



PI 01164538
PI 01164538

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA E COMÉRCIO EXTERIOR
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL

CARTA PATENTE Nº PI 0116453-8

O INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL concede a presente PATENTE DE INVENÇÃO, que outorga ao seu titular a propriedade da invenção caracterizada neste título, em todo o território nacional, garantindo os direitos dela decorrentes, previstos na legislação em vigor.

(21) Número do Depósito: PI 0116453-8

(22) Data do Depósito: 19/12/2001

(43) Data da Publicação do Pedido: 27/06/2002

(51) Classificação Internacional: G06G 7/48

(30) Prioridade Unionista: 19/12/2000 US 60/256,679; 18/06/2001 US 60/299,002

(54) Título: APARELHO E MÉTODO PARA CONVERTER OS SINAIS DE SAÍDA DE UMA FERRAMENTA DE REGISTRO

(73) Titular: HALLIBURTON ENERGY SERVICES, INC., Companhia Norte Americana. Endereço: 4100 Clinton Drive, Building 01, 6th Floor, Houston, Texas 77020, Estados Unidos (US).

(72) Inventor: LUIS E. SAN MARTIN; ROBERT W. STRICKLAND; MARTIN T. HAGAN; DINGDING CHEN; GULAMABBAS A. MERCHANT

Prazo de Validade: 10 (dez) anos contados a partir de 30/12/2014, observadas as condições legais.

Expedida em: 30 de Dezembro de 2014.

Assinado digitalmente por:

Liane Elizabeth Caldeira Lage
Diretora de Patentes Substituta



“APARELHO E MÉTODO PARA CONVERTER OS SINAIS DE SAÍDA DE UMA FERRAMENTA DE REGISTRO”

Prioridade

Este pedido reivindica o benefício de Pedido Provisório US N° 60/256.679, depositado em 19 de dezembro de 2000; e Pedido Provisório US 5 N° 60/299.002, depositado em 18 de junho de 2001.

1. Campo da Invenção

Esta invenção relaciona-se a registro de poço, e mais particularmente a uma rede neural treinada para processar sinais de uma 10 ferramenta de registro em uma representação de parâmetros de formação.

2. Fundamento da Invenção

Operações modernas de perfuração e produção de petróleo exigem uma grande quantidade de informação relativa a parâmetros e condições furo abaixo. Tal informação tipicamente inclui características das 15 formações de terra atravessadas pela cavidade de poço, além de dados relativos ao tamanho e configuração da própria cavidade de poço. Registro de poço de petróleo foi conhecido na indústria por muitos anos como uma técnica para prover informação a um profissional de avaliação de formação ou perfurador relativa à formação de terra particular sendo perfurada. A coleta de 20 informação relativa às condições furo abaixo, que geralmente é referida como "registro", pode ser executada por vários métodos. Estes métodos incluem medição enquanto perfurando, MWD, e registro enquanto perfurando, LWD, em que uma ferramenta de registro é levada em uma cadeia de broca durante o processo de perfuração. Os métodos também incluem registro de linha de 25 fios.

Em registro de linha de fios de poço de petróleo convencional, uma sonda é abaixada no furo de sondagem depois que um pouco ou todo do poço foi perfurado, e é usada para determinar certas características das formações atravessadas pela cavidade de poço. A sonda pode incluir um ou

mais sensores para medir parâmetros furo abaixo e tipicamente é construída como um cilindro hermeticamente lacrado para alojar os sensores, que se penduram na ponta de um cabo longo ou "linha de fios". O cabo ou linha de fios provê suporte mecânico à sonda e também provê conexões elétricas entre os sensores e instrumentação associada dentro da sonda, e equipamento elétrico localizado à superfície do poço. Normalmente, o cabo supre energia operacional à sonda e é usado como um condutor elétrico para transmitir sinais de informação da sonda à superfície. De acordo com técnicas convencionais, vários parâmetros das formações da terra são medidos e correlatados com a posição da sonda no furo de sondagem quando a sonda é puxada furo acima.

Um mapa ou gráfico de um parâmetro de terra ou de um sinal de ferramenta de registro contra a posição ou profundidade no furo de sondagem é chamado um "registro". A profundidade pode ser a distância da superfície da terra à localização da ferramenta no furo de sondagem ou pode ser profundidade verdadeira, que é a mesma só para uma cavidade de poço reta perfeitamente vertical. O registro do sinal de ferramenta ou dados brutos freqüentemente não provêem uma representação clara do parâmetro de terra que o profissional de avaliação de formação ou perfurador precisa saber. O sinal de ferramenta deve normalmente ser processado para produzir um registro que mais claramente represente um parâmetro desejado. O registro é normalmente primeiro criado em forma digital por um computador e armazenado em memória de computador, em fita, disco, etc., e pode ser exibido em uma tela de computador ou impresso em forma de cópia física.

Os sensores usados em um sonda de linha de fios normalmente incluem um dispositivo de fonte para transmitir energia para a formação, e um ou mais receptores para detectar a energia refletida da formação. Vários sensores foram usados para determinar características particulares da formação, incluindo sensores nucleares, sensores acústicos e sensores

elétricos. Veja geralmente J. Lab, "A Practical Introduction to Borehole Geophysics" (Sociedade de Geofísicos de Exploração 1986); D.R. Skinner, "Introduction to Petroleum Production", Volume 1, em 54-63 (Gulf Publishing Co. 1981).

5 Para uma formação conter petróleo, e para a formação permitir o petróleo fluir por ela, a rocha incluindo a formação deve ter certas características físicas bem conhecidas. Uma característica é que a formação tenha uma certa faixa de resistividade mensurável (ou condutividade), que em muitos casos pode ser determinada induzindo um campo eletromagnético
10 alternado na formação por um arranjo de bobina de transmissor. O campo eletromagnético induz correntes elétricas alternadas (ou de remoinho) na formação em caminhos que são substancialmente coaxiais com o transmissor. Estas correntes por sua vez criam um campo eletromagnético secundário no meio, induzindo uma tensão elétrica alternada na bobina de receptor. Se a
15 corrente na bobina de transmissor for mantida constante, a intensidade de corrente parasita é geralmente proporcional à condutividade da formação. Conseqüentemente, a condutividade da formação determina a intensidade do campo eletromagnético secundário, e assim, a amplitude da tensão elétrica na bobina de receptor. Veja geralmente, James R. Jordan, e outros, "Well
20 Logging II -Electric And Acoustic Logging", Série de Monografias de SPE, Volume 10, em 71-87 (1986).

 Uma ferramenta de indução exemplar é mostrada no desenho da arte anterior da Figura 1, no qual um ou mais transmissores (T) e uma pluralidade de receptores (R_i) são mostrados em uma sonda de registro. Cada
25 transmissor ou receptor pode ser um conjunto de bobinas, com ferramentas de indução de arranjo modernas tendo vários receptores, por exemplo R_1 , R_2 , R_3 , e R_4 , de espaçamento de transmissor para receptor crescente para medir progressivamente mais fundo na formação.

 Em uma ferramenta de indução convencional tal como aquela

mostrada na Figura 1, as bobinas são enroladas coaxialmente ao redor de um mandril cilíndrico. Ambas bobinas de transmissor e bobinas de receptor são em forma de solenóide, e são enroladas coaxiais com o mandril. Tais bobinas portanto estariam alinhadas com o eixo principal da ferramenta de registro, que é normalmente também o eixo central do furo de sondagem e é normalmente referido como o eixo z. Quer dizer, os momentos magnéticos das bobinas estão alinhados com o eixo do mandril no qual elas são enroladas. O número, posição e número de espiras das bobinas são arranjados para anular o sinal em um vácuo devido à indutância mútua de transmissores e receptores.

Durante operação, um oscilador supre corrente alternada à bobina de transmissor ou bobinas, por esse meio induzindo corrente na bobina ou bobinas de receptor. A tensão elétrica da corrente induzida nas bobinas de receptor resulta da soma de todas as correntes parasitas induzidas nas formações circundantes pelas bobinas de transmissor. Eletrônica sensível à fase medi a tensão elétrica de receptor que está em fase com a corrente de transmissor dividida por magnitude da corrente de transmissor. Quando normalizado com o fator de escala correto, isto provê sinais que representam a condutividade aparente daquela parte da formação pela qual o sinal transmitido passou. O componente fora de fase ou de quadratura também pode ser útil por causa de sua sensibilidade a efeito pelicular, embora seja menos estável e seja adversamente afetado por contrastes na permeabilidade magnética.

Como notado, as correntes parasitas induzidas tendem a fluir em caminhos circulares que são coaxiais com a bobina de transmissor. Como mostrado na Figura 1, para um furo de sondagem vertical que atravessa formações horizontais, há uma simetria geral para a corrente induzida ao redor da ferramenta de registro. Nesta situação ideal, cada linha de fluxo de corrente permanece na mesma formação ao longo de seu caminho de fluxo

inteiro, e nunca cruza um limite de leito.

Em muitas situações, como mostrado por exemplo na Figura 2, a cavidade de poço não é vertical e os limites de leito não são horizontais. A cavidade de poço na Figura 2 é mostrada com um ângulo de inclinação Θ medido relativo à vertical verdadeira. Um limite de leito entre formações é mostrado como um ângulo de inclinação α . A cavidade de poço inclinada atinge o leito inclinado a um ângulo β . Como resultado, as correntes parasitas induzidas fluem por mais de um meio, encontrando formações com propriedades resistivas diferentes. Os registros resultantes são distorcidos, especialmente quando o ângulo de inclinação α dos limites de leito aumenta. Se a ferramenta de registro atravessar um leito fino, o problema se torna até mesmo mais exagerado.

Como mostrado no gráfico da Figura 3A, uma sonda de indução que atravessa um leito inclinado produz um registro com distorções normalmente referido como "chifres". Quanto mais severo o ângulo de inclinação, menos precisa é a medição com profundidade. Figura 3A representa uma simulação de computador de um registro que seria gerado durante registro de um leito grosso de 3m (em profundidade real), com gráficos diferentes para ângulos de inclinação diferentes. Figura 3B mostra uma simulação de computador de um registro que seria gerado se a espessura do leito fosse profundidade vertical verdadeira com gráficos diferentes para ângulos de inclinação diferentes. Como é evidente destes registros simulados, quando o ângulo de inclinação aumenta, a precisão e significância do registro diminui. Em casos de ângulos de inclinação altos, os gráficos se tornam virtualmente sem sentido na vizinhança dos limites de leito.

Figuras 3A e 3B também ilustram que até mesmo para um poço vertical atravessando formações horizontais, o sinal elétrico real ou dados produzidos por uma ferramenta de registro de indução são bastante diferentes de um gráfico exato de resistividade de formação. Nestes figuras,

as representações desejadas de resistividade de formação são as formas de onda quadradas de linha tracejada 10 e 20. A resistividade real dentro de uma camada é geralmente uniforme, de forma que há mudanças abruptas em resistividade nas interfaces entre camadas. Porém, ferramentas de registro limitaram resolução e não medem diretamente estas mudanças abruptas. Quando a bobina de transmissor T na Figura 1 está perto de uma interface, como ilustrado, seu sinal transmitido é dividido entre camadas de resistividade diferente. Como resultado, os dados brutos ou sinal da ferramenta de registro é uma combinação ou média dos valores reais das camadas adjacentes. Este efeito é referido como o efeito de ombro. Até mesmo no caso de 0° mostrado na Figura 3A e 3B, onde a ferramenta é vertical e a formação é horizontal, os dados medidos são bastante diferentes da representação desejada de resistividade. Quando a inclinação aumenta, o efeito é aumentado.

Muito trabalho foi feito em métodos e equipamento para processar dados ou sinais de ferramenta de registro para produzir uma representação precisa de parâmetros de formação. Este processo de dados é geralmente chamado inversão. Inversão é normalmente efetuada em algum tipo de computador. No sistema da arte anterior da Figura 1, um bloco rotulado "módulo de computação" pode executar algum tipo de processo de inversão. Os métodos atualmente disponíveis para executar este processamento são iterativos em natureza. Os métodos iterativos padrão têm a desvantagem de serem computacionalmente intensivos. Como resultado, a inversão deve normalmente ser efetuada em centros de computação usando computadores relativamente grandes, que podem entregar resultados da inversão em uma quantidade de tempo razoável, e normalmente não pode ser executada em computadores adequados para uso no local de poço.

Um método de processamento alternativo é o método de convolução inversa. Este método é muito rápido e pode ser implementado no

local de poço, por exemplo, no módulo de computação da Figura 1. Porém, este método é baseado em teoria de filtro linear, que é uma aproximação que não é sempre precisa. Em furos de sondagem desviados, a não linearidade da resposta de ferramenta se torna manifesta, fazendo o problema difícil para o método de convolução inversa operar. Os métodos de convolução inversa não geram representações reais dos parâmetros de formação, assim eles não podem ser corretamente chamados de métodos de inversão.

Tentativas anteriores para resolver a inversão de problema de dados de registro usaram o método de inversão paramétrica. Este método é um método iterativo que usa um solucionador dianteiro e critérios, tais como inversão de mínimo quadrado, para determinar o melhor ajuste para os parâmetros de uma formação predefinida, normalmente um modelo com um perfil de degrau. Porém, se a formação real não conformar com o modelo predefinido, os parâmetros de saída determinados por este método podem estar muito longe dos parâmetros reais da formação. Esta é uma consequência da natureza mal colocada do problema de inversão que o faz altamente não trivial.

Um método mais atual para inversão de dados de registro de resistividade é o "Método de Entropia Máxima", MEM. Neste método iterativo, um modelo de teste ou formação proposta é modificado para maximizar a entropia funcional, que depende dos parâmetros da formação. Este método não usa uma formação predefinida e produz soluções de melhor qualidade. É mais eficiente que as abordagens paramétricas, mas ainda é computacionalmente intensivo. Pode ser aplicado a qualquer tipo de ferramenta à qual um solucionador dianteiro está disponível. Um exemplo do método de MEM é exposto na Patente US nº 5.210.691, intitulado "Method and Apparatus for Producing a More Accurate Resistivity Log from Data Recorded by an Induction Sonde in a Borehole".

Em geral, todos os esquemas de inversão iterativos têm

essencialmente duas partes. A primeira parte é um solucionador dianteiro que gera um registro sintético de uma formação de teste sintética que é uma representação razoável de uma formação real. A formação de teste é um gráfico geralmente assumido de onda quadrada de um parâmetro de formação, por exemplo, resistividade, contra profundidade, como os gráficos 10 e 20 nas Figuras 3A e 3B. O solucionador dianteiro simula a resposta de uma ferramenta de registro selecionada à formação de teste para gerar o registro sintético. Se a ferramenta de registro tiver múltiplos conjuntos de transmissor-receptor ou arranjos, como ilustrado na Figura 1, uma solução dianteira separada é precisada para cada conjunto, desde que cada conjunto responde diferentemente. A segunda parte do método iterativo é um critério para modificar a formação de teste. O critério é baseado na diferença entre o registro sintético que corresponde à formação de teste e os dados de registro reais medidos pela ferramenta. Depois que a formação de teste foi modificada, um novo registro sintético é gerado pelo solucionador dianteiro. Este processo é repetido iterativamente até que a diferença entre o registro sintético e o registro real seja menos que uma tolerância predefinida. A saída do algoritmo de inversão são os parâmetros da formação de teste final. Estes parâmetros são lançados graficamente contra profundidade para produzir o registro desejado. É a natureza iterativa destes métodos que os fazem computacionalmente intensivos.

Vários esforços foram feitos para usar Redes Neurais Artificiais, ANN, como parte de processos de inversão. Por exemplo, no documento intitulado "Detection of Layer Boundaries from Array Induction Tool Responses using Neural Networks", 69º encontro internacional de SEG Anual (Houston, 1999). Resumo expandido, V1, pp. 140-143, os autores Srinivasa V. Chakravarthy, Raghu K. Chundur, Alberto G. Mezzatesta, e Otto Fanini usam uma rede neural de função de base radial treinada para identificar limites de leito de registros de poço de indução. A rede é treinada

usando a derivada logarítmica de ambos dados de registro medidos e sintéticos. Como resultado, dados de registro reais a serem processados pela rede neural treinada também devem ser primeiro processados tomando a derivada logarítmica. Os limites de leito detectados são então usados em processos de inversão conhecidos.

Na publicação intitulada "Artificial Neural Networks And High Speed Resistivity Modeling Software Speeds Reservoir Characterization", Jeff S. Arbogast e Mark H. Franklin, 'Petroleum Engineer International', pp. 57-61, os autores descrevem uso de uma rede neural treinada em registros de poço reais de vários tipos. Por seleção correta de registros disponíveis para treinamento, é relatado que é possível sintetizar registros perdidos ou preencher dados ruins para outros poços no mesmo campo.

Na Patente US nº 5.251.286, intitulada "Method for Estimating Formation Permeability from Wireline Logs Using Neural Networks", os inventores Jacky M. Wiener, Robert F. Moll e John A. Rogers, expõem uso de uma rede neural para determinar permeabilidade. A rede é treinada com resistividade, porosidade de nêutrons, densidade volumétrica, tempo de trânsito de intervalo, e outros registros e permeabilidade de núcleo medida real. É então capaz de usar as mesmas medições de registro de linha de fios de outros poços na mesma área para estimar permeabilidade de formação em poços dos quais núcleos não foram realmente tomados e medidos.

Na Patente US nº 5.862.513, intitulada "Systems and Methods for Forward Modeling of Well Logging Tool Responses", os inventores Alberto G. Mezzatesta, Michael A. Jervis, David R. Beard, Kurt M. Strack, e Leonty A. Tabarovsky, expõem uso de uma rede neural para produzir respostas de ferramenta sintéticas para uma ferramenta de registro de poço. A rede neural é treinada para simular a resposta de uma ferramenta de registro particular para modelos de formações de terra. A rede treinada é pretendida

para uso como o solucionador dianteiro em um processo de inversão iterativo.

Na Patente US nº 6.044.325, intitulada "Conductivity Anisotropy Estimation Method for Inversion Processing of Measurements Made by a Transverse Electromagnetic Induction Logging Instrument", os inventores Srinivasa V. Chakravarthy, Pravin Gupta, Raghu Chunduru, Berthold G. Kriegshauser, e Otto N. Fanini, ensinam um método de usar uma rede neural treinada para melhorar estimativas iniciais de parâmetros de formação. A rede é treinada sintetizando a resposta da ferramenta primeiro a modelos de formações de terra. Então, estimativas iniciais dos parâmetros de terra são calculadas das respostas sintetizadas. As estimativas iniciais e modelos de terra conhecidos são usados para treinar uma rede neural. Para usar a rede treinada com dados reais, sinais de ferramenta reais são primeiro processados para produzir uma estimativa inicial de parâmetros de terra. Estes sinais processados são então introduzidos à rede neural treinada para produzir estimativas melhoradas de parâmetros.

Enquanto estas referências mostraram melhorias em inversão de registro de poço por uso de redes neurais treinadas, nenhum deles ensinou um método para inversão direta de sinais de ferramenta de registro para produzir um registro de parâmetros de formação. Inversão direta seria mais rápida do que os métodos da arte anterior e permitiria geração em tempo real de registros de poço no local de poço. Também permitiria processamento em tempo real de sinais de ferramenta de registro em LWD ou MWD. Isto seria bastante útil ao engenheiro de perfuração durante o processo de perfuração. Por exemplo, em perfuração de poço inclinada, os registros de poço poderiam ser usados ao guiar o sistema de perfuração.

SUMÁRIO DA INVENÇÃO

A presente invenção provê um método melhorado para treinar uma rede neural para processar sinais de registro para produzir registros representativos de um parâmetro de formação de terra e uma rede neural

treinada melhorada. Modelos sintéticos ou artificiais de parâmetros de formação de terra são gerados para treinar uma rede neural. Os modelos são selecionados para cobrir a faixa operacional inteira de uma ferramenta selecionada baseado em sua sensibilidade e características de resolução e baseado em uma faixa realista de parâmetros de formação. Em cada modelo, os contrastes de parâmetro em interfaces de camada são limitados a valores realistas que estão dentro da faixa operacional da ferramenta. Os modelos selecionados incluem modelos que têm valores de parâmetro mínimos no limite inferior da faixa operacional de ferramenta e modelos que têm valores de parâmetro máximos no limite superior da faixa operacional de ferramenta. Um solucionador dianteiro é usado para simular a resposta de ferramenta para os modelos. As respostas simuladas e modelos são então usados para treinar uma rede neural para produzir os modelos como saídas em resposta às respostas simuladas como entradas. Dados reais coletados pela ferramenta de registro podem então ser processados pela rede neural para produzir registros do parâmetro de terra.

BREVE DESCRIÇÃO DOS DESENHOS

Para um entendimento mais detalhado da invenção, referência é feita agora aos desenhos, em que:

Figura 1 é uma ilustração de um sistema de registro de indução da arte anterior;

Figura 2 é uma ilustração de uma cavidade de poço sendo perfurada por uma formação de leito inclinado de acordo com práticas de perfuração típicas;

Figuras 3A-3B descrevem dados de resistividade obtidos em formações de leito inclinado usando a sonda de indução da Figura 1;

Figura 4 é um fluxograma que ilustra treinamento de uma rede neural;

Figura 5 é um gráfico de resistividade de formação contra

profundidade para formações de terra do tipo Oklahoma;

Figura 6 é um gráfico de resistividade de formação contra profundidade para uma formação de terra do tipo de chilo;

Figura 7 é uma demonstração de desempenho de uma rede neural treinada em inversão de dados de registro a inclinação zero;

Figura 8 é uma demonstração de desempenho de uma rede neural treinada em inversão de dados de registro a inclinação de 55 graus;

Figura 9 é uma ilustração de uma formação de teste bidimensional;

Figura 10 é uma ilustração do desempenho de uma rede neural treinada no processamento de dados de registro da formação bidimensional da Figura 9;

Figura 11 é um fluxograma típico de inversão de rede neural de registros de indução;

Figura 12 é uma ilustração de uma rede de alimentação avançada de multicamadas com saídas múltiplas que formam uma junta de rede submetida;

Figura 13 é uma ilustração de calcular média de saídas de uma junta de rede submetida através de uma diagonal;

Figura 14 é um fluxograma que ilustra processamento de registros de indução de arranjo com uma junta de rede submetida;

Figura 15 são saídas de inversão provendo uma comparação de desempenho de uma junta de rede submetida e uma única rede de saída;

Figura 16 são saídas de inversão para uma aplicação de leito inclinado provendo uma comparação de desempenho de uma junta de rede submetida e uma única rede de saída;

Figura 17 é um gráfico de trajetória de treinamento para inicialização padrão para uma junta de rede submetida;

Figura 18 é um gráfico de trajetória de treinamento para

inicialização padrão para uma junta de rede submetida com o método de inspeção rápida; e

Figura 19 é um gráfico de trajetória de treinamento para inicialização padrão para uma junta de rede submetida com uma opção diferente do método de inspeção rápida.

DESCRIÇÃO DETALHADA DA INVENÇÃO

Como pode ser visto das referências citadas acima, tentativas para usar redes neurais artificiais, ANNs, nos vários processos de inversão para dados de registro de poço tiveram sucesso limitado. Usar grandes quantidades de dados existentes para treinar de redes neurais aumenta o custo e despesa de gerar a ANN treinada e não melhorou a velocidade ou precisão ou a ANN ou a fez extensamente aplicável fora da área de qual dados foram selecionados. Alguns fomentadores sugeriram que é importante escolher só aquelas partes dos dados disponíveis que são claramente precisas e não contaminadas por condições de furo de sondagem ruins, resposta de ferramenta pobre, ou outras fontes de erro. Se uma ANN for ensinada para inverter dados ruins em um registro bom, é provável inverter dados bons em um registro ruim.

Os presentes inventores acharam que um modo viável para evitar usar dados ruins ou imprecisos para treinar uma ANN é usar só dados sintéticos. Além disso, seleção de dados de treinamento deveria ser baseada no comportamento da ferramenta selecionada, não nas formações de terra em qualquer área particular. O conjunto de treinamento deveria cobrir a faixa operacional da ferramenta, mas contrastes de interface deveriam ser limitados a faixas de parâmetro realistas. Usando estas regras simples para selecionar só alguns modelos de formação de terra e para graduar os modelos, ANNs treinadas foram geradas, que proveram boa inversão de dados de registro sem limitação de área geográfica.

As referências acima citadas também ilustram que a estrutura

de ANNs e métodos para treinar ANNs são bem conhecidos. As Patentes acima referidas US nº 5.251.286 e 5.862.513 estão por este meio incorporadas por referência para todos os propósitos e particularmente para suas exposições relativas à estrutura e treinamento de ANNs.

5 Com referência à Figura 4, o treinamento de uma ANN de acordo com a presente invenção será descrito. Uma primeira etapa, representada por caixa 30, é para produzir vários modelos de formação sintéticos ou formações alvo para o processo de treinamento. Formações que foram selecionadas para uma concretização preferida serão descritas abaixo

10 com referência às Figuras 5 e 6. Todos os modelos de formação selecionados são introduzidos a um solucionador dianteiro para gerar um registro sintético de condutividade na caixa 32. O solucionador dianteiro é um programa de computador que simula a resposta de uma ferramenta de registro selecionada a qualquer modelo de formação de terra selecionado. Ferramentas de indução

15 modernas têm vários espaçamentos de transmissor para receptor e uma ANN separada pode ser treinada para cada ou qualquer combinação deles. Um solucionador dianteiro separado é usado para cada espaçamento de transmissor a receptor. Ao desenvolver a presente invenção, os inventores basearam seu trabalho na ferramenta de registro de indução de HRAI

20 desenvolvida pelo representante deste pedido de patente. Aquela ferramenta é o assunto de um documento intitulado "A New High Resolution Array Induction Tool", por Randy Beste, T. Hagiwara, George King, Robert Strickland, e G. A. Merchant, apresentada ao 41º Simpósio de Registro Anual SPWLA, 4-7 de junho de 2000.

25 O logaritmo do registro de condutividade sintética gerado na etapa 32 é alimentado à entrada da ANN 34 na forma de pequenas janelas de dados. A janela de entrada é selecionada para incluir várias amostras que correspondem pelo menos à faixa de profundidades de cavidade de poço que um conjunto de transmissor-receptor de ferramenta selecionada estaria

medindo de uma vez em uma zona de alta resistividade. A janela deveria incluir várias amostras que correspondem a uma faixa de várias vezes a distância de transmissor a receptor. Fazendo a janela mais larga geralmente melhora o esquema de inversão, mas também aumenta o tempo de
5 treinamento e custo.

Na concretização preferida, a ANN era uma rede neural de percepção avançada de multicamadas com cinquenta e uma entradas. A janela de entrada incluiu cinquenta e uma amostras representando sinais de ferramenta espaçados 15 cm à parte. Estas amostras portanto representaram
10 dados de 7,6 m de furo de sondagem. Nesta concretização, a rede tinha duas camadas ocultas com oito neurônios na primeira e vinte na segunda e tinha uma saída. Resultados bons também foram alcançados com redes tendo três camadas ocultas. Para cada janela de dados de entrada, a ANN 34 gerou um valor de saída centrado na janela de entrada. O processo continuou
15 introduzindo janelas rolantes de cinquenta e uma amostras. Quer dizer, uma amostra era retirada de uma extremidade da janela e uma era adicionada à outra extremidade. Ao término do processo, um valor de saída foi gerado para cada espaçamento de 15 cm no furo de sondagem.

Em outro ensaio, um tamanho de janela de 101 amostras foi
20 usado, com a ANN novamente produzindo um valor de saída centrado na janela de entrada. Neste ensaio, o espaçamento de amostra de entrada era de 7,6 cm, assim as entradas também representaram 15,2 m de furo de sondagem. O processo de janela de entrada rolante foi usado novamente para gerar um valor de saída para cada 7,6 cm de furo de sondagem. Porém, isto
25 requer uma ANN com 101 entradas e aumenta o tempo de treinamento e despesa. Os resultados alcançados não foram suficientemente diferentes para justificar o custo extra.

Vários softwares comercialmente disponíveis podem ser usados para construir, treinar e testar redes neurais. Por exemplo, a 'Neural

Network Toolbox' para MATLAB foi usada em desenvolvimento e teste da presente invenção.

Quando o logaritmo dos dados de registro sintéticos são introduzidos à ANN 34, ele produz uma representação dos modelos de formação de terra à sua saída 36. Como os dados de entrada eram o logaritmo dos sinais de condutividade de ferramenta sintética, a saída é o logaritmo de uma representação da condutividade de formação. A exponencial das saídas da ANN é portanto usada como a representação da formação. Ambas a representação de saída 36 e os modelos de entrada 30 são alimentados a uma etapa de comparação 38, que determina a diferença entre as duas. A diferença é realimentada à ANN 34 para ajustar os parâmetros ou coeficientes da ANN e o processo é repetido. Quando a diferença detectada em etapa de comparação 38 está abaixo de um nível de erro aceitável, o processo é parado. Quando a ANN assim foi treinada com todos os modelos de formação selecionados, os coeficientes finais da ANN são armazenados para uso futuro. A ANN com estes coeficientes está então pronta para uso em processamento de dados reais produzidos pela ferramenta de registro selecionada.

O processo pode ser repetido para qualquer ângulo de inclinação selecionado. Os mesmos modelos de formação selecionados são usados na etapa 30. O solucionador dianteiro é ajustado para simular o ângulo de inclinação selecionado, de forma que o registro sintético produzido em 32 precisamente simule resposta de ferramenta no ângulo de inclinação selecionado. Como mostrado nas Figuras 3A e 3B, a resposta de ferramenta para a mesma formação de terra pode mudar significativamente quando ângulo de inclinação muda. Quando a ANN é treinada com estes dados, ela pode ser usada para processar dados reais de poços que têm o ângulo de inclinação selecionado. Na prática, uma ANN separada não precisa ser treinada para cada grau de possível inclinação. Ao invés, uma ANN pode ser treinada para cada cinco a dez graus de inclinação. Quando dados reais são

para serem processados, a ANN com a inclinação mais próxima pode ser selecionada e usada. Se a inclinação dos dados reais for, por exemplo, meio caminho entre dois dos ângulos de inclinação selecionados para treinar ANNs, ambos podem ser usados para processar os dados reais e o resultado
5 pode ser extrapolado das duas saídas.

Com referência agora à Figura 5, é mostrado um dos dois modelos de terra básicos usados na concretização preferida. Este modelo de formação é referido como uma formação do tipo Oklahoma porque é semelhante às formações de terra reais que ocorrem em Oklahoma. O
10 particular mostrado na Figura 5 é porém só um modelo sintético selecionado para ter certas características. A formação é representada pelo gráfico de onda quadrada 40 de resistividade contra profundidade. Como cada camada de leito de terra normalmente tem resistividade uniforme entre suas interfaces superior e inferior com camadas adjacentes, o modelo tem a forma de onda
15 quadrada. Os modelos usados na concretização preferida assumem que o sinal de ferramenta será pré-processado para corrigir efeito de cavidade de poço, que é uma função de condutividade de lama de perfuração e diâmetro de cavidade de poço.

O modelo inclui camadas relativamente grossas tal como
20 camada 42. Também inclui camadas finas, tal como 44, que estão perto da espessura mínima de um leito que pode ser resolvido pela ferramenta de registro selecionada. O modelo inclui uma variedade de contrastes, que são as mudanças em resistividade entre camadas adjacentes. Os contrastes variam de abaixo de 10 para 1, por exemplo em 46, a acima de 100 para 1, por exemplo,
25 em 48. Esta faixa de contraste foi escolhida como sendo realista em termos de quais contrastes são mais comuns em formações de terra reais. Há casos onde contrastes de 1000 para 1 ou mais altos podem ser encontrados, mas estes são considerados incomuns ou extremos e não são considerados realistas como aquele termo é usado na presente invenção. Quando eles ocorrem, é provável

que eles se estenderão acima ou abaixo dos limites da faixa operacional de ferramenta, e portanto não serão medidos precisamente de qualquer maneira. No caso incomum, onde um tal contraste de 1000 para 1 acontece dentro da faixa operacional de ferramenta, a ANN pode interpretá-lo como dois contrastes proximalmente espaçados. Nenhum dos contrastes de interface se estende dos valores de sensibilidade de ferramenta mínimo a máximo, que para o tipo de ferramenta e espaçamentos de transmissor a receptor usados em teste eram de cerca de 0,2 ohm-m a cerca de 2000 ohm-m para uma faixa total de cerca de 10.000 para 1. As mudanças de contraste acontecem através de faixas baixas de resistividade, por exemplo em 50, e através de faixas altas, por exemplo em 46.

Várias versões do modelo na Figura 5 são usadas ao treinar a ANN. Dois cores as faixas superior e inferior extremas de resistividade. Na Figura 5, a resistividade em 42 é a máxima para o modelo inteiro. Pelo menos uma versão foi selecionada posicionando este máximo perto da sensibilidade máxima da ferramenta selecionada, que nesta concretização era cerca de 2000 ohm-m. De modo semelhante, uma versão de faixa baixa foi selecionada posicionando a resistividade mais baixa em 52 perto da faixa mais baixa esperada de cerca de 0,2 ohm-m. Uma ou mais versões em faixas intermediárias como mostrado na Figura 5 também são usadas. Os inventores acharam que as ANNs fazem um bom trabalho de interpolar entre faixas nas quais elas foram treinadas, mas não fazem um bom trabalho de extrapolar além dessas faixas. Incluindo níveis máximo e mínimo baseados em faixa operacional de ferramenta e contrastes que de forma realista acontecem na natureza, a ANN recebe todo o treinamento que precisa para interpolar qualquer sinal razoável.

A faixa operacional de ferramenta é limitada por vários fatores. Em formações de resistividade muito alta, a corrente induzida é muito pequena e produz sinais muito pequenos nas bobinas de recepção. A

eletrônica de recepção tem algum ruído elétrico inerente que limita a habilidade do sistema analisar os sinais recebidos acima de algum nível de resistividade. Em resistividade muito baixa, o efeito pelicular se torna forte, fazendo a resposta se tornar não linear como também prevenindo medição da resistividade de formação real.

A resposta de ferramentas de registro em interfaces é afetada por mais que apenas o valor de contraste àquela interface. Também é afetada pela faixa à qual o contraste acontece. Quer dizer, sua resposta a um contraste de 10 para 1 entre 100 ohm-m e 1000 ohm-m não é a mesma como é para um contraste de 10 para 1 entre 10 ohm-m e 100 ohm-m. Resposta é afetada por espessuras relativas camadas adjacentes igualmente. Quer dizer, a resposta a um dado contraste entre duas camadas grossas é diferente da resposta ao mesmo contraste entre duas camadas finas ou entre uma camada fina e uma camada grossa. O tipo Oklahoma foi selecionado porque provê exemplos através de uma faixa destas possíveis condições de interface.

Figura 6 ilustra uma formação de chiro que era o outro tipo de modelo usado ao treinar a ANN. Este modelo é novamente representado por uma forma de onda quadrada pelas mesmas razões como se aplicam ao modelo do tipo Oklahoma. A diferença principal é que para qualquer versão única, o contraste de resistividade para cada interface é o mesmo. O modelo contém uma série de camadas, 62, 64, etc., de espessuras variadas, começando com a mais grossa em 64 e terminando com a mais fina em 66. As regras para selecionar valores de parâmetro e limites para o modelo de chiro são essencialmente as mesmas como para o modelo do tipo Oklahoma. Na Figura 6, cada contraste é ilustrado como tendo um contraste de 100 para 1. Outras versões deste modelo tendo um contraste de 10 para 1 também foram usadas para treinar a ANN. Duas versões de faixa extrema foram selecionadas. Uma teve um valor de resistividade máxima de cerca de 2000 ohm-m. A outra teve um valor de resistividade mínima de cerca de 0,2 ohm-

m. Estes valores foram novamente selecionados para cobrir os limites da faixa operacional de ferramenta enquanto não excedendo valores realistas de contrastes achados em formações de terra.

5 Nas Figuras 5 e 6, também são ilustrados os sinais de
ferramenta de registro sintético 54 e 68, respectivamente. Estes são os sinais gerados na etapa 32 da Figura 4. Sinais 54 e 68 são o tipo de sinais realmente produzidos por uma ferramenta de registro de indução usada para medir resistividade. O processo de inversão é o processo de converter estes sinais nos sinais de onda quadrada 40 e 60 que mais precisamente representam o
10 perfil de resistividade real de formações pelas quais o furo de sondagem é perfurado. Como discutido com referência à Figura 4, sinais 54 e 68 são os sinais alimentados à entrada de ANN 34 durante o processo de treinamento.

Figura 6 também provê informação de formação homogênea para a ANN. Uma formação homogênea é grossa bastante que a ferramenta
15 mede só a formação a um ponto particular na cavidade de poço. Quer dizer, o campo da bobina de transmissor de fato ou efetivamente passa só por uma formação de resistividade essencialmente uniforme. Na Figura 6, isto é simulado nas faixas de profundidade de - 3 m a +3 m e de 42 m a 48 m. O modelo tem uma resistividade de 10 ohm-m nestas faixas. Mas, o sinal de
20 ferramenta 68 indica uma resistividade de cerca de 11 ohm-m. A diferença é causada pelo efeito pelicular. Em teste anterior da presente invenção, modelos homogêneos separados a vários níveis de resistividade foram usados no conjunto de treinamento como um modo de ensinar à ANN o efeito pelicular a vários níveis de resistividade. Isto foi achado não ser essencial,
25 provavelmente porque a ANN aprende bastante informação relativa às formações homogêneas de partes de modelos do tipo da Figura 6.

A ANN foi treinada como discutido acima para vários ângulos de inclinação. Ela foi então testada introduzindo outros sinais de registro, ambos sintético e real. Como foi feito durante o processo de treinamento, os

logaritmos de sinais de condutividade de ferramenta foram introduzidos à ANN treinada, e a exponencial da saída de ANN foi tomada como a representação de condutividade de formação. Resultados de inversão bons foram alcançados essencialmente em todos os casos, incluindo dados
5 sintéticos que representam formações não no conjunto de treinamento como também dados de registros reais de áreas geográficas diferentes. Figuras 7 e 8 são representativas dos resultados alcançados. Em ambas as Figuras 7 e 8, o mesmo perfil de formação sintético 70 foi usado. Na Figura 7, o sinal de registro 72 era para um caso de inclinação zero. Na Figura 8, os dados de
10 registro 74 eram para uma inclinação de 55° . A diferença entre respostas de ferramenta é aparente. Porém, em ambos os casos, a inversão de ANN, 76 e 78, do sinal de ferramenta proximamente casa com o modelo de formação.

Uma formação de teste sintético mais complexa é ilustrada na Figura 9. Este é um modelo bidimensional no qual a resistividade verdadeira é
15 mostrada pelo gráfico de linha sólida 80. Em um caso bidimensional, partes da formação perto da cavidade de poço foram invadidas por fluido de perfuração que muda a resistividade na zona invadida. No gráfico de linha pontilhada 82, uma parte da formação foi invadida por lama de perfuração a uma profundidade de 0,76 m do furo de sondagem abaixando a resistividade
20 de 60 ohm-m para 10 ohm-m. No gráfico de linha pontilhada 84, uma parte da formação foi invadida por lama de perfuração a uma profundidade de 1m da cavidade de poço abaixando a resistividade de 50 ohm-m a cerca de 15 ohm-m. Este modelo foi usado para produzir registros sintéticos para espaçamentos de transmissor-receptor raso, médio e fundo. Os registros sintéticos foram
25 então processados por ANNs treinadas como publicado acima, uma ANN para cada receptor. Os resultados deste teste são mostrados na Figura 10. Os resultados raso, médio e fundo são mostrados pelas curvas 86, 88 e 90. A curva rasa 86 está próxima à resistividade das zonas invadidas, porque a maioria do sinal medido pelo receptor raso se origina na região perto do furo

de sondagem. A curva funda 90 está próxima à resistividade da formação não invadida, porque muito de suas medições de sinal se aprofundam na formação. A curva de profundidade média 88 está entre, como esperado. Métodos conhecidos de ademais processar as curvas 86, 88 e 90 podem
5 prover uma boa estimativa da profundidade da zona invadida. Este teste ilustra que uma ANN treinada como especificado aqui é adequada para processar sinais de ferramenta de registro de formações bidimensionais, embora nenhum dado bidimensional tenha sido usado no conjunto de dados de modelo de treinamento. Porém, se desejado, a ANN pode ser treinada
10 usando modelos bidimensionais. Solucionadores dianteiros para ferramentas de registro podem produzir a resposta sintética para os modelos bidimensionais que são precisados para o processo de treinamento. Caso contrário, o processo de treinamento é o mesmo como para modelos unidimensionais. Em alguns casos, ANNs treinadas com modelos
15 bidimensionais e tridimensionais podem dar melhores resultados.

As saídas de ANN, tais como aquelas mostradas nas Figuras 7, 8 e 10, não são representações perfeitas das formações desejadas. Em um esforço para reduzir os erros, várias ANNs foram treinadas com o mesmo conjunto de treinamento para produzir vários conjuntos diferentes de
20 coeficientes. Isto pode ser feito treinando ANNs tendo a mesma estrutura com os conjuntos de dados idênticos, mas com condições iniciais diferentes para os coeficientes de rede. Alternativamente, a estrutura da ANN pode ser modificada ligeiramente antes de treinamento. Em qualquer caso, os coeficientes finais são diferentes e os erros inerentes são diferentes. As
25 múltiplas ANNs treinadas foram usadas para processar os mesmos dados de teste e os resultados foram combinados. Os erros inerentes nas saídas foram diferentes e portanto se cancelaram até certo ponto. As saídas combinadas proveram uma representação mais precisa dos parâmetros de formação reais. Este processo de ANN múltiplas também ilustra que não há nenhuma

estrutura de ANN melhor ou conjunto de condições iniciais. Muitas combinações de estrutura e condições iniciais resultarão em coeficientes que provêm processamento de inversão aceitável.

Enquanto modelos de formação sintéticos particulares foram
5 usados na concretização exposta aqui, é aparente que outros modelos poderiam ser usados com sucesso semelhante se as regras de seleção básicas forem seguidas. O conjunto de treinamento deveria incluir modelos sintéticos que têm valores de parâmetro superior e inferior que abrangem os limites de faixa operacional superior e inferior da ferramenta de registro selecionada.
10 Várias versões de cada modelo deveriam ser incluídas com pelo menos uma tendo um valor de parâmetro superior próximo ao limite de faixa operacional superior da ferramenta e pelo menos uma tendo um valor de parâmetro inferior próximo ao limite de faixa operacional inferior da ferramenta de registro. Contrastes de parâmetro em interfaces de camada de leito deveriam
15 variar através de uma faixa que é realista em termos do que normalmente acontece em formações de terra reais, que para a concretização preferida era cerca de 10 para 1 a cerca de 100 para 1. Os modelos deveriam incluir espessuras de camada de leito variando de um máximo aproximadamente correspondendo à área medida pela ferramenta à espessura mínima que a
20 ferramenta selecionada pode analisar. Estas condições podem ser satisfeitas com um conjunto relativamente pequeno de modelos sintéticos, de forma que tempo de treinamento seja razoável. Usando só modelos sintéticos, todas as "regras" que a ANN "aprende" durante o processo de treinamento são precisas, que não é contaminada por medição ou outros erros. Como
25 resultado, as ANNs treinadas com estes tipos de conjuntos de treinamento são capazes de executar inversão direta de sinais de registro nos registros desejados de parâmetros de formação para dados essencialmente de qualquer área.

Ao desenvolver a presente invenção, ANNs foram

inicialmente treinadas com ambos sinais em fase e quadratura da ferramenta de registro e bons resultados foram alcançados. Porém, usando ambos os sinais reduziu a velocidade do projeto de desenvolvimento porque dobra as entradas à ANN durante o processo de treinamento e portanto aumenta o tempo e despesa envolvida. Geralmente, o sinal de quadratura para sinais de ferramenta de registro reais é mais ruidoso do que o sinal em fase. Foi decidido usar só o componente em fase para simplificar o desenvolvimento e processo de teste e para evitar a parte mais ruidosa dos dados reais. Os resultados indicam que isto era uma boa escolha para ferramentas de indução como a HRAI. Pode haver alguma formação incomum ou extrema para a qual pode ser necessário usar ambos os componentes, e portanto será necessário treinar uma ANN com ambos. Em processos de LWD ou MWD, é habitual usar ambos sinais em fase e quadratura para avaliar fase e atenuação e a ANN deveria ser treinada para ambos os sinais fazerem isto.

Como notado acima, ANNs separadas podem ser treinadas para cada conjunto de transmissor-receptor em uma ferramenta de registro. Na ferramenta de HRAI há seis espaçamentos diferentes e dez arranjos de receptor diferentes. Na concretização preferida, ANNs foram geradas para vários espaçamentos diferentes como ilustrado na Figura 10. Também é possível, e freqüentemente desejável, usar os sinais de dois ou mais dos espaçamentos para produzir um registro. Isto é feito freqüentemente para melhorar a qualidade da inversão. Combinando sinais de dois ou mais receptores, a parte não correlatada do ruído tende a se cancelar enquanto os sinais desejado reforçam. Uma ANN pode ser treinada para este propósito. Quer dizer, as saídas de solucionadores dianteiros para dois ou mais espaçamentos de transmissor-receptor podem ser usadas para treinar uma ANN, que então pode ser usada para processar sinais reais correspondentes para gerar um registro do parâmetro desejado.

A presente invenção foi desenvolvida e demonstrada usando

dados de condutividade de ferramenta de registro de indução de HRAI. A invenção é igualmente aplicável a outros dados produzidos por ferramentas de registro de indução, tais como medições de inclinação, incidência e anisotropia. Também é aplicável a dados de outros tipos de ferramentas de registro, tais como ferramentas elétricas, acústicas, magnéticas, de gravidade e nuclear (por exemplo, raio de nêutrons ou gama). É aplicável a ferramentas levadas em cadeias de broca como também aquelas suspensas por linhas de fios.

A Concretização de Rede de Junta Submetida

10 A prática comum para inversão de ANN de registros de indução de arranjo é usar uma seqüência de medições de resistividade aparente como entrada, para recuperar a resistividade de formação verdadeira no ponto central da janela de entrada. Nós demonstramos que esta arquitetura de múltipla entrada/saída única funciona bem para vários sub-arranjos de
15 espaçamento de transmissor-receptor curtos. Para sub-arranjos de espaçamento fundos, porém, a variância em predição com uma única ANN é relativamente alta. Isto é devido ao fato que as medições de arranjo fundo têm menos conteúdo de alta freqüência, maior efeito de leito de ombro, e não linearidade aumentada. Tipicamente, as regiões que circundam limites de leito
20 na formação se tornam mais difíceis de recuperar precisamente. Para melhorar a precisão dos modelos de inversão de ANN para sub-arranjos de espaçamento fundo, nós expomos uma nova arquitetura de rede neural, chamada a junta de rede submetida, junto com um método de "inspeção rápida" para significativamente reduzir a carga computacional de treinar a
25 junta de rede proposta.

Figura 11 mostra um fluxograma típico do uso de algoritmo de inversão de ANN no processamento dos dados de registro. Neste fluxograma, uma rede de múltipla entrada/saída única é usada para pesquisar a correlação transformada entre as sensibilidades aparentes de janela e a resistividade de

formação verdadeira referencial, onde a janela de entrada contém os mesmos pontos de medição acima e abaixo do centro de referência na profundidade vertical verdadeira com o erro no treinamento sendo avaliado a uma única posição, a posição da resistividade de saída que corresponde à posição do centro da janela de entrada. Sendo um problema mais difícil, devido a seu conteúdo de frequência mais baixo e não linearidade aumentada, a inversão das medições de sub-arranjo mais fundas é menos precisa. A incerteza ao modelar relação de entrada/saída com o uso da estrutura de janela fixa é uma das razões principais que causam variância na interpretação de dados de registro. Para resolver este problema complexo, a tecnologia atual permite-nos combinar várias redes juntas para formar uma junta. Os membros de junta poderiam ser selecionados de muitas redes distintas com vários pesos de estrutura/iniciais e treinados com conjuntos de dados diferentes. A saída de junta pode ser tomada como a saída média das várias redes únicas que incluem a junta. O problema com esta aproximação em interpretação de dados de registro de poço é o tempo de processamento. O número total de parâmetros em uma tal junta é a soma dos parâmetros de cada rede individual, e lidar com redes com arquiteturas diferentes requer mais manipulações de matriz que toma mais tempo em processamento em série, e precisa mais processadores em processamento paralelo. Também, treinar e manter rastro de várias redes diferentes aumentará a carga computacional e administrativa.

Nesta concretização, nós apresentamos um novo método para superar as limitações discutidas acima, e mostramos como melhora a interpretação de dados de registro. Esta concretização provê: uma nova relação de mapeamento de resistividade/resistividade verdadeira aparente; uma junta de rede submetida para estabelecer a relação presumida e reduzir a incerteza de saída; e, um método de treinamento de "inspeção rápida" para eficientemente treinar a junta de rede apresentada.

O método proposto nesta concretização pode ser aplicado para

melhorar o processamento de qualquer medição de registro com problemas semelhantes aos associados com os sub-arranjos fundos da ferramenta de HRAI. O método proposto deveria melhorar o processamento de dados de registro em cada situação, embora sendo relativamente mais demorado que o
5 procedimento de saída única padrão, nós recomendamos o novo método para os problemas relativamente mais difíceis, nos quais o uso do método padrão conduz a resultados de baixa qualidade. Mais geralmente, esta concretização é aplicável a sistema não causal incerto para o qual a saída $y(\mathbf{n}_0)$ depende das amostras de entrada $\mathbf{x}(\mathbf{n})$, para \mathbf{n} estendido em ambas as direções de \mathbf{n}_0 .
10 Muitas aplicações geofísicas estão entre esta categoria.

Nesta concretização, nós estabelecemos uma nova relação de mapeamento de entrada/saída para arranjos de espaçamento fundo ao processar dados de registro. Para as dadas entradas de rede, a saída de rede, que é a resistividade de formação recuperada, não é necessariamente mapeada
15 ao centro referencial somente. Poderia ser mapeada a qualquer ponto na vizinhança central. Predizendo a resistividade a várias posições, que formam uma janela de saída, e avaliando o erro no treinamento através do comprimento desta janela de saída, não só o erro no valor de saída, mas também o erro na inclinação de saída são penalizados, conduzindo a menos
20 variação na predição. Além disso, o novo procedimento gera tantas predições a cada posição quanto o número de pontos na janela de saída. Depois de calcular a média destas saídas, a variância é ademais reduzida. Esta relação pode ser implementada com uma rede avançada de multicamadas com saídas múltiplas, que é mostrado na Figura 12. Note que, cada saída tem conexões de
25 rede compartilhadas (pesos) na camada oculta. As conexões compartilhadas põem as restrições ao conjunto de saída. Esta arquitetura de rede permite cada nó de saída produzir sua seqüência de interpretação baseada na suposição de mapeamento ligeiramente diferente. Figura 13 mostra tais seqüências em um exemplo de cinco saídas, com cada seqüência sendo uma predição deslocada

da outra. Os modelos que simultaneamente extraem as resistividades de formação na vizinhança central constituem uma junta de rede submetida (CNC), e as saídas que se referem ao mesmo índice de TVD (profundidade vertical verdadeira) podem exibir uma variação observada, indicando a incerteza em interpretação de dados de registro. Para reduzir a incerteza de interpretação, a saída de CNC pode ser computada calculando a média de suas saídas de membro através da diagonal ao longo da qual as saídas têm o mesmo índice de TVD (veja Figura 13).

O problema associado com CNC é a carga computacional ao treinar a rede neural de multi-entradas/multi-saídas. Usando uma junta de rede de 11 membros por exemplo, o número total de parâmetros pode ser até 4.000, e os termos de erro envolvidos no algoritmo de otimização podem exceder 500.000 com um conjunto de treinamento moderado. Uma única tentativa de treinamento para este problema usando método tradicional custará mais de uma semana com capacidade de computador atual. Nesta concretização, um método de "inspeção rápida" foi desenvolvido para reduzir a carga computacional. Este método inicializa os parâmetros de rede de modos diferentes quando um novo modelo de sub-arranjo está pronto para treinar. As opções principais deste método de "inspeção rápida" são:

Inicializar um novo modelo de sub-arranjo com os pesos de rede do sub-arranjo adjacente treinado.

Inicializar um novo modelo de sub-arranjo de certa frequência com os pesos resultantes do mesmo sub-arranjo de frequência diferente.

Inicializar um novo modelo de sub-arranjo combinando seus pesos de rede prévios com pesos perto de zero recentemente adicionados ao aumentar o número de neurônios de entrada, ou neurônios ocultos, ou neurônios de saída são precisados.

A idéia de usar aproximação de "inspeção rápida" é baseada no fato que algum tipo de semelhança em resposta de ferramenta existe entre os

sub-arranjos adjacentes, ou mesmo sub-arranjo, mas frequências de excitação diferentes. Portanto, o treinamento inicializado por opção 1 e 2 de alguma maneira atua como um rescalonamento do mapeamento de entrada/saída, que normalmente cria um gradiente mais íngreme em redução de erro durante o
5 aprendizado iterativo. A aproximação descrita na opção 3 pode fazer a precisão de partida de treinamento do novo modelo tão próxima quanto o modelo prévio, que melhorará significativamente a eficiência de treinamento.

A nova aproximação tem as seguintes vantagens:

10 A CNC provê um método promissor para reduzir a incerteza causada por limitação de ferramenta, e efeitos ambientais em interpretação de dados de registro. A redução em erro pode ser vista como surgindo da variância reduzida devido ao calculo de média através de muitas soluções.

15 A CNC pode ser manipulada usando uma única rede neural avançada de multicamadas que é efetivo em custo com velocidade de processamento competitiva.

Como a CNC gera os pesos compartilhados e saída calculada em média, normalmente produz predição uniforme. Nenhuma outra técnica de regularização é precisada nesta aproximação, que permite a rede de junta ser treinada usando o algoritmo de treinamento rápido com menos preocupação
20 sobre sobre-adaptação.

O método de "inspeção rápida" pode reduzir a carga computacional com o método de inicialização tradicional até 60 por cento.

25 Processar registros de indução de arranjo com junta de rede submetida é ilustrado na Figura 14. Neste fluxograma, os dados de registro (resistividade normalmente aparente) de um certo sub-arranjo são formatados para encher a janela de entrada. Então, uma transformação de pré-processamento aos dados de entrada é aplicada antes que seja apresentada à rede de CNC. A rede de CNC funciona como um filtro não linear, e é treinada com dados de simulação que são descritos em nossa publicação prévia. A

saída de CNC alimenta por um procedimento de pós-processamento antes de prover ao cliente.

Para a rede de CNC, a janela de entrada normalmente cobre informação sobre medições de 7,5 m a 15 m com respeito ao TVD. Uma saída de 11 nós (correspondendo a 11 membros de junta) é preferida com intervalo de 7,5 cm no meio, que constitui uma janela de saída de 0,75 m. Para a aplicação de leito de alta inclinação, a janela de saída com comprimento semelhante em distância vertical verdadeira é preferida. Este tamanho de janela provê ótimo compromisso entre tendência de predição e variância, e permite carga computacional razoável durante o treinamento. A saída de CNC tanto pode ser soma média ou ponderada através das saídas de membro tendo o mesmo índice de TVD.

Nesta seção, nós primeiro ilustramos os resultados de teste ao processar registros simulados, para os quais as resistividades de formação verdadeiras são conhecidas, com rede de CNC e rede de saída única respectivamente. Então, nós demonstramos que o método de "inspeção rápida" realmente reduz significativamente a carga computacional ao treinar a rede de CNC.

Figura 15 apresenta uma comparação de desempenho da rede de CNC e da rede de saída única padrão para sub-arranjo 1, usando os dados de treinamento de frequência de 8 kHz simulados da geometria de inclinação zero. O perfil de formação utilizado aqui é um arquivo de teste que é excluído dos padrões de treinamento. Não é difícil identificar pela inspeção visual que a rede de CNC produz a predição que gera melhor que a rede de saída única.

O outro exemplo é dado na Figura 16 para aplicação de leito inclinado, testado com modelos de sub-arranjo 1 e dados de 8 kHz. O arquivo de teste tem a forma como formação de Oklahoma, que é o problema de referência padrão para avaliação de desempenho. A mesma conclusão pode ser tirada deste teste que a interpretação de medição usando rede de CNC é

menos excursiva dentro dos leitos e mais consistente com resistividade de formação verdadeira.

Figura 17 ilustra uma trajetória do erro de treinamento contra o número de iterações para uma rede de CNC, usando os exemplos de treinamento do sub-arranjo 2, frequência de excitação de 8 kHz e ângulo de inclinação zero. A rede 101-20-40-11 escolhida é inicializada com método padrão e treinada com algoritmo de gradiente conjugado graduado (SCG).
5
Leva cerca de 2.000 iterações para reduzir o erro médio quadrático (mse) para 0,006, e ainda precisa mais iterações para adquirir a precisão de treinamento adequada.
10

Em comparação, Figura 18 mostra a taxa de redução de erro do método de "inspeção rápida". A rede de CNC com mesma arquitetura é treinada com mesmo algoritmo usando os mesmos exemplos. A diferença aqui é o modo para inicializar os parâmetros de rede. Os pesos iniciais usados nesta tentativa de treinamento são os pesos resultantes da rede de CNC para o mesmo sub-arranjo, mas frequência de excitação diferente (32 kHz). Nós podemos ver que embora o erro de treinamento de partida na Figura 18 esteja perto de Figura 17, leva só 200 iterações na Figura 18 para alcançar a precisão de treinamento muito melhor como ilustrado na Figura 17.
15

Figura 19 apresenta outro exemplo usando uma opção diferente do método de "inspeção rápida". A rede de CNC é treinada para sub-arranjo 1 sob frequência de excitação de 32 kHz e ângulo de inclinação zero, mas inicializada com pesos resultantes da rede de CNC de sub-arranjo 2. O treinamento leva 400 iterações para alcançar a precisão exibida, que normalmente precisa mais de cinco mil iterações para treinar usando o método de inicialização padrão.
20
25

É aparente que várias mudanças podem ser feitas no aparelho e métodos expostos aqui, sem partir da extensão da invenção como definida pelas reivindicações anexas.

REIVINDICAÇÕES

1. Aparelho para converter os sinais de saída de uma ferramenta de registro em um registro que representa um parâmetro de formações de terra circundando um furo de sondagem, compreendendo:

5 uma rede neural artificial treinada com um conjunto de modelos de formação de terra sintéticos selecionados para cobrir a faixa operacional de uma ferramenta de registro selecionada com base em limites de sensibilidade e resolução da ferramenta de registro e com base em faixas realistas de parâmetros de formação,

10 onde os sinais de saída da ferramenta de registro são uma série de amostras, cada uma representando o sinal num ponto de profundidade no furo de sondagem, e onde a rede neural tem uma pluralidade de entradas que recebem aquelas amostras a partir de uma faixa de profundidades no furo de sondagem,

15 caracterizado pelo fato de que a rede neural artificial tem uma pluralidade de saídas, cada uma produzindo um sinal de saída representando um ponto de profundidade diferente no furo de sondagem, e um meio para combinar as saídas da rede neural de acordo com pontos de profundidade para produzir um registro médio de um parâmetro de formação.

20 2. Aparelho de acordo com a reivindicação 1, caracterizado pelo fato de que a rede neural artificial treinada com um conjunto de modelos de formação de terra sintéticos compreende:

25 a) uma pluralidade de modelos de chilo tendo espessuras de camada continuamente crescentes, cada modelo de chilo tendo contrastes de parâmetro em interfaces de camada limitadas a contrastes realistas achados em formações de terra reais, pelo menos um modelo com um limite de parâmetro superior perto do limite superior da faixa operacional da ferramenta selecionada, e pelo menos um modelo com um limite de parâmetro inferior perto do limite inferior da faixa operacional da ferramenta selecionada, e

b) uma pluralidade de modelos tipo Oklahoma com contrastes de parâmetro em interfaces de camada limitadas a contrastes realistas achados em formações de terra reais, pelo menos um modelo tendo um limite de parâmetro superior perto do limite superior da faixa operacional da ferramenta selecionada, e pelo menos um modelo tendo um limite de parâmetro inferior perto do limite inferior da faixa operacional da ferramenta selecionada.

3. Aparelho de acordo com a reivindicação 2, caracterizado pelo fato de que a ferramenta de registro é uma ferramenta de registro de indução tendo uma relação de sensibilidade máxima para sensibilidade mínima de cerca de 10.000 para 1 e os modelos de chilo incluem pelo menos um modelo com contrastes de parâmetro em interfaces de camada de cerca de 10 para 1 e pelo menos um modelo com contrastes de parâmetro em interfaces de camada de cerca de 100 para 1.

4. Aparelho de acordo com a reivindicação 2, caracterizado pelo fato de que a ferramenta de registro é uma ferramenta de registro de indução tendo uma relação de sensibilidade máxima para sensibilidade mínima de cerca de 10.000 para 1 e os modelos tipo Oklahoma têm contrastes de parâmetro em interfaces de camada de cerca de 10 para 1 a cerca de 100 para 1.

5. Método para converter os sinais de saída de uma ferramenta de registro em um registro que representa um parâmetro de formações de terra circundando um furo de sondagem, compreendendo:

criar um conjunto de modelos de formação de terra sintéticos, compreendendo:

a) uma pluralidade de modelos de chilo tendo espessuras de camada continuamente crescentes, cada modelo de chilo tendo contrastes de parâmetro em interfaces de camada limitadas a contrastes realistas achados em formações de terra reais, pelo menos um modelo com um limite de parâmetro superior perto do limite superior da faixa operacional da ferramenta selecionada, e pelo menos um modelo com um limite de parâmetro inferior perto do limite

inferior da faixa operacional da ferramenta selecionada, e

b) uma pluralidade de modelos tipo Oklahoma com contrastes de parâmetro em interfaces de camada limitadas a contrastes realistas achados em formações de terra reais, pelo menos um modelo tendo um limite de parâmetro superior perto do limite superior da faixa operacional da ferramenta selecionada, e pelo menos um modelo tendo um limite de parâmetro inferior perto do limite inferior da faixa operacional da ferramenta selecionada;

gerar respostas sintéticas da ferramenta selecionada para cada um dos modelos de formação artificial;

10 usar as respostas sintéticas e os modelos de formação para treinar uma rede neural artificial para gerar representações dos modelos de formação em resposta às respostas sintéticas; e

15 processar sinais de registro reais da ferramenta selecionada com a rede neural treinada para produzir um registro do parâmetro de terra, caracterizado pelo fato de que no processamento a rede neural artificial tem uma pluralidade de saídas, cada uma produzindo um sinal de saída representando um ponto de profundidade diferente no furo de sondagem, com o método compreendendo adicionalmente:

20 combinar aquelas saídas da rede neural de acordo com pontos de profundidade para produzir um registro médio de um parâmetro de formação.

6. Método de acordo com a reivindicação 5, caracterizado pelo fato de que a ferramenta de registro é uma ferramenta de registro de indução tendo uma relação de sensibilidade máxima para sensibilidade mínima de cerca de 10.000 para 1 e os modelos de chilo incluem pelo menos um modelo com contrastes de parâmetro em interfaces de camada de cerca de 10 para 1 e pelo menos um modelo com contrastes de parâmetro em interfaces de camada de cerca de 100 para 1.

7. Método de acordo com a reivindicação 5, caracterizado pelo

fato de que a ferramenta de registro é uma ferramenta de registro de indução tendo uma relação de sensibilidade máxima para sensibilidade mínima de cerca de 10.000 para 1 e os modelos tipo Oklahoma têm contrastes de parâmetro em interfaces de camada de cerca de 10 para 1 a cerca de 100 para 1.

5 8. Método de acordo com a reivindicação 5, caracterizado pelo fato de que compreende adicionalmente:


 usar as respostas sintéticas e modelos de formação para treinar uma ou mais redes neurais artificiais adicionais para gerar representações dos modelos de formação em resposta às respostas sintéticas;

10 processar os sinais de registro reais da ferramenta selecionada com a rede ou redes neurais treinadas adicionais para produzir um registro ou registros adicionais do parâmetro de terra; e,

 combinar os registros do parâmetro de terra para produzir um registro médio do parâmetro de terra.

15 9. Método de acordo com a reivindicação 5, caracterizado pelo fato de que a ferramenta de registro selecionada é uma ferramenta de registro de indução com mais de um par de transmissor-receptor e as respostas sintéticas da ferramenta selecionada incluem respostas de mais de um par de transmissor-receptor.

20 10. Método de acordo com a reivindicação 5, caracterizado pelo fato de que a ferramenta de registro selecionada é uma ferramenta de registro de indução tendo ambos sinais de saída em fase e em quadratura e as respostas sintéticas da ferramenta selecionada incluem ambos os sinais.






FIG.2




FIG.3a




FIG.3b

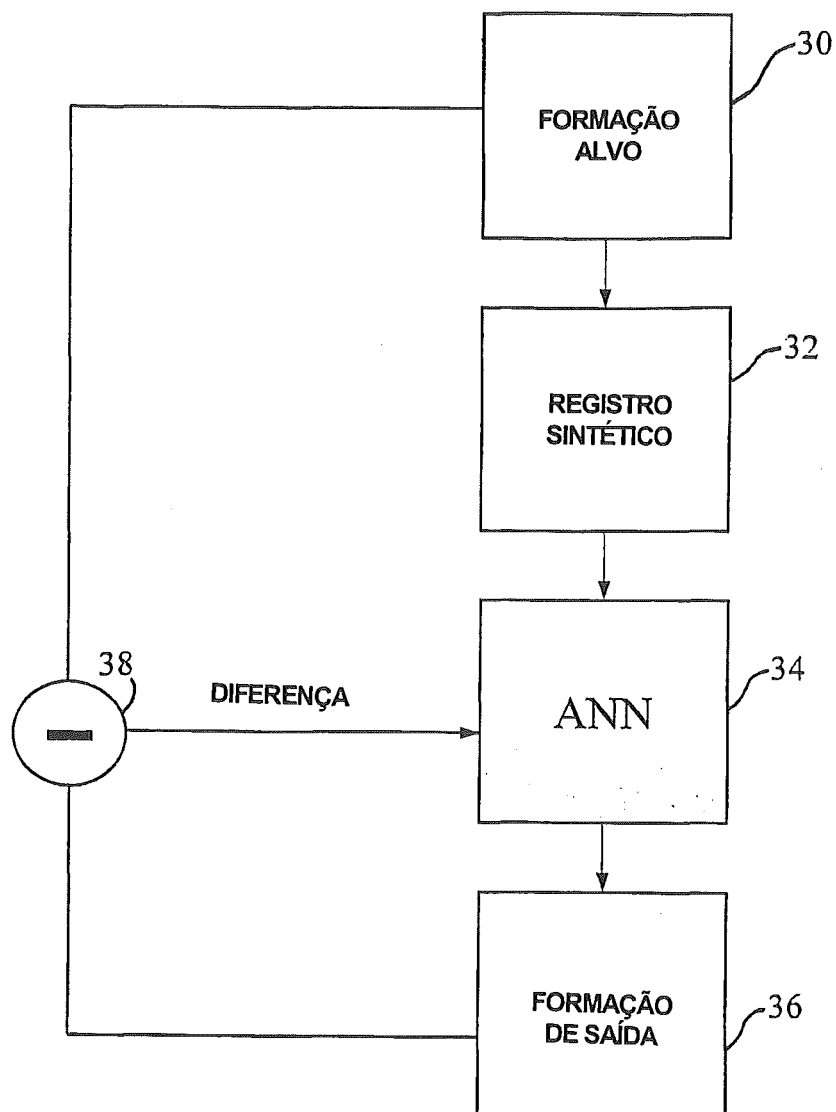


FIG.4




FIG.5

FORMAÇÃO DE CHILRO




FIG.6

INVERSÃO DE SUB-ARRANJO TÍPICA
ARRANJO MÉDIO, INCLINAÇÃO = 0 [GRAUS]




FIG.7

INVERSÃO DE LEITO INCLINADO
SUB-ARRANJO FUNDO, INCLINAÇÃO = 55 [GRAUS]




FIG.8




FIG.9




FIG.10

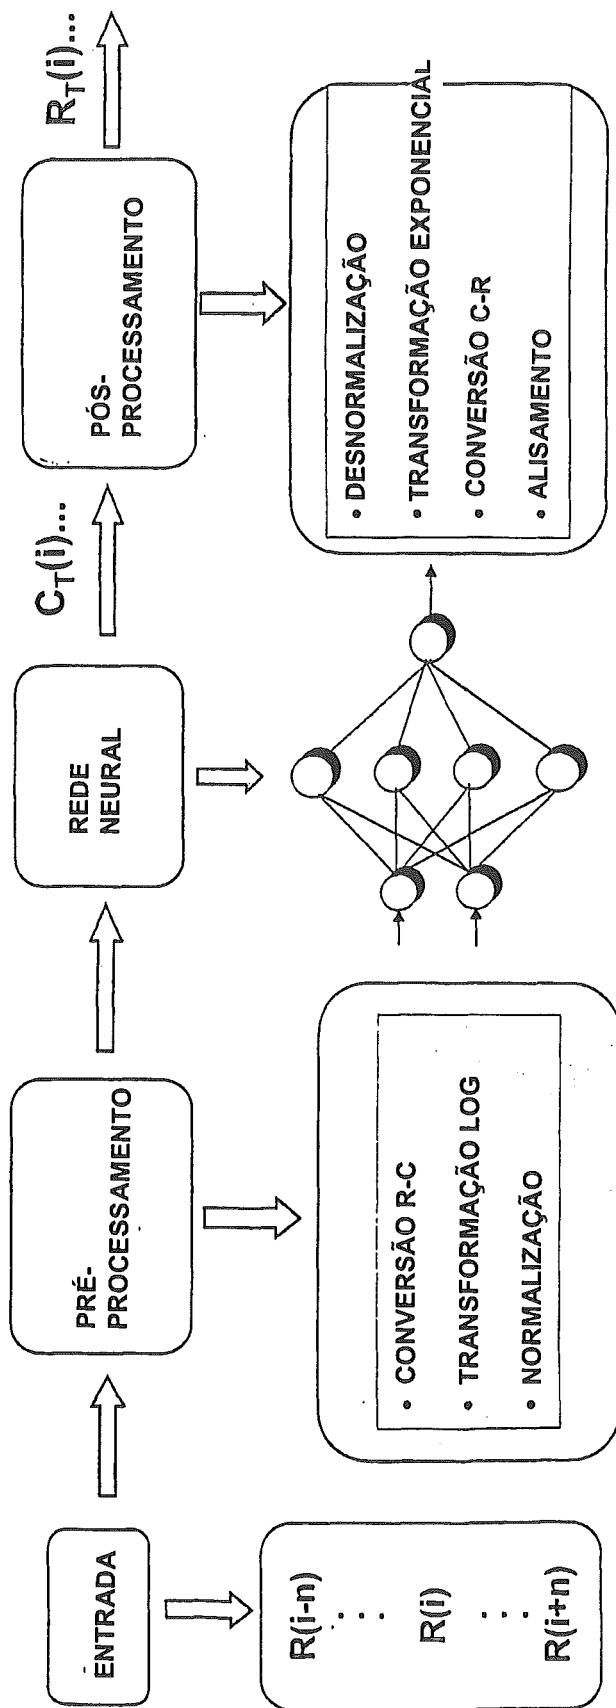


FIG.11




FIG.12




FIG.13

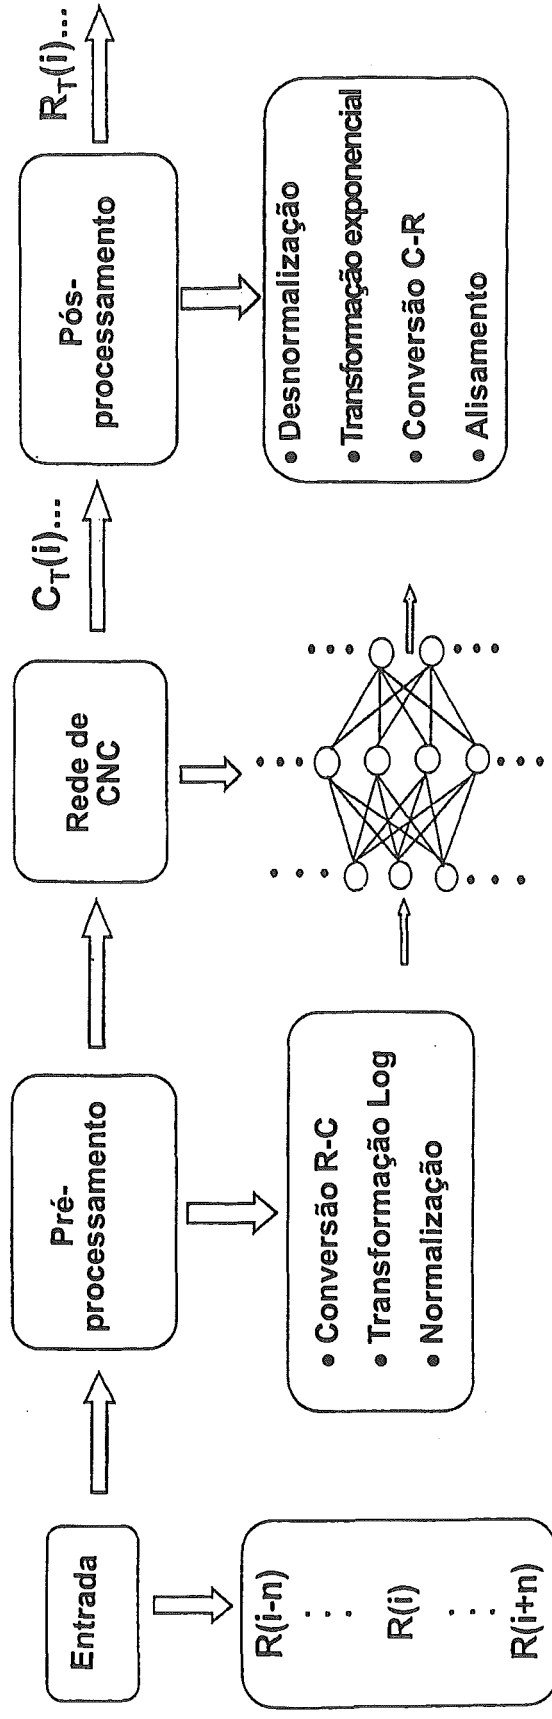


FIG.14





FIG.15





FIG.16




FIG.17




FIG.18




FIG.19

RESUMO

“APARELHO E MÉTODO PARA CONVERTER OS SINAIS DE SAÍDA DE UMA FERRAMENTA DE REGISTRO”

Uma rede neural artificial, ANN, e método de treinar a ANN para inversão de sinais de ferramenta de registro em registros de poço de parâmetros de formação são expostos. Modelos sintéticos corretamente selecionados de formações de terra são usados para treinar a ANN. Os modelos incluem tipo de formações de Oklahoma e de chilo. Em cada modelo, contrastes de parâmetro de 10 para 1 a cerca de 100 para 1 são incluídos. Modelos incluindo valores de parâmetro máximo e mínimo abrangendo a faixa operacional da ferramenta de registro selecionada são incluídos. Contrastes de parâmetro a interfaces são limitados a valores realistas achados em formações de terra. Os modelos selecionados são usados para gerar sinais de ferramenta sintéticos, que são então usados como entradas à ANN para treinamento. Quando os coeficientes de ANN são corretamente ajustados para produzir uma saída que casa com os modelos originais, a ANN pode ser usada para inversão de qualquer sinal real da ferramenta de registro selecionada.