

1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajuba
Itajuba, 24 a 27 de outubro de 1994

Modelagem de Superfícies Usando Redes Neurais

LUIZ CARLOS DA SILVA
CLYLTON GALAMBA FERNANDES
EDSON COSTA DE BARROS CARVALHO FILHO

UFPE-Universidade Federal de Pernambuco
Departamento de Informática
Cx 7851, 50.732-970, Recife, PE, Brasil
{lcds@di, cjgf, ecdbcf}@di.ufpe.br

Sumário. Este trabalho apresenta uma técnica para modelagem de superfícies utilizando Redes Neurais Artificiais, visando à geração de objetos físicos sólidos. Será discutida a viabilidade do uso dos Mapas de Kohonen nesta modelagem. É apresentada uma análise de alguns experimentos do ponto de vista da convergência da rede, observando os melhores parâmetros usados no processo de treinamento. Será averiguado também os aspectos visuais da superfície gerada: suavidade e distribuição de pontos.

1 Introdução

Em muitas aplicações, as Redes Neurais Artificiais tem sido usadas como ferramenta para reconhecimento de padrões [7]. Elas possuem a habilidade de generalização e adaptação para novas situações, onde após o treinamento de alguns exemplos uma rede é capaz de definir uma representação dos estímulos de entrada nas suas estruturas internas.

A Modelagem de Sólidos [3], por sua vez, emergiu rapidamente como um dos principais campos de pesquisa e desenvolvimento em diversas áreas de aplicação, tais como: engenharia e design de produtos, prototipagem eletrônica, *motion planning* e *computer-aided manufacturing*. Todas essas aplicações requerem representações de formas de objetos físicos sólidos. É essa modelagem que dá subsídios para geração dessas representações bem como operações primitivas sobre elas.

A Modelagem Geométrica ou de Superfície, subárea da Modelagem de Sólidos, tradicionalmente identifica um conjunto de técnicas que pode modelar certas classes de *piecewise parametric surfaces* [3], sujeitas a condições particulares de forma e suavidade. Ela tem se desenvolvido como um campo a parte em várias indústrias, incluindo a automobilística, a aeroespacial e a de construção civil. Como a modelagem de sólidos empenha-se em envolver completamente a geometria dos objetos, há uma necessidade crescente de se pesquisar a geração, de maneira rápida e simplificada, das formas de superfícies e técnicas para sua manipulação.

Neste trabalho será investigado não só a modelagem de superfícies a partir de objetos geradores, mas também mecanismos para a manipulação dessas superfícies, criando interativamente novos objetos. Neste sentido utilizou-se o modelo neural proposto por Koho-

nen em [6]. O estudo da viabilidade dessa modelagem é realizada analisando a visualização do comportamento dessas redes durante seu processo de aprendizagem. Isto é feito devido à rede poder ser interpretada como um *wireframe* [2], grade de arame, da superfície de um sólido, onde cada um dos seus neurônios representa um ponto no espaço euclidiano¹.

Este trabalho é apresentado em quatro seções, onde esta é a primeira. Na segunda seção será exposto como é feita essa modelagem, fazendo considerações a respeito da adaptação da rede e visualização da superfície. São mostradas ainda, as razões do uso de Redes Neurais e especificamente dos Mapas de Kohonen² para essa modelagem. Na seção três, é feito um estudo de caso de alguns experimentos realizados. Esta análise aborda tanto o aspecto de convergência da rede quanto o visual. Na última seção tem-se as conclusões finais juntamente com os trabalhos futuros.

2 Modelagem usando Redes Neurais

Para se conseguir a modelagem de sólidos, foram utilizadas as Redes de Kohonen com vetores de peso tridimensionais, onde estes vetores são tratados como pontos. Isto é feito no intuito de usar a matriz de neurônios como um *wireframe* auto-adaptativo. Considerando a rede como uma grade de pontos será possível a visualização gráfica da mesma. Os padrões de treinamento da rede também são tratados como pontos, só que estes são originários da superfície de um objeto gerador. Durante o processo de treinamento, esses padrões são apresentados à rede, fazendo com que ela

¹Para uma maior clareza, neste trabalho utilizar-se-á o termo *ponto* significando *ponto no espaço euclidiano*.

²Os termos *Mapas de Kohonen* e *Redes de Kohonen* serão usados neste trabalho como sinônimos.

aproxime seus pesos às entradas, gerando, deste modo, uma superfície que representa os padrões de entrada nas suas estruturas internas.

2.1 Adaptação da Rede

A adaptação da rede é feita usando o algoritmo de aprendizagem proposto por Kohonen em [6], o qual usa um processo de aprendizagem não-supervisionado para gerar *clusters*³, a medida que os padrões vão sendo apresentados à rede. No início desse processo, a rede possui os vetores de peso aleatórios e normalizados com valores variando no intervalo $[-1, 1]$. Tal rede apresenta-se graficamente, neste estágio, como um emaranhado de linhas (Figura 1). No decorrer do processo, entretanto, a rede vai tomando a forma da superfície do sólido gerador através desse processo adaptativo.




Figura 1: Rede com Pesos Aleatórios

Esse algoritmo de aprendizagem usa o conceito de *Vizinhança Topológica* [6] que é uma fronteira dinâmica a qual define os nós que envolverão o *neurônio vencedor* e serão estimulados pelo padrão de entrada corrente. Este limite e a forma como ele é diminuído são particularmente responsáveis pela apresentação final da rede, pois eles permitem a formação e determinam a disposição dos clusters na rede, definindo a forma final da superfície. No início do processo de aprendizagem esse limite é grande chegando a conter a maioria dos neurônios da rede. A medida que o processo avança, entretanto, o raio da vizinhança decresce até conter apenas o neurônio vencedor.

Outro conceito usado no algoritmo de treinamento é o de *Neighborhood Kernel*, função definida sobre a grade de pontos que especifica a distribuição do estímulo sobre os neurônios da vizinhança topológica. Foi utilizado duas definições para essa função: *Borbulhamento* e *Gaussiana* [4]. No borbulhamento todos os neurônios da vizinhança topológica são estimulados igualmente. Já a outra definição, usa uma função gaussiana no cálculo do ajuste dos pesos. Assim os nós mais próximos do neurônio vencedor serão mais

estimulados que aqueles da periferia da vizinhança topológica.

Foi escolhida a forma de grade quadrada (Figura 2) para a disposição dos neurônios na rede, ou seja, cada neurônio está ligado graficamente aos seus quatro vizinhos imediatos, exceto os neurônios localizados nas bordas e nas quinas da rede os quais possuem três e dois vizinhos respectivamente. Embora cada neurônio possa ser conectado graficamente a no máximo quatro vizinhos, cada neurônio vencedor está virtualmente ligado e pode disparar todos aqueles que estão dentro de sua vizinhança topológica.




Figura 2: Grade Quadrada

2.2 Visualização da Superfície

A visualização da rede é realizada ligando todos os vetores de peso das linhas e os das colunas da matriz, isto é, conecta-se os vetores de peso dos neurônios de cada linha dois a dois, onde o primeiro é ligado ao segundo, o segundo ao terceiro e assim por diante até o último neurônio de cada linha. O mesmo procedimento é feito para conectar os vetores de peso das colunas, de modo que no final desse processo tem-se uma grade de pontos interconectados, representando uma superfície.

A visualização da rede tridimensional no monitor de vídeo é baseada nos mesmos princípios usados por pintores e designers. A diferença é que o computador usa um modelo matemático em vez da tela de pintura. Assim, para um maior realismo da imagem, foram usadas sobre os vetores de peso da rede as seguintes transformações geométricas tridimensionais: projeção, mudança de escala, rotação sobre os eixos cartesianos e translação de coordenadas.

2.3 Viabilidade do Modelo de Kohonen para Modelagem de Superfícies

As Redes Neurais foram escolhidas para dar suporte a modelagem de superfícies devido suas características intrínsecas de paralelismo e generalização. Pois com a capacidade de adaptação a novas situações

³Classes de padrões.

pode-se pensar na rede como um wireframe que se modifica a medida que os padrões vão sendo-lhe apresentados. Esta constante modificação gera uma superfície cujo conjunto de pontos converge para os padrões de treinamento. Já o paralelismo permite que essa convergência seja feita de modo muito rápido.

Optou-se pelas Redes de Kohonen para a implementação desta modelagem devido sua arquitetura apresentar uma matriz de neurônios. Quando se usa vetores de peso tridimensionais esta matriz se assemelha muito a um wireframe.

As características de auto-organização e mapas ordenados também foram levados em consideração nessa escolha: a primeira permite o surgimento de clusters na rede, criando regiões de concentração de pontos na superfície; já a segunda faz com que não haja mudanças abruptas na disposição dos pontos da superfície modelada, pois os clusters variam gradativamente pela rede, apresentando uma topologia mais ou menos ordenadas.

3 Resultados Obtidos

Os resultados obtidos neste trabalho foram originários tanto da análise de convergência da rede como da análise do aspecto visual do wireframe representado pela rede. No primeiro caso foram investigados os melhores valores dos parâmetros para um processo de treinamento eficiente. Já no segundo caso, o interesse maior estava no resultado gráfico final da rede. Embora estes dois aspectos estejam intimamente ligados, nesta seção, será dado as duas abordagens separadamente, fazendo as analogias entre elas a medida que se forem fazendo necessárias.

3.1 Análise da Convergência da Rede

Os parâmetros analisados nos experimentos foram: o raio inicial da vizinhança topológica, o número de apresentações de cada padrão e o número de neurônios da rede.

Na primeira série de experimentos foram utilizados, como conjunto de treinamento, 154 pontos uniformemente espaçados da superfície de um esfera de raio 30. Variou-se o raio inicial da vizinhança topológica e fixou-se o número de nós da rede em 1444 (matriz 38x38), a taxa de aprendizagem em 85% e o número de apresentação em 65, resultando em 10010 iterações.

A variação do Erro Médio em função do raio da vizinhança topológica, usando o processo de treinamento *borbulhamento*, é mostrado na Figura 3, onde cada curva do gráfico representa um experimento começando com um raio inicial indicado nas legendas.

Usando um raio inicial grande (diâmetro da rede) verificou-se que os neurônios passam algumas ite-




Figura 3: Variação do Erro Médio em Função do Raio da Vizinhança Topológica

rações oscilado entre os padrões de treinamento. Com o passar do tempo, no entanto, o raio diminui e os clusters vão sendo formados. No final do processo a rede apresentou um erro médio de 3.09, que é razoável haja vista o usado em [4] o qual fica em torno de 3.61.

O melhor erro médio encontrado, usando o *borbulhamento*, foi 0.066 com um raio inicial igual a 3 (10% do diâmetro da rede). Entretanto gerou-se clusters com baixo grau de generalização formados por apenas alguns neurônios. Além disso houve um grande número de nós não comprometidos, 111 *uncommitted neurons*, assim como uma desordenação dos clusters na rede. Neste momento a rede se apresentou muito facetada, assemelhando-se a um cristal, com uma concentração de pontos no seu centro representando os neurônios não comprometidos (Figura 4).




Figura 4: Rede com o Menor Erro Médio

Fez-se necessário a análise não só do erro médio mais também do grau de generalização dos clusters (concentração de pontos), do número de neuronios não comprometidos e a ordenação dos clusters na rede (sua-vidade da rede).

Fazendo-se essa análise mais completa, a rede que melhor se adaptou aos padrões de entrada foi usando o raio inicial igual a 15 (40% do diâmetro da rede). Neste experimento todos os neurônios foram comprometidos e a rede apresentou um erro médio de 1.79.

Usando o método *gaussiano* a melhor aproximação para a rede foi obtida usando o raio inicial igual a 5 (13% do diâmetro da rede). Neste experimento todos os neurônios foram comprometidos. Os clusters gerados, entretanto, não atingiram uma ordenação adequada, resultando em uma superfície muito acidentada. A Figura 5 mostra um gráfico do erro médio em função do número de interações para alguns experimentos empregando esse método. Em cada experimento foi usado o raio inicial indicado na legenda.

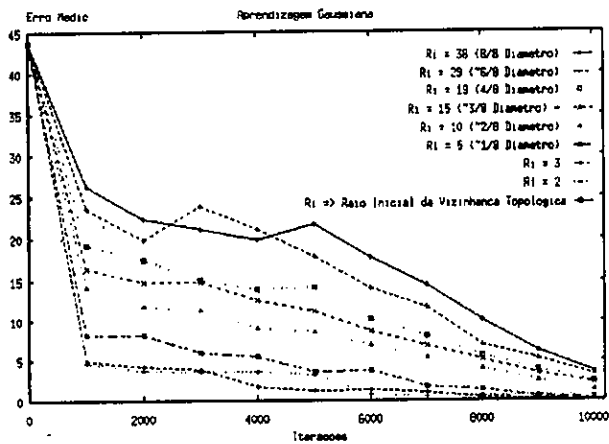


Figura 5: Variação do Erro Médio em Função do Tempo (Método *Gaussiano*)

Na segunda bateria de testes foram fixados o raio inicial em 19 (1/2 diâmetro da rede), a taxa de aprendizagem em 85%, o diâmetro da rede em 38 (matriz 38x38) e variou-se o número de apresentação de cada padrão à rede. O aumento do número de iterações, resultando em um acréscimo do número de iterações, fez com que o erro médio fosse diminuído cada vez mais. O melhoramento desse resultado, porém, está relacionado com o tempo que a rede leva para convergir e em alguns casos este tempo pode ser muito grande para pequenos aperfeiçoamentos.

Na figura 6 é mostrado o gráfico da variação do erro médio em função do tempo (iterações) usando o método *borbulhamento*. O número de apresentações é mostrado nas legendas.

Na última série de testes da convergência foi analisado a quantidade de neurônios da rede. Para isso, foram fixados o número de apresentação em 65, o raio inicial na metade do diâmetro da rede e taxa de adap-

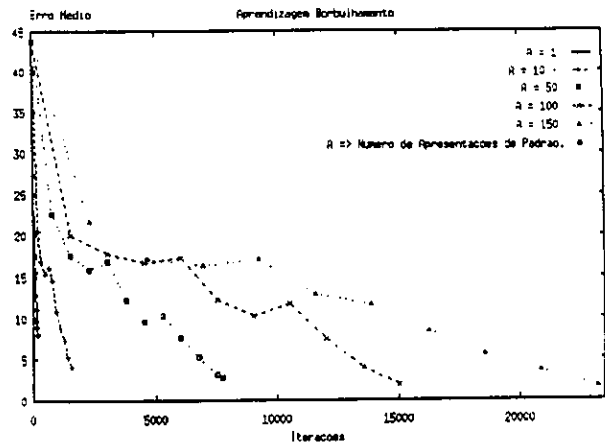


Figura 6: Variação do Erro Médio em Função do Tempo (Método *Borbulhamento*).

tação em 85%. A medida que aumentava-se o número de neurônios na rede o erro médio também era reduzido e os clusters eram melhor definidos gerando uma superfície menos acidentada. Não foi registrado o aparecimento de neurônios não comprometidos.

A figura 7 mostra o comportamento do erro médio final da rede em relação ao número de neurônios dos clusters, isto é, o número de total de neurônios dividido pela quantidade de padrões. O gráfico mostra duas curvas, uma usando o método *Borbulhamento* e outra o *Gaussiano*.




Figura 7: Variação do Erro Médio em Função do Número de Neurônios por Padrão.

A partir desses resultados, verificou-se que o método borbulhamento é eficiente na criação dos clusters, permitindo que a superfície gerada envolva a maioria dos padrões de entrada. O erro médio obtido usando

esse método é relativamente menor que o obtido pelo gaussiano fazendo com que os clusters sejam melhor distribuídos pela rede. Já o método gaussiano espalha mais os neurônios pelo cluster possibilitando uma suavidade na superfície gerada. Assim esses métodos devem ser combinados para, num primeiro instante, distribuir os clusters pela rede e depois ordenar os neurônios dentro de cada cluster (ver Figura 8).




Figura 8: Superfícies Geradas usando os Métodos *Borbulhamento* e *Gaussiano* a partir de uma Esfera.

3.2 Análise do Aspecto Visual da Rede

Esta análise foi feita observando o comportamento dos pesos da rede durante o treinamento. Foi usado como conjunto de treinamento os pontos da superfície de uma *esfera*, de um *cone*, pontos de uma superfície de revolução que se assemelha a um *cálice* e outra a um *chapéu* e pontos da superfície de um *tronco feminino*. Cada experimento foi realizado em duas fase, na primeira partiu-se de uma rede aléatoria e usou-se o método *borbulhamento* para criação dos clusters. Já na segunda fase, utilizou-se a rede obtida na primeira, aplicou-se o método *gaussiano* a fim de suavizar a superfície.

A tabela abaixo mostra os parâmetros usados na primeira fase da modelagem:

Método Borbulhamto					
Exp	Superf.	Rede	R_i	NA	Taxa
1	Esfera	38x38	19	50	90%
2	Cone	36x36	18	50	90%
3	Taça	38x38	19	50	90%
4	Chapéu	38x38	19	50	90%
5	Tronco	33x33	25	50	90%

Legendas: Exp = Experimento; Superf. = Superfície Geradora; Rede = Dimensão da Rede; R_i = Raio Inicial da Vizinhaça Topológica; NA = Número de Apresentação; Taxa = Taxa de Adaptação

A seguir é apresentada uma tabela⁴ com os parâmetros

⁴Usar as legendas da tabela anterior.

utilizados na segunda fase dos experimentos:

Método Gaussiano					
Exp	Superf.	Rede	R_i	NA	Taxa
1	Esfera	38x38	4	25	40%
2	Cone	36x36	3	25	30%
3	Taça	38x38	4	25	40%
4	Chapéu	38x38	4	25	40%
5	Tronco	33x33	5	25	40%

As figuras seguintes mostram a evolução da modelagem de superfície para os experimentos acima.

A Figura 9 mostra a evolução do experimento 1, onde tem-se a superfície geradora, a rede após o *borbulhamento* e a rede após o método *gaussiano*, respectivamente. Neste experimento foram usados 154 pontos da superfície da esfera como conjunto de padrões.




Figura 9: Exp. 1 - Superfície Geradora. Método *Borbulhamento* e Método *Gaussiano*.

Na Figura 10 são mostradas as superfícies obtidas a partir da superfície de um cone usando os dois métodos de treinamento. O conjunto de padrões de treinamento foi composto de 146 pontos.



Figura 10: Exp 2 - Superfície Geradora. Método *Borbulhamento* e Método *Gaussiano*.

No experimento 3 foi utilizado, como sólido gerador, uma superfície de revolução semelhante a uma taça. O conjunto de treinamento para esse experimento foi constituído por 160 pontos da superfície desse sólido. A Figura 11 apresenta o comportamento da rede durante esta experiência:

Já no experimento 4, foi gerado uma superfície que se aproxima dos pontos de um sólido de revolução




Figura 11: Exp 3 - Superfície Geradora, Método *Borbulhamento* e Método *Gaussiano*.

parecido com um chapéu. O conjunto de treinamento usado continha 61 pontos dessa superfície. A Figura 12 ilustra esse experimento.




Figura 12: Exp 4 - Superfície Geradora, Método *Borbulhamento* e Método *Gaussiano*.

O último experimento usou a escultura de um tronco feminino como superfície geradora. A Figura 13 mostra a evolução deste experimento. Pode-se perceber o aparecimento de 1 neurônio não comprometido na superfície.




Figura 13: Exp 5 - Superfície Geradora, Método *Borbulhamento* e Método *Gaussiano*.

Através desses experimentos pode-se verificar o resultado das aplicações dos métodos *Borbulhamento* e *Gaussiano* na modelagem de superfícies. Variando o número de apresentações, o número de neurônios e sobretudo o raio inicial da vizinhança topológica, pode-se conseguir diferentes graus de suavidade e distribuição de pontos.

4 Conclusões e Trabalhos Futuros

Este trabalho apresentou uma técnica para modelagem de superfície através de Redes Neurais Artificiais. A utilização do modelo neural proposto por Kohonen se mostrou bastante satisfatório, favorecendo a geração e adaptação de superfícies. Este pro-

cesso auto-adaptativo permitiu a manipulação dessas superfícies gerando novos objetos.

Foram apresentados métodos para distribuição de pontos pela superfície e para aumentar a sua suavidade. No primeiro caso usou-se o *borbulhamento* no processo de treinamento da rede. O controle da suavidade, no entanto, foi obtido utilizando uma *função gaussiana* no algoritmo de aprendizagem.

Uma vez conseguido a modelagem de superfícies, os trabalhos serão voltados para a modelagem de sólidos usando essa mesma abordagem. Isto será feito simulando o método interativo empregado pelo escultor, onde a cada ponto apresentado pelo designer, a rede será adaptada gerando novos objetos. Será usado técnicas de iluminação e texturização para um maior realismo dos sólidos obtidos.

Agradecimentos

Este trabalho contou com o suporte financeiro do CNPq e FACEPE e o apoio técnico do grupo de Redes Neurais dessa Universidade, em particular de Anne M. P. Canuto, Edward Roe e Marcílio C. P. de Souto. Agradecimento especial a Sílvia R. P. C. Melo e a Venusa S. Leitão.

Referências

- [1] Marc Berger. *Computer Graphics with Pascal*. The Benjamin/Cummings Publishing Company, Inc, University of Colorado, Colorado, 1986.
- [2] J. D. Foley and A. Van Dam. *Fundamentals of Interactive Computer Graphics*. Addison-Wesley Systems Programming Series. Addison-Wesley Publishing Company, July 1984.
- [3] Christoph M. Hoffman. *Geometric & Solid Modeling - an Introduction*. Morgan Kaufman Publishers, Inc., San Mateo, California, 1989.
- [4] Jari Kangas, Teuvo Kohonen, and Jorma Laaksonen. *SOM_PAK, The Self-Organizing Map Program Package - Version 1.2*. SOM Program Team of the Helsinki University of Technology, Finland, November 1992.
- [5] Teuvo Kohonen. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43:59-69, 1982.
- [6] Teuvo Kohonen. *Self-Organization and Associative Memory*, volume 8 of *Springer Series in Information Sciences*. Berlin - Heidelberg - New York. 3 edition, April 1984.
- [7] Yoh-Han Pao. *Adaptive Pattern Recognition and Neural Networks*. Addison-Wiley, 1989.