

**UNIVERSIDADE FEDERAL DO RIO GRANDE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA OCEÂNICA**

**FERRAMENTAS DE ANÁLISE INTELIGENTE APLICADAS AO PLANEJAMENTO
E CONTROLE NA CONSTRUÇÃO NAVAL**

KAREN BARAÑANO SOUZA

Dissertação apresentada à Comissão de Curso de Pós-Graduação em Engenharia Oceânica da Fundação Universidade do Rio Grande, como requisito parcial à obtenção do título de Mestre em Engenharia Oceânica.

Orientadora: Silvia Silva da Costa Botelho, Dra.

Rio Grande, agosto de 2011

Este trabalho é dedicado a meus pais João e Sufi, exemplos determinantes de coragem, perseverança e amor.

AGRADECIMENTOS

Agradeço a Deus pelas oportunidades que me foram dadas na vida, principalmente por ter conhecido pessoas e lugares interessantes, mas também por ter vivido fases difíceis, que foram matérias-primas de aprendizado.

Aos meus pais João e Sufi, que deram o melhor de si para que eu pudesse compor o que sou hoje.

Aos meus irmãos pelo carinho, atenção e exemplo de retidão e amizade. Em especial a minha irmã Dirciara por ter sido tão dedicada em todas as etapas de minha formação, sempre me apoiando em todos os momentos, enfim pelos conselhos e pela confiança em mim depositada, minha eterna gratidão.

A meu cunhado Paulo Ricardo, pela amizade e apoio incondicional.

Aos meus amigos André, Andresa, Sérgio e Vitta que apesar de distantes se fizeram presentes nos momentos de incertezas.

A Nilza, pelo extremo profissionalismo frente a secretaria do PPG e por insistir para que eu não fosse covarde com minhas fragilidades, meu especial obrigada.

A Ana Luiza Nunes, pela disponibilização de tempo e trabalho para ajuste do projeto às normas do programa de pós graduação. Ao Paulinho, meu sobrinho de coração, por sua parceria nas traduções que se fizeram necessárias durante o percurso.

A minha orientadora Dra Silvia Botelho, pela convivência neste período de retorno a vida acadêmica, acrescentando profundo conhecimento técnico e empírico a minha vida e por saber respeitar meus tempos produtivos.

A todos que de alguma forma fizeram parte desta conquista através do apoio, convivência e compartilhamento de conhecimento.

*“Ninguém pode construir em teu lugar as pontes que precisarás para atravessar o rio da vida
- ninguém, exceto tu, só tu.”
Friedrich Nietzsche*

RESUMO

O objetivo deste trabalho é desenvolver um sistema baseado em inteligência artificial, com o uso de redes neurais artificiais, mais especificamente as arquiteturas de mapas auto-organizáveis utilizando o algoritmo de *kohonen* para agrupamento e *multilayer perceptron* (MLP) utilizando o algoritmo *backpropagation* para classificação de dados, que possibilite a melhoria do agrupamento das diferentes partes estruturais dos navios, identificando os diversos elementos de uma família de produtos e os agrupando de acordo com os atributos de projeto e produtivos, utilizando os princípios da tecnologia de grupo de forma a mobilizar recursos específicos (Células de Manufatura) em sua concepção e minimizar custos. Fazendo uma análise dos principais métodos utilizados na construção naval para gerenciamento da produção, bem como as ferramentas aplicadas, são apresentados conceitos relativos à identificação das famílias de produtos intermediários, processos utilizados na construção naval, estrutura analítica do produto, conceitos de manufatura celular e tecnologia de grupo. A metodologia proposta para atender o objetivo deste trabalho, destaca a aplicação de técnicas inteligentes, sendo descrita a função de cada variável envolvida no sistema de agrupamento/classificação de dados. De forma a contribuir nas funções de planejamento, com ganhos de eficiência na manufatura, facilidade de programação em seqüência de peças de uma mesma família, melhoria no controle do processo, planos de processo e instruções padronizadas, possibilidade de formação de células de manufatura e aumento da qualidade e controle da construção naval.

Palavras-chave: Inteligência Artificial, Construção Naval.

ABSTRACT

The objective of this work is to develop a system based on artificial intelligence, using artificial neural networks, more specifically the self-organizing maps architectures, using Kohonen's algorithm for clustering and multilayer perceptron (MLP), using the backpropagation algorithm for data classification, which enables the enhancement of aggregation of different ships' structural parts, identifying the various elements of a products family and grouping them according to the attributes of project and productives, using group technology principles in order to mobilize specific resources (Manufacturing Cells) in its conception and minimize costs. Making an analysis of the main methods used in shipbuilding for production management, as well as the tools used, concepts are presented on the identification of intermediate products families, processes used in shipbuilding, product analytical structure, concepts of cellular manufacturing and group technology. The methodology proposed to serve the study objective highlights the application of intelligent techniques, being described the function of each variable involved in the system of data grouping/classification. In order to help in planning functions, with efficiency gains in manufacturing, ease of programming in sequences of same family parts, improvement in process control, process plans and standardized instructions, possibility of formation of manufacturing cells and increased shipbuilding control and quality.

Keywords: Artificial Intelligence, Shipbuilding.

SUMÁRIO

LISTA DE SÍMBOLOS	10
LISTA DE ABREVIATURAS	12
LISTA DE TABELAS	13
LISTA DE FIGURAS	14
1 INTRODUÇÃO	16
1.1 MOTIVAÇÃO	16
1.2 OBJETIVO GERAL	22
1.2.1 Objetivos Específicos	22
1.3 ESTRUTURA DO TRABALHO	23
2 A CONSTRUÇÃO DE NAVIOS ;.....	24
2.1 AS ETAPAS DE CONSTRUÇÃO DE UM NAVIO	25
2.1.1 Construindo cascos.....	27
2.1.2 Os Processos de <i>Outfitting</i>	32
2.2 A EVOLUÇÃO DOS PROCEDIMENTOS NA CONSTRUÇÃO NAVAL	33
2.2.1 Construção por sistemas	33
2.2.2 Construção por blocos	34
2.2.3 Pré- <i>Outfitting</i> e <i>Outfitting</i> por zonas	34
2.2.4 Construção integrada	35
2.3 CONSIDERAÇÕES FINAIS	37
3 IMPLEMENTANDO UMA PRODUÇÃO INTEGRADA	38
3.1 UTILIZANDO TECNOLOGIAS DE GRUPO	38
3.2 ESTRUTURA ANALÍTICA DO PRODUTO – PWBS	40
3.3 MANUFATURA CELULAR	41
3.3.1 Atividades de produção e layout da fábrica	42
3.4 CLASSIFICAÇÃO E CODIFICAÇÃO DE PEÇAS	45
3.5 CONSIDERAÇÕES FINAIS	47

4	TÉCNICAS INTELIGENTES PARA AGRUPAMENTO E CLASSIFICAÇÃO DE DADOS	49
4.1	REDES NEURAIAS ARTIFICIAIS	49
4.2	APLICAÇÕES DAS REDES NEURAIAS ARTIFICIAIS	51
4.2.1	Agrupamento (<i>Clustering</i>)	51
4.2.2	Reconhecimento de padrões	52
4.3	ANÁLISE DE AGRUPAMENTOS: MAPAS AUTO-ORGANIZÁVEIS (SOM).....	53
4.3.1	Estrutura básica	53
4.3.2	Funcionamento do Algoritmo SOM	55
4.3.3	Análise dos resultados do mapa	58
4.3.4	Visualização de dados com SOM	60
4.4	MÉTODOS DE CLASSIFICAÇÃO USANDO REDES NEURAIAS SUPERVISIONADAS	61
4.4.1	O neurônio <i>Perceptron</i>	62
4.4.2	<i>Perceptron</i> multicamadas	65
4.4.3	Algoritmo <i>Backpropagation</i>	66
4.5	CONSIDERAÇÕES FINAIS	68
5	UMA PROPOSTA PARA AGRUPAMENTO E CLASSIFICAÇÃO DE FAMÍLIAS DE PRODUTOS INTERMEDIÁRIOS.....	69
5.1	INTRODUÇÃO	69
5.2	PRÉ-PROCESSAMENTO DOS DADOS	70
5.2.1	Extração de características e normalização	71
5.3	CATEGORIZAÇÃO (CLUSTERING): OBTENÇÃO DAS FAMÍLIAS DE PRODUTOS	72
5.4	MÓDULO MLP DE CLASSIFICAÇÃO: CLASSIFICANDO BLOCOS	74
5.5	PARÂMETROS A SEREM DEFINIDOS	79
5.6	CONSIDERAÇÕES FINAIS	81
6	ESTUDO DE CASO: TESTE E VALIDAÇÃO	83
6.1	IMPLEMENTAÇÃO DA PROPOSTA NO MATLAB	83
6.1.1	Heurísticas	84

6.1.2	Medidas estatísticas de qualidade	84
6.1.3	Tamanho do mapa	84
6.2	RELATÓRIO DE EXPERIMENTOS	85
6.2.1	Implementando o Módulo Agrupador SOM	86
6.2.2	Classificador: Algoritmo <i>Backpropagation</i>	94
6.3	CONSIDERAÇÕES FINAIS	104
7	CONCLUSÃO	106
	REFERÊNCIAS BIBLIOGRÁFICAS	108

LISTA DE SIMBOLOS

D	dimensão dos dados de entrada
$ERR0_i$	o erro obtido para a saída do neurônio 'i'
$ERR0_{ESTIMADO\ i}$	o erro estimado
$EXP(X)$	função que representa o logaritmo Neperiano
N	o número de vetores de entrada
N	número de amostras de treinamento ou validação
OUT_i	valor obtido na saída do neurônio 'i'
Q	tamanho do Mapa
R_c	representa as coordenadas do neurônio vencedor
R_i	representam as coordenadas de um vetor vizinho
$SAIDA_{DESEJADA\ i}$	a saída que queremos obter no neurônio 'i'
$SAIDA_{OBTIDA\ i}$	a saída que o neurônio 'i'
W	valor do peso
W_{ik}	representa o peso do neurônio 'i' associado à entrada 'k'
$W_{ik}(t)$	é o valor do peso W do neurônio 'i' conectado a entrada 'k' em um dado instante de tempo (t)
X	vetor de entrada
$c(x)$	representa a coordenada do neurônio vencedor
d	é a distância euclidiana
$h(t)$	função de vizinhança em um dado instante de tempo (t)
i	neurônio
k	vetor de pesos do neurônio vencedor
m	vetor de pesos sinápticos
n	características
t	instante de tempo
y_{do}	valor de saída desejado
y_o	saída da rede
β	é denominado constante de momento
$\sigma(t)$	representa a função que determina o raio da vizinhança em um dado

$\infty (t)$

instante de tempo (t)

é a taxa de aprendizagem que mostra a rapidez com o mapa se ajusta aos dados de entrada em um dado instante de tempo (t)

somatório

LISTA DE ABREVIATURAS

BMU	Best Matching Unit
CAD	Computer-Aided Design
CAM	Computer-Aided Manufacturing
CAPP	<i>Computer Aided Process Planning</i>
CIM	Computer-Integrated Manufacturing
CEGN	Centro de Estudos de Gestão Naval
COPPE/UFRJ	Instituto Luiz Alberto Coimbra de Pós-Graduação e Pesquisa de Engenharia – Universidade Federal do Rio de Janeiro
CNC	Controle Numérico Computadorizado
ERP	Enterprise Resource Planning
IA	Inteligência Artificial
IHI	Ishikawajima-Harima
MATLAB	MATriz LABoratory
MLP	<i>MultiLayer Perceptron</i>
MRP II	<i>Material Requirement Planning</i>
MSE	<i>Mean Square Error</i>
PFA	<i>Production flow analysis</i>
PWBS	Estrutura Analítica de Produto
QE	Erro Médio de Quantização
RNA	Redes Neurais Artificiais
SOM	<i>Self-organized Maps</i>
TE	Erro Topográfico
TG	Tecnologia de Grupo
VQ	<i>Vector Quantization</i>
WBS	<i>Work breakdown structure</i>

LISTA DE TABELAS

Tabela 2.1	Avanço no lançamento a água.	36
Tabela 5.	Arquitetura do Sistema de Reconhecimento de Padrões	78
Tabela 6.1	'Blocks' (Dados)	85
Tabela 6.2	Mapas representativos do Banco de Dados	88
Tabela 6.3	Erros médios de quantização e topográfico	89
Tabela 6.4	Número ideal de classes	93
Tabela 6.5	Comportamento da MLP frente ao aprendizado	96
Tabela 6.6	Resultados obtidos frente às diferentes taxas de aprendizado na Rede 01	96
Tabela 6.7	Comportamento da MLP frente ao aprendizado	97
Tabela 6.8	Resultados obtidos frente às diferentes taxas de aprendizado na Rede 02	98
Tabela 6.9	Comportamento da MLP frente ao aprendizado	99
Tabela 6.10	Comportamento da MLP frente ao aprendizado	100
Tabela 6.11	Resultados obtidos frente às diferentes taxas de aprendizado na Rede 03	101
Tabela 6.12	Comportamento da MLP frente ao aprendizado	102
Tabela 6.13	Resultados obtidos frente às diferentes taxas de aprendizado na Rede 04	103

LISTA DE FIGURAS

Figura 1.1	Estaleiros associados a grupos estrangeiros no Brasil	17
Figura 1.2	Definição de planejamento e controle de capacidade produtiva	18
Figura 1.3	Caracterização dos níveis tecnológicos de estaleiros.....	20
Figura 2.1	Montagem no Dique	24
Figura 2.2	Divisão do navio em blocos (linhas cheias)	28
Figura 2.3	Exemplos de painel curvo do Sub-Bloco do Bojo	28
Figura 2.4	Fabricação de peças	29
Figura 2.5	Montagem das peças	29
Figura 2.6	Montagem dos sub-conjuntos	30
Figura 2.7	Montagem dos painéis	30
Figura 2.8	Montagem dos blocos (Castelo de Proa)	31
Figura 2.9	Fluxograma do material no Estaleiro	31
Figura 2.10	Carreira de construção	33
Figura 2.11	Construção por blocos.	34
Figura 2.12	Divisão do navio por zonas	35
Figura 2.13	Construção integrada	36
Figura 3.1	Exemplo de Produto Final, com a montagem dos diversos blocos e sub-blocos	39
Figura 3.2	Tipos de processos em operações de manufatura	42
Figura 3.3	Estratégias de manufatura - Tradicional e Celular	44
Figura 3.4	Exemplo de um sistema de manufatura celular/chão de fábrica	45
Figura 4.1	Pontos no espaço de características	52
Figura 4.2	Estrutura de um mapa auto-organizado	53
Figura 4.3	Relação de vizinhança	54
Figura 4.4	Formas diferentes de mapas: plano retangular à esquerda, cilindro no centro e toróide à direita	54
Figura 4.5	Adaptação dos neurônios próximos ao neurônio vencedor	57
Figura 4.6	Capacidade de representação dos dados	61
Figura 4.7	Comparação entre o neurônio biológico e artificial	62

Figura 4.8	(a) Padrão linearmente separável. (b) Padrão não linearmente separável	66
Figura 4.9	Operação do Algoritmo <i>Backpropagation</i>	67
Figura 4.10	<i>Backpropagation</i> em modo progressivo (<i>feed-forward</i>)	68
Figura 5.	Arquitetura do sistema de agrupamento e classificação de dados	69
Figura 5.	Valores escalares	71
Figura 5.	Categorização (Clustering): o sistema recebe um conjunto de padrões representado cada qual por n características	73
Figura 5.	Vetores de características próximas. Neste exemplo cada amostra possui duas características, X_1 e X_2 para a sua descrição	73
Figura 5.5	Desenvolvimento de um modelo baseado em RNA	75
Figura 5.6	Método de Parada Antecipada com conjunto de validação	81
Figura 6.1	Esquema dos blocos de construção	86
Figura 6.2	BMU com o nº de vezes que o dado ocorreu	88
Figura 6.3	Matriz U - 2D e 3D	91
Figura 6.4	Correlação dos planos de cada um dos atributos	92
Figura 6.5	Clusterização dos dados	93
Figura 6.6	Rede Neural MLP-BP	95

1. INTRODUÇÃO

1.1. MOTIVAÇÃO

Nos anos 80 com a criação de uma política industrial e algumas formas de subsídio, a indústria da construção naval brasileira chegou a ocupar posições significativas no ranking mundial da construção em tonelada de porte bruto-tpb. No seu ápice, a indústria naval chegou a ter quase meio milhão de pessoas, direta ou indiretamente empregadas, atingindo 40.000 postos diretos de trabalho, gerando cada um mais 5 postos indiretos.

Apesar da demanda e de fortes incentivos governamentais a indústria naval brasileira não sobreviveu à crise do petróleo e ao desaquecimento da economia global na década de 80. A maioria das grandes potências passou a empreender ações políticas a fim de reduzir o grau de participação das bandeiras dos países em desenvolvimento, utilizando mais intensamente bandeiras de conveniência e oferecendo seus navios no mercado de afretamento a preços reduzidos.

Essa situação refletiu-se na armação brasileira, gerando grande queda no movimento internacional de mercadorias e nos níveis de frete, aumentando o afretamento de embarcações estrangeiras e reduzindo drasticamente as encomendas dos estaleiros, trazendo a indústria de construção naval do Brasil a um nível de estagnação tal que em 1988 existiam apenas cerca de dois mil empregados, ou seja, vinte vezes menor do que na época do seu auge.

Como consequência direta, também a cadeia produtiva da indústria naval brasileira sofreu prejuízos, com o desaparecimento de segmentos importantes, como as indústrias de motores navais, hélices e outras específicas do setor naval. Essa combinação de fatores adversos fragilizou econômica e financeiramente o setor, conduzindo a crescente diminuição em atualização tecnológica, modernização de instalações e melhoramento dos métodos de trabalho. Esta crise causou endividamento dos estaleiros, colocando-os em situação de inadimplência, levando muitos deles a se associarem a grupos estrangeiros, principalmente da Noruega e Cingapura, enquanto outros simplesmente arrendaram suas instalações para grupos também estrangeiros, conforme se pode observar na Figura 1.1.

EISA – Estaleiros Ilha S. ^a	Grupo Jurong	Cingapura
Estaleiros Verolme	Grupo Keppel Fels	Cingapura
Estaleiros Mauá	Grupo Jurong	Cingapura
Estaleiros Cruzeiro do Sul	Grupo Rodriguez Cantiere Navali	Itália
Estaleiros PROMAR	Grupo Aker	Noruega

Figura 1.1 - Estaleiros associados a grupos estrangeiros no Brasil
Fonte: Brasil, 2002.

Atualmente, essa indústria está passando por uma fase de grande desenvolvimento, encerrando um período de crise iniciado em meados da década de 1970 e que se arrastou pela década de 1980. Em todo o mundo a indústria da construção naval está se organizando de forma estratégica, integrando as cadeias produtivas que envolvem fornecedores de produtos e serviços, criando novas oportunidades de negócios, promovendo a inovação e a formação de recursos humanos qualificados e representando uma fonte importante de geração de empregos, movimentando anualmente mais de US\$ 20 trilhões. A retomada de investimentos no setor possibilita um aumento das economias de escala e o crescimento de cadeias produtivas que estavam estagnadas devido à falta de demanda interna.

As estatísticas do *Lloyd's Register* (É uma sociedade de classificação marítima e uma organização da gestão de risco independente, para fornecer serviços de avaliação de riscos e de mitigação e certificação de sistemas de gestão) apontam uma mudança na estrutura mundial da construção naval. Se em 1975 a produção anual de embarcações segmentava-se em 17,4 milhões de toneladas brutas na Ásia, contra 13 milhões na Europa Ocidental, e 2,5 milhões nos demais países, em meados do ano 2000 os estaleiros asiáticos conquistam o mercado e aumentam seu patamar de produção atingindo 26,4 milhões de toneladas brutas.

Neste período a Europa reduz sua participação no mercado, caindo de 13 milhões de toneladas brutas para 4 milhões em 2001. As estatísticas para 2001 apontavam a entrega de navios na Ásia, num total de 25,9 milhões de toneladas brutas, 4,3 milhões de toneladas brutas na Europa, 129 mil toneladas brutas nos EUA e 804 mil toneladas brutas nos demais países do mundo (Brasil, 2002).

No seu processo de retomada o setor de construção naval brasileiro necessita de condições para competir no mercado internacional. Velasco (1997) considera que para não se repetirem os erros do passado é preciso que se invista em condições organizacionais, incluindo dentre outras medidas, a modernização das práticas gerenciais e dos métodos produtivos.

Diante do exposto, é importante decidir-se sobre o melhor emprego dos recursos de produção, assegurando assim a execução do que foi previsto pelo planejamento e controle da produção. Em nível mais agregado, envolve a administração da capacidade de produção, de modo que atenda as flutuações da demanda. Para tal deve-se estabelecer em mais alto nível técnicas para mensurar a capacidade de produção e demanda que discriminem entre os diferentes produtos e serviços que uma operação produtiva pode fazer, conciliando no nível geral e agregado, a existência da capacidade com o nível de demanda a ser satisfeita (Fig. 1.2).



Figura 1.2- Definição de planejamento e controle de capacidade produtiva

Fonte: Slack, 1997.

Segundo Slack *et.al.*(1997, p. 346), a capacidade de uma operação é “o máximo nível de atividade de valor adicionado em determinado período de tempo, que o processo pode realizar sob condições normais de operação”, algumas organizações optam por operar abaixo desta quando a demanda diminui, permitindo que a operação possa rapidamente responder a cada novo pedido. Com frequência, normalmente algumas partes da operação funcionam abaixo de sua capacidade, enquanto outras partes operam em sua capacidade máxima. Os processos que trabalham em sua capacidade máxima são os responsáveis pelas restrições de capacidade de toda a operação.

Estas restrições, denominadas pontos de estrangulamento ou gargalos, limitam o desempenho de todo um sistema (Chase e Aquilano, 1995), justificando a necessidade de prever suas ocorrências e minimizar seus efeitos.

Analisando o comportamento de mercado da indústria naval é possível criar estratégias de antecipação da capacidade à demanda e de acompanhamento da demanda pela capacidade. A medição da demanda e da capacidade (Planejamento e controle de capacidade é

a tarefa de determinar a capacidade efetiva da operação produtiva, de forma que ela possa responder a demanda, Slack, 1997, p.347) de um estaleiro pode ser difícil de prever. Para fins de planejamento, a demanda pode ser **determinística** ou **estocástica** dependendo das circunstâncias.

A demanda determinística caracteriza-se pela ausência de incerteza sobre o impacto da demanda no planejamento e na capacidade do estaleiro a médio prazo. A demanda é considerada determinística quando o estaleiro considera apenas trabalhos em curso e seu planejamento de processos a médio prazo.

A demanda é estocástica quando o processo de planejamento de médio prazo inclui navios que sejam apenas expectativas de demanda. Nestes casos se faz necessária uma representação estocástica das previsões de demanda, que dependendo da extensão que o planejamento abrange, envolvem a confiabilidade das previsões, o tamanho total e o nível de concorrência desse mercado. Demandas estocásticas envolvem estratégias de planejamento de médio prazo capazes de explicar a variabilidade dos processos através de uma representação estocástica das variáveis associadas. Também devem ser capaz de empregar uma representação estocástica da demanda, se necessário. Quando as representações estocásticas do desempenho do processo e/ou demanda são utilizadas, o processo de planejamento de médio prazo deve gerar programações probabilísticas, planos de utilização de recursos e estimativas de custos, tanto para a avaliação de risco, como para suporte ao desenvolvimento e inclusão de estratégias de mitigação de riscos como parte da estratégia global de construção. O objetivo do planejamento estocástico é gerar um plano que tenha uma probabilidade de ocorrência, que seja aceitável do ponto de vista de satisfazer tanto as necessidades dos clientes e estratégia da empresa, como o planejamento de negócios, ou seja, que represente os níveis aceitáveis de risco do negócio para a empresa e seus clientes.

Tendo em vista as variações atuais no mercado global de navios a médio e longo prazo, caracterizando aos estaleiros uma demanda estocástica, é importante decidir como a operação deve reagir a estas flutuações (Torquato; Silva, 2000). Também é cada vez mais decisiva a habilidade em colaborar ou, mais precisamente, é cada vez mais decisivo aumentar a colaboração entre as principais áreas das empresas. Isso é conseguido por meio da aplicação de novas tecnologias (Swink, 2006). Estas vêm permitindo a definição mais precisa da capacidade do estaleiro a longo prazo, bem como a produção em série dos navios mais demandados (graneleiros, petroleiros) e a produção de navios com alta tecnologia embarcada.

Neste novo cenário tecnológico é característica importante a definição de níveis de capacidade em médio e longo prazo em termos agregados. Isto é, tomar decisões de

capacidade amplas e gerais, não se preocupando com todos os detalhes dos produtos e serviços oferecidos. Surgem políticas agregadas de gestão as quais assumem que o mix de diferentes produtos e serviços permanece relativamente constante durante o período de planejamento adequando-se ao produto final de acordo com sua complexidade.

Desta forma é possível a criação de *frameworks* (Atua onde há funcionalidades em comum a várias aplicações, porém para isso as aplicações devem ter algo razoavelmente grande em comum para que o mesmo possa ser utilizado em várias aplicações) genéricos que atendam de forma satisfatória as variações do produto final. Estas estruturas genéricas podem ser utilizadas de forma a otimizar os diferentes processos fabris associados a cada encomenda. Ferramentas tecnológicas tornam-se um componente importante para o sucesso da implantação de estratégias de utilização de *frameworks* genéricos. No mercado mundial de construção naval, o nível tecnológico de um estaleiro é definido pelo conjunto de ativos e sistemas de informação disponíveis. Os níveis que caracterizam a tecnologia utilizada em um dado estaleiro, conforme o National Shipbuilding Research Program (FMI, 2010) são aqui apresentados na Figura 1.3.

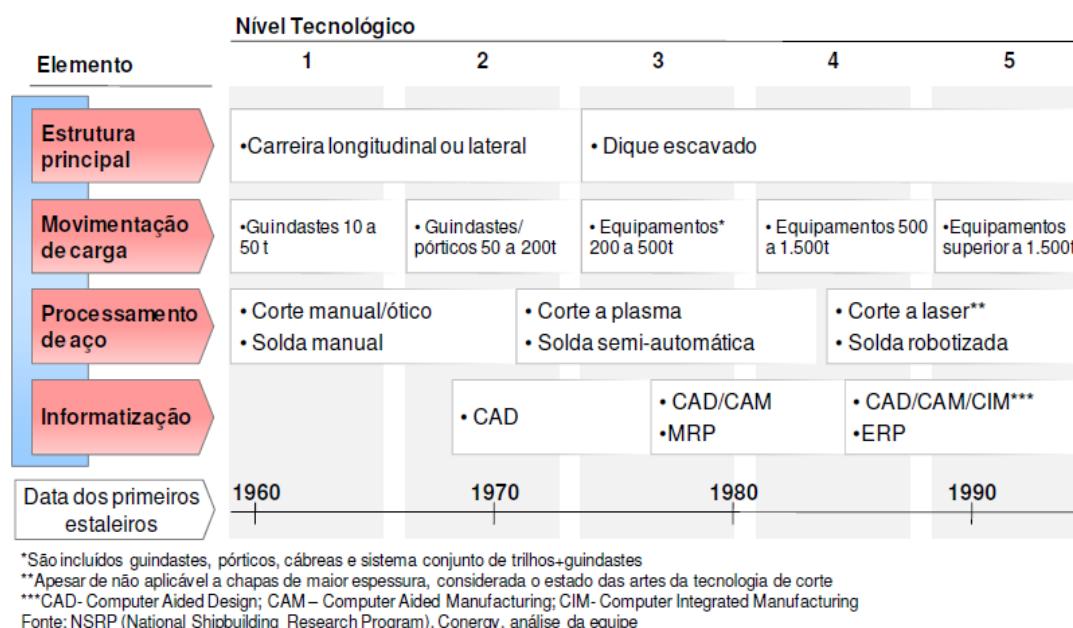


Figura 1.3 - Caracterização dos níveis tecnológicos de estaleiros

Fonte: FMI, 2010.

Os primeiros níveis, 1 e 2, apresentam praticamente nenhuma informatização, ao passo que a partir do nível 3 surgem sistemas de informação que permitem gerenciar recursos, processos, projeto e finanças. Na medida em que se aproximam do nível 5, estes sistemas se tornam integrados. Naturalmente, os avanços tecnológicos exigirão níveis maiores de qualificação da mão-de-obra.

A baixa capacidade de movimentação de cargas e união dos blocos no dique são características de níveis inferiores ao 3º. Com o aumento significativo da capacidade dos equipamentos de içamento, a partir do nível 3 começaram a ser utilizados grandes blocos na construção naval. Hoje estaleiros do nível 5 constroem navios em seis partes, denominadas anéis (Considera-se um anel a seção transversal inteira do navio, ao passo que blocos constituem apenas uma parte deste), e utilizam o dique apenas para uni-las (Favarin *et al.*, 2010).

Uma pesquisa realizada pelo Centro de Estudos de Gestão Naval (CEGN) (Pinto *et al.*, 2010) junto a estaleiros brasileiros (Estaleiro Wilson Sons, Estaleiro Aliança, Estaleiro Ilha S.A., Estaleiro Itajaí, Estaleiro Mauá Jurong, Aker Promar, Arsenal da Marinha do Rio de Janeiro, Estaleiro Alumitech) e mundiais (Daewoo Shipbuilding, IHI Marine United, Kawasaki Shipbuilding, Sumitomo HD), ressalta a importância do incremento da tecnologia no cenário nacional. Mesmo concluindo que as práticas nos estaleiros nacionais são adequadas, o estudo aponta existir um longo percurso a ser percorrido na introdução de novas tecnologias que aproximem o chão de fábrica a novos métodos construtivos, impactando na execução da obra no prazo.

Na evolução do mercado da construção naval, elenca-se um conjunto de ações que podem contribuir para o aumento de produtividade. Dentre estas pode-se citar a padronização de navios, a qual possibilita uma maior velocidade de construção, além de maior flexibilidade para atender a novos escopos de projeto. Mesmo apresentando algumas restrições como a escolha das características do desenho, diminuição de transferência de *know-how* (Ou conhecimento processual é o conhecimento de como executar alguma tarefa) dos fornecedores para os construtores, certa dificuldade de adaptação com novos contratantes, na prática o custo benefício tem-se mostrado recompensador.

Os estaleiros mais competitivos como o *Daewoo Shipbuilding and Heavy Machinery*, coreano, tem uma maior integração vertical, onde cada membro dos pacotes de trabalho é unido através de uma hierarquia, e cada membro da hierarquia produz um produto diferente e estes produtos combinados satisfazem uma necessidade produtiva.

Associadas a padronização, novas práticas se instituem. Por exemplo, surge a adoção da construção por blocos, onde seções inteiras são pré-montadas. Quando esta pré-montagem inclui os equipamentos, eixos e redes pré-alinhadas, deixando para a carreira apenas a montagem final, denomina-se construção pelo processo de acabamento avançado. Esta reduz a utilização da carreira ou dique, conduzindo a um aumento significativo na produtividade do estaleiro, com o uso do dique paralelamente por outros navios. Economia de tempo de 10

vezes em relação ao acabamento/preenchimento no navio pronto são alcançados. Os melhores estaleiros fazem uso desta técnica em 80% do total do navio.

A definição de grupos estruturais que otimizem os atributos de projeto e produtivos é um desafio associado a produção em blocos e por famílias. A complexidade associada a diversidade de formas e processos produtivos presentes a médio termo no estaleiro, conduz a necessidade de uso de métodos matemáticos para a categorização e classificação dos conjuntos a serem agregados. Recentemente, técnicas de Inteligência Artificial vêm sendo empregadas na definição destes grupos (Souza *et al.*, 2008) devido a sua capacidade para tratamento de padrões complexos e não-lineares (Haykin, 2001). Com base em tais técnicas, metodologias podem ser desenvolvidas e aplicadas a diferentes estaleiros, levando em conta os quesitos customizados de cada canteiro e modelo de produção.

1.2 OBJETIVO GERAL

O objetivo deste trabalho é desenvolver um sistema baseado em inteligência artificial que possibilite a melhoria do agrupamento das diferentes partes estruturais dos navios, identificando os diversos elementos de uma família de produtos e os agrupando de acordo com os atributos de projeto e produtivos, utilizando os princípios da tecnologia de grupo de forma a mobilizar recursos específicos (Células de Manufatura) em sua concepção e minimizar custos.

1.2.1 Objetivos Específicos

De forma mais específica, tem-se as seguintes etapas a serem realizadas:

- Estudo do estado de arte de técnicas de produção para a indústria naval e *offshore*;
- Levantamento bibliográfico das técnicas de Inteligência Artificial (IA) para agrupamento e classificação de padrões;
- Desenvolvimento de uma metodologia de uso de técnicas de IA para a obtenção automática de grupos associados a famílias de produtos intermediários; e
- Teste e validação da metodologia proposta em um estudo de caso associado à construção naval.

1.3 ESTRUTURA DO TRABALHO

A dissertação está estruturada em sete capítulos, sendo que este primeiro apresenta uma contextualização do trabalho, seus aspectos relevantes e o objetivo a ser alcançado.

No capítulo 2 é descrito o processo de construção de navios e suas principais características, tendo como foco as etapas envolvidas.

O capítulo 3 faz uma análise dos principais métodos utilizados na construção naval para gerenciamento da produção, bem como as ferramentas aplicadas. São apresentados conceitos relativos à identificação das famílias de produtos intermediários, processos utilizados na construção naval, estrutura analítica do produto, conceitos de manufatura celular e tecnologia de grupo.

O capítulo 4 destaca a aplicação de técnicas inteligentes para agrupamento e classificação de dados, com o uso de redes neurais artificiais, mais especificamente as arquiteturas de mapas auto-organizáveis utilizando o algoritmo de *Kohonen* e *MultiLayer Perceptron* (MLP) utilizando o algoritmo de aprendizado *Backpropagation*.

O capítulo 5 apresenta a metodologia proposta para atender o objetivo deste trabalho, sendo descrita a função de cada variável envolvida no sistema de agrupamento/classificação de dados.

O capítulo 6 traz as simulações realizadas para a validação da metodologia proposta no capítulo cinco.

O capítulo 7 aborda as conclusões sobre o trabalho e encaminhamento para trabalhos futuros.

2 A CONSTRUÇÃO DE NAVIOS

Navios, como produtos a serem produzidos, normalmente apresentam as seguintes características gerais:

- são extremamente grandes e complexos;
- apresentam um valor unitário elevado;
- são geralmente produzidos em baixo volume (1-10 por estaleiro por ano);
- são feitos sob encomenda;
- a maioria das vezes são semi-customizados, ou customizados; e
- normalmente possuem um curto tempo de contrato até o fornecimento, levando-se em conta a complexidade do conteúdo de trabalho.

Estas características orientadas a projetos únicos, com estruturas que são mobilizadas e desmobilizadas com o propósito de executar um único projeto fizeram com que a construção artesanal no dique fosse considerada inicialmente a abordagem mais adequada para a produção de navios (Fig 2.1). As técnicas de produção de navios evoluíram e modernizaram-se, no capítulo 3 é feita uma análise dos principais métodos utilizados atualmente.



Figura 2.1 - Montagem no Dique
Fonte: Brito; Gordo, 2006.

Recentemente busca-se identificar grupos de processos que estejam associados a famílias de produtos intermediários ao longo de todo o processo de manufatura naval. Este capítulo visa apresentar as diferentes etapas de construção de navios, bem como uma revisão das práticas gerenciais e métodos produtivos de planejamento e controle utilizados nos últimos anos, de forma a possibilitar o entendimento da metodologia para agrupamento de blocos a ser introduzida neste trabalho.

De forma mais precisa serão apresentados os processos associados a construção de cascos e *outfitting*. Será apresentada uma análise documental dos diversos processos envolvidos nas etapas de construção de um navio, a edificação da estrutura principal (casco) e os processos de preenchimento do mesmo.

Como referências básicas foram utilizadas o livro “Arte Naval, *Ship Design and Construction*, trabalhos do Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE/UFRJ), do Centro de Estudos de Gestão Naval (CEGN), apostilas do curso de especialização em Engenharia Naval da Universidade Técnica de Lisboa e artigos de periódicos sobre a indústria da construção naval no cenário mundial.

2.1 AS ETAPAS DE CONSTRUÇÃO DE UM NAVIO

Em resumo as fases convencionais das atividades de um Estaleiro de construção naval começam com a celebração do contrato com o armador, a avaliação dos requisitos do projeto de produção e adequação do estaleiro para a fabricação. Seguido do planejamento, escolha da estratégia construtiva e programação da construção, escolha e encomenda dos materiais, execução dos moldes do casco, superestrutura, e acessórios. Dá-se início a construção estrutural (laminagem) - casco, superestrutura e outros elementos de dimensão significativa. O *Outfitting* (Na construção naval costumam-se chamar de *outfitting* todos os elementos de uma embarcação que não fazem parte da estrutura do casco. Incluem-se nesse grupo acessórios de casco e de convés, máquinas e equipamentos, cabos e calhas elétricos, de instrumentação e Telecom, HVAC, tubulações e acessórios de tubulação) com a instalação de todos os equipamentos e acessórios necessários à utilização do navio é feito durante a montagem estrutural no estaleiro ou na carreira e/ou dique.

Na fase de *outfitting* são usados diversos processos tecnológicos de fabricação inerentes às diversas especialidades técnicas utilizadas, como: mecânica, eletricidade, serralharia, carpintaria, isolamentos, construção de encanamentos e dutos, entre outros. Este

último tendo especificidades próprias na utilização em navios; com máquinas próprias para conformação dos tubos, bem como para o seu corte e soldagem.

Depois da junção dos blocos são feitos os ajustes com a colocação em funcionamento pela primeira vez do navio, são feitas as provas de entrega (a de cais e de mar). Após a entrega é posta uma garantia.

As fases enunciadas não são estanques entre si. Isto é, existe alguma sobreposição entre elas, variável caso a caso. A seguir apresenta-se uma descrição de cada:

- **Projeto Detalhado:** Partindo do anteprojeto do navio realiza-se o projeto de detalhes que permite o estabelecimento da configuração do navio e a definição pormenorizada de todos os componentes a adquirir, a manufaturar e a montar; esta fase também permite a definição das necessidades do material a adquirir, permitindo a sua encomenda.
- **Estudo e Preparação do Trabalho:** Elaboração dos documentos técnicos que permitem ordenar a execução dos trabalhos com o uso extensivo do apoio dos sistemas de informação no projeto de engenharia; esta fase confunde-se cada vez mais com a anterior.
- **Traçagem e Planificação:** Obtenção de elementos informativos que permitam a definição geométrica dos componentes estruturais (painéis, reforços e outros); obtenção das dimensões antes das deformações; execução do aninhamento (*nesting* - A definição das partes a serem obtidas de uma chapa de aço através de um plano de corte), que é o processo de decidir sobre o modo de aproveitamento do material.
- **Marcação:** Operação onde se define de forma indelével a forma e as dimensões dos componentes a fabricar. Tratava-se da operação física de inserir marcas nas superfícies externas do material através do uso de riscadores e punções. Hoje, com o uso do computador para apoiar o projeto e a manufatura é possível prescindir da marcação em operações fabris, designando o corte por meios automáticos; os elementos informativos são enviados diretamente do projeto para a máquina ferramenta, maçaricos automáticos de corte, entre outros.
- **Manufatura:** Fabricação de componentes individualizados a partir da matéria-prima; recorre-se, sobretudo ao corte (térmico ou mecânico, sendo o primeiro mais generalizado) e à deformação plástica ou conformação. Por vezes, no caso de ser necessário fabricar perfis de dimensões não comercializadas, usa-se também a soldagem.

- **Pré-Fabricação:** Corresponde à união entre si de peças ou componentes simples, formando painéis reforçados e blocos bidimensionais (pavimentos, anteparas, etc.). Usa-se principalmente o processo de soldagem.
- **Montagem de Blocos:** Ligações de peças simples, de painéis e blocos bidimensionais entre si, formando blocos tridimensionais de diversas dimensões e complexidade consoante à estratégia de fabrico e capacidade de içamento do estaleiro. Usa-se principalmente o processo de soldagem.
- **Montagem do Navio:** Posicionamento, alinhamento e ligação de blocos entre si. Usam-se principalmente os processos de solda e os meios para movimentação e elevação.
- **Controle de Qualidade:** Uso de técnicas de medição linear e de forma, verificação de solda, de pinturas, de estanqueidade e outras no âmbito da verificação de qualidade. Estas atividades têm em vista verificar a conformidade das peças e dos seus conjuntos com o que consta nos desenhos construtivos e na especificação técnica do navio. Feita em todas as etapas do processo construtivo.
- **Proteção Superficial:** Decapagem e pintura das peças e dos seus conjuntos; estes trabalhos são feitos em todas as fases. A pintura total do navio é feita no final da construção.

Devido ao significativo papel da construção estrutural (casco) na execução da obra dentro dos atuais padrões de mercado, é importante conhecer este aspecto detalhadamente.

2.1.1 Construindo cascos

Na década de 20 a construção naval se utilizava da técnica de rebites. Com a introdução da solda na década de 30, os princípios básicos da construção naval começaram a mudar. A construção do casco se transformou em um processo de montagens e sub-montagens de blocos soldados que eram posteriormente agregados, formando o casco da embarcação, ver Fig. 2.2. Uma parte do processo se deslocou para uma região próxima da carreira ou em oficinas independentes, onde a maior parte do processo de soldagem pode ser feita com maior qualidade.




Figura 2.2 - Divisão do navio em blocos (linhas cheias)

Fonte: Brito; Gordo, 2006, p. 10.

Sendo um navio formado basicamente por chapas de aço, perfis e sistemas, a construção do casco através de blocos é dividida em cinco níveis de operações de modo a otimizar o fluxo de trabalho e reduzir o tempo de montagem na carreira ou no dique. Apresenta-se a seguir estes níveis:

- 1º Nível - Fabricação de peças: esta fabricação é composta por uma diversidade de componentes, como: painéis retos; painéis curvos (Fig. 2.3) e perfis (Vigas).

As seções de popa e proa possuem a maioria dos painéis curvos existentes no navio. O tempo gasto em peças curvas é, em média, maior que nas planas, mas as seções do corpo médio paralelo são consideravelmente maiores que as seções curvas, sendo assim a carga de trabalho por seção ficam compensadas (Fig. 2.4).




Figura 2.3 - Exemplos de painel curvo do Sub-Bloco do Bojo

Fonte: Clarkson Research, 2010.




Figura 2.4 - Fabricação de peças
 Fonte: Brito; Gordo, 2006, p. 06.

- 2º Nível - Montagem de peças (Fig. 2.5): neste nível são feitas as montagem de perfis das seções não oferecidas pela siderurgia; e a montagem de componentes como, por exemplo, de um esquadro ligado à aba (Ou Flange: 1. Cada um dos dois lados de uma Cantoneira; 2. Lado menor dos demais Perfis. O mesmo que Flange. Cf. Alma) de um perfilado.




Figura 2.5 - Montagem das peças
 Fonte: Brito; Gordo, 2006, p. 06.

- 3º Nível - Montagem dos blocos de 2 dimensões (Fig. 2.6 e 2.7): esta montagem envolve, numa primeira fase, a construção do painel e, na segunda, a montagem sobre o painel dos elementos resistentes ou estruturais (Reforço de qualquer natureza ligado a uma chapa, que sirva para aumentar a sua resistência e a sua rigidez).

- 4º Nível - Montagem dos blocos de 3 dimensões (Fig. 2.8): esta montagem é feita em zonas distintas organizadas em função das necessidades operacionais, e poderão existir as seguintes montagens: blocos planos; blocos curvos; e superestruturas (Em um navio a parte da estrutura acima do convés deste, torna-se tecnicamente, uma Superestrutura).

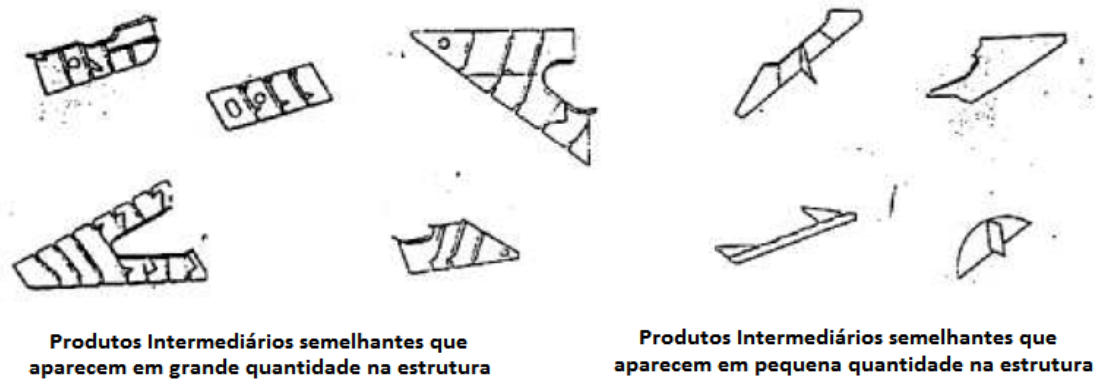


Figura 2.6 - Montagem dos sub-conjuntos
 Fonte: Brito; Gordo, 2006, p. 06.




Figura 2.7 - Montagem dos painéis
 Fonte: Brito; Gordo, 2006, p. 07.




Figura 2.8 - Montagem dos blocos (Castelo de Proa)

Fonte: Brito; Gordo, 2006, p. 07.

- 5º Nível - Montagem do casco: a montagem do casco no dique ou na carreira é o ultimo nível. Normalmente consideram-se as seguintes áreas, corpo de ré; praça de máquinas; corpo principal; corpo de vante; superestrutura. Na Fig. 2.9 segue um exemplo de fluxograma de material de um estaleiro, através dos diversos níveis de montagem.

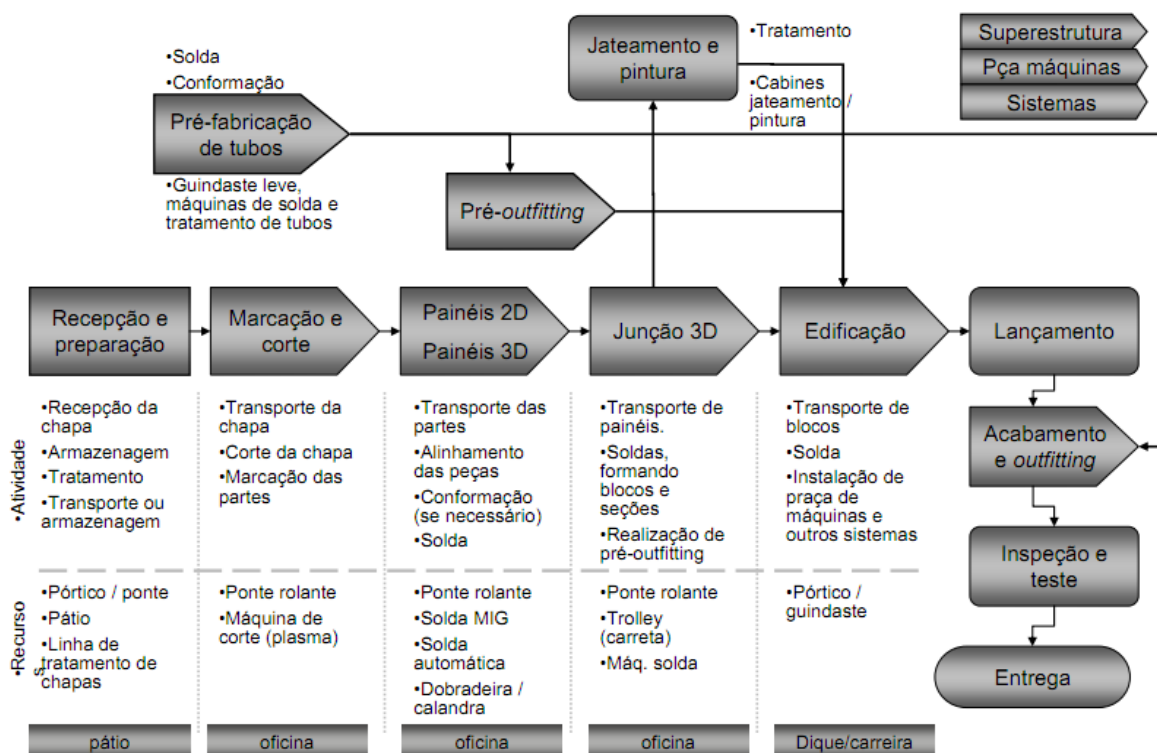


Figura 2.9 - Fluxograma do material no Estaleiro

Fonte: CEGN, 2010.

A estrutura do navio é repartida em seções/zonas e, por sua vez, em blocos. Tal divisão é feita de acordo com a capacidade de içamento do estaleiro, o qual determina o peso máximo dos blocos. É importante na definição de um bloco levar em consideração, as dimensões médias do bloco; peso máximo do bloco; limitações de içamento do bloco; bainhas (1. Lado maior de uma chapa retangular; 2. Emenda de duas chapas retangulares ao longo dos seus lados maiores) e topos das chapas do forro; acesso às zonas de ligação entre blocos; possibilidade de utilização de máquinas de soldar automáticas, tipo de estrutura (transversal ou longitudinal); direção das fiadas de chapa; bordas alinhadas ou desencontradas, dimensões das chapas, preparação de tanques e espaços adjacentes, apoios dos blocos; olhais de suspensão; material em excesso para a montagem e o número de berços (Brito e Gordo, 2006).

Finalizando, a montagem final do casco é realizada pela união dos diferentes anéis, que são a junção de um ou mais blocos, que constituem o navio.

2.1.2 Os Processos de *Outfitting*

O *outfitting* engloba todos os componentes não estruturais existentes no navio, sendo eles:

- Sistemas de propulsão e seus auxiliares;
- Sistemas de governo - leme e respectivas máquinas de acionamento;
- Sistemas de conversão de energia — elétrico, vapor, hidráulico e respectivos dispositivos de comando de controle e proteção;
- Sistemas de fluidos, compreendendo redes de encanamentos e respectivos acessórios, bombas, compressores, permutadores de calor, etc.;
- Sistemas de aquecimento, ventilação e ar condicionados e respectivos acessórios;
- Equipamento de áreas habitacionais (acomodações, alimentação, instalações, sanitárias, etc.);
- Equipamento de convés e de carga e
- Outros equipamentos específicos, relacionados com a finalidade do navio.

O termo *outfitting* ou acabamento refere-se ainda à fase de fabrico onde se processa a instalação do material acima referido. Nesta fase de fabrico interessa sobretudo a natureza do material e a sua localização física em detrimento da sua finalidade. Quem procede à instalação

dos diversos órgãos e do equipamento não está necessariamente inteirado das respectivas implicações funcionais, logo tem de haver criteriosas e detalhadas instruções de montagem, informação sobre os cuidados de manuseio e limpeza a observar; as atividades cruciais devem ser executadas, acompanhadas ou supervisionadas por pessoal especializado (Brito e Gordo, 2006).

2.2 A EVOLUÇÃO DOS PROCEDIMENTOS NA CONSTRUÇÃO NAVAL

A indústria da construção naval tem acompanhado o crescimento do setor de navegação na última década, através de avanços de métodos construtivos, materiais e projeto. A seguir enumeram-se os principais métodos de construção, sendo eles: construção por sistemas, por blocos, por zonas e construção integrada.

2.2.1 Construção por sistemas

A montagem dos elementos estruturais (painéis, reforços, vigas, etc.) realiza-se na *carreira* (*Berth, Inclined Berth, Slipway*, é um plano inclinado onde um navio é edificado ou montado durante a construção, ou ainda, onde é encalhado para sofrer revisão ou reparos. Podendo ser longitudinal ou lateral) de construção (Fig. 2.10), um a um. O *outfitting* realiza-se parcialmente na carreira, mas, sobretudo após o lançamento à água.



Figura 2.10 - Carreira de construção
Fonte: Clarkson Research, 2010.

2.2.2 Construção por blocos

Os blocos do casco (Fig. 2.11) são executados em oficina, sendo posteriormente levados para a carreira de construção; a maior parte dos trabalhos estruturais realiza-se na oficina. A adoção desse modelo, chamado de método de construção em blocos, evidenciou as vantagens da padronização, repetição e automação, das economias de escala e da eficiência na produção, induzindo menores custos e reduções nos cronogramas (Souza, 2009).

Esta evolução é fundamentalmente baseada na evolução tecnológica dos processos de soldagem e está associada a uma maior capacidade dos meios de elevação e movimentação do estaleiro. O *outfitting* realiza-se quando o casco estiver completo.

A quantidade de *outfitting* realizado na carreira de construção aumenta relativamente ao procedimento anterior (construção por sistemas), contudo continua a prevalecer o *outfitting* após o lançamento à água.



Figura 2.11 - Construção por blocos
Fonte: Clarkson Research, 2010.

2.2.3 Pré-*Outfitting* e *Outfitting* por zonas

Neste procedimento, aproveitando as facilidades de acesso ao interior dos blocos montados, introduzem-se nos blocos alguns elementos do *outfitting*. Os trabalhos de construção estrutural do casco e *outfitting* vão progredindo em paralelo, com a coordenação da Engenharia de Produção. Há uma redução do período de *outfitting* após o lançamento à água. A divisão do navio por zonas é mostrada abaixo (Fig. 2.12).




Figura 2.12- Divisão do navio por zonas
Fonte: Favarin, 2010.

2.2.4 Construção integrada

Nesta modalidade de produção, os trabalhos de construção estrutural, *outfitting* e pintura progridem em conjunto, segundo as possibilidades de realização local.

A técnica desenvolve-se baseada na divisão do navio em produtos intermediários (Fig. 2.13). Define-se como produto intermediário qualquer subdivisão física de um produto que objetiva um conjunto discreto de trabalho. Procura-se neste último modo de construção a padronização da construção modular. A evolução para este procedimento só é possível com o uso de sistemas CAD - Computer-Aided Design (Projeto Auxiliado por Computador)/CAM - Computer-Aided Manufacturing (Fabricação Auxiliada por Computador)/ CIM -Computer-Integrated Manufacturing (Fabricação Integrada por Computador) e com os recursos de gestão integrada de projeto e materiais MRP II (*Material Requirement Planning*)/ERP (Enterprise Resource Planning). O tempo de *outfitting* na carreira de construção e após o lançamento à água é reduzido, bem como o período total da construção.

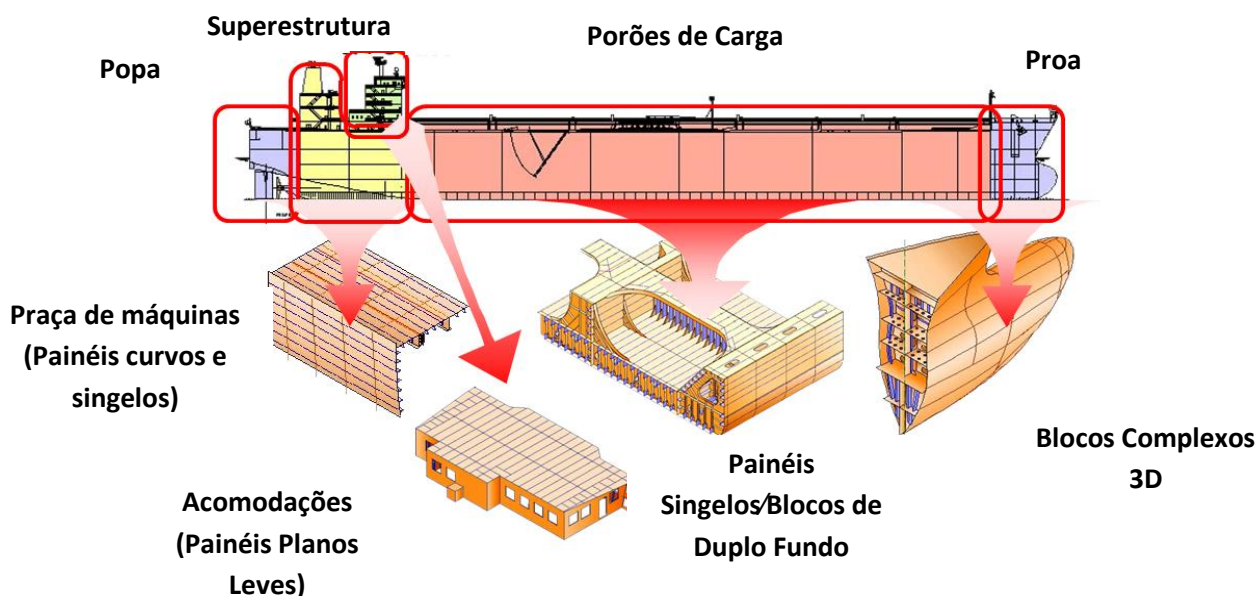


Figura 2.13 - Construção integrada
 Fonte: Pinto, 2010.

Salienta-se que na construção integrada deve-se aproveitar o momento mais oportuno para realizar cada trabalho, evitando-se esforços e posições inadequadas, manobras e meios auxiliares. Também, sempre que possível deve-se induzir o efeito da produção em série, procurando afinidades nas obras a realizar. Através da construção integrada também se obtêm melhoria da qualidade, associada à melhoria das condições de execução, já que o monitoramento das atividades é feito de forma mais precisa com o uso de programas de gestão globais de produção. Na Tabela 2.1, mostra-se um exemplo dos ganhos no avanço de uma construção, em percentual, nas diversas fases construtivas de um navio, na altura do lançamento à água usando o processo de construção tradicional (construção por blocos) e o processo de construção integrada.

Tabela 2.1- Avanço no lançamento a água

	Const. Tradicional (blocos)	Construção Integrada
Estrutura	90	99
Casa de Máquinas	30	92
Redes de encanamentos	30	93
Dutos	30	97
Habitabilidade	10	64
Cabos eléctricos	5	40
Avanço no lançamento à água	39%	75%

Fonte: Brito; Gordo, 2006, p. 11.

2.3 CONSIDERAÇÕES FINAIS

O volume e a variedade das atividades de produção associados à construção naval influenciam especialmente a determinação da forma como a produção vai obter seus objetivos de desempenho. Ao longo do tempo o segmento da construção naval foi se ajustando as necessidades de mercado e a inserção de novas tecnologias, partindo de um modelo de construção por sistemas chegando até a integração das diversas fases do processo produtivo. A decisão sobre qual método melhor se adéqua a necessidade produtiva da indústria naval, não obedece nenhum parâmetro fixo já que é possível ter-se vários modelos produtivos que vão desde o projeto inicial que possui elevado grau de complexidade e diferenciação, até os arranjos de produção onde é possível grande quantidade de produtos padronizados ou similares, que vão integrar os diversos produtos de toda cadeia produtiva.

Neste capítulo foram apresentadas as principais etapas de construção de um navio, bem como os principais processos utilizados ao longo do tempo na construção naval. Com a construção integrada busca-se reduzir o tempo médio do projeto, pela realização simultânea de um maior número de operações, conduzindo ao aumento do grau de paralelismo das atividades de desenvolvimento. Atividades que eram realizadas somente após o término e aprovação das atividades anteriores são antecipadas de forma que seu início não dependa dos demorados ciclos de aprovação (engenharia simultânea) e igualmente a redução de custo. O prazo de construção assim é reduzido, através da maior eficácia na coordenação entre tarefas.

A integração das diferentes etapas da produção com ênfase na definição de produtos intermediários permite um maior grau de padronização dos componentes desde os estágios iniciais. Desta forma integram-se as diversas fases do projeto, o planejamento da construção, e a engenharia. Os sistemas de informação tendem a uma comunhão plena das atividades de projeto, produção, administração e comercial.

No próximo capítulo serão apresentados os subsídios metodológicos e tecnológicos que poderão viabilizar a integração das etapas de produção. Conceitos e ferramentas associadas a Tecnologias de Grupo, tais como Estrutura Analítica de Produto, Manufatura Celular e Sistemas de TI serão descritos de forma a contextualizar a proposta apresentada.

3 IMPLEMENTANDO UMA PRODUÇÃO INTEGRADA

Este capítulo tem como objetivo apresentar uma visão geral sobre as metodologias e tecnologias capazes de dar suporte a Produção Integrada, descrita no capítulo anterior. De forma mais precisa serão apresentados os conceitos relativos a Tecnologias de Grupo para produção, dando-se ênfase ao importante papel do desenvolvimento tecnológico e o impacto deste nos níveis de produtividade.

3.1 UTILIZANDO TECNOLOGIAS DE GRUPO

Em busca do aumento de eficiência, foi proposto um método de fabricação baseado no produto. Neste método, o estaleiro busca maior eficiência focando seus esforços nos processos de construção e nos produtos que o estaleiro pode fabricar eficientemente. No estudo feito pela universidade do Michigan em 1997 (UMTRI 97- 29) este método recebe a denominação de Tecnologia de Grupo (TG). A TG é baseada na aplicação de grupos tecnológicos que se refletem na manufatura pela decomposição dos sistemas produtivos em um conjunto de centros de trabalho ou células. Cada centro de trabalho é uma coleção de equipamentos e processos dedicados para o atendimento dos requisitos de processamento de uma família de peças (peças com requisitos de fabricação similares) (Storch *et al.*, 1995).

O paradigma de Tecnologia de Grupo se beneficia das similaridades de projeto e fabricação das peças a serem fabricadas. Desenvolvido na Europa no início do século XX, com a classificação e registro das peças, foi melhorado nos anos 50 e o termo TG foi utilizado pela 1ª vez em 1959. Somente com os computadores nos anos 70 o conceito foi difundido.

A abordagem de TG determina que os navios possam ser progressivamente subdivididos em produtos intermediários ou intercalares, que podem ser classificados em grupos ou “famílias”, permitindo a uniformização do processo de produção empregado.

O agrupamento de peças diferentes em uma família vem ao encontro da abordagem de decomposição do trabalho orientada a produtos da construção naval, onde existe uma grande similaridade de componentes intermediários, mesmo para navios de tipo e porte diferentes, nos diversos estágios de agregação para montagem do produto final (Fig. 3.1).




Figura 3.1 - Exemplo de Produto Final, com a montagem dos diversos blocos e sub-blocos
Fonte: Bole, 2006.

Segundo Santos *et al.* (2004), TG é um método que tenta analisar e arranjar o espectro de peças e os processos de fabricação (planos de processo, produtos, montagens, ferramentas, etc.) aplicáveis de acordo com as similaridades de desenho e usinagem, de modo que uma base de grupo e famílias possa ser estabelecida para a racionalização dos processos de produção (projeto, manufatura, compras, planejamento e controle da produção, etc.) na área de produção em lotes médios e pequenos.

Segundo Hyer e Wemmerlöv (1984, p. 142) o aproveitamento dessas similaridades ocorre de três maneiras:

- 1 Executando atividades similares em conjunto, evitando assim perda de tempo com as alterações necessárias para mudar de uma atividade para outra não relacionada (ex.: a fabricação em seqüência de duas peças com características similares reduz tempo de setup entre as operações);
- 2 Padronizando as atividades similares e relacionadas, focando assim apenas nas diferenças necessárias e impedindo duplicação de esforços (ex.: redução da variedade de parafusos utilizados);
- 3 Armazenando e recuperando informações de forma eficiente, principalmente as relacionadas com um problema repetido, reduzindo assim o tempo de procura por informações, bem como eliminando a necessidade de resolver novamente um problema já solucionado (ex.: utilizar em um novo produto, componentes de outro já existente)

Realizando tais atividades estar-se-á também reduzindo a proliferação desnecessária de novos itens (peças compradas e fabricadas, dispositivos de fixação, ferramentas, etc.). A Tecnologia de Grupo reúne os objetos com atributos similares em famílias, identificadas para

um propósito bem definido. Os objetos em uma família requerem métodos similares de tratamento e manuseio, e os ganhos de eficiência são atingidos pelo processamento conjunto dessas peças. O projeto e a manufatura são os principais campos de aplicação da TG.

Sendo assim, a Construção naval moderna está baseada em análise de processos e tecnologia de grupo, que depende da identificação do produto intermediário parcial, aqui denominado Estrutura Analítica de Produto e seus atributos (Souza, 2009), bem como da manufatura em células, a seguir descritas.

3.2 ESTRUTURA ANALÍTICA DO PRODUTO - PWBS

Em Gestão de Projetos, uma Estrutura Analítica de Trabalho, do Inglês, *Work breakdown structure* (WBS) é uma ferramenta de decomposição do trabalho do projeto em partes manejáveis, sendo a ferramenta primária para descrever o escopo do projeto (trabalho). O objetivo de uma WBS é identificar elementos terminais (os produtos, serviços e resultados a serem feitos em um projeto). Assim, a WBS serve como base para a maior parte do planejamento.

O PMBOOK (2004) define o WBS como uma decomposição hierárquica orientada à entrega do trabalho a ser executado pela equipe do projeto, para atingir os objetivos do projeto e criar as entregas necessárias. A WBS organiza e define o escopo total do projeto, subdivide o trabalho do projeto em partes menores e mais facilmente gerenciáveis, em que cada nível descendente da WBS representa uma definição cada vez mais detalhada do trabalho a ser realizado. Tendo sido um caso de sucesso na indústria aeronáutica (Beeby; Thompson, 1986, Beeby, 2002), a aplicação e customização do WBS na indústria naval vem sendo estudada de forma a permitir o agendamento, a estimação de custos, o monitoramento e o controle do trabalho planejado.

Uma evolução do WBS foi implementada no final da década de 70 no estaleiro Ishikawajima-Harima (IHI) no Japão (Ferraz, 2002). Nela o conceito de WBS foi aplicado ao desenvolvimento de produtos intermediários ao longo da fabricação de navios resultando na Estrutura Analítica de Produto (PWBS). Em tal proposta os itens a serem desenvolvidos foram codificados agrupados em famílias de produtos. Sendo o modelo de codificação seguido posteriormente pelo *Naval Ship Engineering Center* em Washington (1977) que estendeu estes estudos para o desenvolvimento de uma codificação ‘ótima’.

Em PWBS define-se em detalhe o trabalho que se espera que cada organização individual realize, compondo-se em uma estrutura orientada ao produto (em oposição à

funcional), ou seja, ao item que está sendo produzido ou desenvolvido ou ao serviço que está sendo prestado (Chirillo; Chirillo, 1985). O PWBS define o(s) produto(s) a ser desenvolvido e/ou produzido e relaciona os elementos do trabalho a ser realizado para cada outro produto e para o produto final (Chase; Aquilano, 1995).

O PWBS se contrapõe à construção funcional, onde o navio era preenchido no dique com enfoque nos sistemas a serem desenvolvidos (elétrico, hidráulico, etc.). No PWBS, partes e subconjuntos (*sub-assemblies*) são agrupados de acordo com características de projeto e produção. Pelo código atribuído a cada parte, deve-se poder identificar a zona ou área do navio, o tipo de peça e o estágio em que se encontra na escala produtiva.

O PWBS divide o trabalho inicialmente em 3 partes: construção do casco, *outfitting* e pintura, levando em consideração às particularidades de cada trabalho. Em seguida, consideram-se os recursos necessários por cada parte, como material (chapas, cabos, etc.), mão-de-obra (soldador, transportador) e diques, equipamentos, ferramentas, além do momento de uso.

O processo de produção para cada grupo de PWBS pode ser racionalizado para eliminar tarefas desnecessárias e utilizar de forma eficiente os recursos disponíveis, resultando em uma célula de trabalho por produto ou por processo.

3.3 MANUFATURA CELULAR

Com base na análise de informações descritas, verifica-se as peculiaridades da indústria da construção naval que produz bens de alto valor e complexidade de processos. É importante definir processos de produção que Produto sugere um bem tangível de demanda associadas à capacidade da planta disponibilizada e a complexidade do produto final (Produto sugere um bem tangível), implicando em uma forma diferente de organização das operações para atender diferentes graus de volume-variedade. Esta escolha terá conseqüências especialmente em termos de custo e flexibilidade.

Considerando o volume e a variedade dos produtos envolvidos na construção naval, o layout típico para estaleiros é o arranjo físico posicional, também conhecido como *layout* de posição fixa. Esse arranjo caracteriza-se pelo fluxo de equipamentos, maquinários, instalações e pessoas enquanto o produto permanece estacionado. Embora essa configuração seja uma realidade globalmente observada nos estaleiros, o cotidiano de construção e reparo tem mostrado uma tendência a arranjos celulares por processo e por produtos, de forma a atender

os novos modelos de produção que utilizando TG implementam frameworks baseados em PWBS.

3.3.1 Atividades de produção e layout de fábrica

A manufatura discreta de peças pode ser classificada segundo a atividade de produção (quantidade de produto fabricado) e em função do *layout* da fábrica (Slack, 1997). Considerando a atividade de produção em ordem de volume crescente e variedade decrescente, existem três tipos principais de sistemas de produção (Fig. 3.2):

- pequena produção (*Job shop*): baixo volume de produção e grande variação de peças fabricadas, por exemplo, usualmente o tamanho do lote de manufatura é pequeno (uma peça),
- linha de produção (*Mass*): altas taxas de produção, com equipamentos que são completamente dedicados à um produto em particular; a fábrica normalmente é projetada com o propósito exclusivo de fabricar um produto específico,
- produção em lotes (*Batch*): fabricação de lotes de tamanho médio de forma contínua ou intercalada com o propósito de satisfazer a demanda do usuário por um determinado produto.

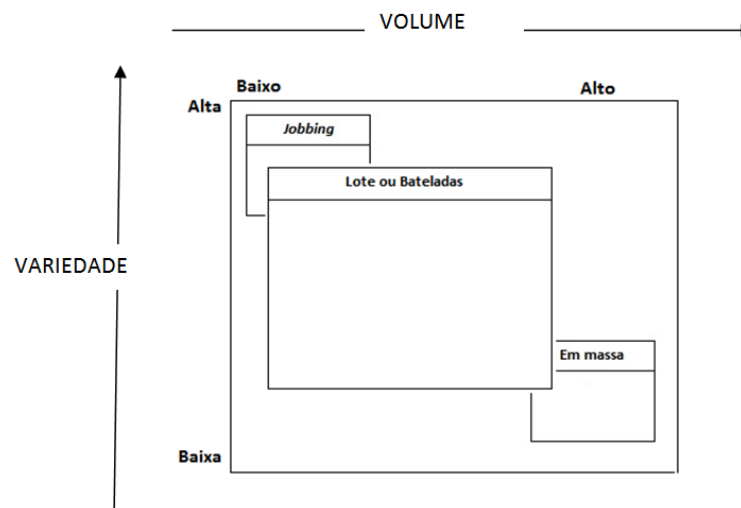


Figura 3.2 - Tipos de processos em operações de manufatura
Fonte: Slack *et al*, 1997.

Na prática são encontrados, além de exemplos que representam fielmente as abordagens apresentadas, combinações de processos que exploram as características de cada modelo de acordo com o perfil da demanda e do produto encontrados.

Na década de 60 a 70 na Indústria Naval, o tipo *job shop* era bastante usual, as atividades envolvidas na execução do produto eram mal definidas e incertas, às vezes modificando-se durante o próprio processo de produção e as atividades de acabamento do navio eram feitas quase todas a bordo. Atualmente há uma sobreposição entre tipos de processos que podem ser utilizados, e os processos oscilam entre *jobbing*, *Batch* e em linha. A evolução desses modelos passou pelo reconhecimento das vantagens de se produzir grandes “pedaços” dos navios em áreas cobertas e transportá-los para a montagem em um dique seco ou carreira.

O conceito do tipo do processo é, muitas vezes, confundido com o arranjo físico. Arranjo físico é um tipo mais restrito, mas é a manifestação física de um tipo de processo. Depois que o tipo de processo foi selecionado, o tipo básico de arranjo físico deve ser definido, que é a forma geral do arranjo de recursos produtivos da operação.

Na prática a maioria dos arranjos físicos, de layout de fábrica associados aos sistemas de produção de peças discretas, deriva de apenas três tipos básicos de arranjo físico:

- posição fixa (*fixed-position layout*); em função do tamanho e do peso do produto, o mesmo permanece em um local e os equipamentos usados na sua fabricação são trazidos até ele. Usualmente este tipo de *layout* é associado a sistemas de produção do tipo *Job shop*.
- orientado a processo (*process layout*): as máquinas de produção são arranjadas em grupos de acordo com o tipo geral de processo de manufatura. Este tipo de *layout* é comum em sistemas de produção do tipo *Job shop* e *Batch*; e
- orientado ao fluxo do produto (*product-flow layout*): quando a fábrica é especializada para a produção de um, ou uma classe de produtos em grande escala, os equipamentos são arranjados da forma mais eficiente para a produção do mesmo. Este tipo de *layout* normalmente é associado a sistemas de produção do tipo *Mass production*.

A manufatura baseada em células (manufatura celular), representa uma tentativa de combinar a eficiência do *layout* orientado a fluxo (*product-flow layout*) com a flexibilidade do *layout* orientado a processo (*process layout*) em sistemas de produção em *Batch*. Na manufatura celular, o sistema de manufatura é decomposto em um conjunto de centros de

trabalho ou células. Cada centro de trabalho é uma coleção de equipamentos e processos dedicados para o atendimento dos requisitos de processamento de uma família de peças (peças com requisitos de fabricação similares). Abaixo é mostrado a estratégia de manufatura tradicional e a celular de uma forma bem simplificada (Fig. 3.3). Como resultado da utilização da organização celular, os tempos de transporte de material podem ser significativamente reduzidos. Na busca de flexibilidade e automação, a manufatura celular utiliza equipamentos tais como robôs, máquinas-ferramenta numericamente controladas, sistemas automáticos de inspeção e sistemas de transporte de material.

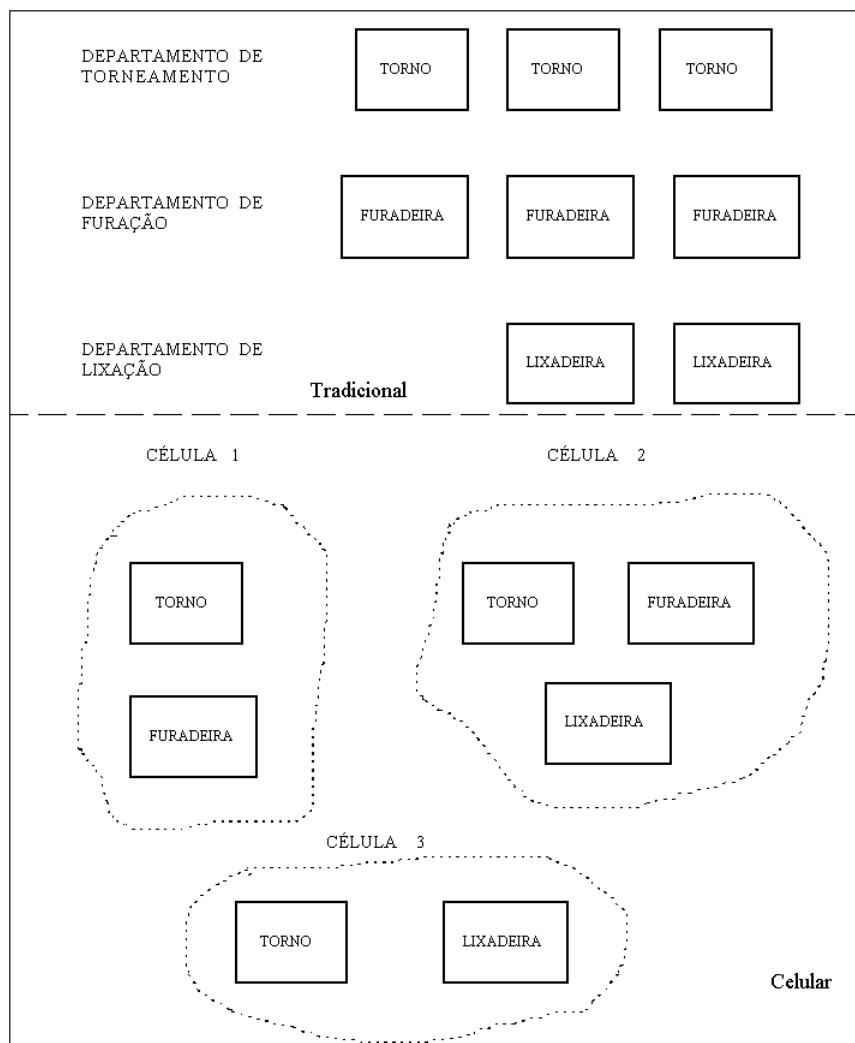


Figura 3.3 - Estratégias de manufatura - Tradicional e Celular
 Fonte: Adaptação de Vitale, 1994.

A funcionalidade e definição exatas de uma célula de trabalho vêm sofrendo evoluções, mas a idéia fundamental de célula é a de controlar e coordenar um conjunto relativamente pequeno de dispositivos em um ambiente de produção. Os dispositivos são

agrupados de forma que possam, sob o controle de um computador, configurar-se para a produção de diferentes peças. A seguir é mostrado um exemplo de um sistema de manufatura em nível de chão-de-fábrica utilizando o conceito de células ou centros de trabalho (Fig. 3.4).




Figura 3.4 - Exemplo de um sistema de manufatura celular/chão de fábrica

Fonte: Thompson, 2009.

Frente ao novo paradigma de Tecnologias de Grupo, onde o processo fabril é organizado em estruturas PWBS executados através de um sistema de produção celular, surgem mudanças em diversos setores envolvidos no processo produtivo, tais como: nova estrutura organizacional, novo planejamento e controle da produção e nova política de estoque. A TG é o elemento chave para a manufatura em célula e representa um diferencial, se comparada às estruturas de manufatura orientadas ao processo.

3.4 CLASSIFICAÇÃO E CODIFICAÇÃO DE PEÇAS

Tatikonda e Wemmerlöv (1992, p. 2099) definem quatro tipos de atividades necessárias na implementação da TG:

- 1 Determinação dos atributos críticos dos objetos que representarão o critério para esse pertencer ou não a uma família;
- 2 Alocação dos objetos para as famílias estabelecidas;
- 3 Recuperação dos membros da família e as informações relativas;
- 4 Representação da família e suas classes por atributos sob a forma de códigos ou numa base de dados relacional.

Na implantação da filosofia da Tecnologia de Grupo, as peças são identificadas e agrupadas em famílias através de sistemas de classificação e codificação. Segundo Tatikonda e Wemmerlöv (1992), os Sistemas de Classificação podem assistir a Tecnologia de Grupo nas atividades de implementação fornecendo uma estrutura para classificar os objetos em famílias baseada em atributos selecionados para esses objetos.

Classificação: Os produtos são classificados conforme similaridades no que tange aspectos de projeto e fabricação. Os atributos de projeto consistem em similaridades geométricas, como:

- 1 Formas e dimensões externas e internas;
- 2 Relações de dimensões (comprimento/largura, comprimento/diâmetro);
- 3 Tolerâncias dimensionais;
- 4 Acabamento superficial;
- 5 Função da peça.

Os atributos de Fabricação consistem nas similaridades no método e seqüência de fabricação da peça. Como o processo de fabricação depende dos atributos de projeto, conseqüentemente os atributos são inter-relacionados.

- 1 Processo primário utilizado;
- 2 Processos secundários e finais utilizados;
- 3 Tolerâncias dimensionais e acabamento superficial;
- 4 Seqüência de operações;
- 5 As ferramentas, matrizes, fixação e máquinas utilizadas;
- 6 Quantidade de peças e taxa de produção.

Tradicionalmente a classificação era realizada através de observações simples, estudo criterioso dos projetos e da fabricação ou ainda pela análise dos processos já utilizados (*production flow analysis* - PFA). Atualmente buscam-se desenvolver técnicas automáticas de classificação.

Codificação: O sistema de codificação das peças pode ser específico para o estaleiro ou padronizado para uma maior aceitação comercial. Em função da grande variedade de produtos e empresas não existe um sistema universal, mas é importante que o sistema adotado

seja compatível com outros sistemas da empresa como CAPP (*Computer Aided Process Planning*), as funções do planejamento do processo são selecionar e definir os processos a serem executados em uma peça de maneira econômica, de acordo com as especificações do projeto, verificando as condições de venda (como volume e prazos). O documento resultante do planejamento do processo, conhecido como plano de processo é a base para se realizar o planejamento da produção e serve como referência à produção propriamente dita. Por isso é que se considera o planejamento do processo como o elo entre projeto e o planejamento da produção e também o chão-de-fábrica e de máquinas CNC (Controle Numérico Computadorizado) que são controladores numéricos que permitem o controle de máquinas e são utilizados principalmente em tornos e centros de usinagem. Permitem o controle simultâneo de vários eixos, através de uma lista de movimentos escritos num código específico (código G). O "Comando" funciona como um sistema operacional dos computadores desktops, gerenciando uma máquina a CNC, e possibilitando a comunicação com o operador/programador. Suprindo a necessidade da produção de peças de alta precisão, e larga escala de produção. Com isso atinge-se o objetivo de peças complexas e de grande precisão, especialmente quando associado a programas de CAD/CAM.

3.5 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os principais conceitos relativos a Tecnologias de Grupo, tendo como foco a sua aplicação na construção naval. Com o uso de TG os ganhos de eficiência na manufatura vêm da redução dos tempos de *setup*, da facilidade de programação em seqüência de peças de uma mesma família, da melhoria no controle do processo, planos de processo e instruções padronizadas, possibilidade de formação de células de manufatura e aumento da qualidade.

No que tange as etapas de projeto o uso de TG pode aportar a facilidade de recuperação de informações, a padronização de itens e não duplicação destes. Na fabricação, custos podem ser estimados mais facilmente, planos de processo podem ser padronizados e programados de modo eficiente, ordens de produção podem ser agrupadas, tempos de preparação podem ser reduzidos, ferramentas, dispositivos de fixação e máquinas podem ser compartilhados pela família de peças.

Com o uso de sistemas CAD/CAM, CIM associados a layouts em célula percebe-se o aumento da produtividade e diminuição de custos na fabricação de lotes pequenos. Menciona-se como exemplo, a redução de custo de transporte, visto que a proximidade das máquinas

reduz o caminho dos materiais e a redução do custo do material em processo e estoque. Nesta a redução do ciclo de fabricação, melhora a resposta a demanda e a diminuição dos estoques intermediários combinados ao estoque final.

O uso de estruturas PWBS padronizadas na indústria da construção naval brasileira representaria ganhos para o desenvolvimento da estratégia de construção (Clark e Lamb, 1996) permitindo um acompanhamento mais claro pelos agentes externos aos estaleiros (*stakeholders*). Para tal, a definição de grupos de produtos os quais comporão as famílias a serem processadas torna-se um gargalo para o sistema. Técnicas automáticas para agrupamento e classificação estão sendo utilizadas com o intuito de:

- a partir das características próprias de cada estaleiro e de seu histórico de encomendas, fornecerem os principais grupos de produtos intermediários constituídos por elementos com características de projeto e fabricação comuns
- classificarem cada produto a ser produzido em uma nova encomenda em um dos possíveis grupos definidos para aquele estaleiro.

A proposta deste trabalho prevê o uso de ferramentas de inteligência artificial, apresentadas no próximo capítulo, para agrupamento e classificação de famílias de produtos intermediários.

4 TÉCNICAS INTELIGENTES PARA AGRUPAMENTO E CLASSIFICAÇÃO DE DADOS

Inteligência Artificial (IA) pode ser definida como um conjunto de modelos, algoritmos, técnicas, ferramentas e aplicações, em um sistema computadorizado, que emula algumas das habilidades cognitivas do homem (Allard; Fuchs, 1993). A IA abrange o conhecimento de diversas ciências, tais como, Ciência da Computação, Linguística, Matemática, Neurofisiologia, Psicologia, que conjuntamente, objetivam o desenvolvimento de computadores e programas capazes de imitar e/ou entender aspectos do pensamento humano. Diferentes técnicas atualmente utilizadas em computação, tais como a alocação dinâmica de memória e o paradigma da programação orientada a objetos, tiveram suas origens no campo da IA.

A busca por modelos que representassem comportamento inteligente conduziu ao desenvolvimento de sistemas biologicamente inspirados. Tal enfoque levou muitos pesquisadores como Marvin Minsky, Seymour Papert e John Von Neumann, a estudarem novas formas de processamento de informações baseadas nos estudos neurofisiológicos do cérebro. Tais pesquisas baseiam-se na reprodução de neurônios como elementos básicos do processamento de novas arquiteturas de máquinas inteligentes, ao invés de usar portas lógicas, bits e bytes controlados por uma Unidade Central. Esperava-se que a partir de elementos de processamento simples capazes de operar em paralelo, (baseados numa rede de neurônios ligados por um grande número de conexões entre eles), se pudesse obter como resultado um “comportamento inteligente”. Este ramo da IA foi denominado de *Inteligência Artificial Conexionista*, tendo como principal contribuição as *Redes Neurais Artificiais* (RNA). A IA conexionista de certa forma se opõe a IA clássica e baseada em processamento simbólico. As RNA têm sido largamente utilizadas na solução de problemas complexos, onde os algoritmos e técnicas tradicionais são inadequados (Osório; Bittencourt, 2000).

4.1 REDES NEURAI ARTIFICIAIS

As Redes Neurais Artificiais são modelos matemático-computacionais inspirados no funcionamento das células neuronais. Possuem processamento altamente paralelo, executado

por unidades denominadas neurônios, "que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso", (Aleksander; Morton, 2010). As RNA's apresentam as seguintes propriedades neurobiológicas Trippi e Turban (1993, p.02):

1. O conhecimento é adquirido pela rede, a partir de seu ambiente, através de um processo de aprendizagem;
2. Forças de conexões entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

As RNAs são processadores, massivamente paralelos e distribuídos, que têm uma propensão natural para armazenar o conhecimento proveniente da experiência e torná-lo útil (Haykin, 1998). Organizadas através de camadas de neurônios, as RNA propagam através de suas conexões sinápticas os sinais de entrada a ela apresentados. Diferentes conexões têm seus pesos adaptados de forma a aprender determinado comportamento de propagação relacionando de forma diferente a entrada apresentada a saída final do sinal propagado. Neste contexto, aprender significa atribuir pesos que conduzam a determinados mapeamento entrada-saída.

O aprendizado é iterativo, sendo apresentada a rede, de forma exaustiva, o conjunto de padrões de entrada a ser aprendido. Assim, a rede é treinada e os pesos são ajustados e definidos. Com isto, diz-se que a RNA aprendeu a reconhecer de modo generalizado um conjunto para o qual é previamente treinada (Haykin, 1998).

Basicamente quanto ao modelo de aprendizado, têm-se duas grandes categorias de RNAs: redes supervisionadas e não supervisionadas. Na aprendizagem supervisionada ou aprendizagem associativa, a rede necessita que os dados para treinamento sejam compostos por pares de entrada-saída. O vetor de saída desejado do conjunto de treinamento atua como um professor para a aprendizagem da rede. No processo de treinamento, os sinais de erro são calculados a partir da diferença entre a saída desejada e a saída real do sistema. Através do processo iterativo de treinamento os pesos da rede são ajustados pelo sinal de erro, de forma que a saída da rede tente alcançar o resultado desejado o mais próximo possível. O processo de aprendizado continua até que o sinal de erro chegue próximo de zero ou abaixo de um valor pré-definido. A soma de erros das amostras durante todo o treinamento pode ser considerada como uma espécie de medida de desempenho da rede, que é uma função dos parâmetros livres do sistema (Chow; Cho, 1997), (Kröse; Smagt, 1995).

Na aprendizagem não-supervisionada ou auto-organização, a rede não conta com a presença de um professor durante o processo de treinamento. A aprendizagem é realizada a partir de um comportamento de auto-organização. No decorrer do treinamento nenhum fator

externo é utilizado para interferir no ajuste dos pesos dos neurônios, uma vez que as saídas corretas são desconhecidas. Neste paradigma, o sistema deve desenvolver a sua própria representação dos estímulos de entrada.

4.2 APLICAÇÕES DAS REDES NEURAIIS ARTIFICIAIS

A capacidade em mapear entradas apresentadas em diferentes saídas permite o uso de RNA para a resolução de diversos tipos de problemas associados a necessidade de agrupamento e classificação de dados, tais como associação, filtragem, categorização, previsão, compressão e mineração de sinais, dentre outros (Tafner; Xerez; Rodrigues Filho, 1996).

4.2.1 Agrupamento (*Clustering*)

Denomina-se como algoritmos para agrupamento o grupo de técnicas multivariadas cuja finalidade primária é agregar elementos com base em suas características. Tal análise classifica um elemento de forma que cada elemento do grupo é muito semelhante aos demais considerando algum critério de seleção pré-determinado. Os agrupamentos resultantes devem então exibir elevada homogeneidade interna (*within-cluster*) e elevada heterogeneidade externa (*between-cluster*) (Hair Jr *et al.*, 2005).

Em relação a critérios de similaridade entre elementos, estas podem ser estabelecidas de várias maneiras, sendo que três métodos dominam as aplicações de análise de agrupamentos: medidas correlacionais, medidas de distância e medidas de associação. As duas primeiras requerem dados métricos, ao passo que medidas de associação são para dados não-métricos. Na análise de agrupamentos as medidas de similaridade baseadas em métricas de distância, as quais representam a similaridade como às proximidades entre observações ao longo das variáveis na variável estatística de agrupamento são o método mais frequentemente utilizado. Outro fator a ser considerado refere-se à necessidade de padronização dos dados. A maioria das métricas de distância é bastante sensível a diferentes escalas ou magnitudes entre variáveis, logo se deve estar ciente do peso implícito de variáveis com base em sua dispersão relativa, o que ocorre com as medidas de distância (Hair Jr *et al.*, 2005). Pontos anômalos – *outliers*, também devem ser tratados de forma a não distorcerem a verdadeira estrutura do conjunto, tornando os grupos derivados não representativos da verdadeira estrutura da população (Brausntein, 2010).

4.2.2 Reconhecimento de padrões

O reconhecimento de padrões utilizando RNs pode ser feito por categorização (*Clustering*), classificação, reconhecimento, otimização, aproximação de funções, estimativa e Previsão. A área de reconhecimento de padrões trata da descoberta automática de regularidades nos dados através da utilização de algoritmos computacionais e no uso dessas regularidades para classificar os dados em diferentes classes ou categorias. Dependendo da aplicação, estes dados podem ser imagens, sinais de onda ou qualquer outro tipo de medida que precisam ser classificados. O reconhecimento de padrões é parte integrante na maioria dos sistemas de inteligência de máquina construída para a tomada de decisões (Bishop, 2006); (Theodoridis; Koutroumbas, 2003).

O reconhecimento de padrões ocorre através da separação dos dados de entrada em grupos ou classes. A maioria das aplicações de RNAs são de reconhecimento de padrões, como reconhecimento da face humana, reconhecimento de caracteres manuscritos, reconhecimento de voz e locutor, identificação de impressões digitais, previsão de compra ou venda na Bolsa de Valores, dentre outros.

Dado a característica numérica da modelagem neural, costumam-se representar os padrões ou objetos abstratos como pontos no espaço de características, conforme (Fig. 4.1):




Figura 4.1 - Pontos no espaço de características
Fonte: Theodoridis; Koutroumbas, 2003.

Para obter soluções para os problemas de classificação, as RNs permitem classificar o vetor de características em uma das classes já conhecidas, normalmente com aprendizado supervisionado.

4.3 ANÁLISE DE AGRUPAMENTOS: MAPAS AUTO-ORGANIZÁVEIS (SOM)

Dentre as arquiteturas e algoritmos neurais, destaca-se como algoritmo para agrupamentos os Mapas Auto-Organizáveis (*Self-organized Maps* – SOM).

O SOM é um método de mapeamento associado à redução dimensional, no sentido que representa um espaço de alta dimensão em um mapa discreto de baixa dimensão (Oja; Kaski; Kohonen, 2003), composto por grupos de neurônios que representam as categorias existentes no espaço de entrada apresentado a rede. Tal processo apresenta dois objetivos principais (1) reduzir a dimensionalidade de representação com a menor perda de informações e (2) distinguir grupos de padrões ambíguos com maior facilidade.

A grade de baixa dimensionalidade serve para capturar um espaço de alta dimensão. Neste mapa, as localizações espaciais (coordenadas) dos neurônios na grade são indicativas das características estatísticas intrínsecas presentes nos padrões de entrada. Dentre os modelos básicos de mapeamento de características podem ser citados o modelo proposto por Willshaw e Von der Malsburg (1976) e o modelo introduzido por Kohonen (1982).

4.3.1 Estrutura básica

O mapa auto-organizável é uma rede de duas camadas. A primeira camada é a camada de entrada. A segunda camada é a camada competitiva e é organizada normalmente como uma grade bi-dimensional. Todas as interconexões vão da primeira camada para a segunda. As duas camadas ficam inteiramente interconectadas, assim, cada padrão de entrada é conectado a todas as unidades da camada competitiva. Cada neurônio i é representado por um vetor de pesos sinápticos: $\mathbf{m}_i = m_{i1}, \dots, m_{iD}$ onde D é a dimensão dos dados de entrada (Fig. 4.2).




Figura 4.2 - Estrutura de um mapa auto-organizado
Fonte: Rego Jr, 2006.

SOM é definida por um conjunto de neurônios i , dispostos em um arranjo que define a vizinhança de cada neurônio. Na camada competitiva os neurônios conectam-se entre si, apresentando diferentes tipos de vizinhanças topológicas para cada neurônio. As possibilidades mais usadas são:




Figura 4.3 - Relação de vizinhança
Fonte: Vesanto *et al*, 2008.

Na Fig. 4.3 acima se vê no arranjo à esquerda uma vizinhança retangular, enquanto no arranjo à direita tem-se uma vizinhança hexagonal. Se os lados do mapa forem conectados, a forma do mapa transforma-se num cilindro ou num toróide. O formato cilíndrico e toroidal são pouco explorados. O formato padrão utilizado para visualização do mapa produzido é o plano retangular. Se o objetivo é obter uma visualização bidimensional fechada utiliza-se o formato cilíndrico ou se é desejada uma visualização tridimensional é sugerido o formato toroidal (Fig. 4.4).




Figura 4.4 - Formas diferentes de mapas: plano retangular à esquerda, cilindro no centro e toróide à direita
Fonte: Vesanto *et al*, 2008.

4.3.2 Funcionamento do Algoritmo SOM

Para o presente trabalho entende-se como uma base de dados, um conjunto de m vetores com D componentes cada. Normalmente, para uso de técnicas de análise de grupos de dados, a quantidade m de vetores da base de dados ou o número n de componentes é elevado.

Os mapas auto-organizáveis possuem os seguintes elementos:

1. Base de dados;
2. Número fixo de vetores modelo (neurônios);
3. Algoritmo de auto-organização; e
4. Elevado tempo de processamento.

Mapa: Os vetores modelos também conhecidos como pesos sinápticos, são simplesmente vetores com a mesma dimensão dos vetores que representam os dados de entrada. Tipicamente para os valores iniciais dos vetores modelos são estabelecidos valores aleatórios.

Dados de Entrada: A base de dados é composta pelos vetores de dados a serem analisados e que serão fornecidos ao algoritmo para o aprendizado não supervisionado e para a organização do mapa. A Normalização dos Dados e Parametrização do Mapa de acordo com Medeiros e Barreto (2008) é comum, antes de apresentar os dados de treinamento à rede, mudar a escala original dos componentes do vetor de entrada x , de modo que o comprimento de cada vetor de entrada seja constante (de preferência unitário). Para isto basta dividir cada elemento do vetor pelo seu comprimento, ou seja, dividi-los pelo módulo ou norma do vetor, conforme equação 4.1:

$$x'_j(t) = \frac{x_j(t)}{\|X(t)\|} \quad (4.1)$$

Onde a norma de um vetor qualquer é dada por,

$$X(t) = \sqrt{x_1^2(t) + x_2^2(t) + \dots + x_n^2(t)} \quad (4.2)$$

Outra forma de se proceder à normalização dos componentes do vetor de entrada x , segundo (Medeiros e Barreto, 2008), é dividir cada $x_j(t)$ pelo seu maior valor

$x_j^{\max} = \max_{\forall t} x_j(t)$, ou seja,

$$x'_j(t) = \frac{x_j(t)}{x_j^{\max}} \quad (4.3)$$

propiciando-se que $x'_j(t) \in [0,1]$

Algoritmo: O algoritmo de auto-organização define a forma com que o mapa irá responder à entrada de dados externos. Os vetores $m_i(t)$ são rearranjados de acordo com os dados $x(t)$ fornecidos conforme a expressão 4.4:

$$m_i(t+1) = m_i(t) + h(c(x), t) \cdot (x(t) - m_i(t)) \quad (4.4)$$

Na expressão 4.4 do reposicionamento dos vetores modelos, onde:

$m_i(t+1)$ representa o novo vetor modelo, já reposicionado de acordo com $x(t)$;

$m_i(t)$ é o vetor da iteração anterior; não reposicionado;

$h(c(x), t)$ é a função vizinhança e aprendizagem e define a taxa de aprendizagem do mapa, com valores variando de 0 a 1; e

$x(t)$ representa um dos vetores de entrada (padrão da base de dados de entrada).

O algoritmo de auto-organização do mapa opera basicamente em duas etapas:

1. **Competição** – Uma dada amostra de dados $x(t)$ é comparada a cada neurônio $m_i(t)$, esta comparação se dá através de alguma métrica, como por exemplo, através da distância Euclidiana entre os vetores ou através de alguma expressão que determine logicamente a similaridade espacial entre $x(t)$ e $m_i(t)$. A unidade no mapa mais similar, ou mais próxima, a $x(t)$ é chamada de unidade vencedora (Best Matching Unit - BMU).
2. **Cooperação** – nesta etapa, o neurônio vencedor aproxima-se do vetor de dados $x(t)$ conforme a expressão 4.4. Todos os neurônios vizinhos ao neurônio vencedor têm seus vetores ajustados para uma aproximação de $x(t)$ de acordo com a função de vizinhança $h(c(x), t)$ diminuindo à medida que a distância de cada neurônio ao

neurônio vencedor aumenta. Logo, os neurônios que estão mais próximos ao neurônio vencedor se ajustam mais rapidamente a $x(t)$ e os neurônios que estão mais distantes ao neurônio vencedor sofrem poucas modificações.




Figura 4.5 - Adaptação dos neurônios próximos ao neurônio vencedor
Fonte: Vesanto *et al*, 2008.

A Fig. 4.5 mostra o padrão de entrada em amarelo, o seu BMU, sua adaptação e da sua vizinhança (neurônios em preto e adaptados em cinza). Quanto mais próximo um neurônio encontra-se do BMU, ou seja, quanto menor à distância $\|R_c - R_i\|$, maior é a adaptação aplicada ao neurônio. O neurônio com maior adaptação é o BMU.

A função $h(c(x), t)$ varia de acordo com:

$c(x)$ – representa a coordenada do neurônio vencedor;

t – para cada instante t , tem-se um novo $x(t)$ e novas comparações são feitas entre $x(t)$ e os vetores modelos dos neurônios do mapa;

$\sigma(t)$ – representa a função que determina o raio da vizinhança, o valor decresce com o tempo;

$\omega(t)$ – é a taxa de aprendizagem que mostra a rapidez com o mapa se ajusta aos dados de entrada, o valor da taxa decresce com o tempo.

A função vizinhança pode ser expressa como uma função gaussiana, definida na expressão 4.5:

$$H(c(x), t) = \omega(t) * \exp(-\|R_c - R_i\| / 2\sigma(t) \wedge 2) \quad (4.5)$$

Na expressão 4.5 de função de vizinhança,

R_c – representa as coordenadas do neurônio vencedor; e

R_i – representam as coordenadas de um vetor vizinho $m_i(t)$.

Quatro versões possíveis são descritas para a função vizinhança: Bubble, Gaussian, Cutgauss, Epanechnikov.

Bubble: Esta versão define uma largura ou um raio do neurônio vencedor, e somente os neurônios que estão no alcance deste raio são ajustados ao padrão de entrada.

Gaussian: É a versão mais usada. Uma importante propriedade desta função é que um neurônio que se encontra mais próximo do padrão de entrada sofrerá mais ajuste do que um neurônio que esteja mais afastado.

Cutgauss: Esta é uma combinação das duas versões acima. Se a distância de um dado neurônio ao neurônio vencedor estiver dentro de um valor dado (raio), o neurônio será atualizado.

Epanechnikov: Uma propriedade dessa versão é que a taxa de aprendizagem diminui mais enquanto a distância de cada neurônio ao padrão de entrada aumenta.

4.3.3 Análise dos resultados do mapa

Terminada a fase de treinamento é preciso verificar a qualidade da aprendizagem da rede. Importantes propriedades de um mapa de características após a convergência do algoritmo *SOM* podem ser elencadas como (1) aproximação do espaço de entrada, (2) ordenação topológica, (3) casamento de densidade e (4) seleção de características (Haykin, 2001). Dentre estas propriedades, focaliza-se na análise das duas primeiras, tendo em vista a possibilidade de estas poderem ser mensuradas e, assim, permitirem a avaliação da qualidade do mapa.

A primeira propriedade reflete o objetivo básico do algoritmo *SOM*, ou seja, a partir de um conjunto grande de vetores do espaço de entrada, encontrar um conjunto menor de protótipos (vetores de pesos sinápticos), de modo que o mapa venha a fornecer uma boa aproximação do espaço de entrada. A base teórica desta idéia é fundamentada na teoria da quantização vetorial (Haykin, 2001). Segundo (Medeiros e Barreto, 2008), vetor protótipo é aquele que apresenta um valor típico ou central que melhor representa os dados de um determinado grupo.

A segunda propriedade é uma consequência direta da equação 4.5, a qual força o vetor de peso sináptico do neurônio vencedor a se mover em direção ao vetor de entrada e

provocando que a localização espacial de um neurônio na grade corresponda a um domínio particular ou a uma característica dos padrões de entrada (Haykin, 2001).

- **Erro de Quantização**

O *SOM* está relacionado com o método clássico de quantização vetorial (*Vector Quantization - VQ*). Quantização vetorial é a tarefa de formar grupos de vetores de entrada, a fim de comprimir a quantidade de dados sem a perda de informações importantes. Assim como no *VQ*, o *SOM* representa uma distribuição de vetores de entrada usando um conjunto finito de modelos e em ambos os métodos, a noção de erro pode ser obtida utilizando-se o erro de quantização (Kohonen *et al.*, 2010); (Fausett, 1994).

De acordo com (Wu e Takatsuka, 2011), a qualidade de um som é comumente avaliada pelo erro de quantização, o qual é dado por

$$\varepsilon_q = \frac{E}{N}, \quad (4.6)$$

sendo N o número de vetores de entrada e

$$E = \sum_{i=1}^N d_i(X_i, w_k) \quad (4.7)$$

onde d é a distância euclidiana entre um vetor x do espaço de entrada e o vetor de pesos do neurônio vencedor k para a respectiva entrada.

- **Erro Topográfico**

A medida da continuidade do mapeamento chamada erro topográfico ε_t é obtida considerando-se a adjacência dos campos receptivos e a proporção dos vetores de treinamento, os quais indicam uma descontinuidade local do mapeamento (Kiviluoto, 1996).

Pode-se analisar a seguinte situação: seja um vetor x do espaço de entrada, w_k o primeiro vetor de peso mais próximo de x e w_j o segundo. Se os neurônios correspondentes n_k e n_j (primeiro e segundo neurônios vencedores, respectivamente) são adjacentes, o mapeamento é localmente contínuo; se eles não são adjacentes significa que há uma descontinuidade local ou, em outras palavras, um erro topográfico local. O erro

topográfico ε_t para todo o mapeamento é, então, obtido pela soma dos erros topográficos locais para todos os N vetores da amostra de treinamento conforme segue (Kiviluoto, 1996).

$$\varepsilon_t = \frac{1}{N} \sum_{i=1}^N u(X_i), \text{ onde } u(X_i) = \begin{cases} 1, & \text{se } n_k \text{ e } n_j \text{ não são adjacentes} \\ 0, & \text{caso contrário} \end{cases} \quad 4.8$$

onde o fator $1/N$ fornece uma idéia de proporção da vizinhança local que é mapeada corretamente, sem descrever o tipo de mapeamento incorreto, uma vez que 2 vetores próximos no espaço de entrada podem ser mapeados por neurônios que distem de apenas uma unidade no espaço de saída ou que estejam em cantos opostos do mapa (Kiviluoto, 1996).

4.3.4 Visualização de dados com SOM

A ferramenta SOM apresenta grande potencial quando é usada na área de classificação de dados. Esta verificação geralmente é feita pela matriz-U tomando como base a forma em que os neurônios foram rearranjados.

O SOM comporta-se como uma grade contendo neurônios interconectados por conexões elásticas, responsáveis por dobrar, esticar ou comprimir o estado da grade, de forma a representar da melhor maneira possível o conjunto de dados de entrada. A idéia do algoritmo é realizar uma projeção dos dados de entrada na tentativa de preservar ao máximo a topologia original dos dados. Na Fig. 4.6 é mostrada a idéia deste comportamento, onde a imagem à esquerda mostra-se a inicialização dos vetores de pesos da grade de neurônios e na imagem à direita observa-se a grade de neurônios já adaptada ao conjunto de dados de entrada. Na figura à esquerda os pontos com as cores vermelho, verde e azul representam o conjunto de entrada para a grade de neurônios. A superfície gerada mostra a deformação que a grade original sofre na tentativa de representar o conjunto de entrada, onde os neurônios da grade se comprimem em regiões de alta densidade dos dados de entrada (pontos azuis) e se esticam em regiões de baixa densidade (pontos verdes).

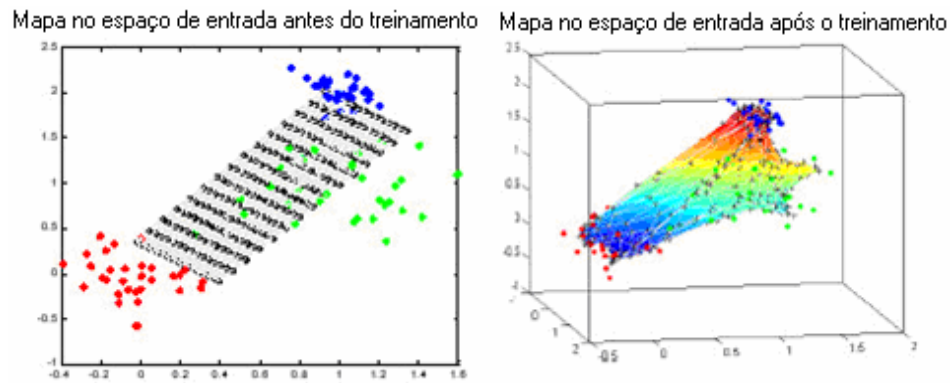


Figura 4.6 - Capacidade de representação dos dados
Fonte: Theodoridis; Koutroumbas, 2003.

4.4 MÉTODOS DE CLASSIFICAÇÃO USANDO REDES NEURAIIS SUPERVISIONADAS

Por volta da década de 50 começam a surgir modelos matemáticos de processamento de informações baseados no comportamento de neurônios biológicos. Tais modelos podem ser utilizados para mapeamento de um conjunto de entradas em uma saída desejada. O agrupamento de tais elementos conduz a redes de neurônios denominadas de Redes Neurais Supervisionadas. Estas são capazes de aprender a classificar padrões a partir de um conjunto de treinamento fornecido a priori que estabelecerá a relação entre entrada e grupo desejado a ser aprendida pelo sistema.

O comparativo entre um neurônio artificial, associado a RN supervisionadas, e um neurônio biológico resultou na descrição matemática do modelo simplificado denominado *perceptron* e explicitado na Fig. 4.7.

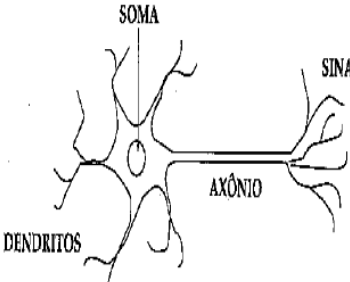
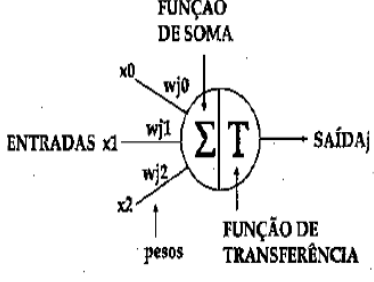
Parâmetros	Neurônio Biológico	Neurônio Artificial
Modelo		
Entrada	Dendritos	$x_1, x_2, x_3, \dots, x_n$
Saida	Axônio	y
Pesos	Comportamento das sinapses	$w_1, w_2, w_3, \dots, w_n$
Efeito da uma sinapse	Neurônio pós-sináptico	$s = \sum_{i=1}^n x_i \cdot w_i$

Figura 4.7 - Comparação entre o neurônio biológico e artificial
 Fonte: Pagliosa, 2003.

4.4.1 O neurônio *Perceptron*

O neurônio recebe um conjunto de sinais de entrada de outros neurônios. Então, é computada a média ponderada entre os sinais de entrada e os pesos das conexões (cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias). O resultado disto é aplicado à função de ativação, também chamada de função de transferência. O resultado final é chamado de ativação do neurônio.

Para apresentação completa do modelo matemático (Toda conceituação matemática exposta, pode ser encontrada nas referências bibliográfica (Russel; Norvig, 1995); (Velasco, 2010)) que envolve o *perceptron*, algumas convenções foram estabelecidas para maior clareza do conteúdo:

- As multiplicações são indicadas pelo ‘.’, ou seja, A vezes B é A.B
- Variáveis são escritas em maiúsculas, índices em minúsculas
- EXP(X) = Função que representa o logaritmo Neperiano – “e” elevado a potência “x”, ou simplesmente como costuma dizer “e na x” (logaritmo natural -> base ‘e’)

Lembrando que o *perceptron* é uma rede neural de uma camada só, na qual se pode treinar pesos vinculados a padrões de entrada que são fornecidos a rede, seguindo-se os passos abaixo, tem-se um modelo adequado para tal fim.

a) Ativação da Rede. Neste passo, ativam-se os neurônios, para calcular o valor obtido na saída da rede.

$$OUT_i = \text{Valor obtido na saída do neurônio 'i'} \quad (4.9)$$

Na equação 4.9, a variável ‘ OUT_i ’ é igual a ‘ $F(\text{SomaPond}_i)$ ’ e ‘ SomaPond_i ’, é igual a ‘ $\sum_k W_{ik} + BIAS_i \sum_k$ ’, onde $BIAS_j$ é um termo polarizador implementado através de um peso associado a uma entrada constante em 1.

Logo, a saída do perceptron OUT_i é descrita por:

$$OUT_i = F(\sum_k W_{ik} + BIAS_i) \quad (4.10)$$

Na equação 4.12, a função de transferência $F(X)$ pode ser implementada por:

$$F(X) = \frac{1}{1 + e^{-x}} \quad (4.11)$$

Então, teremos que

$$OUT_i = \frac{1}{1 + EXP(\sum W_{ik} . X_{ik} + BIAS_i)}$$

Na equação 4.10, o somatório (), varia ‘k’ de 0 até N, onde N é o número de conexões de entrada que possui o neurônio em questão (neurônio ‘i’), X_{jk} representa o sinal da entrada ‘k’ do neurônio em questão (neurônio i) e W_{ik} representa o peso do neurônio ‘i’ associado à entrada ‘k’(este mesmo neurônio possui N entradas, e obviamente N pesos).

Exemplo, o neurônio 3 tem quatro entradas e portanto sua ativação será igual a:

$$OUT_3 = F(W_{31} \times X_{31} + W_{32} \times X_{32} + W_{33} \times X_{33} + BIAS_3)$$

Nº da entrada ('k')

Nº do neurônio ('i')

b) Aprendizado – Cálculo do erro e correção dos pesos

No caso de uma rede de uma só camada, o erro é aplicado diretamente sobre os neurônios da última e única camada sem precisar retro-propagar para as camadas superiores.

$$ERRO_i = F'(SomaPondi_i) \times ERRO_{ESTIMADO_i} \quad (4.12)$$

Na equação 4.14, o 'ERRO_{ESTIMADO_i}' é igual a 'SAIDA_{DESEJADA_i}' subtraída da 'SAIDA_{OBTIDA_i}'.

Desta forma:

$$ERRO_{ESTIMADO_i} = SAIDA_{DESEJADA_i} - OUT_i \quad (4.13)$$

Na equação 4.13, a 'SAIDA_{OBTIDA_i}' é na realidade o valor OUT_i . Assim:

$$ERRO_i = F'(SomaPondi_i) \times SAIDA_{DESEJADA_i} - SAIDA_{OBTIDA_i} \quad (4.14)$$

Na equação 4.14, a variável $F'(X)$ é igual à derivada da função $F(X)$, ou seja, derivada da função sigmóide:

$$\hat{F}'(X) = \frac{1}{1 + \exp(-X)} \quad (\text{Sigmóide}).$$

Ao derivá-la, obtêm-se $F'X = F(X)(1 - F(X))$ (**derivada da sigmóide**), resultando em:

$$F(X) = \frac{1}{1 + \exp(-X)} \cdot \left(1 - \frac{1}{1 + \exp(-X)}\right) \quad (4.15)$$

Na equação 4.15, X é o valor que é fornecido para a função. Neste caso, X será a soma ponderada:

$$'SomaPondi_i = \sum W_{ik} \cdot X_{ik} + BIAS'_i$$

Tem-se, portanto os seguintes elementos:

$ERRO_i$ = O erro obtido para a saída do neurônio 'i'

$ERRO_{ESTIMADO_i}$ = O erro estimado, ou seja, a diferença da resposta desejada e a resposta que realmente foi obtida na saída do neurônio 'i' (uma rede pode ter vários neurônios na camada de saída).

$SAIDA_{DESEJADA_i}$ = A saída que queríamos obter no neurônio 'i' (esta informação esta presente no conjunto de treinamento).

$SAIDA_{OBTIDA_i}$ = A saída que o neurônio ‘i’ obteve, ou seja o valor de ativação deste que foi calculado no passo 1 de propagação *forward* (é o valor de OUT_i).

- a) De posse do erro ‘ $ERRO_i$ ’ do neurônio ‘i’ pode-se ajustar seus pesos usando a seguinte fórmula:

$$W_{ik}(t+1) = W_{ik}(t) + \text{alfa} * ERRO_i * X_{ik} \quad (4.16)$$

Na equação 4.16, $W_{ik}(t)$ é o valor do peso W do neurônio ‘i’ conectado a entrada ‘k’ em um dado instante de tempo (t), $W_{ik}(t+1)$ é o valor do peso W do neurônio ‘i’ conectado a entrada ‘k’ em um dado instante de tempo (t+1), ou seja, logo após a correção deste peso que é calculada pela expressão acima. Também é adicionado ao processo de correção o parâmetro alfa, o qual é responsável pela velocidade de adaptação conduzindo a mudanças suaves dos pesos a cada novo valor apresentado, sem esquecimento das adaptações anteriores. Alfa deve assumir valores entre 0 e 1.

A fórmula original apresentada é introduzida uma nova parcela, denominada fator de inércia ou *momentum*, a qual a conservação de corretas alterações na presença de distúrbios:

$$W_{ik}(t+1) = W_{ik}(t) + ERRO_i * X_{ik} * \text{alfa} + MOMENTUM * \Delta W_{ik}(t-1) \quad (4.17)$$

onde $\Delta(t-1)$ é igual ao último ajuste feito nos pesos.

Ou seja, podemos re-escrever a fórmula acima em duas etapas:

$$\Delta W_{ik}(t) = ERRO_i * X_{ik} * \text{alfa} + MOMENTUM * \Delta W_{ik}(t-1) \quad (4.18)$$

$$W_{ik}(t+1) = W_{ik}(t) + \Delta W_{ik}(t)$$

Assim, usa-se o valor da última alteração dos pesos para acrescentar a próxima alteração destes. O valor do *momentum* também é um valor real entre 0 e 1, mas normalmente utiliza-se uma inércia alta, de digamos 0.9, pois a inércia ajuda a chegar mais rápido num valor de pesos que satisfaça (reduzindo o erro na saída do neurônio mais rapidamente) sem no entanto provocar perturbações exageradas no processo de convergência em direção ao ponto de mínimo na curva de erro.

4.4.2 Perceptron multicamadas

As capacidades do *perceptron* de uma simples camada são limitadas a fronteiras de decisão linear e funções lógicas simples (Russel; Norvig, 1995). Identificando as limitações relativas ao *perceptron* de camada simples, foi desenvolvido o *multilayer perceptron* (MLP), que em geral, consiste de uma camada de entradas, uma ou mais camadas intermediárias (escondidas) e uma camada de saída.

Nas redes *multilayer perceptron*, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa do problema.

Perceptrons de uma única camada permitem a classificação de padrões linearmente separáveis, onde a categorização dos grupos é satisfeita por fronteiras de decisão tais como apresentadas na Fig. 4.8, a) - reta (espaço 2D) ou hiperplano (espaço 3D). No caso de MLP as fronteiras de decisão podem assumir curvas com diferentes comportamentos, decorrentes da topologia da rede (numero de neurônios e camadas existentes). Tais curvas permitem a implementação de fronteiras de decisão adequadas para a separação de classes complexas não separáveis linearmente, ver Fig. 4.8.

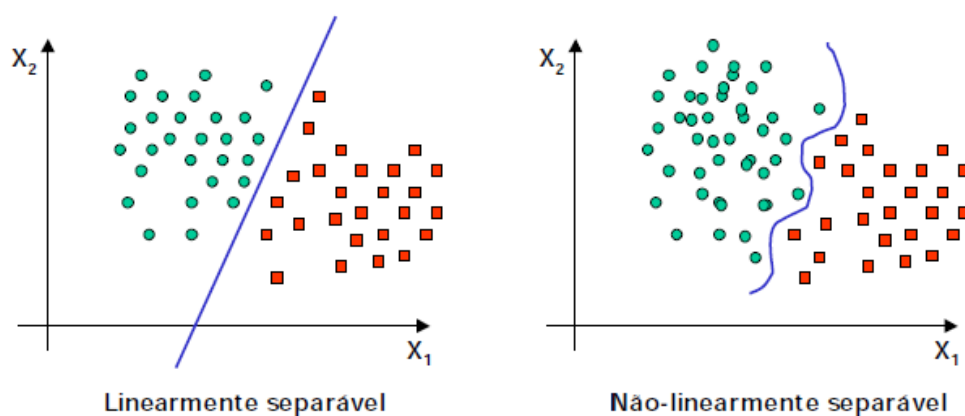


Figura 4.8 – (a) Padrão linearmente separável. (b) Padrão não linearmente separável
Fonte: Theodoridis; Koutroumbas, 2003.

4.4.3 Algoritmo *Backpropagation*

O mais popular método para aprendizado em redes multicamadas é chamado *backpropagation* (retro-propagação). Ele foi inicialmente criado em 1969 por Bryson e Ho, mas foi ignorado até o início dos anos 80.

- **O funcionamento do *Backpropagation***

Durante o treinamento com o algoritmo *backpropagation*, similarmente ao processo apresentado para o *perceptron* de uma camada, a rede opera em uma seqüência de dois passos (Fig. 4.9). Primeiro, um padrão é apresentado a rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída é obtida comparando-a a saída desejada para este padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados através da regra delta conforme o erro é retropropagado (Carvalho, 2010).




Figura 4.9 - Operação do Algoritmo *Backpropagation*
Fonte: Tonsig, 2000.

A regra delta padrão essencialmente implementa um gradiente descendente no quadrado da soma do erro para funções de ativação lineares. Redes sem camadas intermediárias podem resolver problemas onde a superfície de erro tem a forma de um parabolóide com apenas um mínimo. Entretanto, a superfície do erro pode não ser tão simples, e suas derivadas mais difíceis de serem calculadas. Nestes casos devem ser utilizadas

redes com camadas intermediárias. Ainda assim, as redes ficam sujeitas aos problemas de procedimentos “*Hill-climbing*”, ou seja, ao problema de mínimos locais (Carvalho, 2010).

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de novos dados (Fig. 4.10). Para isto, a rede deverá ser utilizada apenas no modo progressivo (*feed-forward*). Ou seja, novas entradas são apresentadas a camada de entrada, são processadas nas camadas intermediárias e os resultados são apresentados nas camadas de saída, como no treinamento, mas sem retropropagação do erro. A saída apresentada é o modelo dos dados, na interpretação da rede (Carvalho, 2010).




Figura 4.10 - *Backpropagation* em modo progressivo (*feed-forward*)

Fonte: Tonsig, 2000.

4.5 CONSIDERAÇÕES FINAIS

A proposta deste trabalho prevê o uso de redes neurais artificiais para a obtenção dos grupos de famílias, bem como um método automático de classificação destes. Assim, este capítulo apresentou a fundamentação teórica associada ao uso de técnicas de RNA para agrupamento e classificação. Mais especificamente foram detalhadas as técnicas de agrupamento por mapas auto-organizáveis e os classificadores utilizando *multilayer perceptron* (MLP) com algoritmo *backpropagation* para aprendizado supervisionado.

Os mapas, auto-organizáveis de *kohonen* serão responsáveis por extrair, a partir de um histórico, as principais famílias de produtos intermediários através de seus atributos. Tais grupos serão utilizados para treinar a rede MLP com o algoritmo *backpropagation*. A MLP

após treinada e salva sua topologia e seus principais parâmetros de conexão, permitirá classificar qualquer novo conjunto de dados sem esforço adicional de treinamento e validação.

A metodologia é apresentada no capítulo 5, onde será descrito a função de cada variável envolvida no sistema de agrupamento/classificação de dados.

5 UMA PROPOSTA PARA AGRUPAMENTO E CLASSIFICAÇÃO DE FAMÍLIAS DE PRODUTOS INTERMEDIÁRIOS

5.1 INTRODUÇÃO

Nos capítulos anteriores fez-se um estudo das fundamentações teóricas que dão suporte as especificidades da indústria de construção naval, e os avanços significativos nas funções de planejamento, programação e controle da produção. Apresentou-se como uma das etapas chave para o processo produtivo na construção naval a definição das famílias de produtos, onde o conceito de agrupamento de produtos por similaridade de variáveis dimensionais e recursos produtivos tem por finalidade a concepção de linhas dedicadas de produção para famílias distintas de trabalho (Tecnologia de Grupo). O desenvolvimento destes princípios permite, em seu estado de arte, a redução de movimentação de materiais, redução de estoques desnecessários, redução de atrasos e redução significativa dos tempos de espera entre um processo e outro (*lead time*).

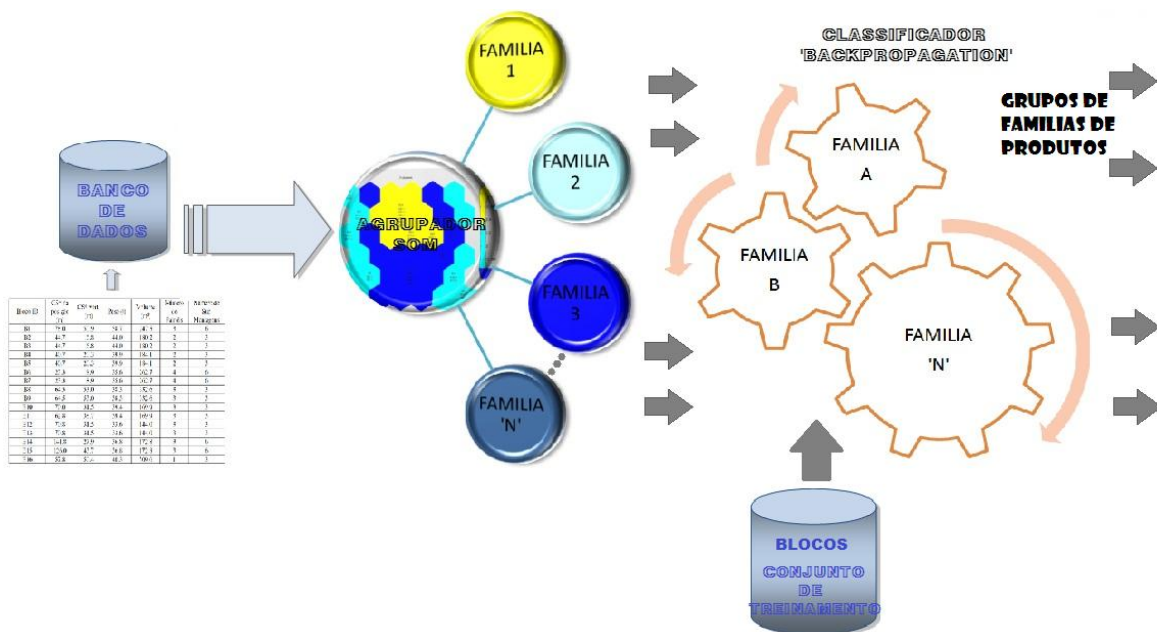


Figura 5.1- Arquitetura do Sistema de Agrupamento e Classificação de Dados
 Fonte: Barañano, 2011, Rio Grande

Neste capítulo 5 é apresentada a metodologia proposta neste trabalho para o tratamento automático de famílias de produtos intermediários. A Fig. 5.1 apresenta uma visão geral da proposta, composta pelos seguintes elementos:

- Banco de dados histórico: conjunto de informações (dimensionais, funcionalidade, etc) associadas a elementos já processados na planta que será utilizado para concepção do sistema automático de agrupamento e classificação
- Sistema de Agrupamento SOM: sistema de clusterização, baseado em algoritmo SOM, que definirá os grupos básicos de produtos intermediários, a partir do banco de dados existente
- Sistema de classificação MLP: classificador baseado em MLP capaz de classificar cada novo bloco a ser produzido em um dos grupos de produtos intermediários fornecidos pelo SOM. O sistema de classificação é concebido através de fase de treinamento que utiliza informações presentes no Banco de Dados de Histórico e nos grupos (famílias de produtos fornecidos pelo SOM).

Percebe-se que tanto as etapas de agrupamento como as de classificação são realizadas de forma totalmente autônomas sem interferência de operadores, sendo capazes de tratar complexas relações entre informações de alta dimensionalidade (grande quantidade de amostras categorizadas por grande quantidade de informações).

5.2 PRÉ-PROCESSAMENTO DOS DADOS

Busca-se desenvolver um modelo para agrupamento e classificação capaz de tratar informações de alta dimensionalidade, estocásticas e de difícil previsão. Estas características indicam que o uso de RNA capazes de tratar não-linearidades pode produzir resultados eficazes, permitindo o tratamento destes grandes conjuntos de dados que representam os diferentes produtos intermediários associados à implantação de Tecnologias de Grupo.

O modelo desenvolvido considera somente as operações de fabricação típicas, com a transformação de matérias primas que permitem a obtenção de produtos complexos, como o caso dos itens estruturais principais e secundários de um dos blocos da seção mestra (Chama-se seção mestra a maior das seções transversais de um casco. A seção mestra se situa coincidentemente com a seção a meia nau, ou muito próximo desta, na maioria dos navios modernos, qualquer que seja o tipo. Em muitos navios modernos, e particularmente nos navios mercantes de carga, certo comprimento da região central do casco é constituído por

seções iguais à seção mestra numa distância apreciável, quer para vante, quer para ré da seção a meia-nau ou seção mestra; diz-se então que o navio tem formas cheias. Nos navios que têm formas finas, a forma das seções transversais varia muito em todo o comprimento do navio a vante e a ré da seção mestra”. (Fonseca,1989 p. 56)) que vão formar o casco do navio. Devido à predominância dos aspectos dimensionais dos blocos na definição dos grupos, os processos de *outfitting* foram desconsiderados nas análises realizadas. Entretanto ressalta-se que a metodologia permite o tratamento destas informações, sem qualquer necessidade de criação e desenvolvimento de novas abordagens.

5.2.1 Extração de características e Normalização

A primeira etapa da metodologia é associada ao processamento dos dados originais e determinação do conjunto de características (variáveis mais relevantes) descritoras dos produtos a serem agrupados e classificados. Neste trabalho trabalha-se com um vetor de características de dimensão D, o qual fornece a dimensionalidade do sistema. Exemplos de características podem ser:

- Largura
- Comprimento
- Peso
- Número de painéis
- Número de Sub-montagens

Tais características são representadas por valores escalares (Fig. 5.2):

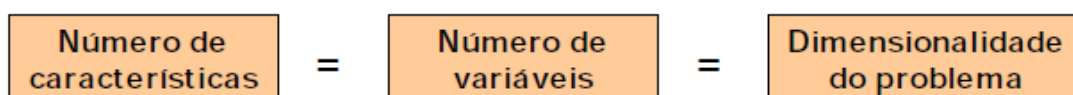


Figura 5.2 - Valores Escalares
Fonte: Barañano, 2011, Rio Grande.

Como pré-processamento para análise de dados, é feita a normalização das variáveis características. A normalização adotada neste trabalho é a função 'logistic' ou 'normalização

softmax' da ferramenta somtoolbox utilizada neste estudo. Esta normalização garante que todos os valores futuros estejam dentro da faixa [0,1]. A transformação é predominantemente linear na faixa intermediária (ao redor do valor médio), e tem não-linearidade suave em ambos os extremos o que assegura que todos os valores estejam dentro da faixa esperada. Os dados são primeiramente escalados como na normalização por variância e então transformados dentro da função logística, conforme equação 5.1. Para reduzir a redundância de dados e as chances dos dados se tornarem inconsistentes. O método Softmax é baseado na função logística:

$$x_i = \frac{1}{1+e^{-x}} \quad 5.1$$

A qual transforma os valores de $[-\infty, +\infty]$ para $[0,1]$, lidando naturalmente com valores fora da faixa esperada sendo de fácil implementação.

5.3 CATEGORIZAÇÃO (CLUSTERING): OBTENÇÃO DAS FAMÍLIAS DE PRODUTOS

A determinação dos principais grupos de produtos intermediários é realizada por categorização (*Clustering*), utilizando os mapas auto-organizáveis de *Kohonen* para apresentação dos dados (Fig. 5.3). O SOM recebe como padrão de entrada um conjunto de informações, representadas por cada característica X_i , associadas a cada um dos blocos existentes no Banco de Dados de Histórico. Para cada bloco a ser apresentado a SOM (padrão), um conjunto de n características serão utilizadas como entradas a serem clusterizadas pelo sistema.

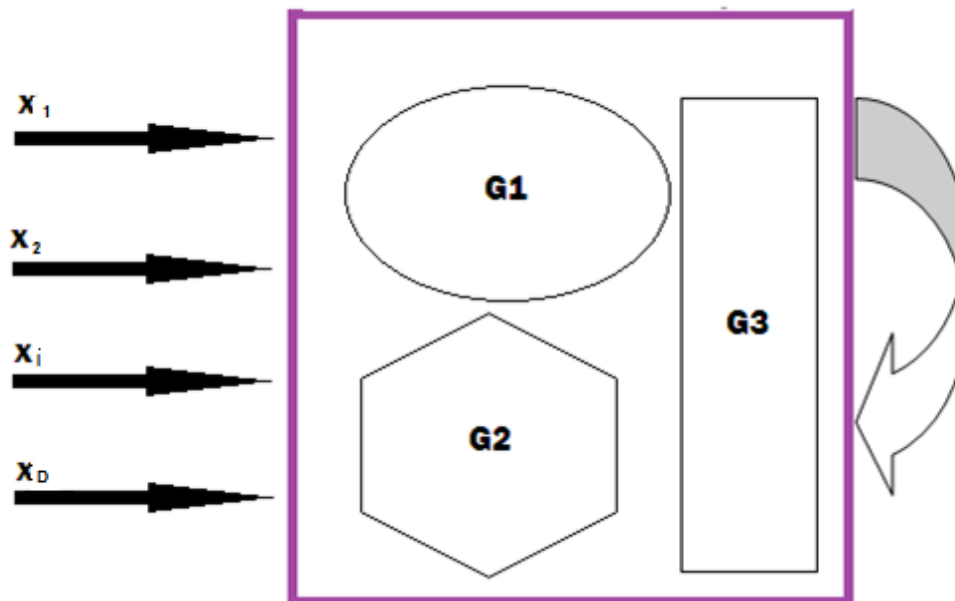


Figura 5.3 - Categorização (Clustering): o sistema recebe um conjunto de padrões representado cada qual por n características

Fonte: Barañano, 2011, Rio Grande.

O SOM realiza aprendizado não supervisionado e explora semelhanças entre padrões e agrupa os padrões parecidos em categorias ou grupos. Padrões semelhantes ou similares são representados por vetores de características próximos (Fig. 5.4).

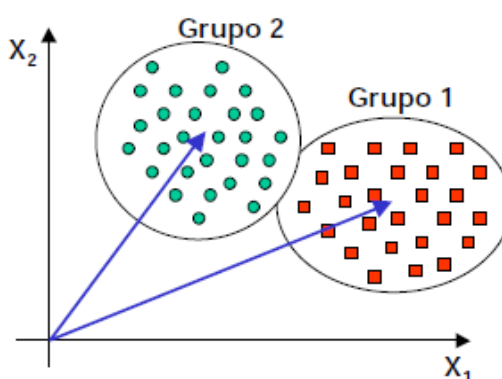


Figura 5.4 - Vetores de características próximas. Neste exemplo cada amostra possui duas características, X_1 e X_2 para a sua descrição

Fonte: Theodoridis; Koutroumbas, 2003.

A SOM reduz a dimensionalidade de representação com a menor perda de informações e distingue grupos de padrões ambíguos com maior facilidade.

A grade de baixa dimensionalidade resultante captura um espaço de alta dimensão presente no banco de dados de histórico. No mapa, as localizações espaciais (coordenadas)

dos neurônios na grade são indicativas das características estatísticas intrínsecas presentes nos padrões de entrada.

O algoritmo de auto-organização do mapa opera primeiramente por competição onde cada dado (x_i) da amostra de dados é comparada a cada neurônio, esta comparação se dá através de uma métrica, em nosso estudo através da distância Euclidiana entre os vetores. A unidade no mapa mais similar, ou mais próxima, ao dado (x_i) da amostra de dados é chamada de unidade vencedora, BMU. Passada esta etapa o algoritmo opera por cooperação, onde o neurônio vencedor aproxima-se do vetor dado x_i . Todos os neurônios vizinhos ao BMU têm seus vetores ajustados para uma aproximação de x_i apresentado de acordo com um raio de vizinhança, determinado neste estudo pela função gaussiana. O fator de ajuste diminui à medida que a distância de cada neurônio ao neurônio vencedor aumenta. Logo, os neurônios que estão mais próximos ao neurônio vencedor se ajustam mais rapidamente a x_i e os neurônios que estão mais distantes ao neurônio vencedor sofrem poucas modificações. Desta forma quanto mais próximo um neurônio encontra-se do BMU, maior é a adaptação aplicada ao neurônio. Processo este descrito de forma detalhada no capítulo 4 deste estudo.

Após a submissão dos dados ao SOM e a convergência da rede para os grupos existentes, obtêm-se o conjunto de famílias existentes presentes no universo de amostragem que constitui o Banco de Dados de Histórico. Além dos grupos, tem-se também a categorização de cada um dos seus elementos em um dos grupos resultantes. Tal categorização será utilizada para o treinamento supervisionado do módulo de classificação MLP descrito a seguir.

5.4 MÓDULO MLP DE CLASSIFICAÇÃO: CLASSIFICANDO BLOCOS

Num segundo momento as classes obtidas para cada elemento do histórico através do reconhecimento de padrões do SOM são utilizadas como metas para treinamento de uma rede supervisionada MLP-*Backpropagation* (Tabela 5.1).

Para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais são necessárias diversas etapas (Fig. 5.5), descritas conforme adaptação de Caudill (1991, p. 108): “definição do problema, coleta dos dados de treinamento e de teste; pré e pós-processamento dos dados; projeto da estrutura da rede; treinamento, teste e validação”.




Figura 5.5 - Desenvolvimento de um modelo baseado em RNA
 Fonte: Medeiros, 1999, p. 74.

Uma vez treinada a MLP poderá ser utilizada para classificar novos produtos em uma das famílias (classes) existentes.

Topologia da Rede: A camada de entrada é utilizada para receber os dados de entrada, não efetuando qualquer tipo de processamento servindo apenas para receber e armazenar o vetor de entrada. Neste trabalho, os dados de entrada são de dimensão n , representando as n características de cada produto a ser classificado.

A camada de saída armazena as respostas obtidas pela rede, esta camada pode proporcionar não-linearidade. O número de neurônios nesta camada corresponde aos vetores de saída. Neste trabalho, a rede apresentará ‘ n ’ saídas, onde ‘ n ’ é o número de grupos fornecidos pelo módulo SOM, os quais serão equivalentes as famílias existentes.

Entre a camada de entrada e de saída, pode-se ter uma ou mais camadas ocultas, conforme citado no capítulo 4 deste estudo. As camadas ocultas proporcionam complexidade e não – linearidade para a rede, não existindo um método que determine um n° ideal de neurônios desta camada (Haykin, 1998).

Os parâmetros da rede neural testados podem ser utilizados para aplicação de novos agrupamentos a outros conjuntos de blocos de dados. Neste tipo de rede para a classificação de padrões deve-se atribuir para cada exemplo que lhe é fornecido uma classe ao qual este exemplo pertence. Portanto, a saída da rede é a classe associada ao exemplo e por consequência, as classes são valores discretos e não contínuos. A classificação é um caso particular da aproximação de funções onde o valor de saída da rede é discretizado e pertence a um conjunto finito de classes. No caso do aprendizado supervisionado, o conjunto de classes é bem definido e conhecido antes de ser iniciado o processo de aprendizado. Uma rede utilizada para fins de classificação deve possuir saídas discretas, ou então, deve implementar métodos de discretização de suas saídas (e.g. aplicação de um limiar de discriminação – *activation threshold*). As entradas da rede podem ser tanto contínuas, como também podem ser discretas, o que não deve interferir no fato desta rede ser usada para uma aplicação classificação discreta.

Consideramos aqui o caso de uma única camada escondida. A generalização para mais de uma camada escondida é direta e a teoria aplica-se sem alteração. Um neurônio recebe várias entradas da camada anterior e calcula uma combinação não-linear dessas variáveis. O resultado da combinação não-linear passa pela função de ativação, neste caso uma função tangente hiperbólica sigmóide ‘tansig’ e algoritmo de treinamento com gradiente descendente. O modelo de rede neural utilizado foi configurado com ‘D’ neurônios na camada de entrada, de acordo com os vetores características do banco de dados. A rede é testada com uma camada oculta com ‘m’ neurônios, sendo esta camada definida conforme a avaliação dos resultados obtidos no estudo de caso para a melhor topologia para o treinamento, testes e validação da rede. E uma camada de saída com ‘n’ neurônios de acordo com a definição do número ideal de classes obtidas pelo modelo de RN SOM-*Kohonen*.

Método de Aprendizado - Algoritmo do Gradiente Descendente com Momentum:

Esse algoritmo busca minimizar o erro quadrático, que é expresso em função dos pesos, de modo a se obter um conjunto de pesos otimizado que encerrará o processo de treinamento, tornando a rede apta a produzir padrões de saída aceitáveis. A rede é treinada de forma a minimizar o erro quadrático associado aos padrões do histórico e sua classificação pela SOM, ver detalhes na seção 4.4.1.

Efetuada o processo de ajuste, o valor atualizado do peso é descrito em (5.2):

$$W(k+1) = W(k) - DW(k) \quad 5.2$$

É de particular interesse a determinação do parâmetro η , que é diretamente responsável pela rapidez do processo de aprendizado. O algoritmo *backpropagation* provê uma aproximação da trajetória de movimento sobre a superfície de erro, a qual, a cada ponto da superfície, segue a direção do ponto mais íngreme em busca do ponto de mínimo global. Quanto menor for a taxa de aprendizado, menores vão ser as correções a serem aplicadas aos pesos entre cada iteração, ocasionando um processo de convergência lento. Caso contrário, se o valor desse parâmetro for alto, pode-se obter uma aceleração no processo de convergência, mas pode-se tornar o algoritmo instável pela oscilação em torno de um ponto de mínimo local.

Uma forma simples de garantir a estabilidade e acelerar a convergência é a utilização da regra delta acrescida do fator de momento. Essa é representada em 5.3:

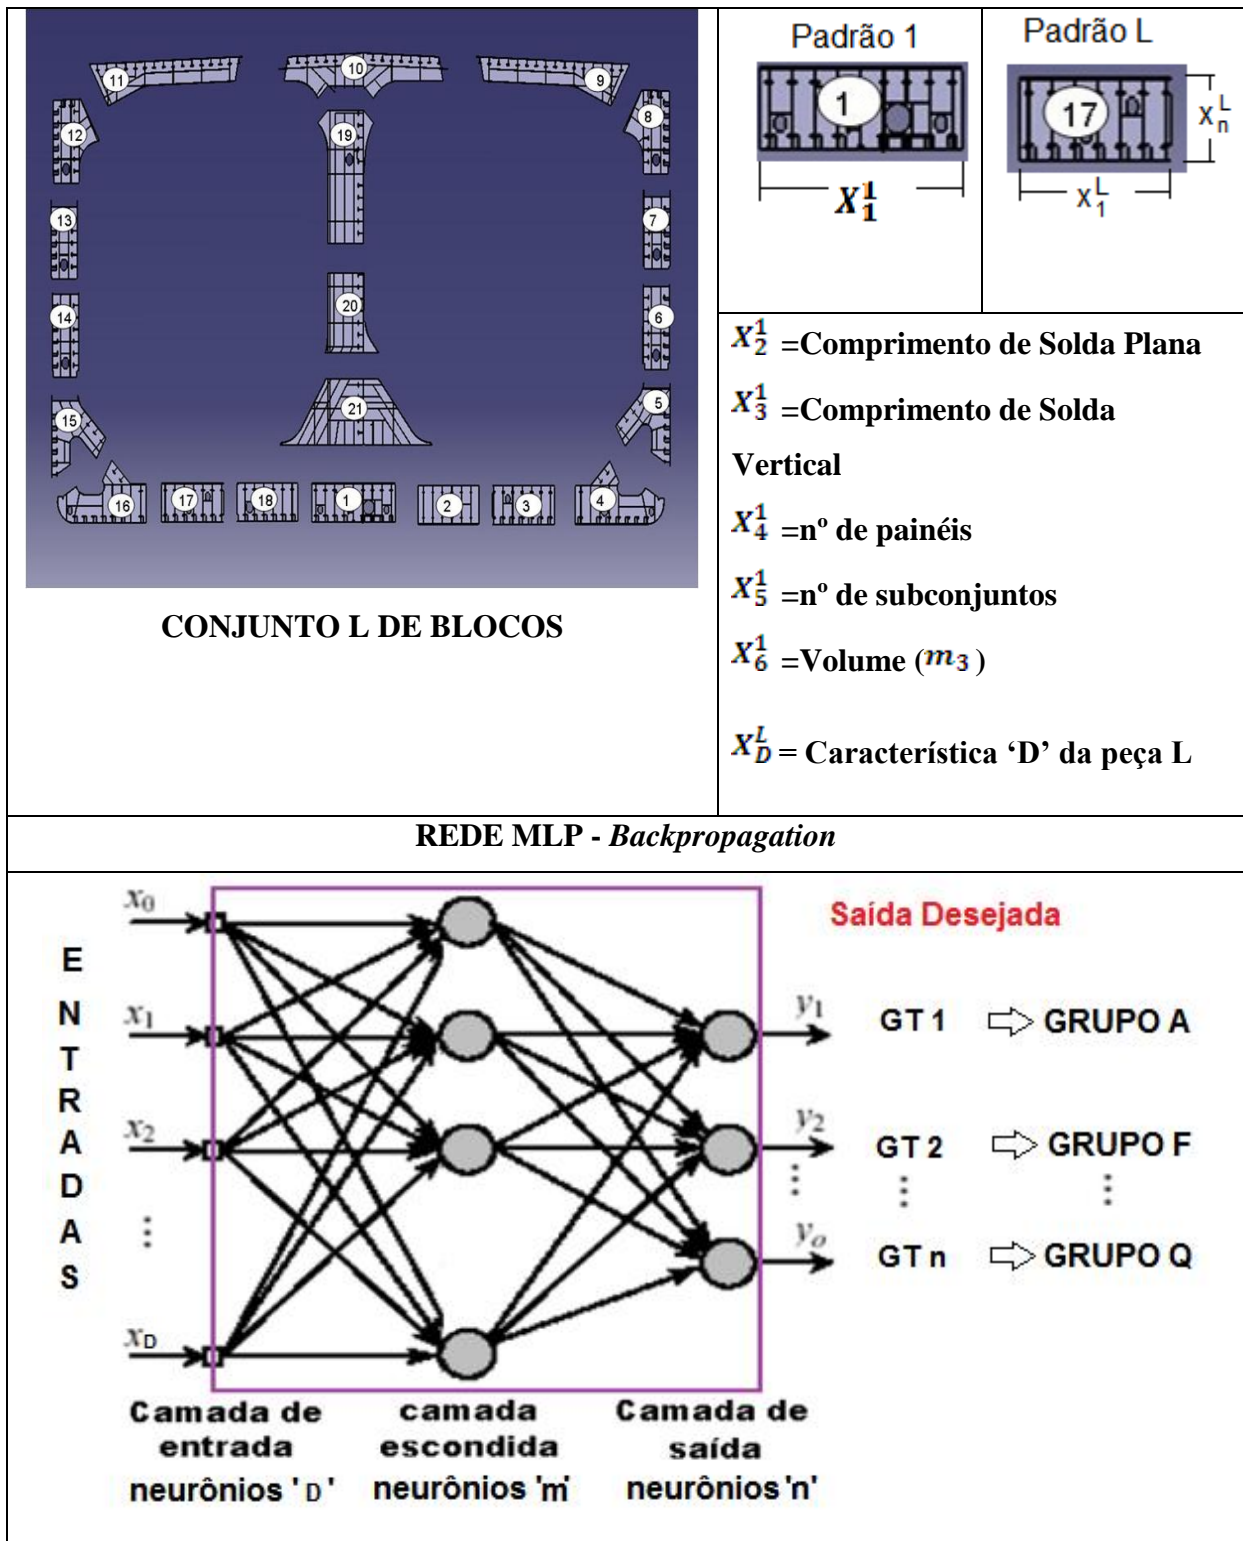
$$\Delta \mathbf{W}(k) = \beta \Delta \mathbf{W}(k-1) + \eta \frac{\partial E_R(\mathbf{W})}{\partial \mathbf{W}} \quad 5.3$$

onde β é denominado constante de momento e possui a variação $0 < \beta < 1$.

O efeito dessa constante é aumentar a velocidade na direção do ponto de mínimo. O que se deseja com a inserção do termo de momento é a redução no tempo de treinamento, a melhora na estabilidade do processo e, com isso, aumentar a possibilidade de encontrar o mínimo global.

Padrões a serem aprendidos: A rede MLP-*Backpropagation* receberá como entrada um vetor \vec{x} de dimensão D igual ao número de características dimensionais e produtivas que representam o bloco. Como saída desejada a rede deverá classificar o bloco em cada um dos n grupos fornecidos pela rede SOM. Desta forma utiliza-se para treinamento e classificação uma rede *backpropagation* com D entradas e n saídas. A tabela 5.1 apresenta a arquitetura deste sistema de reconhecimento para a classificação de L padrões em n grupos distintos.

Tabela 5.1 - Arquitetura do Sistema de Reconhecimento de Padrões



Fonte: Barañano, 2011, Rio Grande.

5.5 PARÂMETROS A SEREM DEFINIDOS

Alguns parâmetros das redes utilizadas precisam ser definidos de forma a um melhor aproveitamento do treinamento dos dados apresentados a rede. A escolha dos parâmetros é baseada na literatura consultada para execução deste trabalho.

Inicialização da Rede: Freeman; Skapura, 1992, sugere que os pesos das conexões entre as camadas de uma rede neural sejam inicializados com valores aleatórios e pequenos para que se evite a saturação da função de ativação e a conseqüente incapacidade de realizar a aprendizagem.

Taxa de Aprendizado: À medida que o treinamento evolui, os pesos sinápticos podem passar a assumir valores maiores, forçando a operação dos neurônios na região onde a derivada da função de ativação é muito pequena. Como o erro retropropagado é proporcional a esta derivada, o processo de treinamento tende a se estabilizar, levando a uma paralisação da rede sem que a solução tenha sido encontrada. Isto pode ser evitado pela aplicação de uma taxa de aprendizagem menor. Teoricamente, o algoritmo de aprendizado exige que a mudança nos pesos seja infinitesimal (Rumelhart; Hinton; Williams, 1986). Entretanto, a alteração dos pesos nessa proporção é impraticável, pois implicaria em tempo de treinamento infinito. Em vista disso, é recomendável que a taxa de aprendizado assuma valor maior no início do treinamento e, à medida em que se observe decréscimo no erro da rede, essa taxa também seja diminuída.

É necessária a definição de taxa de aprendizagem, que à medida que seus valores diminuem, menores vão ser as correções a serem aplicadas aos pesos entre cada iteração, ocasionando um processo de convergência lento. Caso contrário, se o valor desse parâmetro for alto, pode-se obter uma aceleração no processo de convergência, mas pode-se tornar o algoritmo instável pela oscilação em torno de um ponto de mínimo local. Sendo assim as redes foram testadas com diversos valores de taxa de aprendizagem e escolhidos aqueles que melhor representam o objetivo deste estudo, os quais são descritos no capítulo 6.

Diminuindo progressivamente a taxa de atualização dos pesos, o *gradiente decrescente* está apto a alcançar uma solução melhor (Beale e Jackson, 1990).

Momento: Outra maneira de aumentar a velocidade de convergência da rede neural artificial treinada pelo algoritmo *backpropagation* é a adoção do método descrito anteriormente chamado *momentum* (Beale, 1990; Freeman, 1992; Rumelhart, 1986; Wasserman, 1989). O propósito desse método consiste em adicionar, quando do cálculo do valor da mudança do peso sináptico, uma fração proporcional à alteração anterior. Assim, a

introdução desse termo na equação de adaptação dos pesos tende a aumentar a estabilidade do processo de aprendizado, favorecendo mudanças na mesma direção.

Topologia da rede: Outro parâmetro importante é o número de unidades de processamento das camadas da rede. O número de neurônios das camadas de entrada e saída é usualmente determinado pela aplicação. No caso das camadas ocultas, a relação não é tão transparente. O ideal é utilizar o menor número possível de unidades ocultas para que a generalização não fique prejudicada (Rumelhart, 1986). As camadas ocultas proporcionam complexidade e não-linearidade para a rede. Não existindo um método que determine um nº ideal de neurônios desta camada, conforme descrito no capítulo 4. Normalmente obtêm-se resposta satisfatória com apenas uma camada oculta, sendo assim a rede foi testada com uma única camada e diversos números de neurônios.

Se o número de neurônios ocultos for muito grande, a rede acaba memorizando os padrões apresentados durante o treinamento. Contudo, se a arquitetura das camadas ocultas possuir unidades de processamento em número inferior ao necessário, o algoritmo *backpropagation* pode não conseguir ajustar os pesos sinápticos adequadamente, impedindo a convergência para uma solução. Assim sendo, foi utilizada a configuração que obteve melhor desempenho. A experiência ainda é a melhor indicação para a definição da topologia de um modelo conexionista (Surkan; Singleton, 1990).

Capacidade de Generalização e Base de Validação: A capacidade de generalização de uma rede pode ser avaliada através dos exemplos de validação que não foram usados durante o treinamento. Quando uma rede é treinada excessivamente, a mesma pode perder a sua capacidade de generalização. Este fenômeno é denominado super treinamento (*overfitting*), aonde o erro durante os treinos são bastante pequenos, porém podem ser grandes quando novos dados são apresentados a rede (Hou, 1998). Sendo generalização a capacidade de um modelo de aprendizado responder corretamente aos exemplos que lhe são apresentados, sendo que estes exemplos não devem estar presentes na base de aprendizado. Um modelo que tem uma boa generalização é aquele modelo que responde corretamente aos exemplos contidos na base de aprendizado, mas também a outros exemplos diferentes daqueles da base de aprendizado, aqui denominado base de validação e que estão contidos em uma base de teste.

Método de Parada: De forma a avaliar os resultados de uma rede neural, o erro médio quadrático (MSE-*Mean Square Error*) é normalmente utilizado como indicador de desempenho. O MSE é a diferença entre a média de quadrados entre os resultados da rede e suas metas (*targets*).

A equação 5.2 expressa essa função:

$$MSE = \frac{1}{N} \sum_{o=1}^M \sum_{k=1}^N (y_{ok} - y_{dok})^2 \quad 5.2$$

Onde M é o número de saídas da rede, N é o número de amostras de treinamento ou validação, y_o é a saída da rede, y_{do} é o valor de saída desejado e MSE é o erro médio entre a saída da rede y_o e os valores desejados y_{do} .

O ponto de parada antecipada é dado na época aonde o MSE de validação começa a crescer, como ilustrado na (Fig. 5.6), e permitindo desta forma que a rede não perca a sua capacidade de generalização.




Figura 5.6 - Método de Parada Antecipada com conjunto de validação
Fonte: Beale, 1990.

A capacidade de generalizar é a principal capacidade buscada nas tarefas que envolvem aprendizado.

5.6 CONSIDERAÇÕES FINAIS

Neste capítulo descreveu-se a metodologia para a concepção de um modelo de agrupamento e classificação de famílias de produtos intermediários. A partir de um Banco de Dados de Histórico de Produtos, as etapas para definição desta metodologia foram definidas em dois momentos:

- a) A descoberta do número de grupos de famílias presente no universo de amostragem (banco de dados de histórico). O reconhecimento de padrões é feito por categorização (*Clustering*), utilizando os mapas auto-organizáveis de *Kohonen* para apresentação dos dados;
- b) As classes obtidas através do reconhecimento de padrões do SOM são utilizadas como metas para treinamento de uma rede supervisionada *MLP-Backpropagation* para treinar a rede.

As etapas desenvolvidas neste capítulo demandaram inúmeras simulações até chegarem à proposta aqui apresentada.

Sendo esta proposta adequada ao estudo de sistemas de classificação de famílias de produtos intermediários baseado em análise de sistemas inteligentes, a simulação de algumas das etapas será relatada a seguir.

6 ESTUDO DE CASO: TESTES E VALIDAÇÃO

A metodologia apresentada no capítulo anterior foi aplicada em um estudo de caso real de agrupamento e classificação de produtos intermediários em um Banco de Dados de Histórico real.

A metodologia foi implementada utilizando a ferramenta matemática MATLAB (MATriz LABoratory), o qual é um sistema baseado em matrizes, empregado em cálculos matemáticos e de engenharia. Sua escolha se deve ao seu extenso conjunto de rotinas para a obtenção de saídas gráficas, boa *interface* com outros sistemas e ferramentas adequadas ao estudo de sistemas de classificação de famílias de produtos intermediários baseado em análise de sistemas inteligentes.

6.1 IMPLEMENTAÇÃO DA PROPOSTA NO MATLAB

Dentro dos pacotes de trabalho do MATLAB encontra-se o toolbox de Redes Neurais o qual apresenta todos os algoritmos apresentados no Capítulo 4.

O estudo de caso foi feito utilizando-se dois tipos de arquiteturas de RN: *Self-Organizing Maps* (SOM) com algoritmo de treinamento de *Kohonen* e Rede *Multi-Layer Perceptron* (MLP) com algoritmo de treinamento *Backpropagation*, para tratamento dos dados de uma das seções do navio suexmax da transpetro.

Os experimentos realizados neste estudo tiveram como objetivo testar o desempenho das Redes Neurais de *Kohonen/MLP* em tarefas de agrupamento/classificação de famílias de produtos em um número ideal de classes, possibilitando a alocação de recursos produtivos das células de manufatura do estaleiro de forma a minimizar perdas e otimizar meios na execução dos produtos intermediários que irão compor os blocos, permitindo desta forma uma maior previsibilidade pelas equipes de projeto do navio e planejamento da produção dos recursos disponíveis.

Os modelos aplicados neste trabalho, *Kohonen* e *Backpropagation*, são aplicados para buscar soluções ótimas e automáticas quando os espaços de busca se tornam grandes o suficiente para que técnicas tradicionais de otimização das células de produção não funcionem.

6.1.1 Heurísticas

Devido à ausência de fundamentação teórica sólida para a escolha de parâmetros de Redes SOM, tanto relacionados à inicialização quanto de treinamento do mapa, não seguindo regras bem definidas, são propostas para a sua definição, heurísticas baseadas no comportamento do mapa e em médias estatísticas de critérios de qualidade.

6.1.2 Métricas Estatísticas de Qualidade

O Erro Médio de Quantização (QE) corresponde à média das distâncias entre cada vetor de dados v_n e o correspondente vetor de pesos do neurônio BMU (Cada dado de entrada possui uma BMU (Best Match Unit) associada a ele, ou seja, um neurônio que melhor o representa (Neurônio Vencedor)). A medida QE corresponde à resolução do mapa e é inversamente proporcional ao número de neurônios (Rittner e Brum, 2008).

A segunda medida é o Erro Topográfico (TE), que quantifica a capacidade do mapa de representar a topologia dos dados de entrada. Para cada objeto é calculados seu BMU e o segundo BMU e toda vez que eles não forem adjacentes, aumenta-se o erro em uma unidade, tirando-se depois a média pelo número total de objetos (Rittner; Kohonen, 1989).

6.1.3 Tamanho do mapa

A escolha do tamanho do mapa possui mais de uma heurística. Se estivermos trabalhando com um conjunto pequeno de dados, podemos escolher o número de neurônios igual ao número de dados. A SOM Toolbox propõe $Q=5(N)^{0,5}$. Onde: N é o número de dados de entrada; e Q =Tamanho do Mapa (Ritter; Kohonen, 1989).

Se o arranjo possuir um número muito grande de neurônios, pode ocorrer de os neurônios posicionarem-se praticamente sobre os objetos a serem representados. Neste caso, o erro de quantização tende a zero, porém o mapa perde sua capacidade de generalização. Além disso, o erro topográfico provavelmente terá aumentado muito, o que pode não ser desejável. O correto é encontrar a melhor relação entre QE, TE e tamanho do mapa (Ritter; Kohonen, 1989).

O trabalho de resolução de problemas utilizando mapas auto-organizáveis de *Kohonen* pode ser dividido em 4 etapas básicas: entrada de dados, inicialização e treinamento do mapa, visualização do mapa e dos dados e análise dos resultados.

A etapa de entrada de dados destaca-se das demais por ser melhor visualizada, enquanto que as etapas de inicialização e treinamento do mapa confundem-se com a de visualização e análise dos resultados do mapa que representa os dados.

6.2 RELATÓRIO DE EXPERIMENTOS

Como entrada utiliza-se um banco de dados que possui um total de 30 blocos que pertencem a um organismo paralelo ao grande bloco (anel) de um tanque *Suezmax*. Cada um dos blocos de construção com 6 variáveis ($R^{D=6}$): comprimentos de solda (na posição e vertical), peso, volume e número de painéis e submontagens conforme tabela 6.1.

Tabela 6.1- ‘Blocks’ (Dados)

Partes	WL* Plano	WL* Vert	Largura(t)	Volume(m3)	Número de painéis	Número de Subconjuntos
P1	78.0	50.9	58.7	247.5	3.0	6.0
P2	44.7	16.8	44.0	180.2	2.0	3.0
p3	44.7	16.8	44.0	180.2	2.0	3.0
P4	40.7	20.3	39.9	184.1	2.0	3.0
P5	40.7	20.3	39.9	184.1	2.0	3.0
P6	23.3	18.9	35.6	262.7	4.0	6.0
P7	23.3	18.9	35.6	262.7	4.0	6.0
P8	64.5	53.0	38.3	332.6	3.0	3.0
P9	64.5	53.0	38.3	332.6	3.0	3.0
P10	70.0	31.5	39.4	169.9	3.0	3.0
P11	62.8	38.7	39.4	169.9	3.0	3.0
P12	70.8	31.5	33.6	144.0	3.0	3.0
P13	70.8	31.5	33.6	144.0	3.0	3.0
P14	141.8	27.9	36.8	172.8	4.0	6.0
P15	120.0	28.9	35.4	176.3	3.0	5.0
P16	58.0	51.0	41.0	510.0	1.0	3.0
P17	58.0	51.0	41.0	510.0	1.0	3.0
P18	80.0	57.0	49.0	519.0	3.0	6.0
P19	27.0	9.0	16.0	176.0	1.0	6.0
P20	27.0	9.0	29.0	192.0	1.0	3.0
P21	36.0	13.0	33.0	276.0	1.0	6.0
P22	26.0	22.0	39.0	780.0	1.0	6.0
P23	24.0	12.0	32.0	144.0	1.0	0
P24	12.0	6.0	26.0	123.0	1.0	0
P25	17.0	8.0	23.0	97.0	1.0	0
P26	9.0	4.0	17.0	86.0	1.0	0
P27	24.0	12.0	32.0	144.0	1.0	0
P28	12.0	6.0	26.0	123.0	1.0	0
P29	17.0	8.0	23.0	97.0	1.0	0

P30	9.0	4.0	17.0	86.0	1.0	0
-----	-----	-----	------	------	-----	---

Fonte: Souza, 2009, p. 98.

A base de dados é limitada devido à disponibilidade de informações, mas, no entanto os códigos foram desenvolvidos assumindo que bases de dados de maior porte poderiam estar disponíveis.

A Fig. 6.1 apresenta um esquema dos blocos de construção.

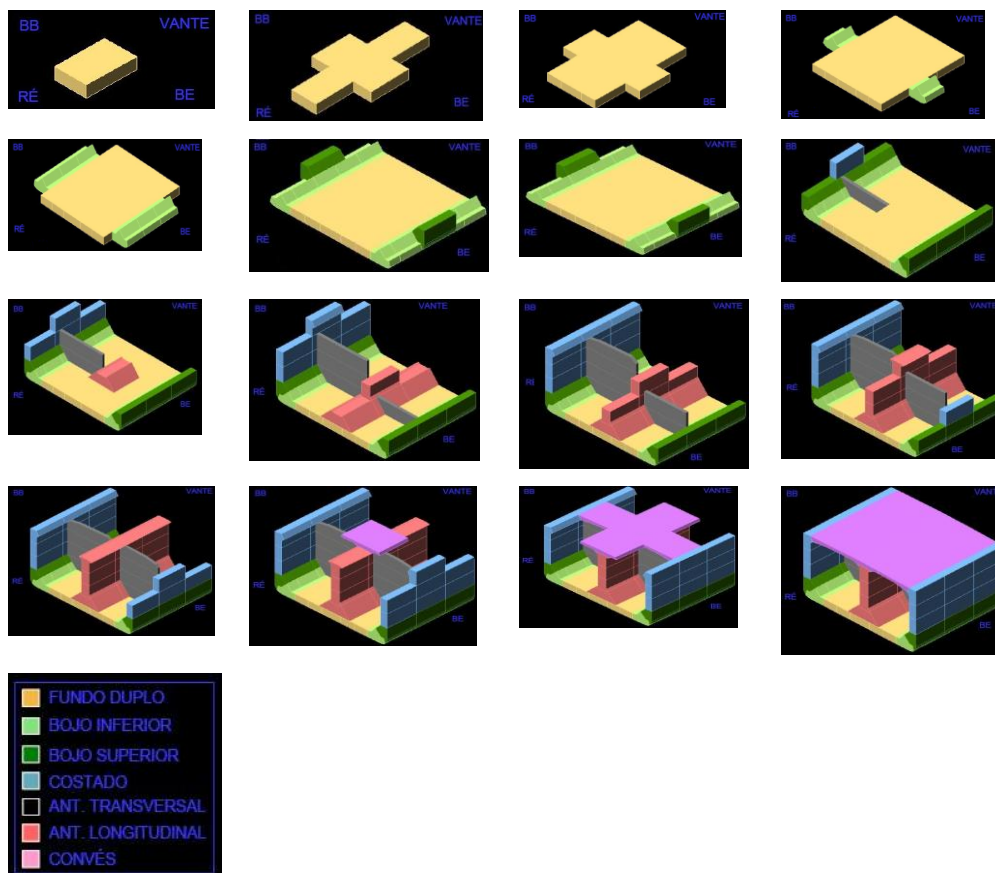


Figura 6.1 - Esquema dos blocos de construção
 Fonte: ONIP, 2008.

6.2.1 Implementando o Módulo Agrupador SOM

Para a definição automática das famílias presentes no histórico foi utilizada a SOM Toolbox, uma implementação do mapa auto-organizável de Kohonen em Matlab®. Esta *toolbox* (Pacote de trabalho) é de domínio público e pode ser encontrada para instalação no endereço: <http://www.cis.hut.fi/projects/somtoolbox/>.

Esta *toolbox* pode ser utilizada para pré-processamento dos dados, inicialização e treinamento do mapa auto-organizável em várias topologias e visualização dos dados e do mapa após o treinamento. No aprendizado não supervisionado a rede “analisa” os padrões, regularidades e correlações para agrupar o conjunto de dados em classes (Clusters).

A partir da matriz ‘*Blocks*’ (Ver tabela. 6.1) o conjunto de dados é normalizado e adicionam-se rótulos a eles. Estes rótulos não serão utilizados nas fases de treinamento do mapa, mas serão utilizados na visualização dos resultados.

Inicialização: Foram criadas redes SOM para cada experimento, onde os vetores de pesos são inicializados primeiramente com um algoritmo linear ao longo dos dois maiores autovetores, se isto não pode ser feito (autovetores não podem ser calculados) a inicialização dos vetores de pesos é feita com pequenos valores aleatórios.

Normalização: é feito um pré-processamento nos dados para a sua correta utilização pela SOM, conforme descrito no capítulo 5.

Treinamento da SOM: A rede SOM realiza o agrupamento dos produtos através da sua capacidade de redução de dimensionalidade. Neste estudo de caso, as características de cada elemento a ser classificado apresenta dimensão $R^{D=6}$, os quais serão apresentados a rede SOM com neurônios dispostos em uma topologia no espaço R^2 (Fig. 6.2). Tal técnica permite eliminar parte da informação redundante em cada dimensão.

O mapa resultante, mapa 3 de matriz [6 6], agrupou as diversas famílias de blocos a partir de seus atributos de comprimento de solda (na horizontal e na vertical), peso, volume, número de painéis e número de submontagens. Rotulando as BMUs com os rótulos dos dados (Bloco ID).

Uma vez que temos mais neurônios do que dados, muitos dos neurônios não venceram nunca (não são BMUs de nenhum dado), não temos 30 neurônios rotulados no mapa, o que nos leva a concluir que alguns neurônios foram BMUs para vários dados. Isto é possível de se observar pela frequência que cada dado ocorreu. O resultado obtido:

Mapa3 = [6 6]

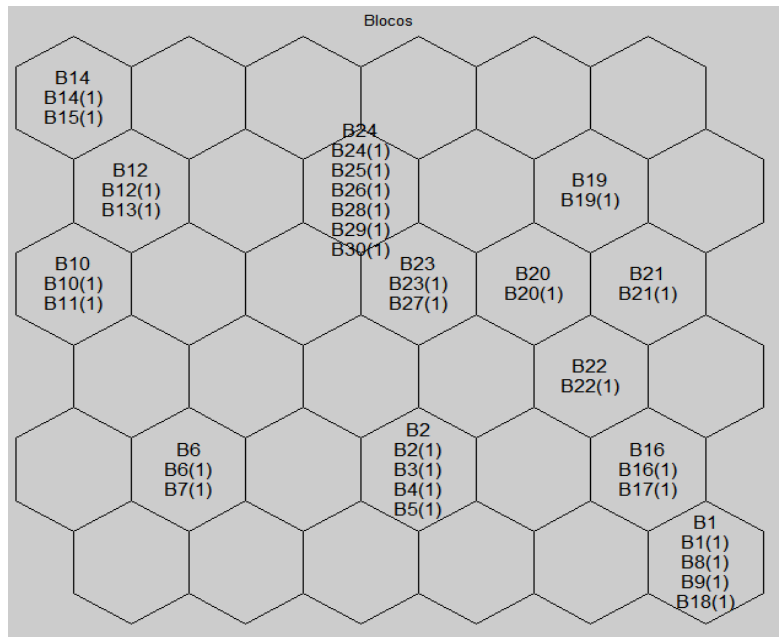
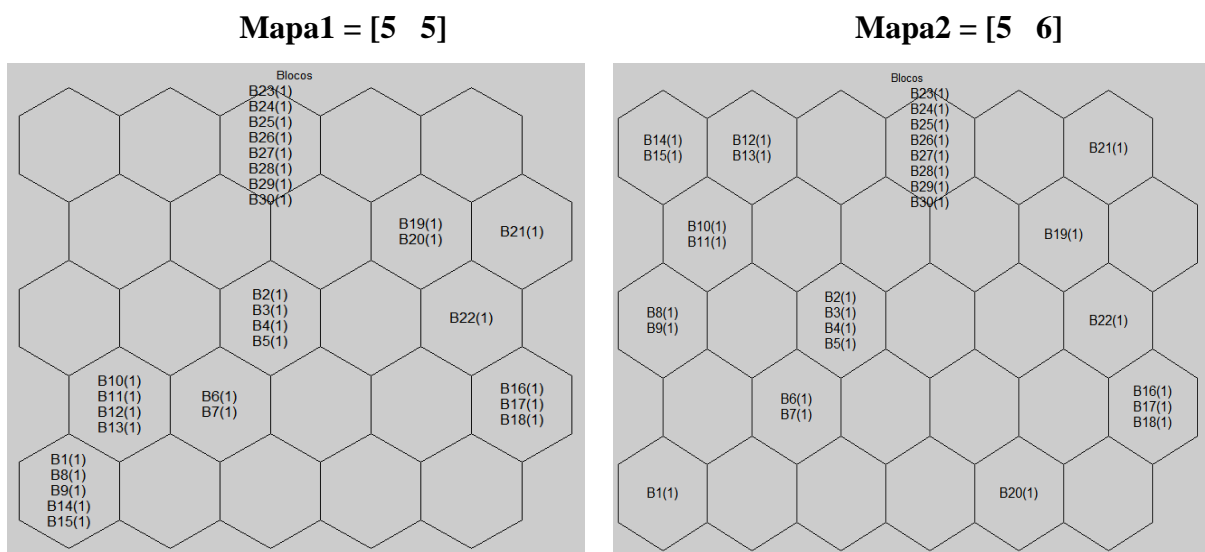


Figura 6.2 - BMU com o nº de vezes que o dado ocorreu
 Fonte: Barañano, 2011, Rio Grande.

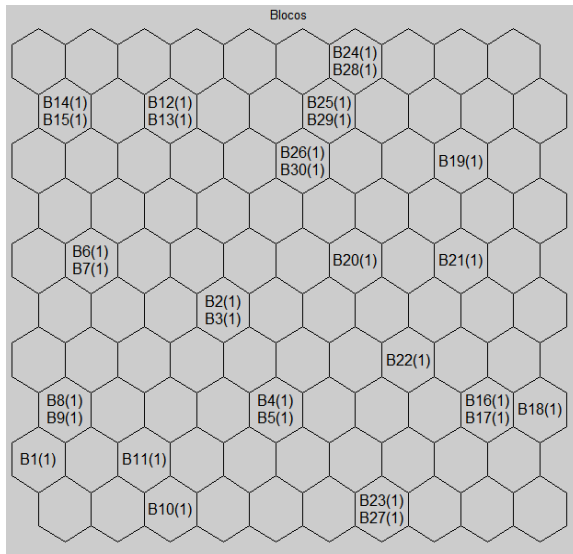
Este mapa (Fig. 6.2) nos mostra as BMUs rotuladas com o rótulo do dado para qual ela é BMU, adicionado do número de vezes que isto aconteceu (entre parênteses).

Sensibilidade do Método ao numero de Neurônios e a relação de vizinhança: Para verificar a influência do número de neurônios do mapa nos resultados, inicializamos o mapa com 4 tamanhos diferentes: um calculado conforme heurística da ferramenta, um mapa menor e dois mapas maiores do que o padrão da toolbox, conforme mostrado na Tabela 6.2.

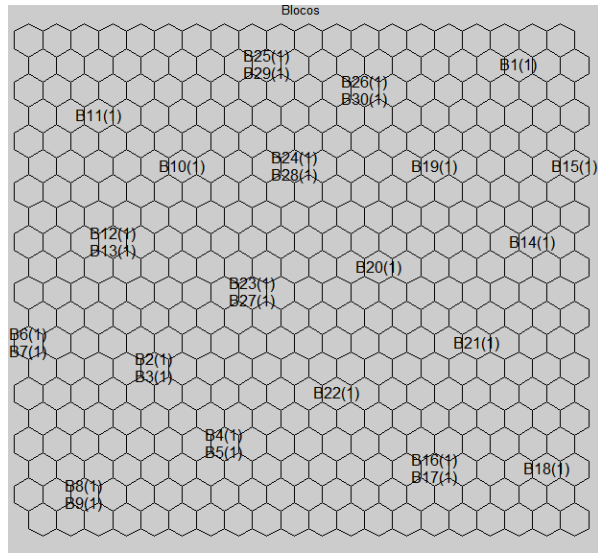
Tabela 6.2 – Mapas representativos do Banco de Dados



Mapa4 = [10 10]



Mapa5 = [20 20]



Fonte: Barañano, 2011, Rio Grande.

E para cada tamanho de mapa foi testada a relação de vizinhança retangular e hexagonal.

Tabela 6.3 – Erros médios de Quantização e Topográfico

	TAMANHO	HEX			RET		
		QE	TE	T(s)	QE	TE	T(s)
MAPA 1	5 5	1,248	0,167	10	1,248	0,167	0
MAPA 2	5 6	1,053	0,033	10	1,053	0,033	120
MAPA 3	6 6	0,942	0,100	10	0,942	0,100	0
MAPA 4	10 10	0,432	0,067	170	0,432	0,067	150
MAPA 5	20 20	0,002	0,033	840	0,002	0,033	826

Fonte: Barañano, 2011, Rio Grande.

Analisando a Tabela 6.3, optou-se por uma estrutura de vizinhança hexagonal, já que não houve variação significativa nos resultados aproximados dos dados de QE e TE em relação à vizinhança hexagonal ou retangular.

Observa-se ainda que à medida que os mapas vão ficando maiores o erro médio de quantização (QE), que corresponde à média das distâncias entre cada vetor de dados v_n e o correspondente vetor de pesos do neurônio BMU, cai significativamente. Induzindo-nos a concluir que quanto maior o número de neurônios maior sua capacidade de representar o conjunto de dados. Mas esta assertiva não é verdadeira, já que se arranjo possuir um número muito grande de neurônios, pode ocorrer de os neurônios posicionarem-se praticamente sobre os objetos a serem representados como pode ser observado nos mapas 4 e 5 da tabela acima. A segunda medida a ser avaliada para a escolha do melhor mapa é o Erro Topográfico (TE), que quantifica a capacidade do mapa de representar a topologia dos dados de entrada. Pode-se observar nos mapas 2,4 e 5 que esta representação tende a zero desclassificando estes mapas para análise. O correto é encontrar a melhor relação entre QE x TE para análise dos dados, tanto o mapa 1 como o mapa 3 apresenta uma boa relação entre estas medidas. Mas o mapa 3 apresenta um maior compromisso com a representação da topologia dos dados de entrada (TE) e à média das distâncias entre cada vetor de dados v_n e o correspondente vetor de pesos do neurônio (QE), que apresenta neste mapa um melhor valor. Então escolhemos o mapa 3 para realizar os demais testes.

Sensibilidade do Método a *somtoolbox*: Uma das principais funções do toolbox e também muito utilizada é a “*som_make*”. É uma função básica que cria, inicializa e treina um SOM com parâmetros default e em duas fases: a primeira fase é a de ordenação do mapa e a segunda é a fase de convergência.

Com esta linha de código os seguintes parâmetros são utilizados: algoritmo de treinamento (batch), função de inicialização (lininit), topologia dos neurônios (grade), formato de vizinhança (hexagonal), função de vizinhança (gaussiana), função para decréscimo da taxa de aprendizagem (inversa), raio inicial (1/8 do maior lado do mapa), raio final (valor padrão é 1, mas se for uma fase de ordenamento, o raio final corresponde a 1/4 do raio inicial), duração do treinamento (na fase de ordenamento é de 10 vezes a razão entre número de unidades e quantidade de dados e se for na fase de convergência o valor é 40 vezes esta mesma razão).

A função *som_make* foi utilizada para inicialização e treinamento da rede. Para entender o processo de clusterização, pode ser útil olhar para a Matriz U (Fig. 6.3). A Matriz U nada mais é do que a matriz de distâncias entre cada unidade (neurônio) do mapa e seus

vizinhos. Ao observarmos a matriz no plano 2D, ou ainda, a superfície formada por ela em 3D, podemos identificar regiões de agrupamento (vales) separadas umas das outras por picos.

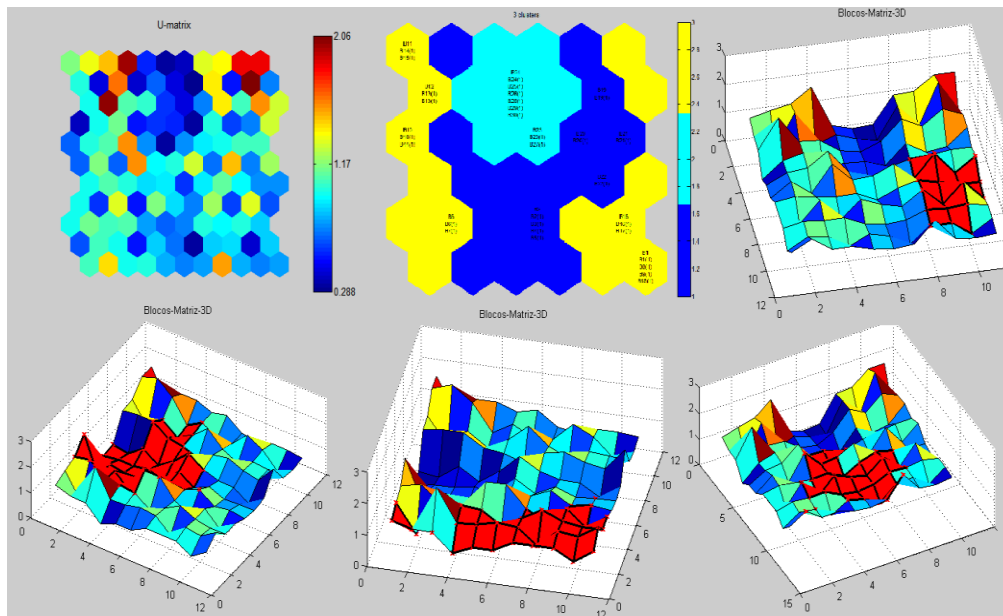


Figura 6.3 - Matriz U- 2D e 3D
 Fonte: Barañano, 2011, Rio Grande.

Um dos usos da Matriz U é servir como ponto de partida para o algoritmo de clusterização. Pois ela representa a distância entre cada neurônio e seus vizinhos, percebe-se que cada vez que há um pico, significa que os neurônios em cada um dos vales estão muito distantes uns dos outros. Indicando muito provavelmente que cada vale representa uma classe distinta e o pico é justamente a separação entre estas duas classes.

Outra forma de correlação disponível são os planos de cada um dos atributos, que nos possibilita fazer uma análise da correlação positiva e correlação negativa entre os atributos. Enquanto a correlação positiva é dada pelo mesmo padrão de cores, correlação negativa pode ser percebida por um padrão de cores invertido.

Observando a Fig. 6.4, percebe-se que as variáveis “Peso” e “Nº de Painéis” apresentam uma correlação negativa (padrão de cor invertido). Outra variável que apresenta correlação negativa é “Nº de Submontagens”. Já as variáveis “CS* na posição”, “CS* Vert” e “Volume”, são exemplos de correlação positiva. Todas estas correlações podem ser calculadas numericamente, mas são extremamente fáceis de perceber graficamente.

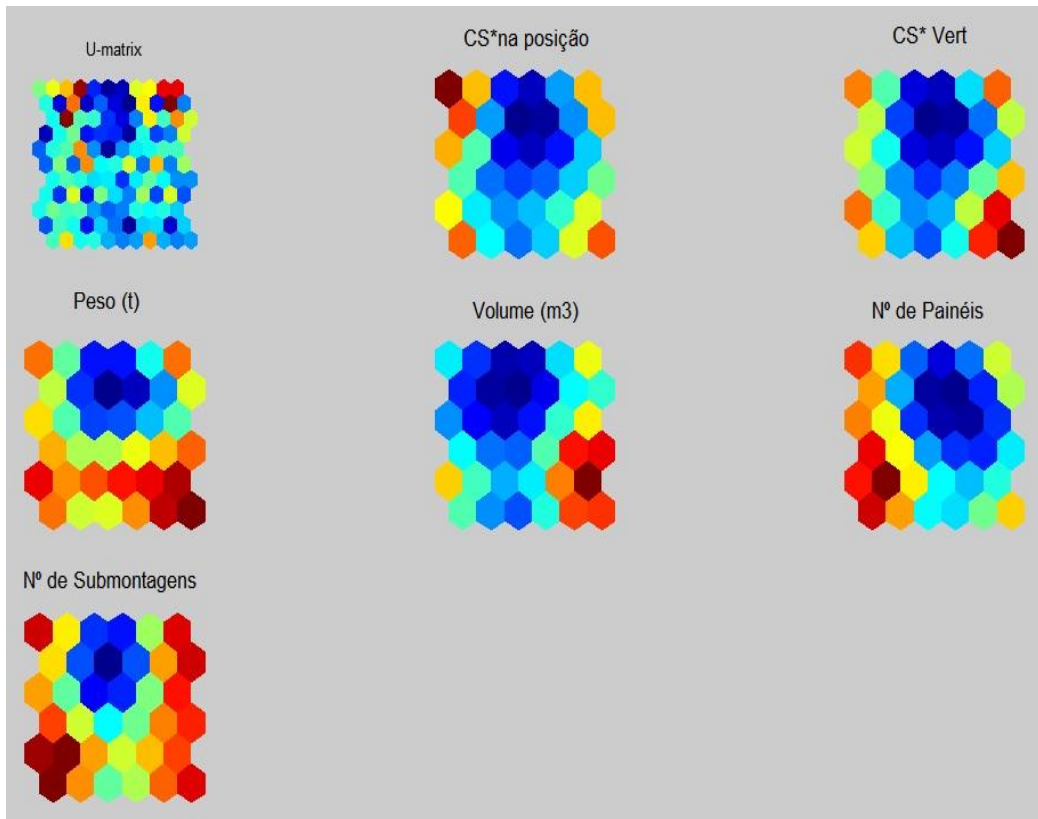


Figura 6.4 - Correlação dos planos de cada um dos atributos
Fonte: Barañano, 2011, Rio Grande.

Para este estudo foi utilizado o algoritmo de validação cruzada leave-one-out (LOO) para calcular os acertos dos modelos de redes neurais artificiais no processo de clusterização (Burnham; Anderson, 2004), com a utilização da função `som_supervised` do *toolbox*. Que a partir dos dados de treinamento produzidos pela `som_make` adiciona uma matriz codificada 1-de-N para os dados originais com base na informação de classe no campo de rótulos. A dimensão dos vetores após o processo é (a dimensão antiga + número de classes diferentes). No algoritmo LOO, $N - 1$ exemplos são usados para treinar o modelo, e este é validado testando-o sobre o exemplo deixado de fora. O experimento é repetido para um total de N vezes, cada vez deixando de fora um exemplo diferente para a validação (Burnham; Anderson, 2004). Como resultado obtemos o mapa da (Fig. 6.5).

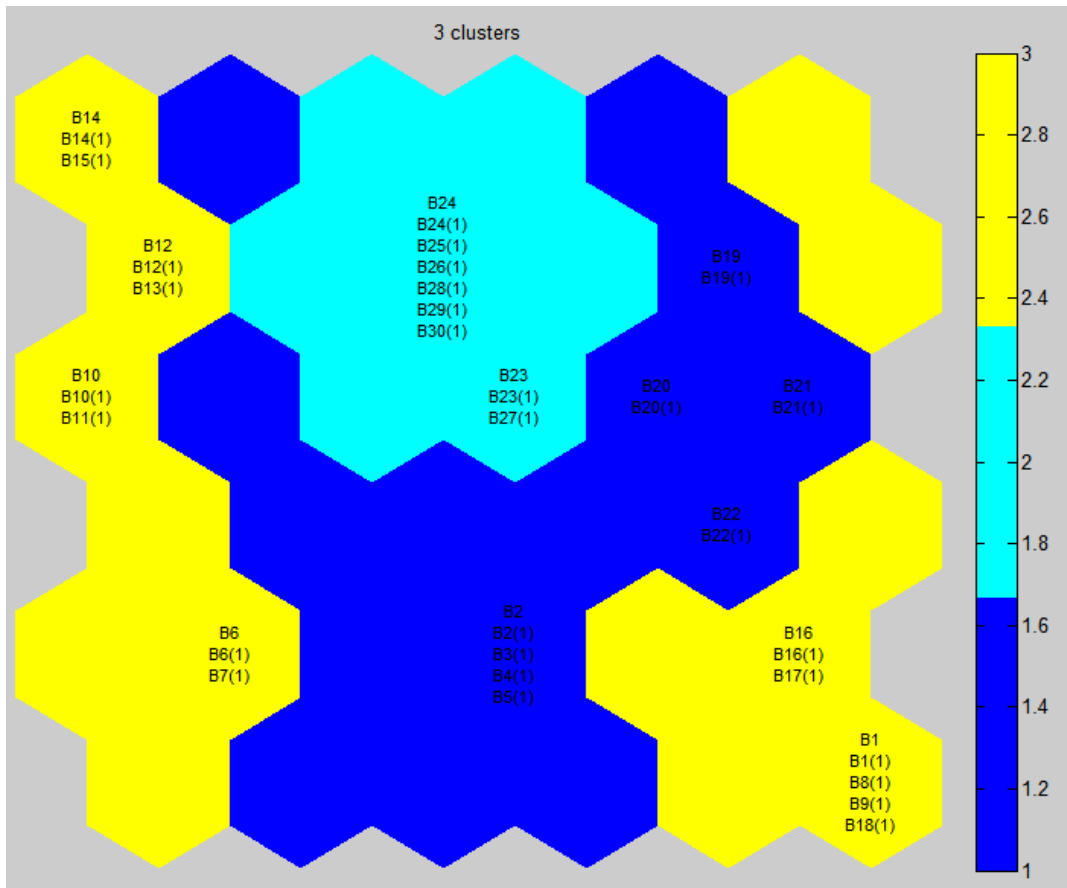


Figura 6.5 - Clusterização dos dados
 Fonte: Barañano, 2011, Rio Grande.

O 3º passo é usarmos o mapa resultante, que define o número ideal de classes Tabela 6.4 como entrada no algoritmo de classificação *Backpropagation*.

Tabela 6.4 - Número ideal de Classes

CLASSES	BLOCOS	NÚMERO DE ELEMENTOS
1	B23, 24, 25, 26, 27, 28, 29 e 30	8
2	B2, 3, 4, 5, 19, 20, 21 e 22	8
3	B1, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 e 18	14

Fonte: Barañano, 2011, Rio Grande.

O número ideal de classes está associado com o número de linhas de produção específicas que serão planejadas para implementação de um projeto. Pode-se também fixar o número de classes para determinada família de produtos de acordo com os recursos produtivos existentes, mas é um problema diferente já abordado em outros estudos (Souza, 2009) e não está considerado no objetivo deste trabalho.

6.2.2 Classificador: Algoritmo *Backpropagation*

A partir da definição do número ideal de classes, conforme Tabela 6.4, é utilizado o modelo de rede neural MLP-BP para treinamento dos dados, após a validação da RN para um conjunto de dados específico, é necessário que sejam salvos sua topologia e seus principais parâmetros de conexão. Feito isso, é possível classificar qualquer novo conjunto de dados sem esforço adicional de treinamento e validação.

Os dados de entrada utilizados foram os mesmos do modelo de rede neural SOM-*Kohonen*, aprendizado não-supervisionado (Tabela 6.1). Os dados foram utilizados na proporção de 70% para treinamento, 15% para teste e 15% para validação da rede.

A Implementação da MLP no MatLab:

Inicialização: Conforme visto no capítulo 5, os pesos das conexões entre as camadas da rede serão inicializados com valores aleatórios e pequenos para que se evite a saturação da função de ativação e a conseqüente incapacidade de realizar a aprendizagem.

O algoritmo de treinamento é o gradiente descendente ‘traingd’, **a função de ativação e de saída** é a tangente hiperbólica sigmóide ‘tansig’. Para **avaliação de desempenho** foram observados os valores de erro médio quadrático (MSE-*Mean Square Error*).

Os dados foram normalizados para intervalos entre [-1 1]. As variáveis normalizadas transformadas foram utilizadas nos modelos porque representam o conjunto de dados de uma forma mais simples e efetiva.




Figura 6.6 - Rede Neural MLP-BP
 Fonte: Barañano, 2011, Rio Grande.

Topologia da Rede. O modelo de rede neural (Fig. 6.6) utilizado foi configurado com $D=6$ neurônios na camada de entrada, uma camada oculta testada com $m = 5, 10, 15$ e 20 neurônios respectivamente, sendo esta camada definida conforme a avaliação dos resultados obtidos para a melhor topologia para o treinamento, testes e validação da rede. E uma camada de saída com $n = 3$ neurônios de acordo com a definição do número ideal de classes obtidas pelo modelo de RN SOM-Kohonen.

Taxa de Aprendizado. A rede foi testada com taxas de aprendizagem de $0,1$, $0,05$ e $0,01$ respectivamente.

Sensibilidade da MLP ao número de neurônios na camada escondida. Foram realizados um conjunto de testes onde a MLP foi treinada com diferente número de neurônios na camada escondida, descritos a seguir:

REDE 01 – 5 neurônios na camada escondida. Foram realizados 3 experimentos cada qual com diferentes taxas de aprendizado: $0,1$, $0,05$ e $0,01$. Função de treinamento: Algoritmo *backpropagation* gradiente descendente ‘traingd’; Função de Aprendizagem e Adaptação: algoritmo descendente com *momentum* dos pesos e função de aprendizagem dos *bias*, ‘learnngdm’.

A Tabela 6.5 apresenta um resumo do comportamento da MLP frente ao aprendizado e reconhecimento. A Tabela 6.6 resume os resultados obtidos frente às diferentes taxas de aprendizado. É possível observar que a rede tem capacidade de aprender.

Tabela 6.5 - Comportamento da MLP frente ao aprendizado

Resultados para a Rede 01			
Sensibilidade da rede MLP a 05 neurônios na camada escondida			
Taxa de Aprendizado	MSE	Épocas	Validações
0,01	0,0178	10.000	0
0,05	0,00159	10.000	0
0,1	0,663	163 iterações de 10.000	6

Fonte: Barañano, 2011, Rio Grande.

Tabela 6.6 - Resultados obtidos frente às diferentes taxas de aprendizado na Rede 01

BLOCOS	METAS	SAIDAS – Tx. 0,01	SAIDAS – Tx. 0,05	SAIDAS – Tx. 0,1
B1	1 -1 -1	0.9689 -0.7725 -0.9014	0.9876 -0.9463 -0.9995	0.2379 -0.7815 -0.9954
B2	-1 1 -1	-0.9139 0.8627 -0.9545	-0.9694 0.8894 -0.9290	-0.4804 -0.8800 -0.9973
B3	-1 1 -1	-0.9139 0.8627 -0.9545	-0.9694 0.8894 -0.9290	-0.4804 -0.8800 -0.9973
B4	-1 1 -1	-0.8097 0.6964 -0.9611	-0.6078 0.2270 -0.9731	-0.0083 -0.7828 -0.9959
B5	-1 1 -1	-0.8097 0.6964 -0.9611	-0.6078 0.2270 -0.9731	-0.0083 -0.7828 -0.9959
B6	1 -1 -1	0.5631 -0.6558 -0.9794	0.9127 -0.9270 -0.9984	0.0916 -0.3746 -0.9697
B7	1 -1 -1	0.5631 -0.6558 -0.9794	0.9127 -0.9270 -0.9984	0.0916 -0.3746 -0.9697
B8	1 -1 -1	0.9524 -0.9639 -0.9845	0.9972 -0.9998 -0.9718	0.8540 -0.7223 -0.9467
B9	1 -1 -1	0.9524 -0.9639 -0.9845	0.9972 -0.9998 -0.9718	0.8540 -0.7223 -0.9467
B10	1 -1 -1	0.9914 -0.9680 -0.9721	0.9904 -0.9740 -0.9992	0.9405 -0.9225 -0.9689
B11	1 -1 -1	0.9992 -0.9939 -0.9689	0.9962 -0.9933 -0.9989	0.9457 -0.9134 -0.9701
B12	1 -1 -1	0.9998 -0.9978 -0.9688	0.9960 -0.9823 -0.9996	0.9609 -0.9260 -0.9606
B13	1 -1 -1	0.9998 -0.9978 -0.9688	0.9960 -0.9823 -0.9996	0.9609 -0.9260 -0.9606
B14	1 -1 -1	0.9990 -0.9394 -0.9133	0.9647 -0.8751 -0.9999	0.7677 -0.7508 -0.9063
B15	1 -1 -1	1.0000 -0.9997 -0.8581	0.9965 -0.9762 -0.9998	0.7070 -0.8159 -0.8589
B16	1 -1 -1	0.8777 -0.8963 -0.9847	0.9938 -0.9991 -0.9892	0.7371 -0.5736 -0.8841
B17	1 -1 -1	0.8777 -0.8963 -0.9847	0.9938 -0.9991 -0.9892	0.7371 -0.5736 -0.8841
B18	1 -1 -1	0.8696 -0.8857 -0.9851	0.9932 -0.9967 -0.9972	0.7332 -0.5289 -0.9227
B19	-1 1 -1	-0.9707 0.9864 -0.9851	-0.9846 0.9997 -1.0000	-0.9037 0.8782 -0.9922
B20	-1 1 -1	-0.7835 0.7521 -0.9769	-0.9063 0.9485 -0.9992	-0.4792 -0.0693 -0.9904
B21	-1 1 -1	-0.9757 0.9864 -0.9851	-0.9956 0.9998 -1.0000	-0.6963 0.5585 -0.9922

B22	-1	1	-1	-0.6386	0.7918	-0.9896	-0.9206	0.9272	-1.0000	0.3818	0.4836	-0.8797
B23	-1	-1	1	-0.9301	-0.8522	0.9528	-0.9725	-0.9530	0.9508	-0.9309	-0.8509	-0.9994
B24	-1	-1	1	-0.9491	-0.8880	0.9792	-0.9752	-0.9635	0.9666	-0.9636	-0.7309	-0.9997
B25	-1	-1	1	-0.9491	-0.9042	0.9862	-0.9754	-0.9661	0.9696	-0.9553	-0.8640	-0.9994
B26	-1	-1	1	-0.9272	-0.9396	0.9860	-0.9763	-0.9678	0.9719	-0.9789	-0.6108	-0.9997
B27	-1	-1	1	-0.9301	-0.8522	0.9528	-0.9725	-0.9530	0.9508	-0.9309	-0.8509	-0.9994
B28	-1	-1	1	-0.9491	-0.8880	0.9792	-0.9752	-0.9635	0.9666	-0.9636	-0.7309	-0.9997
B29	-1	-1	1	-0.9491	-0.9042	0.9862	-0.9754	-0.9661	0.9696	-0.9553	-0.8640	-0.9994
B30	-1	-1	1	-0.9272	-0.9396	0.9860	-0.9763	-0.9678	0.9719	-0.9789	-0.6108	-0.9997

Fonte: Barañano, 2011, Rio Grande.

REDE 02 – 10 neurônios na camada escondida. Foram realizados 3 experimentos cada qual com diferentes taxas de aprendizado: 0.1, 0.05 e 0.001. A Tabela 6.7 apresenta um resumo do comportamento da MLP frente ao aprendizado e reconhecimento. A Tabela 6.8 resume os resultados obtidos frente às diferentes taxas de aprendizado.

Parâmetros –

Função de treinamento: Algoritmo *backpropagation* gradiente descendente ‘traingd’;

Função de Aprendizagem e Adaptação: algoritmo descendente com *momentum* dos pesos e função de aprendizagem dos *bias*, ‘learnngdm’.

Tabela 6.7 - Comportamento da MLP frente ao aprendizado

Resultados para a Rede 02			
Sensibilidade da rede MLP a 10 neurônios na camada escondida			
Taxa de Aprendizado	MSE	Épocas	Validações
0,01	0,0126	9197 iterações de 10.000	6
0,05	0,226	146 iterações de 10.000	6
0,1	0,000697	10.000 iterações de 10.000	0

Fonte: Barañano, 2011, Rio Grande.

Tabela 6.8 - Resultados obtidos frente às diferentes taxas de aprendizado na Rede 02

BLOCOS	METAS	SAIDAS – Tx.0,01	SAIDAS – Tx.0,05	SAIDAS – Tx.0,1
B1	1 -1 -1	0.9547 -0.8657 -0.9324	0.7646 -0.6712 -0.8618	0.9751 -0.9663 -0.9982
B2	-1 1 -1	-0.7686 0.7794 -0.9128	-0.3292 -0.4590 -0.7209	-0.9946 0.9813 -0.9735
B3	-1 1 -1	-0.7686 0.7794 -0.9128	-0.3292 -0.4590 -0.7209	-0.9946 0.9813 -0.9735
B4	-1 1 -1	0.3210 -0.3153 -0.9326	0.0717 -0.3896 -0.7532	-0.9672 0.9542 -0.9900
B5	-1 1 -1	0.3210 -0.3153 -0.9326	0.0717 -0.3896 -0.7532	-0.9672 0.9542 -0.9900
B6	1 -1 -1	0.7174 -0.8066 -0.9494	0.0510 -0.1049 -0.8393	0.9196 -0.9143 -0.9974
B7	1 -1 -1	0.7174 -0.8066 -0.9494	0.0510 -0.1049 -0.8393	0.9196 -0.9143 -0.9974
B8	1 -1 -1	0.9998 -0.9999 -0.9900	0.7197 -0.7889 -0.8913	0.9999 -1.0000 -0.9950
B9	1 -1 -1	0.9998 -0.9999 -0.9900	0.7197 -0.7889 -0.8913	0.9999 -1.0000 -0.9950
B10	1 -1 -1	0.9987 -0.9988 -0.9872	0.6318 -0.8459 -0.8465	0.9839 -0.9994 -0.9912
B11	1 -1 -1	0.9998 -0.9998 -0.9841	0.7733 -0.8653 -0.8418	0.9991 -1.0000 -0.9912
B12	1 -1 -1	0.9998 -0.9998 -0.9919	0.6903 -0.8999 -0.8845	0.9983 -1.0000 -0.9950
B13	1 -1 -1	0.9998 -0.9998 -0.9919	0.6903 -0.8999 -0.8845	0.9983 -1.0000 -0.9950
B14	1 -1 -1	0.8545 -0.8761 -0.9977	-0.1049 0.0293 -0.8617	0.9815 -0.9840 -0.9969
B15	1 -1 -1	0.9992 -0.9990 -0.9944	0.7743 -0.3519 -0.9166	0.9980 -0.9998 -0.9951
B16	1 -1 -1	0.9953 -0.9965 -0.9840	0.4198 -0.4453 -0.9335	0.9976 -0.9987 -0.9984
B17	1 -1 -1	0.9953 -0.9965 -0.9840	0.4198 -0.4453 -0.9335	0.9976 -0.9987 -0.9984
B18	1 -1 -1	0.9959 -0.9972 -0.9830	0.4521 -0.3673 -0.9310	0.9983 -0.9986 -0.9990
B19	-1 1 -1	-0.9882 0.9995 -0.9591	-0.6514 0.6751 -0.8823	-0.9948 0.9994 -0.9945
B20	-1 1 -1	-0.7390 0.7761 -0.9641	-0.0498 -0.0625 -0.8159	-0.9422 0.9515 -0.9921
B21	-1 1 -1	-0.9880 0.9968 -0.9716	-0.2096 0.2119 -0.9039	-0.9906 0.9988 -0.9985
B22	-1 1 -1	-0.7307 0.8127 -0.9779	0.0326 -0.0834 -0.9623	-0.9570 0.9452 -0.9927
B23	-1 -1 1	-0.8236 -0.9239 0.6338	-0.9252 -0.7127 0.6948	-0.9976 -0.9605 0.9719
B24	-1 -1 1	-0.9441 -0.9051 0.9178	-0.9553 -0.6909 0.8075	-0.9978 -0.9607 0.9876
B25	-1 -1 1	-0.9410 -0.9412 0.9321	-0.9685 -0.8644 0.8742	-0.9970 -0.9943 0.9984
B26	-1 -1 1	-0.9737 -0.9561 0.9649	-0.9725 -0.8446 0.8796	-0.9879 -0.9987 0.9989
B27	-1 -1 1	-0.8236 -0.9239 0.6338	-0.9252 -0.7127 0.6948	-0.9976 -0.9605 0.9719
B28	-1 -1 1	-0.9441 -0.9051 0.9178	-0.9553 -0.6909 0.8075	-0.9978 -0.9607 0.9876
B29	-1 -1 1	-0.9410 -0.9412 0.9321	-0.9685 -0.8644 0.8742	-0.9970 -0.9943 0.9984
B30	-1 -1 1	-0.9737 -0.9561 0.9649	-0.9725 -0.8446 0.8796	-0.9879 -0.9987 0.9989

Fonte: Barañano, 2011, Rio Grande.

REDE 03 – 15 neurônios na camada escondida. Foram realizados 3 experimentos cada qual com diferentes taxas de aprendizado: 0.1, 0.05 e 0.01. A Tabela 6.9 e 6.10 apresentam um resumo do comportamento da MLP frente ao aprendizado e reconhecimento. A Tabela 6.11 resume os resultados obtidos frente às diferentes taxas de aprendizado.

Parâmetros –

Função de treinamento: Algoritmo *backpropagation* gradiente descendente ‘traingd’;

Função de Aprendizagem e Adaptação: algoritmo descendente com *momentum* dos pesos e função de aprendizagem dos *bias*, ‘learngdm’.

Tabela 6.9 - Comportamento da MLP frente ao aprendizado

Resultados para a Rede 03			
Sensibilidade da rede MLP a 15 neurônios na camada escondida			
Taxa de Aprendizado	MSE	Épocas	Validações
0,01	0,766	568 iterações de 10.000	0
0,05	0,122	122 iterações de 10.000	6

Fonte: Barañano, 2011, Rio Grande.

Tabela 6.10 - Comportamento da MLP frente ao aprendizado

Resultados para a Rede 03			
Sensibilidade da rede MLP a 15 neurônios na camada escondida e taxa de aprendizado de 0,1			
MSE	Épocas	DESEMPENHO DA REDE (MSE) - ESTADO DE TREINAMENTO DA REDE	Validações
0,00216	3459 iterações de 10.000	<p style="text-align: center;">Best Validation Performance is 0.036696 at epoch 3453</p>	6
		<p style="text-align: center;">Gradient = 0.00303223, at epoch 3459</p> <p style="text-align: center;">Validation Checks = 6, at epoch 3459</p>	

Fonte: Barañano, 2011, Rio Grande.

Tabela 6.11 - Resultados obtidos frente às diferentes taxas de aprendizado na Rede 03

BLOCOS	METAS	SAIDAS – Tx.0,01	SAIDAS – Tx.0,05	SAIDAS – Tx. 0,1
B1	1 -1 -1	0.7311 -0.9643 -0.9411	0.2197 -0.8249 -0.8739	0.8174 -0.9588 -0.9526
B2	-1 1 -1	-0.5860 -0.9979 -0.9993	-0.4548 0.2555 -0.8735	-0.9870 0.9816 -0.9946
B3	-1 1 -1	-0.5860 -0.9979 -0.9993	-0.4548 0.2555 -0.8735	-0.9870 0.9816 -0.9946
B4	-1 1 -1	-0.5160 -0.9978 -0.9993	-0.3950 0.0508 -0.8886	-0.9038 0.9081 -0.9952
B5	-1 1 -1	-0.5160 -0.9978 -0.9993	-0.3950 0.0508 -0.8886	-0.9038 0.9081 -0.9952
B6	1 -1 -1	-0.7683 -0.9995 -0.9989	0.1924 -0.1058 -0.9607	0.8400 -0.8533 -0.9926
B7	1 -1 -1	-0.7683 -0.9995 -0.9989	0.1924 -0.1058 -0.9607	0.8400 -0.8533 -0.9926
B8	1 -1 -1	0.8318 -0.9930 -0.9948	0.7362 -0.8817 -0.7834	0.9995 -0.9994 -0.9944
B9	1 -1 -1	0.8318 -0.9930 -0.9948	0.7362 -0.8817 -0.7834	0.9995 -0.9994 -0.9944
B10	1 -1 -1	0.6754 -0.9847 -0.9977	0.4511 -0.8340 -0.8764	0.9456 -0.9498 -0.9891
B11	1 -1 -1	0.8766 -0.9615 -0.9884	0.6097 -0.9421 -0.8875	0.9982 -0.9991 -0.9668
B12	1 -1 -1	0.8309 -0.9711 -0.9946	0.6464 -0.9283 -0.8999	0.9944 -0.9933 -0.9887
B13	1 -1 -1	0.8309 -0.9711 -0.9946	0.6464 -0.9283 -0.8999	0.9944 -0.9933 -0.9887
B14	1 -1 -1	0.8843 -0.9492 -0.9934	0.9284 -0.5080 -0.8762	0.8941 -0.2060 -0.9997
B15	1 -1 -1	0.9961 -0.6585 -0.7459	0.9698 -0.9333 -0.9248	0.9964 -0.9295 -0.9989
B16	1 -1 -1	0.4021 -0.9973 -0.9954	0.8155 -0.6879 -0.9220	0.9964 -0.9917 -0.9967
B17	1 -1 -1	0.4021 -0.9973 -0.9954	0.8155 -0.6879 -0.9220	0.9964 -0.9917 -0.9967
B18	1 -1 -1	0.3649 -0.9973 -0.9954	0.6887 -0.6755 -0.9123	0.9976 -0.9950 -0.9970
B19	-1 1 -1	-0.6092 -0.9927 -0.9888	0.5822 0.7523 -0.9940	-0.9970 0.9998 -0.9969
B20	-1 1 -1	-0.8454 -0.9995 -0.9992	-0.2369 0.2875 -0.9698	-0.9117 0.9124 -0.9930
B21	-1 1 -1	-0.8576 -0.9994 -0.9984	0.0951 0.6584 -0.9898	-0.9901 0.9977 -0.9963
B22	-1 1 -1	-0.4856 -0.9992 -0.9977	0.9231 0.1591 -0.9803	-0.8970 0.9006 -0.9575
B23	-1 -1 1	-0.9254 -0.9993 -0.9995	-0.9427 -0.7993 0.7244	-0.9663 -0.9990 0.9637
B24	-1 -1 1	-0.9354 -0.9996 -0.9996	-0.9584 -0.7604 0.8498	-0.9994 -0.9743 0.9946
B25	-1 -1 1	-0.9615 -0.9988 -0.9991	-0.9606 -0.9607 0.7962	-0.9981 -0.9980 0.9978
B26	-1 -1 1	-0.9665 -0.9995 -0.9993	-0.8869 -0.9550 0.8822	-0.9996 -0.9858 0.9976
B27	-1 -1 1	-0.9254 -0.9993 -0.9995	-0.9427 -0.7993 0.7244	-0.9663 -0.9990 0.9637
B28	-1 -1 1	-0.9354 -0.9996 -0.9996	-0.9584 -0.7604 0.8498	-0.9994 -0.9743 0.9946
B29	-1 -1 1	-0.9615 -0.9988 -0.9991	-0.9606 -0.9607 0.7962	-0.9981 -0.9980 0.9978
B30	-1 -1 1	-0.9665 -0.9995 -0.9993	-0.8869 -0.9550 0.8822	-0.9996 -0.9858 0.9976

Fonte: Barañano, 2011, Rio Grande.

REDE 04 – 20 neurônios na camada escondida. Foram realizados 3 experimentos cada qual com diferentes taxas de aprendizado: 0.1, 0.05 e 0.01. A Tabela 6.12 apresenta um resumo do comportamento da MLP frente ao aprendizado e reconhecimento. A Tabela 6.13 resume os resultados obtidos frente às diferentes taxas de aprendizado.

Parâmetros –

Função de treinamento: Algoritmo *backpropagation* gradiente descendente ‘traingd’;

Função de Aprendizagem e Adaptação: algoritmo descendente com *momentum* dos pesos e função de aprendizagem dos *bias*, ‘learngdm’.

Tabela 6.12 - Comportamento da MLP frente ao aprendizado

Resultados para a Rede 04			
Sensibilidade da rede MLP a 20 neurônios na camada escondida			
Taxa de Aprendizado	MSE	Épocas	Validações
0,01	0,389	520 iterações de 10.000 épocas	6
0,05	0,00109	10.000 iterações	0
0,1	0,000168	10.000 iterações	0

Fonte: Barañano, 2011, Rio Grande.

Tabela 6.13 - Resultados obtidos frente às diferentes taxas de aprendizado na Rede 04

BLOCOS	METAS	SAIDAS – Tx.0,01	SAIDAS – Tx.0,05	SAIDAS – Tx.0,1
B1	1 -1 -1	0.9764 0.4854 -0.8450	0.9915 -0.9792 -0.9958	0.9712 -0.9727 -0.9905
B2	-1 1 -1	0.9765 0.5589 -0.7617	-0.9966 0.9968 -0.9906	-0.9909 0.9868 -0.9876
B3	-1 1 -1	0.9765 0.5589 -0.7617	-0.9966 0.9968 -0.9906	-0.9909 0.9868 -0.9876
B4	-1 1 -1	0.9652 0.3250 -0.8919	-0.9560 0.9540 -0.9931	-0.9634 0.9617 -0.9929
B5	-1 1 -1	0.9652 0.3250 -0.8919	-0.9560 0.9540 -0.9931	-0.9634 0.9617 -0.9929
B6	1 -1 -1	0.7923 -0.1816 -0.8410	0.8959 -0.8940 -0.9909	-0.9704 0.9666 -0.9978
B7	1 -1 -1	0.7923 -0.1816 -0.8410	0.8959 -0.8940 -0.9909	-0.9704 0.9666 -0.9978
B8	1 -1 -1	0.3923 -0.9262 -0.7834	0.9990 -0.9995 -0.9678	0.9994 -0.9990 -0.9987
B9	1 -1 -1	0.3923 -0.9262 -0.7834	0.9990 -0.9995 -0.9678	0.9994 -0.9990 -0.9987
B10	1 -1 -1	0.8415 -0.6991 -0.6683	0.9645 -0.9703 -0.9879	0.9795 -0.9899 -0.9898
B11	1 -1 -1	0.9112 -0.7363 -0.6439	0.9998 -0.9996 -0.9957	0.9957 -0.9978 -0.9890
B12	1 -1 -1	0.9254 -0.8780 -0.3192	0.9945 -0.9958 -0.9894	0.9980 -0.9986 -0.9941
B13	1 -1 -1	0.9254 -0.8780 -0.3192	0.9945 -0.9958 -0.9894	0.9980 -0.9986 -0.9941
B14	1 -1 -1	0.9707 -0.8779 -0.0004	0.9707 -0.9688 -0.9920	0.9992 -0.9987 -0.9989
B15	1 -1 -1	0.9890 -0.9456 0.3370	0.9749 -0.9853 -0.9920	0.9995 -0.9983 -0.9958
B16	1 -1 -1	0.4839 -0.6780 -0.8160	0.9949 -0.9985 -0.9746	0.9851 -0.9830 -0.9990
B17	1 -1 -1	0.4839 -0.6780 -0.8160	0.9949 -0.9985 -0.9746	0.9851 -0.9830 -0.9990
B18	1 -1 -1	0.6008 -0.7269 -0.8111	0.9975 -0.9983 -0.9880	0.9878 -0.9796 -0.9992
B19	-1 1 -1	0.9594 0.8280 -0.8839	-0.9489 0.9982 -0.9960	-0.9963 0.9945 -0.9895
B20	-1 1 -1	0.9355 0.0522 -0.8467	-0.9268 0.9307 -0.9910	-0.9914 0.9927 -0.9977
B21	-1 1 -1	0.9377 0.4593 -0.8946	-0.9884 0.9970 -0.9972	-0.9993 0.9996 -0.9983
B22	-1 1 -1	0.3106 0.2532 -0.8468	-0.9427 0.9295 -0.9789	-0.9832 0.9798 -0.9984
B23	-1 -1 1	-0.6135 -0.8661 0.4670	-0.9747 -0.9857 0.9663	-0.9945 -0.9604 0.9399
B24	-1 -1 1	-0.8640 -0.8117 0.6649	-0.9875 -0.9818 0.9840	-0.9986 -0.9842 0.9868
B25	-1 -1 1	-0.9658 -0.9678 0.8632	-0.9895 -0.9939 0.9950	-0.9966 -0.9987 0.9989
B26	-1 -1 1	-0.9695 -0.9435 0.8084	-0.9925 -0.9872 0.9940	-0.9933 -0.9993 0.9996
B27	-1 -1 1	-0.6135 -0.8661 0.4670	-0.9747 -0.9857 0.9663	-0.9945 -0.9604 0.9399
B28	-1 -1 1	-0.8640 -0.8117 0.6649	-0.9875 -0.9818 0.9840	-0.9986 -0.9842 0.9868
B29	-1 -1 1	-0.9658 -0.9678 0.8632	-0.9895 -0.9939 0.9950	-0.9966 -0.9987 0.9989
B30	-1 -1 1	-0.9695 -0.9435 0.8084	-0.9925 -0.9872 0.9940	-0.9933 -0.9993 0.9996

Fonte: Barañano, 2011, Rio Grande.

6.3 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados um conjunto de testes onde a metodologia apresentada no capítulo 5 foi aplicada. A metodologia foi implementada através da ferramenta Matlab. Os testes são baseados em um histórico real de informações estruturais de blocos de um navio Suezmax. Uma etapa de obtenção automática das famílias foi inicialmente realizada com a rede SOM. Após, de posse dos grupos, uma MLP foi desenvolvida de forma a classificar o histórico de bloco em uma das famílias resultantes.

Vários testes com a rede SOM, verificando a sua sensibilidade frente a vários parâmetros, foram realizados. A melhor rede foi escolhida fornecendo o conjunto de famílias presentes no universo de entrada. A rede SOM forneceu a base de treinamento para o histórico de blocos. Cada bloco foi associado a uma família.

Utilizou-se a rede MLP para aprender esta associação. O avaliador de desempenho utilizado para avaliar os resultados das redes neurais simuladas foi o MSE. A Tabela 6.9 apresenta o comportamento de suas saídas para o conjunto de treinamento, validação e teste. Uma vez finalizado o processo de aprendizado a rede escolhida é utilizada para classificação. A Tabela 6.10 apresenta a saída desta rede para o conjunto completo de blocos presentes no histórico. Verifica-se que a rede classificou corretamente todos os elementos existentes, incluindo aqueles utilizados para aprendizado, validação e teste.

Durante o treinamento, foram testadas várias topologias e taxas de aprendizado. Onde o MSE normalmente começa com valores altos e então decresce conforme aumenta o número de épocas. No final, o MSE se mantém praticamente constante e a rede neural converge.

Foi observado também o desempenho das redes a capacidade de generalização, que pode ser avaliada através dos exemplos de validação que não foram usados durante o treinamento. Já que quando uma rede é treinada excessivamente, a mesma pode perder a sua capacidade de generalização, conforme mostrado no capítulo 5. Este fenômeno é denominado super treinamento (*overfitting*), aonde o erro durante os treinos são bastante pequenos, porém podem ser grandes quando novos dados são apresentados a rede (Hou, 1998).

Desta forma para projetar uma RNA com bom poder de generalização, utilizou-se um conjunto de validação durante o processo de treinamento de forma a determinar qual momento exato de se interromper o mesmo. Esse método conhecido como o método da parada antecipada (Early Stopping), testa a rede com os dados de validação após cada época.

Nas diversas redes testadas a que obteve melhor capacidade de generalização dos dados apresentados foi a que apresenta a topologia de 15 neurônios na camada oculta, taxa de aprendizado (η) de 0,1, algoritmo de treinamento ‘traingd’, de aprendizagem ‘learnngdm’ e função de ativação e de saída - tangente hiperbólica sigmóide ‘tansig’ (Os demais valores não citados são Default’s da ferramenta utilizada para treinamento, validação e teste). Sendo a parada da rede determinada pelo conjunto de validação na iteração 3459 de 10.000 épocas, MSE de treinamento igual a 0,0030323, MSE de teste igual a 0,00216 e MSE de validação igual a 0,036696. As demais arquiteturas de redes testadas apesar de apresentarem capacidade de aprender, não atingiram com igual desempenho de forma simultânea todos os objetivos propostos pelo o algoritmo *backpropagation*.

A partir dos dados específicos presentes no histórico, obteve-se a topologia e parâmetros da melhor RN que classificou seus elementos. Esta pode ser usada para classificar qualquer novo conjunto de dados sem esforço adicional de treinamento.

7. CONCLUSÃO

Esta dissertação desenvolveu-se de forma a abordar melhores práticas gerenciais para construção de navios com o uso de ferramentas de análise inteligente, norteando desta forma novos conceitos tecnológicos para planejamento e gestão da produção na construção de navios. De forma mais precisa foram estudados conceitos de produção por famílias de produtos, tendo sido proposta uma metodologia para agrupamento e classificação automática de produtos intermediários no processo de produção de navios para um estaleiro.

Inicialmente foram apresentadas as diversas etapas de construção de um navio, com especial atenção na edificação estrutural do casco. Para que fosse possível um maior entendimento das peculiaridades da indústria da construção naval foi apresentada a evolução dos procedimentos de construção de um navio e a divisão das estruturas de trabalho com enfoque no produto. Ainda foram abordados os conceitos de manufatura celular e a utilização da filosofia de tecnologias de grupo, com a inserção do uso de simulação e inteligência artificial para melhoria dos processos produtivos.

Num segundo momento são apresentadas técnicas inteligentes para agrupamento e classificação de dados com o uso de redes neurais. Em detalhes foram apresentadas as técnicas para agrupamento dos dados utilizando mapas auto-organizáveis de *kohonen*, e como método de classificação dos dados as redes *MLP-Backpropagation*. Estas ferramentas fundamentaram o desenvolvimento da proposta para agrupamento e classificação de famílias de produtos intermediários, que foi testada e validada com o estudo de caso.

O principal objetivo deste trabalho foi utilizar os conhecimentos de planejamento e gestão da produção na construção naval aliados a modernas técnicas gerenciais: clusterização e classificação de dados, com a utilização de ferramentas de Inteligência artificial (RN), permitindo desta forma novos entendimentos sobre as possibilidades existentes para classificação de grandes conjuntos de dados dentro do ambiente produtivo.

Foi proposta uma metodologia totalmente baseada em redes neurais artificiais. Os métodos utilizados fazem uso de Mapas Auto-organizáveis para obtenção das principais famílias de produtos e Redes Multi-Camadas para a classificação automática de novos blocos. Os conceitos de SOM foram originalmente apropriados ao processo de definição de grupos de famílias na construção naval, tendo sido especificados os requisitos de entrada e saída dos sistemas envolvidos, frente às bases de dados presentes em um estaleiro.

A metodologia foi implementada utilizando-se a ferramenta matemática MatLab e seu toolbox associado a RNA. A proposta foi testada e validada com dados reais.

A sensibilidade da SOM e MLP a vários parâmetros foi analisada. Em todos os testes as redes apresentaram resultados adequados. Os resultados da avaliação realizada validaram a proposta, indicando a possibilidade de seu uso em situações reais de aplicação aos sistemas de produção de estaleiros, contribuindo para a adoção da filosofia de tecnologia de grupo e manufatura celular nos canteiros de obras.

Como trabalhos futuros podem ser citados:

□ A avaliação de outras técnicas de agrupamento e classificação, como por exemplo, o WEKA (Disponível em: <http://www.cs.waikato.ac.nz/ml/weka>), que é uma coleção de algoritmos de aprendizagem de máquina para tarefas de mineração de dados.

□ A utilização de um banco de dados com um maior número de blocos e a implantação deste modelo em um projeto real de trabalho, com análise prática de resultados.

□ O uso de outras informações estruturais, bem como a busca automática por métricas características dos grupos.

REFERÊNCIAS BIBLIOGRÁFICAS

ALEKSANDER L.; MORTON M. **Tutorial de Redes Neurais Aplicações em Bioinformática**. Laboratório Nacional de Computação Científica. São Paulo. Disponível em: <<http://www.lncc.br/~labinfo/tutorialRN/>>. Acesso em: 15 maio 2010.

ALLARD, F.; FUCHS, J. Artificial Intelligence – The state of the Art. **ESA's Technology Programme Quartely**, v. 3, n. 3, sep. 1993.

BEALE, R; JACKSON, T. **Neural Computing: an Introduction**. Bristol: Adam Hilger, 1990. p. 240.

BEEBY, W. D.; THOMPSON, A. R. **A Broader View of Group Technology**. Washington: Engineering Division, Boeing Commercial Airplane Co. 1986.

BEEBY, A. Centre for Molecular and Nanoscale Electronics. Findlay, P. J. Low, T.B. Marder, **J. Am. Chem. Soc.**, 2002.

BISHOP C. **Pattern Recognition and Machine Learning**. New York; Springer Science, 2006.

BOEING, C. A. **A Broader View of Group Technology**. Seattle, Wash.: Engineering Division, Boeing Commercial Airplane, 2002.

BOLE, M. **Parametric Cost Assessment of Concept Stage Designs**. Gosport: COMPIT, 2006.

BRASIL. Ministério do Desenvolvimento, Indústria e Comércio Exterior. Desenvolvimento de Ações de Apoio à Cadeia Produtiva da Indústria Naval e Marinha Mercante. **Relatório**. Brasília, 2002. 22 p.

BRAUNSTEIN, S. H. **Utilização de Mapas Auto-Organizáveis para Predição de Alarmes em Plantas Industriais**. 2010. Dissertação de Mestrado. Rio Grande: Ed. FURG, 2010.

BRITO, G.; GORDO, J. **Tecnologia de Estaleiro, Engenharia e Arquitetura Naval**. Portugal: Universidade de Faro, 2006.

BURNHAM, K. P.; ANDERSON, D. **Model Selection and Multi-Model Inference**. Berlim: Springer, 2004.

CARVALHO, A. P. de L. F. **Home Page "Perceptron Multicamadas**. Departamento de Ciência da Computação. Disponível em: <<http://icmc.sc.usp.br/~andre/neural2.html>>. Acesso em: 11 out. 2010.

CAUDILL, M. Expert Network. **Byte**, New York, USA. 1991. p 108.

CEGN. Centro de Estudos em Gestão Naval. Disponível em: <www.gestaonaval.org.br>. Acesso em: 12 abr. 2010.

CHASE, R. B.; AQUILANO, N. J. **Gestão da produção e das operações: perspectiva do ciclo de vida**. Lisboa: Monitor, 1995. p.52.

CHIRILLO, L.; CHIRILLO, R. The History of Modern Shipbuilding Methods: The U.S.-Japan Interchange. **Journal of Ship Production**, New Jersey, USA., 1985. p. 150

CHOW, H.; CHO, J. K. **An expert system for fault section diagnosis of power systems using fuzzy relations**. IEEE - Transactions on Power Systems, v. 12, n. 1, feb., 1997.

CLARK J.; LAMB T. "Build Strategy Development". **Journal of Ship Production**. v.12, n.3, aug., p. 198-209, 1996.

CLARKSON RESEARCH, abrangente e confiável provedor de inteligência sobre os setores naval e *offshore*. Disponível em: <www.crsi.com>. Acesso em: 14 jul. 2010.

FAUSETT, L. V. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**. New Jersey: Prentice Hall, 1994.

FAVARIN, J. V. R. *et.al.* Competitividade da indústria naval brasileira. In: CONGRESSO NACIONAL DE TRANSPORTE AQUAVIÁRIO, CONSTRUÇÃO NAVAL E OFFSHORE, 2010, p. 23. Rio de Janeiro: 2010.

FERRAZ, J. C. **Estudo da competitividade de cadeias integradas no Brasil: Impactos das zonas de livre comércio**. UNICAMP, Campinas: 2002.

FMI. **Report Development of Marine Industries to the National Monetary Fun**. NSRP. Disponível em: <www.nsrp.org>. Acesso em: 13 ago. 2010.

FONSECA, M. M. **Arte Naval**. Escola de Armamento e Convés. 5. ed. Rio de Janeiro; SMD,1989. p. 56.

FREEMAN, J. A.; SKAPURA, D. M. **Neural Networks Algorithms, Applications and Programming Techniques**. [S.L.]: Addelfon-Wefley, 1992. p. 89 - 106.

HAIR Jr., J. F. *et al.* **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005. p. 593

HAYKIN, S. **Neural Networks A Comprehensive Foundation**. 2. ed. New York: Prentice Hall, 1998.

_____. **Redes Neurais: Princípios e Práticas**. 2. ed. Porto Alegre: Bookman, 2001.

HOU, F. **Development of a Neural Network Fault Diagnostic System** - MSC Thesis. Cranfield, Bedfordshire: Cranfield University, 1998. p. 78.

HYER, N. L.; WEMMERLÖV, U. **Group technology and productivity**. Harvard: Business Review, 1984, v. 62, n. 4, p. 140-149.

KIVILUOTO, K. Topology Preservation in Self-organizing Maps, **IEEE International Conference on Neural Networks**, v.1, p. 224-299, jun., 1996.

KOHONEN, T. *et al.* **On the quantization Error in SOM vs.VQ**: A critical and Systematic Study, Proceedings of the 7th International Workshop on Advances in Self-Organizing Maps, 2009. Disponível em:

<<http://portal.acm.org/citation.cfm?id=1568127.1568143&coll=GUIDE&dl=GUI&CFID=96951480&CFTOKEN=42436611>>. Acesso em: 13 set. 2010.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. **Biological Cybernetics**, Ed. Copy Books. v. 43, p. 59-69, 1982.

KRÖSE, B. J. A.; SMAGT, P. P. V. D. **An introduction to neural networks**. 7. ed. Amsterdam: University of Amsterdam, 1995.

MEDEIROS, C. M. S.; BARRETO, G. A. **Reconhecimento de Padrões-Notas de Aula**. Centro Federal de Educação Tecnológica do Ceará. Ceará: Engenharia Mecatrônica, 2008.

MEDEIROS, J. S. **Bancos de Dados Geográficos e Redes Neurais Artificiais**: Tecnologias de Apoio à Gestão de Territórios. 1999. Tese de Doutorado em Geografia Física. São Paulo, 1999.

OJA, M.; KASKI, S.; KOHONEN, T. Bibliography of Self-Organizing Map (SOM) Papers: 1998-2001. Addendum. **Neural Computing Surveys**, Finland. v.3, p. 1-156, 2003.

ONIP. Organização Nacional da Indústria e Petróleo, 3. ed. do Café com Energia. EISA - Estaleiro Ilha S.A. Projeto e Construção de quatro Navios Petroleiros para Macaé-RJ. Transpetro, 2008.

OSÓRIO, F.; BITTENCOURT, J. R. Sistemas inteligentes baseados em RNAs aplicados ao processamento de imagens. In: **Workshop de Inteligência Artificial**. Santa Cruz do Sul: UNISC, 2000.

PAGLIOSA, A. L. **Obtenção das funções de Pertinência de um sistema Neurofuzzy Modificado pela Rede de Kohonen**. Santa Catarina: UDESC, 2003.

PINTO, M. M. *et.al.* **Work Shop CEGN\PPCPE na Construção Naval**. Centro de Estudos em Gestão Naval-CEGN. Disponível em:

<http://www.gestaonaval.org.br/arquivos/Documentos/Ind%20Naval%20-%20WS1/11ws1_PPCPE_DavidGoldberg.pdf>. Acessado em: 13 mar. 2010.

PMBOOK. Um Guia do Conjunto de Conhecimentos em Gerenciamento de Projetos. 3. ed. Pennsylvania. EUA: Campus Boulevard Newtown Square, 2004.

REGO Jr., U. **Recuperação Inteligente de Informação**: Construção de Interface de Navegação sobre mapa de documentos. Recife: Universidade de Pernambuco, 2006.

RITTNER, L.; BRUM, I. B. **Revisão Bibliográfica sobre Mapas Auto-Organizáveis Bi-dimensionais IA353**. Redes Neurais, 2005. Disponível em: <<ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/...03/revisao/.../tema16.doc>>. Acesso em: 02 maio 2008.

RITTNER, H.; KOHONEN, T. Self-Organizing Semantic Maps. **Biological Cybernetics**, Berlin, Germany. v., 61, p. 241-254, 1989.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. In: **Parallel Distributed Processing: exploration in the microstructure of cognition**. Cambridge: MIT Press, 1986.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence – A Modern Approach**. New Jersey: Prentice-Hall, 1995. P. 563-597.

SANTOS, F. *et al.* **Planejamento de processos assistido por computador – CAPP (COMPUTER AIDED PROCESS PLANNING)**. Automação. Joinville, 2004.

SLACK, N. *et al.* **Administração da Produção**. 3. ed. São Paulo: ATLAS, 1997. p. 346.

SOUZA, C. M. **Técnicas Avançadas em Planejamento e Controle da Construção Naval**. Rio de Janeiro: Coppe/UFRJ, 2009.

SOUZA, C. M. *et al.* **Shipbuilding Interim Product Identification and Classification System Based on Intelligent Analysis Tools**. Disponível em: <http://www.anast.ulg.ac.be/COMPIT08/Files/COMPIT_programme.pdf> Acesso em: 12 dez. 2008.

STORCH, R. L. *et al.* **Process Analysis Via Accuracy Control**, Revised, USDOT Maritime administration and Todd Pacific Shipyards Corporation, 1995. p. 163.

SURKAN, A. J.; SINGLETON, C. Neural Networks for Bond Rating Improved by Multiple Hidden Layers. In: **Proceedings of the IEEE International Joint Conference on Neural Networks**. San Diego: [s.n.], 1990. p. 163-168.

SWINK, M. Building Collaborative Innovation Capability. **Research Technology Management**, Indiana, mar./apr., p. 37-47, 2006.

TAFNER, M. A.; XEREZ, M.; RODRIGUES FILHO, I. W. **Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação**. Blumenau: Editora Eko e Editora FURB, 1996.

TATIKONDA, M. V.; WEMMERLÖV, U. Adoption and implementation of classification and coding systems: insights from seven case studies. **International Journal of Production Research**, Núcleo de Computação Avançada. São Carlos, n. 9, v. 30, p. 2099, 1992.

THEODORIDIS S.; KOUTROUMBAS K, **Pattern Recognition**, 4. ed. Califórnia: Editora Elsevier, 2003.

THOMPSON, C. G. **Uma avaliação do Potencial de Aplicação da Mentalidade Enxuta (Lean Thinking) na Construção Naval: Estudo de Casos Múltiplos**. São Paulo, 2009.

TONSIG, S. L. **Redes Artificiais Multicamadas e o Algoritmo Backpropagation**. Campinas: UFSCar, 2000.

TORQUATO, P. R. G.; SILVA, G. P. Tecnologia e estratégia: uma abordagem analítica e prática. **Revista de Administração**, São Paulo, v. 35, n.1, p.72-85, jan./mar., 2000.

TRUPI, A. TURBAN J. **Tutorial de Redes Neurais Aplicações em Bioinformática** – Laboratório Nacional de Computação Científica. São Paulo: Elsevier, 1993. p. 02.

VELASCO, L. O. M. de L.; ERIKSOM, T. **Informe Infra-estrutura**. Área de projetos de infra-estrutura. BNDES. Agosto, 1997, n. 49.

VELLASCO, M. M. B. R. **Home Page “Redes Neurais”**. ICA: Núcleo de Pesquisa em Inteligência Computacional Aplicada-PUC-Rio, 2000. Disponível em: <<http://www.ele.puc-rio.br/labs/ica/icahome.html>>. Acesso em: 03 dez. 2010.

VESANTO, J. *et al.* **SOM Toolbox for Matlab 5**: report A57. Disponível em: <http://www.cis.hut.fi/projects/somtoolbox/download/>. Acesso em: 02 jul. 2008.

VITALE, Michael J. **A Formal Methodology for Constructing Decoupled Manufacturing System Control Software Components**. 1994. Thesis. University of Michigan, 1994.

WASSERMAN, P. D. **Neural Computing**: Theory and Practice. New York: Van Nostrand Reinhold, 1989.

WILLSHAW, D. J.; VON DER MALSBERG, C. **Proceedings of the Royal Society of London**. Series B, Biological Sciences, v. 194, n. 1117, nov., p. 431-445, 1976.

WU, Y.; TAKATSUKA, M. **The Geodesic Self-Organizing Map and Its Error Analysis**. Proceedings of the Twenty-eighth Australasian conference on Computer Science. Disponível em: <<http://www.inf.ufsc.br/~patrec/estatisticas.html>>. Acesso em: 12 jan. 2011.