

# UERJ

Dissertação de Mestrado em Engenharia de Computação

**USO DE MODELOS NEURO-FUZZY EM SISTEMAS DE SUPORTE A  
ANÁLISE DE PARÂMETROS OCEANOGRÁFICOS**

Autor: Pablo Medeiros Jabor

Orientador: Flávio Joaquim de Souza

Co-orientador: Marcelo Sperle Dias

Programa de Pós Graduação em Engenharia de Computação  
Área de Concentração: Geomática

Setembro - 2004



**Faculdade de Engenharia**

Resumo da Dissertação apresentada à FEN/UERJ, como parte dos requisitos necessários à obtenção do título de Mestre em Ciências (M.Sc.).

## **USO DE MODELOS NEURO-FUZZY EM SISTEMAS DE SUPORTE A ANÁLISE DE PARÂMETROS OCEANOGRÁFICOS**

Pablo Medeiros Jabor

Setembro/2004

Orientador: Flávio Joaquim de Souza  
Co-orientador: Marcelo Sperle Dias

Programa: Programa de Pós Graduação em Engenharia de Computação – Área de Concentração Geomática.

Este trabalho apresenta uma metodologia que possibilita a utilização de sistema de inteligência computacional, especificamente redes neuro-fuzzy, na área da oceanografia, como ferramenta de interpolação de forma a cobrir toda a área compreendida entre 20°S e 30°S e da costa até 30°W. Foram utilizados dados em malhas regulares de tipo de fundo e batimétricos, dados climatológicos meteorológicos (pressão atmosférica, umidade do ar e temperatura do ar) e perfis de temperatura e salinidade. Os dados foram separados em conjuntos de treinamento e foram submetidos a redes de aprendizado neuro-fuzzy para o estabelecimento dos pesos que permitem a reconstituição de cada parâmetro. Foram elaborados mapas comparativos entre os valores originais e os valores resultante das redes neuro-fuzzy. De forma geral, os resultados mostram grande similaridade, permitindo o uso das redes neuro-fuzzy para o estabelecimento de climatologia na área da oceanografia em sistemas que necessitem de informações contínuas como os sistemas de informações geográficas.

Palavras-chave: Oceanografia, Inteligência Computacional, Neuro-Fuzzy

Abstract of Dissertation presented to FEN/UERJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

Pablo Medeiros Jabor

September/2004

Advisors: Flávio Joaquim de Souza

Marcelo Sperle Dias

Pos Graduated Program in Computer Engineering – Field of Geomatics.

This study presents a methodology that applies an artificial intelligence system, particularly neuro-fuzzy networks, as a tool for interpolating oceanographic data covering the area delimited by 20°S and 30°S, from the coastline to 30°W. Regular grids of bathymetric and bottom sediment type data were used together with climatic meteorological data (atmospheric pressure, humidity and temperature) and ocean temperature and salinity profiles. The data were divided in training sets and submitted to neuro-fuzzy learning networks for defining the weights that allow the reconstitution of the parameter. Charts were draw comparing the original values with the ones resulting from the neuro-fuzzy networks. In general, the results show great similarity, allowing the use of neuro-fuzzy networks for establishing the oceanographic climatology in systems where there is a need for continuous information such as geographic information systems.

Keywords: Oceanography, Artificial Intelligence, Neuro-fuzzy

## SUMÁRIO

CAPÍTULO 1 .....	11
INTRODUÇÃO .....	11
1.1 ASPECTOS GERAIS .....	11
1.2 OBJETIVOS .....	15
1.2.1 OBJETIVOS GERAIS .....	15
1.2.2 OBJETIVOS ESPECÍFICOS .....	15
1.3 ÁREA DE ESTUDOS .....	16
CAPÍTULO 2 .....	18
PARÂMETROS OCEANOGRÁFICOS E METEOROLÓGICOS .....	18
2.1 – TEMPERATURA .....	18
2.2 – SALINIDADE .....	21
2.3 – MORFOLOGIA DO FUNDO E SEDIMENTAÇÃO MARINHA .....	25
2.4 – BATIMETRIA .....	28
2.5 – TEMPERATURA DO AR .....	28
2.6 – PRESSÃO ATMOSFÉRICA .....	30
2.7 – UMIDADE RELATIVA .....	32
CAPÍTULO 3 .....	33
INTELIGÊNCIA COMPUTACIONAL .....	33
3.1 – LÓGICA FUZZY .....	33
3.2 – REDES NEURAIS .....	35
3.3 – NEURO-FUZZY .....	37
3.3.1 - MODELO ANFIS .....	40
3.3.1.1 – ARQUITETURA .....	40
3.3.1.2 – APRENDIZADO .....	43
CAPÍTULO 4 .....	45
MATERIAIS E MÉTODOS .....	45
4.1 – BUSCA DOS DADOS .....	45
4.1.1 – TEMPERATURA E SALINIDADE .....	45
4.1.3 - BATIMETRIA .....	48
4.1.4 – TEMPERATURA DO AR, PRESSÃO ATMOSFÉRICA E UMIDADE RELATIVA DO AR .....	49
4.2 – GERAÇÃO DE GRADE REGULAR COM TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL .....	50
4.3 – ELABORAÇÃO DE MAPAS E GRÁFICOS COMPARATIVOS PARA AS DIFERENTES VARIÁVEIS .....	57
CAPÍTULO 5 .....	59
RESULTADOS E DISCUSSÕES .....	59
5.1 – TEMPERATURA E SALINIDADE .....	59
5.2 – PARÂMETROS DE FUNDO .....	71
5.2.1 – TIPO DE FUNDO .....	71
5.2.2 – BATIMETRIA .....	72
5.3 – PARÂMETROS METEOROLÓGICOS .....	74
CAPÍTULO 6 .....	79
CONCLUSÕES E RECOMENDAÇÕES .....	79
REFERÊNCIAS BIBLIOGRÁFICAS .....	80

# CAPÍTULO 1

## INTRODUÇÃO

### 1.1 ASPECTOS GERAIS

O oceano se apresenta àqueles que procuram estudar o seu comportamento como um ambiente muito complexo. A existência de diversos fenômenos, muitos deles gerados pela combinação entre variáveis com uma distribuição espaço-temporal não homogênea dificulta a compreensão e a análise do meio ambiente marinho.

O oceano participa do controle do clima do planeta. A distribuição da temperatura da superfície do mar influencia a circulação atmosférica, a superfície das águas acumula a energia recebida pelo Sol e a redistribui, na forma de evaporação e precipitação, controlando, por fim, a temperatura. Em Oceanografia Física é muito importante o estabelecimento de condições médias, a partir das quais pode-se determinar ou avaliar o intervalo das variações e determinar escalas em tempo e espaço (Ramos, 1999).

Uma grande preocupação atual, relacionada com variações climáticas e seus efeitos sobre o planeta, incentiva o desenvolvimento de estudos envolvendo trocas de calor entre oceano e atmosfera. Vários trabalhos têm sido desenvolvidos com o objetivo de obter um melhor entendimento da influência dos oceanos no comportamento do clima terrestre.

O conhecimento deste meio ambiente e suas interações, por meio dos parâmetros oceanográficos e meteorológicos, é importante para o desenvolvimento de diversas áreas de interesse da sociedade, como a pesca, o tráfego marítimo, exploração mineral, obras costeiras e oceânicas, o turismo, a indústria, defesa, além da dispersão, transporte e fixação de poluentes.

Os avanços na tecnologia de sensoriamento remoto acústico e técnicas de orientação e posicionamento têm propiciado um aumento considerável na quantidade e precisão de dados geoespaciais marinhos nos últimos 20 anos. Estas novas tecnologias, quando usadas em conjunto com as fontes tradicionais de informação marinha, geram uma quantidade enorme de dados e conseqüentemente novos desafios na gerência, análise e interpretação.

Ao longo de vários anos de pesquisas foi coletado um grande número de dados oceanográficos e meteorológicos na área marítima de interesse do Brasil. Estes se encontram armazenados no Banco Nacional de Dados Oceanográficos (BNDO) da Marinha do Brasil e em instituições estrangeiras como a National Oceanographic and Atmospheric Administration (NOAA) dos Estados Unidos. A maior abundância de dados compreende perfis verticais de temperatura e salinidade e dados meteorológicos de pressão atmosférica, vento, umidade relativa, e temperatura do ar. A questão principal é como esses dados coletados podem ser convertidos em informações? Em muitos casos, analistas desejam convertê-los em mapas de contorno, diagramas de perspectiva ou imagens, com a finalidade de representar graficamente a variação espacial dos dados. Neste contexto, ferramentas capazes de manipular e analisar grandes volumes de dados fazem-se necessárias (Ramos, 1999). Uma ferramenta de visualização e de correlação entre estas variáveis que favoreça a sua análise é fundamental para a obtenção de informações representativas e confiáveis. Dessa forma, a aplicação da tecnologia SIG (Sistema de Informações Geográficas) apresenta um enorme potencial nesta análise, permitindo realizar análises complexas ao integrar dados de diversas fontes e ao criar banco de dados georeferenciados (Câmara e Medeiros, 1996). Sistemas de informação geográfica têm se tornado a solução padrão para a integração de dados multivariáveis em quase todas as aplicações terrestres (Arnoff, 1991). O mesmo desafio existe agora para o ambiente marinho, onde o SIG, com algumas adaptações podem provir um meio de integração de grande quantidade de informação dispersos em diversos formatos.

Mesmo que os dados valores apresentem-se regularmente distribuídos, as consultas em um SIG sobre esses dados podem eventualmente ocorrer em pontos onde não existam informações. Desta forma, é necessário utilizar uma técnica de interpolação. Diferentes técnicas de interpolação têm sido utilizadas para criar informações climatológicas na área de oceanografia, como por exemplo, interpolação linear (Lozier, 1995) e rotina de interpolação ótima (Steele, 2001) e Levitus (1982). Neste trabalho, utilizaremos técnicas estudadas na área de Inteligência Computacional, em particular, os sistemas neuro-fuzzy híbridos ou, simplesmente, sistemas neuro-fuzzy. Segundo Souza (1999), os modelos neuro-fuzzy são sistemas adaptativos que têm sua origem nas redes neurais e na lógica fuzzy. Estas técnicas de modelagem têm sido empregadas com sucesso em várias áreas onde a abordagem convencional tem falhado em fornecer soluções satisfatórias. As duas técnicas apresentam características comuns, como operação em paralelo e capacidade de tolerância a falhas, embora suas origens sejam bem distintas.

A lógica Fuzzy surgiu no final dos anos 70, criada por Lofti Zadeh, e veio para satisfazer os problemas onde a lógica clássica, fundada por Aristóteles, falhava. Fuzzy significa vago, impreciso, portanto a lógica Fuzzy trata da imprecisão, processando informações vagas para chegar a uma conclusão. Para um sim ou um não, em uma resposta, pode existir um intervalo de diversos graus de indecisão. Por outro lado, as redes neurais artificiais têm por inspiração o sistema de neurônios biológicos.

As Redes Neurais conseguem apresentar algumas características de processamento inteligente, como é o caso da adaptação, tolerância a falhas e ruídos, tomada de decisões e a mais importante: a habilidade de *aprender* a partir de dados de entrada. Este conjunto de características fornece às redes neurais artificiais potencialidade para resolver uma série de problemas como reconhecimento visual de padrões, análise de séries temporais, reconhecimento de voz e imagem, dentre outros. Sua principal propriedade é o *aprendizado* a partir de dados de entrada. Os dados podem ser não-lineares, ruidosos, incompletos ou contraditórios. São aplicadas em vários campos, como reconhecimento e classificação de padrões e análise de séries temporais.

Uma rede neural pode ser treinada utilizando grandes quantidades de exemplos significativos, o que contribui para a obtenção de performance elevada. Ou seja, a avaliação é modelada através de exemplos de aplicações bem ou mal sucedidas, encontrados nos históricos dos clientes e não através de modelos objetivos ou quantificáveis da operação de avaliação. Desta forma, a rede é capaz de encontrar relações entre as diversas informações.

Os modelos híbridos têm vantagens interessantes sobre as técnicas de identificação de sistemas individuais (por ex., redes neurais, sistemas fuzzy, algoritmos genéticos, técnicas de regressão, sistemas especialistas, técnicas de agrupamento (“*clustering*”), dentre outros). O grande interesse que tais sistemas têm despertado na comunidade científica deve-se ao sinergismo obtido pela combinação de duas ou mais técnicas de modelagem. Este sinergismo reflete-se na obtenção de um sistema mais poderoso (em termos de poder de interpretação, de aprendizado, de estimativa de parâmetros, de generalização, etc) e com menos deficiências.

Os sistemas neuro-fuzzy pretendem associar as vantagens de cada abordagem e minimizar suas deficiências, são sistemas adaptativos, como as redes neurais, e são interpretáveis através de regras da lógicas fuzzy, é tecnologia de inteligência artificial que gera regras diretamente de dados numéricos. A rede neuro-neural pode ser iniciada usando

conhecimento apurado expressado com regras fuzzy, e então treiná-la usando valores numéricos. Após treinar a rede, as regras podem ser avaliadas e editadas para sobrepor qualquer deficiência nos dados treinados. Pesquisas mais recentes têm produzido sistemas de "aprendizagem" que podem extrair automaticamente um conjunto de regras fuzzy de um conjunto dado, sem necessitar inicializar o sistema com regras conhecidas "importadas".

Algoritmos recentes permitem o treinamento e extração de regras, mesmo na ausência de conhecimento "expert". Algumas vantagens podem ser adicionadas à tecnologia neuro-fuzzy como, por exemplo: as redes produzidas por técnicas neuro-fuzzy podem ser simplificadas automaticamente, bem como busca ao melhor modelo para representar o conjunto de dados.

## **1.2 OBJETIVOS**

### **1.2.1 OBJETIVOS GERAIS**

Desenvolver uma metodologia que substitua a utilização de um banco de dados oceanográficos e meteorológicos por um sistema baseado em redes neuro-fuzzy que represente e interpole esses dados, visando à aplicação em um SIG.

### **1.2.2 OBJETIVOS ESPECÍFICOS**

Utilização de um Sistema Neuro-fuzzy para permitir a obtenção de informações em qualquer ponto da área de estudo a partir do aprendizado da rede com séries de dados de batimetria, tipo de fundo, temperatura e salinidade (em níveis de profundidade), pressão atmosférica, umidade relativa do ar e temperatura do ar ao nível do mar.

Isto deverá ser implementado por um programa que forneça os parâmetros ambientais a partir de dados de entrada como latitude, longitude e mês.

### 1.3 ÁREA DE ESTUDOS

Para o desenvolvimento do sistema, será utilizada uma área compreendida entre 20°S e 30°S de latitude e da costa até o paralelo 50° W. Esta área, que compreende grande parte litoral sudeste e sul do Brasil, foi escolhida por ser a região de maior abundância de dados da costa brasileira, correspondendo aos quadrados de MARSDEN 376 e 375 (Figura 1).

A orientação geral da linha da costa é de NE-SW, com exceção das regiões situadas imediatamente ao sul de Cabo Frio (23°S), onde a orientação é E-W, e ao norte do Cabo de Santa Marta (28°40'S), onde a orientação é N-S. Esses dois cabos delimitam uma das principais regiões geomorfológicas da plataforma continental brasileira, a Plataforma Continental Sudeste – PCSE (Castro Filho *et al.*, 1994). A parte mais larga da PCSE, com 230 km, está localizada em frente a Santos, e as partes mais estreitas nas proximidades de Cabo Frio, com 50 km, e Cabo de Santa Marta, com 70 km. Seu comprimento é de aproximadamente 1100 km e, com exceção de algumas poucas ilhas, geralmente situadas nas proximidades da costa, como Ilha Grande, Ilha de São Sebastião, Ilha de São Francisco e Ilha de Santa Catarina, e de muitas ilhas pequenas, situadas geralmente no interior de baías. A topografia da PCSE é suave, com as isóbatas dispendo-se paralelamente à linha da costa (Castro Filho, 1996) sendo que a profundidade da quebra da plataforma continental varia entre 120 m e 180 m, e a área total da PCSE é de cerca de 150.000 km<sup>2</sup> (Castro Filho, 1994). A extensão da PCSE após o cabo de Santa Marta, em direção ao Chuí, define a extremidade sul da plataforma continental brasileira, a Plataforma Continental Sul (PCS). As mesmas condições de suavidade da topografia, e de largura acentuada da plataforma continental, projetam-se na PCS. O comprimento aproximado é de cerca de 750 km, a largura aproximada de 120 km (Castro Filho *et al.*, 1994).

A variação sazonal das características hidrográficas e da circulação superficial para a região de estudo foram apresentadas nos trabalhos pioneiros de Bohnecke (1936) e Schumacher (1943), citados por Miranda e Katsuragawa (1991). Posteriormente, vários estudos de caráter regional complementaram o conhecimento das características hidrográficas da região: Emilsson (1961); Reid *et al.*(1977); Miranda e Castro Filho (1979); Miranda (1982); Matsuura (1986); Castro Filho *et al.*(1987); Bakun e Parrish (1990); Peterson e Stramma (1991); Silva (1995); Lentini (1997). A circulação geral do Atlântico Sudoeste é caracterizada pelo fluxo da Corrente do Brasil (CB) em direção ao polo ao longo da margem continental da América do Sul e pelo fluxo da Corrente das Malvinas (CM) para norte sobre a

quebra-da-plataforma Argentina (Legeckis e Gordon, 1982). A corrente quente do Brasil encontra-se com a corrente fria das Malvinas criando uma região com fortes gradientes térmicos conhecida como Convergência Subtropical, marcando a região limítrofe entre as águas subtropicais e subantárticas (Castro Filho, 1990b).

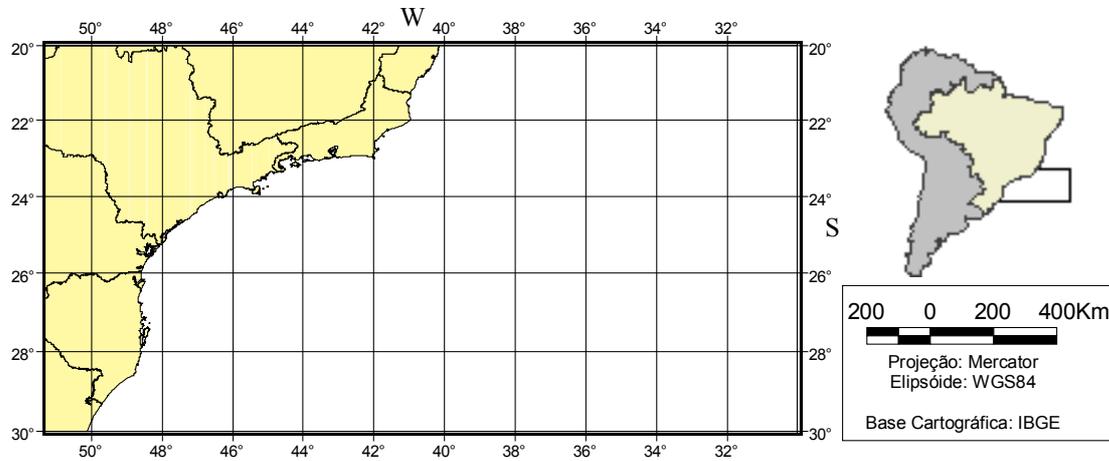


Figura 1 – Área de Estudo

## CAPÍTULO 2 PARÂMETROS OCEANOGRÁFICOS E METEOROLÓGICOS

A água do mar é caracterizada por certas propriedades físicas e químicas que representam as características quantitativas do sistema oceânico. Essas quantidades são chamadas de parâmetros, ou as características de estado do sistema. Para a água do mar os parâmetros de estado são massa, volume, pressão, temperatura e salinidade. Os três primeiros são mecânicos; a temperatura é um parâmetro termodinâmico, e a salinidade está associada a parâmetros físicos-químicos (Mamayev, 1975). Neste trabalho, será de grande importância o estudo da temperatura e da salinidade, pois tais parâmetros possibilitam a identificação de massas de água no oceano.

### 2.1 – TEMPERATURA

A temperatura da água do mar, como propriedade fundamental do oceano, apresenta-se como parâmetro básico para caracterização das massas de água em termos de comportamento e distribuição espacial ou temporal (Nijoku et al., 1985).

Em oceanografia, a sua medida, abaixo da superfície, normalmente é feita com o termômetro de reversão, que vai instalado numa garrafa de coleta de água (Nansen, Van Dorn etc). Outra alternativa é a medida na vertical através de um conjunto de sensores de registro contínuo chamado “CTD”, que é lançado da embarcação. Já a medida da temperatura superficial do oceano pode ser feita com um termosalinômetro instalado a bordo de embarcações ou até através de imagens de satélite na faixa do infravermelho (Castro Filho, 1994).

Geralmente, em Oceanografia, a temperatura é medida em graus Celsius (°C) com uma precisão padrão da ordem de 0,01°C. Os oceanógrafos definem dois tipos de temperatura: “*in situ*” e potencial  $\theta$ . Temperatura “*in situ*” é a temperatura medida pelo termômetro em um ponto qualquer no oceano e a temperatura potencial é a temperatura de uma parcela adiabaticamente reduzida à pressão normal (atmosférica), isto é, a temperatura que a parcela de água teria se fosse trazida à superfície adiabaticamente (sem ganho ou perda de calor) (Mamayev, 1975).

A distribuição da temperatura à superfície no oceano é aproximadamente zonal e as isolinhas de temperatura seguem aproximadamente os paralelos de latitude (Figura 2.1). Perto da costa, que desvia as correntes, as isothermas podem tender à direção norte-sul. Também ao longo da margem leste dos oceanos, baixas temperaturas muitas vezes ocorrem à superfície devido ao afloramento ou ressurgência das águas subsuperficiais, mais frias, como se vê, por exemplo, ao longo da costa oeste da América do Sul. A temperatura superficial dos oceanos decresce de valores bem elevados, em torno de 28°C um pouco ao norte do equador, a cerca de -2°C junto ao gelo, nas latitudes polares (Pickard e Emery, 1990).

No oceano, entre aproximadamente 200-300 m e 1000 m de profundidade, a temperatura decresce rapidamente (Figura 2.2). Essa região com acentuado gradiente vertical de temperatura é conhecida como **termoclina permanente**, abaixo da qual, em torno de 1000 m de profundidade, não existe variação sazonal e a temperatura decresce suavemente estabilizando-se entre 0°C e 3°C. Essa faixa limitada é mantida em todo oceano profundo, geograficamente e sazonalmente, pois é determinada pela temperatura de resfriamento e pela água densa que mergulha das regiões polares para o fundo do oceano em direção ao Equador (Brown *et al.*, 1989).

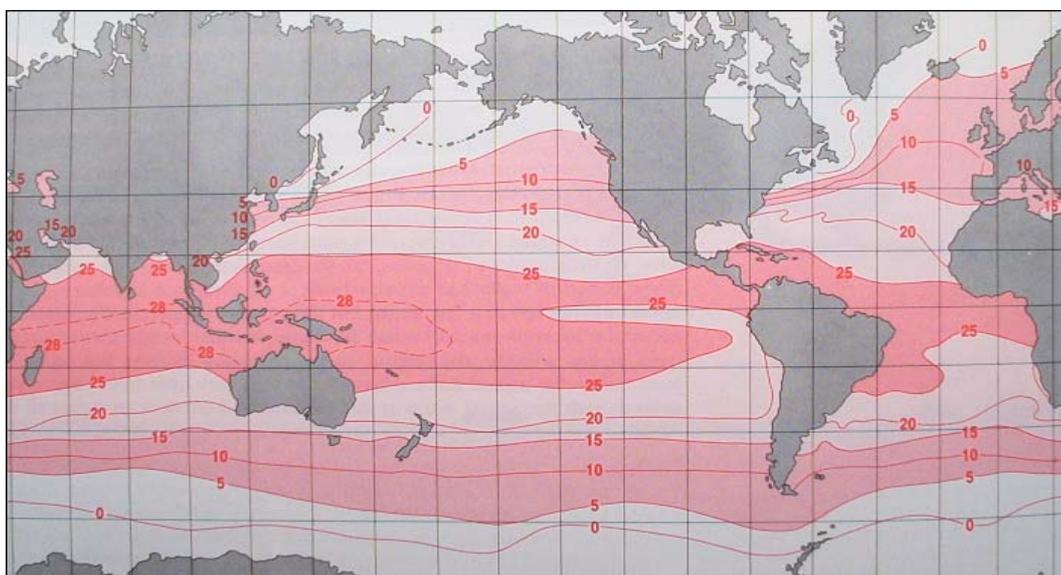


Figura 2.1 – Climatologia da Temperatura superficial média dos oceanos em fevereiro. Fonte Brown *et al.*(1989).

A região entre a superfície e uma profundidade de 25 a 200 m onde geralmente a temperatura é próxima da temperatura de superfície, devido à mistura produzida pelo estado do mar, é chamada de “camada de mistura”. A temperatura e a profundidade da camada de mistura mostram variações sazonais em médias latitudes (Figura 2.3). Durante o inverno, quando as temperaturas de superfície são baixas e as condições na superfície são turbulentas,

a camada de mistura superior pode aprofundar-se até atingir a termoclina permanente; isto é, o perfil de temperatura pode ser efetivamente vertical (constante) entre 200-300 m ou mais. No verão, como as temperaturas superficiais aumentam e as condições na superfície são menos turbulentas, uma termoclina sazonal freqüentemente surge acima da termoclina permanente (Brown *et al.*, 1989).

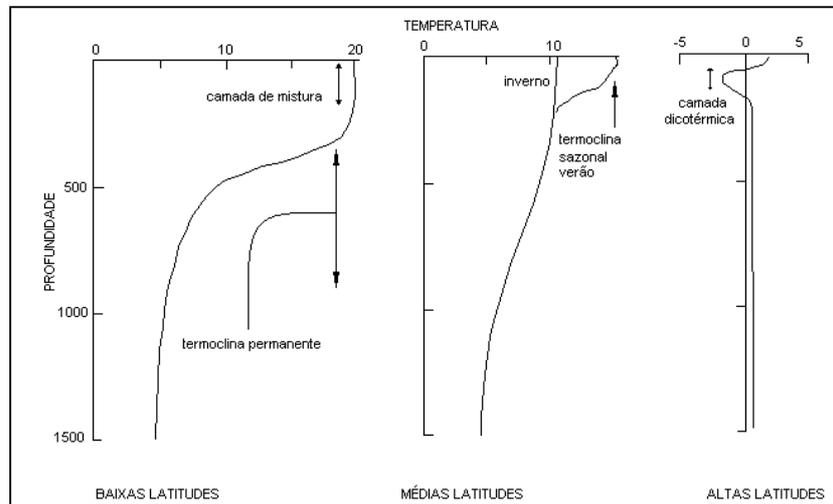


Figura 2.2 – Perfis típicos de temperatura no Oceano. Adaptado de Pickard, G. L. & Emery, W. J. 1990.

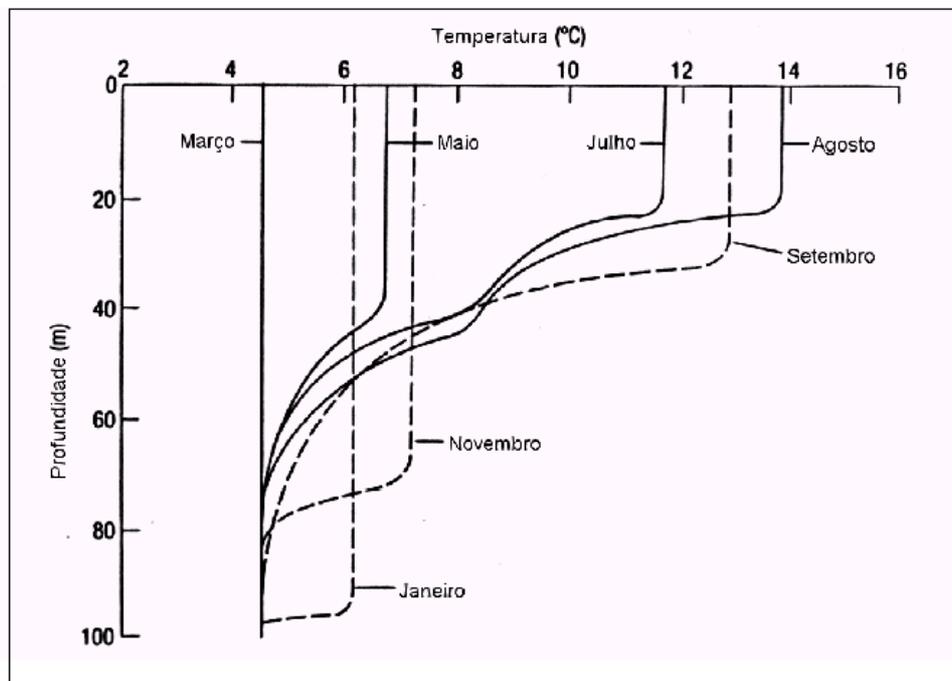


Figura 2.3 – Sucessão de perfis de temperatura mostrando o desenvolvimento e desaparecimento da Termoclina sazonal no hemisfério norte. Modificada de: Brown *et al.*(1989)

A termoclina sazonal começa a se formar na primavera e alcança seu desenvolvimento máximo (isto é, com maior gradiente vertical de temperatura) no verão. Esta termoclina se localiza geralmente em profundidades de poucas dezenas de metros, com uma camada de mistura acima. Resfriamento e fortes ventos no inverno aumentam progressivamente a profundidade da termoclina sazonal e reduzem o gradiente de temperatura ao longo dela, de maneira que a camada de mistura superior alcança sua total espessura de 200-300 m. Em baixas latitudes não existe resfriamento de inverno, assim a ‘termoclina sazonal’ torna-se ‘permanente’ e une com a termoclina permanente nas profundidades de 100-150 m. Em altas latitudes (maiores ou iguais a 60°), não existe termoclina permanente. Apesar disso, a termoclina sazonal pode ainda desenvolver-se no verão nessas altas latitudes, sobre a fraca termoclina permanente (Brown *et al.*, 1989).

## 2.2 – SALINIDADE

Entre os constituintes mais abundantes encontrados na água do mar estão os íons de cloro, (55% do total de substâncias dissolvidas), os íons de sódio (30,6%), os íons de sulfato, (7,7%), os íons de magnésio (3,7%) e os íons de potássio (1,1%) (Pickard e Emery, 1990).

A concentração média de sais dissolvidos nos oceanos denomina-se “salinidade”, que pode ser definida como “a quantidade total dos materiais sólidos, em gramas, contidos em um quilograma de água do mar quando todos os carbonatos são convertidos em óxidos, todos os brometos e iodetos substituídos por cloretos, e toda matéria orgânica completamente oxidada”.

A salinidade média da água do mar é de cerca de 35g/kg, que em geral se escreve “S=35‰” e lê-se “trinta e cinco partes por mil”. Tornou-se padrão a prática de dispensar o símbolo(‰), pois a salinidade é agora definida em termos da razão da condutividade elétrica (Pickard e Emery, 1990).

Desde meados de 1960 a definição de salinidade tem sido baseada (por acordo internacional) em uma determinação empírica que envolve um padrão de condutividade. A definição formal que tem sido usada desde os anos de 1980 é a seguinte:

A salinidade prática de uma amostra de água do mar é definida em termos da razão de condutividade, K15, a qual é definida por:

$$K15 = \frac{\text{condutividade de amostra da mar do água}}{\text{condutividade da solução de KCl padrão}}$$

a 15°C e pressão de 1 atm a concentração da solução padrão de KCl é 32,4356 g/kg.

A salinidade prática é relacionada com a razão K15 pela seguinte equação:

$$S = 0.0080 + 0,1692K_{15}^{1/2} + 25,3851K_{15} + 14,0941K_{15}^{3/2} - 7,0261K_{15}^2 - 2,7081K_{15}^{5/2}$$

O valor da salinidade determinada pela condutividade depende da temperatura e da pressão na qual a condutividade é medida (Brown *et al.*, 1989).

Se a medição da razão da condutividade elétrica é feita a uma temperatura diferente de 15°C, então resulta a razão Rt. Neste caso a conversão desse valor em S é feita mediante a seguinte equação:

$$s = \sum a_i (R_t)^{i/2} + \Delta S$$

Onde:

$$a_0 = 0.0080$$

$$a_1 = 0.1692$$

$$a_2 = 25.3851$$

$$a_3 = 14.0941$$

$$a_4 = -7.0261$$

$$a_5 = 2.7081$$

$$\sum a_i = 35$$

E  $\Delta S$  é dado pela equação:

$$\Delta S = \frac{(t-15)}{1+A(t-15)} \left[ \sum b_i (R_t)^{i/2} \right]$$

Onde:

$$\begin{aligned} b_0 &= 0.0005 \\ b_1 &= -0.0056 \\ b_2 &= -0.0066 \\ b_3 &= -0.0375 \\ b_4 &= 0.0636 \\ b_5 &= -0.0144 \end{aligned}$$

$$A = 0.0162$$

$$\sum b_i = 0.0000$$

Para a determinação da salinidade a partir de medições “*in situ*” da razão da condutividade elétrica os pesquisadores introduziram uma quantidade R, medida com equipamentos de CTD, que se define por:

$$R = R_p \cdot R_t \cdot r_t$$

Verifica-se que com o conhecimento das razões  $R_p$  e  $r_t$ , pode-se calcular  $R_t$  a partir das medições “*in situ*” da razão de condutividade R e, pode-se obter o valor correspondente da salinidade na escala prática. As quantidades  $R_p$  e  $r_t$  foram obtidas por uma série de experimentos de laboratório e suas expressões em função de R, T e p são encontradas no manual da UNESCO 1981 (Miranda, 1999). A distribuição da salinidade superficial é basicamente zonal, embora menos claramente que a temperatura. Os mínimos e máximos de salinidade aparecem em todos os oceanos e os valores decrescem para as altas latitudes. As observações mostram que a salinidade superficial é determinada por dois efeitos contrários: a evaporação, que a aumenta, e a precipitação, que a reduz. Os máximos de salinidade estão na região dos aliseos, onde a evaporação excede a precipitação (Pickard e Emery, 1990).

A faixa de valores da salinidade superficial (figura 2.4) nos oceanos varia de 33,0 a 37,0. Valores mais baixos podem ocorrer junto à costa, próximo ao desaguadouro de grandes rios, e nas regiões polares, onde gelo se funde. Valores mais altos aparecem nas regiões com excesso de evaporação, como no Mediterrâneo Oriental (39,0) e no Mar Vermelho (41,0). Em média, o Atlântico Norte é o oceano mais salgado (35,5), o Atlântico Sul e o Pacífico Sul tendo apenas 35,2 e o Pacífico Norte, o menos salgado, 34,2 (Pickard e Emery, 1990).

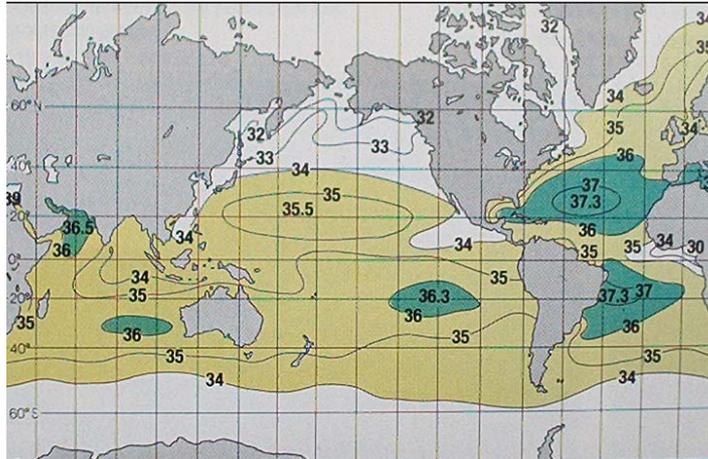


Figura 2.4 – Climatologia da Salinidade superficial média dos oceanos. Fonte Brown *et al.*(1989).

Na vertical, encontra-se nas regiões equatorial, tropical e subtropical, um mínimo permanente de salinidade entre 600 e 1000 metros, depois aumentando até 2000 m (Figura 2.5). Essas zonas, onde a salinidade decresce com a profundidade, são conhecidas como *haloclinas*. Nos trópicos encontra-se muitas vezes um destacado máximo de salinidade a cerca de 100 m, junto ao teto da termoclina. Nas altas latitudes, onde o valor à superfície é baixo, a salinidade em geral cresce com a profundidade ate cerca de 2000 m, sem o mínimo subsuperficial (Pickard e Emery, 1990). Nas águas profundas, abaixo de 4000 m, a salinidade é relativamente uniforme, entre 34,6 e 34,9 em todos os oceanos. Como a temperatura das águas profundas varia também entre estreitos limites (-0,9 e 2°C), pode-se dizer que o ambiente da água profunda é quase perfeitamente uniforme (Brown *et al.*, 1989).

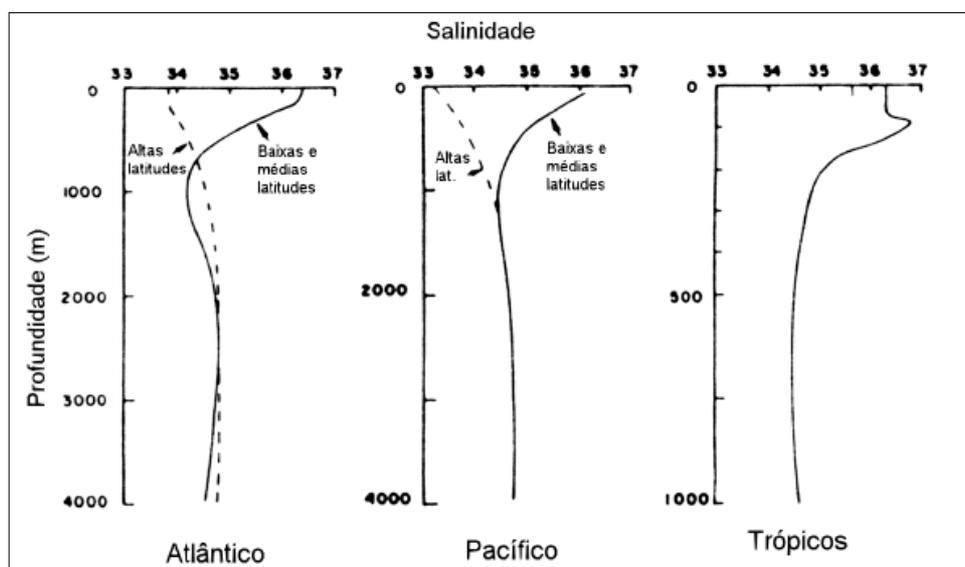


Figura 2.5 – Perfis verticais médios típicos de salinidade nos oceanos. Adaptado de Pickard, G. L.& Emery, W. J. 1990.

## 2.3 – MORFOLOGIA DO FUNDO E SEDIMENTAÇÃO MARINHA

Geólogos, geofísicos e geoquímicos explicam a formação do fundo marinho pela combinação de processos de sedimentação e os processos conhecidos por expansão do assoalho marinho, deriva continental e tectônica global. A estrutura de províncias marginais, até o talude continental inclusive, está relacionada, primeiramente aos grandes processos tectono-orogênicos de formação da própria margem continental e, posteriormente, às progradações sedimentares mais volumosas que por ventura tiverem ocorrido (Zembruski, 1979).

As margens continentais representam a zona de transição entre os continentes e as bacias oceânicas e, do ponto de vista geológico, fazem parte do continente, muito embora situem-se abaixo do nível do mar.

Essencialmente, as margens do “tipo Atlântico”, ou passivas, caracterizam-se por sua maior extensão, estabilidade e acúmulo de espessas camadas sedimentares, apresentam três províncias fisiográficas distintas, definidas pelo gradiente batimétrico: a plataforma continental, o talude continental e a elevação continental (figura 2.6).

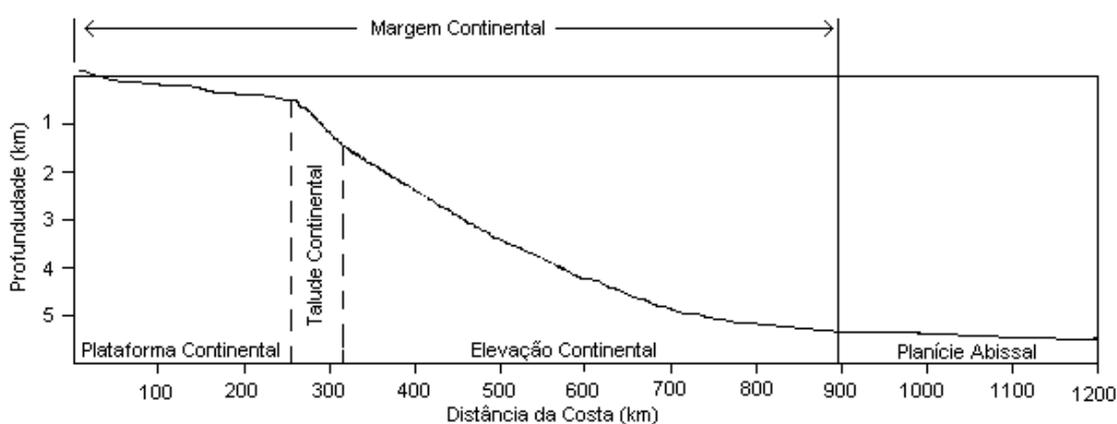


Figura 2.6 - Principais feições da margem continental passiva - Exagero vertical 1/50 (modificado de Baptista Neto & Silva, 2004)

A plataforma continental representa a extensão submersa dos continentes. Normalmente apresenta gradientes suaves, inferiores a 1:1000, desde a linha de praia até uma região de aumento substancial de aumento de profundidade, chamada de quebra de plataforma continental que situa-se a uma profundidade média de 130m nos oceanos.

A partir da quebra da plataforma continental, as profundidades aumentam rapidamente de 130 m para 1500 m podendo atingir em alguns lugares 3500 m, essa região é denominada de talude continental. Esta província fisiográfica apresenta gradientes íngremes, com valores médios de podendo ser superiores a 1:40. Os taludes e os sopés são as regiões das margens continentais que apresentam as maiores espessuras sedimentares, podendo ultrapassar 10 km de sedimentos.

Entre as margens continentais e os flancos das cordilheiras mesoceânicas, situam-se as bacias oceânicas onde ocorrem as planícies abissais que constituem as feições mais planas de todo o planeta com gradientes menores que 1:3000 e com profundidades variando entre 3000 e 6000 metros.

Na região do presente estudo, a margem continental caracteriza-se por uma plataforma intensamente progradante e subsidente, resultante da evolução tectônica meso-cenozóica da borda continental e do intenso aporte sedimentar terrígeno vindo do continente, o que favoreceu o desenvolvimento de uma morfologia suave de transição para o talude continental. O talude é interrompido por cânions submarinos, como os que ocorrem ao largo da porção norte do Rio de Janeiro. A cadeia Vitória-Trindade é constituída por montes com topos rasos, atingindo até 60 metros de profundidade, por vezes aplainados e alinhados na direção leste-oeste.

A feição mais conspícua da margem continental sudeste é o platô de São Paulo, com larguras variáveis entre 125 a 550 Km entre profundidades de 1.600 a 3.300 m (Palma, 1979)

Entre o sopé continental e as bacias oceânicas da Argentina e do Brasil, ocorre uma extensa elevação de origem vulcânica, denominada Elevação do Rio Grande. A porção central é a mais conspícua, elevando-se de profundidades de 3.500 a 4.000 metros para menos de 800 metros sua parte mais rasa (Palma, 1979)

Na plataforma continental, a cobertura sedimentar atual, reflete a natureza predominante de seus componentes, a ação do transporte e retrabalhamento dos mesmos promovida pela atividade hidrodinâmica.

No talude e elevação continental, o estilo da sedimentação é controlado em sua maior parte, por ressedimentação, circulação de fundo e a deposição pelágica (Ponzi, 2004).

A ressedimentação é o principal processo de transporte dos sedimentos clásticos que chegam ao fundo oceânico: esses sedimentos, constituídos em sua maior parte por material previamente acumulado na plataforma continental, são transportados via talude através de uma complexa suíte de mecanismos, envolvendo movimentos de massa, relacionados a fluxo de sedimentos acionados pela ação da gravidade. Quando atingem o sopé do talude, originam depósitos de extensões variáveis, muitos dos quais configurando leques ou cones submarinos (Ponzi, 2004).

O conhecimento do tipo de fundo marinho é obtido principalmente pelas amostragens pontuais, onde são usados diversos tipos de equipamentos tais como dragas de arrasto, busca-fundo e testemunhadores para a recuperação destes sedimentos.

Partículas muito finas, originárias do intemperismo das rochas continentais, lentamente depositam-se no fundo. Restos de plantas marinhas e formas animais como esqueletos ou conchas de sílica ( $\text{SiO}_2$ ) ou carbonato de cálcio ( $\text{CaCO}_3$ ) também se depositam no fundo. Carbonato de Cálcio é solúvel, e a quantidade de  $\text{CaCO}_3$  que alcança o fundo depende da sua supersaturação na água do mar. A água do Oceano Atlântico está supersaturada de calcita, a forma menos solúvel de  $\text{CaCO}_3$ , em torno de 4500m. Abaixo desta profundidade, chamada de horizonte de saturação ou profundidade de compensação, a calcita se dissolve. Quando o assoalho marinho se move abaixo do horizonte de saturação, o silte e a argila tornam-se predominantes. Em áreas onde a produção biológica é baixa, o sedimento é predominantemente vermelho. A sílica é comum em áreas com intensa atividade biológica. Estas camadas principais são intercaladas com camadas de origem vulcânica.

Na margem continental do assoalho marinho, produtos erosionais do continente também se movem para o fundo da plataforma continental. Nestas regiões, a velocidade da água dos rios é importante pois altas velocidades são exigidas para carregar grandes partículas. Com a diminuição da velocidade do aporte fluvial, os sedimentos se depositam no fundo – as partículas mais grosseiras primeiro, as finas depois. Os sedimentos formam praias e deltas de rios ao longo da costa.

## **2.4 – BATIMETRIA**

A técnica de levantamento batimétrico consiste em produzir impulsos acústicos seqüenciados dentro da água e registrar os respectivos ecos do fundo do mar. Ela permite delinear gradativamente, à medida que o navio avança, um perfil contínuo do piso marinho.

O sistema de ecobatimetria, ou sonar, consta de emissor, amplificador de potência, receptor, transeptor e registrador. O emissor e o receptor (conjunto normalmente conhecido como transdutor) pode ser rebocado pelo navio, ou, então, preso ao fundo pelo lado externo do casco. A unidade emissora do transdutor vale-se de dois fenômenos: eletrostrição ou magnetostrição. No primeiro caso, cristais de alguma substância (quartzo, por exemplo) sofrem deformações com a aplicação de campos elétricos ao longo de determinados eixos cristalográficos. No segundo, certas estruturas, como bobinas de folha de níquel, deformam-se sob efeito de campos magnéticos.

A energia acústica é gerada por meio de campos elétricos ou magnéticos, alternados, com as freqüências usuais de 12 kHz e 3,5 KHz. A alta freqüência fornece definição mais acurada do piso marinho, mas a freqüência menor tem ainda, a capacidade de produzir reflexões das interfaces imediatamente sotopostas ao fundo.

Tanto a eletrostrição quanto a magnetostrição constituem fenômenos reversíveis, propriedade aproveitada no receptor, que, quando isolado do emissor, é chamado de hidrofone. O receptor ou hidrofone consiste, comumente, em uma bateria de placas de quartzo, imersas em silicone dentro de um recipiente hermético.

O transeptor tem as funções de enviar ao emissor a onda de 3,5 kHz ou 12 kHz, receber o sinal do hidrofone amplificá-lo e transmiti-lo ao registrador que pode ser mecânico ou digital.

## **2.5 – TEMPERATURA DO AR**

A temperatura do ar a superfície é usada em meteorologia para traduzir a temperatura reinante em um ponto da atmosfera próximo à superfície terrestre. Aplica-se à temperatura do

ar adjacente ao oceano, determinada através de bóias, em plataformas flutuantes, em navios ou através de sensores instalados em satélites meteorológicos.

A escala Celcius ou centígrada ( $^{\circ}\text{C}$ ) é internacionalmente aceita e recomendada para o intercâmbio de dados.

A temperatura do ar normalmente apresenta acentuadas variações temporais, no entanto, as aplicações sinóticas e climatológicas de rotina não exigem o conhecimento das flutuações instantâneas da temperatura do ar. Em geral, tais aplicações representam a oscilação representada pelas médias mensais. As curvas que representam a variação mês a mês dessas temperaturas revelam uma acentuada correlação com a energia recebida do sol. O valor mais baixo das médias das temperaturas ocorre um ou dois meses após o mínimo de energia solar ter acontecido; fato semelhante se verifica com respeito às médias mais elevadas.

O mar atua como um regulador da temperatura do ar, tendendo a suavizar as flutuações e, portanto, reduzindo a sua amplitude anual.

A representação da temperatura através de isotermas traduz a configuração do campo de temperatura. São comuns cartas climatológicas contendo isotermas médias, referentes à temperatura do ar à superfície.

A temperatura média do ar à superfície, aumenta dos pólos para o equador, enquanto sua amplitude cresce no sentido contrário, em ambos os hemisférios. O fator das mais elevadas temperaturas médias se situarem nas proximidades do equador decorre da maior incidência de energia solar na faixa tropical.

O gradiente horizontal da temperatura média do ar é tanto maior quanto mais próximo dos pólos for a zona que se consiste.

Nas áreas circumpolares e na zona tropical sobre os oceanos, as isotermas médias anuais estão dispostas zonalmente, seguindo aproximadamente os paralelos.

## 2.6 – PRESSÃO ATMOSFÉRICA

A pressão atmosférica refere-se ao peso exercido por uma coluna de ar, com seção reta da área unitária, que se encontra acima do observador, em dado instante e local. Fisicamente, representa o peso que a atmosfera exerce por unidade de área.

O movimento da atmosfera está intimamente relacionado com a distribuição da pressão atmosférica, muito embora existam outras forças intervenientes, que modificam bastante a tendência inicial do ar de mover-se diretamente para as regiões onde a pressão estiver mais baixa.

O barômetro é o instrumento mais preciso para a determinação da pressão atmosférica, funciona segundo os experimentos de E. Torricelli, que mostrou que a pressão atmosférica é capaz de compensar a pressão reinante na base de uma coluna de mercúrio, mantida em equilíbrio.

Durante muito tempo costumou-se exprimir a pressão atmosférica em termos da altura da coluna de mercúrio, adotando-se o milímetro de mercúrio (mmHg) como unidade. As unidades recomendadas para exprimir a pressão são o pascal (Pa) e o milibar (mb), esta inclusive para intercâmbio internacional de dados (OM.M., 1971).

$$1 \text{ mb} = 10^3 \text{ Dyn cm}^{-2} = 10^2 \text{ N m}^{-2} = 10^2 \text{ Pa} = 1 \text{ hPa}$$

Considerando-se as condições-padrão de temperatura ( $0^\circ\text{C}$ ) e de aceleração da gravidade ( $g = 980,665 \text{ cm s}^{-2}$ ) e, ainda, que a pressão normal corresponde a 76 cm de coluna

$$P = -\rho_H g \int_0^h dh = \rho_H gh$$

barométrica (altura  $h$ ), pode-se aplicar a equação:

Onde:  $\rho_H$  é a densidade do mercúrio ( $13,5951 \text{ g cm}^{-3}$ )

$$P = 980,665 \times 13,5951 \times 76 \text{ dyn cm}^2 = 1013,25 \text{ mb}$$

Então, uma atmosfera (1 at) corresponde a 760 mmHg, a 1013,25 mb ou a 101325Pa, ou 1013,25 hPa.

Em geral, a pressão atmosférica muda de ponto para ponto e em cada ponto ao longo do tempo. Essa contínua variação da pressão decorre da incessante alteração da massa específica do ar, nas diferentes camadas da atmosfera situadas acima do local em questão;

A partir dos valores de pressão atmosférica plotados em uma carta geográfica, podem ser traçadas linhas que unam pontos de mesmo valor de pressão. Tais linhas são chamadas isóbaras.

As isóbaras caracterizam a distribuição espacial da pressão atmosférica. As configurações do campo de pressão à superfície estão associados a condições de tempo bem caracterizadas. Assim é possível fazer inferências quanto ao comportamento da atmosfera.

Os núcleos de pressão mais elevadas são denominados centros de alta pressão ou anticiclones. Neste centro, a tendência inicial de qualquer parcela de ar será a de mover-se radialmente, afastando-se do centro para a periferia.

As configurações no campo de pressão, constituídas por uma ou mais isóbaras fechadas que delimitam áreas onde a pressão é menor do que qualquer ponto circunjacente são chamados centros de baixa pressão ou centros ciclônicos. Nas proximidades desses centros, qualquer parcela de ar tende inicialmente a deslocar-se na direção radial, da periferia para o centro.

Uma vez iniciado o movimento entra em ação a aceleração de Coriolis, agindo perpendicularmente à direção do movimento, desviando-o para a esquerda no hemisfério Sul e para a direita no hemisfério Norte. Como consequência o vento observado não será perpendicular às isóbaras, mas inclinado em relação a elas, estabelecendo-se uma circulação no sentido horário no hemisfério Sul.

Em perfeita analogia com as configurações topográficas, as superfícies isobáricas também pode se apresentar onduladas, formando cavados (vales) e cristas (Saucier, 1969) . Em uma carta de superfície a crista representa uma linha de pressão máxima, à semelhança de um divisor de águas na topografia. Em cartas isobáricas o eixo da crista constitui uma linha de máximo geopotencial

## 2.7 – UMIDADE RELATIVA

A umidade relativa é um dos parâmetros que definem o teor de umidade do ar, trata-se do quociente entre a pressão parcial do vapor ( $e$ ) e a pressão de saturação ( $e_s$ ) a uma determinada temperatura, ou seja:

$$U = \frac{e}{e_s}$$

Normalmente  $U$  é expresso em porcentagem:

$$U = 100 \frac{e}{e_s}$$

Essa expressão revela que a umidade relativa atinge 100% quando o ar está saturado. Fisicamente  $U$  representa a fração da umidade máxima possível que já se encontra preenchida.

Os higrômetros, higrógrafos e os termohigrógrafos, são instrumentos que permitem obter diretamente a umidade relativa do ar. Seu funcionamento se baseia na variação do comprimento que experimenta um feixe de cabelos humanos, quando a umidade relativa do ar se altera. O feixe se distende com aumento da umidade, contraindo-se no caso contrário. Instrumentos desse tipo, embora tendam a ser substituídos por sensores elétricos, ainda são encontrados, com bastante frequência, nas estações meteorológicas convencionais (Varejão-Silva, 2001).

O teor de umidade do ar pode variar de modo acentuado, tanto no espaço como no tempo. As variações do teor de umidade do ar, associadas às da temperatura, estabelecem o nível de conforto ambiental. A sensação de desconforto é devida mais à umidade do ar do que propriamente à temperatura ambiente (Varejão-Silva, 2001)

## CAPÍTULO 3 INTELIGÊNCIA COMPUTACIONAL

Para contornar os problemas encontrados pelos métodos convencionais de modelagem, que apoiam-se em ferramentas matemáticas que enfatizam a precisão e a descrição exata de cada quantidade envolvida, propostas alternativas surgiram nas últimas décadas, tais como a modelagem por Lógica Fuzzy (LF) e a modelagem por redes neurais artificiais (RNA). Essas duas técnicas de modelagem têm sido empregadas com sucesso em várias áreas onde a abordagem convencional tem falhado em fornecer soluções satisfatórias, especialmente à medida que o sistema em foco cresce e torna-se complexo (Souza 1999).

Essas duas abordagens fazem parte do conjunto de técnicas estudadas na área de Inteligência Computacional. Por causa de suas origens distintas, suas abordagens na solução de problemas de modelagem são em geral complementares. Como consequência, muitos pesquisadores têm tentado integrar essas duas técnicas de modelagem para gerar um modelo híbrido que possa associar as vantagens de cada abordagem e minimizar suas deficiências. O Quadro 3.1 apresenta as diferentes técnicas e respectivas inspirações que as originaram.

Quadro 3.1 – Técnicas de Inteligência Artificial

<b>Técnica Computacional</b>	<b>Inspiração</b>
Redes Neurais (RN)	Neurônios Biológicos
Lógica Fuzzy (LF)	Processamento Lingüístico
Modelos Híbridos (Ex. Neuro-fuzzy)	Simbiose entre RN e LF

### 3.1 – LÓGICA FUZZY

A Teoria dos Conjuntos Nebulosos (*Fuzzy Sets*) fornece uma base matemática que permite o manuseio das imprecisões – que podem ser chamadas **expressões lingüísticas** – para a implementação de um Sistema de Raciocínio Nebuloso, vago ou impreciso semelhante à forma humana de raciocinar.

Como todo conceito revolucionário, a Lógica Fuzzy enfrentou resistências das mais variadas, principalmente das correntes mais conservadoras do mundo acadêmico, que fizeram com que este novo paradigma de modelagem de sistemas percorresse, como tantos outros, o trinômio ceticismo, oposição e aceitação.

Historicamente sua origem tem-se em 1965 com a criação da Teoria dos Conjuntos Nebulosos por Lotfi A. Zadeh. Em 1974, foi criado o primeiro controlador nebuloso por Mamdani. Apesar da oposição inicial, os números da Indústria mundial comprovam: os produtos com tecnologia *Fuzzy* funcionam, são mais baratos e oferecem excelente relação custo x benefício. Em 1994 o Japão exportou 35 Bilhões de Dólares em equipamentos com Lógica Fuzzy ou Neuro-Fuzzy embutidos. A grande variabilidade de uso inclui desde sistemas de controle, sistemas de tomada de decisão, sistemas diagnósticos a reconhecimentos de padrões.

### Conjuntos Nebulosos

Formalmente, se quisermos definir um conjunto **A** de um universo de discurso **U**, e qualquer elemento **x** pertencente a **U**, teremos a função:

$$f_A(x) : U \rightarrow A.$$

Onde:  $f_A$  é chamada de função característica pois define os elementos de **A**.

tal que:

- $f_A(x) = 1$  se e somente se  $X \in A$
- $f_A(x) = 0$  se e somente se  $X \notin A$

• Se generalizarmos esta função  $f_A$  para qualquer **valor de saída** dentro de um intervalo fechado  $[0,1]$ , teremos uma função de pertinência de um conjunto nebuloso (*fuzzy*), definida como:

$$\mu_A(x) : U \rightarrow [0,1]$$

onde o grau de pertinência (*membership*) dessa função pode assumir um número infinito de valores dentro deste intervalo.

## 3.2 – REDES NEURAIS

O desenvolvimento de estudos de Redes Neurais tem raízes em muitas disciplinas, que vão desde a neurociência até a mecânica estatística, passando pela matemática, ciência da computação e engenharia.

As Redes Neurais conseguem apresentar algumas características de processamento inteligente, como é o caso da adaptação, tolerância a falhas e ruídos, tomada de decisões e a mais importante: a habilidade de **aprender** a partir de dados de entrada. Este conjunto de características fornece às redes neurais artificiais potencialidade para resolver uma série de problemas como reconhecimento visual de padrões, análise de séries temporais, reconhecimento de voz e imagem, entre outros (Silva, 2002).

As *Redes Neurais* têm seus princípios fundamentais assentados no modelo de um *cérebro humano*. Sua principal propriedade é o *aprendizado* a partir de dados de entrada. Os dados podem ser não-lineares, ruidosos, incompletos ou contraditórios. São aplicadas em vários campos, como reconhecimento e classificação de padrões e análise de séries.

Em 1943, McCulloch e Pitts formularam a primeira definição formal de um modelo simples de um neurônio baseada nas considerações do modelo biológico, que forma a base para o projeto de redes neurais (artificiais). Aqui nós identificamos três elementos básicos do modelo do neurônio, conforme pode ser visto na figura 3.1:

1. Um conjunto de *sinapses* ou *elos de conexão*, cada uma caracterizada por um *peso* ou *força* própria. Especificamente, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicado pelo peso sináptico  $w_{kj}$ . É importante notar a maneira como são escritos os índices do peso sináptico  $w_{kj}$ . O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos bem como positivos.
2. Um *somador* para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um *combinador linear*.

3. Uma *função de ativação* para restringir a amplitude da saída de um neurônio. A função de ativação é também referida *como função restritiva*. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado  $[0, 1]$  ou alternativamente  $[-1, 1]$ .

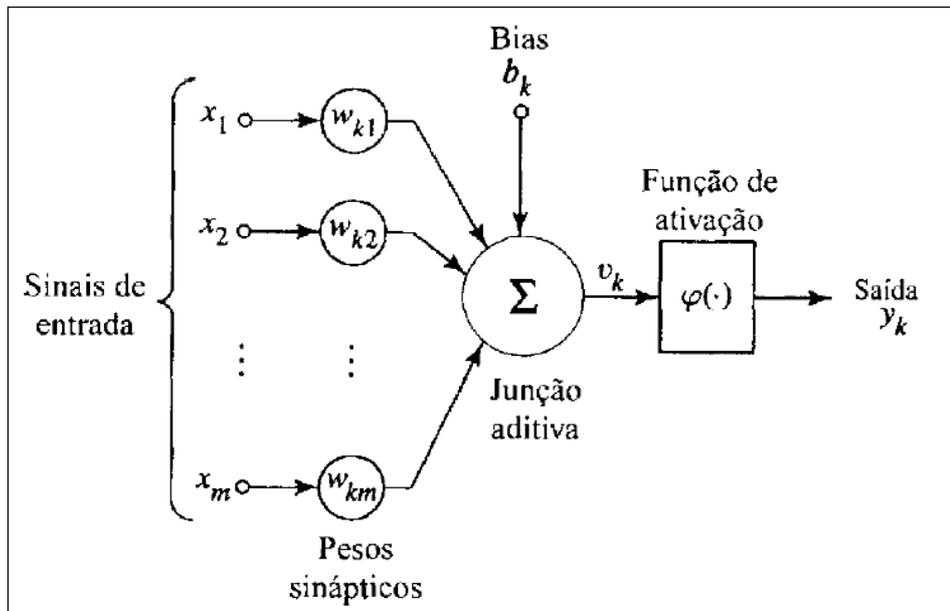


Figura 3.1 - Modelo não linear de neurônio.

A modelagem da topologia da rede neural (figura 3.2) corresponde a descrição das interconexões entre os neurônios da rede. A topologia (estrutura) da rede tem reflexos significativos nas características e propriedades apresentadas pelo modelo. As redes neurais podem ser classificadas, quanto à estrutura de conexão, em *feedforward* (alimentada adiante) e *feedback* (recorrentes).

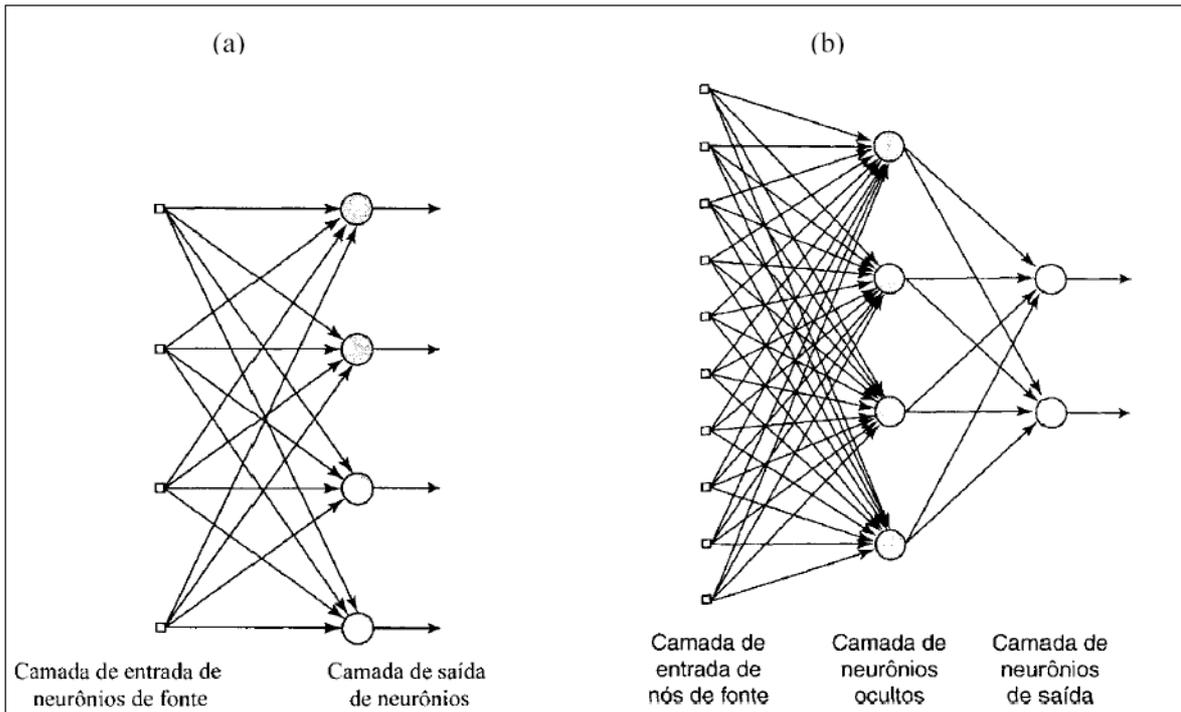


Figura 3.2 - Modelos de redes neurais: a – Com uma única camada de neurônio e (b) – Totalmente conectada com uma camada oculta.

### 3.3 – NEURO-FUZZY

Os sistemas Neuro-Fuzzy estão entre os sistemas híbridos mais pesquisados na atualidade, por associarem vantagens de duas técnicas de modelagem muito populares como as Redes Neurais e a Lógica Fuzzy.

Atualmente, estes sistemas estão sob intensa investigação. Tal fato deve-se principalmente à confluência dos seguintes fatores: a) aplicabilidade dos algoritmos de aprendizado desenvolvidos para redes neurais; b) possibilidade de promover a integração de conhecimentos (implícito e explícito); e c) possibilidade de extração de conhecimento, sob o formato de regras fuzzy, a partir de um conjunto de dados.

A idéia básica de um Sistema Neuro-Fuzzy é implementar um Sistema de Inferência Fuzzy numa arquitetura paralela distribuída de tal forma que os paradigmas de aprendizado comuns às redes neurais possam ser aproveitados nesta arquitetura híbrida. A pesquisa na área dos Sistemas Neuro-Fuzzy busca, portanto, a maximização das propriedades desejáveis das Redes Neurais e Sistemas de Inferência Fuzzy e a minimização de suas limitações e

deficiências. O esforço para vencer essas limitações tem sido umas das principais motivações na criação desses sistemas híbridos inteligentes.

Devido à natureza dual destes sistemas, propôs-se a divisão da taxonomia desses SNF em duas categorias (Souza, 1999), quanto às características fuzzy do sistema e quanto às características de aprendizado. Onde uma categoria contempla o lado fuzzy enquanto a outra contempla o lado neural (referente às características de aprendizado).

Com relação às características fuzzy dos sistemas Neuro-Fuzzy, a taxonomia divide-se em quatro sub-classes (Souza, 1999):

- Modelo Fuzzy
- Formato das funções de pertinência
- Particionamento do espaço de entrada/saída
- Método de defuzzificação

Os principais modelos de inferência fuzzy são Mamdani, Takagi-Sugeno e Tsukamoto, a diferença básica entre os modelos recai no tipo de conseqüente e no procedimento de defuzzificação. Estes modelos são mais adequados para aplicações em controle, previsão, reconhecimento de padrões, aproximação de funções, sistemas especialistas, entre outros. Existe ainda um quarto formato que contemplar os sistemas fuzzy de classificação.

As Funções de Pertinência podem ser apresentadas através de várias formas na implementação de sistemas fuzzy e Neuro-Fuzzy. Os 5 tipos mais comuns de funções de pertinência são: triangular, trapezoidal, gaussiano, sino e “singleton”.

As variáveis de entrada/saída dos sistemas de inferência fuzzy são divididas em vários termos lingüísticos (baixo, médio e alto, por exemplo) que são utilizados pelas regras fuzzy. Com relação ao espaço de entrada, o seu particionamento indica a forma como as regras fuzzy estão relacionadas com este espaço. O particionamento do espaço de saída costuma ser mais simples e está associado aos conseqüentes das regras. Neste trabalho utilizaremos o particionamento *Fuzzy Grid* que é simples e intuitivo.

O particionamento *Fuzzy Grid* é fixo, não permitindo ajustes nas funções de pertinência. Os sistemas que o utilizam ajustam apenas os parâmetros dos conseqüentes.

Existem particionamentos flexíveis que permitem ajustes nos perfis das funções de pertinência que criam novas regras localmente, conforme o conjunto de treinamento. Sua vantagem principal é permitir a criação de sistemas que constroem sua própria estrutura de forma automática.

O processo de Defuzzificação determina o valor real da saída do sistema fuzzy após feitas as avaliações das regras fuzzy. Segundo Souza (1999), os métodos de defuzzificação mais encontrados nos Sistemas Neuro-Fuzzy são: **Centro de Área**, onde a saída é produzida pelo cálculo do centro de gravidade do conjunto fuzzy conseqüente obtido pela composição das regras; **Média Ponderada**, que combina os conseqüentes das regras fuzzy com o nível de disparo de cada uma delas; **Centro de Somas**, que é uma simplificação do método do centro de área, com a vantagem de necessitar menor esforço computacional no cálculo da saída; **Defuzzificação Caixa Preta**, que faz uso de uma rede neural para implementar a etapa de defuzzificação, neste método, os valores dos níveis de disparo de cada regra são ponderados e somados em neurônios com função de ativação sigmoide.

Dividiu-se em três subclasses a taxonomia quanto às características de aprendizado dos sistemas Neuro-Fuzzy (Souza, 1999):

- Quanto à apresentação dos padrões de treinamento;
- Quanto ao método de identificação da estrutura;
- Quanto ao aprendizado dos parâmetros.

A apresentação dos padrões de treinamento pode ser realizada de duas formas diferentes: o aprendizado Off-line e o aprendizado On-line. O aprendizado Off-line requer um conjunto de dados de treinamento disponível antes da identificação da estrutura e dos parâmetros pois a atualização dos parâmetros só é feita após a apresentação de todo o conjunto de treinamento. No Aprendizado on-line, onde a atualização dos parâmetros acontece logo após cada par de treinamento ter sido apresentado, sendo indicada quando não se tem previamente um conjunto de dados de treinamento.

A identificação da estrutura está relacionada à determinação de um número adequado de regras fuzzy, podendo ser Identificação Prévia ou Automática. O método de Identificação Prévia pode ser uma distribuição uniforme, auto-organizado ou com apoio de especialista. A identificação Automática o aprendizado das regras pode ser feito de forma incremental,

partindo-se de um conjunto de regras vazias onde novas regras são acrescentadas segundo uma determinada heurística, ou decremental, que inicia-se com um conjunto superestimado de regras sendo eliminadas por um processo de eliminação de regras supérfluas.

O aprendizado dos parâmetros determina como os pesos das regras devem ser ajustados para minimizar o erro, ou seja, trata-se do ajuste dos parâmetros do sistema, tais como os pesos fuzzy que definem os perfis das funções de pertinência dos antecedentes e conseqüentes das regras fuzzy, e o peso ou importância relativa destas regras. pode-se dividir os sistemas Neuro-Fuzzy em três tipos: Sistemas com identificação apenas dos antecedentes, Sistemas com identificação dos antecedentes e conseqüentes, Sistemas com identificação dos antecedentes, conseqüentes e peso das regras.

Uma vez que o modelo Neuro-Fuzzy utilizado neste trabalho foi o ANFIS, o mesmo será descrito a seguir.

### **3.3.1 - MODELO ANFIS**

O sistema Neuro-Fuzzy ANFIS foi criado por Jang (1993) e sua sigla significa “*Adaptive Network-based Fuzzy Inference System*”. Sua popularidade já o levou a ser inserido no MATLAB©.

#### **3.3.1.1 – ARQUITETURA**

Para simplificar, assumiremos que o sistema de inferência fuzzy a ser considerado tem duas entradas  $x$  e  $y$  e uma saída  $z$ . Para um modelo fuzzy Sugeno de primeira ordem, um conjunto de regras com duas regras fuzzy se-então é o seguinte:

Regra 1: Se  $x$  é  $A_1$  e  $y$  é  $B_1$ , então  $f_1 = p_1x + q_1y + r_1$ ,

Regra 2: Se  $x$  é  $A_2$  e  $y$  é  $B_2$ , então  $f_2 = p_2x + q_2y + r_2$ .

A figura 1 ilustra o mecanismo para este modelo Sugeno, a arquitetura ANFIS correspondente é mostrado na figura 2, onde os nós da mesma camada têm a mesma função. Conforme descrito a seguir.

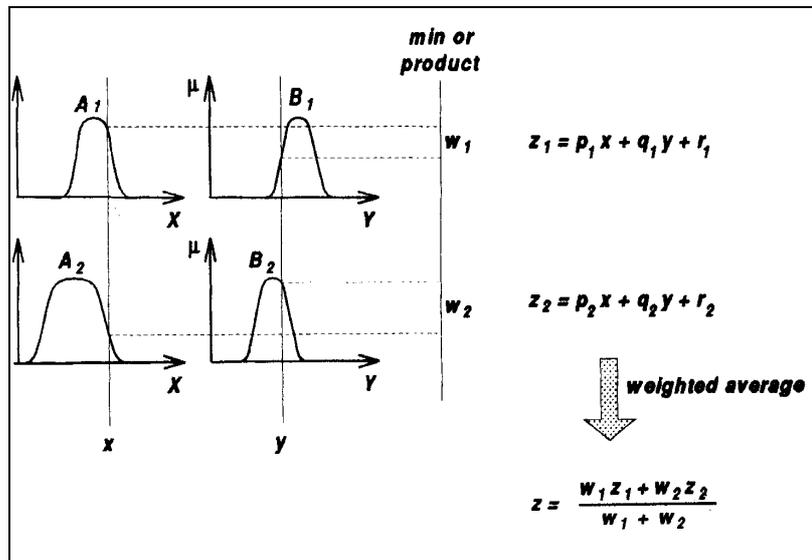


Figura 3.3 – Um modelo Sugeno de duas entradas com duas regras.

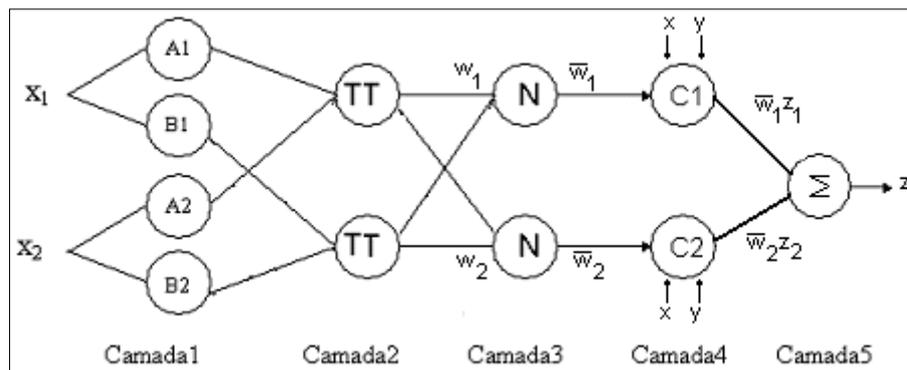


Figura 3.4 – arquitetura ANFIS equivalente ao modelo Sugeno com duas entradas

**Camada 1** – Cada nó  $i$  nesta camada é um nó adaptativo com uma função:

$$O_{1,i} = \mu_{A_i}(x), \quad \text{Para } i = 1, 2 \text{ ou}$$

$$O_{1,i} = \mu_{B_{i-2}}(y), \quad \text{Para } i = 3, 4,$$

Onde  $x$  (ou  $y$ ) é a entrada para o nó  $i$  e  $A_i$  (ou  $B_{i-2}$ ) é o termo lingüístico (como “pequeno” ou “grande”) associado a este nó. Em outras palavras,  $O_{1,i}$  é o grau de pertinência para conjunto fuzzy  $A$  ( $=A_i, A_2, B_i$  ou  $B_2$ ) e especifica o grau para cada entrada  $x$  (ou  $y$ ) satisfaz o

quantificado  $A$ . Aqui a função de pertinência para  $A$  pode ser qualquer função de pertinência parametrizada, como por exemplo a função sino:

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}},$$

Onde  $\{a_i, b_i, c_i\}$  é o conjunto de parâmetros. Como os valores destes parâmetros mudam, a função em forma de sino varia.

**Camada 2** - Cada nó nesta camada (marcados como TT), apresenta como saída o produtos de todos os sinais de entrada:

$$O_{2,i} = w_i = \mu_{A_i}(x)\mu_{B_i}(y), i = 1,2.$$

Cada nó de saída representa o disparo da regra. Em geral um operador T-norm que pode ser usado como função dos nós nesta camada.

**Camada 3** – Cada nó desta camada é marcado como N. os nós  $i$ 's calculam a razão de níveis de disparos de regras  $i$ 's pela soma de todos os níveis de disparo. Também chamada de camada de normalização.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2.$$

**Camada 4** - Cada  $i$  nesta camada é um nó adaptativo com uma função:

$$O_{4,i} = \bar{w}_i z_i = \bar{w}_i(p_i x + q_i y + r_i),$$

Onde  $\bar{w}_i$  é um nível de disparo normalizado da camada 3 e  $\{p_i, q_i, r_i\}$  é o conjunto de parâmetros deste nó. Os parâmetros nesta camada são chamados de consequentes.

**Camada 5** – O nó desta camada ( $\Sigma$ ), que computa a saída total como o somatório de todos os sinais de entrada:

$$SaídaTotal = O_{5,i} = \overline{\sum_i \bar{w}_i z_i} = \frac{\sum_i w_i z_i}{\sum_i w_i}$$

A estrutura desta rede adaptativa não é única, é possível combinar as camadas 3 e 4 para obter uma rede equivalente com somente 4 camadas. Da mesma forma, é possível obter normalização no último nível. A figura 3 ilustra um modelo ANFIS deste tipo. Em casos extremos é possível agrupar toda a rede em um único nó adaptativo com o mesmo conjunto de parâmetros. Obviamente a configuração da rede e o ajuste das funções dos nós são arbitrárias, a medida em que cada nó e cada camada realiza funcionalidades significativas e modulares.

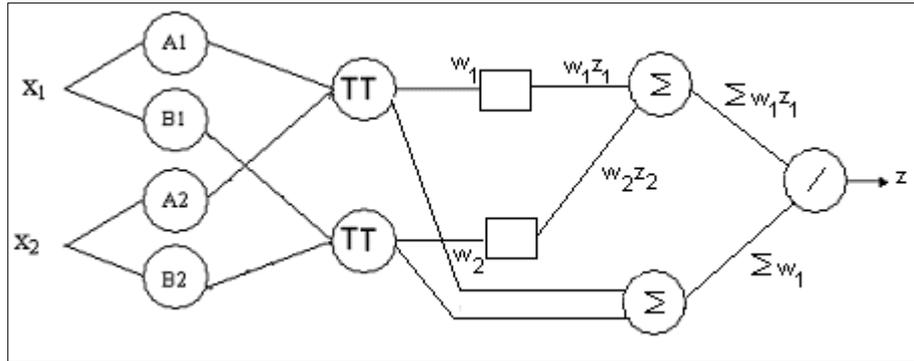


Figura 3.5 – arquitetura ANFIS equivalente ao modelo Sugeno com duas entradas, onde a normalização dos pesos é realizada na última camada.

### 3.3.1.2 – APRENDIZADO

A partir da arquitetura ANFIS mostrada na Figura 3.4, observa-se que quando os valores das premissas são fixados, a saída pode ser expressa como uma combinação linear dos conseqüentes. O valor  $f$  na figura 3.4 pode ser expresso como:

$$\begin{aligned}
 f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\
 &= \overline{w_1}(p_1x + q_1y + r_1) + \overline{w_2}(p_2x + q_2y + r_2) \\
 &= (\overline{w_1}x)p_1 + (\overline{w_1}y)q_1 + (\overline{w_1})r_1 + (\overline{w_2}y)q_2 + (\overline{w_2})r_2,
 \end{aligned}$$

Que é linear nos parâmetros conseqüentes,  $p_1, q_1, r_1, p_2, q_2, e r_2$ . Desta observação, tem-se:

S = Conjunto total de parâmetros

S1 = Conjunto de parâmetros premissas

S2 = Conjunto de parâmetros (lineares) conseqüentes

Este sistema utiliza o particionamento Fuzzy-grid Adaptativo. Seu aprendizado (identificação da estrutura e parâmetros) é feito em duas etapas que se repetem até que o critério de parada seja alcançado:

*Etapa 1* - fixam-se os parâmetros das premissas (antecedentes) e os consequentes são ajustados pelo método MQO, estimação por mínimos quadrados ordinários (Costa Neto, 1977).

*Etapa 2* - fixam-se os parâmetros dos consequentes e os parâmetros dos antecedentes são ajustados pelo algoritmo GD, Gradient Descent (Haykin, 1994).

## CAPÍTULO 4 MATERIAIS E MÉTODOS

### 4.1 – BUSCA DOS DADOS

Todos as informações utilizados compõem climatologias regulares. O processo de obtenção desses valores médios regularmente distribuídos, representativos mensalmente (excetuando-se batimetria e faciologia) é descrito a seguir.

O conjunto de dados utilizado nesse trabalho está descrito na tabela 4.1. Os dados de Salinidade, temperatura e parâmetros meteorológicos correspondem a médias mensais.

Parâmetro	Núm. de pontos /resolução da grade	Níveis	Total
Temperatura	156 / 1°	Até 33 em 12 meses	55.154
Salinidade	156 / 1°	Até 33 em 12 meses	55.154
Tipo de Fundo	16088 / 0.1°	1	16.088
Batimetria	16088 / 0.1°	1	16.088
Temperatura do Ar	16088 / 0.1°	1 em 12 meses	193.056
Pressão Atmosférica	16088 / 0.1°	1 em 12 meses	193.056
Umidade do Ar	16088 / 0.1°	1 em 12 meses	193.056
Total			721.652

Tabela 4.1 – Quantidade de dados nas climatologias utilizadas.

Em um sistema de banco de dados relacional (MS Access<sup>®</sup>) os dados ocupam 7.696 MB de memória.

#### 4.1.1 – TEMPERATURA E SALINIDADE

Os dados referentes a temperatura e salinidade foram obtidos junto ao BNDO/DHN (Banco Nacional de Dados Oceanográficos)/diretoria de Hidrografia e Navegação) e NODC/NOAA (National Oceanographic Data Center) e não representavam perfis climatológicos. O departamento de Engenharia Oceânica do Instituto de Estudos do Mar Alte. Paulo Moreira desenvolve um projeto que necessita de climatologias de temperatura e salinidade fazendo uso de uma rotina de tratamento e qualificação para tais dados. A rotina

envolve a identificação de erros, correção (quando possível), eliminação de duplicados e aplicação de procedimentos estatísticos para a obtenção de perfis médios mensais representativos para uma grade regular de 1°. Esta rotina foi utilizada para a obtenção da grade regular que servirá de entrada para o modelo utilizado neste trabalho.

Os testes aplicados nos dados foram baseados nas rotinas descritas no Global Temperature Salinity Pilot project - GTSP (COI/UNESCO,1984). Essas rotinas qualificam os dados seguindo uma seqüência de testes que envolvem várias possibilidades de falha do equipamento ou coleta. Os perfis marcados por este sistema são avaliados por um analista que pode usar ferramentas de edição para corrigir ou descartá-los.

Os perfis qualificados passam por tratamento, previamente para o estabelecimento de interpolação linear no eixo da profundidade em níveis padrões (tabela 4.2), e em seguida através de um procedimento chamado análise objetiva, o estabelecimento da climatologia mensal representativa para grade com resolução de 1° por 1°. Este processamento resultou em uma base de dados com 156 perfis de temperatura e salinidade para cada mês, ou 4588 valores de temperatura e salinidade em todos nos níveis até o nível padrão mais próximo do fundo para cada mês.

Nível	Prof (m)	Nível	Prof (m)	Nível	Prof (m)
1	0	12	300	23	1400
2	10	13	400	24	1500
3	20	14	500	25	1750
4	30	15	600	26	2000
5	50	16	700	27	2500
6	75	17	800	28	3000
7	100	18	900	29	3500
8	125	19	1000	30	4000
9	150	20	1100	31	4500
10	200	21	1200	32	5000
11	250	22	1300	33	5500

Tabela 4.2 – Níveis de Profundidades Padrões

#### 4.1.2 – TIPO DE FUNDO

Os dados referentes ao tipo de fundo, ou faciologia, utilizados neste trabalho foram obtidos pela Divisão de Geologia do Instituto de Estudos do Mar Almirante Paulo Moreira junto ao sistema de Geologia do Banco Nacional de Dados Oceanográficos (SISGEO-BNDO). Aproximadamente 13.000 amostras geológicas da margem continental brasileira

foram obtidas e tratadas. Estes dados compreendem basicamente dois níveis de informações: Tença e Análise Laboratorial.

A Tença é uma classificação baseada na análise visual da amostra no momento de sua coleta e tem como finalidade fornecer informações sobre o tipo de fundo para a comunidade hidrográfica, cujo interesse primário é a segurança da navegação detectando “altos-fundos” e assegurando fundeios. O segundo nível de informações, o de Análise Laboratoriais, é mais preciso que o anterior e abrange cerca de 8.000 amostras de sedimentos do banco de amostras. No entanto para regiões com profundidades superiores a 200 metros, a quantidade de dados é limitada, compreendendo cerca de 300 amostras. As análises são feitas nos diversos laboratórios de análises granulométricas do país, os quais, em sua maioria, usam a metodologia desenvolvida por Folk & Ward (1957).

Após a identificação das diversas frações granulométricas que compõem as amostras de sedimentos, são realizados cálculos estatísticos (média, mediana, desvio padrão, assimetria e curtose) que permitem classificar os sedimentos em função de seus parâmetros estatísticos. Outro tipo de classificação resultante desta análise é a de Shepard (1963). Nesta classificação os percentuais de cascalho areia e lama (site e argila) são dispostos em um gráfico triangular de onde se poderá identificar se o sedimento é cascalho, cascalho arenoso, areia cascalhosa, areia, areia lamosa, lama arenosa ou lama. As classes de tipo de fundo utilizadas para a caracterização da área de estudo estão relacionadas na tabela 4.3 a seguir.

CLASSE	TIPO	CLASSE	TIPO
1	lama	10	cascalho arenoso
2	lama cascalhosa	11	areia lamosa
3	lama cascalho areia	12	areia lama cascalho
4	lama areia cascalho	13	areia cascalho lama
5	lama arenosa	14	areia cascalhosa
6	cascalho lamoso	15	areia
7	cascalho	16	rochas
8	cascalho lama areia	17	sedimento lamoso
9	cascalho areia lama	18	sedimento arenoso

Tabela 4.3 – Classes faciológicas adotadas para a área de estudo

Os dados de tipo de fundo tiveram suas posições formatadas para coordenadas geográficas (gg:mm:ss,ss), no datum WGS84. Os dados integraram uma única base de dados que serviram de base para confecção de uma superfície regular utilizando o software Oasis Montaj da Geosoft Inc. versão 5.1.4. Foram adotados o tamanho de célula de *gridagem* de 0.1° e o método de mínima curvatura foram usados para a geração desta superfície

matemática. Esta resolução gerou uma base de dados com 16088 pontos para a região de estudo.

#### 4.1.3 - BATIMETRIA

Os dados referentes a batimetria utilizados neste trabalho foram obtidos junto a Divisão de Geologia do Instituto de Estudos do Mar Almirante Paulo Moreira. A base de dados foi confeccionada a partir das informações batiméticas das cartas náuticas da série 100 e 1000, dos dados do Programa de Levantamento da Plataforma Continental Brasileira (LEPLAC) e GEODAS e da base de dados internacional de elevação terrestre e oceânica ETOPO2 da *National Geophysical Data Center* (NGDC) dos EUA.

A base de dados oriunda das cartas náuticas possui as posições das profundidades medidas segundo especificações técnicas emanadas pela Comissão Hidrográfica Internacional (OHI) e cobrem integralmente a plataforma continental brasileira sendo que em função da conformação da margem continental brasileira podem alcançar as regiões abissais. Estas informações são consideradas de alta confiabilidade.

A base de dados batimétricos coletados para o LEPLAC também seguiram as especificações da OHI para os levantamentos considerados como de ordem especial. Neste levantamento os perfis foram espaçados em 15 Km, em média, cobrindo profundidades que variaram de 200m a 6000 m. Neste banco de dados estão contidos também as informações de profundidades da base de dados GEODAS que agrega informações de várias instituições de diversos países. Esta base de dados cobre de forma não uniforme toda a superfície do planeta e, por ter diversos métodos de aquisição e processamento, requer uma criteriosa análise antes de sua utilização.

A base de dados ETOPO2 (*Global gridded elevations data*) forneceram informações espaçadas em até 2 milhas náuticas, e forneceram dados para preencher os vazios das outras bases de dados. As informações do ETOPO2 são provenientes de medições indiretas realizadas por duas fontes: a primeira fonte destes dados são os obtidos por satélites que medem a superfície dos oceanos com resolução capaz de detectar as suas rugosidades em função da topografia do fundo oceânico, sendo desta forma obtida a profundidade prevista; a segunda fonte de dados são os cruzeiros regulares realizados por navios de várias instituições

acadêmicas e governamentais. Em função da instabilidade dos dados do ETOPO, foram selecionados os valores absolutos superiores a 2500 m para este trabalho.

Os dados batimétricos oriundos das três fontes de dados tiveram suas posições formatadas para coordenadas geográficas (gg:mm:ss,ss), no datum WGS84 e, utilizando o software Oasis Montaj da Geosoft Inc. versão 5.1.4, efetuou-se a análise da consistência individual destas informações. Os dados considerados consistentes integraram uma única base de dados que serviram de base para confecção de uma superfície matemática que retratasse a geomorfologia marinha. Foram adotados o tamanho de célula de *gridagem* de 0.1° e o método de mínima curvatura para a geração desta superfície matemática. Esta resolução gerou uma base de dados com 16088 pontos para a região de estudo.

#### **4.1.4 – TEMPERATURA DO AR, PRESSÃO ATMOSFÉRICA E UMIDADE RELATIVA DO AR**

Os dados referentes a meteorologia foram obtidos junto ao National Centers for Environmental Prediction (NCEP-EUA). Tais dados correspondem a médias mensais dos campos de reanálise descritos em Kistler (2001). O NCEP disponibiliza dados de reanálise nos 4 horários sinóticos diários desde 1948, no entanto para este trabalho foram utilizados dados entre 1978 a 1996.

A resolução original dos dados obtidos junto ao NCEP corresponde a um grid regular de 1° por 1°. No entanto estes dados foram interpolados através do método de mínima curvatura pela Divisão de Meteorologia do IEAPM para 0.1° por 0.1° gerando uma base de dados com 16088 pontos para cada um dos parâmetros.

## 4.2 – GERAÇÃO DE GRADE REGULAR COM TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL

A rotina descrita no apêndice I apresenta o algoritmo de ajuste dos pesos do sistema neuro-fuzzy utilizado para a reconstituição dos parâmetros ambientais em estudo.

Para o aprendizado neuro-fuzzy os dados foram separados em conjuntos de treinamento (arquivos ASCII) em função do tamanho dos conjuntos de dados brutos e também em função do número de entradas e saídas. O número de conjuntos nebulosos para cada entrada é estabelecido em sucessivas tentativas até que o treinamento de cada rede apresente resultados satisfatórios. De forma geral, estipulou-se um maior número de conjuntos nebulosos para a longitude do que para a latitude e para a temperatura e salinidade a profundidade também teve que ser subdividida em conjuntos nebulosos, que no geral foram superiores aos da latitude. A figura 4.1 apresenta um esquema do processo de ajuste dos pesos para os parâmetros ambientais.

É importante ressaltar que quanto maior a complexidade dos dados de entrada, ou seja, maior variabilidade e maior quantidade, mais conjuntos nebulosos são necessários para a convergência do erro de saída.

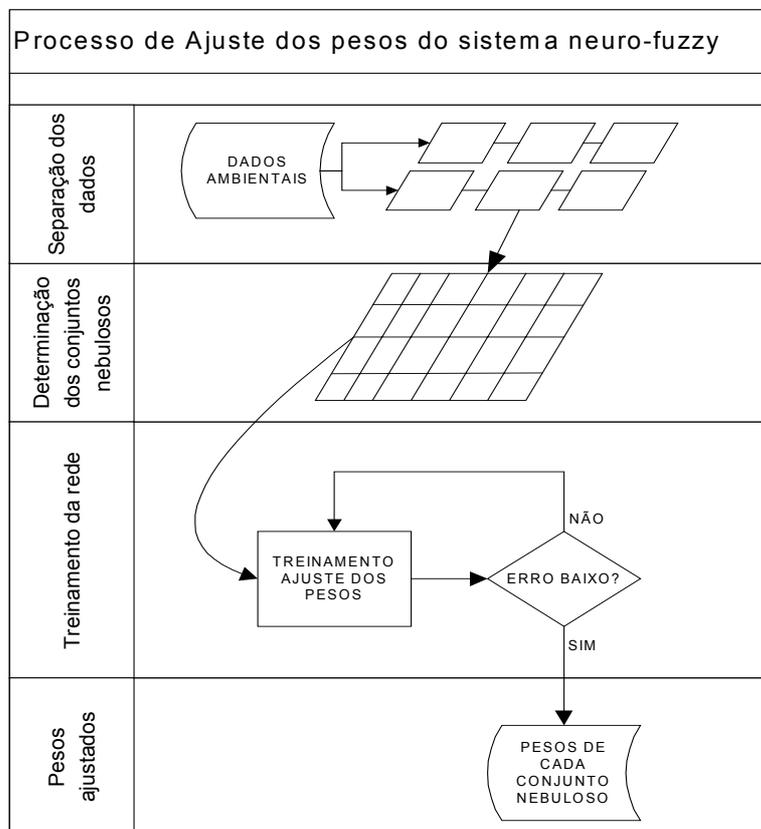


Figura 4.1 – Esquema do processo de obtenção dos pesos de saída

Cada parâmetro teve sua topologia da rede de treinamento definida da seguinte forma:

**a) Batimetria**

Devido ao grande número de dados batimétricos (16088) e a grande variabilidade entre os valores, a área foi dividida em sete sub-áreas conforme a figura 4.2. Foram desenvolvidos modelos neuro-fuzzy para cada sub-área. A tabela 4.5 descreve os limites de cada sub-área e o número de conjuntos nebulosos usados em cada modelo.

Sub-área	Conjuntos de latitude	Conjuntos de longitude	Limite Inferior de Latitude	Limite Superior de latitude	Limite Inferior de longitude	Limite Superior de longitude
1	35	35	-25	-20	-35	-30
2	50	50	-25	-20	-40	-35
3	25	25	-25	-20	-48	-40
4	35	35	-29.9	-25	-35	-30
5	30	30	-29.9	-25	-40	-35
6	30	30	-29.9	-25	-45	-40
7	45	45	-29.9	-25	-49.9	-45

Tabela 4.5 – Estrutura dos dados de batimetria usados para a modelagem neuro-fuzzy.

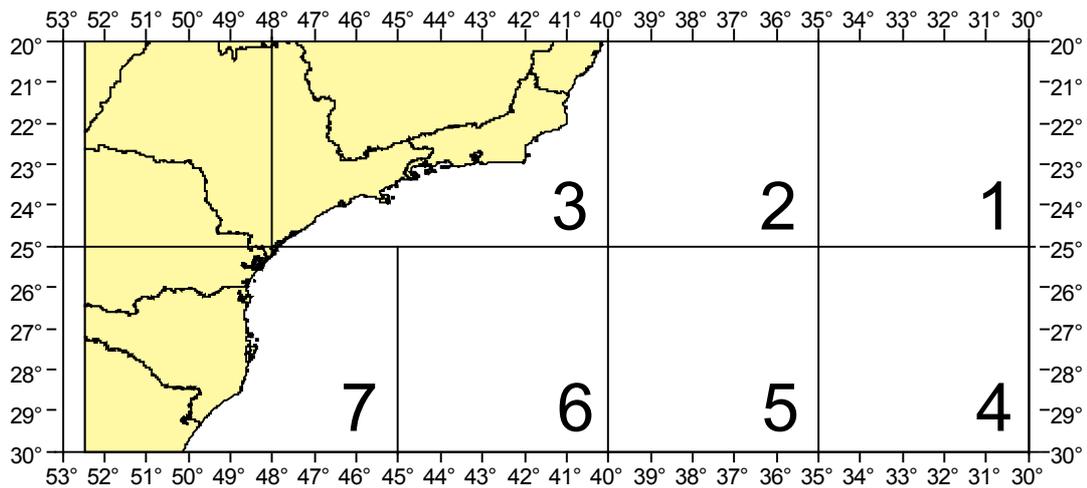


Figura 4.2 – Área de estudo subdividida em 7 áreas para a modelagem neuro-fuzzy da batimetria.

A figura 4.3 exemplifica a arquitetura Neuro-fuzzy usada na batimetria.

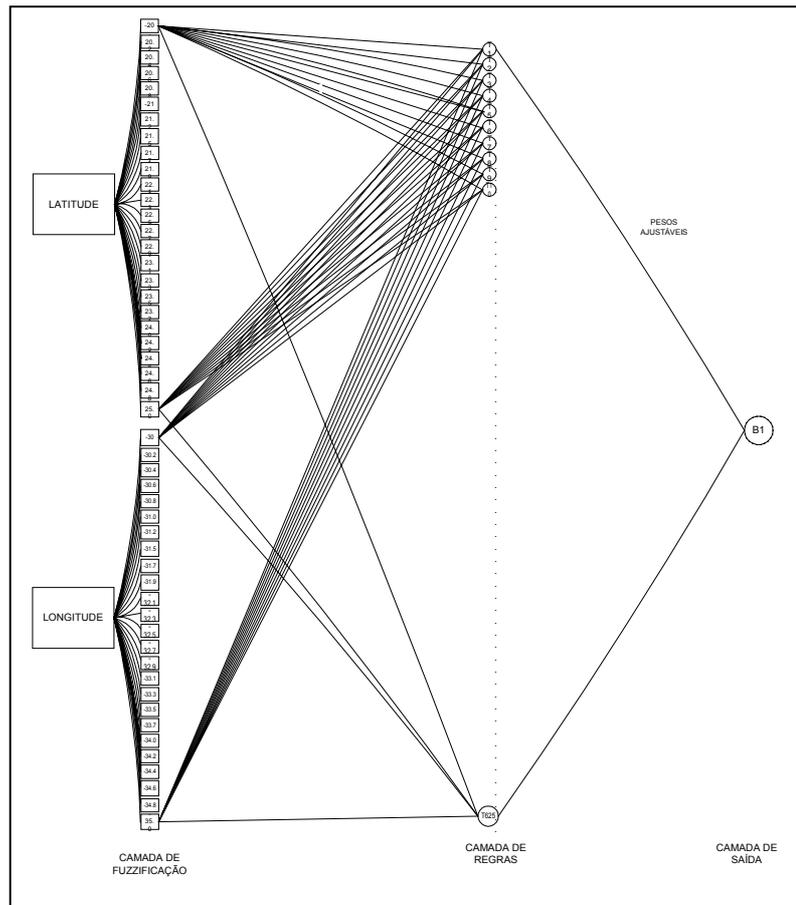


Figura 4.3 - arquitetura Neuro-fuzzy usada na sub-área 3 da batimetria.

As Funções de pertinências dos modelos neuro-fuzzy usados na batimetria estão descritos na figura 4.3.1.

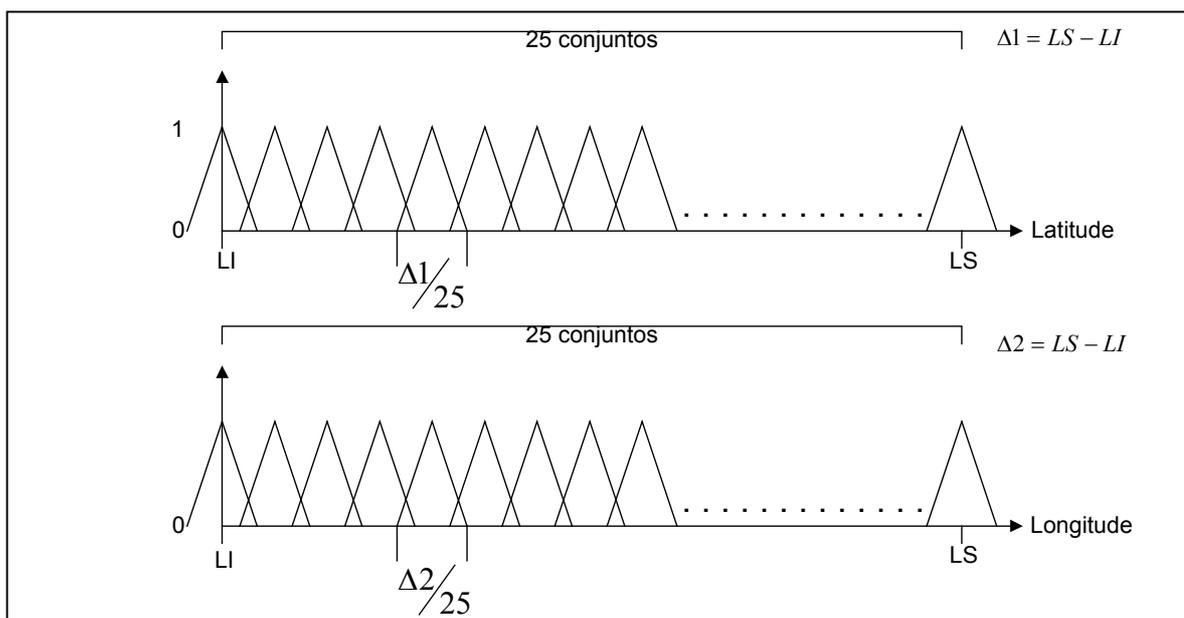


Figura 4.3.1 – Funções de pertinência do modelo neuro-fuzzy usado na batimetria.

## b) Faciologia

A faciologia é representada por classes, portanto, a estrutura da rede foi concebida para apresentar 18 saídas, sendo uma para cada possibilidade de classe, dessa forma, o resultado apresentado será sempre a classe cuja saída apresente o maior valor. A área foi subdividida em 4 sub-áreas conforme a figura 4.4.

Em comparação com a batimetria, um menor número de sub-áreas para os dados faciológicos implicou em um maior número de divisões em conjuntos de latitude em longitudes para os dados de faciologia, conforme a tabela 4.6.

Sub-área	Conjuntos de latitude	Conjuntos De longitude	Limite Inferior de latitude (LI)	Limite Superior de latitude (LS)	Limite Inferior de longitude (LI)	Limite Superior de longitude (LS)
1	60	70	-25	-20	-40	-30
2	60	70	-25	-20	-47.8	-40
3	60	70	-29.9	-25	-40	-30
4	70	80	-29.9	-25	-49.9	-40

Tabela 4.6 – Estrutura dos conjuntos de treinamento de faciologia usados para a modelagem neuro-fuzzy.

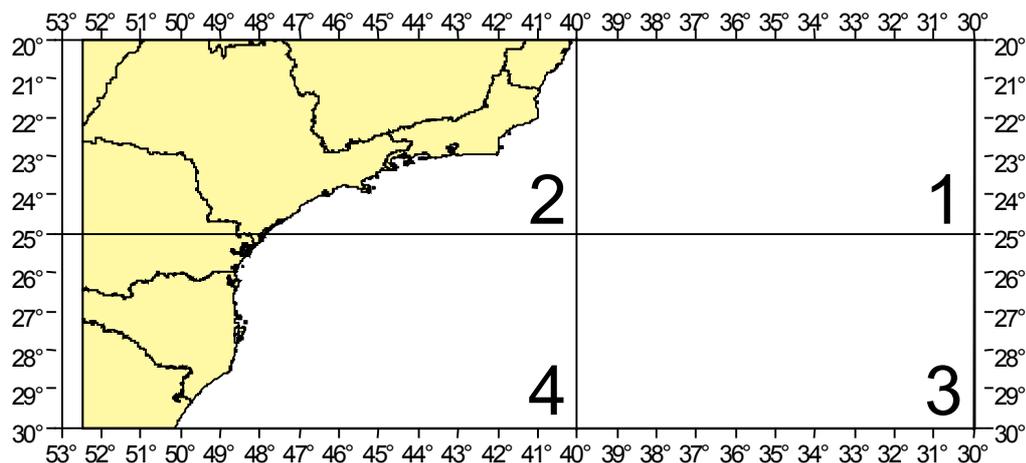


Figura 4.4 – Área de estudo subdividida em 4 áreas para a modelagem neuro-fuzzy da faciologia

A figura 4.5 exemplifica a arquitetura Neuro-fuzzy usada na faciologia.

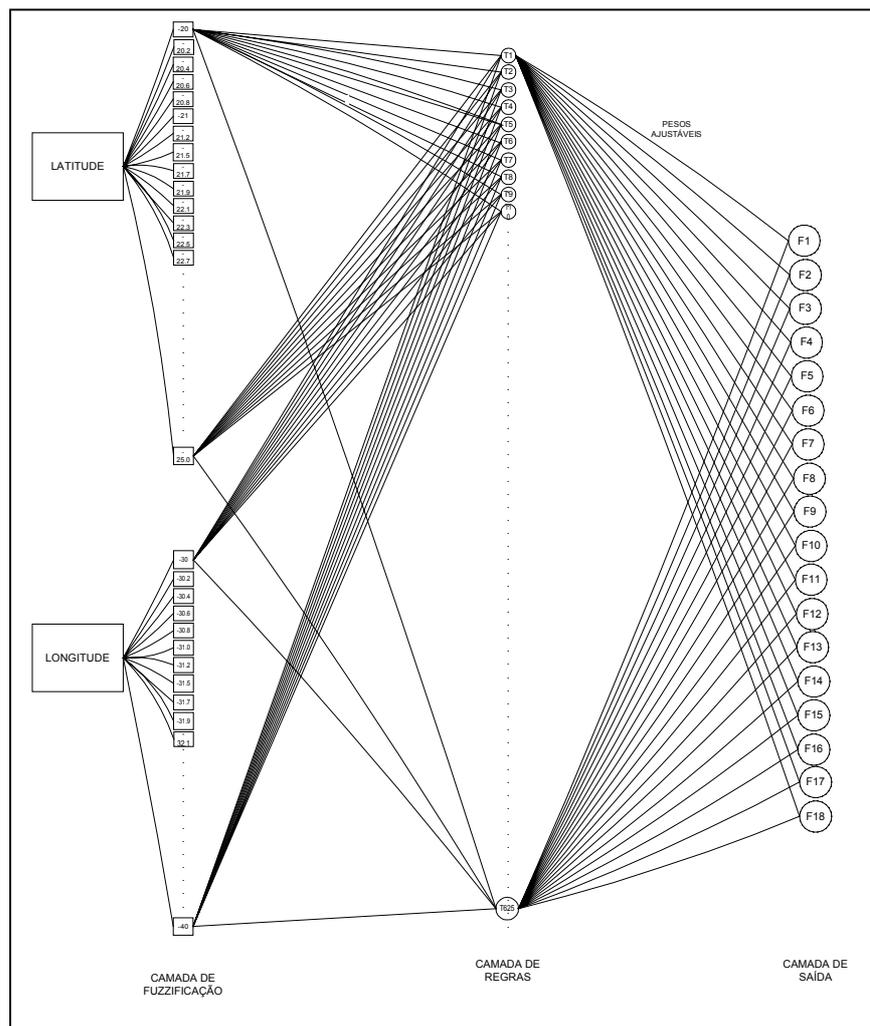


Figura 4.5 - arquitetura Neuro-fuzzy usada na sub-área 1 da faciologia.

As Funções de pertinências dos modelos neuro-fuzzy usados na faciologia são semelhantes os utilizados na batimetria exemplificado na figura 4.3.1.

### c) Temperatura e Salinidade

A temperatura e a salinidade são os únicos parâmetros com mais de uma camada dentre os parâmetros do estudo. Por este motivo, a profundidade torna-se uma das entradas para os modelos neuro-fuzzy.

Os dados de temperatura e salinidade foram separados, em função da profundidade, em 5 arquivos de treinamento para cada mês totalizando 60 arquivos para cada parâmetro (0 a

75 metros, 75 a 400 metros, 400 a 1100 metros, 1100 a 2500 metros, maior ou igual a 2500 metros). Os conjuntos de treinamento para temperatura foram definidos conforme a tabela 4.7.

Mês	Conjuntos De latitude	Conjuntos de longitude	Conjuntos de Prof.	Limite Inferior de latitude	Limite Superior de latitude	Limite Inferior de longitude	Limite Superior de longitude	Limite Inferior de Prof.	Limite Superior de Prof.
1	8	10	5	-29.5	-20.5	-49.5	-30.5	0	75
1	6	15	10	-29.5	-20.5	-49.5	-30.5	75	400
1	6	15	10	-29.5	-20.5	-48.5	-30.5	400	1100
1	6	15	10	-29.5	-20.5	-47.5	-30.5	1100	2500
1	8	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
2	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
2	10	10	15	-29.5	-20.5	-49.5	-30.5	75	400
2	6	15	10	-29.5	-20.5	-48.5	-30.5	400	1100
2	6	15	10	-29.5	-20.5	-47.5	-30.5	1100	2500
2	8	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
3	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
3	10	10	15	-29.5	-20.5	-49.5	-30.5	75	400
3	10	10	15	-29.5	-20.5	-48.5	-30.5	400	1100
3	6	15	10	-29.5	-20.5	-47.5	-30.5	1100	2500
3	8	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
4	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
4	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
4	10	8	10	-29.5	-20.5	-48.5	-30.5	400	1100
4	6	15	10	-29.5	-20.5	-47.5	-30.5	1100	2500
4	8	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
5	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
5	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
5	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
5	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
5	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
6	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
6	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
6	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
6	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
6	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
7	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
7	10	10	15	-29.5	-20.5	-49.5	-30.5	75	400
7	10	10	15	-29.5	-20.5	-48.5	-30.5	400	1100
7	10	10	15	-29.5	-20.5	-47.5	-30.5	1100	2500
7	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
8	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
8	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
8	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
8	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
8	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
9	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
9	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
9	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
9	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
9	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
10	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
10	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
10	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
10	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
10	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
11	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
11	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
11	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
11	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
11	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000
12	8	15	5	-29.5	-20.5	-49.5	-30.5	0	75
12	10	15	15	-29.5	-20.5	-49.5	-30.5	75	400
12	10	15	15	-29.5	-20.5	-48.5	-30.5	400	1100
12	10	15	15	-29.5	-20.5	-47.5	-30.5	1100	2500
12	10	15	15	-29.5	-20.5	-47.5	-30.5	2500	6000

Tabela 4.7 – Estrutura dos conjuntos de treinamento da temperatura usados para a modelagem neuro-fuzzy.

Todos os arquivos de treinamento de salinidade tiveram o mesmo numero de conjuntos de latitude, longitude e profundidade, sendo respectivamente, 8, 15 e 5. Isto foi possível pois a salinidade é um parâmetro que apresenta pequena variabilidade sazonal e ao longo da coluna d'água.

A figura 4.6 a seguir exemplifica a arquitetura Neuro-fuzzy usada na temperatura e salinidade.

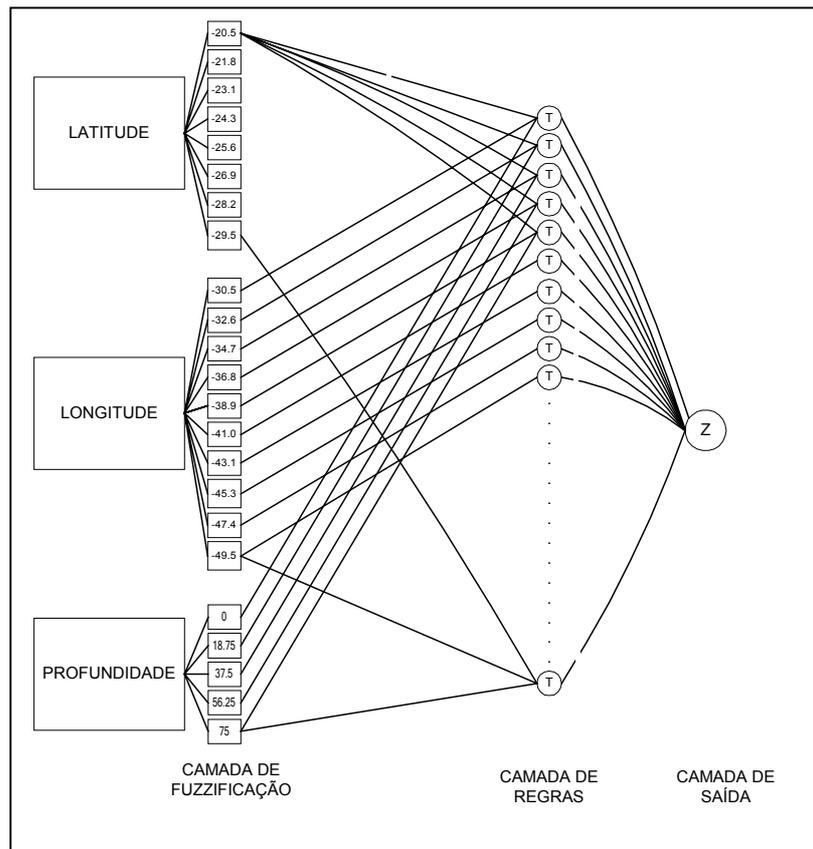


Figura 4.6 - arquitetura Neuro-fuzzy usada na temperatura ou salinidade para a camada de profundidade de 0 a 75 metros.

As Funções de pertinências dos modelos neuro-fuzzy usados na temperatura e salinidade podem ser descritos conforme a figura 4.6.1.

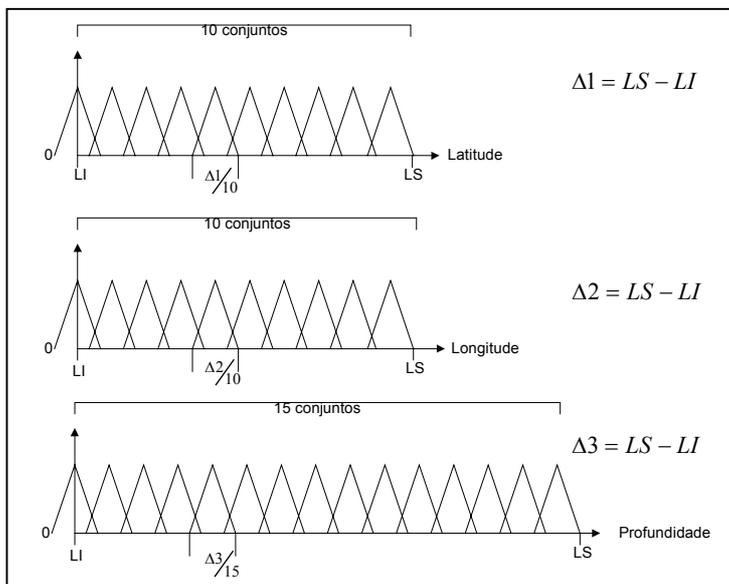


Figura 4.6.1 – Funções de pertinência do modelo neuro-fuzzy usado na temperatura e na salinidade

#### d) Pressão Atmosférica Umidade Relativa do Ar e Temperatura do Ar

Todos os parâmetros meteorológicos foram separados mensalmente para toda a área de estudo, e definidos para treinamento 35 conjuntos de latitude e 35 conjuntos de longitude. A arquitetura neuro-fuzzy utilizada foi semelhante aquela da batimetria mostrada na figura 4.3.

### 4.3 – ELABORAÇÃO DE MAPAS E GRÁFICOS COMPARATIVOS PARA AS DIFERENTES VARIÁVEIS

Após o ajuste dos pesos dos modelos neuro-fuzzy para cada parâmetro ambiental (em um total de 167 arquivos de treinamento) é possível obter estimativas em qualquer ponto da área de estudo. Dessa forma, para efeitos comparativos, os parâmetros ambientais foram estimados para as coordenadas coincidentes aos dos dados de treinamento.

Os dados estimados e de treinamento foram processados pelo aplicativo ArcView na extensão 3DAnalyst, que permite interpolar linearmente os dados com uma resolução igual a

resolução dos dados de entrada. Essa técnica foi utilizada para garantir que os dados apresentados visualmente em mapas com escala de cores fosse uma representação fiel de sua origem, sem gerar pontos intermediários resultantes do método de interpolação.

As figuras exibidas no capítulo Resultados mostram as comparações entre cada uma das variáveis. Para os parâmetros temperatura, salinidade, pressão, temperatura do ar, e umidade foram comparados os meses de janeiro, abril, julho e outubro (representativos para cada estação do ano). Os dados de temperatura e salinidade são comparados em 3 camadas na coluna d'água (10 metros, 100 metros e 1000 metros).

Para comparar os dados ao longo da coluna d'água, os dados de temperatura e salinidade são também comparados sob forma de perfis verticais da superfície até a profundidade padrão mais próxima do fundo para os meses de janeiro, abril, julho e outubro em um ponto da área de estudo escolhido ao acaso. A posição do ponto é 28.5S/32.5W, possuindo pontos representativos ao longo da coluna d'água até a profundidade de 1750 metros.

Além dos mapas e perfis comparativos também foram desenvolvidos mapas e perfis que representam as diferenças em porcentagem, essa forma de representação é especialmente importante pois facilita a identificação de regiões ou período (mês) com os erros mais marcantes entre o dado estimado pelo sistema neuro-fuzzy e o dado de treinamento.

## CAPÍTULO 5 RESULTADOS E DISCUSSÕES

Este capítulo está estruturado em 3 seções onde serão apresentados os produtos gerados a partir dos modelos neuro-fuzzy, sempre comparados com os dados originais. Na primeira seção serão mostrados e comentados os resultados e as diferenças obtidos para os parâmetros temperatura e salinidade apresentando a sua variação espacial nas profundidades de 10, 100 e 1000 metros para os meses de janeiro e julho, além de perfis nas profundidades padrões em 2 pontos da área de estudo. Na Segunda seção apresentar-se-á os parâmetros de fundo (batimetria e faciologia) e as suas respectivas diferenças em relação ao dado original. Finalmente, na terceira seção serão apresentados os resultados e as diferenças dos parâmetros relativos a meteorologia (pressão atmosférica, temperatura do ar e umidade relativa do ar).

É importante ressaltar que resultados obtidos com os modelos neuro-fuzzy foram aplicados no desenvolvimento de um programa (apêndice I). Este programa foi concebido com o objetivo de apresentar os resultados calculados com base no aprendizado neuro-fuzzy para cada um dos parâmetros conforme a metodologia descrita no capítulo anterior, o resultado é calculado em tempo real para um par de coordenadas e um mês informado pelo usuário. Apesar de não possuir rigor cartográfico nem a maioria das funcionalidades de SIG, este sistema permite a verificação da aplicação prática das redes neuro-fuzzy. O executável, seus arquivos fontes e o banco de dados de pesos que acessa constam no apêndice I.

### 5.1 – TEMPERATURA E SALINIDADE

A tabela 4.1 apresenta a porcentagem de pontos da grade com erro superior a 5% comparando-se os valores resultantes dos modelos com os valores originais.

Parâmetro	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Temperatura	1.02	0.92	0.98	1.08	0.76	0.74	0.62	0.56	0.43	0.29	0.32	0.43
Salinidade	0.39	0.42	0.50	0.91	0.43	0.47	0.49	0.71	0.39	0.42	0.71	0.61

Tabela 5.1 – Pontos da grade com erro superior a 5% (expresso em porcentagem). Para a temperatura e salinidade (em todos os níveis) para cada mês.

A maior quantidade de pontos com erro superior a 5% para a temperatura foi observada no mês de janeiro (1.02%) e o menor valor foi observado no mês de outubro

(0.29%). Com relação a salinidade em nenhum caso os erros foram superiores a 1% do total de pontos avaliados.

Para exemplificar a distribuição dos dados e seus erros para cada parâmetro, os mesmos estão representados nas profundidades de 10 metros, 100 metros e 1000 metros para os meses de janeiro e julho nas figuras 5.1.1 a 5.1.8. Em todas as figuras, os mapas indicados pela letra “A” representam os dados originais, a letra “B” representa os dados obtidos pelos modelos neuro-fuzzy.

É possível observar que as diferenças entre os dados originais e aqueles obtidos pelas redes neuro-fuzzy são pequenas. Os modelos reproduzem a tendência de resfriamento/aquecimento em função da latitude (figuras 5.1.1 e 5.1.3) e mantém estáveis as condições em profundidades superiores (Figuras 5.1.1 e 5.1.3, mapas B3).

Os erros são observados nos pontos mais próximos da costa, o que indica uma maior dificuldade das redes neuro-fuzzy em representar as condições mais próximas de bordas irregulares.

As figuras 5.1.9 e 5.1.10 apresentam perfis verticais nas profundidades padrões para os meses de janeiro, abril, julho e outubro. Estes exemplos mostram uma grande semelhança entre os dados originais (linha azul) e aqueles obtidos pelo modelo neuro-fuzzy (linha vermelha) nos gráficos à esquerda, com suas diferenças expostas nos gráficos à direita. As diferenças para a temperatura em todas as profundidades do perfil foram em média 0.32 % e para a salinidade 0.004 %.

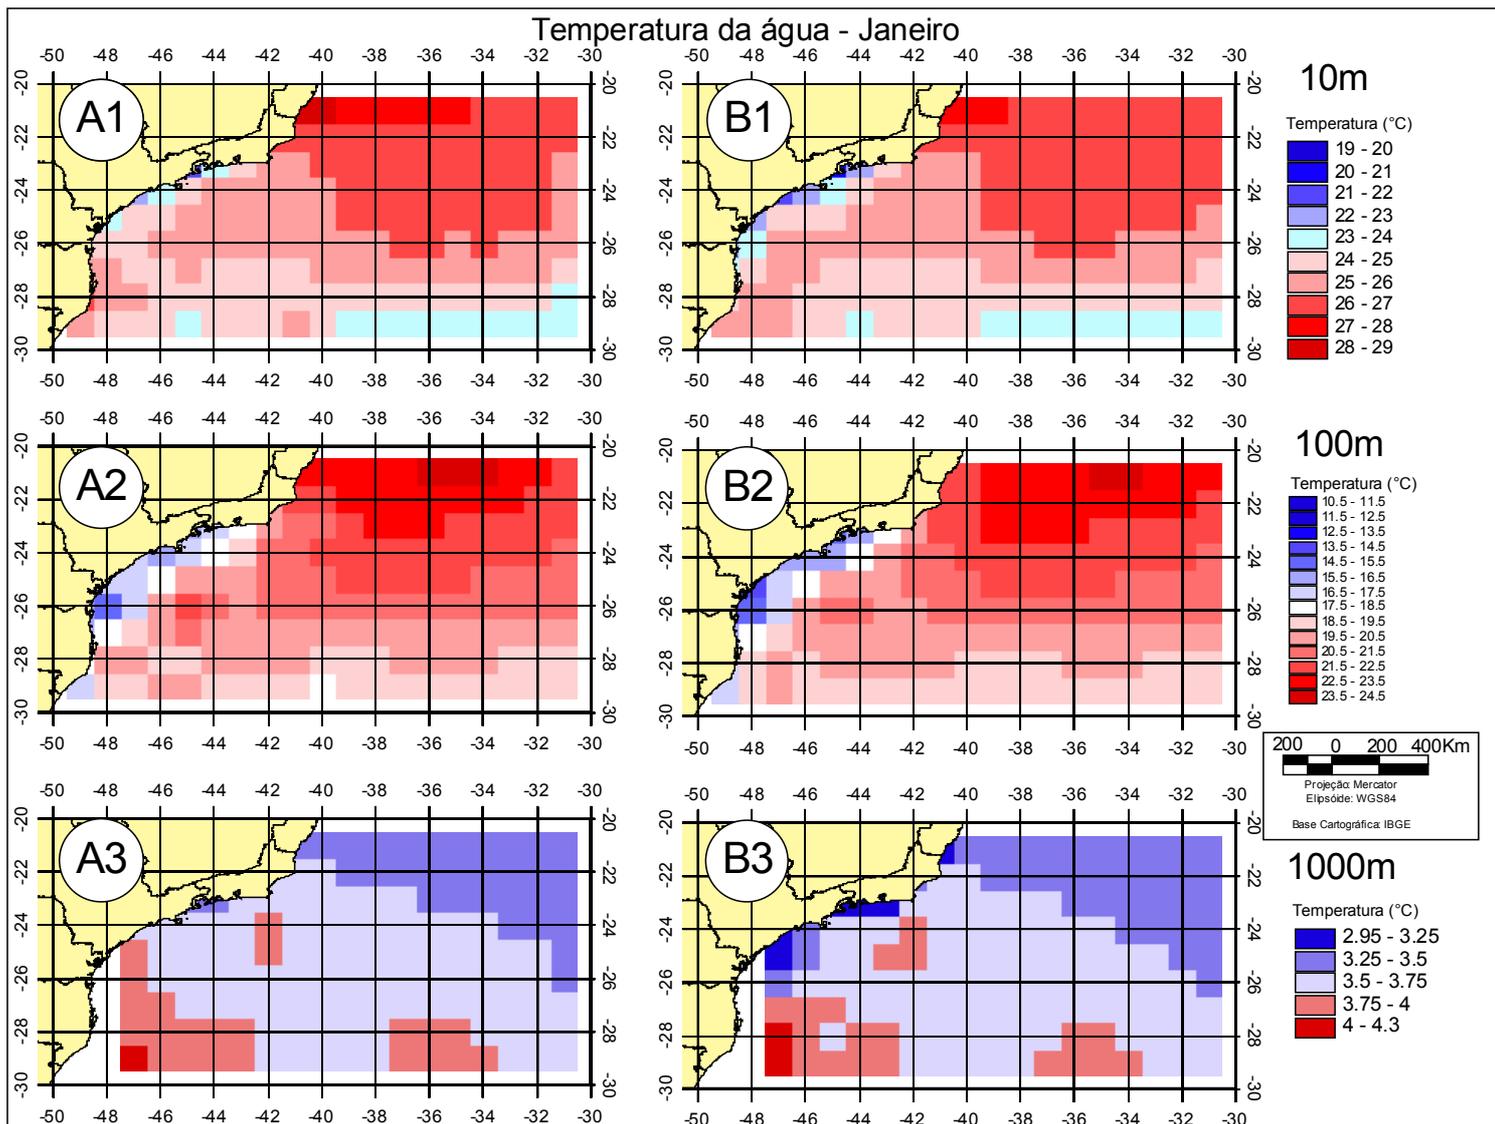


Figura 5.1.1 - Temperatura da água em janeiro em 10, 100 e 1000m (A - dados originais / B - Dados redes neuro-fuzzy).

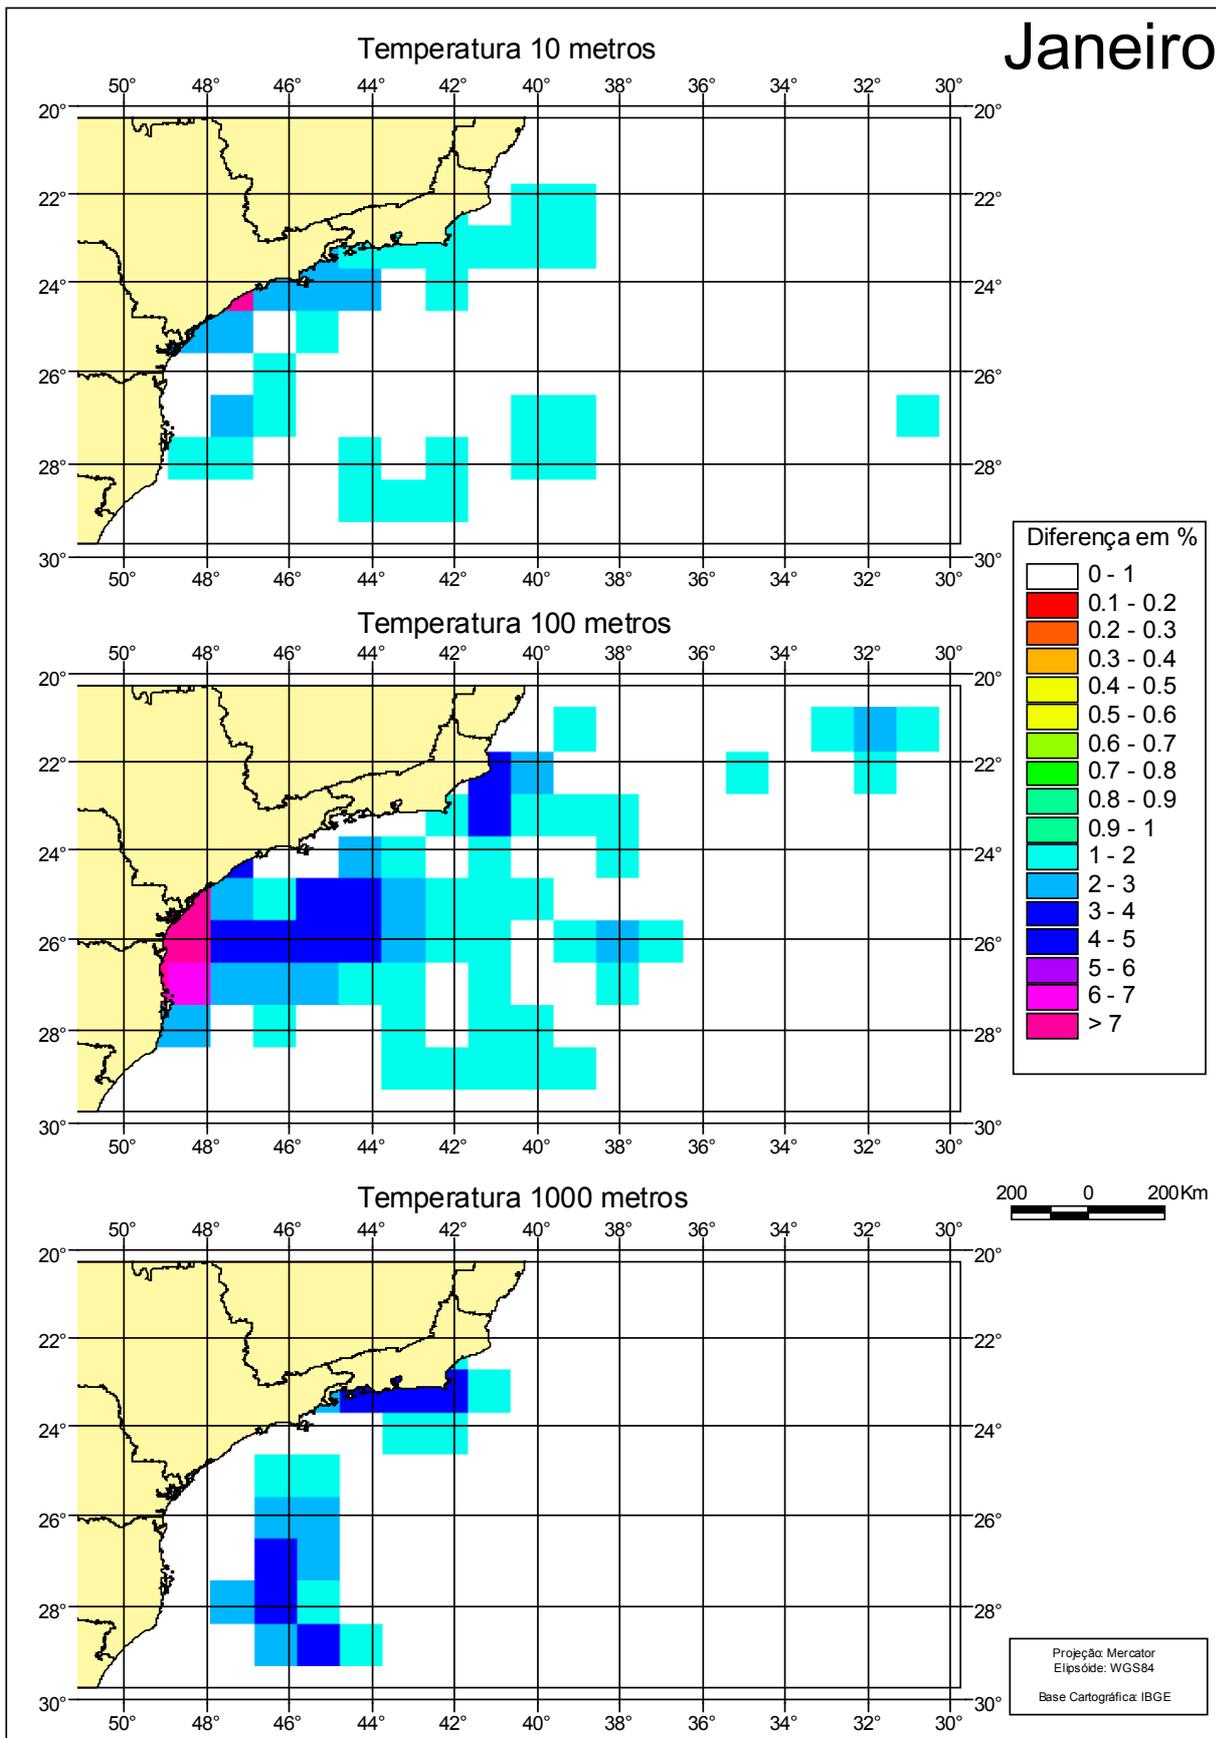


Figura 5.1.2 - Diferença da temperatura da água em janeiro em 10, 100 e 1000m em porcentagem.

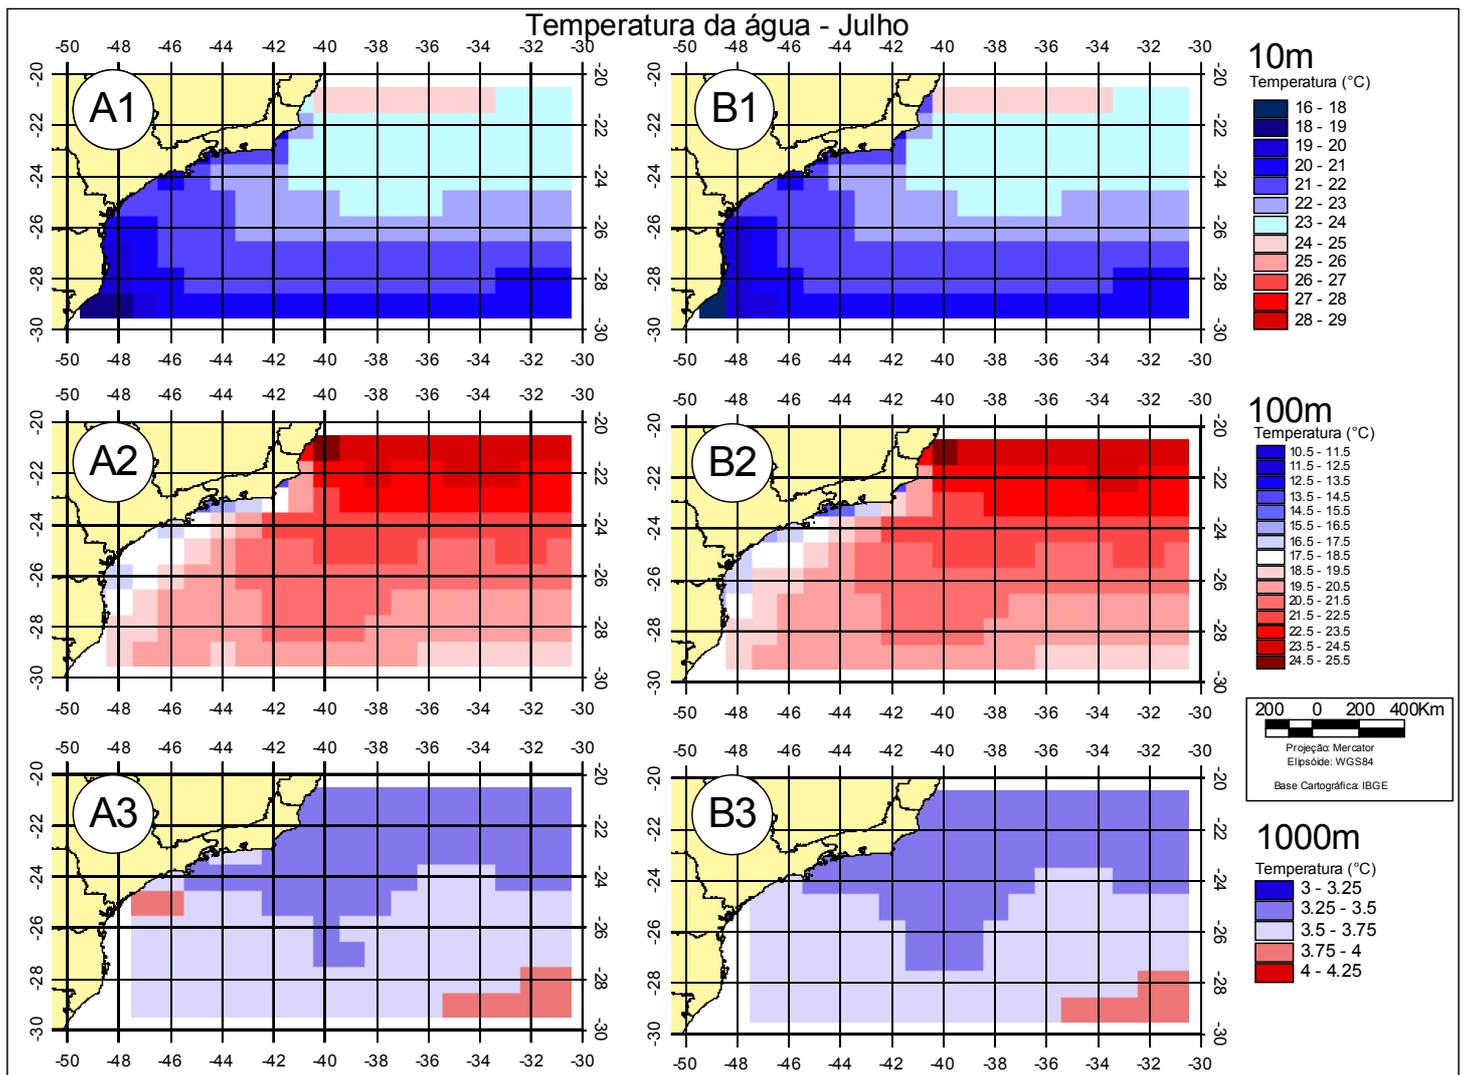


Figura 5.1.3 - Temperatura da água em julho em 10, 100 e 1000m (A - dados originais / B - Dados redes neuro-fuzzy).

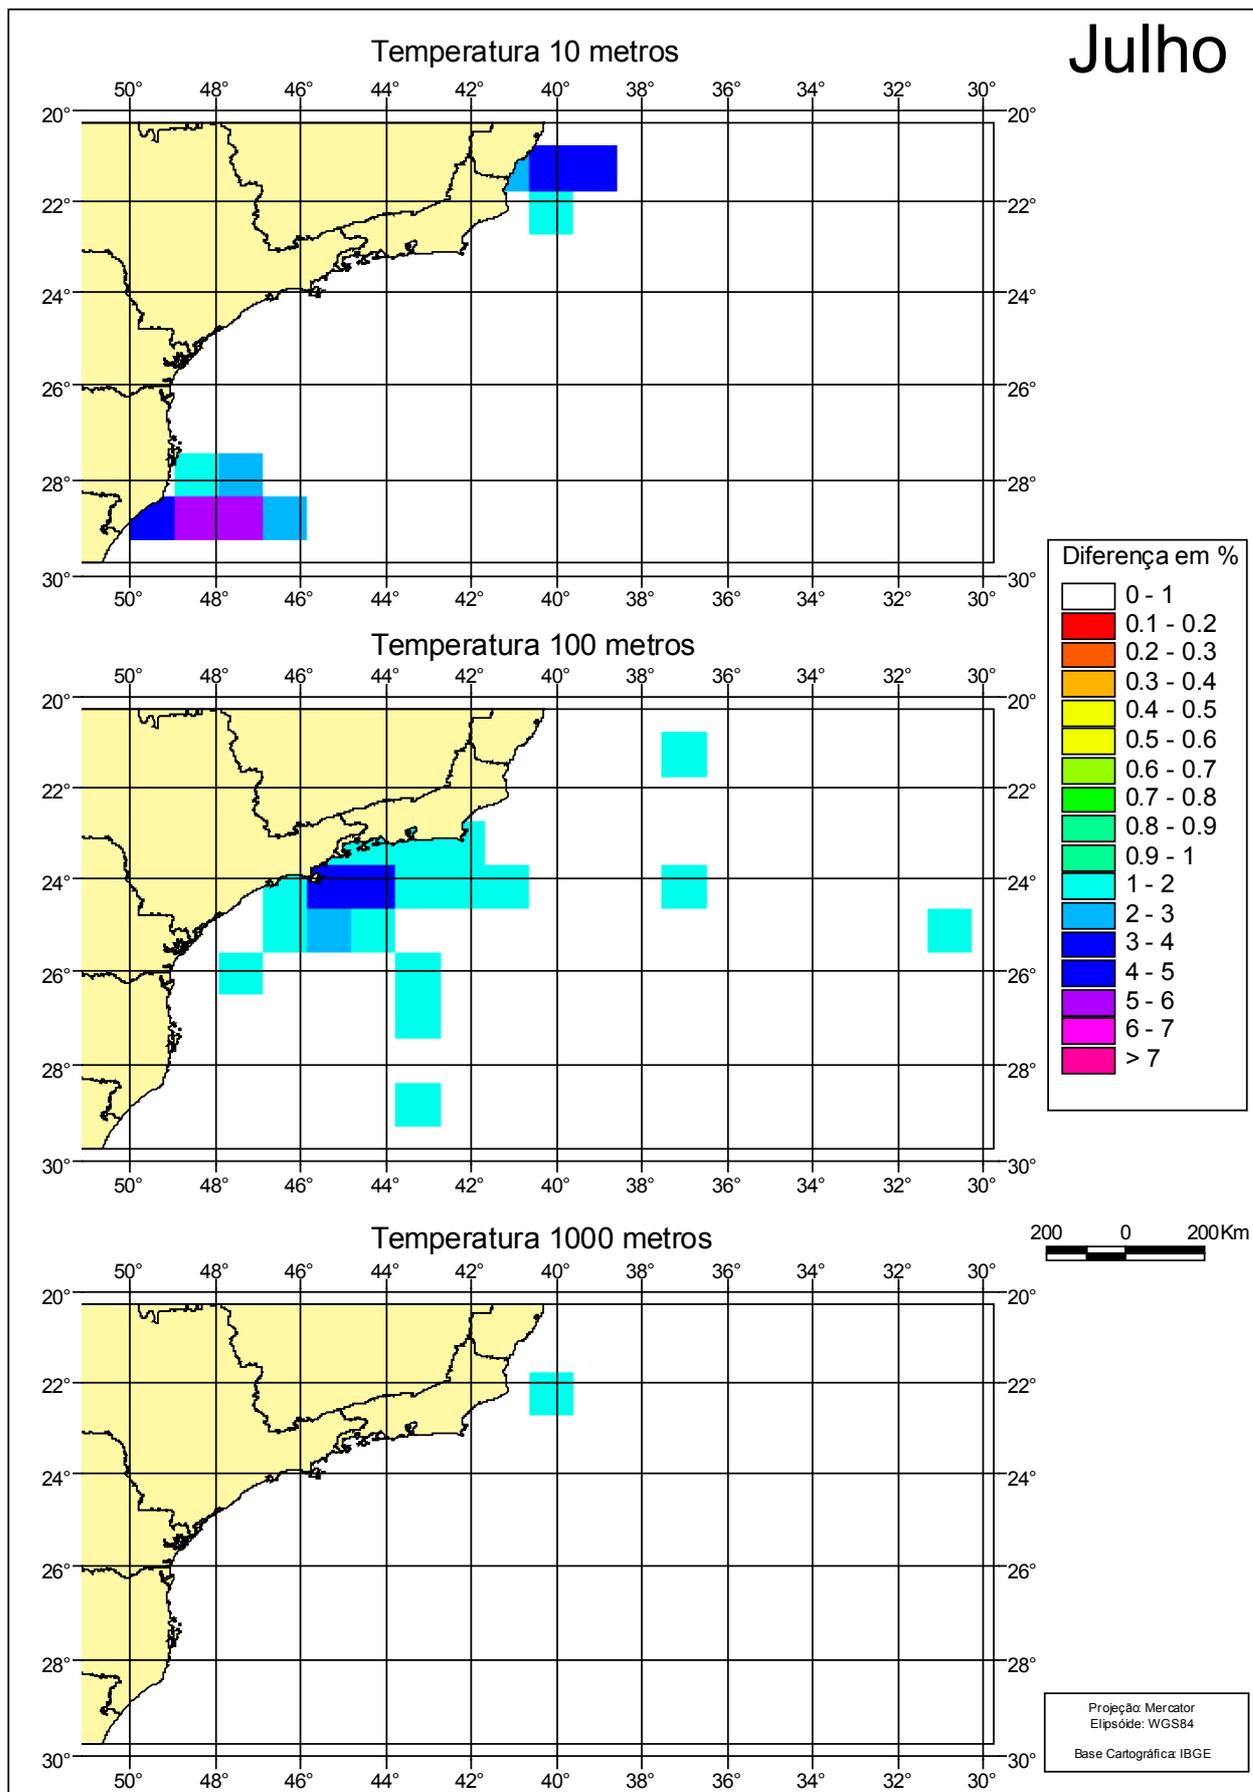


Figura 5.1.4 - Diferença da temperatura da água em julho em 10, 100 e 1000m em porcentagem.

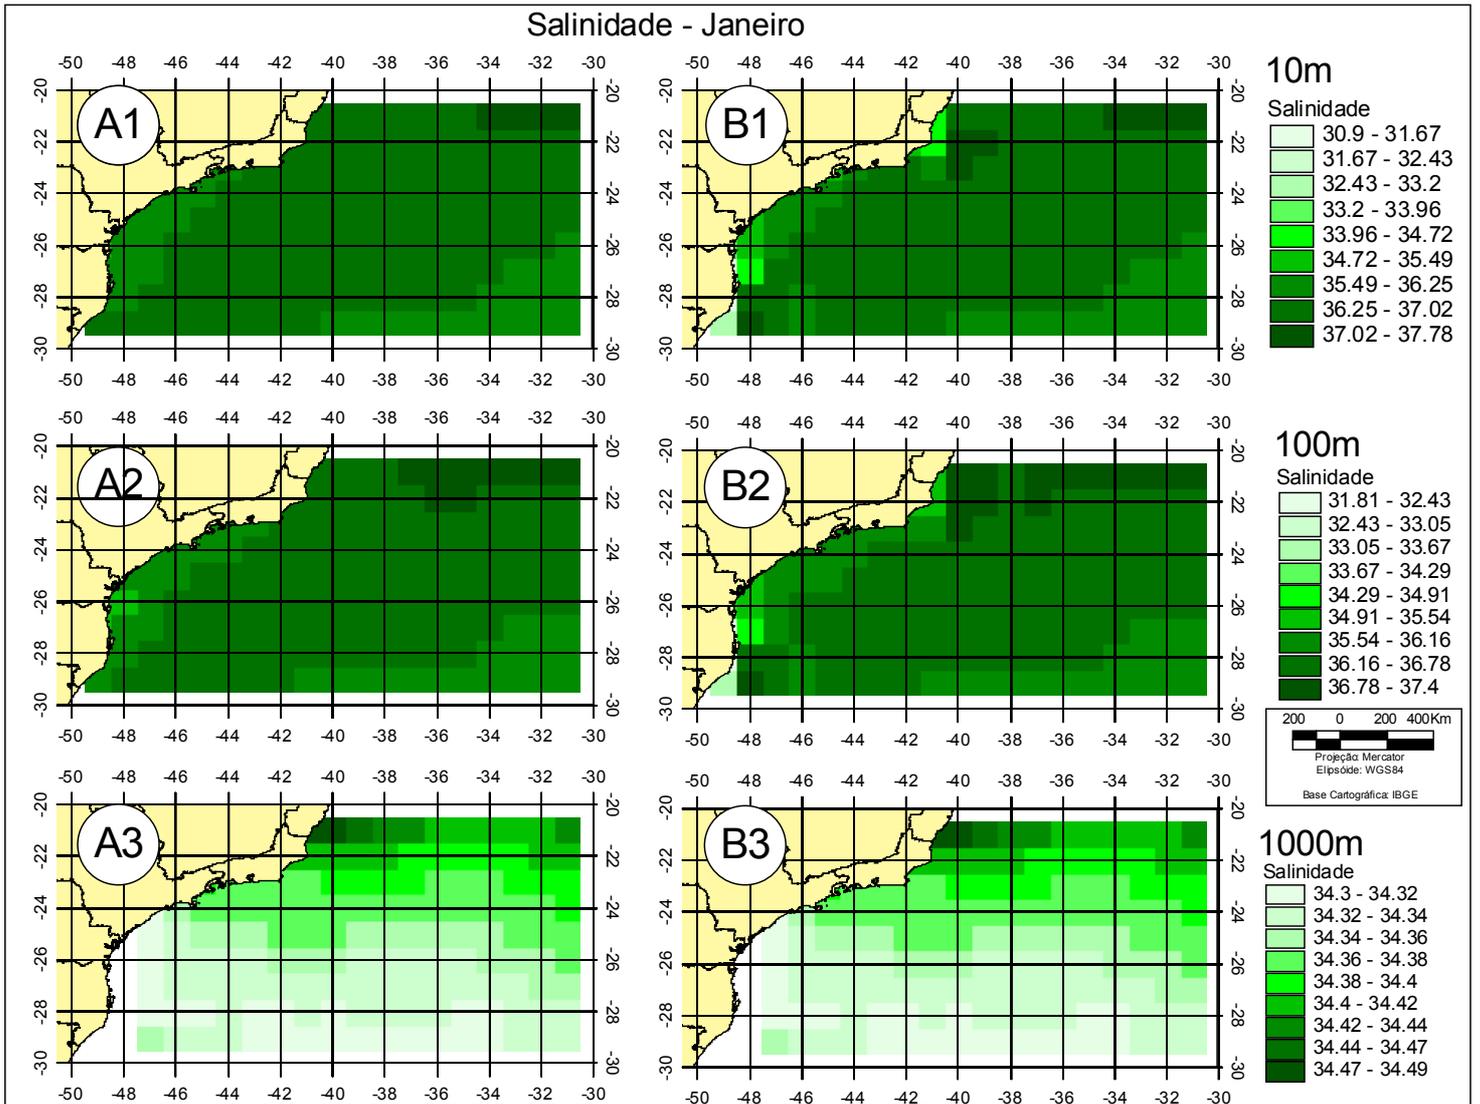


Figura 5.1.5 - Salinidade em janeiro em 10, 100 e 1000m (A - dados originais / B - Dados redes neuro-fuzzy).

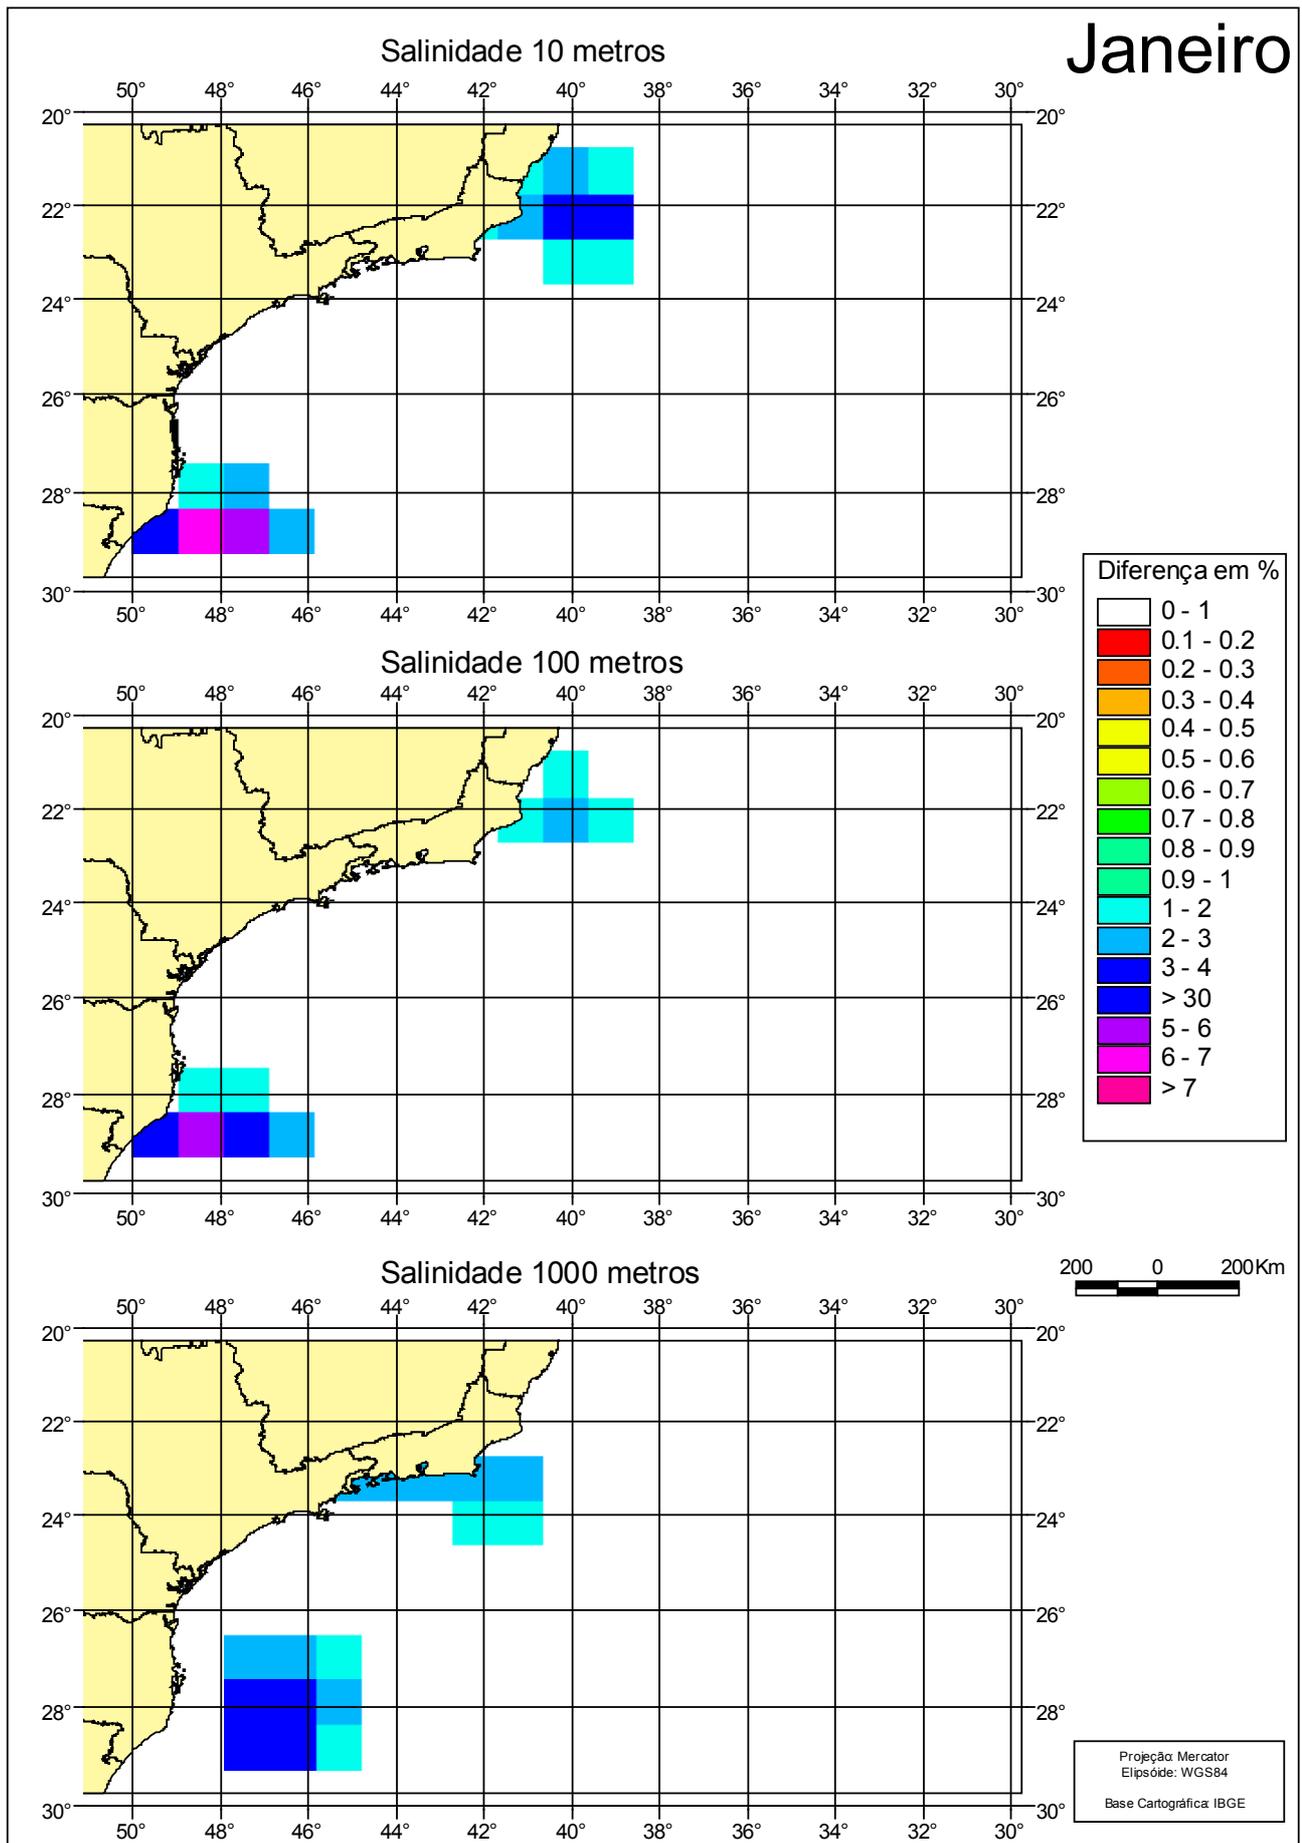


Figura 5.1.6 - Diferença da salinidade em janeiro em 10, 100 e 1000m em porcentagem.

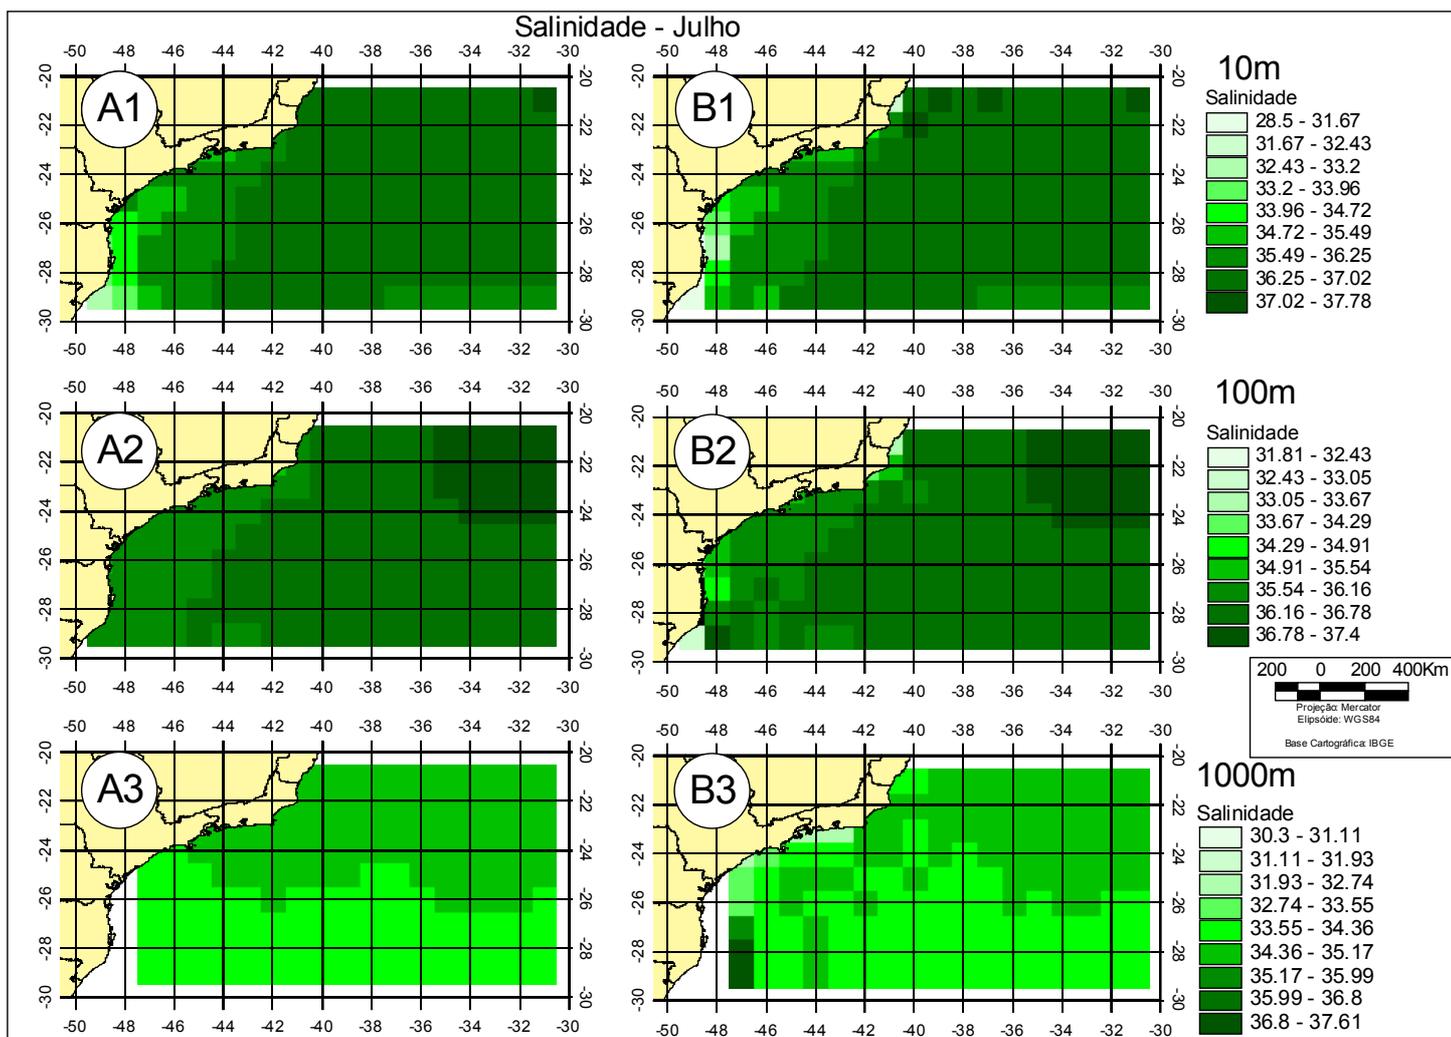


Figura 5.1.7 - Salinidade em julho em 10, 100 e 1000m (A - dados originais / B - Dados redes neuro-fuzzy).

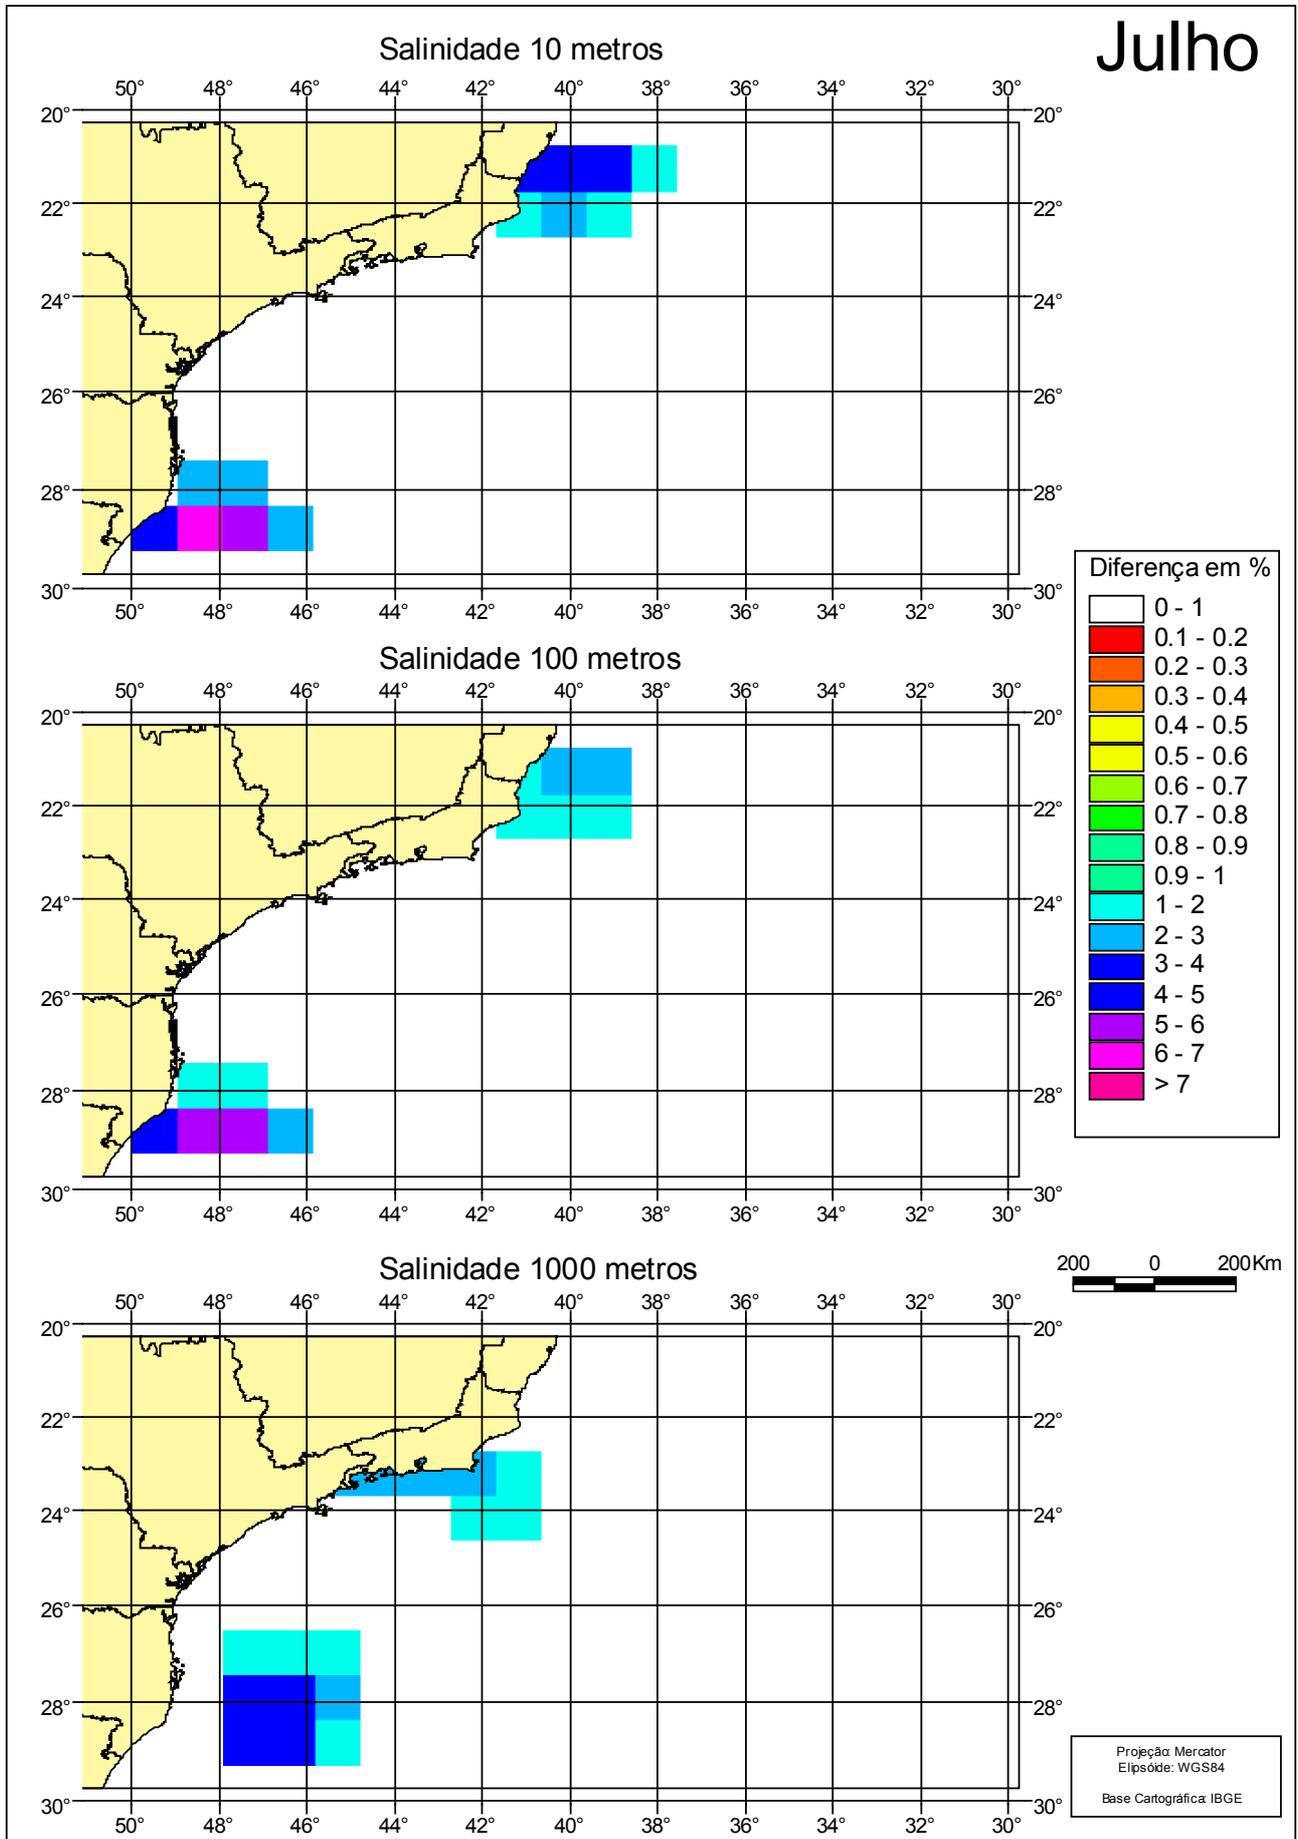


Figura 5.1.8 - Diferença da Salinidade da água em julho em 10, 100 e 1000m em porcentagem.

# Perfis de temperatura

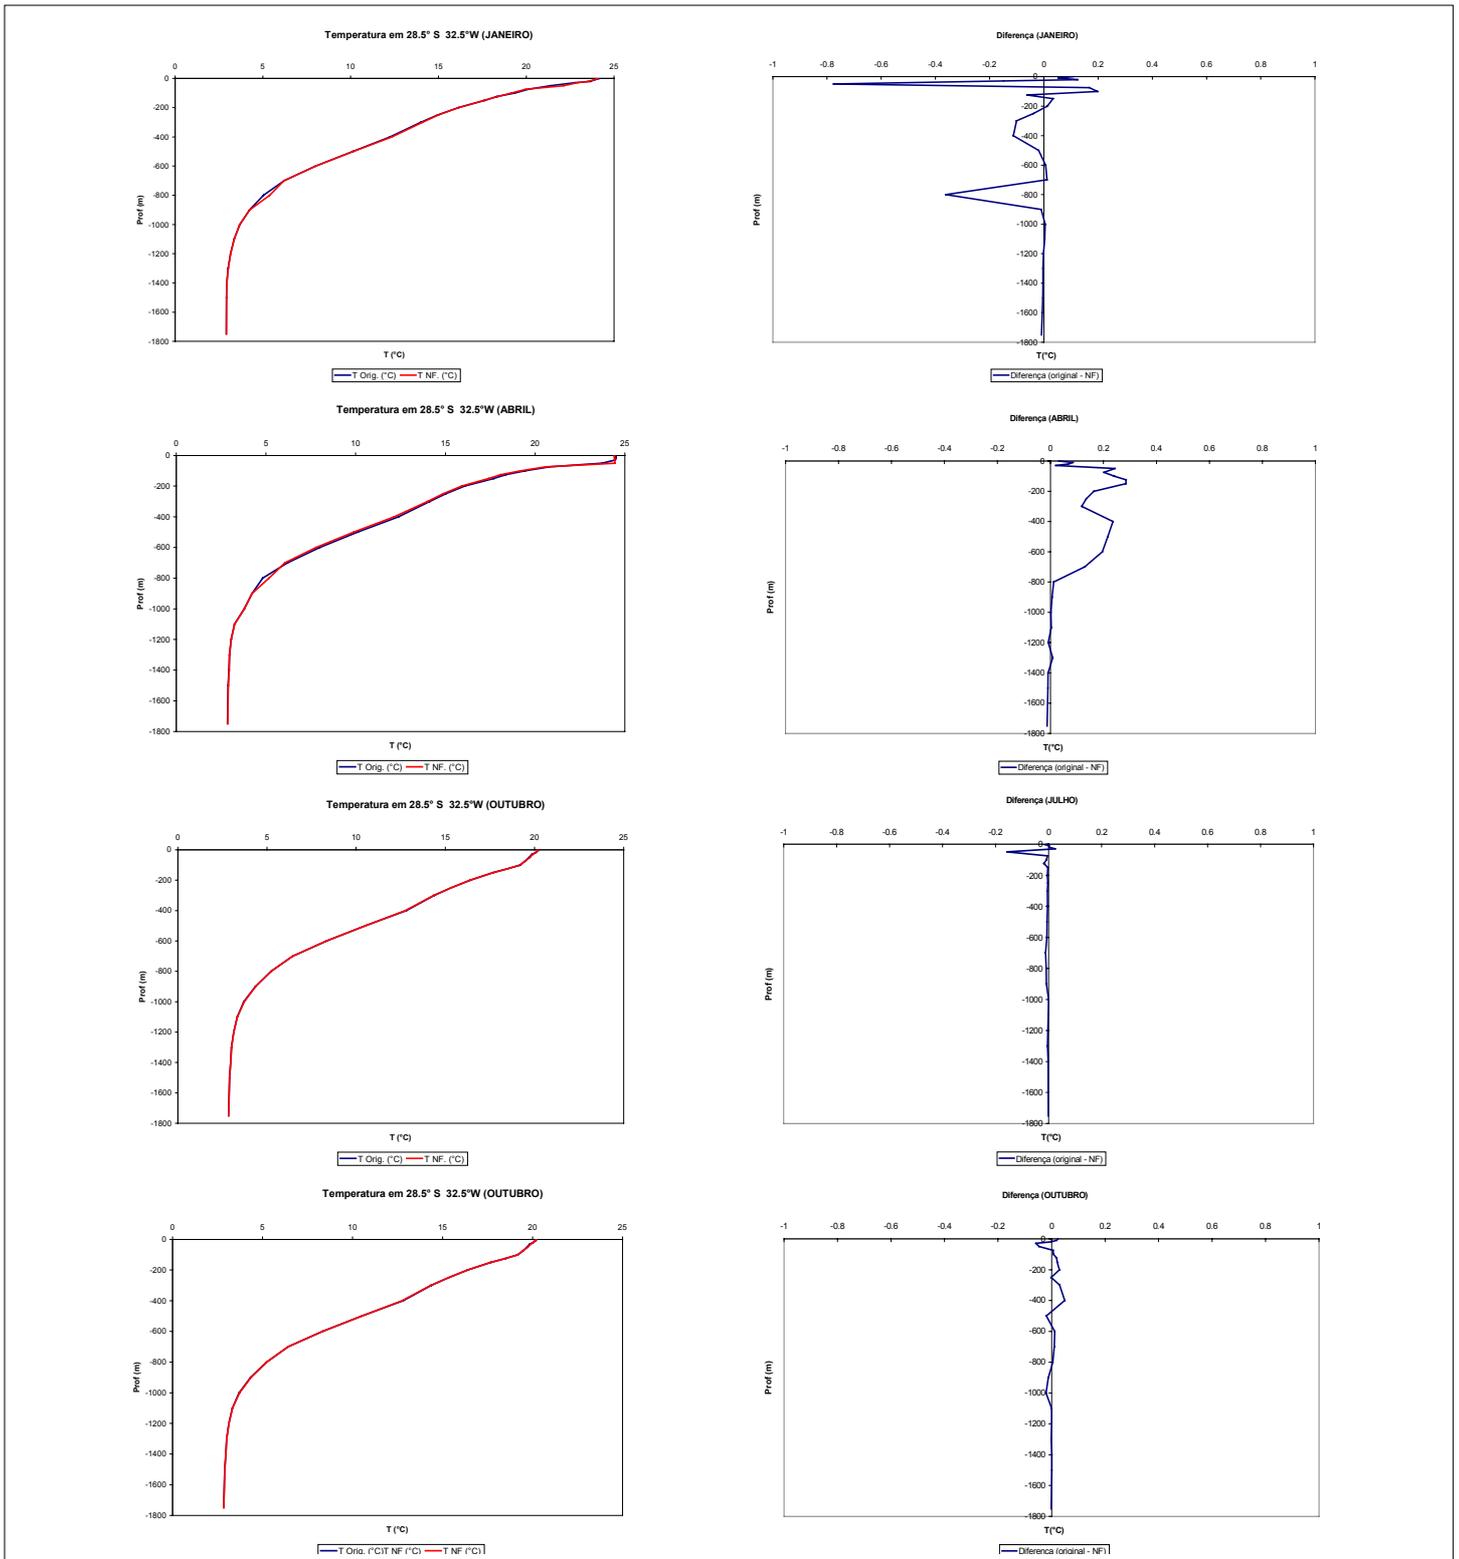


Figura 5.1.9 – Perfis de temperatura para o ponto em 28.5S/32.5W para os meses janeiro, abril, julho e outubro

# Perfis de Salinidade

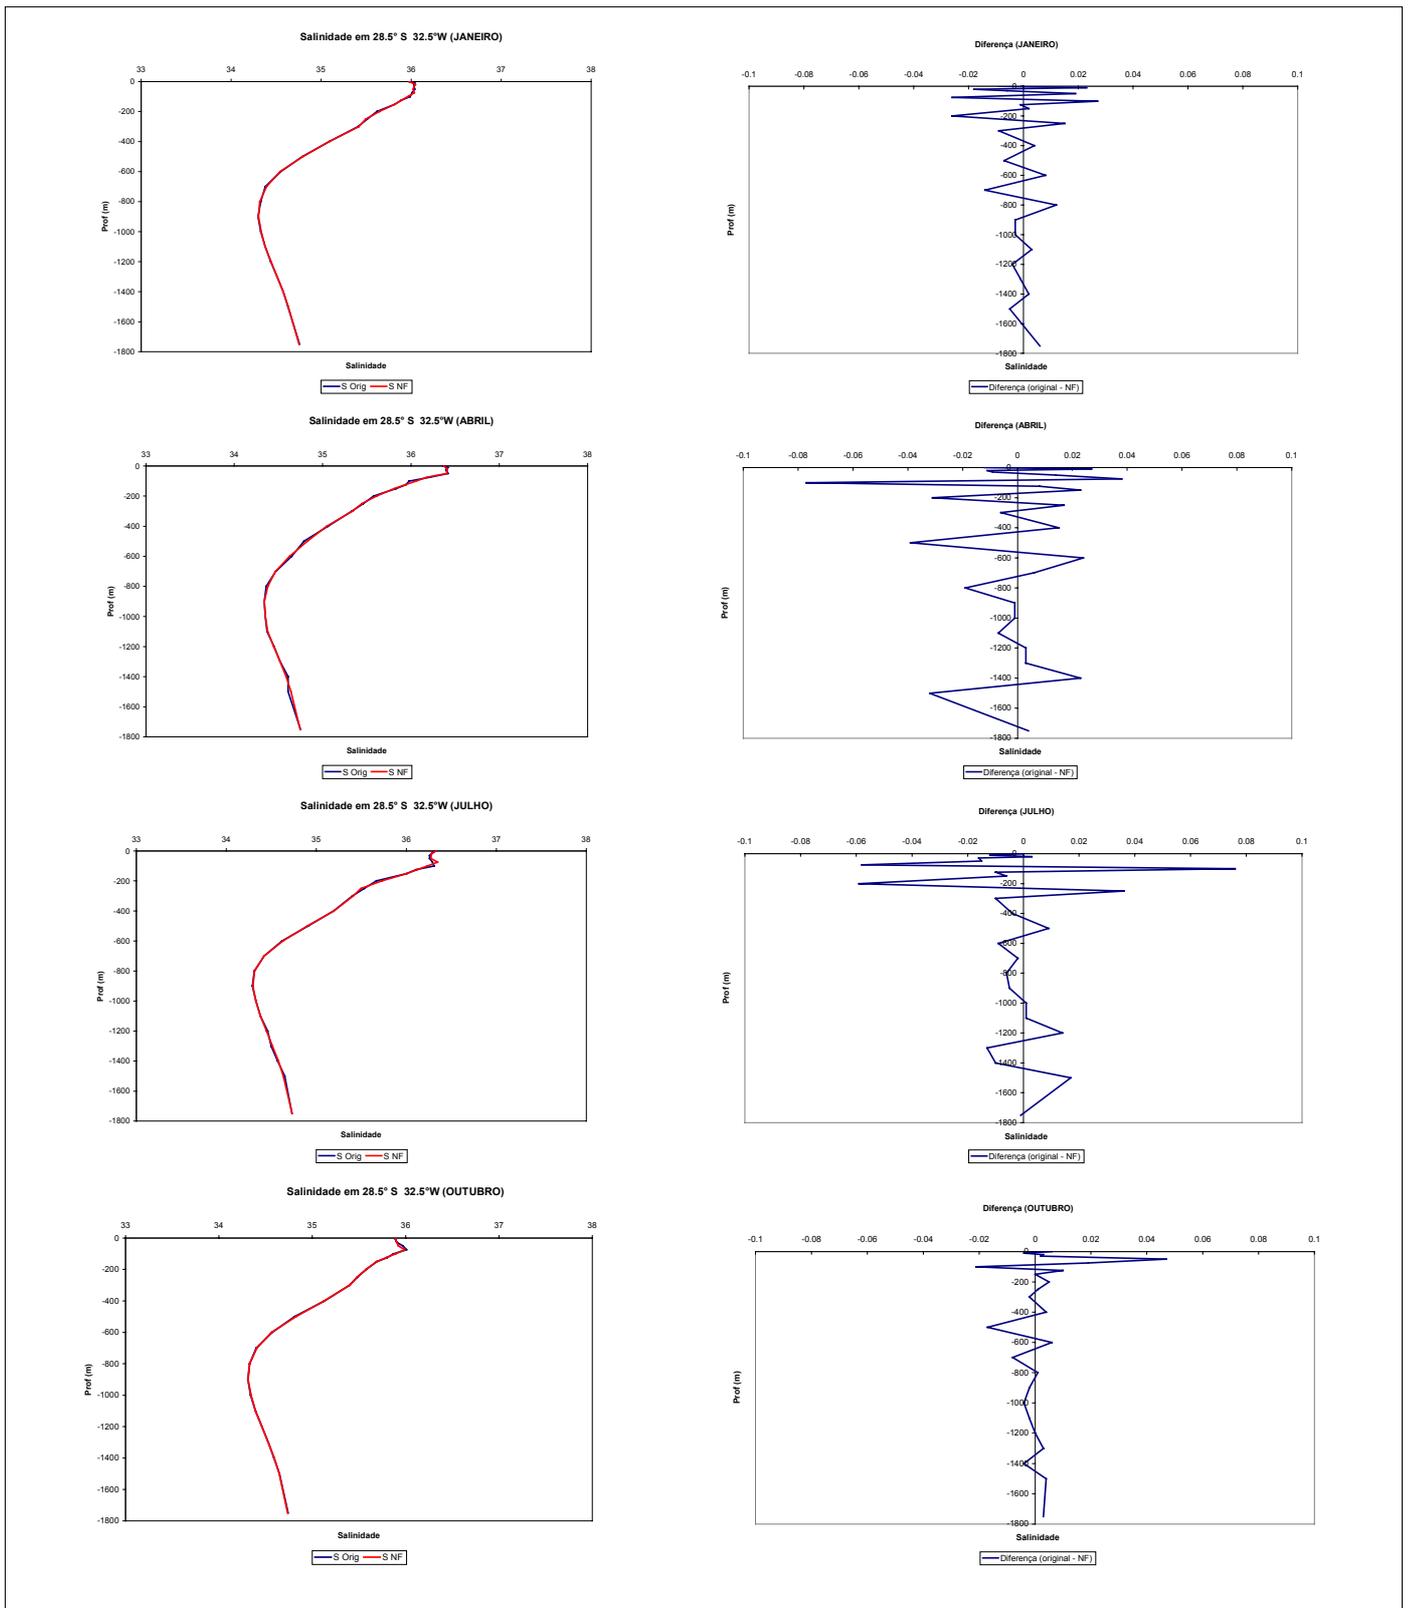


Figura 5.1.10 – Perfis de salinidade para o ponto em 28.5S/32.5W para os meses janeiro, abril, julho e outubro

## 5.2 – PARÂMETROS DE FUNDO

### 5.2.1 – TIPO DE FUNDO

Os dados de tipo de fundo apresentaram os melhores resultados, por se tratar de classificação faciológica, ou seja, os tipos de fundo são representados por classes e não por valores contínuos, os modelos neuro-fuzzy puderam representá-los sem erro. A figura 5.2.1 apresenta os resultados para a faciologia, os dados do mapa “B” (resultado das redes neuro-fuzzy) são iguais aos dados do mapa “A” (dados originais).

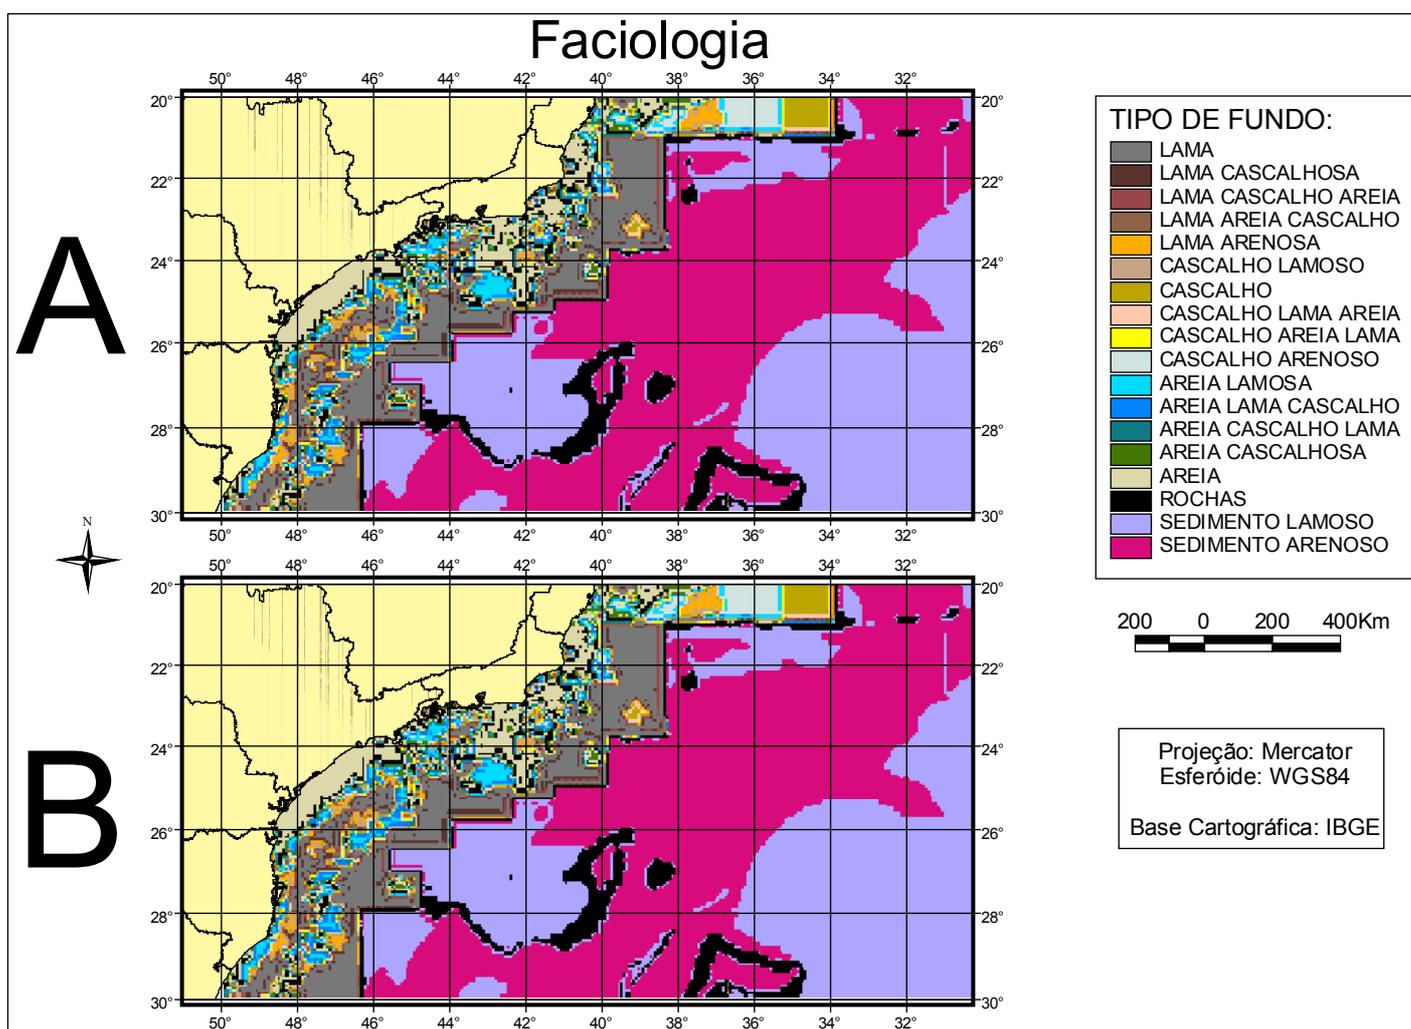


Figura 5.2.1 - Faciologia (A - dados originais / B - Dados redes neuro-fuzzy)

## 5.2.2 – BATIMETRIA

A batimetria (figura 5.2.2 “B”) apresentou-se em geral semelhante aos dados originais (figura 5.2.2 “A”), todas as feições batimétricas estão representadas como pode-se perceber nos números que indicam a localização aproximada da Cadeia Vitória-Trindade, Monte Alte, Saldanha, Platô de São Paulo e Elevação de Rio Grande.

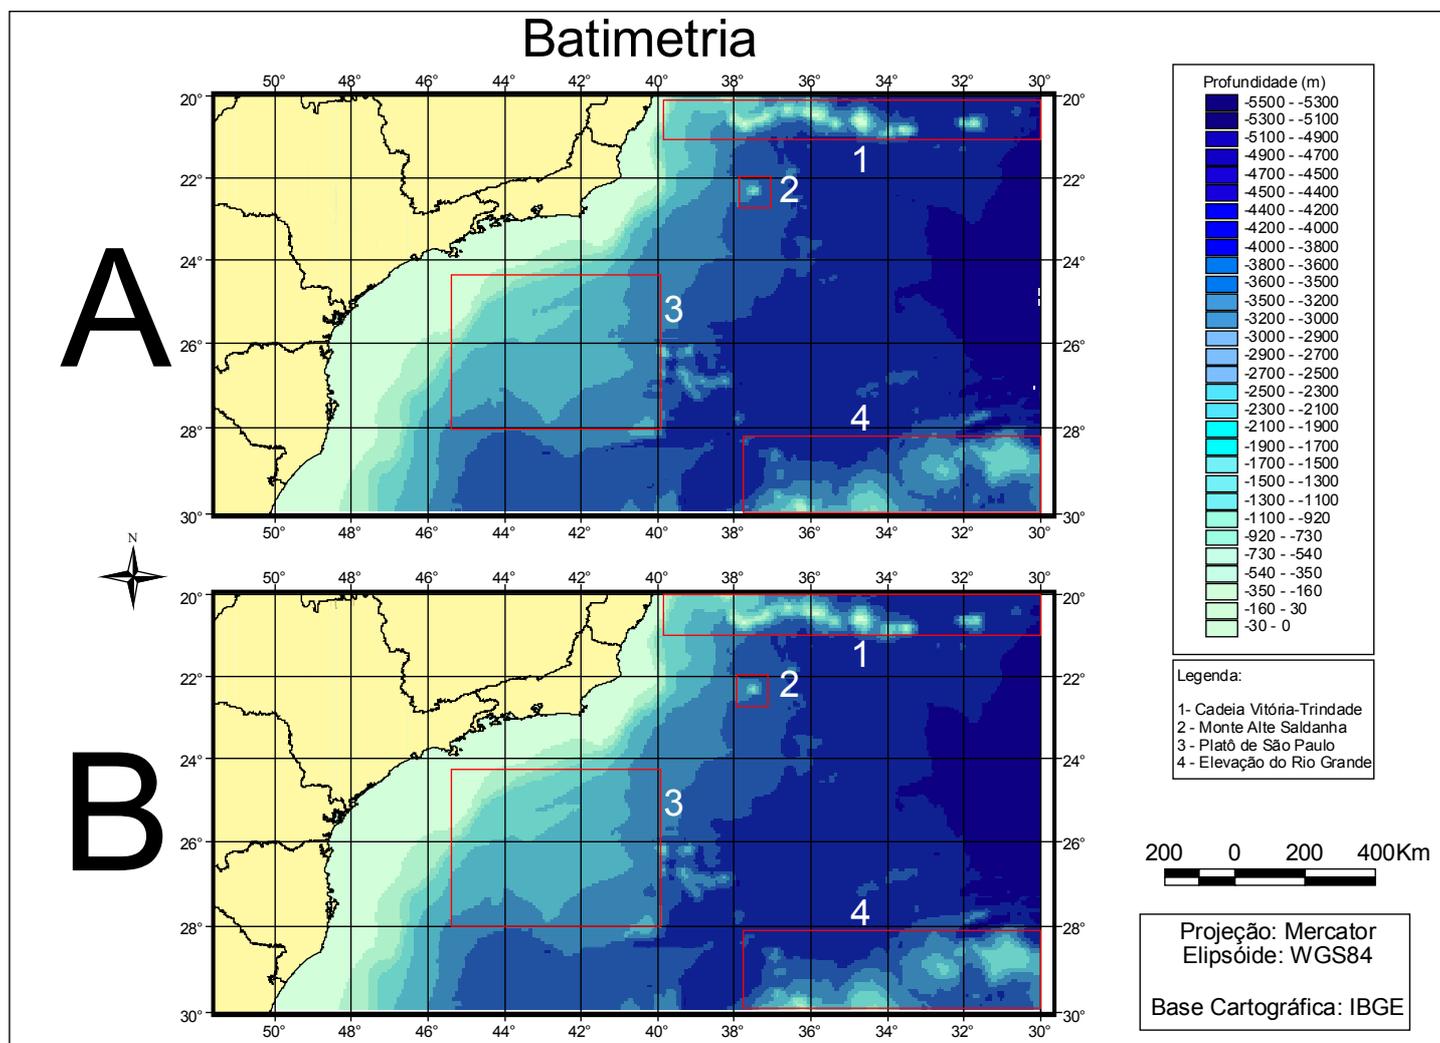


Figura 5.2.2 - Batimetria (A - dados originais / B - Dados redes neuro-fuzzy)

Como pode-se observar na figura 5.2.3, as maiores diferenças situam-se em regiões de maior gradiente como a cadeia vitória trindade, entre 20°S/21°S e 31°W/40°W. A porcentagem de pontos da grade com erro superior a 5% comparando-se os valores resultantes dos modelos com os valores originais foi de 4.2 %.

### Diferença entre a batimetria original e a batimetria obtida pelo modelo neuro-fuzzy

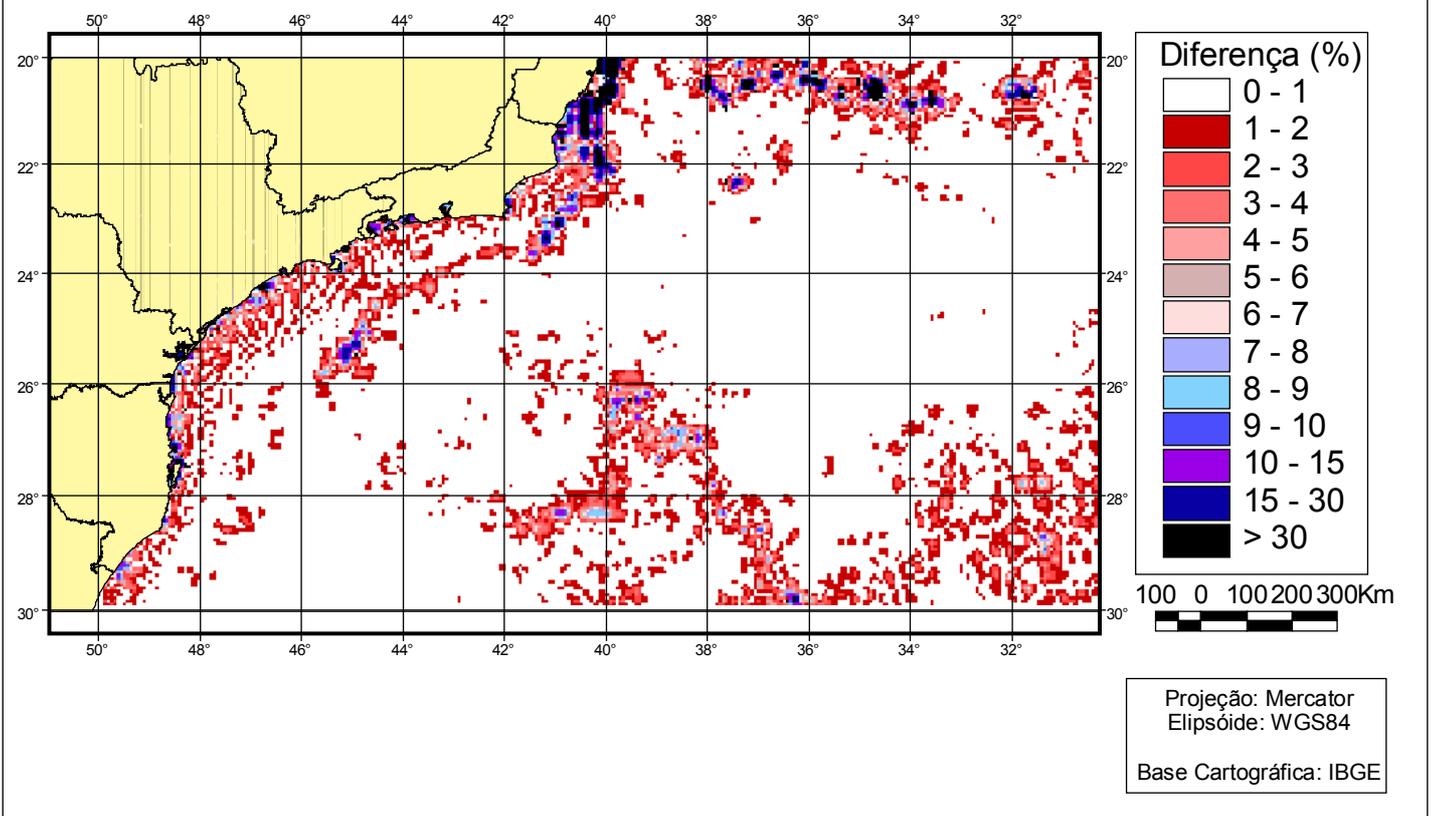


Figura 5.2.3 - Diferença entre Batimetria com dados originais e com dados redes neuro-fuzzy em porcentagem

### 5.3 – PARÂMETROS METEOROLÓGICOS

A tabela 5.3 apresenta a porcentagem de pontos da grade com erro superior a 5% comparando-se os valores resultantes dos modelos com os valores originais.

<b>Parâmetro</b>	<b>Jan</b>	<b>Fev</b>	<b>Mar</b>	<b>Abr</b>	<b>Mai</b>	<b>Jun</b>	<b>Jul</b>	<b>Ago</b>	<b>Set</b>	<b>Out</b>	<b>Nov</b>	<b>Dez</b>
Pressão Atmosférica	1.08	1.06	1.04	1.08	0.78	0.95	0.59	0.62	0.68	0.08	0.32	0.54
Umidade Relativa do Ar	1.83	1.03	0.75	1.11	0.87	1.06	0.27	0.94	0.74	1.06	0.64	0.73
Temperatura do Ar	1.11	1.06	0.64	0.59	0.72	0.84	0.94	0.51	0.74	1.11	0.83	0.94

Tabela 5.3 – Pontos da grade com erro superior a 5% (expresso em porcentagem). Para os parâmetros meteorológicos (pressão atmosférica, umidade relativa do ar e temperatura do ar) para cada mês.

A umidade relativa do ar foi o parâmetro que apresentou a maior quantidade de pontos com erro superior a 5%, observada no mês de Janeiro (1.83%). A menor quantidade de pontos com erro superior a 5 % foi encontrado no mês de outubro para a pressão atmosférica (0.08%).

Para exemplificar a distribuição dos dados e seus erros para cada parâmetro. Os mesmos estão representados para os meses de janeiro e julho nas figuras 5.3.1 a 5.3.4. Em todas as figuras, os mapas indicados pela letra “A” representam os dados originais, a letra “B” representa os dados obtidos pelos modelos neuro-fuzzy.

É possível observar que as diferenças entre os dados originais e aqueles obtidos pelas redes neuro-fuzzy são pequenas. De forma geral, os erros são observados nos pontos mais próximos da costa, o que indica uma maior dificuldade das redes neuro-fuzzy em representar as condições mais próximas de bordas irregulares.

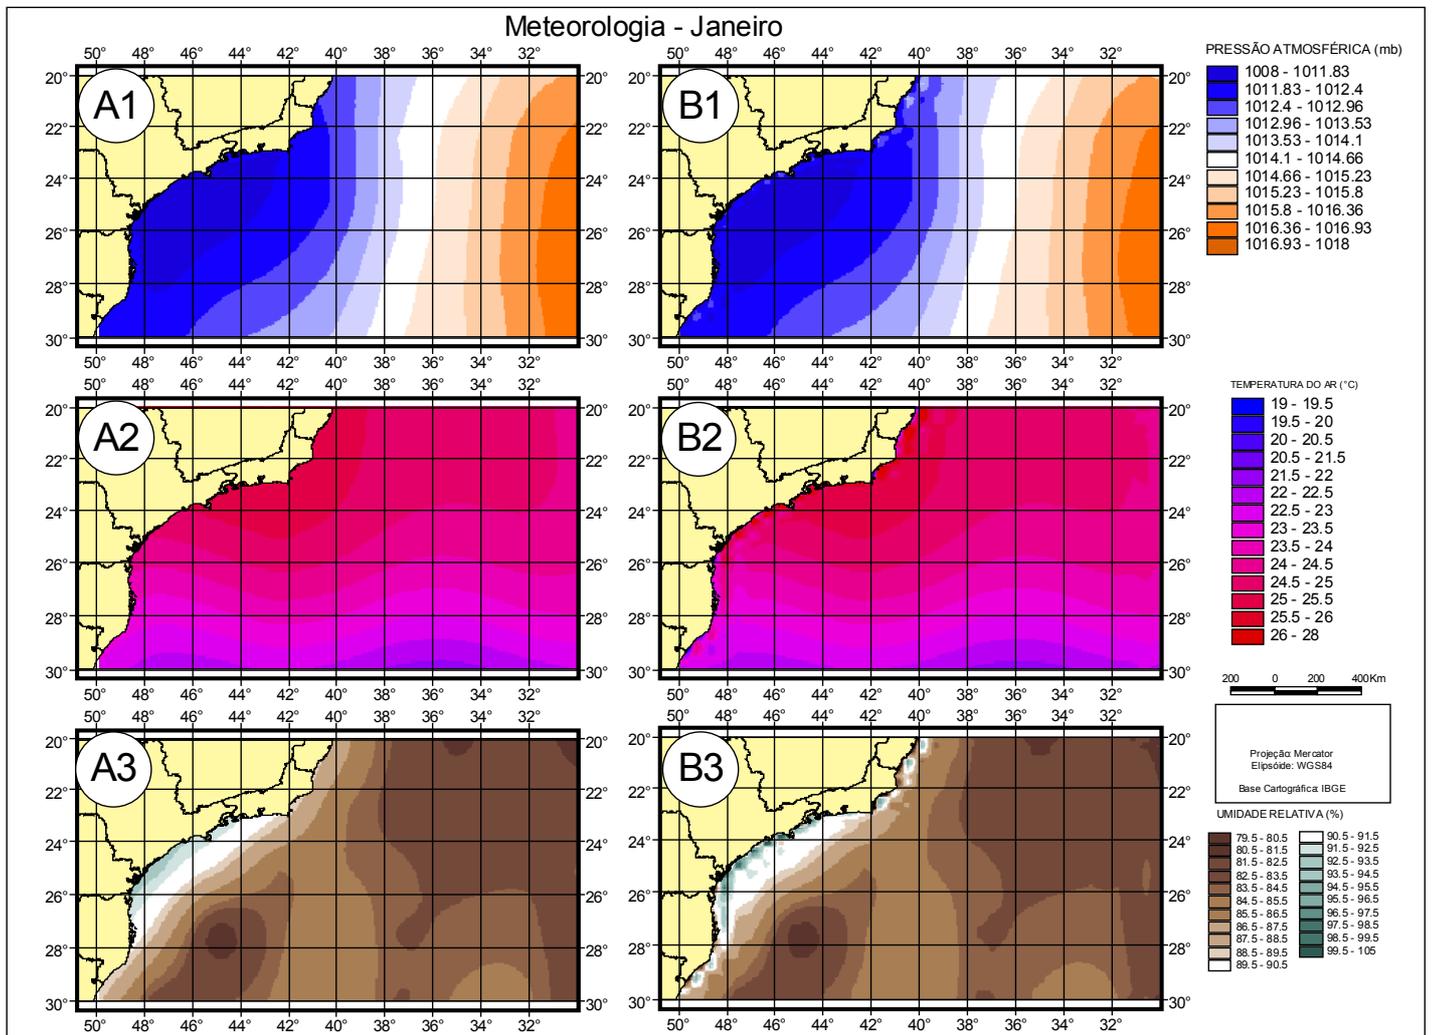


Figura 5.3.1 - Meteorologia em janeiro (A - dados originais / B - Dados redes neuro-fuzzy).

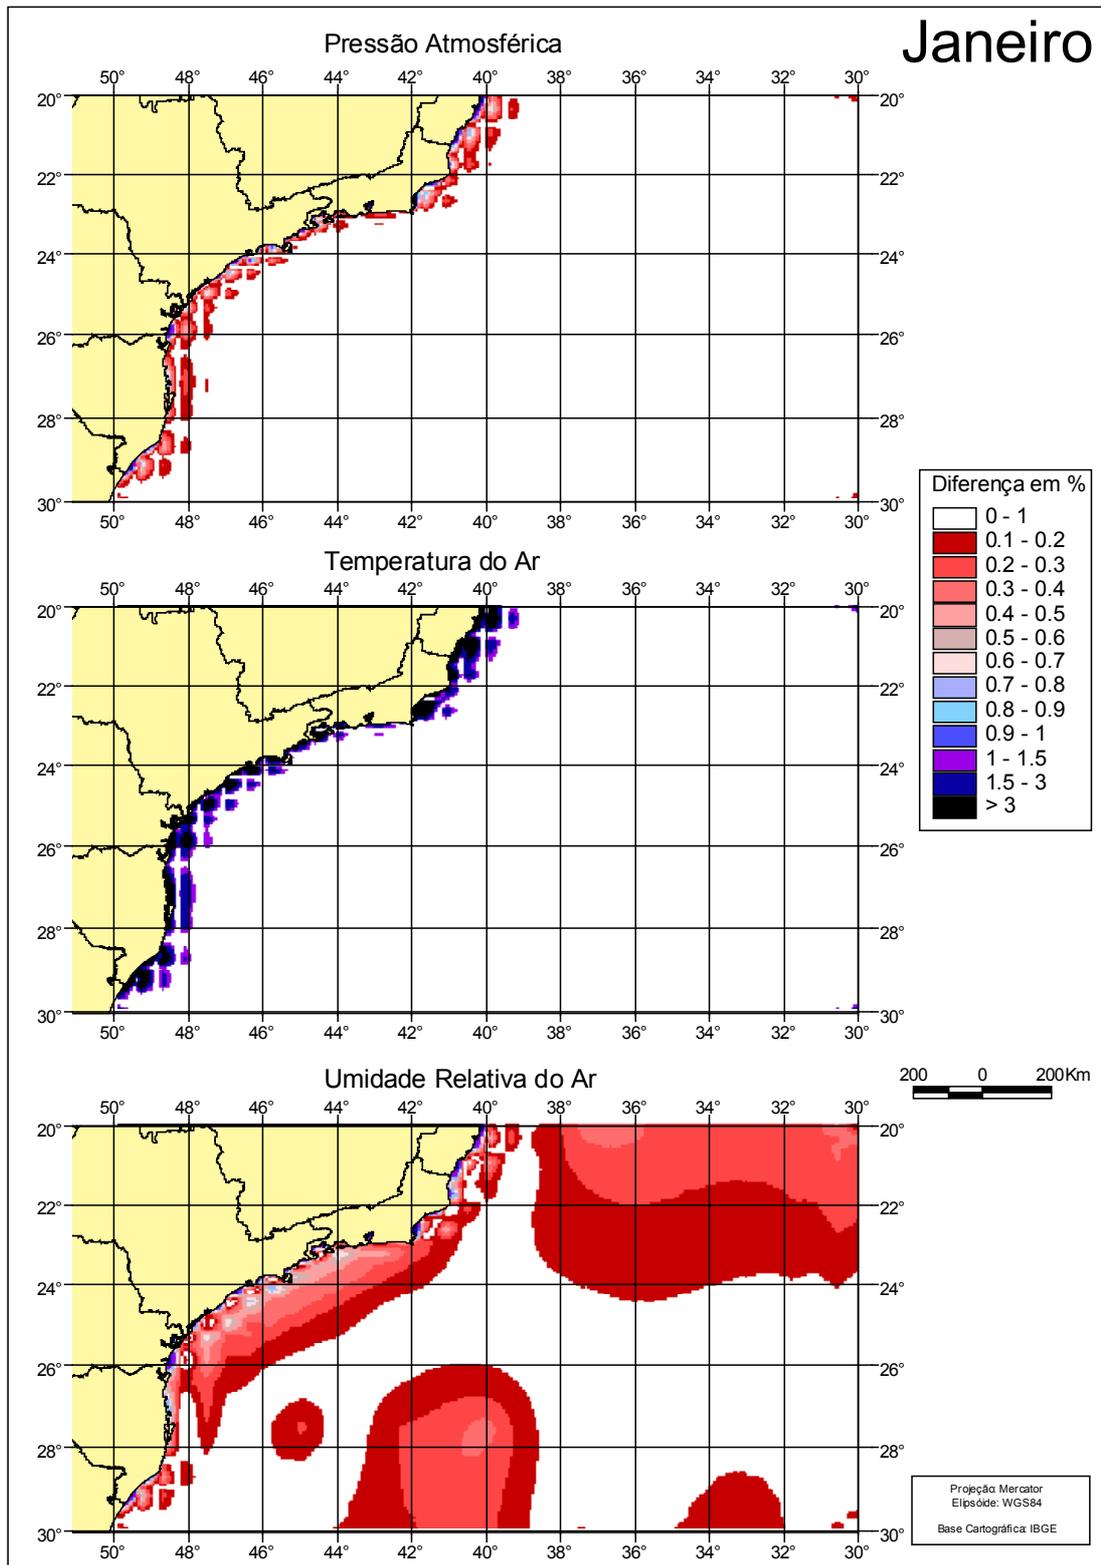


Figura 5.3.2 - Diferença dos dados meteorológicos entre dados originais e dados do modelo neuro-fuzzy. para julho.

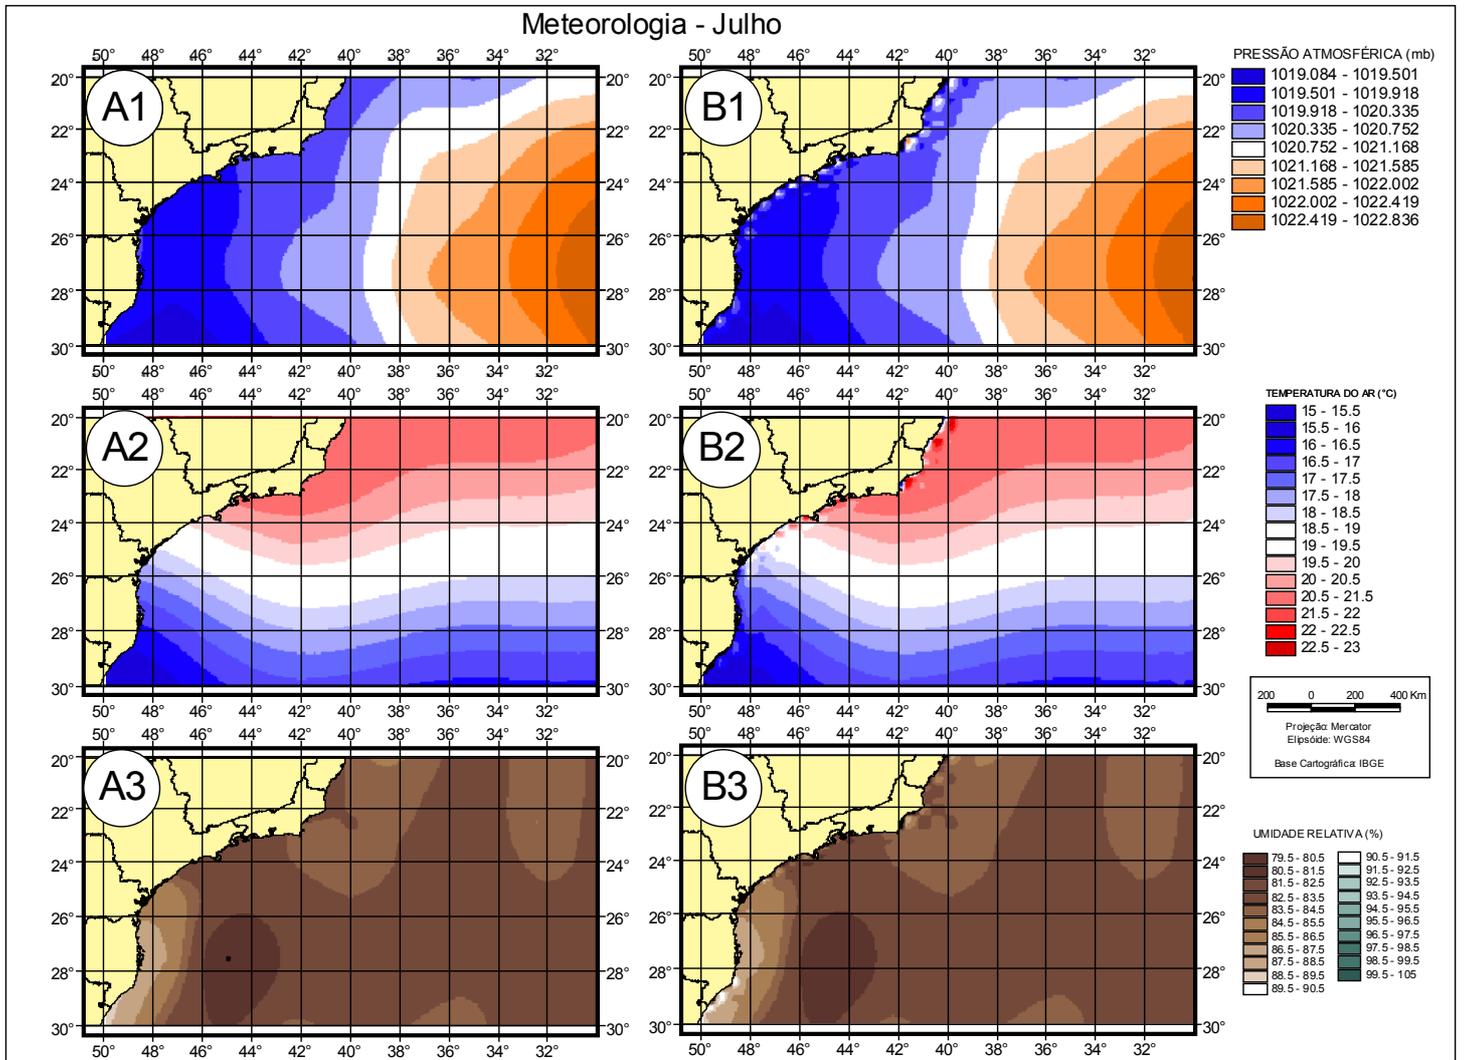


Figura 5.3.3 - Meteorologia em julho (A - dados originais / B - Dados modelo neuro-fuzzy).

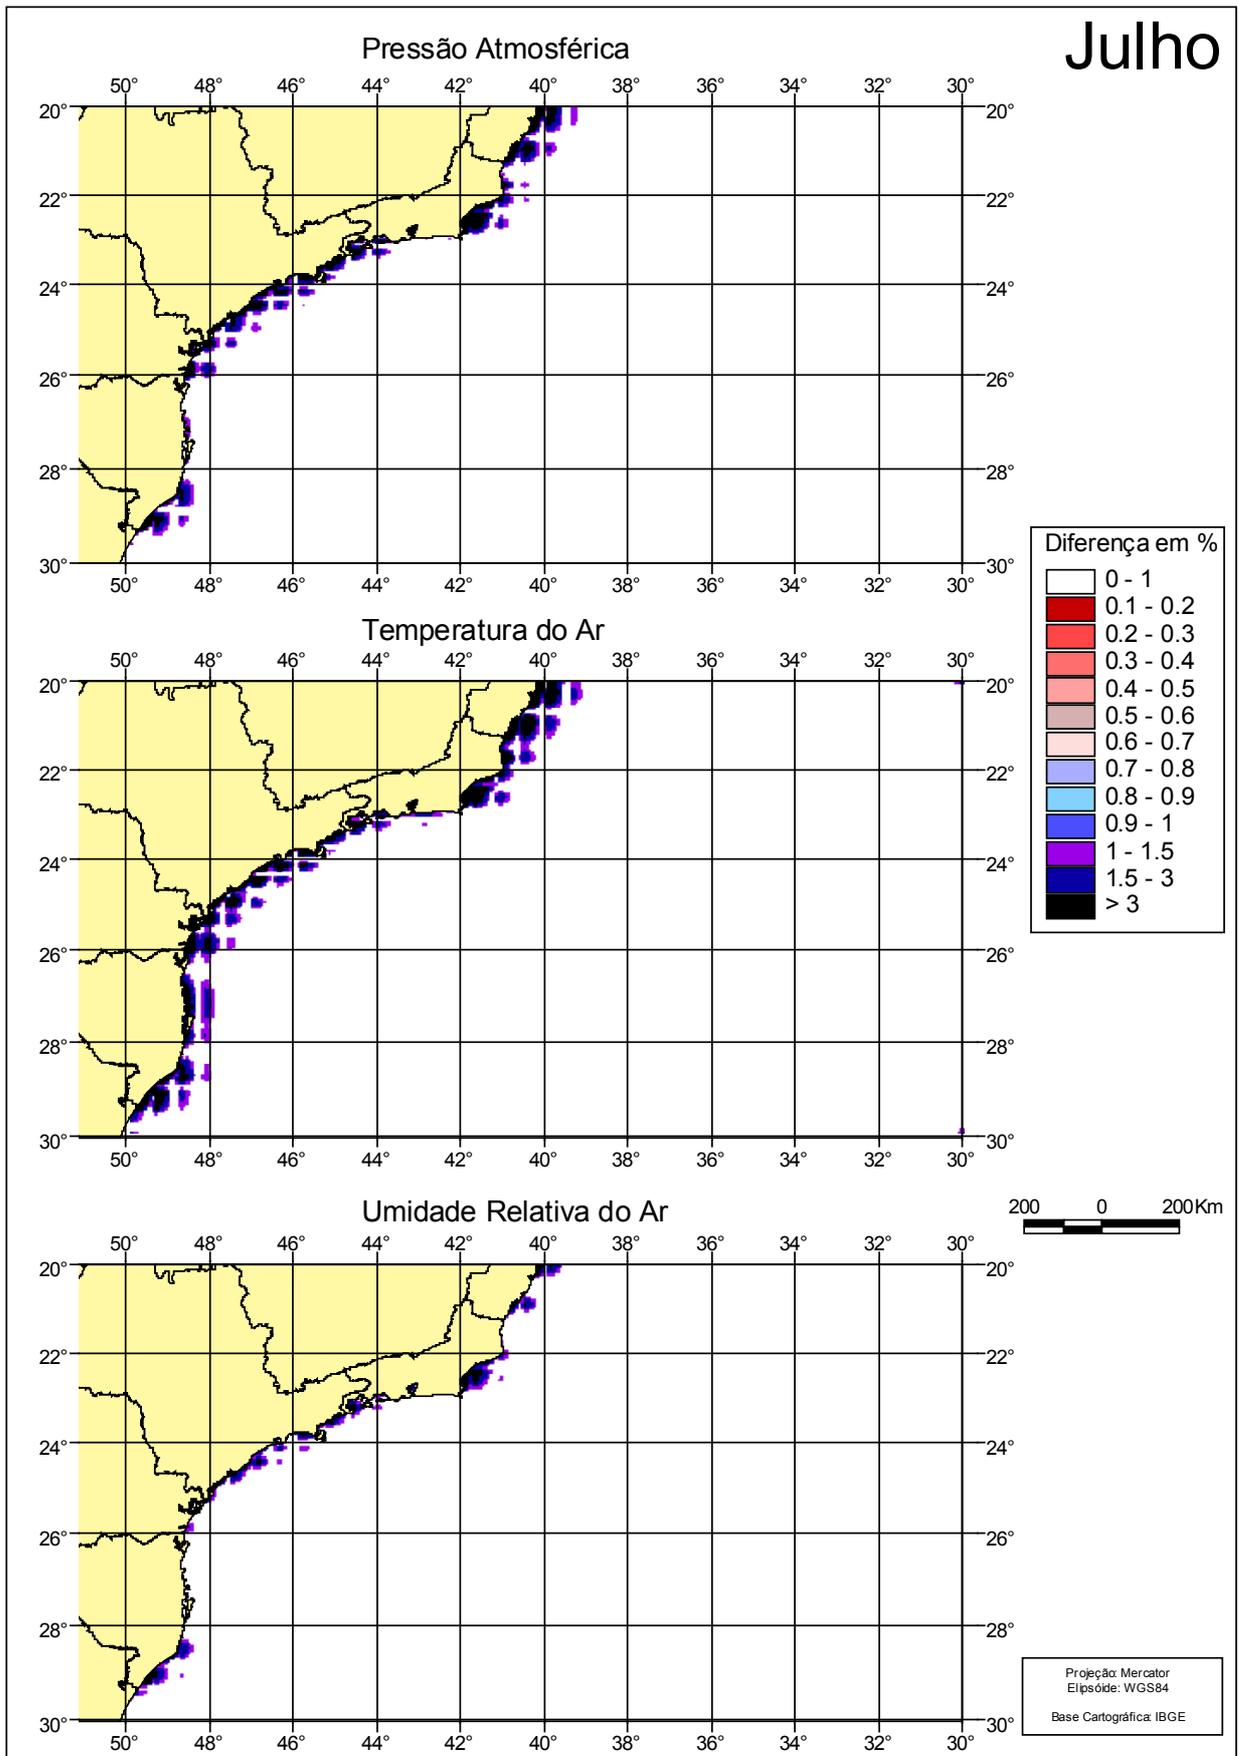


Figura 5.3.4 - Diferença dos dados meteorológicos entre dados originais e dados do modelo neuro-fuzzy, para julho.

## **CAPÍTULO 6**

### **CONCLUSÕES E RECOMENDAÇÕES**

A partir do objetivo principal deste trabalho, verificou-se que a substituição de um banco de dados oceanográficos e meteorológicos por banco de pesos obtidos através de redes neuro-fuzzy gera bons resultados, podendo ser aplicado em Sistemas de Informação Geográfica (SIG), permitindo interpolações para qualquer ponto da área e também proporcionando uma redução significativa no tamanho do banco de dados.

As rotinas de determinação dos parâmetros ambientais utilizadas no programa desenvolvido (apêndice I), podem ser implementadas em um SIG, o que permitirá a exibição dos resultados em mapas com rigor cartográfico, além de execução de consultas espaciais com combinação entre os parâmetros.

Os erros encontrados nos parâmetros climatológicos (temperatura salinidade e meteorologia) podem indicar a necessidade de subdividir a área, principalmente nas regiões mais próximas da costa e utilização de modelos neuro-fuzzy mais elaborados, quem permitam o ajuste automático das funções de pertinência dos antecedentes das regras.

Os resultados obtidos apontam para uma eventual necessidade de maior amostragens de dados nos pontos com os maiores erros, podendo dessa forma servir como instrumento de auxiliar de tomada de decisão para coletas ou comissões oceanográficas.

A metodologia deste trabalho mostrou-se promissora, sugere-se a sua utilização com outros tipos de dados, além de modelos de previsão ambiental.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ARNOFF, S. **Geographic information systems: a management perspective**. Ottawa, WDL, 1991. 295p.
- BAKUN, A.; PARRISH, R. H. **Comparative studies of coastal pelagic fish reproductive habitats: the brazilian sardine (*Sardinella aurita*)**. J. Cons. Int. Explor. Mer., nº 46, p.269-283, 1990.
- BAPTISTA NETO J. A.; SILVA, C. G. Morfologia dos Oceanos. *In* Baptista Neto J. A. et al. **Introdução à Geologia Marinha**. Rio de Janeiro: Interciência, 2004. p. 31 –53
- BOHNECKE, G. **Temperature, salinity and density of the surface waters of the Atlantic Ocean. Scientific results of the German Atlantic expedition of the research Vessel Meteor, 1925-1927**. Washington, DC: v. 5, 1936.
- BROWN, J.; COLLING, A.; PARK, D.; PHILLIPS, J.; ROTHERY, D. ; WRIGHT, J. **Seawater: its composition, properties and behaviour**. New York: Pergamon, 1989. 165p.
- CÂMARA G.; MEDEIROS J. S. **Geoprocessamento para projetos ambientais**. São José dos Campos, INPE, 1996.
- CÂMARA, G.; MEDEIROS, J. S. **Mapas e suas representações computacionais**. *In*: Assad, E. D.; Sano, E. E. ed. **Sistemas de informações geográficas: aplicações na agricultura** 2.ed. Brasília: Embrapa, 1998. Cap. 2, p 13 – 31.
- CASTRO FILHO, B. M.; MIRANDA L. B.; MIYAO, S. Y. **Condições hidrográficas na plataforma continental ao largo de Ubatuba: variações sazonais e em média escala**. Bolm. Inst. oceanogr., v.35, n.2, p.135-151, 1987.
- CASTRO FILHO, B. M. **Estado atual do conhecimento dos processos físicos das águas da plataforma continental do Brasil**. *In*: II Simpósio de Ecossistemas da costa sul e sudeste brasileira, v.1, p.1-19. Estrutura, função e manejo. Águas de Lindóia, 1990a.

- CASTRO FILHO, B. M. **Relatório do 5º ano do subprojeto oceanografia física do projeto utilização racional dos ecossistemas costeiros da região tropical brasileira.** São Paulo: Instituto Oceanográfico da Universidade de São Paulo. 1990b.
- CASTRO FILHO, B. M.; CAMPOS, E.J.D.; MASCARENHAS JR., A.S.; IKEDA, Y.; LORENZZETTI, J.A.; GARCIA, C.A.E.; MÖLLER JR., O.O. **Diagnóstico ambiental oceânico e costeiro das regiões Sul e Sudeste do Brasil.** São Paulo: FUNDESPA, v.3, p. 04-214, 1994.
- INTERNATIONAL OCEANOGRAPHIC COMMISSION. **GTSPP – Global Temperature-Salinity Pilot Project.** Fourth Session, Washington DC, UNESCO. 1990.
- EMILSSON, I. **The shelf and coastal waters of southern Brazil.** Bolm Inst. oceanogr., v.7, n.2, p.101-112, 1961.
- FOLK, R. L.; WARD, W. C. **Brazos River Bar: Study in the Significance of Grain Size parameter.** Journal of Sedimentology Petrology. 27 (1:3-36).
- JANG, J. S. R. **ANFIS: Adaptive-Network-Based Fuzzy Inference System.** IEEE Transactions on Systems, Man, and Cybernetics, may/june 1993, Vol.23, No.3, pp.665-685, 1993.
- KISTLER, R., ET AL. **The NCEP-NCAR 50-Year Reanalysis: Monthly Means CD-ROM and Documentation - Bulletin of The American Meteorological Society.** Vol. 82, No. 2, 2001, pp.247-267
- LEE, M. A., TAKAGI, H. **Learning Control for High Performance Genetic Algorithms.** Proc. IEEE / Nagoya University. Nagoya, Japan. 1994.
- LEGECKIS, R.; GORDON, A. L. **Satellite Observations of the Brazil and Falkland Currents, 1975 to 1976 and 1978.** Deep-Sea Research, v.36, n. 3, p. 359-384, 1982.
- LENTINI, C. A. D. **Estudo das variabilidades da temperatura da superfície do mar na plataforma continental sudeste da américa do sul.** São Paulo: 133p. Dissertação

- (Mestrado em Oceanografia Física) - Instituto Oceanográfico da Universidade de São Paulo, 1997.
- LEVITUS, S. **Climatological Atlas of the World Ocean**. NOAA/ERL GFDL Professional Paper 13, Princeton, N.J., 173p. 1982
- LOZIER, M. S.; OWENS, W. B.; CURRY, R.G. **The climatology of the North Atlantic**, *Prog. in Oceanogr.* 1995.
- MAMAYEV, O. I. **Temperature-salinity analysis of world ocean waters**. Amsterdam: Holanda. Elsevier Scientific Pub. Co., 1975. 374p.
- MAMDANI, E. H., ASSILIAN S., **An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller**. International Journal of Man-Machine Studies, 7(1): 1-13,1975.
- MATSUURA, Y. **Contribuição ao estudo da estrutura oceanográfica da região sudeste entre Cabo Frio (RJ) e Cabo de Santa Marta Grande (SC)**. Ciência e Cultura, v.38, n.8, p.1439-1451, 1986.
- MIRANDA, L. B. **Análise de massas de água da plataforma continental e da região oceânica adjacente: Cabo de São Tomé (RJ) à ilha de São Sebastião (SP)**. São Paulo: 194p. Tese (Livre Docência em Oceanografia) Instituto Oceanográfico da Universidade de São Paulo, 1982.
- MIRANDA, L. B.; CASTRO FILHO, B. M. **Aplicação do diagrama TS estatístico volumétrico à análise das massas de água da plataforma continental do Rio Grande do Sul**. Bolm. Inst. Oceanogr., v. 28, n.1, p. 185-200, 1979.
- MIRANDA, L. B.; KATSURAGAWA, M. **Estrutura térmica na região sudeste do Brasil (outono/novembro de 1988)**. Pub. Esp. Inst. Oceanogr., v.8, p. 1-14, 1991.
- NIJOKU, E. G. ; BARNETT, T. P. ; LAURUS, R. M.; VASTANO, A. C. **Advances in satellite sea surface temperature measurement and oceanographic applications**. Journal of Geophysical Research, v. 90(C6) , p.11573 - 11586, Nov. 1985.

ORGANIZAÇÃO METEOROLÓGICA MUNDIAL. **Guide to Meteorological Instruments and Observing Practices.** Genebra, 1971

PALMA, J. J. C. Geomorfologia da Plataforma Continental Norte Brasileira. *In* Chaves, H. A. **Geomorfologia da Margem Continental Brasileira e das Áreas Costeiras Adjacentes.** Rio de Janeiro, PETROBRAS, Projeto REMAC, Vol 7: 25: 50. 1979

PETERSON, R. G.; STRAMMA, L. **Upper-level circulation in the South Atlantic Ocean.** *Progress in Oceanography.* v.26, n.1, p. 1-73, 1991.

PICKARD, G. L.; EMERY, W. J. **Descriptive physical oceanography: an introduction.** New York: Pergamon, 1990. 300p.

PONZI, V. R. A. Sedimentação Marinha. *In* Baptista Neto J. A. et al. **Introdução à Geologia Marinha.** Rio de Janeiro: Interciência, p. 219-242. 2004.

RAMOS, J. A. P. **Uso de Sistemas de Informações Geográficas (SIG) e Banco de Dados Para Análise de Parâmetros Meteorológicos e Oceanográficos.** 141p. Dissertação de Mestrado em Sensoriamento Remoto. São José dos Campos: INPE, 1999.

REID, J. L.; NOWLIN JR, W. D.; PATZERT, W. C. **On characteristics and circulation of the Southwestern Atlantic Ocean.** *Journal of Physical Oceanography,* v.7, p. 62-91, 1977.

SHEPARD, F. P. **Submarine Geology.** Nova York, Harper & Row. 1963

SILVA, M. P. **Caracterização físico-química das massas de água da bacia de Santos durante o projeto COROAS. Verão e inverno de 1993.** São Paulo. 153p. Dissertação de Mestrado em Oceanografia. Instituto Oceanográfico da Universidade de São Paulo, 1995.

SILVA, R., R.; COSTA, W. C. **Ambiente de Simulação em Redes Neurais.** 99p. Projeto de Graduação. Univer2002 (RN)

SOUZA, F. J. **Modelos Neuro-Fuzzy Hierárquicos.** 169p. Tese de Doutorado. PUC-Rio de Janeiro. 1999.

STEELE, M., R. ERMOLD, W, PHC: **A Global Ocean Hydrography With a High Quality Arctic Ocean** PHC. 2001.

VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**. Brasilia. INMET. 2001.

ZADEH, L. A. **Fuzzy Sets, Information and Control**. Vol 8, p. 338-353, 1965.

ZEMBRUSKI, S., BARRETO, H.T., PALMA, J. C., MILLIMAN, J., D. **Estudo Preliminar das Províncias Geomorfológicas da Margem Continental Brasileira**. Anais XXVI Congresso Brasileiro de Geologia – Belem –PA Vol. 2, 1972.