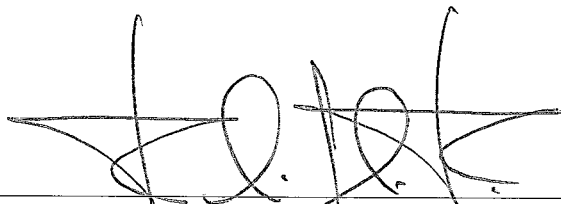


MODOS DE APRENDIZADO NÃO-SUPERVISIONADO PARA O MODELO
NEURAL SEM-PESOS WISARD

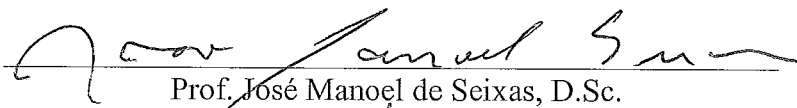
Iuri Wickert

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM
ENGENHARIA DE SISTEMAS E COMPUTAÇÃO

Aprovada por:



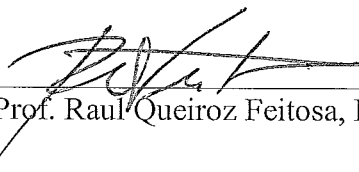
Prof. Felipe Maria Galvão França, Ph.D.



Prof. José Manoel de Seixas, D.Sc.



Prof. Priscila Machado Vieira Lima, Ph.D.



Prof. Raul Queiroz Feitosa, Dr.Ing.

RIO DE JANEIRO, RJ - BRASIL

NOVEMBRO DE 2001

WICKERT, IURI

Modos de Aprendizado Não-Supervisionado para o Modelo Neural Sem-Pesos WISARD [Rio de Janeiro] 2001

X, 54p. 29,7cm (COPPE/UFRJ, M.Sc., Engenharia de Sistemas e Computação, 2001)

Tese – Universidade Federal do Rio de Janeiro, COPPE

1 - Redes Neurais

2 - Aprendizado Não-Supervisionado

3 - WISARD

I. COPPE/UFRJ II. Título (série)

À Angela

Agradecimentos

Agradeço à todas as pessoas e instituições que colaboraram, direta ou indiretamente, para a realização deste trabalho: ao CNPq, pelo financiamento, ao meu orientador, Felipe, pela atenção dispensada, à Inês, Vítor e Luís Alfredo, pela ajuda com as dificuldades iniciais do meu período na COPPE, e à minha família, por tudo. Agradeço também à comunidade cearense do PESC, de ontem e sempre, ao pessoal da IA, especialmente aos companheiros de todas as horas, Ricardo, Rogério e Wagner, e ao Eduardo, pelo incentivo. Também quero lembrar daqueles que nos deixaram ao longo dessa jornada: o Vanderlei Rodrigues (vandi) e, especialmente, a minha irmã Angela.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc)

MODOS DE APRENDIZADO NÃO-SUPERVISIONADO PARA O
MODELO NEURAL SEM-PESOS WISARD

Iuri Wickert

Novembro/2001

Orientador: Felipe Maia Galvão França

Programa: Engenharia de Sistemas e Computação

Neste trabalho, apresentamos o modelo neural AUTOWISARD, um novo algoritmo de aprendizado não-supervisionado para o conhecido modelo neural sem-pesos WISARD. AUTOWISARD é capaz de classificar padrões binários em uma única época de treinamento, atingindo um estado estável. O modelo implementa métodos de controle de geração de classes e de aprendizado, como a janela de aprendizado, o aprendizado parcial e a função de controle de aprendizado. Foi realizada uma comparação entre a AUTOWISARD e a rede Fuzzy ART, numa aplicação de reconhecimento ótico de caracteres, usando imagens de dígitos manuscritos rotulados. Para comparar redes e paradigmas neurais diversos, os resultados foram normalizados e convertidos para uma representação gráfica que permitisse a visualização do desempenho médio de ambas as redes em termos de qualidade de classificação (quantidade de classes que reconhecem múltiplos dígitos e grau de saturação das classes). Os resultados mostram que as classificações geradas pela AUTOWISARD são consistentemente superiores em qualidade às da Fuzzy ART. Também integram este trabalho uma revisão dos modelos relacionados: WISARD, Fuzzy ART e WIS-ART, conclusões e trabalhos futuros, apresentando o modelo AUTOWISARD hierárquico.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

UNSUPERVISED LEARNING MODES FOR THE WISARD
WEIGHTLESS NEURAL NETWORK

Iuri Wickert

November/2001

Advisor: Felipe Maia Galvão França

Department: Engenharia de Sistemas e Computação

In this thesis we present the AUTOWISARD neural model, a new unsupervised learning algorithm for the well-known WISARD weightless neural model. AUTOWISARD is able to classify binary patterns in a single learning epoch, reaching a stable state. The model implements several class generation and learning control methods, as the learning window, the partial learning and the learning control function. A comparison was made with AUTOWISARD and Fuzzy ART, in an optical character recognition application, using labelled handwritten digits images. To compare such different neural paradigms and networks, the results were normalized and converted into a graphical representation which yields the visualization and the comparison of the average performance for both networks relatively to the quality of classification (quantity of classes which recognises multiple digits and saturation level of the classes). The results showed that the classifications generated by AUTOWISARD are consistently superior in quality to the Fuzzy ART's. This work also presents a revision of related models: WISARD, Fuzzy ART and WIS-ART, conclusions and future works, presenting the hierarchical AUTOWISARD model.

Sumário

1	Introdução	1
2	Revisão Bibliográfica	4
2.1	WISARD	4
2.2	Fuzzy ART1	9
2.3	WIS-ART	13
3	O Modelo AUTOWISARD	15
3.1	AUTOWISARD	15
3.2	Características funcionais	16
3.3	Considerações sobre o treinamento	21
4	Experimentos comparativos	23
4.1	Descrição dos experimentos	23
4.2	Resultados e análises comparativas	30
5	Conclusões e Trabalhos Futuros	49
5.1	Trabalhos Futuros	50
	Referências Bibliográficas	53

Lista de Figuras

2.1	Neurônio RAM.	5
2.2	Discriminador tendo como entrada uma imagem.	6
2.3	Rede WISARD tendo como entrada uma imagem	8
2.4	Rede Fuzzy ART1 durante ciclo de treinamento, com nó selecionado para adaptação.	11
2.5	Rede Fuzzy ART1 durante ciclo de treinamento, com novo nó alocado e adaptado.	12
2.6	Espaço de estados para um nó Fuzzy ART de 4 bits, classificado em regiões por distância de Hamming.	13
2.7	Esquema da rede WIS-ART.	14
3.1	Escala de reconhecimento de um discriminador, e limite de criação de novas classes.	17
3.2	Janela de aprendizado para um discriminador.	17
3.3	Demonstração do reconhecimento de combinações de ênuplas aprendidas por um discriminador.	18
3.4	Janela de aprendizado e aprendizado parcial para um discriminador.	19
3.5	Janela de aprendizado com aprendizado parcial e função de controle de aprendizado para um discriminador.	20
4.1	Exemplos de dígitos a serem classificados.	25

- 4.2 Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 1 (10-15 classes). 37
- 4.3 Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 2 (50-60 classes). 38
- 4.4 Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 3 (100-120 classes). 39
- 4.5 Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 1 (10-15 classes). 40
- 4.6 Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 2 (50-60 classes). 41
- 4.7 Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 3 (100-120 classes). 42
- 4.8 Evolução do percentual de imagens em classes saturadas (a 50%) em ambas as redes. 43
- 4.9 Evolução do percentual de imagens em classes saturadas (a 75%) em ambas as redes. 44
- 4.10 Evolução do percentual de classes saturadas (a 50%) em ambas as redes. 45
- 4.11 Evolução do percentual de classes saturadas (a 75%) em ambas as redes. 46
- 5.1 Modelo AUTOWISARD hierárquico. 52

Lista de Tabelas

- 4.1 Configurações de parâmetros de treinamento da rede Fuzzy ART. 27
- 4.2 Configurações de parâmetros de treinamento da rede AUTO-
WISARD. 28
- 4.3 Instâncias da rede Fuzzy ART para o intervalo 1 (10-15 classes). 31
- 4.4 Instâncias da rede Fuzzy ART para o intervalo 2 (50-60 classes). 32
- 4.5 Instâncias da rede Fuzzy ART para o intervalo 3 (100-120 classes). 33
- 4.6 Instâncias da rede AUTOWISARD para o intervalo 1 (10-15
classes). 34
- 4.7 Instâncias da rede AUTOWISARD para o intervalo 2 (50-60
classes). 35
- 4.8 Instâncias da rede AUTOWISARD para o intervalo 3 (100-120
classes). 36

Capítulo 1

Introdução

Neste trabalho, apresentamos o modelo neural sem-pesos AUTOWISARD, suas motivações originais, seu posicionamento no contexto das redes neurais, os testes comparativos realizados, conclusões e trabalhos futuros.

O modelo neural AUTOWISARD é um algoritmo de aprendizado não-supervisionado para o conhecido modelo neural sem-pesos WISARD, capaz de classificar padrões binários multidimensionais em um única iteração de treinamento, criando uma representação interna bastante peculiar (e poderosa) das classes geradas. AUTOWISARD significa “WISARD automática”.

Vários fatores levaram à sua criação, como a necessidade de desenvolver um sistema de reconhecimento de padrões implementando propriedades do sistema visual humano para outra pesquisa, assim como o desejo do autor em aprofundar seus conhecimentos sobre aprendizado não-supervisionado e modelos neurais sem-pesos. Também influiu a vontade de criar um modelo neural baseado na rede WISARD, que capitalizasse as propriedades interessantes desse modelo neural (algumas vistas como limitações) e suprisse a carência de um algoritmo de aprendizado sem supervisão que mantivesse a compatibilidade, isto é, que não introduzisse modificações, com a arquitetura WISARD original.

Seguindo a estrutura desta dissertação, no Capítulo 2 é feita uma revisão

dos modelos neurais relevantes para este trabalho, com um nível de detalhamento proporcional à importância de cada um deles no contexto dessa dissertação. Esses modelos são o WISARD, o mais simples e popular dos modelos neurais sem-pesos, apesar de ser muito menos conhecido (e empregado) do que modelos *mainstream*, como Backpropagation e Kohonen; o Fuzzy ART, variante mais recente, simples e rápida do modelo ART (o paradigma clássico em termos de aprendizado não-supervisionado), na sua versão binária, e, por fim, o modelo WIS-ART, um híbrido entre o WISARD e o ART1 que era até então o único modelo não-supervisionado relacionado à WISARD, mesmo não sendo puro.

O Capítulo 3 trata da evolução do modelo AUTOWISARD, partindo da rede WISARD original e introduzindo funcionalidades até atingir sua forma final. São discutidos os objetivos propostos para o novo modelo, como, por exemplo, ser capaz de atingir um estado estável em um único ciclo de treinamento, os problemas que afligem a rede WISARD (potencial para saturação) e as soluções adotadas para os mesmos, e as outras características que foram introduzidas no modelo para que seu aprendizado exibisse comportamento não-supervisionado. No final desse capítulo são feitas considerações sobre as variáveis de projeto e treinamento de uma rede AUTOWISARD e seus reflexos sobre o grau de generalização e qualidade de classificação obtidos por ela.

Como forma de ilustrar o desempenho da AUTOWISARD, bem como proporcionar uma base para uma comparação com outro modelo neural já estabelecido, foi desenvolvida uma pequena aplicação de reconhecimento ótico de caracteres (dígitos), descrita no Capítulo 4. A fim de efetuar a comparação entre redes diversas, dois conjuntos de execuções sobre a aplicação foram utilizados, um para a AUTOWISARD e outro para a ART1. Seus resultados foram, então, processados por um novo método de normalização, de modo a

gerarem gráficos que permitissem a visualização e comparação direta do comportamento médio (e de melhor e pior caso) do desempenho em termos de qualidade de classificação obtida de cada rede. De posse desses gráficos, foram tecidos comentários comparativos entre essas redes, propondo explicações para a melhor qualidade verificada nas classificações geradas pela AUTOWISARD em relação às da rede Fuzzy ART.

O Capítulo 5 conclui esta dissertação, apresentando as contribuições originais deste trabalho: as características do modelo AUTOWISARD, como a janela de aprendizado e o aprendizado parcial, o novo método de normalização de perfis de classificação, baseado em intervalos de classes e ordenação de variáveis, e o fato do modelo AUTOWISARD, tendo resolvido algumas das chamadas limitações da WISARD, abrir novas perspectivas para o desenvolvimento de sistemas baseados nesse tipo de rede. Também são propostos alguns trabalhos futuros que podem ser desenvolvidos com ou sobre a AUTOWISARD, destacando-se uma variação sobre o modelo básico, capaz de gerar classificações hierárquicas sobre bases de dados não-rotulados.

Capítulo 2

Revisão Bibliográfica

Neste capítulo, apresentaremos os três modelos neurais relevantes ao desenvolvimento deste trabalho: WISARD, Fuzzy ART1 e WIS-ART. O modelo WISARD é um modelo neural sem-pesos clássico, e, como ele é a base do algoritmo que será introduzido no próximo capítulo, será abordado em detalhes. O modelo Fuzzy ART1 é o paradigma de classificador neural com aprendizado não-supervisionado, tendo sido escolhido para efeitos de comparação de desempenho de classificação com o modelo AUTOWISARD; porém, como o modelo AUTOWISARD não possui relação direta com a ART1, será exibida apenas uma descrição funcional da mesma. Já o modelo WIS-ART será revisto por ser o único modelo, mesmo que híbrido, de rede WISARD que implementava aprendizado não-supervisionado até então.

2.1 WISARD

A rede neural WISARD (Wilkie, Stonham and Alexander Recognition Device) [2], criada por Alexander *et al* na década de 1980, é um modelo conhecido de redes neurais sem-peso. Ela é, assim como outras redes neurais populares (Backpropagation, por exemplo), um dispositivo genérico de reco-

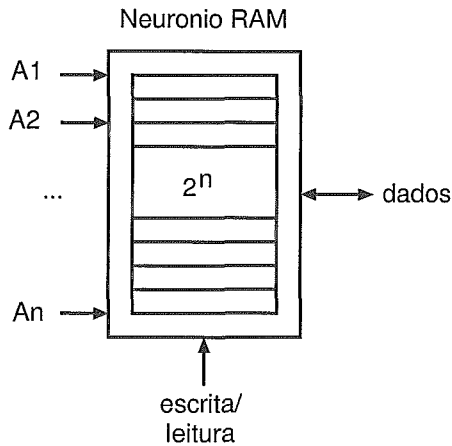


Figura 2.1: Neurônio RAM.

nhecimento de padrões, que armazena seu treinamento explicitamente dentro de seus nós. A nomenclatura “sem-pesos” advém justamente desse fato, em oposição às redes neurais mais tradicionais, que utilizam “pesos” (números reais ou binários) nas suas conexões internas para representar seu estado interno. As implementações originais da rede WISARD foram realizadas em hardware, utilizando componentes de memória conectados paralelamente à entrada, explicando a origem desse paradigma neural. Existe atualmente uma família de nós (neurônios) e modelos de redes sem-pesos mais sofisticados do que a WISARD, tais como PLN, GSM, GRAM [9], entre outros; a discussão desses modelos foge ao escopo deste trabalho.

A rede WISARD usa como neurônios (nós) memórias RAM capazes de armazenar 1 bit em cada posição de endereço; possuindo n entradas de endereçamento, cada nó é capaz de armazenar 2^n bits (Figura 2.1), podendo representar qualquer função booleana de n bits. O conjunto ordenado das entradas de endereçamento de um neurônio é comumente chamado de ênupla (“tuple” em inglês).

O treinamento de neurônios RAM consiste em armazenar o valor 1 no bit endereçado pela ênupla apresentada às suas entradas de endereçamento; a

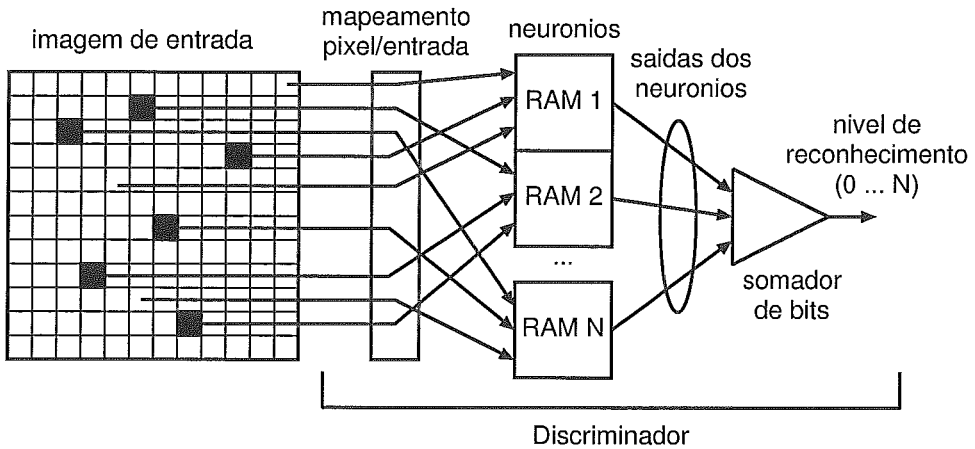


Figura 2.2: Discriminador tendo como entrada uma imagem.

recuperação de padrões é simplesmente a leitura do bit endereçado da mesma forma. Observe que as posições da memória, inicializadas em 0, nunca serão zeradas novamente; portanto, a função de reconhecimento de um neurônio RAM é monotônica, i.e., uma vez tendo sido treinado com um padrão, ele nunca o “esquecerá”. Considerando o modo de treinamento e recuperação desse neurônio, é fácil notar que ele não possui capacidade de generalização. Para se obter esse fenômeno, é necessário organizar um conjunto de neurônios numa estrutura chamada de discriminador (Figura 2.2).

Num discriminador, o padrão de entrada (no caso, uma imagem) é decomposto, através de um mapeamento de bits de entradas para bits de endereços dos nós, num conjunto de ênuplas (sub-padrões) de tamanho n bits, que servirão de entrada para seus respectivos neurônios¹. Para uma imagem de dimensões x e y , o número de neurônios N de n bits necessários para uma cobertura completa é

$$N = \lceil \left(\frac{xy}{n} \right) \rceil$$

Para o exemplo da Figura 2.2, considerando-se a imagem de 12x12 pixels, e

¹Embora venhamos a falar somente de imagens bidimensionais de entrada, esse mapeamento pode ser trivialmente restrito ou estendido a dados uni ou multidimensionais.

assumindo-se um tamanho de ênupla de 4 bits, serão necessários 36 neurônios para prover uma cobertura completa da entrada. Se o número de pixels da imagem de entrada não for múltiplo de n , surgirá um (único) neurônio com menos de n bits de endereçamento. Como o discriminador é somente um arranjo de neurônios independentes entre si, seu treinamento é trivial; já no reconhecimento de padrões, as saídas (bits) de cada neurônio são somadas, gerando um valor proporcional ao grau de reconhecimento do padrão de entrada pelo discriminador.

Uma analogia que pode ser feita para compreender o discriminador é vê-lo como um dispositivo reconhecedor de uma classe de padrões, seus neurônios agindo como detectores de características (*features*): tendo sido treinado com apenas um padrão, ele reconhecerá as *features* em comum com outros padrões que vierem a ser apresentados. Um grande número (soma) de *features* em comum pode indicar um reconhecimento positivo do padrão; um pequeno número implicaria numa rejeição do padrão pelo discriminador. Devido à sua saída graduada (em neurônios), o discriminador é capaz de reconhecer entradas distintas mas similares, i.e., generalizações do padrão de treinamento original.

Essa decomposição da entrada em *features* resulta numa visão “estruturada” do discriminador sobre a mesma, que é uma das suas propriedades mais importantes. Essa propriedade pressupõe a existência de relações entre bits arbitrários no padrão de entrada (relações essas descritas no mapeamento do discriminador), de modo que o reconhecimento de um padrão previamente treinado com alguns de seus bits negados nem sempre resultará num reconhecimento proporcionalmente menor, uma vez que as posições dos bits alterados são relevantes no cômputo da soma do discriminador (i.e., o discriminador não está apenas “contando” os bits da entrada).

É importante ressaltar a influência do tamanho das ênuplas (neurônios)

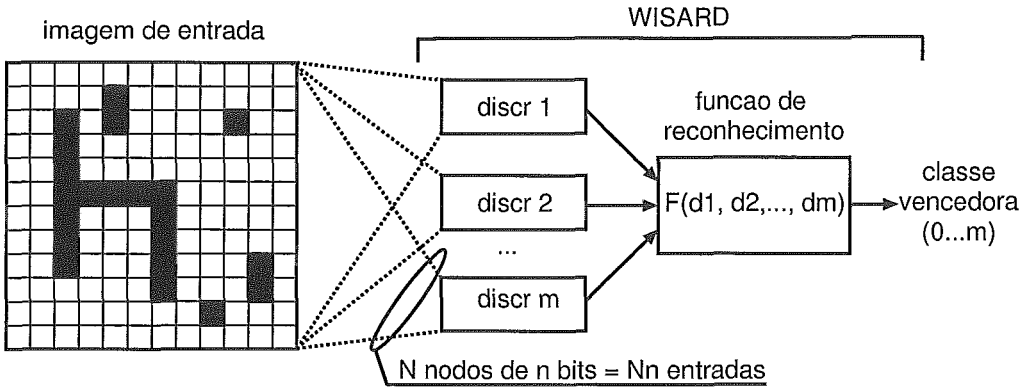


Figura 2.3: Rede WISARD tendo como entrada uma imagem

no comportamento da saída do discriminador, a relação entre o número de neurônios e o nível de generalização obtido pelo mesmo. Optar pelo uso de ênuplas grandes resultará em poucos neurônios para formar um discriminador; devido a isso, ele será bastante sensível à ocorrência de ruído no padrão de entrada (que afetará um percentual elevado de neurônios no discriminador), chegando ao extremo de se especificar um único neurônio que abranja toda a entrada que, naturalmente, não terá poder de generalização algum. O caso oposto é optar-se por ênuplas pequenas, demandando um número grande de neurônios, porém gerando um discriminador mais robusto (pois o ruído influenciará um percentual pequeno de neurônios no discriminador), até que se utilizem neurônios de 1 bit, resultando numa comparação bit a bit da entrada com o padrão aprendido.

Uma rede WISARD é composta de um conjunto de discriminadores, cada um representando uma das classes que se deseja reconhecer (Figura 2.3). O treinamento da WISARD é realizado criando-se um número adequado de discriminadores, atribuindo-se a cada um rótulo de classe e treinando-os com padrões (previamente rotulados) das respectivas classes, até que a rede atinja uma configuração que apresente um baixo erro de reconhecimento de padrões de teste (treinamento supervisionado). Observe que a determinação da classe

vencedora é feita por uma função das saídas dos discriminadores (somas): a função mais usada é a que retorna o índice (classe) do discriminador que apresentou a maior soma (o vencedor), independente do valor da soma em si, mas também podem-se usar outras, que tirem proveito do não-reconhecimento de um padrão por parte da rede (maior soma = 0), ou da medida de confiança de reconhecimento[1] (a diferença entre as duas maiores somas provenientes de seus discriminadores).

2.2 Fuzzy ART1

A rede neural ART[4] (de *Adaptive Resonance Theory*) foi criada por Grossberg e Carpenter, em meados da década de 1980. Seu objetivo era resolver o que Grossberg chamou de Dilema da Plasticidade - Estabilidade: como fazer com que um sistema aprenda perante novas entradas (plasticidade), mas permaneça reconhecendo corretamente entradas já aprendidas (estabilidade). Sua resposta foi a rede chamada de ART(1), capaz de aprender padrões binários, depois estendida em uma família de redes neurais. Neste trabalho, apresentaremos o modelo Fuzzy ART1[5] de aprendizado rápido de padrões binários, por ser mais recente e simples que o modelo ART1 original.

Uma rede Fuzzy ART1 consiste de um conjunto de vetores binários (nós), cada um representando uma classe distinta de entradas. Esses vetores podem ser atualizados (treinados) para incorporar novo conhecimento, ou novos vetores podem ser alocados dinamicamente para representar novas classes de entradas. Uma vantagem característica da Fuzzy ART1 é que, por usar simples vetores binários para representar suas classes, é possível ver cada nó como um exemplar prototípico da classe que ele representa, em oposição à WISARD, que representa suas classes via discriminadores.

Segue-se o algoritmo de treinamento da Fuzzy ART1:

1. *Normalização dos vetores a serem apresentados à rede.* É necessário fazer a codificação complementar dos vetores de entrada (X_i , de tamanho f bits).

$$X_{i,j+f} = 1 - X_{i,j}, \quad 1 \leq j \leq f$$

Após a codificação, cada padrão terá $2f$ bits.

2. *Alocação do primeiro nó da rede.* É um vetor de elementos 1 de tamanho $2f$ bits.
3. *Laço de iteração dos padrões de entrada.* Um padrão (X_i) é selecionado, aleatoriamente, do conjunto de treinamento². Quando não houver mais padrões ainda não selecionados para treinamento, reiniciar o laço.
4. *Criação de uma lista das similaridades.* Para auxiliar no passo seguinte, o índice de cada nó será armazenado numa lista ordenada decrescentemente, de acordo com a medida de similaridade entre o padrão de entrada (X_i) e cada nó da rede (W_i). A métrica de similaridade é dada pela seguinte equação:

$$\frac{\sum_{j=1}^f (X_{i,j} \wedge W_{i,j})}{\sum_{j=1}^f W_{i,j} + \alpha}, \quad \alpha = 10^{-6}$$

5. *Teste de ressonância.* A cada nó W_i da lista de similaridades (ordenada)

²todos os vetores do conjunto serão selecionados exatamente uma vez

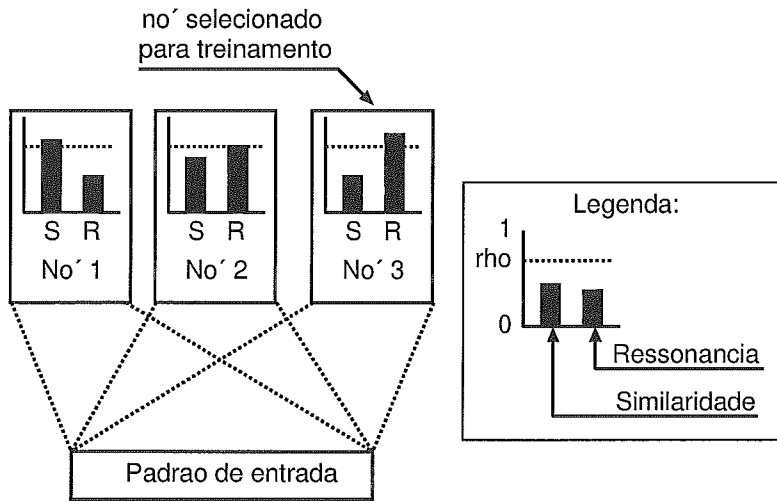


Figura 2.4: Rede Fuzzy ART1 durante ciclo de treinamento, com nó selecionado para adaptação.

é aplicado o teste de ressonância contra o limiar de vigilância ρ (“rho”)³:

$$\frac{\sum_{j=1}^f (X_{i,j} \wedge W_{i,j})}{\sum_{j=1}^f X_{i,j}} > \rho, \quad 0 \leq \rho \leq 1$$

Se o nó “entrar em ressonância” com o padrão de entrada (i.e., passar no teste de ressonância), ele será adaptado para representar melhor sua entrada (Figura 2.4):

$$W_i = W_i \wedge X_i$$

retornando ao passo 3. Se nenhum nó entrar em ressonância, um novo nó (de tamanho $2f$) será alocado na rede, tendo seus bits adaptados do mesmo modo para esse padrão de entrada (Figura 2.5).

6. *Retornar ao passo 3*, até que não haja mais alterações nos bits dos nós.

Os mecanismos responsáveis pela estabilização da rede são a normalização dos padrões de entrada, evitando uma proliferação de classes (nós)[10], e a

³Na função de ressonância, o denominador é trivialmente f .

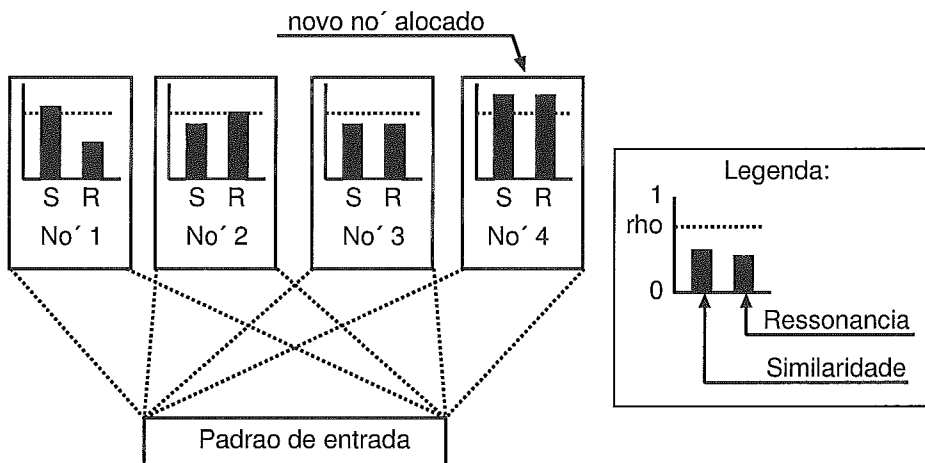


Figura 2.5: Rede Fuzzy ART1 durante ciclo de treinamento, com novo nó alocado e adaptado.

regra de adaptação dos nós, que previne o retorno (possivelmente cíclico) de um nó a alguma configuração anterior (i.e., uma com um maior número de 1's). A rede estabiliza no primeiro ciclo de iteração dos padrões de entrada, sendo necessário um ciclo posterior para recuperar as classes corretas (estáveis) para cada entrada.

Analisando-se a regra de adaptação dos nós da Fuzzy ART1, pode-se verificar a existência de um gradiente de informação: vetores mais próximos do vetor de zeros (em termos da distância de Hamming), têm mais informação que vetores mais próximos do vetor de uns. Sob esse ponto de vista, é possível interpretar a definição de similaridade como uma medida (inversamente proporcional) de distância entre dois vetores (desconsiderando-se a influência da constante α), e a definição de ressonância como uma medida (também inversamente proporcional) da quantidade de informação de um vetor (X_i) que já está representada em outro (W_i).

Assim sendo, o algoritmo de treinamento da Fuzzy ART1 resume-se a selecionar, dentre os nós mais próximos (pela similaridade) de um padrão de entrada, qual nó é capaz de aprender uma quantidade aceitável de informação




Figura 2.6: Espaço de estados para um nó Fuzzy ART de 4 bits, classificado em regiões por distância de Hamming.

(dada pelo parâmetro de vigilância ρ), visando minimizar sua distância de Hamming para o vetor de zeros (Figura 2.6). A constante α serve para prevenir divisões por zero no caso do nó assumir um vetor de zeros, assim como favorecer razões com denominadores maiores (nós que contenham menos informação, por estarem mais distantes, em Hamming, do vetor de zeros). O nível de generalização da rede é controlado pelo parâmetro de vigilância (ρ , "rho"): quanto mais próximo de 1, menor grau de generalização será apresentado pela rede.

2.3 WIS-ART

O modelo WIS-ART[7] foi criado por Eamon Fulcher, em 1991: ele é um híbrido entre as redes WISARD e ART, visando unir a capacidade de aprendizado não-supervisionado da (Fuzzy) ART1 e a simplicidade de implementação e treinamento da WISARD. Cada nó da WIS-ART é composto por um discri-

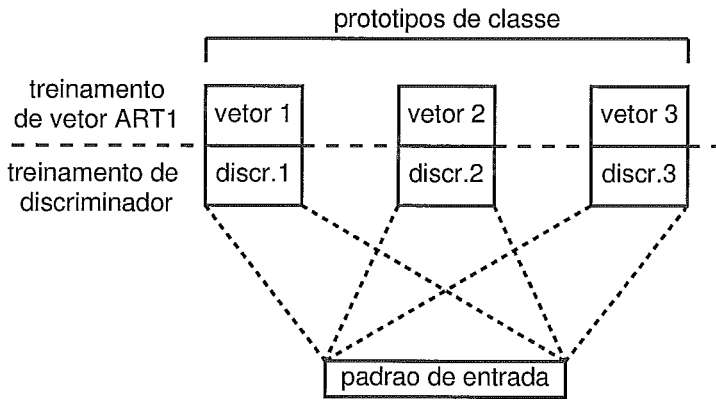


Figura 2.7: Esquema da rede WIS-ART.

minador e por um nó ART (vetor): o discriminador é responsável pelo reconhecimento da entrada (similaridade), enquanto que o nó ART armazena a informação da classe (protótipo).

Seu algoritmo de treinamento é similar aos algoritmos da ART e WISARD: dado um padrão de entrada, é feita uma lista de nós ordenados decrescentemente pela similaridade (neste caso, o valor de reconhecimento fornecido pelos discriminadores dos nós), e dessa lista, será treinado o nó cujo vetor (ART) passar no teste de ressonância; se um nó passar no teste, seu discriminador será treinado com a entrada, assim como seu vetor será adaptado. Caso nenhum nó esteja apto para ser treinado, um novo nó WIS-ART será criado e treinado como descrito anteriormente.

A rede WIS-ART oferece como vantagem sobre o modelo WISARD a possibilidade de fornecer um protótipo para cada classe gerada (propriedade herdada da ART1); no entanto, está sujeita à uma limitação da WISARD, que é a propensão a saturar os discriminadores (questão esta que será abordada no capítulo seguinte).

Capítulo 3

O Modelo AUTOWISARD

Neste capítulo, apresentaremos o modelo neural AUTOWISARD: sua origem, a evolução de suas características funcionais e os problemas (inerentes à WISARD) que essas características procuram solucionar, assim como considerações sobre o ajuste de seus parâmetros durante o treinamento não-supervisionado.

3.1 AUTOWISARD

O modelo AUTOWISARD[13] surgiu primariamente da necessidade de um dispositivo de reconhecimento de padrões visuais para ser usado em um modelo do sistema visual[12], bem como do desejo do autor em adquirir conhecimentos teóricos e práticos sobre redes neurais sem-pesos e outros modelos que implementam aprendizado não-supervisionado. Algumas características desejáveis de um sistema do tipo retina são a capacidade de reconhecer e aprender autônoma e rapidamente padrões (bidimensionais), a decomposição/paralelização desses métodos e a utilização de amostragens em multi-resolução (foveal) dos padrões de entrada (para auxiliar na implementação de movimento foveal sacádico). Tendo em conta esses requisitos, a rede neural que melhor se adequava à tarefa era a WISARD, por seu treinamento e reconhecimento rápi-

dos e sua decomposição estruturada (via mapeamento entradas-neurônios) dos padrões de entrada; no entanto, não havia um algoritmo simples de aprendizado não-supervisionado implementado sobre ela. O resultado dessa tentativa de se criar um modelo de retina baseado em WISARD é o algoritmo de treinamento AUTOWISARD, que, apesar de não cumprir todos os requisitos da aplicação descrita, ao permitir apenas o uso de resolução fixa e não implementar um mecanismo de movimento sacádico, é capaz de atender aos requisitos de aprendizado e reconhecimento rápidos e sem supervisão, sem promover alterações na arquitetura do modelo WISARD original, mantendo-se compatível com as muitas implementações (reconhecedores) atualmente existentes.

3.2 Características funcionais

O modelo AUTOWISARD é basicamente uma rede WISARD à qual se acrescentam novos discriminadores ao longo do treinamento, conforme a necessidade de acomodar novas classes de padrões. O critério para a criação de um novo discriminador é o reconhecimento insatisfatório de um padrão de entrada pelos discriminadores existentes. Esse reconhecimento é determinado por um valor limite (patamar) w_{max} , sobre uma escala de reconhecimento dada pelo número de neurônios por discriminador (i.e., o intervalo de reconhecimento de um discriminador): quando a rede obtém um reconhecimento máximo (chamado de r_{best}) inferior a w_{max} , um novo discriminador será alocado e treinado com esse padrão; caso contrário, o padrão será considerado como reconhecido e nada será feito. Desse modo, a rede já pode acomodar novas classes, porém, com o ônus de não haver mais aprendizado na rede, e sim apenas a memorização dos padrões de entrada, como em um sistema de quantização de vetores (*vector quantization*), vide Figura 3.1.

Para tentar contornar o sub-aproveitamento da capacidade de armazena-




Figura 3.1: Escala de reconhecimento de um discriminador, e limite de criação de novas classes.




Figura 3.2: Janela de aprendizado para um discriminador.

mento (e da capacidade de generalização) dos discriminadores pelo método de treinamento descrito acima, foi introduzido um mecanismo de controle de aprendizado, chamado de janela de aprendizado. Essa janela é a região entre o limite de criação de classes w_{max} e um novo parâmetro de limite inferior (w_{min}), sobre o mesmo intervalo de reconhecimento do discriminador (Figura 3.2). Em adição aos casos anteriores, agora, quando o melhor reconhecimento fornecido pela rede cair dentro da janela de aprendizado ($w_{min} \leq r_{best} < w_{max}$), o discriminador vencedor será treinado normalmente com o padrão de entrada.

Um discriminador treinado com um número arbitrário de padrões é capaz de reconhecer cada um deles com um valor de r_{max} , assim como as combinações

Exemplo de treinamento de uma rede WISARD
 Configuracao: 4 nos de 4 bits

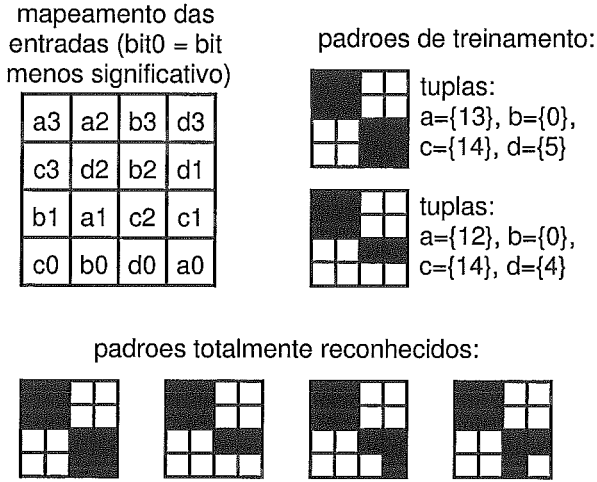


Figura 3.3: Demonstração do reconhecimento de combinações de ênuplas aprendidas por um discriminador.

entre as ênuplas representadas em cada nó. Supondo t um vetor contendo o número de ênuplas armazenadas em cada nó (i) e N o número de neurônios do discriminador, o número de padrões P reconhecidos totalmente por um discriminador é:

$$P = \prod_{i=1}^N t_i$$

Considerando-se o caso trivial de um discriminador treinado com apenas um padrão de entrada, ele reconhecerá (com r_{best}) somente um padrão, o próprio do treinamento; se o mesmo discriminador for novamente treinado com um padrão completamente diverso do primeiro (isto é, um padrão que obtenha um valor de reconhecimento igual a zero), o número de padrões totalmente reconhecidos saltará para 2^N . Os padrões compostos pelas combinações de ênuplas, total ou parcialmente reconhecidos ($w_{max} \leq r \leq r_{best}$), formam o espaço de generalização de um discriminador (Figura 3.3).

O uso da janela de aprendizado como controle de treinamento, na medida em que possibilita aprendizados futuros, faz crescer consideravelmente a

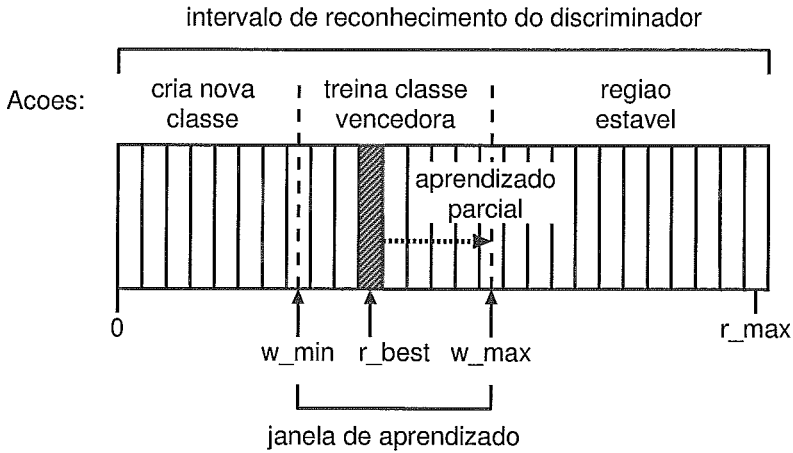


Figura 3.4: Janela de aprendizado e aprendizado parcial para um discriminador.

probabilidade de se levar algum discriminador à saturação, que é a existência de um grande número de ênuplas armazenadas nos nós, consequência do seu aprendizado monotônico. Nesse estado, o discriminador possui um espaço de generalização indesejavelmente amplo, reconhecendo padrões espúrios formados pelas combinações das ênuplas armazenadas. A solução empregada para tentar limitar os efeitos da saturação foi denominada de aprendizado parcial, que consiste em fazer com que o discriminador vencedor receba apenas o treinamento mínimo necessário para reconhecer o padrão de entrada ($r_{best} = w_{max}$). A quantidade mínima de treinamento é compreendida como a diferença entre o reconhecimento e o limite superior da janela ($w_{max} - r_{best}$), conforme é mostrado na Figura 3.4. Como essa quantidade é expressa em neurônios, ela corresponde ao número de nós que devem ser treinados. Esses nós são então selecionados aleatoriamente entre o conjunto de nós que falharam ao reconhecer o padrão de entrada, e treinados com as respectivas ênuplas.

A última característica funcional do modelo AUTOWISARD faz referência ao fato de cada discriminador se comportar como um atrator, na medida em que ele não “esquece” padrões (ênuplas) antigos para aprender novos, outro desdobramento de seu aprendizado monotônico. Para evitar que um discrimi-




Figura 3.5: Janela de aprendizado com aprendizado parcial e função de controle de aprendizado para um discriminador.

nador vencedor sempre aprenda novas ênuplas quando se encontra dentro da janela de aprendizado, mesmo quando seu nível de reconhecimento for demasiadamente baixo (tendendo a w_{min}), foi introduzida uma função para controlar a ação a ser tomada dentro da janela. Essa função determina a probabilidade do discriminador vencedor, dada a posição de sua saída na janela, receber o treinamento parcial, ou então de um novo discriminador ser gerado para acomodar a entrada. Várias funções podem ser usadas, mas, por simplicidade, foi adotada uma função linear decrescente, de modo a retornar uma probabilidade não-nula para o treinamento do discriminador no limite w_{min} , e outra também não-nula de criação de nova classe em $(w_{max} - 1)$. A versão completa do modelo AUTOWISARD está esquematizada na Figura 3.5.

O modelo AUTOWISARD é estável com qualquer combinação de número de bits por nó, parâmetros da janela de aprendizado ou função de controle de aprendizado: uma vez que cada padrão de entrada ou será reconhecido ($w_{max} \leq r_{best} \leq r_{max}$) e não contribuirá para o aprendizado da rede, ou não será reconhecido por nenhum discriminador ($0 \leq r_{best} \leq w_{min}$), quando um novo discriminador será gerado para representá-lo ($r_{best} = w_{max}$) ou ainda cairá dentro da janela de aprendizado, quando a decisão probabilística o mapeará

para um dos casos anteriores. Assim, é garantido que cada amostra, tendo sido apresentada à rede apenas uma vez, será reconhecida com um valor mínimo de w_{max} .

3.3 Considerações sobre o treinamento

O número de classes geradas, bem como a qualidade de classificação de redes neurais não-supervisionadas, como a AUTOWISARD, é dependente dos parâmetros de projeto da rede e de controle do treinamento; desse modo, se faz necessário tecer algumas considerações sobre a influência desses parâmetros sobre o comportamento da AUTOWISARD:

- *Determinação do número de bits por neurônio*, em função do tamanho dos padrões de entrada, de modo que sua decomposição em nós resulte num intervalo de reconhecimento adequado ao uso de uma janela de aprendizado. A adoção de ênuplas muito grandes resulta em pouca generalização por parte dos discriminadores (i.e., intervalo pequeno), enquanto que ênuplas demasiadamente pequenas fazem a performance dos discriminadores degenerar para uma comparação *bitwise* entre os padrões de entrada e as pequenas ênuplas armazenadas neles.
- *Posicionamento do limite inferior w_{min} na janela de aprendizado*. A escolha de um valor muito baixo para w_{min} implicará na criação de um número pequeno de classes, que apresentarão alto grau de generalização.
- *Posicionamento do limite superior w_{max} na janela de aprendizado*. Um valor muito alto de w_{max} fará com que os discriminadores aprendam muitas ênuplas e, como o seu espaço de generalização cresce com o produto da quantidade de ênuplas aprendidas, eles poderão atingir a saturação.

- *Largura da janela de aprendizado*¹. Uma janela de aprendizado de tamanho zero ($w_{min} = w_{max}$) anulará o propósito da mesma, transformando a AUTOWISARD num sistema de *vector quantization*, assim como uma janela muito ampla pode implicar em saturação de discriminadores. Redes com janelas de larguras diferentes (mas com o mesmo centro) tendem a criar um número de classes semelhante. Porém, as redes com janelas mais estreitas apresentam classes com menor generalização do que as com janelas mais largas.

¹A introdução da função de controle de aprendizado contribui para a robustez da janela de aprendizado, tornando-a menos dependente de um acerto ótimo de limites.

Capítulo 4

Experimentos comparativos

Neste capítulo, apresentaremos os experimentos comparativos que permitirão caracterizar o desempenho de classificação da rede AUTOWISARD e compará-lo ao da rede Fuzzy ART, juntamente com uma discussão sobre as medidas de desempenho empregadas nesses experimentos e a confecção dos gráficos que exibirão os resultados experimentais sumarizados e processados. Ao final, serão apresentados os resultados dos experimentos em suas formas tabular e gráfica, bem como as análises comparativas entre essas duas redes neurais.

4.1 Descrição dos experimentos

Para a definição dos experimentos que demonstrariam o desempenho da rede AUTOWISARD, bem como permitiriam a comparação deste modelo com a rede Fuzzy ART, foi necessário criar uma aplicação sobre a qual medidas de desempenho seriam tomadas de ambas as redes. A aplicação desenvolvida foi um reconhecedor (classificador) ótico de caracteres (componente de um sistema do tipo *OCR* – “optical character recognition”), um exemplo bastante comum de aplicação de redes neurais. Ela consiste em treinar as redes com um conjunto de imagens de dígitos (0 a 9), de modo não-supervisionado. Cada

rede, então, apresentará o conjunto de classes resultantes desse treinamento, descritas pelo conjunto de imagens reconhecidas em cada. O objetivo dessa aplicação é fornecer medidas “puras” da qualidade de classificação, i.e., sem auxílio de outros métodos de filtragem/normalização, bem como de recursos de processamento simbólico ou geométrico auxiliares, pois a confecção de um sistema *OCR* completo foge do escopo deste trabalho.

Como essas redes trabalham apenas com dados binários, um conjunto de imagens com essa característica devia ser empregado. Para tanto, foi encontrado na Internet um conjunto de imagens de dígitos manuscritos, disponibilizado publicamente pela Universidade de Bogazici[3]. Esse conjunto é composto de 1934 imagens binárias pré-classificadas, de dimensões 32x32 pixels, com a seguinte distribuição de imagens por dígito:

Dígito	0	1	2	3	4	5	6	7	8	9
Imagens	189	198	195	199	186	187	195	201	180	204

Esses dígitos, conforme se observa na Figura 4.1, têm legibilidade bastante variável, não tendo sofrido nenhum pré-processamento; no entanto, como estão rotulados (de 0 a 9), tornam possíveis medidas da qualidade da classificação, e sua quantidade significativa de pixels permite o uso de redes baseadas em discriminadores (resultando num grande intervalo de reconhecimento).

Para compararem-se redes com arquiteturas, representações internas, parâmetros de controle, algoritmos de treinamento e métricas de erro distintas, como é o caso da Fuzzy ART e da AUTOWISARD, faz-se necessário abstrair todos esses fatores e buscar um fator comum para comparação. Esse fator será fornecido pelos resultados das instâncias das redes para essa aplicação (abordagem “caixa-preta”), que são da mesma natureza, isto é, listas das classes geradas e as respectivas imagens reconhecidas. Desses perfis de classificação, diversas medidas de qualidade podem ser extraídas. As medidas consider-

0 0-043.xpm 0-083.xpm 0-107.xpm	1 1-007.xpm 1-010.xpm 1-065.xpm
2 2-001.xpm 2-099.xpm 2-155.xpm	3 3-007.xpm 3-034.xpm 3-167.xpm
4 4-005.xpm 4-010.xpm 4-089.xpm	5 5-005.xpm 5-031.xpm 5-146.xpm
6 6-177.xpm 6-001.xpm 6-049.xpm	7 7-020.xpm 7-100.xpm 7-118.xpm
8 8-004.xpm 8-033.xpm 8-159.xpm	9 9-004.xpm 9-056.xpm 9-087.xpm

Figura 4.1: Exemplos de dígitos a serem classificados.

adas relevantes para este trabalho, com o intuito de manter a simplicidade e a validade das análises, são o número de classes geradas em cada instância, absolutamente, e separadas pela quantidade de dígitos (símbolos) reconhecidos, o número de classes que apresentam saturação e o número de imagens reconhecidas por essas classes saturadas. Note-se que medidas e comparações de desempenho em termos de tempo de execução ou complexidade de algoritmos não serão contempladas neste trabalho.

Como cada rede neural pode gerar variada quantidade de classes (i.e., diversos graus de generalização podem ser obtidos) em cada execução, resultado do uso de mapeamentos e seleção aleatórios de padrões para treinamento e diferentes configurações de parâmetros de controle, a comparação direta entre instâncias de redes diferentes, ou até da mesma rede, se torna complicada, senão inválida ou incoerente. Visando permitir essas comparações entre instâncias das diferentes redes, foram criados três intervalos de generalização: o primeiro, contendo as instâncias com 10 a 15 classes geradas, o segundo, com 50 a 60 classes e o terceiro, com 100 a 120 classes¹. Assim, as instâncias serão comparadas entre si dentro de cada intervalo, com redes que apresentaram um

¹Intervalos definidos empiricamente

grau semelhante de generalização, independente dos parâmetros de controle usados nos treinamentos. Não é o objetivo deste trabalho explorar as relações entre os diferentes parâmetros de treinamento entre as redes.

O conjunto de dados experimentais sobre os quais se baseiam as análises deste trabalho é composto de 20 execuções de cada rede para cada intervalo, seguindo as configurações de parâmetros de controle descritos nas Tabelas 4.1 e 4.2, respectivamente para a rede Fuzzy ART e AUTOWISARD. Esses parâmetros foram obtidos empiricamente, de modo a gerarem (na maioria dos casos) quantidades de classes dentro dos intervalos definidos, e evitar que as comparações fossem influenciadas pelo uso de uma única configuração de treinamento, especialmente no caso do número de bits na AUTOWISARD, que poderia afetar significativamente a qualidade de classificação de suas instâncias. Como não há garantia, devido aos fatores acima, de que cada instância gerada com essas configurações caia dentro do respectivo intervalo, algumas vezes foi necessário criar novas instâncias com as mesmas configurações, até obterem-se todas as 20 perfis por rede e intervalo, apesar de outras combinações adequadas de parâmetros serem possíveis.

A definição dos parâmetros de treinamento, para ambas as redes, foi feita empiricamente. O único parâmetro de controle da rede Fuzzy ART, o limiar de vigilância, foi determinado de forma a gerar, na maioria dos casos, instâncias com o número de classes desejado, isto é, de acordo com o intervalo de generalização para o qual se estava treinando a instância. Para que as comparações não fossem influenciadas por utilizarem um único valor de parâmetro de treinamento para cada intervalo, outros valores (também adequados) foram encontrados e usado alternadamente na criação das instâncias nos respectivos intervalos. Para a rede AUTOWISARD, que possui três parâmetros de treinamento, ou um de projeto (número de bits) e dois de treinamento (w_{min} e

Intervalos	10 - 15 classes			50 - 60 classes		100 - 120 classes	
Configuração	a1	a2	a3	a4	a5	a6	a7
ρ (vigilância)	0,28	0,29	0,30	0,36	0,37	0,40	0,41

Tabela 4.1: Configurações de parâmetros de treinamento da rede Fuzzy ART.

w_{max}), a determinação dos conjuntos de parâmetros foi mais complexa. Novamente, para evitar comparações tendenciosas (a favor de uma configuração “ótima”), foram adotados diferentes valores para tamanho de ênuplas para gerar as instâncias de cada intervalo. Os valores de bits para cada intervalo foram selecionados baseando-se na experiência empírica do autor no uso da implementação do sistema. Uma vez tendo-se selecionados os tamanhos de ênuplas adequados, se fazia necessário encontrar as respectivas janelas de aprendizado (w_{min} e w_{max}) que gerassem instâncias com as quantidades desejadas de classes. Se uma configuração de parâmetros (isto é, bits, w_{min} e w_{max}) gerasse a quantidade desejada de classes consistentemente, ela seria adotada para o treinamento. Porém, se o número de classes fosse aquém do desejado, o parâmetro w_{min} seria aumentado, ou então o w_{max} seria reduzido. Inversamente, se a configuração gerasse classes demais, w_{min} seria reduzido, ou w_{max} aumentado. No entanto, de posse das instâncias da AUTOWISARD, verificou-se que algumas produziam resultados muito pobres (inconsistentes com a experiência do autor), como grande quantidade de imagens em classes saturadas e de classes com múltiplos símbolos. Essa questão foi resolvida criando-se novas redes, mantendo os respectivos tamanhos de ênuplas e reduzindo-se a largura das janelas, de modo a preservarem a posição do seu centro no intervalo de reconhecimento do discriminador. Assim, foram criadas novas instâncias com quantidades de classes similares às anteriores, mas com melhor qualidade de classificação.

Para as comparações quanto à qualidade de generalização, independentemente do uso dos intervalos de classes, cada instância teve suas classes separadas em função do número de dígitos (símbolos) diferentes no conjunto de

Intervalos	10 - 15 classes			50 - 60 classes			100 - 120 classes			
Configuração	w1	w2	w3	w4	w5	w6	w7	w8	w9	w10
Bits	3	4	5	4	5	6	5	6	7	8
w_{min} (%)	35	25	15	36	28	20	35	28	23	15
w_{max} (%)	45	35	30	50	40	33	45	40	33	30

Tabela 4.2: Configurações de parâmetros de treinamento da rede AUTOWIS-ARD.

imagens reconhecidas por cada uma. Essa classificação visa caracterizar cada instância de rede em termos do quão distante ela se encontraria de um classificador ideal, isto é, um classificador que possua o máximo número de classes representando poucos símbolos, e um mínimo de classes representando demasiados símbolos.

A comparação das instâncias quanto à saturação é realizada examinando-se qualitativamente as classes que representem múltiplos símbolos, de modo a verificar quantas atingiram o estado de saturação. O conceito de saturação empregado aqui é o mesmo da rede WISARD, na qual discriminadores que tenham aprendido muitas ênuplas exibem generalização excessiva, reconhecendo amostras de classes distintas. Apesar desse conceito não estar normalmente associado ao modelo Fuzzy ART, que não usa discriminadores, como não estão sendo consideradas as representações internas das redes mas seus perfis (e erros) de classificação resultantes, é razoável assumir que esse fenômeno também ocorra com as classes geradas por uma Fuzzy ART1. Desse modo, uma classe oriunda de qualquer rede é dita estar saturada se não existir um dígito (símbolo) com uma ocorrência superior a um patamar percentual do total de imagens reconhecidas pela mesma; os valores de patamar adotados foram 50% e 75%. As classes saturadas não apresentam uma “tendência” de reconhecimento, tendo pouco poder de discriminação, fato refletido na baixa frequência de seus símbolos ditos vencedores. Complementar à contagem das classes saturadas é encontrar a razão da quantidade de imagens representadas

por essas classes pelo total do conjunto de treinamento: essa medida informa o impacto das classes saturadas na qualidade geral de classificação alcançada pelas instâncias das redes.

As tabelas montadas com os resultados, embora completas, não propiciam uma visualização clara do desempenho médio das redes neurais ao longo dos experimentos, na medida em que não abstraem as grandes variações entre as medidas de cada instância, mesmo considerando-se os intervalos de generalização. Para que tal visualização do comportamento das redes se tornasse possível, os dados foram pós-processados para gerar uma representação gráfica que simplificasse as comparações entre redes. Desse modo, os dados das tabelas de resultados foram resumidos em 10 gráficos: 6 demonstrando a evolução das instâncias em termos de símbolos representados por classe (1 por rede e por intervalo de classes), 2 exibindo a quantidade de classes saturadas e 2 com as imagens reconhecidas por tais classes (2 gráficos por patamar).

A primeira operação sobre os dados para a confecção dos gráficos foi somar as colunas de classes com 4, 5 e 6 ou mais símbolos numa única coluna (contando 4 ou mais símbolos), resultando em menos curvas para exibir nos gráficos. Em seguida, todas as colunas foram normalizadas: em relação ao total de classes de cada instância, no caso das colunas que representam classes, e ao total de imagens de treinamento, para as colunas que representam quantidade de imagens. Essa normalização permite uma comparação direta de desempenho entre diferentes redes e intervalos de classes, tanto em termos de generalização, quanto de saturação. Finalmente, as colunas sofreram uma ordenação crescente, com exceção da coluna das classes que representam um símbolo, que foi ordenada de modo decrescente. Assim, pode-se afirmar que, em cada gráfico gerado do modo descrito acima, os pontos mais próximos do eixo das ordenadas formariam um “melhor caso”, isto é ilustrariam um perfil de

classificação mais próximo de um classificador ideal, ao maximizar o número de classes com apenas um símbolo e minimizar as demais, e que o desempenho de cada rede vai caindo até o “pior caso”, no qual o número de classes com um símbolo é mínimo, e as curvas restantes estão nos seus máximos; a mesma situação ocorre com os gráficos de classes e imagens em saturação. É importante observar que, como esses gráficos visam exibir o comportamento médio (das grandezas medidas) das redes, e, devido às ordenações, as ordenadas exibidas não correspondem mais às instâncias, i.é., cada conjunto de pontos com a mesma abscissa não mais corresponde a uma instância real (da tabela de resultados), e sim a uma instância artificial.

4.2 Resultados e análises comparativas

Os resultados completos de todas as execuções das redes estão descritos nas Tabelas 4.3, 4.4, 4.5, 4.6, 4.7 e 4.8. Os gráficos comparativos são as Figuras 4.2, 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9, 4.10 e 4.11.

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	a1	11	0	0	1	0	2	8	10	1928	11	1934
2	a2	12	1	0	0	2	0	9	9	1817	11	1933
3	a3	15	0	0	1	2	3	9	11	1790	14	1905
4	a1	10	0	1	0	2	0	7	8	1917	10	1934
5	a2	14	0	0	0	2	5	7	12	1785	14	1934
6	a3	13	1	0	0	1	1	10	12	1933	12	1933
7	a1	10	1	0	0	0	2	7	8	1876	9	1932
8	a2	12	1	0	0	0	1	10	10	1918	11	1933
9	a3	14	0	0	0	0	3	11	10	1789	14	1934
10	a1	12	0	0	0	0	2	10	11	1740	12	1934
11	a2	13	0	0	0	0	2	11	11	1820	13	1934
12	a3	15	0	0	3	1	3	8	12	1837	14	1915
13	a1	12	0	1	0	2	2	7	10	1912	12	1934
14	a2	15	0	1	1	1	2	10	13	1847	15	1934
15	a3	15	0	0	0	1	2	12	12	1873	14	1902
16	a1	11	0	0	1	0	0	10	9	1899	11	1934
17	a2	14	0	1	0	0	0	13	10	1792	14	1934
18	a3	12	0	1	0	0	0	11	10	1918	12	1934
19	a1	11	0	0	0	1	3	7	11	1934	11	1934
20	a2	13	0	1	0	2	4	6	12	1893	13	1934

Tabela 4.3: Instâncias da rede Fuzzy ART para o intervalo 1 (10-15 classes).

A Tabela 4.3 mostra as medidas extraídas das instâncias da Fuzzy ART para o intervalo 1. Essas instâncias caracterizam-se pelo elevado número de classes que reconhecem seis ou mais dígitos, em oposição às classes que reconhecem apenas um dígito. Também fica evidente que a grande maioria das imagens do conjunto de treinamento é reconhecida por classes saturadas, para ambos os patamares. Como essas execuções geraram poucas classes, essas classes apresentam um alto grau de generalização, o que explica o grande número de classes de múltiplos dígitos e de imagens em classes saturadas.

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	a4	51	0	0	3	11	13	24	41	1707	51	1934
2	a5	53	0	1	4	10	12	26	38	1436	51	1861
3	a4	54	1	1	0	11	15	26	42	1576	51	1904
4	a5	59	1	2	3	12	14	27	41	1552	56	1908
5	a4	51	1	1	3	8	11	27	35	1420	48	1884
6	a5	54	0	0	10	9	9	26	43	1666	54	1934
7	a4	51	0	0	2	12	8	29	41	1689	48	1861
8	a5	59	0	1	3	13	12	30	47	1581	58	1902
9	a4	51	1	0	5	8	9	28	37	1515	46	1654
10	a5	59	1	2	9	11	15	21	38	1570	53	1838
11	a4	51	0	0	7	5	14	25	38	1671	51	1934
12	a5	56	0	2	7	7	9	31	43	1749	54	1903
13	a4	51	0	1	1	10	13	26	51	1934	51	1934
14	a5	58	0	0	7	13	10	28	44	1654	58	1934
15	a4	53	0	0	3	9	14	27	43	1738	52	1911
16	a5	56	1	1	9	4	12	29	38	1533	52	1865
17	a4	50	0	0	6	9	11	24	41	1670	46	1731
18	a5	55	1	2	6	7	10	29	36	1521	53	1928
19	a4	50	0	1	3	4	14	28	38	1594	49	1907
20	a5	52	0	0	3	6	17	26	43	1752	51	1907

Tabela 4.4: Instâncias da rede Fuzzy ART para o intervalo 2 (50-60 classes).

Para o intervalo seguinte (2), ilustrado na Tabela 4.4, o nível de generalização das classes geradas deveria ser significativamente menor. No entanto, não é o que se observa analisando as medidas das instâncias da Fuzzy ART, pois o número de classes com seis ou mais dígitos continua alto (em torno de 50% das classes geradas por execução). Ao mesmo tempo, a quantidade de classes com um dígito permanece praticamente inalterada em relação ao intervalo anterior, assim como a quantidade de imagens em classes saturadas.

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	a6	100	0	2	11	28	25	34	76	1370	96	1773
2	a7	109	1	3	8	41	24	32	73	1229	103	1797
3	a6	102	0	6	11	26	25	34	74	1575	92	1801
4	a7	109	0	3	14	29	30	33	76	1353	102	1732
5	a6	102	1	3	12	21	29	36	75	1326	96	1822
6	a7	117	1	2	18	33	35	28	73	1188	111	1777
7	a6	100	0	2	12	19	36	31	78	1414	94	1819
8	a7	114	0	3	16	23	28	44	85	1445	109	1831
9	a6	101	0	1	11	18	35	36	70	1179	100	1892
10	a7	117	1	1	12	35	31	37	80	1322	115	1912
11	a6	101	0	0	13	23	29	36	76	1461	100	1905
12	a7	115	0	3	11	34	33	34	87	1411	110	1866
13	a6	102	1	0	12	28	29	32	75	1475	98	1840
14	a7	116	0	2	12	34	34	34	82	1312	113	1891
15	a6	103	0	1	14	23	31	34	73	1258	96	1780
16	a7	112	0	3	13	37	24	35	80	1475	108	1870
17	a6	101	0	2	11	28	21	39	76	1544	95	1823
18	a7	115	1	2	16	40	27	29	88	1508	109	1828
19	a6	101	1	0	11	27	24	38	74	1404	97	1856
20	a7	118	1	0	18	41	26	32	85	1369	111	1800

Tabela 4.5: Instâncias da rede Fuzzy ART para o intervalo 3 (100-120 classes).

No intervalo com maior número de classes (3), as instâncias da Fuzzy ART continuaram apresentando um demasiadamente baixo número de classes com um dígito, vide Tabela 4.5. A maioria das classes criadas (aproximadamente 60%) se dividiu, principalmente, entre classes com cinco e seis ou mais dígitos; as restantes se dividiram nas categorias restantes. Apesar do grau de generalização ter sido reduzido drasticamente desde os intervalos anteriores, neste intervalo, pelo menos 60% das imagens do conjunto estão em classes saturadas, indicando que apenas a variação no grau de generalização não resultou em melhorias significativas na qualidade das classificações geradas pela Fuzzy ART para esta aplicação.

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	w1	14	0	0	1	1	4	8	3	371	10	1323
2	w2	14	1	3	1	2	2	5	5	1229	7	1503
3	w3	14	1	2	4	2	1	4	4	1050	4	1050
4	w1	12	0	1	2	0	2	7	4	895	8	1317
5	w2	13	1	0	2	1	1	8	5	991	7	1259
6	w3	13	2	0	1	3	1	6	2	1083	6	1422
7	w1	10	0	1	1	0	2	6	2	901	4	1033
8	w2	14	0	1	1	1	4	7	1	374	7	1080
9	w3	14	0	2	1	3	2	6	2	485	8	1189
10	w1	13	0	0	2	1	1	9	4	665	7	1209
11	w2	11	0	0	2	2	3	4	2	971	5	1252
12	w3	13	1	0	1	2	2	7	3	820	7	1407
13	w1	12	0	0	1	2	3	6	3	970	9	1608
14	w2	13	0	1	0	3	2	7	3	792	7	1295
15	w3	14	0	3	2	1	3	5	5	1382	10	1636
16	w1	14	1	0	1	2	3	7	4	507	7	1141
17	w2	14	1	1	0	5	2	5	3	755	8	1289
18	w3	12	1	0	2	3	1	5	2	634	5	1084
19	w1	11	0	2	1	1	1	6	2	877	7	1555
20	w2	15	0	2	3	2	2	6	3	509	6	1145

Tabela 4.6: Instâncias da rede AUTOWISARD para o intervalo 1 (10-15 classes).

A Tabela 4.6 exibe as medidas das instâncias da AUTOWISARD para o intervalo 1. Percebe-se que a distribuição das classes geradas em termos de símbolos reconhecidos é similar à da Fuzzy ART para o mesmo intervalo. Porém, comparando-se a quantidade de imagens em classes saturadas, nota-se que a AUTOWISARD obteve mais sucesso em minimizar a influência das classes saturadas no reconhecimento do conjunto de imagens, especialmente para o patamar de saturação de 50% (aproximadamente 40% das imagens em classes saturadas).

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	w4	53	25	17	4	2	2	3	1	493	11	777
2	w5	57	23	18	7	3	1	5	0	0	13	547
3	w6	51	15	15	7	8	4	2	2	36	16	680
4	w4	57	34	13	3	4	1	2	2	635	10	825
5	w5	50	16	18	7	4	2	3	3	434	10	552
6	w6	56	21	16	6	9	3	1	4	272	15	728
7	w4	59	24	16	8	6	3	2	6	97	13	360
8	w5	58	26	15	9	5	2	1	1	51	11	504
9	w6	57	21	15	8	8	3	2	2	21	12	370
10	w4	58	29	21	1	4	2	1	3	710	13	829
11	w5	58	30	15	4	6	1	2	3	44	9	583
12	w6	55	14	16	12	10	3	0	2	19	13	495
13	w4	58	26	16	5	6	2	3	3	108	10	411
14	w5	56	24	14	11	5	1	1	2	380	9	473
15	w6	51	17	16	8	6	2	2	4	386	15	840
16	w4	58	30	15	4	7	0	2	3	19	13	764
17	w5	51	19	20	3	2	5	2	3	259	13	852
18	w6	55	20	19	5	6	3	2	3	435	8	559
19	w4	50	27	10	3	5	1	4	3	396	7	426
20	w5	50	25	12	8	1	2	2	2	347	8	610

Tabela 4.7: Instâncias da rede AUTOWISARD para o intervalo 2 (50-60 classes).

Já no intervalo 2 (Tabela 4.7), que é menos genérico que o primeiro, vê-se que, como era esperado, as classes com um dígito passaram a predominar sobre as outras, em todas as instâncias. As classes saturadas praticamente desapareceram no patamar de saturação de 50%, proporcionalmente ao tamanho do intervalo, bem como o número de imagens em classes saturadas caiu abruptamente, mesmo para o patamar mais rigoroso (75%). Fica claro que o aumento do grau de discriminação resultante do uso de um intervalo de classes maior refletiu-se na melhoria da qualidade das classificações obtidas pelas instâncias da AUTOWISARD.

Inst.	Conf.	Total classes	Símbolos por classe						Sat. 50%		Sat. 75%	
			1	2	3	4	5	6+	Cl.	Im.	Cl.	Im.
1	w7	104	63	22	11	5	2	1	6	50	15	184
2	w8	116	76	25	10	4	1	0	2	33	12	129
3	w9	111	65	27	11	7	1	0	3	64	15	220
4	w10	101	71	16	6	7	0	1	9	389	13	464
5	w7	107	66	22	12	3	3	1	4	39	11	152
6	w8	112	59	35	12	4	2	0	6	76	20	207
7	w9	110	56	38	11	4	0	1	5	37	14	110
8	w10	105	56	35	9	4	0	1	2	5	16	413
9	w7	111	66	24	13	6	1	1	6	89	20	298
10	w8	115	66	33	12	3	0	1	3	18	18	451
11	w9	107	66	26	6	6	3	0	1	4	14	350
12	w10	114	65	28	14	4	2	1	7	41	15	246
13	w7	101	60	25	7	8	1	0	4	42	13	170
14	w8	103	69	22	8	1	2	1	2	26	11	309
15	w9	108	60	33	10	3	2	0	3	33	11	182
16	w10	109	65	32	4	6	1	1	3	24	16	466
17	w7	108	65	23	13	7	0	0	3	37	15	161
18	w8	111	58	37	10	3	2	1	2	8	13	198
19	w9	102	60	20	12	8	2	0	6	53	18	378
20	w10	112	74	21	9	6	2	0	3	107	13	272

Tabela 4.8: Instâncias da rede AUTOWISARD para o intervalo 3 (100-120 classes).

A última tabela, mostrando as medidas para a AUTOWISARD no intervalo 3, é a Tabela 4.8. Neste intervalo, o mais discriminativo, as instâncias da AUTOWISARD, ao contrário das da Fuzzy ART, conseguiram aumentar ainda mais a quantidade de classes com apenas um símbolo (para em torno de 65% do total) e diminuir o número de imagens em classes saturadas, considerando-se ambos os patamares de saturação.




Figura 4.2: Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 1 (10-15 classes).

Rede Fuzzy ART, intervalo 1 (Figura 4.2): ocorreram muito poucas classes com apenas 1 símbolo, e a curva das classes com 4 ou mais símbolos atinge rapidamente os 100% (i.e., instâncias cujas classes estão todas contidas nessa categoria).




Figura 4.3: Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 2 (50-60 classes).

Rede Fuzzy ART, intervalo 2 (Figura 4.3): similar ao gráfico anterior, porém nesse caso a curva das classes com 4 ou mais símbolos não chega aos 100%, o que, juntamente com o crescimento das classes com 3 símbolos, aponta uma melhoria na qualidade de classificação média das instâncias.




Figura 4.4: Evolução do percentual de classes por quantidade de símbolos da rede Fuzzy ART no intervalo 3 (100-120 classes).

Rede Fuzzy ART, intervalo 3 (Figura 4.4): nesse intervalo as curvas das classes com 3 e 4 ou mais símbolos se estabilizam, possivelmente indicando que este intervalo está próximo do número de classes naturais do conjunto de treinamento.

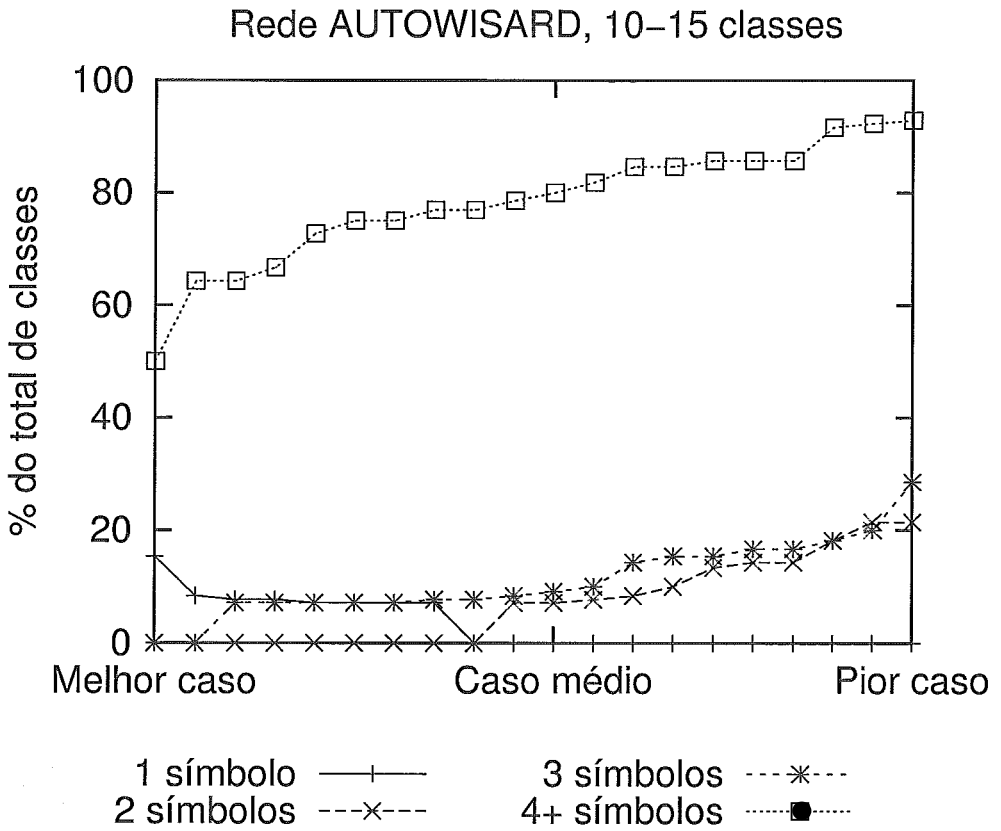


Figura 4.5: Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 1 (10-15 classes).

Rede AUTOWISARD, intervalo 1 (Figura 4.5): as instâncias da AUTOWISARD apresentaram qualidade de classificação semelhante às instâncias da Fuzzy ART no mesmo intervalo, porém, apesar do crescimento acentuado da curva representando as classes com 4 ou mais símbolos, ela não atinge o mesmo patamar que a curva correspondente na rede Fuzzy ART para o mesmo intervalo.




Figura 4.6: Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 2 (50-60 classes).

Rede AUTOWISARD, intervalo 2 (Figura 4.6): destaca-se nesse intervalo o rápido crescimento da curva representando as classes com apenas um símbolo, indicando melhor classificação; as curvas dos múltiplos símbolos estabilizaram-se, apesar do predomínio da curva representando 4 símbolos sobre a de 3 símbolos.




Figura 4.7: Evolução do percentual de classes por quantidade de símbolos da rede AUTOWISARD no intervalo 3 (100-120 classes).

Rede AUTOWISARD, intervalo 3 (Figura 4.7): as curvas das classes com 1 e 2 símbolos distanciam-se claramente das curvas restantes e a curva das classes com 4 símbolos encontra-se com seus valores mais baixos, indicando estar este intervalo mais próximo do número de classes contidas no conjunto das imagens, e de ser o que apresenta os perfis de classificação de melhor qualidade.




Figura 4.8: Evolução do percentual de imagens em classes saturadas (a 50%) em ambas as redes.

Percentual de imagens em classes saturadas a 50% (Figura 4.8): as curvas correspondentes à rede AUTOWISARD são consistentemente mais baixas do que as da rede Fuzzy ART, independentemente do intervalo de classes escolhido; a curva da AUTOWISARD no intervalo 3, estando tão baixa, sugere que, mesmo havendo erros de classificação naquelas instâncias, o percentual de imagens em classes que não apresentam um dígito “vencedor” é bastante pequeno.

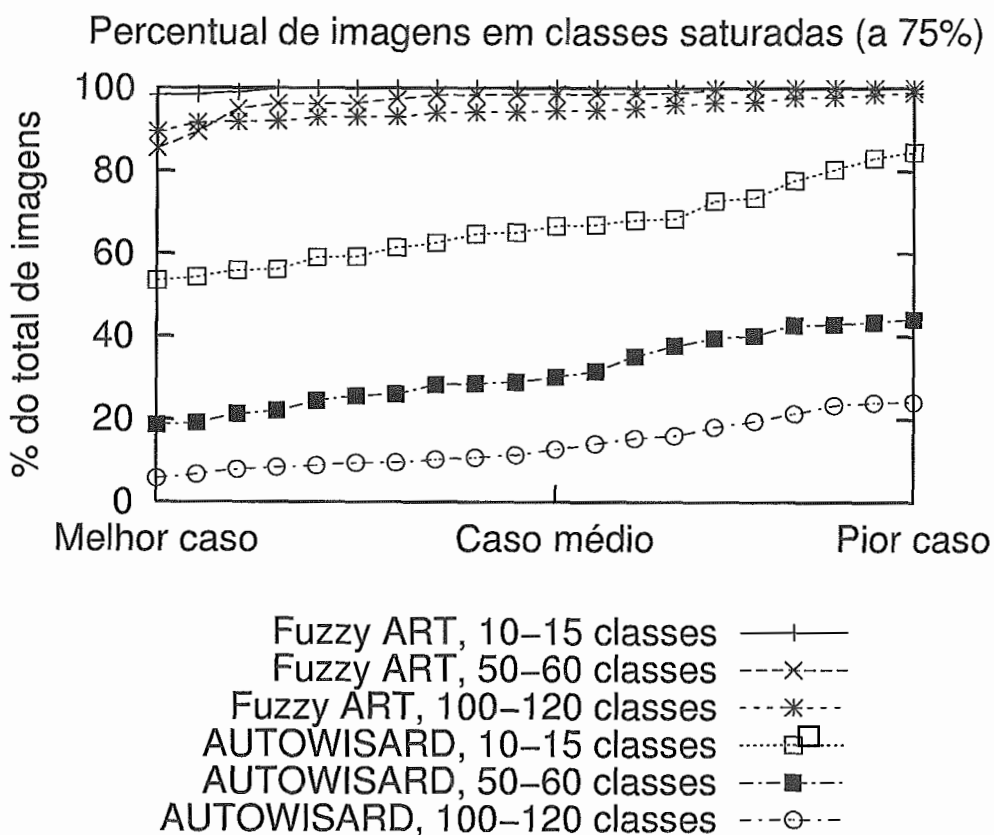


Figura 4.9: Evolução do percentual de imagens em classes saturadas (a 75%) em ambas as redes.

Percentual de imagens em classes saturadas a 75% (Figura 4.9): as curvas se comportam de modo similar ao gráfico anterior, porém com patamares mais elevados, devido ao patamar mais restritivo (discriminativo). Observa-se também que, para esse patamar, todas as imagens estão contidas nas classes saturadas das redes Fuzzy ART, independentemente do intervalo de generalização.




Figura 4.10: Evolução do percentual de classes saturadas (a 50%) em ambas as redes.

Percentual de classes saturadas a 50% (Figura 4.10): apresenta-se uma semelhança entre as curvas dos intervalos 2 e 3 em cada rede. Devido ao patamar baixo, as curvas da AUTOWISARD para os intervalos 2 e 3 atingem seus patamares mais baixos.




Figura 4.11: Evolução do percentual de classes saturadas (a 75%) em ambas as redes.

Percentual de classes saturadas a 75% (Figura 4.11): é muito pequena a separação entre as três curvas da rede Fuzzy ART, tendo subido consideravelmente apenas com a mudança de patamar, indicando independência entre o percentual de classes saturadas (praticamente 100%) e os intervalos de criação das mesmas; também estão próximas as curvas da AUTOWISARD nos intervalos 2 e 3, mas num patamar significativamente mais baixo.

O exame dos gráficos mostra claramente a superioridade em classificação da AUTOWISARD sobre a Fuzzy ART, para este tipo de aplicação, que é aqui considerado representativo de um grande número de problemas interessantes na área de reconhecimento de padrões. Algumas explicações para esse fato verificado residem nas diferenças de representação interna de classes entre a AUTOWISARD e a Fuzzy ART.

Como foi mostrado anteriormente, o modelo Fuzzy ART usa simples vetores para representar suas classes, cada vetor “mimetizando” um padrão, denominado de protótipo de uma classe (não necessariamente um padrão real, geralmente um padrão sintético), enquanto que o modelo AUTOWISARD (e seu precursor, o WISARD) utiliza discriminadores para tanto. Na medida em que um discriminador é capaz de reconhecer (totalmente), via combinações de ênuplas, diversos padrões (representação “multivetorial”), e o vetor da Fuzzy ART apenas um, a AUTOWISARD é beneficiada por usar uma estrutura mais rica, capaz de representar regiões complexas no espaço de padrões de entrada, ao contrário dos vetores da Fuzzy ART, que representam apenas regiões regulares (hipercubos[11]). Essas regiões complexas têm seu crescimento controlado pela janela de aprendizado e o aprendizado parcial implementadas na AUTOWISARD, que tendem a limitar o surgimento de discriminadores abrangendo regiões muito amplas no espaço de entradas (mais suscetíveis a erros de classificação). Essa situação é verificada pela clara predominância das classes que reconhecem um símbolo sobre as classes que reconhecem múltiplos símbolos da AUTOWISARD, em comparação com a Fuzzy ART, demonstrando a melhor adequação das classes geradas pela AUTOWISARD às classes existentes naturalmente no conjunto de entradas.

Outro fator relevante ao melhor desempenho da AUTOWISARD deve-se ao algoritmo de aprendizado da Fuzzy ART implementar “esquecimento”:

mo seus vetores tendem ao vetor zero, um vetor que represente um padrão, ao sofrer novas adaptações, reduzirá sua similaridade ao mesmo padrão, que poderá ser “capturado” por outra classe com menos conhecimento (i.e., com uma distância de Hamming para o vetor zero maior que a classe adaptada). Apesar desse fenômeno da realocação pós-treinamento de padrões para outras classes também ocorrer com a AUTOWISARD, o reconhecimento monotônico característico do discriminador evita que haja queda no reconhecimento dos padrões previamente apresentados ao longo do ciclo de treinamento.

Por último, outra propriedade intrínseca do discriminador que auxilia na melhor qualidade de classificação da AUTOWISARD é a sua visão “estruturada” das entradas, o fato de assumir a existência de relacionamentos entre bits (pixels) arbitrários nos padrões de entrada, refletidos no seu mapeamento interno de bits para ênuplas. Essa propriedade contribui para que sejam representadas, nos neurônios, definições (do tipo tabela-verdade) de *features*, geométricas ou não, importantes na diferenciação das classes. A possibilidade de se realizar tais definições não é contemplada pela representação da Fuzzy ART.

Capítulo 5

Conclusões e Trabalhos Futuros

Neste trabalho, apresentamos o modelo neural AUTOWISARD, um novo algoritmo de aprendizado para a rede neural WISARD, sendo este modelo o primeiro a implementar aprendizado não-supervisionado baseando-se apenas na arquitetura original da WISARD. Esse modelo aproveitou características da WISARD, consideradas como limitações, como o reconhecimento monotônico da sua estrutura de representação de classes, o discriminador, que tende a um estado de saturação, e a sua métrica de erro discreta, para implementar novos métodos de controle e estabilização de aprendizado, como a janela de aprendizado e o aprendizado parcial, que permitiram à AUTOWISARD atingir seu objetivo de estender as potencialidades do modelo original em direção às aplicações que requeiram sistemas com aprendizado não-supervisionado.

O desempenho da AUTOWISARD como classificador foi comparado com o de outra rede não-supervisionada popular, a Fuzzy ART(1), numa aplicação simples de reconhecimento de caracteres (dígitos). Uma comparação direta em cima de resultados dessas redes neurais, no entanto, encerra em si uma série de problemas. Desta maneira, para superá-los, um método de normalização e apresentação de dados foi desenvolvido, resumizando os resultados dos experimentos em representações gráficas, que permitiram realizar as com-

parações entre os modelos distintos. Nestes gráficos verificou-se a constante superioridade das classificações geradas pela AUTOWISARD sobre a Fuzzy ART, tanto em termos de quantidade de classes representando múltiplos símbolos, quanto do grau de saturação (reconhecimento de múltiplos símbolos, com pequena tendência a um símbolo específico) de cada uma dessas classes, quantitativamente.

A superioridade demonstrada pela AUTOWISARD se deve a vários fatores, alguns herdados da WISARD, outros próprios de seu algoritmo de aprendizado, como a capacidade de representação “multivetorial” do discriminador e seu reconhecimento monotônico de padrões previamente aprendidos, bem como o controle de instanciação e saturação de classes proposto pelo novo modelo.

Assim, a AUTOWISARD teve sucesso em um de seus ensejos, que era o de acrescentar novas potencialidades e abrir novas possibilidades para o modelo WISARD.

5.1 Trabalhos Futuros

Por ter sua origem no modelo neural WISARD, e ser compatível com (mapeável para) o mesmo, muitos dos trabalhos futuros que podem ser desenvolvidos com a AUTOWISARD derivam das aplicações da WISARD, que são, basicamente, reconhecedores de padrões em imagens. Tais aplicações, se convertidas para o uso do modelo AUTOWISARD, podem ter seu desempenho melhorado pelo emprego do aprendizado não-supervisionado, que minimiza ou elimina os condicionamentos impostos por treinamentos supervisionados.

Algumas modificações e experimentos que podem ser realizados com a rede AUTOWISARD são:

- uso de ênuplas de vários tamanhos[6], propiciando à AUTOWISARD

aprender e reconhecer *features* de tamanhos diversos que possam existir nos padrões de uma determinada aplicação;

- efetuar comparações do modelo AUTOWISARD com e sem o uso da função de controle de aprendizado na janela de aprendizado, para verificar sua influência sobre a capacidade de generalização da rede, bem como relacionar essas variações na generalização com o mesmo tipo de variação resultante do uso de ênuplas de tamanhos diversos (mas de tamanhos fixos por discriminador);
- propor novos métodos para tornar o controle da AUTOWISARD mais simples, de modo a eliminar algum dos parâmetros de treinamento (os limites da janela de aprendizado), como, por exemplo, implementar um algoritmo que utilize uma janela de largura fixa, mas com posição central variável ao longo do treinamento, de modo que a rede possa controlar dinamicamente (até um certo grau) sua capacidade de generalização;
- testar a AUTOWISARD em aplicações que demandem o reconhecimento de padrões em imagens não-binárias, usando codificações especiais de valores escalares para binários, como o CMAC[8];
- comparar o desempenho em classificação da AUTOWISARD contra a (Fuzzy) ART num domínio caracterizado por padrões unidimensionais, com menor número de bits do que as imagens usadas nesta dissertação, menos favoráveis a uma abordagem baseada em neurônios RAM. Esses padrões não estariam pré-rotulados, e demandariam uma interpretação/rotulação subjetiva, dependente de um especialista (humano).

Outro desenvolvimento digno de nota é o modelo AUTOWISARD hierárquico [13]. Ele consiste de uma rede AUTOWISARD organizada numa estrutura recursiva (árvore), permitindo gerar classificações hierárquicas de conjuntos

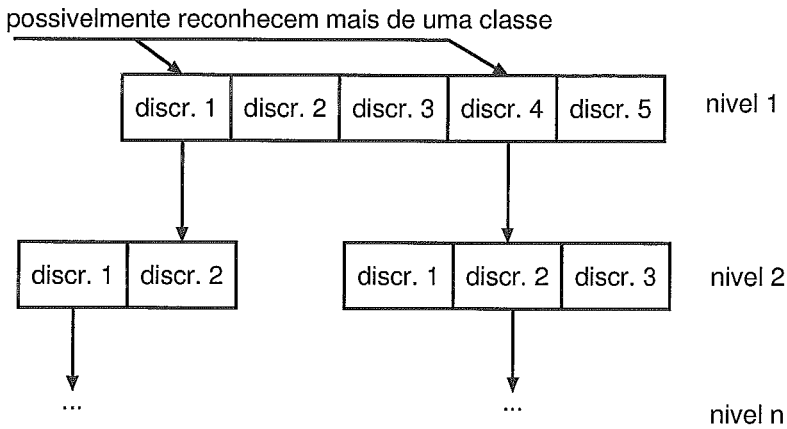


Figura 5.1: Modelo AUTOWISARD hierárquico.

de dados, explicitando relações entre classes e subclasses geradas (Figura 5.1). Nesse modelo, uma rede AUTOWISARD, a raiz, é treinada com o conjunto de dados, e os intervalos entre os reconhecimentos mínimo e máximo obtidos em cada discriminador por seus padrões reconhecidos são avaliados. Os discriminadores cujos intervalos forem maiores do que um valor de intervalo pré-estabelecido possivelmente estão reconhecendo mais de uma classe, e receberão cada um uma rede AUTOWISARD “filha”, que serão treinados com os padrões reclamados pelos respectivos discriminadores “pais”, e assim recursivamente, até que mais nenhum discriminador necessite de uma rede filha.

Desse modo, pode-se treinar a rede-raiz de modo a obter alto grau de generalização, e especializar a classificação nos níveis seguintes, que serão treinados apenas com (sub)conjuntos de padrões afins, aumentando a probabilidade dos discriminadores nas folhas separarem corretamente as classes contidas nos seus subconjuntos.

Referências Bibliográficas

- [1] Aleksander, I., Morton, H. *An Introduction to Neural Computing*. Chapman and Hall, London, 1990.
- [2] Aleksander, I., Thomas, W. V., Bowden, P. A. “WISARD: a radical step forward in image recognition”. *Sensor Review*, v. 4, n. 3, pp. 120–124, 1984.
- [3] Alpaydin, E., Kaynak, C. *Handwritten digits database*. Bogaziçi University, Turkey, <ftp://ftp.ics.uci.edu/pub/machine-learning-databases/optdigits/>, 1998.
- [4] Carpenter, G. A., Grossberg, S. “A Massively Parallel Architecture for a Self Organising Neural Pattern Recognition Machine”. *Computer Vision and Image Processing*, v. 54, pp. 54–115, 1986.
- [5] Carpenter, G. A., Grossberg, S., Rosen, D. B. “Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system”. *Neural Networks*, v. 4, pp. 759–771, 1991.
- [6] França, F. M. G., de Gregorio, M., Soares, C. M., da Silva, C. L. F. “Uma Implementação em Software do Classificador WISARD”. In *Anais do V Simpósio Brasileiro de Redes Neurais*, pp. 225–229, Dez. 1998.

- [7] Fulcher, E. P. “WIS-ART: Unsupervised Clustering with RAM Discriminators”. *International Journal of Neural Systems*, v. 3, n. 1, pp. 57–63, 1992.
- [8] Kolcz, A., Allison, N. M. “Application of the CMAC input encoding scheme in the N-tuple approximation network”. *IEEE Proceedings-E Computers and Digital Techniques*, v. 144, n. 3, pp. 177–183, 1994.
- [9] Ludermir, T. B., de Carvalho, A., Braga, A. P., de Souto, M. C. P. “Weightless Neural Models: A Review of Current and Past Works”. In *Neural Computing Surveys*, v. 2, pp. 41–61, <http://www.icsi.berkeley.edu/~jagota/NCS>, 1999.
- [10] Moore, B. “ART 1 and Pattern Clustering”. In *Proceedings of the 1988 Connectionist Models Summer School*, pp. 174–185, San Mateo, CA, USA, 1988. Morgan Kaufman.
- [11] Sarle, W. S. *Why Statisticians Should Not FART*. <ftp://ftp.sas.com/pub/neural/fart.txt>, 1995.
- [12] Vilela, I. M. O. “An Integrated Approach of Visual Computational Modelling”. In *Proceedings of the 6th Brazilian Symposium on Neural Networks*, pp. 293. IEEE Computer Society, Nov. 2000.
- [13] Wickert, I., França, F. M. G. “AUTOWISARD: Unsupervised Modes for the WISARD”. *Lecture Notes in Computer Science*, v. 2084, pp. 435–441, Jun. 2001.