



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO (CTC)  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Daniel Theisges dos Santos

**Redes Neurais Profundas Aplicadas na Análise Litoestratigráfica Sedimentar**

Florianópolis  
2022

Daniel Theisges dos Santos

**Redes Neurais Profundas Aplicadas na Análise Litoestratigráfica Sedimentar**

Tese submetida ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Santa Catarina para a obtenção do título de doutor em Ciência da Computação.  
Orientador: Prof. Dr. Mauro Roisenberg  
Coorientador: Prof. Dr. Marivaldo dos Santos Nascimento

Florianópolis  
2022

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Santos, Daniel Theisges dos  
Redes Neurais Profundas Aplicadas na Análise  
Litoestratigráfica Sedimentar / Daniel Theisges dos Santos  
; orientador, Mauro Roisenberg, coorientador, Marivaldo  
Nascimento, 2022.  
82 p.

Tese (doutorado) - Universidade Federal de Santa  
Catarina, Centro Tecnológico, Programa de Pós-Graduação em  
Ciência da Computação, Florianópolis, 2022.

Inclui referências.

1. Ciência da Computação. 2. Classificação automática de  
fácies.. 3. Redes neurais recorrentes. . 4. Segmentação  
semântica. . 5. Redes neurais convolucionais.. I.  
Roisenberg, Mauro. II. Nascimento, Marivaldo. III.  
Universidade Federal de Santa Catarina. Programa de Pós  
Graduação em Ciência da Computação. IV. Título.

Daniel Theisges dos Santos

**Redes Neurais Profundas Aplicadas na Análise Litoestratigráfica Sedimentar**

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Dr. Wagner Moreira Lupinacci  
Universidade Federal Fluminense (UFF)

Prof. Dr. Maurício Edgar Stivanello  
Instituto Federal de Santa Catarina (IFSC)

Prof. Dr. Rafael de Santiago  
UNIVERSIDADE FEDERAL DE SANTA CATARINA (UFSC)

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutor em Ciência da Computação.

---

Coordenação do Programa de  
Pós-Graduação

---

Prof. Dr. Mauro Roisenberg  
Orientador

Florianópolis, 2022.

## **AGRADECIMENTOS**

A Deus, pela minha vida, e por me permitir ultrapassar todos os obstáculos encontrados ao longo da realização deste trabalho.

Bruna Kahl, minha amada noiva, sem o seu apoio e companheirismo essa tese não seria possível. Obrigada por ser tão atenciosa e por entender minha ausência em diferentes momentos.

Aos meus pais e sogros, pelo amor e pelo apoio dados nos momentos difíceis.

Ao meu orientador Mauro pela ajuda, motivação e paciência dada durante a realização deste trabalho e por aceitar orientar o meu trabalho no meio do andamento do curso.

Ao meu coorientador Marivaldo pela sua ajuda e motivação em me instruir nesse tema fascinante.

## RESUMO

A determinação de litofácies e da forma e extensão dos estratos são etapas importantes para a caracterização de reservatórios. No caso de afloramentos, onde as rochas estão expostas, o mapeamento e o acesso em afloramentos com ampla continuidade lateral e vertical pode ser difícil devido à sua posição geográfica. Quando as rochas não estão expostas utiliza-se perfis de poços, no entanto as curvas de perfil do poço nem sempre são suficientes para determinar a litologia, pois algumas vezes os sinais são semelhantes para diferentes litologias. Este trabalho tem por objetivo aplicar o estudo de arquiteturas de Deep Learning para identificar litofácies em imagens de afloramento capturadas por Veículo Aéreo Não-Tripulado (VANT) e identificar padrões de litofácies em perfis de poços. Para afloramentos, arquiteturas de Redes Neurais Convolucionais de Segmentação foram utilizadas para identificar automaticamente os estratos aflorantes em um conjunto de imagens VANT de afloramentos com sistemas turbidíticos do Grupo Itararé (Bacia do Paraná, Brasil). Já para perfis de poços, Redes Neurais Recorrentes foram utilizadas para aprender dependências de longo prazo entre etapas de tempo de dados de sequência e aplicadas em um conjunto de poços da Formação Rio Bonito (Bacia do Paraná, Brasil). Ambos os estudos mostraram bons desempenhos dos métodos propostos quando comparados a outros métodos tradicionais.

**Palavras-chave:** Classificação automática de fácies. Redes neurais recorrentes. BiLSTM. Segmentação semântica. Redes neurais convolucionais.

## ABSTRACT

The determination of lithofacies and the shape and extent of the strata are important steps for the characterization of reservoirs. In the case of outcrops, where rocks are exposed, mapping and accessing outcrops with broad lateral and vertical continuity can be difficult due to their geographic position. When the rocks are not exposed, well logs are used, however the well log curves are not always sufficient to determine the lithology, as sometimes the signs are similar for different lithologies. This work aims to apply the study of Deep Learning architectures to identify lithofacies in outcrop images captured by Unmanned Aerial Vehicles (UAVs) and to identify lithofacies patterns in well logs. For outcrops, Segmentation Convolutional Neural Network architectures were used to automatically identify the outcrop strata in a set of UAV images of outcrops with turbidite systems from the Itararé Group (Paraná Basin, Brazil). For well profiles, Recurrent Neural Networks were used to learn long-term dependencies between time steps of sequence data and applied to a set of wells in the Rio Bonito Formation (Paraná Basin, Brazil). Both studies showed good performance of the proposed methods when compared to other traditional methods.

**Keywords:** Automatic facies classification. Recurrent neural networks. BiLSTM. Semantic Segmentation. Convolutional neural networks.

## LISTA DE FIGURAS

|   |    |
|---|----|
| Figura 1 – Bloco diagrama de um sistema fluvial entrelaçado ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).  | 19 |
| Figura 2 – Bloco diagrama de um sistema fluvial anastomosado ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).   | 20 |
| Figura 3 – Bloco diagrama de um sistema fluvial meandrante ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).   | 21 |
| Figura 4 – Arquitetura detalhada dos tratos de sistemas e superfícies estratigráficas associadas (CATUNEANU, 2006).   | 22 |
| Figura 5 – Assinaturas gamaespectrométricas típicas dos principais litotipos sedimentares, adaptado de (RIDER, 1990).   | 23 |
| Figura 6 – Variação em média de valores de K, U & Th para rochas ígneas com aumento de sílica (DICKSON; SCOTT, 1997).   | 24 |
| Figura 7 – Exemplo de relação de padrões de raio gama com a correspondente interpretação sedimentar (SERRA; SULPICE <i>et al.</i> , 1975).  | 25 |
| Figura 8 – . (A) Mapa geológico simplificado da Bacia do Paraná (modificado de Edison José Milani, França e Medeiros (2007)), e (B) as principais estruturas geológicas regionais (Modificado de Zalán <i>et al.</i> (1987); Fúlfaro <i>et al.</i> (2018)). | 28 |
| Figura 9 – Operação de convolução em uma camada convolucional.  | 31 |
| Figura 10 – Operação de <i>pooling</i> em redes convolucionais.   | 31 |
| Figura 11 – Arquitetura da rede de segmentação semântica U-net.   | 33 |
| Figura 12 – Arquitetura da rede neural de segmentação DeepLab V3+.  | 34 |
| Figura 13 – Arquitetura básica de uma rede neural artificial.   | 35 |
| Figura 14 – Arquitetura básica de uma rede neural recorrente (OLAH, 2015).  | 36 |
| Figura 15 – Arquitetura básica de uma rede neural recorrente (NG <i>et al.</i> , 2017).   | 36 |
| Figura 16 – Rede neural recorrente com <i>back propagation</i> (NG <i>et al.</i> , 2017).   | 37 |
| Figura 17 – Diferentes tipos de aplicações usando redes neurais recorrentes (OLAH, 2015).   | 38 |
| Figura 18 – Unidade interna de uma LSTM (OLAH, 2015).   | 39 |
| Figura 19 – Estrutura de uma RNN Bidirecional comum (OLAH, 2015).   | 41 |
| Figura 20 – Arquitetura desdobrada do LSTM bidirecional com três etapas consecutivas (SALEHINEJAD <i>et al.</i> , 2017).  | 42 |

|  |    |
|--|----|
| Figura 21 – Mapa da localidade de Barro Branco, região de Lauro Müller, onde os 20 poços foram perfurados. . . . .   | 49 |
| Figura 22 – Mapa contendo informações geológicas e estatigráficas da região onde os poços foram perfurados. . . . .  | 51 |
| Figura 23 – Parte de um dos arquivos originais contendo as leituras de curva de um poço. . . . .   | 52 |
| Figura 24 – Escala de Krumbein para valores granulométricos. . . . .   | 53 |
| Figura 25 – Exemplo de transição de classes granulométricas presentes no arquivo de leitura de poço. . . . .   | 54 |
| Figura 26 – Arquitetura Bidirectional LSTM desenvolvida no trabalho para classificação. . . . .  | 55 |
| Figura 27 – Arquitetura Bidirectional LSTM desenvolvida no trabalho para regressão. . . . .  | 56 |
| Figura 28 – Matriz de correlação entre as características das leituras em relação a classe da base de dados. . . . .   | 57 |
| Figura 29 – Medições de registros de poço e comparativos de classificação de fácies entre a verdade do solo e os valores preditos de fácies. . . .   | 61 |
| Figura 30 – Padrões a serem identificados no desafio (Adaptado de (EMERY; MYERS, 2009). . . . .  | 63 |
| Figura 31 – Análise do pior caso previsto na base de dados. (A) Classe Correta; (B) Classe prevista. . . . .   | 64 |
| Figura 32 – (A) Estudo da localização do afloramento na Bacia do Paraná; (B) modelo digital com orientação oeste-leste usando fotogrametria; e (C) classificação de fácies com base em métodos convencionais de mapeamento, incluindo correlação a posteriori. . . . . | 66 |
| Figura 33 – Imagens pertencentes ao dataset gerado com as respectivas classes. . . . .   | 67 |
| Figura 34 – Rede neural implementada em pesquisa baseada em DeepLab V3 e Point- Rend. . . . .  | 69 |
| Figura 35 – Resultado da segmentação para os 3 modelos gerados. . . . .  | 70 |

## LISTA DE TABELAS

|   |    |
|---|----|
| Tabela 1 – Trabalhos Relacionados e Suas Características . . . . .  | 48 |
| Tabela 2 – Trabalhos Relacionados e Suas Características . . . . .  | 48 |
| Tabela 3 – Litofácies presentes na base de dados . . . . .  | 58 |
| Tabela 4 – Ordem de relevância das variáveis com o modelo XGBoost . . . . .   | 59 |
| Tabela 5 – Comparação dos resultados da classificação de fácies usando a abordagem proposta com XGBoost, Random Forest, Naïve Bayes e SVM . . . . . | 62 |
| Tabela 6 – Litofácies presentes na base de dados . . . . .  | 63 |
| Tabela 7 – Métricas de cinco imagens extraídas por meio de modelos diferentes.  | 70 |

## LISTA DE ABREVIATURAS E SIGLAS

|      |                                      |
|------|--------------------------------------|
| API  | American Petroleum Institute         |
| CNN  | Convolutional Neural Network         |
| GP   | Gaussian Process                     |
| GR   | Gamma Ray                            |
| K    | Potássio                             |
| LSTM | Long Short-Term Memory               |
| RNA  | Rede Neural Artificial               |
| RNN  | Recurrent Neural Network             |
| SVM  | Support Vector Machine               |
| Th   | Tório                                |
| TS   | Tratos de Sistemas                   |
| TSNA | Tratos de Sistemas Nível Alto        |
| TSNB | Tratos de Sistemas de Nível Baixo    |
| TSNQ | Tratos de Sistemas de Nível em Queda |
| TST  | Transgressivo                        |
| U    | Urânio                               |
| VANT | Veículo Aéreo Não-Tripulado          |

## SUMÁRIO

|              |  |           |
|--------------|--|-----------|
| <b>1</b>     | <b>INTRODUÇÃO</b>  | <b>13</b> |
| 1.1          | MOTIVAÇÃO E JUSTIFICATIVA  | 14        |
| 1.2          | OBJETIVOS DA TESE  | 16        |
| <b>1.2.1</b> | <b>Objetivo Geral</b>  | <b>16</b> |
| <b>1.2.2</b> | <b>Objetivos Específicos</b>   | <b>16</b> |
| <b>1.2.3</b> | <b>Estrutura da Tese</b>   | <b>17</b> |
| <b>2</b>     | <b>FUNDAMENTAÇÃO TEÓRICA</b>   | <b>18</b> |
| 2.1          | SISTEMAS DEPOSICIONAIS   | 18        |
| <b>2.1.1</b> | <b>Fácies</b>  | <b>18</b> |
| <b>2.1.2</b> | <b>Sistemas Depositionais Fluviais</b>   | <b>19</b> |
| <b>2.1.3</b> | <b>Estratigrafia de Sequências em Ambientes Costeiros</b>                                  | <b>20</b> |
| <b>2.1.4</b> | <b>Padrões de Raios-gama em Rochas Sedimentares</b>  | <b>21</b> |
| <b>2.1.5</b> | <b>Sistemas Depositionais Turbidíticos</b>   | <b>26</b> |
| 2.2          | CONTEXTO GEOLÓGICO E ESTRATIGRÁFICO  | 26        |
| <b>2.2.1</b> | <b>Bacia do Paraná</b>   | <b>27</b> |
| <b>2.2.2</b> | <b>Formação Rio Bonito</b>   | <b>27</b> |
| <b>2.2.3</b> | <b>Grupo Itararé</b>   | <b>29</b> |
| 2.3          | REDES NEURAIS ARTIFICIAIS  | 29        |
| <b>2.3.1</b> | <b>Redes Neurais Convolucionais</b>  | <b>30</b> |
| 2.3.1.1      | U-net  | 32        |
| 2.3.1.2      | DeepLab  | 33        |
| <b>2.3.2</b> | <b>Redes Neurais Recorrentes</b>   | <b>35</b> |
| <b>2.3.3</b> | <b>Arquitetura das Redes Neurais Recorrentes</b>   | <b>38</b> |
| 2.3.3.1      | Redes de Memória de Longo Prazo  | 39        |
| 2.3.3.2      | Redes Neurais Recorrentes Bidirecionais  | 40        |
| <b>3</b>     | <b>TRABALHOS CORRELATOS</b>  | <b>43</b> |
| 3.1          | PLANO DE REVISÃO   | 43        |
| 3.2          | CLASSIFICAÇÕES DE PADRÕES FACIOLÓGICOS E ESTRATIGRÁFICOS UTILIZANDO DADOS DE CURVA DE POÇO | 44        |
| <b>3.2.1</b> | <b>Tabela Comparativa</b>  | <b>46</b> |
| 3.3          | CLASSIFICAÇÕES DE LITOFÁCIES UTILIZANDO IMAGENS DE AFLO-<br>RAMENTOS                       | 46        |
| <b>3.3.1</b> | <b>Tabela Comparativa</b>  | <b>47</b> |
| <b>4</b>     | <b>CLASSIFICAÇÃO DE LITOFÁCIES A PARTIR DE LOGS DE CUR-<br/>VAS DE POÇOS</b>               | <b>49</b> |
| 4.1          | DESENVOLVIMENTO  | 49        |
| <b>4.1.1</b> | <b>Conjunto de Dados Desenvolvido</b>  | <b>49</b> |

|         |   |    |
|---------|---|----|
| 4.1.2   | <b>Arquitetura de Rede Neural <i>Bidirectional LSTM</i></b> . . . . .               | 50 |
| 4.1.3   | <b>Ferramentas de Implementação</b> . . . . .                                       | 55 |
| 4.2     | <b>EXPERIMENTOS E DISCUSSÕES</b> . . . . .  | 56 |
| 4.2.1   | <b>Abordagem de Classificação de Litofácies</b> . . . . .                           | 58 |
| 4.2.1.1 | Abordagem de Supervisionada e Avaliação da Base de Dados . . . .                    | 58 |
| 4.2.1.2 | Abordagem de Regressão Utilizando Dados de Granulometria . . . .                    | 59 |
| 4.2.1.3 | Classificação Utilizando Dados Sequencias . . . . .                                 | 60 |
| 4.2.2   | <b>Método de Identificação de Padrões Estatigráficos</b> . . . . .                  | 62 |
| 5       | <b>CLASSIFICAÇÃO DE LITOFÁCIES A PARTIR DE IMAGENS DE<br/>AFLORAMENTO</b> . . . . . | 65 |
| 5.1     | <b>DESENVOLVIMENTO</b> . . . . .  | 65 |
| 5.1.1   | <b>Conjunto de Dados Desenvolvido</b> . . . . .                                     | 65 |
| 5.1.2   | <b>Arquitetura Convolutacional para Segmentação Semântica</b> . . . . .             | 67 |
| 5.2     | <b>EXPERIMENTOS E DISCUSSÕES</b> . . . . .  | 68 |
| 6       | <b>CONCLUSÃO</b> . . . . .  | 71 |
|         | <b>REFERÊNCIAS</b> . . . . .  | 73 |

## 1 INTRODUÇÃO

A caracterização de padrões faciográficos e estratigráficos é importante na determinação da qualidade e na análise dos padrões de fluxo de fluidos em um reservatório, assim como no estudo da viabilidade econômica de um poço (NICHOLS, 2009).

A análise de perfis de poços permite categorizar os padrões faciográficos em reservatórios de subsuperfície, cujas descrições são baseadas em inspeção visual de amostras laterais, testemunhos e calhas. A dificuldade em extrair a amostra inteira de um poço faz com que essa abordagem apresente um valor financeiro elevado (GRACIOLLI, 2018).

Outra forma de inspecionar o perfil de um poço se dá por meio de medições de grandezas geofísicas. Darling (2005) explica que nas sondas de perfuração são integradas múltiplas ferramentas de medição (sensores) de diferentes propriedades geofísicas, além das ferramentas de medição dos parâmetros da perfuração. No entanto, a identificação manual dessas propriedades e parâmetros, geralmente, consome muito tempo, e envolve a análise de grandes volumes de dados. Além disso, a análise destes dados requer conhecimento específico, como: sedimentologia, petrologia e estratigrafia de seqüências (GRACIOLLI, 2018).

No caso dos afloramentos, a identificação das litofácies é realizada através da descrição da composição e estruturas dos litotipos e captura de imagens. Em cenários onde os afloramentos são muito extensos ou estão em terrenos de difícil acesso, a utilização de veículos aéreos não tripulados VANT são utilizados para capturar imagens e dados de sensores (HARWIN; LUCIEER, 2012)(TURNER; LUCIEER; WATSON, 2012). No entanto, esse volume de dados torna a análise manual demorada.

Estudos na área da Inteligência Artificial têm surgido para resolver este problema mediante a criação de métodos computacionais para utilizar uma abordagem baseada em aprendizagem de máquina e construir conhecimentos a partir de bases de dados robustas, tanto de perfis e testemunhos quanto imagens de afloramentos. Na Geologia, estes métodos vêm sendo adaptados e aplicados na identificação e classificação de padrões sedimentares e estratigráficos (AL-ANAZI; GATES, 2010), (TSCHANNEN *et al.*, 2017).

O principal objetivo deste trabalho é propor e avaliar dois sistemas computacionais baseados em redes neurais profundas para identificar, automaticamente, litofácies e padrões estratigráficos. O primeiro sistema utilizado envolve arquiteturas de Redes Neurais Recorrentes (*Recurrent Neural Network* - RNN) para identificar litofáceis a partir de dados de curvas de perfis de poços oriundos de testemunhos de sistemas deposicionais da Formação Rio Bonito (Bacia do Paraná).

A metodologia proposta neste primeiro estudo apresentou resultados preliminares coerentes que consistem na definição de uma arquitetura de rede neural de memó-

ria de longo prazo bidirecional. Esses resultados se igualam aos métodos tradicionais de análise granulométrica e observações visuais aos depósitos, tendo a vantagem de reduzir as incertezas e subjetividades neste tipo de análise, que permite a classificação dos padrões faciológicos e estratigráficos de sistemas deposicionais sedimentares.

O segundo sistema utilizou métodos de segmentação semântica a partir de Redes Neurais Convolucionais (*Convolutional Neural Network* - CNN) para classificar litofácies a partir de imagens obtidas de um VANT em sistemas turbidíticos do Grupo Itararé (Bacia do Paraná, Brasil). As arquiteturas de rede neural usadas permitiram identificar descontinuidades ou mudanças em pistas visuais como cor e textura (tamanho de grão), sendo possível prever mudanças mineralógicas entre unidades estratigráficas.

Os resultados nesse segundo problema mostraram-se viáveis para utilizar redes de segmentação semântica na classificação de litofácies em afloramentos. Comparado com métodos puramente manuais ou semiautomáticos, a metodologia proposta garante uma alta taxa de acurácia e melhora muito a eficiência aplicada ao problema.

## 1.1 MOTIVAÇÃO E JUSTIFICATIVA

Para o problema de classificação a partir de dados de poços, quanto mais informações se obtém de um determinado problema, melhor será a acurácia do modelo. No caso da caracterização de padrões faciológicos e estratigráficos, o ideal é ter vários poços perfurados com informações de testemunhos e dados de curvas de perfis de poço. No entanto, isso é muito caro, pois a perfuração de um poço custa milhões de dólares (BOUGHER, 2016).

A construção de uma base de dados contendo essas informações sobre um reservatório conhecido contribui na obtenção de bons resultados, além de poder ser utilizado em trabalhos futuros. Desde a década de 1970, a Formação Rio Bonito tem sido alvo de pesquisas devido a sua importância econômica com a ocorrência de jazidas de carvão e urânio, e potencial como rochas geradoras e reservatórios para hidrocarbonetos (MINERAIS, 1974).

A análise estratigráfica e sedimentar pode ser realizada em diversas escalas no tempo e espaço, considerando a identificação dos elementos arquiteturais deposicionais. Neste trabalho, a classificação foi realizada por meio da identificação de padrões de curva de poços, que também revelam os elementos arquiteturais correspondentes.

No entanto, a interpretação de raios gama em arenitos líticos, apresenta limitações, especialmente com relação aos valores de Potássio (K), Urânio (U) e Tório (Th). Neste caso, para arenitos líticos é necessário integrar dados de raio gama com dados das litofácies, assegurando se a assinatura de curva de poço corresponde a minerais deposicionais ou autigênicos (WORDEN, RH; MORAD, 2003).

Alguns trabalhos buscaram resolver o problema de classificação dos perfis de

poço. Algumas abordagens partem da ideia de utilizar classificadores supervisionados conhecidos, como o algoritmo de máquinas de vetores de suporte e redes neurais convolucionais (WANG, D. *et al.*, 2019)(ZHANG *et al.*, 2017). Outros trabalhos utilizaram abordagens não supervisionadas para agrupar os diferentes tipos de minerais existentes (BOUGHER, 2016).

Uma hipótese desta pesquisa é verificar uma estrutura de RNN muito utilizada em problemas de transcrição de voz para texto (*speech to text*) para a identificação de litofácies através de leituras de perfis de poços. O trabalho desenvolvido por Graves *et al.* (2006) obteve bons resultados no reconhecimento de palavras e transcrição, além de conseguir recuperar trechos inaudíveis de informação. Martinez e Baldwin (2011) propuseram uma arquitetura capaz de detectar palavras chaves (*trigger word detection*) na frequência de voz.

Vale ressaltar que a abordagem de RNN pode ajudar a recuperar informações incompletas de perfis de Gamma Ray (GR). ZHANG, Yuntian e Jin (2018) propuseram uma abordagem com RNN exclusivamente desenvolvida para este problema. Espera-se que com a transcrição dos trechos das leituras de perfis, conforme proposto anteriormente, esse problema também possa ser resolvido.

Uma vez que este processo deposicional ocorre ao longo do tempo, o processamento temporal das informações disponíveis é essencial para a correta classificação dos elementos nos mais diversos níveis. Neste contexto, a aplicação de uma rede neural de longo prazo bidirecional mostra-se interessante ao objetivo da pesquisa.

Já para o problema de caracterização de litofácies em afloramentos, torna-se necessário coletar imagens de toda a área. Nesse contexto, VANTs são ferramentas importantes pois permitem obter imagens em áreas extensas e de difícil acesso. Para isso, a segunda hipótese de pesquisa visa utilizar redes neurais convolucionais de segmentação para realizar essa tarefa, combinadas com estruturas de redes neurais específicas que permitem identificar corretamente a transição de fácies.

O banco de dados utilizado neste trabalho foi construído a partir de imagens de um afloramento de um sistema turbidítico Permiano do Grupo Itararé (Bacia do Paraná), que registra sedimentação permocarbonífera no Supercontinente Gondwana Ocidental. A escolha deste afloramento para este trabalho foi motivada pela importância dos estudos de sistemas turbidíticos para a geologia do petróleo.

O volume de dados torna a análise manual das imagens capturadas demorada. Alguns estudos utilizam diferentes abordagens para segmentação de imagens. Enquanto alguns utilizam algoritmos semissupervisionados, onde o usuário deve demarcar a área com características a serem agrupadas, esse estudo utiliza redes neurais profundas para identificação de forma supervisionada, sem intervenção humana.

A combinação entre o método PointRend e arquiteturas conhecidas podem contribuir para melhoria na identificação do ponto de transição entre as fácies, permitindo

que o método seja estendido para outros casos semelhantes. Além disso, a correta escolha de padrões convolucionais desempenha um papel muito importante na extração dos recursos de alta dimensão.

## 1.2 OBJETIVOS DA TESE

A automatização da interpretação de perfis de poços através de modelos de aprendizagem de máquina é um problema relevante para a caracterização de reservatórios. O trabalho proposto pode contribuir com novas ferramentas que irão auxiliar o geólogo na interpretação dos poços. Assim, pretende-se ao longo deste trabalho, responder à seguinte questão de pesquisa: é possível aplicar modelos de RNN na interpretação de perfis de poços e modelos de CNN para segmentação em imagens de afloramento com boa acurácia em diferentes ordens de grandeza?

### 1.2.1 Objetivo Geral

Para verificar as hipóteses apresentadas, este trabalho de pesquisa teve como objetivo criar uma arquitetura de RNN para classificar padrões faciologicos e estatigraficos a partir de padrões curvas de pocos e uma arquitetura CNN de segmentacao capaz de classificar padrões faciologicos a partir de imagens de afloramento. A abordagem se da por meio da preparacao das fontes de dados que caracterizam sistemas deposicionais transgressivos e da criação de modelos capazes de traduzir leituras e identificar classes faciologicas.

### 1.2.2 Objetivos Específicos

Os objetivos específicos deste trabalho de pesquisa foram:

1. Construir um conjunto de dados contendo leituras de curvas de raios gama, de resistividade, densidade, assim como, dados faciológicos presentes em sistemas deposicionais transgressivos;
2. Conceber um método capaz de identificar padrões faciológicos e estatigráficos através de RNN;
3. Construir um conjunto de dados contendo imagens de afloramento capturadas com VANT;
4. Conceber um método capaz de identificar padrões faciológicos e estatigráficos através de CNN de segmentação;
5. Definir o método capaz de gerar avaliação geológicas em diferentes ordens de ciclos deposicionais.

### 1.2.3 Estrutura da Tese

Este documento está organizado da seguinte forma. Após esta introdução, o Capítulo 2 apresenta a fundamentação teórica sobre sistemas deposicionais fluviais e turbidíticos, os contextos geológicos e estatigráficos do sistema deposicionais utilizados, os principais conceitos relacionados às redes neurais recorrentes e convolucionais de segmentação e à construção destes modelos de redes neurais. O Capítulo 3 apresenta o estado da arte relacionado a utilização de dados de curvas de poços e de imagens de afloramentos para classificação de padrões faciológicos e estatigráficos. O Capítulo 4 apresenta o trabalho de classificação de litofácies a partir de logs de curva de poços, contendo a construção da base de dados a partir dos logs de curva de poços pertencentes a Formação Rio Bonito, os modelos de redes neurais recorrentes implementados durante o desenvolvimento e os resultados obtidos a partir dos experimentos realizados. Já o capítulo 5 apresenta o trabalho de classificação de litofácies a partir de imagens de afloramento, contendo a construção da base de dados a partir de imagens de um afloramento pertencente ao grupo Itararé, os modelos de redes neurais convolucionais de segmentação semântica implementados durante o desenvolvimento e os resultados obtidos a partir dos experimentos realizados. Por fim, o Capítulo 6 sumariza os resultados alcançados com este trabalho e finaliza com as sugestões para sua continuidade.

## 2 FUNDAMENTAÇÃO TEÓRICA

A definição dos sistemas deposicionais torna-se possível por meio da associação de fácies sedimentares. Neste capítulo, inicialmente serão abordados os conceitos de sistemas deposicionais fluviais e turbidíticos. Os padrões em sistemas fluviais e turbidíticos serão analisados, bem como a análise de padrões faciológicos a partir de padrões de curvas de poços.

Em seguida, será descrito o contexto geológico e estatigráfico da Formação Rio Bonito, cujos poços foram utilizados na construção da base de dados. Este sistema deposicional fluvial é transgressivo, que ocorre na porção superior da seção estratigráfica e constitui um sistema estuarino. Em seguida, será descrito o contexto geológico e estatigráfico do Grupo Itararé, onde as imagens dos afloramentos foram coletadas.

Serão apresentados ainda os aspectos relacionados com as Redes Neurais Convolucionais e Recorrentes. Neste sentido, serão introduzidos primeiramente o funcionamento e as características das estruturas que compõem cada abordagem. Em seguida, serão apresentadas as funções frequentemente usadas na ativação de características, além das arquiteturas específicas abordadas nesse trabalho.

### 2.1 SISTEMAS DEPOSICIONAIS

Sistemas deposicionais são formados por sedimentos originados por intempérie e erosão de rochas que sofreram deslocamento e foram depositados em uma bacia sedimentar, para então sofrer o processo de diagênese. Existem vários agentes transportadores, sendo os mais comuns rios, ventos, geleiras e a gravidade.

Essa seção aborda conceitos importantes utilizados no trabalho, como os conceitos de fácies, sistemas deposicionais fluviais e turbidíticos. Conceitos específicos sobre a estratigrafia de sequências em ambientes costeiros e análise de padrões de raio gama também são abordados e aplicados no trabalho.

#### 2.1.1 Fácies

Entende-se como fácies um conjunto de rochas com características distintas, como o aspecto composicional, químico, mineralógico, morfológico, estrutural ou textural (READING, 2009). As fácies sedimentares resultam da combinação de processos de transporte e deposição de partículas (pelo vento, gelo, água e gravidade), bem como da atividade de organismos em regiões particulares específicas de uma bacia sedimentar.

Reading (2009) define a associação de fácies como uma relação tridimensional de fácies geneticamente relacionadas, que são produto da sedimentação que se desenvolve em um ambiente específico. Elementos arquiteturais que representam um

cenário paleogeomórfico se desenvolvem nesses ambientes, que resultam da combinação de uma série de fatores e processos físicos, químicos e biológicos (NICHOLS, 2009).

### 2.1.2 Sistemas Depositionais Fluviais

A partir da análise das associações de fácies, torna-se possível definir um sistema deposicional, cujos padrões de sucessão de fácies servem para distinguir ambientes canais meandrantos, anastomosados e entrelaçados (NICHOLS, 2009).

O sistema fluvial entrelaçado (figura 1) é composto por uma rede de canais separados por barras arenosas ou cascalhosas, e correspondem a rios com transporte de carga de fundo na classificação de Schumm (SCHUMM, 1972). Os sistemas fluviais entrelaçados caracterizam-se por indicar alta variabilidade da descarga ao longo do ano e alto suprimento sedimentar, e são formados em contextos de declividade acentuada.

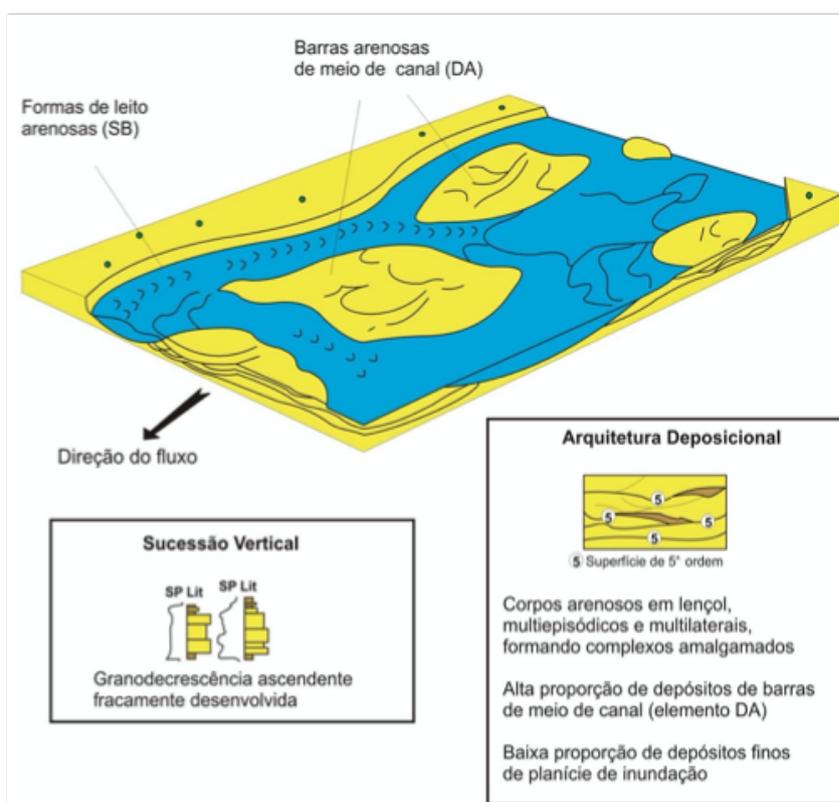


Figura 1 – Bloco diagrama de um sistema fluvial entrelaçado ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).

O Sistema fluvial anastomosado (figura 2) é caracterizado por complexos de canais interconectados de baixa energia, desenvolvidos em regiões úmidas e alagadas, onde dominam ilhas alongadas e cobertas por vegetação (SMITH; PUTNAM, 1980). A

baixa declividade e sinuosidade dos canais causa frequentemente extravasamento do canal e deposição de finos.

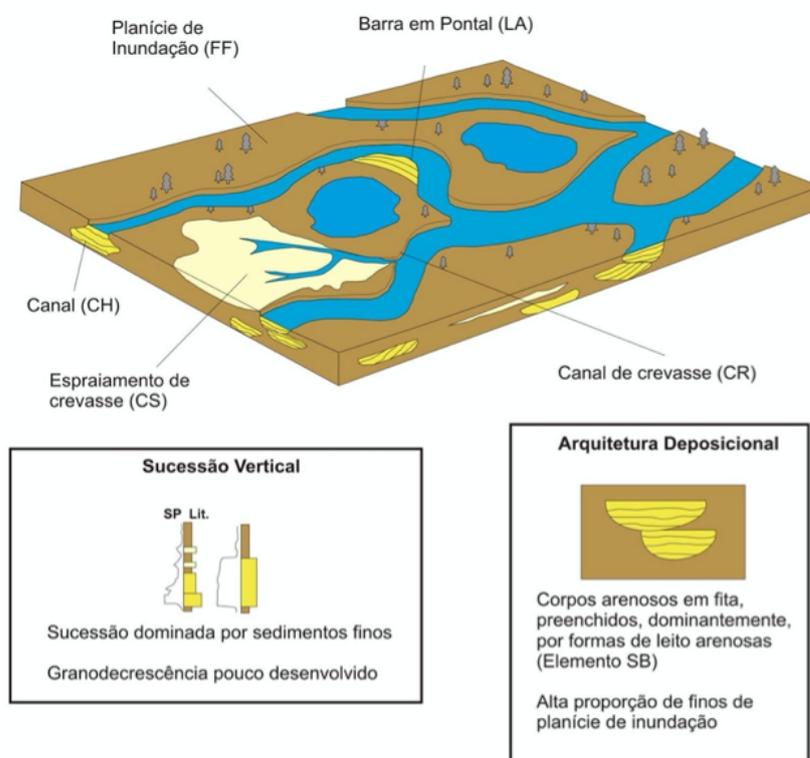


Figura 2 – Bloco diagrama de um sistema fluvial anastomosado ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).

O Sistema fluvial meandrante (figura 3) é caracterizado por canais com alta sinuosidade, apresentam pouca variação de descarga e correspondem a rios com carga mista na classificação (SCHUMM, 1972). Os canais meandrantés apresentam altas taxas de migração lateral, resultante da diferença na velocidade do fluxo no meandro externo e interno.

### 2.1.3 Estratigrafia de Sequências em Ambientes Costeiros

A estratigrafia de sequências através da interpretação sedimentológica das diferentes camadas litológicas é de grande importância para a reconstrução da paleogeografia e sedimentologia e também para caracterização de recursos naturais na subsuperfície. A estratigrafia de sequências pode ocorrer em diversas escalas, permitindo identificar os elementos do sistema deposicional (SHANLEY; MCCABE; HETTINGER, 1992).

Os sistemas deposicionais costeiros evoluem em diversos contextos de Tratos de Sistemas (TS), durante eventos de transgressão e regressão marinha, quando ocorre mudanças na taxa de nível base e taxa de sedimentação. Tratos de Sistemas

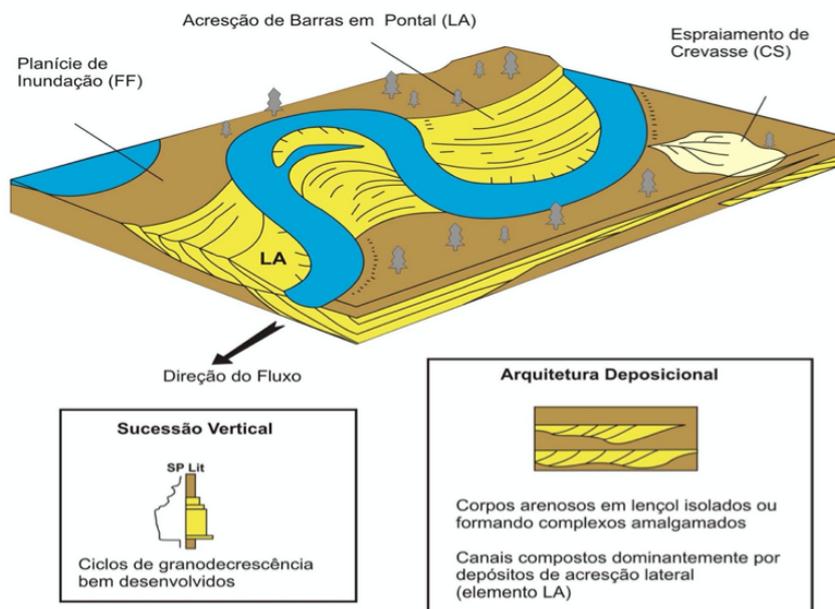


Figura 3 – Bloco diagrama de um sistema fluvial meandrante ilustrando a geometria dos corpos arenosos, os elementos arquiteturais internos e externos aos canais e a sucessão vertical de fácies (SCHERER, 2008).

compreendem um conjunto de sistemas deposicionais geneticamente relacionados, que constituem uma sequência deposicional, sendo caracterizados por padrões de empilhamento das fácies, que definem as tendências deposicionais (CATUNEANU, 2006).

Os Tratos de Sistemas são delimitados por superfícies estratigráficas específicas e são classificados como: Tratos de Sistemas de Nível em Queda (TSNQ), de Nível Baixo (TSNB), Transgressivo (TST) e de Nível Alto (TSNA), com as principais superfícies estratigráficas, no contexto da zona de transição entre o ambiente fluvial e marinho raso (CATUNEANU, 2006)(figura 4).

A ocorrência de depósitos estuarinos no registro geológico está, principalmente, associada a inundações marinhas de vales fluviais incisos durante eventos de transgressão – os processos estuarinos tornam-se componentes menos importantes no TSNA (REINSON, 1992) (BOYD; JAMES; 2010), onde tendem a dominar sistemas de ilhas-barreiras, formando cordões litorâneos regressivos.

#### 2.1.4 Padrões de Raios-gama em Rochas Sedimentares

A gamaespectrometria quer seja aérea, terrestre ou de poço, tem como base os princípios da geofísica nuclear (PARASNIS, 1997). Segundo Ellis e Singer (2007), a detecção dos raios gama se processa em duas etapas. Primeiramente, os raios gama ao entrarem em contato com o detector, são parcial ou totalmente convertidos em radiação ionizante (elétrons), ocorrendo então os principais processos de interação com a matéria: o efeito fotoelétrico e o espalhamento Compton.

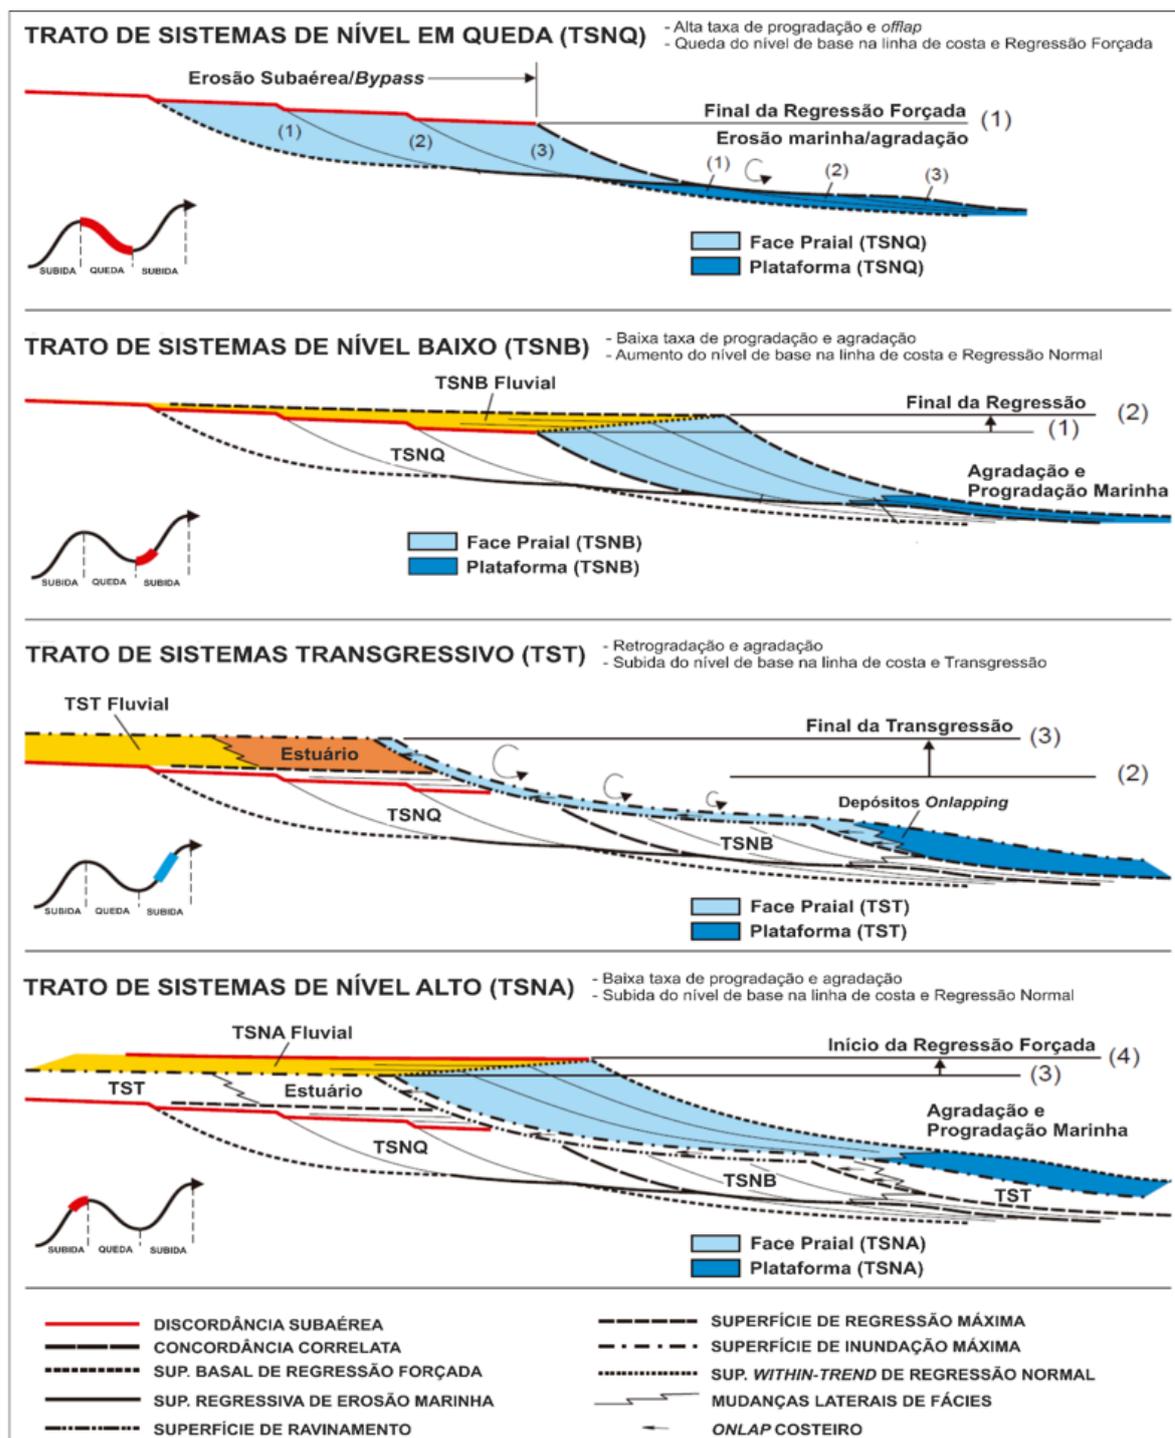


Figura 4 – Arquitetura detalhada dos tratos de sistemas e superfícies estratigráficas associadas (CATUNEANU, 2006).

Na indústria do petróleo, a gamaespectrometria começou a ser utilizada na década de 1930 como o primeiro método elétrico de perfilagem de poços (ELLIS; SINGER, 2007) e, desde então, a detecção da radioatividade natural das rochas é amplamente utilizada na exploração e desenvolvimento dos campos de hidrocarbonetos.

Os raios-gama têm sido utilizados para medir a radiação gama natural emitida pela rocha, que é detectada por um sensor e medida em API (unidade empírica de radi-

ação gama utilizada em perfis radioativos de poços pelo American Petroleum Institute - API/USA, (SHERIFF, 2002)(DUARTE, 1997). Esta radiação é gerada por isótopos de potássio ( $^{40}\text{K}$ ), tório ( $^{232}\text{Th}$ ) e urânio ( $^{238}\text{U}$ ) e seus respectivos decaimentos.

A principal aplicação da gamaespectrometria nas rochas sedimentares é para definir as variações na argilosidade das unidades estratigráficas siliciclásticas e carbonáticas, que varia diretamente com a radioatividade (figura 5). Por meio da argilosidade é possível definir litossomas e variações de granulometria, assim como subsidiar análise de estratigrafia de seqüências e correlações entre poços e afloramentos (RIDER, 1990).

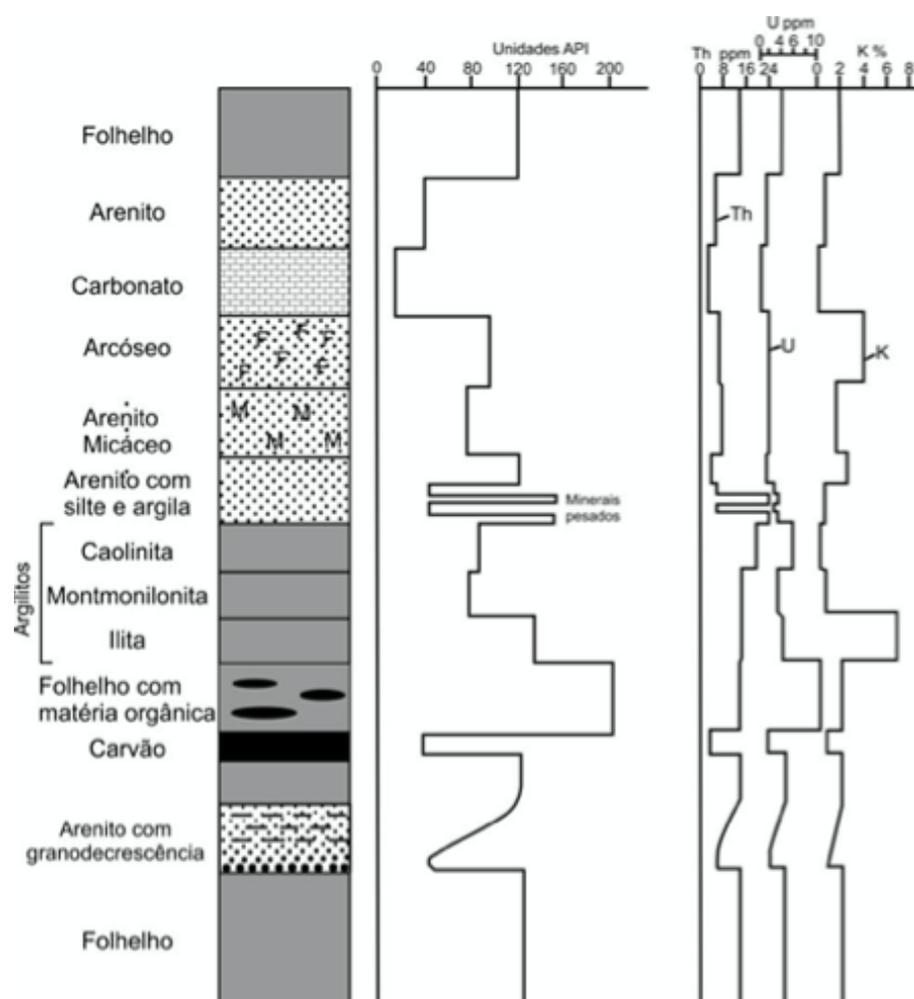


Figura 5 – Assinaturas gamaespectrométricas típicas dos principais litotipos sedimentares, adaptado de (RIDER, 1990).

A definição de padrões ou assinaturas de perfis de raios gama é um dos métodos mais utilizados na análise estratigráfica e caracterização de reservatórios em subsuperfície, onde, na maioria das vezes, não se dispõe de dados diretos (testemunhos). Para isso são utilizados modelos de formatos de curva que refletem tendências de variações de argilosidade típicas de determinados elementos e sistemas deposicionais.

No presente trabalho são analisadas as assinaturas gamaespectrométricas de depósitos fluviais neopermianos da porção superior da Formação Rio do Rasto (Membro Morro Pelado) em afloramentos e poços no Leste de Santa Catarina. A Formação Rio do Rasto é uma das unidades mais bem expostas da Bacia do Paraná, seus afloramentos de grande extensão lateral e vertical favorecem o levantamento de perfis geofísicos (SOWEK *et al.*, 2013).

A interpretação de raios gama em arenitos líticos, apresenta limitações, especialmente com relação aos valores de K, U e Th que podem variar de acordo com a mineralogia de fragmentos de rocha (p.e. vulcânicas e metassedimentares argilas) (DICKSON; SCOTT, 1997). Estudos mostram que, em média, ocorre um aumento de radioelementos com o aumento de sílica em rochas ígneas félsicas (figura 6).

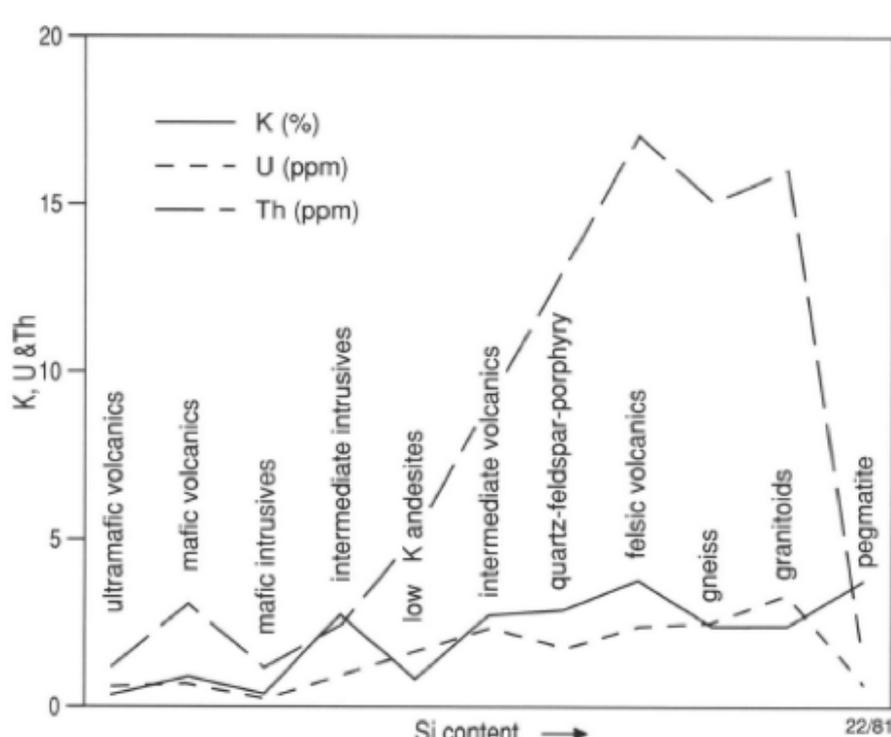


Figura 6 – Variação em média de valores de K, U & Th para rochas ígneas com aumento de sílica (DICKSON; SCOTT, 1997).

Padrões de raios gama tem sido interpretados com relação à variação granulométrica, principalmente com relação à quantidade de argilas, na qual tem sido interpretada com tipos de ambientes deposicionais. Entretanto, Rider (1990), delimita o uso de *log shapes* na aplicação dos seguintes fatos: (1) relação entre resposta do raio gama com relação à quantidade de argilas, (2) relação da quantidade de argila com granulometria, (3) relação entre variação da granulometria na sequência com fácies ambientais.

Estudos mostram que padrões de raio gama podem funcionar muito bem em alguns casos, porém em outros não. Portanto, uma correlação entre raio gama e descrição de testemunho deve ser feita a fim de se garantir uma correlação correta

(RIDER, 1990). A principal aplicação da gamaespectrometria nas rochas sedimentares é para definir as variações na argilosidade das unidades estratigráficas siliciclásticas, que varia diretamente com a radioatividade (figura 7). Por meio da argilosidade é possível definir litossomas e variações de granulometria, assim como subsidiar análise de estratigrafia de seqüências e correlações entre poços, e entre poços e afloramentos (RIDER, 1990).

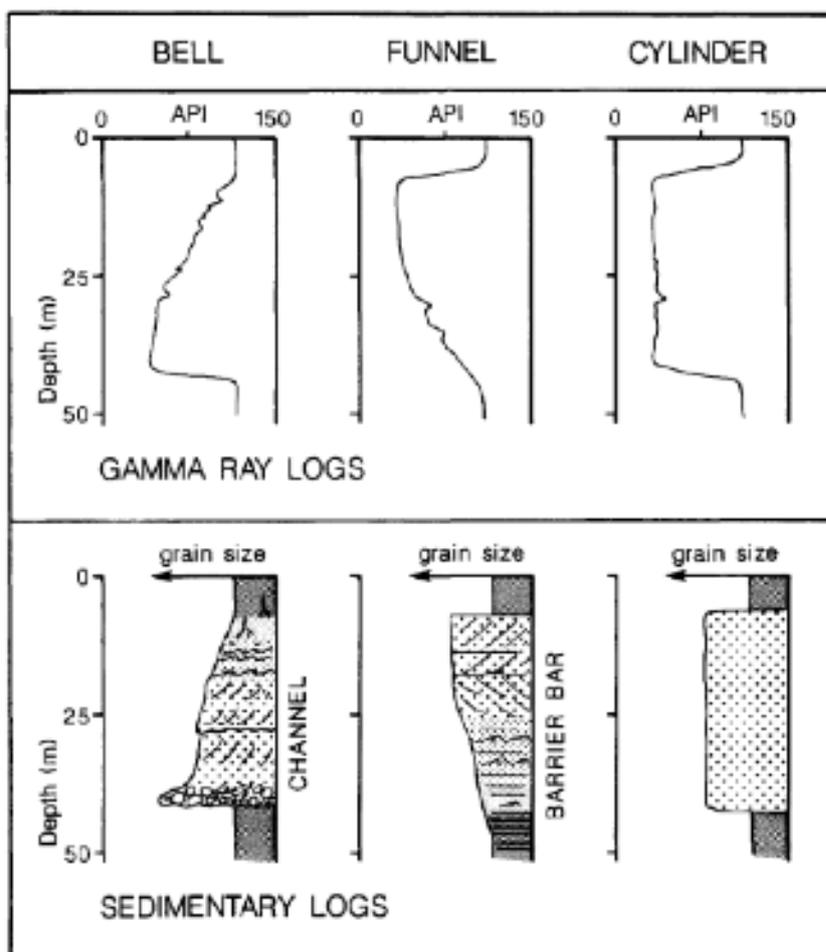


Figura 7 – Exemplo de relação de padrões de raio gama com a correspondente interpretação sedimentar (SERRA; SULPICE *et al.*, 1975).

Segundo Ruffell e Richard Worden (2000), a abundância e meias-vidas do potássio (K), urânio (U) e tório (Th) tornam esses elementos as principais fontes de detecção de raios gamas nas rochas, tanto em afloramentos como em subsuperfície.

Traços de minerais radioativos são encontrados em todos os litotipos, podendo ser detectados também em rios, hidrocarbonetos e matéria orgânica (SOWEK *et al.*, 2013). Dos principais elementos que são detectados pelo gamaespectrômetro, o potássio é o de maior ocorrência e solubilidade, em relação ao urânio e ao tório, sendo medido em %, enquanto U e Th, de menor ocorrência e solubilidade, são registrados em ppm.

### 2.1.5 Sistemas Depositionais Turbidíticos

Avaliar o relacionamento genético, espacial e estratigráfico entre associações de fácies deltaicas e marinhas profundas visa estabelecer critérios geológicos de suporte à exploração e desenvolvimento de reservatórios turbidíticos. De acordo com Kneller e Buckee (2000), a corrente de turbidez é o principal agente transportador de sedimentos em ambientes fluviais e marinhos.

Turbidito é o nome genético dado ao depósito de um processo sedimentar originado por correntes de turbidez submarinas, que é um fluxo gravitacional de sedimento comum em bacias de antepaís e em ambiente tectônico de margem convergente (HANNAFORD *et al.*, 1982). Esse tipo de depósito é importante não somente pelo potencial de risco ambiental que possuem, tais como sedimentação de reservatórios, rompimento de cabos submarinos, dispersão de poluentes e riscos vulcânicos, mas também pelo fato dos sistemas turbidíticos serem responsáveis pela formação dos maiores reservatórios de rochas carbonáticas do mundo (STOW; MAYALL, 2000).

Segundo Della Fávera e Della Fávera (2001), os depósitos turbiditos constituem os principais reservatórios de petróleo em ambiente marinho profundo e respondem por grande parte da produção de petróleo no Brasil, o que motiva a predição desses depósitos no registro estratigráfico e suas relações espaciais com rochas argilosas de baixa permeabilidade. Entretanto, sabe-se que atualmente devido à descoberta da camada de pré-sal, que é um conjunto de rochas localizadas nas porções marinhas de grande parte do litoral brasileiro e com acúmulo de petróleo, essa afirmação precisa ser revista.

Um trato de fácies turbidítico é definido como a associação lateral de fácies genéticas, acamamento regular e gradacional com gradação grano-classificada, que podem ser observadas dentro de uma camada individual ou um pacote de fácies estritamente equivalentes em tempo (MUTTI *et al.*, 2014). Cada estrato de uma sequência turbidítica é depositado em um único evento (VAN WAGONER *et al.*, 1990).

## 2.2 CONTEXTO GEOLÓGICO E ESTRATIGRÁFICO

Essa seção aborda os contextos geológicos e estratigráficos das regiões abordadas durante o desenvolvimento do trabalho. Para a identificação automática de litofácies e padrões estratigráficos, este trabalho utiliza uma base de dados criada a partir das curvas de perfis de poços de sistemas deposicionais da Formação Rio Bonito (Bacia do Paraná). O banco de dados para realização desta pesquisa foi construído a partir de 20 poços, realizados na localidade de Barro Branco, região de Lauro Müller, sul de Santa Catarina.

Os testemunhos extraídos apresentam profundidade entre 86 a 279m. As fácies se encontram organizadas na forma de ciclos granodecrescentes ascendentes

a, subordinadamente, granocrescentes ascendentes. No geral, o padrão estratigráfico é retrogradacional, onde as fácies proximais (com canais fluviais e planícies de inundação na base) são gradativamente sucedidas por depósitos de planície de maré e praias. Geralmente, toda a sucessão sedimentar apresenta nódulos de pirita e níveis carbonáticos.

Para a classificação de padrões faciográficos a partir de imagens de afloramento foi criada uma base de imagens a partir de afloramentos pertencentes ao sistema turbidítico Permiano do Grupo Itararé. Um drone DJI Phantom 4 Advanced pertencente ao Laboratório de Análise de Bacias e Reservatórios (LABAC) foi usado para coletar 380 fotografias a uma altitude média de 30m de afloramento.

### 2.2.1 Bacia do Paraná

A Bacia do Paraná compreende uma ampla área sedimentar situada no sudoeste da Plataforma Sulamericana, e possui um registro estratigráfico que abrange rochas do Paleozoico ao Mesozoico. Esta bacia possui geometria alongada NE-SW e ocupa uma área de 1.100.000  $km^2$  no Brasil, além de 300.000  $km^2$  distribuídos no nordeste da Argentina, oeste do Paraguai e norte-noroeste do Uruguai (CHAVES *et al.*, 1994)(Figura 8).

Segundo Edison José Milani, França e Medeiros (2007), o pacote sedimentar-magmático da Bacia do Paraná pode atingir espessura de 7.000 m em seu depocentro, que coincide com a calha principal do Rio Paraná. Seus limites geográficos são erosivos e estão associados aos eventos tectônicos que atuaram na Plataforma Sulamericana, durante o Meso-Cenozoico, quando da abertura do Oceano Atlântico Sul (MILANI, Edison José; FRANÇA; MEDEIROS, 2007).

A sedimentação na Bacia do Paraná esteve associada à um conjunto de calhas aulacogênicas dispostas segundo direção NW-SE (FÚLFARO *et al.*, 2018)(8B). Zalán *et al.* (1987) propõem que a instalação e subsidência desta bacia esteve vinculada à contração térmica resultante do final do Ciclo Brasileiro. Segundo Edison José Milani (1997), cinturões colisionais na borda sudoeste do Gondwana influenciaram diretamente na evolução e subsidência da Bacia do Paraná ao longo do Fanerozoico. A partir de esforços compressivos causados pela Orogenia Oclógica, foram geradas depressões alongadas segundo direção NE-SW, onde iniciou-se a instalação da primeira unidade da Bacia do Paraná, a Supersequência Rio Ivaí (MILANI, Edison José, 1997).

### 2.2.2 Formação Rio Bonito

A Formação Rio Bonito (WHITE, 1908) registra o início da sedimentação pós-glacial na Bacia do Paraná e foi depositada durante evento de transgressão marinha em vales incisivos, diretamente sobre o Grupo Itararé (LAVINA; LOPES, 1987)(MILANI,

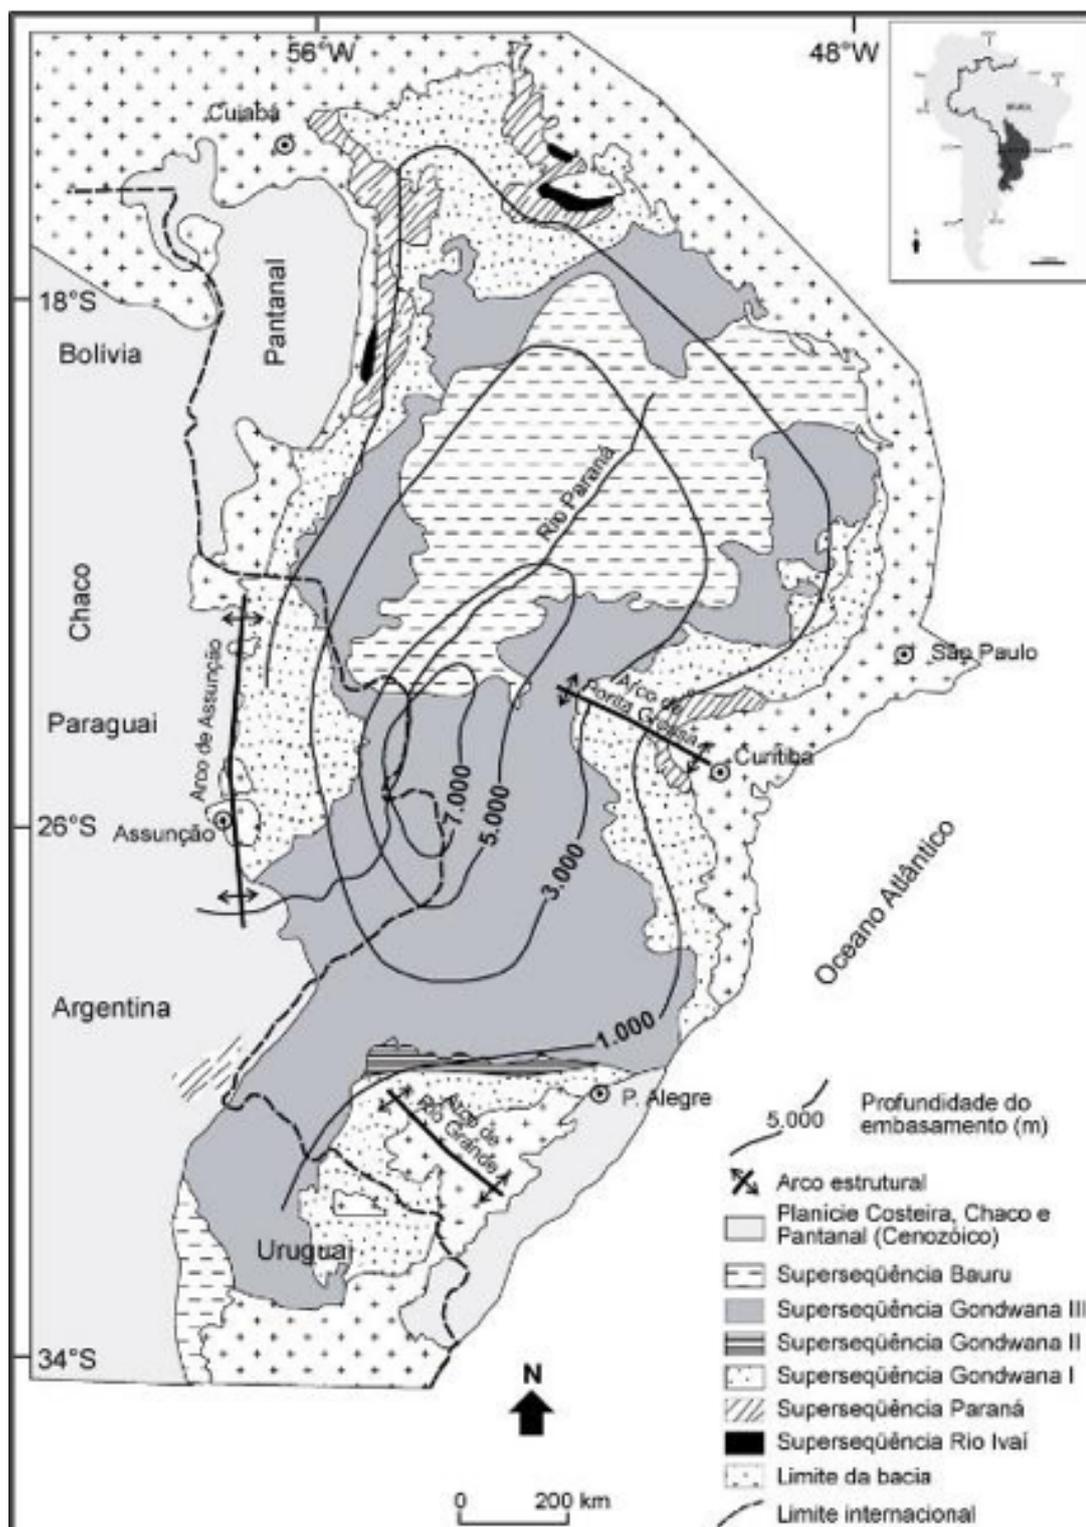


Figura 8 – . (A) Mapa geológico simplificado da Bacia do Paraná (modificado de Edison José Milani, França e Medeiros (2007)), e (B) as principais estruturas geológicas regionais (Modificado de Zalán *et al.* (1987); Fúlfaro *et al.* (2018)).

Edison José; FRANÇA; MEDEIROS, 2007) e faz parte da Superseqüência Gondwana I (MILANI, Edison José; FRANÇA; MEDEIROS, 2007).

O conhecimento do arcabouço estratigráfico e evolução paleoambiental da For-

mação Rio Bonito é no mapeamento de superfícies estratigráficas regionais formadas durante ciclos de regressão e transgressão marinha na Bacia do Paraná. Desde a década de 1970, a Formação Rio Bonito tem sido alvo de pesquisas devido a sua importância econômica com a ocorrência de jazidas de carvão (no Rio Grande do Sul, Santa Catarina e Paraná) e urânio (Paraná), e potencial como rochas geradoras e reservatórios para hidrocarbonetos.

A Formação Rio Bonito tem arcabouço estratigráfico e evolução associados à sistemas deposicionais fluvio-costeiros, dominados por processos fluviais, onda e maré. Inicialmente, esta formação foi interpretada como um extenso front deltaico (NORTHFLEET; MEDEIROS; MUHLMANN, 1969). Trabalhos como Holz, Kalkreuth e Banerjee (2002) relacionam a deposição das camadas de carvão da Formação Rio Bonito na região de Candiota, Rio Grande do Sul, a um modelo deposicional de complexo ambiente lagunar estuarino influenciado por onda e maré.

### 2.2.3 Grupo Itararé

O Grupo Itararé é um grupo de formações geológicas pertencentes à Bacia do Paraná e pertence à Supersequência Godwana I (MILANI, Edison Jose, 1997). Este Grupo é um registro marcante da grande glaciação gondwânica que ocorreu entre 360 e 270 milhões de anos atrás e cujo pico ocorreu no Mississípiano (Carbonífero inferior).

O Grupo Itararé aflora em duas faixas alongadas, praticamente na direção nortesul, uma na margem oeste da Bacia, do estado de São Paulo ao estado do Rio Grande do Sul e a outra na margem oeste, do estado do Mato Grosso ao Paraguai, sendo que seu nome deriva da cidade de Itararé, onde a mesma foi inicialmente estudada. Mesmo com a forte ação do gelo, o Grupo Itararé é rico em arenitos que são potenciais reservatórios de petróleo (MILANI, Edison José; FRANÇA; MEDEIROS, 2007).

Atualmente é bem aceito que grande parte do preenchimento da bacia no “tempo Itararé” se deu pela ação de fluxos gravitacionais subaquáticos de diferentes tipos (LIMA RODRIGUES *et al.*, 2020). O topo da sucessão envolve já as fácies arenosas regressivas da Formação Rio Bonito, cuja sedimentação ocorreu em ambiente desde marinho raso até fluvial (CASTRO; MORENO-VENTAS; DE LA ROSA, 1991).

## 2.3 REDES NEURAIIS ARTIFICIAIS

Rede Neural Artificial (RNA) pode ser descrita como um paradigma de programação inspirado biologicamente no cérebro humano, que permite um computador aprender a partir de um conjunto de dados (NIELSEN, 2015). Ou seja, a RNA consiste em uma coleção de perceptrons (neurônios), que estão conectados através de unidades de camadas ocultas e por sua vez são ativados através de funções de ativação,

uma representação análoga das sinapses neurais. Novas arquiteturas foram propostas nos últimos anos para resolver problemas em diferentes tipos de dados e situações.

Existem diversas situações na natureza em que um determinado evento é consequência direta de eventos anteriores. Ambientes que contêm eventos deste tipo são denominados ambientes sequenciais (RUSSELL; NORVIG, 2016). Neste tipo de ambiente, um determinado dado ou valor não pode ser avaliado isoladamente. Ele é fruto e parte de uma sequência de outros valores.

Buscando maneiras sistemáticas de se realizar previsões sobre dados sequenciais e aproveitando a estrutura de redes neurais artificiais, surgiram as redes neurais recorrentes (RNN - *Recurrent Neural Network*). Este trabalho utiliza este tipo de estrutura para classificar padrões de raio gama.

Os neurônios de uma Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*) são organizados volumetricamente, transformando um determinado volume de dados de entrada em um volume diferente de dados de saída (SHANMUGAMANI, 2018). Por exemplo, o processo de segmentação, onde uma imagem de entrada é simplificada por agrupamento de pixels a partir de um rótulo de classificação.

Esta seção aborda o funcionamento das RNNs e das CNNs, relevantes para o trabalho. No caso das RNNs, essa seção apresenta as diferentes configurações de entrada e saídas, bem como a implementação das funções necessárias para o seu funcionamento. Já para CNNs, a seção abordará os diferentes tipos de neurônios existentes e as arquiteturas de redes neurais de segmentação semântica utilizadas no trabalho.

### 2.3.1 Redes Neurais Convolucionais

As Redes Neurais Convolucionais são redes neurais que incluem uma ou mais camadas de convolução. Estas camadas de convolução são caracterizadas por possuírem neurônios que têm o papel de buscar características específicas dos dados de entrada, com capacidade para reconhecer padrões com alto grau de invariância a translação, escalamento, inclinação e outras formas de distorção (SHANMUGAMANI, 2018).

Shanmugamani (2018) explica que por meio de uma organização volumétrica, as camadas de convolução podem transformar determinado volume de dados de entrada em um volume diferente de dados de saída. Em aplicações voltadas à visão computacional, este volume de dados pode ser representado pelas camadas de cores RGB de uma imagem digital.

O principal componente da operação de convolução é o *kernel*, uma matriz contendo informações do filtro que será aplicado sobre o conjunto de entradas da camada de convolução, ou seja, possui a configuração do que será preservado na imagem (RUSSELL; NORVIG, 2016). O *kernel* do processo de convolução possui dois

parâmetros: a máscara, que diz respeito ao tamanho do mesmo; e o número de passos ou *strides*, que são executados durante o deslocamento (Figura 9).

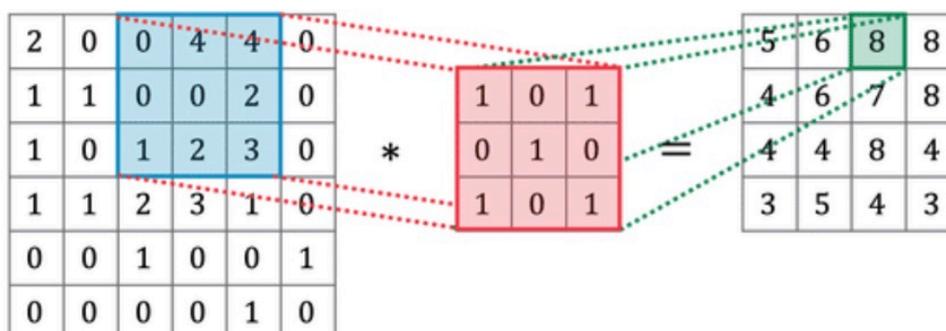


Figura 9 – Operação de convolução em uma camada convolucional.

Após gerados os mapas de características, aplica-se uma função de ativação não-linear sobre a matriz resultado do processo de convolução. Cada camada convolucional é responsável por captar certo nível de características, sendo que as camadas iniciais capturam regiões menores e características mais simples como bordas e cantos. Já as camadas mais profundas captam informações de partes maiores, podendo extrair padrões de formas complexas (RAWAT; WANG, Z., 2017).

As camadas de *pooling* são inseridas entre as camadas convolucionais, com intuito de simplificar e reduzir a resolução espacial da informação gerada pela camada de convolução, retendo apenas as informações mais importantes. Segundo Shanmugamani (2018), as operações mais comuns para esta camada consistem em obter o valor máximo (*max-pooling*) ou o valor médio para cada conjunto de pixels (Figura 10).

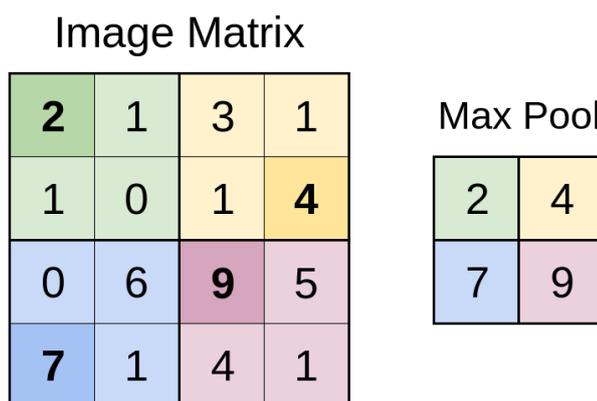


Figura 10 – Operação de *pooling* em redes convolucionais.

Existem arquiteturas de redes convolucionais preparadas para diferentes tarefas e que utilizam diferentes tipos de camadas. Nos casos de simplificação de imagens, como a segmentação, a saída da rede neural é uma nova imagem.

Em arquiteturas de segmentação semântica, é comum o uso de camadas de *unpooling*. Rawat e Zenghui Wang (2017) explicam que este tipo de camada gera um mapa de características com uma resolução espacial maior proveniente de um mapa

de características com resolução menor. A implementação da camada de *unpooling* mitiga a redução da informação espacial que foi perdida pela operação de *pooling* em camadas anteriores por meio da reconstrução dos mapas de características para seus tamanhos originais.

A combinação e o empilhamento de diferentes camadas permite construir diferentes arquiteturas de redes neurais, onde cada arquitetura possui um objetivo específico. Recentemente, as redes neurais convolucionais estenderam suas habilidades a segmentação semântica.

A segmentação semântica é o processo de atribuição de uma classe de objeto para cada pixel de uma imagem, gerando uma imagem simplificada destacando as regiões de interesse da imagem. A seguir são apresentadas as arquiteturas de redes neurais U-net e DeepLab, objetos de estudo nesse trabalho para a tarefa de segmentação de litofácies em afloramentos.

#### 2.3.1.1 U-net

Em relação à tarefa de segmentação, é necessário que a rede neural seja capaz de combinar a informação da localização com a informação contextual dos mapas de características da imagem a ser predita. A U-net é capaz de juntar as informações, sem necessidade de pré ou pós-processamento.

A arquitetura U-net é uma versão estendida das redes convolucionais de classificação de objetos, mas projetada para proporcionar segmentações mais precisas com conjuntos de treinos pequenos. Consiste em um caminho de contração da resolução para capturar contexto, seguido de um caminho no qual a resolução volta a ser expandida, permitindo a localização precisa dos pixels (LONG; SHELHAMER; DARRELL, 2015).

Long, Shelhamer e Darrell (2015) explicam que a parte inicial da rede, chamada nessa arquitetura de *encoder*, ou caminho de contração, é igual a uma arquitetura típica de uma rede convolucional de classificação de imagens, exceto as camadas totalmente conectadas que são excluídas. A principal diferença está na camada de *decoder*, onde são executadas consecutivas operações de *unpooling* em grande de mapas de características, tendo como consequência uma simetria em relação à camada de *encoder*.

A simetria entre as camadas de *encoder* e *decoder* faz com que essa arquitetura de segmentação assuma a forma "U", conforme apresentado na Figura 11. Essa notação faz com que a rede aprende o conteúdo da informação da imagem e onde este conteúdo está localizado na imagem.

A principal contribuição feita pela U-net, consiste em ter um grande número de canais com características extraídas de altas resoluções conectadas diretamente também à etapa de *upsampling*. Para aplicações similares a proposta nesse trabalho,

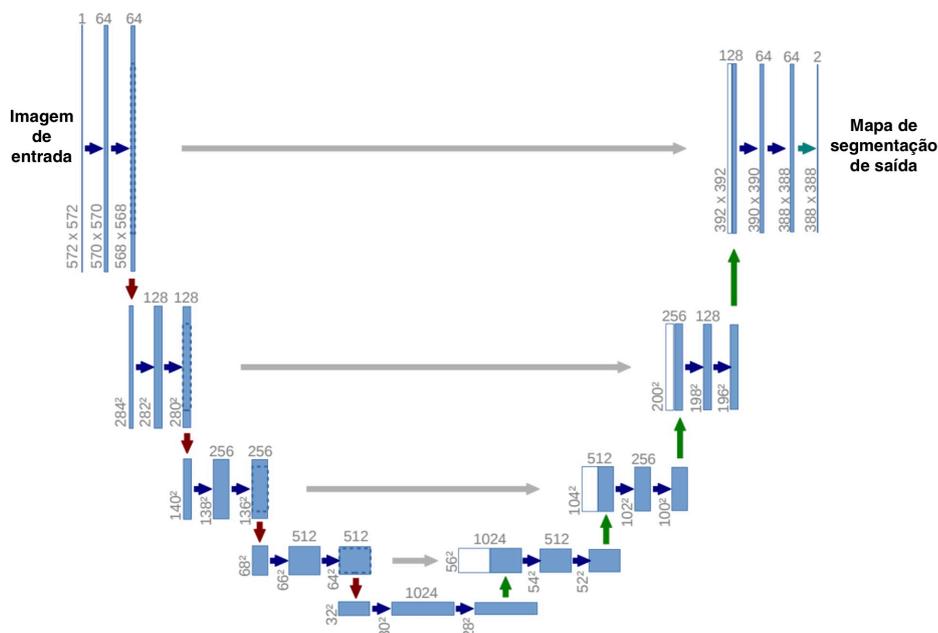


Figura 11 – Arquitetura da rede de segmentação semântica U-net.

Long, Shelhamer e Darrell (2015) propõem o uso da prática de *data augmentation*, principalmente quando o conjunto de dados é pequeno.

### 2.3.1.2 DeepLab

Os primeiros modelos de redes totalmente convolucionais implementadas para a segmentação semântica demonstraram-se eficientes e proporcionaram bons resultados. Conforme visto anteriormente, a arquitetura A U-net tem um design de um *encoder* e um *decoder*. O primeiro é usado para extrair recursos por *downsampling*, enquanto o último é usado para *upsampling* dos recursos extraídos usando as camadas deconvolucionais.

No entanto, o uso excessivo das operações de *pooling* em consecutivas camadas convolucionais reduziram significativamente a resolução dos mapas de características. Esse problema é comum em limites excessivamente suaves que podem não ser precisos para objetos ou cenas com limites irregulares, limitando o uso deste modelo em diferentes escalas de imagens (CHEN, L.-C. *et al.*, 2017).

Ao contrário do U-net, que usa recursos de cada bloco convolucional e, em seguida, os concatena com seu bloco deconvolucional correspondente, o DeepLab usa recursos gerados pelo último bloco convolucional antes do *upsampling*. Liang-Chieh Chen *et al.* (2017) explicam que na arquitetura DeepLab as características dos objetos presentes na imagem são extraídos da rede *backbone*, que é a sequência de camadas de convolução de arquiteturas de redes neurais conhecidas para classificação de objetos, como a VGG, a DenseNet e a ResNet.

Além disso, na arquitetura DeepLab é adotada a técnica de convolução dilatada,

que altera o campo de visão do *kernel* inserindo um parâmetro extra para definir a taxa de dilatação. Liang-Chieh Chen *et al.* (2017) relatam que a adoção desta técnica permite calcular as respostas das camadas extratoras de características de uma rede para qualquer escala de mapas geradas pelas mesmas.

Dado uma imagem de entrada, primeiramente aplica-se um *downsampling* fator 2, em seguida aplica-se uma operação de convolução *backbone*. A etapa de *upsampling* analisa a imagem no tamanho original gerando o mapa correspondente aos valores vazios, para então somar os resultados das operações e gerar o mapa de características final.

Considerando que um mesmo tipo de objeto pode ser representado por diferentes escalas em uma imagem, Liang-Chieh Chen *et al.* (2017) introduziram ao DeepLab a técnica de pooling da pirâmide espacial de dilatação para a etapa de codificação. A operação une paralelamente as convoluções de dilatação com diferentes taxas de dilatação na entrada do mapa de características para reconstruir as informações geradas em diferentes tamanhos nas camadas de convolução padrão.

Atualmente, a arquitetura DeepLab encontra-se na versão v3+ e é considerada o estado da arte como método de segmentação semântica por trazer avanços importantes para realizar a tarefa de segmentação semântica. O objetivo do DeepLabV3 era capturar limites de objetos mais nítidos, causada pela existência de objetos em múltiplas escalas. Isso foi alcançado adotando a arquitetura *encoder-decoder* com convolução *atrous* nos últimos blocos do *backbone*, conforme pode ser observado através de um exemplo básico de funcionamento da mesma na figura 12.

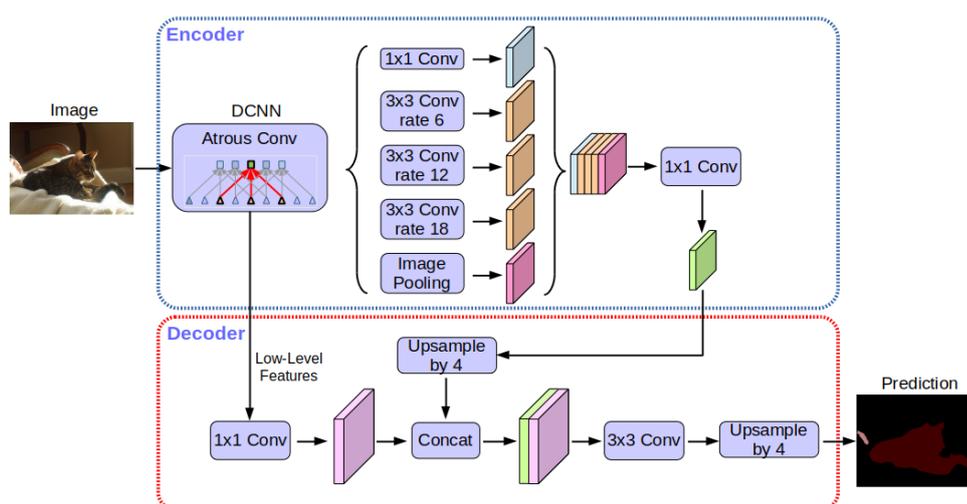


Figura 12 – Arquitetura da rede neural de segmentação DeepLab V3+.

O método de convolução *atrous* modifica o *kernel* inserindo lacunas/espacos entre os elementos. Com elas, aumenta-se diretamente o espaçamento entre os pesos de convolução, sem realmente aumentar o número de pesos na operação. A distância entre cada peso é chamada de taxa de dilatação (*atrous rate*).

Quando uma baixa taxa de dilatação é usada, ela é processada em informações muito locais ou de baixa escala. Quando alta taxa de dilatação é usada, mais informações globais/de alta escala são processadas. Assim, o modelo DeepLabV3 mescla *atrous* com diferentes taxas de dilatação para capturar informações multiescala (CHEN, L.-C. *et al.*, 2017).

Além das características extraídas do *backbone*, uma rede Atrous Spatial Pyramid Pooling (ASPP) é adicionada para classificar cada pixel correspondente às suas classes. A saída da rede ASPP é passada por uma convolução 1 x 1 para obter o tamanho real da imagem que será a máscara segmentada final para a imagem (CHEN, L.-C. *et al.*, 2017).

### 2.3.2 Redes Neurais Recorrentes

Para entender sobre RNN, torna-se importante entender primeiramente o conceito de redes neurais *feedforward*. A figura 13 exhibe o comportamento desse tipo de rede neural, onde todos os neurônios estão conectados em apenas uma direção : da camada de entrada (*input layer*) para as camadas intermediárias (*hidden layers*) e finalmente para a camada de saída (*output layer*)(GULLI; PAL, 2017).

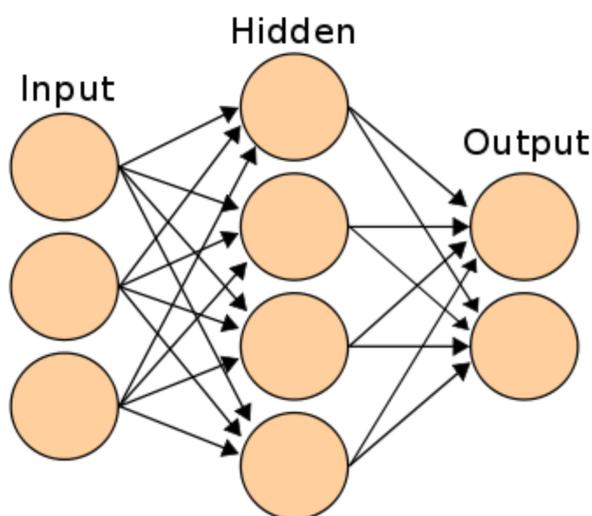


Figura 13 – Arquitetura básica de uma rede neural artificial.

Redes neurais *feedforward* não são boas em resolver problemas que envolvem dados sequenciais. Segundo Kawakami (2008), isso ocorre porque na sua estrutura interna não existe uma memória da entrada que receberam previamente, não existindo uma noção de ordem temporal entre duas ou mais entradas sequenciais.

Goldberg (2017) explica que esta característica pode ser adquirida se a informação que é transmitida do neurônio da camada atual para o neurônio da camada seguinte também for retransmitida para ele mesmo, formando uma conexão de recor-

rência. Assim, o neurônio possui não apenas informações das entradas atuais, mas também informações das entradas anteriores.

As RNN foram estruturadas para que funcionem desta forma. Cada *feature*  $x$  de um *input* alimenta a rede neural e gera um *output*  $\hat{y}$ , quando a rede lê a próxima *feature*, ela carrega alguma informação do passo anterior para gerar um *output*. Esse processo se repete até o final do dado sequencial, como é mostrado na figura 14 (GULLI; PAL, 2017).

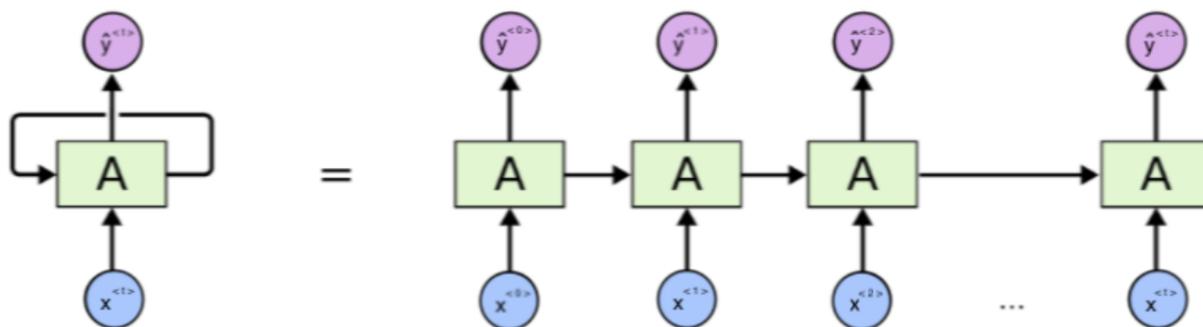


Figura 14 – Arquitetura básica de uma rede neural recorrente (OLAH, 2015).

A figura 15 apresenta, com maiores detalhes, a estrutura de uma RNN. Toda vez que a rede neural computa o valor de  $\hat{y}^{<t>}$  ela passa para o próximo *step* uma variável de ativação  $a^{<t>}$ , que é levada em consideração no cálculo de  $\hat{y}^{<t+1>}$ .

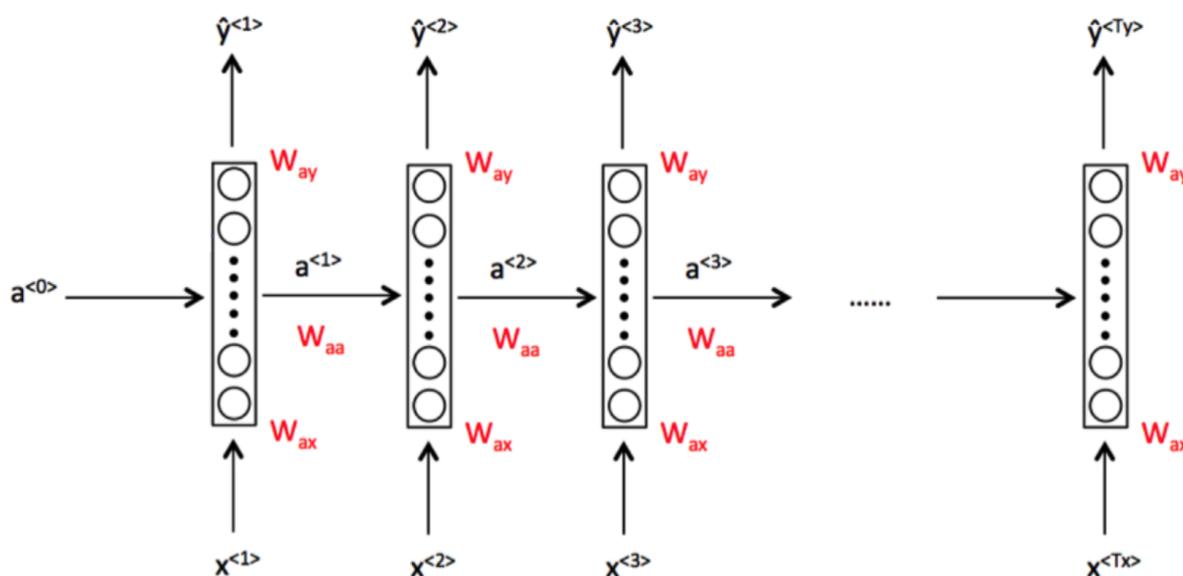


Figura 15 – Arquitetura básica de uma rede neural recorrente (NG *et al.*, 2017).

A RNN analisa os dados sequenciais da esquerda para a direita e os pesos usados para cada passo, dados pela matriz  $W_{ax}$ , são compartilhados entre todos os passos. As conexões horizontais são governadas pela matriz de pesos  $W_{aa}$ , enquanto a responsável pelo output é a matriz  $W_{ay}$ .

A RNN funcionando em *forward propagation* é regida pelas seguintes fórmulas:

$$a^{<0>} = \vec{0} \tag{1}$$

$$a^t = g(W_{aa}a^{<t-1>} + W_{ax}x^{<t>} + b_a) \tag{2}$$

$$\hat{y}^{<t>} = g(W_{ya}a^{<t>} + b_y) \tag{3}$$

onde  $a^{<t>}$  é a variável de ativação,  $g()$  é a função de ativação sendo utilizada,  $b_a$  é um fator de correção para o cálculo de  $a^{<t>}$  e  $b_y$  é o fator de correção para o cálculo de  $\hat{y}^{<t>}$ .

Para que a rede aprenda através do *back propagation*, é preciso uma função de custo. Para isso, será definida seguinte função:

$$L^{<t>} = (y^{<t>}, \hat{y}^{<t>}) = -y^{<t>} \log \hat{y}^{<t>} - (1 - y^{<t>}) \log (1 - \hat{y}^{<t>}) \tag{4}$$

Para definir uma função de custo geral da sequência inteira, basta fazer o somatório das funções de custo de 1 até  $T_y$ , nesse caso  $T_x = T_y$ . Portanto:

$$L(\hat{y}, y) = \sum_{t=1}^{T_y} (y^{<t>}, \hat{y}^{<t>}) \tag{5}$$

O processamento do *back propagation* é realizada conforme apresentado pelas setas vermelhas da figura 16.

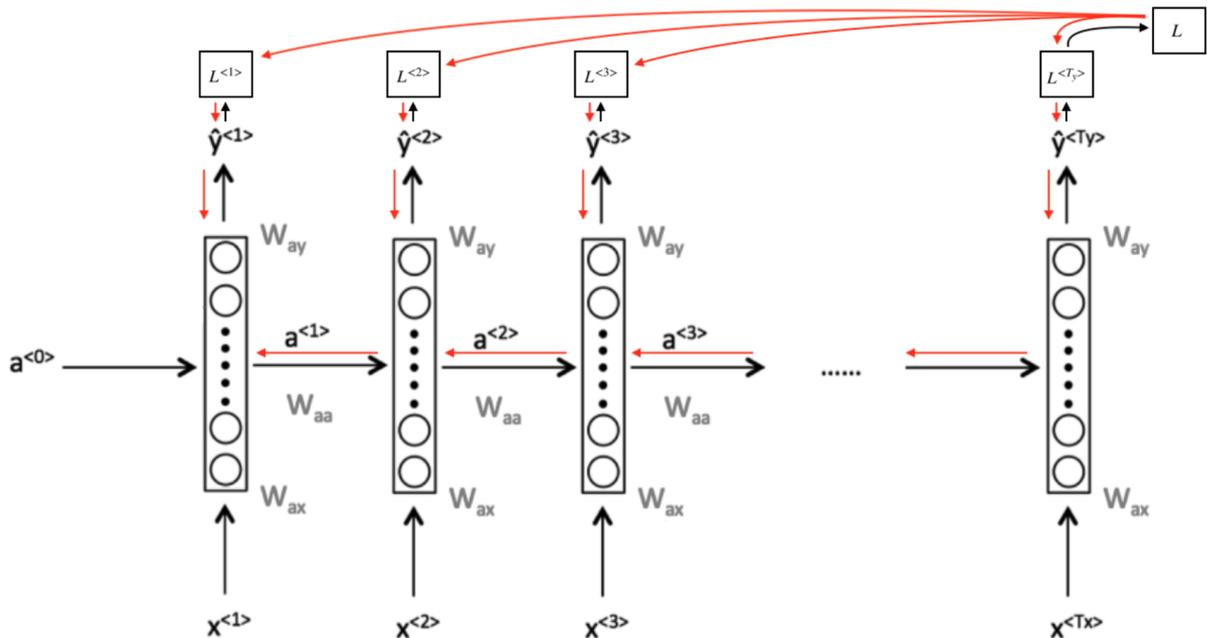


Figura 16 – Rede neural recorrente com *back propagation* (NG et al., 2017).

### 2.3.3 Arquitetura das Redes Neurais Recorrentes

Uma rede neural recorrente pode assumir diferentes formas, variando a quantidade de camadas de entrada, camadas ocultas e de saída. Gulli e Pal (2017) explicam que cada tipo de rede neural recorrente é utilizado para um fim diferente. A Figura 17 representa as principais disposições que uma rede neural recorrente pode assumir.

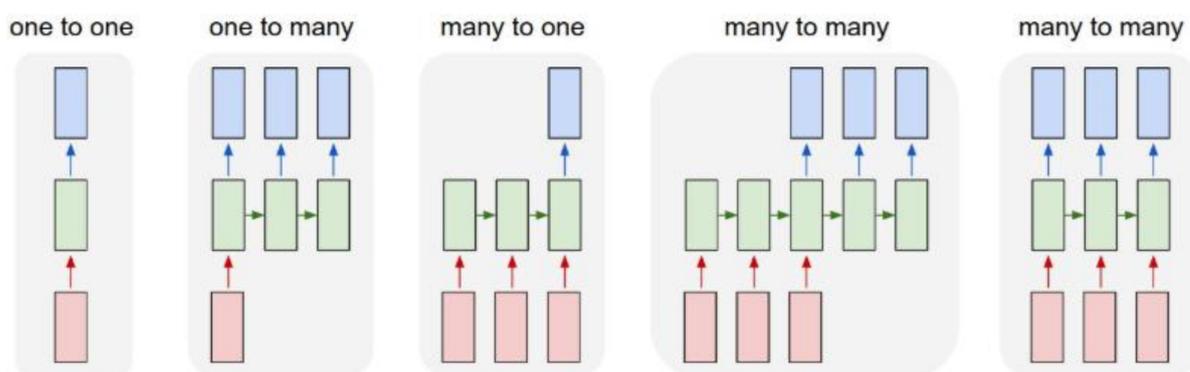


Figura 17 – Diferentes tipos de aplicações usando redes neurais recorrentes (OLAH, 2015).

Nas imagens da figura 17, as entradas estão representadas pelos blocos de cor rosa, as camadas ocultas estão sendo representadas pelos blocos em verde e as camadas de saída pelos blocos em azul. No primeiro caso (*one-to-one*), observa-se que os sinais de entrada levam diretamente aos sinais da camada oculta que, por sua vez, transferem para a saída. Trata-se de uma rede neural *feedforward* clássica (KAWAKAMI, 2008).

As redes *one-to-many* possuem apenas uma entrada para dados, mais de uma camada oculta com recorrência (os sinais da camada oculta são transferidos para as saídas e para os sinais da camada oculta no período de tempo posterior) e mais de uma saída. Segundo Gulli e Pal (2017), um bom exemplo de uso deste tipo de rede seria a transcrição de uma imagem, uma vez que a entrada seria a própria imagem e o estado oculto seria lido várias vezes, representando cada palavra da descrição desta imagem, que seria enviada para a saída.

No caso *many-to-one*, os dados são passados para a entrada diversas vezes, esses dados são processados na camada oculta, mas geram apenas um resultado na saída. Um bom exemplo de uso deste tipo de rede é a análise de sentimentos em textos, cuja entrada seriam várias palavras e a saída um valor (GULLI; PAL, 2017).

Na aplicação *many-to-many* representada pela terceira imagem, os dados são lidos por alguns períodos de tempo antes de iniciar uma previsão, o que dá a este tipo de rede neural uma característica de defasagem temporal entre a entrada e a saída da previsão. Gulli e Pal (2017) explicam que bons exemplos seriam a tradução de áudios ou textos escritos em outra língua.

Por fim, há uma última aplicação *many-to-many* que é utilizada quando há a necessidade de ter várias entradas e saídas no mesmo período de tempo. Bianchi *et al.* (2017) citam a utilização em séries temporais, situações em que há a necessidade de realizar previsões para o período de tempo seguinte, dado o que aconteceu no período atual e nos períodos anteriores. Essa pode ser uma boa abordagem para ser utilizada na classificação de elementos arquiteturais.

### 2.3.3.1 Redes de Memória de Longo Prazo

Hochreiter e Schmidhuber (1997) introduziram um tipo especial de RNN denominadas Redes de Memória de Longo Prazo (*Long Short-Term Memory - LSTM*). Este tipo de rede neural é recomendado para tratar o problema de *vanishing gradients*, quando a rede “esquece” o que aconteceu anteriormente e não consegue propagar as dependências através da sequência inteira.

Conforme apresentado na seção anterior, é possível perceber que as RNNs conseguem perceber que a saída da rede foi influenciada principalmente pelos valores da sequência mais próximos. Por outro lado, há situações em que as features possuem longas dependências com dados mais distantes (BIANCHI *et al.*, 2017).

RNNs básicas não são eficientes em capturar essas dependências de longo prazo, porque essas redes não conseguem propagar para os *timesteps* de sequências mais antigas.

Diferentemente das RNNs padrões, as LSTMs possuem um módulo de repetição, até então composto por uma única camada de rede neural (GULLI; PAL, 2017). Esses módulos são compostos por quatro camadas que interagem de forma especial, como pode ser visto na figura 18.

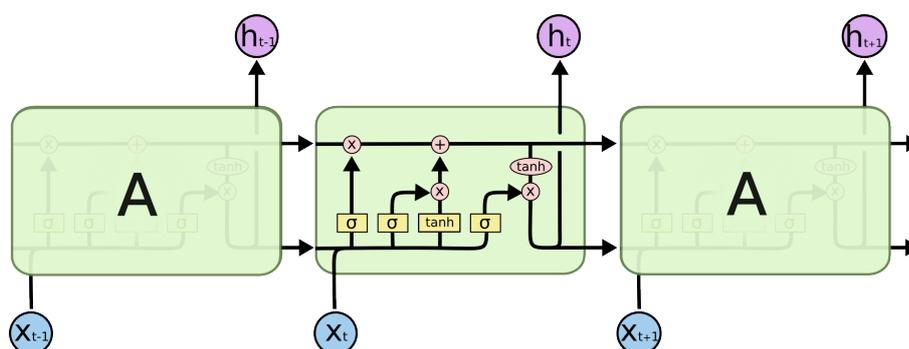


Figura 18 – Unidade interna de uma LSTM (OLAH, 2015).

O *core* da LSTM é o estado da célula, que é a linha horizontal que atravessa o topo do diagrama. Ela atravessa a cadeia inteira sofrendo apenas pequenas alterações causadas pelas estruturas conhecidas como *gates* (GULLI; PAL, 2017).

Esses são meios que opcionalmente deixam a informação atravessar a cadeia e são compostos por uma camada *Sigmoid* e uma operação de multiplicação. O sinal

*Sigmoid* tem como saída valores de 0 a 1, que representam deixar o sinal passar inteiramente ou não passar, respectivamente. Uma LSTM possui três gates como esse para proteger e controlar o estado da célula.

O primeiro desses gates é o *forget gate*, que olha para o valor de  $a^{<t-1>}$  e  $x^{<t>}$  e gera um número de 0 a 1 para cada número no estado da célula. A fórmula para o forget gate é:

$$f_t = \sigma(W_f[a^{<t-1>}, x^{<t>}] + b_f), \quad (6)$$

onde  $W_f$  é uma matriz de parâmetros que recebe  $a^{<t-1>}$  e  $x^{<t>}$ , e  $b_f$  é um valor de correção.

O próximo passo é para decidir qual nova informação será armazenada no estado da célula. Para isso há duas etapas: a primeira é uma camada *Sigmoid* chamada *input gate*, que decide quais valores serão atualizados, a segunda é uma camada *tanh* que cria um vetor de novos valores candidatos,  $\tilde{C}^{<t>}$ , que podem ser adicionadas ao estado, sendo:

$$u_t = \sigma(W_u[a^{<t-1>}, x^t] + b_u) \quad (7)$$

$$\tilde{C}^{<t>} = \tanh(W_c[a^{<t-1>}, x^t] + b_c) \quad (8)$$

onde  $W_u$  e  $W_c$  são matrizes de parâmetros que recebem  $a^{<t-1>}$  e  $x^{<t>}$ , e  $b_u$  e  $b_c$  são valores de correção.

Na sequência, o antigo  $C^{<t-1>}$  é atualizado com um novo  $C^{<t>}$ , multiplicando o estado antigo por  $f_t$  e depois adicionando  $u_t * \tilde{C}^{<t>}$ . Portanto:

$$C^{<t>} = f_t * C^{<t-1>} + u_t * \tilde{C}^{<t>} \quad (9)$$

Finalmente, é decidido qual será o *output*. Primeiro, roda-se uma camada *Sigmoid* que decide quais partes do estado farão parte da saída. Depois, submete-se o estado da célula a uma função *Tanh*, resultando em valores entre -1 e 1 e multiplica-se a saída da função *Sigmoid*, de acordo com:

$$o^{<t>} = \sigma(W_o[a^{<t-1>}, C^{<t>}] + b_o) \quad (10)$$

$$a^{<t>} = o^{<t>} * \tanh(C^{<t>}) \quad (11)$$

Essa estrutura de *gates* permite que o fluxo de informações de um estado de célula permite a solução de diversos problemas relacionados a modelos sequenciais com dependências de longo prazo.

### 2.3.3.2 Redes Neurais Recorrentes Bidirecionais

As RNNs bidirecionais são uma extensão dos RNNs tradicionais que podem melhorar o desempenho do modelo em problemas de classificação de sequência

(SCHUSTER; PALIWAL, 1997). O uso de RNNs bidirecionais pode não fazer sentido para todos os problemas de previsão de sequência, mas pode oferecer algum benefício em termos de melhores resultados para os domínios em que é apropriado.

Schuster e Paliwal (1997) comentam sobre o uso de fornecer a sequência bidirecionalmente no domínio do reconhecimento de fala, porque há evidências de que o contexto de toda a expressão é usada para interpretar o que está sendo dito, em vez de uma interpretação linear. Uma visão de uma rede bidirecional aplicada em uma RNN comum pode ser visualizada na figura 19.

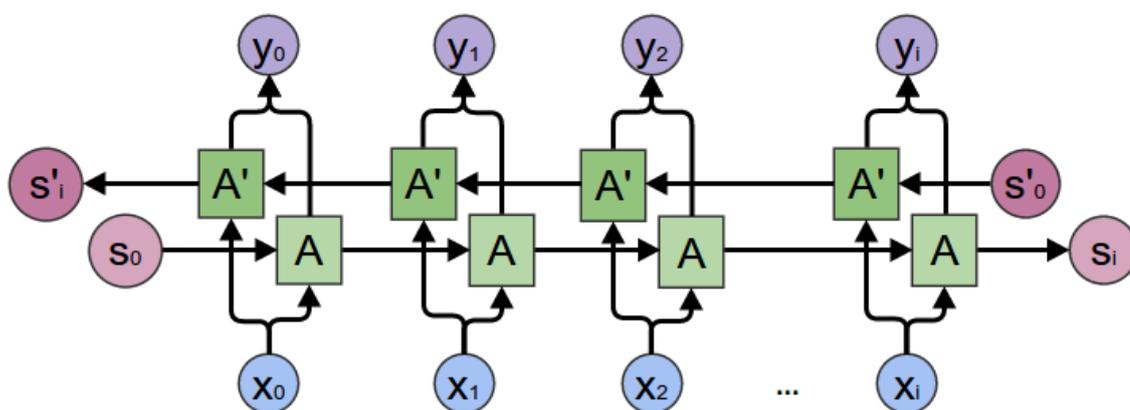


Figura 19 – Estrutura de uma RNN Bidirecional comum (OLAH, 2015).

Nos problemas em que todas as etapas de tempo da sequência de entrada estão disponíveis, os RNNs bidirecionais treinam duas camadas lado a lado, fornecendo a sequência de entrada como está na entrada da primeira camada e fornecendo uma cópia invertida da sequência de entrada para a segunda (SALEHINEJAD *et al.*, 2017).

A idéia das LSTM Bidirecionais (*Bidirectional LSTM - BDLSTM*) vem do RNN bidirecional e pode ser visualizada na figura 20 (GRAVES; SCHMIDHUBER, 2005). A sequência de saída da camada *forward*,  $\vec{h}$ , é calculada usando entradas em uma sequência positiva do tempo  $T - n$  até o tempo  $T - 1$ , enquanto que a sequência de saída da camada *backward*,  $\overleftarrow{h}$ , é calculada usando entradas reversas do tempo  $T - n$  até o tempo  $T - 1$ .

As saídas da camada *forward* e *backward* são calculadas usando as equações de atualização padrão do LSTM. A camada BDLSTM gera um vetor de saída,  $Y_T$ , no qual cada elemento é calculado usando a seguinte equação:

$$y_t = \sigma(\vec{h}_t, \overleftarrow{h}_t) \tag{12}$$

onde a função  $\sigma$  é usada para combinar as duas sequências de saída.

Graves e Schmidhuber (2005) explicam que pode ser uma função de concatenação, uma função de soma, um função média ou uma função de multiplicação. Semelhante ao Camada LSTM, a saída final de uma camada BDLSTM pode ser representado por um vetor,  $Y_T = [y_{T-n}, \dots, y_{T-1}]$ , no qual o último elemento,  $y_{T-1}$ , é a

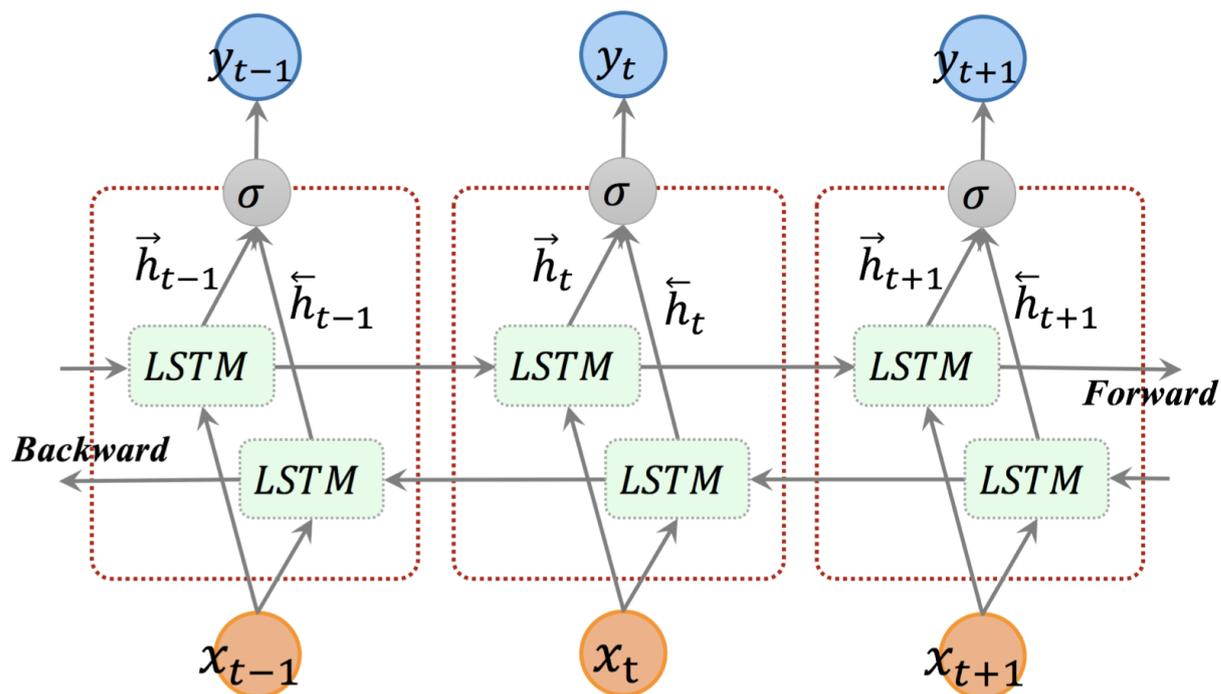


Figura 20 – Arquitetura desdobrada do LSTM bidirecional com três etapas consecutivas (SALEHINEJAD *et al.*, 2017).

velocidade prevista para a próxima iteração ao tomar a previsão de velocidade como um exemplo.

### 3 TRABALHOS CORRELATOS

Neste capítulo será descrito o plano adotado para a revisão da bibliografia. Serão apresentados os trabalhos relacionados à identificação de padrões faciográficos e estatigráficos, bem como trabalhos que utilizam dados de curva de poço para classificação de padrões sedimentares e dados de afloramento para classificação de litofácies. Por fim, serão apresentadas as tabelas comparativas entre os métodos existentes para classificação dos padrões faciográficos, fontes de dados utilizadas e o método proposto neste trabalho.

#### 3.1 PLANO DE REVISÃO

Para esta revisão sistemática foram consultados os portais SCOPUS, Science Direct, ACM Digital Library e IEEE Xplore. A fim de listar os trabalhos relacionados, as buscas foram divididas em dois temas: o primeiro, relacionado técnicas de classificação de padrões faciográficos e estatigráficos e de predição utilizando dados de curva de poço; e o segundo, relacionado trabalhos de classificação de litofácies utilizando imagens de afloramento.

Esta busca é refinada nas seguintes perguntas de análise:

- Quais abordagens existem?
- Quais os conjuntos de dados utilizados para treinamento e seus tamanhos?
- Qual algoritmo de aprendizado foi utilizado?
- Qual a acurácia/qualidade dos resultados obtidos?

Durante o levantamento de trabalhos correlatos relacionados a classificação de litofácies utilizando curvas de poços, foram excluídas publicações que não implementam ou propõe métodos utilizando inteligência artificial para classificação de padrões geológicos. Apenas artefatos na língua inglesa e acessíveis pela CAPES foram considerados. Além disso, a busca foi limitada aos últimos doze anos de publicações, entre 2010 e 2022. Segue abaixo o termo de busca utilizado nas fontes de dados para padrões faciográficos utilizando curvas de poços.

```
TITLE-ABS-KEY ( ( "wireline log" OR "well logging"
OR " log facies" ) AND ( "shape" OR "pattern" ) AND
( "machine learning" OR "neural network" OR
"artificial Intelligence" ) )
```

Inicialmente a busca retornou um total de 365 resultados, sendo posteriormente analisados e estudados, excluindo assim artigos e publicações que não se enquadravam ao escopo do trabalho proposto. Os resultados de cada plataforma foram os seguintes:

- SCOPUS: 169 obras;
- Science Direct: 41 obras;
- ACM Digital Library: 69 obras;
- IEEE Xplore: 86 obras.

Para o problema de classificação de litofácies utilizando imagens de afloramento, foram levantados trabalhos que utilizam redes neurais e métodos clássicos de visão computacional. Além disso, a busca foi limitada aos últimos doze anos de publicações, entre 2010 e 2022. Segue abaixo o termo de busca utilizado nas fontes de dados para padrões de litofácies a partir de imagens de afloramentos.

```
TITLE-ABS-KEY ( ( "lithologic boundar" OR "outcrop"  
OR " lithological boundar" ) AND ( "detection" OR  
"segmentation" ) AND  
( "image" OR "uav" ) )
```

Inicialmente a busca retornou um total de 304 resultados, sendo posteriormente analisados e estudados, excluindo assim artigos e publicações que não se enquadravam ao escopo do trabalho proposto. Os resultados de cada plataforma foram os seguintes:

- SCOPUS: 147 obras;
- Science Direct: 33 obras;
- ACM Digital Library: 54 obras;
- IEEE Xplore: 70 obras.

### 3.2 CLASSIFICAÇÕES DE PADRÕES FACIOLÓGICOS E ESTATIGRÁFICOS UTILIZANDO DADOS DE CURVA DE POÇO

Os trabalhos selecionados foram analisados e filtrados a partir de seu resumo. Foram desconsiderados trabalhos que não utilizam dados de curva de poço, que não tem por objetivo classificar fácies geológicas ou que de identificar padrões faciológicos. Após esta análise, 7 artigos foram selecionados, considerando suas contribuições para o desenvolvimento desta pesquisa.

Os métodos de aprendizado de máquina mais usados para a identificação automática de microfácies deposicionais por registros de poços incluem algoritmos bayesianos, agrupamento difuso, Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) e RNA. Estas abordagens forneceram plataformas robustas, eficientes e eficazes para resolver problemas.

Al-Anazi e Gates (2010) propuseram uma estrutura de modelagem baseada em SVMs para identificar litofácies utilizando dados de curva de poços. Além disso, os autores apresentaram uma seleção de recursos com base na teoria difusa para identificar recursos em potencial discriminatório dos registros de poços em um reservatório heterogêneo de arenito. Os resultados foram superiores comparados aos métodos de análise discriminante e redes neurais probabilísticas. No entanto, abordagens mais recentes podem apresentar resultados superiores.

Outra abordagem baseada em SVM foi proposta por Dahai Wang *et al.* (2019), com o objetivo de identificar fácies deposicionais a partir de dados de curva de poços. As fácies deposicionais foram determinadas manualmente em vários poços, e então um modelo quantitativo de discriminação foi criado para realizar a classificação das microfácies deposicionais. O método foi aplicado em campo e mostrou-se útil para identificar fácies deposicionais em poços não-escavados.

Li *et al.* (2013) utilizam Mapas de Kohonen para identificação de fácies sedimentares, através de informações geométricas de dados de curva de poços. O modelo desenvolvido foi aplicado em 1000 poços e apresentou uma taxa superior a 90% de acurácia.

Silversides *et al.* (2015) apresentam um método para identificar marcadores estratigráficos recorrentes em registros de raio gama de vários poços. Os folhelhos marcadores são identificados usando Processos Gaussianos (*Gaussian Process* - GP). O método de aprendizado ativo, que apresentou uma acurácia maior nas assinaturas identificadas, utiliza a medida de incerteza fornecida pelo GP para selecionar exemplos específicos para o usuário considerar como adição.

Tschannen *et al.* (2017) propuseram uma abordagem utilizando uma estrutura de Redes Neurais Convolucionais (*Convolutional Neural Network* - CNN) para determinar fácies geológicas a partir de registros de poços. A rede foi treinada para prever séries de fácies que correspondem exatamente à interpretação dos especialistas.

O trabalho desenvolvido por Zhang *et al.* (2017) utiliza dois tipos de abordagens para implementar a identificação das fácies, uma direta e outra indireta. Para cada abordagem, dois algoritmos foram implementados, um baseado em Regressão Logística Multinomial (*Multinomial Logistic Regression* - MLR) e outra em RNA. Os algoritmos da abordagem indireta, que realiza a classificação das litofácies primeiro e depois identificaram as microfácies com base nas litofácies estimadas anteriormente, apresentaram desempenhos superiores.

Song *et al.* (2020) desenvolveram um método para a identificação de formas padrões de raio gama utilizando uma rede neural LSTM. de log. O conjunto de dados utilizado contém 2676 segmentos de log de Potencial Espontâneo (*Self Potential* - SP). Um comitê de quatro geólogos experientes anotou um conjunto de dados de teste padrão, com base no qual diferentes abordagens poderiam ser comparadas em

relação à sua acurácia. Entre todas as abordagens testadas, a arquitetura com núcleo LSTM apresentou os melhores resultados.

### 3.2.1 Tabela Comparativa

A tabela 2 apresenta uma comparação entre os trabalhos analisados, bem como a proposta do atual trabalho. Foram consideradas as abordagens utilizadas, o padrão geológico a ser classificado, a base de dados e as *features* utilizadas.

## 3.3 CLASSIFICAÇÕES DE LITOFÁCIES UTILIZANDO IMAGENS DE AFLORAMENTOS

Os trabalhos selecionados foram analisados e filtrados a partir de seu resumo. Foram desconsiderados trabalhos que não utilizam imagens de afloramento, que não tem por objetivo classificar fácies geológicas ou que de identificar padrões faciológicos. Após esta análise, 7 artigos foram selecionados, considerando suas contribuições para o desenvolvimento desta pesquisa.

Várias técnicas de segmentação não supervisionadas foram usadas para detectar limites litológicos de dados de sensoriamento remoto, usando abordagens de superpixel e crescimento de região a partir de cores selecionadas pelo usuário. Outros trabalhos têm abordagens semelhantes, como o algoritmo de casamento de modelos de variantes de rotação (RTM).

Salati *et al.* (2011) aplicaram o algoritmo RTM a imagens ASTER para detectar limites entre calcário e arenito evaporado. Já Marques *et al.* (2022) estudaram o problema de identificação de fraturas e descontinuidades na estimativa do fluxo de fluidos em reservatórios de hidrocarbonetos através de imagens de VANTs através do método de segmentação adaptativa local Sauvola.

Vasuki *et al.* (2014) propuseram um método usando um algoritmo de superpixel, mesclando cada superpixel com superpixels vizinhos com base em sua semelhança de cor e na próxima etapa aplicando o crescimento de regiões especificadas pelas linhas marcadas pelo usuário para determinar diferentes unidades litológicas.

Um estudo piloto do (NGCOFE; MINNAAR, 2012) mostra que, embora a técnica automatizada detecte bem alguns dos limites, ela produziu supersegmentação em algumas litologias. Além disso, os métodos não supervisionados são dependentes da interação humana, o que pode levar a resultados de segmentação diferentes para diferentes usuários do aplicativo.

A pesquisa de segmentação de imagens tem focado principalmente em métodos baseados em semântica de alto nível. Sua ideia central é determinar as possíveis localizações do alvo na imagem a serem detectadas antecipadamente através de regiões candidatas. À medida que a tecnologia de segmentação de imagens baseada

em métodos de aprendizado profundo se tornou cada vez mais madura no campo das ciências da terra.

Wu *et al.* (2022) utilizaram métodos de extração automática baseada em redes neurais convolucionais para identificação automática de cavidades no perfil digital do afloramento através da arquitetura de rede neural convolucional de região de máscara (Mask R-CNN) é proposta. Este método se adapta às características multiescala da cavidade manipulando as escalas da imagem de entrada.

Junior *et al.* (2021) compararam as arquiteturas CNNs Segnet e U-net utilizaram no reconhecimento automático da rede de fraturas sobre as imagens do afloramento utilizando imagens de VANTs. Sato *et al.* (2021) utilizaram imagens de afloramentos capturadas através de uma câmera digital monocular RGB, para então utilizar redes neurais para medir de camadas geológicas, processo importante para o levantamento de um modelo geológico. Foram comparadas as arquiteturas SegNet, U-Net e DeepLabv3+.

### 3.3.1 Tabela Comparativa

A tabela 2 apresenta uma comparação entre os trabalhos analisados, bem como a proposta do atual trabalho. Foram considerados os tipos de captura das imagens, as abordagens utilizadas e o padrão geológico a ser classificado.

Tabela 1 – Trabalhos Relacionados e Suas Características

| Trabalho                           | Abordagem utilizada | Padrão geológico                    | Base de dados  | <i>well-log</i> |
|------------------------------------|---------------------|-------------------------------------|----------------|-----------------|
| (AL-ANAZI; GATES, 2010)            | SVM e teoria Fuzzy  | Litofácies                          | 2 furos        | 9               |
| (WANG, D. <i>et al.</i> , 2019)    | SVM                 | Microfácies                         | 25 microfácies | 1               |
| (LI <i>et al.</i> , 2013)          | Mapas de Kohonen    | Microfácies                         | 1000 poços     | 1               |
| (SILVERSIDES <i>et al.</i> , 2015) | GP                  | Padrões estatigráficos              | 5948 furos     | 1               |
| (ZHANG <i>et al.</i> , 2017)       | MLR e RNA           | Litofácies                          | 3 poços        | 3               |
| (TSCHANNEN <i>et al.</i> , 2017)   | CNN                 | Microfácies                         | 11 poços       | 5               |
| (SONG <i>et al.</i> , 2020)        | LSTM                | Padrões estatigráficos              | 2676 leituras  | 1               |
| Este trabalho                      | Bidirectional LSTM  | Litofácies e Padrões estatigráficos | 20 poços       | 6               |

Tabela 2 – Trabalhos Relacionados e Suas Características

| Trabalho                       | Timpo de image | Abordagem utilizada           | Padrão geológico          |
|--------------------------------|----------------|-------------------------------|---------------------------|
| (SALATI <i>et al.</i> , 2011)  | Satélite       | RTM e ASTER                   | Litologia                 |
| (NGCOFE; MINNAAR, 2012)        | Satélite       | Agrupamento                   | Litologia                 |
| (MARQUES <i>et al.</i> , 2022) | VANTs          | Sauvola                       | Fraturas                  |
| (VASUKI <i>et al.</i> , 2014)  | VANTs          | Superpixel                    | Falhas, juntas e fraturas |
| (JUNIOR <i>et al.</i> , 2021)  | VANTs          | SegNet e U-Net                | Fraturas                  |
| (WU <i>et al.</i> , 2022)      | Câmera digital | Mask R-CNN                    | Espaço poroso             |
| (SATO <i>et al.</i> , 2021)    | Câmera digital | SegNet, U-Net e DeepLabv3+    | Padrões geológicos        |
| Este trabalho                  | VANTs          | U-Net, DeepLabv3+ e PointRend | Litologia                 |

## 4 CLASSIFICAÇÃO DE LITOFÁCIES A PARTIR DE LOGS DE CURVAS DE POÇOS

Neste capítulo serão abordados o desenvolvimento e os resultados obtidos no trabalho de classificação de litofácies a partir de logs de curvas de poços. Primeiramente serão apresentadas a base de dados criada a partir de poços presentes na formação Rio Bonito e a arquitetura de rede neural recorrente utilizada para resolver esse problema. Em seguida, serão apresentados os experimentos realizados e os resultados obtidos na identificação de litofácies e de padrões de raio gama.

### 4.1 DESENVOLVIMENTO

Nesta seção serão apresentadas as ideias e implementações amadurecidas durante esta pesquisa, que resultaram em um modelo de LSTM bidirecional capaz de identificar padrões em dados de curva de poço. Além disso, será apresentada a base de dados construída, que conta com informações de 20 poços perfurados na região do Rio Bonito, contendo ainda informações geológicas dos testemunhos extraídos. Discute-se ainda as estratégias adotadas na definição dos conjuntos de dados e os resultados obtidos.

#### 4.1.1 Conjunto de Dados Desenvolvido

O banco de dados para realização desta pesquisa foi construído a partir de 20 poços cedidos pela CPRM (Companhia de Pesquisa de Recursos Minerais), realizados na localidade de Barro Branco, região de Lauro Müller, sul de Santa Catarina. A figura 21 exibe o mapa da região, contendo a localização dos poços.

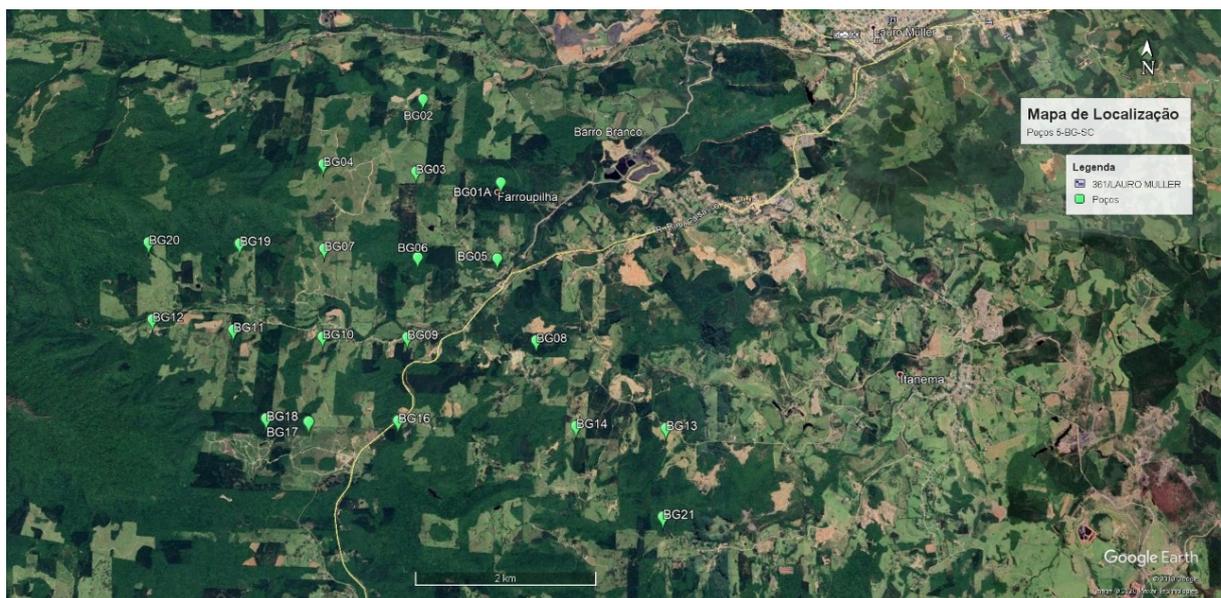


Figura 21 – Mapa da localidade de Barro Branco, região de Lauro Müller, onde os 20 poços foram perfurados.

Os testemunhos apresentam profundidade entre 86 a 279m e estão presentes no relatório do Projeto do Carvão Bonito Gaseificável (MINERAIS, 1974). A figura 22 exibe o mapa dos dados estatigráficos da região, bem como as unidades litoestratigráficas.

As litofácies predominantes incluem arenitos finos, médios a grossos, siltitos e folhelhos, além de camadas de carvão distribuídas em três níveis estratigráficos. Essas fácies se encontram organizadas na forma de ciclos granodecrescentes ascendentes a, subordinadamente, granocrescentes ascendentes.

No geral, o padrão estratigráfico é retrogradacional, onde as fácies proximais (com canais fluviais e planícies de inundação na base) são gradativamente sucedidas por depósitos de planície de maré e praias. Geralmente, toda a sucessão sedimentar apresenta nódulos de pirita e níveis carbonáticos.

Conforme apresentado na figura 23, cada relatório apresenta ainda as leituras de densidade, raio gama e resistividade. Cada relatório foi digitalizado, com o objetivo de ter os valores reais de cada poço, para que seja possível ser manipulado por ferramentas computacionais. Por se tratarem de documentos antigos, para a realização deste processo, foi necessário considerar fatores como alinhamento do documento e escala, afim de tratar o efeito de curvatura do documento. Como resultado, um documento que antes estava digitalizado no formato Portable Document Format (PDF), agora está sumarizado em um arquivo no formato LIDAR Data Exchange Format (LAS).

Na digitalização dos relatórios, as classes granulométricas dos dados faciológicos oriundos dos testemunhos foram rotuladas de forma discreta. Posteriormente, a classificação foi convertida para apresentar os valores contínuos, seguindo a escala de Krumbein (LÓPEZ, 2017), conforme apresentado na figura 24.

Alguns dados faciológicos foram classificados como transição de classes granulométricas, conforme apresentado na figura 25. Como por exemplo, arenito médio à grosso, arenito grosso à muito grosso. Para esses casos, foi aplicada uma função polinomial linear sobre os dados de início e fim do seguimento classificado, utilizando os valores granulométricos para obtenção dos valores em momentos de transição de fácies. Após essa etapa, todos os registros foram armazenados em um arquivo no formato CSV.

#### **4.1.2 Arquitetura de Rede Neural *Bidirectional LSTM***

Neste trabalho, nós optamos por utilizar uma RNN para identificar segmentos de padrões de dados de curva de poço. Essa arquitetura foi escolhida por permitir reconhecer padrões em diferentes escalas sem a necessidade de grandes alterações na arquitetura da rede neural. Em arquiteturas CNN, por exemplo, torna-se necessário alterar o tamanho das máscaras de convolução para reconhecer padrões com diferentes tamanhos de sequência.

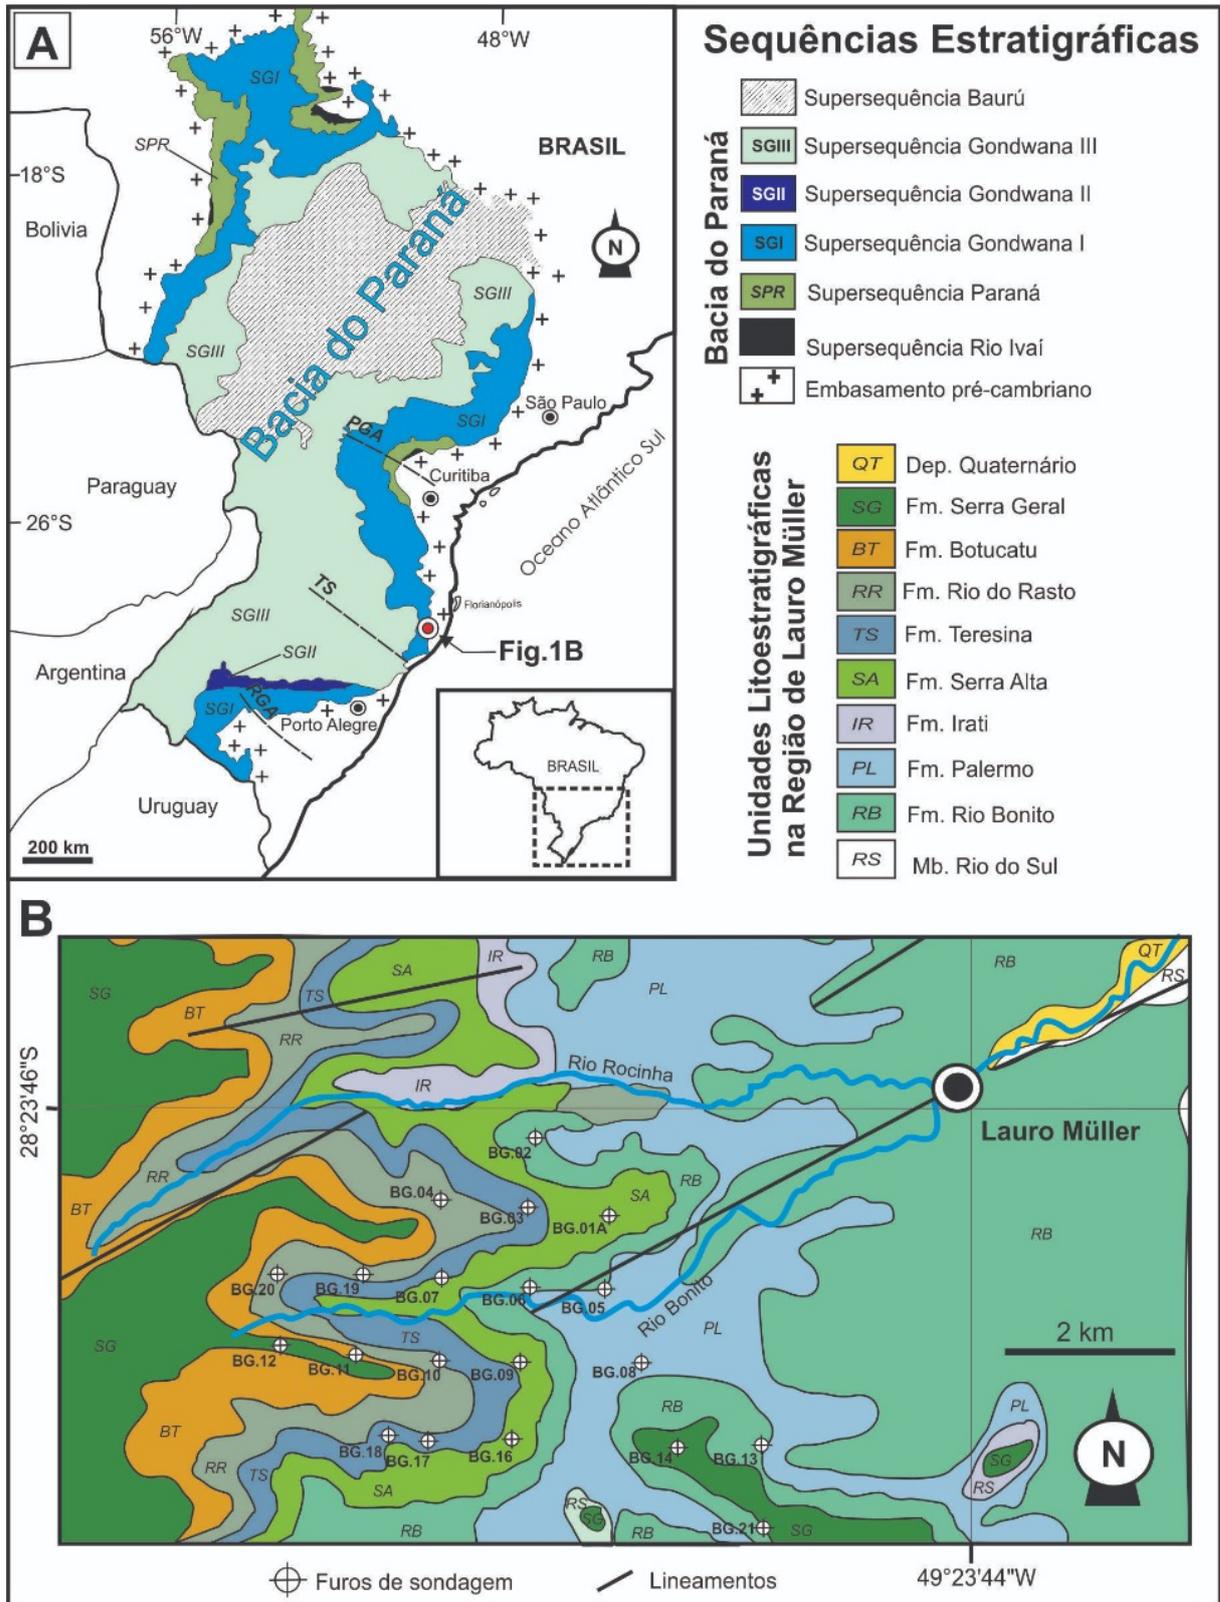


Figura 22 – Mapa contendo informações geológicas e estatigráficas da região onde os poços foram perfurados.

Como já mencionado, a estratigrafia de sequências pode ocorrer em diversas escalas, iniciando pela identificação dos elementos arquiteturais deposicionais, através

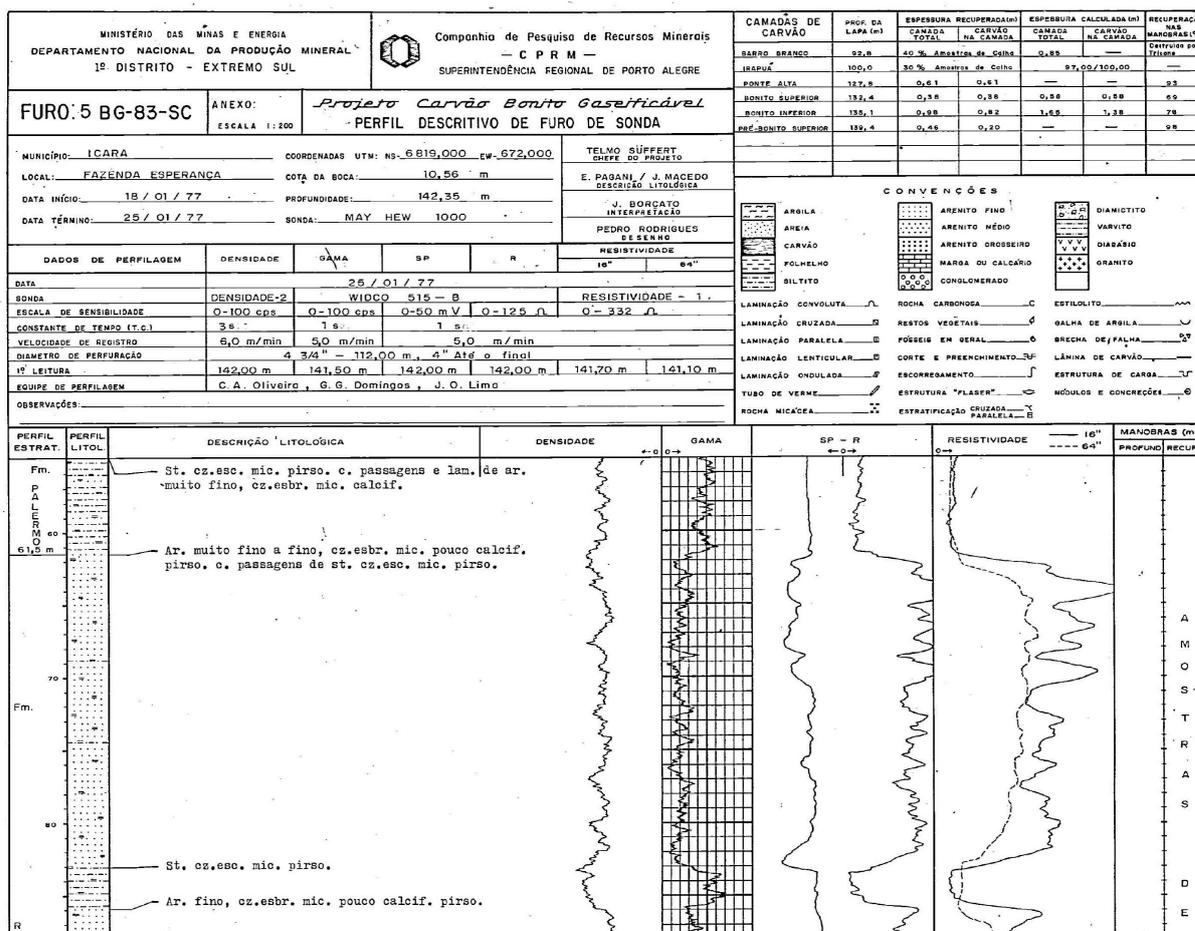


Figura 23 – Parte de um dos arquivos originais contendo as leituras de curva de um poço.

da classificação dos formatos dos perfis de raios gama ou potencial espontâneo e sua correlação com possíveis elementos arquiteturais correspondentes (canal, planície de inundação, barra em pontal, etc).

Uma vez que este processo deposicional ocorre ao longo do tempo, o processamento temporal das informações disponíveis é essencial para a correta classificação dos elementos nos mais diversos níveis. Além disso, a necessidade de examinar também sequencialmente as classes obtidas nas etapas anteriores, parece guardar bastante semelhança com o processamento de voz em aplicações de voz-para-texto (*speech-to-text*) que estão impulsionando pesquisas no estado-da-arte de modelos e aplicações de RNN.

Nestas aplicações o processamento também se dá em diversos níveis (identificação de fonemas a partir de sinais de áudio, identificação de palavras a partir dos fonemas e formação de frases a partir das palavras). Assim, a hipótese desta pesquisa é verificar se técnicas atualmente empregadas no processamento *voice-to-text* poderiam ser empregadas também para a análise estratigráfica em sistemas deposicionais fluviais.

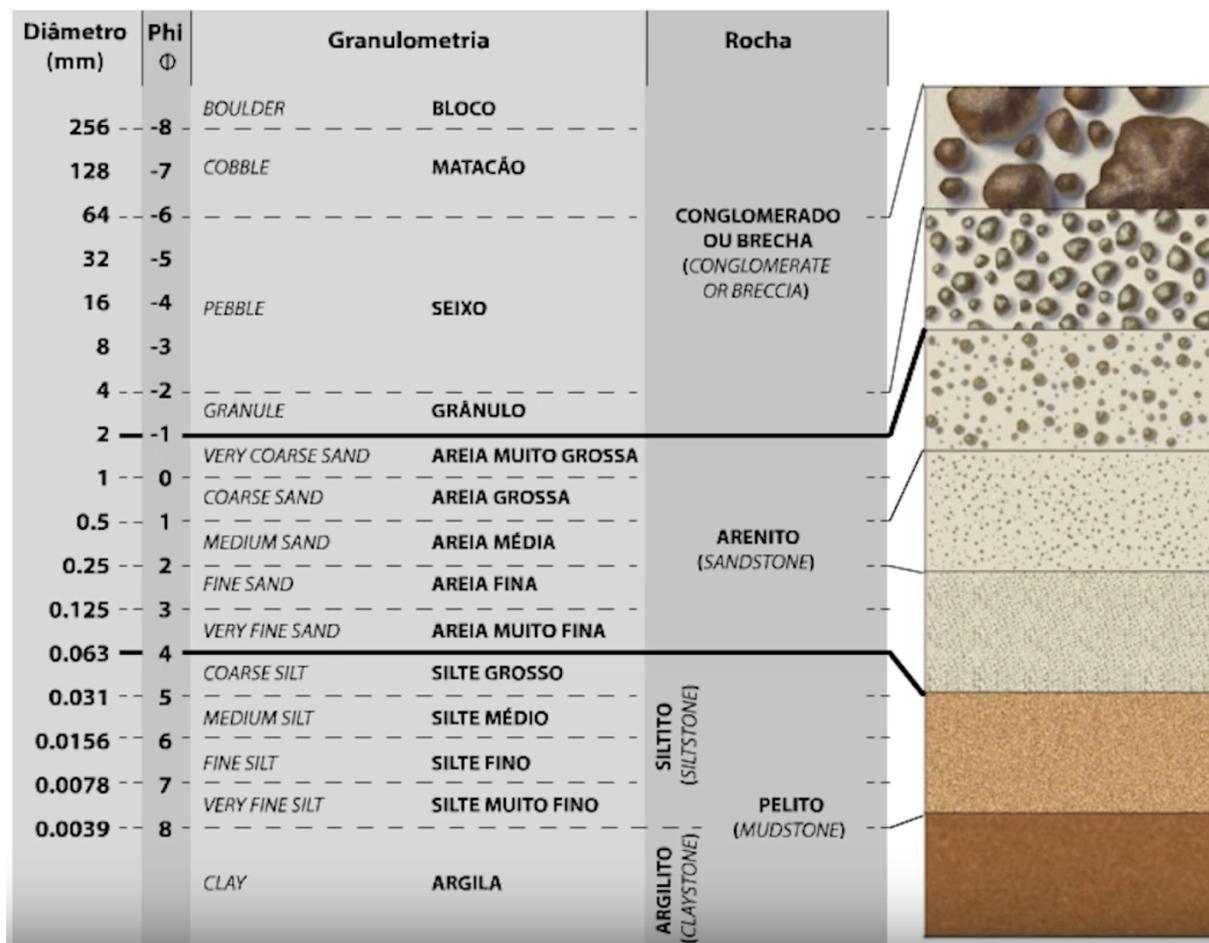


Figura 24 – Escala de Krumbein para valores granulométricos.

Diferentes arquiteturas de RNN foram avaliadas durante o desenvolvimento do trabalho. A arquitetura LSTM foi escolhida por possuir núcleos de memória de longo prazo, o que pode beneficiar o resultado do trabalho.

Além da abordagem LSTM, optou-se por utilizar a arquitetura de LSTM bidirecional. Assim como no domínio do reconhecimento de fala, onde o contexto de toda a expressão é usada para interpretar o que está sendo dito, em vez de uma interpretação linear, o reconhecimento de padrões de curva de poço pode se beneficiar utilizando um reconhecimento bidirecional.

A arquitetura da LSTM bidirecional construída pode ser visualizada na Figura 26. Para a entrada da rede neural foi fixado um comprimento de 100 entradas. Este padrão foi estabelecido visto que os poços da base de dados possuem diferentes profundidades.

Para cada entrada da rede neural, 4 características são usadas para fazer as previsões de fácies: raio gama, densidade, resistividade e granulometria dos dados faciológicos. Durante o desenvolvimento dos trabalhos, outras características derivadas das originais foram adicionadas às entradas, com o objetivo de melhorar a qualidade dos dados, como por exemplo técnicas de suavização.

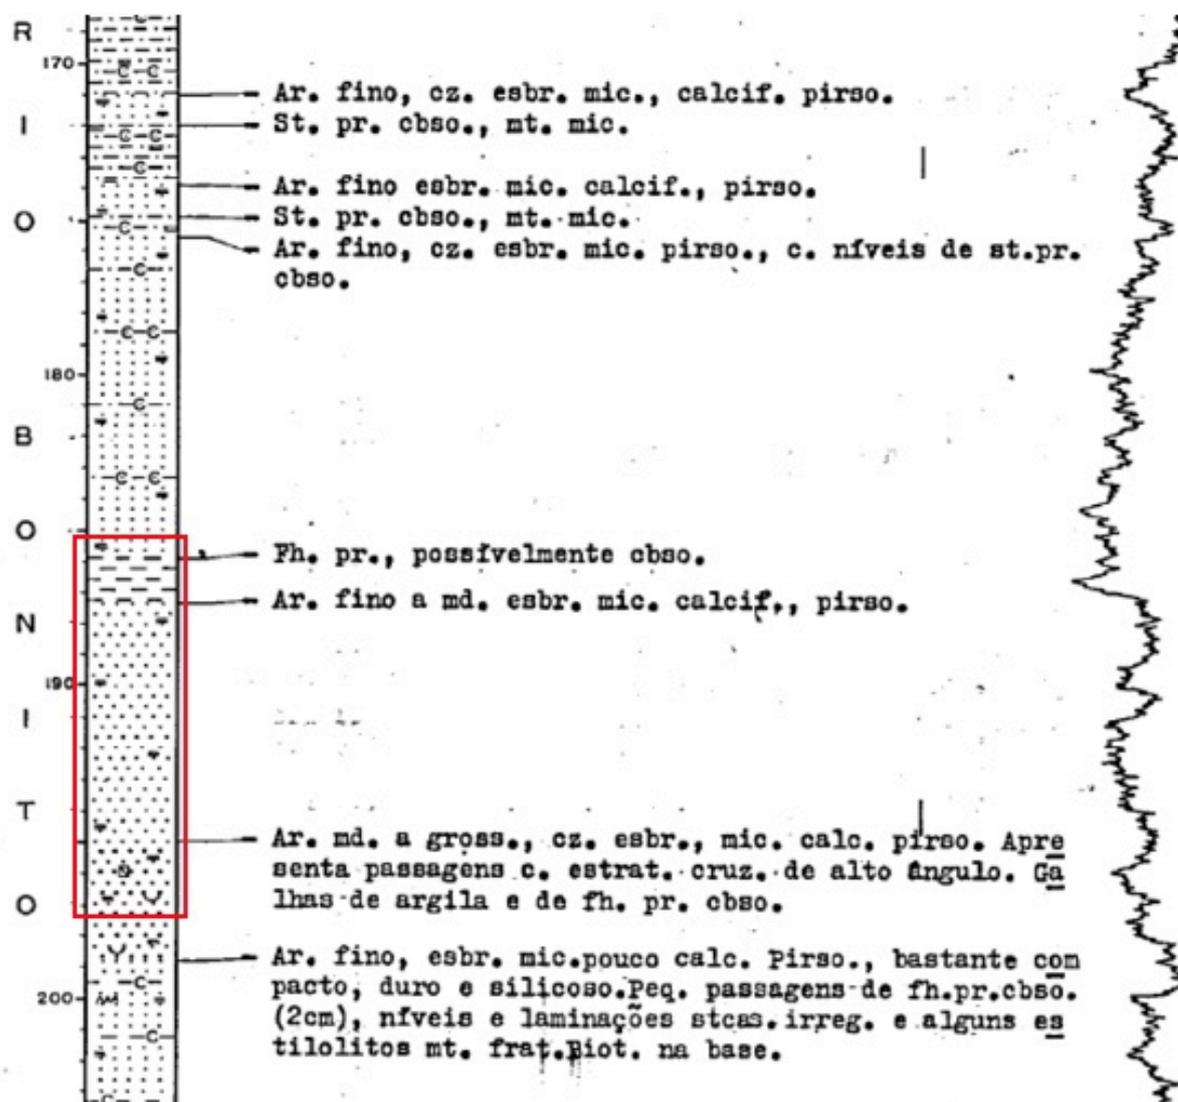


Figura 25 – Exemplo de transição de classes granulométricas presentes no arquivo de leitura de poço.

Após a saída da camada LSTM bidirecional, foi utilizada uma camada *Dropout*. Essa técnica fundamenta-se na eliminação aleatória de neurônios durante o processo de aprendizagem, para evitar a sobreajustação aos dados. A principal motivação do algoritmo é dar maior robustez à rede para previsões fora da amostra, buscando capturar informações populacionais ao invés de características amostrais.

Durante o treinamento, a cada inserção de um novo vetor de dados na rede, ocorre a eliminação temporária de neurônios e respectivas ligações, com a probabilidade  $p = 0,50$ . Os neurônios que restarem após a eliminação são treinados *backpropagation*.

Outra técnica aplicada no modelo foi a *Batch Normalization*. Para aumentar a estabilidade de uma rede neural, esta técnica de normalização ajusta a saída de uma camada de ativação anterior, subtraindo a média do lote e dividindo pelo desvio padrão



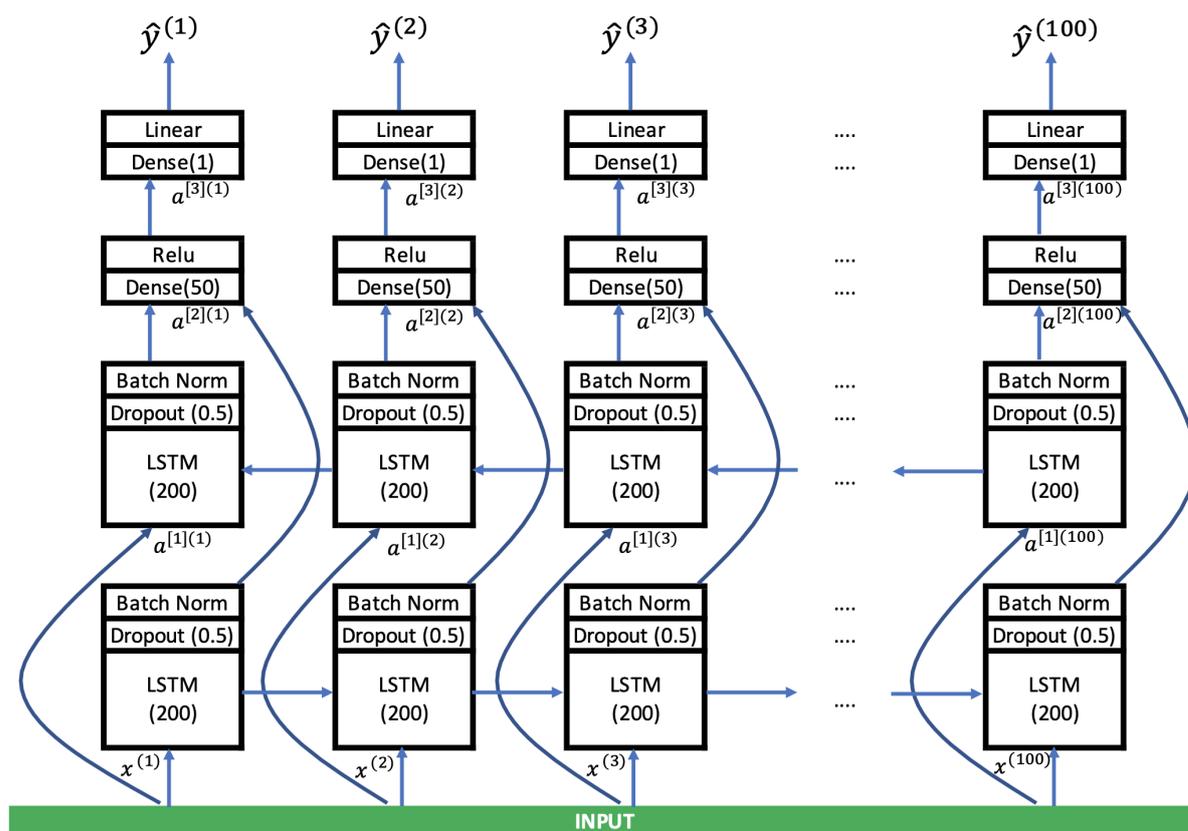


Figura 27 – Arquitetura Bidirecional LSTM desenvolvida no trabalho para regressão.

facilitar a construção de modelos de aprendizagem de máquina.

Por meio de uma sintaxe mais próxima da linguagem Python, Keras abstrai a complexidade de implementação, de modo que as rotinas para construção, treinamento e teste dos modelos são traduzidas para a estrutura do Tensorflow e executadas em segundo plano. Além disso, as bibliotecas Sklearn (PEDREGOSA *et al.*, 2011) e XGBoost (CHEN, T. *et al.*, 2015) foram utilizadas no trabalho, para avaliação de classificação de dados sem considerar dados em sequência.

Neste trabalho foram utilizadas ainda a biblioteca de visualização de dados Matplotlib (HUNTER, 2007), a biblioteca Imblearn (LEMAITRE; NOGUEIRA; ARIDAS, 2017) para balanceamento de dados, e o aplicativo de computação científica Octave (EATON; BATEMAN; HAUBERG, 2002).

Os experimentos apresentados a seguir foram executados em um computador desktop executando o sistema operacional Windows, com processador Intel Core T M i7-8700K, 64GB de memória RAM e placa de vídeo NVIDIA - GeForce R GTX 1080 Ti.

## 4.2 EXPERIMENTOS E DISCUSSÕES

Esta seção aborda os experimentos realizados a partir da base gerada, além dos resultados obtidos e discussões das abordagens utilizadas. Primeiramente, foi

realizada a análise dos dados gerados. A figura 28 apresenta a matriz de correlação obtida a partir da características e classes da base gerada.

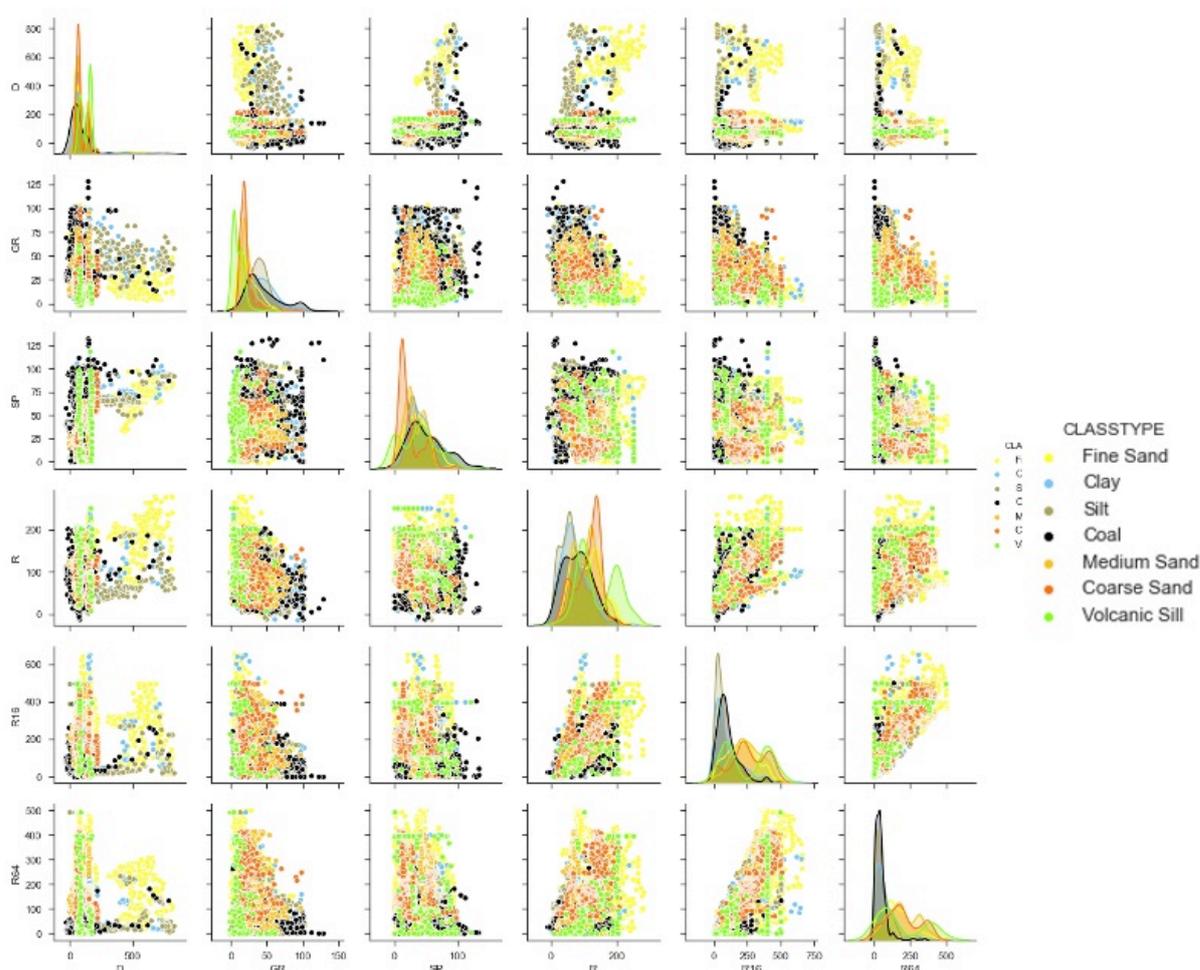


Figura 28 – Matriz de correlação entre as características das leituras em relação a classe da base de dados.

Visualmente é possível observar que a comparação entre leituras permite identificar as características mais relevantes para a criação de um modelo de aprendizagem de máquina. No entanto, para identificar as características mais relevantes, outros métodos devem ser empregados durante os experimentos.

A identificação de litofácies a partir da base de dados geradas ocorreu primeiramente através de uma abordagem de classificação, utilizando as informações diretamente extraídas dos poços. A segunda etapa utiliza os valores granulométricos com uma função polinomial linear na transição de classes. Com esta abordagem, verificou-se os seguintes aspectos: (1) a qualidade da base de dados gerada; (2) a capacidade de um método supervisionado em trabalhar com tarefas de classificação de litofácies; (3) a hipótese dos valores das sequências melhorarem as predições.

Tabela 3 – Litofácies presentes na base de dados

| Classe | Qtde. Registros |
|--------|-----------------|
| Sand m | 251             |
| Sand f | 1911            |
| Clay   | 504             |
| Silt   | 867             |

#### 4.2.1 Abordagem de Classificação de Litofácies

A primeira abordagem utilizada para a classificação das litofácies foi desenvolvida com os dados extraídos diretamente dos 20 relatórios de registros de poços. Nos casos onde existem variação de granulometria entre intervalos, foi considerada o maior valor granulométrico. A tabela 3 exibe as classes utilizadas e a quantidade de registros de cada classe.

Pode-se observar na tabela que os dados estão desbalanceados e por esse motivo, classes como areia grossa não foram utilizadas nesta avaliação inicial. Essas classes possuem poucos exemplos na base de dados. Com o objetivo de avaliar se as leituras das curvas de poços correspondem às litofácies identificadas, testes de correlação foram executados.

##### 4.2.1.1 Abordagem de Supervisionada e Avaliação da Base de Dados

Após verificar que os dados de entrada possuem alta correlação com as litofácies, optou-se por aplicar uma técnica de aprendizagem supervisionada sobre os dados, abordagem comumente utilizada nessa tipo de problema. Optou-se por utilizar o algoritmo XGBoost, que utiliza uma estrutura de árvore de decisão baseada em *Gradient boosting*. Este algoritmo foi selecionado por possuir bons resultados em dados estruturados em competições voltadas para ciência de dados.

Para a avaliação da base de dados, os dados foram divididos entre treinamento e teste. Para a criação do modelo, 70% da base foi utilizada para treinamento, e 30% para testes. Para o teste inicial, o algoritmo alcançou uma acurácia de 80%. Isso indica que é possível gerar previsões sobre a base de dados gerada e que é possível melhorar a acurácia utilizando técnicas de preparação dos dados.

Uma abordagem para lidar com conjuntos de dados desbalanceados é sobre-amostrar a classe minoritária. A abordagem mais simples envolve a duplicação de exemplos na classe minoritária, embora esses exemplos não adicionem novas informações ao modelo. Em vez disso, novos exemplos podem ser sintetizados a partir dos exemplos existentes. Esse é um tipo de aumento de dados para a classe minoritária e é chamado de Técnica de Superamostragem por Minoria Sintética (*Synthetic Minority Oversampling Technique - SMOTE*).

Além de aplicar a técnica de SMOTE, foi aplicada uma técnica para buscar a

Tabela 4 – Ordem de relevância das variáveis com o modelo XGBoost

| Variável             | Peso            |
|----------------------|-----------------|
| Resistividade 64"    | 0.1320 - 0.0064 |
| Raio gama            | 0.0988 - 0.0041 |
| Densidade            | 0.0592 - 0.0092 |
| Resistividade 16"    | 0.0585 - 0.0070 |
| Potencial espontâneo | 0.0574 - 0.0100 |
| Resistividade        | 0.0339 - 0.0038 |

melhor combinação de hiperparâmetros conhecida como *Grid Search*. Trata-se de um método que busca a combinação de melhores hiperparâmetros utilizando força bruta, utilizando a abordagem *K-fold* para avaliar os modelos com a combinação de hiperparâmetros. Ao final, a melhor combinação é escolhida.

Após estes ajustes, a acurácia do novo modelo subiu para 87,3%. Com este modelo gerado, foi aplicada a técnica de permutação de importância, para avaliar as variáveis mais relevantes para o modelo. Neste tipo de abordagem, uma coluna é reordenada aleatoriamente por vez na base de treinamento e o conjunto de dados resultantes é aplicado ao modelo. Como resultado, as colunas que mais impactaram o modelo são consideradas mais relevantes.

Todas as variáveis usadas no problema foram consideradas relevantes, a tabela 4 exibe a ordem de importância de cada variável, indicando variação no peso da acurácia das previsões.

Com os resultados aqui obtidos, pode-se concluir que a base de dados possui informações relevantes para a classificação de litofácies. A utilização do XGBoost como método de classificação permitiu avaliar a capacidade de fazer previsões utilizando a base de dados, bem como avaliar a capacidade de gerar interpretações sobre o modelo gerado. Verificações de combinações de variáveis após a geração do modelo também podem ser executadas e avaliadas durante o desenvolvimento do trabalho.

#### 4.2.1.2 Abordagem de Regressão Utilizando Dados de Granulometria

Uma versão da base de dados foi criada utilizando os padrões de litofáceis em escala de granulometria. Essa base permite realizar previsões sequências, utilizando a arquitetura de LSTM Bidirecional descrita na figura 26.

Para realizar essa tarefa, apenas 4 poços foram utilizados e o arquivo gerado possui 2030 registros. O processo de conversão de classes de litofácies para classes granulométricas é demorado e deve ser executado com cuidado, para não gerar viés sobre os dados. Nesta etapa, o modelo foi gerado sem considerar técnicas de balanceamento de dados.

Assim como na etapa de classificação, para a construção do modelo de regressão 70% da base foi utilizada para treinamento, e 30% para testes. A métrica utilizada

para avaliar a regressão foi o Erro Quadrático Médio (*Mean Squared Error* - MSE), que para o modelo foi de 0.011.

#### 4.2.1.3 Classificação Utilizando Dados Sequencias

O próximo experimento realizado no trabalho foi a capacidade das previsões de litofácies utilizando informações sequenciais. Para executar esta tarefa, foi utilizada a arquitetura LSTM Bidirecional descrita na seção 4.1.2 e figura 26.

As entradas utilizadas para o modelo foi a mesma descrita na seção 4.1.1, mas com uma sequência de 100 registros. Cada poço utilizado possui de 86 a 279 metros. As informações de curvas de poços foram extraídas a cada 15 centímetros utilizando a ferramenta NeuraLog. A base de dados gerada ao final possui 10706 registros. Antes de executar o modelo, todas as entradas foram normalizadas.

Um modelo criado a partir a arquitetura LSTM Bidirecional foi gerado utilizando os dados originais da base. O modelo gerado foi comparado com outros modelos gerados a partir de paradigmas que não utilizam dados sequências, como XGBoost, Random Forest, NaïveBayes e SVM.

O procedimento de padronização foi aplicado aos dados para que tivessem média zero e variância unitária. Os dados de entrada são divididos em conjuntos de treinamento e validação (16 poços são usados para treinamento e 4 poços para validação, representando aproximadamente 80% e 20% do conjunto de dados) para conduzir os experimentos. O *batch size* foi determinado como 10, e a função de perda foi escolhida como a entropia cruzada ponderada categórica. Normalmente, cada exemplo e classe na função de perda terá peso igual de 1,0. Este método de ponderação da perda para cada classe é usado para minimizar o problema de desequilíbrio de classe.

Cada resultado experimental foi obtido em 150 épocas para fornecer comparações consistentes. *Adam Optimization* foi usado com taxa de aprendizado exponencialmente decrescente (inicialmente definido como 0,01) e durante o treinamento, a precisão do modelo atingiu 90,45%. A precisão do modelo no conjunto de teste foi de 65,79%. Observou-se que parece haver um fenômeno de *overtraining* para esses dados. À medida que o número de épocas de treinamento aumenta, o modelo começa a "memorizar" o conjunto de treinamento, mas o desempenho para o conjunto de validação piora.

Depois de treinar o modelo, podemos prever as fácies em um perfil de poço a partir do conjunto de teste. Aplicando o modelo a um poço de teste, a arquitetura proposta fez a interpretação mostrada na Figura 29, que também contém a interpretação do especialista humano das informações básicas do poço. Esta imagem nos permite comparar o que o modelo foi capaz de prever em comparação com as classes definidas no conjunto de dados.

Observando a Figura 29, observamos visualmente que nosso modelo foi capaz

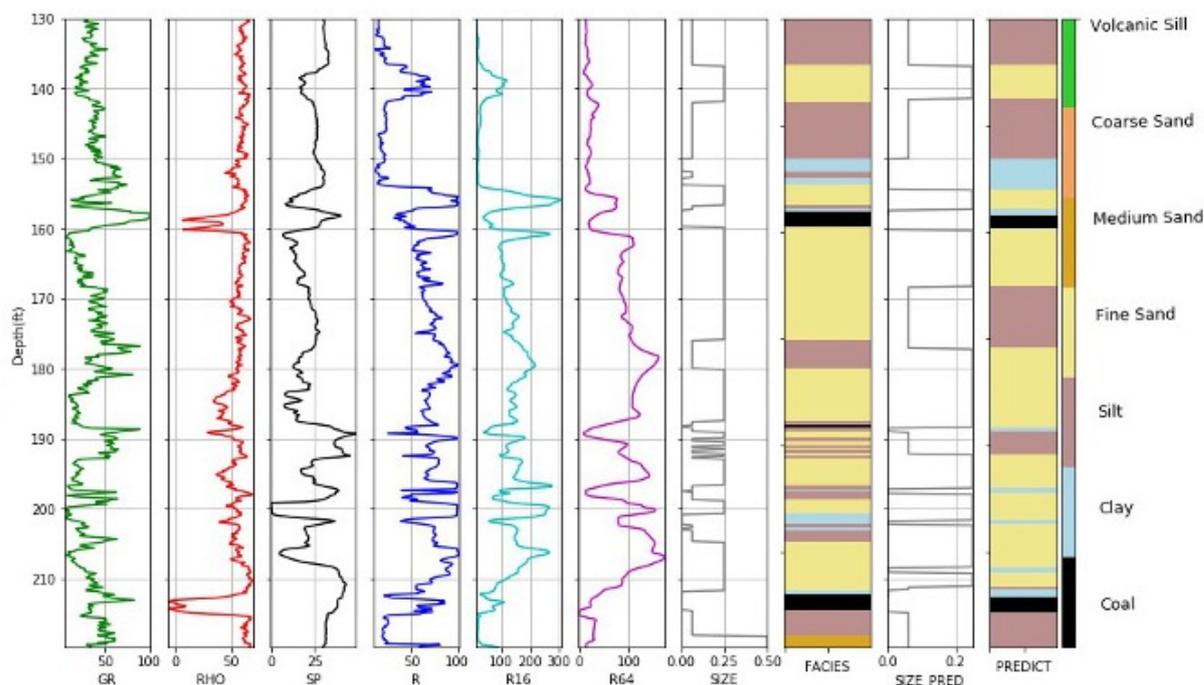


Figura 29 – Medições de registros de poço e comparativos de classificação de fácies entre a verdade do solo e os valores preditos de fácies.

de capturar a sucessão geral das fácies, mas teve dificuldades em capturar intercalações muito finas entre areias finas e silte, o final da transição entre o silte e as areias de grão fino e a camada de areia de grão médio na base da formação.

Comparamos a arquitetura BiLSTM com outros métodos de aprendizado de máquina que não utilizam o conceito de padrões sequenciais, através das bibliotecas Sklearn (PEDREGOSA *et al.*, 2011) e XGBoost (CHEN, T. *et al.*, 2015), foi utilizado o método grid search para encontrar a melhor combinação de hiperparâmetros.

A Tabela 5 apresenta uma análise comparativa entre o modelo proposto e outros métodos de aprendizado de máquina, utilizou-se o recall (que realmente calcula a sensibilidade do modelo, ou seja, a capacidade de um modelo encontrar todos os casos relevantes dentro de um conjunto de dados) e a métrica F1-Score (que é a média harmônica de precisão e recall e importante quando há uma distribuição de classe desigual). Os melhores resultados de acordo com a métrica de recall estão marcados em negrito e os da métrica F1-score estão sublinhados.

Inicialmente, pode-se observar que o modelo BiLSTM foi o que apresentou o melhor desempenho geral tanto em termos de recall quanto de F1-score. Também pode-se notar que outras granulometrias de areia são bastante difíceis de classificar corretamente, mesmo para os outros métodos. O SVM foi o melhor método para classificar as areias grossas e médias, mas ainda com desempenho muito ruim. O BiLSTM tem um desempenho muito superior a todos os outros métodos de classificação de Vulcânico, Carvão, Silte e até mesmo Argila, apesar do baixo valor de recall

Tabela 5 – Comparação dos resultados da classificação de fácies usando a abordagem proposta com XGBoost, Random Forest, Naïve Bayes e SVM

| Método        | Métrica de Avaliação | Facies      |             |             |             |             |             |             |             |
|---------------|----------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
|               |                      | VS          | CS          | MS          | FS          | ST          | CL          | CO          | Total       |
| XGBoost       | Recall               | 0.57        | 0.00        | 0.00        | <b>0.89</b> | 0.63        | 0.08        | 0.23        | 0.34        |
|               | F1-Score             | 0.69        | 0.00        | 0.00        | 0.72        | 0.63        | 0.13        | 0.36        | 0.36        |
| Random Forest | Recall               | 0.18        | 0.00        | 0.07        | 0.89        | 0.63        | 0.07        | 0.29        | 0.30        |
|               | F1-Score             | 0.56        | 0.00        | <u>0.12</u> | 0.72        | 0.64        | 0.12        | 0.39        | 0.33        |
| Naïve Bayes   | Recall               | 0.92        | 0.00        | 0.00        | 0.72        | 0.73        | 0.05        | 0.34        | 0.39        |
|               | F1-Score             | 0.72        | 0.00        | 0.00        | 0.67        | 0.64        | 0.08        | 0.43        | 0.36        |
| SVM           | Recall               | 0.24        | <b>0.22</b> | <b>0.08</b> | 0.68        | 0.38        | 0.28        | 0.37        | 0.32        |
|               | F1-Score             | 0.35        | <u>0.13</u> | 0.11        | 0.63        | 0.49        | 0.20        | 0.35        | 0.32        |
| BiLSTM        | Recall               | <b>0.95</b> | 0.00        | 0.03        | 0.80        | <b>0.74</b> | <b>0.34</b> | <b>0.7</b>  | <b>0.51</b> |
|               | F1-Score             | <u>0.72</u> | 0.00        | 0.04        | <u>0.74</u> | <u>0.77</u> | <u>0.31</u> | <u>0.69</u> | <b>0.46</b> |

para este último. O experimento apresentado nessa seção foi publicado na revista *IEEE Geoscience And Remote Sensing Letters* (SANTOS; ROISENBERG; SANTOS NASCIMENTO, 2021).

#### 4.2.2 Método de Identificação de Padrões Estatigráficos

Comforme apresentado na seção 4.2.1, a abordagem LSTM bidirecional apresentou bons resultados na identificação de litofácies, comparado com outros métodos que não utilizam dados sequências. No entanto, essa abordagem tende a ser mais promissora na classificação de padrões estatigráficos, cuja classificação se dá através da associação de fácies.

A construção da arquitetura da rede foi avaliada utilizando uma base de dados pública, disponibilizada em uma competição de ciência de dados do site Xstarter (XSTARTER, 2020). O objetivo da competição é fazer uma previsão de padrões em leituras de raio gama, que foram extraídos de dados de curvas de poços. Os padrões a serem avaliados são apresentados na figura 30.

A base de dados contém apenas registros de raio gama e de profundidade, 4000 poços para treinamento e 2000 poços para testes, sendo que cada poço possui 1100 leituras. Apenas a base de treinamento possui a classe correta para testes. A tabela 6 exhibe as classes utilizadas e a quantidade de registros de cada classe do desafio.

Pode-se observar que a base de dados disponibilizada pelo desafio já possui os dados balanceados. Outro ponto importante é que a classe "Cilíndrico" é a mais comum na base de dados e que a maioria dos poços começam e terminam com esta classe. Se compararmos com problemas *speech-to-text* onde o objetivo é detectar palavras, essa classe pode ser interpretada como som de fundo.

Uma hipótese a ser explorada neste trabalho foi a de verificar se para a identifi-

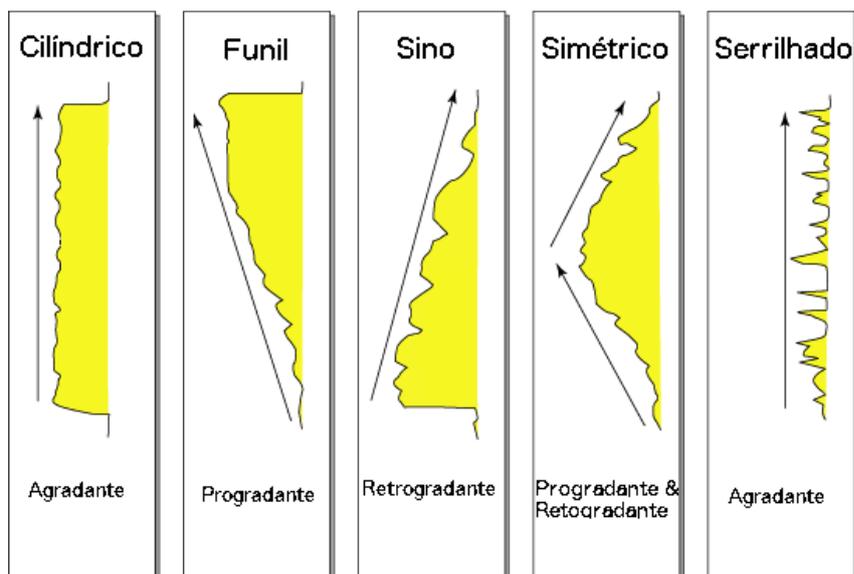


Figura 30 – Padrões a serem identificados no desafio (Adaptado de (EMERY; MYERS, 2009).

Tabela 6 – Litofácies presentes na base de dados

| Classe     | Qtde. Registros |
|------------|-----------------|
| Cilíndrico | 2326115         |
| Funil      | 521372          |
| Sino       | 519394          |
| Simétrico  | 518039          |
| Serrilhado | 515080          |

cação de padrões estatigráficos a partir de registros de poços pode ser resolvida com técnicas utilizadas para resolver problemas *speech-to-text*. Para isso, diferentes arquitetura de redes neurais foram exploradas. A arquitetura que gerou melhores resultados foi a arquitetura apresentada na seção 4.2, figura 26.

Além dos dados de raio gama, 2 novos dados foram adicionados ao modelo: um filtro de média móvel suavizada sobre o dado de raio gama; um filtro de transformação de recursos entre a escala de -1 e 1. Antes de submeter ao modelo, todas as entradas foram normalizadas.

Para a construção do modelo, dos 4000 poços disponibilizados 90% foi utilizado para treinamento e 10% para testes. Após 100 épocas, o modelo alcançou uma acurácia de 98,8%. Ao submeter o resultado do modelo para a competição, utilizando a base de dados não rotulada, a acurácia foi de 97,84%.

A Figura 31 exibe a previsão do pior caso previsto. A imagem (A) apresenta a classe correta a ser identificada, enquanto (B) exibe a classe que o modelo previu. Pode-se observar que o modelo teve mais dificuldade em identificar as classes com intervalos menores, especialmente para as classes "Funil" e "Simétrico". Isso ocorre porque a base de dados não possui um padrão de tamanho de parasequência.



## 5 CLASSIFICAÇÃO DE LITOFÁCIES A PARTIR DE IMAGENS DE AFLORAMENTO

Neste capítulo serão abordados o desenvolvimento e os resultados obtidos no trabalho de classificação de litofácies a partir de imagens de afloramento. Primeiramente serão apresentadas a base de dados criada a partir de imagens pertencentes a um afloramento do Grupo Itararé e a arquitetura de rede neural convolucional de segmentação semântica utilizada para resolver esse problema. Em seguida, serão apresentados os experimentos realizados e os resultados obtidos na identificação de litofácies.

### 5.1 DESENVOLVIMENTO

Nesta seção serão apresentadas as ideias e implementações amadurecidas durante esta pesquisa, que resultaram na utilização da arquitetura de segmentação DeepLab V3, combinada com as camadas PointRend para segmentação de imagens de afloramentos. Além disso, será apresentada a base de dados construída, que conta com imagens capturadas a partir de dispositivos VANT em afloramentos do Grupo Itararé. Discute-se ainda as estratégias adotadas na definição dos conjuntos de dados e os resultados obtidos.

#### 5.1.1 Conjunto de Dados Desenvolvido

O banco de dados utilizado neste trabalho foi construído a partir de imagens de um afloramento de um sistema turbidítico Permiano do Grupo Itararé (Bacia do Paraná; Figura 32A), que registra sedimentação permocarbonífera no Supercontinente Gondwana Ocidental. A escolha deste afloramento para este trabalho foi motivada pela importância dos estudos de sistemas turbidíticos para a geologia do petróleo. Além disso, o afloramento apresenta ampla continuidade lateral e vertical, com estruturas deposicionais muito bem preservadas (Figura 32B-C). Um drone DJI Phantom 4 Advanced do Laboratório de Análise de Bacias e Reservatórios (LABAC) foi usado para coletar 380 fotografias a uma altitude média de 30m do afloramento. Havia mais de 70% de sobreposição entre as fotografias vizinhas, e a visão da câmera do drone era ortogonal à superfície do alvo na maioria dos pontos de disparo. Depois que todas as imagens foram capturadas, elas foram usadas para construir um modelo 3D de alta resolução dentro do EasyUAV versão 2.1.

O software EasyUAV processou os conjuntos de dados de imagem de acordo com os seguintes procedimentos: (1) alinhar espacialmente todas as imagens usando informações do sistema de posicionamento global (GPS); (2) otimizar o alinhamento aplicando uma correção aos parâmetros da lente da câmera do drone; (3) nuvens de pontos de ajuste, modelo digital de elevação (DEM) e opções de saída de ortofoto; (4)

construir nuvens de pontos densas com fotogrametria SfM; (5) construir uma densa malha de nuvens; e (6) gerar um DEM e ortofoto de alta resolução.

A partir da fotogrametria oblíqua, foi produzido um mosaico 3D do afloramento (Figura 32B). As fácies sedimentares desse sistema de turbidez foram classificadas por especialistas do Laboratório de Análise de Bacias e Reservatórios (LABAC) da UFSC em três categorias (Figura 32C): (1) arenitos laminados de granulação média a fina (fácies lóbulo rico em areia); (2) arenitos maciços e de granulação média (fácies de canal rico em areia); e (3) silte maciço e folhelho laminado preto (fácies clara). Para treinar os modelos de aprendizado de máquina em diferentes arquiteturas, foi construído um dataset a partir do mosaico 3D, com resolução de 23865x11600 pixels. Foram criadas imagens de recorte com resolução de 512x512 pixels, resultando em um conjunto de dados de 334 imagens. Cada imagem resultante desse treinamento foi reclassificada de acordo com dados geológicos do afloramento previamente interpretados do mosaico 3D.

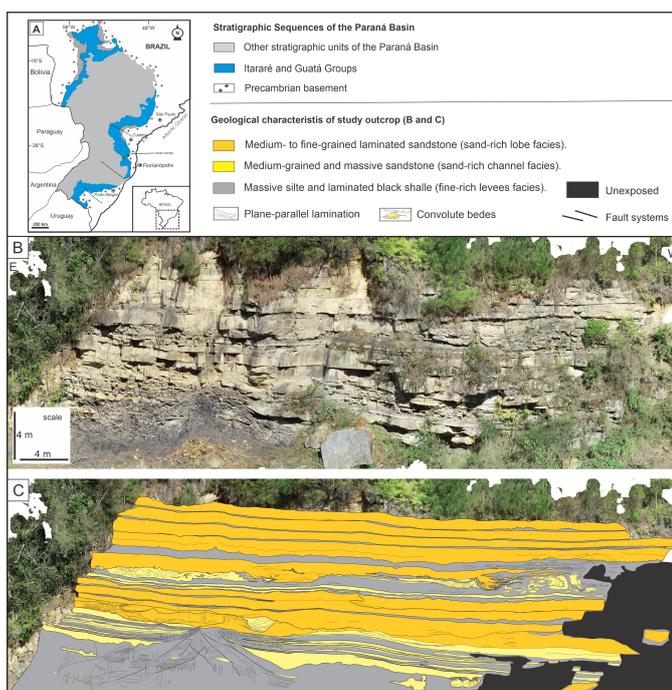


Figura 32 – (A) Estudo da localização do afloramento na Bacia do Paraná; (B) modelo digital com orientação oeste-leste usando fotogrametria; e (C) classificação de fácies com base em métodos convencionais de mapeamento, incluindo correlação a posteriori.

O conjunto de dados gerado foi classificado usando a ferramenta de rotulagem para segmentação de imagens LabelMe. LabelMe gera um arquivo json contando as coordenadas de cada segmento presente na imagem. A partir disso, dois scripts foram criados para converter os jsons para os formatos COCO Database e Cityscape, formatos esperados pelas arquiteturas de threading de instância e threading semântico de acordo. O dataset gerado com as classes correspondentes pode ser visto na Figura

33.

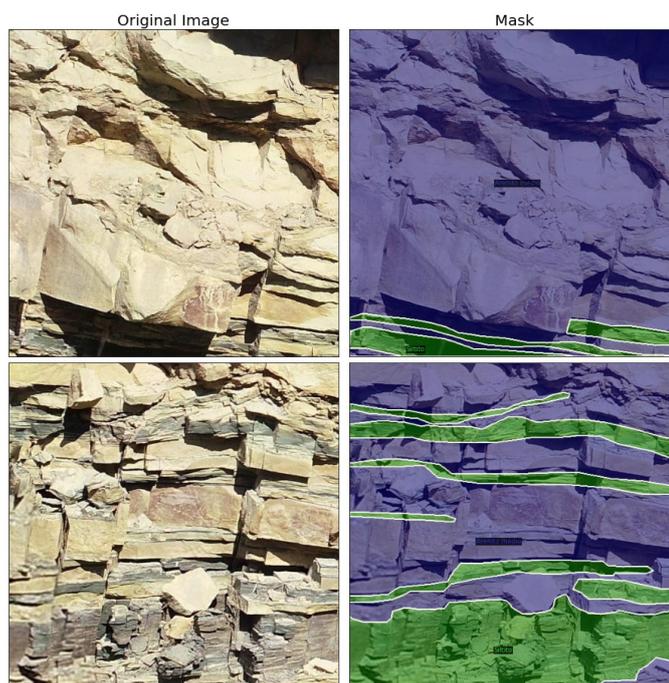


Figura 33 – Imagens pertencentes ao dataset gerado com as respectivas classes.

### 5.1.2 Arquitetura Convolutacional para Segmentação Semântica

Estruturas estratigráficas podem ser descritas em diferentes escalas, desde escala de poros/tampões até escala de pilha de sistema passando por pilha de leito litológico e identificação de elementos arquitetônicos deposicionais. O processo deposicional ocorre ao longo do tempo, possibilitando identificar visualmente as diferentes sequências verticais e suas continuidades horizontais. Neste estudo, estamos considerando a capacidade de diferentes arquiteturas de redes neurais de segmentação serem capazes de identificar esses padrões. Sabe-se que para segmentação de objetos, onde há grandes diferenças de contraste nas bordas de cada objeto, tais métodos apresentam bons resultados. Aqui avaliamos os afloramentos, onde a transição de cores e texturas é mais suave entre os elementos.

Diferentes arquiteturas para segmentação foram propostas ao longo dos anos. A U-net tem um design semelhante de um codificador e um decodificador. O primeiro é usado para extrair recursos por downsampling, enquanto o último é usado para upsampling dos recursos extraídos usando as camadas deconvolucionais. Ao contrário do U-net, que usa recursos de cada bloco convolutacional e, em seguida, os concatena com seu bloco deconvolutacional correspondente, o DeepLab usa recursos gerados pelo último bloco convolutacional antes do upsampling. Estes recursos são extraídos da rede backbone (VGG, DenseNet, ResNet) (CHEN, L.-C. *et al.*, 2017).

A arquitetura DeepLabV3 trouxe avanços importantes para realizar a tarefa de segmentação semântica. O objetivo do DeepLabV3 era capturar limites de objetos mais nítidos. Isso foi alcançado adotando a arquitetura codificador-decodificador com convolução atrosa nos últimos blocos do backbone. Este método modifica o kernel inserindo lacunas/espacos entre os elementos. Além das características extraídas do backbone, uma rede Atrous Spatial Pyramid Pooling (ASPP) é adicionada para classificar cada pixel correspondente às suas classes. A saída da rede ASPP é passada por uma convolução 1 x 1 para obter o tamanho real da imagem que será a máscara segmentada final para a imagem (CHEN, L.-C. *et al.*, 2017).

Os modelos de segmentação tendem a gerar limites excessivamente suaves que podem não ser precisos para objetos ou cenas com limites irregulares. Para obter um limite de segmentação nítido, foi proposto um módulo de rede neural de renderização baseado em pontos chamado PointRend. Um módulo PointRend consiste em três componentes principais: (i) Uma estratégia de seleção de pontos escolhe um pequeno número de pontos de valor real para fazer previsões. (ii) Para cada ponto selecionado, uma representação de recurso ponto a ponto é extraída. (iii) Uma cabeça de ponto: uma pequena rede neural treinada para prever um rótulo a partir dessa representação de recurso pontual, independentemente para cada ponto.

A arquitetura utilizada neste trabalho combinando DeepLab V3 e PointRend pode ser vista na Figura 34. A rede recebe imagens no tamanho de 512x512 com 3 canais como entrada. O backbone do codificador é uma rede ResNet, que utiliza blocos residuais e blocos de downsampling em cada camada. A informação contextual em múltiplas escalas é adquirida pelo Atrous Spatial Pyramid Pooling (ASPP). Baseado na ideia original do PointRend, o decodificador consiste em duas partes: camadas de upsampling (para 4 vezes) e PointRend que irá recuperar os recursos aprendidos para o limite detalhado da estrada. Os rótulos de saída são previstos por uma rede point-head de recursos ponto a ponto.

## 5.2 EXPERIMENTOS E DISCUSSÕES

Vários frameworks foram usados. Os frameworks gerados foram utilizados durante o desenvolvimento do projeto. No entanto decidiu-se implementar a rede neural proposta no Pytorch 1.9 e Python 3.7. Além de permitir a implementação de arquiteturas de redes neurais, o Pytorch possui uma biblioteca de arquiteturas de redes neurais de segmentação conhecidas para realizar o aprendizado de transferência. Nesse sentido, a rede neural proposta foi comparada com uma rede neural U-net padrão. A rede neural foi treinada em um computador GPU com uma GPU RTX 2060.

Além de comparar os resultados com o U-net como linha de base, foi realizado um estudo comparando o DeepLabV3 com e sem o uso da estrutura PointRend. Como backbone, ou seja, uma estrutura de rede neural para extração de características, foi

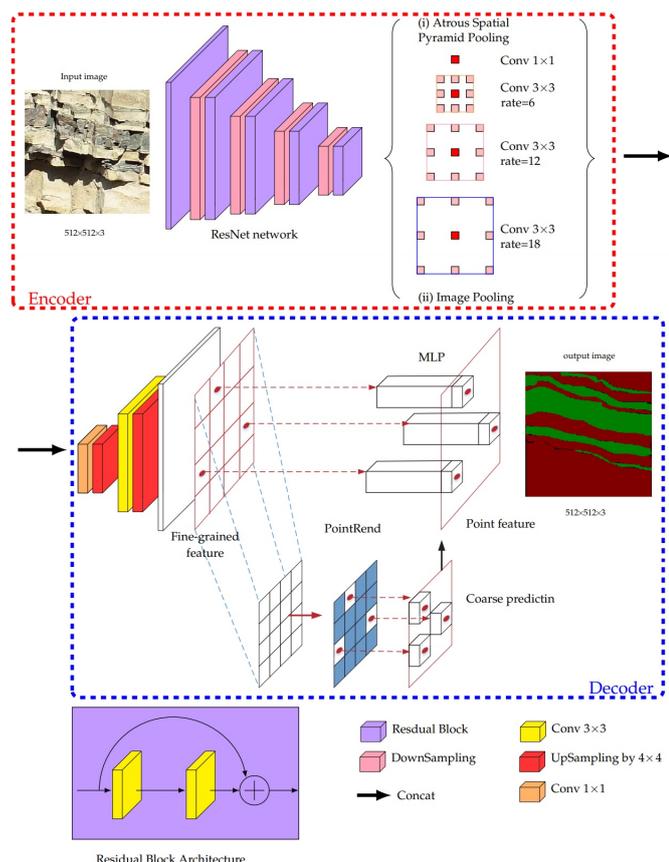


Figura 34 – Rede neural implementada em pesquisa baseada em DeepLab V3 e Point-Rend.

utilizada a estrutura ResNet50, que utiliza blocos residuais e blocos de downsampling em cada camada.

Optamos por não usar mecanismos de aumento de dados, seguindo a mesma abordagem usada nas publicações originais do DeepLabV3 e PointRend, escolha também motivada pela quantidade de dados. Como métrica de avaliação, usamos Mask Intersection-over-Union (Mask IoU) e Boundary IoU (CHENG *et al.*, 2021). Boundary IoU permite uma análise mais granular de erros relacionados à segmentação para as tarefas multifacetadas complexas. Para levantar os resultados, foram utilizadas cinco imagens para avaliar essas métricas. Como configuração de treinamento, utilizamos o otimizador Adadelta com as configurações padrão e taxa de aprendizado de 0,0001. O treinamento foi feito por 100 épocas.

A Tabela 7 apresenta os resultados obtidos para cada arquitetura analisada, utilizando mIoU em cinco imagens de conjuntos de dados. Pode-se observar que a arquitetura proposta apresentou bons resultados em relação à rede U-net, escolhida como arquitetura de linha de base. A aplicação da estrutura PointRend ajudou a melhorar a qualidade do resultado, mostrando ser uma abordagem interessante para o problema proposto. A Figura 35 apresenta a comparação visual entre os três modelos gerados para as cinco imagens.

Tabela 7 – Métricas de cinco imagens extraídas por meio de modelos diferentes.

| Method                | Mask IoU | Boundary IoU |
|-----------------------|----------|--------------|
| U-net                 | 80.0     | 69.0         |
| DeepLabV3             | 84.6     | 75.1         |
| DeepLabV3 + PointRend | 85.5     | 82.0         |

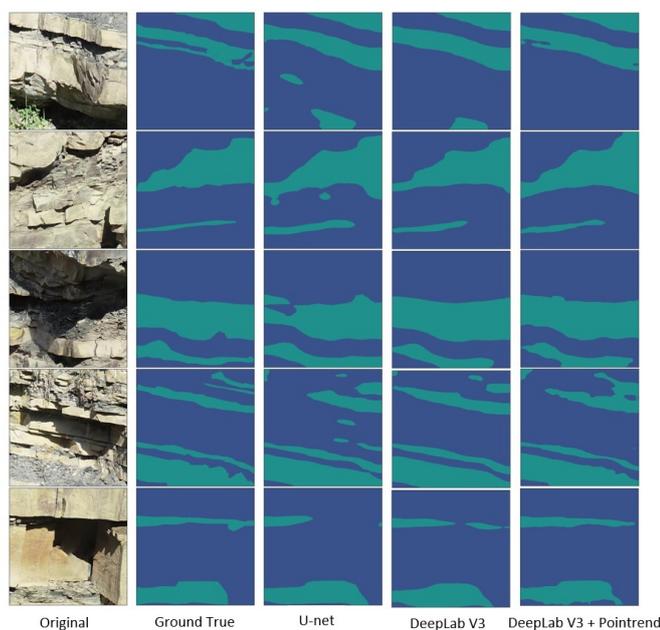


Figura 35 – Resultado da segmentação para os 3 modelos gerados.

A identificação de estratos aflorantes é um campo importante dentro da geologia sedimentar, onde os métodos tradicionais baseados em segmentação semi-supervisionada demandam muito tempo de especialistas. Em comparação com métodos existentes puramente manuais ou semiautomáticos, nossa estrutura de modelo proposta garante uma alta taxa de acurácia e melhora muito a eficiência e atende ao objetivo de segmentar afloramentos.

A combinação do método PointRend com a arquitetura DeepLabV3 melhorou a acurácia na identificação de áreas de alteração de fácies, permitindo que o método seja estendido para outros casos semelhantes. A profundidade das camadas de convolução do ResNet50 desempenha um papel muito importante na extração dos recursos de alta dimensão.

Para investigar os efeitos do algoritmo PointRend, construímos dois modelos codificador-decodificador: o decodificador do primeiro possui apenas camadas de up-sampling e o decodificador do segundo possui tanto camadas de up-sampling quanto o módulo PointRend. Podemos observar que a adoção do método supera ligeiramente o valor métrico, apresentando uma alteração litológica mais suave e nítida. O uso de métricas como Boundary IoU contribui para uma melhor análise do efeito de transição de fácies. Este experimento foi publicado na conferência IDEAL 2022 (SANTOS; ROISENBERG; SANTOS NASCIMENTO, 2022).

## 6 CONCLUSÃO

Neste trabalho, foi proposto uma arquitetura de RNN para identificar padrões faciográficos e estatigráficos a partir de dados de curvas de poços e uma arquitetura CNN para identificar padrões faciográficos a partir de imagens de afloramentos. A arquitetura RNN proposta pode ser aplicado para identificar litofácies, quando os dados de testemunho são ausentes, ou para identificar padrões estatigráficos com a presença de dados de testemunho ou não.

A metodologia adotada neste trabalho se baseou na concepção de modelos de redes LSTM bidirecionais e no treinamento de tais modelos a partir de uma base de dados própria, criada a partir de dados de poços da Formação Rio Bonito. Além disso, uma base de dados pública da Xstarter foi utilizada para validar a abordagem na classificação de padrões estatigráficos.

A abordagem para identificação de litofácies foi comparada com outros métodos de classificação supervisionada. Essa avaliação serviu ainda para verificar a qualidade da base gerada, indicando que os dados foram corretamente extraídos dos relatórios dos poços.

Os resultados mostram que a arquitetura proposta indicou um caminho viável na identificação dos padrões faciográficos. Por utilizar informações das sequências, o modelo apresentou uma acurácia mais assertiva. Outra hipótese que ainda deve ser explorada é sobre a possibilidade de técnicas de balanceamento sobre dados sequências melhorar a qualidade das previsões. Vale ressaltar ainda que o tempo de treinamento é consideravelmente maior.

Para avaliar a utilização do método para identificação de padrões estatigráficos, optou-se pela identificação dos padrões de raio gama. Aplicar o método em uma competição com uma base de dados pública permite avaliar a abordagem perante outras propostas submetidas. No entanto, por não apresentar os código publicamente, a comparação com outras abordagens não foi possível.

Outras hipóteses ainda precisam ser avaliadas na classificação de padrões estatigráficos. Como por exemplo, avaliar a possibilidade de aplicar o modelo gerado na competição sobre os dados gerados a partir da Formação Rio Bonito. Além disso, o modelo gerado para a competição pode ser aprimorada, visando a utilização para ambientes reais.

Deve-se ainda gerar modelos para previsão de padrões estatigráficos a partir da base da Formação do Rio Bonito. Acredita-se que quando todos os dados granulométricos forem levantados, será possível gerar modelos com previsões melhores. A correlação entre raio gama e descrição de testemunho deve ser feita a fim de garantir que as leituras estão corretas.

Portanto, os resultados dos experimentos indicam que é possível utilizar mode-

los de redes LSTM bidirecionais para classificação de padrões faciográficos e estatigráficos. Além do melhoramento na arquitetura, a aplicação de técnicas de preparação de dados serão exploradas, com o objetivo de melhorar a acurácia dos modelos.

A fotogrametria em combinação com um sensor remoto baseado em drone para estudar e modelar afloramentos geológicos é uma solução em termos de custo, acurácia e eficiência. Este trabalho apresentou uma arquitetura de Rede Neural Convolutiva baseada em Segmentação Semântica para a identificação de estratos em afloramentos de sistemas turbidíticos usando dados fotogramétricos baseados em VANTs. O conjunto de dados foi baseado em um afloramento de sistemas turbidíticos do Permiano do Grupo Itararé (Bacia do Paraná).

A arquitetura proposta possui a estrutura *encoder* e *decoder*. O codificador emprega a rede ResNet50 e a técnica ASPP, e o decodificador usa a camada de up-sampling e o algoritmo PointRend para recuperar o limite da estrada. Os resultados experimentais mostram que o modelo gerado supera o modelo U-net usado como linha de base. O método PointRend faz com que as fácies extraídas tenham uma borda suave e nítida com melhor conectividade. A abordagem adotada neste trabalho mostrou-se promissora, pois combinou técnicas de sensoriamento remoto com arquiteturas de redes neurais recentes. Essas informações podem ser usadas para avaliar e melhorar o processo de classificação do afloramento.

## REFERÊNCIAS

AL-ANAZI, A; GATES, ID. On the capability of support vector machines to classify lithology from well logs. **Natural Resources Research**, Springer, v. 19, n. 2, p. 125–139, 2010.

BIANCHI, Filippo Maria; MAIORINO, Enrico; KAMPFFMEYER, Michael C; RIZZI, Antonello; JENSSEN, Robert. **Recurrent neural networks for short-term load forecasting: an overview and comparative analysis**. [S.l.]: Springer, 2017.

BOUGHER, Benjamin Bryan. **Machine learning applications to geophysical data analysis**. 2016. Tese (Doutorado) – University of British Columbia.

BOYD, R; JAMES, NP; Transgressive wave-dominated coasts. **Facies models**, v. 4, p. 265–294, 2010.

CASTRO, A; MORENO-VENTAS, I; DE LA ROSA, JD. H-type (hybrid) granitoids: a proposed revision of the granite-type classification and nomenclature. **Earth-science reviews**, Elsevier, v. 31, n. 3-4, p. 237–253, 1991.

CATUNEANU, Octavian. **Principles of sequence stratigraphy**. [S.l.]: Elsevier, 2006.

CHAVES, HAF; PEREIRA, E; MEDEIROS, MAM; CÂMARA FILHO, LM. Evolução geológica da seqüência permiana da região de Candiota–RS–Brasil. **Acta Geol Leopold**, v. 39, p. 235–246, 1994.

CHEN, Liang-Chieh; PAPANDREOU, George; SCHROFF, Florian; ADAM, Hartwig. Rethinking atrous convolution for semantic image segmentation. **arXiv preprint arXiv:1706.05587**, 2017.

CHEN, Tianqi; HE, Tong; BENESTY, Michael; KHOTILOVICH, Vadim; TANG, Yuan. Xgboost: extreme gradient boosting. **R package version 0.4-2**, p. 1–4, 2015.

CHENG, Bowen; GIRSHICK, Ross; DOLLÁR, Piotr; BERG, Alexander C.; KIRILLOV, Alexander. Boundary IoU: Improving Object-Centric Image Segmentation Evaluation. *In*: CVPR. [S.l.: s.n.], 2021.

CHOLLET, François *et al.* **keras**. [S.l.: s.n.], 2015.

DARLING, Toby. **Well logging and formation evaluation**. [S.l.]: Elsevier, 2005.

DELLA FÁVERA, Jorge C; DELLA FÁVERA, Jorge C. **Fundamentos de estratigrafia**. [S.l.]: EdUERj, 2001.

DICKSON, BL; SCOTT, KM. Interpretation of aerial gamma-ray surveys-adding the geochemical factors. **AGSO Journal of Australian Geology and Geophysics**, AUSTRALIAN GOVERNMENT PUBLISHING SERVICE, v. 17, p. 187–200, 1997.

DUARTE, Osvaldo de Oliveira. Dicionário enciclopédico inglês-português de geofísica e geologia. *In*: 03) 55= 20= 690 DUA. SOCIEDADE Brasileira de Geofísica. Congresso Internacional (5o: 28 set.-2 out. 1997: Sao Paulo, BR). [S.l.: s.n.], 1997.

EATON, JW; BATEMAN, D; HAUBERG, S. **GNU Octave—a high-level language for numerical computations**. [S.l.: s.n.], 2002.

ELLIS, Darwin V; SINGER, Julian M. **Well logging for earth scientists**. [S.l.]: Springer, 2007. v. 692.

EMERY, Dominic; MYERS, Keith. **Sequence stratigraphy**. [S.l.]: John Wiley & Sons, 2009.

FÚLFARO, Vicente José; SAAD, Antonio Roberto; SANTOS, MV dos; VIANNA, Roberto Breves. Compartimentação e evolução tectônica da Bacia do Paraná. **Revista Brasileira de Geociências**, v. 12, n. 4, p. 590–611, 2018.

GOLDBERG, Yoav. Neural network methods for natural language processing. **Synthesis Lectures on Human Language Technologies**, Morgan & Claypool Publishers, v. 10, n. 1, p. 1–309, 2017.

GRACIOLLI, Vinicius Medeiros. A novel classification method applied to well log data calibrated by ontology based core descriptions, 2018.

GRAVES, Alex; FERNÁNDEZ, Santiago; GOMEZ, Faustino; SCHMIDHUBER, Jürgen. Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks. *In*: ACM. PROCEEDINGS of the 23rd international conference on Machine learning. [S.l.: s.n.], 2006. P. 369–376.

GRAVES, Alex; SCHMIDHUBER, Jürgen. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. **Neural networks**, Elsevier, v. 18, n. 5-6, p. 602–610, 2005.

GULLI, Antonio; PAL, Sujit. **Deep Learning with Keras**. [S.l.]: Packt Publishing Ltd, 2017.

HANNAFORD, P; LOWE, RM; GREVESSE, N; BIEMONT, E; WHALING, W. Oscillator strengths for Y I and Y II and the solar abundance of yttrium. **The Astrophysical Journal**, v. 261, p. 736–746, 1982.

HARWIN, Steve; LUCIEER, Arko. Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from unmanned aerial vehicle (UAV) imagery. **Remote Sensing**, Molecular Diversity Preservation International, v. 4, n. 6, p. 1573–1599, 2012.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.

HOLZ, Michael; KALKREUTH, Wolfgang; BANERJEE, Indranil. Sequence stratigraphy of paralic coal-bearing strata: an overview. **International Journal of Coal Geology**, Elsevier, v. 48, n. 3-4, p. 147–179, 2002.

HUNTER, John D. Matplotlib: A 2D graphics environment. **Computing in science & engineering**, IEEE Computer Society, v. 9, n. 3, p. 90–95, 2007.

JUNIOR, Ademir Marques *et al.* DEEP LEARNING APPLICATION FOR FRACTURE SEGMENTATION OVER OUTCROP IMAGES FROM UAV-BASED DIGITAL PHOTOGRAMMETRY. *In*: 2021-July, p. 4692–4695. Cited by: 1.

KAWAKAMI, Kazuya. Supervised sequence labelling with recurrent neural networks. **Ph. D. thesis**, Technical University of Munich, 2008.

KNELLER, Ben; BUCKEE, Clare. The structure and fluid mechanics of turbidity currents: a review of some recent studies and their geological implications. **Sedimentology**, Wiley Online Library, v. 47, p. 62–94, 2000.

LAVINA, EL; LOPES, R da C. A transgressão marinha do Permiano Inferior e a evolução paleogeográfica do Supergrupo Tubarão no Estado do Rio Grande do Sul. **Paula-Coutiana**, v. 1, p. 51–103, 1987.

LEMAITRE, Guillaume; NOGUEIRA, Fernando; ARIDAS, Christos K. Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning. **The Journal of Machine Learning Research**, JMLR. org, v. 18, n. 1, p. 559–563, 2017.

LI, Wen Bo; YU, Yun Liang; WANG, Jian Qiang; BAI, Ye; WANG, Xin. Application of Self-Organizing Neural Network Method in Logging Sedimentary Microfacies Identification. *In*: TRANS TECH PUBL. ADVANCED Materials Research. [S.l.: s.n.], 2013. v. 616, p. 38–42.

LIMA RODRIGUES, Mérolyn Camila Naves de; TRZASKOS, Barbara; ALSOP, G Ian; VESELY, Fernando Farias. Making a homogenite: An outcrop perspective into the evolution of deformation within mass-transport deposits. **Marine and Petroleum Geology**, Elsevier, v. 112, p. 104033, 2020.

LONG, Jonathan; SHELHAMER, Evan; DARRELL, Trevor. Fully convolutional networks for semantic segmentation. *In*: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2015. P. 3431–3440.

LÓPEZ, Gloria I. Grain Size Analysis. *In*: **Encyclopedia of Geoarchaeology**. Edição: Allan S. Gilbert. Dordrecht: Springer Netherlands, 2017. P. 341–348. ISBN 978-1-4020-4409-0.

MARQUES, Ademir; RACOLTE, Graciela; ZANOTTA, Daniel C.; MENEZES, Eniuce; CAZARIN, Caroline Lessio; GONZAGA, Luiz; VERONEZ, Mauricio Roberto. Adaptive Segmentation for Discontinuity Detection on Karstified Carbonate Outcrop Images From UAV-SfM Acquisition and Detection Bias Analysis. **IEEE Access**, v. 10, p. 20514–20526, 2022. Cited by: 0; All Open Access, Gold Open Access.

MARTINEZ, David; BALDWIN, Timothy. Word sense disambiguation for event trigger word detection in biomedicine. *In*: BIOMED CENTRAL, 2. BMC bioinformatics. [S.l.: s.n.], 2011. v. 12, s4.

MILANI, Edison Jose. **Evolução tectono-estratigráfica da Bacia do Paraná e seu relacionamento com a geodinâmica fanerozóica do Gondwana sul-ocidental.**

1997. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul.

MILANI, Edison José; FRANÇA, Almério Barros; MEDEIROS, RA. Roteiros Geológicos. **Boletim de Geociências da PETROBRAS**, v. 15, n. 1, p. 135–162, 2007.

MINERAIS, COMPANHIA DE PESQUISA DE RECURSOS. Projeto Rio Bonito: relatório das atividades. CPRM, 1974.

MUTTI, Emiliano; CUNHA, Rogério S; BULHOES, EM; ARIENTI, Luci M; VIANA, Adriano R. Contourites and turbidites of the Brazilian marginal basins. **AAPG Search and Discovery Article**, v. 51069, p. 1–46, 2014.

NG, Andrew *et al.* Neural networks and deep learning. **Coursera**. <https://www.coursera.org/learn/neuralnetworks-deep-learning>, v. 325, 2017.

NGCOFE, L; MINNAAR, H. A study on automated segmentation for object-based image analysis for geological mapping in the northern Cape Province, South Africa. **Proceedings of the 4th GEOBIA**, p. 7–9, 2012.

NICHOLS, Gary. **Sedimentology and stratigraphy**. [S./]: John Wiley & Sons, 2009.

NIELSEN, Michael A. **Neural networks and deep learning**. [S./]: Determination press San Francisco, CA, USA, 2015. v. 25.

NORTHFLEET, AA; MEDEIROS, RA; MUHLMANN, H. Reavaliação dos dados geológicos da Bacia do Paraná. **Boletim Técnico da Petrobrás**, v. 12, n. 3, p. 291–346, 1969.

OLAH, Christopher. Neural networks, types, and functional programming, 2015. **URL** <https://colah.github.io/posts/2015-09-NN-Types-FP>, 2015.

PARASNIS, DS. Principles of Applied Geophysics: Chapman and Hall. **London, England**, p. 400, 1997.

PEDREGOSA, Fabian *et al.* Scikit-learn: Machine learning in Python. **Journal of machine learning research**, v. 12, Oct, p. 2825–2830, 2011.

RAWAT, Waseem; WANG, Zenghui. Deep convolutional neural networks for image classification: A comprehensive review. **Neural computation**, MIT Press, v. 29, n. 9, p. 2352–2449, 2017.

READING, Harold G. **Sedimentary environments: processes, facies and stratigraphy**. [S.l.]: John Wiley & Sons, 2009.

REINSON, Gerald E. Transgressive barrier island and estuarine systems. **Facies models response to sea level change**, Geol. Assoc. Can., p. 179–194, 1992.

RIDER, MH. Gamma-ray log shape used as a facies indicator: critical analysis of an oversimplified methodology. **Geological Society, London, Special Publications**, Geological Society of London, v. 48, n. 1, p. 27–37, 1990.

RUFFELL, Alastair; WORDEN, Richard. Palaeoclimate analysis using spectral gamma-ray data from the Aptian (Cretaceous) of southern England and southern France. **Palaeogeography, Palaeoclimatology, Palaeoecology**, Elsevier, v. 155, n. 3-4, p. 265–283, 2000.

RUSSELL, Stuart J; NORVIG, Peter. **Artificial intelligence: a modern approach**. [S.l.]: Malaysia; Pearson Education Limited, 2016.

SALATI, Sanaz; RUITENBEEK, Frank JA van; MEER, Freek D van der; TANGESTANI, Majid Hashemi; WERFF, Harald van der. Lithological mapping and fuzzy set theory: Automated extraction of lithological boundary from ASTER imagery by template matching and spatial accuracy assessment. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 13, n. 5, p. 753–765, 2011.

SALEHINEJAD, Hojjat; SANKAR, Sharan; BARFETT, Joseph; COLAK, Errol; VALAEE, Shahrokh. Recent advances in recurrent neural networks. **arXiv preprint arXiv:1801.01078**, 2017.

SANTOS, Daniel Theisges dos; ROISENBERG, Mauro; SANTOS NASCIMENTO, Marivaldo dos. Deep Recurrent Neural Networks Approach to Sedimentary Facies Classification Using Well Logs. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 19, p. 1–5, 2021.

SANTOS, Daniel Theisges dos; ROISENBERG, Mauro;  
SANTOS NASCIMENTO, Marivaldo dos. Identification of Sedimentary Strata by Segmentation Neural Networks of Oblique Photogrammetry of UAVs. *In: SPRINGER. INTERNATIONAL Conference on Intelligent Data Engineering and Automated Learning. [S.l.: s.n.], 2022. P. 31–41.*

SATO, Kodai; MADOKORO, Hirokazu; NAGAYOSHI, Takeshi; CHIYONOBU, Shun; MARTIZZI, Paolo; NIX, Stephanie; WOO, Hanwool; SAITO, Takashi K.; SATO, Kazuhito. Semantic Segmentation of Outcrop Images using Deep Learning Networks Toward Realization of Carbon Capture and Storage. *In: 2021-October*, p. 436–441. Cited by: 0.

SCHERER, CMS. Ambientes fluviais. **Ambientes de sedimentação siliciclática do Brasil. Beca/BALL edições Ltda, São Paulo**, p. 102–130, 2008.

SCHUMM, SA. Fluvial paleochannels. Special Publications of SEPM, 1972.

SCHUSTER, Mike; PALIWAL, Kuldip K. Bidirectional recurrent neural networks. **IEEE Transactions on Signal Processing**, IEEE, v. 45, n. 11, p. 2673–2681, 1997.

SERRA, O; SULPICE, L *et al.* Sedimentological analysis of shale-sand series from well logs. *In: SOCIETY OF PETROPHYSICISTS e WELL-LOG ANALYSTS. SPWLA 16th Annual Logging Symposium. [S.l.: s.n.], 1975.*

SHANLEY, KW; MCCABE, PJ; HETTINGER, RD. Significance of tidal influence in fluvial deposits for interpreting sequence stratigraphy. **Sedimentology**, v. 39, p. 905–930, 1992.

SHANMUGAMANI, Rajalingappaa. **Deep Learning for Computer Vision: Expert techniques to train advanced neural networks using TensorFlow and Keras. [S.l.]: Packt Publishing Ltd, 2018.**

SHERIFF, Robert E. **Encyclopedic dictionary of applied geophysics. [S.l.]: Society of exploration geophysicists, 2002.**

SILVERSIDES, Katherine; MELKUMYAN, Arman; WYMAN, Derek; HATHERLY, Peter. Automated recognition of stratigraphic marker shales from geophysical logs in iron ore deposits. **Computers & Geosciences**, Elsevier, v. 77, p. 118–125, 2015.

SMITH, Derald G; PUTNAM, Peter E. Anastomosed river deposits: modern and ancient examples in Alberta, Canada. **Canadian Journal of Earth Sciences**, NRC Research Press, v. 17, n. 10, p. 1396–1406, 1980.

SONG, Suihong; HOU, Jiagen; DOU, Luxing; SONG, Zezhang; SUN, Shuang. Geologist-level wireline log shape identification with recurrent neural networks. **Computers & Geosciences**, Elsevier, v. 134, p. 104313, 2020.

SOWEK, Guilherme Arruda; FERREIRA, Francisco José Fonseca; VESELY, Fernando Farias; BERTON, Fabio. Assinatura gamaespectrométrica de depósitos fluviais: estudo de caso na Formação Rio do Rasto, Permiano Superior da Bacia do Paraná. **Geologia USP. Série Científica**, v. 13, n. 3, p. 83–98, 2013.

STOW, Dorrik AV; MAYALL, Mike. Deep-water sedimentary systems: New models for the 21st century. **Marine and Petroleum Geology**, Elsevier, v. 17, n. 2, p. 125–135, 2000.

TSCHANNEN, Valentin; DELESCLUSE, Matthias; RODRIGUEZ, Mathieu; KEUPER, Janis. Facies classification from well logs using an inception convolutional network. **arXiv preprint arXiv:1706.00613**, 2017.

TURNER, Darren; LUCIEER, Arko; WATSON, Christopher. An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on structure from motion (SfM) point clouds. **Remote sensing**, Molecular Diversity Preservation International, v. 4, n. 5, p. 1392–1410, 2012.

VAN WAGONER, John C; MITCHUM, RM; CAMPION, KM; RAHMANIAN, VD. Siliciclastic sequence stratigraphy in well logs, cores, and outcrops: concepts for high-resolution correlation of time and facies. AAPG Special Volumes, 1990.

VASUKI, Yathunathan; HOLDEN, Eun-Jung; KOVESI, Peter; MICKLETHWAITE, Steven. Semi-automatic mapping of geological Structures using UAV-based photogrammetric data: An image analysis approach. **Computers & Geosciences**, Elsevier, v. 69, p. 22–32, 2014.

WANG, Dahai; PENG, Jun; YU, Qian; CHEN, Yuanyuan; YU, Hanghang. Support vector machine algorithm for automatically identifying depositional microfacies using well logs. **Sustainability**, Multidisciplinary Digital Publishing Institute, v. 11, n. 7, p. 1919, 2019.

WHITE, Israel Charles. Relatório final da Comissão de Estudos das Minas de Carvão de Pedra do Brasil. **Rio de Janeiro**, v. 14, 1908.

WORDEN, RH; MORAD, S. Clay minerals in sandstones: controls on formation, distribution and evolution. **SPECIAL PUBLICATION-INTERNATIONAL ASSOCIATION OF SEDIMENTOLOGISTS**, Wiley Online Library, v. 34, p. 3–42, 2003.

WU, Siqi; WANG, Qing; ZENG, Qihong; ZHANG, Youyan; SHAO, Yanlin; DENG, Fan; LIU, Yuangang; WEI, Wei. Automatic extraction of outcrop cavity based on a multiscale regional convolution neural network. **Computers and Geosciences**, v. 160, 2022.

Cited by: 0.

XSTARTER. **XStarter: Find Ancient River Channels**. [S.l.: s.n.], 2020. Disponível em: <https://www.xstarter.xyz/challenge-details/gamma-log-facies-identification>.

ZALÁN, PV; WOLFF, S; CONCEIÇÃO, JC de J; ASTOLFI, MAM; VIEIRA, IS; APPI, VT; ZANOTTO, OA. Tectônica e sedimentação da Bacia do Paraná. **Simpósio Sul-Brasileiro de Geologia**, v. 3, n. 1987, p. 441–473, 1987.

ZHANG, Dongxiao; YUNTIAN, Chen; JIN, Meng. Synthetic well logs generation via Recurrent Neural Networks. **PETROLEUM EXPLORATION AND DEVELOPMENT-ELSEVIER-**, Elsevier, v. 45, n. 4, p. 629–639, 2018.

ZHANG, Jinliang; LIU, Shasha; LI, Jingzhe; LIU, Longlong; LIU, Huimin; SUN, Zhongqiang. Identification of sedimentary facies with well logs: An indirect approach with multinomial logistic regression and artificial neural network. **Arabian Journal of Geosciences**, Springer, v. 10, n. 11, p. 247, 2017.