

APLICAÇÃO DE UMA REDE NEURAL ARTIFICIAL SIMPLIFICADA PARA A IDENTIFICAÇÃO DE GRADAÇÃO DE DEPÓSITOS TURBIDÍTICOS

Rafael MANICA¹

(1) Núcleo de Estudos de Correntes de Densidade – Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul. Av. Bento Gonçalves, 9500 Cep 91501-970 Caixa Postal 15029, Porto Alegre, Brasil. Endereço eletrônico: manica@iph.ufrgs.br

Introdução

Metodologia

O problema: identificação da gradação normal, inversa e maciça

Preparação e aplicação da metodologia de identificação de padrões

Escolha das imagens

Aplicativo sirene®

Treinamento e Validação

Resultados

Considerações finais

RESUMO - Redes Neurais Artificiais são sistemas computacionais inteligentes inspirados no sistema biológico humano reproduzindo o cérebro na resolução de tarefas. No contexto geológico, esta ferramenta foi adaptada e aplicada na identificação e classificação da gradação de depósitos turbidíticos ao longo da vertical (gradação normal, inversa e maciça). O método aplicado baseou-se somente nas imagens digitais dos depósitos gerados via simulação física de correntes de turbidez e a rede neural foi idealizada, utilizando como dado de entrada a média e variância dos valores de pixels dessas imagens. A rede neural foi treinada (aprendizado), validada (verificação de eficiência) e utilizada para identificar os padrões. Os resultados apresentaram uma eficiência de acerto variando entre 53-92% (média de 76%) para a gradação normal, 52-99% (média de 73%) para a gradação maciça e 38-76% (média de 53%) para a gradação inversa. A metodologia simplificada introduzida neste estudo apresentou resultados coerentes, igualando-se aos métodos tradicionais de análise granulométrica e observações visuais aos depósitos e tendo a vantagem de reduzir as incertezas e subjetividades neste tipo de análise. Ainda, esta ferramenta pode ser aperfeiçoada e extrapolada para os diversos estudos geológicos de campo (afloramentos e testemunhos de sondagens) para auxiliar no entendimento dos fenômenos naturais.

Palavras Chaves: rede neural artificial, gradação de depósitos, turbiditos, modelagem física.

ABSTRACT - Artificial Neural Networks are intelligent computational systems inspired by the human biological system capable of reproduce the human brain ability in solving tasks. In the geological context, this tool was adapted and applied in the identification and classification of graded beds (normal, inverse and massive). The method applied was based only on the digital images of turbidity currents deposits generated through physical simulation. The Neural Network was designed using as input the mean and variance of the pixel values of these images and it were trained (pattern learning), validated (efficiency checking) and later, processed the images. Artificial Neural Networks results demonstrated accuracy factors ranged between 53-92% (mean of 76%) for normal grading, 52-99% (mean of 73%) for massive grading and 38-76% (mean of 53%) for inverse grading. The methodology introduced in this study, although quite simple, presented very concise results, which closely match up the results obtained through conventional analyzing tools (grain size analysis and qualitative observations) being an alternative tool to reduce uncertainty and subjectivity in physical simulation analysis. Furthermore, this non-intrusive methodology (based in digital images only) can be extrapolated to field observations allowing the classification of several turbidity facies and/or sedimentological process in natural sites.

Keywords: artificial neural networks, graded deposits, turbidities, physical modeling

INTRODUÇÃO

Os sistemas deposicionais turbidíticos são resultados da sedimentação de materiais erodidos e transportados por correntes de densidade (água + sedimento) em águas oceânicas profundas ao longo de milhares de anos. Os depósitos gerados por tais fluxos apresentam propriedades características (p. ex. arranjo de grãos, permeabilidade, porosidade, etc), os quais proporcionam, em algumas situações, a formação de reservas potenciais de

hidrocarbonetos, tornando-se desta forma um importante alvo da indústria de petróleo.

Desde o trabalho pioneiro de Kuenen & Migliorini (1950), o estudo detalhado dos padrões deposicionais turbidíticos são utilizados para a compreensão de seus processos dinâmicos, porém, ainda hoje, o comportamento dessas correntes não foi totalmente explicado, principalmente pela dificuldade de obtenção dos dados reais naturais (Baas et al., 2004). Assim, três

caminhos foram seguidos para o entendimento desse fenômeno: o estudo de sistemas turbidíticos em campo (afloramentos, testemunhos de sondagens e outras técnicas); os modelos teóricos de sedimentação; e os experimentos de laboratório (Kneller & Buckee, 2000). A modelagem física, através do uso de experimentos em escala reduzida em laboratório, é fundamental para o entendimento deste processo, pois permite o total controle das condições de contorno nos ensaios e de seus resultados, em destaque os depósitos nela gerados (Middleton, 1970).

No ambiente natural, os sistemas deposicionais turbidíticos apresentam, entre outras fácies características, três tipos de arranjo interno dos grãos bem característicos, são eles: gradação normal, gradação inversa e gradação maciça, os quais se distinguem, principalmente, pela disposição dos grãos depositados ao longo da vertical, i.e., da base ao topo do depósito. A gradação normal é caracterizada pela presença de sedimento mais grosso junto à base do depósito e por sedimento mais fino junto ao topo. Esse processo é o mais comum, pois segue a tendência de queda do grão por gravidade (Bouma 1962). Já a gradação inversa é o oposto da gradação

normal, com os grãos mais finos junto à base do depósito e os grãos mais grossos junto ao topo. Esse tipo de arranjo está correlacionado aos processos de transporte e deposição característicos, tais como perturbações do fluxo, passagem por obstáculos, remobilização de sedimento (ver Hiscott, 1994; Hand, 1997; Ávila *et al*, 2003), os quais provocam a inversão natural dos grãos. Já a gradação maciça se caracteriza por apresentar uma distribuição homogênea ao longo de sua altura, com a presença de grãos grossos e finos misturados, mostrando que o fluxo possui capacidade de transporte suficiente para manter os grãos em suspensão. Na simulação física, esses padrões também são reproduzidos, como pode ser verificado em diversos trabalhos fluentes na literatura, (p.ex. Kuenen & Migliorini, 1950, Middleton, 1966; Postma, 1988; Ávila *et al.*, 2002; Amy *et al.*, 2006 Manica, 2012 entre muitos outros). A figura 1, apresenta um exemplo de depósito gerado na simulação física de correntes de densidade (Ávila *et al*, 2002), onde é possível verificar um depósito gradado normalmente a partir de imagens digitais do depósito e posterior tratamento das mesmas.

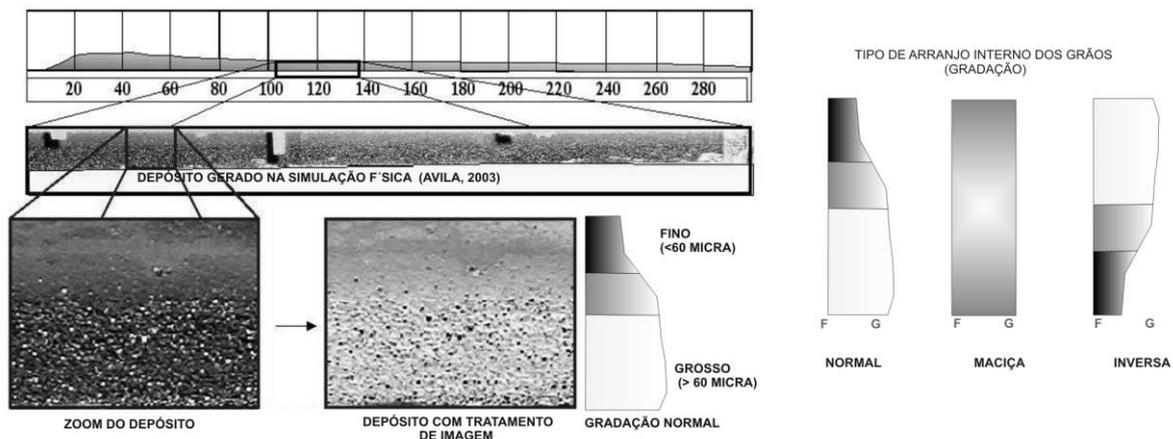


Figura 1. Esquema mostrando o depósito resultante de uma simulação bidimensional de correntes de turbidez através de modelagem física, com a interpretação de parcela do depósito, via tratamento de imagens.

Para a realização desta identificação do padrão de deposição, tanto em campo quanto em laboratório, utilizam-se frequentemente dois métodos de avaliação: a análise qualitativa de imagens digitais realizadas no local do registro deposicional e análise granulométrica dos grãos depositados, sendo estas coletadas em diversas

fatias ao longo da vertical. Muitas vezes, porém tais avaliações granulométricas não podem ser realizadas com exatidão, especialmente no campo, onde a coleta de material particulado é invasiva e altera as características iniciais do depósito, por exemplo, criando cavidades ou

alterando a sua forma e/ou estrutura a ponto de inviabilizar análises posteriores (figura 2).

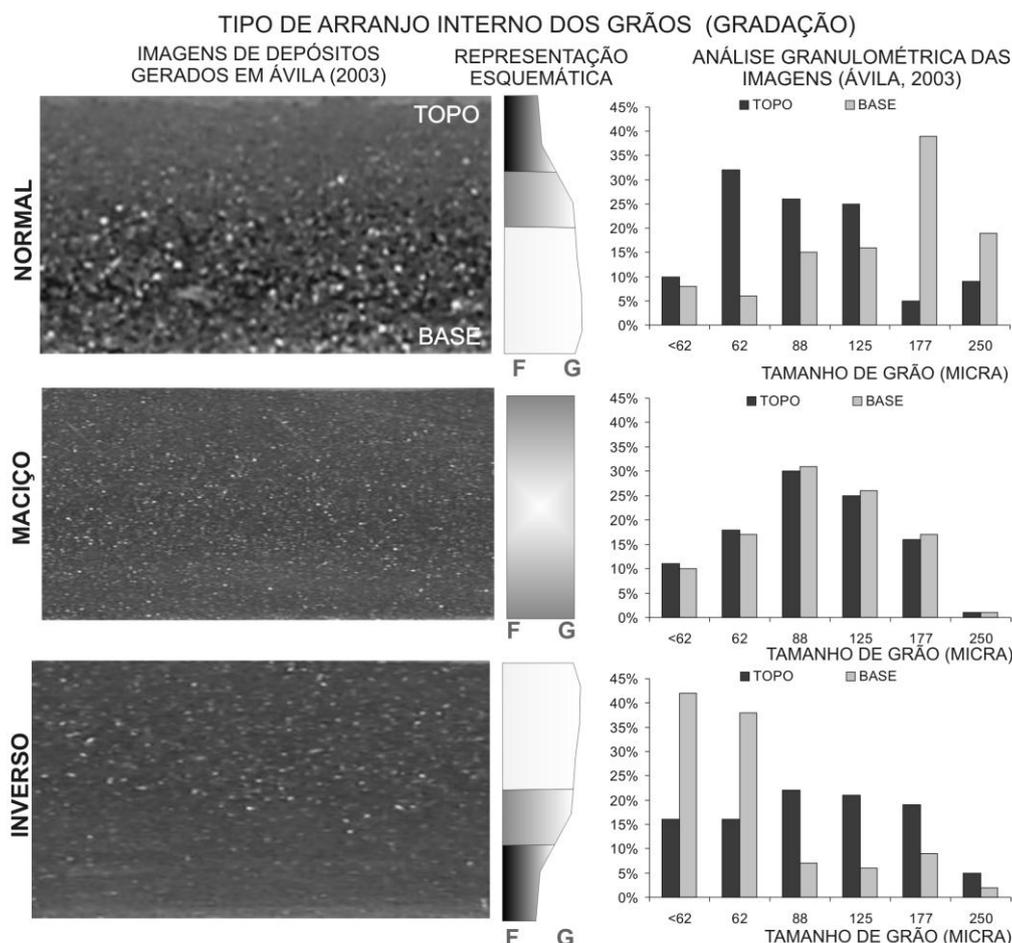


Figura 2. Três tipos de arranjo interno dos grãos utilizados nesse trabalho, com o respectivo esquema de gradação de grãos e análise granulométrica dos respectivos depósitos.

Por outro lado, as análises qualitativas do depósito são baseadas em observação visual direta ou indireta do depósito (imagens) e a classificação do arranjo interno dos grãos é realizada comparando-a com um padrão pré-estabelecido. Neste caso, as incertezas e a subjetividade na interpretação dos resultados estão sempre presentes. Uma maneira de minimizar essa subjetividade é a de substituir esse comportamento humano de avaliação qualitativa, tornando-a quantitativa. Para tal, pode-se utilizar os sistemas inteligentes computacionais, os quais vêm sendo cada vez mais aprimorados ao longo dos anos e que vêm sendo aplicados em diferentes campos do conhecimento, tais como: reconhecimento de padrões, processamento de sinais, robótica, otimização de sistemas entre outras aplicações (Haykin, 2001).

Conceitualmente, os sistemas inteligentes fazem parte da ciência da computação dedicada ao projeto de sistemas que simulam

características da inteligência humana, fornecendo métodos e técnicas para o desenvolvimento de programas visando a solução de problemas. Particularmente, as Redes Neurais Artificiais (RNA) são sistemas computacionais inteligentes inspirados no sistema humano, e simulam algumas funções cerebrais, reproduzindo de forma geral a capacidade do cérebro na resolução de problemas. Isto é feito com a utilização de um modelo que consiste em elementos de processamento (chamados, por analogia, de neurônios artificiais) e suas conexões, com coeficientes numéricos sinápticos (pesos sinápticos) associados. Desta forma, as RNA's constroem suas próprias estratégias de processamento de informação para a solução de problemas que requerem aquisição de conhecimento através da experiência.

Dentre as principais características das redes neurais artificiais são: capacidade de aprendizado e adaptação que ocorre quando a

rede consegue obter soluções generalizadas para uma classe de problemas; generalização não chegam a ser totalmente universais (aproximações de funções ou ajustamento), mas conseguem identificar uma solução plausível (saídas), mesmo em processos onde não há conhecimento explícito; memorização que representa o conhecimento adquirido; auto-organização que identifica as conexões mais importantes dentro de um sistema a ser analisado; e imunidade que não colapsa quando

há informações incorretas ou ausentes (Góes et al, 2001).

O neurônio biológico utilizado como inspiração nesses sistemas, se caracteriza por possuir um corpo celular, também chamado de soma, dendritos e axônio (Figura 3a). O neurônio é uma célula capaz de receber impulsos elétricos de um primeiro neurônio, a partir de seus dendritos, processá-los no seu corpo celular, e transmiti-los, através do axônio, para os dendritos de outros neurônios em sequência (Haykin, 2001).

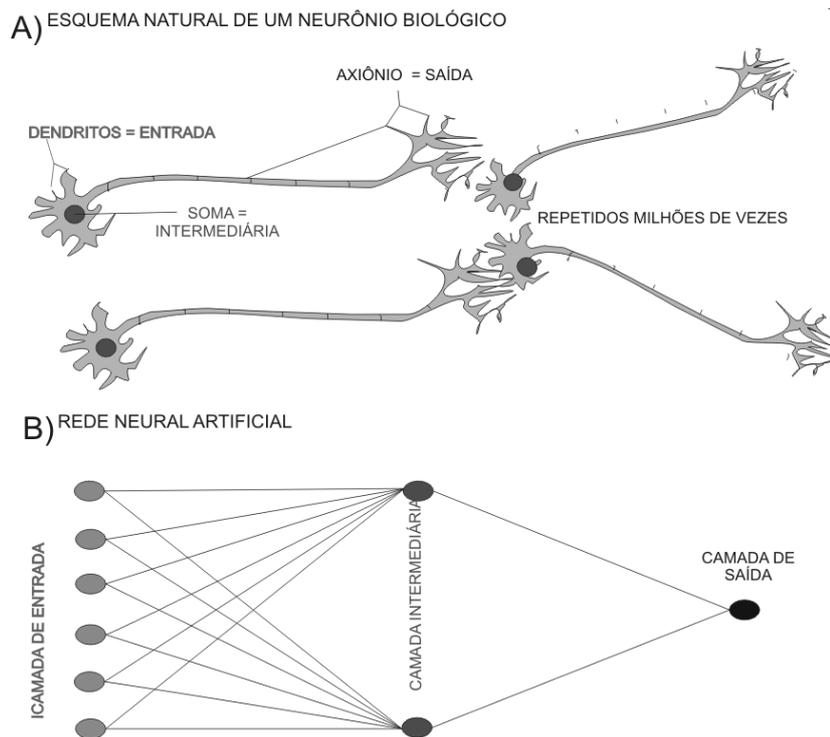


Figura 3. A) Esquema de um neurônio Biológico; B) arquitetura da Rede Neural Artificial utilizada

A conexão entre um neurônio e outro é chamado de sinapse. A sinapse é a unidade funcional básica para a construção dos circuitos neurais biológicos. O funcionamento básico dos neurônios pode ser simplificado da seguinte maneira: a permeabilidade da membrana pós-sináptica é proporcional a soma algébrica dos potenciais recebidos em todos os dendritos do neurônio. Se esta soma supera um valor limiar, o neurônio passa a transmitir um potencial de ação de natureza elétrica. Considerando que no corpo humano há um número elevadíssimo de neurônios, esse processamento se dá em paralelo, ou seja, é realizado distributivamente entre seus elementos processadores, garantindo assim, rapidez na realização de tarefas.

As RNA's são normalmente constituídas de forma a representar o neurônio biológico, estruturando-se da seguinte maneira (figura 3b): entradas, geralmente numérica e corresponde ao estímulo ou potencial elétrico recebido; função ou regra de propagação, que é a soma ponderada das entradas correspondentes a soma algébrica dos potenciais recebidos; pesos sinápticos (coeficiente de ponderação das entradas), os quais representam a ação sináptica atuante sobre cada potencial de ação recebido em cada dentrito; função ou regra de ativação que calcula o nível de ativação do neurônio, podendo ser uma função contínua ou binária (ligado e desligado); função limiar de um neurônio biológico; função de saída que

converte o sinal emitido, resultante da função de ativação, para a forma ou escala conveniente, constituindo a resposta sensorial.

Com essa estrutura, uma RNA é composta por um elevado número de elementos processadores amplamente conectados entre si. Cada uma das conexões possui um valor que determina o grau de conectividade entre estes, denominados pesos da conexão (pesos sinápticos). O ajuste destes pesos sinápticos é que capacita a rede em resolver os diversos tipos de problemas a ela submetida.

Assim, este trabalho propõe-se aplicar uma ferramenta complementar não subjetiva e não invasiva para a identificação de padrões

deposicionais turbidíticos gerados através da simulação física, no caso uma Rede Neural Artificial simplificada, com o uso apenas de imagens digitais não tratadas destes depósitos. Também, busca apresentar uma metodologia simples e independente a ser aplicada futuramente em depósitos naturais ou outros campos de atuação para o reconhecimento do arranjo interno deposicional sedimentar, i.e. testemunho de sondagem, lâminas petrográficas. Dessa forma, espera-se que as incertezas neste processo sejam minimizadas e que essa metodologia simples desenvolvida sirva de inspiração para o uso de sistemas inteligentes nos estudos de geociências.

METODOLOGIA

O problema: identificação da gradação normal, inversa e maciça

Para a realização deste trabalho, a única informação que distinguia os três tipos de gradação a serem identificadas nos depósitos era a sua distribuição de grãos ao longo de sua vertical. Isso era obtido através de imagens digitais dos depósitos gerados através de simulação física em laboratório.

Numa primeira análise qualitativa das imagens coletadas de depósitos gerados, notou-se que os grãos mais finos possuíam tonalidades mais escuras, enquanto que, os grãos mais grossos presentes possuíam uma tonalidade mais clara na imagem devido à influência da luminosidade uma vez que, nesses grãos há uma maior superfície de contato com uma maior capacidade de refletir a luz.

Esta diferença de tonalidade foi utilizada como indicador para diferenciar os três tipos de fácies analisada. Cabe destacar, que essa diferença entre os sedimentos grossos e finos não é muito evidente, uma vez que, na região onde predomina os sedimentos grossos há espaços vazios, que são preenchidos com materiais de menor tamanho, tornando a diferença entre os grãos muito tênue, o que muitas vezes, dificulta na distinção dos padrões. Nesses casos, não há como realizar a análise somente pela observação visual das imagens digitais e outros método, como a análise granulométrica por exemplo, deve ser utilizada. A desvantagem é que a essa se caracteriza por ser um método de análise invasiva, ou seja,

destruindo o depósito gerado na hora de sua coleta. Assim, a utilização de outra ferramenta de análise não-invasiva, no caso as redes neurais artificiais, torna-se válida.

A partir deste ponto, buscou-se desenvolver uma metodologia que fosse o mais independente e o mais simples possível de outros tipos de metodologia utilizados até então para esse tipo de caracterização, empregando o uso de uma Rede Neural Artificial simples (Perceptron) que necessitasse apenas de imagens digitalizadas como dado de entrada. Neste caso, a imagem digitalizada do depósito gerado era representada pela sua matriz de pixels. Optou-se por não utilizar nenhum tipo de pré-tratamento da imagem, apenas utiliza-la em tons de cinza, onde cada pixel contém um nível de cinza com valores variando entre 0 e 256.

Comparando a imagem digital com sua matriz de pixels é possível observar que os maiores valores (próximos a 256) estão relacionados aos tons mais claros, enquanto que valores mais baixos, aos tons mais escuros (próximos a zero). Desta maneira, uma matriz que apresenta valores próximos a zero na sua parte superior (topo do depósito) e valores próximos a 256 junto a sua base indicariam, que nesse depósito estava acontecendo à gradação normal, enquanto que o contrário disso, indicaria uma gradação inversa e se acaso ocorresse a mistura de valores, indicaria uma gradação maciça. Como estas características estão fortemente ligadas as distribuições dos grãos ao longo da

vertical, não há necessidade de termos imagens muito largas, e sim, pequenas fatias verticais já seriam suficiente para caracterizar esses arranjos internos de grãos. Com isso, há três

padrões teóricos possíveis que podem ser encontrados na matriz de pixel, relacionando os tons de cinza pela altura (número de linhas) da imagem (figura 4).

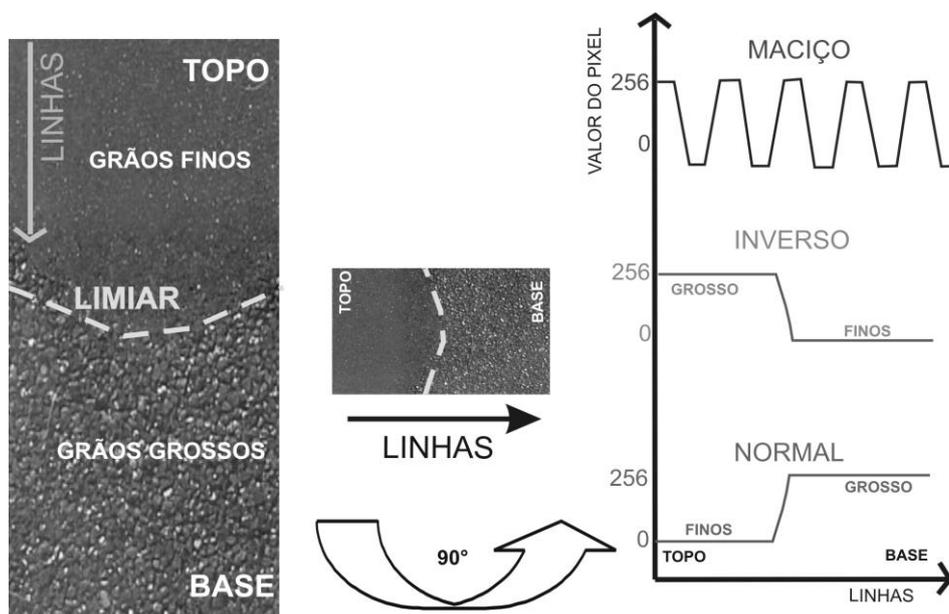


Figura 4. Imagens de um depósito artificial mostrando as diferenças dos tipos de grãos ao longo do número de linhas (altura da imagem), a zona limiar (linha tracejada) de troca da classe dos sedimentos e os modelos esquemáticos criados para representar cada tipo de arranjo de grãos (à direita) na rede neural artificial.

Para que uma RNA possa fazer o reconhecimento destes padrões são necessários parâmetros de entrada que permitem o treinamento e, conseqüentemente, o aprendizado da rede. Diversos trabalhos da literatura (p. ex. Campos, 2001 e Dahmer, 2000) indicaram os fatores, de entrada, passando pelos mais simples, como a média, mediana, variância da matriz de pixels, até aplicação de processos de tratamento de imagem, como aplicação de contrastes, detecção de bordas, filtros, transformadas diversas, que se baseiam em algoritmos mais complexos. Nestes casos a imagem digital sofre um grande processo de pré-tratamento, o que não era objetivo deste trabalho. Desta forma, dois parâmetros de entrada para a RNA foram escolhidos: a média e a variância dos pixels ao longo de cada linha da matriz de pixel (formada pelo número de linhas ou altura e pelo número de colunas ou largura da imagem).

A utilização da média foi justificada como o indicativo de tonalidade predominante na linha, ou seja, se o valor naquela linha estava próximo do padrão de tons escuros (sedimento

fino) ou claros (sedimento grosso). Já a utilização da variância se justifica como indicador de mudança entre os valores dos pixels vizinhos, ao longo de uma linha, como no caso citado anteriormente, quando há predominância de material grosso com seus espaços preenchidos com grãos mais finos. Desta forma, a variância de uma linha será pequena quando houver predominância de grãos do mesmo tamanho e grande quando houver predominância de sedimento com diferentes tamanhos.

A imagem do depósito apresentado nas figuras 4 e 5 - que possuía o tamanho de 200 colunas (largura) e 300 linhas (altura) - apresenta esse comportamento. Nesse caso, uma amostra artificial foi montada para demonstrar essa diferença. Na parte inferior foi colocado carvão mineral (sedimento utilizado nas simulações físicas avaliadas) com tamanho 500 micra e na parte superior o mesmo material com tamanho de 62 micra. O esquema apresentado na figura 4 demonstra claramente o comportamento descrito anteriormente. Em torno do limiar (linha 118 indicada pela linha

tracejada), onde ocorre a troca da granulometria notamos que os valores médios e a variância aumentam em direção a base do depósito, sendo

esse último com uma diferença de valores significativas.

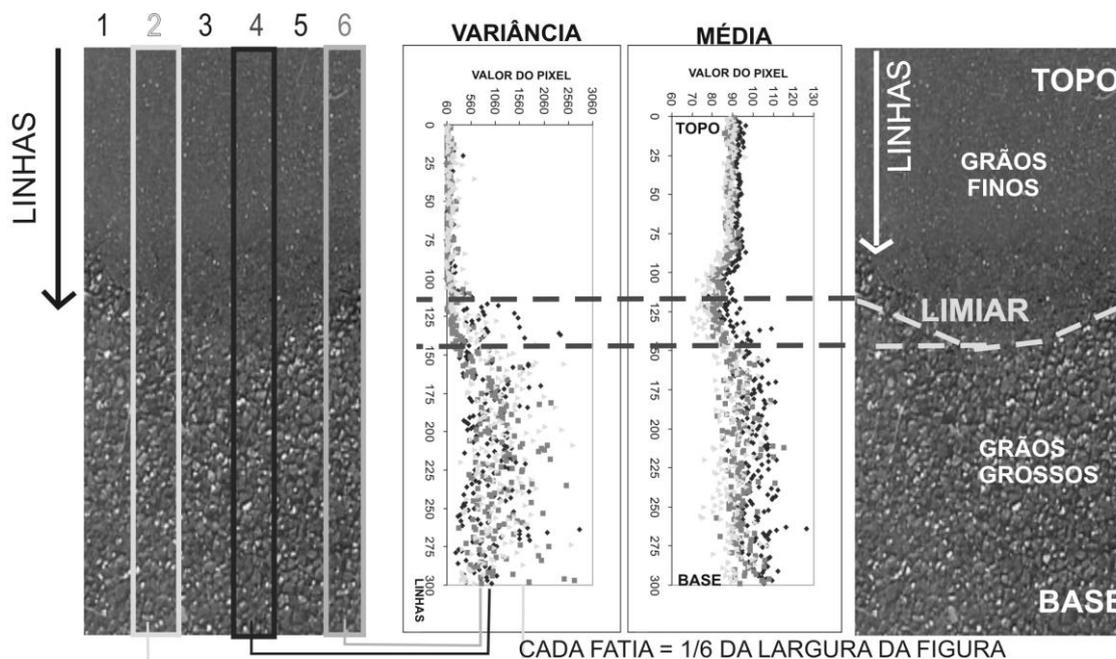


Figura 5. Imagens de um depósito mostrando a metodologia empregada para fatiar o depósito e avaliar a tonalidade de cinza ao longo do número de linhas (altura da imagem) e o respectivo cálculo da média e variância dos pixels para cada linha da matriz (imagem)

Com a definição desses dois parâmetros, foi decidido utilizar três valores médios e três valores de variância de uma mesma figura. A imagem inicialmente era dividida em seis fatias ao longo da vertical e foram escolhidas a segunda, a quarta e a sexta fatias (figura 5). Nessas, eram calculadas a média e a variância para cada linha da imagem ao longo de toda a altura da mesma. Essa divisão em fatias foi utilizada, também, para permitir que a entrada de dados tivesse uma heterogeneidade nos valores, não sendo suavizadas apenas por um valor médio ao longo de sua largura. Assim, com os parâmetros de entrada definidos estabeleceu-se uma RNA com a seguinte arquitetura (figura 3b): seis neurônios na camada de entrada (três médias e três variâncias), dois neurônios na camada intermediária e 1 neurônio de saída, que classificava o resultado em duas classes binárias, zero para sedimento fino (valor de pixel abaixo de 128) e 1 para sedimento grosso (valor de pixel acima de 128).

Preparação e Aplicação da Metodologia de Identificação de Padrões

Para a realização da metodologia proposta foram realizados quatro processos, são eles: escolha das imagens; preparação da imagem digital (tons de cinza); à preparação de dados para a entrada na RNA e; utilização do aplicativo SIRENE© que projeta, treina, valida e executa a RNA arquitetada.

Escolha das Imagens

Dezoito imagens de regiões de depósitos turbidíticos simulados em modelos físicos do trabalho de Ávila et al, (2003), foram selecionadas para serem aplicadas na RNA. Essas imagens foram classificadas pelo referido autor conforme seu arranjo interno do grão e divididas em três grupos com seis imagens cada em: gradação normal (GN); gradação inversa (GIN) e gradação maciça (MAC). O critério utilizado pelo pesquisador foi à análise qualitativa das imagens digitais e resultados de análise granulométrica realizada nas suas amostras. A tabela 1 apresenta as características das imagens selecionadas.

Tabela 1. Características das imagens utilizadas Gradação Normal (GN); Gradação Inversa (GIN) e Gradação Maciça (MAC)

Nome	Gradação	Numero de Colunas	Número de Linhas	Linha do limiar
1 GN_I	Normal	100	50	23
2 GN_II		50	50	19
3 GN_III		250	125	33
4 GN_IV		250	75	25
5 GN_V		250	115	55
6 GN_VI		230	190	82
7 GIN_I	Inversa	200	125	79
8 GIN_II		250	250	147
9 GIN_III		200	105	81
10 GIN_IV		175	50	37
11 GIN_V		200	60	43
12 GIN_VI		150	390	220
13 MAC_I	Maciça	250	175	-
14 MAC_II		250	175	-
15 MAC_III		250	250	-
16 MAC_IV		150	150	-
17 MAC_V		750	150	-
18 MAC_VI		200	270	-

Após a seleção das imagens, as mesmas foram preparadas para servir de dado de entrada da RNA utilizada nesse trabalho. Dessa forma, as imagens eram transformadas em escala de cinza, convertidas digitalmente para o sistema binário, e posteriormente divididas em seis fatias. Assim, para cada linha (altura) da imagem, eram calculadas as médias e variâncias das três fatias escolhidas para o processamento. Com esses valores e posição (número de linhas) uma planilha era gerada e estava pronta para ser processada.

Aplicativo SIRENE®

O aplicativo SIRENE© - Sistema de Redes Neurais - foi desenvolvido no IPH/UFRGS para trabalhar com sistemas de redes neurais progressivas. Através dele é possível projetar qualquer RNA com até quarenta neurônios. Possui ainda três funções de ativação (identidade, sigmoideal e sinoidal) e três funções de saída (identidade, invertida e discreta) esta última permite o uso de diversas padrões de resposta. O treinamento da rede pode ser realizado com o uso do método de

retropropagação do erro, ou ainda, por algoritmos genéticos.

Neste estudo foi utilizada uma RNA com nove neurônios (figura 3b), seis na camada de entrada, conectados simultaneamente com dois neurônios na camada intermediária, cuja função de ativação era a identidade, a qual que conectava um neurônio de saída, que classificava o resultado em duas classes, zero para sedimento fino e um para sedimento grosso.

Treinamento e Validação

O processo de treinamento de uma RNA é caracterizado pelo aprendizado da rede na identificação do comportamento ou padrão a ser reconhecido, assim à medida que ela vai treinando deve ser capaz de modificar gradualmente os padrões de interconexão inicial, de modo a adaptá-lo a resolução do problema proposto. Quando os resultados desejados são fornecidos, chamamos o treinamento de supervisionado. As RNA são treinadas com dados experimentais para a sua aprendizagem, sendo a qualidade desses dados

muito importante, pois exercem uma forte influência no desempenho da rede. Neste trabalho o arquivo utilizado no treinamento foi uma composição de três imagens previamente selecionadas e classificadas como gradação normal. De cada uma das imagens foi extraída uma fatia vertical (50 linhas) e foram calculadas a sua média e a variância para cada linha. A linha 25 foi utilizada como limiar, sendo de 0 - 25 considerado sedimento fino e de 25 - 50 considerado sedimento grosso. Cabe salientar que, na prática, essa mudança não é abrupta, existindo entre as duas classes uma mudança gradual dos valores (região do limiar).

O treinamento da rede foi realizado com o aplicativo SIRENE©, utilizando o algoritmo de retropropagação de erro, com 1000 interações, atingindo 100% de acerto para a amostra analisada (figura 6a).

Uma vez treinada, a RNA estava apta para a reprodução de dados de saída correspondentes a novos dados de entrada. Esta etapa se caracteriza pela verificação e seu desempenho. Foi escolhida uma imagem digitalizada com 150 colunas (largura) e 50 linhas (altura) que foi previamente classificada como gradação normal.

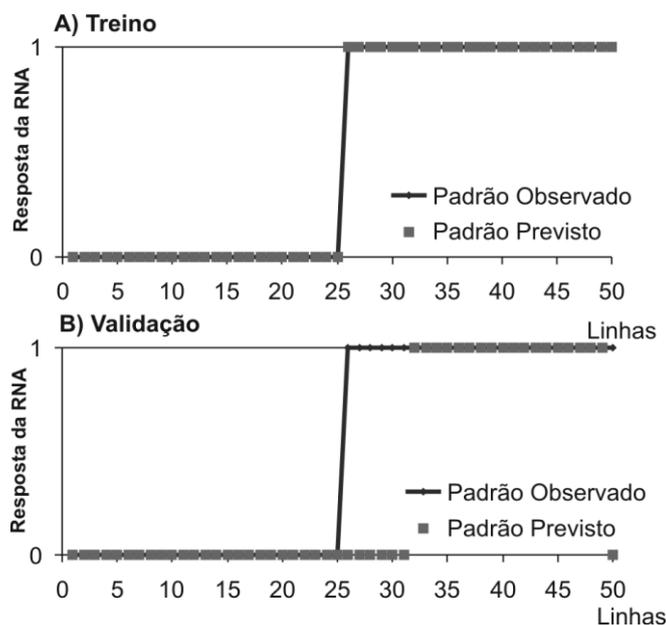


Figura 6. A) Gráfico de resposta do treino da RNA com acerto de 100% do padrão previsto (gradação normal); B) Gráfico de resposta da validação da RNA com acerto de 76% do padrão previsto (gradação normal).

O resultado apresentado pela validação foi de 86%. A figura 6b apresenta o gráfico do padrão observado na imagem e o valor calculado pela RNA. Nota-se que nesse resultado, que em meio aos sete erros apresentados (padrão observado diferente do padrão calculado), seis deles foram na zona de transição entre sedimento fino e grosso (linhas

25 a 30). Comparando com os gráficos apresentados nas figuras 4 e 5, notamos que o resultado foi altamente positivo, uma vez que realmente nessa região, a transição nunca é abrupta. Desta forma a rede foi considerada validada e pronta para ser utilizada nas dezoito imagens selecionadas para a amostragem.

RESULTADOS

As simulações foram realizadas seguindo a metodologia descrita anteriormente. Os resultados estão apresentados na figura 7, onde nota-se que para quase todas as imagens a

tendência resultante foi similar a tendência observada pelas outras ferramentas de análise (observação visual e análise granulométrica).

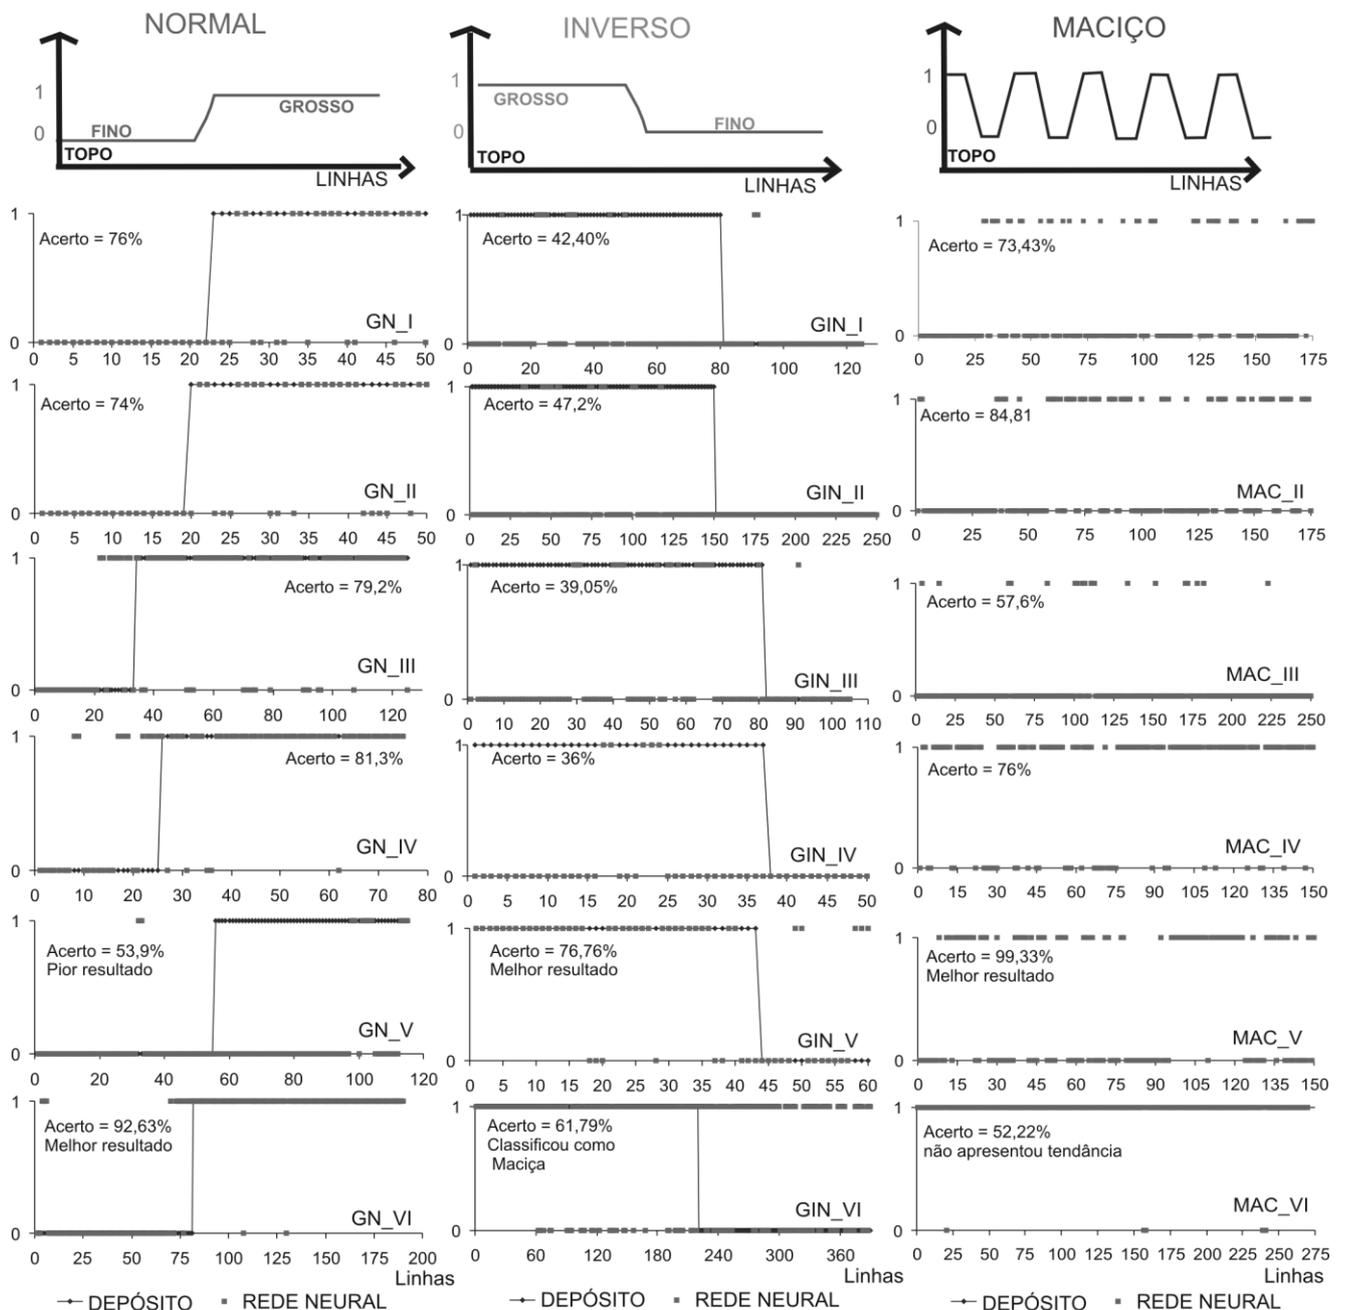


Figura 7. Resultados da aplicação da Rede Neural Artificial para prever o comportamento do depósitos para as 18 imagens selecionadas: Gradação Normal (GN); Gradação Inversa (GIN) e Gradação Maciça (MAC)

A imagem GIN_VI que pertencia ao grupo da gradação inversa (acerto de 61,79%) foi mais bem classificada como gradação maciça (no caso, teria eficiência de 88,00%). Já a imagem GN_V, GIN_I, GIN_III e GIN_IV e MAC_III apresentaram uma tendência muito pequena, considerada insuficiente para uma classificação mais precisa. A imagem MAC_VI não apresentou tendência alguma. Nestas figuras, a média dos valores da matriz de pixel estava muito abaixo ou muito acima dos valores utilizados no seu treinamento, fazendo com que

a rede classificasse uma classe apenas (no caso, só sedimento grosso). A solução nestes casos deveria ser a variância, porém como esta também apresentou valores baixos, não pode compensar a diferença dos valores da média, tornando o resultado inexpressivo.

Por outro lado, as figuras GN_VI, GIN_V e MAC_V apresentaram os melhores resultados, sendo que no último chegando a 99,33% de desempenho. Conforme o previsto anteriormente, na zona de transição entre uma classe e outra provocou alguns erros nos

resultados gerados pela rede neural, fazendo com que o seu desempenho apresentasse valores mais baixos. Se isso fosse desconsiderado as imagens GN_I, GN_II, GN_III, GN_IV, GN_V, GIN_V e GIN_VI apresentariam um desempenho ainda melhor.

Para comprovarmos a eficiência do uso das RNA's utilizamos os métodos tradicionais realizados em laboratório para a avaliação das imagens digitais. Através de análise pelo processamento da imagem (detecção de bordas) e por análise granulométrica podemos comparar os resultados obtidos.

Pelos resultados encontrados através das metodologias descritas vimos que as figuras GN_V e GIN_I apresentam uma distribuição de grãos com pouca gradação, o que justificaria os

baixos desempenhos atribuídos pela rede neural, para essas imagens. Porém, foi constatado que a figura GIN_VI realmente possuía gradação inversa, bem como a figura MAC_VI, a qual era gradação maciça. Nestes dois casos as redes não obtiveram êxito na identificação dos padrões propostos. Essas divergências entre os resultados podem ser explicadas pela metodologia adotada no tratamento das imagens, que buscou ser o mais simples possível para obter resultados rápidos, nesse caso, a falta de iluminação padrão na hora da realização das imagens digitais, bem como a diferenças na umidade dos depósitos (alteram o valor do pixel) são explicações para tais diferenças.

CONSIDERAÇÕES FINAIS

Com este trabalho podemos concluir que a utilização das RNA's como ferramenta alternativa e não invasiva para identificar padrões de deposição gerados em laboratório foi considerada satisfatória, pois o desempenho de acerto atingindo, em alguns casos, foi maior de 90%.

Cabe salientar que nesse tipo de análise, devido à metodologia simplificada utilizada, os resultados não devem se basear apenas no percentual de desempenho e sim, na análise do gráfico de saída gerado, pois esses indicam a tendência que o depósito possui.

Considerando, que a imagem digital utilizada como dado de entrada para a rede neural não sofreu nenhum tipo de tratamento prévio, como aplicações de filtros, transformadas matemáticas, e que as imagens coletadas não eram padronizadas na hora de seu registro, ou seja, possuíam diferenças na posição, ângulo de incidência da câmera, e principalmente de iluminação demonstram que a Rede Neural Artificial utilizada apresentou uma grande *performance* em se ajustar, aprender e generalizar o padrão treinado.

A metodologia clássica para o reconhecimento de padrões se caracteriza por trabalhar com uma matriz de entrada com dimensões únicas (sempre de mesmo tamanho). Na metodologia empregada neste trabalho, buscou-se a solução alternativa de não restringir a matriz, trabalhando com as dimensões

abertas, ou seja, as imagens podem ter tamanhos diferentes (alturas diferentes), desde que sejam respeitadas as limitações dos aplicativos utilizados no processo.

A metodologia desenvolvida neste trabalho, nesse primeiro momento, apesar de simples e rápida apresentou resultados muito coerentes com os métodos habitualmente utilizados para esse tipo de caracterização, no caso, análise granulométrica e imagens de depósito. A utilização das premissas, parâmetros e aplicativos, validam a utilização dos sistemas inteligentes para esse tipo de análise. Num segundo momento, esses processos poderão ser aperfeiçoados, com a distinção de mais classes granulométricas nos depósitos, bem como novas estruturas e parâmetros podem ser testados para aumentar ainda mais a eficiência e extrapolação deste processo.

Na prática, além do uso em laboratórios, essa metodologia pode ser empregada no campo, com a caracterização de fácies turbidíticas em depósitos naturais (p. ex. afloramentos), pois atualmente a utilização de imagens é um dos métodos utilizados para tal classificação. Ainda, devido à liberdade na altura (espessura) da amostra, esse método pode auxiliar na interpretação de resultados de aplicações específicas, como a avaliação de tamanho ou arranjo dos grãos em testemunhos de sondagem de depósitos sedimentares, uma

vez que as, nessas situações, as estruturas verticais e mudanças de comportamento são realizadas ao longo da vertical, despertando,

também o interesse da indústria, bem como da academia.

AGRADECIMENTOS

O autor agradece ao Prof. Olavo Pedrollo pela disponibilização do programa SIRENE® e ao geol. Marcelo Ávila, pela disponibilidade das imagens dos depósitos.

REFERÊNCIAS

1. AMY, L. A., TALLING, P. J., EDMONDS, V. O., SUMNER, E. J., LESEUR, A. An experimental investigation on sand-mud suspension settling behaviour and implications for bimodal mud content of submarine flow deposits. *Sedimentology*, v. 53, p.1411-1434., 2006
2. ÁVILA, M. D., DUCKER, R. E. E CORREA, I. S. Modelagem física de correntes de densidade não conservativas: um método para interpretação e avaliação de depósitos turbidíficos. in XLI CONGRESSO BRASILEIRO DE GEOLOGIA, 2002, João Pessoa.
3. ÁVILA, M. D., GIACOMEL, R. S. DUCKER, R. E., MAESTRI, R. D., BORGES, A. L. O. Study of the formation mechanism of inverse grading in turbidity currents. in AAPG ANNUAL MEETING, 2003, Salt Lake City.
4. BAAS, J.H., KESTEREN, W.V., POSTMA, G. Deposits of depletive high-density turbidity currents: a flume analogue of bed geometry, structure and texture. *Sedimentology*, v. 51 p.1053-1088., 2004
5. CAMPOS, T. J. 2001. Reconhecimento de caracteres alfanuméricos de placas em imagens de veículos. 2001, 186p. Dissertação de mestrado, Instituto de Informática, Universidade Federal do Rio Grande do Sul.
6. BOUMA, A. H. Sedimentology of some flysch deposits: a graphic approach to facies interpretation. Amsterdam: Elsevier; 168p, 1962.
7. DAHMER, A. Segmentação de imagens ecocardiográficas utilizando redes neurais e medidas de textura. 2000, 123p. Dissertação de mestrado, Instituto de Informática, Universidade Federal do Rio Grande do Sul
8. GOES, E. A., ROGRIGUES, J. F., SILVA, I. N. Uma abordagem baseada em redes neurais artificiais para identificação de trechos submetidos a curto-circuitos em sistemas de distribuição in XVI SNPTTE, 2001, Campinas.
9. KNELLER, B. & BUCKEE, C. The structure and fluid mechanics of turbidity currents: a review of some recent studies and their geological implications. *Sedimentology*, v. 47 p.62-94., 2000.
10. KUENEN, P. H. & MIGLIORINI, C. I. Turbidity currents as a cause of graded bedding *Journal of Geology*, v. 58, p.91-127, 1950.
11. HAND, B. M. Inverse grading resulting from coarse-sediment transport lag. *Journal of Sedimentary Research*, v. 67, p.124-129, 1997.
12. HISCOTT, R. N. Traction carpet stratification in turbidites - fact or fiction *Journal of Sedimentary Research*, v. 64, p.204-208, 1994.
13. MANICA, R. Sediment Gravity Flows: Study Based on Experimental Simulations. In H. E. SCHULZ, A. L. A. SIMÕES, R. J. LOBOSCO (Eds.) *Hydrodynamics - Natural Water Bodies*, ISBN: 978-953-307-893-9, InTech, p. 263-286, 2012.
14. MIDDLETON, G.V. Experiments on density and turbidity currents III. Deposition of sediment. . *Canadian Journal of Earth Sciences*, v. 4, p. 475-505, 1967.
15. MIDDLETON, G. V. Experimental studies related to problems of flysch sedimentation. In: *Flysch Sedimentology in North America*. Lajoie. p. 253-272, 1970.
16. – SIRENE® - Sistemas de Redes Neurais. Criador: Prof. Olavo Pedrollo – IPH/UFRGS. Versão 1.0, 2004.
17. POSTMA, G., NEMEC, W., KLEINSPEHN, K.L. 1988 Large floating clasts in turbidites: a mechanism for their emplacement. *Sedimentary Geology*, v. 58, p.47-61, 1988.

*Manuscrito recebido em: 16 de Outubro de 2012
Revisado e Aceito em: 24 de Abril de 2013*