

UNIVERSIDADE FEDERAL DE PELOTAS

Instituto de Física e Matemática
Departamento de Informática



Trabalho de Conclusão de Curso

Redes Neurais: Utilização de Mapas Auto-Organizáveis na Classificação de Jogadores de Voleibol

Eduardo Frio Marins

Pelotas, 2008

EDUARDO FRIO MARINS

**REDES NEURAIIS: UTILIZAÇÃO DE MAPAS AUTO-
ORGANIZÁVEIS NA
CLASSIFICAÇÃO DE JOGADORES DE VOLEIBOL**

Trabalho de conclusão de curso apresentado ao curso de Bacharelado em Ciência da Computação da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Bacharel em Ciência da Computação.

Orientador: Prof. MSc. Anderson Priebe Ferrugem
Co-orientador: Prof. MSc. Renato Siqueira Rochefort

Pelotas, 2008

BANCA EXAMINADORA

Dedico à minha família e meus amigos. Esses sim, merecem o meu empenho.

AGRADECIMENTOS

Quero agradecer, em primeiro lugar, a Deus, pelo maior dom que Ele me deu, o da vida, e por todas as bênçãos que Ele me deu ao longo da vida, inclusive o fato de estar concluindo mais esta etapa, e acima de tudo, por Ele nunca ter me abandonado.

Ao Prof. MSc. Renato Siqueira Rochefort vai um agradecimento em especial pela atenção e colaboração demonstrada como co-orientador deste trabalho. Mesmo cheio de compromissos com seu doutorado não mediu esforços para contribuir com o trabalho.

Aos meus pais José Geraldo e Regina, que além de subsidiar essa minha caminhada com todas as minhas necessidades, também foram importantes me estimulando a nunca desistir.

Ao meu irmão Marcelo, o qual compreendia o porquê de eu estar à maioria das vezes, usando o computador até de madrugada, seja estudando ou fazendo trabalho.

Agradeço, principalmente, a minha namorada Thiana pela sua compreensão, paciência e tolerância. Além disso, por ser uma grande incentivadora nos meus momentos de fraqueza e angústia.

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 aos colegas Fábio, Piero e Roberto, os quais foram muito presentes durante a minha caminhada neste curso e não mediram esforços para me incentivar a nunca desistir.

A professora de Língua Portuguesa e amiga Suzana Tust, a qual contribuiu enormemente na estruturação e na correção deste trabalho.

Ao Prof. MSc. Anderson Priebe Ferrugem, que em virtude do trabalho possuir características interdisciplinares, mostrou-se interessado na área e assim inseriu idéias de sua área de atuação. Por ser uma pessoa alegre durante as reuniões e um grande motivador do trabalho interdisciplinar.

A Escola Superior de Educação Física - ESEF, através do Prof. MSc. Renato Siqueira Rochefort, pela disponibilização dos dados utilizados.

Ao meu grupo de Emaús Coríntios XII, o qual foi um grande incentivador nos momentos de dúvida no decorrer de toda a graduação.

Finalizo, agradecendo a todos que, de alguma forma, contribuíram para a conclusão deste trabalho.

*“Pedi força e vigor.
Deus me mandou dificuldades para me
fazer forte.
Pedi sabedoria.
Deus me deu problemas para resolver.
Pedi prosperidade.
Deus me deu energia e cérebro para
trabalhar.
Pedi coragem.
Deus me mandou situações para superar.
Pedi favores.
Deus me deu oportunidades.
Não recebi nada do que queria.
Recebi tudo o que precisava.
Minhas orações foram atendidas!”*

Resumo

MARINS, Eduardo Frio. **Redes Neurais: Utilização de Mapas Auto-Organizáveis na Classificação de Jogadores de Voleibol.** 2008. 72f. Monografia - Curso de Bacharelado em Ciência da Computação. Universidade Federal de Pelotas.

Mapas auto-organizáveis estão sendo aplicados em diversas áreas, com especial destaque para problemas de análise exploratória de dados multivariados. Porém, na área esportiva, especificamente no voleibol, onde os dados coletados (scouts) de uma competição são dessa natureza, a técnica não tem sido muito explorada. Este trabalho apresenta uma metodologia para a análise desses dados utilizando, como ferramentas, o Mapa Auto-Organizável e seus algoritmos. A modelagem abrange os dados a respeito dos melhores em cada fundamento, dados sobre o grupo de jogadores como um todo, além da relação entre eles e seu aproveitamento individual na competição. Com essa ferramenta pode-se reduzir o número de dados dos agrupamentos, e assim projetar os dados de uma forma não linear em uma rede bidimensional. Os resultados são expressos e analisados visando a compreensão dos motivos pelo baixo ou alto desempenho de uma atleta em uma competição, visto que muitos treinadores e/ou preparadores físicos buscam em suas equipes a padronização dos jogadores. A utilização dos Mapas Auto-Organizáveis e de seus algoritmos mostrou-se uma ferramenta robusta para a classificação dos dados multivariados, e de forma rápida apresentou os resultados dos agrupamentos com bastante clareza, facilitando assim a hermenêutica e posterior comparação dos resultados obtidos.

Palavras-chave: Rede Neural Artificial; Redes de Kohonen; voleibol e *scouts*.

Abstract

MARINS, Eduardo Frio. **Neural Networks: Utilization of Self-Organization Map in classification for players of Volleyball.** 2008. 72f. Monografia - Curso de Bacharelado em Ciência da Computação. Universidade Federal de Pelotas.

Self Organizing-Maps are being applied in several areas, with special emphasis on problems of exploratory analysis of multivariate data. But in sports, specifically in volleyball, where the collected data from a competition (Scouts) are of this nature, the technique has not been widely explored. This work presents a methodology for analysis of such data, using as tools the Self-Organizing-Map and its algorithms. The methodology encompass the data of best players in each principle, data concerning the entire set of players, besides them relationship and individual gain in a volleyball competition. With this tool it is possible to reduce the number of data clusters and thus present the data in a non-linear manner onto on a two-dimensional network. The results are expressed and analyzed aiming the understanding of the reasons of a low or high performance of an athlete in a competition, because many coaches and/or physical coaches look after a standardization of the team players. The use of Self Organizing-Maps and their algorithms proved to be a robust tool for classification of multivariate data, and quickly presented the results of groups with considerable clarity, thus facilitating the interpretation and subsequent comparison of results.

Keywords: Artificial Neural Network; SOM; volleyball and scouts

Lista de Figuras

Figura 1 – Desenho esquemático de um neurônio biológico.....	24
Figura 2 – Desenho esquemático de um neurônio artificial.....	25
Figura 3 – Organização em camadas	26
Figura 4 – Modelos de Rummelhart e Hopfield	27
Figura 5 – Rede alimentada adiante com camada única	27
Figura 6 – Rede direta de múltiplas camadas.	28
Figura 7 – Redes <i>Feedback</i>	28
Figura 8 - Treinamento supervisionado.....	29
Figura 9 - Treinamento não-supervisionado.....	30
Figura 10 – Arquitetura de aprendizado competitivo	34
Figura 11 – Grade do padrão de Kohonen.....	36
Figura 12 – Conexões sinápticas de um neurônio de saída.....	36
Figura 13 – Alteração dos pesos do neurônio vencedor e dos seus vizinhos em direção a entrada x.....	40
Figura 14 – Função de vizinhança gaussiana	40
Figura 15 – Diferentes vizinhanças para rede <i>SOM</i>	41
Figura 16 - Exemplo da representação de agrupamentos em mapas auto-organizáveis através da U-matriz	43
Figura 17 - Representação das distâncias dx , dy , dz e do componente du para uma rede 3x3 hexagonal. Os círculos representam os neurônios e os quadrados representam os valores dos componentes.....	43
Figura 18 - Disposição do avaliador e do anotador na quadra de voleibol.....	45
Figura 19 – Comparação entre os tipos de topologia e função de vizinhança	52
Figura 20 – U-matriz das cinco melhores jogadoras - fundamento ataque	53
Figura 21 – U-matriz com separação dos agrupamentos - fundamento ataque.....	54
Figura 22 – U-matriz e variáveis individuais - fundamento ataque	55
Figura 23 – U-matriz e rede <i>SOM</i> - fundamento ataque	56
Figura 24 - U-matriz das cinco melhores jogadoras - fundamento saque	57
Figura 25 – U-matriz com separação dos agrupamentos - fundamento saque	58
Figura 26 - U-matriz e variáveis individuais - fundamento saque.....	59
Figura 27 – U-matriz e rede <i>SOM</i> - fundamento saque.....	60

Lista de Tabelas

Tabela 1 – Quadro comparativo entre o cérebro e o computador	24
Tabela 2 – Modelo de planilha de dados para o fundamento ataque.....	47

Lista de Abreviaturas e Siglas

<i>BMU</i>	Neurônio vencedor (<i>Best Match Unit</i>)
CBV	Confederação Brasileira de Voleibol
IA	Inteligência Artificial
<i>LCIS</i>	Laboratório de Computação e Ciência da Informação (<i>Laboratory of Computer and Information Science</i>)
RNA	Redes Neurais Artificiais
<i>SOM</i>	Mapa Auto-Organizável (<i>Self-Organizing Map</i>)
U-matriz	Matriz de distância unificada (<i>Unified Distance Matrix</i>)

Sumário

1 INTRODUÇÃO	16
2 ABORDAGEM DO PROBLEMA.....	19
2.1 Introdução	19
2.2 Considerações básicas sobre o voleibol	20
2.3 <i>Scout</i>	21
2.4 Fundamentos	21
2.4.1 Ataque.....	22
2.4.2 Saque.....	22
3 REDES NEURAIS	23
3.1 Introdução	23
3.2 Topologia da rede	26
3.2.1 Disposição dos neurônios	26
3.2.2 Ciclos.....	27
3.2.2.1 Redes alimentadas adiante com camada única.....	27
3.2.2.2 Redes alimentadas diretamente com múltiplas camadas.....	28
3.2.2.3 Redes Recorrentes.....	28
3.3 Aprendizado das redes neurais.....	29
3.3.1 Processo de aprendizagem supervisionado.....	29
3.3.2 Processo de aprendizagem não-supervisionado.....	29
3.4 Regras de aprendizado	30
3.4.1 Correção de erros	30
3.4.2 Baseada em memória	31
3.4.3 Hebbiana	32
3.4.4 Boltzmann	32
3.4.5 Competitiva	33
3.5 Mapas auto-organizáveis	35
3.5.1 Fases da <i>SOM</i>	37
3.5.1.1 Competitiva	37
3.5.1.2 Cooperativa.....	37
3.5.1.3 Adaptativa	37
3.6 Algoritmos de aprendizado da <i>SOM</i>	38

3.6.1	Aprendizado seqüencial ou padrão	38
3.6.2	Aprendizado em lote	39
3.7	Função de vizinhança	39
3.8	Algoritmo <i>SOM</i>	41
3.9	Visualização do mapa auto-organizável.....	42
3.9.1	Matriz de distância unificada (U-matriz)	42
4	COLETA, ANÁLISE EXPLORATÓRIA E MODELAGEM DOS DADOS	44
4.1	Introdução	44
4.2	Escolha do método de agrupamento.....	47
4.3	Análise exploratória de dados através de mapas auto-organizáveis.....	49
4.3.1	Pré-processamento dos dados.....	49
4.3.2	Parametrização da rede	49
4.3.3	Ferramentas computacionais utilizadas	50
5	OBTENÇÃO E ANÁLISE DOS RESULTADOS.....	51
5.1	Introdução	51
5.2	Análise do fundamento ataque.....	53
5.3	Análise do fundamento saque	57
	Referências	64
	Anexo A – Base de dados (<i>scouts</i>)	68

1 INTRODUÇÃO

Este trabalho de conclusão, do curso de Bacharelado em Ciência da Computação, da Universidade Federal de Pelotas, apresenta um modelo de redes neurais como ferramenta computacional para a modelagem e classificação de jogadores de voleibol, a partir da coleta de dados em um campeonato adulto realizado em Pelotas - RS, durante o período de julho a agosto de 2000. No estudo, foram analisados os *scouts* (dados estatísticos) das atletas de cada equipe do naípe feminino durante toda a competição, baseados nos fundamentos ataque e saque, os quais foram analisados individualmente dentro de cada equipe e divididos em variáveis. Além disso, o trabalho discute o quão é importante possuir equipes com padrão de rendimento.

O modelo utilizado neste trabalho é um mapa auto-organizável (*SOM – Self-Organizing Maps*) proposto por Kohonen, também conhecido como mapas de Kohonen (FAUSETT, 1994). Essa rede é baseada na aprendizagem competitiva. De acordo com 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 de saída são indicativas das características estatísticas intrínsecas, contidas nos padrões de entrada”, ou seja, o mapa é capaz de realizar o agrupamento de padrões, mediante diferentes valores das variáveis de entrada, e com isso fazer uma classificação entre elas.

A criação de um sistema de comparação entre desportistas, em função da análise dos seus desempenhos, torna-se um aliado instrumento de avaliação para treinadores e preparadores físicos, a fim de que eles possam entender o que ocorre nas atividades desportivas. Em virtude disto, é possível organizar estratégias para

jogos, bem como a programação dos treinamentos dentro da especificidade da modalidade, valendo-se da aplicação de técnicas de Inteligência Artificial.

Haja vista que esportes coletivos de alto rendimento como o voleibol, buscam o constante aperfeiçoamento de seus atletas, o processo de classificação nesse desporto está intimamente ligado ao estudo das “características de modelo” dos atletas mais destacados nessa modalidade (FONSECA et al., 2008). Através de estatísticas, obtidas de um jogador considerado de elite, é possível extrair várias informações, tanto de aspecto tático como físico. Tais informações permitem avaliar o desempenho e possibilitam ajustar o atleta à estratégia tática, dentro de sua equipe ou em relação à estratégia adotada pela equipe adversária.

Comparando as informações extraídas de um aspirante a jogador, com a de outros jogadores profissionais, é possível classificá-los de acordo com suas habilidades, identificando em que fundamentos eles podem apresentar melhor rendimento.

Assim, o objetivo principal deste trabalho é utilizar o conhecimento de Inteligência Artificial para que seja estabelecida a classificação de atletas, em grupos, de acordo com seus desempenhos, nos diversos fundamentos, a fim de manipular e produzir conhecimentos específicos de forma qualitativa para o processo de decisão de treinadores e/ou técnicos de voleibol, reduzindo o fator empírico e o tempo das decisões tomadas. Para tanto, foram utilizados métodos baseados em redes neurais, através da aplicação do algoritmo *SOM* para modelar um sistema de rede que atenta às particularidades exigidas pelo voleibol.

Ressalta-se que a interdisciplinaridade, presente neste estudo, abrange tanto a área computacional como, a esportiva.

Uma vez que a mineração de dados contribui para a descoberta de talentos esportivos, o mapa de Kohonen além de reduzir a quantidade de dados por agrupamento, também faz a projeção dos dados de uma forma não-linear em uma estrutura bidimensional capaz de visualmente comparar a proximidade de dois indivíduos. A utilização do método *SOM* é uma inovação na área esportiva, visto que sua estrutura é capaz de gerar dados importantes para treinadores e/o técnicos. Além disso, a construção dos mapas auto-organizáveis contribui com a organização de dados relevantes e na modelagem da rede.

Em relação à área esportiva, devido a um considerável aumento na prática do voleibol no Brasil, motivados pelas importantes conquistas em nível mundial,

percebe-se que há uma variedade de pessoas participando desta modalidade, como homens e mulheres das mais variadas idades e com diferentes níveis de habilidade (FARINA, 2008). Com isso, a escolha do melhor jogador que se adapte a sua equipe torna-se uma tarefa difícil para o treinador, o qual normalmente a faz de maneira empírica. Desta forma, é necessário observar o atleta e seus respectivos fundamentos ao longo de uma competição, para assim poder compará-lo com outro atleta, o qual é o referencial padrão, e assim extrair-se as conclusões necessárias sobre o desempenho.

A partir dos dados de entrada, pode-se fazer a modelagem e a aplicação desses dados, utilizando redes neurais. Essa modelagem é importante não só para os treinadores, mas também para os preparadores físicos que buscam o alto rendimento físico em suas equipes.

Para tanto, este estudo está estruturado em cinco capítulos, a saber: no primeiro capítulo faz-se uma breve introdução ao problema, bem como apresenta-se os objetivos e expõe-se as contribuições importantes nas duas áreas: esportiva e computacional.

Uma descrição do problema é apresentada no segundo capítulo, no qual se enfatiza alguns conceitos do voleibol.

O terceiro capítulo traz uma revisão bibliográfica sobre redes neurais e, mais detalhadamente, sobre a rede de Kohonen (*SOM*), utilizada neste estudo.

A descrição sobre a modelagem, coleta e a análise exploratória dos dados com rede de Kohonen são apresentadas no quarto capítulo, juntamente com a justificativa da utilização de redes de Kohonen na classificação de jogadores. Os resultados obtidos nos agrupamentos de jogadoras por fundamentos em uma competição na cidade de Pelotas são apresentados no quinto capítulo.

Na seqüência, apresentam-se as considerações finais deste estudo e sugestões para posteriores aprofundamentos sobre o tema, tendo em vista que se trata de assunto quase inexplorado no Brasil.

2 ABORDAGEM DO PROBLEMA

Neste capítulo, são abordados alguns conceitos básicos da área esportiva, especificamente no voleibol, seus principais fundamentos e os *scouts* coletados, que são os dados de entrada para a modelagem da rede.

2.1 Introdução

Este trabalho propõe a utilização de um modelo de rede neural competitiva, mais comumente conhecida como Rede de Kohonen ou mapas auto-organizáveis de Kohonen (*SOM*) para realizar o agrupamento e modelagem das jogadoras de voleibol, cujos dados foram apresentados através de um relatório final quantitativo, por fundamento, em uma competição realizada no período de julho a agosto de 2000. Com isso, pode-se fazer uma análise qualitativa do desempenho das atletas em determinado fundamento e, para desta maneira, relacionar as jogadoras entre si, de acordo com um padrão preestabelecido.

Os *scouts* foram organizados pelo professor Renato Siqueira Rochefort da Escola Superior de Educação Física (ESEF) da Universidade Federal de Pelotas (UFPel) e pela monitora da disciplina de voleibol Andréa de Ávila Lerípio, com a participação de alunos do projeto de extensão “Clínica de Arbitragem em Voleibol”, os quais fizeram a coleta dos dados durante a competição da Copa União de voleibol de 2000. Com isso, foram gerados dois relatórios finais, masculino e feminino, contendo: a classificação dos jogadores por fundamento, aproveitamento por equipe e resultados parciais e finais dos jogos.

O voleibol, enquanto desporto coletivo de não-invasão, constitui um tema de interesse na investigação centrada na análise do jogo, no sentido de identificar

variáveis que melhor definam o rendimento desportivo das equipas e dos jogadores (OLIVEIRA R.; MESQUITA; OLIVEIRA O., 2003).

O processo de seleção e promoção do talento desportivo tem sido tema constante de discussões na área do esporte. De modo geral, é difícil classificar os jogadores com relação aos seus fundamentos e identificar o motivo do seu baixo ou alto rendimento, pois cada atleta apresenta características técnicas e físicas diferentes uns dos outros.

2.2 Considerações básicas sobre o voleibol

Para uma melhor compreensão do trabalho, alguns conceitos e definições sobre estatística, *scout* e fundamentos do voleibol são apresentados a seguir:

O primeiro conceito importante é o de estatística, que é a ciência a qual recolhe fatos, analisa-os e interpreta-os quanto ao número e frequência, estabelecendo as leis que os regem (MICHAELIS, 2007). Esses números podem ser expressos em porcentagem de rendimento, eficácia, eficiência, erros, de forma individual ou por grupos, entre outros.

O uso da estatística no voleibol é chamado de *scout* (observador ou explorador), que captura e processa informações estatísticas de desempenho de atletas de sua própria equipa ou da adversária, e assim permite dar ao treinador uma clara visão de como cada jogador se desempenha dentro do jogo em cada ação que realiza (ZAMBERLAM et al, 2005). Entretanto, esse sistema, que até hoje é puramente estatístico, neste trabalho faz uso de técnicas de IA para fazer a classificação das atletas.

No voleibol de alto nível, preparam-se atletas para construir jogadas eficientes, que gerem ponto a favor de sua equipa. Conforme afirma Massa et al. (2003a), o voleibol é uma das modalidades desportivas mais complexas, em que a habilidade perfeita na execução de seus fundamentos e as características físicas de seus atletas são fundamentais para um ótimo desempenho da equipa. Desta forma, equipas buscam alcançar a homogeneidade no rendimento entre seus atletas, obtendo assim uma padronização da equipa.

Portanto, agrupar e classificar o perfil dos jogadores por fundamento tornasse necessário, uma vez que quanto mais próximos os resultados gerados estiverem dos perfis já preestabelecidos de talentos naquele fundamento, mais

próximos poderão estar de um desempenho ótimo e, conforme Fernandes Filho & Medina (2002) ressaltam, "o perfil de características é um instrumento de excelência para o esporte".

2.3 Scout

Sistemas de *scouts* atuais, apenas repassam dados para a comissão, a qual avalia essa gama diversificada, referente aos fundamentos do voleibol, em um intervalo de tempo mínimo, e toma decisões a partir dos dados relatados. Decisões, muitas vezes, baseadas no conhecimento empírico do técnico ou da comissão do que no fator real da situação exposta naquele momento. Assim, utilizando a técnica dos mapas auto-organizáveis e de seus algoritmos sobre as informações recebidas, acredita-se ser possível reduzir o fator empírico e o tempo de tomada de decisões, deixando o técnico liberado para tomada de outras decisões em sua equipe, durante uma partida (ZAMBERLAM et al., 2005).

Segundo Roberta Giglio (BALIEIRO, 2004), o sistema de *scout* é dividido em dois tipos: o técnico e o tático. O primeiro tipo serve para avaliar o desempenho de sua própria equipe, levando em consideração os principais fundamentos do voleibol: ataque, recepção, bloqueio, saque, defesa e contra-ataque, mostram o aproveitamento de cada jogador em determinados fundamentos e o seu aproveitamento final. Neste trabalho, valeu-se desse tipo para a elaboração dos mapas de Kohonen e na posterior análise dos resultados. Já o *scout* tático, é usado para avaliar as equipes adversárias, em que tais dados são analisados antes das partidas. Esse último tipo pode servir como proposta para aprofundamento futuro, pois com a utilização da rede *SOM* e uma boa análise de treinadores experientes pode-se prever e se adequar às prováveis jogadas dos adversários.

2.4 Fundamentos

Segundo Villamea (1998), a estatística individual é baseada na coleta de dados individuais de cada jogador em cada ação e na inserção de uma notação de acordo com o resultado da mesma. Em vista disso, cada um dos fundamentos foi dividido em três variáveis chamadas de opções de evolução: ponto (positivos), sempre que a ação de jogo termine a favor da própria equipe; andam (neutro),

sempre que a ação de jogo permita a continuidade da mesma; e erros (negativa), sempre que a ação de jogo termine contra a própria equipe.

2.4.1 Ataque

O ataque consiste no ato de golpear a bola para a quadra adversária na tentativa de vencer o bloqueio e a defesa contrária (WIKIPÉDIA, 2008).

Os dados estatísticos são divididos em:

- Ataque Positivo (Ponto): Todas as ações de ataque que depois de realizadas, a bola pique na quadra contrária ou que ela seja golpeada contra o bloqueio e o adversário não possa seguir jogando.

- Ataque Negativo (Erros): Todas as ações de ataque que depois de realizadas, a bola pique fora do campo de jogo, fique na rede ou permita uma ação positiva do bloqueio.

- Ataque Neutro (Andam): Todas as ações de ataque que depois de realizadas, a bola possa seguir em jogo por qualquer uma das equipes.

2.4.2 Saque

O saque ou serviço marca o início de uma disputa de pontos no voleibol. Um jogador coloca-se atrás da linha de fundo de sua quadra, estende o braço e acerta a bola, de forma a fazê-la atravessar o espaço aéreo acima da rede delimitado pelas antenas e atingir a quadra adversária (WIKIPÉDIA, 2008). Esse fundamento é dividido como os anteriores, e são apresentados seus diferentes conceitos:

- Saque Positivo (Ponto): Todos os saques em que se realiza ponto direto.

- Saque Negativo (Erros): Todos os saques que são errados.

- Saque Neutro (Andam): Todos os saques que permitam à equipe adversária seguir jogando.

3 REDES NEURAIS

Neste capítulo, os conceitos de redes neurais artificiais e as técnicas e os algoritmos utilizados nesse estudo são descritos mais detalhadamente.

3.1 Introdução

Existe uma tendência visível nas últimas décadas, em que pesquisadores procuram estudar a neurofisiologia humana (estuda o funcionamento do cérebro), a fim de desenvolver arquiteturas computacionais de processamento semelhantes ao funcionamento do mesmo. Com isso, surgiu o interesse em desenvolver as Redes Neurais Artificiais, a qual visa adequar algumas atividades do cérebro humano para os computadores (PANICKI, 2004).

De acordo com Haykin (2001), o cérebro é tido como um processador altamente complexo e que realiza processamentos de maneira paralela. Para isso, ele organiza sua estrutura, ou seja, os neurônios, de forma que realizem o processamento necessário. Além disso, ele 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 específica. Na tab. 1, apresenta-se uma comparação das principais diferenças existentes entre os computadores tradicionais e o cérebro humano.

Tabela 1 – Quadro comparativo entre o cérebro e o computador

Parâmetro	Cérebro	Computador
Elementos Computacionais	Neurônio simples	Processadores
Velocidade	Milisegundos (10^{-3})	Nanosegundos (10^{-9})
Tipo de processamento	Paralelo	Seqüencial
Armazenamento de informação	Adaptável	Substituível
Controle de processos	Distribuído	Centralizado
Tolerância a falhas	Grande	Quase nenhuma

Fonte: TAFNER; XEREZ; FILHO 1995, p. 52.

As Redes Neurais Artificiais (RNA) consistem de um método que soluciona problemas na área de Inteligência Artificial (IA), desenvolvendo assim um modelo lógico e matemático que simule em algum grau o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. O cérebro humano pode ser formado por algo em torno de 10 bilhões de neurônios interligados, enquanto que uma grande rede neuronal artificial pode ter centenas ou milhares de unidades de processamento (TAFNER; XEREZ; FILHO, 1995).

Uma descrição do modelo neuronal biológico está ilustrada abaixo na Fig. 1.

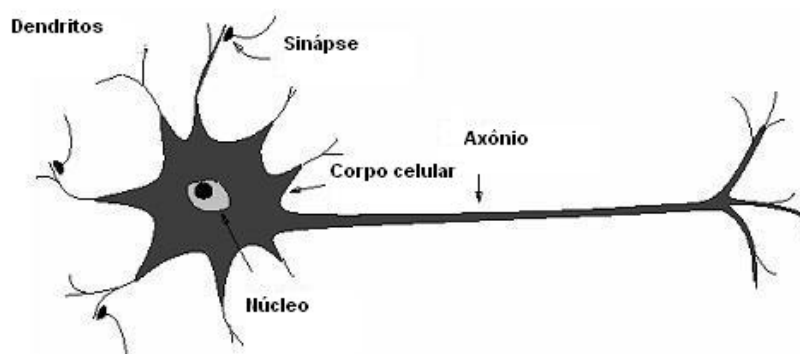


Figura 1 – Desenho esquemático de um neurônio biológico

Fonte: Adaptado de RUSSEL; NORVIG, 2003, p. 11.

No estudo das RNA, os dendritos são substituídos por entradas e sua ligação com a estrutura artificial neural é realizada através de uma variável chamada peso. Esta variável representa a capacidade de armazenamento, sendo que o processo de aprendizado está ligado à alteração dela durante a aprendizagem.

Segundo Panicky (2004), as redes neurais são formadas por nós de processamento (Fig. 2), os quais se interligam unidirecionalmente com os demais pelo que chamamos de sinapse. A função soma acumula os dados recebidos (estímulos) de outros elementos, e a função de transferência processa a função soma convertendo-a em outro sinal (RUSSEL; NORVIG, 2003).

O neurônio artificial possui o seguinte formato:

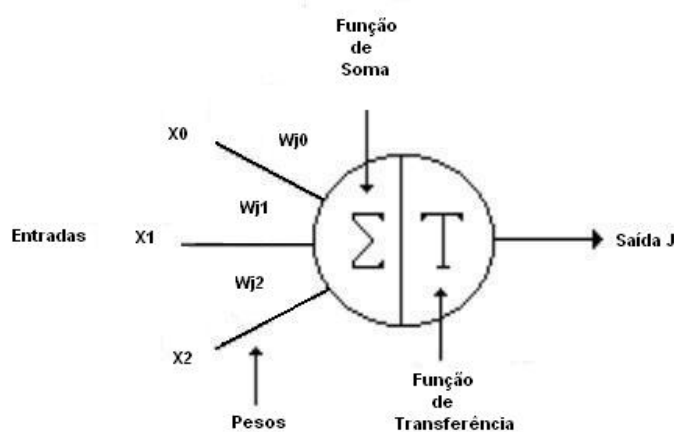


Figura 2 – Desenho esquemático de um neurônio artificial
Fonte: PANICKY, 2004, p. 27.

A rede neural artificial (RNA) é um sistema de neurônios ligados por conexões sinápticas e tem sua divisão em: neurônios de entrada, em que os padrões são apresentados à rede, neurônios intermediários ou *hidden* (ocultos), na qual é feita a maior parte do processamento e neurônios de saída, cujo resultado final é concluído e apresentado.

Arquiteturas neurais são tipicamente organizadas em camadas (Fig. 3):

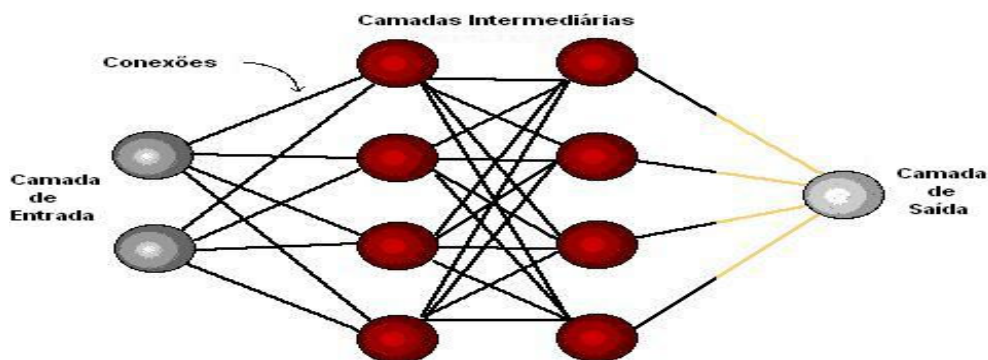


Figura 3 – Organização em camadas
Fonte: TATIBANA, 2003.

Os modelos de redes neurais, em sua maioria, possuem algum tipo de regra de treinamento, em que os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem através de exemplos.

De acordo com Silva (2004), as RNA são caracterizadas pela sua topologia (a forma como os neurônios estão dispostos), pela característica dos neurônios que as compõem e pela regra de treinamento usada para absorção do conhecimento.

3.2 Topologia da rede

As topologias de redes neurais podem ser classificadas quanto a: disposição dos neurônios e quanto aos ciclos.

3.2.1 Disposição dos neurônios

Segundo Rumelhart (RUMELHART; HINTON; WILLIAMS, 1986), a rede neural deve ter pelo menos duas camadas para apresentar um resultado significativo no desempenho de suas funções: entrada e saída de dados. Porém, uma rede de Rumelhart possui o processamento muito limitado, por isso faz-se necessária a adição de uma camada intermediária, fazendo com que uma rede neural tenha pelo menos três camadas.

A rede neural de Hopfield (PORTILHO; CASTRO, 2006 apud HOPFIELD, 1982) apresenta fluxo de dados multidirecional e comportamento dinâmico, devido ao fato de que todos os neurônios são interconectados, desaparecendo assim a idéia de camadas.

As duas redes neurais citadas podem ser observadas na Fig. 4.

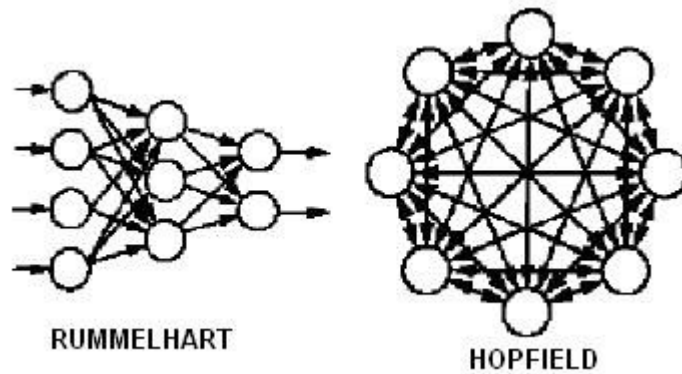


Figura 4 – Modelos de Rumelhart e Hopfield
 Fonte: PORTILHO; CASTRO, 2006.

3.2.2 Ciclos

Quanto aos ciclos, as redes neurais podem ser classificadas em: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes.

3.2.2.1 Redes alimentadas adiante com camada única

Em redes alimentadas adiante com camada única (Fig. 5), existe uma camada formada pelos neurônios de entrada que se projeta sobre a camada de neurônios de saída, mas não vice-versa.




Figura 5 – Rede alimentada adiante com camada única
 Fonte: HAYKIN, 2001, p. 47.

3.2.2.2 Redes alimentadas diretamente com múltiplas camadas

Em redes alimentadas diretamente com múltiplas camadas, a camada de entrada projeta-se sobre a camada de saída (ou camadas ocultas) e vice-versa. A Fig. 6 mostra esse tipo de rede.




Figura 6 – Rede direta de múltiplas camadas.
Fonte: TATIBANA, 2003.

3.2.2.3 Redes Recorrentes

Redes recorrentes ou *feedback* (realimentação) são uma variação da anterior, cujo sinal de saída de um neurônio pode servir como entrada para a mesma camada, ou camada anterior. Conforme mostra a Fig. 7.




Figura 7 – Redes *Feedback*
Fonte: TAFNER; XEREZ; FILHO, 1995, p.64.

Portanto, a construção da arquitetura da rede neural é livre, podendo ser alterada conforme o tipo de problema especificado ou necessidade do projetista.

3.3 Aprendizado das redes neurais

A principal propriedade de uma rede neural é a sua capacidade de aprender a partir de seu ambiente e de aperfeiçoar seu desempenho através da aprendizagem. O processo de aprendizagem pode ocorrer de duas formas: supervisionado e não-supervisionado.

3.3.1 Processo de aprendizagem supervisionado

No processo de aprendizagem supervisionado, a rede neural é treinada com o auxílio de um professor ou treinador. Para isso, a rede possui uma ligação entre os pares de entrada e saída fornecidos, conforme mostra a Fig. 8. Toda vez que for apresentada à rede uma entrada, deverá ser comparada se a resposta obtida (gerada a partir dos cálculos efetuados com os pesos que a rede possui) confere com a resposta desejada para àquela entrada. Caso seja diferente, os pesos das conexões são ajustados pela rede de forma a minimizar o erro. Esse processo iterativo de treinamento deverá ser repetido, até que a taxa de acerto caminhe, se possível, para uma solução otimizada.




Figura 8 - Treinamento supervisionado
Fonte: PANICKI, 2004, p. 34.

3.3.2 Processo de aprendizagem não-supervisionado

Na aprendizagem não-supervisionada ou auto-organizada, não existe uma resposta definida para os dados de entrada, e por isso não utiliza professores para o seu treinamento. A rede trabalha apenas com os valores de entrada, sendo que a partir do instante em que a rede estabelece uma relação com as regularidades estatísticas dos dados de entrada, desenvolve-se nela a habilidade de formar

representações internas para codificar as características da entrada e dessa forma, criar automaticamente novas classes. Conforme Fig. 9.



Figura 9 - Treinamento não-supervisionado
Fonte: PANICKI, 2004, p. 35.

3.4 Regras de aprendizado

O conjunto de regras, preestabelecidas e bem definidas, que solucionem problemas de aprendizagem é denominado de algoritmo de aprendizagem. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, tais algoritmos diferem entre si, principalmente, pelo modo como os pesos são modificados.

A rede neural é baseada pura e exclusivamente nos dados de entrada para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos espúrios. Primeiramente, a rede é treinada com dados escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras e não "decore" exemplos. O restante dos dados só é apresentado à rede neural na fase de testes para que ela possa "deduzir" algum padrão de relação entre os dados.

A escolha de um determinado algoritmo de aprendizagem está relacionada com o serviço que a rede deverá realizar. Haykin (2001) descreve cinco regras básicas de aprendizagem, a saber: por correção de erro, baseada em memória, Hebbiana, de Boltzmann e competitiva.

3.4.1 Correção de erros

Na regra de aprendizagem por correção de erros, o algoritmo busca minimizar a diferença entre a soma ponderada das entradas pelo peso e a saída desejada, ou seja, o erro da saída obtida pela rede. A função da regra correção de erro é utilizar a diferença entre a saída desejada e a saída obtida pela rede para então modificar os pesos das conexões, diminuindo o erro gradualmente.

O erro deve ser calculado pela seguinte expressão:

$$e(t) = d(t) - y(t) \quad (1)$$

Onde $d(t)$ e $y(t)$ são, respectivamente, a saída desejada e a resposta atual (calculada) no instante t . A fórmula genérica de alteração de pesos por essa regra de aprendizagem é definida por:

$$w_i(t+1) = w_i(t) + \eta \quad (2)$$

Onde η é a taxa de aprendizado. É importante que η seja selecionado cuidadosamente, para assegurar que seja alcançada a estabilidade e convergência do processo de aprendizagem iterativo (HAYKIN, 2001). Esse método pode ser chamado de regra delta de aprendizado.

3.4.2 Baseada em memória

A regra de aprendizagem baseada em memória objetiva armazenar experiências passadas em uma estrutura de memória contendo muitos exemplos corretos de pares de entrada-saída (x_k, d_k) , $k=1, \dots, N$. Onde x_k representa o vetor de entrada e d_k representa a resposta desejada correspondente. Sem perder a generalidade, a saída é considerada uma grandeza escalar. Dado um vetor de testes, x_{teste} , o algoritmo responde, buscando e analisando os dados dentro de uma vizinhança do vetor de testes.

Segundo Haykin (2001), os algoritmos baseados em memória envolvem dois componentes principais: o critério para definir a vizinhança de x_{teste} e a regra de aprendizagem aplicada aos exemplos de treinamento na vizinhança do vetor de testes.

Um exemplo efetivo de aprendizagem, baseada em memória, é a regra do vizinho mais próximo, na qual a vizinhança local é definida como o padrão armazenado mais próximo do vetor de teste x_{teste} . Ou seja, o vetor $x_v = \{x_1, x_2, \dots, x_N\}$ e é dito ser o vizinho mais próximo de x_{teste} se:

$$\text{mind}(x_k, x_{\text{teste}}) = d(x_v, x_{\text{teste}}) \quad (3)$$

onde $d(x_k, x_{teste})$ é a distância euclidiana entre os vetores.

3.4.3 Hebbiana

A regra de aprendizagem Hebbiana é a regra de aprendizagem mais conhecida e antiga (anterior a idéia de treinamento) no uso de redes neurais. A teoria de Hebb, um biólogo, foi inspirada nos neurônios biológicos. Hebb afirma que:

Quando um axônio da célula A está perto o suficiente para excitar uma célula B e participa do disparo repetida ou persistentemente, então algum processo de crescimento ou modificação metabólica acontece em uma das células ou em ambas, de tal forma que a eficiência de A como uma das células que dispara B é aumentada (HEBB, 1949, p. 62).

De acordo com Hebb (1949), se dois neurônios em cada lado de uma sinapse (conexão) são ativados simultaneamente (sincronamente), logo os pesos daquela conexão devem ser seletivamente incrementados.

Porém, se os neurônios forem ativados assincronamente, a sinapse será enfraquecida ou até mesmo excluída. Resumindo, se o neurônio pré-sináptico tiver grande influência na ativação do neurônio pós-sináptico, a conexão entre eles deve ser reforçada (PANIKI, 2004).

3.4.4 Boltzmann

A regra de aprendizagem de Boltzmann é baseada em um algoritmo de aprendizagem estocástico, cuja concepção foi inspirada na mecânica estatística. Deu origem ao modelo de rede neural chamado de máquina de Boltzmann, com as seguintes características:

- Estrutura recorrente que opera de uma forma binária, com os seguintes estados de ativação: +1 (ligado), -1 (desligado).
- Função de energia, definida por:

$$E = -\frac{1}{2} \sum_j \sum_k w_{kj} \cdot x_k \cdot x_j \quad \text{com } j \neq k \quad (4)$$

Onde x_j é o estado do neurônio j e w_{kj} é o peso sináptico conectando o neurônio j ao neurônio k .

- Mudança de estado, definido por:

$$P(x_k \rightarrow -x_k) = \frac{1}{1 + \exp(-\Delta E_k/T)} \quad (5)$$

Onde ΔE_k é a variação de energia resultante daquela troca. A operação a ser realizada pela máquina é de escolha de um neurônio, aleatoriamente, e posterior mudança de seu estado de ativação de x_k para $-x_k$ a uma pseudotemperatura (T), até que a máquina se encontre em equilíbrio térmico.

A regra de aprendizagem de Boltzmann é definida segundo Haykin (2001 apud HINTON e SEJNWSKI, 1986) por:

$$\Delta w_{kj} = \eta(\rho_{kj}^+ - \rho_{kj}^-), j \neq k \quad (6)$$

Onde η é o parâmetro taxa de aprendizagem. Tanto o ρ_{kj}^+ como ρ_{kj}^- assumem valores no intervalo entre -1 e +1.

3.4.5 Competitiva

Diferentemente das outras regras de aprendizagem (correção de erro. Hebbiana, Boltzmann) em que múltiplas unidades de saída podem ser disparadas simultaneamente, no aprendizado competitivo, os neurônios de saída competem entre si para se tornarem ativos (disparar). Assim, com essa competição, teremos apenas uma unidade de saída, ou apenas uma por grupo, que será ativada. O neurônio vencedor é chamado de *best matching* (HAYKIN, 2001).

A Fig. 10 mostra uma rede de aprendizado competitivo simples que consiste em conexões de alimentação adiante (excitadoras) com camada única. E também cada unidade de saída conecta-se lateralmente (inibidoras) a todas as outras unidades de saída via pesos sinápticos.

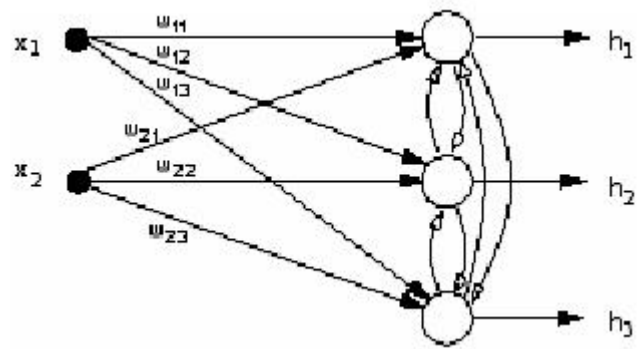


Figura 10 – Arquitetura de aprendizado competitivo
Fonte: NETO, 2007, p. 88.

No aprendizado competitivo, padrões semelhantes são reunidos pela rede e representados numa única unidade, tornando-se detectores de características. Agrupando assim, padrões similares e os dispendo em uma única unidade. De acordo com Neto (2007), esse processo de agrupamento é feito pela rede, a partir das correlações dos dados.

No aprendizado competitivo, todos os neurônios da camada de saída se conectam as unidades de entrada x . Essa conexão ocorre via pesos sinápticos w_{kj} . Abaixo é representado o vetor dos sinais de entrada:

$$X = [x_1, \dots, x_k, \dots, x_p]$$

O vetor dos pesos sinápticos incidentes ao neurônio j é denotado por:

$$w_j = [w_{1j}, w_{2j}, \dots, w_{pj}], \quad j = 1, \dots, N$$

onde N é o número de neurônios da camada de saída. A função de ativação h_j pode ser expressa como:

$$h_j = \sum_{i=1}^p x_i \cdot w_{ij} = x \cdot w_j, \quad j = 1, \dots, N \quad (7)$$

Logo, para se obter o melhor ajuste entre o vetor de entrada e os vetores de pesos sinápticos, deve-se comparar o produto $(x \cdot w_j)$ entre eles e selecionar o maior valor.

$$x \cdot w_{j^*} \geq x \cdot w_j, \quad \forall j \quad (8)$$

O neurônio j^* que satisfaz a condição acima é denominado de neurônio vencedor para o vetor x . Esse neurônio tem como saída desse neurônio (h_{j^*}) o valor '1' e para as demais o valor '0'.

Logo,

$$h_j = \begin{cases} 1, & \text{se } j = j^* \\ 0, & \text{se } j \neq j^* \end{cases}$$

Conforme Haykin (2001), uma regra simples de aprendizado competitivo padrão baseia-se na liberação de certa proporção do peso sináptico, pelos nós de entrada do neurônio vencedor, e posterior distribuição uniforme desse peso em direção aos nós de entrada ativos.

Ou seja:

$$\Delta w_j(t) \begin{cases} \eta[x - w_j(t)], & \text{se } j = j^* \\ 0, & \text{se } j \neq j^* \end{cases}$$

onde η é o parâmetro taxa de aprendizagem. O efeito dessa regra é mover o vetor de peso sináptico w_j do neurônio vencedor j^* um pouco mais perto do padrão de entrada x .

Neste estudo, foi utilizada uma rede neural baseada na regra de aprendizagem competitiva e no aprendizado não-supervisionado, para assim ordenar, classificar e modelar agrupamentos de jogadoras conforme seus desempenhos estatísticos nos mais variados fundamentos.

3.5 Mapas auto-organizáveis

Em 1972, Teuvo Kohonen, pesquisador da Universidade de Helsinki, estabeleceu um novo modelo de rede neural, denominado de mapa auto-organizável de características. A rede de Kohonen utiliza o aprendizado não-supervisionado e competitivo, em que os neurônios competem entre si para serem ativados. O neurônio, cujo vetor de pesos gerar a menor distância Euclidiana com o vetor de entrada, é o vencedor. Nesse modelo, estabelecido por Kohonen, não apenas os pesos do neurônio vencedor são ajustados, mas também os pesos dos seus vizinhos (TAFNER; XEREZ; FILHO, 1995).

Para Kohonen (2001), o comportamento de sua rede simula a atividade cerebral do córtex humano. Essa parte do cérebro humano aloca regiões semelhantes para atividades específicas e, dependendo da atividade cerebral, o grau de ativação dos neurônios diminuía à medida que se distanciavam da região de ativação inicial.

Os mapas auto-organizáveis constituem-se em uma rede, ilustrada na Fig. 11, de duas camadas de neurônios (Kohonen, 2001): camada de entrada I e a de saída U . A entrada da rede é descrita como um vetor, representado por: $x = [x_0, x_1, \dots, x_n] \in \mathfrak{R}^n$.




Figura 11 – Grade do padrão de Kohonen
Fonte: AHN; SYN, 2005.

Cada neurônio da grade está amplamente conectado com todos os nós de fonte da camada de entrada (Fig.12). De acordo com o sinal de entrada, um neurônio de saída deverá responder melhor para a respectiva entrada, e esse será considerado o vencedor. A seguir, os pesos sinápticos do neurônio vencedor e de seus vizinhos serão ajustados.

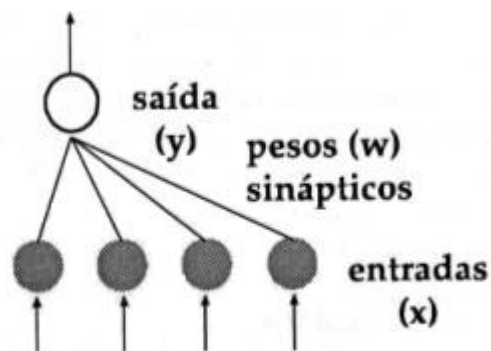


Figura 12 – Conexões sinápticas de um neurônio de saída
Fonte: TAFNER; XEREZ; FILHO, 1995, p. 126.

A rede *SOM* tem como característica a preservação topológica, ou seja, ela admite que padrões de entrada próximos devam ativar unidades de saída próximas no mapa.

A rede de Kohonen (*SOM*) possui uma ampla aplicabilidade em diversas áreas como: Medicina, Engenharia. Salienta-se a visualização de dados multivariados, análises de agrupamento, mineração de dados e compressão de dados (Kohonen, 2001). Por apresentar um algoritmo de fácil implementação e por realizar uma projeção não-linear de dados multivariados em um espaço bidimensional, essa rede é indicada para solucionar o problema proposto.

3.5.1 Fases da *SOM*

Segundo Haykin (2001), depois de ter sido inicializada a grade, existem três fases essenciais envolvidas na formação do mapa auto-organizável: competitiva, cooperativa e adaptativa.

3.5.1.1 Competitiva

Na fase competitiva, para cada padrão de entrada, os neurônios de saída competem entre si, mediante alguma função discriminante, normalmente a distância Euclidiana. O particular neurônio com o maior valor de função discriminante é denominado vencedor da competição, ou também chamado de *BMU* (*Best Match Unit*).

3.5.1.2 Cooperativa

Na fase cooperativa, o neurônio vencedor define espacialmente o centro de uma vizinhança topológica de neurônios excitados (cooperativos), provendo, desta maneira, as bases para a cooperação entre tais neurônios vizinhos.

3.5.1.3 Adaptativa

A fase adaptativa permite que os neurônios excitados aumentem os valores de sua função discriminante em relação ao padrão de entrada, através de ajustes em seus pesos sinápticos. Conseqüentemente, a grade vai se tornando auto-organizável.

3.6 Algoritmos de aprendizado da *SOM*

O algoritmo de treinamento baseia-se em dois tipos: seqüencial (ou padrão), em lote.

3.6.1 Aprendizado seqüencial ou padrão

No treinamento seqüencial, a rede é treinada iterativamente. Em cada etapa do treinamento, a partir do conjunto de entrada, uma amostra desse conjunto é escolhida aleatoriamente e a distância entre o vetor de entrada e todos os vetores de peso da rede é calculada usando uma medida de distância (Euclidiana). O neurônio que apresentar a menor distância é considerado o neurônio vencedor (*BMU*).

O algoritmo de aprendizagem padrão ou seqüencial é descrito em dois passos, como segue:

- a) Os vetores de peso são inicializados linearmente;
- b) Em cada época t
 - 1) Para todo neurônios pertencentes ao conjunto de entrada, no tempo discreto t , encontre o *BMU* segundo a mínima distância Euclidiana:

$$BMU = \operatorname{argmin}_j \{ \|x_k - w_j\| \}, j = 1, \dots, n$$

onde n corresponde ao número de neurônios da rede.

- 2) Os vetores de peso sináptico do neurônio vencedor e dos seus vizinhos são ajustados segundo a equação:

$$w_i(t+1) = w_i(t) + \eta(t)h(t)[x_i(t) - w_i(t)]$$

onde $\eta(t)$ é a taxa de aprendizado na iteração t e $h(t)$ é a vizinhança entre o neurônio vencedor e seus vizinhos.

3.6.2 Aprendizado em lote

Segundo Vesanto (2000), o algoritmo de aprendizado em lote também é iterativo, porém difere da aprendizagem seqüencial quanto à forma de atualização dos vetores de código, na ausência da taxa de aprendizagem $\alpha(t)$ e na não obrigatoriedade de apresentação aleatória dos padrões. Em cada etapa (época) do treinamento, o conjunto de dados é dividido conforme as regiões de Voronoi dos vetores de pesos do mapa neural, isto é, as unidades de vetores de pesos mais próximos no conjunto de dados. Depois disso, os vetores de pesos podem ser atualizados, segundo a equação abaixo:

$$s_i(t) = \sum_j^{n_{V_i}} x_j \quad (9)$$

onde s_i corresponde o somatório dos padrões relativos à região de Voronoi V_i e n_{V_i} , representa o número de amostras do conjunto de Voronoi do neurônio i . Então, os novos valores dos vetores de pesos sinápticos podem ser calculados pela seguinte fórmula:

$$w_i(t+1) = \frac{\sum h_{ji}(t)s_j(t)}{\sum n_{V_j}h_{ji}(t)} \quad (10)$$

Em vista do que foi apresentado sobre os dois algoritmos de aprendizagem, optou-se pelo algoritmo em lote para a implementação deste estudo, uma vez que ele não possui o parâmetro taxa de aprendizagem $\eta(t)$ e apresenta bom desempenho (VESANTO, 2000).

3.7 Função de vizinhança

A relação de vizinhança topológica entre os neurônios é determinada na fase cooperativa por uma função. Função essa que objetiva identificar os neurônios em torno do *BMU* da fase competitiva e assim atribuir novos valores a eles. De acordo com o modelo neurobiológico, tem-se que à medida que os neurônios vizinhos se aproximam do neurônio vencedor, o nível de atuação deles cresce. Além disso, podemos dizer que quando um vetor x é apresentado, os pesos do *BMU* e de sua vizinhança próxima movem-se em direção a x (Fig. 13).




Figura 13 – Alteração dos pesos do neurônio vencedor e dos seus vizinhos em direção a entrada x

Fonte: VESANTO, 2000, p. 9,

De acordo com Haykin (2001), a função que satisfaz as premissas expostas acima é a função topológica gaussiana (Fig. 14), pois nela ocorre a cooperação (forte alteração dos pesos) entre o neurônio vencedor e os neurônios próximos a ele, entretanto os que estão mais distantes sofrem pouca modificação ou simplesmente permanecem sem mudanças em seus pesos.

$$h_{j,j^*} = \exp\left(-\frac{d_{j,j^*}^2}{2\sigma^2}\right) \quad (11)$$

onde: σ é a dispersão da função de vizinhança, chamado de raio de vizinhança e d_{j,j^*} é a distância lateral entre o neurônio j e o vencedor j^* .




Figura 14 – Função de vizinhança gaussiana

Fonte: HAYKIN, 2001, p. 49.

Outro fator importante é a escolha da topologia para a camada de saída, isto é, as formas a ser utilizadas para definir quais neurônios pertencem a vizinhança do neurônio vencedor. Ela pode possuir uma disposição retangular, hexagonal dos neurônios, ou outras configurações possíveis como os arranjos cilíndricos e toroidais, conforme ilustrado na Fig. 15 abaixo.

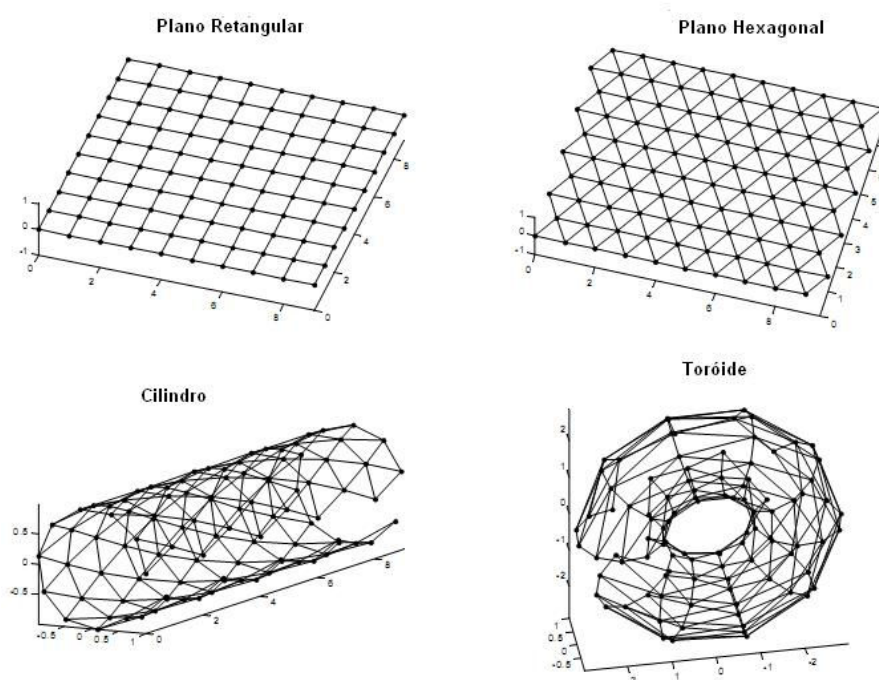


Figura 15 – Diferentes vizinhanças para rede *SOM*
Fonte: ZUCHINI, 2003.

3.8 Algoritmo *SOM*

O algoritmo *SOM*, desenvolvido por Teuvo Kohonen, realiza uma redução na dimensionalidade da rede. A seguir é apresentado o algoritmo computacional de Kohonen, em alguns passos básicos (HAYKIN, 2001):

Passos:

1. Inicialize os pesos da rede;
2. Defina o raio inicial da vizinhança V_i ;
3. Apresente os vetores de entrada x à rede em ordem aleatória;
4. Calcule a distância Euclidiana entre a entrada e os pesos dos neurônios selecionados para assim encontrar o neurônio vencedor;
5. Selecione o neurônio vencedor (*BMU*) que tem a menor distância Euclidiana;

6. Ajuste todos os vetores de peso sinápticos dos neurônios com a regra a baixo:

$$w_i(t+1) = w_i(t) + \eta(t)h(t)[x_i(t) - w_i(t)]$$

7. Decremente o valor da taxa de aprendizado e do raio topológico de toda a vizinhança ao redor do *BMU*.
8. Termine quando o número de iterações atingirem o especificado no início.

3.9 Visualização do mapa auto-organizável

Depois do processo de treinamento e aprendizagem da rede é necessário que se possa analisar visualmente o resultado possível dos agrupamentos através de alguns métodos. Para Silva (2004 apud ULTSCH, 1993), o método mais comumente utilizado é o da matriz de distâncias unificada ou U-Matriz, pois facilita o processo de análise dos dados. Por isso, o método da U-matriz foi escolhido para o desenvolvimento deste estudo.

3.9.1 Matriz de distância unificada (U-matriz)

A técnica da matriz de distância unificada foi criada por Ultsch nos anos 80, e é utilizada na visualização do mapa para posterior separação manual dos agrupamentos. Essa matriz é composta pelas distâncias (Euclidiana) entre todos os neurônios vizinhos do mapa.

Dado um mapa de tamanho $L \times C$, a U-matriz é representada pela imagem desse mapa em outro mapa de dimensão $(2L - 1 \times 2C - 1)$ onde o nível de intensidade de cada pixel corresponde a uma distância calculada.

Por exemplo, considerando-se o mapa bidimensional hexagonal 3×3 representado na Fig. 16, encontra-se a U-matriz, calculando-se as distâncias dx , dy e dz (Fig. 17), para cada neurônio, resultando em um mapa 5×5 . O valor de du pode ser calculado pela média, mediana, valor máximo ou mínimo entre os vetores pesos dos neurônios circunvizinhos do neurônio du .

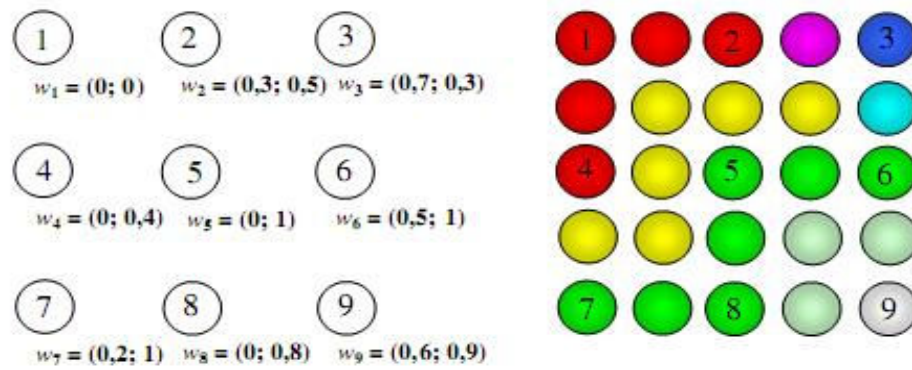


Figura 16 - Exemplo da representação de agrupamentos em mapas auto-organizáveis através da U-matriz
 Fonte: SIQUEIRA, 2005.




Figura 17 - Representação das distâncias dx, dy, dz e do componente du para uma rede 3x3 hexagonal. Os círculos representam os neurônios e os quadrados representam os valores dos componentes
 Fonte: SILVA, 2004.

Para a construção da U-matriz são atribuídos aos neurônios, de acordo com os valores das coordenadas dos vetores peso $w(x, y)$, cores para cada intervalo definido a seguir: no intervalo de $x [0; 0,5]$ e $y [0; 0,5]$, a cor atribuída ao neurônio é vermelha; quando $x [0; 0,5]$ e $y (0,5; 1]$, então a cor estipulada ao neurônio é verde; já no intervalo de $x (0,5; 1]$ e $y [0; 0,5]$, a cor designada ao neurônio é azul; e se $x (0,5; 1]$ e $y (0,5; 1]$, a cor atribuída ao neurônio é branca.

4 COLETA, ANÁLISE EXPLORATÓRIA E MODELAGEM DOS DADOS

4.1 Introdução

Os dados, que serviram para o desenvolvimento deste estudo foram obtidos em um projeto de extensão, Clínica de Arbitragem em Voleibol, na cidade de Pelotas por alunos da ESEF- UFPel, foram coletados nas diversas quadras, onde eram disputadas as partidas, durante o período da Copa União do ano de 2000. Seguindo o padrão de *scouts* da CBV, foram utilizados para a coleta dos dados, alunos da ESEF - UFPel, os quais eram divididos em duplas e dispostos no fundo de cada lado da quadra. Com essas duplas, foram realizados treinamentos; observação de treinos ou de jogos televisionados para que fosse aperfeiçoada a destreza e que houvesse maior entrosamento entre a dupla. Após isso, elas não eram mais desfeitas até o término da competição. Nas duplas, havia duas funções: a de anotador, o qual ficava de lado pra quadra transcrevendo a narração do outro companheiro; e o avaliador, o qual ficava de frente para quadra narrando os acontecimentos por meio de códigos preestabelecidos por eles, durante o treinamento, para registrar cada ação realizada pelas atletas, tentando assim coletar o maior número de dados possíveis. A Fig. 18 ilustra a disposição das duplas na quadra.




Figura 18 - Disposição do avaliador e do anotador na quadra de voleibol

Os seis fundamentos coletados pelos alunos foram: ataque, saque, bloqueio, levantamento, recepção e defesa. Neste estudo, foram abordados apenas os fundamentos de ataque e saque, pois o fundamento defesa possuía variáveis diferentes dos demais fundamentos, o fundamento levantamento por ser dependente da boa execução de outros fundamentos de sua equipe como a recepção e o ataque. Salienta-se que o fundamento bloqueio também não foi explorado devido ao baixo índice de execuções realizadas pelas jogadoras e a recepção por ser um fundamento de prioridade para um jogador específico de cada equipe: o líbero.

Os dados foram coletados em uma competição com cem (100) jogadoras, divididas em sete equipes. Com o intuito de apresentar uma amostragem, colocouse, na seqüência, uma pequena parte (30 jogadoras de 100) da planilha de dados, apresentada na Tabela 2. Assim, a primeira coluna apresenta o número total de ações que não geraram erros (Total), ou seja, é apenas a soma das variáveis Ponto e Andam das colunas seguintes, as quais significam, respectivamente, ações que geraram ponto diretamente e ações que dão continuidade ao jogo. A quarta coluna apresenta o número de erros no fundamento especificado (Erros). A quinta coluna

apresenta o número total de ações individuais, realizadas pela atleta (T_{indiv}), onde é calculado pela fórmula abaixo:

$$T_{\text{Indiv}} = \text{Ponto} + \text{Andam} + \text{Erros}$$

Já as colunas seis, sete e oito representam, respectivamente, o aproveitamento individual em cada fundamento ($\text{Fund}_{\text{apr}_v\text{indiv}}$), o aproveitamento em relação à equipe ($\text{Suces}_{\text{apr}_v\text{equip}}$) e em relação à competição ($\text{Suces}_{\text{apr}_v\text{compet}}$).

O aproveitamento individual por fundamento, em relação à equipe e à competição são expressos em percentual (%) e calculados pelas fórmulas abaixo, respectivamente:

$$\text{Fund}_{\text{AprvIndiv}} = \frac{(\text{Ponto} + \text{Andam}).100}{\text{Total}_{\text{AcoesIndiv}}}$$

$$\text{Suces}_{\text{AprvEquipe}} = \frac{(\text{Total}_{\text{Indiv}}).100}{\text{Total}_{\text{Equipe}}}$$

$$\text{Suces}_{\text{AprvComp}} = \frac{(\text{Total}_{\text{Indiv}}).100}{\text{Total}_{\text{Comp}}}$$

Assim, as ações de cada jogadora em cada fundamento eram somadas a cada rodada e colocadas nas tabelas. Ao final da competição, foram obtidos os percentuais de cada atleta.

Por fim, além das oito variáveis utilizadas para coletar os dados, foi também atribuída uma variável de identificação (código) para cada atleta, para que assim possam ser relacionadas com as demais jogadoras da competição e serem visualizadas no mapa. Conforme mostra a Tabela 2, a variável identificadora (Ident) é composta de uma letra, simbolizando a primeira letra do fundamento (A, S), e um número, identificando a atleta dentro do conjunto total (1, 2, 3,..., 100). Em que A=ataque e S=saque.

Tabela 2 – Modelo de planilha de dados para o fundamento ataque

Total	Ponto	Andam	Erros	T_indiv	Fund_a prv_indi v	Suces_ aprv_eq uip	Suces_ aprv_co mpet	Ident
16	6	10	5	21	76.2	5.9	1.1	A1
106	23	83	19	125	84.8	22.8	4.3	A2
32	14	18	3	35	91.4	13.9	2.6	A3
1	0	1	0	1	100	0	0	A4
19	9	10	3	21	90.5	8.9	1.7	A5
12	1	11	3	15	80	1	0.2	A6
0	0	0	0	0	0	0	0	A7
75	15	60	16	91	82.4	14.9	2.8	A8
78	19	59	20	98	79.6	18.8	3.5	A9
0	0	0	0	0	0	0	0	A10
38	14	24	6	44	86.4	13.9	2.6	A11
0	0	0	0	0	0	0	0	A12
8	4	4	2	10	80	2.8	0.7	A13
35	14	21	6	41	85.4	10	2.6	A14
2	0	2	1	3	66.7	0	0	A15
1	0	1	0	1	100	0	0	A16
99	34	65	13	112	88.4	24.3	6.3	A17
13	7	6	2	15	86.7	5	1.3	A18
150	43	107	16	166	90.4	30.7	8	A19
46	11	35	6	52	88.5	7.9	2	A20
36	12	24	5	41	87.8	8.6	2.2	A21
11	4	7	2	13	84.6	2.9	0.7	A22
0	0	0	0	0	0	0	0	A23
1	0	1	0	1	100	0	0	A24
48	10	38	5	53	90.6	7.1	1.9	A25
7	1	6	1	8	87.5	0.7	0.2	A26
0	0	0	0	0	0	0	0	A27
0	0	0	0	0	0	0	0	A28
0	0	0	0	0	0	0	0	A29
106	44	62	11	117	90.6	35.2	8.2	A30

4.2 Escolha do método de agrupamento

A rede *SOM* foi escolhida por apresentar um algoritmo de fácil implementação e por realizar uma projeção não-linear dos dados multivariados. Reduzindo assim o espaço de variáveis n dimensionais (dados multivariados) para um espaço bidimensional e gerando assim um mapa de similaridades, onde as distâncias entre os jogadores podem ser visualizada facilmente, sendo indicada para solucionar o problema proposto.

Um dos problemas em se utilizar métodos de classificação baseados apenas na distância entre valores de *scout* simples é o fato que isso geraria uma tabela (gráfico) para cada tipo de variável, assim ao final teríamos agrupamentos baseados apenas em valores simples nos quais seria difícil para o treinador visualizar a relação entre esses vários gráficos. Já no *SOM*, apesar da classificação utilizar as mesmas equações de distância para classificar os dados de entrada, no algoritmo de aprendizagem, o resultado final é um gráfico bidimensional, que leva em consideração o conjunto de variáveis de entrada e não apenas uma única variável.

Portanto, o método *SOM* difere dos métodos estatísticos convencionais para classificação ou aglomeração não-espaciais, que não geram uma saída bidimensional, como por exemplo: K-vizinhos mais próximos, K-médias.

No método k-médias, o número de grupos k deve ser escolhido de acordo com o número de grupos existentes nos dados de entrada (ou que se supõe existir), enquanto que no *SOM* é implícito o agrupamento dos dados, independente da expectativa do número de aglomerados.

Por exemplo, neste estudo são tomadas oito variáveis para cada jogadora, esse é o número de entradas do mapa. Isso implica também que as 100 jogadoras da amostra estão distribuídas no \mathfrak{R}^8 . O número de pesos é igual ao número de entradas, isto indica que cada neurônio terá associado a si um ponto no \mathfrak{R}^8 (correspondente ao seu vetor de peso). Portanto, o processo de auto-organização dos vetores de peso ocorre no mesmo espaço em que estão distribuídas as amostras. Apenas o resultado final será expresso no \mathfrak{R}^2 , no qual se podem visualizar os neurônios mais ativados e, por conseguinte, traz benefícios como, por exemplo, ser um facilitador de visualização espacial das relações entre as variáveis utilizadas, para uma posterior análise e interpretação por um treinador e/ou técnico, sendo assim indicado para formação de agrupamentos (HAYKIN, 2001).

Em vista dessas características da rede *SOM*, que possuem afinidade com o problema a ser resolvido, o estudo busca relacionar as vantagens da aplicação dessa técnica no voleibol, criando agrupamentos na forma de mapas bidimensionais visando o apoio ao treinador.

4.3 Análise exploratória de dados através de mapas auto-organizáveis

A análise exploratória de dados consiste em buscar padrões em dados amostrais a partir de técnicas de visualização, como a U-matriz, análise de agrupamentos, entre outras.

As etapas da análise exploratória de dados através de mapas auto-organizáveis compreendem: a escolha do conjunto de dados de entrada, o pré-processamento dos dados, a modelagem dos dados, a parametrização da rede, a elaboração do mapa, a visualização dos mapas neurais e interpretação dos resultados obtidos.

4.3.1 Pré-processamento dos dados

O primeiro passo do trabalho foi importar todos os dados do relatório final da competição, o qual fora digitalizado, para um arquivo de dados (Anexo A) que pudesse ser lido pela ferramenta computacional utilizada. Foram criadas tabelas para cada fundamento, em seguida, os dados de entrada foram normalizados através da função `som_normalize`, o qual converte todas as variáveis para um intervalo de variância unitário. Isso foi feito, para prevenir que variáveis com valores de maior ordem de magnitude que outras não dominem ou distorçam os pesos da rede. Caso contrário, ficaria complicado achar um padrão quando se trabalha com valores discrepantes.

Para este estudo, os dados foram separados por fundamentos: ataque e saque. De cada planilha, foram gerados mapas, separados, para os cinco melhores em cada fundamento e, em seguida, foi utilizado todo o conjunto de dados para verificar se existia a formação de *clusters*.

4.3.2 Parametrização da rede

Como a aplicação da rede *SOM* neste trabalho está designada para a classificação de padrões, então algumas técnicas para a parametrização dessa rede são comentadas a seguir.

A rede é constituída de oito entradas por neurônio na primeira camada, em que os valores associados representam a quantidade de acertos, erros e totais das

ações realizadas pelas atletas e também os percentuais de aproveitamento durante a competição. De acordo com essas variáveis, a rede realizará o agrupamento de padrões.

Diversos mapas foram elaborados para cada fundamento, variando a dimensão, a topologia (retangular ou hexagonal) e a função de vizinhança (gaussiana ou *bubble*), até que o mapa fosse considerado como bom, isto é, conseguisse separar e agrupar as jogadoras de uma forma visualmente clara. A escolha do “melhor” mapa segue pelo bom senso, considerando o método da U-matriz utilizado para essa análise.

O mapa de Kohonen aplicado foi o modelo bidimensional, com disposição hexagonal da grade de neurônios, com a função de vizinhança gaussiana, com aprendizagem em lote e com dimensão da camada de saída de 12x4. Esse número foi escolhido de forma aleatória, através de experimentos iniciais, e mostrou-se adequado para o problema, com bom desempenho para a visualização dos agrupamentos.

4.3.3 Ferramentas computacionais utilizadas

O estudo foi desenvolvido no ambiente computacional MATLAB 7.2, implementado com a ajuda da caixa de ferramentas *SOM* para MATLAB 5 (versão 2), disponível no site¹ do *Laboratory of Computer and Information Science* (LCIS). O *SOM Toolbox* foi desenvolvida por Juha Vesanto, em conjunto com Johan Himberg, Esa Alhoniemi e Juha Parhankangas na *Helsinki University of Technology* - Finlândia e funciona como uma biblioteca do software MATLAB, composta por várias rotinas, e tem grande flexibilidade e variedade de funções para criação e análise da rede *SOM*.

As funções utilizadas neste estudo foram: `som_read_data`, `som_normalize`, `som_make`, `som_autolabel`, `som_show_add`, `som_show` e outras. Com essas funções, é possível realizar inúmeras combinações de topologias (hexagonal, retangular), tamanhos do mapa, inicialização (randômico ou linear), treinamentos (seqüencial ou por lote).

¹ Disponível em: <http://www.cis.hut.fi/projects/somtoolbox/>

5 OBTENÇÃO E ANÁLISE DOS RESULTADOS

5.1 Introdução

Dezenas de mapas foram elaborados variando a topologia, o tamanho da rede, a função de vizinhança, com o objetivo de obter um mapa considerado adequado para a resolução do problema a ser resolvido. Primeiramente, foram treinados mapas com o conjunto das cinco melhores jogadoras, em cada fundamento, utilizando sempre as mesmas especificações: para a camada de saída, uma grade bidimensional de tamanho 4x3, com topologia hexagonal; uso do treinamento em lote e da função de vizinhança gaussiana.

Para a identificação dos agrupamentos, foi utilizado o método de visualização da U-matriz, obtida pela função `som_umat` do *SOM Toolbox*. A U-matriz apresenta, através das células coloridas do mapa, as distâncias entre os agrupamentos. A matriz apresentada é quase duas vezes maior que o mapa original, isso acontece devido à adição de hexágonos entre todos os pares de unidades de mapa vizinhas. Isto é, define cada célula como sendo um hexágono central cercado de outros hexágonos, para delimitação dos agrupamentos. As cores variam de acordo com uma escala de distâncias, do azul escuro ao vermelho, em que 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., 2000).

A função `som_show` apresenta a grade bidimensional de cada variável analisada ou de cada fundamento, sendo muito útil para visualização dos agrupamentos.

Outra função utilizada foi a `som_autolabel`, a qual permite a inserção de rótulos pré-definidos, nas células, para cada jogadora, permitindo assim, melhor

visualização do mapa auto-organizado e posterior facilidade na análise dos agrupamentos.

Foram elaborados mapas bidimensionais variando sua topologia (retangular e hexagonal) e sua função de vizinhança (bubble e gaussiana), visando observar diferenças entre os agrupamentos formados. Desta forma, percebeu-se que não havia diferenças significativas entre os agrupamentos formados (Fig. 19), por isso optou-se, neste estudo, pela configuração padrão: topologia hexagonal e vizinhança gaussiana.




Figura 19 – Comparação entre os tipos de topologia e função de vizinhança

Finalmente, é apresentado um mapa bidimensional, com rótulos, do conjunto total de dados, com dimensão de 12x4. Para identificação e análise dos agrupamentos desse mapa foi elaborado um mapa indicativo da localização das

variáveis utilizadas individualmente, para cada um dos fundamentos escolhidos, e também um mapa com a U-matriz e a rede *SOM* rotulada.

5.2 Análise do fundamento ataque

O mapa das cinco melhores jogadoras da competição no fundamento ataque foi gerado (Fig. 20), de acordo com as especificações padrão.




Figura 20 – U-matriz das cinco melhores jogadoras - fundamento ataque

A Fig. 21 apresenta o mapa com cem (100) neurônios na camada de saída, dispostos na U-matriz, e os agrupamentos do conjunto total de jogadoras avaliadas no fundamento ataque.




Figura 21 – U-matriz com separação dos agrupamentos - fundamento ataque

Pode-se observar que o mapa foi dividido em três regiões: A, B e C, ilustradas na Fig. 21. Algumas linhas foram tracejadas, apresentando a idéia de divisão dos agrupamentos, conforme apresentado na legenda das distâncias, onde a cor azul escuro representa uma distância de 0,0559 entre os agrupamentos e a cor vermelha uma distância de 1,99, o que mostra a separação dos agrupamentos, pois se observa que a média da distância entre as células vizinhas é grande.

Para se obter uma visualização clara dos agrupamentos, é necessário observar a Fig. 22, a qual representa a U-matriz (matriz indicativa das distâncias

entre os agrupamentos) e o mapa indicativo da localização das jogadoras individualmente. Um detalhe a salientar nesta figura, é relativo às cores e à indicação das distâncias entre as células, pois conforme mencionado anteriormente, na U-matriz, quanto mais a cor se aproxima do vermelho, mais distantes estão os agrupamentos e, na visualização individual das jogadoras, a escala é inversa, quanto mais próxima a cor estiver do vermelho mais próximos estarão os agrupamentos das jogadoras.

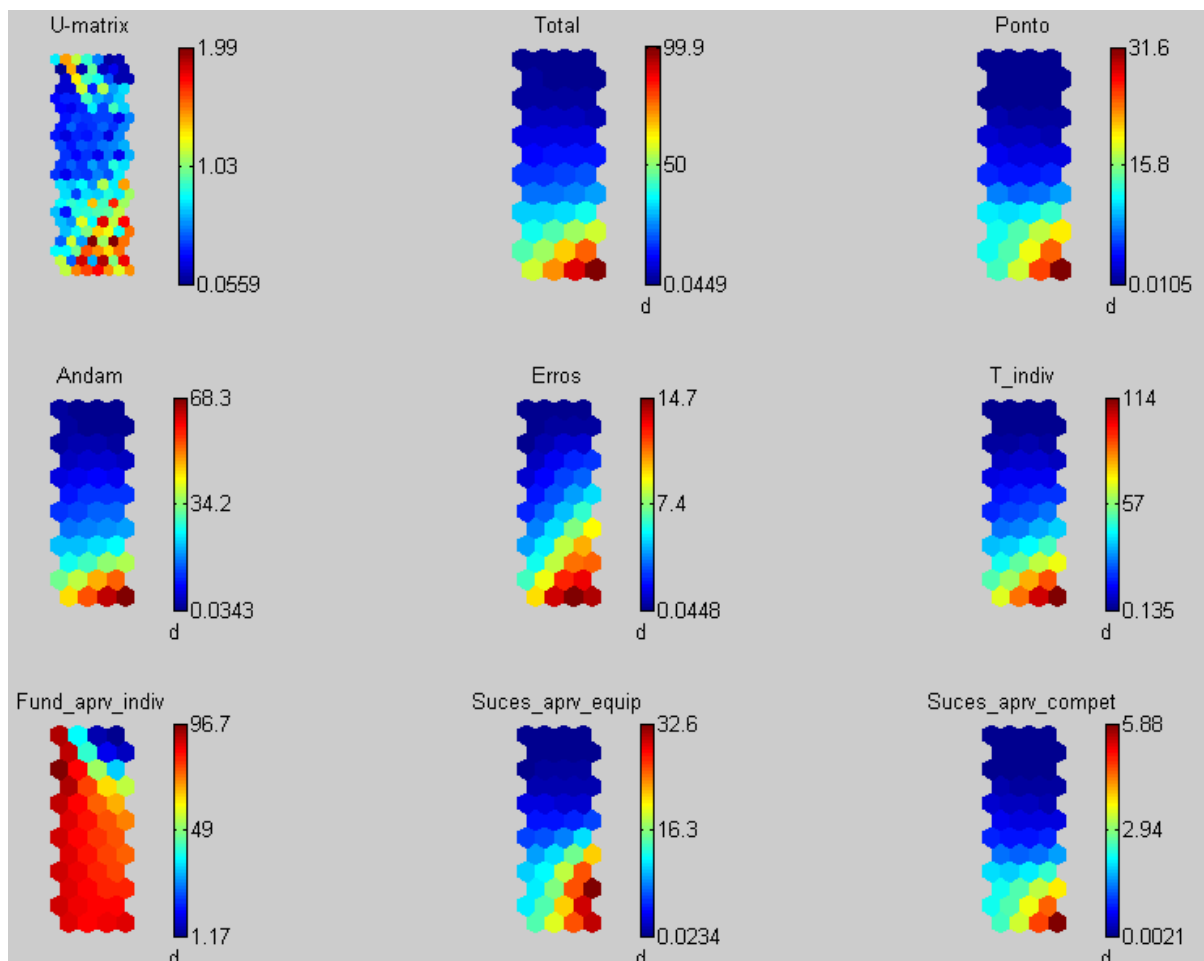


Figura 22 – U-matriz e variáveis individuais - fundamento ataque

onde: Total= número total de ações de ataque, sem erros; Ponto= ataques positivos; Andam= ataques que deram continuidade ao jogo; Erros= ataques negativos; T_indiv= número total de ações individuais; Fund_aprv_indiv= aproveitamento individual no fundamento ataque; Suces_aprv equip= aproveitamento da jogadora em relação à equipe; Suces_aprv compet= aproveitamento da jogadora em relação à competição.

Outro mapa é ilustrado na Fig. 23, o qual representa a U-matriz e a rede SOM, correspondente, com os rótulos.

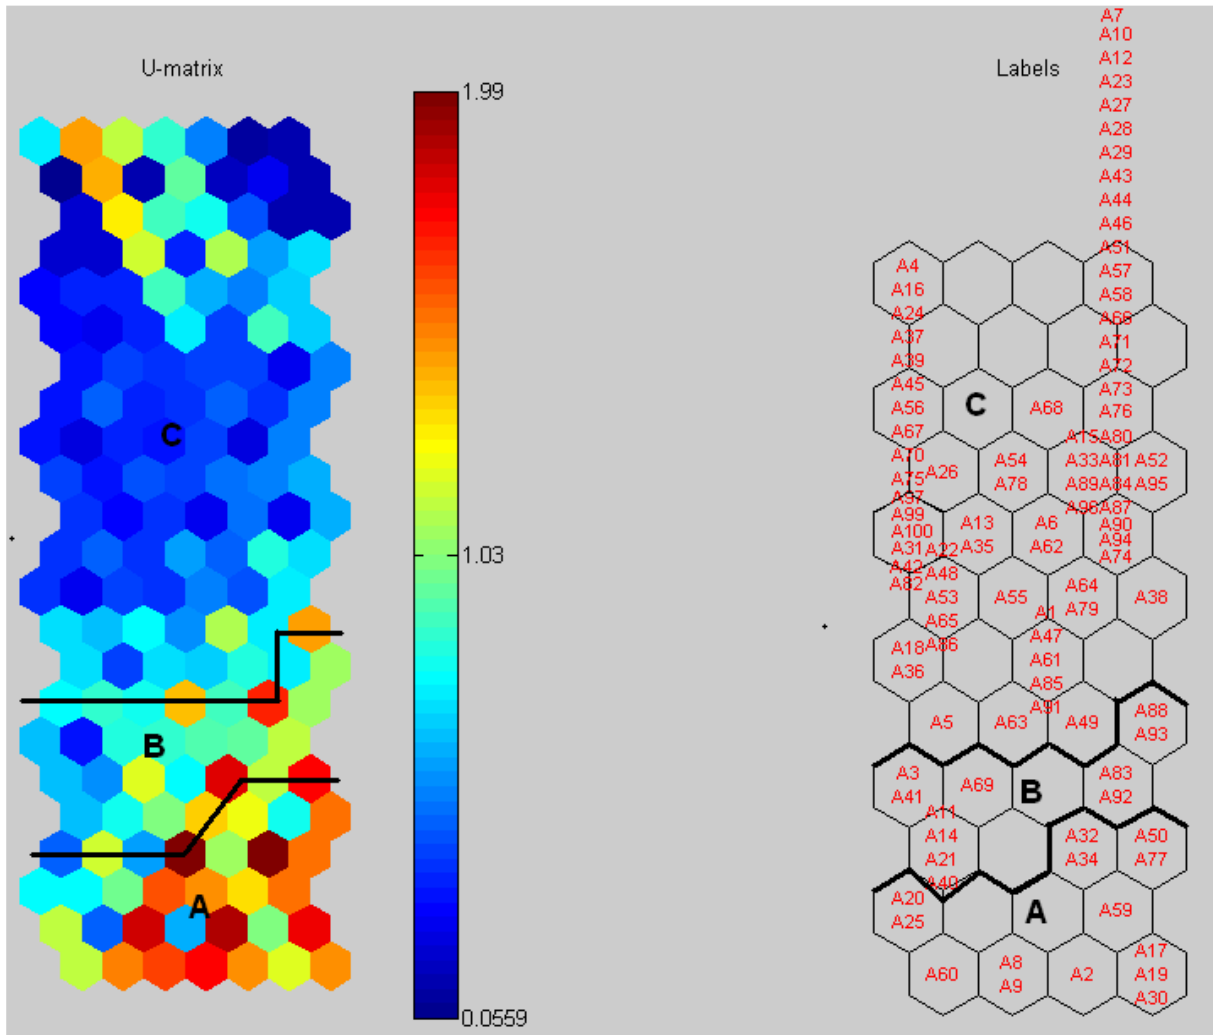


Figura 23 – U-matriz e rede SOM - fundamento ataque

O SOM nos permite ver entidades semelhantes colocadas na mesma unidade ou em unidades adjacentes no mapa. No entanto, se as amostras não são semelhantes, a distância entre as unidades correspondentes no mapa é visualizada, na U-matriz, com cores quentes (vermelho, amarelo).

Desta maneira, é possível identificar e confirmar que há três grupos bem distintos. Na região A, estão agrupadas as cinco melhores atacantes (destacadas em azul na Fig. 21) e também as jogadoras que executaram um maior número de ações de ataque e de ataques positivos, em consequência disso erraram mais do que as outras jogadoras das outras regiões, porém obtiveram um aproveitamento superior às demais na competição, tendendo assim a aproximarem-se das melhores atacantes. Na região B, estão as jogadoras intermediárias, as quais participaram da competição, porém apresentaram um índice de ações de ataque inferior ao da região A. As demais jogadoras estão na região C, isto é, agrupamento das jogadoras

que não executaram nenhuma ação de ataque (destacadas em preto na Fig. 21), pois não entraram para jogar ou não executaram essa ação durante o período que estavam atuando em quadra (*scout* de ataque zerado), e das jogadoras com aproveitamento individual de 100% (destacadas em vermelho na Fig. 21), pois executaram poucas ações individuais de ataque e assim apresentam baixo índice de ataques errados, quando comparadas às jogadoras da região A. Entretanto, o número de ataques positivos e o seu aproveitamento na competição é muito baixo ou nulo.

5.3 Análise do fundamento saque

Esta seção segue os mesmos passos da seção anterior, porém para o fundamento saque. O mapa das cinco melhores jogadoras da competição no fundamento saque foi gerado (Fig. 24), de acordo com as especificações padrão.




Figura 24 - U-matriz das cinco melhores jogadoras - fundamento saque

A Fig. 25 apresenta o mapa com cem (100) neurônios na camada de saída, dispostos na U-matriz, e os agrupamentos do conjunto total de jogadoras avaliadas no fundamento saque.

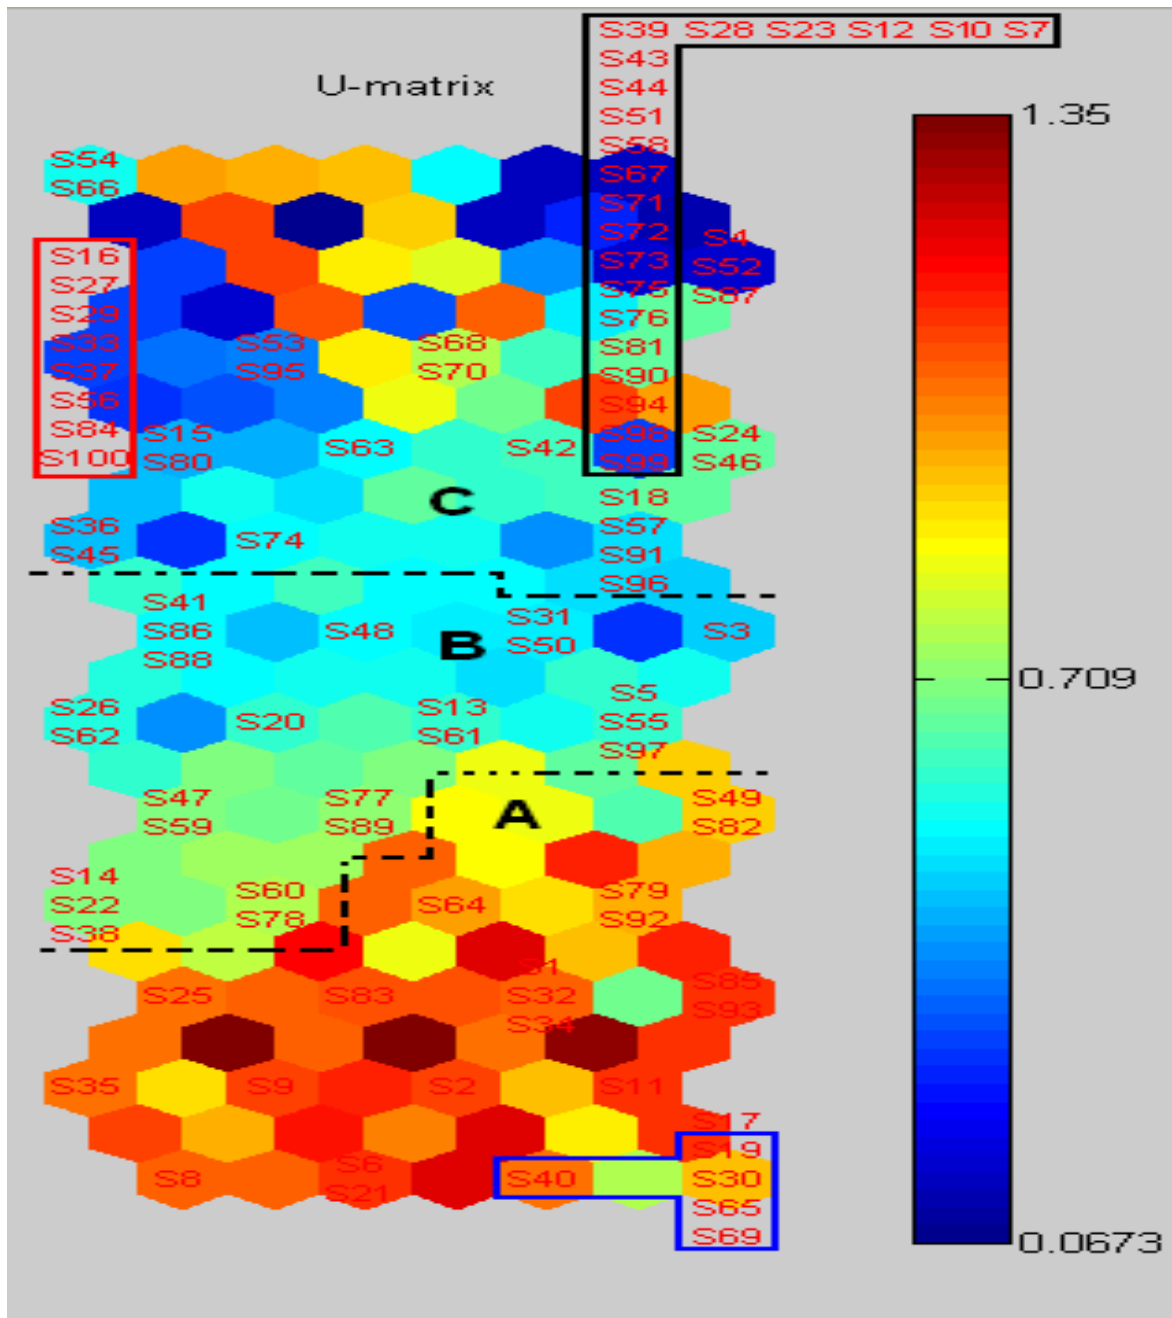


Figura 25 – U-matriz com separação dos agrupamentos - fundamento saque

O mapa classificado como bom é ilustrado na Fig. 25, no qual se observa a separação de três agrupamentos: A, B e C. Algumas linhas foram tracejadas, apresentando a idéia de divisão dos agrupamentos. Observa-se na legenda da Fig. 24 que a tonalidade verde representa uma distância de 0,709 entre os agrupamentos e o vermelho escuro uma distância de 1,35.

Para uma melhor visualização da separação das jogadoras no mapa, observe a Fig. 26, onde é apresentada a U-matriz e os mapas indicativos das jogadoras individualmente. Relembrando que as cores indicativas da U-matriz e dos

mapas indicativos das jogadoras individualmente possuem representações contrárias.

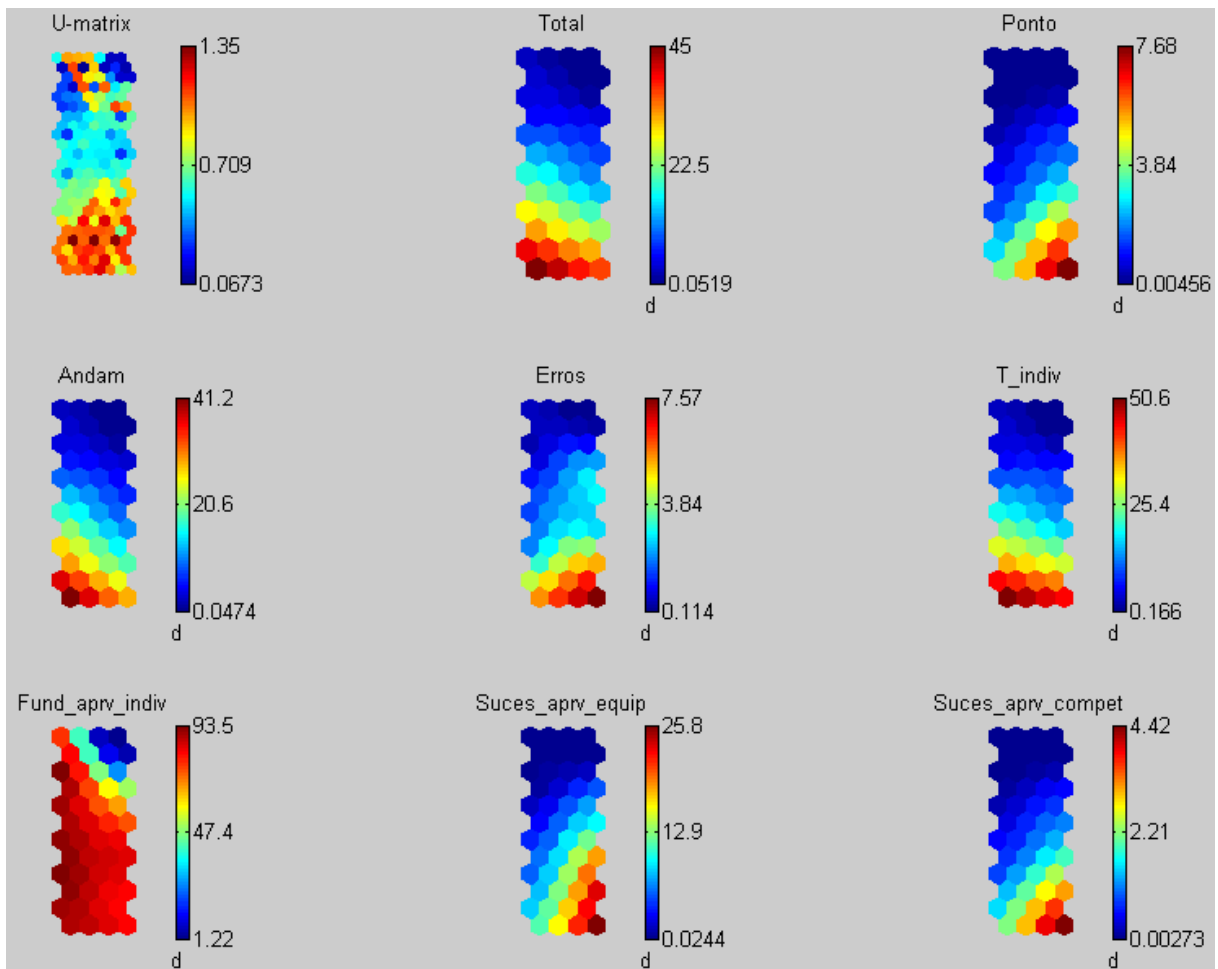


Figura 26 - U-matriz e variáveis individuais - fundamento saque

onde: Total= número total de ações de saque, sem erros; Ponto= saques positivos; Andam= saques que deram continuidade ao jogo; Erros= saques negativos; T_indiv= número total de ações individuais; Fund_aprv_indiv= aproveitamento individual no fundamento saque; Suces_aprv equip= aproveitamento da jogadora em relação à equipe; Suces_aprv compet= aproveitamento da jogadora em relação à competição.

A Fig. 27 ilustra o rotulamento das jogadoras e ressalta a capacidade da SOM de agrupar jogadoras com características semelhantes em células próximas.

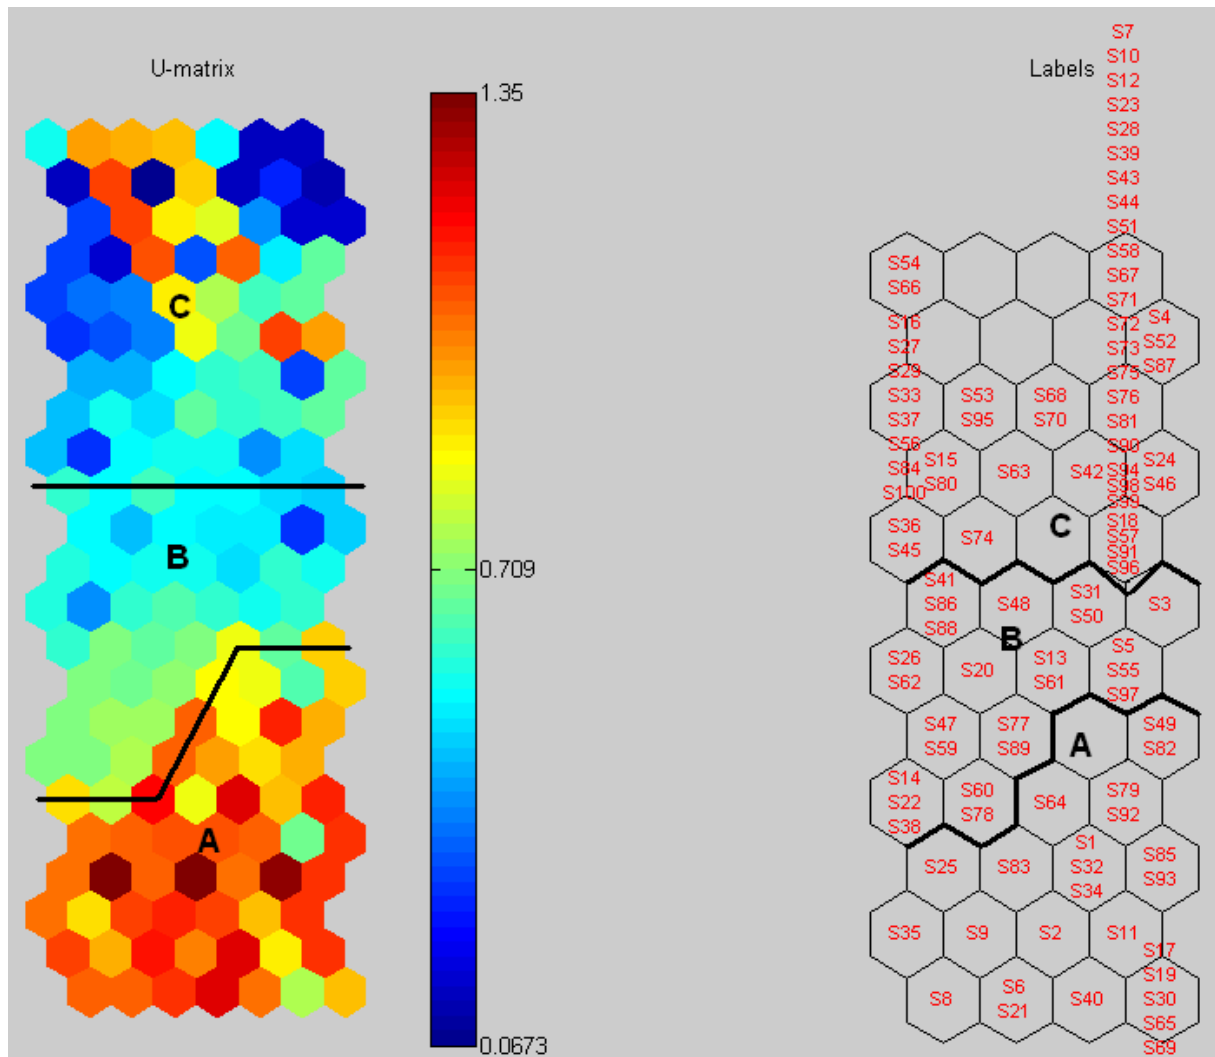


Figura 27 – U-matriz e rede SOM - fundamento saque

Na Fig. 27, é possível a identificação de três grupos distintos. Na região A estão agrupadas as cinco melhores sacadoras (destacadas em azul na Fig. 25) e também as jogadoras que executaram um maior número de ações de saque e de saques positivos. Conseqüentemente, tiveram um índice de erros maior do que as outras jogadoras, porém obtiveram um aproveitamento superior as demais na competição, tendendo assim a aproximarem-se das melhores sacadoras. Na região B encontram-se as jogadoras intermediárias, as quais participaram da competição, entretanto executaram poucas ações de saque, quando comparadas as jogadoras da região A. Como o aproveitamento individual no fundamento é calculado sobre o número total de saques executados, logo as jogadoras da região B apresentam um alto índice de aproveitamento individual, mas em relação à equipe e à competição esse aproveitamento diminui (Fig. 26). As demais jogadoras estão na região C, isto é, agrupamento das jogadoras que não executaram nenhuma ação de ataque

(destacadas em preto na Fig. 25), por não terem jogado ou não executado essa ação, durante o período que estavam atuando em quadra (*scout* de saque zerado), e das jogadoras com aproveitamento individual de 100% (destacadas em vermelho na Fig. 25), pois executaram poucas ações individuais de saque e assim apresentam baixo índice de saques errados, quando comparadas às jogadoras da região A. Em contrapartida, o número de ataques positivos e o seu aproveitamento na competição é muito baixo ou nulo.

As análises dos fundamentos apresentaram resultados satisfatórios com o uso da rede de Kohonen para as classificações dos agrupamentos. Foi visto que algumas jogadoras foram distribuídas em regiões diferentes no fundamento ataque e no fundamento saque. Isto pode ser explicado pelo fato das jogadoras não possuírem um mesmo padrão de desempenho nos dois fundamentos avaliados.

Observou-se que as jogadoras 30, 19 e 17 foram agrupadas, na região A, em células próximas nos fundamentos ataque e saque, este fato deve-se, provavelmente, ao alto rendimento delas nesses fundamentos. Em vista disso, pode-se designar essas jogadoras como um referencial padrão, pois elas apresentam uma homogeneidade em relação aos fundamentos analisados.

Com a classificação obtida através dos mapas auto-organizáveis foi possível a identificação de diferenças e similaridades em determinadas jogadoras. Desta forma, conclui-se que os mapas auto-organizáveis representam um recurso de grande valia no agrupamento de jogadores de voleibol e na classificação deles nos fundamentos em separado. Para assim, obter uma posterior análise do desempenho do jogador.

Por fim, há alguns pontos positivos a serem considerados neste caso, como: a rapidez da modelagem, a facilidade de visualização e interpretação dos agrupamentos nos resultados obtidos.

6 CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS

A essência desta pesquisa, desenvolvida ao longo deste estudo, buscou oferecer contribuições em duas áreas: na computacional e na desportiva. Mais especificamente, este trabalho de conclusão de curso mostrou que o *SOM* constitui uma técnica poderosa e promissora que vem ao encontro do objetivo proposto neste estudo, ou seja, de classificar/padronizar jogadores, neste caso, de voleibol, valendo-se da auto-organização. Uma característica de grande valor, neste estudo, foi a utilização de dados reais, coletados de uma competição, para avaliar os resultados obtidos com a aplicação da ferramenta.

Como Tavares (2006) afirma, que o desempenho de atletas pode ser observado diretamente em situações de treino e competição, e também na busca em otimizar o comportamento dos jogadores e equipes. Logo, treinadores e técnicos, com o auxílio desses mapas, podem fazer um estudo facilitado dos fundamentos do jogo, contribuindo assim na construção de referenciais para controle das cargas de treinamentos técnicos e táticos.

Como o objetivo do trabalho foi estabelecer a classificação de atletas, em grupos, de acordo com seus desempenhos nos diversos fundamentos, o algoritmo do *SOM* provou sua utilidade, sendo uma alternativa não apenas viável, mas útil, principalmente se a análise for realizada com a ajuda de outros métodos. Nos mapas obtidos, é possível visualizar jogadoras que, mesmo pertencendo a outro grupo, estão próximas, do ponto de vista de padrão de jogo, às cinco melhores jogadoras em determinado fundamento. Portanto, são jogadoras que os técnicos de voleibol obterão um melhor rendimento para sua equipe.

Diante dos resultados obtidos, quando se observa os fundamentos simultaneamente, detecta-se que jogadoras da mesma equipe com distâncias

pequenas, entre elas, apresentam um rendimento similar. Em vista disso, a utilização de mapas auto-organizáveis pode avaliar o quanto uma equipe é homogênea, isto é, a quantidade de jogadoras, da mesma equipe, que possuem distâncias pequenas em relação a companheira de equipe considerada como referência padrão em cada fundamento do voleibol. Quanto maior o número de jogadoras próximas, maior será a homogeneidade dessa equipe.

Vários tópicos, relacionados direta e indiretamente com este trabalho, podem ser citados para trabalhos futuros, por exemplo, possibilidade de construção do modelo *SOM* para obtenção de análises e comparações mensais dos jogadores de uma equipe de voleibol, nos quais treinadores e comissão técnica poderão ilustrar, aos seus jogadores, o rendimento, mensal, dos fundamentos em relação aos outros companheiros de equipe.

Uma aplicação significativa para o voleibol, seria o uso de mapas auto-organizáveis em *scouts* táticos, o qual é usado para avaliar as equipes adversárias. Com isso, treinadores poderão analisar os fundamentos dos jogadores da equipe adversária, antes das partidas, e assim poder explorar suas dificuldades.

É interessante, também, aplicar o uso desta técnica nos outros fundamentos do voleibol, como: recepção, defesa e levantamento. Desenvolvendo as mesmas avaliações realizadas neste trabalho e comparar seus resultados com os de sua equipe.

Referências

AHN, Jae-Wook; SYN, Sue Y. **Self-Organizing Map tutorial system**. Self-Organizing Map. Interactive System Design, abril de 2005. Disponível em: <<http://www.sis.pitt.edu/~ssyn/som/index.html>>. Acesso em: 10 nov. 2008.

BALIEIRO, S. **Jogada de alta tecnologia**. INFO: tecnologia da informação, número 224, ano 19, novembro 2004. Disponível em: <http://info.abril.com.br/edicoes/224/arquivos/4746_1.shl>. Acesso em: 3 nov. 2008.

BARRETO, Jorge M. **Introdução às redes neurais artificiais**. Laboratório de Conexionismo e Ciências Cognitivas. Florianópolis: 2002.

CARVALHO, Paulo Alexandre C. F. **Modelação do risco de incêndio florestal com redes neuronais artificiais**: aplicação ao Parque Natural de Montesinho. 2005. 173f. Tese (Mestrado em Ciência e Sistemas de Informação Geográfica) – Instituto Superior de Estatística e Gestão da Informação, Universidade Nova de Lisboa, Portugal.

CASTRO, Fernando César C.; CASTRO, Maria Cristina F. **Redes neurais artificiais**. Porto Alegre: PUCRS, 2001. Apostila para fins didáticos. Disponível em: <http://diana.ee.pucrs.br/~decastro/RNA_hp/RNA.html>. Acesso em: 24 set. 2008.

COSTA, José Alfredo F. **Classificação automática e análise de dados por redes neurais auto-organizáveis**. 1999. 341f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, São Paulo.

ESTATÍSTICA. In: MICHAELIS, Henriette. **Moderno dicionário da língua portuguesa**. São Paulo: Melhoramentos, 2007.

FARINA, Elaine Cristina R. **Riscos de lesões na região do tornozelo em jogadores de voleibol: proposta de prevenção**. Revista Digital, Buenos Aires,

Ano 12, n. 117, fev. 2008. Disponível em: <<http://www.efdeportes.com/>>. Acesso em: 12 set. 2008.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms, and applications**. Upper Saddle River: Prentice Hall, 1994.

FERNANDES FILHO, José. & MEDINA, M. F. **Identificação dos perfis genético e somatotípico que caracterizam atletas de voleibol masculino adulto de alto rendimento no Brasil**. Fitness & Performance Journal, v. 1, n. 4, p. 12-20, 2002.

FONSECA, Cláudio Luis T. et al. **Perfil dermatoglífico, somatotípico e da força explosiva de atletas da seleção brasileira de voleibol feminino**. . Fitness & Performance Journal, v. 1, n. 7, p. 35-40, 2008.

HAYKIN, Simon. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001.

HUSSEL, Stuart J.; NORVIG, Peter. **Artificial Intelligence: A modern approach**. 2.ed. Upper Saddle River: Pearson Education International, 2003.

KOHONEN, Teuvo. **Self-organizing maps**. Information Sciences. 3.ed. New York: Springer, 2001.

MASSA, M., SILVA, L. R. R. da, BOHME, M. T. S., UEZU, R. **A utilização de variáveis cineantropométricas no processo de detecção, seleção e promoção de talentos no voleibol**. Revista Brasileira Ciência e Movimento, v. 11, n. 1, p. 69-76, 2003a.

OLIVEIRA, Rui, MESQUITA, Isabel, OLIVEIRA, Manuel. **Caracterização da eficácia do bloco no voleibol de elevado rendimento competitivo**. Revista Digital, Buenos Aires, Ano 10, n. 84, maio 2005. Disponível em: <<http://www.efdeportes.com/>>. Acesso em: 9 set. 2008.

PANICKI, Luiz César. **Redes neurais: (SOM) Mapas auto-organizáveis** – Kohonen. 2004. Projeto de Diplomação (Especialização em Ciência da Computação). Universidade Estadual de Londrina, Londrina.

PORTILHO, Maycon Cesar C.; CASTRO, Daniel M. **Uma visão geral sobre redes neurais artificiais**. 2006. 28f. Monografia (Trabalho de Graduação). Curso de Engenharia Mecânica. Setor de Ciências Exatas. Universidade Estadual do Oeste do Paraná, Foz do Iguaçu.

RAIMANN, Luis Henrique. **Scout: sistema de monitoração em equipes de voleibol**. 2007. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) – Instituto de Ciências Exatas e Tecnológicas, Feevale, Novo Hamburgo.

RUMELHART, D; HINTON G, WILLIAMS R. **Learning Internal Representations by Error Propagation**. In: Parallel Distributed Processing: Explorations in the Microstructure of Cognition - Vol. 1. Cambridge: MIT Press, 1986.

SILVA, Marco Aurélio S. **Mapas auto-organizáveis na análise exploratória de dados Geoespaciais multivariados**. 2004. 117f. Tese (Mestrado em Computação Aplicada) – São José dos Campos: INPE (Instituto Nacional de Pesquisas Espaciais), São Paulo.

SIQUEIRA, Paulo Henrique. **Uma nova abordagem na resolução do problema do caixeiro viajante**. 2005. 102f. Tese (Doutorado em Ciências). Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná, Curitiba.

TAFNER, Malcon, XEREZ, Marcos, RODRIGUES FILHO, Ilson. **Redes Neurais Artificiais: introdução e princípios de neurocomputação**. Blumenau: EKO, 1995.

TATIBANA, Cássia Yuri. **Introdução a Redes Neurais**. Disponível em: <<http://www.din.uem.br/ia/neurais>>. Acesso em: 10 set. 2008.

TAVARES, F. J. S. Analisar o jogo nos esportes coletivos para melhorar a performance: uma necessidade para o processo de treino. *In*: DE ROSE JUNIOR, D. **Modalidades esportivas coletivas**. Rio de Janeiro: Guanabara Koogan, 2006.

UNIVERSIDADE FEDERAL DE PELOTAS. **Clínica de Arbitragem em Voleibol**. Voleibol Feminino – relatório final agosto/2000. Pelotas, 2000. 27 p.

VESANTO, Juha, HIMBERG, Johan, ALHONIEMI, Esa, PARHANKANGAS, Juha. **SOM Toolbox for Matlab 5**. Report A57. Finland. 2000.

VILLAMEA, Oscar Luis. **El uso de la estadística em El voleibol**. Disponível em: <<http://www.efdeportes.com/efd9/voley9.htm>>. Acesso em: 3 set. 2008.

ZAMBERLAM, A. O. ; WIVES, L. K. ; GOULART, R. R. V.; SILVEIRA, R. G. **A IA entrando na quadra de vôlei: scout inteligente**. Hífen (Uruguaiana), Uruguaiana, v. 29, p. 103-106, 2005.

ZUBEN, Fernando, ATTUX, Romis. **Tópico 8 - Rede neural de Kohonen e aprendizado não-supervisionado**. 2007. 57f. Notas de aula. Universidade Estadual de Campinas, São Paulo.

ZUCHINI, Márcio Henrique. **Aplicações de mapas auto-organizáveis em mineração de dados e recuperação de informação**. 2003. 215f. Tese (Mestrado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, São Paulo.

WIKIPÉDIA. Voleibol. Disponível em: < <http://pt.wikipedia.org/wiki/Voleibol> >. Acesso em: 22 set. 2008.

Anexo A – Base de dados (*scouts*)

Total	Positivo	Andam	Erros	T_indiv	Fund_ap rv_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
16	6	10	5	21	76.2	5.9	1.1	A1
106	23	83	19	125	84.8	22.8	4.3	A2
32	14	18	3	35	91.4	13.9	2.6	A3
1	0	1	0	1	100	0	0	A4
19	9	10	3	21	90.5	8.9	1.7	A5
12	1	11	3	15	80	1	0.2	A6
0	0	0	0	0	0	0	0	A7
75	15	60	16	91	82.4	14.9	2.8	A8
78	19	59	20	98	79.6	18.8	3.5	A9
0	0	0	0	0	0	0	0	A10
38	14	24	6	44	86.4	13.9	2.6	A11
0	0	0	0	0	0	0	0	A12
8	4	4	2	10	80	2.8	0.7	A13
35	14	21	6	41	85.4	10	2.6	A14
2	0	2	1	3	66.7	0	0	A15
1	0	1	0	1	100	0	0	A16
99	34	65	13	112	88.4	24.3	6.3	A17
13	7	6	2	15	86.7	5	1.3	A18
150	43	107	16	166	90.4	30.7	8	A19
46	11	35	6	52	88.5	7.9	2	A20
36	12	24	5	41	87.8	8.6	2.2	A21
11	4	7	2	13	84.6	2.9	0.7	A22
0	0	0	0	0	0	0	0	A23
1	0	1	0	1	100	0	0	A24
48	10	38	5	53	90.6	7.1	1.9	A25
7	1	6	1	8	87.5	0.7	0.2	A26
0	0	0	0	0	0	0	0	A27
0	0	0	0	0	0	0	0	A28
0	0	0	0	0	0	0	0	A29
106	44	62	11	117	90.6	35.2	8.2	A30
11	3	8	1	12	91.7	2.4	0.6	A31
51	19	32	12	63	81	15.2	3.5	A32
2	1	1	1	3	66.7	0.8	0.2	A33
48	20	28	13	61	78.7	16	3.7	A34
11	0	11	2	13	84.6	0	0	A35
17	5	12	2	19	89.5	4	0.9	A36
1	1	0	0	1	100	0.8	0.2	A37
13	4	9	7	20	65	3.2	0.7	A38
1	0	1	0	1	100	0	0	A39
38	13	25	5	43	88.4	10.4	2.4	A40
27	11	16	2	29	93.1	8.8	2	A41
9	4	5	0	9	100	3.2	0.7	A42

Total	Positivo	Andam	Erros	T_indiv	Fund_ap rv_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
0	0	0	0	0	0	0	0	A43
0	0	0	0	0	0	0	0	A44
2	0	2	0	2	100	0	0	A45
0	0	0	0	0	0	0	0	A46
19	3	16	5	24	79.2	7.5	0.6	A47
13	3	10	0	13	100	7.5	0.6	A48
22	7	15	7	29	75.9	17.5	1.3	A49
60	20	40	8	68	88.2	50	3.7	A50
0	0	0	0	0	0	0	0	A51
3	1	2	3	6	50	2.5	0.2	A52
13	3	10	2	15	86.7	7.5	0.6	A53
5	1	4	2	7	71.4	2.5	0.2	A54
14	2	12	3	17	82.4	5	0.4	A55
3	0	3	0	3	100	0	0	A56
0	0	0	0	0	0	0	0	A57
0	0	0	0	0	0	0	0	A58
75	17	58	15	90	83.3	37	3.2	A59
58	10	48	7	65	89.2	21.7	1.9	A60
21	2	19	5	26	80.8	4.3	0.4	A61
11	0	11	3	14	78.6	0	0	A62
19	6	13	5	24	79.2	13	1.1	A63
18	1	17	5	23	78.3	2.2	0.2	A64
16	2	14	2	18	88.9	4.3	0.4	A65
0	0	0	0	0	0	0	0	A66
1	0	1	0	1	100	0	0	A67
1	1	0	1	2	50	2.2	0.2	A68
36	7	29	4	40	90	15.2	1.3	A69
1	0	1	0	1	100	0	0	A70
0	0	0	0	0	0	0	0	A71
0	0	0	0	0	0	0	0	A72
0	0	0	0	0	0	0	0	A73
9	1	8	5	14	64.3	1.7	0.2	A74
1	0	1	0	1	100	0	0	A75
0	0	0	0	0	0	0	0	A76
60	30	30	8	68	88.2	50	5.6	A77
5	1	4	2	7	71.4	1.7	0.2	A78
12	3	9	4	16	75	5	0.6	A79
0	0	0	0	0	0	0	0	A80
0	0	0	0	0	0	0	0	A81
7	2	5	1	8	87.5	3.3	0.4	A82
37	15	22	13	50	74	25	2.8	A83
0	0	0	0	0	0	0	0	A84
18	4	14	4	22	81.8	6.7	0.7	A85
12	4	8	2	14	85.7	6.7	0.7	A86

Total	Positivo	Andam	Erros	T_indiv	Fund_aprv_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
0	0	0	1	1	0	0	0	A87
24	5	19	14	38	63.2	20	0.9	A88
4	0	4	2	6	66.7	0	0	A89
0	0	0	0	0	0	0	0	A90
23	2	21	4	27	85.2	8	0.4	A91
27	8	19	16	43	62.8	32	1.5	A92
26	9	17	6	32	81.3	36	1.7	A93
0	0	0	0	0	0	0	0	A94
2	1	1	2	4	50	4	0.2	A95
4	0	4	2	6	66.7	0	0	A96
1	0	1	0	1	100	0	0	A97
1	0	1	3	4	25	0	0	A98
1	0	1	0	1	100	0	0	A99
2	0	2	0	2	100	0	0	A100

Total	Positivo	Andam	Erros	T_indiv	Fund_aprv_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
20	4	16	7	27	74.1	11.4	2.3	S1
37	6	31	3	40	92.5	17.1	3.4	S2
9	2	7	6	15	60	5.7	1.2	S3
0	0	0	1	1	0	0	0	S4
11	3	8	3	14	78.6	8.6	1.7	S5
58	6	52	7	65	89.2	17.1	3.4	S6
0	0	0	0	0	0	0	0	S7
59	3	56	4	63	93.7	8.6	1.7	S8
37	5	32	3	40	92.5	14.2	2.9	S9
0	0	0	0	0	0	0	0	S10
29	6	23	7	36	80.6	17.1	3.4	S11
0	0	0	0	0	0	0	0	S12
13	2	11	2	15	86.7	6.3	1.2	S13
26	2	24	1	27	96.3	6.3	1.2	S14
5	0	5	1	6	83.3	0	0	S15
5	0	5	0	5	100	0	0	S16
37	8	29	13	50	74	25.8	4.6	S17
6	2	4	3	9	66.7	6.3	1.2	S18
58	9	49	7	65	89.2	28.1	5.2	S19
16	1	15	2	18	88.9	3.1	0.6	S20
37	4	33	10	47	78.7	12.5	2.3	S21
35	0	35	0	35	100	0	0	S22
0	0	0	0	0	0	0	0	S23
2	1	1	2	4	50	3.1	0.6	S24

Total	Positivo	Andam	Erros	T_indiv	Fund_apr v_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
35	2	33	3	38	92.1	6.3	1.2	S25
16	1	15	0	16	100	3.1	0.6	S26
1	0	1	0	1	100	0	0	S27
0	0	0	0	0	0	0	0	S28
3	0	3	0	3	100	0	0	S29
41	10	31	7	48	85.4	28.6	5.8	S30
8	2	6	1	9	88.9	5.7	1.2	S31
18	5	13	9	27	66.7	14.3	2.9	S32
5	1	4	0	5	100	2.9	0.6	S33
27	6	21	3	30	90	17.1	3.5	S34
44	1	43	7	51	86.3	2.9	0.6	S35
9	0	9	1	10	90	0	0	S36
1	0	1	0	1	100	0	0	S37
37	0	37	1	38	97.4	0	0	S38
0	0	0	0	0	0	0	0	S39
52	8	44	6	58	89.7	22.9	4.6	S40
13	1	11	1	14	92.9	2.9	0.6	S41
3	1	2	2	5	60	2.9	0.6	S42
0	0	0	0	0	0	0	0	S43
0	0	0	0	0	0	0	0	S44
12	0	12	1	13	92.3	0	0	S45
1	1	0	1	2	50	10	0.6	S46
22	1	21	1	23	95.7	10	0.6	S47
11	1	10	2	13	84.6	10	0.6	S48
11	3	8	2	13	84.6	30	1.7	S49
11	1	10	3	14	78.6	10	0.6	S50
0	0	0	0	0	0	0	0	S51
0	0	0	1	1	0	0	0	S52
4	0	4	1	5	80	0	0	S53
2	0	2	1	3	66.7	0	0	S54
6	2	4	0	6	100	20	1.2	S55
5	0	5	0	5	100	0	0	S56
5	1	4	3	8	62.5	10	0.6	S57
0	0	0	0	0	0	0	0	S58
24	1	23	1	25	96	3.8	0.6	S59
26	2	24	3	29	89.7	7.7	1.2	S60
13	2	11	2	15	86.7	7.7	1.2	S61
20	1	19	1	21	95.2	3.8	0.6	S62
5	0	5	2	7	71.4	0	0	S63
24	4	20	4	28	85.7	15.4	2.3	S64
28	8	20	6	34	82.4	30.8	4.6	S65
2	0	2	1	3	66.7	0	0	S66
0	0	0	0	0	0	0	0	S67
2	0	2	2	4	50	0	0	S68

Total	Positivo	Andam	Erros	T_indiv	Fund_apr v_indiv	Suces_a prv_indiv	Suces_a prv_com pet	Ident
27	8	19	9	36	75	30.8	4.6	S69
2	0	2	2	4	50	0	0	S70
0	0	0	0	0	0	0	0	S71
0	0	0	0	0	0	0	0	S72
0	0	0	0	0	0	0	0	S73
8	1	7	1	9	88.9	5	0.6	S74
0	0	0	0	0	0	0	0	S75
0	0	0	0	0	0	0	0	S76
17	1	16	5	22	77.3	5	0.6	S77
26	2	24	1	27	96.3	10	1.2	S78
19	5	14	4	23	82.6	25	2.9	S79
6	0	6	1	7	85.7	0	0	S80
0	0	0	0	0	0	0	0	S81
11	4	7	1	12	91.7	20	2.3	S82
27	2	25	6	33	81.8	10	1.2	S83
3	0	3	0	3	100	0	0	S84
18	5	13	6	24	75	25	2.9	S85
15	0	15	3	18	83.3	0	0	S86
0	0	0	1	1	0	0	0	S87
14	0	14	2	16	87.5	0	0	S88
16	1	15	5	21	77	6.7	0.6	S89
0	0	0	0	0	0	0	0	S90
6	1	5	3	9	66.7	6.7	0.6	S91
21	4	17	1	22	95.5	26.7	2.3	S92
17	6	11	5	22	77.3	40	3.5	S93
0	0	0	0	0	0	0	0	S94
4	0	4	1	5	80	0	0	S95
8	1	7	5	13	61.5	6.7	0.6	S96
9	2	7	2	11	81.8	13.3	1.2	S97
0	0	0	0	0	0	0	0	S98
0	0	0	0	0	0	0	0	S99
2	0	2	0	2	100	0	0	S100