

CLÁUDIA APARECIDA CAVALHEIRO FRANCISCO

**REDE DE KOHONEN:
Uma ferramenta no estudo das relações tróficas entre espécies de peixes.**

Dissertação de Mestrado apresentada como requisito parcial à obtenção do grau de Mestre em Ciências. Programa de Pós-Graduação em Métodos Numéricos em Engenharia, área de concentração em Programação Matemática, Universidade Federal do Paraná.
Orientador: Prof^ª. Dra. Maria Teresinha Arns Steiner
Co-orientador: Prof^ª. Dra. Lúcia Valéria Ramos Arruda.

Curitiba

2004

TERMO DE APROVAÇÃO

CLÁUDIA APARECIDA CAVALHEIRO FRANCISCO

REDE DE KOHONEN:

Uma ferramenta no estudo das relações tróficas entre as espécies de peixes.

Dissertação aprovada como requisito parcial à obtenção do grau de Mestre em Ciências. Programa de Pós-Graduação em Métodos Numéricos em Engenharia, área de concentração em Programação Matemática, Universidade Federal do Paraná, pela seguinte banca examinadora:

Aprovada em

Maria Teresinha Arns Steiner, D.Eng.- Depto. de Matemática, UFPR

Lúcia Valéria Ramos Arruda, D.Eng. - CPGEI, CEFET-PR

Sérgio Scheer, D.Sc. – Centro de Estudos de Engenharia Civil, UFPR

Celso Carnieri, D.Eng. - PPGMNE, UFPR-PR

Dedico à minha família maravilhosa, que no início desta jornada tornou-se completa. Vocês confiaram e sabiam que eu seria capaz. Palavras não são suficientes para traduzir o sentimento de gratidão.

AGRADECIMENTOS

Como é difícil colocar no papel todos os sentimentos, lembranças e pessoas que colaboraram nas mais diferentes formas para a conclusão desta etapa tão importante de minha vida.

Primeiramente a Deus, e que ele me ajude a lembrar de todos...

Às minhas orientadoras, Maria Teresinha e Valéria que me proporcionaram vislumbrar e adquirir um novo conhecimento.

A todos os docentes do curso por compartilharem suas idéias, opiniões e permitirem sobretudo nosso crescimento nos mais diversos sentidos.

Aos meus amigos de turma, vocês foram sensacionais na solidariedade, na amizade e no companheirismo, tenho a certeza de que a amizade e as recordações estarão sempre em nossos corações.

Em especial a Lauri pela generosidade, Carlos e Daniel, que não demonstravam medo na estrada, tornando tudo mais prazeroso e as viagens menos cansativas. Além das horas de estudos em conjunto.

Aos amigos do Nupélia: Karla, você sabe que sem os dados nada disso seria possível. Professor Luiz Carlos pela idéia inicial do trabalho, enquanto eu persistia em conseguir os dados sobre o Reservatório do Irai. Professores Ângelo, Norma, Liliana e Rô pelos conhecimentos e idéias compartilhados. Aos alunos do PEA que ajudaram a entender o significado de palavras tão estranhas ao meu vocabulário (onívero, teleósteos, plâncton entre outras).

Às amigas de serviço, Aldenir e Thayana por segurarem a barra enquanto me ausentava para os estudos e por suportarem as crises de ansiedade.

À bibliotecária Salete, por revisar as referências e pela injeção de ânimo no momento decisivo.

E lembrando dos momentos decisivos, ao professor Penczak por lembrar que cavalos não possuem chifres.

Bem, à minha família já dediquei este trabalho e todo agradecimento a ser feito seria insuficiente. Arthur, você apoiou integralmente tudo, sua ajuda foi fundamental. Aos meus pais por proporcionarem as condições de meus estudos e desenvolvimento. Ao meu filho Gabriel por seu amor e saiba que o meu é incondicional e, que as ausências são simplesmente físicas pois nossa ligação é eterna e indelével. Ao meu irmão pelo orgulho mútuo e por vislumbrar oportunidades ainda inexploradas, com calma chegaremos lá.

E a todos meus amigos não citados, por participarem de minha vida. Ninguém vive ou constrói algo só.

SUMÁRIO

SUMÁRIO	5
LISTA DE FIGURAS	7
LISTA DE TABELAS	8
RESUMO	9
ABSTRACT	10
CAPÍTULO I	11
1 INTRODUÇÃO	11
1.1 APRESENTAÇÃO DO PROBLEMA.....	11
1.2 OBJETIVOS	12
1.3 IMPORTÂNCIA.....	12
1.4. ESTRUTURA.....	14
CAPÍTULO II	15
2 DESCRIÇÃO DO PROBLEMA	15
2.1 INTRODUÇÃO.....	15
2.2 ALGUMAS CONSIDERAÇÕES ECOLÓGICAS.....	16
2.3 ALIMENTAÇÃO DE PEIXES.....	16
2.4 PROPOSTAS PARA A CATEGORIZAÇÃO TRÓFICA DE PEIXES	17
2.4.1 CATEGORIAS TRÓFICAS EM PEIXES	19
2.4.2 CLASSIFICAÇÕES PROPOSTAS DE ACORDO COM O HÁBITO ALIMENTAR..	19
2.4.3 DESCRIÇÃO E CARACTERIZAÇÃO DE CADA CATEGORIA TRÓFICA.....	21
2.5 DISCUSSÃO E PROPOSTA.....	23
CAPÍTULO III	24
3 REDES NEURAIS: UMA VISÃO GERAL	24
3.1 INTRODUÇÃO.....	24
3.2 APLICAÇÕES NA ECOLOGIA	28
3.3 REDES COMPETITIVAS.....	32
3.4 REDES DE KOHONEN	35
3.4.1 PROCESSO COMPETITIVO	39
3.4.2 PROCESSO COOPERATIVO.....	41
3.4.3 PROCESSO ADAPTATIVO	44
3.4.3.1 Fase de ordenação ou auto-organização	47
3.4.3.2 Fase de convergência.....	48
3.4.4 ALGORITMO DE KOHONEN	50
3.4.5 PROPRIEDADES DO MAPA DE CARACTERÍSTICAS	51
3.5 REDES NEURAIS E CLASSIFICAÇÃO TRÓFICA	53
CAPÍTULO IV	55
4 COLETA E ANÁLISE EXPLORATÓRIA DOS DADOS DO PROBLEMA ABORDADO	55
4.1 INTRODUÇÃO.....	55
4.2 ANÁLISE EXPLORATÓRIA DE DADOS COM REDE DE KOHONEN	61
4.2.1 PRÉ-PROCESSAMENTO DOS DADOS	61
4.2.2 PARAMETRIZAÇÃO DA REDE	62

4.2.3 FERRAMENTAS COMPUTACIONAIS	63
CAPÍTULO V	64
5 OBTENÇÃO E ANÁLISE DOS RESULTADOS	64
5.1 INTRODUÇÃO	64
5.2 ANÁLISE DA FASE RIO	66
5.2 ANÁLISE DA FASE RESERVATÓRIO	80
5.3 DISCUSSÃO COMPARATIVA ENTRE AS FASES RIO E RESERVATÓRIO	91
CAPÍTULO VI.....	95
6 – CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS....	95
6.1 CONSIDERAÇÕES FINAIS.....	95
6.2 PROPOSTAS PARA TRABALHOS FUTUROS	98
REFERÊNCIAS	99
ANEXO I - EXEMPLO ILUSTRATIVO DO FUNCIONAMENTO DA REDE DE KOHONEN	104

LISTA DE FIGURAS

Figura 1 – Diferentes funções de vizinhança (Fonte: VESANTO et al., 2000b, p.10).	42
Figura 2 – Diferentes funções de taxa de aprendizagem (Fonte: VESANTO et al., 2000b, p.10).....	46
Figura 3 - Parâmetros topológicos de vizinhança e raio topológico.....	38
Figura 4 - Ilustração da relação entre o mapa de características Φ e o vetor de pesos \underline{w}_i o neurônio vencedor j (HAYKIN, 2001 p.495).....	52
Figura 5 - Localização da UHE Corumbá (Fonte Nupélia).....	56
Figura 6 - <i>U-matrix</i> com separação dos agrupamentos iniciais – fase rio.....	69
Figura 7- Dendrograma dos agrupamentos iniciais da fase rio.	70
Figura 8 - <i>U-matrix</i> e recursos alimentares – agrupamento inicial da fase rio.....	71
Figura 9 - Rótulos das células do agrupamento inicial – fase rio.....	72
Figura 10 - Rótulos das células do agrupamento inicial das espécies 2, 3, 4, 29 e 38 – fase rio.	73
Figura 11 - Apresentação do mapa com separação da contribuição de cada recurso alimentar.	74
Figura 12 - Identificação das espécies por agrupamento – fase rio.....	75
Figura 13 - <i>U-matrix</i> com separação dos agrupamentos da região A – fase rio.....	76
Figura 14 - <i>U-matrix</i> e recursos alimentares dos sub-agrupamentos – fase rio.	77
Figura 15 - Identificação das espécies dos sub-agrupamentos – fase rio.	78
Figura 16 - Apresentação do mapa com separação da contribuição de cada recurso alimentar.	78
Figura 17 – <i>U-matrix</i> com separação dos agrupamentos – fase reservatório.....	82
Figura 18 – Dendrograma dos agrupamentos iniciais da fase reservatório.	83
Figura 19 – <i>U-matrix</i> e recursos alimentares - fase reservatório.....	84
Figura 20 - Rótulos das células do agrupamento inicial das espécies 2, 4, 26, 27, 31, 38 e 42 – fase reservatório.....	85
Figura 21 – Apresentação do mapa com separação da contribuição de cada recurso alimentar.	86
Figura 22 – Identificação das espécies por agrupamento – fase reservatório.	86
Figura 23 – <i>U-matrix</i> com separação dos agrupamentos da região A- fase reservatório.....	88
Figura 24 – <i>U-matrix</i> e recursos alimentares dos subagrupamentos – fase reservatório.	89
Figura 25 – Identificação das espécies dos sub-agrupamentos – fase reservatório.....	89
Figura 26 – Apresentação do mapa com separação da contribuição de cada recurso alimentar.	90

LISTA DE TABELAS

Tabela 1 - Resumo comparativo entre as redes com função de base radial e de Kohonen.	28
Tabela 2 - Modelo da planilha de dados.....	58
Tabela 3 - Código, espécies de peixes e nome popular.	60
Tabela 4 Resumo treinamento <i>SOM</i> , fase rio.	68
Tabela 5 Agrupamento inicial da fase rio.....	75
Tabela 6 - Sub-agrupamentos da região A – insetívoro, fase rio.	79
Tabela 7 Classificação trófica das espécies de peixes no reservatório de Corumbá- fase rio..	79
Tabela 8 – Resumo treinamento <i>SOM</i> , fase reservatório.	81
Tabela 9 – Agrupamento inicial da fase reservatório.....	87
Tabela 10 – Sub-grupos da região A – insetívoro.....	90
Tabela 11 – Classificação trófica das espécies de peixes do reservatório de Corumbá –fase reservatório.	91

RESUMO

As redes neurais artificiais têm sido aplicadas com sucesso em diversos problemas de análise exploratória de dados multivariados relacionados à ecologia. Todavia, poucos são os trabalhos utilizando a rede de Kohonen (mapas auto-organizáveis) para classificação de padrões de dados ecológicos. A dificuldade encontra-se na obtenção de um conjunto adequado de dados para o treinamento e validação da rede. Para o desenvolvimento deste trabalho foram utilizados dados obtidos no projeto “Estudos ictiológicos na área de influência do AHE Corumbá” pelo Núcleo de Pesquisas em Limnologia, Ictiologia e Aqüicultura (Nupélia), Universidade Estadual de Maringá (UEM) em convênio com FURNAS Centrais Elétricas S.A. Este trabalho utiliza a rede de Kohonen como uma metodologia para a classificação das espécies de peixes em categorias tróficas do reservatório de Corumbá – GO, de acordo com a dieta, envolvendo duas fases distintas: fase rio (anterior ao represamento), com a classificação de 1845 estômagos de 33 espécies de peixes, e a fase reservatório (posterior ao represamento), com a classificação de 5492 estômagos de 36 espécies de peixes. As classificações foram obtidas nas duas fases distintamente, resultando em ambas, em uma separação de dois grandes grupos: o dos generalistas e o dos especialistas. Os peixes especialistas foram divididos em quatro grupos: insetívoros, herbívoros, piscívoros e detritívoros. Os insetívoros apresentaram um grande número de espécies, sendo necessário modelar uma nova rede, visando a separação desta categoria, em quatro sub-grupos. A rede de Kohonen mostrou-se uma ferramenta robusta para a classificação dos dados, apresentando resultados rápidos, com uma clara visualização dos agrupamentos, facilitando sobremaneira a interpretação dos resultados.

Palavras-chave: Rede Neural Artificial; Redes de Kohonen; peixes e categorias tróficas.

ABSTRACT

Artificial neural network has been successfully applied in several problems of exploratory analysis of multivariate data related to ecology. However, there are few works using the Kohonen Map (Self-Organizing Map - *SOM*) for identification of patterns in ecological data. The difficulty is to obtain an appropriate set of data for training and validation of the net. For the development of this work, data used were obtained in the project “Estudos ictiológicos na area de influência do AHE Corumbá” by the Núcleo de Pesquisas em Limnologia, Ictiologia e Aqüicultura (Nupélia), Universidade Estadual de Maringá (UEM) in agreement with FURNAS Centrais Elétricas S.A. The Kohonen Map was used as a methodology for classification of trophic categories of fish from Corumbá Reservoir – GO. According to their diet, in two different phases: river phase (previous to impoundment), with analysis of 1845 stomachs belonging to 33 species of fish, and the reservoir phase (subsequent to impoundment), with analysis of 5492 stomachs belonging to 36 species of fish. The classifications into trophic categories allowed the separation of two big groups: one of generalists and another of specialists. Specialist fish were divided in four trophic groups: insetivores, herbivores, piscivores and detritivores. Insetivores presented great number of species, which demanded to model a new net, seeking the separation of this category, in four sub-groups. The Kohonen Map was shown to be robust tool for classification of the data, presenting fast results, with a clear visualization of the groupings, facilitating interpretation of the results.

Word-key: Artificial Neural Network; *SOM*; fish and trophic categories.

CAPÍTULO I

1 INTRODUÇÃO

1.1 APRESENTAÇÃO DO PROBLEMA

Este trabalho apresenta um modelo de redes neurais como ferramenta para a identificação da estrutura trófica de peixes no reservatório de Corumbá, Estado de Goiás (bacia do rio Paranaíba). Para o estudo, foi analisado o espectro alimentar das espécies de peixes presentes em amostras obtidas em rios, ribeirões e riachos, influenciados em graus variados pelo represamento da Usina Hidrelétrica de Corumbá (UHE), localizada no Estado de Goiás, durante o período de março de 1996 a fevereiro de 1999. Foram analisados de forma distinta dois períodos: anterior ao represamento (fase rio) de março de 1996 a agosto de 1996 e posterior ao represamento (fase reservatório) março de 1997 a fevereiro de 1999. Para análise da dieta, foram utilizados os volumes dos itens alimentares encontrados nos estômagos dos peixes e redes neurais competitivas, mais especificamente as redes de Kohonen, para formação dos agrupamentos das categorias tróficas. Entende-se por categorias tróficas, grupos de peixes que fazem uso do mesmo recurso alimentar.

As redes de Kohonen, também conhecidos como mapas auto-organizáveis (*SOM*) estão baseados na aprendizagem competitiva. Segundo HAYKIN (2001), um mapa auto-organizável é “caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais dos neurônios na grade são indicativas das características estatísticas intrínsecas contidas nos padrões de entrada”, ou seja, o mapa é capaz de realizar os

agrupamentos dos padrões através das características das variáveis de entrada. O modelo a ser utilizado é um mapa auto-organizável (*SOM – Self-Organizing Maps*) proposto por Kohonen (FAUSETT, 1994, p.169)

1.2 OBJETIVOS

O objetivo principal deste trabalho é separar, com o uso de um método baseado em redes neurais, através da aplicação de um *SOM*, as espécies de peixes em agrupamentos para classificação das categorias tróficas. A classificação das categorias tróficas será realizada em dois períodos distintos: fase rio e fase reservatório, visando identificar possíveis alterações na dieta das espécies e conseqüentemente nas relações tróficas dos agrupamentos encontrados, após o represamento do rio.

1.3 IMPORTÂNCIA

Com o represamento de rios, acontecem alterações na estrutura das comunidades de peixes, com a proliferação de espécies sedentárias e a redução ou mesmo a eliminação de espécies migratórias. Desta forma, ocorre uma substituição de espécies de maior interesse econômico (migradoras) por aquelas que possuem menor aceitação no mercado consumidor (lênticas) (UNIVERSIDADE ESTADUAL DE MARINGÁ. Nupélia/Furnas, 1997).

Com o represamento acontece também um aumento da biomassa terrestre que será incorporada ao reservatório (grama, árvores, folhagens etc), o que altera drasticamente o ambiente e interfere nas condições de vida, principalmente alimentação, das assembléias de peixes. Ocorre uma redução da quantidade de oxigênio no fundo do reservatório, em virtude das grandes profundidades, recolonização do ambiente e pela elevação da carga de nutrientes, ocasionado pela decomposição de folhedos, gramíneas e liberação de nutrientes do solo.

Existe ainda a mudança do fluxo do rio, que era horizontal e passa a ser vertical. Tudo isso provoca alterações nos hábitos dos peixes em busca de oxigênio e alimentação. Os peixes procuram a superfície do reservatório e as margens, que contém uma quantidade maior de oxigênio, mesmo assim, acontece uma grande mortandade neste período.

No Brasil não existem lagos, portanto, o país não possui espécies lacustres, que seriam indicadas como bem adaptadas aos reservatórios. Em muitos reservatórios têm sido introduzidas espécies exóticas. Porém, segundo a opinião do professor Dr. Ângelo Antonio Agostinho da Universidade Estadual de Maringá (informação verbal), a introdução de espécies normalmente é um erro, e vários estudos devem ser feitos antes que qualquer medida seja adotada. Cada reservatório é único, não sendo possível extrapolar as informações para todos.

O conhecimento acerca das assembléias de peixes fornece embasamento também sobre condições dos ecossistemas aquáticos, ou seja, são excelentes bioindicadores fornecendo, assim, informações sobre a qualidade da água (AGUILAR IBARRA et al., 2003).

Quanto maior for o conjunto de informações acerca das relações existentes no ambiente, mais adequadas serão as medidas de manejo a serem adotadas, visando uma melhor conservação e um melhor controle, beneficiando não somente o meio ambiente, mas também a população que tira seu sustento dele.

As relações entre assembléias de peixes e o meio ambiente são extremamente complexas e fornecem dados não-lineares, o que representa uma grande dificuldade para os pesquisadores na interpretação desses tipos de dados.

Os métodos estatísticos normalmente utilizados reduzem, de certa forma, os dados (variáveis), o que conduz freqüentemente a uma perda de informações valiosas e realidade ecológica, além de não levarem em consideração a complexidade dos dados e a não-

linearidade. As redes neurais têm se mostrado eficientes para trabalhar com conjuntos de dados não-lineares (LEK et al., 1995; RECKNAGEL et al., 1997b.).

1.4. ESTRUTURA

Uma descrição do problema é apresentada no segundo capítulo, enfatizando alguns conceitos ecológicos e um levantamento bibliográfico sobre alimentação de peixes e algumas classificações das categorias tróficas. O terceiro capítulo traz um breve estudo sobre redes neurais e, mais detalhadamente sobre a rede de Kohonen (*SOM*), que será utilizada no estudo, assim como algumas citações de aplicações na área biológica, relacionadas à ecologia.

A descrição sobre a coleta e a análise exploratória dos dados com rede de Kohonen são apresentadas no quarto capítulo. Os resultados obtidos nos agrupamentos das categorias tróficas das espécies de peixes do Reservatório da UHE Corumbá, envolvendo distintamente as duas fases do reservatório são apresentados no quinto capítulo.

Na seqüência, no sexto capítulo, são apresentadas as conclusões deste estudo e idéias para futuros trabalhos, tendo em vista que é um ramo quase inexplorado no Brasil.

CAPÍTULO II

2 DESCRIÇÃO DO PROBLEMA

2.1 INTRODUÇÃO

A organização dos ecossistemas aquáticos ocorre através de categorias, níveis ou guildas tróficas. Cada nível abrange organismos que ingerem recursos alimentares similares, resultando na transferência de energia (GERKING, 1994). De modo geral, é muito difícil classificar os peixes em categorias tróficas, saber onde começa e onde termina uma determinada categoria, pois geralmente os peixes apresentam amplo espectro alimentar.

A proposta deste trabalho é a utilização de um modelo de redes neurais competitivas, conhecida como Rede de Kohonen ou Mapas Auto-Organizáveis de Kohonen (*SOM*) para realizar os agrupamentos das espécies de peixes, coletadas em rios, ribeirões e riachos, de acordo com a dieta, influenciados pelo represamento da UHE Corumbá, durante o período de março de 1996 a fevereiro de 1999. Dessa forma as espécies de peixes serão classificadas em categorias tróficas, em dois períodos distintos (fase rio e fase reservatório), buscando informações sobre alterações na composição da ictiofauna.

As amostras foram separadas, analisadas e organizadas por pesquisadores do projeto “Estudos ictiológicos na área de influência do Aproveitamento Hidrelétrico (AHE) Corumbá” do Núcleo de Pesquisas em Limnologia, Ictiologia e Aqüicultura (Nupélia), da Universidade Estadual de Maringá (UEM), sendo que as observações resultantes destes estudos estão

disponíveis em dois relatórios (parcial e final), na Biblioteca Setorial do Nupélia, UEM, Maringá.

2.2 ALGUMAS CONSIDERAÇÕES ECOLÓGICAS

Visando uma melhor compreensão do trabalho, alguns conceitos e definições ecológicas são apresentados a seguir.

O conceito essencial é o de teia alimentar, que é o conjunto das relações tróficas que ocorrem entre os seres vivos que compõem um ecossistema, mediante os quais a energia de um nível é transferida a outro (ODUM, 1985). KREBS (1989) relata que a melhor abordagem é usar a teia alimentar, subdividindo cada nível trófico em categorias tróficas, que são grupos de espécies que exploram uma base de recursos comum, de maneira similar.

O conhecimento das relações tróficas, ou seja, as relações de alimentação e fluxo de energia existentes entre as espécies de peixes, é de grande importância para a construção de teias alimentares que, por sua vez, segundo Winemiller e Jepsen (1998), fornecem o embasamento para trabalhos de manejo e conservação de ecossistemas. Trabalho este, dependente também de um conhecimento amplo do ambiente, incluindo os fatores biológicos, ambientais, sócioeconômicos e políticos.

2.3 ALIMENTAÇÃO DE PEIXES

As informações fornecidas pela dieta dos peixes de uma comunidade e pela abundância específica dos alimentos existentes são primordiais para: a identificação das diferentes categorias tróficas; avaliar o grau de importância dos distintos níveis tróficos e entender as inter-relações entre os componentes da referida comunidade (AGOSTINHO et al., 1997b).

Um complicador para a compreensão das inter-relações e categorização das estruturas tróficas é a capacidade que algumas espécies de peixes fluviais possuem, de poder utilizar-se de diversos alimentos distintos, variando suas dietas conforme a ocasião e a disponibilidade (LOWE-McCONNELL, 1999). Este fato é agravado quando ocorrem distúrbios ambientais como é o caso da formação de reservatórios, que devido a incorporação de grande quantidade de biomassa terrestre, provoca alterações na disponibilidade do alimento. O leito dos rios se estende em terras anteriormente ocupadas por florestas, plantações, criação de animais etc., tornando as relações tróficas ainda mais complexas, devido a incorporação de novos recursos alimentares.

Assim, se um determinado alimento estiver disponível todo o tempo, maiores serão as possibilidades do peixe se especializar naquele determinado alimento e, por outro lado, se a disponibilidade de alimentos for diversa no decorrer do tempo, os peixes tendem a tornarem-se oportunistas, ou seja, mudam sua dieta conforme a disponibilidade de alimento no ambiente.

2.4 PROPOSTAS PARA A CATEGORIZAÇÃO TRÓFICA DE PEIXES

Existem várias classificações propostas para organizar os peixes em categorias tróficas, pois estes diferem muito no caráter do alimento consumido, sendo mais diversificado que qualquer outro grupo de vertebrados. NIKOLSKY (1978) propôs a seguinte classificação, baseado na diversidade dos alimentos consumidos: (1) eurifágicos: são espécies que apresentam uma dieta ampla (comem de tudo), (2) estenofágicos: são espécies que se alimentam de poucos itens alimentares e (3) monofágicos: são espécies que consomem somente um tipo de alimento. Esta classificação não pode ser considerada adequada aos peixes tropicais, pois poucas espécies se enquadram na categoria de monofágicas.

Quanto a estratégia alimentar, pode-se adotar termos como: generalistas, especialistas e oportunistas. GERKING (1994) descreve os generalistas como espécies que possuem um amplo espectro alimentar, não apresentando preferência por uma fonte alimentar em particular, apresentando portanto, alta flexibilidade trófica. Os especialistas seriam aquelas espécies cuja dieta é limitada a um pequeno número de espécies-presa. Entretanto, um especialista pode se tornar um generalista quando suas fontes de alimento se tornarem escassas. O autor alerta que os termos especialista e generalista têm vários significados para diferentes pesquisadores e que devem ser utilizados com cautela. Os oportunistas por outro lado, apresentam flexibilidade alimentar, sem especialização a nenhum alimento em particular, sendo capazes de aproveitar qualquer recurso alimentar que se torne momentaneamente disponível no ambiente. A maioria dos peixes oportunistas possuem hábito alimentar onívoro, alimentando-se de vegetais, insetos, organismos bentônicos e peixes.

Os peixes podem ocupar todos os níveis tróficos do ecossistema aquático, explorando todos os tipos de alimentos (desde algas até vegetais superiores e desde microorganismos até peixes, além de detritos). Mas, um comedor de detritos pode consumir algas e alguns organismos bentônicos, mas raramente peixes. Por outro lado, um piscívoro, devido a seu comportamento alimentar, com características estruturais e fisiologia digestiva particulares, não consegue digerir e assimilar detritos (WOOTTON, 1990). Isto demonstra que algumas espécies têm restrições alimentares, mesmo quando alguns recursos são abundantes e amplamente distribuídos no ambiente.

Os peixes podem também mudar de categoria trófica dependendo da fase de desenvolvimento em que se encontra ou durante as estações do ano e muitas dessas mudanças podem ser ocasionadas por fatores abióticos e bióticos (GERKING, 1994; HAHN et al., 1998).

2.4.1 CATEGORIAS TRÓFICAS EM PEIXES

Uma categoria trófica (também conhecida por grupo trófico ou guilda trófica) organiza os peixes dentro de grupos funcionais, baseando-se no hábito e comportamento alimentar (GERKING, 1994). Para a classificação em categorias tróficas das espécies de peixes de ambientes tropicais, que exibem uma grande flexibilidade alimentar, AGOSTINHO et al. (1997b) relatam ser conveniente classificá-los de acordo com o alimento predominante na dieta.

Normalmente, para a classificação das espécies em categorias tróficas são utilizados índices, baseando-se nas informações obtidas através da análise dos conteúdos estomacais e na avaliação qualitativa e quantitativa do alimento, através de métodos convencionais (ocorrência, número e volume/peso dos itens alimentares). Dentre estes índices pode-se citar: Índice Alimentar de KAWAKAMI e VAZZOLER (1980) que reúne os percentuais da ocorrência e volume/peso dos itens alimentares e o Índice de Importância Relativa de PINKAS et al. (1971), que agrupa os percentuais de ocorrência, volume/peso e número dos itens das dietas. Ambos fornecem um valor único que permite visualizar os principais alimentos consumidos.

2.4.2 CLASSIFICAÇÕES PROPOSTAS DE ACORDO COM O HÁBITO ALIMENTAR

MATTHES (1964, apud WELCOMME, 1979) propôs as seguintes categorias para peixes de ambientes tropicais:

- Comedores de lodo – se alimentam de sedimento finamente particulado, microorganismos e matéria orgânica.
- Comedores de detrito – ingerem principalmente detrito vegetal e detrito pouco particulado, associados a restos de invertebrados.

- Onívoros – consomem vegetal e animal, desde invertebrados até peixes.
- Herbívoros – podem ser separadas em microherbívoras - ingerem algas e macroherbívoros - ingerem vegetais superiores e macrófitas.
- Comedores de plâncton - ingerem fitoplâncton e zooplâncton, por filtração.
- Carnívoros – podem ser separadas em mesopredadoras - ingerem insetos e crustáceos. e macropredadoras - ingerem peixes e grandes invertebrados.

MARLIER (1967) propôs as seguintes categorias para peixes amazônicos:

- Estenofágicos – espécies que se alimentam de poucos itens alimentares. Podem ser divididas em:
 - 1 Carnívoros (ingerem peixes, insetos, zooplâncton).
 - 2 Herbívoros (fitoplâncton, algas, restos de vegetais, sementes, frutos).
 - 3 Comedoras de lodo.
- Eurifágicos – espécies que se alimentam de muitos itens alimentares:
 - 1 Predominantemente carnívoros.
 - 2 Predominantemente herbívoros.

KEENLEYSIDE (1979) sugeriu uma classificação para peixes teleósteos (que possuem ossos), para ambientes temperados que, por não serem alvo deste trabalho, serão apenas citados:

- Dentritívoros.
- Necrófagos.
- Herbívoros.
- Carnívoros.

- 1 Bentônicos:
 - a Abocanham presas relativamente pequenas.
 - b Revolvem o sedimento e abocanham a presa.
 - c Abocanham o sedimento e selecionam a presa.
 - d Capturam presas relativamente grandes.
 - 2 Zooplancctívoros:
 - a Filtram o alimento.
 - b Comedoras de partículas.
 - 3 Comedores aéreas.
- Piscívoros:
 - a Emboscadores.
 - b Atraem a presa.
 - c Espreitadores.
 - d Perseguidores.
 - e Ectoparasitas (incluindo comedores de escamas e nadadeiras).

2.4.3 DESCRIÇÃO E CARACTERIZAÇÃO DE CADA CATEGORIA TRÓFICA

Através da análise dos conteúdos estomacais, pode-se obter a composição da dieta dos peixes e assim classificá-los em categorias tróficas. Normalmente, são utilizados para esta classificação, o item ou recurso alimentar predominante nestes conteúdos.

A seguir são apresentadas as classificações das espécies de peixes, de acordo com o item ou recurso alimentar consumido.

- 1 Dentrítívoros ou iliófagos: peixes que se alimentam de itens obtidos em depósitos de fundo, ingerindo matéria orgânica e fragmentos de invertebrados (AGOSTINHO et al., 1997; HAHN et al., 1998). Detrito é a matéria orgânica morta em vários estágios de

decomposição que se acumula no fundo de corpos d'água, sendo uma mistura complexa de fragmentos de plantas e animais que foram reduzidos química ou fisicamente a partículas, por uma variedade de organismos (KEENLEYSIDE, 1979).

- 2 Herbívoros: peixes que se alimentam de vegetais superiores como folhas, sementes e frutos de plantas aquáticas e terrestres, além de algas filamentosas (AGOSTINHO et al., 1997b; HAHN et al., 1998).
- 3 Planctófagos: peixes que se alimentam do plâncton, fitoplâncton ou zooplâncton.¹
- 4 Insetívoros (aquática e terrestre): os peixes se alimentam de insetos aquáticos e terrestres em diferentes fases de desenvolvimento (AGOSTINHO et al., 1997b; HAHN et al., 1998).
- 5 Piscívoros: os peixes que se alimentam predominantemente de outros peixes, incluindo espécies forrageiras e formas jovens, mas também podem completar sua dieta com insetos e crustáceos (AGOSTINHO et al., 1997b; HAHN et al., 1998). Podem ainda, dentro dessa categoria apresentar especializações nos hábitos alimentares, sendo então classificados como: lepidófagos – hábito de consumir escamas; hematófagos – se alimentam de sangue das brânquias. Nesse caso, todos ocupam o topo da hierarquia trófica (GERKING, 1994).
- 6 Onívoros – apresentam um espectro alimentar amplo, sem predomínio evidente de qualquer recurso em particular, utilizando alimentos de origem animal e vegetal em partes equilibradas (AGOSTINHO et al., 1997b; HAHN et al., 1998). Podem ser classificados como onívoros com tendência à herbivoria ou à carnivoria.

¹ Plâncton é constituído por pequenos animais e plantas que não possuem movimentos próprios capazes de se opor aos movimentos da água, é composto pelo fitoplâncton (parte vegetal), zooplâncton (pequenos animais) e bacterioplâncton (ESTEVEZ, 1988)

2.5 DISCUSSÃO E PROPOSTA

Diante do exposto, observa-se que as classificações tróficas variam e possuem grandes especificidades de acordo com o ambiente. Este trabalho apresenta o estudo de uma região fortemente impactada, buscando identificar as categorias tróficas e as alterações nos hábitos alimentares dos peixes, comparando as duas fases: anterior e posterior ao represamento, obtendo assim, um maior conhecimento acerca das assembléias de peixes e os impactos produzidos pelo represamento. Além de propor o uso de uma nova ferramenta para este tipo de classificação.

A proposta da utilização de *SOM* para a classificação trófica justifica-se pelo fato dos peixes analisados ingerirem diversos recursos alimentares disponíveis, não sendo possível a priori, uma identificação do recurso alimentar predominante.

CAPÍTULO III

3 REDES NEURAIIS: uma visão geral

3.1 INTRODUÇÃO

O ser humano apresenta diversas habilidades e a maioria delas foi adquirida a partir de observações de exemplos, que sofreram adaptações no cérebro através de funções específicas. Inspirados nestes conceitos, pesquisadores desenvolveram as Redes Neurais Artificiais, visando adaptar algumas atividades do cérebro humano para os computadores. Deve-se levar em consideração que o cérebro humano processa informações de uma forma inteiramente diferente de um computador. O cérebro é complexo, não linear e paralelo e consegue realizar atividades com muito mais rapidez que qualquer computador e a rede neural pode ser considerada uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular (HAYKIN, 2001).

As Redes Neurais Artificiais são algoritmos que podem ser programados em diversas linguagens. Trata-se de um modelo matemático com diversos parâmetros ajustáveis, os quais são modificados de acordo com um conjunto de dados que contém informações sobre o comportamento que esta rede deve apresentar (FAUSETT, 1994).

Segundo HAYKIN (2001), uma rede neural se assemelha ao cérebro em dois aspectos: “1) o conhecimento adquirido pela rede, a partir de seu ambiente, através de um processo de aprendizagem” e “2) forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido”. Para que uma rede

neural “aprenda” é empregado um algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo desejado. Existem diversas maneiras de se configurar uma rede neural, alterando suas topologias, aumentando assim sua eficiência e fazendo com que ela forneça os resultados desejados.

A base de uma rede neural é formada pelos neurônios artificiais que são unidades de processamento de informação. A maneira como os neurônios estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Existem duas grandes classes de arquiteturas de rede (a forma como os neurônios estão dispostos):

- i Redes alimentadas adiante com camada única, ou seja, uma camada formada pelos neurônios de entrada se projeta sobre uma camada de saída, mas não vice-versa.
- ii Redes alimentadas diretamente com múltiplas camadas, redes competitivas ou recorrentes, onde a camada de entrada projeta-se sobre a camada de saída (ou camadas intermediárias) e vice-versa, incluindo em certos casos de rede a realimentação, onde pode ocorrer uma situação onde a saída de um neurônio é alimentada para a sua própria entrada.

A principal propriedade de uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar seu desempenho através da aprendizagem. Para isto ocorrem iterações no seu processo de aprendizagem. HAYKIN (2001) apresenta cinco regras básicas de aprendizagem:

- i por correção de erro;
- ii baseada em memória;
- iii Hebbiana;
- iv Competitiva;
- v de Boltzmann.

O princípio de aprendizado de Hebb, um biólogo, foi inspirado nos neurônios biológicos. Hebb constatou que quando um impulso passa pela célula nervosa, facilita a passagem dos próximos impulsos. O princípio de Hebb foi a primeira regra de aprendizado (anterior a idéia de treinamento) de uma rede neural, afirmando que se dois neurônios em cada lado de uma sinapse (conexão) são ativados simultaneamente, então os pesos daquela conexão devem ser aumentados. Portanto, a cada apresentação do padrão, a saída fica mais reforçada. A maioria das regras de aprendizagem derivam da regra de Hebb (FAUSETT, 1994).

O processo de aprendizagem pode ocorrer de duas formas: supervisionada e não-supervisionada. Na aprendizagem supervisionada, a rede recebe a resposta desejada para um determinado vetor de treinamento, e tem seus pesos sinápticos alterados de acordo com o erro cometido no processo. Na aprendizagem não-supervisionada não existem exemplos rotulados na função a ser aprendida pela rede, a rede desenvolve a habilidade de formar representações internas para codificar as características da entrada e desse modo, criar automaticamente novas classes.

A escolha de um determinado algoritmo de aprendizagem está intimamente relacionada com a tarefa que a rede deverá realizar. Existem dezenas de modelos de redes neurais, sendo que os mais conhecidos são:

- Rede Neural de McCulloch-Pitts – representa o neurônio como uma unidade de limite binário que pode executar operações lógicas básicas (*and* e *or*), por meio do ajuste adequado dos pesos.
- *Perceptron* de Múltiplas Camadas – realiza operações lógicas complexas, reconhecimento, classificação de padrões, controle de robôs e processamento de fala.

- Rede de Hopfield - utilizada para reconhecimento de imagens, otimização de problemas e simulação, controle.
- ART (*Adaptative Resonance Theory*) de Grossberg – possui uma habilidade de se adaptar diante de novas entradas e é utilizada para reconhecimento de sinais de radar e processamento de imagens.
- CNM (*Combinatorial Neural Model*) – utilizada no processamento de reconhecimento, análise e classificação de dados.
- RBF (*Radial Basis Function*) – são as redes com função de base radial, utilizada para pedição não-linear de séries temporais e para realização de agrupamentos (FAUSETT, 1994).
- SOM (*Self-Organizing Map*) de Kohonen – utilizada para agrupamento de padrões, otimização de problemas e simulações, capturando as características importantes contidas em espaço de entrada multidimensional e desta forma, representá-lo num espaço bidimensional (HAYKIN, 2001).

O objeto deste estudo foi a utilização de uma rede neural competitiva e não supervisionada, para ordenar, classificar e realizar agrupamentos das espécies de peixes conforme seu hábito alimentar. A Rede de Kohonen (Mapa de Kohonen, ou ainda, SOM – Mapas Auto-Organizáveis) apresenta um algoritmo de fácil implementação e realiza uma projeção não-linear dos dados multivariados num espaço bidimensional, sendo indicada para solucionar o problema proposto.

De forma ilustrativa, é apresentada na tabela 1 um resumo comparativo entre a rede com função de base radial (RBF) e a rede de Kohonen.

Tabela 1 - Resumo comparativo entre as redes com função de base radial e de Kohonen.

	RBF	Kohonen
Aprendizagem	supervisionada	não-supervisionada (competitiva)
Maior aplicabilidade ecológica	predição de séries temporais (dados não-lineares) e agrupamento de padrões	agrupamento de padrões
Conexões	camada de saída é conectada com a última camada escondida.	camada de entrada é conectada diretamente com a camada de saída.
Etapas de treinamento	treinamento híbrido: 1º -técnicas não supervisionadas (nas camadas intermediárias) 2º -métodos lineares supervisionados (última camada)	1º - fase de agrupamento (em determinado número de épocas iniciais) 2º - fase de convergência (em determinado número de épocas finais)

3.2 APLICAÇÕES NA ECOLOGIA

Existem diversos artigos científicos internacionais publicados a partir da segunda metade da década de 90, que relatam a utilização de redes neurais na grande área de ciências biológicas, mais especificamente na área de ecologia, no qual este trabalho está focado. A grande maioria deles utilizam redes neurais artificiais como modelo válido para predição e reconhecimento de padrões.

Dentre os trabalhos sobre predição, destacam-se os artigos relacionados a predição de “*bloom*” (floração) de algas (YABUNAKA et al., 1997; RECKNAGEL, 1997a; RECKNAGEL et al., 1997b; WHITEHEAD et al., 1997; MAIER e DANDY, 1997; MAIER et al., 1998; WALTER et al., 2001; LEE et al., 2003;). Dentre estes estudos tem-se que a maioria trata das cianobactérias, pois no período que ocorre o “*bloom*” há liberação de grandes quantidades de toxinas que são prejudiciais aos organismos dependentes do mesmo ambiente, inclusive o ser humano. Como exemplo, pode-se citar o florescimento de algas num reservatório para abastecimento de água, como no Reservatório de Iraí, que abastece a grande

região metropolitana de Curitiba, ou em alguma parte do litoral voltada ao turismo, provocando alergias aos banhistas, como ocorrido no litoral do Estado das Alagoas no início de 2004, noticiado em vários jornais. Este fenômeno é extremamente prejudicial mesmo quando a água não tem como destino o consumo, pois a abundância de plantas aquáticas, por exemplo, em uma represa para geração de energia, provoca problemas na captação das águas, no funcionamento das turbinas e ocasionando sérios danos e prejuízos (MARCONDES et al., 2003).

A grande maioria desses trabalhos utiliza o modelo de redes neurais de múltiplas camadas do tipo *feed-forward* com algoritmo baseado na retropropagação do erro. O que diferencia um trabalho do outro são as regiões pesquisadas e as variáveis de entrada e saída (predição).

YABUNAKA et al. (1997) utilizaram dez variáveis ambientais de entrada (neurônios de *input*) e cinco variáveis de saída (neurônios de *output*), dentre elas, as espécies de algas. Os autores concluíram que os resultados foram bons para uma predição da biomassa de algas, mas não é satisfatório para a predição das espécies de algas.

Uma preocupação por parte dos pesquisadores em relação às redes neurais é a “falta” de poder explicativo do modelo, considerado como uma “caixa preta”, porque não fornecem informações explicativas da influência das variáveis independentes no processo de predição. A interpretação dos modelos é necessária para que os pesquisadores possam adquirir conhecimentos das relações causais dos fenômenos estudados. O artigo de OLDEN e JACKSON (2002) retrata esta preocupação e apresenta estudos para o entendimento do funcionamento das redes neurais, concluindo que elas possuem fortes habilidades de predição e prometem ser uma valiosa ferramenta quantitativa para avaliar, entender e prever fenômenos ecológicos. Os autores apresentam ainda três métodos que auxiliam na

interpretação dos pesos das conexões e as contribuições das variáveis e propõem mais um método denominado “*randomization*” (randomização).

Existem desvantagens quanto ao uso das redes neurais em trabalhos ecológicos. Primeiramente a necessidade de bancos de dados muito grande (também necessário para análise estatística multivariada) para proporcionar uma predição considerada boa e segura e é desejável que haja um conjunto de dados independentes para validar o modelo, o que é muito difícil de encontrar em trabalhos ecológicos (AGUILAR IBARRA et al., 2003). Cita-se também a impossibilidade de identificação de onde ocorrem ou estão alocadas determinadas informações no algoritmo. Destaca-se ainda uma desvantagem específica da rede de Kohonen, onde não existem parâmetros para avaliar a qualidade de um mapa, com um determinado nível de confiança. Se o usuário não tiver um conhecimento prévio sobre o conjunto de dados trabalhados fica difícil a validação do mapa obtido.

Dentre as vantagens, destacam-se três principais, apontadas por LEE et al., 2003: i) são relativamente fáceis de projetar; ii) fornecem respostas rápidas e iii) a capacidade de modelar dados dinâmicos, não lineares e ruidosos (fora do padrão), especialmente quando as relações físico-biológicas não são entendidas completamente.

Resultados promissores são obtidos em trabalhos utilizando redes neurais, com a utilização do algoritmo de retropropagação do erro para predição da densidade e biomassa de várias populações de peixes (LEK et al., 1996; MASTRORILLO et al., 1997), para predição de riqueza de espécies de peixes (GUEGAN et al., 1998), para predição da ocupação espacial e abundância de peixes (BROSSE et al., 1999) e na modelagem de assembleias de peixes para prever riqueza de espécies das guildas tróficas e testar a contribuição das variáveis ambientais na explicação da estrutura dessas guildas (AGUILAR IBARRA et al., 2003).

O algoritmo de Kohonen tem sido amplamente utilizado para a análise de dados dentro de algumas áreas como economia, química ou aplicações médicas (GIRAUDEL e LEK, 2001).

FOODY (1999) apresentou um estudo para classificação e ordenação de dados sobre vegetação utilizando mapas auto-organizáveis e afirmou que os mapas constituem uma poderosa ferramenta para classificação ecológica (agrupando amostras semelhantes) e ordenação (organizando as amostras de forma ordenada).

Os mapas auto-organizáveis ainda são pouco utilizados em ecologia, mas prósperos resultados foram obtidos por BROSSE et al. (2001) no estudo de assembléias de peixes, distribuição espacial e abundância de peixes. Os autores apresentaram uma comparação entre o modelo estatístico normalmente utilizado para esta finalidade (Análise de Componentes Principais) e o *SOM*, chegando a conclusão que os mapas auto-organizáveis constituem um método mais confiável quando se trabalha com um conjunto de dados ecológicos complexo, pois não ocorre a redução da dimensionalidade de variáveis como nas análises estatísticas multivariadas.

Segundo GIRAUDEL e LEK (2001), os mapas auto-organizáveis podem ser vistos como um método para explorar dados e alcançar a ordenação de comunidades ecológicas, pois em seu artigo, utilizando o mesmo conjunto de informações acerca de uma floresta em Wisconsin-EUA, obtiveram uma grande semelhança dos resultados obtidos, comparando os mapas com as técnicas mais utilizadas para ordenação: Ordenação Polar, Análise de Componentes Principais, Análise de Correspondência e Escalonamento Dimensional Não-Métrico.

Outras interessantes aplicações dos mapas auto-organizáveis na ecologia podem ser encontradas em CÉRÉGHINO et al. (2001), onde é analisada a distribuição espacial do fluxo de macroinvertebrados de quatro ordens de insetos. Tem-se ainda uma técnica morfométrica

não-destrutiva para prever endoparasitas de peixes, onde LOOT et al. (2002) utilizaram os mapas auto-organizáveis para detectar as principais variáveis e posteriormente um modelo preditivo através de uma rede de múltiplas camadas com o algoritmo de retropropagação do erro. GEVREY et al. (2004) utilizaram-se também de dois modelos de rede neural para avaliar a qualidade da água, utilizando assembléias de algas, diatomáceas.

PENCZAK et al. (2004) apresentam os resultados obtidos com a utilização de *SOM* para classificação de padrões de assembléias de peixes em dois pequenos tributários do rio Paraná e os compara com resultados obtidos utilizando Análise de Correspondência Canônica. Os autores concluem que o algoritmo *SOM* é uma das melhores técnicas em ecologia para análise de dados de populações e especialmente para ordenação de comunidades, resolvendo problemas complexos, multidimensionais e não lineares, que são comumente encontrados em estudos de comunidades.

3.3 REDES COMPETITIVAS

A característica principal das redes competitivas é seu aprendizado não supervisionado, ou seja, “aprende sem professor”. Neste tipo de rede não é procurada uma solução ótima, mas uma solução factível que apresente bons resultados; esta é uma das diferenças com as redes que utilizam o algoritmo de retropropagação do erro, que sempre tentam encontrar a solução ótima do aprendizado.

A aprendizagem não-supervisionada consiste em modificar repetidamente os pesos sinápticos de uma rede neural em resposta a padrões de ativação e de acordo com regras pré-estabelecidas, até que se desenvolva uma configuração final. Isto é possível, pois segundo a observação de TURING (1952 apud HAYKIN, 2001, p. 430): “Uma ordem global pode surgir de interações locais”.

De modo particular, muitas interações locais originalmente aleatórias entre neurônios vizinhos de uma rede podem se fundir em estados de ordem global e finalmente levar a um comportamento coerente na forma de padrões espaciais; encontra-se aí a essência da auto-organização. Assim sendo, o equilíbrio/estabilidade da rede é encontrado através de buscas locais da competição, quando um determinado grupo de neurônios sempre vence e outros não (HAYKIN, 2001).

A organização da rede acontece em dois níveis diferentes que interagem entre si na forma de um laço de realimentação:

- 1 Atividade: certos padrões de atividade são produzidos por uma determinada rede em resposta a sinais de entrada, é a ativação de uma determinada região do mapa auto-organizável.
- 2 Conectividade: os pesos sinápticos da rede são modificados em resposta a sinais neurais dos padrões de atividade, devido a plasticidade sináptica. Se uma determinada região é muito ativa, ela terá valores de pesos característicos.

As mudanças nos pesos devem ser positivas para se obter a auto-organização da rede, onde para um determinado padrão de entrada, somente um neurônio “vença” e os outros não.

Existem quatro princípios básicos da auto-organização (ARRUDA, 2004):

Princípio 1: a modificação dos pesos tende a se auto-amplificar.

- i baseada nos sinais locais (pré e pós) sinápticos,
- ii o peso é reforçado caso os sinais obtidos antes e depois da sinapse são coincidentes e também, caso o padrão de resposta for coincidente ao de entrada. Desta forma, todos os pesos associados são reforçados,

- iii a estabilidade é alcançada via competição: se alguns pesos aumentam, outros tendem a desaparecer.

Princípio 2: princípio da plasticidade das sinapses.

- iv a limitação de recursos leva a competição entre sinapses, e assim o problema de seleção das sinapses mais forte melhora às custas das outras.

Princípio 3: a modificação dos pesos tende a cooperar.

- v as vizinhanças dos neurônios mais fortes são melhoradas, apesar do aspecto global de competição da rede,
- vi todos os neurônios são igualmente estimulados.

Princípio 4: princípio da redundância de informação.

- vii a ordem e a estrutura da rede devem determinar a redundância de informação necessária para garantir a aquisição de conhecimento; se existirem poucos neurônios, a rede pode aprender e desaprender, é o princípio de que quanto maior o espaço, mais coisas pode-se guardar.

Existem dois tipos de redes competitivas:

- 1 Peso fixo: não ocorre o treinamento, somente a competição:
 - MAXNET – utilizada para tomar decisões e encontrar o maior valor, normalmente é acoplada em outra rede para determinação do neurônio vencedor, onde o vencedor leva tudo.
 - Chapéu Mexicano – os neurônios possuem pesos positivos e negativos.

- Rede de Hamming – é um classificador de máxima verossimilhança, pode ser classificada também como uma rede probabilística e sua técnica de agrupamento utiliza a distância de Hamming.
- 2 Peso variável: ocorre a competição e o treinamento, onde é utilizado o princípio de aprendizagem de Kohonen.
- Mapa de Kohonen – algoritmo de agrupamento que será detalhado a seguir.
 - Redes com quantização do vetor de aprendizagem (LVQ – *Learning Vector Quantization*) – utilizada para classificação de padrão.
 - Redes com contrapropagação – semelhante a rede de múltiplas camadas com uma estrutura competitiva.

3.4 REDES DE KOHONEN

O tempo computacional, geralmente, não é importante para uma aplicação ecológica como, por exemplo, a ordenação de comunidades. Os mapas auto-organizáveis podem ser recomendados em aproximações explanatórias no qual poderiam ser encontradas estruturas inesperadas e não encontradas nos métodos estatísticos tradicionais (GIRAUDEL, LEK, 2001).

A estatística multivariada, através da análise dos componentes principais, é a abordagem normalmente utilizada para sumarizar e interpretar dados ecológicos, mas apresenta desvantagens, como a redução (que geralmente ocorre) do número de variáveis. Este método, freqüentemente, leva a identificação do padrão evidente em detrimento de outras informações importantes. Ela não considera toda a complexidade da matriz e as relações não-lineares entre as variáveis, além de dificultar a compreensão dos resultados obtidos, pois a

maioria delas são ordenações. Existem outras abordagens estatísticas que não reduzem a dimensionalidade dos dados, mas não são utilizadas devido a complexidade dos cálculos.

O desenvolvimento das redes de Kohonen como modelo neural foi motivado por uma característica do cérebro humano, que é a organização das informações em muitas regiões, de tal forma que entradas sensoriais distintas são representadas por mapas computacionais topologicamente ordenados.

A rede de Kohonen é uma rede competitiva com a habilidade de realizar mapeamentos que preservam a topologia entre os espaços de entrada e de saída. São utilizadas em muitos projetos industriais como ferramentas para resolver problemas práticos de difícil solução. Seu objetivo é descobrir padrões significativos ou característicos dos dados de entrada. É indicada para resolver problemas não-lineares de alta dimensionalidade, tais como extração de características e classificação de imagens e padrões acústicos, controle adaptativo de robôs, equalização, modulação e transmissão de sinais (CASTRO; CASTRO, 2001).

O processo de aprendizagem é baseado no aprendizado competitivo, o algoritmo tem natureza local e as modificações dos pesos sinápticos são confinadas à vizinhança do neurônio ativado. A ordem global, ou seja, o equilíbrio da rede surge de interações locais. Os neurônios de saída competem entre si para serem ativados, de forma que apenas um neurônio de saída seja considerado “vencedor”.

Os neurônios em uma rede de Kohonen são colocados nos nós de uma grade (que apresenta uma topologia particular, que pode ser retangular, hexagonal etc.), que é usualmente de uma ou duas dimensões. Mapas de dimensões maiores são também possíveis, porém de mais difícil aplicação e compreensão.

Cada neurônio na grade é completamente conectado a todos os neurônios da camada de entrada. São apresentados os padrões de entrada à rede, e a cada padrão apresentado tem-se uma região de atividade na grade. A localização e natureza de uma determinada região variam

de um padrão de entrada para outro. Assim sendo, todos os neurônios da rede devem ser expostos a um número suficiente de diferentes padrões de entrada, garantindo assim que o processo de auto-organização ocorra de forma apropriada.

Os neurônios recebem estímulos (padrões de entrada) ao longo do processo competitivo de aprendizado. Serão considerados “vencedores” os neurônios que mais se assemelharem ao padrão de entrada, sendo que para esta comparação são utilizadas medidas de distâncias (normalmente utiliza-se a distância euclidiana).

Outra forma de avaliar a semelhança entre o padrão de entrada e o neurônio vencedor é o produto interno dos vetores de entrada e peso normalizados, que pode ser interpretado como a correlação entre o vetor de entrada e o vetor peso (FAUSETT, 1994).

A localização destes neurônios (que são os neurônios vencedores) se torna ordenada de tal forma que um sistema de coordenadas é criado na grade, para diferentes características de entrada. Assim sendo, a rede é caracterizada pela formação de um mapa topográfico dos padrões de entrada, no qual as localizações espaciais (ou coordenadas) dos neurônios na grade são indicativas de características dos padrões de entrada.

A rede consiste de duas camadas de neurônios conectados por pesos. A camada de entrada é conectada a um vetor de entrada do conjunto de dados e a camada de saída forma um mapa que consiste de uma grade retangular onde são dispostos vários neurônios.

Primeiramente, deve-se determinar:

- 1 a taxa de aprendizagem e o tamanho do raio topológico que decrescem conforme o treinamento é executado;
- 2 a topologia da camada de saída, ou seja, o critério a ser utilizado para determinar quais neurônios pertencem a vizinhança do neurônio vencedor (por exemplo: hexagonal, retangular, etc); é apresentado um exemplo na figura 1.

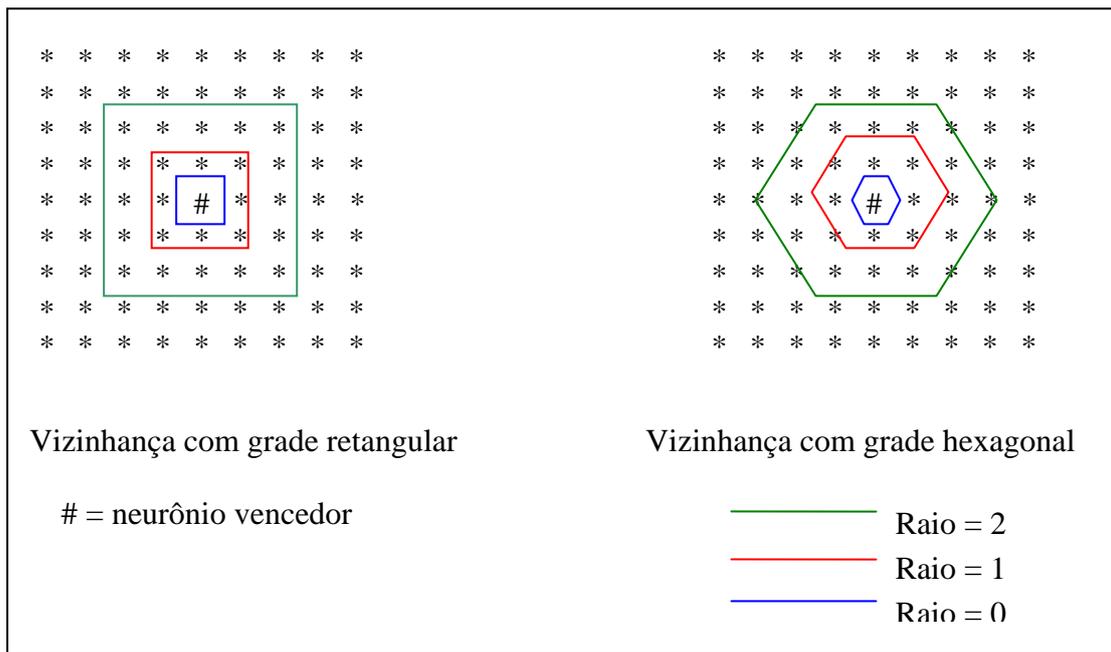


Figura 1- Parâmetros topológicos de vizinhança e raio topológico

O algoritmo responsável pela formação do mapa de Kohonen primeiramente inicializa os pesos sinápticos da rede. Este procedimento pode ser feito atribuindo pequenos valores aleatórios, de igual grandeza aos padrões de entrada. Desta forma, nenhuma ordem prévia é imposta ao mapa de características. No entanto, se existe alguma informação sobre a distribuição dos grupos, estes pesos podem ser escolhidos para refletir este conhecimento. A seguir são inicializados o raio topológico e a taxa de aprendizagem para então ocorrer o processo de formação do mapa de Kohonen.

Para a formação do mapa de Kohonen, existem três processos envolvidos, que são citados abaixo e detalhados a seguir, conforme HAYKIN (2001):

- 1 **Competição:** para cada padrão de entrada, os neurônios da rede computam os seus respectivos valores de uma função discriminante. Esta função provê as bases para a competição entre os neurônios. O neurônio com maior valor da função discriminante é declarado vencedor da competição.

- 2 Cooperação: o neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, provendo, desta forma, as bases para a cooperação entre tais neurônios vizinhos.
- 3 Adaptação Sináptica: este último mecanismo permite aos neurônios excitados aumentar seus valores individuais da função discriminante em relação ao padrão de entrada, através de ajustes adequados aplicados a seus pesos sinápticos. Os ajustes feitos são tais que, a resposta do neurônio vencedor à subsequente aplicação de um padrão similar de entrada é realçada.

Os processos de competição e cooperação estão de acordo com dois dos quatro princípios de auto-organização apresentados anteriormente (seção 3.3), assim como o processo de auto-amplificação pode ser considerado uma forma modificada e melhorada do aprendizado Hebbiano no processo adaptativo, pois é possível a prova da convergência do aprendizado de Kohonen. As propriedades envolvendo a convergência do algoritmo de treinamento são demonstradas no artigo de ZHEN-PING et al. (1993). Ainda, a presença de redundância nos dados de entrada é necessária para o aprendizado, desde que é responsável por prover o conhecimento (HAYKIN, 2001).

Os três processos formadores do mapa de Kohonen estão apresentados de forma mais detalhada a seguir.

3.4.1 PROCESSO COMPETITIVO

Seja m a dimensão do espaço de dados de entrada. Seja um padrão de entrada (vetor) selecionado aleatoriamente a partir do espaço de entrada, denotado por

$$\underline{x} = [x_1 \ x_2 \ x_3 \ \dots \ x_m]^T \quad (3.1)$$

O vetor de pesos sinápticos de cada neurônio na camada de saída da rede tem a mesma dimensão do espaço de entrada. Seja o vetor de pesos sinápticos do neurônio j denotado por

$$\underline{w}_j = [w_{j1} \ w_{j2} \ w_{j3} \ \dots \ w_{jm}]^T, \quad j = 1, 2, \dots, l \quad (3.2)$$

onde l é o número total de neurônios na camada de saída da rede.

Para encontrar o vetor de entrada \underline{x} que mais se aproxima do vetor de pesos sinápticos \underline{w}_j , são utilizadas medidas de distâncias e o neurônio cujo vetor peso apresentar a menor distância em relação ao padrão de entrada será considerado o vencedor local, onde estará centrada a vizinhança topológica dos neurônios excitados.

Utilizando o índice $i(\underline{x})$ para identificar o neurônio que mais se aproxima do vetor de entrada \underline{x} pode-se, então, determinar o neurônio vencedor, aplicando a condição apresentada na equação (3.3), onde $i(\underline{x})$ é o neurônio cujo vetor peso apresentar a menor distância (critério da mínima distância euclidiana),

$$i(\underline{x}) = \arg \min \| \underline{x} - \underline{w}_j \|, \quad \text{para } j = 1, 2, \dots, l \quad (3.3)$$

que resume a essência do processo de competição entre os neurônios.

O neurônio particular i que satisfaz a condição expressa na função (3.3) é chamado de neurônio vencedor para o vetor de entrada \underline{x} .

A equação (3.3) leva a seguinte observação: A norma euclidiana aplicada nos padrões de entrada e nos neurônios presentes no mapa de saída, faz com que os padrões de ativação da entrada sejam mapeados em um espaço discreto de saída de neurônios por um processo de competição entre os neurônios da grade.

Dependendo da aplicação de interesse, a resposta da rede pode ser tanto o índice do neurônio vencedor (isto é, sua posição na grade), quanto o vetor de pesos sinápticos que está mais próximo do vetor de entrada, em relação à distância utilizada.

3.4.2 PROCESSO COOPERATIVO

O neurônio vencedor determina o centro de uma vizinhança topológica de neurônios cooperativos. A definição desta vizinhança topológica é baseada na evidência neurobiológica de que há interação lateral entre um conjunto de neurônios biológicos excitados.

Em particular, um neurônio classificado como vencedor tende a excitar mais os neurônios em sua vizinhança imediata, do que aqueles neurônios que estão mais distantes. Assim, pode-se afirmar que a vizinhança topológica ao redor do neurônio vencedor i decai suavemente com a distância lateral.

Seja h_{ji} a vizinhança topológica centrada no neurônio vencedor i e circundada por um conjunto de neurônios excitados cooperativos, dos quais um neurônio típico é denotado por j . Seja, ainda, d_{ij} a distância lateral entre o neurônio vencedor i e o neurônio excitado j . Pode-se então assumir que a vizinhança topológica h_{ji} é uma função unimodal (que apresenta um único mínimo ou máximo) da distância lateral d_{ij} (relativa a distância topológica dos neurônios), tal que satisfaça duas exigências distintas (CASTRO; CASTRO, 2001):

- 1 A vizinhança topológica h_{ji} é simétrica ao redor do ponto máximo definido por $d_{ij} = 0$, ou seja, atinge seu valor máximo no neurônio vencedor i , para o qual a distância d_{ij} é zero.
- 2 A amplitude da vizinhança topológica h_{ji} decresce monotonicamente com o aumento da distância lateral d_{ij} , decaindo a zero para $d_{ij} \rightarrow \infty$; condição necessária para convergência.

Várias funções, listadas a seguir, satisfazem as exigências para a vizinhança topológica h_{ji} e são apresentadas graficamente na figura 2:

a) $h_{ji}(t) = (\sigma_t - d_{ji})$

$$\text{b) } h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}} \quad (3.4)$$

$$\text{c) } h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}} (\sigma_t - d_{ji})$$

$$\text{d) } h_{ji}(t) = \max\{0, 1 - (\sigma_t - d_{ji})^2\}$$

onde σ_t é o raio da vizinhança topológica no tempo t (t representa o número de iterações), mede o grau com que os neurônios excitados, vizinhos do neurônio vencedor, participam do processo de aprendizagem.

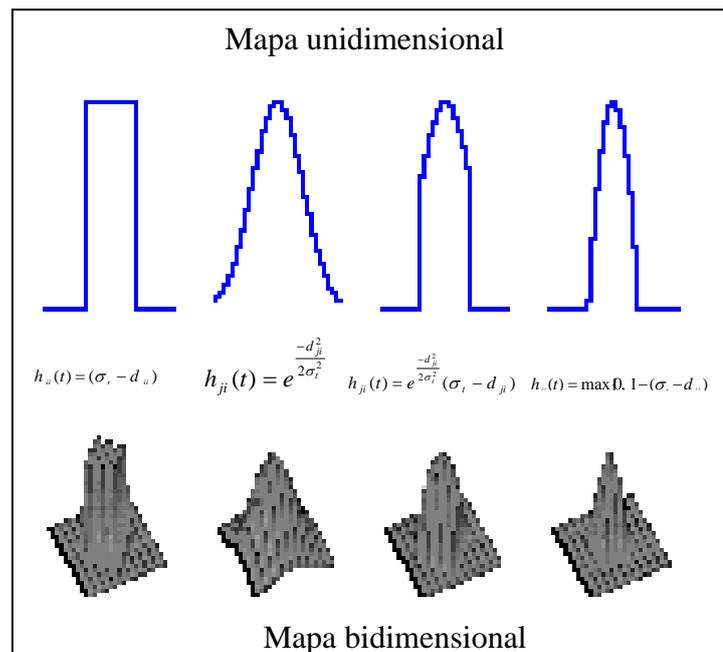


Figura 2– Diferentes funções de vizinhança (Fonte: VESANTO et al., 2000b, p.10).

A mais utilizada é a função de vizinhança gaussiana $h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}}$ (3.4), a qual é invariante à translação, isto é, independente da localização do neurônio vencedor (CASTRO; CASTRO, 2001).

Para que ocorra a cooperação entre os neurônios vizinhos, é necessário que a vizinhança topológica h_{ji} seja mais dependente da distância d_{ij} entre o neurônio vencedor i e o neurônio excitado j no espaço de saída, do que de alguma medida de distância no espaço de entrada original. No caso de uma grade unidimensional, d_{ij} é um inteiro igual a $|j - i|$. No caso de uma grade bidimensional, a distância d_{ij} é dada por

$$d_{ij}^2 = \|\underline{r}_j - \underline{r}_i\|^2 \quad (3.5)$$

onde o valor discreto \underline{r}_j define a posição do neurônio excitado j e \underline{r}_i define a posição discreta do neurônio vencedor i , ambas medidas no espaço discreto de saída.

Uma outra característica do algoritmo é que o tamanho da vizinhança topológica “encolhe” com o tempo. Esta exigência é satisfeita fazendo a largura de σ_t da função de vizinhança topológica h_{ji} decrescer com o tempo. A função mais utilizada para a dependência de σ no tempo discreto t é o decaimento exponencial descrito por (3.6)

$$\sigma(t) = \sigma_0 e^{\left(\frac{-t}{T_l}\right)}; t = 0, 1, 2, \dots \quad (3.6)$$

onde σ_0 é o valor do raio σ na inicialização do algoritmo e T_l é uma constante. Assim sendo, a função de vizinhança topológica (3.4) assume uma forma variante com o tempo, conforme mostrada por (3.7)

$$h_{j\hat{i}(x)}(t) = e^{\frac{-d_{ji}^2}{2\sigma^2(t)}}, t=0, 1, 2, \dots \quad (3.7)$$

onde $\sigma(t)$ é definido pela função (3.6). Assim, a medida que o tempo t (isto é, o número de iterações) aumenta, a largura $\sigma(t)$ diminui a uma taxa exponencial, e a vizinhança topológica “encolhe” de forma correspondente.

3.4.3 PROCESSO ADAPTATIVO

O último processo envolvido na formação auto-organizável de um mapa de características (*SOM*) é o processo adaptativo dos pesos sinápticos.

Para que a rede possa se auto-organizar, o vetor de pesos sinápticos \underline{w}_j do neurônio j deverá variar com relação ao vetor de entrada. No postulado de aprendizado de Hebb, um peso sináptico é aumentado quando há ocorrência simultânea de atividades pré e pós-sinápticas.

Para o tipo de aprendizado não-supervisionado aqui considerado, entretanto, a hipótese de Hebb em sua forma básica é insatisfatória pela seguinte razão: mudanças nas conectividades ocorrem em apenas uma direção, o que acabaria por levar todos os pesos sinápticos à saturação.

Para superar esta dificuldade a hipótese de Hebb é modificada incluindo um termo de esquecimento. Dada uma função $g(\cdot)$ tal que,

$$g(y_j) = 0 \text{ para } y_j = 0, \quad (3.8)$$

onde $g(y_j)$ é uma função escalar positiva da resposta y_j .

Pode-se então expressar a mudança no vetor de pesos sinápticos do neurônio j na grade, conforme (3.9):

$$\Delta \underline{w}_j = \underbrace{\eta y_j \underline{x}}_{\text{Termo Hebbiano}} - \underbrace{g(y_j) \underline{w}_j}_{\text{Termo de Esquecimento}} \quad (3.9)$$

onde η é o parâmetro taxa de aprendizagem do algoritmo. O primeiro termo no lado direito da função (3.9) é o termo Hebbiano e o segundo termo é o termo de esquecimento. Para satisfazer a condição dada pela função (3.8), escolhe-se uma função linear para $g(y_j)$, conforme (3.10).

$$g(y_j) = \eta y_j \quad (3.10)$$

A função (3.9) pode ainda, ser simplificada fazendo-se:

$$\Delta \underline{w}_j = \eta y_j \underline{x} - g(y_j) \underline{w}_j, \text{ onde } \Delta \underline{w}_j = w_{j(novo)} - w_{j(velho)}. \text{ Assim,}$$

$$w_{j(novo)} = w_{j(velho)} + \eta y_j (\underline{x} - w_{j(velho)})$$

$$w_{j(novo)} = w_{j(velho)} + \eta y_j \underline{x} - \eta y_j w_{j(velho)}$$

$$w_{j(novo)} = (1 - \eta y_j) w_{j(velho)} + \eta y_j \underline{x}, \text{ observa-se que o aprendizado de Kohonen é um}$$

filtro de primeira ordem do aprendizado de Hebb.

Tem-se (3.11):

$$y_j = h_{j,i(\underline{x})} \quad (3.11)$$

Substituindo as funções (3.10) e (3.11) na função (3.9), tem-se (3.12).

$$\Delta \underline{w}_j = \eta h_{j,i(\underline{x})} (\underline{x} - \underline{w}_j) \quad (3.12)$$

Finalmente, dado o vetor de pesos sinápticos $\underline{w}_j(t)$ do neurônio j no tempo t , o vetor de pesos atualizado $\underline{w}_j(t+1)$ no tempo $t+1$ é definido por (3.13).

$$\underline{w}_j(t+1) = \underline{w}_j(t) + \eta(t) h_{j,i(\underline{x})}(t) (\underline{x} - \underline{w}_j(t)) \quad (3.13)$$

que é o aprendizado de Kohonen, o qual é aplicado a todos os neurônios na grade que estão dentro da vizinhança topológica do neurônio vencedor i .

A equação (3.13) tem o efeito de mover o vetor de pesos sinápticos \underline{w}_i do neurônio vencedor i na direção do vetor de entrada \underline{x} . Sob repetidas apresentações dos dados de treinamento, os vetores de pesos sinápticos tendem a seguir a distribuição dos vetores de entrada, devido à atualização da vizinhança. O algoritmo, portanto, conduz a uma ordenação topológica do mapa de características no espaço de entrada, no sentido de que os neurônios que são adjacentes na grade tenderão a ter vetores de pesos sinápticos similares (HAYKIN, 2001).

A equação (3.13) é a expressão desejada para computar os pesos sinápticos do mapa de características. Em adição a esta equação, entretanto, é necessário considerar-se a equação (3.7) para selecionar a função de vizinhança $h_{ji(x)}(t)$ e uma heurística adicional para selecionar o parâmetro taxa de aprendizagem $\eta(t)$.

O parâmetro taxa de aprendizagem $\eta(t)$ deve variar com o tempo, como indicado na equação (3.13). Em particular, a taxa de aprendizagem deve iniciar em um valor η_0 , e então, decrescer gradualmente com o aumento do tempo t . Esta condição pode ser satisfeita escolhendo qualquer uma das equações apresentadas a seguir e apresentadas graficamente na Figura 3.

a) linear: $\eta(t) = \eta_0 \left(1 - \frac{t}{T_2}\right)$

b) recíproca: $\eta(t) = \frac{\eta_0}{\left(1 + \frac{100t}{T_2}\right)}$

c) exponencial: $\eta(t) = \eta_0 \left(\frac{0,005}{\eta_0}\right)^{\frac{t}{T_2}}$, ou $\eta(t) = \eta_0 e^{-\frac{t}{T_2}}$ (3.14)

onde T_2 é uma constante, t é o número de iterações = 0, 1, 2,

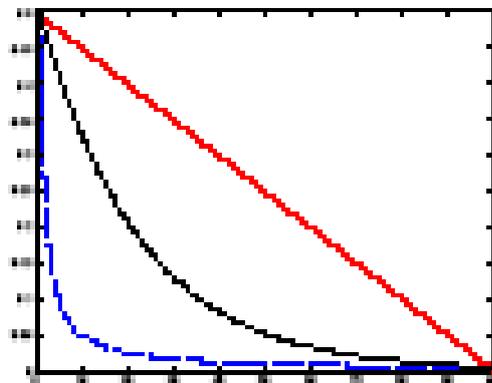


Figura 3 – Diferentes funções de taxa de aprendizagem (Fonte: VESANTO et al., 2000b, p.10)
onde a cor vermelha representa a função linear, a preta a exponencial e a azul a recíproca

A mais utilizada é a exponencial (3.14), que juntamente com a função para redução do raio topológico, são adequadas para a formação do mapa de características de uma forma auto-organizável (HAYKIN, 2001).

Em resumo, no treinamento ocorre uma competição construtiva do neurônio vizinho, ou seja, é escolhido o neurônio vencedor, sendo aquele que apresentar a menor distância (no caso euclidiana) ao vetor de entrada. Na seqüência é atualizado seu peso e de toda sua vizinhança determinada pelo raio topológico e pela topologia determinada, conforme o princípio de aprendizagem de Kohonen (equação 3.13). Desta forma ocorrem os agrupamentos e cada grupo está associado aos vetores de peso (neurônios da camada de saída).

Partindo de um estado inicial de desordem completa, o algoritmo (*SOM*) gradualmente conduz a uma representação organizada dos padrões de ativação extraídos do espaço de entrada, desde que os parâmetros do algoritmo sejam selecionados de forma apropriada.

Pode-se decompor em duas fases a adaptação dos pesos sinápticos, na rede: uma fase relativa à ordenação ou auto-organização, seguida por uma fase relativa à convergência, que podem ser descritas conforme seções seguintes 3.3.3.1 e 3.3.3.2.

3.4.3.1 Fase de ordenação ou auto-organização

É durante esta primeira fase do processo adaptativo que a ordenação topológica dos vetores pesos sinápticos acontece. As escolhas dos parâmetros: taxa de aprendizagem e da função de vizinhança devem ser feitas de forma cuidadosa.

- ✓ O parâmetro taxa de aprendizagem $\eta(t)$ deve iniciar com um valor próximo a 0,1, decrescendo gradualmente, mas permanecendo acima de 0,01. Estes

valores são atingidos através das seguintes escolhas para os parâmetros:

$\eta_0 = 0,1$ e $T_2 = 1000$ (na função (3.14)).

- ✓ A função de vizinhança $h_{ji(x)}(t)$ deve incluir inicialmente quase todos os neurônios na rede centrados no neurônio vencedor i e, então, reduzir o raio, lentamente com o tempo (épocas).

Especificamente, durante a fase de ordenação (que pode ocupar 1000 iterações ou mais), $h_{ji(x)}(t)$ pode ser reduzida a um valor tão pequeno quanto, por exemplo, a apenas dois neurônios vizinhos ao redor de um neurônio vencedor ou, até mesmo, ao próprio neurônio vencedor. Assumindo o uso de uma grade de duas dimensões de neurônios para o mapa discreto, pode-se então ajustar o tamanho inicial σ_0 da função de vizinhança fazendo-se igual ao raio da grade. Correspondentemente, pode-se ajustar a constante de tempo T_1 na função (3.6), por exemplo, como na função (3.15).

$$T_1 = \frac{1000}{\log \sigma_0} \quad (3.15)$$

3.4.3.2 Fase de convergência

Esta segunda fase do processo adaptativo é necessária para o “ajuste fino” do mapa de características e, portanto, para prover uma quantificação estatística acurada do espaço de entrada.

Algumas sugestões relatadas por HAYKIN (2001) são as seguintes:

- ✓ Para uma boa precisão estatística, o parâmetro taxa de aprendizagem $\eta(t)$ deve ser mantido em um valor pequeno durante a fase de convergência, da ordem de 0,01, não devendo cair a zero em nenhuma situação. Caso contrário a rede poderá ficar “presa” em um estado onde não ocorrem mais mudanças

na matriz dos pesos (indicando convergência) e mesmo assim não seja uma “boa” solução. O decaimento exponencial presente na função (3.14) evita este fato.

- ✓ A função de vizinhança $h_{ji(x)}(t)$ deve conter somente os vizinhos mais próximos de um neurônio vencedor, podendo, eventualmente, reduzir o número de neurônios vizinhos mais próximos a um, ou mesmo a zero.

3.4.4 ALGORITMO DE KOHONEN

A seguir é apresentado o algoritmo de Kohonen, passo a passo (CHON, 1996):

Passo 0: INICIALIZAÇÃO

- Inicializar a taxa de aprendizagem inicial ($a=$)
- Inicializar o raio topológico ($r=$)
- Informar o número máximo de épocas a serem executadas ($e=$)
- Inicializar pesos: Matriz W_{ixjxk} (onde: $i=n^\circ$ de colunas do arquivo de dados, $j=n^\circ$ de colunas do mapa e $k= n^\circ$ de linhas do mapa), com valores aleatórios entre 0 e 1

Passo 1: CRITÉRIO DE PARADA

- Comparar o número máximo de épocas e a alteração dos valores da matriz peso.

Passo 2: TREINAMENTO

Para cada vetor x_i :

Fase Competitiva

- Calcular as distâncias ($D(j)= \text{soma } (w_{ij}-x_i)^2$), de cada linha da matriz de dados com todas as colunas da matriz peso
- Encontrar o índice j tal que $D(j)$ seja mínimo (é o neurônio vencedor)

Fase Cooperativa

- Para todas as colunas da matriz peso:
- Localizar os vizinhos do neurônio vencedor (j) pelo raio topológico (se o neurônio analisado fizer parte da vizinhança, faça $z(k)=1$, caso contrário $z(k)=0$)

Fase Adaptativa

- Atualizar toda a matriz peso:

$$w_{ij}(t+1) = w_{ij}(t) + a(x_i - w_{ij}(t)) * z(k)$$

Retornar para Passo 2: com a entrada de um novo x_i

Passo 3: ATUALIZAÇÃO

- Atualizar taxa de aprendizagem: (uma função decrescente linear, exponencial ou geométrica em função das épocas)
- Atualizar raio topológico: (definido como uma função monotonicamente decrescente em função das épocas)

Retornar ao Passo 1

FIM

SAÍDA DE DADOS

Os parâmetros essenciais do algoritmo são:

- 1 Uma topologia da rede na forma de uma grade de neurônios, a qual define um espaço de saída discreto.
- 2 Uma taxa de aprendizagem que deve decrescer lentamente em função do tempo ou das épocas de treinamento. Este decrescimento pode ser linear, geométrico ou exponencial.
- 3 Um raio da vizinhança em torno do neurônio que é o centro do grupo que deve decrescer à medida que o processo de agrupamento converge, observar a figura 1 da página 37.
- 4 Os pesos podem ser inicializados com valores aleatórios pequenos. No entanto se existe alguma informação sobre a distribuição dos grupos, estes pesos podem ser escolhidos para refletir este conhecimento.

3.4.5 PROPRIEDADES DO MAPA DE CARACTERÍSTICAS

As propriedades do mapa de características apresentadas a seguir, seguem basicamente as informações de HAYKIN (2001).

Após a convergência do algoritmo *SOM*, o mapa de características computado apresenta propriedades importantes do espaço de entrada.

Seja \mathcal{X} um espaço de dados de entrada contínuo, cuja topologia é definida pela relação métrica dos vetores $\underline{x} \in \mathcal{X}$. Seja \mathcal{A} um espaço de saída discreto, cuja topologia vem do arranjo de um conjunto de neurônios sob a forma de nós computacionais de uma grade. Seja Φ uma transformação não-linear chamada “mapa de características”, a qual mapeia o espaço de entrada \mathcal{X} no espaço de saída \mathcal{A} , ou seja, $\Phi : \mathcal{X} \rightarrow \mathcal{A}$. (3.16)

A transformação não-linear (3.16) pode ser vista como uma abstração da função (3.3), a qual define a localização de um neurônio vencedor $i(\underline{x})$ a partir de um vetor de entrada \underline{x} .

Dado um vetor de entrada \underline{x} , o algoritmo *SOM* inicialmente identifica um neurônio vencedor $i(\underline{x})$, que seja o mais semelhante no espaço de saída \mathcal{A} , de acordo com o mapa de características Φ . O vetor de pesos sinápticos \underline{w}_i do neurônio $i(\underline{x})$ pode, então, ser visto como um ponteiro para aquele neurônio no espaço de entrada, ou seja, os elementos sinápticos do vetor \underline{w}_i podem ser vistos como as coordenadas da imagem do neurônio i projetado no espaço de entrada. Estas duas operações encontram-se representadas na Figura 4.

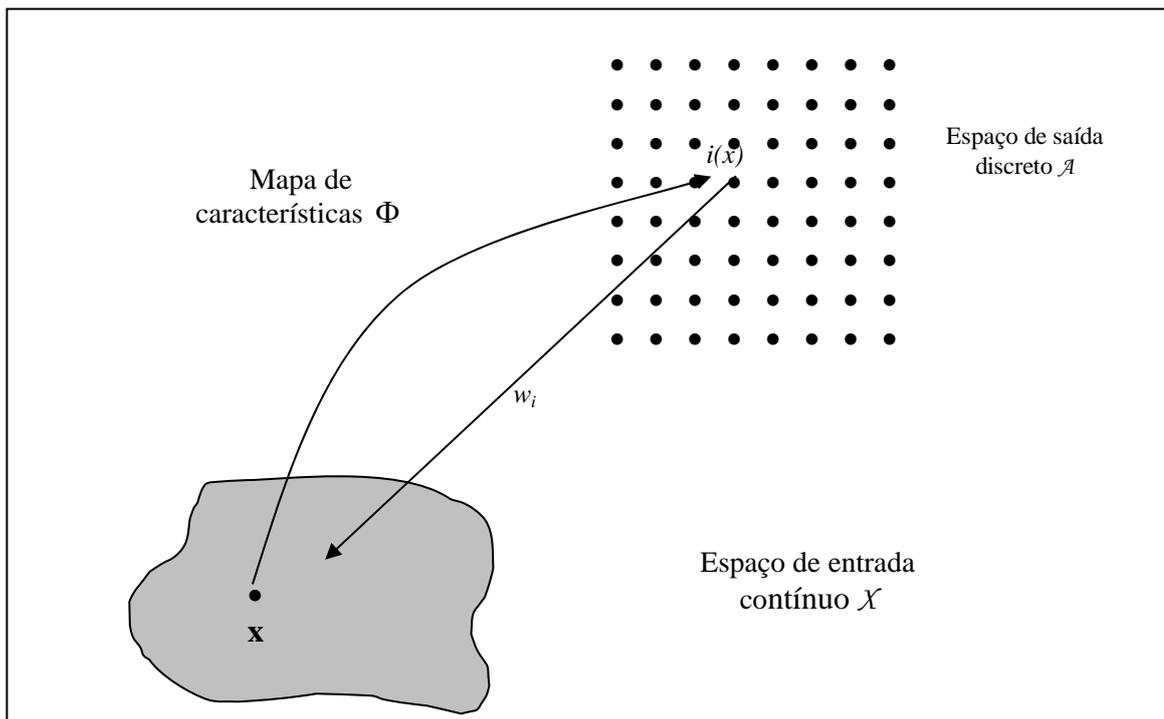


Figura 4 - Ilustração da relação entre o mapa de características Φ e o vetor de pesos \underline{w}_i o neurônio vencedor j (HAYKIN, 2001 p.495)

O mapa de características Φ tem algumas propriedades importantes:

- 1 O mapa de características Φ , representado pelo conjunto de vetores de pesos sinápticos $\{ \underline{w}_i \}$ no espaço de saída \mathcal{A} , provê uma boa aproximação do espaço de entrada \mathcal{X} .
- 2 O mapa de características Φ computado pelo algoritmo *SOM* é topologicamente ordenado, no sentido de que a localização espacial de um neurônio na grade corresponde a um domínio particular ou característica dos padrões de entrada.
- 3 O mapa de características Φ reflete variações na estatística da distribuição de entrada: regiões no espaço de entrada \mathcal{X} dos quais os vetores amostra \underline{x} são retirados com uma alta probabilidade de ocorrência são mapeados para domínios maiores do espaço de saída \mathcal{A} e, portanto, com melhor resolução que regiões em \mathcal{X} das quais os vetores amostra \underline{x} são extraídos com uma baixa probabilidade de ocorrência.
- 4 Se os dados que compõem um espaço de entrada possuem uma distribuição não-linear, o mapa auto-organizável é capaz de selecionar um conjunto de características adequado para aproximar a distribuição não-linear subjacente.

3.5 REDES NEURAI E CLASSIFICAÇÃO TRÓFICA

Considerando as informações apresentadas no decorrer deste capítulo, conclui-se que as redes neurais artificiais são indicadas para tratamento de dados ecológicos. Como o objetivo deste trabalho é a classificação trófica de espécies de peixes, ou seja, a realização de

agrupamentos baseado na dieta alimentar dos peixes, a rede de Kohonen é indicada para realizar esta tarefa.

Uma dificuldade para a utilização da rede de Kohonen, em geral, é a obtenção do conjunto de dados, pois para o treinamento da rede é necessário um banco de dados confiável com redundância nos dados de entrada (HAYKIN, 2001). Para a realização deste trabalho, a obtenção deste banco de dados foi possível através do projeto “Estudos ictiológicos na área de influência do AHE Corumbá” desenvolvido Núcleo de Pesquisas em Limnologia, Ictiologia e Aqüicultura (Nupélia), UEM.

O capítulo IV a seguir apresenta com detalhes as informações sobre o conjunto de dados, assim como a parametrização do mesmo para o treinamento da rede.

CAPÍTULO IV

4 COLETA E ANÁLISE EXPLORATÓRIA DOS DADOS DO PROBLEMA ABORDADO

4.1 INTRODUÇÃO

Para o desenvolvimento deste trabalho foram utilizados dados obtidos no desenvolvimento do projeto “Estudos ictiológicos na área de influência do AHE Corumbá” pelo Núcleo de Pesquisas em Limnologia, Ictiologia e Aqüicultura (Nupélia), UEM em convênio com FURNAS Centrais Elétricas S.A., conforme já mencionado. A localização da UHE Corumbá é apresentada na Figura 5.

Os peixes foram coletados com periodicidade mensal, durante a fase rio (anterior ao represamento) e trimestralmente na fase reservatório (posterior ao represamento) no período de março de 1996 a fevereiro de 1999. Foram utilizadas para a coleta dos peixes, redes de espera de diferentes malhagens (áreas abertas), arrastes (áreas litorâneas) e pesca elétrica (córregos).

Foi analisado o espectro alimentar das espécies de peixes presentes em amostras obtidas em rios, ribeirões e riachos, influenciados em graus variados pelo represamento da UHE Corumbá. Esta análise foi realizada de acordo com o método volumétrico, onde se registra o volume de cada item ou recurso alimentar, obtendo-se a porcentagem em relação ao volume total de todos os conteúdos estomacais (HYSLOP, 1980).

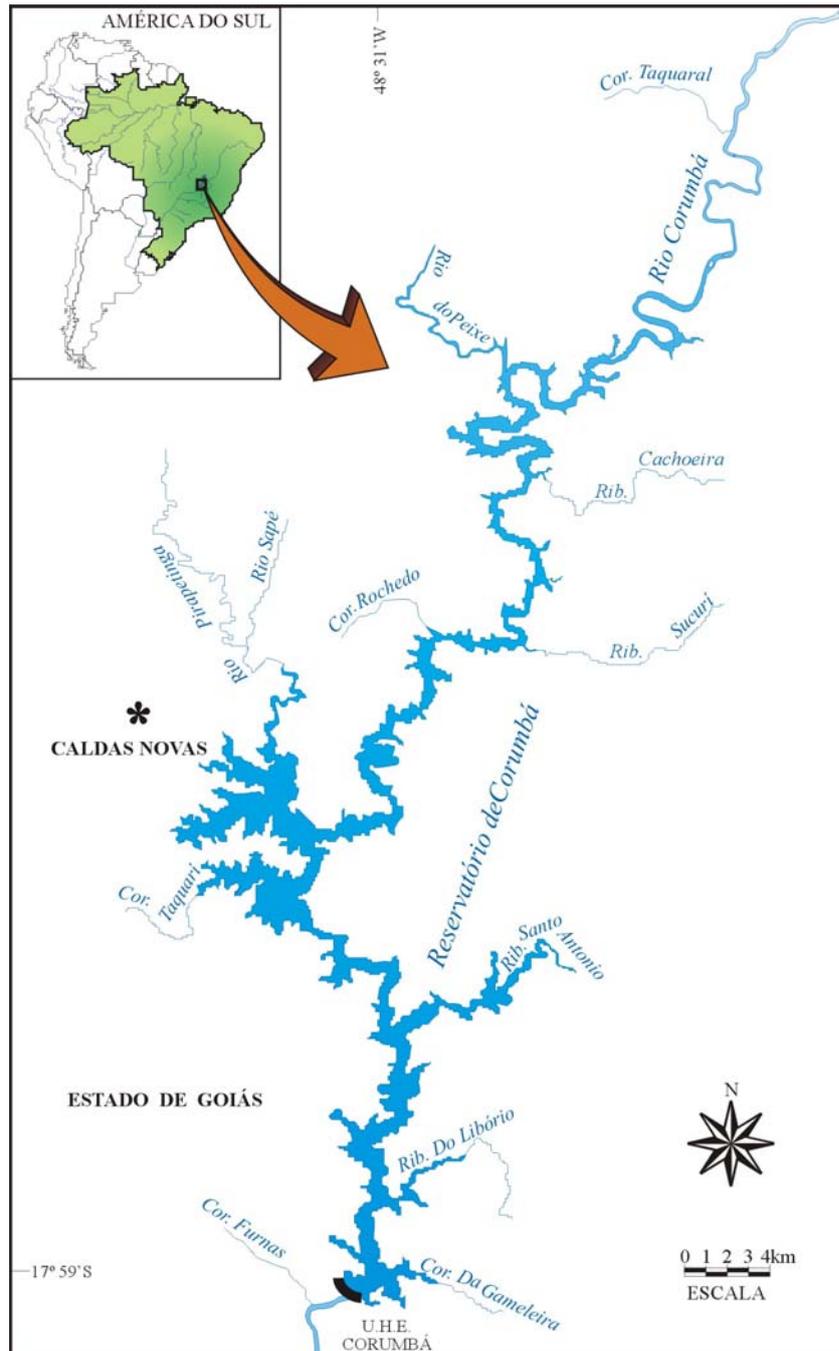


Figura 5 - Localização da UHE Corumbá (Fonte: Nupélia)

Os onze recursos alimentares explorados pelos peixes foram: microcrustáceos (cladóceras, copépodos, ostrácodos, conchostracas etc.); insetos aquáticos (dípteras, efemerópteras, odonatas, tricópteras, hemípteras, coleópteras, plecópteras etc.); insetos terrestres (himenópteras, coleópteras, isópteras, ortópteras, homópteras, neurópteras, odonatas, lepidópteras etc.); outros invertebrados aquáticos (acarinas, briozoas, bivalvias, nemátodos, tecamebas, oligoquetas, rotíferas, decápodos etc.); outros invertebrados terrestres

(diplópodos, arâneas, isópodos, oligoquetas, gastrópodos etc.); peixes (characiformes, siluriformes etc.); outros vertebrados (anfíbios); algas (filamentosas e unicelulares); vegetais aquáticos (briófitas, parte de macrófitas) e terrestres (sementes, frutos, folhas de vegetais superiores); detrito/sedimento (material orgânico amorfo com elevada participação de partículas minerais) (GASPAR DA LUZ, 2000).

A caracterização da dieta foi realizada para conteúdos estomacais de 7.337 peixes, pertencentes a 52 espécies no total, pois espécies que apresentaram um número de estômagos analisados com alimento passível de identificação menor que dez foram descartadas. Uma pequena parte (52 peixes do total de 7337) da planilha de dados é apresentada na Tabela 2. A primeira coluna apresenta o código destinado a cada espécie de peixe, a seguir o mês e o ano da coleta. A terceira coluna apresenta informação da fase em que o peixe foi coletado: pré (fase rio, pré enchimento), pós (fase reservatório, pós enchimento – no ano de 1997 e início de 1998) e pós1 (fase reservatório, pós enchimento – a partir de abril de 1998 e parte de 1999), as demais colunas apresentam o volume (ml) de cada recurso alimentar.

A Tabela 3 relaciona as espécies de peixes estudadas, seus nomes populares e o número atribuído a cada espécie, que será utilizado no decorrer do trabalho.

Tabela 2 - Modelo da planilha de dados

(recursos alimentares: I=microcrustáceos, II=insetos aquáticos, III=insetos terrestres, IV=outros invertebrados aquáticos, V=outros invertebrados terrestres, VI=peixes, VII=outros vertebrados, VIII=algas, IX=vegetais aquáticos, X=vegetais terrestres, XI=detrito/sedimento. Os valores são apresentados em volume (ml)).

CÓD.	DATA	FASE	RECURSOS ALIMENTARES										
			I	II	III	IV	V	VI	VII	VIII	IX	X	XI
1	abr-96	pré	0	0	0	0,002	0	0,05	0	0,004	0	0	0,24
2	abr-97	pós	0,1	0	0	0	0	0	0	0	0	0	0
3	jul-96	pré	0	0,02	0,065	0	0	0	0	0	0	0	0
4	fev-99	pós1	0	0	0,062	0	0	0	0	0	0	0,0349	0
5	abr-96	pré	0	0,001	0	0	0	0	0	0	0	0,185	0
6	ago-96	pré	0	0,001	0	0	0	0	0	0,011	0	0	0,09
7	jun-97	pós	0	0	0	0	0	0	0	0	0	0,05	0
8	mai-96	pré	0	0	0,41	0	0	0	0	0	0	0	0
9	mai-96	pré	0	0,001	0,002	0	0	0	0	0	0,001	0	0
10	jul-96	pré	0	0,0145	0,095	0	0	0	0	0	0	0	0
11	jun-97	pós	0	0	0,1	0	0	0	0	0	0	0	0
12	ago-96	pré	0	0,0002	0,007	0	0	0	0	0	0	0	0
13	abr-98	pós1	0	0	0	0	0	1	0	0	0	0	0
14	set-97	pós	0	0,08	0	0	0	0	0	0	0	0	0,005
15	jun-97	pós	0	0	0,01	0	0	0	0	0	0	0	0
16	mai-96	pré	0,001	0,0021	0	0,0002	0	0	0	0,0001	0	0	0,001
17	ago-96	pré	0	0,25	0	0	0	0	0	0	0	0	0,05
17	mai-98	pós1	0	0,0395	0,005	0	0	0,03	0	0	0	0	0
18	dez-97	pós	0	1	0,1	0	0	0,002	0	0	0	0	0
19	jan-98	pós	0	0	0,08	0	0	0	0	0	0	0	0
20	mar-97	pós	0	0	0	0	0	3	0	0	0	0	0
21	mar-97	pós	0	0	0	0	0	9	0	0	0	0	0
22	mar-96	pré	0	0	0	0	0	0	0	1,001	0	0	0,019
23	set-97	pós	0	0,003	0	0	0	0	0	0,07	0	0	1,23
24	fev-99	pós1	0	0,001	0	0	0	0,006	0	0	0	0	0,0012

/... segue

Tabela 3 - Código, espécies de peixes e nome popular.

Código	Espécies	Nome popular
01	<i>Apareiodon affinis</i>	“canivete”
02	<i>Astyanax bimaculatus</i>	“tambuí”
03	<i>Astyanax eigenmanniorum</i>	“lambari”
04	<i>Astyanax fasciatus</i>	“lambari”
05	<i>Apareiodon ibitiensis</i>	“canivete”
06	<i>Apareiodon piracicabae</i>	“canivete”
07	<i>Astyanax scabripinnis paranae</i>	“lambari”
08	<i>Brycon nattereri</i>	“pirapitinga”
09	<i>Bryconamericus stramineus</i>	“pequira”
10	<i>Bryconamericus</i> sp.	“pequira”
11	<i>Crenicichla haroldoi</i>	“joaninha”
12	<i>Cetopsorhamdia iheringi</i>	“mandizinho”
13	<i>Cichla monoculus</i>	“tucunaré”
14	<i>Cichlasoma paranaense</i>	“cará”
15	<i>Characidium zebra</i>	“canivete”
16	<i>Corydoras</i> sp.	“coridoras”
17	<i>Eigenmannia</i> sp.	“tuvira”
18	<i>Gymnotus carapo</i>	“morenita”
19	<i>Glanidium cesarpintoi</i>	“jundiá”
20	<i>Galeocharax knerii</i>	“peixe-cadela”
21	<i>Hoplias malabaricus</i>	“traíra”
22	<i>Hypostomus regani</i>	“cascudo”
23	<i>Hypostomus</i> sp.	“cascudo”
24	<i>Iheringichthys labrosus</i>	“mandi-beiçudo”
25	<i>Leporinus amblyrhynchus</i>	“canivete”
26	<i>Leporinus elongatus</i>	“piapara”

Código	Espécies	Nome popular
27	<i>Leporinus friderici</i>	“piauí”
28	<i>Leporinus octofasciatus</i>	“ferreirinha”
29	<i>Lebistes reticulatus</i>	“guaru”
30	<i>Leporellus vittatus</i>	“solteira”
31	<i>Moenkhausia intermedia</i>	“pequi”
32	<i>Megalonema platanus</i>	“pati”
33	<i>Myloplus tiete</i>	“pacu-prata”
34	<i>Metynnis</i> sp.	“pacu”
35	<i>Odontostilbe</i> sp.	“pequira”
36	<i>Oreochromis niloticus</i>	“tilápia”
37	<i>Oligosarcus planaltinae</i>	“cadela”
38	<i>Piabina argentea</i>	“pequira”
39	<i>Pseudoplatystoma corruscans</i>	“pintado”
40	<i>Pimelodus fur</i>	“mandi”
41	<i>Prochilodus lineatus</i>	“curimbatá”
42	<i>Pimelodus maculatus</i>	“mandi”
43	<i>Pimelodus paranensis</i>	“mandi”
44	<i>Pimelodella</i> sp.	“mandi-chorão”
45	<i>Rhamdia quelen</i>	“bagre”
46	<i>Steindachnerina corumbae</i>	“sagüiru”
47	<i>Steindachnerina insculpta</i>	“sagüiru”
48	<i>Sternopygus macrurus</i>	“tuvira”
49	<i>Salminus maxillosus</i>	“dourado”
50	<i>Schizodon nasutus</i>	“ximborê”
51	<i>Serrasalmus spilopleura</i>	“piranha”
52	<i>Tatia neivai</i>	“jundiá”

4.2 ANÁLISE EXPLORATÓRIA DE DADOS COM REDE DE KOHONEN

A análise exploratória de dados consiste na busca por padrões em dados amostrais a partir de técnicas de visualização e de análise de agrupamentos, dentre outras.

Os estágios da análise exploratória de dados com Redes de Kohonen compreendem a escolha do conjunto de dados de entrada, o pré-processamento dos dados, a parametrização da rede, a formação do mapa, a escolha de “bons” mapas neurais e a interpretação dos resultados. A escolha de um “bom” mapa faz-se através de uma análise qualitativa, observando-se os agrupamentos e suas localizações no mapa.

4.2.1 PRÉ-PROCESSAMENTO DOS DADOS

Primeiramente os dados foram normalizados, utilizando a razão do volume de cada recurso alimentar pela soma dos volumes de todos os recursos alimentares da amostra.

O objetivo foi transformar todas as variáveis de modo que o intervalo de variação fique entre 0 e 1, mantendo a proporção da diferença entre as colunas da matriz de dados (classes de alimentos) e contemplando as diferenças entre os tamanhos dos peixes. Um peixe grande, normalmente, possui um estômago maior e seus volumes alimentares seriam discrepantes em relação a um peixe pequeno que possua o mesmo hábito alimentar. Desta forma foi possível reduzir todas as variáveis ao mesmo nível de agrupabilidade, pois as variáveis apresentam a mesma unidade (volume em ml).

Os dados foram separados em dois períodos distintos: fase rio (pré) e fase reservatório (pós e pós1). De cada planilha foram separados 70% dos dados para treinamento e 30 % para validação da rede.

4.2.2 PARAMETRIZAÇÃO DA REDE

A rede apresenta onze neurônios na camada de entrada, onde cada um representa a quantidade (volume – ml) de um recurso alimentar, encontrado no estômago do peixe, e a rede realizará os agrupamentos de acordo com estes recursos.

Dezenas de mapas foram elaborados para cada classificação, variando a topologia (retangular ou hexagonal), raio inicial e taxa de aprendizagem inicial. Os dados foram fornecidos em forma seqüencial, por espécies e de forma aleatória, até que um mapa fosse classificado como bom, ou seja, que conseguisse separar as classes de uma forma visualmente clara.

Cada época do treinamento corresponde à apresentação de todos os vetores de entrada para a rede. O critério de parada utilizado foi o número máximo de épocas, buscando um mapa que apresentasse menor erro. Para se avaliar a qualidade de um mapa, normalmente são utilizados dois critérios: resolução e preservação da topologia. Quando o trabalho envolve um conjunto de dados, com uma dimensão maior que a grade do mapa, estes critérios tornam-se contraditórios. A contradição reside no fato de que, ao escolher um mapa que apresente um menor erro quantitativo, ele deverá ser um mapa “grande”, para que existam maiores possibilidades de escolha para o neurônio vencedor. No entanto, quando isto ocorre, é aumentado substancialmente o erro topográfico, pois quando o número de neurônios aumenta, aumenta a dispersão dos vetores (pertencentes a uma mesma classe) pelos neurônios vencedores. A escolha do “melhor” mapa segue pelo bom senso, considerando estes dois fatores.

Desta forma, busca-se o “melhor” mapa, considerando os dois erros, o quantitativo, que mede a resolução, ou seja, a média da distância entre cada vetor do conjunto de dados e seu neurônio vencedor e o erro topográfico que apresenta a proporção de todos os vetores dados, para os quais, o primeiro e o segundo neurônio vencedor não são unidades adjacentes.

A convergência é garantida pelo processo de decrescimento do raio topológico e da taxa de aprendizagem e ocorre a partir do momento em que não ocorrem mais alterações significativas na matriz dos pesos. Para facilitar a convergência, os pesos são inicializados de forma aleatória, dentro do intervalo $[0, 1]$, tendo em vista que os dados foram normalizados dentro do mesmo intervalo reduzindo todas as variáveis ao mesmo nível de agrupabilidade.

4.2.3 FERRAMENTAS COMPUTACIONAIS

Este trabalho foi realizado no ambiente computacional Matlab 6.0, implementado com a caixa de ferramentas *SOM* para Matlab 5 (versão 2), disponível no site <http://www.cis.hut.fi/projects/somtoolbox/>. A caixa de ferramentas foi desenvolvida por Juha Vesanto, Johan Himberg, Esa Alhoniemi e Juha Parhankangas na *Helsinki University of Technology* – Finlândia e contém funções para criação, visualização e análise de *SOM*.

As funções utilizadas foram: `som_read_data`, `som_train_struct`, `som_make`, `som_randinit`, `som_seqtrain`, `som_linkage`, `som_quality`, `som_show` e outras. Com estas funções é possível realizar uma gama de combinações de topologias (hexagonal, retangular), tamanhos do mapa, inicialização (randômico ou linear), treinamentos (seqüencial ou por lote), funções de decrescimento de taxa de aprendizagem e do raio topológico.

CAPÍTULO V

5 OBTENÇÃO E ANÁLISE DOS RESULTADOS

5.1 INTRODUÇÃO

Foram elaborados diversos mapas variando a topologia, tamanho, funções, forma de treinamento, até a obtenção de um mapa que fosse considerado adequado. Os mapas apresentados a seguir foram treinados da mesma forma: utilizou-se para a camada de saída, uma grade bidimensional medindo 8x6, com topologia hexagonal; as inicializações dos pesos ocorreram de forma aleatória com treinamento seqüencial, os dados de entrada foram apresentados à rede de forma aleatória, pois todas as observações eram “embaralhadas” antes do treinamento, evitando-se assim que os dados fossem fornecidos seqüencialmente pelas espécies.

Para a atualização do raio de vizinhança foi utilizada a função gaussiana:

$h_{ji}(t) = e^{\frac{-d_{ji}^2}{2\sigma_t^2}}$ e para atualização da taxa de aprendizagem foi utilizada a função

$\eta(t) = \frac{\eta_0}{(1 + \frac{100t}{T_2})}$, onde d_{ij} é a distância lateral entre o neurônio vencedor i e o neurônio

excitado j , t é o número de iterações = 0, 1, 2, ..., σ_t , onde σ_t é o raio da vizinhança topológica no tempo t , η_0 é a taxa de aprendizagem inicial e T_2 é uma constante.

Na fase de ordenação, os valores inicializados foram: taxa de aprendizagem = 0,5 e o raio topológico = 2, finalizado em 1. Na fase de convergência, a taxa de aprendizagem foi

inicializada com 0,05 e o raio topológico inicializado com 1 e finalizado com 0 (onde somente o neurônio vencedor é atualizado), observando que a taxa de aprendizagem nunca chega a zero.

Para uma melhor visualização do número de agrupamentos, foi utilizada a função `som_linkage`, que calcula a matriz dos agrupamentos hierárquicos, utilizando como base uma matriz simétrica fornecida pelo cálculo da distância entre a matriz de dados e a matriz peso (neurônios). Para este procedimento, os agrupamentos são feitos por meio de ligações. Nas análises foi utilizada a distância euclidiana para o cálculo da matriz das distâncias e as ligações foram calculadas pelas ligações simples, conhecida como vizinho mais próximo, onde o agrupamento é feito juntando-se dois grupos com menor distância ou maior similaridade. Uma vez formado o novo grupo, a distância entre este novo grupo e os demais são calculados, juntando-se novamente as ligações que apresentarem menor distância e formando os agrupamentos sucessivamente. Os resultados obtidos são dispostos graficamente em um diagrama de árvore ou dendrograma que possui uma escala para observar os níveis. Para encontrar o número de agrupamentos, observa-se o dendrograma e onde este apresentar um “salto” traça-se uma reta e observando-se o número de intersecções da reta com o gráfico, este será o número de agrupamentos (MARQUES, 2003).

Uma outra forma de identificar os agrupamentos é apresentada graficamente através da *U-matrix*, obtida pela função `som_umat`. A *U-matrix* apresenta, através das unidades coloridas do mapa, as distâncias entre os agrupamentos. Verifica-se que a matriz é quase duas vezes maior que o mapa original, pois existem hexágonos adicionais entre todos os pares de unidades de mapa vizinhas. Ou seja, considera cada célula como um hexágono central cercado por outros hexágonos, para delimitação dos agrupamentos. As cores variam de acordo com uma escala de distâncias, do azul escuro ao vermelho, onde a cor azul escuro representa as

células (neurônios) mais próximas, ou seja, os agrupamentos. As cores mais claras até o vermelho representam a separação dos agrupamentos (VESANTO et al., 2000a).

A função `som_pieplane` apresenta a grade bidimensional, com gráficos no formato de “pizza” coloridos, onde cada cor indica um recurso alimentar, sendo muito útil para a identificação visual dos agrupamentos.

Na seqüência é apresentado um mapa bidimensional com as células (neurônios) contendo o número respectivo da espécie de peixe alocada. Para a elaboração deste mapa, foi analisado o gráfico individual por espécie para identificação dos agrupamentos, sendo posteriormente resumido no mapa bidimensional apresentado.

As classificações das espécies de peixes serão dispostas em tabelas, relacionando a cada agrupamento.

5.2 ANÁLISE DA FASE RIO

Esta fase compreende o período de março de 1996 a agosto de 1996, onde foram coletadas 46 espécies de peixes², mas 13³ dessas espécies apresentaram um número de estômagos analisados com alimento passível de identificação menor que dez sendo, portanto, excluídas desta análise. Assim sendo, os agrupamentos foram realizados para 33 espécies, totalizando 1845 observações. Estas observações foram separadas para o treinamento (1318) e para validação (527).

Na Tabela 4 é apresentado um resumo do treinamento realizado, onde observam-se os valores dos erros obtidos. A função `som_quality` da caixa de ferramentas fornece os erros quantitativo e topográfico. O erro quantitativo (Eq) mede a resolução do mapa, ou seja, a

² Espécies: 1; 2; 3; 4; 5; 6; 7; 8; 9; 10; 11; 12; 14; 15; 16; 17; 18; 20; 21; 22; 23; 24; 25; 26; 27; 28; 29; 31; 32; 33; 34; 35; 37; 38; 40; 41; 42; 44; 45; 46; 47; 48; 49; 50; 51; 52.

³ Espécies: 5; 8; 14; 21; 26; 28; 32; 34; 37; 47; 48; 49; 51.

média da distância euclidiana entre cada vetor do conjunto de dados e seu neurônio vencedor e é dado por:

$$Eq = \frac{\sum \sqrt{(\text{neurônio vencedor} - \text{vetor de entrada})^2}}{n}, \text{ onde } n \text{ é o número de amostras}$$

do conjunto de dados.

O erro topográfico apresenta a proporção de todos os vetores dados para os quais o primeiro e o segundo neurônio vencedor não são unidades adjacentes.

O erro quantitativo não é representativo, pois utiliza a matriz peso dos neurônios vencedores e a matriz dos dados para o cálculo da distância. Como a matriz peso dos neurônios vencedores não é normalizada, este valor depende da dimensão dos dados e, desta forma, não é possível avaliar a qualidade de um determinado mapa em relação a mapas obtidos em outros treinamentos.

Por esta razão foi calculado o erro geral, que apresenta a porcentagem de amostras que foram alocadas fora da região de seu agrupamento. Para o cálculo foram utilizados os mapas individuais de cada espécie de peixe, observando-se a região destinada a cada agrupamento. O erro geral foi obtido pela razão do número de amostras alocadas erroneamente pelo número total na amostra. Sendo uma medida adimensional, pode ser utilizada para uma comparação entre mapas obtidos em outros treinamentos.

Desta forma procura-se obter a “qualidade” do mapa. Como os erros encontrados foram pequenos, considera-se o resultado obtido como bom. Os valores dos vetores de entrada variam de 0 a 1 e obteve-se um erro quantitativo de 0,1379 para o conjunto de treinamento e de 0,1495 para o conjunto de validação.

Os erros topográficos encontrados foram: 2,30% no treinamento e 4,80% na validação, levando-se em consideração que o mapa apresenta 48 neurônios para realizar o agrupamento de 1318 amostras no treinamento e 527 amostras na validação.

Foi encontrado um erro geral de 9,25% no treinamento, onde 122 amostras do total de 1318 foram alocadas em células não pertencentes às regiões de seus agrupamentos e um erro geral no valor de 8,73% na validação da rede, onde 46 amostras do total de 527 foram alocadas erroneamente. Os erros foram considerados aceitáveis, devido a plasticidade alimentar da maioria das espécies.

Tabela 4 Resumo treinamento *SOM*, fase rio.

		Nº ÉPOCAS	ERRO		
			Quantitativo	Topográfico	Geral
TREINAMENTO	ORDENAÇÃO	50	0,1379	0,0230 (2,30%)	9,25%
	CONVERGÊNCIA	300			
VALIDAÇÃO			0,1495	0,0480 (4,80%)	8,73%

Portanto, o mapa bidimensional com 48 neurônios na camada de saída, dispostos numa matriz 8x6, apresentou resultados satisfatórios, com separação de quatro agrupamentos iniciais, conforme Figura 6.

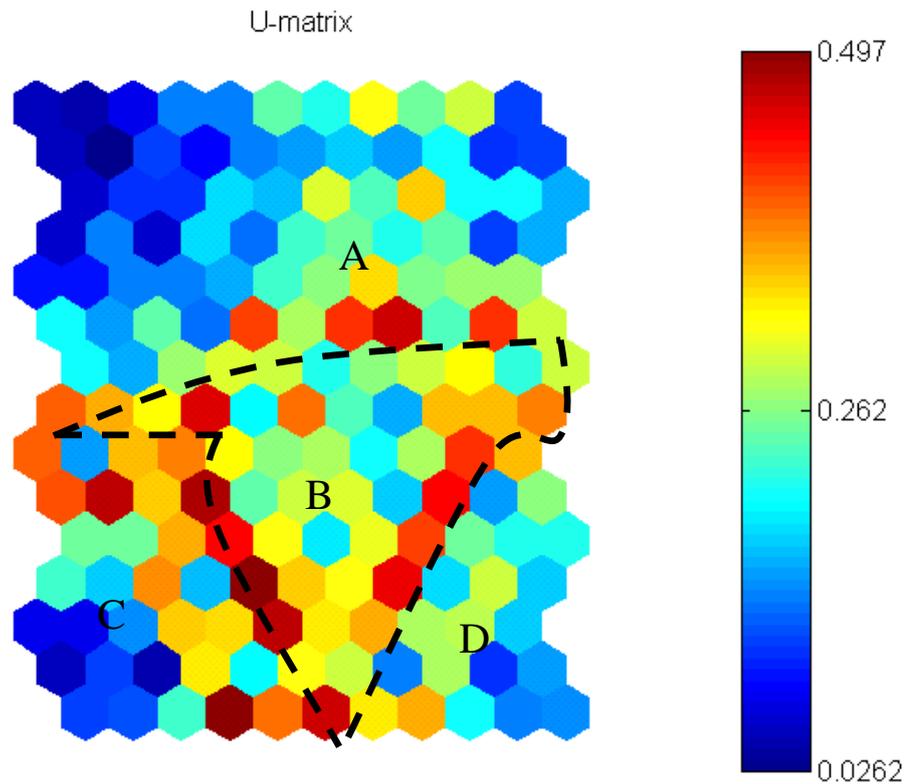
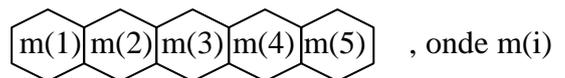


Figura 6 - *U-matrix* com separação dos agrupamentos iniciais – fase rio.

A *U-matrix* apresenta uma matriz de distância unificada de um *SOM*. É apresentado a seguir um exemplo ilustrativo:

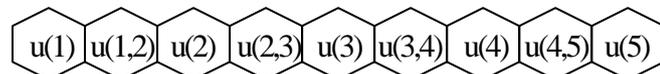
Seja um *SOM* de dimensão 1x5:



, onde $m(i)$

denota uma unidade do mapa.

A *U-matrix* será um vetor 1x9 da seguinte forma:



onde $u(i,j)$ é a distância entre $m(i)$ e $m(j)$, onde i e j são unidades do mapa *SOM* 1x5 e $u(k)$ é uma unidade inserida que representa a média dos valores circunvizinhos, por exemplo $u(3)=(u(2,3)+u(3,4))/2$.

Desta forma, pode-se observar que a separação do mapa ocorreu em quatro regiões: A, B, C e D, apresentadas na Figura 6. A linha tracejada apresenta uma idéia da divisão dos agrupamentos (que apresenta os hexágonos em cores mais claras tendendo ao vermelho),

conforme mostrado na legenda das distâncias, onde a cor azul escuro representa uma distância de 0,0262 entre os agrupamentos e a cor vermelho uma distância de 0,497, ou seja, a separação os agrupamentos, pois a média da distância entre as unidades vizinhas é grande. Observa-se que a separação ocorreu nos hexágonos de tonalidade verde clara (em torno de 0,26) até o vermelho (0,497). Estes valores são melhores compreendidos no dendrograma apresentado na Figura 7.

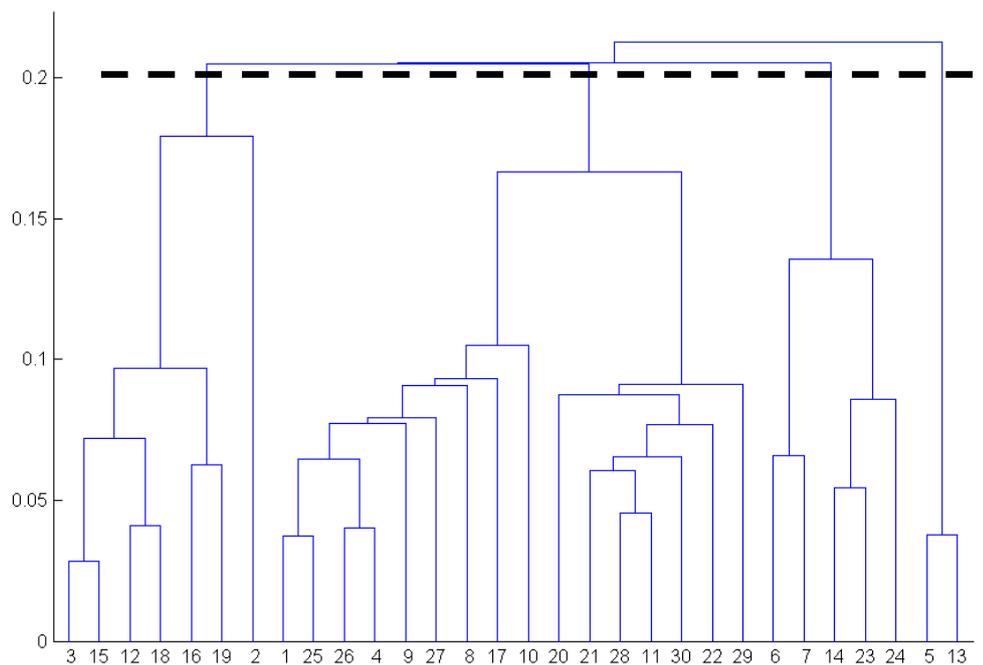


Figura 7- Dendrograma dos agrupamentos iniciais da fase rio.

Observa-se na Figura 7 a reta tracejada na altura de 0,2, interceptando quatro pontos do dendrograma, indicando a ocorrência de quatro grupos distintos, considerando o valor 0,2 como a distância para a separação dos agrupamentos (tonalidade verde claro na Figura 6).

Para uma visualização nítida da separação dos recursos alimentares no mapa, veja Figura 8, que apresenta a *U-matrix* (matriz indicativa das distâncias entre os agrupamentos) e os mapas indicativos da localização dos recursos alimentares individualmente. Um detalhe a ser observado nesta figura, é relativo as cores e a indicação das distâncias entre as células,

pois na *U-matrix*, quanto mais a cor se aproxima do vermelho, mais distantes estão os agrupamentos e, na apresentação individual dos recursos alimentares, a escala é inversa, quanto mais próxima a cor estiver do vermelho mais próximos estarão os agrupamentos dos recursos alimentares.

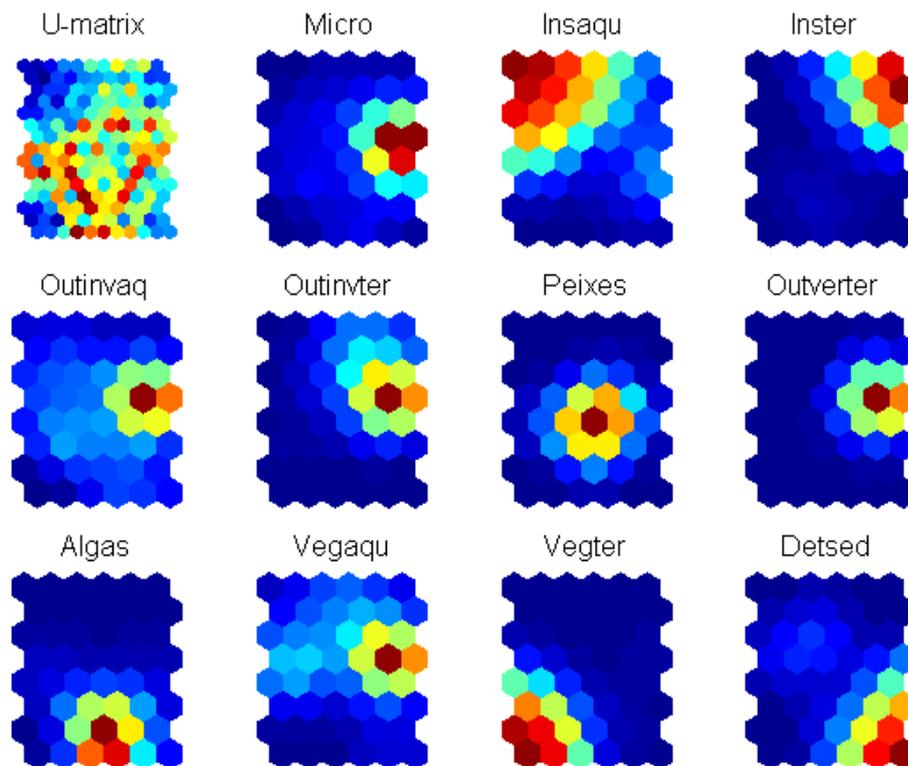


Figura 8 - *U-matrix* e recursos alimentares – agrupamento inicial da fase rio.

(onde: **Micro**=microcrustáceos, **Insaqu**=insetos aquáticos, **Inster**=insetos terrestres, **Outinvaq**=outros invertebrados aquáticos, **Outinvter**=outros invertebrados terrestres, **Peixes**=peixes, **Outverter**=outros vertebrados, **Algas**=algas, **Vegaqu**=vegetais aquáticos, **Vegter**=vegetais terrestres, **Detsed**=detrito/sedimento).

Desta forma é possível identificar inicialmente quatro grupos bem distintos. Na região B os peixes, na região D os detritos e sedimentos, na região C os vegetais terrestres, sendo que as algas encontram-se tanto na região C como na D, como indicativo de que não existe uma espécie de peixe que possa ser classificada essencialmente como algívora (comedora de

algas), pois ingerem em conjunto os recursos vegetais terrestres e/ou detritos / sedimentos. Os demais recursos alimentares estão dispostos na região A.

O rotulamento das células, indicando qual espécie pertence a cada grupo, pode ser visualizado na Figura 9. Foi utilizado o número das espécies que apresentaram maior frequência por célula (em número de amostras). Este processo não é o ideal, pois beneficia as espécies que se apresentam na amostra em maior número de indivíduos. Mas, é o mais indicado para uma visualização inicial.

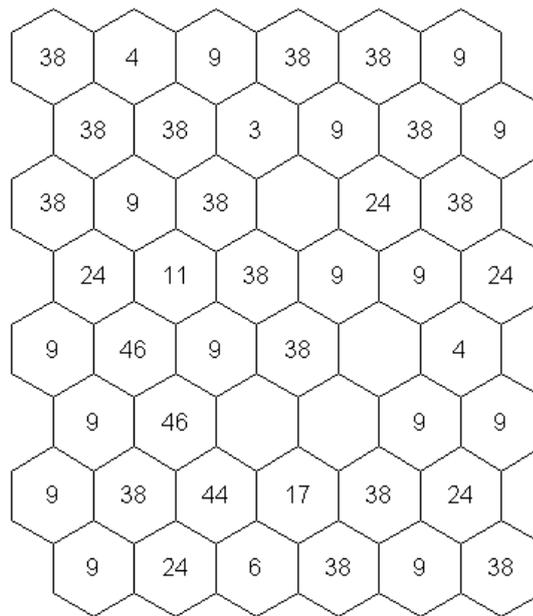


Figura 9 - Rótulos das células do agrupamento inicial – fase rio.

Observa-se na Figura 9 que a espécie 38 predomina em todo o mapa, devido a grande plasticidade alimentar e por se apresentar em maior número de indivíduos na amostra utilizada para o treinamento. Para a identificação das espécies em cada célula, foram elaboradas figuras individuais por espécies, com o rotulamento, possibilitando desta forma as identificações das espécies nos agrupamentos. Além da espécie 38, mais quatro espécies: 2, 3, 4 e 29 também apresentaram grande plasticidade alimentar (aparecendo em mais de um

agrupamento em número significativo), conforme pode ser observado na Figura 10 que apresenta o mapa com o rotulamento destas cinco espécies (o número entre parênteses indica a frequência com que cada espécie aparece na célula). Estas espécies ingerem quase todos os recursos alimentares, não apresentando nenhuma especificidade na dieta, por isto foram agrupadas como generalistas. As demais espécies agrupadas nas regiões A, B, C ou D do mapa da Figura 6, foram classificadas como especialistas.

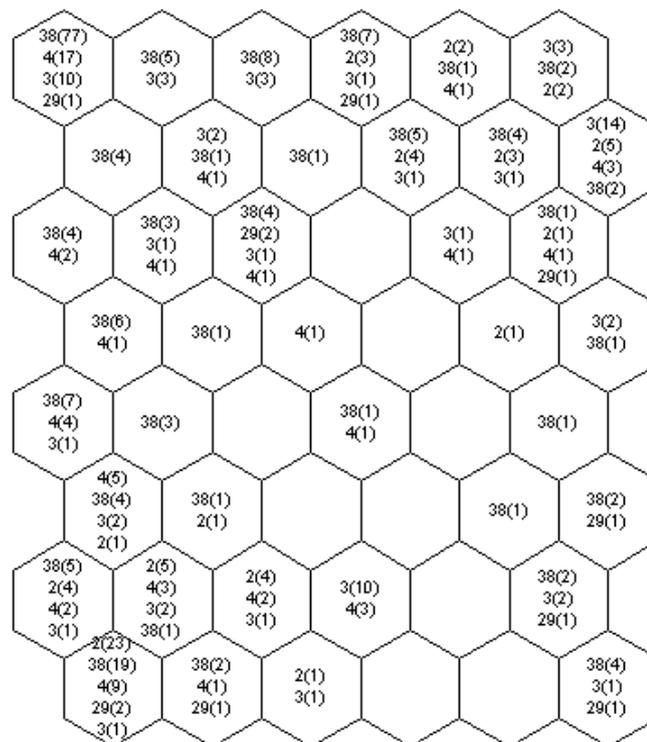


Figura 10 - Rótulos das células do agrupamento inicial das espécies 2, 3, 4, 29 e 38 – fase rio.

A Figura 11 apresenta o mapa, dividido nas 48 células, onde em cada célula foi elaborado um gráfico no formato de “pizza”, indicando a participação de cada recurso alimentar.

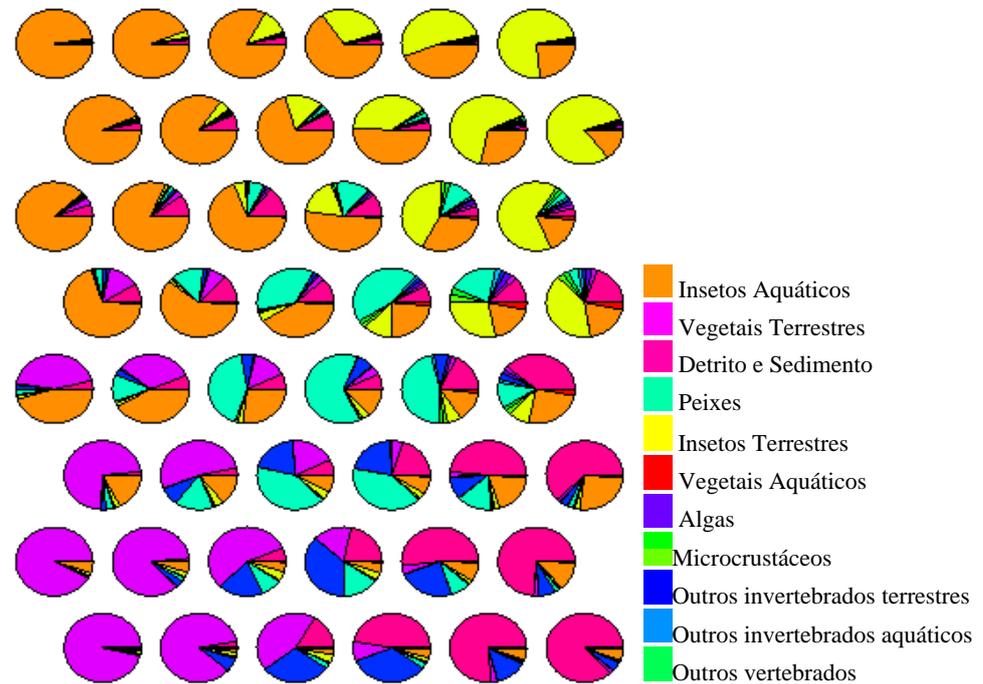


Figura 11 - Apresentação do mapa com separação da contribuição de cada recurso alimentar.

Após a identificação das espécies em cada célula foi possível a classificação das mesmas nas categorias tróficas apresentadas na Figura 12.

Um resumo dos agrupamentos é apresentado na Tabela 5, onde ocorre a separação das espécies entre os dois grandes grupos: generalistas (comem de tudo) e especialistas. Dentre os especialistas, foi possível a identificação de quatro categorias tróficas: região A – insetívoros, região B – piscívoros, região C – herbívoros e região D – detritívoros.

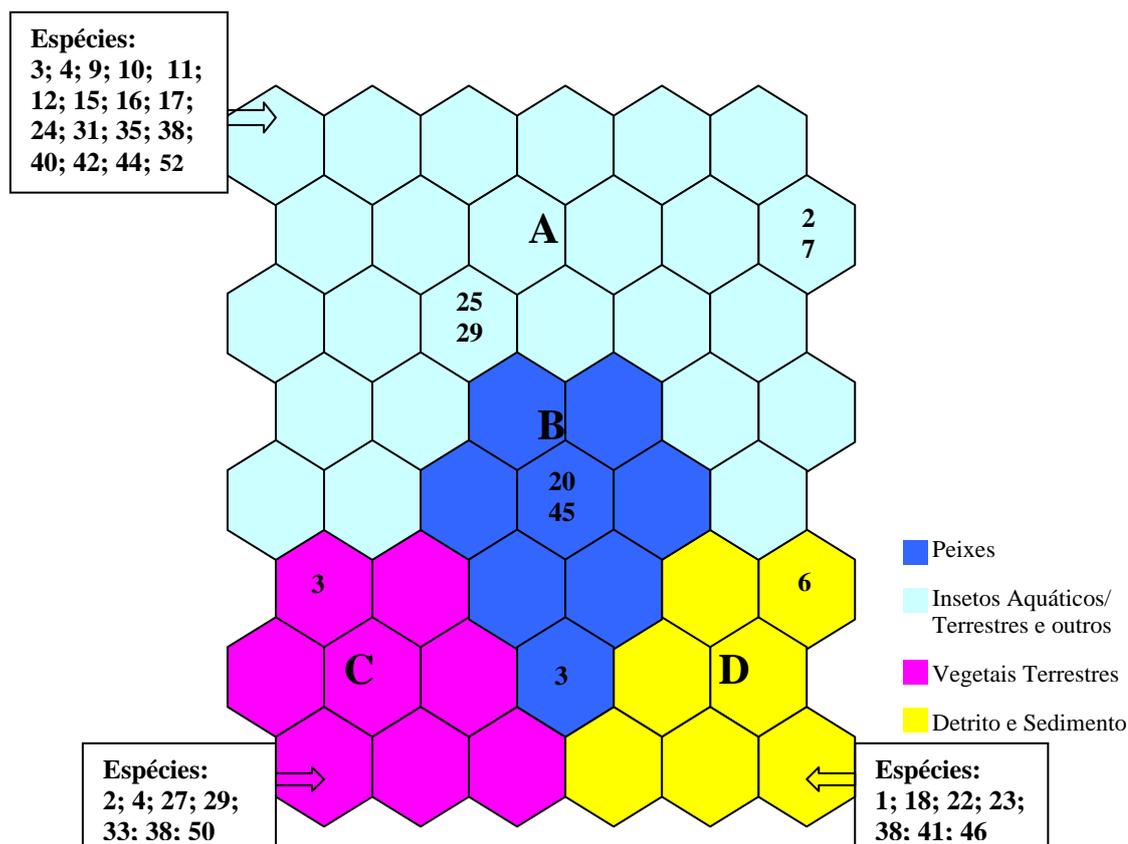


Figura 12 - Identificação das espécies por agrupamento – fase rio.

Tabela 5 Agrupamento inicial da fase rio.

	GRUPOS	ESPÉCIES
Generalistas		2, 3, 4 ,29, 38
Especialistas	A – insetívoros	7, 9, 10, 11, 12, 15, 16, 17, 24, 25, 31, 35, 40, 44, 42, 52
	B – piscívoros	20, 45
	C – herbívoros	27, 33, 50
	D – detritívoros	1, 6, 18, 22 ,23, 41, 46

O grupo A – insetívoros, é formado por um número bem elevado de espécies, onde não foi possível uma separação mais detalhada a partir dos recursos alimentares. Observa-se na Figura 8 que a região no mapa é a localização dos seguintes recursos alimentares: microcrustáceos, insetos aquáticos, insetos terrestres, outros invertebrados aquáticos, outros invertebrados terrestres, outros vertebrados e vegetais aquáticos.

Desta forma, foi realizado um novo treinamento com a apresentação do conjunto de dados formados pelas 16 espécies agrupadas na região A. O mapa obtido é apresentado na Figura 13.

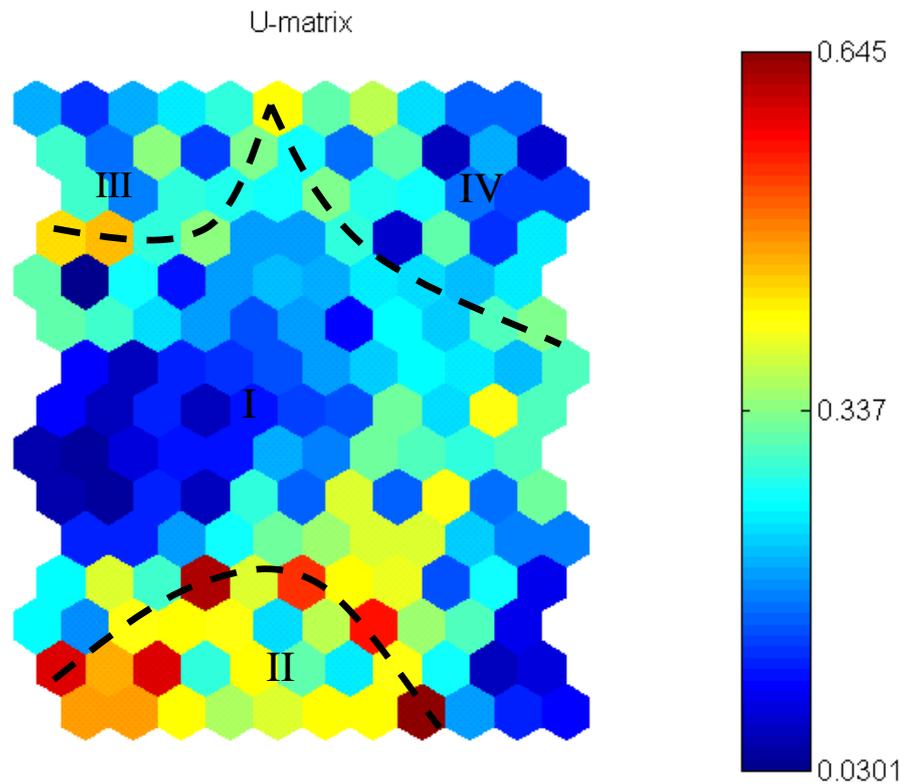


Figura 13 - U-matrix com separação dos agrupamentos da região A – fase rio.

De maneira análoga a análise anterior, as espécies agrupadas na região A - insetívoros foram separadas em quatro sub-grupos: I, II, III e IV.

A classificação das espécies de acordo com o recurso alimentar explorado foi possível através da separação dos mapas individuais por espécies, observando a separação dos recursos alimentares, conforme indicado na Figura 14.

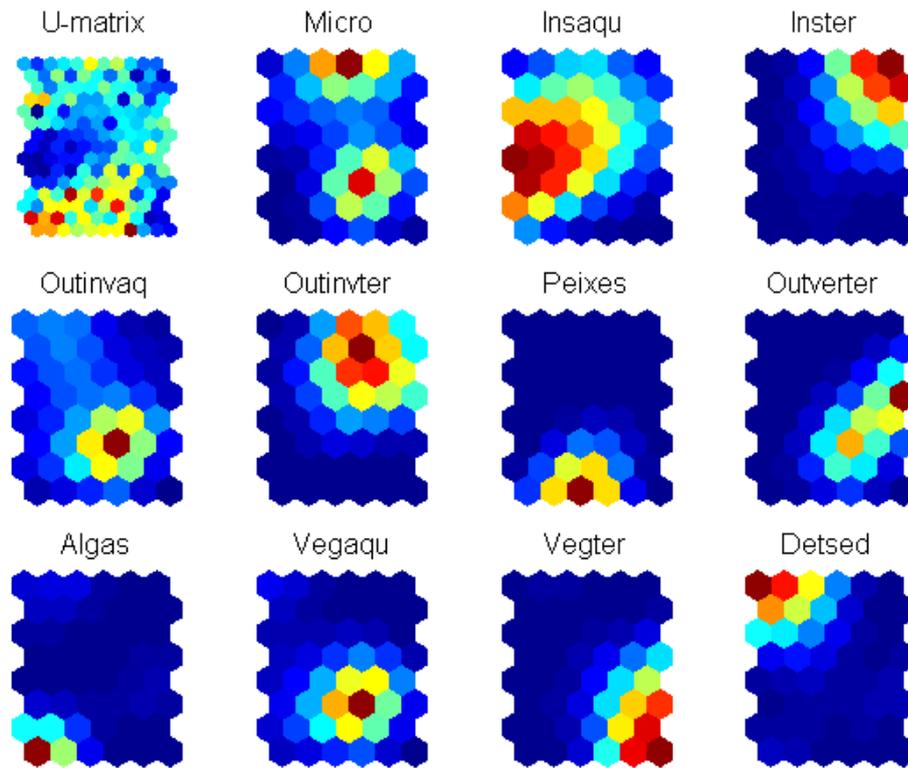


Figura 14 - U-matrix e recursos alimentares dos sub-grupamentos – fase rio.
 (onde: Micro=microcrustáceos, Insaqu=insetos aquáticos, Inster=insetos terrestres, Outinvaq=outros invertebrados aquáticos, Outinvter=outros invertebrados terrestres, Peixes=peixes, Outverter=outros vertebrados, Algas=algas, Vegaqu=vegetais aquáticos, Vegter=vegetais terrestres, Detsed=detrito/sedimento).

Para identificação das espécies em cada célula, foram elaborados gráficos individuais por espécie e assim foi possível realizar as identificações apresentadas na Figura 15.

A Figura 16 apresenta um mapa bidimensional com 48 células (neurônios), onde para cada uma delas foi confeccionado um gráfico no formato de “pizza”, indicando a participação de cada recurso alimentar nas células.

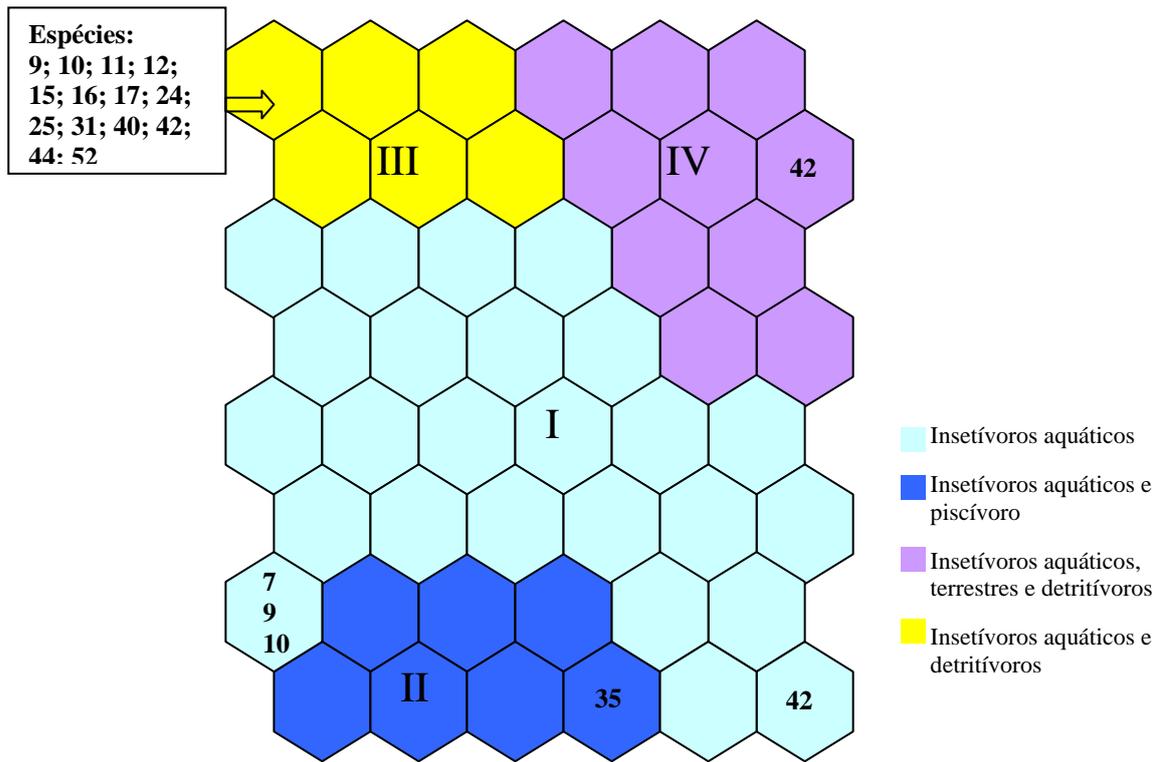


Figura 15 - Identificação das espécies dos sub-agrupamentos – fase rio.

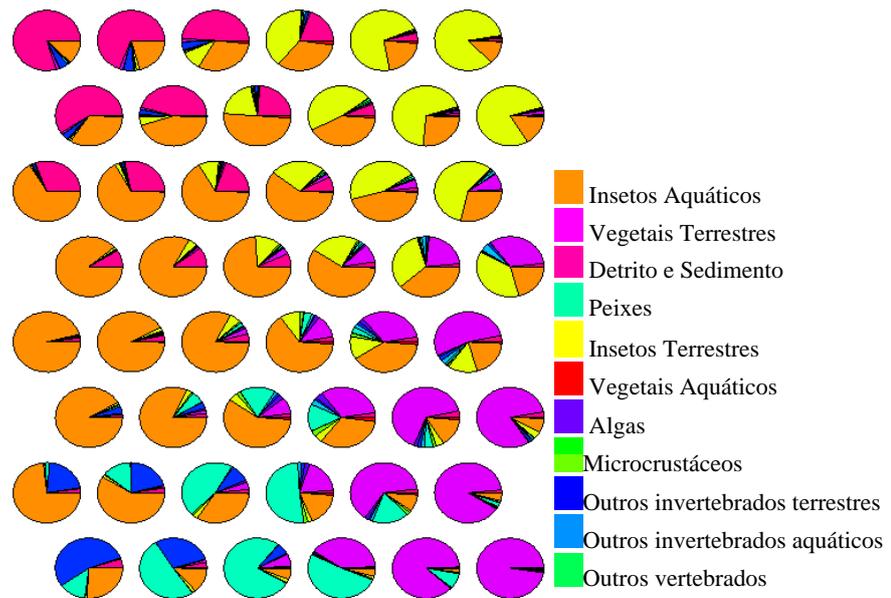


Figura 16 - Apresentação do mapa com separação da contribuição de cada recurso alimentar.

A Tabela 6 apresenta um resumo da classificação trófica das espécies insetívoras.

Tabela 6 - Sub-agrupamentos da região A – insetívoro, fase rio.

SUB-GRUPOS	ESPÉCIES
I – insetívoros aquáticos	7
II – insetívoros aquáticos/piscívoros	35
III – insetívoros aquáticos/detrítívoros	9, 10, 11, 12, 15, 16, 17, 24, 25, 31, 40, 44, 52
IV – insetívoros aquáticos, terrestres e detritívoro	42

Observa-se que ocorreram agrupamentos distintos entre os insetívoros. Desta forma, foi possível realizar separações das espécies que ingerem insetos aquáticos das que se alimentam de insetos aquáticos associado a outros recursos alimentares como peixe, detrito / sedimento ou insetos terrestres. A Tabela 7 apresenta a classificação trófica das espécies de peixes no reservatório de Corumbá, na fase anterior do represamento.

Tabela 7 Classificação trófica das espécies de peixes no reservatório de Corumbá- fase rio.

	GRUPOS	ESPÉCIES	
Generalistas		2, 3, 4 ,29, 38	
Especialistas	A – Insetívoros	I – Insetívoros aquáticos	7
		II – Insetívoros aquáticos e piscívoros	35
		III – insetívoros aquáticos e detritívoros	9, 10, 11, 12, 15, 16, 17, 24, 25, 31, 40, 44, 52
		IV – insetívoros aquáticos, terrestres e detritívoros	42
	B – Piscívoros	20, 45	
	C – Herbívoros	27, 33, 50	
	D - Detritívoros	1, 6, 18, 22 ,23, 41, 46	

5.2 ANÁLISE DA FASE RESERVATÓRIO

Esta análise compreende a fase posterior ao represamento, ou seja, a fase de reservatório. Geralmente a fase de enchimento dura mais que um ano, dependendo da vazão dos rios que formarão o reservatório e do índice pluviométrico. No reservatório de Corumbá o processo foi rápido, devido ao período de intensas chuvas que caíram na região durante o enchimento. É abordado, neste trabalho, o período de março de 1997 a fevereiro de 1999, onde foram coletadas 48 espécies de peixes⁴ mas 12⁵ dessas espécies apresentaram um número de estômagos analisados com alimento passível de identificação menor que dez e foram excluídas da análise. Assim sendo, os agrupamentos foram realizados para 36 espécies, totalizando 5492 observações. Estas observações foram separadas para o treinamento (3872) e para validação (1620).

O mapa bidimensional com 48 neurônios na camada de saída, dispostos numa matriz 8x6, apresentou uma separação bem nítida dos agrupamentos para esta situação.

A Tabela 8 apresenta um resumo do treinamento realizado, assim como os erros obtidos no treinamento e validação. Um detalhamento sobre o cálculo dos erros quantitativos e topográficos foi apresentado na seção 5.2. Os valores encontrados para os erros quantitativos (que representam a média da distância euclidiana do vetor de entrada e de seu respectivo neurônio vencedor) foram: 0,0995 para o treinamento e 0,0929 para a validação dos dados. Os erros topográficos obtidos foram: 1,85% para o treinamento e 1,68% para a validação.

Observa-se que os erros quantitativo e topográfico obtidos na fase reservatório foram em torno de 40% menores que os obtidos na fase rio, com um mapa apresentando dimensões e

⁴ Espécies: 1; 2; 3; 4; 5; 6; 7; 9; 11; 12; 14; 15; 17; 18; 19; 20; 21; 22; 23; 24; 25; 26; 27; 28; 29; 31; 33; 34; 35; 36; 37; 38; 39; 40; 41; 42; 43; 44; 45; 46; 47; 48; 49; 50; 51; 52.

⁵ Espécies: 3; 7; 11; 12; 15; 19; 23; 29; 34; 35; 36; 48.

características idênticas, assim como o número de épocas utilizadas no treinamento. A diferença ocorreu no número de amostras apresentadas à rede, quase o triplo.

O erro geral encontrado na fase reservatório representa aproximadamente um terço dos valores obtidos na fase rio. Foi encontrado um erro geral de 3,05% no treinamento, onde 118 amostras do total de 3872 foram alocadas em células não pertencentes às regiões de seus agrupamentos e um erro geral no valor de 3,09% na validação da rede, onde 50 amostras do total de 1620 foram alocadas erroneamente.

Não é possível realizar comparações entre os mapas resultantes dos treinamentos baseadas nos erros quantitativos e topográficos, pois seus valores não são adimensionais. Mas a comparação com o erro geral é possível e conclui-se que foi bem menor, indicando que o mapa resultante da fase reservatório é muito bom. Tal diferença pode ser explicada pela quantidade de amostras (três vezes maior), pois conforme descrito na seção 3.3, a redundância dos dados de entrada é necessária para o aprendizado.

No algoritmo de Kohonen, o treinamento é não supervisionado, dificultando o processo de validação da rede, pois não é possível mensurar os erros como ocorre nos treinamentos supervisionados, onde se constata exatamente os valores dos erros cometidos.

Tabela 8 – Resumo treinamento SOM, fase reservatório.

		Nº ÉPOCAS	ERRO		
			Quantitativo	Topográfico	Geral
TREINAMENT O	ORDENAÇÃO	50	0,0995	0,0185	3,05%
	CONVERGÊNCIA	300		(1,85%)	
VALIDAÇÃO			0,0929	0,0168 (1,68%)	3,09%

Considerando os erros obtidos, o mapa escolhido e classificado como bom é apresentado na Figura 17, onde se observa a separação de quatro agrupamentos. A linha tracejada nos hexágonos em tonalidades de verde claro, amarelo e vermelho apresenta uma idéia da divisão desses agrupamentos. Observa-se na legenda da Figura 17 que a tonalidade verde representa uma distância de 0,436 entre os agrupamentos e o vermelho escuro uma distância de 0,859.

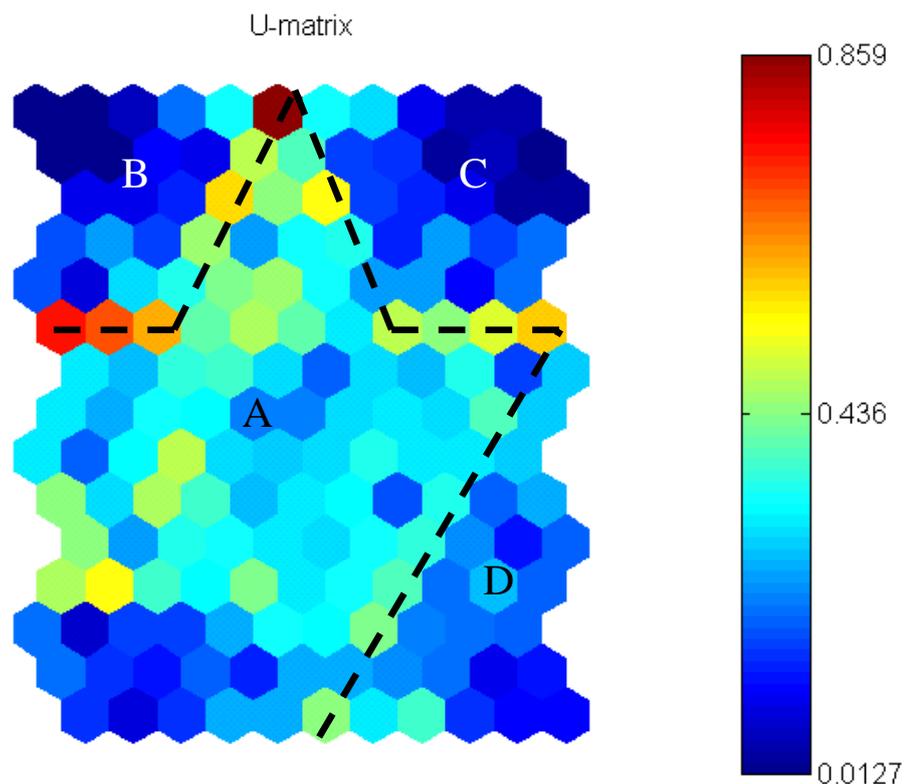


Figura 17 – U-matrix com separação dos agrupamentos – fase reservatório.

Os valores encontrados para a separação dos agrupamentos podem ser identificados no dendrograma apresentado na Figura 18, onde se observa a reta tracejada na altura de 0,2, interceptando o gráfico em quatro pontos, indicando a existência de quatro agrupamentos. É possível observar na Figura 17, que o valor 0,2 para a distância dos agrupamentos pode ser localizado nos hexágonos em tonalidades de azul claro, ciano e verde.

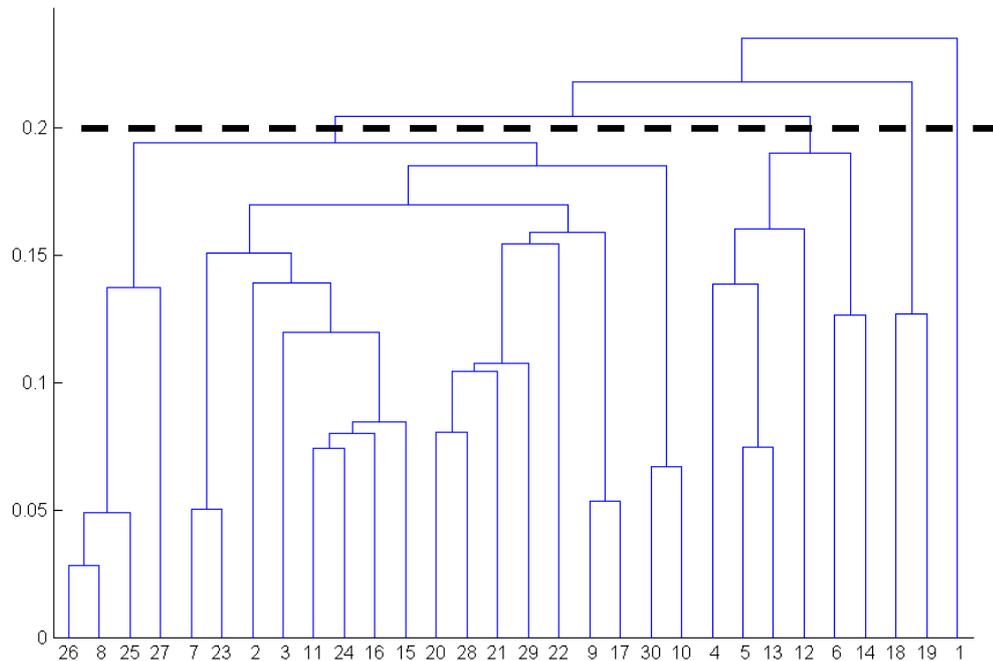


Figura 18 – Dendrograma dos agrupamentos iniciais da fase reservatório.

Para uma melhor visualização da separação dos recursos alimentares no mapa, observe a Figura 19, onde é apresentada a *U-matrix* e os mapas indicativos da localização dos recursos alimentares individualmente. Recordando que as cores indicativas na *U-matrix* e dos mapas dos recursos alimentares individuais possuem representações contrárias.

Na Figura 19 é possível a identificação de quatro grupos distintos: Na região B os peixes, na região C os vegetais terrestres e na região D os detritos e sedimentos. O recurso alimentar algas ficou diluído entre as regiões C e D, indicando que as espécies de peixes costuma se alimentar tanto com vegetais terrestres e algas, como com detritos e sedimentos associados a algas. A combinação desses alimentos já foi observada na análise anterior da fase rio. Os demais recursos alimentares: microcrustáceos, insetos aquáticos, insetos terrestres, outros invertebrados aquáticos, outros invertebrados terrestres, outros vertebrados e vegetais aquáticos ficaram dispostos na região A.

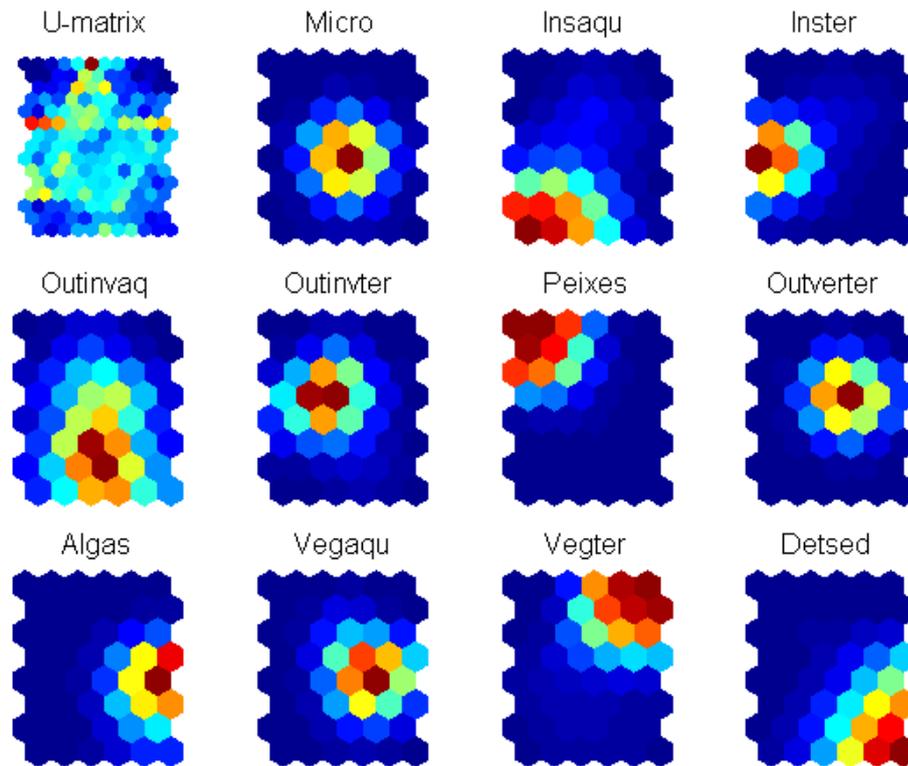


Figura 19 – U-matrix e recursos alimentares - fase reservatório

(onde: **Micro**=microcrustáceos, **Insaqu**=insetos aquáticos, **Inster**=insetos terrestres, **Outinvaq**=outros invertebrados aquáticos, **Outinvter**=outros invertebrados terrestres, **Peixes**=peixes, **Outverter**=outros vertebrados, **Algas**=algas, **Vegaqu**=vegetais aquáticos, **Vegter**=vegetais terrestres, **Detsed**=detrito/sedimento).

Para uma completa identificação das espécies em cada célula, foram elaborados gráficos das espécies individualmente, sendo possível uma classificação detalhada de todas as espécies de acordo com o rotulamento. Com este processo foi possível a identificação de sete espécies que apareceram dispersas pelo mapa: 2, 4, 26, 27, 31, 38 e 42, que serão classificadas como generalistas. O fato é explicado pela elevada plasticidade alimentar desses peixes e também pelas mudanças ocorridas no ambiente, que fez com que alterassem suas dietas para que garantissem suas sobrevivências. As demais espécies foram classificadas como especialistas, por estarem agrupadas nas regiões claramente delimitadas por um tipo específico de alimento.

A Figura 20 apresenta o rotulamento das espécies generalistas no mapa, onde o número entre parênteses ao lado do número da espécie indica a frequência da espécie na célula.

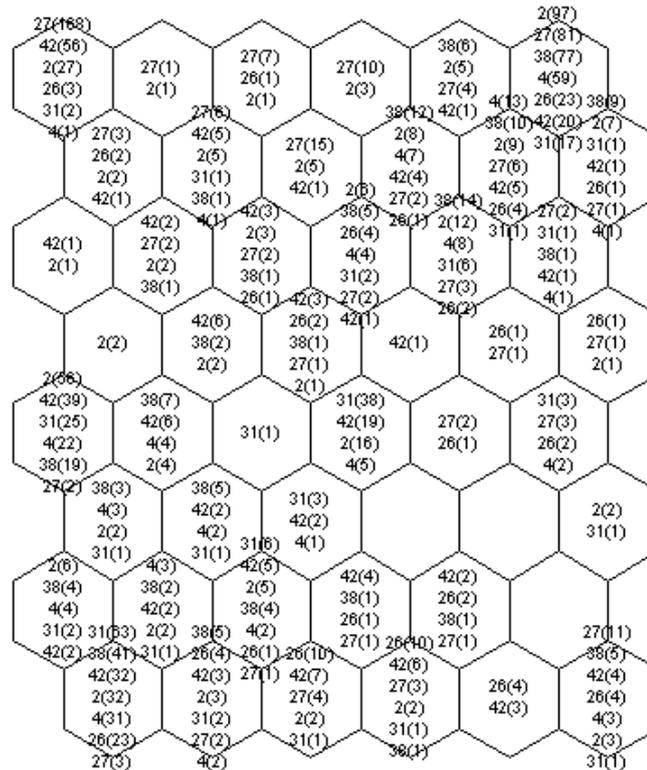


Figura 20 - Rótulos das células do agrupamento inicial das espécies 2, 4, 26, 27, 31, 38 e 42 – fase reservatório.

A Figura 21 apresenta o mapa, dividido em 48 células, onde em cada célula foi elaborado um gráfico no formato de “pizza”, indicando a participação de cada recurso alimentar.

Para a identificação das espécies em cada célula, foram elaboradas figuras individuais por espécies, com o rotulamento, possibilitando desta forma as identificações das espécies por categorias tróficas apresentadas na Figura 22.

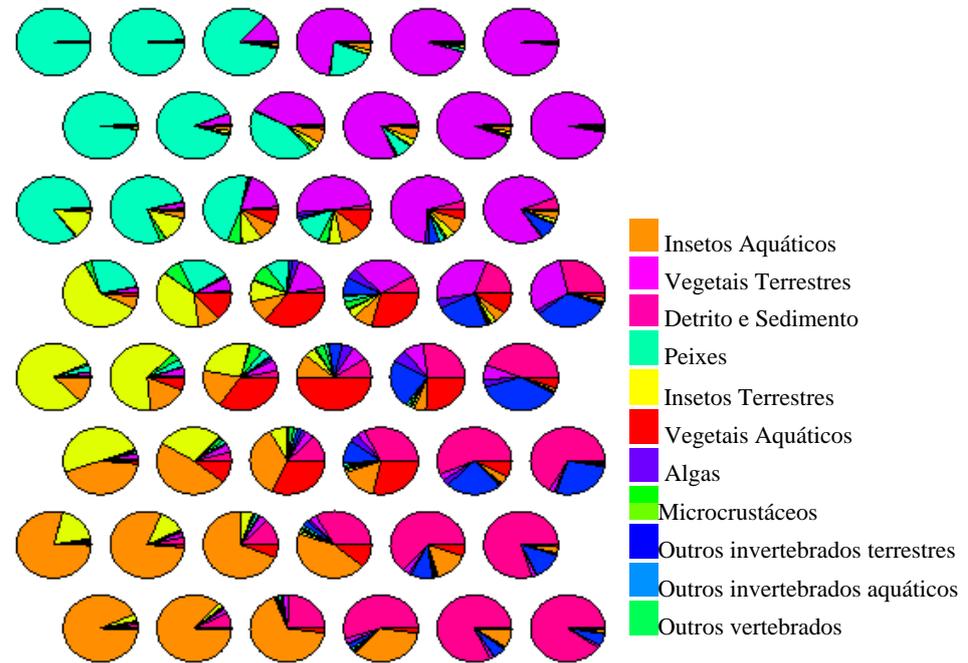


Figura 21 – Apresentação do mapa com separação da contribuição de cada recurso alimentar.

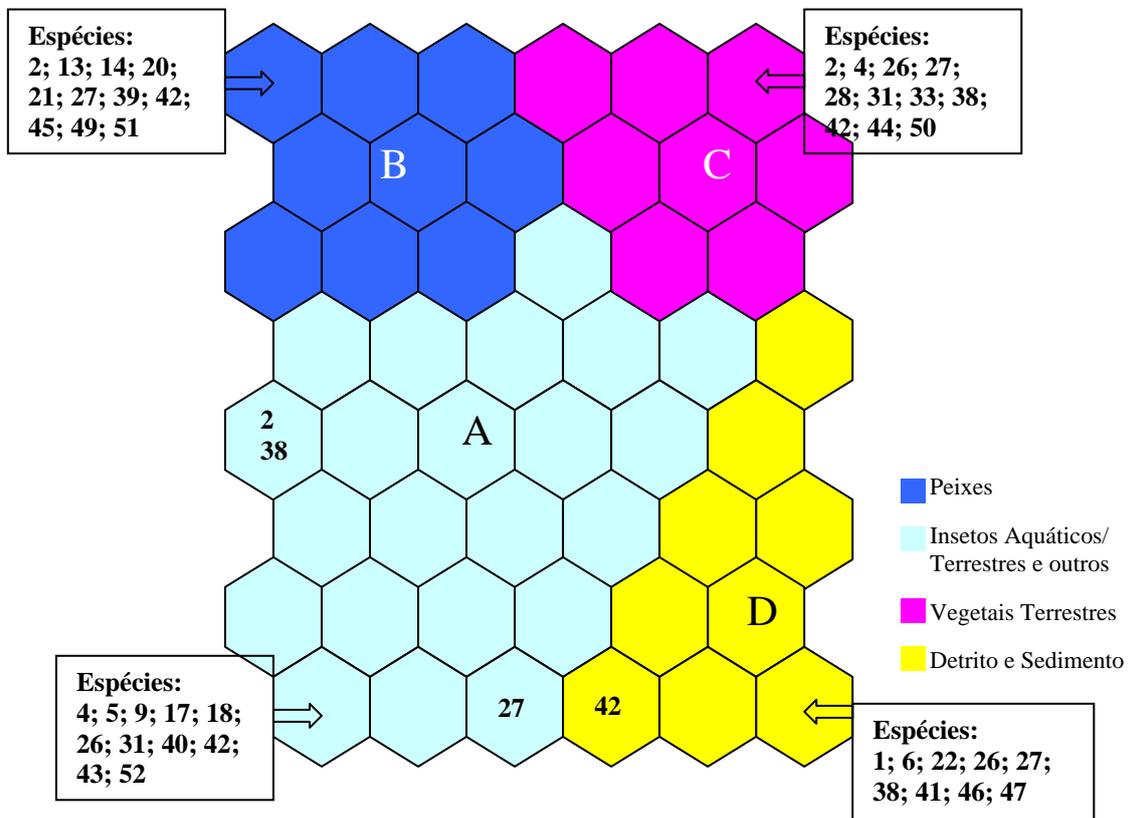


Figura 22 – Identificação das espécies por agrupamento – fase reservatório

Um resumo dos agrupamentos é apresentado na Tabela 9, onde ocorre a separação das espécies entre os dois grandes grupos: generalistas (comem de tudo) e especialistas. Dentre os especialistas, ocorreu a divisão de quatro categorias tróficas: região A – insetívoros, região B – piscívoros, região C – herbívoros e região D – detritívoros.

Tabela 9 – Agrupamento inicial da fase reservatório.

	GRUPOS	ESPÉCIES
Generalistas		2; 4; 26; 27; 31; 38; 42;
Especialistas	A – insetívoros	5; 9; 17; 18; 24; 25; 30; 37; 40; 43; 52
	B – piscívoros	13; 14; 20; 21; 39; 45; 49; 51
	C – herbívoros	28; 33; 44; 50
	D -detritívoros	1; 6; 22; 41; 46; 47;

O grupo dos insetívoros (região A), apresentou um grande número de espécies, assim como na fase rio, sendo necessário um novo treinamento envolvendo estas espécies visando uma classificação mais detalhada.

Portanto, um novo conjunto de dados formado pelas 11 espécies agrupadas na região A foi apresentado a rede para um novo treinamento. A Figura 23 mostra que o novo treinamento resultou em um mapa que proporcionou a divisão dos insetívoros (região A) em quatro sub-grupos: I, II, III e IV. Observa-se na Figura 23, que a linha tracejada que apresenta uma idéia da separação dos agrupamentos foi realizada sobre os hexágonos que apresentavam tonalidades ciano para verde claro, chegando ao vermelho, o que indica uma separação dos agrupamentos numa distância de 0,2 aproximadamente (verificado na legenda da Figura 23).

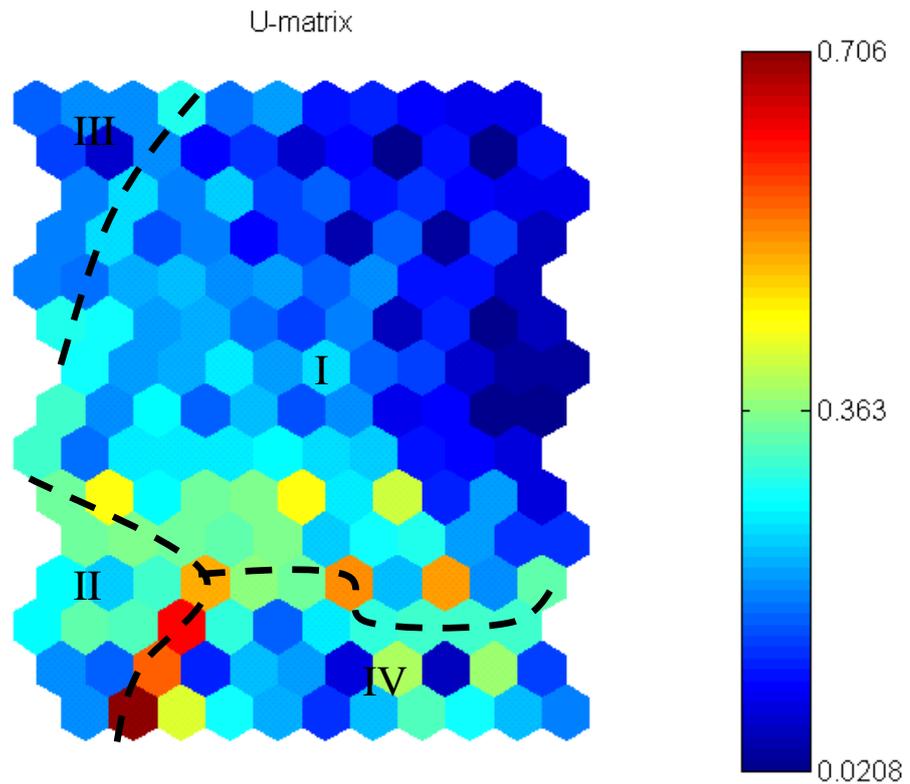


Figura 23 – U-matrix com separação dos agrupamentos da região A- fase reservatório.

A classificação das espécies de acordo com o recurso alimentar explorado foi possível através da separação dos mapas individuais por espécies, observando a separação dos recursos alimentares, conforme indicado na Figura 24. Os recursos alimentares identificados como outros invertebrados terrestres e outros vertebrados, são visualizados na Figura 24 com a tonalidade verde, o que significa que não apresentaram valores para a análise destas espécies no treinamento, no caso indica a inexistência desses recursos alimentares no mapa.

O rotulamento das espécies no mapa, separado pelas regiões é apresentado na Figura 25.

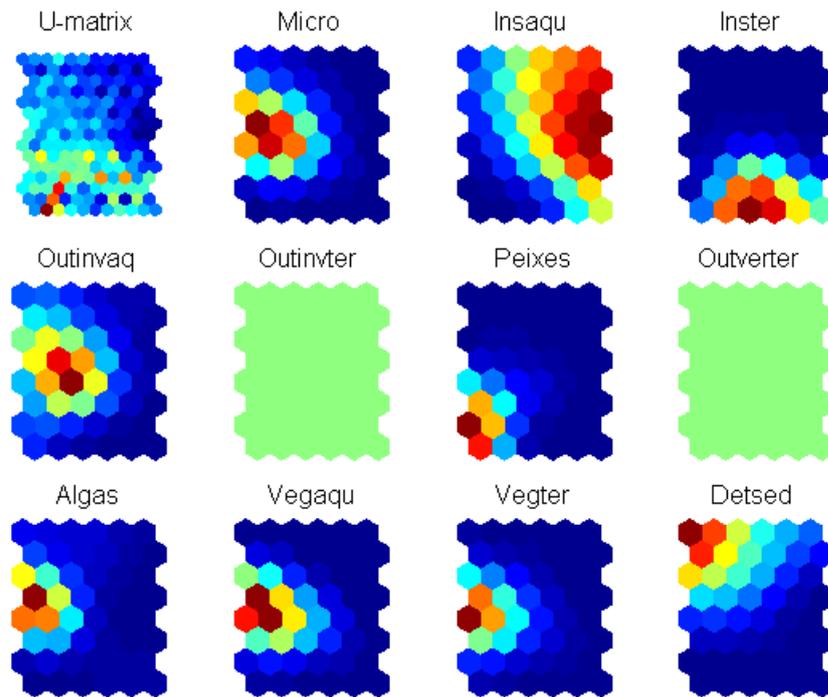


Figura 24 – U-matrix e recursos alimentares dos subagrupamentos – fase reservatório.

(onde: Micro=microcrustáceos, Insaqu=insetos aquáticos, Inster=insetos terrestres, Outinvaq=outros invertebrados aquáticos, Outinvter=outros invertebrados terrestres, Peixes=peixes, Outverter=outros vertebrados, Algas=algas, Vegaqu=vegetais aquáticos, Vegter=vegetais terrestres, Detsed=detrito/sedimento).

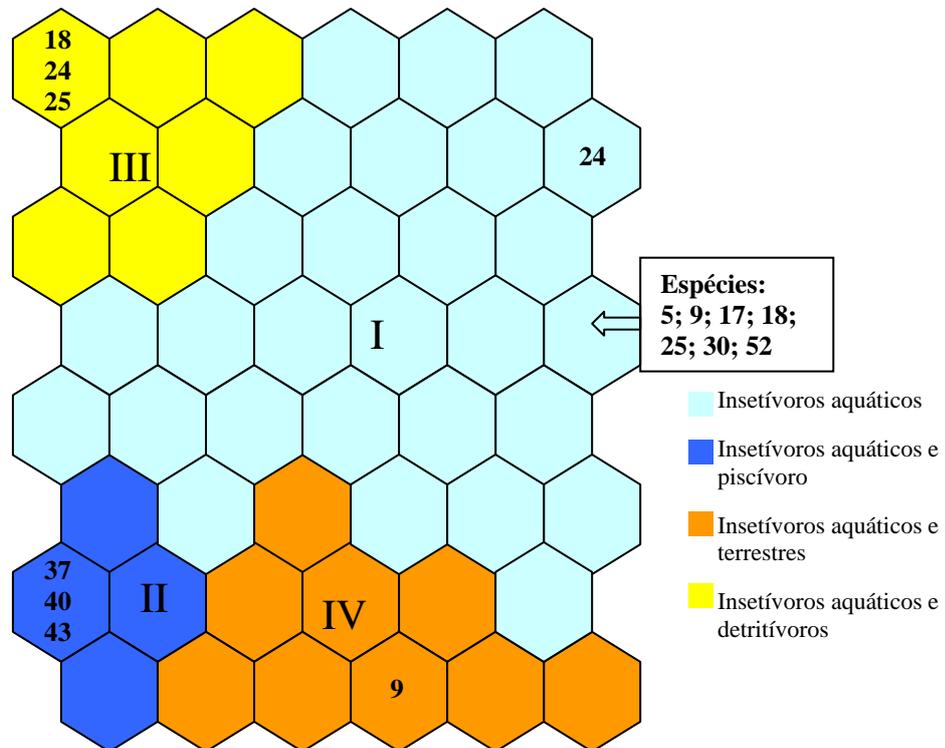


Figura 25 – Identificação das espécies dos sub-agrupamentos – fase reservatório.

Visualiza-se na Figura 26 o mapa bidimensional dividido em 48 células, onde cada uma apresenta um gráfico no formato de “pizza” indicando a participação de cada recurso alimentar nas células.

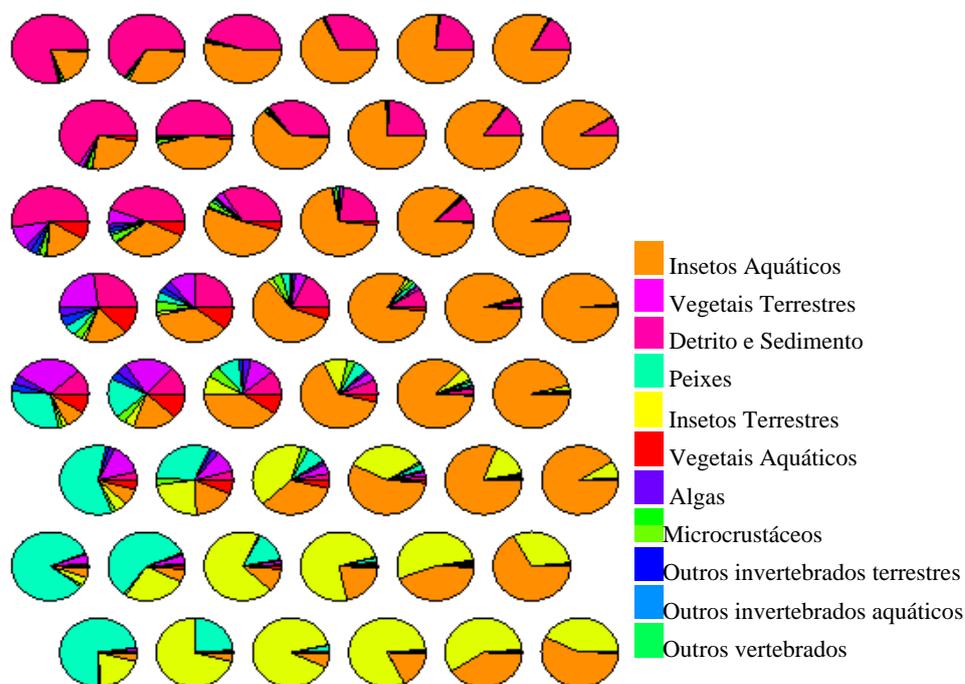


Figura 26 – Apresentação do mapa com separação da contribuição de cada recurso alimentar.

Desta forma, a região A foi dividida em quatro sub-grupos. A tabela 10 apresenta um resumo da classificação trófica das espécies insetívoras na fase reservatório.

Tabela 10 – Sub-grupos da região A – insetívoro, fase reservatório

SUB-GRUPOS	ESPÉCIES
I – insetívoros aquáticos	5; 17; 30; 52
II – insetívoros aquáticos e piscívoros	37; 40; 43
III – insetívoros aquáticos e detritívoros	18; 24; 25
IV – insetívoros aquáticos e terrestres	9

Observa-se que ocorreram separações distintas entre os insetívoros. Sendo possível uma separação das espécies que se alimentam especificamente de insetos aquáticos, ou de insetos aquáticos associados a outros recursos alimentares como peixes, detritos e sedimentos e insetos terrestres.

A classificação trófica das espécies de peixes no reservatório de Corumbá na fase do reservatório é apresentada na Tabela 11.

Tabela 11 – Classificação trófica das espécies de peixes do reservatório de Corumbá –fase reservatório.

	GRUPOS	ESPÉCIES	
Generalistas		2; 4; 26; 27; 31; 38; 42	
Especialistas	A – Insetívoros	I – Insetívoros aquáticos	5; 17; 30; 52
		II – Insetívoros aquáticos e piscívoros	37; 40; 43
		III – insetívoros aquáticos e detritívoros	18; 24; 25
		IV – insetívoros aquáticos e terrestres	9
	B – Piscívoros	13; 14; 20; 21; 39; 45; 49; 51	
	C – Herbívoros	28; 33; 44; 50	
	D - Detritívoros	1; 6; 22; 41; 46; 47;	

5.3 DISCUSSÃO COMPARATIVA ENTRE AS FASES RIO E RESERVATÓRIO

As análises apresentaram resultados satisfatórios, com a utilização da rede de Kohonen para as classificações. Ocorreram espécies que foram classificadas em categorias tróficas distintas na fase rio e na fase reservatório. Isto pode ser explicado pelo fato das espécies de peixes serem dotadas de grande plasticidade na dieta, ou seja, são facilmente adaptáveis aos recursos alimentares que se apresentam mais disponíveis. Este fato é facilmente observado quando se compara informações provenientes de biótopos distintos, o que pode ser comprovado com as duas análises realizadas, na fase rio, envolvendo rios,

riachos, ribeirões e na fase reservatório, incluindo o novo ambiente formado pelo alagamento de regiões como pastagens, plantações, etc (AGOSTINHO et al., 1997a).

Desta forma, observa-se um incremento de espécies classificadas como generalistas da fase rio (5 espécies) para a fase reservatório (7 espécies).

Esta plasticidade alimentar impõe grandes dificuldades ao enquadramento de espécies em uma dada categoria trófica, pois uma alteração da dieta pode ocorrer devido a outros fatores como o desenvolvimento ontogenético (crescimento), às estações do ano ou algum outro (HAHN et al., 1998). Não foi possível neste trabalho realizar estas comparações, tendo em vista que fatores como tamanho do peixe e época do ano não foram considerados na obtenção dos dados, a comparação fica então limitada entre as duas fases: rio e reservatório.

Observa-se que a grande maioria das espécies ingerem insetos, além de outros itens alimentares, este fato deve-se, provavelmente, mais a habilidade que a maioria dos peixes têm em predá-los do que a abundância apresentada no ambiente (GASPAR DA LUZ, 2000). As espécies 31 (“pequi”) e 42 (“mandi”) classificadas na fase rio como insetívoro aquático/detrítívoro e insetívoro aquático/terrestre/detrítívoro, respectivamente, foram classificadas como generalistas na fase reservatório.

Os piscívoros classificados na fase rio mantiveram-se nesta categoria na fase reservatório, com a inclusão de mais seis espécies.

Considerando os herbívoros da fase rio, observa-se que na fase reservatório, a espécie 27 (“piauí”) tornou-se generalista e as demais mantiveram-se nesta categoria com o acréscimo de duas espécies.

Os detritívoros não apresentaram mudanças na classificação, sendo que tal fato pode ser justificado pela morfologia altamente adaptada a este tipo de dieta e também a elevada disponibilidade deste recurso.

Percebe-se a ausência de duas espécies na fase reservatório que foram coletadas na fase rio. São as espécies 10 e 16 (“pequira” e “coridora”, respectivamente). Outra espécie coletada na fase rio (em pequeno número e que não chegou a ser classificada) e tornou-se ausente na fase reservatório, foi a espécie 32 (“pati”). A espécie 3 (“lambari”) era freqüente na fase rio e tornou-se esporádica na fase reservatório. As espécies 13 (“tucunaré”), 30 (“solteira”), 39 (“pintado”) e 43 (“mandi”) foram coletadas somente na fase reservatório. A pesquisadora GASPAR DA LUZ (2000) informa que a espécie 13 foi introduzida há anos de forma intencional na bacia do rio Paraná, por ser uma espécie de interesse para a pesca esportiva. Como o “tucunaré” tem preferência por águas claras e paradas, apareceu em maior número na fase reservatório por apresentar um ambiente propício.

Diversos fatores influenciam a ausência (ou presença) de espécies em determinada fase, quando o ambiente é fortemente impactado. Neste trabalho nota-se a ausência na fase reservatório das espécies 8, 10, 16 e 32, que foram analisadas na fase rio e as espécies 19, 36, 39 e 43 que foram analisadas somente na fase reservatório. Deve-se lembrar que para este trabalho, somente os peixes com conteúdo estomacal foram classificados. Isto corresponde a 7.337 peixes de um total superior a 255.000 peixes coletados, ou seja, as espécies que não aparecem neste estudo em determinada fase podem ter sido capturadas, mas não foram avaliadas devido a ausência de conteúdo estomacal.

Os reservatórios sempre promovem alterações estruturais nas comunidades, resultando num rearranjo de abundância das espécies diferente daquele verificado anteriormente. Características como estratégias reprodutivas, padrões migratórios e especializações tróficas influenciam a nova composição da assembléia de peixes. Durante o processo da formação do reservatório e da colonização do ambiente recém-formado, verifica-se que algumas espécies encontram condições restritivas e sofrem depleções em seus estoques, tornando-se raras ou até

mesmo ausentes. Enquanto aquelas generalistas (oportunistas) e portadoras de alta plasticidade exibem explosões populacionais (FUGI et al. (em fase de elaboração)).

Com a classificação trófica obtida através dos mapas auto-organizáveis foi possível a identificação de alterações em determinadas espécies. Desta forma, conclui-se que os mapas auto-organizáveis representaram um recurso muito útil na discriminação dos grupos e na classificação trófica deste estudo.

Outros pontos positivos a serem considerados neste caso são: a visualização dos agrupamentos, a rapidez do modelo (mesmo considerando o número elevado de amostras) e, principalmente, a facilidade na interpretação dos resultados.

CAPÍTULO VI

6 – CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS

6.1 CONSIDERAÇÕES FINAIS

Ao final deste trabalho, esperavam-se responder as seguintes indagações:

- ✓ O que são redes neurais competitivas? Quais são as suas principais características; como acontece o seu funcionamento (algoritmo) e o que as diferencia dos demais tipos de redes?
- ✓ É possível a utilização de redes neurais competitivas para aplicações ecológicas? Os seus resultados podem ser considerados satisfatórios?

Pelo exposto no capítulo III, acredita-se que tenha sido contemplada a 1ª indagação que trata das redes neurais competitivas; neste capítulo foi efetuada, também, a citação das redes neurais mais utilizadas na literatura, bem como as suas principais aplicações.

Em resposta afirmativa à 2ª indagação, observa-se um número significativo de artigos científicos internacionais favoráveis à utilização das redes neurais em estudos ecológicos, relatando resultados satisfatórios. Acrescenta-se a esses artigos, os resultados obtidos neste trabalho e apresentados no capítulo V, de forma simples, de fácil visualização e compreensão da classificação trófica de peixes através da formação de agrupamentos.

O presente trabalho teve como objetivo principal a aplicação da rede de Kohonen na classificação trófica de peixes. A essência desta pesquisa pode ser dividida nos seguintes pontos-chave: (i) fundamentação do trabalho quanto aos conceitos básicos de redes neurais artificiais e paradigmas da aprendizagem não-supervisionada, (ii) fundamentação sobre a classificação trófica dos peixes com uma introdução aos conceitos ecológicos e interações com o meio ambiente e (iii) aplicação do modelo da rede de Kohonen para classificação no contexto de ecologia trófica de uma assembléia de peixes. Tomando por base esta divisão, os referidos assuntos foram distribuídos nos seis capítulos aqui apresentados visando facilitar o entendimento dos mesmos aos leitores interessados nesta abordagem em particular e/ou assuntos similares.

Foi possível verificar a capacidade de aprendizagem e o consequente agrupamento de padrões na modelagem matemática utilizando redes neurais artificiais. A rede de Kohonen, com 11 neurônios na camada de entrada e um mapa com 48 neurônios representando a camada de saída, foi aplicada a um conjunto de dados descritos no capítulo IV. Observou-se a capacidade da rede para a formação de agrupamentos, conforme detalhamento do capítulo V; pode-se classificar os resultados obtidos como satisfatórios considerando-se o espaço amostral estudado.

Conforme descrito no capítulo V, foram realizadas duas análises, na fase rio e na fase reservatório, de forma independente, com um conjunto de dados amostrais três vezes maior no segundo caso. Observou-se que os erros encontrados na fase reservatório foram bem menores (o erro geral na fase reservatório representa um terço do obtido na fase rio). Não é possível generalizar que os erros serão menores quando os conjuntos de dados forem maiores, pois não foram realizadas análises adicionais buscando esta comprovação, mas tudo indica que sim, pois um dos princípios para a aprendizagem é que o conjunto de dados deva apresentar redundância de informações para que a rede possa ser bem treinada.

Com os agrupamentos encontrados nas duas fases (de forma independente), foi possível realizar a classificação trófica em cada uma delas sem maiores dificuldades; os resultados gráficos auxiliaram muito no processo de identificação do recurso alimentar consumido por determinado agrupamento.

O trabalho de GASPAR DA LUZ (2000), que utilizou o mesmo conjunto de dados ao deste trabalho (Capítulo IV) e apresenta a classificação trófica das espécies de peixes do reservatório de Corumbá de forma geral (fase rio, enchimento e fase reservatório), compreendendo o período de março/96 a fevereiro/99, fez uso da análise de agrupamentos não hierárquica, denominada *k-means* (métodos estatístico), para a obtenção dos agrupamentos. Assim sendo, não é possível uma comparação entre os dois estudos, pois GASPAR DA LUZ (2000) realizou uma única classificação envolvendo todos os períodos conjuntamente e, neste estudo, as classificações foram separadas nas fases rio e reservatório.

Mesmo assim, é possível identificar alguma analogia entre os dois trabalhos: ambas as classificações apresentaram uma nítida divisão das espécies especialistas nas classes detritívora, piscívora e herbívora; no entanto, as classificações dos insetívoros e generalistas deste trabalho, foram classificados como oníveros em GASPAR DA LUZ (2000).

Em ecologia é difícil avaliar a importância de cada variável (dado de entrada), pois todas estão inter-relacionadas e qualquer alteração, por menor que seja, em uma delas pode provocar alterações significativas no meio ambiente. O *SOM* não desconsidera nenhuma variável dentre as disponíveis, utilizando todas elas para um treinamento satisfatório da rede.

Assim sendo, conclui-se que os mapas auto-organizáveis representaram um recurso muito útil na discriminação dos grupos e a consequente classificação trófica das espécies de peixes analisadas neste trabalho. Na referida análise, outros fatores devem ainda ser relevados: a facilidade para visualização dos agrupamentos; a rapidez do modelo para o agrupamento das

espécies (mesmo considerando o número elevado de amostras) e, principalmente, a facilidade na interpretação dos resultados. Assim sendo, comprovou-se que para o estudo aqui apresentado a rede de Kohonen é uma ferramenta aplicável para a tarefa de classificação de dados ecológicos.

Destaca-se que o presente trabalho não teve a pretensão de esgotar o assunto sobre aplicação de redes neurais em estudos ecológicos e sim, divulgar a eficácia desta ferramenta de modelagem matemática para este tipo de problema.

6.2 PROPOSTAS PARA TRABALHOS FUTUROS

Tendo em vista a importância das redes neurais e de se conhecer melhor esta ferramenta e suas aplicações, alguns temas podem ser propostos como perspectiva para futuras pesquisas, tais como:

- ✓ Predição de algas, macrófitas, densidade e biomassa de espécies;
- ✓ Análise da qualidade da água através de bioindicadores (algas ou peixes);
- ✓ Classificação de espécies de acordo com os biótopos;
- ✓ Estudos comparativos entre *SOM* e métodos estatísticos utilizados em agrupamentos.

REFERÊNCIAS

- AGOSTINHO, A.A.; FERRETTI, C.M.L.; GOMES, L.C.; HAHN, N.S.; SUZUKI, H.I.; FUGI, R.; ABUJANRA, F. Ictiofauna de dois reservatórios do rio Iguaçu em diferentes fases de colonização: Segredo e Foz do Areia. In: AGOSTINHO, A.A.; GOMES, L.C. (Ed.). *Reservatório de Segredo: bases ecológicas para o manejo*. Maringá: EDUEM, 1997a, p.275-292.
- AGOSTINHO, A.A.; HAHN, N.S.; GOMES, L.C.; BINI, L.M. Estrutura trófica. In: VAZZOLER, A.E.A.de M.; AGOSTINHO, A.A.; HAHN, N.S. (Ed.) *Planície de inundação do alto rio Paraná: aspectos físicos, biológicos e socioeconômicos*. Maringá: EDUEM, 1997b. cap.II.6, p. 229-248.
- AGUILAR IBARRA, A.; GEVREY, M.; PARK, Y.-S.; LIM, P.; LEK, S. Modelling the factors that influence fish guilds composition using a back-propagation network: assessment of metrics for indices of biotic integrity. *Ecological Modelling*, v.160, p. 281-290, 2003.
- ARRUDA, L. V. R. Notas de aula da disciplina Redes Neurais, oferecida no segundo trimestre de 2004 no CEFET, Curitiba, PR, 2004.
- BROSSE, S.; GIRAUDEL, J.L.; LEK, S. Utilisation of non-supervised neural networks and principal component analysis to study fish assemblages. *Ecological Modelling*, v.146, p.159-166, 2001.
- BROSSE, S.; GUEGAN, J.-F.; TOURENQ, J.-N.; LEK, S. The use of artificial neural networks to assess fish abundance and spatial occupancy in the littoral zone of a mesotrophic lake. *Ecological Modelling*, v.120, p.299-311, 1999.
- CASTRO, F.C.C.; CASTRO, M.C.F. *Redes Neurais Artificiais*. Porto Alegre: PUCRS, 2001. Paginação irregular. Apostila para fins didáticos. Disponível em: <http://diana.ee.pucrs.br/~decastro/RNA_hp/RNA.html> . Acesso em: 14 Sep. 2004.
- CÉRÉGHINO, R.; GIRAUDEL, J.L.; COMPIN, A. Spatial analysis of stream invertebrates distribution in the Adour-Garonne drainage basin (France), using Kohonen self organizing maps. *Ecological Modelling*, v.146, p.167-180, 2001.
- CHON, T.-S.; PARK, Y.S.; MOON, K.H.; CHA, E.Y. Patternizing communities by using an artificial neural network. *Ecological Modelling*, v.90, p.69-78, 1996.
- ESTEVES, F.A. *Fundamentos de Limnologia*. 2.ed. Rio de Janeiro: Interciência/FINEP, 1998. 602 p., il.
- FAUSETT, L. *Fundamentals of neural networks: architectures, algorithms, and applications*. Upper Saddle River, NJ: Prentice Hall, 1994. 459 p., ill.
- FOODY, G.M. Applications of the self-organising feature map neural network in community data analysis. *Ecological Modelling*, v.120, p.97-107, 1999.

- FUGI, R.; VERÍSSIMO, S.; LUIZ, E.A. Variações na abundância de peixes na pesca experimental do reservatório de Corumbá. In; AGOSTINHO, A. A.; FUGI, R. (Ed.). *Biologia e ecologia de peixes no reservatório de Corumbá: bases para o manejo*. Em fase de elaboração.
- GASPAR DA LUZ, K.D. *Espectro alimentar e estrutura trófica da ictiofauna do reservatório da UHE Corumbá-GO*. Maringá, 2000. 25 f., il. Dissertação (Mestrado em Ecologia de Ambientes Aquáticos Continentais) – Departamento de Biologia, Universidade Estadual de Maringá, 2000.
- GERKING, S.D. *Feeding ecology of fish*. San Diego: Academic Press, 1994. 416 p., ill.
- GEVREY, M.; RIMET, F.; PARK, Y.S.; GIRAUDEL, J.-L.; ECTOR, L.; LEK, S. Water quality assessment using diatom assemblages and advanced modelling techniques. *Freshwater Biology*, v. 49, p.208-220, 2004.
- GIRAUDEL, J.-L.; LEK, S. A comparison of self-organizing map algorithm and some conventional statistical methods for ecological community ordination. *Ecological Modelling*, v. 146, p.329-339, 2001.
- GUEGAN, J.F.; LEK, S.; OBERDORFF, T. Energy availability and habitat heterogeneity predict global riverine fish diversity. *Nature*, v.391, p.382-384, 1998.
- HAHN, N.S.; AGOSTINHO, A.A.; GOMES, L.C.; BINI, L.M. Estrutura trófica da ictiofauna do reservatório de Itaipu (Paraná-Brasil) nos primeiros anos de sua formação. *Interciência*, v.23, n.5, p.299-305, Sept.-Oct. 1998.
- HAYKIN, S. *Redes neurais: princípios e prática*. 2.ed. Tradução de, Paulo Martins Engel. Porto Alegre: Bookman, 2001. 900 p., il. Obra originalmente publicada sob o título: *Neural Networks: a comprehensive foundation*, 2/E.
- HYSLOP, E.J. Stomach contents analysis, a review of methods and their application. *Journal Fish Biology*, v.17, p.411-422, 1980.
- KAWAKAMI, E.; VAZZOLER, G. Método Figura e estimativa de índice alimentar aplicado no estudo de alimentação de peixes. *Boletim do Instituto OceanoFigura*, São Paulo, v. 29, n. 2, p. 205-207, 1980.
- KEENLEYSIDE, M.H.A. *Diversity and adaptation in fish behaviour*. Berlin; New York: Springer-Verlag, 1979. 208p.,ill. (Zoophysiology, v.11)
- KREBS, C.J. *Ecological methodology*. New York: Harper Collins, ©1989. 654p.,ill.
- LAË, R.; LEK, S.; MOREAU, J. Predicting fish yield of African lakes using neural networks. *Ecological Modelling*, v.120, p.325-335, 1999.
- LEE, J.H.W.; HUANG, Y.; DICKMAN, M.; JAYAWARDENA, A.W. Neural network modelling of coastal algal blooms. *Ecological Modelling*, v.159, p.179-201, 2003.

- LEK, S.; BELAUD, A.; BARAN, P.; DIMOPOULOS, I.; DELACOSTE, M. Role of some environmental variables in trout abundance models using neural networks. *Aquatic Living Research*, v.9, p.23-29, 1996.
- LEK, S.; BELAUD, A.; DIMOPOULOS, I.; LAUGA, J.; MOREAU, J. Improved estimation, using neural networks, of the food consumption of fish populations. *Marine and Freshwater Research*, v.46, no.8, p.1229-1236, 1995.
- LOOT, G.; GIRAUDEL, J.-L., LEK, S. A non-destructive morphometric technique to predict *Ligula intestinalis* L. plerocercoid load in roach (*Rutilus rutilus* L.) abdominal cavity. *Ecological Modelling*, v.156, p.1-11, 2002.
- LOWE-McCONNELL, R.H. *Estudos ecológicos de comunidades de peixes tropicais*. Tradução de Anna Emília A. de M. Vazzoler, Ângelo Antonio Agostinho, Patrícia T. M. Cunnighan. São Paulo: EDUSP, 1999. 534 p., il. (Coleção Base).
- MAIER, H.R.; DANDY, G.C. Modelling cyanobacteria (blue-green algae) in the River Murray using artificial neural networks. *Mathematics and Computers in Simulation*, v.43, p.377-386, 1997.
- MAIER, H.R.; DANDY, G.C.; BURCH, M.D. Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. *Ecological Modelling*, v.105, p.257-272, 1998.
- MARCONDES, D.A.S.; MUSTAFÁ, A.L.; TANAKA, R.H. Estudos para manejo integrado de plantas aquáticas no reservatório de Jupia. In: THOMAZ, S.M.; BINI, L.M. (Ed.). *Ecologia e manejo de macrófitas aquáticas*. Maringá: EDUEM, 2003. cap. 15, p.299-317.
- MARLIER, G. Ecological studies on some lakes of the Amazon Valley. *Amazoniana*, v.1, no.2, p.91-115, Mai 1967.
- MARQUES, J.M. *Análise multivariada aplicada à pesquisa*. Curitiba, 2003. Apostila para fins didáticos.
- MASTRORILLO, S.; LEK, S.; DAUBA, F.; BELAUD, A. The use of artificial neural networks to predict the presence of small-bodied fish in a river. *Freshwater Biology*, v.38, no.2, p. 237-246, Oct. 1997.
- NIKOLSKY, G.V. *The ecology of fishes*. Translated from the Russian by L. Birkett. Neptune City, New Jersey: T.F.H., 1978. 352p.
- ODUM, E.P. *Ecologia*. Tradução: Christopher J. Tribe. Supervisão da tradução: Ricardo Iglesias Rios. Rio de Janeiro: Guanabara Koogan, © 1988. 434 p., il. Título do original em inglês: Basic Ecology.
- OLDEN, J.D.; JACKSON, D.A. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, v. 154, p.135-150, 2002.

- PENCZAK, T.; LEK, S.; GODINHO, F.; AGOSTINHO, A. A. Patterns of fish assemblages in tropical streamlets using SOM algorithm and conventional statistical methods. *Ecohydrology & Hydrobiology*, v. 4, no.2, p.139-146, 2004.
- PINKAS, L.; OLIPHANT, M.S.; IVERSON, I.L.K. Food habits of albacore bluefin tuna, and bonito in California waters. *Fishery Bulletin*, v. 152, p. 5-10, 1971.
- RECKNAGEL, F. ANNA – Artificial neural network model for predicting species abundance and succession of blue-green algae. *Hydrobiologia*, v.349, p.47-57, 1997a.
- RECKNAGEL, F.; FRENCH, M.; HARKONEN, P.; YABUNAKA, K.-I. Artificial neural network approach for modelling and prediction of algal blooms. *Ecological Modelling*, v.96, p.11-28, 1997b.
- UNIVERSIDADE ESTADUAL DE MARINGÁ. Nupélia/Furnas. *Estudos ictiológicos na área de influência do AHE Corumbá – Fase rio* : relatório parcial março-agosto/96. Maringá, 1997. 289 p.,il. Apoio Furnas - Centrais Elétricas S.A.
- UNIVERSIDADE ESTADUAL DE MARINGÁ. Nupélia/Furnas. *Estudos ictiológicos na área de influência do AHE Corumbá – Fase reservatório*: relatório parcial março/98-fevereiro/99. Maringá, 2000. 365 p.,il. Apoio Furnas – Centrais Centrais Elétricas S.A.
- VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. *Self-organizing map in Matlab: the SOM Toolbox*. Finland: Helsinki University of Technology. Laboratory of Computer and Information Science, 2000a. 8 p., ill. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox>> . Acesso em: 06 Aug. 2004.
- VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. *SOM Toolbox for Matlab 5*: report A57, April 2000. Libella Oy: Finland: SOM Toolbox Team, Helsinki University of Technology, 2000b. 59 p., ill. Disponível em: <<http://www.cis.hut.fi/projects/somtoolbox>> . Acesso em: 06 Aug. 2004.
- WALTER, M.; RECKNAGEL, F.; CARPENTER, C.; BORMANS, M. Predicting eutrophication effects in the Burrinjuck Reservoir (Australia) by means of the deterministic model SALMO and the recurrent neural network model ANNA. *Ecological Modelling*, v.146, p.97-113, 2001.
- WELCOMME, R.L. *Fishes ecology of floodplain rivers*. London; New York: Longman, 1979. 317p.
- WHITEHEAD, P.G.; HOWARD, A.; ARULMANI, C. Modelling algal growth and transport in rivers: a comparison of time series analysis, dynamic mass balance and neural network techniques. *Hydrobiologia*, v.349, p.39-46, 1997.
- WINEMILLER, K. O.; JEPSEN, D. B. Effects of seasonality and fish movement on tropical river food webs. *Journal of Fish Biology*, v. 53 (Supl. A), p. 267-296, 1998.
- WOOTTON, R.J. *Ecology of teleost fishes*. 1st ed.London; New York: Chapman & Hall, 1990. 404p., ill.

YABUNAKA, K.-I.; HASOMI, M.; MURAKAMI, A. Novel application of a back-propagation artificial neural network model formulated to predict algal bloom. *Water Science & Technology*, v.36, no.5, p.89-97, 1997.

ZHEN-PING,L.; YAOQI,Y.; BEHNAM, B. Analysis of the convergence properties of topology preserving neural networks. *IEEE Transactions on neural networks*, v.4,no.2, p.207-220, March 1993.

ANEXO I - EXEMPLO ILUSTRATIVO DO FUNCIONAMENTO DA REDE DE KOHONEN

Para este exemplo será utilizada uma matriz de dados A com dimensão 5×6 , com valores gerados aleatoriamente dentro do intervalo $[0, 1]$, onde serão apresentados 5 padrões para o treinamento (linhas) e cada padrão apresenta 6 características distintas (colunas). Procura-se separar os padrões que apresentem características semelhantes. Serão apresentadas somente duas iterações (épocas).

$$A = \begin{bmatrix} 0,43 & 0,18 & 0,58 & 0,09 & 0,69 & 0,39 \\ 0,66 & 0,03 & 0,18 & 0,83 & 0,85 & 0,69 \\ 0,28 & 0,17 & 0,11 & 0,33 & 0,59 & 0,71 \\ 0,12 & 0,32 & 0,13 & 0,29 & 0,25 & 0,81 \\ 0,19 & 0,72 & 0,05 & 0,62 & 0,57 & 0,67 \end{bmatrix}$$

Como se trata de um exemplo ilustrativo, será utilizado um mapa de saída bidimensional de pequeno porte, com 9 neurônios. Destaca-se o fato de que não é necessário que a matriz seja quadrada, podendo apresentar qualquer dimensão, desde que a quantidade de neurônios seja superior a quantidade de grupos que se pretende formar.

Cada neurônio do mapa de saída é formado por um vetor 6×1 , pois cada padrão possui 6 características distintas que formam a camada de entrada. Assim teremos uma matriz P da seguinte forma:

$$P = \begin{bmatrix} P_{11} & P_{12} & P_{13} \\ P_{21} & P_{22} & P_{23} \\ P_{31} & P_{32} & P_{33} \end{bmatrix}$$

onde: P_{11} , P_{12} , P_{13} , P_{21} , P_{22} , P_{23} , P_{31} , P_{32} , P_{33} representam os valores dos pesos de cada neurônio.

Observam-se a seguir os valores da matriz peso, gerados aleatoriamente, dentro do mesmo intervalo do conjunto de entrada, ou seja: $[0, 1]$, para que a convergência seja mais rápida.

P =	0,19	0,05	0,17
	0,20	0,41	0,05
	0,01	0,80	0,01
	0,15	0,52	0,61
	0,60	0,21	0,50
	0,25	0,92	0,69
	0,59	0,00	0,73
	0,64	0,31	0,58
	0,38	0,09	0,04
	0,01	0,87	0,68
	0,03	0,43	0,57
	0,49	0,89	0,26
	0,38	0,44	0,78
	0,29	0,35	0,56
	0,47	0,62	0,82
	0,23	0,79	0,27
	0,11	0,94	0,18
	0,31	0,99	0,02

Foi considerada uma topologia retangular, com uma grade de vizinhança retangular.

A taxa de aprendizagem foi inicializada em 0,5 e o raio topológico em 1, sendo que a cada iteração a taxa de aprendizagem sofrerá um decréscimo de acordo com a fórmula:

$$\text{taxa}_{\text{nova}} = \text{taxa}_{\text{atual}} * 0,5$$

e o raio topológico também será diminuído para 0, atualizando somente o neurônio vencedor, para que se possa verificar as alterações produzidas no algoritmo de aprendizagem.

Após as inicializações, o primeiro padrão [0,43 0,18 0,58 0,09 0,69 0,39] é apresentado à rede.

Encontra-se o **neurônio vencedor**, que é aquele que apresentar a menor distância (quadrado da distância euclidiana) para este primeiro padrão de entrada, representando o neurônio que apresentar maior similaridade.

Neurônio:	Cálculos
P11	$(0,43-0,19)^2 + (0,18-0,20)^2 + (0,58-0,01)^2 + (0,09-0,15)^2 + (0,69-0,60)^2 + (0,39-0,25)^2 = 0,4142$
P12	$(0,43-0,05)^2 + (0,18-0,41)^2 + (0,58-0,80)^2 + (0,09-0,52)^2 + (0,69-0,21)^2 + (0,39-0,92)^2 = 0,9419$
P13	$(0,43-0,17)^2 + (0,18-0,05)^2 + (0,58-0,01)^2 + (0,09-0,61)^2 + (0,69-0,50)^2 + (0,39-0,69)^2 = 0,8059$
P21	$(0,43-0,59)^2 + (0,18-0,64)^2 + (0,58-0,38)^2 + (0,09-0,01)^2 + (0,69-0,03)^2 + (0,39-0,49)^2 = 0,7292$
P22	$(0,43-0,00)^2 + (0,18-0,31)^2 + (0,58-0,09)^2 + (0,09-0,87)^2 + (0,69-0,43)^2 + (0,39-0,89)^2 = 1,3679$
P23	$(0,43-0,73)^2 + (0,18-0,58)^2 + (0,58-0,04)^2 + (0,09-0,68)^2 + (0,69-0,57)^2 + (0,39-0,26)^2 = 0,9210$
P31	$(0,43-0,38)^2 + (0,18-0,29)^2 + (0,58-0,47)^2 + (0,09-0,23)^2 + (0,69-0,11)^2 + (0,39-0,31)^2 = 0,3891$
P32	$(0,43-0,44)^2 + (0,18-0,35)^2 + (0,58-0,62)^2 + (0,09-0,79)^2 + (0,69-0,94)^2 + (0,39-0,99)^2 = 0,9431$
P33	$(0,43-0,78)^2 + (0,18-0,56)^2 + (0,58-0,82)^2 + (0,09-0,27)^2 + (0,69-0,18)^2 + (0,39-0,02)^2 = 0,7539$

O neurônio P31 apresentou o menor valor, sendo considerado o neurônio vencedor.

Os neurônios que terão seus pesos atualizados devem pertencer a sua vizinhança num raio topológico de um neurônio, desta forma serão atualizados os neurônios: P31, P32, P21 e P22, pois está sendo utilizada uma grade de vizinhança retangular de raio topológico igual a 1.

P =	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr> <td style="border: none; padding: 5px;">P11</td> <td style="border: none; padding: 5px;">P12</td> <td style="border: none; padding: 5px;">P13</td> </tr> <tr> <td style="border: none; padding: 5px; color: blue;">P21</td> <td style="border: none; padding: 5px; color: blue;">P22</td> <td style="border: none; padding: 5px;">P23</td> </tr> <tr> <td style="border: none; padding: 5px; color: red;">P31</td> <td style="border: none; padding: 5px; color: blue;">P32</td> <td style="border: none; padding: 5px;">P33</td> </tr> </table>	P11	P12	P13	P21	P22	P23	P31	P32	P33
P11	P12	P13								
P21	P22	P23								
P31	P32	P33								

O neurônio vencedor é apresentado na tonalidade vermelha e os neurônios vizinhos, considerando o raio topológico igual a 1 em azul.

Portanto os novos valores destes neurônios foram calculados pela fórmula de atualização do algoritmo:

$$\text{peso}_{(\text{novo})} = \text{peso}_{(\text{atual})} + \text{taxa de aprendizagem} * (\text{vetor} - \text{peso}_{(\text{atual})})$$

Neurônio:	Cálculos
P21	$0,59 + 0,5 * (0,43 - 0,59) = 0,51$ $0,64 + 0,5 * (0,18 - 0,64) = 0,41$ $0,38 + 0,5 * (0,58 - 0,38) = 0,48$ $0,01 + 0,5 * (0,09 - 0,01) = 0,05$ $0,03 + 0,5 * (0,69 - 0,03) = 0,36$ $0,49 + 0,5 * (0,39 - 0,49) = 0,44$
P22	$0,00 + 0,5 * (0,43 - 0,00) = 0,215$ $0,31 + 0,5 * (0,18 - 0,31) = 0,245$ $0,09 + 0,5 * (0,58 - 0,09) = 0,335$ $0,87 + 0,5 * (0,09 - 0,87) = 0,48$ $0,43 + 0,5 * (0,69 - 0,43) = 0,56$ $0,89 + 0,5 * (0,39 - 0,89) = 0,64$

Neurônio:	Cálculos
P31	$0,38 + 0,5 * (0,43 - 0,38) = 0,405$ $0,29 + 0,5 * (0,18 - 0,29) = 0,235$ $0,47 + 0,5 * (0,58 - 0,47) = 0,525$ $0,23 + 0,5 * (0,09 - 0,23) = 0,16$ $0,11 + 0,5 * (0,69 - 0,11) = 0,4$ $0,31 + 0,5 * (0,39 - 0,31) = 0,35$
P32	$0,44 + 0,5 * (0,43 - 0,44) = 0,435$ $0,35 + 0,5 * (0,18 - 0,35) = 0,265$ $0,62 + 0,5 * (0,58 - 0,62) = 0,6$ $0,79 + 0,5 * (0,09 - 0,79) = 0,44$ $0,94 + 0,5 * (0,69 - 0,94) = 0,815$ $0,99 + 0,5 * (0,39 - 0,99) = 0,69$

Portanto, a matriz de pesos atualizada apresenta-se da seguinte forma:

$$P = \begin{bmatrix} 0,19 & 0,05 & 0,17 \\ 0,20 & 0,41 & 0,05 \\ 0,01 & 0,80 & 0,01 \\ 0,15 & 0,52 & 0,61 \\ 0,60 & 0,21 & 0,50 \\ 0,25 & 0,92 & 0,69 \\ \\ 0,51 & 0,215 & 0,73 \\ 0,41 & 0,245 & 0,58 \\ 0,48 & 0,335 & 0,04 \\ 0,05 & 0,48 & 0,68 \\ 0,36 & 0,56 & 0,57 \\ 0,44 & 0,64 & 0,26 \\ \\ 0,405 & 0,435 & 0,78 \\ 0,235 & 0,265 & 0,56 \\ 0,525 & 0,6 & 0,82 \\ 0,16 & 0,44 & 0,27 \\ 0,4 & 0,815 & 0,18 \\ 0,35 & 0,69 & 0,02 \end{bmatrix}$$

O segundo padrão [0,66 0,03 0,18 0,83 0,85 0,69] é apresentado à rede.

Encontra-se o **neurônio vencedor** para este padrão utilizando a matriz de pesos atualizada.

Neurônio:	Cálculos
P11	$(0,66-0,19)^2 + (0,03-0,20)^2 + (0,18-0,01)^2 + (0,83-0,15)^2 + (0,85-0,60)^2 + (0,69-0,25)^2 = 0,9972$
P12	$(0,66-0,05)^2 + (0,03-0,41)^2 + (0,18-0,80)^2 + (0,83-0,52)^2 + (0,85-0,21)^2 + (0,69-0,92)^2 = 1,4595$
P13	$(0,66-0,17)^2 + (0,03-0,05)^2 + (0,18-0,01)^2 + (0,83-0,61)^2 + (0,85-0,50)^2 + (0,69-0,69)^2 = 0,4403$
P21	$(0,66-0,51)^2 + (0,03-0,41)^2 + (0,18-0,48)^2 + (0,83-0,05)^2 + (0,85-0,36)^2 + (0,69-0,44)^2 = 1,1679$
P22	$(0,66-0,215)^2 + (0,03-0,245)^2 + (0,18-0,335)^2 + (0,83-0,48)^2 + (0,85-0,56)^2 + (0,69-0,64)^2 = 0,4773$
P23	$(0,66-0,73)^2 + (0,03-0,58)^2 + (0,18-0,04)^2 + (0,83-0,68)^2 + (0,85-0,57)^2 + (0,69-0,26)^2 = 0,6128$
P31	$(0,66-0,405)^2 + (0,03-0,235)^2 + (0,18-0,525)^2 + (0,83-0,16)^2 + (0,85-0,4)^2 + (0,69-0,35)^2 = 0,9930$
P32	$(0,66-0,435)^2 + (0,03-0,265)^2 + (0,18-0,6)^2 + (0,83-0,44)^2 + (0,85-0,815)^2 + (0,69-0,69)^2 = 0,4355$
P33	$(0,66-0,78)^2 + (0,03-0,56)^2 + (0,18-0,82)^2 + (0,83-0,27)^2 + (0,85-0,18)^2 + (0,69-0,02)^2 = 1,9163$

O neurônio P32 apresentou o menor valor, sendo considerado o neurônio vencedor.

Os neurônios que terão seus pesos atualizados devem pertencer a sua vizinhança num raio topológico de um neurônio, desta forma serão atualizados os neurônios: P21, P22, P23, P31, P32 e P33, pois está sendo utilizada uma grade de vizinhança retangular.

$$P = \begin{array}{|c|c|c|c|} \hline & P11 & P12 & P13 \\ \hline & P21 & P22 & P23 \\ \hline & P31 & P32 & P33 \\ \hline \end{array}$$

O neurônio vencedor é apresentado na tonalidade vermelha e os neurônios vizinhos, considerando o raio topológico igual a 1 em azul.

Portanto os novos valores destes neurônios foram calculados pela fórmula de atualização do algoritmo:

$$\text{peso}_{(\text{nov})} = \text{peso}_{(\text{atual})} + \text{taxa de aprendizagem} * (\text{vetor} - \text{peso}_{(\text{atual})})$$

Neurônio:	Cálculos
P21	$0,51 + 0,5 * (0,66 - 0,51) = 0,585$ $0,41 + 0,5 * (0,03 - 0,41) = 0,22$ $0,48 + 0,5 * (0,18 - 0,48) = 0,33$ $0,05 + 0,5 * (0,83 - 0,05) = 0,44$ $0,36 + 0,5 * (0,85 - 0,36) = 0,605$ $0,44 + 0,5 * (0,69 - 0,44) = 0,565$
P22	$0,215 + 0,5 * (0,66 - 0,215) = 0,4375$ $0,245 + 0,5 * (0,03 - 0,245) = 0,1375$ $0,335 + 0,5 * (0,18 - 0,335) = 0,2575$ $0,48 + 0,5 * (0,83 - 0,48) = 0,655$ $0,56 + 0,5 * (0,85 - 0,56) = 0,705$ $0,64 + 0,5 * (0,69 - 0,64) = 0,665$
P23	$0,73 + 0,5 * (0,66 - 0,73) = 0,695$ $0,58 + 0,5 * (0,03 - 0,58) = 0,305$ $0,04 + 0,5 * (0,18 - 0,04) = 0,11$ $0,68 + 0,5 * (0,83 - 0,68) = 0,755$ $0,57 + 0,5 * (0,85 - 0,57) = 0,71$ $0,26 + 0,5 * (0,69 - 0,26) = 0,475$

Neurônio:	Cálculos
P31	$0,405 + 0,5 * (0,66 - 0,405) = 0,5325$ $0,235 + 0,5 * (0,03 - 0,235) = 0,1325$ $0,525 + 0,5 * (0,18 - 0,525) = 0,3525$ $0,16 + 0,5 * (0,83 - 0,16) = 0,495$ $0,4 + 0,5 * (0,85 - 0,4) = 0,625$ $0,35 + 0,5 * (0,69 - 0,35) = 0,52$
P32	$0,435 + 0,5 * (0,66 - 0,435) = 0,5475$ $0,265 + 0,5 * (0,03 - 0,265) = 0,1475$ $0,6 + 0,5 * (0,18 - 0,6) = 0,39$ $0,44 + 0,5 * (0,83 - 0,44) = 0,635$ $0,815 + 0,5 * (0,85 - 0,815) = 0,8325$ $0,69 + 0,5 * (0,69 - 0,69) = 0,69$
P33	$0,78 + 0,5 * (0,66 - 0,78) = 0,72$ $0,56 + 0,5 * (0,03 - 0,56) = 0,295$ $0,82 + 0,5 * (0,18 - 0,82) = 0,5$ $0,27 + 0,5 * (0,83 - 0,27) = 0,55$ $0,18 + 0,5 * (0,85 - 0,18) = 0,515$ $0,02 + 0,5 * (0,69 - 0,02) = 0,355$

Portanto, a matriz de pesos atualizada após a apresentação do segundo padrão ficou:

$$P = \begin{bmatrix} 0,19 & 0,05 & 0,17 \\ 0,20 & 0,41 & 0,05 \\ 0,01 & 0,8 & 0,01 \\ 0,15 & 0,52 & 0,61 \\ 0,60 & 0,21 & 0,5 \\ 0,25 & 0,92 & 0,69 \\ \\ 0,585 & 0,4375 & 0,695 \\ 0,22 & 0,1375 & 0,305 \\ 0,33 & 0,2575 & 0,11 \\ 0,44 & 0,655 & 0,755 \\ 0,605 & 0,705 & 0,71 \\ 0,565 & 0,665 & 0,475 \\ \\ 0,5325 & 0,5475 & 0,72 \\ 0,1325 & 0,1475 & 0,295 \\ 0,3525 & 0,39 & 0,5 \\ 0,495 & 0,635 & 0,55 \\ 0,625 & 0,8325 & 0,515 \\ 0,52 & 0,69 & 0,355 \end{bmatrix}$$

O terceiro padrão [0,28 0,17 0,11 0,33 0,59 0,71] é apresentado à rede.

Encontra-se o **neurônio vencedor** para este padrão utilizando a matriz de pesos atualizada.

Neurônio:	Cálculos
P11	$(0,28-0,19)^2 + (0,17-0,20)^2 + (0,11-0,01)^2 + (0,33-0,15)^2 + (0,59-0,60)^2 + (0,71-0,25)^2 = 0,2631$
P12	$(0,28-0,05)^2 + (0,17-0,41)^2 + (0,11-0,8)^2 + (0,33-0,52)^2 + (0,59-0,21)^2 + (0,71-0,92)^2 = 0,8112$
P13	$(0,28-0,17)^2 + (0,17-0,05)^2 + (0,11-0,01)^2 + (0,33-0,61)^2 + (0,59-0,5)^2 + (0,71-0,69)^2 = 0,1234$
P21	$(0,28-0,585)^2 + (0,17-0,22)^2 + (0,11-0,33)^2 + (0,33-0,44)^2 + (0,59-0,605)^2 + (0,71-0,565)^2 = 0,1772$
P22	$(0,28-0,4375)^2 + (0,17-0,1375)^2 + (0,11-0,2575)^2 + (0,33-0,655)^2 + (0,59-0,705)^2 + (0,71-0,665)^2 = 0,1684$
P23	$(0,28-0,695)^2 + (0,17-0,305)^2 + (0,11-0,11)^2 + (0,33-0,755)^2 + (0,59-0,71)^2 + (0,71-0,475)^2 = 0,4407$
P31	$(0,28-0,5325)^2 + (0,17-0,1325)^2 + (0,11-0,3525)^2 + (0,33-0,495)^2 + (0,59-0,625)^2 + (0,71-0,52)^2 = 0,1885$
P32	$(0,28-0,5475)^2 + (0,17-0,1475)^2 + (0,11-0,39)^2 + (0,33-0,635)^2 + (0,59-0,8325)^2 + (0,71-0,69)^2 = 0,3026$
P33	$(0,28-0,72)^2 + (0,17-0,295)^2 + (0,11-0,5)^2 + (0,33-0,55)^2 + (0,59-0,515)^2 + (0,71-0,355)^2 = 0,5413$

O neurônio P13 apresentou o menor valor, sendo considerado o neurônio vencedor.

Os neurônios que terão seus pesos atualizados devem pertencer a sua vizinhança num raio topológico de um neurônio, desta forma serão atualizados os neurônios: P12, P13, P22 e P23, pois está sendo utilizada uma grade de vizinhança retangular.

$$P = \begin{vmatrix} P11 & P12 & P13 \\ P21 & P22 & P23 \\ P31 & P32 & P33 \end{vmatrix}$$

O neurônio vencedor é apresentado na tonalidade vermelha e os neurônios vizinhos, considerando o raio topológico igual a 1 em azul.

Portanto os novos valores destes neurônios foram calculados pela fórmula de atualização do algoritmo:

$$\text{peso}_{(\text{novo})} = \text{peso}_{(\text{atual})} + \text{taxa de aprendizagem} * (\text{vetor} - \text{peso}_{(\text{atual})})$$

Neurônio:	Cálculos
P12	$0,05+0,5*(0,28-0,05)=0,165$ $0,41+0,5*(0,17-0,41)=0,29$ $0,8+0,5*(0,11-0,8)=0,455$ $0,52+0,5*(0,33-0,52)=0,425$ $0,21+0,5*(0,59-0,21)=0,4$ $0,92+0,5*(0,71-0,92)=0,815$
P13	$0,17+0,5*(0,28-0,17)=0,225$ $0,05+0,5*(0,17-0,05)=0,11$ $0,01+0,5*(0,11-0,01)=0,06$ $0,61+0,5*(0,33-0,61)=0,47$ $0,5+0,5*(0,59-0,5)=0,545$ $0,69+0,5*(0,71-0,69)=0,7$
P22	$0,4375+0,5*(0,28-0,4375)=0,3587$ $0,1375+0,5*(0,17-0,1375)=0,1537$ $0,2575+0,5*(0,11-0,2575)=0,1837$ $0,655+0,5*(0,33-0,655)=0,4925$ $0,705+0,5*(0,59-0,705)=0,6475$ $0,665+0,5*(0,71-0,665)=0,6875$
P23	$0,695+0,5*(0,28-0,695)=0,4875$ $0,305+0,5*(0,17-0,305)=0,2375$ $0,11+0,5*(0,11-0,11)=0,11$ $0,755+0,5*(0,33-0,755)=0,5425$ $0,71+0,5*(0,59-0,71)=0,65$ $0,475+0,5*(0,71-0,475)=0,5925$

A matriz de pesos atualizada após a apresentação do terceiro padrão é apresentada a seguir:

$$P = \begin{bmatrix} 0,19 & 0,165 & 0,225 \\ 0,2 & 0,29 & 0,11 \\ 0,01 & 0,455 & 0,06 \\ 0,15 & 0,425 & 0,47 \\ 0,6 & 0,4 & 0,545 \\ 0,25 & 0,815 & 0,7 \\ \\ 0,585 & 0,3587 & 0,4875 \\ 0,22 & 0,1537 & 0,2375 \\ 0,33 & 0,1837 & 0,11 \\ 0,44 & 0,4925 & 0,5425 \\ 0,605 & 0,6475 & 0,65 \\ 0,565 & 0,6875 & 0,5925 \\ \\ 0,5325 & 0,5475 & 0,72 \\ 0,1325 & 0,1475 & 0,295 \\ 0,3525 & 0,39 & 0,5 \\ 0,495 & 0,635 & 0,55 \\ 0,625 & 0,8325 & 0,515 \\ 0,52 & 0,69 & 0,355 \end{bmatrix}$$

O quarto padrão [0,12 0,32 0,13 0,29 0,25 0,81] é apresentado à rede.

Encontra-se o **neurônio vencedor** para este padrão utilizando a matriz de pesos atualizada.

Neurônio:	Cálculos
P11	$(0,12-0,19)^2 + (0,32-0,2)^2 + (0,13-0,01)^2 + (0,29-0,15)^2 + (0,25-0,6)^2 + (0,81-0,25)^2 = 0,4894$
P12	$(0,12-0,165)^2 + (0,32-0,29)^2 + (0,13-0,455)^2 + (0,29-0,425)^2 + (0,25-0,4)^2 + (0,81-0,815)^2 = 0,1493$
P13	$(0,12-0,225)^2 + (0,32-0,11)^2 + (0,13-0,06)^2 + (0,29-0,47)^2 + (0,25-0,545)^2 + (0,81-0,7)^2 = 0,1915$
P21	$(0,12-0,585)^2 + (0,32-0,22)^2 + (0,13-0,33)^2 + (0,29-0,44)^2 + (0,25-0,605)^2 + (0,81-0,565)^2 = 0,4747$
P22	$(0,12-0,3587)^2 + (0,32-0,1537)^2 + (0,13-0,1837)^2 + (0,29-0,4925)^2 + (0,25-0,6475)^2 + (0,81-0,6875)^2 = 0,3015$
P23	$(0,12-0,4875)^2 + (0,32-0,2375)^2 + (0,13-0,11)^2 + (0,29-0,5425)^2 + (0,25-0,65)^2 + (0,81-0,5925)^2 = 0,4133$
P31	$(0,12-0,5325)^2 + (0,32-0,1325)^2 + (0,13-0,3525)^2 + (0,29-0,495)^2 + (0,25-0,625)^2 + (0,81-0,52)^2 = 0,5215$
P32	$(0,12-0,5475)^2 + (0,32-0,1475)^2 + (0,13-0,39)^2 + (0,29-0,635)^2 + (0,25-0,8325)^2 + (0,81-0,69)^2 = 0,7528$
P33	$(0,12-0,72)^2 + (0,32-0,295)^2 + (0,13-0,5)^2 + (0,29-0,55)^2 + (0,25-0,515)^2 + (0,81-0,355)^2 = 0,8423$

O neurônio P12 apresentou o menor valor, sendo considerado o neurônio vencedor.

Os neurônios que terão seus pesos atualizados devem pertencer a sua vizinhança num raio topológico de um neurônio, desta forma serão atualizados os neurônios: P11, P12, P13, P21, P22 e P23, pois está sendo utilizada uma grade de vizinhança retangular.

$$P = \begin{array}{|c|c|c|c|} \hline & \text{P11} & \text{P12} & \text{P13} \\ \hline & \text{P21} & \text{P22} & \text{P23} \\ \hline & \text{P31} & \text{P32} & \text{P33} \\ \hline \end{array}$$

O neurônio vencedor é apresentado na tonalidade vermelha e os neurônios vizinhos, considerando o raio topológico igual a 1 em azul.

Portanto os novos valores destes neurônios foram calculados pela fórmula de atualização do algoritmo:

$$\text{peso}_{(\text{novo})} = \text{peso}_{(\text{atual})} + \text{taxa de aprendizagem} * (\text{vetor} - \text{peso}_{(\text{atual})})$$

Neurônio:	Cálculos
P11	$0,19 + 0,5 * (0,12 - 0,19) = 0,155$ $0,2 + 0,5 * (0,32 - 0,2) = 0,26$ $0,01 + 0,5 * (0,13 - 0,01) = 0,07$ $0,15 + 0,5 * (0,29 - 0,15) = 0,22$ $0,6 + 0,5 * (0,25 - 0,6) = 0,425$ $0,25 + 0,5 * (0,81 - 0,25) = 0,53$
P12	$0,165 + 0,5 * (0,12 - 0,165) = 0,1425$ $0,29 + 0,5 * (0,32 - 0,29) = 0,305$ $0,455 + 0,5 * (0,13 - 0,455) = 0,2925$ $0,425 + 0,5 * (0,29 - 0,425) = 0,3575$ $0,4 + 0,5 * (0,25 - 0,4) = 0,325$ $0,815 + 0,5 * (0,81 - 0,815) = 0,8125$
P13	$0,225 + 0,5 * (0,12 - 0,225) = 0,1725$ $0,11 + 0,5 * (0,32 - 0,11) = 0,215$ $0,06 + 0,5 * (0,13 - 0,06) = 0,095$ $0,47 + 0,5 * (0,29 - 0,47) = 0,38$ $0,545 + 0,5 * (0,25 - 0,545) = 0,3975$ $0,7 + 0,5 * (0,81 - 0,7) = 0,755$

Neurônio:	Cálculos
P21	$0,585 + 0,5 * (0,12 - 0,585) = 0,3525$ $0,22 + 0,5 * (0,32 - 0,22) = 0,27$ $0,33 + 0,5 * (0,13 - 0,33) = 0,23$ $0,44 + 0,5 * (0,29 - 0,44) = 0,365$ $0,605 + 0,5 * (0,25 - 0,605) = 0,4275$ $0,565 + 0,5 * (0,81 - 0,565) = 0,6875$
P22	$0,3587 + 0,5 * (0,12 - 0,3587) = 0,2393$ $0,1537 + 0,5 * (0,32 - 0,1537) = 0,2368$ $0,1837 + 0,5 * (0,13 - 0,1837) = 0,1568$ $0,4925 + 0,5 * (0,29 - 0,4925) = 0,3912$ $0,6475 + 0,5 * (0,25 - 0,6475) = 0,4487$ $0,6875 + 0,5 * (0,81 - 0,6875) = 0,7487$
P23	$0,4875 + 0,5 * (0,12 - 0,4875) = 0,3037$ $0,2375 + 0,5 * (0,32 - 0,2375) = 0,2787$ $0,11 + 0,5 * (0,13 - 0,11) = 0,12$ $0,5425 + 0,5 * (0,29 - 0,5425) = 0,4162$ $0,65 + 0,5 * (0,25 - 0,45) = 0,45$ $0,5925 + 0,5 * (0,81 - 0,5925) = 0,7012$

A matriz de pesos atualizada após a apresentação do quarto padrão é apresentada a seguir:

$$P = \begin{bmatrix} 0,155 & 0,1425 & 0,1725 \\ 0,26 & 0,305 & 0,215 \\ 0,07 & 0,2925 & 0,095 \\ 0,22 & 0,3675 & 0,38 \\ 0,425 & 0,325 & 0,3975 \\ 0,53 & 0,8125 & 0,755 \\ \\ 0,3525 & 0,2393 & 0,3037 \\ 0,27 & 0,2368 & 0,2787 \\ 0,23 & 0,1568 & 0,12 \\ 0,365 & 0,3912 & 0,4162 \\ 0,4275 & 0,4487 & 0,45 \\ 0,6875 & 0,7487 & 0,7012 \\ \\ 0,5325 & 0,5475 & 0,72 \\ 0,1325 & 0,1475 & 0,295 \\ 0,3525 & 0,39 & 0,5 \\ 0,495 & 0,635 & 0,55 \\ 0,625 & 0,8325 & 0,515 \\ 0,52 & 0,69 & 0,355 \end{bmatrix}$$

O quinto padrão [0,19 0,72 0,05 0,62 0,57 0,67] é apresentado à rede.

Encontra-se o **neurônio vencedor** para este padrão utilizando a matriz de pesos atualizada.

Neurônio:	Cálculos
P11	$(0,19-0,155)^2 + (0,72-0,26)^2 + (0,05-0,07)^2 + (0,62-0,22)^2 + (0,57-0,425)^2 + (0,67-0,53)^2 = 0,4138$
P12	$(0,19-0,1425)^2 + (0,72-0,305)^2 + (0,05-0,2925)^2 + (0,62-0,3575)^2 + (0,57-0,325)^2 + (0,67-0,8125)^2 = 0,3825$
P13	$(0,19-0,1725)^2 + (0,72-0,215)^2 + (0,05-0,095)^2 + (0,62-0,38)^2 + (0,57-0,3975)^2 + (0,67-0,755)^2 = 0,3519$
P21	$(0,19-0,3525)^2 + (0,72-0,27)^2 + (0,05-0,23)^2 + (0,62-0,365)^2 + (0,57-0,4275)^2 + (0,67-0,6875)^2 = 0,3469$
P22	$(0,19-0,2393)^2 + (0,72-0,2368)^2 + (0,05-0,1568)^2 + (0,62-0,3912)^2 + (0,57-0,4487)^2 + (0,67-0,7487)^2 = 0,3204$
P23	$(0,19-0,3037)^2 + (0,72-0,2787)^2 + (0,05-0,12)^2 + (0,62-0,4162)^2 + (0,57-0,45)^2 + (0,67-0,7012)^2 = 0,2694$
P31	$(0,19-0,5325)^2 + (0,72-0,1325)^2 + (0,05-0,3525)^2 + (0,62-0,495)^2 + (0,57-0,625)^2 + (0,67-0,52)^2 = 0,5951$
P32	$(0,19-0,5475)^2 + (0,72-0,1475)^2 + (0,05-0,39)^2 + (0,62-0,635)^2 + (0,57-0,8325)^2 + (0,67-0,69)^2 = 0,6406$
P33	$(0,19-0,72)^2 + (0,72-0,295)^2 + (0,05-0,5)^2 + (0,62-0,55)^2 + (0,57-0,515)^2 + (0,67-0,355)^2 = 0,7711$

O neurônio P23 apresentou o menor valor, sendo considerado o neurônio vencedor.

Os neurônios que terão seus pesos atualizados devem pertencer a sua vizinhança num raio topológico de um neurônio, desta forma serão atualizados os neurônios: P12, P13, P22, P23, P3 e P33, pois está sendo utilizada uma grade de vizinhança retangular.

$$P = \begin{vmatrix} P11 & P12 & P13 \\ P21 & P22 & P23 \\ P31 & P32 & P33 \end{vmatrix}$$

O neurônio vencedor é apresentado na tonalidade vermelha e os neurônios vizinhos, considerando o raio topológico igual a 1 em azul.

Portanto os novos valores destes neurônios foram calculados pela fórmula de atualização do algoritmo:

$$\text{peso}_{(\text{nov})} = \text{peso}_{(\text{atual})} + \text{taxa de aprendizagem} * (\text{vetor} - \text{peso}_{(\text{atual})})$$

Neurônio:	Cálculos
P12	$0,1425+0,5*(0,19-0,1425)=0,1662$ $0,305+0,5*(0,72-0,305)=0,5125$ $0,2925+0,5*(0,05-0,2925)=0,1712$ $0,3575+0,5*(0,62-0,3575)=0,4887$ $0,325+0,5*(0,57-0,325)=0,4475$ $0,8125+0,5*(0,67-0,8125)=0,7412$
P13	$0,1725+0,5*(0,19-0,1725)=0,1812$ $0,215+0,5*(0,72-0,215)=0,4675$ $0,095+0,5*(0,05-0,095)=0,0725$ $0,38+0,5*(0,62-0,38)=0,5$ $0,3975+0,5*(0,57-0,3975)=0,48375$ $0,755+0,5*(0,67-0,755)=0,7125$
P22	$0,2393+0,5*(0,19-0,2393)=0,2146$ $0,2368+0,5*(0,72-0,2368)=0,4784$ $0,1568+0,5*(0,05-0,1568)=0,1034$ $0,3912+0,5*(0,62-0,3912)=0,5056$ $0,4487+0,5*(0,57-0,4487)=0,5093$ $0,7487+0,5*(0,67-0,7487)=0,7093$

Neurônio:	Cálculos
P23	$0,3037+0,5*(0,19-0,3037)=0,2468$ $0,2787+0,5*(0,72-0,2787)=0,4993$ $0,12+0,5*(0,05-0,12)=0,085$ $0,4162+0,5*(0,62-0,4162)=0,5181$ $0,45+0,5*(0,57-0,45)=0,51$ $0,7012+0,5*(0,67-0,7012)=0,6856$
P32	$0,5475+0,5*(0,19-0,5475)=0,36875$ $0,1475+0,5*(0,72-0,1475)=0,4337$ $0,39+0,5*(0,05-0,39)=0,22$ $0,635+0,5*(0,62-0,635)=0,6275$ $0,8325+0,5*(0,57-0,8325)=0,7012$ $0,69+0,5*(0,67-0,69)=0,68$
P33	$0,72+0,5*(0,19-0,72)=0,455$ $0,295+0,5*(0,72-0,295)=0,5075$ $0,5+0,5*(0,05-0,5)=0,275$ $0,55+0,5*(0,62-0,55)=0,585$ $0,515+0,5*(0,57-0,515)=0,5425$ $0,355+0,5*(0,67-0,355)=0,5125$

A matriz de pesos atualizada após a apresentação do quinto padrão é apresentada a seguir:

P =	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,3525	0,2146	0,2468
	0,27	0,4784	0,4993
	0,23	0,1034	0,085
	0,365	0,5056	0,5181
	0,4275	0,5093	0,51
	0,6875	0,7093	0,6856
	0,5325	0,3687	0,455
	0,1325	0,4337	0,5075
	0,3525	0,22	0,275

Aqui termina a primeira iteração (ou época). Para início da segunda iteração, a taxa de aprendizagem será 0,25 e o raio topológico igual a zero (atualizando somente o neurônio vencedor).

O processo inicia novamente com a apresentação do primeiro padrão [0,43 0,18 0,58 0,09 0,69 0,39] e a verificação do neurônio vencedor:

Neurônio:	Cálculos
P11	$(0,43-0,155)^2 + (0,18-0,26)^2 + (0,58-0,07)^2 + (0,09-0,22)^2 + (0,69-0,425)^2 + (0,39-0,53)^2 = 0,4488$
P12	$(0,43-0,1662)^2 + (0,18-0,5125)^2 + (0,58-0,1712)^2 + (0,09-0,4887)^2 + (0,69-0,4475)^2 + (0,39-0,7412)^2 = 0,6883$
P13	$(0,43-0,1812)^2 + (0,18-0,4675)^2 + (0,58-0,0725)^2 + (0,09-0,5)^2 + (0,69-0,4837)^2 + (0,39-0,7125)^2 = 0,7167$
P21	$(0,43-0,3525)^2 + (0,18-0,27)^2 + (0,58-0,23)^2 + (0,09-0,365)^2 + (0,69-0,4275)^2 + (0,39-0,6875)^2 = 0,3696$
P22	$(0,43-0,2146)^2 + (0,18-0,4784)^2 + (0,58-0,1034)^2 + (0,09-0,5056)^2 + (0,69-0,5093)^2 + (0,39-0,7093)^2 = 0,6699$
P23	$(0,43-0,2468)^2 + (0,18-0,4993)^2 + (0,58-0,085)^2 + (0,09-0,5181)^2 + (0,69-0,51)^2 + (0,39-0,6856)^2 = 0,6836$
P31	$(0,43-0,5325)^2 + (0,18-0,1325)^2 + (0,58-0,3525)^2 + (0,09-0,495)^2 + (0,69-0,625)^2 + (0,39-0,52)^2 = 0,2496$
P32	$(0,43-0,3687)^2 + (0,18-0,4337)^2 + (0,58-0,22)^2 + (0,09-0,6275)^2 + (0,69-0,7012)^2 + (0,39-0,68)^2 = 0,5708$
P33	$(0,43-0,455)^2 + (0,18-0,5075)^2 + (0,58-0,275)^2 + (0,09-0,585)^2 + (0,69-0,5425)^2 + (0,39-0,5125)^2 = 0,4826$

O neurônio P31 apresentou o menor valor, sendo considerado o neurônio vencedor e será o único neurônio a ser atualizado.

Neurônio:	Cálculos
P31	$0,5325+0,25*(0,43-0,5325)=0,5068$
	$0,1325+0,25*(0,18-0,1325)=0,1443$
	$0,3525+0,25*(0,58-0,3525)=0,4093$
	$0,495+0,25*(0,09-0,495)=0,3937$
	$0,625+0,25*(0,69-0,625)=0,6412$
	$0,52+0,25*(0,39-0,52)=0,4875$

A matriz de pesos atualizada após a apresentação do primeiro padrão na segunda iteração é apresentada a seguir:

P =	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,3525	0,2146	0,2468
	0,27	0,4784	0,4993
	0,23	0,1034	0,085
	0,365	0,5056	0,5181
	0,4275	0,5093	0,51
	0,6875	0,7093	0,6856
	0,5068	0,3687	0,455
	0,1443	0,4337	0,5075
	0,4093	0,22	0,275
	0,3937	0,6275	0,585
	0,6412	0,7012	0,5425
	0,4875	0,68	0,5125

Apresenta-se o segundo padrão [0,66 0,03 0,18 0,83 0,85 0,69] e verificação do neurônio vencedor:

Neurônio:	Cálculos
P11	$(0,66-0,155)^2 + (0,03-0,26)^2 + (0,18-0,07)^2 + (0,83-0,22)^2 + (0,85-0,425)^2 + (0,69-0,53)^2 = 0,8983$
P12	$(0,66-0,1662)^2 + (0,03-0,5125)^2 + (0,18-0,1712)^2 + (0,83-0,4887)^2 + (0,85-0,4475)^2 + (0,69-0,7412)^2 = 0,7577$
P13	$(0,66-0,1812)^2 + (0,03-0,4675)^2 + (0,18-0,0725)^2 + (0,83-0,5)^2 + (0,85-0,4837)^2 + (0,69-0,7125)^2 = 0,6757$
P21	$(0,66-0,3525)^2 + (0,03-0,27)^2 + (0,18-0,23)^2 + (0,83-0,365)^2 + (0,85-0,4275)^2 + (0,69-0,6875)^2 = 0,5493$
P22	$(0,66-0,2146)^2 + (0,03-0,4784)^2 + (0,18-0,1034)^2 + (0,83-0,5056)^2 + (0,85-0,5093)^2 + (0,69-0,7093)^2 = 0,6268$
P23	$(0,66-0,2468)^2 + (0,03-0,4993)^2 + (0,18-0,085)^2 + (0,83-0,5181)^2 + (0,85-0,51)^2 + (0,69-0,6856)^2 = 0,6128$
P31	$(0,66-0,5068)^2 + (0,03-0,1443)^2 + (0,18-0,4093)^2 + (0,83-0,3937)^2 + (0,85-0,6412)^2 + (0,69-0,4875)^2 = 0,3640$
P32	$(0,66-0,3687)^2 + (0,03-0,4337)^2 + (0,18-0,22)^2 + (0,83-0,6275)^2 + (0,85-0,7012)^2 + (0,69-0,68)^2 = 0,3126$
P33	$(0,66-0,455)^2 + (0,03-0,5075)^2 + (0,18-0,275)^2 + (0,83-0,585)^2 + (0,85-0,5425)^2 + (0,69-0,5125)^2 = 0,4651$

O neurônio P32 apresentou o menor valor, sendo considerado o neurônio vencedor e será o único neurônio a ser atualizado.

Neurônio:	Cálculos
P32	$0,3687+0,25*(0,66-0,3687) = 0,4415$ $0,4337+0,25*(0,03-0,4337) = 0,3328$ $0,22+0,25*(0,18-0,22) = 0,21$ $0,6275+0,25*(0,83-0,6275) = 0,6781$ $0,7012+0,25*(0,85-0,7012) = 0,7384$ $0,68+0,25*(0,69-0,68) = 0,6825$

A matriz de pesos atualizada após a apresentação do segundo padrão na segunda iteração é apresentada a seguir:

P =	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,3525	0,2146	0,2468
	0,27	0,4784	0,4993
	0,23	0,1034	0,085
	0,365	0,5056	0,5181
	0,4275	0,5093	0,51
	0,6875	0,7093	0,6856
	0,5068	0,4415	0,455
	0,1443	0,3328	0,5075
	0,4093	0,21	0,275

O terceiro padrão [0,28 0,17 0,11 0,33 0,59 0,71] é apresentado à rede e verifica-se o neurônio vencedor:

Neurônio:	Cálculos
P11	$(0,28-0,155)^2 + (0,17-0,26)^2 + (0,11-0,07)^2 + (0,33-0,22)^2 + (0,59-0,425)^2 + (0,71-0,53)^2 = 0,0970$
P12	$(0,28-0,1625)^2 + (0,17-0,5125)^2 + (0,11-0,1712)^2 + (0,33-0,4887)^2 + (0,59-0,4475)^2 + (0,71-0,7412)^2 = 0,1804$
P13	$(0,28-0,1812)^2 + (0,17-0,4675)^2 + (0,11-0,0725)^2 + (0,33-0,5)^2 + (0,59-0,4837)^2 + (0,71-0,7125)^2 = 0,1398$
P21	$(0,28-0,3525)^2 + (0,17-0,27)^2 + (0,11-0,23)^2 + (0,33-0,365)^2 + (0,59-0,4275)^2 + (0,71-0,6875)^2 = 0,0577$
P22	$(0,28-0,2146)^2 + (0,17-0,4784)^2 + (0,11-0,1034)^2 + (0,33-0,5056)^2 + (0,59-0,5093)^2 + (0,71-0,7093)^2 = 0,1367$
P23	$(0,28-0,2468)^2 + (0,17-0,4993)^2 + (0,11-0,085)^2 + (0,33-0,5181)^2 + (0,59-0,51)^2 + (0,71-0,6856)^2 = 0,1525$
P31	$(0,28-0,5068)^2 + (0,17-0,1443)^2 + (0,11-0,4093)^2 + (0,33-0,3937)^2 + (0,59-0,6412)^2 + (0,71-0,4875)^2 = 0,1979$
P32	$(0,28-0,4415)^2 + (0,17-0,3328)^2 + (0,11-0,21)^2 + (0,33-0,6781)^2 + (0,59-0,7384)^2 + (0,71-0,6825)^2 = 0,2065$
P33	$(0,28-0,455)^2 + (0,17-0,5075)^2 + (0,11-0,275)^2 + (0,33-0,585)^2 + (0,59-0,5425)^2 + (0,71-0,5125)^2 = 0,2780$

O neurônio P21 apresentou o menor valor, sendo considerado o neurônio vencedor e será o único neurônio a ser atualizado.

Neurônio:	Cálculos
P21	$0,3525+0,25*(0,28-0,3525) = 0,3343$
	$0,27+0,25*(0,17-0,27) = 0,245$
	$0,23+0,25*(0,11-0,23) = 0,2$
	$0,365+0,25*(0,33-0,365) = 0,3562$
	$0,4275+0,25*(0,59-0,4275) = 0,4681$
	$0,6875+0,25*(0,71-0,6875) = 0,6931$

A matriz de pesos atualizada após a apresentação do terceiro padrão na segunda iteração é apresentada a seguir:

P =	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,3525	0,2146	0,2468
	0,27	0,4784	0,4993
	0,23	0,1034	0,085
	0,365	0,5056	0,5181
	0,4275	0,5093	0,51
	0,6875	0,7093	0,6856
	0,5068	0,4415	0,455
	0,1443	0,3328	0,5075
	0,4093	0,21	0,275
	0,3937	0,6781	0,585
	0,6412	0,7384	0,5425
	0,4875	0,6825	0,5125

O quarto padrão [0,12 0,32 0,13 0,29 0,25 0,81] é apresentado à rede e verifica-se o neurônio vencedor:

Neurônio:	Cálculos
P11	$(0,12-0,155)^2 + (0,32-0,26)^2 + (0,13-0,07)^2 + (0,29-0,22)^2 + (0,25-0,425)^2 + (0,81-0,53)^2 = 0,1223$
P12	$(0,12-0,1662)^2 + (0,32-0,5125)^2 + (0,13-0,1712)^2 + (0,29-0,4887)^2 + (0,25-0,4475)^2 + (0,81-0,7412)^2 = 0,1241$
P13	$(0,12-0,1812)^2 + (0,32-0,4675)^2 + (0,13-0,0725)^2 + (0,29-0,5)^2 + (0,25-0,4837)^2 + (0,81-0,7125)^2 = 0,1370$
P21	$(0,12-0,3343)^2 + (0,32-0,245)^2 + (0,13-0,2)^2 + (0,29-0,3562)^2 + (0,25-0,4681)^2 + (0,81-0,6931)^2 = 0,1221$
P22	$(0,12-0,2146)^2 + (0,32-0,4784)^2 + (0,13-0,1034)^2 + (0,29-0,5056)^2 + (0,25-0,5093)^2 + (0,81-0,7093)^2 = 0,1586$
P23	$(0,12-0,2468)^2 + (0,32-0,4993)^2 + (0,13-0,085)^2 + (0,29-0,5181)^2 + (0,25-0,51)^2 + (0,81-0,6856)^2 = 0,1854$
P31	$(0,12-0,5068)^2 + (0,32-0,1443)^2 + (0,13-0,4093)^2 + (0,29-0,3937)^2 + (0,25-0,6412)^2 + (0,81-0,4875)^2 = 0,5264$
P32	$(0,12-0,4415)^2 + (0,32-0,3328)^2 + (0,13-0,21)^2 + (0,29-0,6781)^2 + (0,25-0,7384)^2 + (0,81-0,6825)^2 = 0,5154$
P33	$(0,12-0,455)^2 + (0,32-0,5075)^2 + (0,13-0,275)^2 + (0,29-0,585)^2 + (0,25-0,5425)^2 + (0,81-0,5125)^2 = 0,4294$

O neurônio P21 apresentou o menor valor, sendo considerado o neurônio vencedor e será o único neurônio a ser atualizado.

Neurônio:	Cálculos
P21	$0,3343+0,25*(0,12-0,3343) = 0,2807$
	$0,245+0,25*(0,32-0,245) = 0,2637$
	$0,2+0,25*(0,13-0,2) = 0,1825$
	$0,3562+0,25*(0,29-0,3562) = 0,3396$
	$0,4681+0,25*(0,25-0,4681) = 0,4135$
	$0,6931+0,25*(0,81-0,6931) = 0,7223$

A matriz de pesos atualizada após a apresentação do quarto padrão na segunda iteração é apresentada a seguir:

	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,2807	0,2146	0,2468
	0,2637	0,4784	0,4993
	0,1825	0,1034	0,085
P =	0,3396	0,5056	0,5181
	0,4135	0,5093	0,51
	0,7223	0,7093	0,6856
	0,5068	0,4415	0,455
	0,1443	0,3328	0,5075
	0,4093	0,21	0,275
	0,3937	0,6781	0,585
	0,6412	0,7384	0,5425
	0,4875	0,6825	0,5125

O quinto padrão [0,19 0,72 0,05 0,62 0,57 0,67] é apresentado à rede e verifica-se o neurônio vencedor:

Neurônio:	Cálculos
P11	$(0,19-0,155)^2 + (0,72-0,26)^2 + (0,05-0,07)^2 + (0,62-0,22)^2 + (0,57-0,425)^2 + (0,67-0,53)^2 = 0,4138$
P12	$(0,19-0,1662)^2 + (0,72-0,5125)^2 + (0,05-0,1712)^2 + (0,62-0,4887)^2 + (0,57-0,4475)^2 + (0,67-0,7412)^2 = 0,0956$
P13	$(0,19-0,1812)^2 + (0,72-0,4675)^2 + (0,05-0,0725)^2 + (0,62-0,5)^2 + (0,57-0,4837)^2 + (0,67-0,7125)^2 = 0,0879$
P21	$(0,19-0,2807)^2 + (0,72-0,2637)^2 + (0,05-0,1825)^2 + (0,62-0,3396)^2 + (0,57-0,4135)^2 + (0,67-0,7223)^2 = 0,3397$
P22	$(0,19-0,2146)^2 + (0,72-0,4784)^2 + (0,05-0,1034)^2 + (0,62-0,5056)^2 + (0,57-0,5093)^2 + (0,67-0,7093)^2 = 0,0801$
P23	$(0,19-0,2468)^2 + (0,72-0,4993)^2 + (0,05-0,085)^2 + (0,62-0,5181)^2 + (0,57-0,51)^2 + (0,67-0,6856)^2 = 0,0673$
P31	$(0,19-0,5068)^2 + (0,72-0,1443)^2 + (0,05-0,4093)^2 + (0,62-0,3937)^2 + (0,57-0,6412)^2 + (0,67-0,4875)^2 = 0,6504$
P32	$(0,19-0,4415)^2 + (0,72-0,3328)^2 + (0,05-0,21)^2 + (0,62-0,6781)^2 + (0,57-0,7384)^2 + (0,67-0,6825)^2 = 0,2707$
P33	$(0,19-0,455)^2 + (0,72-0,5075)^2 + (0,05-0,275)^2 + (0,62-0,585)^2 + (0,57-0,5425)^2 + (0,67-0,5125)^2 = 0,1927$

O neurônio P23 apresentou o menor valor, sendo considerado o neurônio vencedor e será o único neurônio a ser atualizado.

Neurônio:	Cálculos
P23	$0,2468+0,25*(0,19-0,2468) = 0,2326$
	$0,4993+0,25*(0,72-0,4993) = 0,5545$
	$0,085+0,25*(0,05-0,085) = 0,0762$
	$0,5181+0,25*(0,62-0,5181) = 0,5435$
	$0,51+0,25*(0,57-0,51) = 0,525$
	$0,6856+0,25*(0,67-0,6856) = 0,6817$

A matriz de pesos atualizada após a apresentação do quinto padrão na segunda iteração é apresentada a seguir:

	0,155	0,1662	0,1812
	0,26	0,5125	0,4675
	0,07	0,1712	0,0725
	0,22	0,4887	0,5
	0,425	0,4475	0,4837
	0,53	0,7412	0,7125
	0,2807	0,2146	0,2326
	0,2637	0,4784	0,5545
	0,1825	0,1034	0,0762
P =	0,3396	0,5056	0,5435
	0,4135	0,5093	0,525
	0,7223	0,7093	0,6817
	0,5068	0,4415	0,455
	0,1443	0,3328	0,5075
	0,4093	0,21	0,275
	0,3937	0,6781	0,585
	0,6412	0,7384	0,5425
	0,4875	0,6825	0,5125

Finaliza-se, assim, a segunda iteração (ou época). Deve-se continuar o processo até que um dos critérios de parada escolhidos seja satisfeito. Os critérios podem ser: número de iterações e/ou pelas alterações na matriz de pesos (a partir do momento que não forem significativas).

Considerando que neste ponto do exemplo, um critério de parada foi satisfeito. O próximo passo é a verificação de onde cada padrão será alocado.

O cálculo foi feito considerando a menor distância, que corresponde matematicamente ao valor máximo do produto interno do padrão a ser classificado e os vetores da matriz peso (neurônio).

Para o primeiro padrão: [0,43 0,18 0,58 0,09 0,69 0,39]:

Neurônio:	Cálculos
P11	$(0,43-0,155)^2 + (0,18-0,26)^2 + (0,58-0,07)^2 + (0,09-0,22)^2 + (0,69-0,425)^2 + (0,39-0,53)^2 = 0,4488$
P12	$(0,43-0,1662)^2 + (0,18-0,5125)^2 + (0,58-0,1712)^2 + (0,09-0,4887)^2 + (0,69-0,4475)^2 + (0,39-0,7412)^2 = 0,6883$
P13	$(0,43-0,1812)^2 + (0,18-0,4675)^2 + (0,58-0,0725)^2 + (0,09-0,5)^2 + (0,69-0,4837)^2 + (0,39-0,7125)^2 = 0,7167$
P21	$(0,43-0,2807)^2 + (0,18-0,2637)^2 + (0,58-0,1825)^2 + (0,09-0,3396)^2 + (0,69-0,4135)^2 + (0,39-0,7223)^2 = 0,4364$
P22	$(0,43-0,2146)^2 + (0,18-0,4784)^2 + (0,58-0,1034)^2 + (0,09-0,5056)^2 + (0,69-0,5093)^2 + (0,39-0,7093)^2 = 0,6699$
P23	$(0,43-0,2326)^2 + (0,18-0,5545)^2 + (0,58-0,0762)^2 + (0,09-0,5435)^2 + (0,69-0,525)^2 + (0,39-0,6817)^2 = 0,7510$
P31	$(0,43-0,5068)^2 + (0,18-0,1443)^2 + (0,58-0,4093)^2 + (0,09-0,3937)^2 + (0,69-0,6412)^2 + (0,39-0,4875)^2 = 0,1404$
P32	$(0,43-0,4415)^2 + (0,18-0,3328)^2 + (0,58-0,21)^2 + (0,09-0,6781)^2 + (0,69-0,7384)^2 + (0,39-0,6825)^2 = 0,5941$
P33	$(0,43-0,455)^2 + (0,18-0,5075)^2 + (0,58-0,275)^2 + (0,09-0,585)^2 + (0,69-0,5425)^2 + (0,39-0,5125)^2 = 0,4826$

Para o segundo padrão: [0,66 0,03 0,18 0,83 0,85 0,69]:

Neurônio:	Cálculos
P11	$(0,66-0,155)^2 + (0,03-0,26)^2 + (0,18-0,07)^2 + (0,83-0,22)^2 + (0,85-0,425)^2 + (0,69-0,53)^2 = 0,8983$
P12	$(0,66-0,1662)^2 + (0,03-0,5125)^2 + (0,18-0,1712)^2 + (0,83-0,4887)^2 + (0,85-0,4475)^2 + (0,69-0,7412)^2 = 0,7577$
P13	$(0,66-0,1812)^2 + (0,03-0,4675)^2 + (0,18-0,0725)^2 + (0,83-0,5)^2 + (0,85-0,4837)^2 + (0,69-0,7125)^2 = 0,6757$
P21	$(0,66-0,2807)^2 + (0,03-0,2637)^2 + (0,18-0,1825)^2 + (0,83-0,3396)^2 + (0,85-0,4135)^2 + (0,69-0,7223)^2 = 0,6303$
P22	$(0,66-0,2146)^2 + (0,03-0,4784)^2 + (0,18-0,1034)^2 + (0,83-0,5056)^2 + (0,85-0,5093)^2 + (0,69-0,7093)^2 = 0,6268$
P23	$(0,66-0,2326)^2 + (0,03-0,5545)^2 + (0,18-0,0762)^2 + (0,83-0,5435)^2 + (0,85-0,525)^2 + (0,69-0,6817)^2 = 0,6562$
P31	$(0,66-0,5068)^2 + (0,03-0,1443)^2 + (0,18-0,4093)^2 + (0,83-0,3937)^2 + (0,85-0,6412)^2 + (0,69-0,4875)^2 = 0,3640$
P32	$(0,66-0,4415)^2 + (0,03-0,3328)^2 + (0,18-0,21)^2 + (0,83-0,6781)^2 + (0,85-0,7384)^2 + (0,69-0,6825)^2 = 0,1758$
P33	$(0,66-0,455)^2 + (0,03-0,5075)^2 + (0,18-0,275)^2 + (0,83-0,585)^2 + (0,85-0,5425)^2 + (0,69-0,5125)^2 = 0,4651$

Para o terceiro padrão: [0,28 0,17 0,11 0,33 0,59 0,71]:

Neurônio:	Cálculos
P11	$(0,28-0,155)^2 + (0,17-0,26)^2 + (0,11-0,07)^2 + (0,33-0,22)^2 + (0,59-0,425)^2 + (0,71-0,53)^2 = 0,0970$
P12	$(0,28-0,1662)^2 + (0,17-0,5125)^2 + (0,11-0,1712)^2 + (0,33-0,4887)^2 + (0,59-0,4475)^2 + (0,71-0,7412)^2 = 0,1804$
P13	$(0,28-0,1812)^2 + (0,17-0,4675)^2 + (0,11-0,0725)^2 + (0,33-0,5)^2 + (0,59-0,4837)^2 + (0,71-0,7125)^2 = 0,1398$
P21	$(0,28-0,2807)^2 + (0,17-0,2637)^2 + (0,11-0,1825)^2 + (0,33-0,3396)^2 + (0,59-0,4135)^2 + (0,71-0,7223)^2 = 0,0454$
P22	$(0,28-0,2146)^2 + (0,17-0,4784)^2 + (0,11-0,1034)^2 + (0,33-0,5056)^2 + (0,59-0,5093)^2 + (0,71-0,7093)^2 = 0,1367$
P23	$(0,28-0,2326)^2 + (0,17-0,5545)^2 + (0,11-0,0762)^2 + (0,33-0,5435)^2 + (0,59-0,525)^2 + (0,71-0,6817)^2 = 0,2018$
P31	$(0,28-0,5068)^2 + (0,17-0,1443)^2 + (0,11-0,4093)^2 + (0,33-0,3937)^2 + (0,59-0,6412)^2 + (0,71-0,4875)^2 = 0,1979$
P32	$(0,28-0,4415)^2 + (0,17-0,3328)^2 + (0,11-0,21)^2 + (0,33-0,6781)^2 + (0,59-0,7384)^2 + (0,71-0,6825)^2 = 0,2065$
P33	$(0,28-0,455)^2 + (0,17-0,5075)^2 + (0,11-0,275)^2 + (0,33-0,585)^2 + (0,59-0,5425)^2 + (0,71-0,5125)^2 = 0,2780$

Para o quarto padrão: [0,12 0,32 0,13 0,29 0,25 0,81]:

Neurônio:	Cálculos
P11	$(0,12-0,155)^2 + (0,32-0,26)^2 + (0,13-0,07)^2 + (0,29-0,22)^2 + (0,25-0,425)^2 + (0,81-0,53)^2 = 0,1223$
P12	$(0,12-0,1662)^2 + (0,32-0,5125)^2 + (0,13-0,1712)^2 + (0,29-0,4887)^2 + (0,25-0,4475)^2 + (0,81-0,7412)^2 = 0,1241$
P13	$(0,12-0,1812)^2 + (0,32-0,4675)^2 + (0,13-0,0725)^2 + (0,29-0,5)^2 + (0,25-0,4837)^2 + (0,81-0,7125)^2 = 0,1370$
P21	$(0,12-0,2807)^2 + (0,32-0,2637)^2 + (0,13-0,1825)^2 + (0,29-0,3396)^2 + (0,25-0,4135)^2 + (0,81-0,7223)^2 = 0,0686$
P22	$(0,12-0,2146)^2 + (0,32-0,4784)^2 + (0,13-0,1034)^2 + (0,29-0,5056)^2 + (0,25-0,5093)^2 + (0,81-0,7093)^2 = 0,1586$
P23	$(0,12-0,2326)^2 + (0,32-0,5545)^2 + (0,13-0,0762)^2 + (0,29-0,5435)^2 + (0,25-0,525)^2 + (0,81-0,6817)^2 = 0,2269$
P31	$(0,12-0,5068)^2 + (0,32-0,1443)^2 + (0,13-0,4093)^2 + (0,29-0,3937)^2 + (0,25-0,6412)^2 + (0,81-0,4875)^2 = 0,5264$
P32	$(0,12-0,4415)^2 + (0,32-0,3328)^2 + (0,13-0,21)^2 + (0,29-0,6781)^2 + (0,25-0,7384)^2 + (0,81-0,6825)^2 = 0,5154$
P33	$(0,12-0,455)^2 + (0,32-0,5075)^2 + (0,13-0,275)^2 + (0,29-0,585)^2 + (0,25-0,5425)^2 + (0,81-0,5125)^2 = 0,4294$

Para o quinto padrão: [0,19 0,72 0,05 0,62 0,57 0,67]:

Neurônio:	Cálculos
P11	$(0,19-0,155)^2 + (0,72-0,26)^2 + (0,05-0,07)^2 + (0,62-0,22)^2 + (0,57-0,425)^2 + (0,67-0,53)^2 = 0,4138$
P12	$(0,19-0,1662)^2 + (0,72-0,5125)^2 + (0,05-0,1712)^2 + (0,62-0,4887)^2 + (0,57-0,4475)^2 + (0,67-0,7412)^2 = 0,0956$
P13	$(0,19-0,1812)^2 + (0,72-0,4675)^2 + (0,05-0,0725)^2 + (0,62-0,5)^2 + (0,57-0,4837)^2 + (0,67-0,7125)^2 = 0,0879$
P21	$(0,19-0,2807)^2 + (0,72-0,2637)^2 + (0,05-0,1825)^2 + (0,62-0,3396)^2 + (0,57-0,4135)^2 + (0,67-0,7223)^2 = 0,3397$
P22	$(0,19-0,2146)^2 + (0,72-0,4784)^2 + (0,05-0,1034)^2 + (0,62-0,5056)^2 + (0,57-0,5093)^2 + (0,67-0,7093)^2 = 0,0801$
P23	$(0,19-0,2326)^2 + (0,72-0,5545)^2 + (0,05-0,0762)^2 + (0,62-0,5435)^2 + (0,57-0,525)^2 + (0,67-0,6817)^2 = 0,0378$
P31	$(0,19-0,5068)^2 + (0,72-0,1443)^2 + (0,05-0,4093)^2 + (0,62-0,3937)^2 + (0,57-0,6412)^2 + (0,67-0,4875)^2 = 0,6504$
P32	$(0,19-0,4415)^2 + (0,72-0,3328)^2 + (0,05-0,21)^2 + (0,62-0,6781)^2 + (0,57-0,7384)^2 + (0,67-0,6825)^2 = 0,2707$
P33	$(0,19-0,455)^2 + (0,72-0,5075)^2 + (0,05-0,275)^2 + (0,62-0,585)^2 + (0,57-0,5425)^2 + (0,67-0,5125)^2 = 0,1927$

Portanto, pode-se considerar que:

Padrão 1 → neurônio P31

Padrão 2 → neurônio P32

Padrão 3 → neurônio P21

Padrão 4 → neurônio P21

Padrão 5 → neurônio P22

Deste modo, tem-se a formação de 4 grupos. Observa-se abaixo a distribuição dos padrões nos neurônios (células) do mapa bidimensional:

Padrão 3 Padrão 4	Padrão 5	
Padrão 1	Padrão 2	