



COPPE/UFRJ

INTELIGÊNCIA COMPUTACIONAL NA ESTIMATIVA DA PERMEABILIDADE
DE RESERVATÓRIOS DE PETRÓLEO A PARTIR DE PERFIS DE RESSONÂNCIA
MAGNÉTICA NUCLEAR

Vinicius de França Machado

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Civil.

Orientadores: Nelson Francisco Favilla Ebecken

Rodrigo Bagueira de Vasconcellos
Azeredo

Rio de Janeiro
Fevereiro de 2010

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

INTELIGÊNCIA COMPUTACIONAL NA ESTIMATIVA DA PERMEABILIDADE
DE RESERVATÓRIOS DE PETRÓLEO A PARTIR DE PERFIS DE RESSONÂNCIA
MAGNÉTICA NUCLEAR

Vinicius de França Machado

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM CIÊNCIAS EM ENGENHARIA CIVIL.

Examinada por:

Prof. Nelson Francisco Favilla Ebecken, D.Sc

Prof. Rodrigo Bagueira de Vasconcellos Azeredo, D.Sc

Prof. Luiz Landau, D.Sc.

Prof^a. Valéria Menezes Bastos, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

FEVEREIRO DE 2010

Machado, Vinicius de França

Inteligência Computacional na Estimativa de Permeabilidade de Reservatórios de Petróleo a Partir de Perfis de Ressonância Magnética Nuclear – Rio de Janeiro: UFRJ/COPPE, 2010.

IX, 60 p.: il.; 29,7 cm.

Orientadores: Nelson Francisco Favilla Ebecken

Rodrigo Bagueira de Vasconcellos

Azeredo

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Civil, 2010.

Referencias Bibliográficas: p. 59-60.

1. Redes Neurais Artificiais. 2. Tecnologias de Reservatórios de Petróleo. 3. Mineração de Dados. I. Ebecken, Nelson Francisco Favilla et al. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Civil. III. Título.

Agradecimentos

Aos meus pais Celinha e Lu por tudo e sempre.

Aos professores Nelson Ebecken e Rodrigo Bagueira pelo incentivo e orientação positiva dada ao desenvolvimento deste trabalho.

Ao amigo Renato Travassos, o Rei, aos companheiros de trabalho Cristiano Sombra pelas discussões acerca do assunto e André Compan pela inestimável ajuda no trato com os processadores de texto e planilhas eletrônicas.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

INTELIGÊNCIA COMPUTACIONAL NA ESTIMATIVA DA PERMEABILIDADE
DE RESERVATÓRIOS DE PETRÓLEO A PARTIR DE PERFIS DE RESSONÂNCIA
MAGNÉTICA NUCLEAR

Vinicius de França Machado

Fevereiro/ 2010

Orientadores: Nelson Francisco Favilla Ebecken

Rodrigo Bagueira de Vasconcellos Azeredo

Programa: Engenharia Civil

Na engenharia de reservatórios de petróleo a caracterização petrofísica determina propriedades físicas e químicas do sistema rocha-fluido utilizadas para se inferir a capacidade de produção das jazidas. A permeabilidade absoluta das rochas mede sua capacidade de se deixar atravessar por um fluido. Entre as diversas formas de se estimá-la há as que utilizam os perfis de Ressonância Magnética Nuclear (RMN). Suas soluções não são dadas pela aplicação direta da Lei de Darcy, mas por equações empíricas que relacionam a permeabilidade aos parâmetros obtidos pelo perfil.

O estudo desenvolve um algoritmo de Redes Neurais Artificiais (RNA) para modelagem de permeabilidade por perfis RMN. São selecionados três reservatórios cujos dados de perfil e laboratório são reunidos para treinamento e teste das redes. Os resultados de permeabilidade modelados apresentam muito boa aderência aos reais, com desempenho superior aos modelos clássicos de Kenyon and Timur-Coates.

O sucesso no uso de RNA é função da forte não linearidade do problema proposto, da exploração mais eficiente das informações presentes na assinatura do perfil de RMN e do o melhor tratamento dado aos ruídos provenientes da ferramenta e do ambiente de perfilagem.

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

COMPUTACIONAL INTELIGENCE ON THE PETROLEUM RESERVOIR
PERMEABILITY ESTIMATIVE USING NUCLEAR MAGNETIC RESONANCE
LOGGING TOOL

Vinicius de França Machado

February/ 2010

Advisors: Nelson Francisco Favilla Ebecken

Rodrigo Bagueira de Vasconcellos Azeredo

Department: Civil Engineering

In the petroleum reservoir engineering, the petrophysical characterization determines rock and fluids' physical and chemical properties to be used in the flow capacity assessment of oil fields. The rock absolute permeability (K) defines the ability of a rock to transmit fluids. Among the different ways to estimate the permeability some use the Nuclear Magnetic Resonance (NMR) logs. Their solutions are not given by direct application of Darcy's Law, but by empirical equations that correlate the permeability to parameters retrieved from the log.

The study develops an Artificial Neural Networks (ANN) algorithm for permeability modeling using NMR logs. Three reservoirs were selected, its logs and laboratory were gathered for the network training and testing. The modeled permeability data presented very good adherence to real one, with superior results when compared to the Kenyon and Timur-Coates classical equations.

Successful application of NMR has to do with the strong nonlinearity of the proposed study, to the more efficient exploration of the NMR log data and to the better treatment given to the noise coming from the tool and the logging environment.

INDICE GERAL

1	Introdução	1
2	Caracterização Petrofísica de Rochas Reservatórios	2
2.1	Conceitos Gerais	2
2.2	Modelagem da Permeabilidade na Caracterização de Reservatórios	3
3	Princípios Básicos da RMN	8
3.1	Propriedades do Núcleo Atômico	8
3.2	Ressonância e sinal de RMN.....	13
3.3	Relaxação Transversal	14
4	RMN em Rochas Reservatórios de Petróleo.....	18
4.1	Mecanismos de Relaxação em Meios Porosos	18
4.2	Aplicações de Perfis de RMN em caracterização de reservatórios	23
4.3	Modelagem da Permeabilidade por Perfis RMN	25
5	Inteligencia Computacional	28
5.1	Conceitos Gerais	28
5.2	Redes Neurais Artificiais	29
6	Estudo de Caso de Modelagem da Permeabilidade	35
6.1	Metodologia de pesquisa	35
6.2	Permeabilidade de Rocha.....	36
6.3	Espectro de T_2	40
6.4	Modelos Classicos de Permeabilidade de Perfil RMN.....	43
6.5	Modelo de Rede Neural Artificial para Permeabilidade RMN	50
6.6	Comentários Finais.....	56
7	Conclusões e Recomendações.....	57

INDICE DE FIGURAS

Figura 1 - Fontes de informações para a caracterização de reservatórios de petróleo	3
Figura 2 - Representação pictórica do momento magnético μ	8
Figura 3 - Representação pictórica do spin nuclear I	9
Figura 4 - Representação dos níveis de energia de spin nuclear.....	10
Figura 5 - Representação vetorial do um núcleo atômico e seu momento magnético nuclear em precessão ao redor do campo B_0	11

Figura 6 - Representação vetorial de precessão de um conjunto de momentos magnéticos ao redor do campo B_0 a) referencial fixo b) referencial rotativo.....	12
Figura 7 - Representação vetorial da aplicação de um pulso de 90° sobre a magnetização M_0 .	13
Figura 8 - Representação vetorial da indução do sinal de RMN 1) amplitude máxima, $M_{xy}(0)=M_0$ e $M_z(0)=0$; 2) amplitude intermediária, $M_{xy}(t)=M$; 3) amplitude zero, $M_{xy}(t)=0$ e $M_z(t)=M_0$.	14
Figura 9 - Representação esquemática do processo de defasagem e refocalização da magnetização transversal, e formação do sinal de eco de spin.....	16
Figura 10 - Diagrama da seqüência de pulsos CPMG.....	16
Figura 11 - Curva de relaxação transversal (T_2) obtida através da técnica CPMG.	17
Figura 12 - Esquema de decaimentos uni e multiexponencial	21
Figura 13 - Dados brutos de decaimento exponencial de RMN e inversão para determinação de espectro de T_2	22
Figura 14 - Relação do espectro de T_2 com a distribuição de tamanho de poros	24
Figura 15 - Aplicação do T_2 de corte, separação entre fluido livre e fluido aprisionado por forças capilares.	25
Figura 16 – Classificação de algoritmos de mineração de dados	29
Figura 17 – Modelo de neurônio de rede neural artificial.....	30
Figura 18 – Função de limiar	31
Figura 19 – Função linear	31
Figura 20 – Função sigmóide	31
Figura 21 – Exemplo de arquitetura de rede neural artificial.....	31
Figura 22 – Arquitetura típica de rede MLP	34
Figura 23 – Perfil de permeabilidade do Poço I	37
Figura 24 – Histograma de K rocha do Poço I	37
Figura 25 – Perfil de permeabilidade do Poço II.....	38
Figura 26 – Histograma de K rocha do Poço II.....	38
Figura 27 – Perfil de permeabilidade do Poço II.....	39
Figura 28 – Histograma de K rocha do Poço III.....	39
Figura 29 – Espectro de T_2 do Poço I.....	40
Figura 30 – Média e desvio padrão dos espectros de T_2 do Poço I.....	40
Figura 31 – Espectro de T_2 do Poço II.....	41
Figura 32 – Média e desvio padrão dos Espectros de T_2 do Poço II.....	41
Figura 33 – Espectro de T_2 do Poço III	42

Figura 34 – Média e desvio padrão dos Espectros de T_2 do Poço III.....	42
Figura 35 – Perfis K rocha, K SDR e K Timur do Poço I	45
Figura 36 – Histograma de K rocha, K SDR e K TIM do Poço I.....	45
Figura 37 – Perfis K rocha, K SDR e K Timur do Poço II	46
Figura 38 – Histograma de K rocha, K SDR e K TIM do Poço II.....	47
Figura 39 – Perfis K rocha, K SDR e K Timur do Poço III	48
Figura 40 – Histograma de K rocha, K SDR e K TIM do Poço III.....	49
Figura 41 – Representação da rede neural utilizada na modelagem	51
Figura 42 – Perfis K rocha e K RNA do Poço I	52
Figura 43 – Histograma de K rocha e K RNA do Poço I	52
Figura 44 – Perfis K rocha e K RNA do Poço II	53
Figura 45 – Histograma de K rocha e K RNA do Poço II	53
Figura 46 – Perfis K rocha e K RNA do Poço III.....	54
Figura 47 – Histograma de K rocha e K RNA do Poço III.....	54
Figura 48 – Perfis K rocha e K RNA em toda a extensão do Poço I.....	55
Figura 49 – Perfis K rocha e K RNA em toda a extensão do Poço II	55
Figura 50 – Perfis K rocha e K RNA em toda a extensão do Poço III.....	55

INDICE DE TABELAS

Tabela 1 – Estatística descritiva do Poço I.....	37
Tabela 2 – Estatística descritiva do Poço II	38
Tabela 3 – Estatística descritiva do Poço III	39
Tabela 4 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço I	45
Tabela 5 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço II	47
Tabela 6 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço III.....	48
Tabela 7 – Seleção das variáveis dependentes no espectro de T_2	50
Tabela 8 – Estatística Descritiva de K rocha e K RNA do Poço I.....	52
Tabela 9 – Estatística Descritiva de K rocha e K RNA do Poço II.....	53
Tabela 10 – Estatística Descritiva de K rocha e K RNA do Poço III.....	54

1 INTRODUÇÃO

Na engenharia de reservatórios de petróleo, a caracterização petrofísica é a disciplina responsável pela atribuição das propriedades físicas e químicas do sistema rocha fluido que serão modeladas para se inferir a capacidade de armazenamento e de produção das jazidas ^{1,2}.

As informações para caracterização petrofísica vêm de diversas fontes de informação e escalas de medição, entre elas a aquisição de perfis elétricos de poços e a recuperação e análise laboratorial de amostras de rocha de subsolo. Dos parâmetros petrofísicos mais importantes a permeabilidade absoluta (K) da rocha é definida como a medida da sua capacidade de se deixar atravessar por um fluido.

O objetivo deste trabalho é o desenvolvimento de modelo de estimativa de permeabilidade absoluta de rochas com uso das informações do perfil de Ressonância Magnética Nuclear (RMN). Embora sua criação remonte a década de 60 do século passado os perfis RMN tiveram oferta comercial somente a partir da década de 90. Por isto é considerada uma tecnologia recente e com amplas possibilidades de avanços, seja no projeto das ferramentas, nos métodos de aquisição e processamento, na modelagem e interpretação dos dados.

As equações clássicas de permeabilidade RMN de Kenyon^{3,4} e Timur-Coates^{5,6} usam a premissa de que o dado do perfil, chamado espectro de relaxação transversal (espectro T_2), representa a distribuição de tamanho de poros da zona investigada. Tais modelos possuem formulação simplificada, como será visto adiante, seu desempenho é bem reconhecido em rochas homogêneas o que não ocorre em se tratando de rochas de estruturas porosas mais complexas, como alguns tipos de rochas carbonáticas⁷.

O modelo proposto faz uso de inteligência computacional para explorar plenamente as informações do espectro de T_2 do perfil RMN. É desenvolvido um modelo de Rede Neural Artificial (RNA) com dados reais de três reservatórios de estrutura porosa complexa. Para treinamento e teste da rede as variáveis preditoras são os pares ordenados que formam o espectro de T_2 e as variáveis preditas são os valores de permeabilidade de rochas, ensaiadas em laboratório a partir de material recuperado do subsolo.

2 CARACTERIZAÇÃO PETROFÍSICA DE ROCHAS RESERVATÓRIOS

2.1 CONCEITOS GERAIS

Caracterização petrofísica envolve a definição de parâmetros físicos e químicos do sistema rocha fluido. Entre os parâmetros petrofísicos mais importantes podemos destacar:

- A porosidade da rocha;
- A permeabilidade absoluta da rocha;
- A saturação de fluidos;
- As forças capilares;
- As permeabilidades efetivas de cada fluido

As informações para caracterização petrofísica vêm de diversas fontes e escalas de informação. Entre as fontes mais importantes de parâmetros de petrofísica estão:

- A pesquisa geofísica;
- Os testes de formação;
- Os perfis elétricos;
- A descrição e os ensaios em testemunhos de rochas: Petrofísicos, Petrográficos e Sedimentológicos.

Os dados vindos das diferentes fontes são integrados e mutuamente calibrados para formação de um modelo único, o modelo geológico do reservatório. Pelas características de cada fonte, em geral pode-se considerar que as medidas em maior escala são mais representativas e menos acuradas, enquanto que as medidas em menor escala são pouco representativas e mais acuradas.

O processo de modelagem geológica pressupõe calibração iterativa entre as fontes num processo que se inicia na descoberta do reservatório e dura toda a vida produtiva. A partir deste modelo são feitas as previsões de reserva e de capacidade de produção do reservatório, informações que iniciam a longa e complexa cadeia produtiva da indústria do petróleo.

A figura 1 apresenta esquema com as diferentes fontes de informações e respectivas escalas verticais e horizontais.

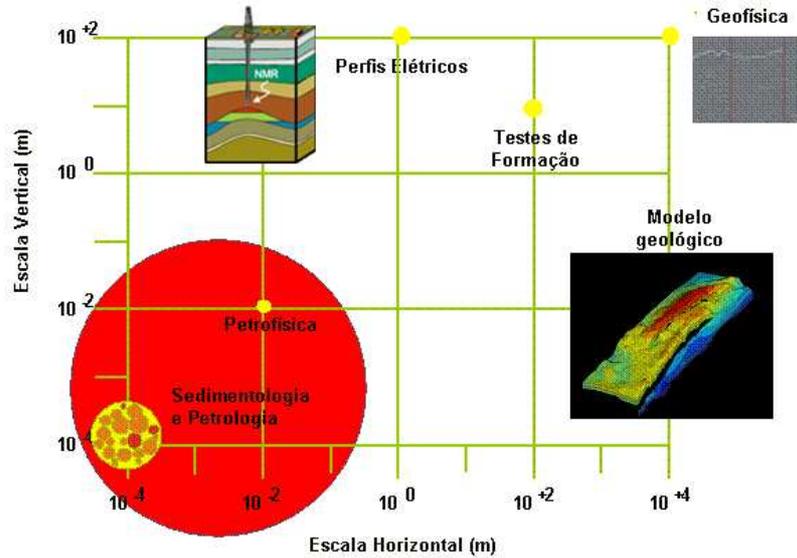


Figura 1 - Fontes de informações para a caracterização de reservatórios de petróleo

2.2 MODELAGEM DA PERMEABILIDADE NA CARACTERIZAÇÃO DE RESERVATÓRIOS

Permeabilidade Absoluta em Rochas

A permeabilidade absoluta de uma rocha porosa é definida como sua capacidade de se deixar atravessar por um fluido. A determinação da permeabilidade absoluta é o principal foco deste estudo.

A permeabilidade absoluta foi pela primeira vez proposta pelo engenheiro francês Henry Darcy⁸, em 1856, em publicação relacionada aos estudos de capacidade de filtragem de leitos de areia para o sistema público de abastecimento de água da cidade de Dijon, França. Em seus experimentos Darcy estabeleceu que a capacidade de vazão de determinado leito de areia era diretamente proporcional à área aberta ao fluxo, à diferença de carga hidráulica entre os pontos de entrada e saída e inversamente proporcional ao comprimento a ser percorrido pelo fluxo de água. Esta lei empírica, determinada há mais de um século, permanece ainda como base para

estudos em engenharia de reservatórios, bem como em outras áreas, como saneamento e agricultura.

A forma geral da lei de Darcy é dada pela equação:

$$u = \frac{q}{A} = -\frac{K}{\mu} \frac{dp}{dl} \quad \text{Equação (1)}$$

Onde:

- u = Velocidade do fluxo, em cm/s;
- q = Vazão do fluxo, em cm³/s;
- A = Área aberta ao fluxo, cm²;
- μ = Viscosidade do fluido, em cP;
- K = Constante de proporcionalidade, a permeabilidade absoluta, em Darcys;
- dp/dl = Gradiente da pressão na direção do fluxo.

A permeabilidade absoluta é definida quando apenas um fluido satura o meio poroso, enquanto que a permeabilidade efetiva/relativa se refere a dois ou mais fluidos, é uma característica intrínseca da rocha, independe do tipo de fluido. Este estudo tratará apenas da permeabilidade absoluta.

A unidade de permeabilidade é chamada de Darcy (D). Sua ordem de grandeza é em geral alto demais para valores correntes de reservatórios de petróleo que são normalmente representados em miliDarcys (mD). Há reservatórios com permeabilidades entre centésimos de miliDarcys e dezenas de Darcys. Sua variabilidade em termos da sua distribuição espacial e da direção de fluxo é fortemente influenciada pelas heterogeneidades do reservatório. Entre os principais fatores que afetam a permeabilidade de um reservatório estão:

- Estado de tensões mecânicas no reservatório;
- Forma e tamanho dos grãos;
- Cimentação e dissolução;
- Presença de fraturas.

A permeabilidade da rocha pode ser obtida ou estimada por diferentes fontes⁹:

Ensaio Petrofísicos

Podem ser realizados nos poços onde há operação de testemunhagem, os testemunhos são partes da rocha retirados do subsolo no momento da perfuração de um poço de petróleo, dos testemunhos são retiradas amostras cilíndricas de aproximadamente 1,5 polegadas de diâmetro e 2 polegadas de comprimento, os plugues petrofísicos. Estes são enviados para os laboratórios de petrofísica onde se submetem diferentes testes, entre eles o de permeabilidade. Os testes de permeabilidade em plugues são medidas diretas sobre a rocha pela simples injeção de fluido através da amostra e aplicação da lei de Darcy. Sua solução é única e acurada, sua representatividade é baixa em relação ao volume do reservatório. Em geral tem seus resultados extrapolados estatisticamente para calibração com outras ferramentas.

Testes de Formação

Testes de formação são realizados diretamente no poço perfurado, normalmente nas fases exploratórias, antes ou depois da completação do poço. Neste último caso há uma completação provisória para produção de fluidos. No teste o reservatório é posto para produção e os fluidos são encaminhados para os separadores de testes das sondas. São realizadas manobras de abertura e fechamento da produção em determinados intervalos de tempo de modo que se tenha o comportamento da queda de pressão devido à abertura da produção e à proporcional recuperação da pressão no tempo de fechamento. O perfil de vazão e pressão no fundo do poço no decorrer do tempo é adquirido e a eles são ajustados modelos que prevêm, dentre outros fatores, a permeabilidade efetiva do reservatório na presença de água irreduzível.

Os testes de formação são uma medida direta, embora haja necessidade de ajuste de modelos que permitem diversas soluções. Seu resultado é representativo de uma grande média de dezenas de metros na escala vertical e até centenas de metros na escala horizontal.

Perfis Elétricos

Diferentemente dos ensaios petrofísicos e testes de formação, que são testes dinâmicos cujas soluções são baseadas diretamente na lei de Darcy, os perfis elétricos obtêm propriedades físicas estáticas de onde é derivada a permeabilidade. Os primeiros são comparativamente mais custosos, além de terem escalas de tal maneira distintas que dificultam sua correlação e ajuste. Por estes motivos, as iniciativas de estimação de permeabilidade por perfis tiveram nas últimas décadas diversos trabalhos publicados.

O trabalho pioneiro de modelagem de permeabilidade por propriedades estáticas de rochas foi desenvolvido em 1937 por Carman¹⁰, inspirados nos trabalhos de 1927 de Kozeny¹¹, que desenvolveram os clássicos modelos de Kozeny-Carman que relacionam a permeabilidade à porosidade, superfície específica do volume poroso, ou seja, a razão entre a superfície e o volume dos poros, e a um fator chamado tortuosidade, definido como a razão entre o comprimento efetivo do percurso percorrido pelo fluido e sua distância em linha reta. Este parâmetro não era passível de ser obtido, então a definição dos valores era empírica baseada em ajustes feitos em inúmeros ensaios laboratoriais.

$$k = \frac{\phi}{k_0 \tau S}$$

Equação (2)

Onde:

- ϕ = Porosidade;
- $K_0\tau$ = Constante empírica de Kozeny-Carman, relacionada a Tortuosidade;
- S = Superfície específica.

Outros esforços para estimativa de permeabilidade por propriedades estáticas de rochas foram realizados em 1943 por Krumbein e Monk¹², que propuseram a utilização da granulometria para predição da permeabilidade, correlacionado-a à média geométrica e ao desvio padrão da distribuição granulométrica. Os modelos de Kozeny e Carman e Krubein e Monk ainda demandam dados de laboratório.

O primeiro modelo de permeabilidade que podia ser feito com dados obtidos exclusivamente por perfis foi proposto em 1949 por Tixier¹³. Relacionava a permeabilidade aos dados de resistividade da formação e de peso específico dos fluidos. Em 1950, Wyllie e Rose¹⁴ propuseram a correlação da permeabilidade com o Fator de Formação e de saturação irreduzível de água obtido por perfis de resistividade. Em 1968, Timur¹⁵ propôs a correlação da permeabilidade com a porosidade e a saturação irreduzível de água. Em 1974, Coates e Dunamoir¹⁶ propuseram a correlação da permeabilidade com os dados de porosidade, resistividade da água e resistividade da formação e em 1981, Coates e Denoo¹⁷, propuseram a correlação da permeabilidade com a porosidade e a saturação irreduzível de água. Diferentemente dos primeiros modelos, onde ensaios laboratoriais eram necessários, ambos os parâmetros destes últimos podiam ser obtidos exclusivamente por perfis.

3 PRINCÍPIOS BÁSICOS DA RMN

A Ressonância Magnética Nuclear (RMN) é um fenômeno físico utilizado para investigar propriedades moleculares da matéria por irradiação sobre o núcleo atômico em ambiente sob atuação de campo magnético e com uso de ondas de rádio¹⁸. É aplicada correntemente em imageamento médico, ciências dos materiais, análises químicas, caracterização de reservatórios de petróleo e controle de processos industriais.

3.1 PROPRIEDADES DO NÚCLEO ATÔMICO

Spin nuclear e momento magnético

A teoria quântica postula que os núcleos atômicos possuem quatro propriedades fundamentais: massa (m), carga elétrica (e), momento magnético (μ) e spin (I). As propriedades físicas e químicas dos materiais, dentre diversos outros fatores, são bastante influenciadas pela massa e a carga elétrica dos núcleos atômicos que os constituem. Entretanto, a manifestação do magnetismo e spin nucleares é bem menos aparente.

Em linhas gerais, o núcleo atômico possui um momento magnético que se assemelha aquele produzido por um pequeno ímã, conforme ilustrado na figura 2. Esse magnetismo intrínseco torna o núcleo atômico capaz de interagir com campos magnéticos externos.

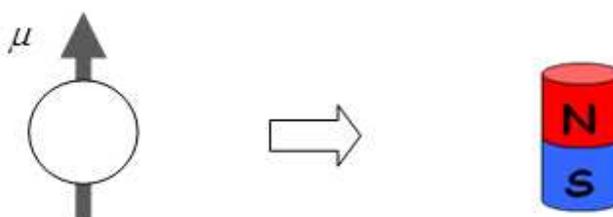


Figura 2 - Representação pictórica do momento magnético μ .

Por sua vez, o spin nuclear consiste de um momento angular intrínseco que, embora não seja proveniente de rotação, encontra um análogo clássico no momento

angular gerado por um corpo em movimento de rotação ao redor do seu próprio eixo, conforme ilustrado na figura 3.

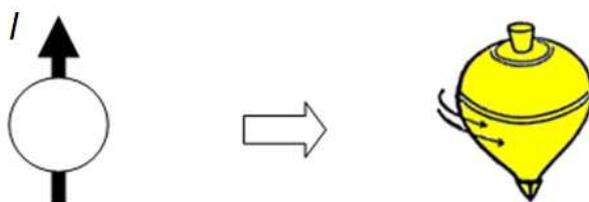


Figura 3 - Representação pictórica do spin nuclear I.

Embora tanto o momento magnético quanto o spin nuclear não influenciem diretamente as propriedades dos materiais, assim como a massa e carga elétrica, elas são fundamentais para a ocorrência do fenômeno da RMN.

Efeito Zeeman

Ainda segundo a teoria quântica, quando um núcleo dotado de momento angular e momento magnético é submetido a um campo magnético estático B_0 , existirá uma interação entre o momento magnético μ e o campo B_0 capaz de agrupar os estados de spin nuclear em $2I+1$ níveis de energia. Este fenômeno é conhecido como efeito Zeeman.

Por exemplo, para o isótopo de maior abundância do hidrogênio, o próton (^1H), cujo o número quântico de spin é igual a $1/2$, dois níveis de energia (α e β), antes degenerados, serão separados por uma quantidade de energia ΔE , tal que:

$$\Delta E = h\nu$$

Equação (3)

onde,

- h = Constante de Planck ($6,62620 \times 10^{-34}$ Js);
- ν = Freqüência de excitação.

Os spins alinhados na mesma direção do campo B_0 ocupam um nível de menor energia, nível α , enquanto que os spins alinhados na direção oposta ocupam níveis de maior energia, nível β .

A figura 4 representa o diagrama de energia dos estados de spin nuclear para $B_0=0$ e $B_0 \neq 0$.

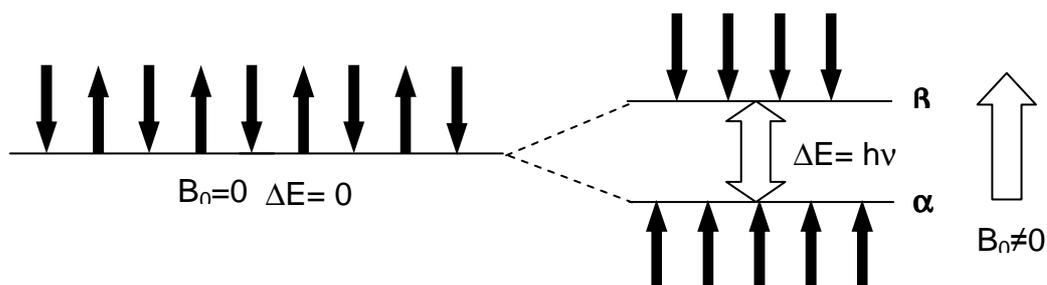


Figura 4 - Representação dos níveis de energia de spin nuclear.

A proporção de spins nucleares entre os níveis α e β apresentadas na figura acima é meramente ilustrativa, pois a verdadeira distribuição de população de cada nível de energia é governada pela lei de distribuição de Boltzmann:

$$\frac{N_{\alpha}}{N_{\beta}} = \exp\left(\frac{\Delta E}{kT}\right) \quad \text{Equação (4)}$$

Onde:

- N_{α} = População no nível de menor energia;
- N_{β} = População no nível de maior energia;
- k = Constante de Boltzmann ($1,380622 \times 10^{-23} \text{ J K}^{-1}$);
- T = Temperatura absoluta.

De acordo com a equação acima, em temperaturas ordinárias, em torno de 300K, ΔE é muito pequeno em relação à energia térmica kT . Logo, as populações nos níveis α e β são quase idênticas, havendo um pequeno excesso populacional no nível de mais baixa energia. Por exemplo, para uma frequência de excitação de 1MHz, o nível α apresenta apenas 2 núcleos a mais que β numa população de 10 milhões de prótons.

Como será visto mais adiante, o fato deste excesso populacional ser tão pequeno é que torna a RMN uma técnica pouco sensível quando comparada com outras técnicas, tais como infravermelho e ultravioleta.

Precessão

Numa visão clássica e estritamente vetorial do fenômeno da RMN o campo B_0 exerce um torque sobre o momento magnético μ ($\mu \times B_0$) provocando uma alteração na direção do seu momento angular. Dessa forma, o núcleo é induzido a precessar ao redor do eixo do campo magnético B_0 com uma velocidade angular ω_0 , (figura 5). Este movimento de precessão é análogo ao movimento de giro do pião ao redor do campo gravitacional da Terra.

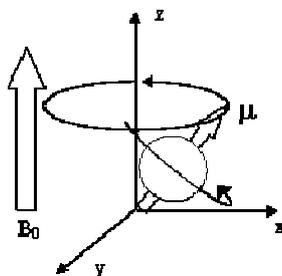


Figura 5 - Representação vetorial de um núcleo atômico e seu momento magnético nuclear em precessão ao redor do campo B_0 .

Para um conjunto de núcleos precessando ao redor de B_0 a resultante das componentes transversais dos momentos magnéticos, denominada magnetização transversal M_{xy} , é nula ($M_{xy} = \sum \mu_{zy} = 0$). Este fato deve-se a inexistência de coerência de fase entre elas, ou seja, embora possuam a mesma velocidade angular, estão distribuídas aleatoriamente no plano x-y.

Para facilitar a compreensão das etapas subseqüentes do fenômeno da RMN, costuma-se utilizar um artifício denominado referencial rotativo, onde o observador gira ao redor do eixo z com a mesma velocidade angular ω_0 . Desta forma, omite-se o movimento de precessão dos momentos magnéticos, o que permite representar apenas a resultante de suas componentes longitudinais. Este vetor é denominado magnetização longitudinal M_0 .

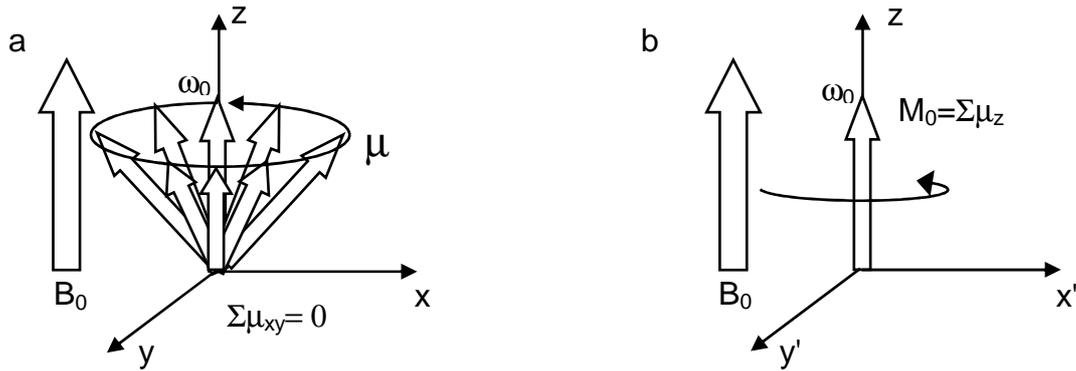


Figura 6 - Representação vetorial de precessão de um conjunto de momentos magnéticos ao redor do campo B_0 a) referencial fixo b) referencial rotativo.

A velocidade angular de precessão, também denominada frequência de Larmor, é uma função direta da intensidade do campo magnético e é dada pela equação fundamental da ressonância:

$$\omega_0 = \gamma B_0 \quad \text{Equação (5)}$$

onde,

- γ = Razão magnetogírica;
- ω_0 = Frequência de Larmor (rad/s).

A razão magnetogírica γ é uma constante intrínseca de cada isótopo (para o próton, $\gamma^{1H} = 2,675197 \times 10^4 \text{ rad s}^{-1} \text{ TGauss}^{-1}$). Como o próprio nome sugere, consiste da razão entre o momento magnético μ e o momento angular J , $\gamma = \mu/J$. Logo, para um mesmo campo magnético, cada isótopo apresentará uma frequência de ressonância distinta, situada na região das frequência de rádio.

Quando submetidos a um campo magnético de 550 Gauss, campo típico das ferramentas de perfilagem por RMN, os prótons dos fluidos de reservatório vão precessar com uma frequência de 2,3 milhões de ciclos por segundos (2,3MHz). Este movimento de precessão perdura em equilíbrio até que o sistema seja perturbado por uma força externa.

3.2 RESSONÂNCIA E SINAL DE RMN

A condição de ressonância é atingida quando um campo magnético linearmente polarizado B_1 , aplicado perpendicularmente a B_0 , oscila com mesma frequência de Larmor ($\nu_{B_1} = \nu_L$). Nesta condição, uma quantidade de energia ΔE é transferida para o sistema, estimulando a transição dos spins nucleares do nível de mais baixa energia para o nível superior, alterando a distribuição de população de Boltzman.

Aplicado sob a forma de pulsos de curta duração, da ordem de microssegundos, o campo magnético B_1 exerce um torque sobre M_0 , deslocando-a α graus em relação ao eixo z. A magnetização longitudinal, antes alinhada na direção do eixo z, é projetada sobre o plano $x'-y'$ gerando uma componente transversal não nula, $M_{xy} \neq 0$.

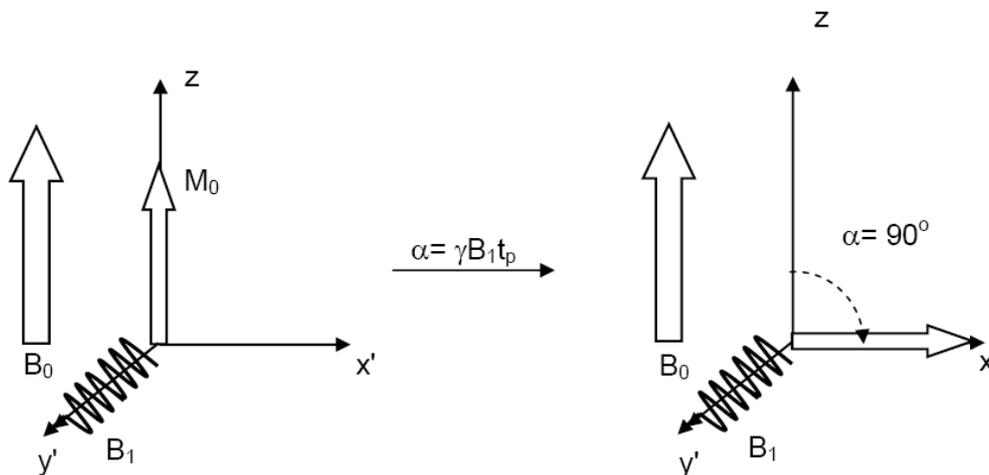


Figura 7 - Representação vetorial da aplicação de um pulso de 90° sobre a magnetização M_0 .

O ângulo de deslocamento é selecionado através do ajuste da duração e/ou intensidade do pulso, de acordo com a seguinte equação:

$$\alpha = \gamma B_1 t_p$$

Equação (6)

Onde:

- α = Ângulo entre a magnetização M e o eixo z;
- t_p = Tempo de duração do pulso.

Uma vez suspenso o campo B_1 , a magnetização retorna a sua condição de equilíbrio inicial. Durante este processo, conhecido como relaxação nuclear, o fluxo magnético produzido pela componente transversal da magnetização induz uma corrente elétrica numa bobina posicionada perpendicularmente ao campo B_0 . O registro da intensidade desta corrente ao longo do tempo é o sinal de RMN, conforme ilustra a figura 8. Este sinal é denominado FID (*Free Induction Decay*).

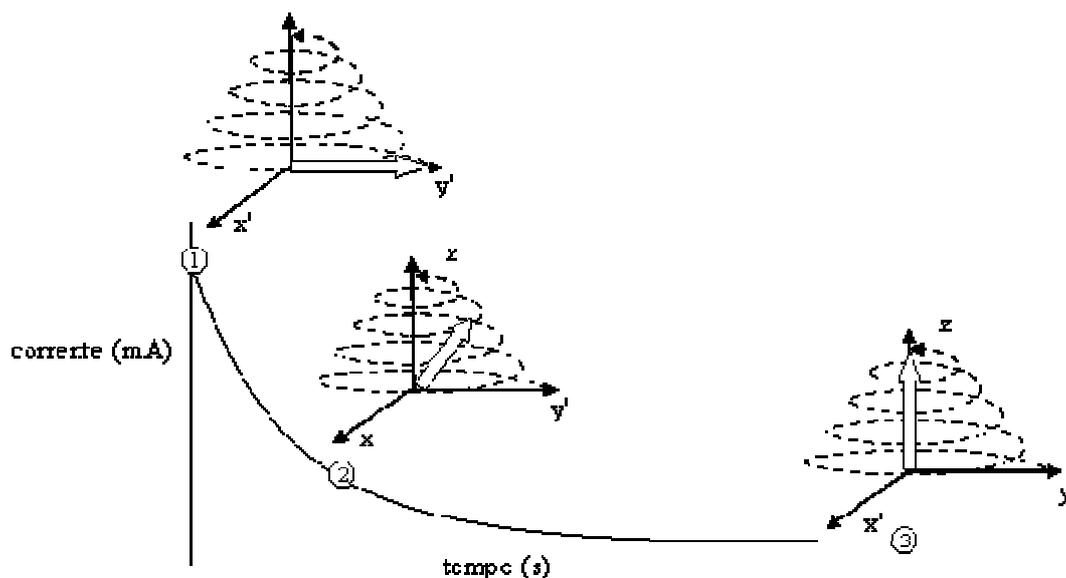


Figura 8 - Representação vetorial da indução do sinal de RMN 1) amplitude máxima, $M_{xy}(0)=M_0$ e $M_z(0)=0$; 2) amplitude intermediária, $M_{xy}(t)=M$; 3) amplitude zero, $M_{xy}(t)=0$ e $M_z(t)=M_0$.

3.3 RELAXAÇÃO TRANSVERSAL

O retorno da magnetização transversal à sua condição inicial de equilíbrio, onde $M_{xy}=0$, independe da transferência de energia para o sistema. Para que suas componentes no plano x-y se anulem basta que comecem a precessionar ao redor de B_0 de forma aleatória. Essa perda de coerência, atribuída à interação mútua entre os momentos magnéticos individuais resulta num processo de relaxação conhecido relaxação transversal.

A relaxação transversal provoca um decaimento exponencial do sinal de RMN, descrito no decorrer do tempo (t) pela seguinte equação:

$$M_{xy}(t) = M_0 e^{-t/T_2}$$

Equação (7)

Onde:

- M_0 = Amplitude da magnetização transversal no instante t_0 ;
- T_2 = Tempo de relaxação característico.

Na prática, a presença de heterogeneidades do campo magnético, inerentes a ferramenta de RMN (ΔB_0) faz com que as componentes transversais da magnetização do fluido se dispersem no plano x-y muito rapidamente, acelerando de maneira falsa o decaimento do sinal de RMN.

O decaimento do sinal de RMN acelerado pela contribuição de ΔB_0 é na verdade representada por um tempo de relaxação aparente T_2^* , tal que:

$$\frac{1}{T_2^*} = \frac{1}{T_2} + \Delta B_0$$

Equação (8)

De acordo com a equação acima, quanto mais homogêneo for o campo magnético B_0 , mais o tempo de relaxação transversal aparente T_2^* se aproximará do valor de T_2 natural do fluido de reservatório.

Para atenuar este efeito indesejável da heterogeneidade de B_0 , utiliza-se um recurso denominado refocalização da magnetização transversal. Neste procedimento, um pulso 180° , aplicado após o tempo TAU, gira os vetores 180° ao redor do eixo y. Uma vez que o sentido de rotação e a velocidade angular ω_n permanecem inalteradas, as componentes transversais da magnetização recuperam sua coerência de fase num tempo 2TAU, ou seja, a diferença entre os ângulos de defasagem constituída ao longo de TAU se reduz a zero ($\Delta\phi=0$). A amplitude deste sinal, denominado eco de spin (ou eco de Hahn), não depende mais de T_2^* , apenas de T_2 .

Quando uma amostra de fluido é submetida à um campo magnético heterogêneo ($\Delta B_0 \neq 0$) a magnetização transversal (M_{xy}) produzida pela ação de um pulso de 90° (figura 9) se defasa no plano x-y durante o tempo TAU. O ângulo de defasagem (ϕ_n)

depende da intensidade do gradiente de campo ΔB_0 da seguinte forma: $\phi_n = \omega_n \text{TAU}$, onde $\omega_n = \gamma \Delta B_0$.

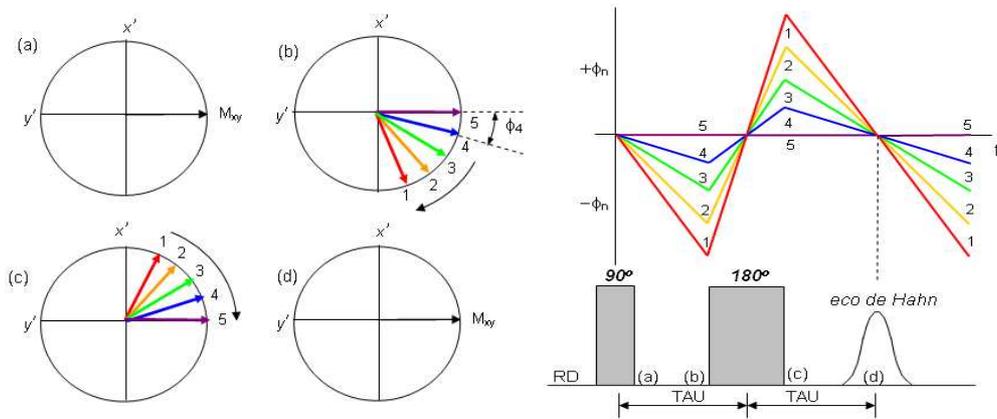


Figura 9 - Representação esquemática do processo de defasagem e refocalização da magnetização transversal, e formação do sinal de eco de spin.

A técnica mais utilizada para a medição de T_2 é a CPMG (Carr-Purcell-Meiboom-Gill). Esta técnica utiliza o mesmo princípio da refocalização da magnetização, só que desta vez é aplicada uma seqüência de n pulsos de 180° consecutivos, igualmente espaçados por um tempo 2TAU . Desta forma, um eco de spin é gerado a cada instante $2n\text{TAU}$. A figura 10 ilustra a seqüência de pulsos que constitui a técnica CPMG.

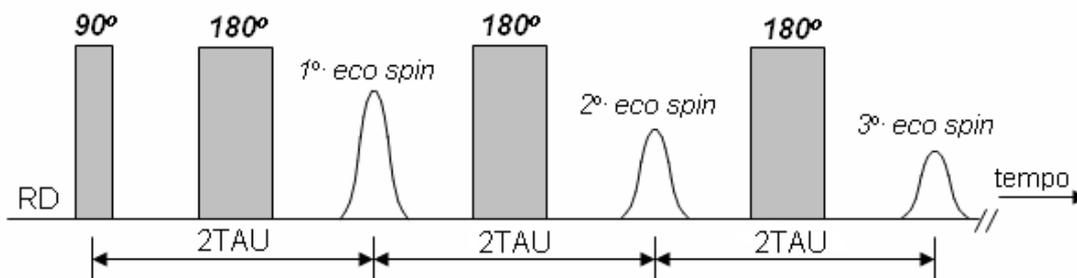


Figura 10 - Diagrama da seqüência de pulsos CPMG.

Uma vez que o efeito da heterogeneidade do campo magnético é cancelado pela refocalização da magnetização, a intensidade de cada eco formado é modulada apenas pelo processo de relaxação transversal intrínseco da amostra analisada. O parâmetro T_2 é obtido matematicamente através do ajuste da função $M(t) = M_0 e^{-t/T_2}$ aos pontos experimentais da curva de relaxação, onde $M(t)$ equivale à intensidade do eco

de spin no tempo $t=2n\tau$ e M_0 no tempo $t=0$. A figura 11 ilustra a obtenção da curva de relaxação T_2 através da técnica CPMG.

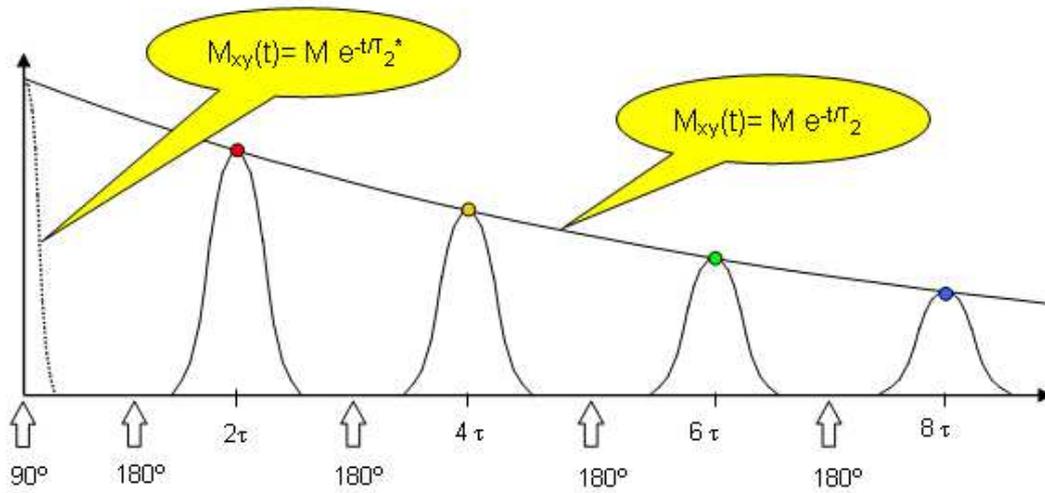


Figura 11 - Curva de relaxação transversal (T_2) obtida através da técnica CPMG.

Para incrementar a razão sinal/ruído do sinal detectado, e assim obter um cálculo de T_2 mais acurado, a média da intensidade de cada eco é obtida através de inúmeras repetições da seqüência CPMG.

4 RMN EM ROCHAS RESERVATÓRIOS DE PETRÓLEO

4.1 MECANISMOS DE RELAXAÇÃO EM MEIOS POROSOS

Sistemas porosos saturados com fluidos possuem um complexo mecanismo de relaxação, cujos efeitos se superpõem na exponencial de decaimento. Distinguem-se três mecanismos principais: (i) Relaxação *Bulk*, equivalente à relaxação intrínseca das moléculas de cada tipo de fluido; (ii) Relaxação Superficial, equivalente à relaxação das moléculas do fluido que estão próximas da interface rocha fluido; (iii) Relaxação Difusiva, resultado do movimento difusivo das moléculas em presença de um gradiente de campo magnético. Estes diferentes mecanismos de relaxação agem em paralelo sobre a curva de decaimento, seus efeitos sobre o T_2 são promediados pela equação:

$$\frac{1}{T_2} = \frac{1}{T_{2 \text{ bulk}}} + \frac{1}{T_{2 \text{ superficial}}} + \frac{1}{T_{2 \text{ difusao}}} \quad \text{Equação (9)}$$

A importância relativa dos três mecanismos depende das características do fluido e do tamanho dos poros.

Relaxação Bulk

A Relaxação *Bulk* é uma característica intrínseca do fluido, depende da composição e arranjo das moléculas, é fortemente correlacionado com características físicas, como a viscosidade. Deve ser medida em célula de leitura suficientemente grande para negligenciar o efeito das paredes sobre a relaxação. Fatores ambientais como a temperatura e pressão afetam a medida. Algumas substâncias puras possuem equação característica para determinação do T_2 , por exemplo a água.

$$T_{2 \text{ bulk}} \cong 3 \left(\frac{T_k}{298 \mu} \right) \quad \text{Equação (10)}$$

Onde:

- T_k = Temperatura absoluta (K);
- μ = Viscosidade (cP).

Relaxação Superficial

A Relaxação Superficial ocorre na interface sólido-fluido, sua equação característica é dada por:

$$\frac{1}{T_{2\text{ surface}}} \cong \rho \left(\frac{S}{V} \right)_{\text{poro}} \quad \text{Equação (11)}$$

Onde

- ρ = Relaxatividade superficial do sólido;
- $(S/V)_{\text{poro}}$ = Relação entre a superfície e o volume do poro.

A Relaxatividade Superficial é uma característica intrínseca do sólido, varia com a mineralogia e não varia de forma notável com a pressão e a temperatura.

Relaxação Difusiva

Determinados tipos de fluidos, como gases e óleos pouco viscosos possuem razoável leitura de relaxação em função do movimento de difusão das moléculas. Nestes casos o $T_{2\text{difusão}}$ passa a influenciar a exponencial de decaimento. Abaixo é apresentada a equação característica do $T_{2\text{difusão}}$.

$$\frac{1}{T_{2\text{ difusão}}} \cong \frac{D(\gamma GTE)^2}{12} \quad \text{Equação (12)}$$

Onde:

- D = Constante de difusão molecular;
- γ = Razão magnetogírica do próton;

- G = Intensidade do gradiente de campo magnético (G/cm);
- TE = Tempo de eco utilizado na seqüência CPMG.

Assim como no mecanismo *Bulk*, fatores ambientais como pressão e temperatura impactam o coeficiente de Difusão. A intensidade do Gradiente é influenciada pela configuração do equipamento e também é influenciada por fatores ambientais. O efeito devido à difusão tende a ser muito pequeno em menores tempos de eco, com exceção de gases, em geral o planejamento da medida no campo é feito de forma a tornar este efeito insignificante.

Decaimento Multiexponencial

Reservatórios de petróleo normalmente contém uma variada distribuição de poros de diversos formatos e tamanhos. Também possuem mais de um fluido, água e hidrocarbonetos, e os hidrocarbonetos são misturas que podem ter composição molecular bastante variada. Em função dos diferentes mecanismos atuando neste complexo sistema a modelagem do decaimento da relaxação transversal não pode ser feita por T_2 único característico, mas pela superposição dos efeitos num tipo de modelagem multiexponencial, conforme visto a seguir:

$$M(t) = \sum M_i(0) e^{\frac{-t}{T_{2i}}} \quad \text{Equação (13)}$$

Onde

- $M(t)$ = Magnetização medida;
- $M_i(0)$ = Magnetização inicial do i-ésimo termo;
- T_{2i} = constante de decaimento do i-ésimo termo.

A figura 12 ilustra os efeitos dos mecanismos de relaxação em sistemas unicomponente e seu resultado em sistemas multicomponentes, onde os efeitos se superpõem.

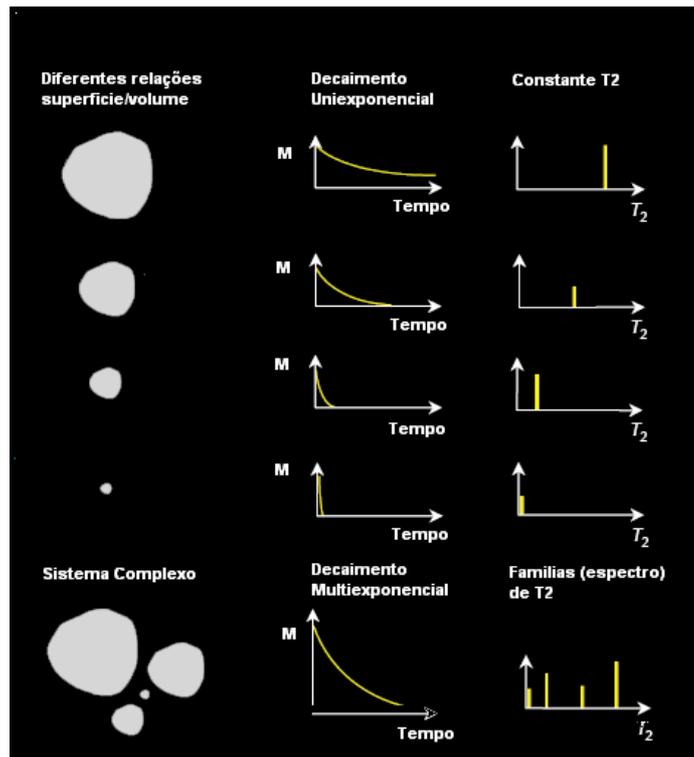


Figura 12 - Esquema de decaimentos uni e multiexponencial

A solução da equação do decaimento multiexponencial deve resultar em diferentes valores de T_2 com amplitudes equivalentes à quantidade de moléculas sob os mesmos efeitos de relaxação.

Como são infinitas as possibilidades de interações entre as moléculas dos fluidos e entre os fluidos e rocha, infinitos valores de constantes T_2 seriam necessários para se ajustar à equação de decaimento, resultando num espectro contínuo de T_2 . A formulação matemática resultaria num sistema cujo número de equações é igual ao número de valores lidos pelo equipamento ao longo do tempo de aquisição e o número de incógnitas seria infinito. Na prática, a solução do sistema é realizada com a discretização do domínio de T_2 em n famílias (chamados de “bins”).

$$\begin{aligned}
M(t_1) &= M_1(0)e^{-\frac{t_1}{T_{21}}} + M_2(0)e^{-\frac{t_1}{T_{22}}} + M_3(0)e^{-\frac{t_1}{T_{23}}} + \dots + M_n(0)e^{-\frac{t_1}{T_{2n}}} + \text{ruído} \\
M(t_2) &= M_1(0)e^{-\frac{t_2}{T_{21}}} + M_2(0)e^{-\frac{t_2}{T_{22}}} + M_3(0)e^{-\frac{t_2}{T_{23}}} + \dots + M_n(0)e^{-\frac{t_2}{T_{2n}}} + \text{ruído} \\
M(t_3) &= M_1(0)e^{-\frac{t_3}{T_{21}}} + M_2(0)e^{-\frac{t_3}{T_{22}}} + M_3(0)e^{-\frac{t_3}{T_{23}}} + \dots + M_n(0)e^{-\frac{t_3}{T_{2n}}} + \text{ruído} \\
&\dots \\
M(t_n) &= M_1(0)e^{-\frac{t_n}{T_{21}}} + M_2(0)e^{-\frac{t_n}{T_{22}}} + M_3(0)e^{-\frac{t_n}{T_{23}}} + \dots + M_n(0)e^{-\frac{t_n}{T_{2n}}} + \text{ruído}
\end{aligned}$$

Equação (14)

Com este artifício, o sistema passa a ter mais equações (leituras do equipamento, de acordo com a capacidade de aquisição e armazenamento do equipamento) do que incógnitas (número de *bins* escolhidos para discretização do espectro de T_2). A solução passa a ser um problema clássico de aproximação numérica para obter a mínima diferença entre o valor lido e o modelado. Chamada de inversão do sinal de RMN, trata-se de um problema bastante instável, fortemente dependente de regularização e imposição de restrições. A figura 13 ilustra este processo.

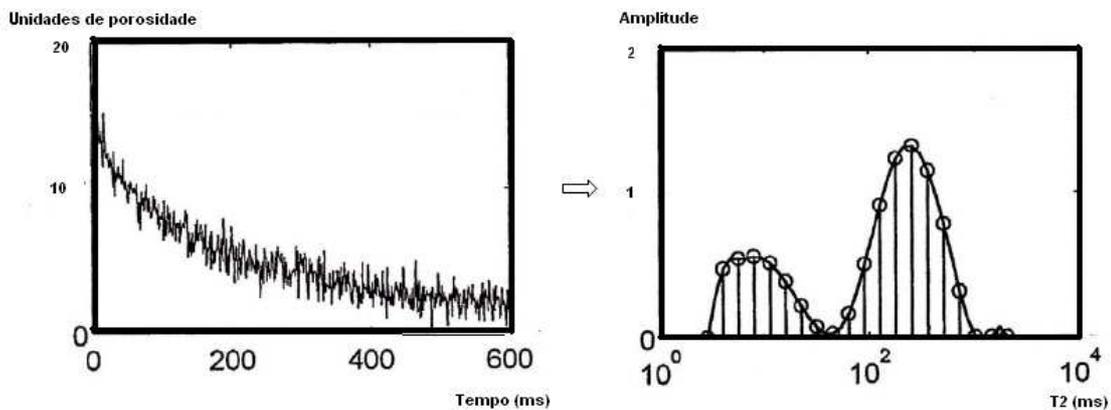


Figura 13 - Dados brutos de decaimento exponencial de RMN e inversão para determinação de espectro de T_2

Neste estudo não serão discutidos os aspectos de inversão do sinal de RMN para determinação do espectro de T_2 . Todo trabalho a ser feito será baseado nos espectros invertidos recebidos pelas companhias prestadoras de serviços de perfilagem.

4.2 APLICAÇÕES DE PERFIS DE RMN EM CARACTERIZAÇÃO DE RESERVATÓRIOS

A tecnologia de RMN foi pela primeira vez reconhecida para utilização em engenharia de reservatórios nos anos de 1950, seguida da construção da primeira ferramenta em 1960, chamada de *Nuclear-Magnetic-Logging* (NML). Em função dos primeiros resultados decepcionantes ela não teve aceitação comercial, tendo continuado as pesquisas em torno da tecnologia, em 1991 foi lançada no mercado a *Magnetic Resonance Image Logging* (MRIL), a primeira das ferramentas largamente utilizada. Desde então a tecnologia tem se sofisticado em termos de sua construção mecânica e eletrônica além dos algoritmos de processamento. Hoje é muito comum nas suítes de perfilagens de poços, sendo considerada imprescindível por alguns operadores.¹⁹.

Porosidade

A porosidade de uma rocha reservatório é a razão entre o volume de vazios (ou poros) e o volume total da amostra. É o principal parâmetro que identifica a capacidade de armazenamento da jazida.

A integral do espectro de T_2 de RMN, ou a área abaixo da curva, é proporcional a quantidade de núcleos de hidrogênio detectados na zona investigada pela ferramenta, quando calibrada, esta informação pode ser considerada uma boa estimativa do volume de fluidos presentes e, conseqüentemente, a porosidade do reservatório.

Distribuição de Tamanho de Poros

Como informado, nos casos em que há apenas um fluido saturando o meio poroso, considera-se que sua resposta é função do mecanismo superficial, mais precisamente, da relação entre a superfície e o volume dos poros. Assim sendo, o espectro de T_2 guarda relação direta com a distribuição de tamanho de poros da zona investigada pela ferramenta. Como apresentado no esquema da figura 14 os poros menores possuem relaxação mais rápida e seus valores de T_2 são menores, enquanto que os poros maiores possuem relaxação mais lenta e seus valores de T_2 são maiores.

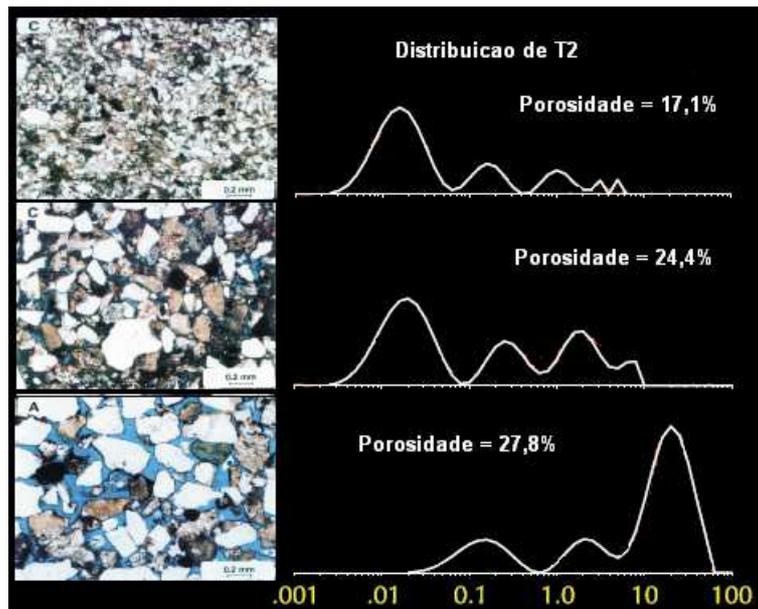


Figura 14 - Relação do espectro de T_2 com a distribuição de tamanho de poros

Saturação Irredutível de Água

A saturação irredutível de água corresponde ao volume de água aprisionada por forças capilares nos meios porosos. O histórico de formação das jazidas de petróleo supõe que o fluido que inicialmente satura o reservatório é água de formação e que durante a migração do petróleo a água é expulsa deixando para trás apenas o volume presente em pequenos poros, que demandam altíssima força capilar para ser deslocado.

A obtenção da saturação irredutível de água pelo perfil de RMN é feita pela separação do domínio do espectro de T_2 em duas partes limitadas por um T_2 de corte. O volume abaixo do T_2 de corte corresponde aos fluidos aprisionados por forças capilares (*bound fluid*), enquanto que o volume acima do T_2 de corte corresponde ao fluido livre (*free fluid*). A premissa deste método é de que nos poros menores, de relaxação curta e T_2 menores, está a S_{wi} . Os valores de T_2 de corte podem ser definidos em ensaios de laboratório. Estudos apresentados na literatura apresentam valores definidos empiricamente após inúmeras medidas de laboratórios, que são de 33 ms para rochas siliciclásticas e 92 ms para rochas carbonáticas.

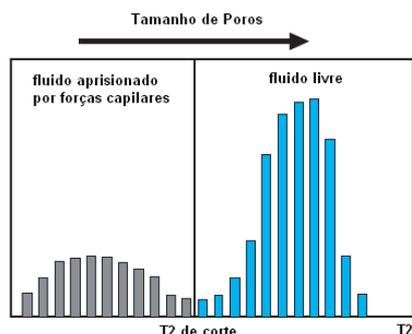


Figura 15 - Aplicação do T_2 de corte, separação entre fluido livre e fluido aprisionado por forças capilares.

4.3 MODELAGEM DA PERMEABILIDADE POR PERFIS RMN

Em 1988, Kenyon iniciou os estudos que proporiem em 1997 a correlação da permeabilidade com a porosidade e o T_2 correspondente à média geométrica do espectro de T_2 . A equação é conhecida pela sigla SDR, de Schlumberger Doll Research, instituto de pesquisas onde foram feitos os estudos:

$$k = a \times \phi^4 \times T_{2_{\log mean}}^2 \quad \text{Equação (15)}$$

Onde:

- ϕ = Porosidade;
- $T_{2_{\log mean}}$ = Posição no espectro de T_2 correspondente a media geométrica;
- a = Coeficiente de ajuste litológico.

Em 1991, Coates propôs o uso do perfil de RMN para estimativa da permeabilidade com o uso da porosidade e da razão entre volume de fluido livre e volume de fluido aprisionado por forças capilares, obtida pela aplicação do T_2 de corte no perfil RMN, conforme a equação abaixo. Este é conhecido como modelo de Timur Coates, pela inspiração de Coates nos modelos anteriormente desenvolvidos por Timur.

$$k = a \times 10^4 \times \phi^4 \times \left(\frac{FF}{BF} \right)^2 \quad \text{Equação (16)}$$

Onde:

- ϕ = Porosidade;
- FF/BF = Razão entre volume de fluido livre (*free fluid*) e volume de fluido aprisionado por forças capilares (*bound fluid*);
- a = Coeficiente de ajuste litológico.

As equações SDR e de Timur Coates são consideradas as equações clássicas de estimativa de permeabilidade a partir de perfis de RMN. Ambas utilizam a premissa de que o espectro de T_2 representa a distribuição de tamanho de poros da zona investigada. Os expoentes das equações foram definidos empiricamente por ajustes feitos em inúmeros ensaios laboratoriais, seu desempenho é reconhecido em rochas homogêneas, embora haja casos em que os parâmetros básicos da literatura não oferecem bons resultados, sendo necessário o ajuste dos expoentes das equações com respectivos dados de permeabilidade de testes petrofísicos ou de formação. A maioria dos trabalhos subsequentes propuseram ajustes aos modelos clássicos para lidarem com estruturas porosas mais complexas, como alguns tipos de rochas carbonáticas.

Em 1997, Chang²⁰ reescreveu a equação de SDR, limitando o espectro de T_2 ao valor máximo de 750 ms, a partir dos quais haveria poros vulgares não conectados que não contribuiriam para o fluxo.

$$k = a \times \phi_{<750 \text{ ms}}^4 \times T_{2_{\log \text{ mean } <750 \text{ ms}}}^2 \quad \text{Equação (17)}$$

Em 2002, Kantzas²¹ verificou que a S_{wi} obtida no perfil RMN era correlacionada a amplitude do primeiro e do último pico do espectro, tendo proposto um modelo modificado Timur Coates que relacionava a permeabilidade a estes dois parâmetros.

$$k = 0,09396 \times (FP)^{-1,81567} \times (LP)^{4,55186} \quad \text{Equação (18)}$$

Em 2006, DiRosa²² propõe que a simples aplicação da distribuição de poros não é suficiente para predição da permeabilidade. Ele introduz o fator de conectividade dos poros (p) no modelo clássico de Timur Coates.

$$k = a \times 10^4 \times \phi^4 \times \left(\frac{p \times FF}{BF + (1 - p) \times FF} \right)^2 \quad \text{Equação (19)}$$

5 INTELIGENCIA COMPUTACIONAL

5.1 CONCEITOS GERAIS

A evolução da computação possibilitou um forte aumento na capacidade de armazenamento e de processamento de dados. A tarefa de descoberta de conhecimento em bases de dados (ou mineração de dados, *data mining*) é definida como o conjunto de processos voltados à identificação de padrões válidos, novos, potencialmente úteis e compreensíveis em conjuntos de dados²³. Sua aplicação tem crescido muito rapidamente em função do desenvolvimento e disseminação de um grande número de ferramentas computacionais relativamente amigáveis e úteis em diversas atividades. A descoberta de conhecimento em base de dados pode ser resumida em três etapas principais: Pré processamento, Extração de Padrões e Pós processamento²⁴.

No Pré processamento os dados são postos em formato adequado. As tarefas principais são a integração de diversas fontes, as transformações, como mudança de escala e retirada de sazonalidade, a exclusão de dados espúrios e a seleção e redução de dados. A Extração de Padrões é direcionada pelo objetivo preestabelecido para o processo de mineração de dados, nesta etapa são escolhidos e configurados os algoritmos computacionais utilizados.

Os algoritmos de Extração de Padrões podem ser agrupados como Preditivos ou Descritivos, a depender do objetivo do estudo. Os Preditivos consistem na generalização de exemplos com resposta conhecida, valor ou classe, e aplicação em novos exemplos. São subdivididos em algoritmos de Classificação e de Regressão, no primeiro as variáveis são categóricas discretas e no segundo são numéricas contínuas. Os Descritivos consistem na busca de padrões intrínsecos do conjunto de dados, sem que tenham valor ou classe especificadas a priori possuem diversas abordagens, sendo as principais as Regras de Associação, o Agrupamento (*Clustering*) e a Sumarização.

Existem diferentes tipos de algoritmos, com diversas premissas e graus de complexidade. Há algoritmos que servem para várias tarefas. A sua escolha depende do conhecimento do problema, do tipo e da quantidade de variáveis. Passam pelo uso de estatística uni e multivariada, métodos de dependência probabilística (métodos

bayesianos), árvores de decisão, regras de produção, algoritmos genéticos e redes neurais artificiais.

O Pós-processamento consiste principalmente da avaliação do modelo gerado em termos de qualidade e desempenho²⁵. No que diz respeito à qualidade, os modelos podem ser incompatíveis com o conhecimento do especialista ou simplesmente incompreensíveis ou inúteis ao usuário final. O desempenho é avaliado por medidas de precisão, erro, confiança, sensibilidade, entre outras²⁶.

O problema abordado nesta tese é o desenvolvimento de algoritmo de regressão por redes neurais artificiais para estimativa de permeabilidade de reservatórios de petróleo a partir de dados de perfis de RMN.

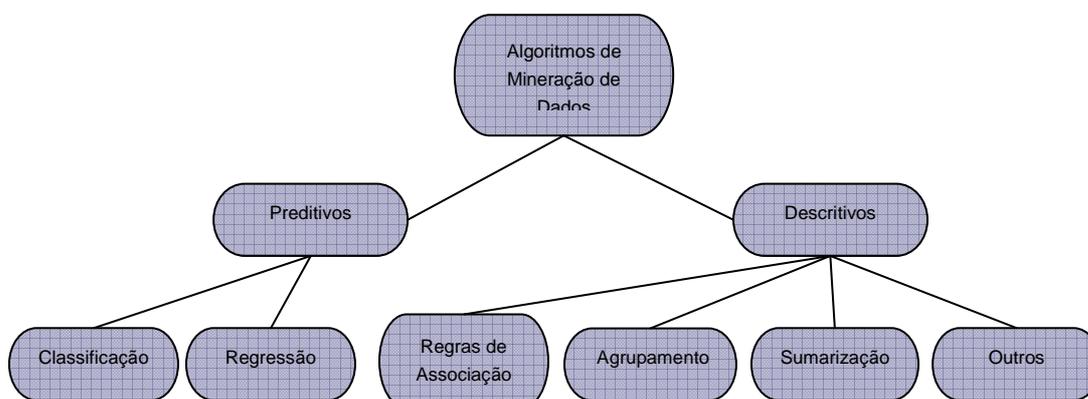


Figura 16 – Classificação de algoritmos de mineração de dados

5.2 REDES NEURAIS ARTIFICIAIS

Introdução

As Redes Neurais Artificiais (RNAs) são algoritmos matemáticos que se assemelham às estruturas neurais biológicas. O cérebro é formado por uma rede com grande quantidade de processadores simples, os neurônios, interconectados por estruturas ramificadas, os axônios e os dendritos. As sinapses fazem a ligação dos axônios e dendritos entre os neurônios. As RNAs foram propostas por McCulloch, um psiquiatra, e Pitts, um matemático que, em seu artigo clássico de 1943²⁷, descreveram cálculos lógicos reunindo neurofisiologia e lógica matemática admitindo que os neurônios seguiam uma lei simples do tipo “tudo ou nada”. Segundo eles, uma grande quantidade destas unidades simples com conexões sinápticas ajustadas operando de

forma sincronizada seriam capazes de computar funções matemáticas. Em resumo, as RNAs são formadas por processadores simples, paralelamente distribuídos e conectados entre si, e que possuem capacidade de adquirir, armazenar conhecimento experimental e torná-lo disponível para uso²⁸.

O modelo é desenvolvido por um processo de treinamento cuja função é modificar os pesos das conexões entre os neurônios (sinapses) de forma a melhor compatibilizar a resposta da rede ao conjunto de variáveis de treinamento. Uma rede neural é especificada principalmente pelas características dos neurônios, arquitetura da rede e pelas regras de treinamento. Algumas características das RNAs são:

- Adaptatividade e facilidade de treinamento;
- Representação de problemas não lineares;
- Capacidade de generalização diante de informações incompletas;
- Robustez e uso disseminado;
- Capacidade de processar informações espaço / temporais;
- Paralelismo intrínseco que lhes conferem rapidez de processamento.

As RNAs são capazes de resolver problemas de regressão, classificação, agrupamento e de otimização geral. São reconhecidas aplicações em reconhecimento de caracteres, imagens, voz, predição de séries temporais e modelagens de processos e controle, inclusive em engenharia do petróleo²⁹.

Modelos de Neurônios

O neurônio, ou nó, é a estrutura mínima de uma RNA. Possui três elementos básicos, conforme vistos na figura 17, retirada de Haykin²⁸.

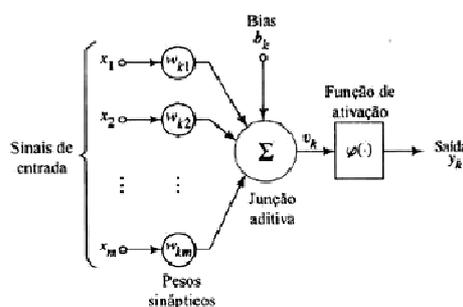


Figura 17 – Modelo de neurônio de rede neural artificial

- Conjunto de sinapses (elos de conexão), caracterizados pelo peso w_{km} , do neurônio k no elo m .
- Junção aditiva, um somador ponderado das sinapses.
- Função de ativação, que serve para escalonar e limitar o valor de saída, que normalmente fica entre $[0, 1]$ ou $[-1, 1]$.

Entre as funções de ativação estão: Limiar (ou perceptron), linear e sigmóide.

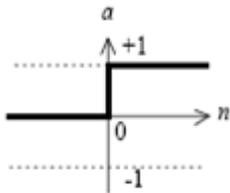


Figura 18 – Função de limiar

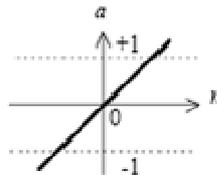


Figura 19 – Função linear

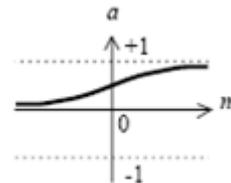


Figura 20 – Função sigmóide

Arquitetura das Redes Neurais

Os neurônios de uma RNA estão organizados em uma ou mais camadas interligadas, tendo obrigatoriamente uma camada de entrada, onde os dados de entrada são apresentados à rede, e uma de saída, onde são apresentados os resultados, e, opcionalmente, uma ou mais camadas intermediárias ou ocultas. A figura 21 apresenta um exemplo simplificado.

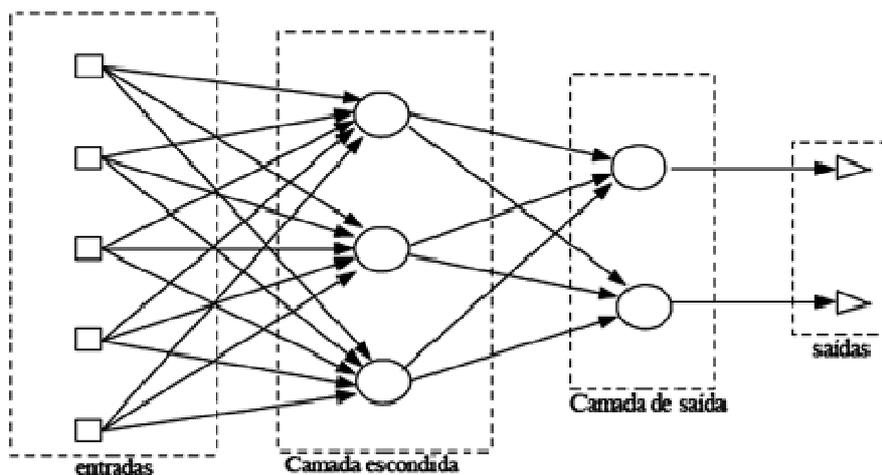


Figura 21 – Exemplo de arquitetura de rede neural artificial

Há duas classificações principais para a estrutura das redes, as alimentadas adiante (*feed forward*), onde cada nó de saída de uma camada é o nó de entrada da camada

seguinte ou as recorrentes, onde há pelo menos um nó de saída retornando para a entrada de uma mesma camada. Variações dos diversos modelos reconhecidos como RNA são baseados na topologia, ou seja, na maneira com que os nós estão conectados, e nas características dos algoritmos de treinamento.

Treinamento das Redes Neurais

Como comentado, o treinamento é um processo cíclico de ajustes aplicados para modificar os pesos das conexões entre os neurônios (sinapses) de forma a melhor compatibilizar a resposta da rede ao conjunto de variáveis de treinamento. Compatibilizar a resposta pode ser a minimização de uma função erro, da variação do erro na saída ou mesmo da variação das magnitudes dos vetores peso. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para determinado problema. O algoritmo de treinamento é o conjunto de regras bem definidas para tal solução. Existem algoritmos específicos ou indicados para determinados modelos de redes neurais. Estes diferem entre si principalmente pelo modo como os pesos são modificados. Outro fator que influencia o treinamento é o seu paradigma, isto é, o fato de ser supervisionado ou não-supervisionado. No primeiro o usuário apresenta à rede a resposta desejada para determinado padrão de entrada, são indicados para solução de problemas de classificação e de regressão, como o deste estudo. No segundo, também conhecido como auto-organização, não existe resposta conhecida e os valores dos pesos são obtidos por comparação com o padrão de entrada. São indicados principalmente para solução de problemas de agrupamento. Um paradigma intermediário é o chamado reforço, quando há apenas padrões de entrada e um crítico avalia a cada ciclo a melhora ou a piora do desempenho, demandando menores ou maiores mudanças nos pesos. No treinamento, um ciclo é fechado quando todas as N variáveis do conjunto de treinamento (as de entrada e as de saída, se houver) tiverem sido apresentadas. A correção dos pesos em um ciclo pode ser executada de dois modos:

Modo Padrão: A correção dos pesos acontece na apresentação à rede de cada um exemplo do conjunto de treinamento. A correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.

Modo Batelada (Batch): Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede. Seu erro médio é calculado e, a partir deste, são feitas as correções dos pesos.

São inúmeros os algoritmos de treinamento propostos hoje na literatura, que diferem entre si pelo paradigma, arquitetura e conectividade. A alguns exemplos são: Camadas Simples e Múltiplas com Correção de Erros, os de Função de Base Radial, os de Memória, os Competitivos, os Hebbianos e os de Boltzmann. Neste estudo serão considerados dois algoritmos: os de Camadas Múltiplas com Retropropagação de Erro (Back Propagation Multilayer Perceptron – MLP).

Camadas Múltiplas com Retropropagação de Erro (Backpropagation Multilayer Perceptron – MLP)

São redes constituídas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Trata-se de uma rede alimentada adiante, o sinal de entrada se propaga camada a camada em um sentido progressivo. As redes MLP podem ser completamente ou parcialmente conectadas, quando todos os neurônios de uma camada são conectados a todos os outros neurônios da camada adjacente, ou parcialmente conectadas, quando algumas conexões não existem.

A quantidade de nós na camada de entrada e saída é determinada, respectivamente, pela quantidade de dimensões dos sinais de entrada e da resposta desejada. Na definição de uma rede MLP os seguintes parâmetros devem ser determinados:

- Número de camadas ocultas;
- Número de neurônios em cada uma das camadas ocultas;
- Pesos sinápticos que conectam os neurônios.

Não há regras estabelecidas para determinação do número de camadas e de neurônios ocultos. Eventualmente são utilizados métodos heurísticos para tal. A determinação dos pesos sinápticos é feita pelo algoritmo de treinamento, o de retropropagação é comumente utilizado.

O algoritmo de retropropagação é executado em duas fases. Na primeira são apresentados os valores de entrada do conjunto de treinamento que são propagados

com pesos sinápticos iniciais aleatoriamente escolhidos até se alcançar a saída da rede, gerando um conjunto modelado de saída. Os valores de saída são então comparados com os valores da saída do conjunto de treinamento, calculando-se o erro na saída. Na segunda fase o erro é retropropagado pela rede, de modo a calcular a diferença necessária nos pesos sinápticos e a aplicar sua efetiva atualização. Um inconveniente deste método é a distribuição do conhecimento que torna difícil a extração de regras. Para a definição do fim do treinamento é indicado um critério de parada normalmente baseado em métrica de erro entre a saída conhecida e a modelada²⁸. A Figura 22 apresenta esquemas de arquitetura típicas de redes MLP.

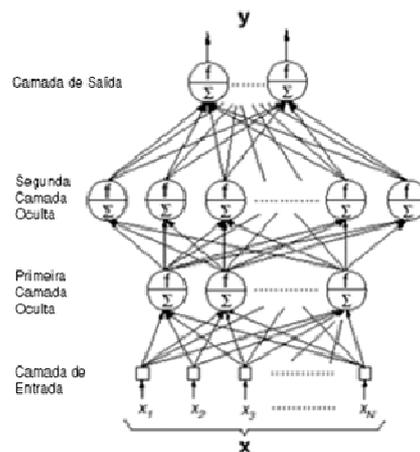


Figura 22 – Arquitetura típica de rede MLP

6 ESTUDO DE CASO DE MODELAGEM DA PERMEABILIDADE

Como descrito no capítulo introdutório, em caracterização de reservatórios as fontes de informação e as respectivas escalas de investigação são distintas e requerem um processo contínuo de calibração entre eles. A modelagem da permeabilidade é uma das etapas deste processo e requer o ajuste entre as análises petrofísicas feitas diretamente em amostras de rocha (plugues de testemunho ou amostras laterais), os modelos de permeabilidade de perfis e de testes de formação.

Conhecida na indústria como Integração Rocha Perfil Teste, esta etapa permite a passagem dos resultados precisos, porém pouco representativos (os plugues e amostras laterais são pequenos fragmentos retirados da rocha), para medidas que representem todo o volume do reservatório. Os perfis de permeabilidade estimados por RMN possuem um papel chave de ancoragem dos resultados obtidos diretamente na rocha. Cabe ressaltar que, por ser uma operação cara e demorada, apenas uma parte dos poços tem recuperadas amostras de rocha e por outro lado, todos os poços são perfilados. Deste modo o ajuste dos modelos de permeabilidade RMN nos poços permite a extrapolação segura dos resultados entre os poços e, finalmente, até os limites do reservatório por população geoestatística dos dados.

6.1 METODOLOGIA DE PESQUISA

A motivação deste trabalho é a proposta de um novo modelo de estimativa de permeabilidade a partir de perfil de RMN. Para isto é realizado um estudo de caso com dados reais de três reservatórios complexos cujos valores de permeabilidade obtidos de rocha servem para treinar e testar o modelo de rede neural aplicado sobre o respectivo perfil de RMN. A organização geral do estudo é a seguinte:

- Seleção de três reservatórios e reunião de dados de três respectivos poços, chamados de Poços I, II e III;
- Reunião dos dados de permeabilidade de rocha e respectivas profundidades, as variáveis independentes dos ajustes dos modelos;
- Reunião dos espectros de T_2 de RMN e respectivas profundidades, as variáveis dependentes dos ajustes dos modelos;
- Descrição estatística das permeabilidades de rocha, tratamento dos dados e entendimento do comportamento da variável;

- Descrição estatística dos espectros de T_2 , tratamento dos dados e entendimento do comportamento das variáveis;
- Parametrização dos modelos clássicos de permeabilidade RMN de Timur Coates e SDR para as variáveis deste estudo, avaliação estatística do desempenho de cada modelo;
- Desenvolvimento de RNA para modelar a permeabilidade a partir do espectro de T_2 do perfil de RMN, avaliação estatística do desempenho do modelo proposto e comparação com os modelos clássicos.

6.2 PERMEABILIDADE DE ROCHA

As permeabilidades de rocha (K rocha) são as variáveis independentes do problema proposto, são reunidas a partir de dados reais de ensaios petrofísicos de laboratórios de rochas, obtidas nos poços onde houve testemunhagem ou retirada de amostra lateral de poço. A abrangência em termos de profundidade é variável e depende do plano da amostragem.

Os poços escolhidos são de reservatórios de litologia complexa, ou seja, os processos da formação geológica resultaram num sistema poroso muito heterogêneo, com fortes variações locais e regionais. Nos respectivos perfis de K rocha fica evidenciada a grande variação da permeabilidade ao longo da profundidade, com locais que chegam a alternar os resultados de décimos de miliDarcys a milhares de miliDarcys, poucos metros abaixo ou acima.

Neste cenário a própria avaliação do conjunto de treinamento e a respectiva comparação dos resultados modelados é difícil. O uso de uma métrica única, como o cálculo do erro médio quadrático ou a comparação de uma variável estatística como a média aritmética pode levar a avaliações pobres ou erradas. Assim para todo conjunto de dados são apresentados os dados estatísticos básicos: Média, Mínimo, P25, P50, P75, Máximo, Desvio Padrão, Assimetria e Distribuição de Freqüência Lognormal da Permeabilidade.

- K Rocha do Poço I

O Poço I possui 144 valores de K rocha. A figura 23 apresenta o perfil de permeabilidade por profundidade do Poço, a tabela 1 apresenta sua estatística descritiva e a figura 24 apresenta sua distribuição de freqüência.

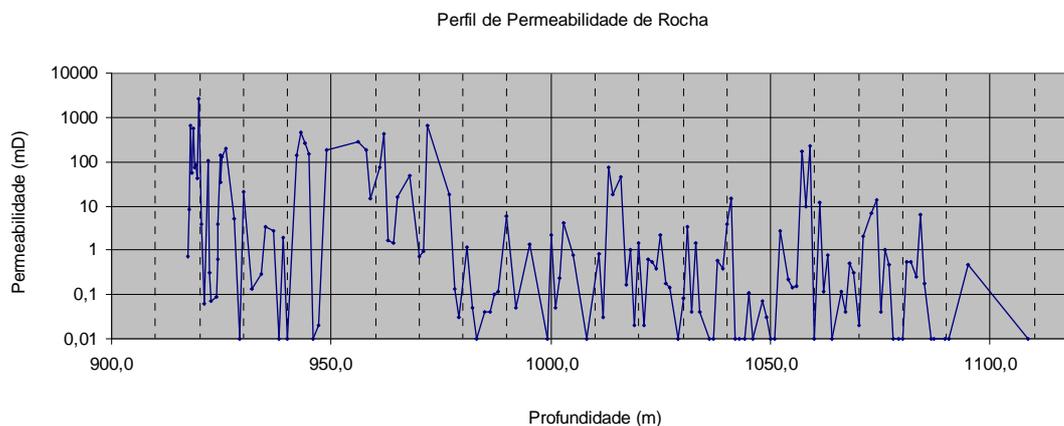


Figura 23 – Perfil de permeabilidade do Poço I

K rocha Poço PI - Estatística Descritiva	
Média (mD)	57,97
Mínimo (mD)	0,01
P25 (mD)	0,04
P50 (mD)	0,53
P75 (mD)	8,52
Máximo (mD)	2710,00
Desvio Padrão	248,48
Assimetria	8,95

Tabela 1 – Estatística descritiva do Poço I

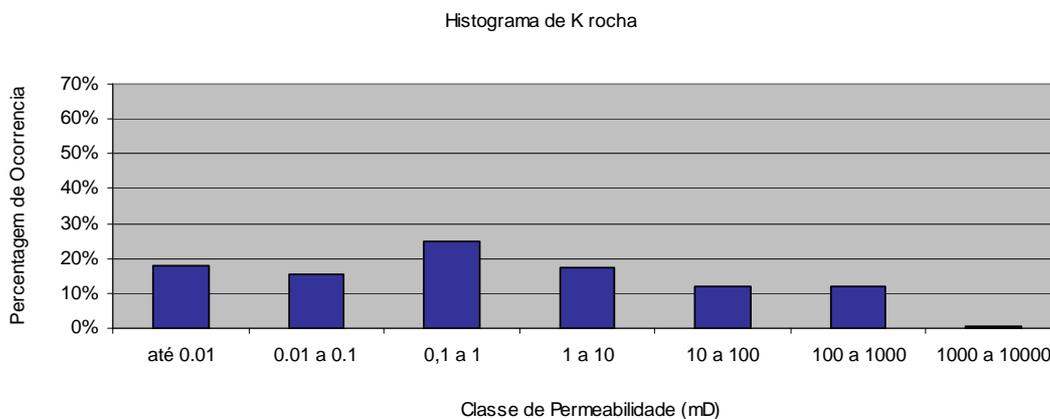


Figura 24 – Histograma de K rocha do Poço I

- K Rocha do Poço II

O Poço II possui 99 valores de K rocha. A figura 25 apresenta o perfil de permeabilidade por profundidade do poço, a tabela 2 apresenta sua estatística descritiva e a figura 26 apresenta sua distribuição de freqüência.

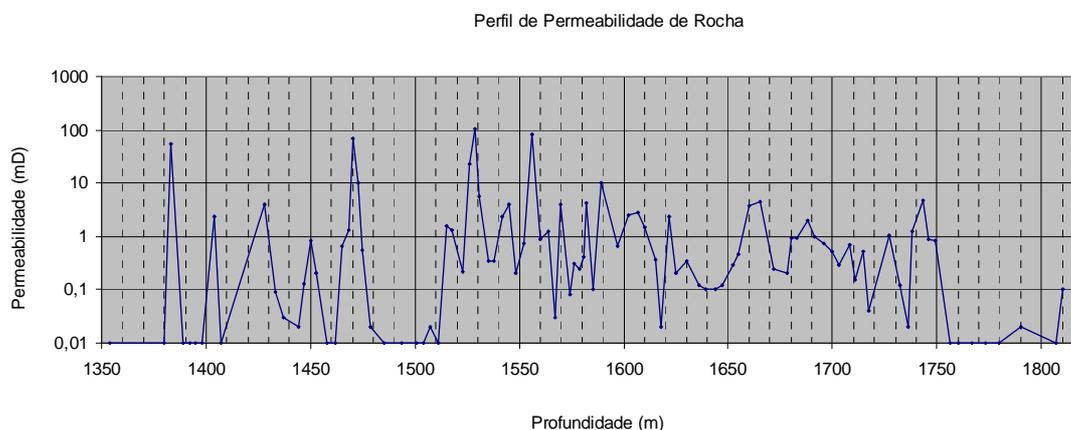


Figura 25 – Perfil de permeabilidade do Poço II

K rocha Poço PII - Estatística Descritiva	
Média (mD)	4,37
Mínimo (mD)	0,01
P25 (mD)	0,02
P50 (mD)	0,31
P75 (mD)	1,27
Máximo (mD)	106,00
Desvio Padrão	16,02
Assimetria	5,00

Tabela 2 – Estatística descritiva do Poço II

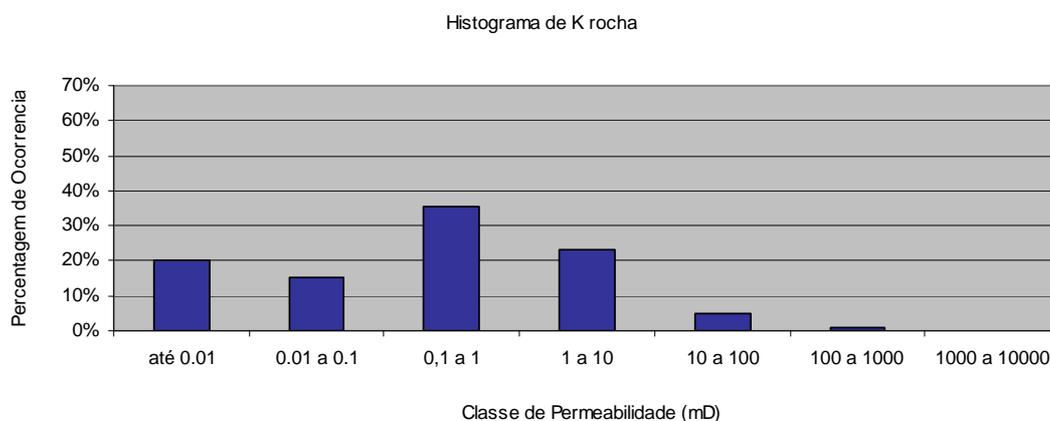


Figura 26 – Histograma de K rocha do Poço II

- K Rocha do Poço III

O Poço III possui 155 valores de K rocha. A figura 27 apresenta o perfil de permeabilidade por profundidade do poço, a tabela 3 apresenta sua estatística descritiva e a figura 28 apresenta sua distribuição de freqüência.

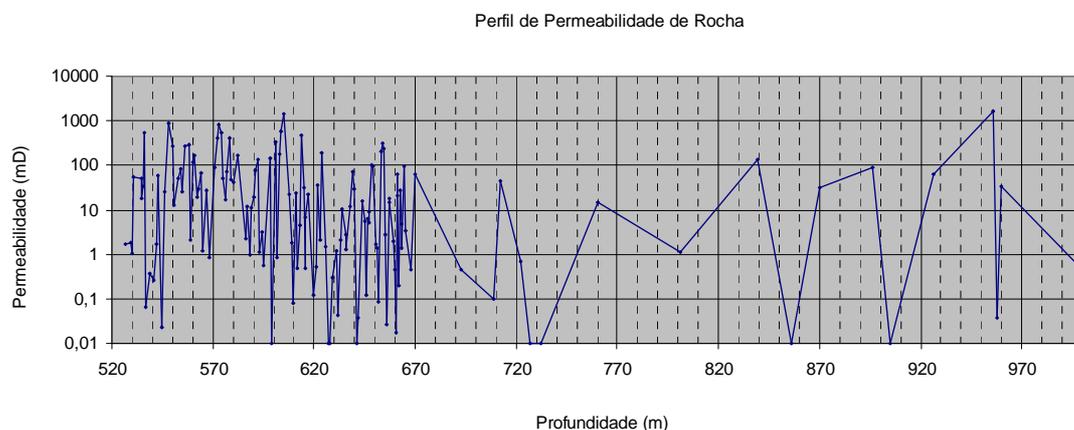


Figura 27 – Perfil de permeabilidade do Poço II

K rocha Poço PIII - Estatística Descritiva	
Média (mD)	85,16
Mínimo (mD)	0,01
P25 (mD)	0,52
P50 (mD)	6,89
P75 (mD)	61,05
Máximo (mD)	1662,00
Desvio Padrão	219,83
Assimetria	4,74

Tabela 3 – Estatística descritiva do Poço III

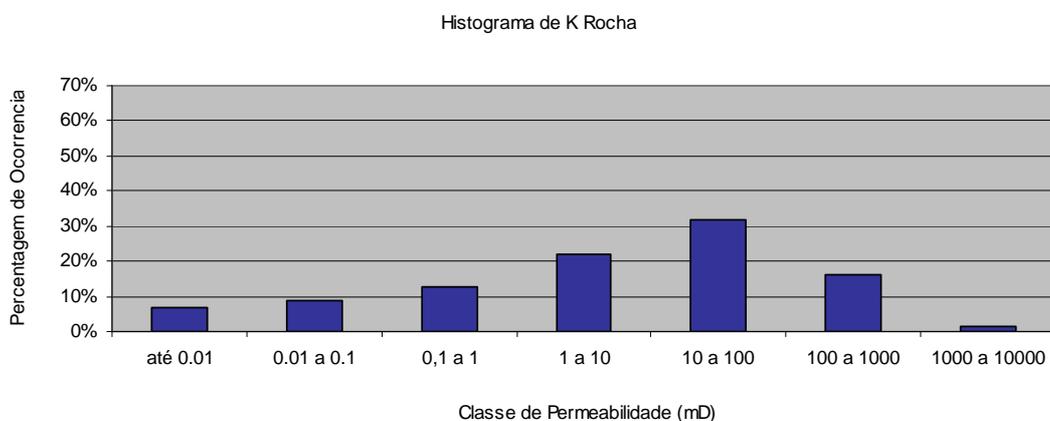


Figura 28 – Histograma de K rocha do Poço III

6.3 ESPECTRO DE T₂

Os espectros de T₂ são as variáveis preditoras do problema. Foram reunidos a partir de dados de perfis de RMN corridos nos poços. Apresenta-se como um conjunto de 30 pares ordenados (T₂ Característico x Amplitude).

- Espectro de T₂ do Poço I

O Poço I possui 144 observações, conjunto de pares ordenados retirados dos perfis na profundidade onde há dado de K rocha. A figura 29 apresenta gráfico matriz dos espectros e a figura 30 apresenta sua média e desvio padrão.

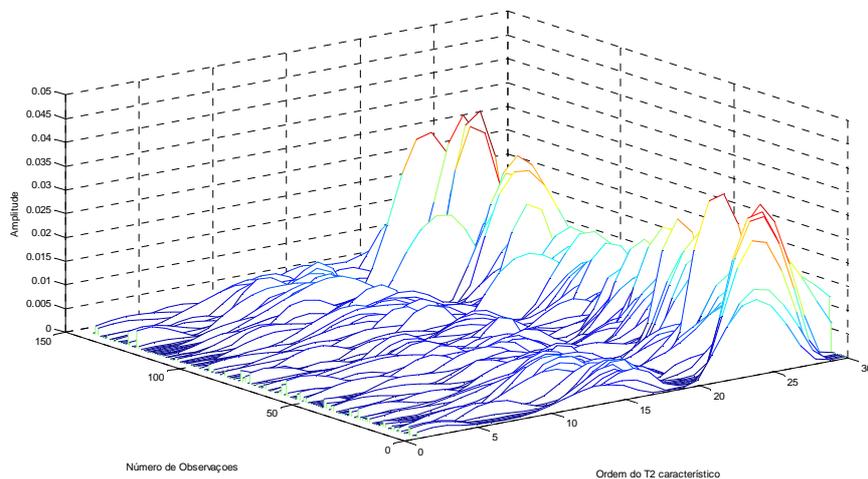


Figura 29 – Espectro de T₂ do Poço I

Média e Desvio Padrão dos Espectros de T₂

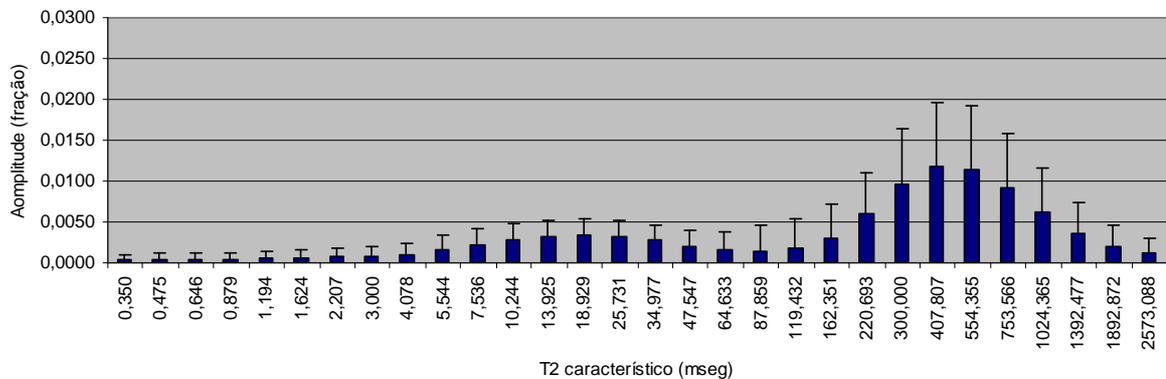


Figura 30 – Média e desvio padrão dos espectros de T₂ do Poço I

- Espectro de T_2 do Poço II

O Poço II possui 99 observações, conjunto de pares ordenados retirados dos perfis na profundidade onde há dado de K rocha. A figura 31 apresenta gráfico matriz dos espectros e a figura 32 apresenta sua média e desvio padrão.

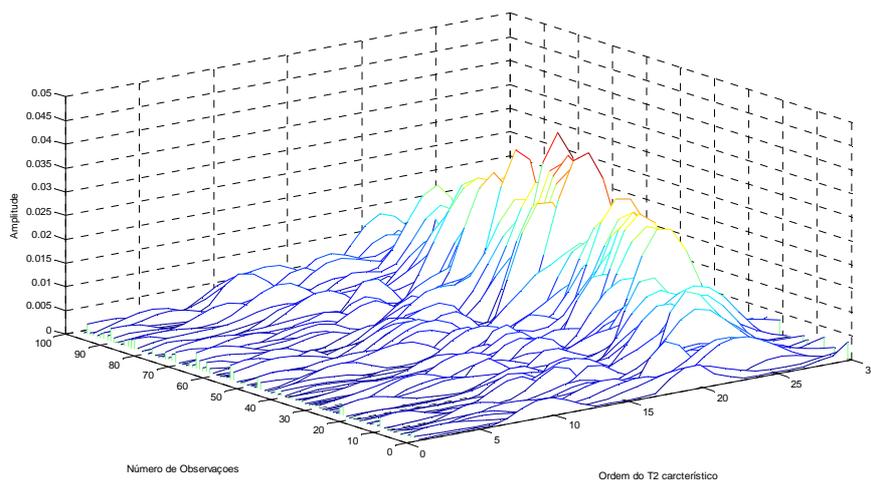


Figura 31 – Espectro de T_2 do Poço II

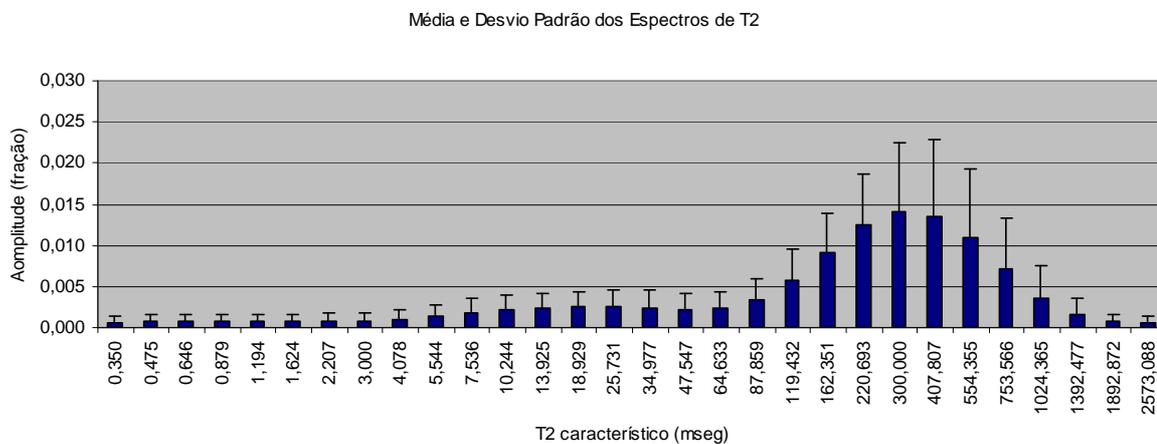


Figura 32 – Média e desvio padrão dos Espectros de T_2 do Poço II

- Espectro de T_2 do Poço III

O Poço III possui 155 observações, conjunto de pares ordenados retirados dos perfis na profundidade onde há dado de K rocha. A figura 33 apresenta gráfico matriz dos espectros e a figura 34 apresenta sua média e desvio padrão.

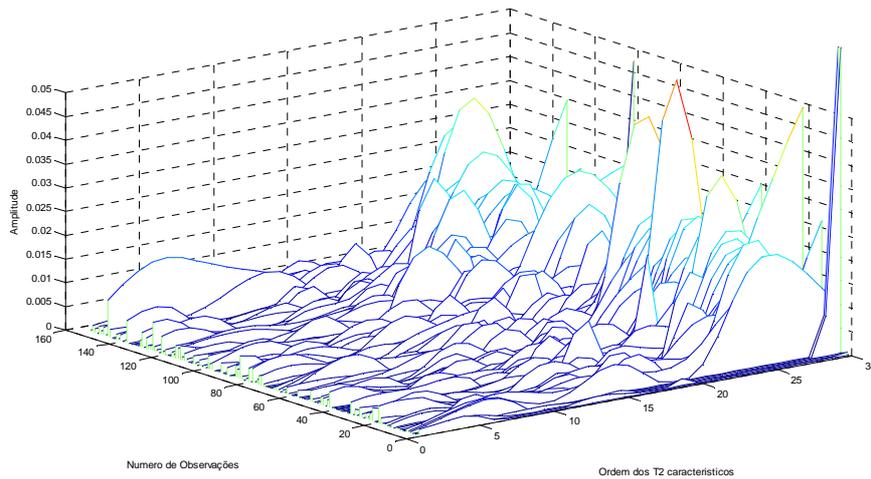


Figura 33 – Espectro de T_2 do Poço III

Média e Desvio Padrão dos Espectros de T_2

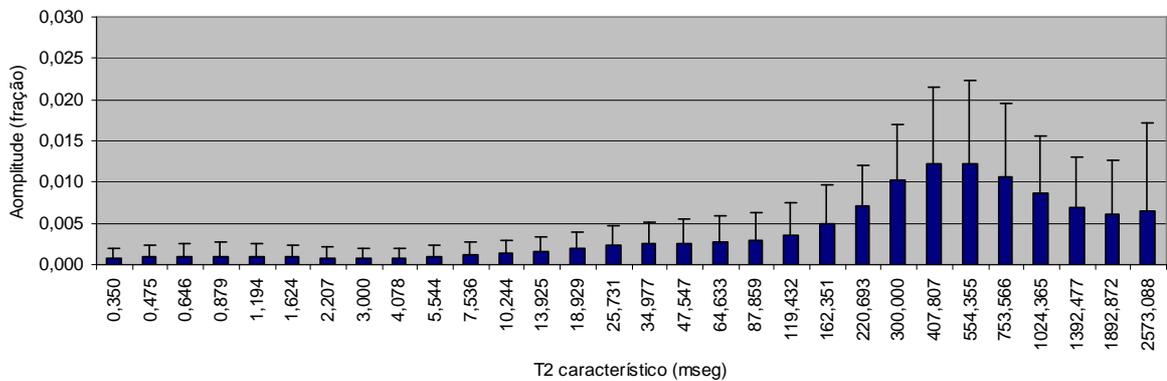


Figura 34 – Média e desvio padrão dos Espectros de T_2 do Poço III

6.4 MODELOS CLASSICOS DE PERMEABILIDADE DE PERFIL RMN

As equações SDR e de Timur Coates são consideradas as equações clássicas de estimativa de permeabilidade a partir de perfis de RMN.

Equação SDR

$$k_{SDR} = a \times \phi^4 \times T_{\log mean}^2 \quad \text{Equação (20)}$$

Onde:

- ϕ = Porosidade
- $T_{\log mean}$ = Posição no espectro de T2 correspondente a media geométrica.
- a = Coeficiente de ajuste litológico.

Equação de Timur Coates

$$k_{TIM} = a \times \phi^4 \times \left(\frac{FF}{BF} \right)^2 \quad \text{Equação (21)}$$

Onde:

- ϕ = Porosidade
- FF/BF = Razão entre volume de fluido livre (*free fluid*) e volume de fluido aprisionado por forcas capilares (*bound fluid*).
- a = Coeficiente de ajuste litológico.

As equações acima apresentam os coeficientes publicados nos trabalhos originais de Kenyon e Coates, tendo sido definidos empiricamente por ajustes a inúmeros ensaios laboratoriais. Neste estudo as equações clássicas de SDR e Timur foram parametrizadas para melhor ajuste possível aos dados de permeabilidade de rocha disponíveis. O método utilizado foi a linearização das equações originais seguida de regressão linear múltipla para ajuste aos dados de K rocha:

Parametrização de K SDR e K TIM

A forma geral da Equação SDR linearizada é:

$$\log k_{SDR} = \log a + b \times \log \phi + c \times \log T 2_{\log mean}$$

Equação (22)

A forma geral da equação de Timur Coates linearizada é:

$$\log k_{TIM} = \log a + b \times \log \phi + c \times \log \left(\frac{FF}{BF} \right)$$

Equação (23)

- Equação SDR do poço I.

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{SDR} = -2.1056 + 1.1032 \times \log \phi + 1.4581 \times \log T 2_{\log mean}$$

Equação (24)

Ou:

$$k_{SDR} = 0.0078 \times \phi^{1.1032} \times T 2_{\log mean}^{1.4581}$$

Equação (25)

- Equação TIM do poço I.

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{TIM} = 0,4859 + 0,9885 \times \log \phi + 1,344 \times \log \left(\frac{FF}{BF} \right)$$

Equação (26)

Ou

$$k_{TIM} = 3,0612 \times \phi^{0,9885} \times \left(\frac{FF}{BF} \right)^{1,344}$$

Equação (27)

A figura 35 apresenta o perfil de permeabilidade Timur Coates e SDR por profundidade do poço, a tabela 4 apresenta sua estatística descritiva e a figura 36 apresenta sua distribuição de freqüência.

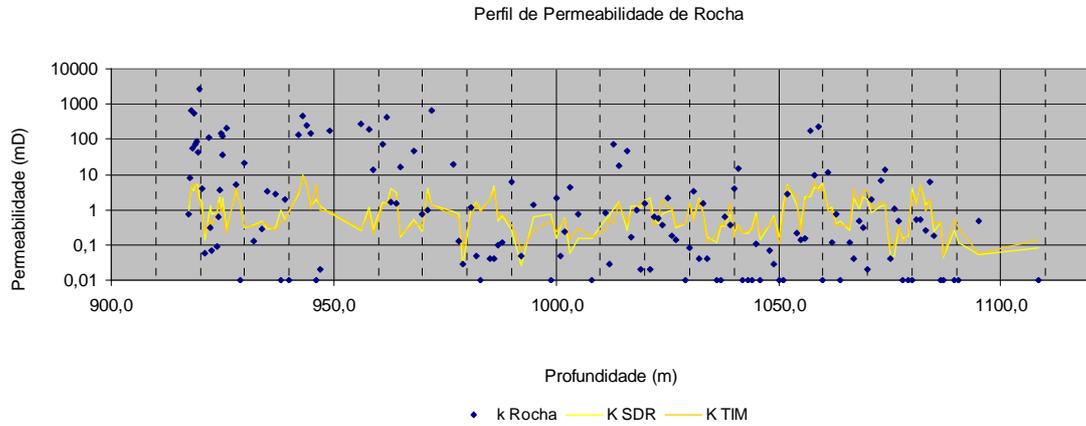


Figura 35 – Perfis K rocha, K SDR e K Timur do Poço I

Descritor	K rocha	K SDR	KTIM
Média (mD)	57,97	1,36	1,33
Mínimo (mD)	0,01	0,02	0,05
P25 (mD)	0,04	0,31	0,34
P50 (mD)	0,53	0,83	0,74
P75 (mD)	8,52	1,68	1,55
Máximo (mD)	2710,00	9,48	8,73
Desvio Padrão	248,48	1,53	1,54
Assimetria	8,95	2,13	2,02

Tabela 4 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço I

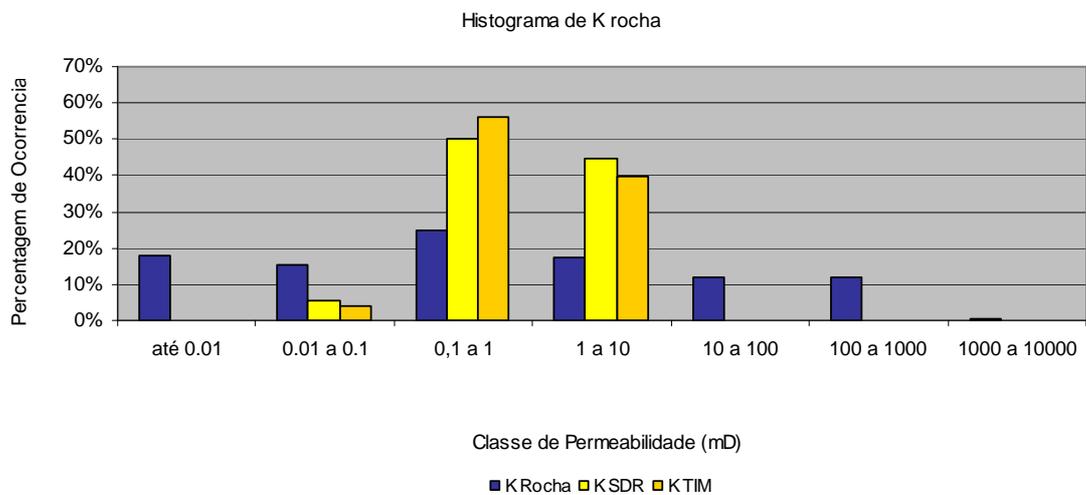


Figura 36 – Histograma de K rocha, K SDR e K TIM do Poço I

- Equação SDR do poço II

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{SDR} = -1.8518 + 1.3902 \times \log \phi + 1.2860 \times \log T 2_{\log mean}$$

Equação (28)

Ou

$$k_{SDR} = 0.0140 \times \phi^{1.3902} \times T 2_{\log mean}^{1.2860}$$

Equação (29)

- Equação TIM do poço II:

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{TIM} = 0.2499 + 1.2429 \times \log \phi + 1.1584 \times \log \left(\frac{FF}{BF} \right)$$

Equação (30)

Ou

$$k_{TIM} = 1.7778 \times \phi^{0.9885} \times \left(\frac{FF}{BF} \right)^{1.1584}$$

Equação (31)

A figura 37 apresenta o perfil de permeabilidade Timur Coates e SDR por profundidade do poço, a tabela 5 apresenta sua estatística descritiva e a figura 38 apresenta sua distribuição de frequência.

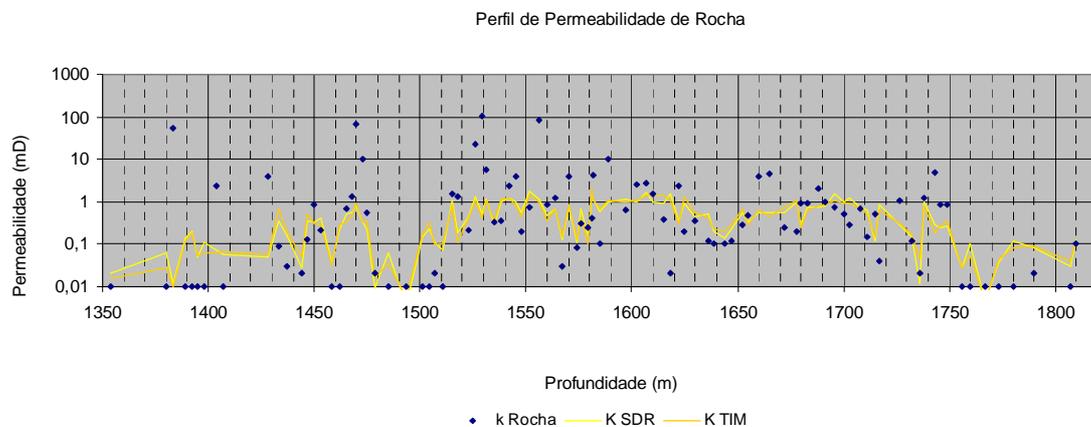


Figura 37 – Perfis K rocha, K SDR e K Timur do Poço II

Descritor	K rocha	K SDR	KTIM
Média (mD)	4,37	0,49	0,50
Mínimo (mD)	0,01	0,00	0,00
P25 (mD)	0,02	0,11	0,12
P50 (mD)	0,31	0,35	0,35
P75 (mD)	1,27	0,79	0,79
Máximo (mD)	106,00	2,04	1,78
Desvio Padrão	16,02	0,44	0,44
Assimetria	5,00	0,97	0,89

Tabela 5 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço II

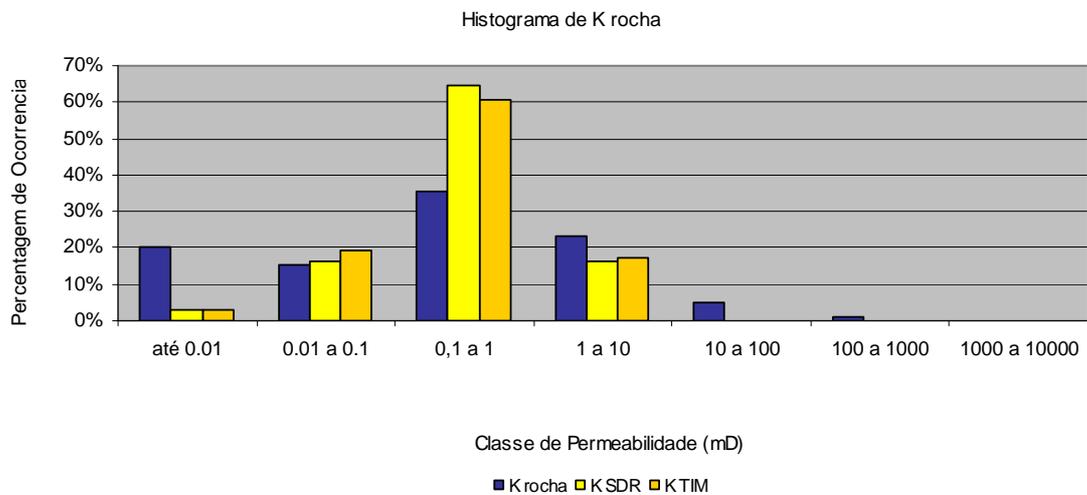


Figura 38 – Histograma de K rocha, K SDR e K TIM do Poço II

- Equação SDR do poço III:

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{SDR} = -0.8903 - 0.0323 \times \log \phi + 0.6957 \times \log T 2_{Logman}$$

Equação (32)

Ou

$$k_{SDR} = 0.1287 \times \phi^{-0.0323} \times T 2_{Logman}^{0.6957}$$

Equação (33)

- Equação TIM do poço III:

A regressão linear múltipla aplicada aos dados de K rocha é:

$$\log k_{TIM} = 0.7871 + 0.2560 \times \log \phi + 0.3864 \times \log \left(\frac{FF}{BF} \right)$$

Equação (34)

Ou

$$k_{TIM} = 6.1249 \times \phi^{0.2560} \times \left(\frac{FF}{BF} \right)^{0.38644}$$

Equação (35)

A figura 39 apresenta o perfil de permeabilidade Timur Coates e SDR por profundidade do poço, a tabela 6 apresenta sua estatística descritiva e a figura 40 apresenta sua distribuição de frequência relativa ao número de observações.

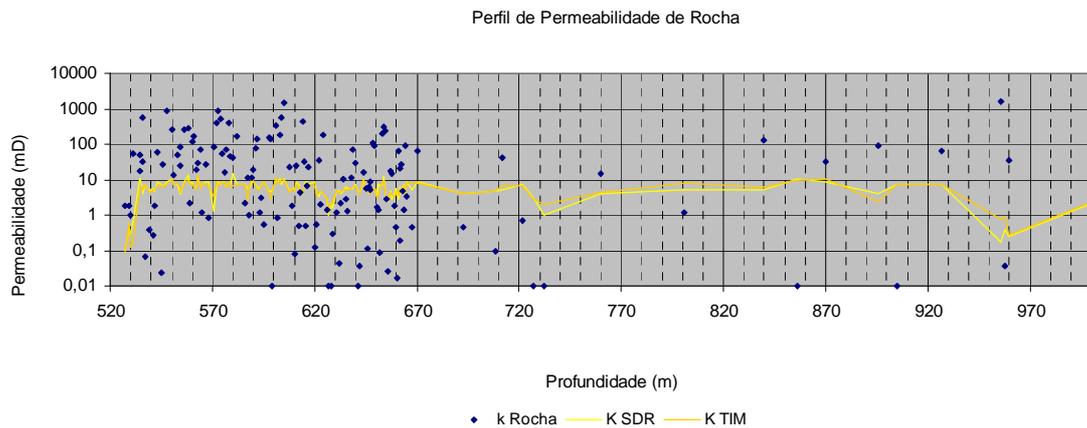


Figura 39 – Perfis K rocha, K SDR e K Timur do Poço III

Descritor	K rocha	K SDR	KTIM
Média (mD)	85,16	5,58	5,88
Mínimo (mD)	0,01	0,09	0,11
P25 (mD)	0,52	4,23	4,03
P50 (mD)	6,89	5,53	5,54
P75 (mD)	61,05	7,23	7,60
Máximo (mD)	1662,00	13,40	14,31
Desvio Padrão	219,83	2,54	2,90
Assimetria	4,74	0,01	-0,02

Tabela 6 – Estatística Descritiva de K rocha, K SDR e K TIM do Poço III

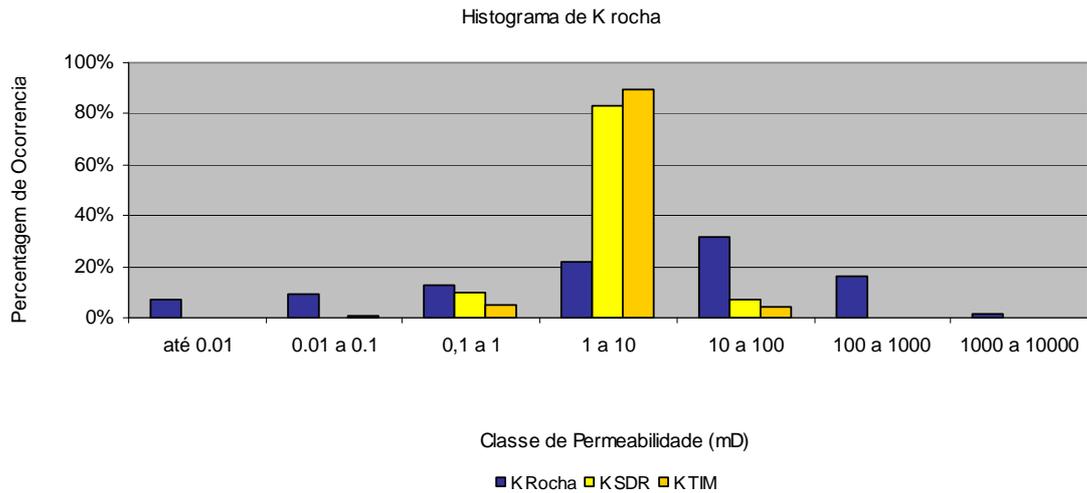


Figura 40 – Histograma de K rocha, K SDR e K TIM do Poço III

Os modelos clássicos de SDR e Timur Coates têm desempenho limitado, mesmo com a nova parametrização dos expoentes para ajuste aos dados de rocha. De forma geral, quando comparados aos dados tais modelos estreitam muito a distribuição em torno da moda e por isso são incapazes de honrar valores altos e baixos encontrados nos poços em estudo.

Uma das possibilidades para o baixo desempenho dos modelos clássicos em reservatórios complexos pode estar na sua fraca formulação. As suas variáveis: A razão entre volume de fluido livre (*free fluid*) e volume de fluido aprisionado por forças capilares (*bound fluid*), na equação de Timur Coates, e a média geométrica do espectro, na equação SDR, e a porosidade, em ambas, não possuem correlação clara e suficientemente robusta com a permeabilidade nestes tipos de reservatórios.

Em função desta observação e da premissa de que o espectro de T_2 do perfil RMN carrega informações correlacionadas com a permeabilidade é proposto um modelo que faz uso de inteligência computacional para explorar plenamente as informações presentes na assinatura do espectro de T_2 . Para tal é desenvolvido um modelo de Rede Neural Artificial (RNA) com dados reais de três reservatórios, conforme apresentado a seguir.

6.5 MODELO DE REDE NEURAL ARTIFICIAL PARA PERMEABILIDADE RMN

A escolha por RNA é principalmente devida ao fato de serem reconhecidas como excelentes preditoras de comportamentos não-lineares. Além disso é reconhecido que seus algoritmos podem lidar com a presença de ruídos provenientes da ferramenta, do ambiente de perfilagem (temperatura e pressão do reservatório, por exemplo) e do laboratório de medida de rocha.

Descrição da Rede Neural e Resultados

As RNAs desenvolvidas para cada poço têm como variáveis dependentes os pares ordenados de amplitudes e T_2 característico nos pontos (*bins*) do espectro de T_2 (no domínio de 0,3 a 3000 ms) e a variável independente foi a permeabilidade da rocha.

Inicialmente foi considerado que os 30 pares ordenados seriam as variáveis dependentes, porém a relação entre este número de variáveis e o número de observações em cada poço – de 144, 99 e 155, respectivamente para os poços PI, PII e PIII – trouxe instabilidade às primeiras redes treinadas, desta maneira fez-se imperiosa sua redução. Há na literatura inúmeras propostas de métodos computacionais para seleção de subconjuntos e transformação de variáveis. Neste estudo optou-se por utilizar conhecimento prévio especializado para determinar os critérios da tarefa de redução. Foram excluídas as variáveis com T_2 abaixo de 3ms uma vez que a interpretação corrente do perfil RMN considera esta uma região composta de material fino e argiloso (*clay bound*) que não influi na permeabilidade. Ainda sob uma relação desfavorável de variáveis e observações o espectro foi reduzido à metade pelo simples uso das variáveis de ordem par. Ao final são considerados os pares ordenados de ordem oitava à trigésima:

T_2 índice	i = 8	i = 10	i = 12	i = 14	i = 16	i = 18	i = 20	i = 22	i = 24	i = 26	i = 28	i = 30
Valor em ms	3,00	5,50	10,20	18,90	35,00	64,60	119,4	220,7	407,8	753,6	1392,5	2573,1

Tabela 7 – Seleção das variáveis dependentes no espectro de T_2

Foi utilizado software comercial chamado *Neuro Solutions*®, em sua versão número cinco, desenvolvido pela empresa *Neuro Dimensions*³⁰.

Nos três casos a rede montada é do tipo *Multilayer Perceptron* (MLP) de 3 camadas: Uma de entrada, com o vetor de variáveis independentes, uma intermediária, com três elementos de processamento e função de transferência do tipo tangente definida entre -1 e 1, e uma de saída e armazenagem de pesos, onde ficam os dados de rocha, os erros obtidos em cada passo da modelagem e os pesos aplicados sobre os elementos de processamento.

O algoritmo de treinamento utilizado é o de retropropagação, tendo sido separados vinte por cento das observações para validação cruzada. A métrica de erro considerada é o erro médio quadrático, EMQ, (*mean squared error, MSE*) dos valores reais e os modelados. O número de épocas é fixado em 1000 e o critério para armazenagem dos pesos é o menor valor de erro médio quadrático na validação cruzada. Estes valores foram no Poço I: 0,0764, no Poço II: 0,0652 e no Poço III: 0,1527.

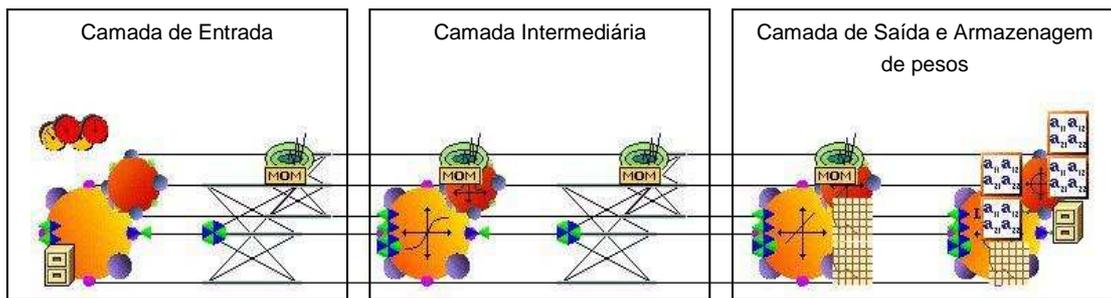


Figura 41 – Representação da rede neural utilizada na modelagem

A equação que define o erro médio quadrático é a seguinte:

$$EMQ = \frac{1}{N} \sum_{n=1}^N \left(K(n)_{\text{observado}} - \hat{K}(n)_{\text{modelado}} \right)^2$$

Equação (36)

Onde:

- N = Número de observações;
- K = Permeabilidade da rocha.

- K RNA do Poço I

A figura 42 apresenta o perfil de permeabilidade RNA por profundidade do poço, a tabela 8 apresenta sua estatística descritiva e a figura 43 apresenta sua distribuição de freqüência relativa ao número de observações.

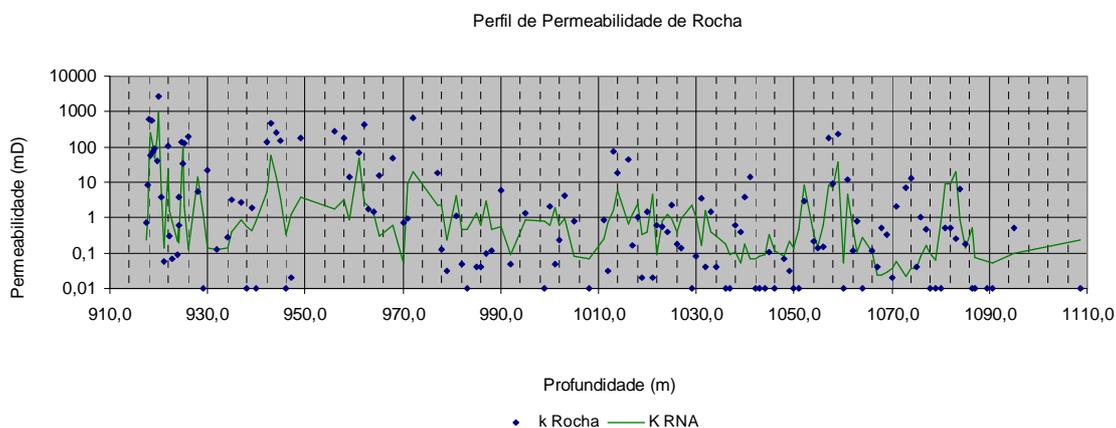


Figura 42 – Perfis K rocha e K RNA do Poço I

Descritor	K rocha	K RNA
Média (mD)	57,97	16,53
Mínimo (mD)	0,01	0,02
P25 (mD)	0,04	0,13
P50 (mD)	0,53	0,61
P75 (mD)	8,52	2,30
Máximo (mD)	2710,00	1054,47
Desvio Padrão	248,48	92,95
Assimetria	8,95	10,11

Tabela 8 – Estatística Descritiva de K rocha e K RNA do Poço I

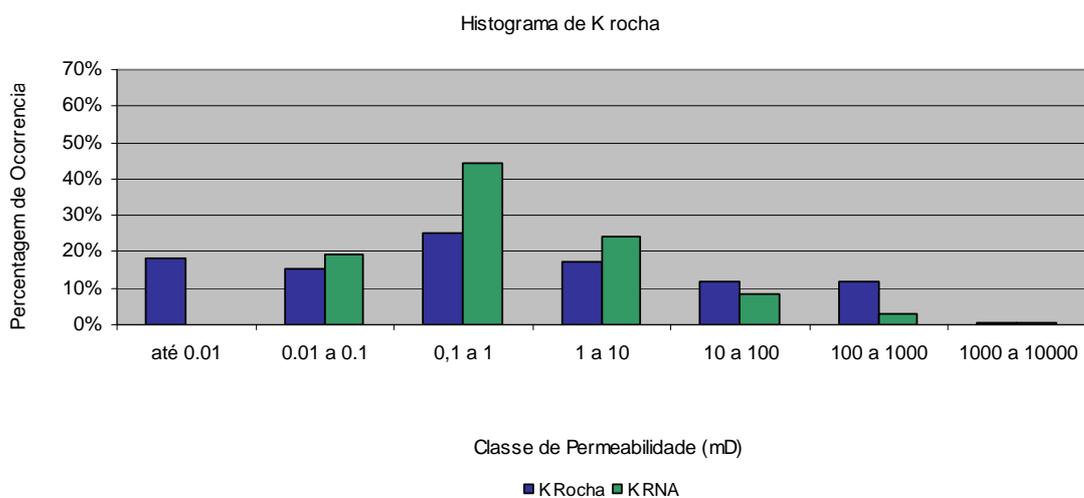


Figura 43 – Histograma de K rocha e K RNA do Poço I

- K RNA do Poço II

A figura 44 apresenta o perfil de permeabilidade RNA por profundidade do poço, a tabela 9 apresenta sua estatística descritiva e a figura 45 apresenta sua distribuição de freqüência relativa ao número de observações.

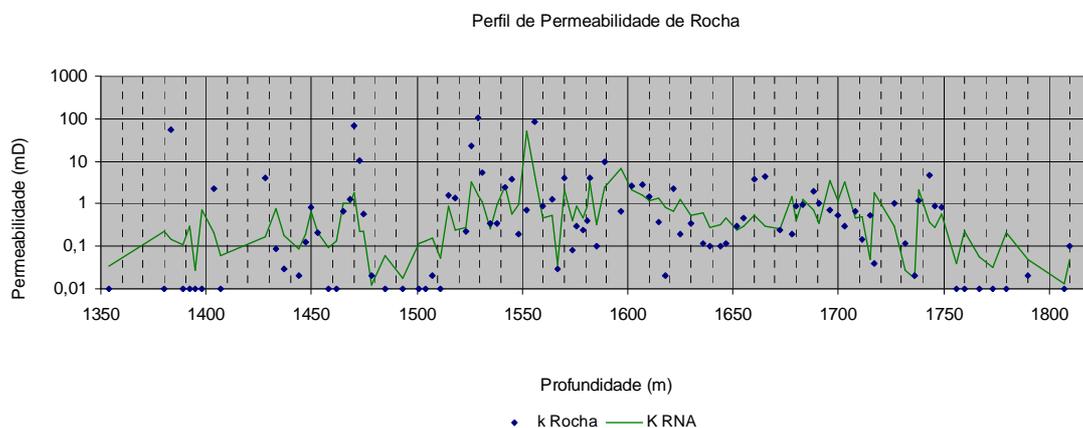


Figura 44 – Perfis K rocha e K RNA do Poço II

Descritor	K rocha	K RNA
Média (mD)	4,37	1,32
Mínimo (mD)	0,01	0,01
P25 (mD)	0,02	0,16
P50 (mD)	0,31	0,36
P75 (mD)	1,27	1,00
Máximo (mD)	106,00	52,74
Desvio Padrão	16,02	5,33
Assimetria	5,00	9,39

Tabela 9 – Estatística Descritiva de K rocha e K RNA do Poço II

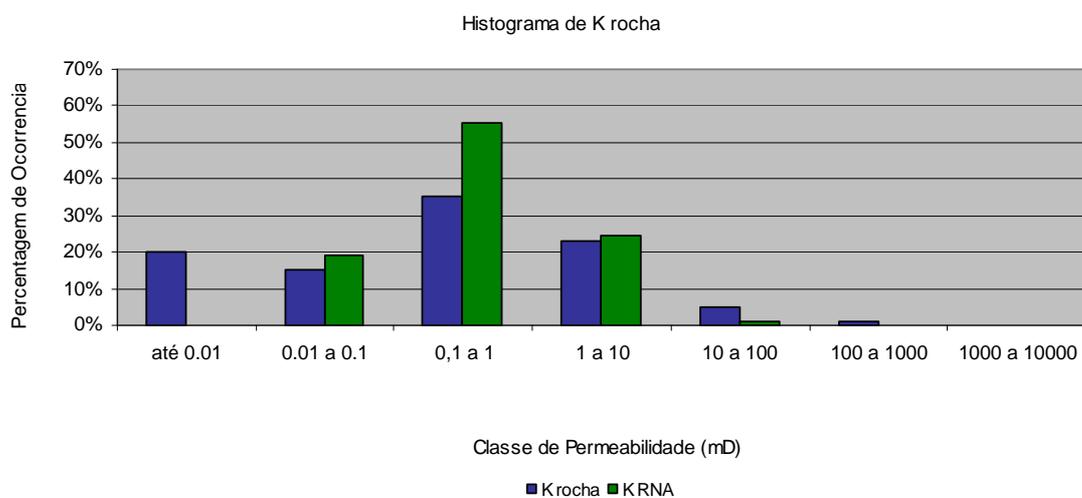


Figura 45 – Histograma de K rocha e K RNA do Poço II

- K RNA do Poço III

A figura 46 apresenta o perfil de permeabilidade RNA por profundidade do poço, a tabela 10 apresenta sua estatística descritiva e a figura 47 apresenta sua distribuição de frequência relativa ao número de observações.

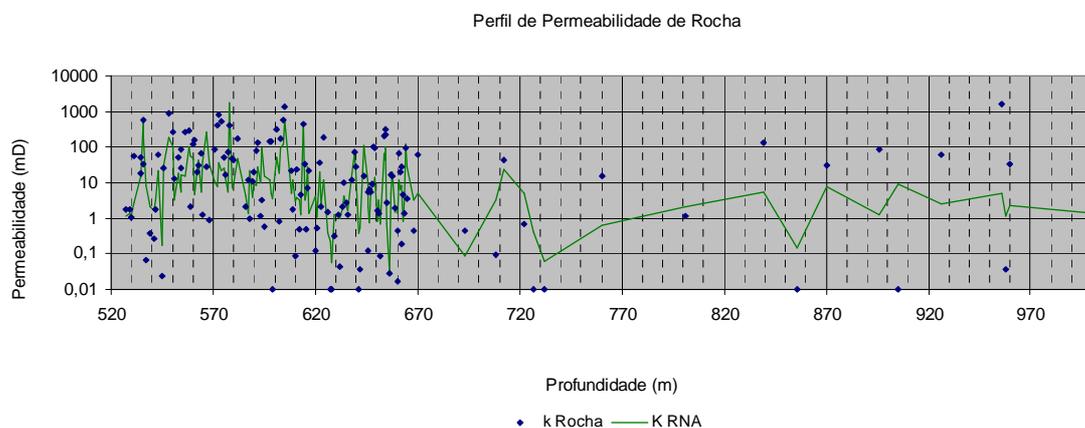


Figura 46 – Perfis K rocha e K RNA do Poço III

Descritor	K rocha	K RNA
Média (mD)	85,16	44,52
Mínimo (mD)	0,01	0,02
P25 (mD)	0,52	1,82
P50 (mD)	6,89	5,46
P75 (mD)	61,05	21,55
Máximo (mD)	1662,00	1854,57
Desvio Padrão	219,83	169,28
Assimetria	4,74	8,67

Tabela 10 – Estatística Descritiva de K rocha e K RNA do Poço III

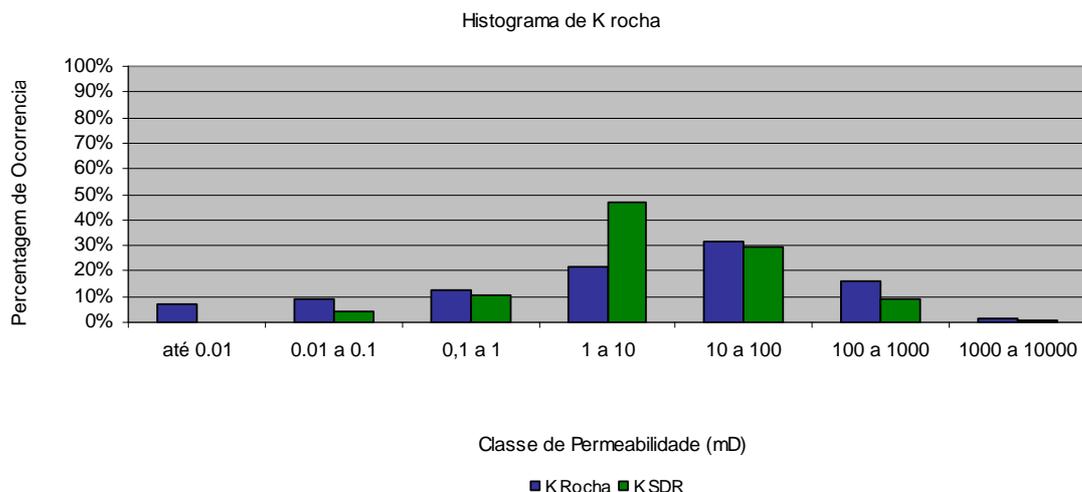


Figura 47 – Histograma de K rocha e K RNA do Poço III

Para teste de robustez do modelo foi feita a avaliação do seu desempenho extrapolado a todo o intervalo onde foi corrido o perfil de RMN:

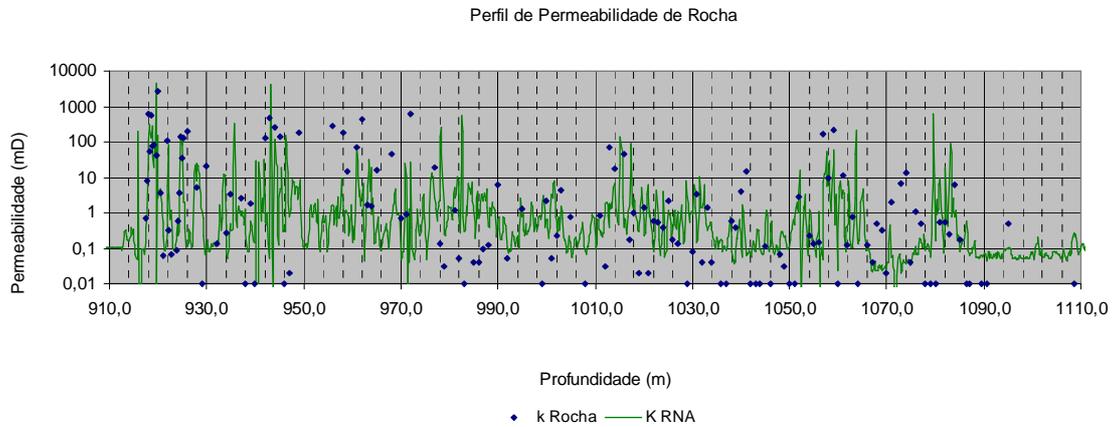


Figura 48 – Perfis K rocha e K RNA em toda a extensão do Poço I

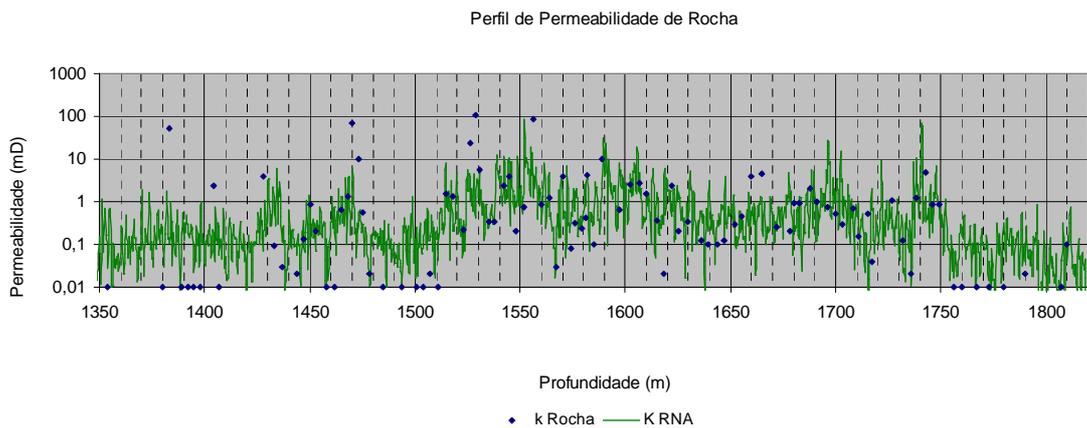


Figura 49 – Perfis K rocha e K RNA em toda a extensão do Poço II

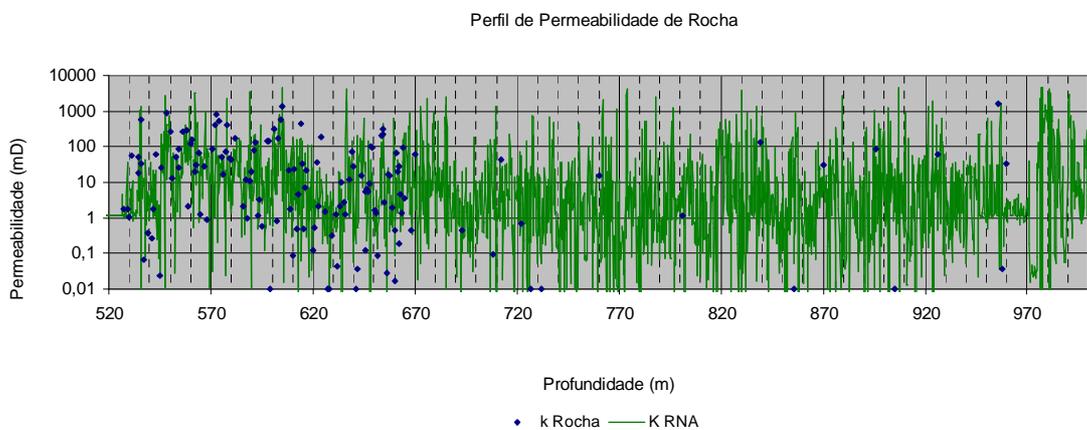


Figura 50 – Perfis K rocha e K RNA em toda a extensão do Poço III

6.6 COMENTÁRIOS FINAIS

Em função da alta complexidade da regressão proposta pode-se considerar que o modelo de Permeabilidade RMN por Redes Neurais obteve desempenho bastante satisfatório. Como comentado, não foi possível estabelecer métrica de erro única sob risco de se mal avaliar o desempenho do modelo. A análise conjunta dos dados estatísticos descritivos apresentaram resultados modelados em razoável aderência aos reais.

Para todos os poços a comparação entre os histogramas logarítmicos de resultados modelados e reais é muito boa. Nos modelos a distribuição de frequência têm comportamento mais aproximado a uma curva lognormal.

Em todos os poços os valores das modas (P50) são particularmente coincidentes. Os resultados do modelo proposto têm mais observações na classe da moda e uma distribuição mais estreita em torno dela. Em consequência disso a proporção de valores nas classes de alta permeabilidade é menor, o que impacta diretamente a medida da média, sistematicamente menor que a dos dados reais. Na outra ponta, os modelos não são capazes de honrar as classes de mais baixa permeabilidade, notavelmente a de 0,01 mD.

Quando comparado aos modelos clássicos de SDR e Timur Coates o modelo de Redes Neurais tem desempenho notavelmente superior. A análise conjunta dos dados estatísticos descritivos mostraram discrepâncias entre os modelos clássicos e os dados reais. Os valores das modas (P50) são também coincidentes nos modelos clássicos, por outro lado sua distribuição é drasticamente estreitada.

O teste de robustez do modelo pela extrapolação a todo intervalo perfilado apresenta excelente resultado. As tendências médias são respeitadas e não são gerados dados espúrios, anormalmente altos ou baixos para valores esperados nos poços.

7 CONCLUSÕES E RECOMENDAÇÕES

O trabalho apresenta metodologia alternativa para estimativa de permeabilidade absoluta de rochas com uso das informações do perfil de Ressonância Magnética Nuclear (RMN). É desenvolvido um modelo de Rede Neural Artificial (RNA) com dados reais de três reservatórios de estrutura porosa complexa. Para treinamento e teste da rede as variáveis preditoras são os pares ordenados que formam o espectro de T_2 e as variáveis preditas são os valores de permeabilidade de rochas ensaiadas em laboratório a partir de material recuperado do subsolo.

As equações clássicas de permeabilidade RMN utilizam a premissa de que o espectro de relaxação transversal representa a distribuição de tamanho de poros da zona investigada. Tais modelos possuem formulação simplificada e suas variáveis tem fraca correlação com a permeabilidade, seu desempenho é particularmente ruim nos reservatórios complexos, como foi nos casos deste trabalho.

O modelo de Permeabilidade RMN por Redes Neurais obteve desempenho bastante satisfatório. Quando comparada aos modelos clássicos de Kenyon e Timur-Coates é notavelmente superior.

A razão primeira para o sucesso relativo das RNA é a não linearidade do problema proposto. Outras razões são: A exploração mais eficiente das informações correlacionadas a permeabilidade presentes na assinatura do espectro de T_2 , tendo utilizado doze variáveis preditoras contra três dos modelos clássicos e o melhor tratamento dos ruídos provenientes da ferramenta e do ambiente de perfilagem.

Para melhoria das redes devem ser realizados desenvolvimentos a partir da incorporação de dados de novas campanhas de aquisição de perfis e amostras de rocha. Isto pode ser feito sob dois aspectos: Agrupando por conhecimento prévio as rochas de características semelhantes e criando redes especializadas ou agrupando indistintamente para determinação de um grande modelo. A primeira abordagem privilegia a acurácia dos dados em regiões conhecidas enquanto que a segunda abordagem prevê a possibilidade de se obter bons resultados em regiões não exploradas.

Sob ponto de vista computacional este trabalho utiliza modelos de redes simplificados do tipo *Multilayer Perceptron* (MLP) de apenas uma camada intermediária. Esta estratégia foi particularmente indicada em função da alta dificuldade da regressão proposta e da pequena disponibilidade de dados de treinamento. Foram feitas tentativas iniciais de uso de algoritmos de otimização para definição das redes complexas mas seus resultados não tiveram sucesso esperado nas avaliações cruzadas, tendo havido possível sobre-treino dos dados. Melhorias neste campo também devem ser feitas a partir da incorporação de novos dados.

Desenvolvimentos futuros de uso de inteligência computacional para caracterização da permeabilidade de reservatórios são ilimitados, além de diversos tipos de algoritmos, sejam baseados em redes neurais ou não, podem ser incorporadas informações que vão além dos perfis de RMN, tais como dados de outros perfis e testes de formação.

REFERENCIAS BIBLIOGRÁFICAS

-
- ¹ Thomas, J.E. Fundamentos de engenharia de petróleo -- Rio de Janeiro : Interciência, 2004. 271 p. il.
- ² Carvalho, R. S.; Rosa, A. J, Xavier, J. A. D.. *Engenharia de Reservatórios de Petróleo*; Rio de Janeiro: Interciência, 2006
- ³ Kenyon, W.E.: "Petrophysical Principles of Applications of NMR Logging," SPE Formation Evaluation, vol. 3, pp 622-636, 1988.
- ⁴ Kenyon, W.E., Day, P.E., Straley, C. and Willemsen, J.F.: "Petrophysical Principles of Applications of NMR Logging," The Log Analyst, March-April 1997
- ⁵ Coates, G.R. and Peveraro, R.C.A.: "The MRI Log Characterized by Comparison with Petrophysical Properties and Lab Core Data", paper SPE 22723 presented at 66th Annual Technical Conference & Exhibition of the SPE held in Dallas, TX. Oct 6-9, 1991
- ⁶ Coates, G.R, Xiao, L, Prammer, M.G., *NMR Logging: Principles and Applications*, Halliburton Energy Services Publication H02308, 1999
- ⁷ Chang, D, Vinegar, H., Morriss, C., and Straley, C., 1997, "Effective porosity, producible fluid and permeability in carbonates from NMR logging," The Log Analyst, vol. 38 (2), pp. 60–72
- ⁸ Darcy, H.. *Les Fontaines Publiques de la Ville de Dijon.*, Paris, Dalmont 1856
- ⁹ Thomas, J.E. Fundamentos de engenharia de petróleo -- Rio de Janeiro : Interciência, 2004. 271 p. il.
- ¹⁰ Carman, P.C. "Fluid Flow Through a Granular Bed", trans. Institution of Chemical Engineers (London), vol. 15, 1506, 1937
- ¹¹ Kozeny, J. "Über Kapillare Leitung des Wassers Im Boden: Sitzungsber", Akad. Wiss. Wien, vol 136, 27-306, 1927
- ¹² Krumbein, W.C. and Monk, G.D.: "Permeability as a Function of the Size Parameters of Unconsolidated Sand," Trans., AIME (1943) 151, 153
- ¹³ Tixier, M.P.: "Evaluation of Permeability From Electric-Log Resistivity Gradients," Oil and Gas J. (June 1949) 48, No. 6, 113.
- ¹⁴ Wyllie, M.R.J. and Rose, W.D.: " Some Theoretical Considerations Related to the Quantitative Evaluation of the Physical Characteristics of Reservoir Rock from Electrical Log Data", Petroleum Transactions, AIME, Vol. 189, 1950.
- ¹⁵ Timur, A.: "An Investigation of Permeability and Porosity, and Residual Water Saturation Relationship for Sandstone Reservoirs," The Log Analyst (July–August 1968) 9, No. 4, 8.
- ¹⁶ Coates, G.R. and Dumanoir, J.L.: "A New Approach to Improved Log Derived Permeability", The Log Analyst (Jan – Feb) 1974, pp.17.
- ¹⁷ Coates, G. R., and S. Denoo, The producibility answer product: Schlumberger Technical Review, v. 29, no. 2, 1981, p. 54–63.
- ¹⁸ Blumich, Bernhard. *Essential NMR for scientists and engineers [meio eletrônico]* -- Berlin : Springer, c2005.
- ¹⁹ Dunn, K.-J. *Nuclear magnetic resonance : petrophysical and logging applications* -- Amsterdam : Pergamon, 2002. 293 p. il. (Handbook of geophysical exploration : seismic exploration 32)
- ²⁰ Chang, D, Vinegar, H., Morriss, C., and Straley, C., 1997, "Effective porosity, producible fluid and permeability in carbonates from NMR logging," The Log Analyst, vol. 38 (2), pp. 60–72.

-
- ²¹ Kantzas, A., Mai, A., An Evaluation of the Application of Low Field NMR in the Characterization of Carbonate Reservoirs, paper SPE 77401, presented at SPE Annual Technical Conference and Exhibition, 29 September-2 October 2002, San Antonio, Texas
- ²² Di Rosa, D., Gyllensten, A., Chen, S., Li, W., Georgi, D., and Tauk, R., 2006, "Use of the NMR diffusivity log to identify and quantify oil and water in carbonate formations", SPE 101396, Abu Dhabi International Petroleum Exhibition and Conference held in Abu Dhabi, U.A.E., 5-8 November.
- ²³ Han, J., Kamber, M. Data Mining: Concepts and Techniques. 2ª edição, São Francisco, Morgan Kaufmann, 2006.
- ²⁴ Rezende, S. O. Sistemas inteligentes: fundamentos e aplicações. 1ª edição, Barueri, Manole, 2003.
- ²⁵ Silberschatz, A., Tuzhilin, A.. On subjective measurements of interestingness in knowledge Discovery> Proceedings of the First International Conference On Knowledge Discovery and Data Mining 1, 275-281, 1995.
- ²⁶ Lavrac, N., Flach, P., Zupan, R. Rule evaluation measures: A unifying view. Proceedings of the Ninth International Workshop on Inductive Logic Programming. Volume 1634, 74-185, Springer-Verlag Lecture Notes in Artificial Intelligence, 1999.
- ²⁷ McCulloch, W.S., Pitts, W, "A logical calculus of the ideas immanent in nervous activity", Bulletin of Mathematical Biophysics, v. 5, pages 115-133, 1943.
- ²⁸ Haykin, S. Redes neurais: princípios e prática. 2ª edição, Porto Alegre, Bookman, 2001.
- ²⁹ Silva, L. C. F da, Inteligência Computacional para Predição de Produção de Reservatórios de Petróleo, Tese de Doutorado, COPPE/UFRJ, Engenharia Civil, 2006.
- ³⁰ <http://www.nd.com/>

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)