

NC-WISARD: UMA INTERPRETAÇÃO BOOLEANA DA ARQUITETURA NEOCOGNITRON

LAWRENCE C. BANDEIRA*, HORACIO L. FRANÇA*, FELIPE M. G. FRANÇA*

*Programa de Engenharia de Sistemas e Computação, COPPE
Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil

Emails: lawrence@cos.ufrj.br, horaciolf@gmail.com, felipe@cos.ufrj.br

Abstract— The NC-WISARD is a neural network based on the *Neocognitron*'s multilayered hierarchical network, on the the weightless *WiSARD* perceptron and also on its variation with non-supervised training methodology, the *AUTO-WiSARD*. The multilayered system enables the correct recognition, not only of previously trained patterns, but also any variation of size, position and distortions that the image may have. As a weightless network, the *WiSARD* contributes with its highly efficient training method and great generalization capability. With the ability of extraction of patterns that are simple and relevant to the images, the NC-WiSARD can, like Neocognitron, through its hierarchical structure, recognize and assemble more complex patterns.

Keywords— NC-Wisard, Neocognitron, WiSARD, AUTO-WiSARD, neural network, weightless.

Resumo— A NC-WiSARD é uma rede neural baseada na rede hierárquica multicamadas do *Neocognitron*, no perceptron sem-peso *WiSARD* e também em sua variação que utiliza o método de treinamento não-supervisionado, a *AUTO-WiSARD*. É através do sistema de multicamadas que é possível o reconhecimento correto não só de padrões que foram treinados, mas de qualquer variação que ocorra em tamanho, localização além de imperfeições que podem acompanhar a imagem. Como a *WiSARD* é uma rede sem-peso, ela contribui com sua alta eficiência no método de treinamento e grande capacidade de generalização. Com habilidade de extração de padrões simples e relevantes das imagens, a NC-WiSARD consegue, de maneira equivalente ao *Neocognitron*, reconhecer e compor padrões mais complexos através de sua estrutura hierárquica.

Palavras-chave— NC-Wisard, Neocognitron, WiSARD, AUTO-WiSARD, rede neural, sem-peso.

1 Introdução

A *WiSARD* é uma rede neural que modifica o conteúdo de memórias RAM distribuídas como mecanismo de aprendizado, ao invés de alterações de valores dos pesos. Um conjunto dessas memórias operam como um conjunto de perceptrons, e são capazes de fornecer alto desempenho para o aprendizado da rede. A *AUTO-WiSARD* surgiu em resposta a necessidade de uma rede com capacidade de treinamento sem supervisão, ou seja, onde não seja preciso indicar qual a categoria treinada.

Diferente das duas redes já citadas, o *Neocognitron* é uma rede neural com peso proposta por Fukushima (Fukushima, 1988; Fukushima, 2003). Baseado em estudos feitos sobre o córtex visual humano (Hubel and Wiesel, 1962), a arquitetura dessa rede neural simula a hierarquia de camadas de neurônios, possibilitando respostas crescentes em complexidade. Isso significa que nos primeiros níveis da rede são identificados padrões simples como linhas e ângulos, e a medida que a hierarquia evolui, características mais complexas são formadas. Dessa forma é possível treinar e reconhecer padrões de imagens, mesmo que não possuam exatamente as mesmas características, como por exemplo tamanho e posição na imagem.

A NC-WiSARD foi desenvolvida com arquitetura similar a do *Neocognitron*, mas com o sistema de aprendizado da *WiSARD* e *AUTO-WiSARD*.

Através do conceito das duas redes sem-peso, é possível extrair a cada nível da hierarquia características importantes de imagens submetidas à rede. Os discriminadores da *WiSARD* são os responsáveis pela retenção da informação aprendida e, com a evolução de camadas eles coletam características cada vez mais complexas. Então, ao final da hierarquia, a identificação de imagens é conseguida como na rede neural *Neocognitron*.

Na Seção 2 é explicado o funcionamento da rede sem-peso *WiSARD*, onde é descrito como o treinamento e reconhecimento de padrões é feito por essa rede. De forma similar à segunda seção, a *AUTO-WiSARD* é descrita na Seção 3 e a rede neural *Neocognitron* na Seção 4. Para a explicação da NC-WiSARD, foi utilizada a Seção 5, onde está descrito em mais detalhes como sua arquitetura foi organizada, como é o funcionamento do método de treinamento e reconhecimento, e por fim a reposta da rede e os resultados. Uma subseção ainda foi reservada para explicar as principais diferenças entre o *Neocognitron* e a NC-WiSARD.

2 *WiSARD*: o perceptron sem-peso

Diferentemente dos modelos baseados na estilização de neurônio artificial de McCulloch e Pitts (Aleksander et al., 1984), o perceptron *WiSARD* (Wilkie, Stonham and Aleksander's Recognition

Device) (Aleksander et al., 1984; Soares et al., 1998) não adota sinapses com pesos como base para seu funcionamento. Alternativamente, neurônios artificiais que priorizam a emulação da topologia das conexões entre dendritos e axônios, i.e., a árvore dendrítica, são adotados. Cada neurônio de uma rede *WiSARD* tem a funcionalidade de uma RAM (*Random Access Memory*) capaz de armazenar 2^n bits e, desta forma, cada neurônio é capaz de aprender e reconhecer entradas de n bits (n -upla) advindas de um padrão alvo, como visto na Figura 1.

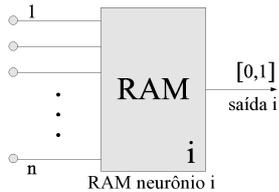


Figura 1: Neurônio RAM com n entradas

O treinamento é feito mudando o conteúdo da posição de memória endereçada pela n -upla, que é iniciado com “0”, para “1”. Apesar dos neurônios RAM serem eficientes no reconhecimento e no aprendizado, eles perdem capacidade de generalização, já que reconhecem apenas os padrões apresentados anteriormente. Para superar essa dificuldade, os neurônios são organizados em uma estrutura denominada discriminador (Figura 2), em que cada neurônio, de um total de d neurônios, é responsável por aprender e reconhecer uma sub-seção de um padrão com tamanho $n \times d$. Um discriminador é capaz de reconhecer um padrão possivelmente desconhecido X fazendo a soma dos bits de saída de todos os seus neurônios. Submetido a um nível de confiança c , o padrão X pode ser associado a uma classe já treinada.

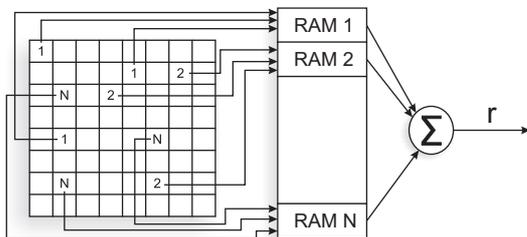


Figura 2: Discriminador

Na Figura 3, é possível observar um perceptron *WiSARD*. Ele consiste em uma série de m discriminadores, cada um representando uma classe diferente de padrões. Um padrão de entrada, depois de passar por uma função de embaralhamento E , será submetida a: (i) um discriminador específico, na fase de treinamento; (ii) todos os discriminadores, na fase de reconhecimento, quando todas as m respostas são analisadas.

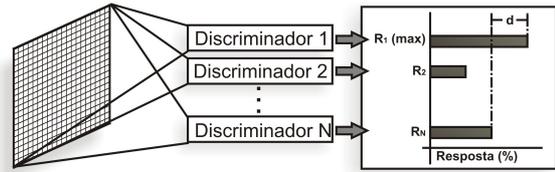


Figura 3: A *WiSARD*

3 *AUTO-WiSARD*: aprendizado não-supervisionado

Visando introduzir treinamento não-supervisionado no modelo *WiSARD*, foi criado o algoritmo de treinamento *AUTO-WiSARD* (Wickert and França, 2002; Wickert and França, 2001). Uma parte importante desse algoritmo é que a arquitetura de discriminadores se mantém, mas o número de discriminadores ao fim do treinamento não é conhecido *a priori*, é resultante do referido processo de treinamento.

O treino é realizado sendo determinado o r_{best} , ou seja, o melhor resultado dentre todos os discriminadores para o padrão apresentado. Dentro da janela de aprendizado em um discriminador, se o r_{best} for maior do que um limite superior w_{max} então nada é alterado. Caso contrário, se r_{best} for menor que o limite inferior w_{min} então é gerada uma nova classe e o primeiro padrão a treiná-la é o padrão apresentado. Finalmente, se o r_{best} for maior que w_{min} e menor que w_{max} então é feito um treino do discriminador que teve o resultado r_{best} para o padrão apresentado.

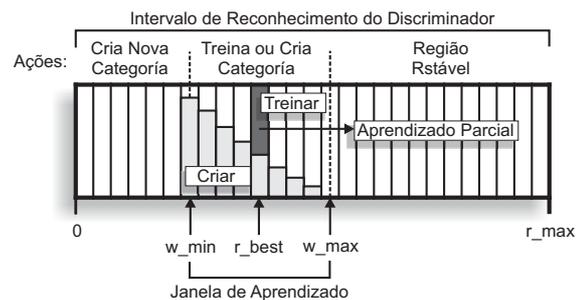


Figura 4: Janela de aprendizado *AUTO-WiSARD*

Para minimizar a saturação (treinamento desnecessário e possivelmente prejudicial) da rede, o re-treinamento de um discriminador não pode ser feito toda vez que o r_{best} for maior que w_{min} e menor que w_{max} . A forma definida para selecionar os padrões que serão efetivamente adotados no treinamento é uma decisão probabilística. Além dos passos explicados anteriormente, quando um discriminador é selecionado para treinamento, utiliza-se uma função de probabilidade para determinar se o padrão é treinado ou se uma nova classe será criada. A

função (que pode variar de acordo com as necessidades) faz com que a probabilidade de que a rede seja re-treinada aumenta à medida que a quantidade de discriminadores que reconheçam o padrão aumenta e a probabilidade de que seja criado outro padrão diminui. O discriminador com a janela de aprendizado por ser visto na Figura 4 (Wickert and França, 2002).

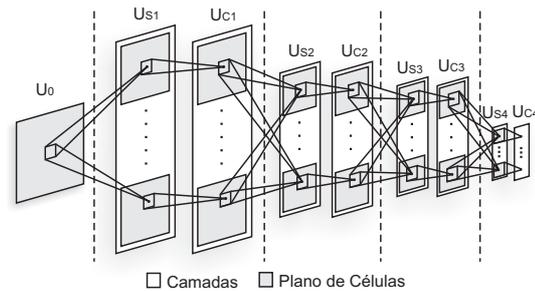


Figura 5: O Neocognitron

4 Neocognitron: arquitetura multicamadas

O córtex visual tem a capacidade de identificação de imagens a partir do reconhecimento de conjuntos de padrões simples. Através de camadas de neurônios, os padrões simples são concatenados de uma camada para a outra até formar imagens completas para o processamento cerebral.

O Neocognitron é definido por Fukushima como uma rede neural hierarquica de múltiplas camadas (Fukushima, 1988; Fukushima, 2003). A rede possui conexões variadas entre células e pode adquirir a habilidade de reconhecer padrões por aprendizado. Ela pode ser treinada para reconhecer quaisquer conjuntos de padrões. Terminado o processo de aprendizado, a resposta das células do nível mais evoluído da rede mostra o resultado final do reconhecimento: apenas uma célula responde, e é a célula correspondente à categoria do padrão de entrada. O reconhecimento é feito com base no grau de similaridade, e é eficiente mesmo na presença de deformações, mudanças de tamanho, ou alterações de posição nos padrões de entrada.

O nível inicial da rede U_0 é composto de uma matriz bi-dimensional de células receptoras u_0 , correspondendo à imagem a ser reconhecida. Cada um dos níveis seguintes é composto de duas camadas: (i) uma camada de células S que reconhecem a presença de uma certa característica em uma determinada posição em todos os planos da camada anterior, sendo estas características determinadas durante o treinamento, exceto no nível 1, onde os pesos são pré-definidos; (ii) uma camada de células C de generalização (ou borramento) para o reconhecimento de padrões com deformações, mudanças de tamanho, ou alterações de posição. A presença de camadas de células C (Figura 5) em cada nível da rede tem um papel importante na habilidade da mesma em reconhecer padrões distorcidos. De forma geral, nos níveis inferiores da rede, características locais, como uma linha em uma determinada orientação, são extraídas, enquanto que nos níveis superiores, características completas, como parte de um padrão treinado ou até mesmo o padrão completo, são contempladas.

5 NC-WiSARD: o Neocognitron Booleano

A NC-WiSARD é uma rede neural multicamada que utiliza o conceito de sinapses sem peso. Por utilizar a idéia de hierarquia de camadas do Neocognitron, e a eficiência do treinamento do perceptron sem-peso WiSARD, a rede proposta tem a capacidade de reconhecer padrões, mediante treinamento, independente da posição e tamanho.

5.1 Arquitetura proposta

A NC-WiSARD buscou na arquitetura do Neocognitron as vantagens do reconhecimento de padrões de imagens, mesmo com deslocamento e/ou alteração de tamanho. Pode-se observar na Figura 6 como o primeiro nível da rede identifica características relevantes de uma imagem. Uma vez estabelecido o tamanho em pixels da extração das características, é possível varrer a imagem, treinando discriminadores através do mecanismo da AUTO-WiSARD, como visto na Seção 3.

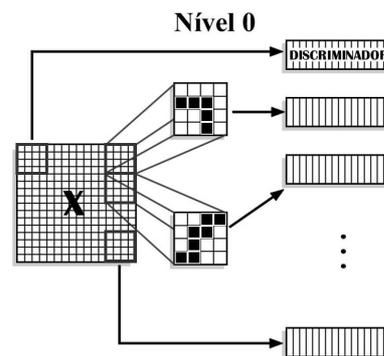


Figura 6: Primeiro Nível da NC-WiSARD

Na Figura 7 observa-se como a arquitetura consegue prover respostas crescentes em complexidade. Para tal, foram utilizadas informações contidas em discriminadores do nível anterior, para gerar cada plano de imagem do nível seguinte. Dessa maneira, a soma de alguns padrões é passada para cada plano de imagem do nível seguinte, tornando-se uma característica mais complexa em relação à

imagem inicial.

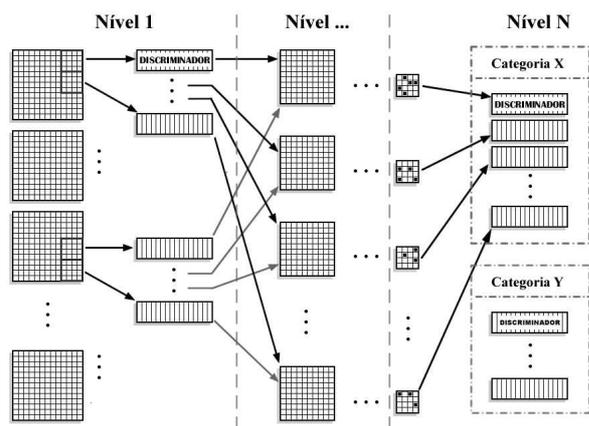


Figura 7: Demais níveis da NC-WiSARD

5.2 Treinamento e reconhecimento

O método de treinamento consiste em extrair características relevantes de uma imagem, e treinar discriminadores para cada nível da NC-WiSARD. Essas características ou padrões são pequenos pedaços da imagem. Cada característica, que seja considerada relevante, irá ou gerar um novo discriminador ou retrainar algum já existente. A decisão de criação ou retraining cabe à janela de aprendizado da *AUTO-WiSARD*, que identifica se a similaridade é baixa ou alta respectivamente. Características com alta similaridade são descartadas, pois são consideradas pela janela de aprendizado como já treinadas, como visto na Seção 3.

Na Figura 6 fica claro que o treinamento dos discriminadores do primeiro nível é feito através de padrões encontrados na imagem apresentada à rede. Entretanto, para os demais níveis (Figura 7), são utilizadas características geradas através da filtragem da imagem do nível anterior, por meio dos discriminadores treinados neste. Para cada padrão encontrado na imagem do nível anterior, o discriminador gera uma resposta (Seção 2) que acionará ou não um pixel na nova imagem. Toda imagem que é apresentada à rede ou criada por ela é representada através de vetores bidimensionais com informação binária.

Exceto o primeiro nível, os discriminadores podem receber treinamentos de características de uma ou mais imagens geradas durante a evolução dos níveis da hierarquia. Dessa forma padrões mais representativos e significativos serão passados para os próximos níveis através das somas de padrões anteriormente identificados. Ao final de todos os níveis, cada categoria deverá possuir um conjunto de discriminadores que a identificará. Exceto o último nível, todo o treinamento da rede é não-supervisionado, pois a própria rede define as ca-

racterísticas que irão criar ou retrainar discriminadores. Para o reconhecimento de uma categoria de imagem, é necessário que o treinamento do último nível da hierarquia da rede seja supervisionado, ou seja, que sejam informados quais serão os discriminadores que o identificarão.

Enquanto no treinamento os discriminadores são criados ou alterados a partir das imagens, no reconhecimento o que acontece é apenas a filtragem da informação das imagens, nível após nível, através dos discriminadores. Ao final da última etapa, as imagens geradas pela rede são submetidas aos discriminadores treinados de cada nível. Através da identificação do maior somatório entre todas as respostas dos discriminadores de cada categoria, a rede é capaz de responder a qual categoria pertence a imagem apresentada.

5.3 Extração de padrões e resposta da rede

Na Figura 8 é possível ver exemplos de padrões extraídos durante o treinamento de algarismos 1's e 0's escritos à mão. No nível 1, observa-se o aprendizado de características marcantes das categorias treinadas. Os níveis 2 e 3 são resultados de filtragens através dos discriminadores dos níveis 1 e 2, respectivamente. É no decorrer da rede que são gerados os padrões únicos que garantem o reconhecimento das diferentes categorias treinadas.

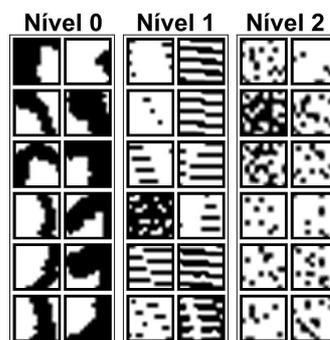


Figura 8: Características extraídas.

Para o treinamento da rede, foram utilizadas 500 imagens de algarismos manuscritos de zero a nove (50 imagens para cada categoria). Essas imagens possuem 32x32 pixels de dimensões, e o tamanho escolhido para a extração das características é de 12x12 pixels. Dessa forma, em cada nível da rede, as imagens geradas terão 11 pixels a menos (em cada dimensão), em relação ao nível anterior. Isso ocorre devido ao mapeamento da resposta do discriminador para apenas um pixel na imagem formada pela filtragem. Uma vez que há a redução de tamanho das imagens geradas, três níveis são suficientes para o aprendizado da rede nessas configurações. Não é necessário que o tamanho inicial

das imagens seja com estas exatas definições. O tamanho para extração de características é parametrizável, e vale ressaltar que essas modificações das configurações de entrada da rede devem ser mantidas para todo o treinamento.

5.4 O Neocognitron e a NC-WiSARD

Para o desenvolvimento da NC-WiSARD foi utilizada a mesma idéia de hierarquia de multicamadas do *Neocognitron*, baseadas no córtex visual. Apesar da similaridade arquitetural das duas redes, o *Neocognitron* utiliza a alteração de pesos para a extração de padrões relevantes das imagens submetidas à rede, enquanto a NC-WiSARD submete ao treinamento booleano de estruturas de aprendizado, os discriminadores (Figura 2).

Entretanto, existem diferenças arquiteturais entre as duas implementações. Conforme observado na Figura 5, o *Neocognitron* utiliza duas camadas em cada nível, sendo uma para a extração de padrões e a outra para o borramento, com a finalidade de generalização da imagem. Na arquitetura proposta por este trabalho, não foi utilizada essa outra camada pelo simples motivo que a *WiSARD* (Seção 2) tem como uma de suas características a generalização dos padrões aprendidos pela rede. Outro ponto que é necessário ressaltar, é a não implementação da extração pré-definida de ângulos no primeiro nível. Essa característica estrutural foi eliminada pelo simples motivo de representar uma amarração da arquitetura, que impossibilitaria abranger categorias genéricas.

6 Conclusões

Neste trabalho foi apresentado uma implementação de uma rede neural sem-peso utilizando a hierarquia multicamadas, a NC-WiSARD. Essa rede foi desenvolvida utilizando as principais características do *Neocognitron*, da *WiSARD* e da *AUTO-WiSARD*. É a primeira versão booleana da arquitetura Neocognitron desenvolvida que temos notícia, que utiliza o conceito de redes neurais sem peso para adaptação do Neocognitron. É esperado que a NC-WiSARD se beneficie das vantagens desse tipo de rede, e dentre todas podemos citar a velocidade de treinamento, como sendo a mais significativa.

Apesar da arquitetura ser similar a do *Neocognitron*, ela apresenta algumas diferenças importantes. Não possui previamente fixada a extração de padrões no primeiro nível e a camada extra para generalização em cada nível da rede. A primeira foi uma decisão de arquitetura para a generalização de categorias aceitas pela rede, e a segunda

diferença ocorre devido a *WiSARD* prover implicitamente essa característica à rede.

Todo o treinamento da rede é não-supervisionado, exceto o último nível para a qual é preciso informar qual a categoria está sendo treinada, pois é dessa forma que são separados os discriminadores que a representam. Os discriminadores são os elementos responsáveis pelas informações do aprendizado. Eles são criados ou alterados de acordo com a janela de aprendizado da *AUTO-WiSARD*. No início da rede, características simples são aprendidas, mas ao decorrer dos níveis da rede, são transformadas em características mais complexas, abrangendo assim diferentes categorias de forma única.

Agradecimentos

Agradecemos aos colegas Leandro Marzulo e Bruno França pela revisão desse texto, além da Fundação COPPETEC pelo suporte financeiro que concede a um dos autores desse artigo.

Referências

- Aleksander, I., Thomas, W. V. and Bowden, P. A. (1984). Wisard: A radical step forward in image recognition, *Sensor Review* pp. 120–124.
- Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition, *Neural Networks* **1**: 119–130.
- Fukushima, K. (2003). Neocognitron for handwritten digit recognition, *Neurocomputing* **51**: 161–180.
- Hubel, D. H. and Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, *Journal de Physiologie* **106**(1): 106–154.
- Soares, C. M., Silva, C. L. F., Gregorio, M. and França, F. M. G. (1998). Uma implementação em software do classificador wisard, *Anais do V Simpósio Brasileiro de Redes Neurais*, Vol. 2, V Simpósio Brasileiro de Redes Neurais, Belo Horizonte, pp. 225–229.
- Wickert, I. and França, F. M. G. (2001). Autowisard: Unsupervised modes for the wisard, *Lecture Notes in Computer Science*, Vol. 2084, pp. 435–441.
- Wickert, I. and França, F. M. G. (2002). Validating an unsupervised weightless perceptron, *Proc. 9th International Conference on Neural Information Processing ICONIP '02*, Vol. 2, pp. 537–541.