

# DETERMINAÇÃO DA VELOCIDADE DE EMPILHAMENTO UTILIZANDO REDES NEURAS

## STACKING VELOCITY DETERMINATION VIA NEURAL NETWORKS

Jurandyr Schmidt<sup>1</sup>

**RESUMO** - O estado-da-arte do processamento sísmico requer procedimento tedioso e expensivo para interpretação do espectro de velocidade. Normalmente, essa interpretação é feita interativamente em estações de trabalho. Mesmo assim, como a sismologia de petróleo caminha de um mundo de duas dimensões para o de três, a interpretação manual do espectro de velocidade torna-se o maior gargalo no fluxo do processamento sísmico, desde o dado de campo até a seção empilhada. Mostra-se um procedimento automático para a interpretação do espectro de velocidade utilizando redes neurais. Três ou quatro redes neurais independentes são empregadas: uma para o *picking* dos tempos significantes, uma para o *picking* da velocidade de empilhamento nos tempos encontrados pela primeira rede, e uma ou duas redes para a confirmação dos *picks* selecionados pelas duas primeiras redes neurais. Em adição aos dados sísmicos, as redes neurais requerem uma função velocidade inicial. O resultado é um procedimento automático para o *picking* da análise de velocidade. Testes em dados sintéticos e reais indicam que o método poderá solucionar o problema da quebra de fluxo na seqüência do processamento sísmico já mencionado, isto é, permitirá que os dados de campo fluam das fitas de campo à seção final automaticamente.

(Originais recebidos em 05.02.93).

**ABSTRACT** - State of the art of petroleum seismology data processing requires tedious and expensive interpretation of velocity spectrum. Usually this interpretation is performed in an interactive way on workstations. Even so, as petroleum seismology goes from a world of two-dimensional data to a world where three-dimensional data are a common place, the manual interpretation of velocity spectrum becomes a major bottleneck in the overall process of progressing from raw data to a stacked section. This paper shows an automated approach to the interpretation of velocity spectra via synthetic neural networks. Three or four independent neural networks are employed: one for picking significant times, another for picking stacking velocity at the significant times found by the first time network, and one or two networks for the validation of picks selected by the first two networks. The networks need an initial velocity function in addition to the seismic data. A fast automatic procedure for stacking velocity picking is the consequence. Rather comprehensive tests on synthetic and real data indicate that this method will probably clear the above mentioned bottleneck.

(Expanded abstract available at the end of the paper).

### 1 - INTRODUÇÃO

A determinação da velocidade de empilhamento tem historicamente envolvido a intuição dos geofísicos. Com o aumento da quantidade dos dados e a grande variação na experiência dos intérpretes, é desejado se fazer parte dessa interpretação (de velocidade) automaticamente.

A automação do *picking* de velocidade de empilhamento tem sido assunto de investigação desde o início dos anos 70. Especialmente valiosos, entre outros, são os trabalhos de Beitzel e Davis (1974), Cunningham e Heffring (1980) e Toldi (1989). Beitzel e Davis defendem uma

técnica gráfico-teórica para simular as decisões complexas inerentes ao intérprete. Cunningham e Heffring advogam o uso da função do *move-out* e da observação que esta função pode ser aproximada por uma linha reta segmentada quando apresentada em logaritmo *versus* tempo. Toldi propõe uma nova técnica para análise de velocidade, também baseada na velocidade de empilhamento. Nesse novo método, é eliminada a necessidade do *picking* convencional porque a velocidade de empilhamento é considerada sempre do ponto de vista de um modelo de velocidades intervalares.

Rede neural é um sistema não-linear, o qual transforma um vetor de entrada de m-dimensões em um vetor de saída

1- E & P/GEREX/GEPROG/GEGEF, Av. República do Chile, 65, Centro, CEP 20035-900, Rio de Janeiro, RJ, Brasil.

de n-dimensões. Os nós da camada de entrada são conectados aos da camada de saída, via conexões, cuja transmissividade, ou pesos, é determinada durante uma fase de treinamento da rede. Uma técnica que usa o gradiente descendente, chamada *backpropagation*, é utilizada nesta fase de treinamento. As derivações do algoritmo *backpropagation* são cobertas em Rumelhart e McClelland (1986).

Entre os nós da camada de entrada e os da camada de saída, a rede neural pode ter camadas intermediárias, o que melhora sua versatilidade.

Redes neurais sintéticas são uma nova tecnologia que está começando a encontrar aplicação na geofísica. Poucos artigos podem ser encontrados sobre o assunto, sendo os mais valiosos, entre outros, os citados nos próximos dois parágrafos.

Fora do campo da sísmica, têm-se os trabalhos de Williams (1991), o qual aplicou as redes neurais para análise espectral de reflexões eletromagnéticas. Em 1991, McCormack usou as redes neurais para a identificação de litologias a partir da perfilagem de poço. Taylor *et al.* (1990) advogam o uso das redes neurais como método para complementação à inversão convencional de dados gravimétricos.

Em exploração sísmica, Huang *et al.* (1990) usaram redes neurais para o rastreamento de horizontes sísmicos. McCormack (1990) usou as redes neurais para o *picking* das primeiras quebras e edição de traços sísmicos. Wagner *et al.* (1990) também usaram a tecnologia para *picking* da primeira quebra.

## 2 - REDE NEURAL

Rede neural é uma tecnologia nova que tem tido crescimento explosivo na última década. Muitos livros são encontrados cobrindo a matéria, variando desde um ponto de vista introdutório, como Wasserman (1989), até um ponto de vista mais aprofundado, como Rumelhart e McClelland (1986). Uma seleção de artigos é encontrada em Shavlik e Dietterich (1992) e essas referências fornecem um bom embasamento sobre o assunto.

Uma característica importante das redes neurais é que elas não são programadas; são treinadas por meio de exemplos. Tipicamente, um conjunto de exemplos definidos como corretos por um especialista é introduzido à rede neural para treinamento da mesma. Esses exemplos, conhecidos como padrões de treinamento, são representados como vetores e podem ser obtidos de uma variedade de fontes, tais como imagens, sinal de voz, dados de sensoriamento, informações de diagnóstico, etc. O procedimento mais comum de treinamento utiliza o treinamento supervisionado, durante o qual é introduzido na rede um padrão junto com a saída desejada para aquele padrão. Esta saída constitui a resposta correta ou classificação correta para o padrão em questão. Em resposta aos pares de exemplos (padrão de entrada/saída desejada), a rede neural ajusta os valores dos seus pesos internos. Se o treinamento da rede for bem

sucedido, os parâmetros internos serão então ajustados ao ponto de a rede neural produzir as respostas corretas em resposta a cada padrão de entrada. Comumente, os padrões de entrada são apresentados muitas vezes durante a fase de treinamento para possibilitar que a rede neural ajuste seus parâmetros internos gradualmente.

### 2.1 - Unidade de Processamento

Apesar da diversidade de redes neurais, quase todas são baseadas no modelo dos neurônios biológicos ou aproximação deles. A unidade de computação que compõe a maioria dos sistemas de neurônios artificiais é conhecida como nós, unidade de processamento ou elemento de processamento. Em essência, um conjunto de dados é aplicado à unidade, cada um representando a saída de outro neurônio. Cada entrada é multiplicada por um peso correspondente, e todas as entradas, após a multiplicação pelos respectivos pesos, são somadas para determinar o nível de ativação do neurônio (elemento de processamento)

Na figura 1, mostra-se esquematicamente uma unidade de processamento. Aqui, um padrão de entrada denominado  $x_1, x_2, x_3, \dots, x_n$  é aplicado a uma unidade de processamento. Cada elemento do padrão de entrada é então multiplicado por um peso associado  $w_1, w_2, w_3, \dots, w_n$ , antes de ser submetido à somatória, representada por  $\Sigma$ . As entradas são referidas como vetor  $\mathbf{X}$  e, os pesos, como o vetor  $\mathbf{W}$ .

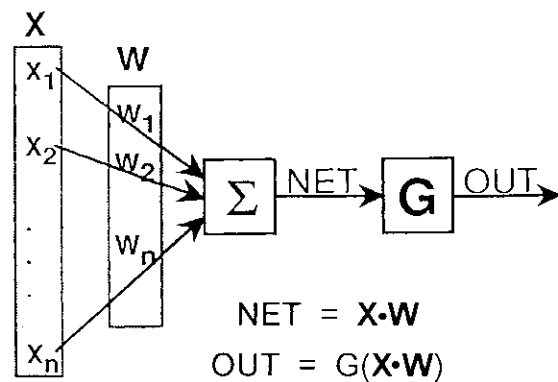


Fig. 1 - Unidade de processamento artificial ou neurônio artificial com função de ativação. A unidade de processamento produz uma saída NET, a qual é submetida a uma função de ativação G para produzir uma saída OUT.

Fig. 1 - Artificial neuron or artificial processing unit with activation function. The processing unit yields an output NET which is submitted to an activation function G to produce the output OUT.

A somatória adiciona todas as entradas ponderadas algebricamente, produzindo a saída escalar NET. Em notação vetorial, tem-se:

$$\text{NET} = \mathbf{X} \cdot \mathbf{W} \quad (1)$$

O sinal NET é posteriormente processado por uma função não-linear G, denominada função de ativação, função de ganho, função de transferência ou função de compressão, para produzir o sinal OUT (fig. 1). Então, a saída da unidade de processamento pode ser expressa por:

$$\text{OUT} = G(\text{NET}) = G(X \cdot W) = G(\sum_i w_i x_i) \quad (2)$$

Se, por exemplo, a função de ativação comprime os valores de NET tal que OUT nunca exceda certos limites independentemente do valor NET, G é chamada de função de compressão.

## 2.2 - Estrutura da Rede Neural

Freeman e Skapura (1991) definem a estrutura da rede neural como uma coleção de processadores paralelos conectados na forma de um gráfico direto.

Na figura 2, mostra-se o diagrama de uma rede neural com três camadas, onde cada unidade de processamento é representada por um círculo cheio, com as conexões entre as unidades indicadas por linhas e a direção de fluxo das informações por setas nas conexões.




Fig. 2 - Arquitetura de uma rede neural de três camadas mostrando as notações para as unidades, para os pesos e para o fluxo da informação. A unidade de processamento é representada por um nó (círculo cheio).

Fig. 2 - A three layer feed-forward network architecture, showing the notation for the units, the weights, and the information flow. The processing unit is represented by a node (solid circle). In this notation, the units in the input layer do not process.

## 2.3 - Rede Backpropagation

A rede *backpropagation* (fig. 2) é designada para operar como uma rede multicamada *feedforward* usando o treinamento supervisionado. A rede é treinada com um

conjunto predefinido de pares entrada-saída. Após um padrão de entrada ter sido submetido como estímulo à camada de entrada, ele é propagado por cada camada subsequente até uma saída ser gerada. O padrão de saída é, então, comparado à saída desejada, e um erro é computado para cada unidade de processamento da camada de saída. Os erros são transmitidos de volta (*backward*) da camada de saída para cada nó da camada intermediária que contribuiu diretamente para a saída. Entretanto, cada unidade na camada intermediária recebe somente uma parte do erro total, baseado na contribuição relativa que a unidade teve na saída. O processo é repetido, camada por camada, até que cada nó da rede tenha recebido um erro que descreva sua contribuição relativa no erro total. Baseado no erro recebido, os pesos nas conexões são, então, atualizados para cada unidade. O processo é repetido até causar a convergência da rede a um estado que permita que todos os padrões de treinamento sejam codificados.

Após o treinamento, a rede responderá com saídas distintas se o dado de entrada à rede contiver um padrão que lembre qualquer dos padrões de treinamento.

## 3 - METODOLOGIA

O espectro de velocidade derivado a partir da análise de velocidade (AV) pode ser representado por um arranjo bidimensional com linhas, correspondendo a tempo duplo de trânsito na vertical ( $t_o$ ), e colunas, correspondendo a velocidades de empilhamento propostas ( $v$ ). A variável dependente nessa função é alguma medida do alinhamento de hipérbolas e eventos que aparecem no dado de campo. Assim, é possível representar o produto da AV, isto é, o espectro de velocidade, como:  $a(t_o, v)$ .

Para interpretar o espectro de velocidade, é necessário se ter uma idéia razoável da função velocidade de empilhamento. Essa função velocidade inicial é denominada de função velocidade de referência, e é representada por  $v_r(t_o)$ . Redes neurais não são empregadas para determinar a velocidade de referência inicial.

O método proposto envolve três estágios. O primeiro é denominado *picking* do tempo, o segundo *picking* da velocidade, e o terceiro confirmação da velocidade.

### 3.1 - Picking do Tempo

Um traço de energia é uma função do tempo de trânsito vertical, o qual é definido por:

$$e(t_o) = \int_R a(t_o, v) dv \quad (3)$$

Sendo R a variação das velocidades de empilhamento propostas. Assim, os máximos locais do traço de energia correspondem aos melhores tempos onde se procura pelas velocidades de empilhamento. Essas velocidades

correspondem a máximos locais nos traços de velocidades, considerando que o dado sísmico em análise não seja contaminado por ruídos (múltiplas e difrações). Uma representação esquemática dos traços de energia e de velocidade é mostrada na figura 3.

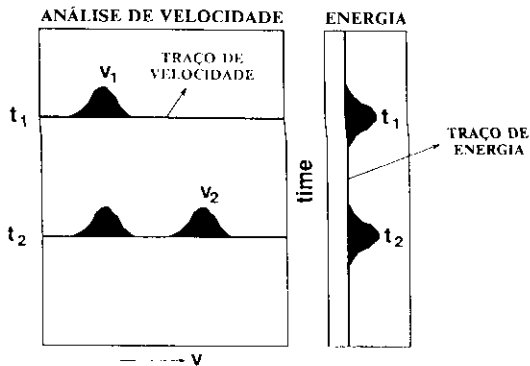


Fig. 3 - Representação esquemática do espectro de velocidade e do traço de energia. O traço de energia é referido como traço do tempo, e, os traços no espectro, como traço de velocidade

Fig. 3 - Schematic representation of the velocity spectrum and the energy trace. The energy is referred to as the time trace, and the traces in the spectrum as the velocity traces.

A rede neural, que define os tempos propícios para a determinação da velocidade, é designada para localizar somente os picos na curva de energia. Observando o traço de energia do dado real mostrado na figura 4, pode-se notar que existem basicamente duas formas ou padrões que compõem a curva de energia: o sinal "maior do que" (>) e o seu oposto, o "menor do que" (<).




Fig. 4 - Traço de energia de dado real (linha sólida) e picos determinados pela rede neural (asteriscos). A posição dos asteriscos (amplitude) indica o nível de saída da rede neural. Note que é possível selecionar somente os picos de maior amplitude relativa (curva sólida), ajustando-se o nível de aceitação da rede neural.

Fig. 4 - Energy trace of real data (solid line) and neural network picks (asterisks). The asterisk position (amplitude) indicates the neural network output level. Notice that it is possible to select only the higher relative amplitude values (solid curve) by adjusting the neural network output.

Assim, o treinamento da rede neural com as curvas mostradas na figura 5 (a,b) são suficientes para se

detectarem os máximos locais no traço de energia. A rede neural para determinação dos tempos nos traços de energia, referida como RNT, tem uma camada intermediária com cinco nós, cinco nós na camada de entrada e um nó na camada de saída.

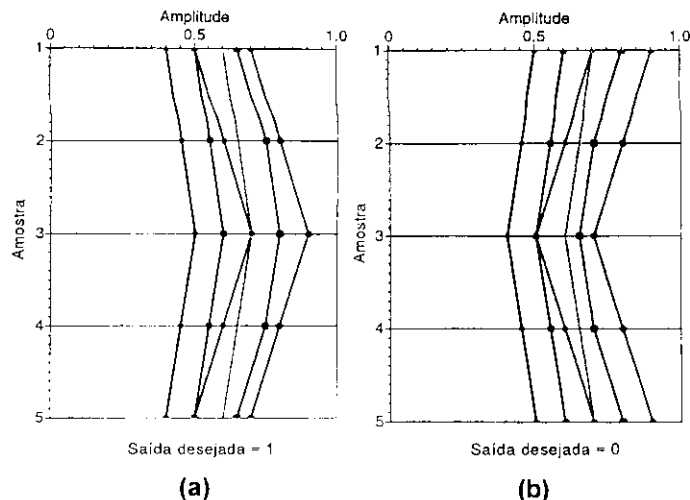


Fig. 5 - Padrões para treinamento das redes neurais usadas para o picking do traço de energia e do traço de velocidade. a) Para esses padrões, a saída desejada da rede neural é de 1; b) para esses padrões, a saída desejada da rede neural é de 0.

Fig. 5 - Patterns for training the neural networks for energy and velocity trace picking. a) For these patterns the wanted neural network output is 1; b) for these patterns the wanted neural network output is 0.

O tempo necessário para treinar a rede neural é insignificante da ordem de segundos. Após o treinamento, os traços de energia são submetidos à camada de entrada da rede neural, movendo para a frente uma amostra para cada saída da RNT. Na figura 4, mostra-se o traço de energia de um dado real com os valores de saída da RNT (asteriscos) acima de um determinado valor. Observe que os asteriscos relativos aos maiores valores correspondem aos máximos locais de maiores amplitudes relativas. Assim, é possível selecionar os máximos locais com determinada amplitude relativa escolhendo-se os valores de saída de RNT.

### 3.2 - Picking da Velocidade

A saída da RNT define os tempos nos quais os traços de velocidade, aqui representados por  $a(t_p, v)$ , serão examinados pela próxima rede neural, denominada RNV, para rede neural de velocidade. A RNV determina os máximos locais nos traços de velocidade. Na função  $a(t_p, v)$ ,  $t_p$  corresponde ao tempo determinado por RNT naturalmente.

Como pode ser observado no traço de velocidade (fig. 6), as formas que compõem a curva de velocidade são idênticas às do traço de energia, isto é, as formas "maior do que" (>)

e "menor do que"(<). Assim, RNV é idêntica à RNT em arquitetura e treinamento. Conforme mostrado na figura 6 (asteriscos), oito velocidades de empilhamento foram selecionadas para um tempo vertical. O problema é que existe mais de uma velocidade para um único tempo. Qual seria a velocidade correta?




Fig. 6 - Traço de velocidade de um dado real (linha sólida) e picos determinados pela rede neural (asteriscos). Note que oito velocidades foram selecionadas para um único tempo no traço de energia.

Fig. 6 - Velocity trace of real data (solid line) and neural network picks (asterisks). Notice that eight velocities were selected by the neural net for one normal incidence travel time chosen in the energy trace.

### 3.3 - Confirmação da Velocidade

As redes neurais (duas), para confirmação da velocidade (RNCs), é designada a tarefa de determinar se a função velocidade, dita como função velocidade candidata à referência  $v_c(t_0)$ , é consistente com a atual função velocidade de referência  $v_r(t_0)$ . Se tal consistência é encontrada, então a função velocidade candidata  $v_c(t_0)$  é utilizada como a nova função velocidade de referência  $v_r(t_0)$ . A premissa é que a distribuição da função velocidade de empilhamento é especialmente contínua e monótona, e que grandes saltos não ocorrem na sua distribuição. Essa afirmativa tem como base o fato de que grandes saltos na distribuição da velocidade de empilhamento ou na velocidade rms ( $V_{rms}$ ) resultam em velocidades intervalares fisicamente não-realísticas.

As RNCs são idênticas em arquitetura. Elas têm uma camada intermediária e a camada de entrada tem tantos nós quantas são as amostras na direção do tempo no espectro de velocidade. No caso do dado real em questão, o

número de nós da camada de entrada foi 150. Para esse exemplo, a camada intermediária teve 100 nós. Novamente, a camada de saída teve um nó. O tempo de treinamento das RNCs são bastante curtos, cerca de 0,5 s de cpu, em uma RISC/6000, com a convergência sendo alcançada em 300 iterações. Os dados para treinamento das RNCs referidas como RNC1 e RNC2 consistem de (fig. 7) :

- função velocidade de referência  $v_r(t_0)$  com saída desejada igual a 1 (RNC1 e RNC2);
- função velocidade-limite inferior  $v_l(t_0)$  com saída desejada igual a 0 (RNC1);
- função velocidade-limite superior  $v_s(t_0)$  com 0 como saída desejada (RNC2).

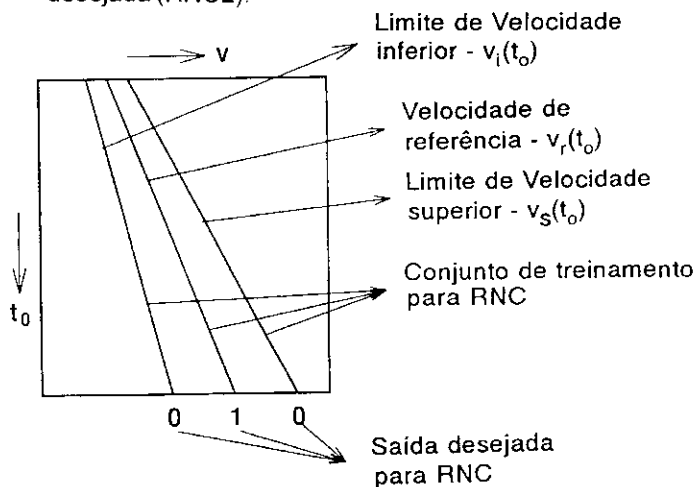


Fig. 7 - Representação esquemática do espectro de velocidade com as curvas utilizadas no treinamento da rede neural (RNC) utilizada na confirmação da velocidade.

Fig. 7 - Schematic representation of the velocity spectrum with the RNC training set.

Esses dados para o treinamento das RNCs foram escolhidos para forçar a saída das RNCs a ter uma distribuição normal, quando tratados em conjunto (fig. 8), quando as  $v_c(t_0)$ s estão no intervalo dos limites de velocidades, isto é,  $v_l(t_0, 0)$  e  $v_s(t_0, 0)$ .

Dado um novo espectro de velocidade,  $a(t_0, v)$  e uma multidão de pontos determinados por RNV, os picos mais próximos, dentro de uma janela especificada, à atual função velocidade de referência  $v_r(t_0)$ , são selecionados para a construção via interpolação e suavização utilizando média móvel de uma função velocidade candidata à referência ( $v_c(t_0)$ ).

As RNCs são, então, empregadas para determinar

se  $v_c(t_0)$  difere de  $v_r(t_0)$ . Há dois níveis de diferença, a saber, nível 1 e nível 2, e são empregados como definido a seguir:

- RNCout > nível 1 → a diferença é insignificante e, assim, o processo continua usando o mesmo  $v_r(t_0)$ ;

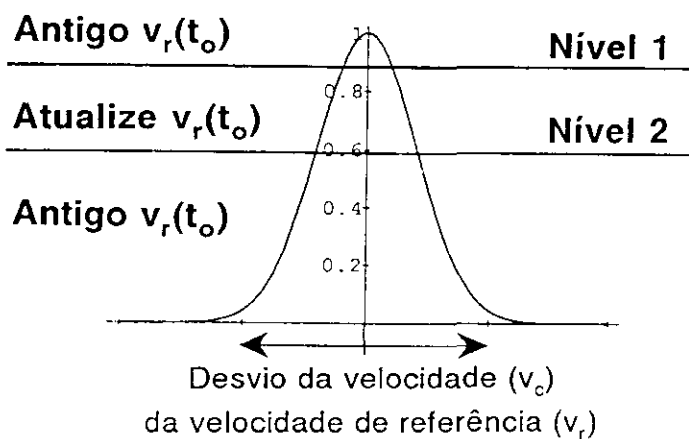


Fig. 8 - Representação esquemática da curva de distribuição normal formada pela resposta de RNC quando suas entradas estão entre os limites de velocidades. São mostrados, também, os dois níveis de diferença usados no estágio da confirmação da velocidade.

Fig. 8 - Schematic representation of the bell-shaped RNC response curve when its inputs are in the interval of the velocity boundaries. Two levels of displacement used in the velocity validation technique are also shown.

- nível 2 < RNCout < nível 1 → a diferença é grande o bastante para ser considerada significativa, mas não tão grande para ser considerada geologicamente suspeita. A função velocidade candidata à referência  $v_c(t_0)$  é utilizada, então, como a nova velocidade de referência  $v_r(t_0)$ . O processo continua usando o novo  $v_r(t_0)$ ;
- RNCout < nível 2 → o espectro de velocidade é descartado. A mudança é considerada muito grande para ser geologicamente razoável. É o caso de espectros de velocidade de má qualidade.

RNCout corresponde a qualquer saída das RNCs. Uma nova função velocidade de referência requer novos limites de velocidades e, então, as RNCs devem ser retreinadas. Esse retreinamento é uma atualização dos pesos anteriores porque os mesmos são utilizados como estado inicial da rede neural.

A escolha do nível 1 não é crítica. Um bom valor é o *threshold* utilizado como condição de parada no treinamento das RNCs ou algum valor um pouco inferior. Isso assegura a mudança da função velocidade de referência para variações maiores que o erro aceito no treinamento da rede neural. A escolha do nível 2 é crítica desde que ele evita a aceitação de funções velocidades suspeitas como função velocidade de referência, o que não é desejado. Funções velocidades suspeitas podem ser resultado de dados ruidosos, ou espectros de velocidade de má qualidade, por exemplo, resultado de zonas de falhas, ou em situação onde  $v_c(t_0)$  é distante de  $v_r(t_0)$  a ponto de ser considerada

geologicamente suspeita. Em tais situações, é razoável não trocar a função velocidade de referência  $v_r(t_0)$ . Visto que, como premissa, a distribuição espacial da velocidade de empilhamento é contínua e suave, a escolha do nível 2 previne contra grandes variações na distribuição da função velocidade de empilhamento e fornece uma maneira de se evitar e passar por perturbações locais. Uma maneira de se escolher o valor para o nível 2 é testar algumas funções velocidades, como se fossem velocidades candidatas à referência, no intervalo entre as velocidades-limites  $v_l(t_0)$  e  $v_s(t_0)$ , para se ter uma idéia da resposta característica das redes neurais.

Um dos inconvenientes do processo já descrito é o retreinamento em tempo real das RNCs. Uma maneira de se evitar o retreinamento em tempo real das redes neurais, na etapa da confirmação da velocidade, é obtida com o pré-processamento dos dados de entrada. O pré-processamento dos dados a serem submetidos à rede neural é um fator muitas vezes decisivo na *performance* e eficiência da rede. Aqui, o pré-processamento consiste em se transformar as funções velocidades utilizadas no treinamento da rede, as quais são  $v_r(t_0)$ ,  $v_l(t_0)$  e  $v_s(t_0)$ . Essa transformação é feita computando-se os valores absolutos da diferença entre as três funções velocidades citadas com  $v_r(t_0)$ . A saber:

$$\begin{aligned} 0(t_0) &= \text{abs} \{ v_r(t_0) - v_r(t_0) \} \\ b_1(t_0) &= \text{abs} \{ v_l(t_0) - v_r(t_0) \} \\ b_2(t_0) &= \text{abs} \{ v_s(t_0) - v_r(t_0) \} \end{aligned} \quad (4)$$

Se, por construção,  $v_l(t_0)$  e  $v_s(t_0)$  forem equidistantes de  $v_r(t_0)$ , então  $b_1(t_0) = b_2(t_0) = b(t_0)$ .

Nesse caso, os dados para treinamento da RNC (uma) consiste do:

- vetor  $0(t_0)$  com saída desejada 1;
- vetor  $b(t_0)$ , com saída desejada 0.

Nesse caso, a entrada dos dados para RNC é o valor absoluto da diferença de  $v_r(t_0) - v_c(t_0) = d(t_0)$  em lugar de  $v_c(t_0)$ .

#### 4 - RESULTADO

Na figura 9, mostra-se o *picking* feito por RNT e RNV nos traços de energia e de velocidades para um CMP do modelo físico. As funções velocidades para o treinamento das RNCs, no caso de se usarem duas redes no estágio de confirmação da função velocidade, são mostradas na figura 10. Na figura 11, apresenta-se o mesmo dado após pré-processamento, em cujo caso somente uma RNC é utilizada. A função velocidade de empilhamento definida pelo método

automático, para o CMP-500, mostra-se na figura 12. Na figura 13, tem-se a saída da RNC e, na figura 14, a seção estaqueada resultante do uso do método em questão.

Observe os baixos valores da saída de RNC nos locais onde a qualidade dos dados é pobre (figs. 13 e 14). Nesse caso, foram analisados CMPs a intervalos de 10.

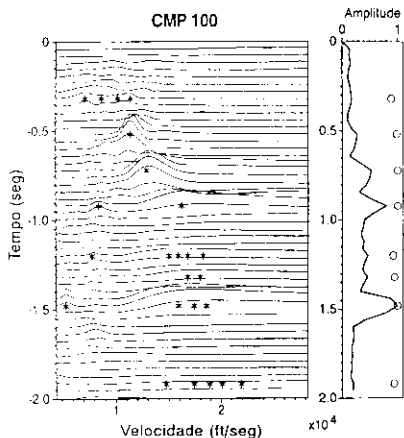


Fig. 9 - Espectro de velocidade e traço de energia dos dados de um modelo físico, com os picos das redes neurais. O traço de energia (linha sólida) e os tempos selecionados (círculos) são mostrados à direita. O espectro de velocidade e as velocidades selecionadas (asteriscos) aparecem à esquerda. Observe que, em certos casos, mais de uma velocidade foi selecionada para um único tempo.

Fig. 9 - Velocity spectrum and energy trace for a physical model data set with the neural network picks. The energy trace (solid line) and the time picks (circles) are shown on the right. The chosen velocity spectrum and velocity picks (asterisks) are shown on the left. Notice that for some situations, more than one velocity was selected (asterisks) to couple with one sole time (circles).




Fig. 10 - Espectro de velocidade dos dados do modelo físico mostrando as curvas para o treinamento da RNC.

Fig. 10 - Velocity spectrum of the physical model data showing the RNC training set.




Fig. 11 - Representação esquemática do espectro de velocidade com as curvas de treinamento da RNC após transformação. As curvas transformadas  $o(t_0)$  e  $b(t_0)$  correspondem às curvas originais mostradas na figura 10.

Fig. 11 - Schematic representation of the velocity spectrum with the preprocessed RNC training set. The curves  $o(t_0)$  and  $b(t_0)$  are the training set curves shown on figure 10 after transformation.




Fig. 12 - Resposta da rede neural (asteriscos) e velocidade de empilhamento resultante (linha sólida) para o CMP-500 do dado do modelo físico. A velocidade de referência inicial foi no CMP-100.

Fig. 12 - Neural net picks (asterisks) and the resulting interpolated stacking velocity function (solid line) for CMP-500 of the physical model data. The initial reference velocity function was at CMP-100.




Fig. 13 - Resposta da RNC usada no teste, que define se a velocidade de referência deve ser mudada ou não. A RNC foi treinada com dados pré-processados.

Fig. 13 - Response of RNC to test if the reference velocity function should be changed. A transformed training set was used.





Fig. 14 - Seção empilhada resultante do uso das velocidades de empilhamento derivadas, usando o método automático das redes neurais. A velocidade inicial de referência foi no CMP-100. A RNC foi treinada com dados pré-processados.

Fig. 14 - Stacked section resulting from derived stacking velocities using the neural net stacking velocity picking procedure. The initial reference velocity function was at CMP-100. A transformed training set was used.

A disposição das duas linhas sísmicas com dados reais processados é mostrada esquematicamente na figura 15. Na figura 16, mostram-se as funções velocidades usadas para o treinamento das RNCs no CMP-450 da linha 1. No caso do dado real, não foi utilizada a rede RNT para o picking do traço de energia devido à grande intensidade da amplitude das múltiplas (fig. 16). Assim sendo, todos os traços de velocidade foram analisados.



Escala: 100 CMP=1.33 Km

Fig. 15 - Representação esquemática de duas linhas sísmicas (dado real) processada usando-se o método das redes neurais para determinação da velocidade de empilhamento. O ponto inicial foi o CMP-450 da linha 1, onde a velocidade de referência inicial requerida pelo método foi manualmente interpretada.

Fig. 15 - Layout of the two seismic lines of real data processed using the neural network stacking velocity picking procedure. The starting point was at CMP-450 of line 1, where the required reference velocity was picked by hand.




Fig. 16 - Espectro de velocidade do CMP-450 da linha 1, com as curvas de treinamento para RNC.

Fig. 16 - Velocity spectrum of CMP-450 of line 1, with the velocity validation neural network (RNC) training set.

Na figura 17, são apresentados o espectro de velocidade do CMP-150, da linha 1, com os picks, e a função



velocidade resultante da utilização do método descrito. A seção estaqueada da linha 1 é mostrada na figura 18.

A linha 2 foi processada tendo-se como função velocidade de referência inicial a função velocidade da linha 1, no CMP-540, que é o ponto de cruzamento com a linha 2. Assim sendo, a linha 2 teve o processamento todo automático. Na figura 19, tem-se a função velocidade determinada para o CMP-550 da linha 2. Já a seção empilhada é mostrada na figura 20. Observe que, na análise de velocidade da linha 2, foram selecionados menos pontos que na da linha 1 (figs. 17 e 19). Isso é resultado do ajuste dos *thresholds* utilizados na RNV.




Fig. 17 - Espectro de velocidade do CMP-150 da linha 1, com as velocidades de empilhamento (linha sólida) obtidas pela interpolação das velocidades (pontos cinzas) selecionadas pela rede neural. Duas RNCs foram usadas nesse exemplo.

Fig. 17 - Velocity spectrum of real data, CMP-150 of line 1, with the stacking velocity function (heavy solid line) obtained by the interpolation of the neural network picks (gray dots). In this case, two RNCs were used.




Fig.18 - Seção sísmica da linha 1 processada usando as redes neurais para determinação das velocidades de empilhamento.

Fig. 18 - Seismic section, line 1, processed using the neural network velocity picking technique.




Fig. 19 - Espectro de velocidade do CMP-550 da linha 2, com as velocidades de empilhamento (linha sólida) obtidas pela interpolação das velocidades (pontos cinzas) selecionadas pela rede neural. Duas RNCs foram usadas nesse caso.

Fig. 19 - Velocity spectrum of real data, CMP-550 of line 2, with the stacking velocity function (heavy solid line) obtained by the interpolation of the neural network picks (gray dots). In this case, two RNCs were used.




Fig. 20 - Seção sísmica da linha 2 processada usando as redes neurais para determinação das velocidades de empilhamento.

Fig. 20 - Seismic section, line 2, processed using the neural network velocity picking technique.

## 5 - CONCLUSÕES

As redes neurais para determinação automática da velocidade de empilhamento foram testadas em dados sintéticos e reais com excelentes resultados. A qualidade da seção empilhada resultante do uso das redes neurais para determinação da velocidade de empilhamento é equivalente àquela produzida utilizando *picking* manual de velocidade. A vantagem do método é sua rapidez quando comparado com o processo manual. A média do tempo de

CPU para a determinação de uma função velocidade foi em torno de 0,5s em uma RISC/6000 tipo 530. A determinação das funções velocidades das linhas 1 e 2, considerando os espectros de velocidades já computados, foi de 1 min, num total de 120 espectros.

Todavia, a maior vantagem do método é que ele trabalha sem a interação do geofísico.

As duas redes neurais utilizadas nos dois primeiros estágios, isto é, RNT e RNV, podem ser substituídas por qualquer outro método algébrico para determinação de máximos locais. Entretanto, as redes neurais oferecem duas grandes vantagens: rapidez e fornecimento de uma maneira fácil de selecionar somente os máximos significantes se desejado, simplesmente ajustando-se os *thresholds* de aceitação.

O uso de RNC fornece uma maneira de atualizar a função velocidade de referência  $v_r(t_0)$  adequadamente ao longo da linha. Também fornece uma maneira de descartar e passar por espectros de má qualidade. A RNC fornece robustez ao método.

Os parâmetros usados na RNC, os quais são os níveis inferior e superior na saída da RNC para controle da aceitação e atualização da velocidade de referência  $v_r(t_0)$ , não são críticos ao ponto de valores exatos serem necessários. O valor do nível inferior é mais crítico, desde que ele define quando atualizar ou não a função velocidade de referência. Um valor entre 0,7 e 0,85 forneceu bons resultados. Naturalmente, esse valor é também uma função da variação da velocidade de empilhamento no intervalo do CMP sob consideração.

É importante enfatizar que os parâmetros usados na metodologia são dependentes dos dados e devem ser ajustados de acordo.

## REFERÊNCIAS BIBLIOGRÁFICAS

- BEITZEL, J. E., DAVIS, J. M. A computer oriented velocity analysis interpretation technique. *Geophysics*, Tulsa, v.40, p. 619-632, 1974.
- CUNNINGHAM, A. B., HEFFRING, H. H. Interpretation of velocity spectra. *Geophysics*, Tulsa, v. 45, p.1741-1752, 1980.
- FREEMAN, J. A., SKAPURA, D. M. *Neural networks : algorithms applications, and programming techniques*. London : Addison-Wesley, 1991.
- HUANG, K. Y. *et al.* Self-organizing neural network for picking seismic horizons. In: INTERNATIONAL MEETING, 60, California, 1990. *Proceedings...* California : Society of Exploration Geophysicists, 1991.
- McCORMARCK, M. D. Seismic trace editing and first break picking using neural network. In : INTERNATIONAL MEETING, 60, California, 1990. *Proceedings...* California : Society of Exploration Geophysicists, 1991.

- McCORMARCK, M. D. Neural computing in geophysics. *The Heading Edge*, [s.l.], v.10, n.11, p.11-15, 1991.
- RUMELHART, D. E., McCLELLAND, J. *Parallel distributed processing: exploration in microstructures of cognition*. Cambridge : MIT Press, 1986, v.1.
- SCHMIDT, J. *Neural network stacking velocity picking*. Colorado: School of Mines, 1992. Tese-Doutorado.
- SHAVLIK, J. W., DIETTERICH, T. G. *Readings in machine learning*. California : Morgan Kaufmann, 1992.
- TAYLOR, C. L. Inversion of gravity gradiometry data using: a neural network. In: INTERNATIONAL MEETING, 60, California, 1990. *Proceedings...* California : Society of Exploration Geophysicists, 1991.
- TOLDI, J. L. Velocity analysis without picking. *Geophysics*, Tulsa, v.54, p.191-199, 1990.
- WAGNER, D. E. *et al.* First break picking using neural networks. In: INTERNATIONAL MEETING, 60, California, 1990. *Proceedings...* California : Society of Exploration Geophysicists, 1991.
- WASSERMAN. P. D. *Neural computing : theory and practice*. New York : Van Nostrand Reinhold, 1989.
- WILLIAMS, P. K. *An investigation into utility of neural networks recognizing different reflected electromagnetic spectra*. Colorado : School of Mines, 1991. Dissertação-Mestrado.

## EXPANDED ABSTRACT

*State of the art of petroleum seismology data processing requires tedious and expensive interpretation of velocity spectrum. Usually this interpretation is performed in an interactive way on workstations. Even so, as petroleum seismology goes from a world of two-dimensional data to a world where three-dimensional data are a common place, the manual interpretation of velocity spectrum becomes a major bottleneck in the overall process of progressing from raw data to a stacked section.*

*This article describes an automated approach to the interpretation of velocity spectrum via synthetic neural networks. The velocity spectrum derived from stacking velocity analysis (SVA) may be represented in a two-dimensional array with rows corresponding to zero-offset travel time ( $t_0$ ) and columns corresponding to proposed stacking velocities ( $v$ ). The dependent variable in this function is some measure of the alignment of hyperbolas and the events that appear in the field data. Thus, the velocity spectrum could be represented as a ( $t_0, v$ ).*

*In order to interpret velocity spectrum one must have a reasonable guess for the primary stacking velocity as a function of zero-offset travel time. The author calls this guess the reference velocity function and represents this function by  $v_r(t_0)$ . Neural nets are not employed to determinate the first guess of the reference velocity function.*

*The proposed method involves three steps. The first step is called time picking, the second step is velocity picking, and the third step is called velocity validation.*

*An energy trace is a function of normal incidence travel time which can be defined by  $e(t_0) = \sum a(t_0, v_i)$ . The energy trace*

*maxima provide good times at which to search for the velocity maxima, which hopefully define the gross properties of the seismic section. So, a neural net is designed to locate only peaks in the energy curve. The neural net training set is constituted of twelve synthetic curves, each of which defined by five points. Six curves have the form of a greater than symbol (>) and the other six have form of a less than symbol (<).*

*The output of the first neural net defines the time velocity traces, at which to search for the velocities in the velocity traces, here represented by a ( $t_p, v$ ), which are to be examined by the next neural net;  $t_p$  stands for the picked time. The neural net that performs the velocity picking is identical in architecture and training to the first one. The problem is that this neural net selects more than one velocity for a chosen time. Which is the correct one?*

*In the third step, corresponding to the velocity validation, the neural network is assigned the task of determining if the picked velocity function referred to as the candidate reference velocity function  $v_c(t_0)$  is consistent with the current reference velocity function  $v_r(t_0)$ . This consistence is defined in accordance with the neural net output level. Depending on the neural net output level, the  $v_c(t_0)$  may become the new reference velocity function  $v_r(t_0)$ . The training set for this neural net is constituted of the reference velocity function  $v_r(t_0)$ , the upper velocity bound  $v_u(t_0)$ , and the lower velocity bound  $v_l(t_0)$ .*

*Comprehensive tests on synthetic and real data indicate that this method will probably clear the above mentioned bottleneck; i.e., it will allow the data to proceed from field tapes to the stacked section without human interaction.*