores e sugerem que a abordagem proposta MAAM-GA enfrenta de forma robusta e eficiente os diferentes tipos de ruído misto, alcançando altos índices de reconhecimento e oferecendo confiabilidade e exatidão no reconhecimento de padrões. Característica que unida ao fato da resposta da MAAM-GA ser calculada em um passo só propõe a utilização da abordagem proposta MAAM-GA como uma ferramenta efetiva e robusta para reconhecimento a ser usada em diversos problemas de reconhecimento de padrões.

Outra vantagem a ser sublinhada para a utilização da MAAM-GA e que a torna atraente para implementação é a preservação das ótimas características de processamento de dados da MAAM, o que faz a diferença ao trabalhar com um conjunto de dados de dimensão elevada.

Vale a pena mencionar que a abordagem híbrida proposta também pode ser estendida para imagens *true-color* construindo uma memória para cada canal de cor e em seguida combinando a informação recuperada por cada uma das memórias para finalmente recuperar a imagem *true-color*.

Atualmente, são diversos os problemas de reconhecimento reais que podem se basear na metodologia híbrida proposta nesta tese. No próximo capítulo é estudada a utilização da abordagem proposta MAAM-GA como parte de um sistema de reconhecimento de gestos da mão baseado em visão artificial.

# Capítulo 4

## Caso de Estudo: Reconhecimento de Gestos para Interagir em Ambientes Inteligentes

Neste capítulo, são apresentados detalhes da aplicação da abordagem desenvolvida dentro de um sistema de reconhecimento de gestos como caminho natural para interagir em ambientes inteligentes. Na seção 4.1, é descrito o funcionamento do sistema de reconhecimento e as metodologias envolvidas em cada fase do sistema. Resultados alcançados neste caso de estudo são apresentados na seção 4.2.

### 4.1 O Sistema de Reconhecimento de Gestos

O reconhecimento de gestos da mão é uma das áreas de pesquisa muito ativa e várias metodologias têm sido usadas para este propósito, principalmente as baseadas em Data-Glove introduzidas por Sturman e Zeltzer (1994) e as baseadas em Visão descritas em Pavlovic et al. (1997).

Os métodos baseados em Data-Glove usam dispositivos com sensores para digitalizar os movimentos da mão e dedos em dados multi-paramétricos. Os sensores extras tornam fácil a coleta de informações dos movimentos da mão. No entanto, os dispositivos são muito caros e podem trazer uma experiência muito incômoda para os usuários.

Em contraste, os métodos baseados em visão requerem apenas uma câmera, realizando assim uma interação natural entre humanos e computadores sem o uso de qualquer dispositivo extra.

Métodos baseados em visão tendem a complementar a visão biológica descrevendo sistemas de visão artificial que são implementados em software e/ou hardware. Isto coloca um problema desafiador, pois esses sistemas precisam ser invariantes ao fundo da imagem, insensíveis à iluminação, independentes à pessoa e à câmera para alcançar um desempenho em tempo real.

Um sistema de reconhecimento de gestos da mão pode ser tratado como um processo onde o usuário realiza gestos com a mão e o sistema receptor os reconhece. Usando este processo, facilmente pode-se interagir com as máquinas e dar-lhes uma mensagem particular de acordo com a sintaxe da aplicação e do ambiente. Para pessoas que não podem se comunicar oralmente, como é o caso de muitas pessoas com limitações físicas e sensoriais, esta tecnologia pode lhes trazer múltiplos benefícios. Permitindo sua interação com diferentes ambientes dotados de inteligência com o propósito de integrá-las ao círculo virtuoso das atividades, ocupações, direitos e obrigações que fazem parte do universo de qualquer membro de uma sociedade.

Os ambientes inteligentes surgiram com o propósito principal de melhorar a qualidade de vida dos seres humanos baseada em equipamentos computacionais. Assim, fornecem ao usuário do ambiente um espaço virtual que incorpora propriedades de computação ubíqua, comunicação ubíqua e interfaces inteligentes, permitindo a comunicação flexível e natural com o ambiente de computação ou com outros usuários. Computação ubíqua trata da integração de microprocessadores em objetos cotidianos de forma imperceptível. A comunicação ubíqua permite que estes objetos possam se comunicar uns com outros e com o usuário por meio de redes sem fio. Uma interface inteligente permite aos usuários do ambiente realizar o controle e interatuar com o ambiente de uma maneira natural e personalizada. O reconhecimento de gestos da mão é um dos meios de comunicação não invasiva e natural mais utilizado na comunicação em um ambiente inteligente. Sinais realizados por gestos podem facilmente interagir com o

ambiente e proporcionar comandos para controle e interação das diversas aplicações do ambiente.

O caminho mais utilizado para o reconhecimento dos gestos é a detecção da imagem da mão para depois obter informação da imagem e utilizar algoritmos que ajudam a definir o que é dedo do que não é, e assim definir a forma exata da mão e/ou a posição dos dedos. Chaudhary et al. (2011) discutem vários trabalhos realizados na área de reconhecimento de movimentos e gestos da mão usando técnicas de visão computacional e abordagens inteligentes.

Neste capítulo é apresentado um estudo de um sistema de reconhecimento de gestos da mão baseado em visão artificial. O sistema é capaz de reconhecer gestos estáticos da mão utilizando a MAAM-GA, abordagem proposta nesta tese e descrita no capítulo anterior. O fluxo do sistema de reconhecimento de gestos é mostrado na figura 4.1.

Este trabalho faz parte de um projeto conjunto de pesquisa entre a Universidad de Alcalá (UAH/Espanha), a Universidade Federal do Espírito Santo (UFES/Brasil) e a Universidade Estadual de Campinas (UNICAMP/Brasil) que se concentra na linha de pesquisa de Tecnologias de Robótica Móvel e Processamento de Sinais Biológicos, e tem como objetivo a pesquisa e desenvolvimento de alternativas para o controle e guiagem, de forma autônoma ou comandada por sinais biológicos, de cadeiras de rodas. Nas cadeiras de rodas é utilizada a estratégia dos Ambientes Inteligentes, onde grande parte da inteligência necessária é instalada no ambiente por onde a cadeira de rodas se locomove. Assim, no lugar de incorporar na cadeira de rodas uma complexa estrutura sensorial e de processamento, a qual é necessária pela grande quantidade de informação que estes sensores proporcionam com o objetivo de resolver a variedade de situações distintas nas quais a cadeira de rodas deve se mover, a parte mais complexa de tal estrutura sensorial é deslocada para o ambiente, simplificando assim a estrutura necessária a bordo da cadeira.

O desenvolvimento do sistema de reconhecimento de gestos foi realizado parcialmente nos laboratórios do *Departamento de Electrónica* (DEPECA-UAH). Para captura de imagens e pré-processamento das imagens foram utilizados algoritmos desenvolvidos por pesquisadores do DEPECA que possuem vasta experiência na aplicação abordada. Cada etapa do sistema de reconhecimento de gestos, junto com os métodos utilizados, estão descritas a seguir.

#### 4.1.1 CAPTURA E PROCESSAMENTO DE IMAGENS

A captura de imagens foi realizada utilizando uma câmera compacta de vídeo colorido com um sensor CCD progressivo de 1/2" com uma resolução espacial de 656x494. Trata-se da AVT Marlin F-033C do fabricante Allied Vision Technology que proporciona uma capacidade de captura de até 74fps e comunicação Fire-Wire (IEEE 1394).

Para a detecção e segmentação da região da mão foi utilizado o método desenvolvido por Blanco (2008). Este método adiciona na imagem capturada um vetor de cor no espaço RGB (*Red, Green and Blue*) com o objetivo de incrementar a separação entre as classes do objeto e o fundo no espaço de Saturação de Hue (*Hue/Saturation*). Como resultado do algoritmo tem-se imagens estáticas no formato PPM de tamanho 350x400 pixels, com a mão segmentada e colorida de verde para diferenciar a pele do restante da imagem. A figura 4.2 mostra imagens de mãos segmentadas.

Durante o processo de captura de imagens freqüentemente há distúrbios nas condições do ambiente e como consequência as imagens segmentadas possuem pequenas imperfeições, buracos no interior da mão e manchas verdes fora da região da mão, que devem ser tratadas para não ser consideradas como características da imagem do gesto. A figura 4.3 apresenta uma imagem de mão segmentada em fundo branco e sua respectiva superfície mostrando com detalhe algumas imperfeições. O tratamento de suavização das imperfeições é realizado aplicando-se um conjunto de combinações de operadores morfológicos clássicos (dilatação e erosão) sobre a imagem convertida em níveis de cinza. A figura 4.4 apresenta as mesmas imagens segmentadas mostradas na figura 4.2 tratadas morfológicamente e convertidas em imagens branco e preto.

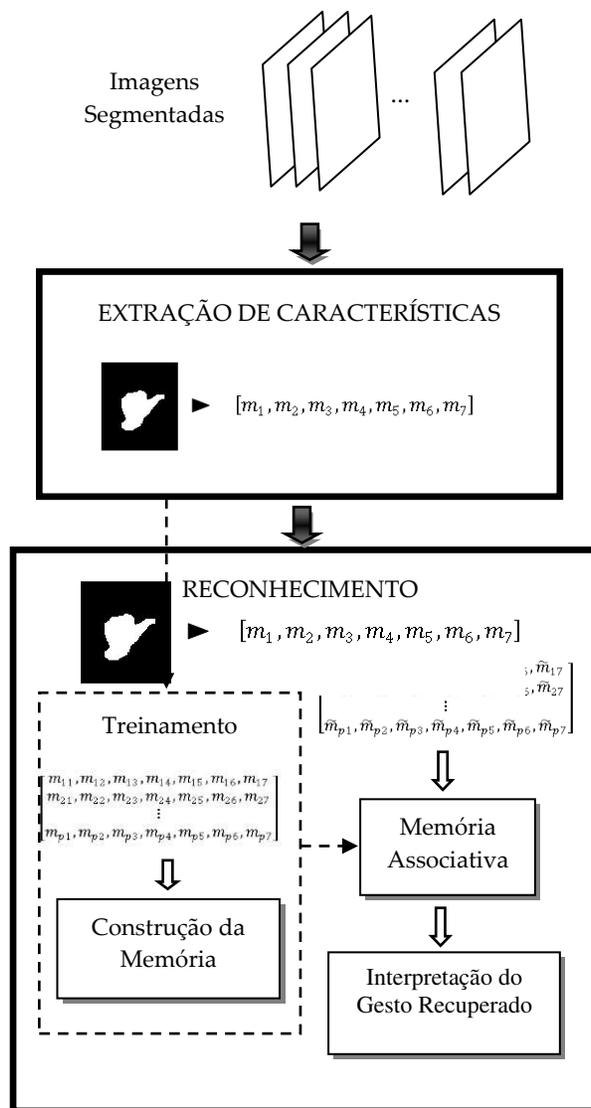


Figura 4.1 – Fluxo do Sistema de Reconhecimento de Gestos usando a MAAM-GA.

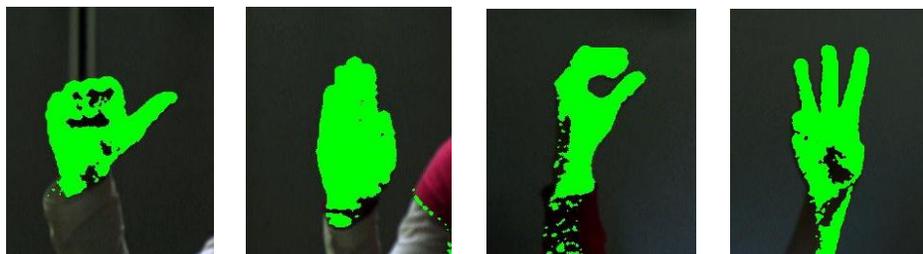


Figura 4.2 – Imagens de gestos das mãos segmentadas correspondentes aos sinais “A”, “B”, “C” e “W” do ASL (*American Sign Language*), respectivamente.

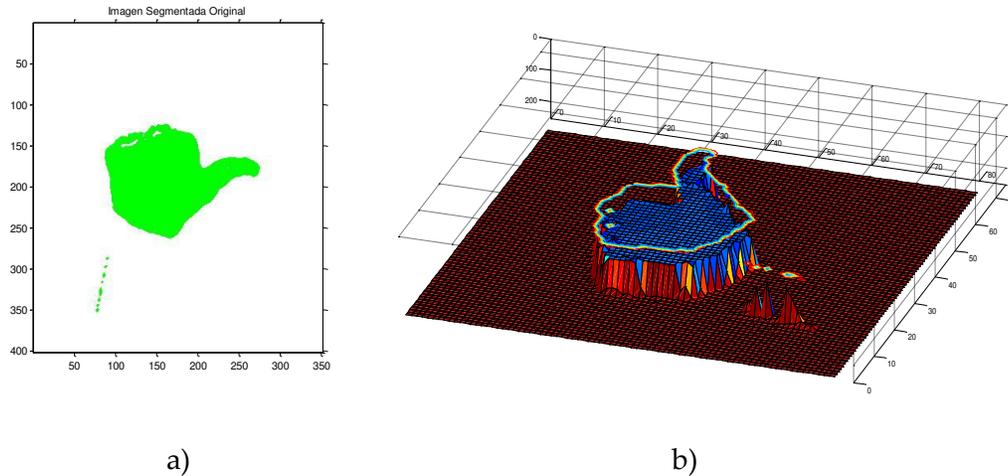


Figura 4.3 – Imagens de gestos das mãos segmentadas correspondentes ao sinal “A” (a) Imagem plana (b) Superfície da imagem evidenciando algumas imperfeições.

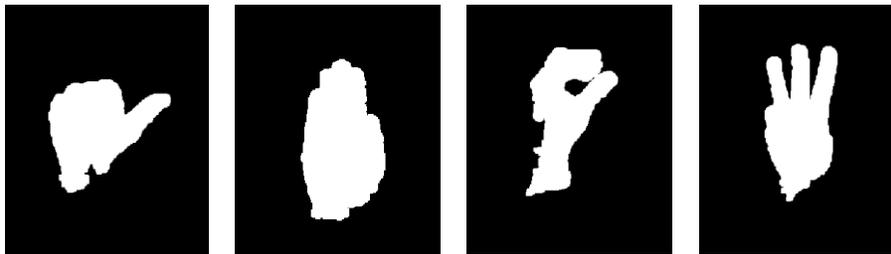


Figura 4.4 – Imagens de gestos das mãos segmentadas correspondentes aos sinais “A”, “B”, “C” e “W” tratadas morfologicamente.

#### 4.1.2 EXTRAÇÃO DE CARACTERÍSTICAS

Para caracterizar cada gesto foram utilizados descritores baseados em momentos invariantes. Os momentos invariantes foram derivados da teoria de álgebra invariante e introduzidos por Hu (1962). A técnica de momentos invariantes tem sido aplicada exitosamente em diferentes áreas, como por exemplo, o reconhecimento de faces por Zhu et al. (2002) e na detecção e reconhecimento de objetos por Muharrem et al. (2005) e Mohamed et al. (2006).

Por definição, dada uma função contínua bidimensional  $f(x, y)$ , o momento de ordem  $p + q$  é descrito na equação 4.1.

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (4.1)$$

Para todo  $p, q = 0, 1, 2, \dots$

Os momentos que satisfazem a propriedade de invariância na translação são chamados de momentos centrais e são definidos como:

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy \quad (4.2)$$

Onde  $\bar{x} = \frac{m_{10}}{m_{00}}$  e  $\bar{y} = \frac{m_{01}}{m_{00}}$  são as coordenadas do centróide.

Para uma imagem digital têm-se:

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad (4.3)$$

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (4.4)$$

Os momentos centrais normalizados invariantes à escala da imagem podem ser definidos como:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad (4.5)$$

Onde  $\gamma = \frac{p+q}{2} + 1$ , para  $p + q = 2, 3, \dots$

Em particular, para descrever cada gesto foram utilizados sete valores calculados conforme em Hu(1962) baseados nos momentos centrais normalizados de ordem dois e três. Estes valores são momentos invariantes à escala, posição e orientação de cada gesto. Em termos

de momentos centrais normalizados os sete momentos invariantes estão definidos na equação 4.6.

$$\begin{aligned}
 m_1 &= (\eta_{20} + \eta_{02}), \\
 m_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \\
 m_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \\
 m_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \\
 m_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
 &\quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \\
 m_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}), \\
 m_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
 &\quad - (\eta_{30} + 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
 \end{aligned} \tag{4.6}$$

Utilizando as expressões anteriores são determinadas as sete características geométricas que formam o vetor de características para cada imagem gestual.

As tabelas XI e XII apresentam exemplos de vetores característicos de gestos correspondentes a sinais diferentes e gestos correspondentes ao mesmo sinal, respectivamente. Os gestos considerados na formação dos vetores são mostrados nas figuras 4.4 e 4.5.

Tabela XI – Vetores característicos de gestos correspondentes a sinais diferentes mostrados na figura 4.4.

	"A"	"B"	"C"	"W"
<i>m1</i>	0,1919945745	0,1996561995	0,2778753896	0,5056908629
<i>m2</i>	0,0028480624	0,0132431825	0,0372594696	0,1240153581
<i>m3</i>	0,0024956443	0,0003178028	0,0051059468	0,2381932642
<i>m4</i>	0,0001399276	0,0000377190	0,0014080078	0,1801243400
<i>m5</i>	0,0000000358	0,0000000039	0,0000037192	0,0373097823
<i>m6</i>	-0,0000000103	0,0000034589	0,0002637715	0,0579271680
<i>m7</i>	0,0000000745	-0,0000000014	-0,0000006484	0,0000633681

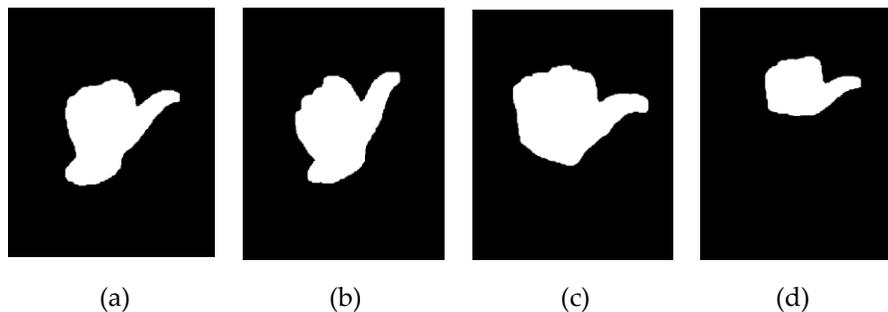


Figura 4.5 – Imagens de gestos das mãos segmentadas e tratadas morfologicamente correspondentes ao sinal “A”.

Tabela XII – Vetores característicos de gestos correspondentes ao sinal “A” mostrados na figura 4.5.

“A”	a)	b)	c)	d)
<i>m1</i>	0,1983589266	0,1922630451	0,1823093252	0,1934887665
<i>m2</i>	0,0050896469	0,0045388775	0,0023266089	0,0064954014
<i>m3</i>	0,0026870071	0,0016124699	0,0012552162	0,0011364207
<i>m4</i>	0,0001227797	0,0001349562	0,0001812815	0,0003203368
<i>m5</i>	0,0000000028	0,0000000562	0,0000000864	0,0000001883
<i>m6</i>	-0,0000049295	0,0000029114	0,0000085367	0,0000254418
<i>m7</i>	0,0000000705	0,0000000285	-0,0000000026	-0,0000000435

#### 4.1.3 TÉCNICA DE TREINAMENTO E RECONHECIMENTO

Nesta etapa do procedimento foi utilizada a MAAM-GA proposta e descrita no capítulo anterior como uma ferramenta efetiva e robusta para o reconhecimento de padrões. O reconhecimento de gestos pode ser um caso de aplicação de uma memória auto-associativa, isto é, o padrão de entrada armazenado deve ser o mesmo padrão a ser recuperado. Cada gesto representado por um vetor de características é considerado como um padrão fundamental a ser armazenado na memória. A memória é construída mediante um processo de treinamento onde os pesos da memória são otimizados utilizando um algoritmo genético, e onde cada um dos padrões de entrada é um padrão fundamental a ser armazenado na memória, para posteriormente, e mediante operações matriciais, recuperar o padrão associado ao padrão de entrada mais provável de acordo com as características armazenadas.

A fase de armazenamento dos padrões na MAAM-GA é realizada seguindo o procedimento descrito na seção 3.1 e utilizando os vetores característicos como memórias fundamentais. Um total de 30 indivíduos foi utilizado na população do GA e a taxa de mutação utilizada foi de 0.1 para este tamanho da população. O procedimento de busca foi realizado usando-se um máximo de até 1000 gerações. Os resultados obtidos estão resumidos na seção seguinte.

## 4.2 Resultados Obtidos no Sistema de Reconhecimento de Gestos

Na fase de armazenamento de padrões os vetores característicos dos padrões foram armazenados calculando-se a respectiva matriz de pesos. Na fase de reconhecimento, a partir de uma configuração arbitrária, a memória foi associada ao padrão armazenado mais próximo da configuração inicial. Assim, quando são armazenados alguns vetores característicos padrões de gestos capturados a diferentes condições ambientais e tamanhos, ao apresentar novos vetores característicos à entrada da estrutura, esta será capaz de associar os dados de entrada ao padrão armazenado.

Este estudo examinou imagens de gestos pertencentes a um subconjunto da língua de sinais americana (ASL do termo em inglês *American Sign Language*), estas imagens passaram por uma etapa de pré-processamento antes de serem apresentadas ao processo de reconhecimento. A linguagem ASL foi utilizada para continuar com os trabalhos iniciados no DEPECA e facilitar a provável avaliação do método de reconhecimento com os outros anteriormente propostos.

As imagens consideradas para teste foram as correspondentes aos sinais A, B, C, H e W mostradas na figura 4.6.

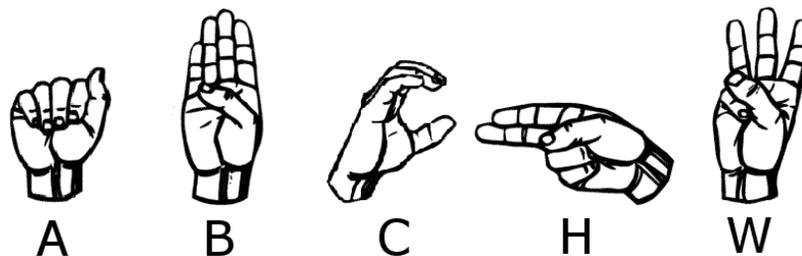


Figura 4.6 – Subconjunto de sinais do ASL selecionadas para teste.

Durante a construção da memória foram utilizadas 25 imagens de cada gesto, gestos produzidos por diferentes pessoas e diferentes condições ambientais. Para validação da abordagem proposta, foram escolhidas aleatoriamente 10 imagens de cada gesto formando um conjunto de 50 imagens no total. Este conjunto de imagens foi apresentado como entrada à memória, através de 100 sequências em ordem aleatória.

O desempenho foi avaliado calculando-se o percentual de interpretações corretas e interpretações erradas. As taxas de reconhecimento obtidas e listadas na tabela XIII são as porcentagens de interpretação correta. A taxa de reconhecimento média obtida foi de 92.22%. Esta taxa de reconhecimento demonstra a robustez de cada módulo do sistema proposto. Os erros de reconhecimento foram ocasionados principalmente pelas falsas características extraídas das imagens da mão.

Tabela XIII – Desempenho da MAAM-GA no reconhecimento de gestos estáticos.

Sinal	Dados de Treinamento (%)	Dados de Validação (%)
"A"	98,4	93,9
"B"	98,9	92,6
"C"	99,2	91,8
"H"	98,1	90,1
"W"	99,0	92,7

Resultados alcançados com a MAAM-GA foram comparados com resultados obtidos anteriormente e publicados por Alvarez&Oliveira (2010) quando foi utilizada uma memória formada unicamente pela MAAM. Na tabela XIV, pode-se observar a comparação das taxas de reconhecimento. As condições de construção de memória e testes de validação foram as mesmas para os dois tipos de experimentos.

A proposta de hibridização MAAM-GA descrita neste trabalho além de alcançar altos índices de reconhecimento oferece uma alta confiabilidade e exatidão no reconhecimento de gestos.

Tabela XIV – Comparação de desempenho da MAAM e MAAM-GA no reconhecimento de gestos.

Sinal	Dados de Validação MAM (%)	Dados de Validação MAAM-GA (%)
"A"	92,7	93,9
"B"	91,4	92,6
"C"	90,9	91,8
"H"	89,3	90,1
"W"	91,8	92,7

# Capítulo 5

## Discussões, Conclusões e Trabalhos Futuros

Nesta tese, está proposta uma solução pragmática completa ao problema de recuperação de padrões de valor real usando uma MAAM canônica em combinação com um GA para a construção da memória, que proporciona elevada exatidão e confiabilidade da recuperação de padrões. Neste capítulo são discutidas características da aplicação de GAs em MAAMs. Conclusões da aplicação da abordagem híbrida proposta são apresentadas e trabalhos futuros discutidos.

### 5.1 Aplicação de GAs em MAAMs

Por definição uma MAAM já possui uma estrutura determinada. Na abordagem híbrida proposta nesta tese o GA foi utilizado para encontrar os melhores parâmetros de conexão da MAAM. Para aperfeiçoar a formação da MAAM de maneira adequada, o GA utilizado sofreu algumas alterações em comparação ao GA canônico, usando uma representação matricial com componentes de valor real para cada indivíduo, um método de seleção para reprodução baseado no método do torneio com elitismo, os operadores de recombinação e mutação foram também acondicionados para a reprodução dos indivíduos em representação matricial. A combinação destas melhorias e principalmente o método de seleção por torneio comparado com o método clássico da roleta, ajudaram a aumentar a taxa de convergência aproximadamente em 50% de

gerações para alcançar o mesmo resultado e um aumento da proporção de convergência de cerca de 70% a mais de 90% sobre o problema de reconhecimento de imagens em níveis de cinza. Este GA condicionado foi aplicado para problemas de reconhecimento de padrões quando os padrões são imagens em níveis de cinza de tamanho 64x64, e mostrou-se bem sucedido em resolver a recuperação de padrões para entradas alteradas com ruídos aleatórios mistos. No entanto, verificou-se que uma função de *fitness* bem definida foi primordial e um ponto crucial para o sucesso da aplicação do GA neste problema. Em conclusão, o GA mostrou-se um método muito eficaz e promissor para encontrar os parâmetros da MAAM. Alguns dos benefícios de usar um GA incluem a capacidade de lidar facilmente com funções de avaliação não diferenciáveis e sua natureza inerentemente paralela do algoritmo. A avaliação de cada indivíduo que é a parte mais intensa do algoritmo, computacionalmente falando, pode ser facilmente distribuída em múltiplos processadores, permitindo uma aceleração significativa relativa ao número de processadores.

## 5.2 Características Práticas de Aplicação de GAs

Os GAs não são um algoritmo definido rigorosamente com respeito aos detalhes de implementação. Esta característica tem vantagens e desvantagens. A vantagem é que permite ser flexível de modo que sua implementação possa ser modificada para atender a uma ampla gama de problemas. A desvantagem é que os detalhes de sua implementação podem necessitar de modificações para que obtenha bons desempenhos em um problema específico. A experiência adquirida com um GA mostrou que mesmo pequenas mudanças no algoritmo, tal como taxa de mutação, método de seleção, ou outra, pode levar a uma diferença significativa em seu desempenho.

A partir dos experimentos realizados nesta tese, mostrou-se que não é fácil aplicar o GA para um problema particular. Ele exige uma quantidade significativa de esforço na primeira tentativa de encontrar os métodos e seus parâmetros para obterem-se resultados satisfatórios.

### 5.3 Limitações do sistema de reconhecimento de gestos

O bom desempenho do sistema de reconhecimento de gestos para as ações que foram projetadas não pode ser generalizado para todo tipo de gestos, isto é, o sistema atualmente não possui grau de confiabilidade para gestos dinâmicos, em movimento. Estes gestos terão que ser reconhecidos por etapas. Estes tipos de gestos não foram considerados na aplicação.

Interfaces de gestos da mão são tecnologias de interação muito importantes para a coexistência e cooperação com outras interfaces e para aumentar as possibilidades de comunicação com computadores. Há situações quando as mãos não podem ser utilizadas, por exemplo, quando o gesto é socialmente inaceitável ou quando a deficiência impede a sua utilização.

O processamento de visão computacional ainda necessita de uma elevada capacidade computacional e altas cargas de processamento de dados. Enquanto câmeras inteligentes e chips de visão prometem atenuar esses fatores, o mercado de hardware deverá dominar nas situações onde haja o emprego de plataformas de visão, pelo menos nos próximos cinco anos.

### 5.4 Conclusões e Trabalhos Futuros

Esta tese apresentou o desenvolvimento de uma nova e efetiva abordagem neuro-genética constituída por um GA e uma MAAM para a solução de problemas de reconhecimento de padrões.

A abordagem proposta mantém a robustez das MAAMs para lidar com ruídos subtrativos e aditivos e estende sua funcionalidade para lidar com outros tipos e quantidades de ruído misto aleatório. Os resultados dos experimentos computacionais comprovam que uma abordagem evolutiva como os GAs é uma ferramenta muito eficiente e adaptável para otimização dos parâmetros de uma MAAM para um problema específico. A abordagem foi direcionada para a recuperação de padrões de valor real. Porém o uso com padrões binários, bipolares pode também ser explorado, não existindo nenhuma limitação para sua aplicação.

Para validar o desempenho da abordagem proposta foi realizado um estudo usando imagens em níveis de cinza como padrões. Experimentos computacionais foram realizados considerando os mesmos padrões fundamentais para armazenamento, as mesmas alterações e as mesmas condições de teste para realizar comparações justas dos resultados alcançados entre o modelo proposto e outros dois modelos associativos MAAM (Ritter et al., 1998) e *Gray-scale* MAAM (Sussner&Valle, 2006). A comparação dos resultados encontrados no processo de reconhecimento confirma que a abordagem proposta é uma alternativa viável para uma correta recuperação de padrões possuindo uma boa tolerância na presença dos diferentes tipos de ruído misto. Somando o excelente desempenho comprovado à principal vantagem das memórias associativas morfológicas, que é o baixo custo computacional, devido às operações de soma e produto no processamento de dados, e ao processo de recuperação ser realizado em uma única iteração, a abordagem proposta MAAM-GA se converte em uma ótima alternativa para sua utilização e conveniente implementação em sistemas de reconhecimento de padrões.

Com o objetivo de mostrar a aplicabilidade da abordagem proposta na resolução de problemas de reconhecimento de padrões reais, foi utilizada a MAAM-GA no sistema de reconhecimento de gestos estáticos por visão. Os resultados alcançados são muito incentivadores e sugerem que a proposta MAAM-GA pode ser considerada uma ferramenta promissora e vantajosa, capaz de solucionar problemas de reconhecimento de gestos e de padrões de valor real em geral, além de fornecer um método inovador para solução deste tipo de problemas. No caso estudado, o ótimo desempenho do sistema de reconhecimento de gestos estáticos como comandos para realizar diversas ações é um passo para continuar na busca de novas tecnologias para criar um ambiente inteligente que dê suporte às necessidades de pessoas com deficiência visual, auditiva ou motora lhe dando certo nível de autonomia, capacidade de controle do entorno e de comunicação.

Diversas outras aplicações relacionadas à interface natural humano-computador podem se basear na metodologia de reconhecimento desenvolvida e apresentada nesta tese.

Próximos trabalhos poderão incluir melhoras na robustez do sistema de reconhecimento de gestos realizados com dificuldade, e a inclusão de outros parâmetros que possam descrever também os gestos. Metodologias diferentes de reconhecimento, baseadas em sistemas

inteligentes, que alcancem um melhor desempenho frente a padrões incompletos ou com alto nível de variância comparado aos padrões ideais também serão motivo de estudo.

A literatura recente reporta o sucesso na implementação de modelos de redes neurais utilizando unidades que promovem a aceleração do processamento de sistemas, como por exemplo, as GPUs (*Graphic Processing Unit*). Portanto a implementação em GPUs do modelo de rede neural aqui apresentado poderá significar a aceleração do processo de reconhecimento a um custo relativamente baixo.

No campo de visão computacional, diversas outras técnicas não abordadas neste trabalho, apresentam altos índices de desempenho no reconhecimento de padrões. Entretanto estas se mostram muito caras computacionalmente. Isto se deve à necessidade de realizar cálculos sobre um conjunto de dados com dimensão elevada, onde o número de variáveis e amostra é alto. Para realizar o mesmo reconhecimento, as redes neurais MAAM utilizam menos cálculos, devido as suas características de processamento.

Este trabalho apresentou o uso de uma rede neural MAAM combinada com um GA, o que resultou num híbrido que aproveita a eficiência computacional das MAAM e a robustez no reconhecimento proporcionada pela GA.

# Referências Bibliográficas

- Alvarez A. B.; Oliveira J. R. (2010) Reconocimiento de Gestos de la Mano Utilizando Momentos Invariantes y Redes Neuronales Morfológicas, XVII International Congress of Electronic, Electrical and Systems Engineering, 2010, Perú.
- Back, T., Hoffmeister, F., Schwefel, H.P. (1991) A Survey of Evolution Strategies. International Conference on Genetic Algorithms, San Diego – CA, pp.2-9.
- Blanco, E. (2008) Contribución a la segmentación en el espacio de color HSI. Aplicación al reconocimiento gestual. Tese de doutorado, DEPECA-UAH, Espanha, 2008.
- Chaudhary A., Raheja J.L., Das K., Raheja S. (2011) Intelligent Approaches to interact with Machines using Hand Gesture Recognition in Natural way: A Survey. International Journal of Computer Science & Engineering Survey (IJCSES), vol. 2(1), pp. 122-133.
- Cuninghame-Green R. A. (1979) Minimax Algebra. Lectures Notes in Economics and Mathematical Systems, vol. 166. Springer-Verlag, Berlin.
- Fogel L.J., Owens, A.J., Walsh, M.J. (1966) Artificial Intelligence through Simulated Evolution, John Wiley.
- Fogel, D.B. (1994) An Introduction to Simulated Evolutionary Computation, IEEE Transactions on Neural Networks, vol. 5(1), pp. 3-14.
- Goldberg D.E. (1989) Genetic algorithms in search, optimization, and machine learning, Addison-Wesley.

- Graña M., Maldonado O., Vicente D. (2005) Morphological independence and hyperspectral image indexing. Astola JT, Tabus I, Barrera J (eds), Proceedings SPIE Mathematical Methods in Pattern and Image Analysis, vol. 5916, 59160L:1-10.
- Graña M., Sussner P., Ritter G.X. (2003) Innovative applications of associative morphological memories for image processing and pattern recognition. *Mathware & Soft Computing*, vol. 10, pp. 155-168.
- Hashiguchi H., Hattori M. (2003) Robust morphological associative memory using multiple kernel patterns. Proceedings 10th International Conference on Neural Information Processing.
- Hassoun M. H. (1993) Dynamic associative neural memories. *Associative Neural Memories: Theory and Implementation*, M. H. Hassoun, Ed. Oxford University Press, Oxford, U.K.
- Hattori M, Fukui A, Ito H (2002) A fast method of constructing kernel patterns for morphological associative memories. Proceedings 9th International Conference on Neural Information Processing, pp. 1058-1063, Singapore.
- Haykin S. (1999) *Neural Networks: A Comprehensive Foundation*. Prentice Hall, Upper Saddle River, NJ.
- Holland, J.H. (1975) *Adaptation in Natural and Artificial Systems*, University of Michigan Press, 1975.
- Holland, J.H. (1992) *Adaptation in Natural and Artificial Systems*, 2nd edition, The MIT Press, 1992.
- Hu, M. (1962) Visual pattern recognition by moments invariants. *IRE Trans. Information Theory*, 1962, vol. 8, pp. 179-187.
- Janikow, C.Z., Michalewicz, Z. (1991). An Experimental Comparison of Binary and Floating Point Representations in Genetic Algorithms. In Belew, R. K. and Booker, L. B., editors,

- Proceedings of the Fourth International Conference on Genetic Algorithms, pp. 31–36, Morgan Kaufmann, San Mateo, California.
- Mesquita M. (2005) Um Estudo Comparativo em Memórias Associativas com Ênfase em Memórias Associativas Morfológicas. Dissertação de Mestrado, IMECC-UNICAMP, Brasil, 2005.
- Michalewicz, Z. (1996) Genetic Algorithms + Data Structures = Evolution Programs. 3rd edition, Berlin: Springer-Verlag, 1996.
- Mohamed R., Haniza Y., Puteh S., Ali Y., Abdul R., Mohd M., Sazali Y., Hazri D., Karthigayan M. (2006) Object Detection using Geometric Invariant Moment. American Journal of Applied Sciences, 2006, vol. 2(6), pp. 1876-1878.
- Muharrem M., Kayhan G., Tarik V. (2005) Real object recognition using moment invariants. Sadhana, 2005, vol. 30, Part. 6, pp. 765–775.
- Pavlovic V.I. (1997) Sharma R. Huang TS. Visual interpretation of hand gestures for human-computer interaction: A review. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 19(7), pp. 677-695.
- Ritter G.X., Gader P.D. (2006) Fixed points of lattice transforms and lattice associative memories. P. Hawkes Editor, Advances in Imaging and Electron Physics, vol.144, pp.165-242.
- Ritter G.X., Iancu L., Schmalz M.S. (2004) A new auto-associative memory based on lattice algebra. In: Sanfeliu A, Trinidad JF, Ochoa JA (eds), Progress in Pattern Recognition and Image Analysis, LNCS, vol. 3287, pp. 148-155. Springer, Berlin, Germany.
- Ritter G.X., Sussner P. (1996) An introduction to morphological neural networks. Proceedings of the 13th International Conference on Pattern Recognition (Vienna, Austria), Apr. 1996, pp. 709-717.

- Ritter G.X., Sussner P., (1997) Associative memories based on lattice algebra. IEEE International Conference on Systems, Man, and Cybernetics (Orlando, FL), Oct. 1997, pp. 3570-3575.
- Ritter G.X., Sussner P., Diaz de Leon, J.L. (1998) Morphological associative memories. IEEE Transactions on Neural Networks, vol. 9(2), Mar. 1998, pp. 281-293.
- Ritter G.X., Urcid G., Iancu L. (2003) Reconstruction of noisy patterns using morphological associative memories. J Math Imaging and Vision, vol. 19(5), pp. 95-111.
- Stright J., Coffield, P. e Brooks G. (1998) An analog VLSI implementation of a morphological associative memory, in *Proceedings SPIE Parallel and Distributed Methods for Image Process. II*, vol. 3452, San Diego, CA, July.
- Sturman D.J., Zeltzer D. (1994) A survey of glove-based input. IEEE Transactions on Computer Graphics and Applications, vol. 14(1), pp. 30-39.
- Sussner P. (2000a) Observations on morphological associative memories and the kernel method. Neurocomputing, vol. 31, pp.167-183.
- Sussner P. (2000b) Fixed points of autoassociative morphological memories. Proceedings International Joint Conference on Neural Networks, Italy, 2000, pp. 611-616.
- Sussner P. (2003a) Associative morphological memories based on variations of the kernel and dual kernel methods. Neural Networks, vol. 16, pp.625-632.
- Sussner P. (2003b) Generalizing operations of binary morphological autoassociative memories using fuzzy set theory. Journal of Mathematical Imaging and Vision, vol. 19(5), pp. 81-93.
- Sussner P. (2005) Recall of patterns using binary and gray-scale autoassociative morphological memories. Astola JT, Tabus I, Barrera J (eds), Proceedings SPIE Math Methods in Pattern and Image Analysis, vol. 5916, 59160M:1-10.

Sussner P., Valle M., (2006) Gray-scale morphological associative memories. *IEEE Transactions on Neural Networks*, vol. 17(3), 2006, pp. 559–570.

Urcid G., Ritter G.X. (2003) Kernel computation in morphological associative memories for grayscale image recollection. *Proceedings 5th IASTED International Conference on Signal and Image Processing*, pp. 450-455.

Wang M., Chen S. (2005) Enhanced fuzzy morphological auto-associative memory based on empirical kernel map. *IEEE Transactions on Neural Networks*, vol. 16(3), pp. 557-564.

Zhu, Y.; De Silva, L.C. and Ko, C.C. (2002) Using moment invariants and HMM in facial expression recognition. In *Pattern Recognition Letters*, 2002, vol. 23, Issues 1-3, pp. 83-91.

# Apêndice A

## Produção Científica

ALVAREZ Ana Beatriz; Oliveira, J. R.. Reconhecimento de Sinais da Mão como Caminho Natural para Interagir em Ambientes Inteligentes usando Uma Abordagem Neuro-Genética Híbrida. Brazilian Journal of Biomedical Engineering (**artigo submetido**).

ALVAREZ Ana Beatriz; Oliveira, J. R.. Melhoria da Tolerância ao Ruído na Recuperação de Padrões em Níveis de Cinza da Memória Associativa Morfológica. In: IV Encontro dos Alunos e Docentes do Departamento de Engenharia de Computação e Automação Industrial - EADCA. Anais do IV EADCA, pp. 89-92, Campinas, SP, Brasil, 2011.

ALVAREZ Ana Beatriz; Oliveira, J. R.. Reconocimiento de Gestos de la Mano Utilizando Momentos Invariantes y Redes Neuronales Morfológicas. In: XVII International Congress of Electronic, Electrical and Systems Engineering - INTERCON, CD-ROM v. BIO, Puno, Perú, 2010.

ALVAREZ Ana Beatriz; Oliveira, J. R.. Hand Gesture Recognition using a Lattice Autoassociative Memory. In: 8th International Conference and Workshop on Ambient Intelligence and Embedded Systems - AmiEs, Proceedings of AmiEs v. I, Funchal, Madeira, Portugal, 2009.