

SEG SOCIETY OF EXPLORATION
GEOPHYSICISTS

Student Chapter

State University of Rio de Janeiro
Geophysical Society

UERJ Geophysical Society

MAGAZINE

Revista Trimestral

3ª edição | Abr • Mai • Jun de 2019

Nesta edição:

- ▶ **Capa:**
Inteligência Artificial: uma nova fronteira para geólogos e geofísicos por Victor Carreira, do Observatório Nacional
- ▶ Inteligência Artificial vs. *Machine Learning* vs. *Deep Learning*
- ▶ Qual é a diferença entre aprendizado supervisionado, não supervisionado, semi-supervisionado e por reforço?
- ▶ Vantagens em ser membro da SEG: *SEG/ExxonMobil Student Education Program* e *SEG/Chevron Student Leadership Symposium*
- ▶ Artigo técnico sobre a Anomalia Gravimétrica Residual da Bacia de Barreirinhas utilizando Modelagem Crustal
- ▶ Terceira parte da Coletânea *Algoritmos e Lógica da Programação*.

Confira nesta edição:**3**

Editorial

4

Inteligência Artificial: uma nova fronteira para geólogos e geofísicos por Victor Carreira (Observatório Nacional)

6

Inteligência Artificial vs. *Machine Learning* vs. *Deep Learning*

8

Qual é a diferença entre aprendizado supervisionado, não supervisionado, semi-supervisionado e por reforço?

14

Vantagens em ser membro da SEG:
SEG/ExxonMobil Student Education Program e
SEG/Chevron Student Leadership Symposium

15

Artigo técnico:
Anomalia Gravimétrica Residual da Bacia de Barreirinhas utilizando Modelagem Crustal

20

Artigo técnico:
Instruções Primitivas: Atribuição, Entrada e Saída de Dados

Sobre nós

O Student Chapter da UERJ, foi fundado em 2015 por alunos do curso de graduação em Geologia para fomentar uma área de pouco interesse pelos geólogos: Geofísica. Nosso papel é intermediar as relações entre entidades, empresas e os alunos para que juntos possamos crescer e nos qualificarmos, tanto profissionalmente quanto academicamente.

Organização do Student Chapter

Presidente - Lucas Guimarães P. Monteiro
Vice-presidente - Isabela Dantas de Albuquerque
Secretário - Vanderson Ribeiro de Assis Lima
Tesoureira - Isabelle Vasconcelos Alcantara
Advisor - Paulo T. L. Menezes

Visite nosso site:

segchapteruerj.wixsite.com/geophysicalsociety

Conecte-se conosco por nossas redes sociais:

facebook.com/UERJGeophysicalSociety/



linkedin.com/in/uerjgeophysicalsociety/



instagram.com/seg_uerj_geophysical_society/



youtube.com/channel/UC-Gr50hTX4pZ6yvkzunIerA

Organização da Revista

Editor-chefe
Lucas G.P. Monteiro

Design e revisão
Isabela Dantas de Albuquerque

Fotografias
Capa e contra capa: bit.ly/30IX18S

UERJ Geophysical Society

R. São Francisco Xavier, 524 - Bloco A, 4º Andar, Sala 2031; CEP: 20550-900; Maracanã, Rio de Janeiro - RJ

Editorial

O tema dessa edição, *Machine Learning* (ou aprendizado de máquina), foi escolhido por, apesar de já ser usado nas geociências há vários anos, ainda gerar entusiasmo e novas descobertas diárias sobre as possibilidades de aplicação deste em diversas áreas.

O destaque do ML vem principalmente da sua capacidade de resolver problemas complexos usando apenas dados, além da abundância de bibliotecas de código aberto e tutoriais on-line gratuitos disponíveis para ajudar um cientista de dados iniciante a aprender sobre esta tecnologia.

Nós, geocientistas, estamos em uma boa posição para nos tornarmos adeptos às ferramentas mais recentes em ciência de dados. Em geral, temos experiência suficiente em álgebra linear e estatística para entender os conceitos matemáticos subjacentes, e apenas habilidades de programação rudimentares são necessárias para começar a fazer previsões com um modelo existente ou para construir um personalizado. Por isso, torna-se importante para nós estarmos cientes das possibilidades de aplicação destas ferramentas, pois estas são o presente e o futuro da ciência de dados.

Nesta edição, reunimos textos sobre *Machine Learning* e suas aplicações nas geociências. Começando com o texto *Inteligência Artificial: uma nova fronteira para geólogos e geofísicos*, Victor Carreira, doutorando do Observatório Nacional, introduz sobre os primórdios da Inteligência Artificial e suas aplicações.

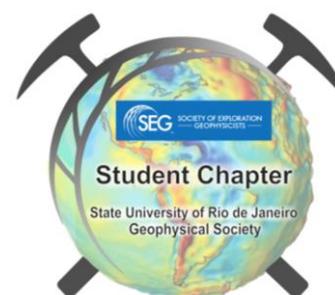
Os textos seguintes explicam as diferenças entre Inteligência Artificial, *Machine Learning* e

Deep Learning, termos que muitas vezes são utilizados como sinônimos, porém apresentam suas diferenças, e dissertam sobre os tipos de aprendizado de máquina (supervisionado, não supervisionado, semi-supervisionado e por reforço).

Aproveitamos para anunciar a segunda edição do workshop de Geofísica Aplicada, que este ano terá *Machine Learning* como tema central, no qual serão ministradas palestras com profissionais da indústria e da academia em que estes apresentarão trabalhos sobre a aplicação de ML em suas pesquisas. No último dia, ocorrerá uma mesa redonda com o tema *O futuro da Geofísica e a importância do Machine Learning*. O workshop ocorrerá entre os dias 25 e 27 de Setembro na Universidade do Estado do Rio de Janeiro (UERJ).

Mostramos também algumas vantagens em ser associado à SEG, como a possibilidade de participar do *SEG/ExxonMobil Student Education Program* e do *SEG/Chevron Student Leadership Symposium*, que este ano ocorrerão em Houston, Texas, e nosso presidente, Lucas Monteiro irá atender.

Por fim, temos os artigos *Anomalia Gravimétrica Residual da Bacia de Barreirinhas utilizando Modelagem Crustal* e a terceira parte da Coletânea *Algoritmos e Lógica da Programação*. Não deixem de conferir! ■



Inteligência Artificial: uma nova fronteira para geólogos e geofísicos

Por Victor Carreira (Observatório Nacional)

É inegável que os últimos anos experimentaram um tremendo avanço no que tange a aplicação dos métodos de inteligência artificial e do aprendizado de máquina nas mais diversas atividades. Esses avanços podem ser percebidos principalmente nas áreas de *e-commerce*, *internet*, redes sociais e bancos.

A mera aplicação advém de um estudo muito mais profundo, dirigido principalmente pela matemática, aonde os primeiros algoritmos de redes neurais foram concebidos. Tais algoritmos tinham como objetivo modelar determinadas funções do cérebro humano. Dentre essas funções, destaca-se a complexidade do aprendizado. Durante esse contexto é escrito o trabalho pioneiro de *MCCulloch* e *Pitts*, que modelaram o primeiro neurônio artificial, em 1943, denominado *Perceptron*. Este trabalho dedicou-se principalmente a modelar o processo de sinapse nervosa.

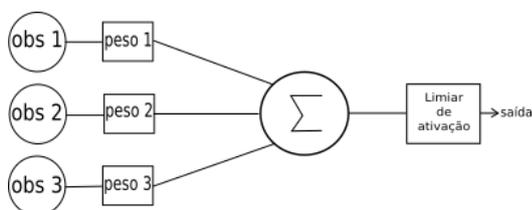


Figura 1: Modelo esquemático de um Perceptron. Neste modelo as entradas são observações que serão associadas aos pesos respectivos. O resultado da somatória induzirá uma reação binária que será modelada pela função de ativação.

Uma das capacidades mais antigas do ser humano é a sua capacidade de aprender por meio da observação. Diversas ocorrências cíclicas foram observadas e aprendidas por nossos antepassados, por questões de sobrevivência, planejamento ou mero acúmulo de riquezas. Estes tiveram que reconhecer a rota de cervídeos para a caça e posteriormente planejar qual a melhor época do ano para plantar e colher. Em seguida, quando os primeiros núcleos urbanos estavam estabelecidos, tornou-se imperativo o reconhecimento de algumas jazidas minerais tais como o betume para vedar barcos e telhados de casas, cobre e ferro para confecção de ferramentas e ouro e prata.

O processo de aprendizado humano baseado na observação requer necessariamente duas etapas. A primeira é o registro do fenômeno que é feito por meio de diversas observações ao longo de tempo. A esta etapa é dado o nome de **treinamento**. A segunda etapa é estabelecida uma vez que o fenômeno é bem compreendido e pode ser reconhecido. A esta etapa damos o nome de **identificação**.

Tomemos agora como base o exemplo descrito acima, o de uma sociedade primitiva. Nesta, houve um ser humano pioneiro que foi capaz de observar determinado fenômeno e identificar certo padrão de interesse para a sua tribo. Ele fez isso sozinho, pois durante a sua etapa de treinamento ele se baseou apenas nas suas próprias observações. Este tipo de treinamento é conhecido como **não-**

supervisionado. Digamos agora que esse humano pioneiro passe a ensinar seu conhecimento para os demais integrantes de sua tribo. Neste caso o processo de aprendizado dos demais integrantes seria realizado agora por meio da observação e por meio de um professor. A este segundo tipo de aprendizado dá-se o nome de **treinamento supervisionado.**

No mundo da geologia e da geofísica, as observações realizadas por esta tribo primitiva são chamadas de conjunto de dados ou *data sets* e podem ser das mais variadas origens. Para um geólogo de campo, seu *data set* seriam as atitudes das camadas geológicas, aerofotografias e imagens de satélite. Já para para um geoquímico ambiental, a concentração de metais pesados em águas e solos. Para um sedimentólogo, seriam os perfis de campo mostrando fácies, gradações e agradações sedimentares nos mais diversos ambientes pretéritos. E, por fim, para os geofísicos, seriam os mais diversos dados tais como tempo de trânsito (sísmica e sismologia), suscetibilidade magnética e aceleração da gravidade (métodos potenciais), resistividade e condutividade elétrica (métodos elétricos e eletromagnéticos). Também são usadas imagens tais como ressonância magnética nuclear na área de perfilagem de poços.

Em 1989, iniciaram-se as primeiras publicações sobre a aplicação de algoritmos de inteligência artificial na área de geofísica e de geologia e duas grandes fases são notáveis desde então. A primeira delas, que vai de 1989 até 1994, cujo o foco principal era descobrir o que uma rede neuronal poderia fazer com diferentes *data sets* e como preparar o dado

para que as redes analisassem o resultado. A segunda vai de 1995 até o presente e se dedica a aplicações mais específicas dentro das mais diversas áreas. Por exemplo, a caracterização de reservatórios. Além disso, a utilização de redes tem sido aplicada com sucesso na interpretação conjunta e compreensiva de um grande volume de dados ao invés de se usar estas como um aplicação isolada.

Um caso de grande sucesso na aplicação da inteligência artificial na indústria de petróleo vem da sísmica. Até 1993, durante a etapa de processamento e aquisição sísmica, cerca de 73% do tempo do operador era gasto com três tarefas fundamentais: edição de traços ruidosos, corte do primeiro pico de refração e análise de velocidade. A consequência do sucesso da implementação, neste caso, foi a redução drástica e economia de tempo do operador. Outros casos de sucesso são documentados na área de perfilagem de poços, onde os profissionais reportam com frequência a detecção de horizontes mineralizados de rocha. Na área de inversão de dados, a inteligência artificial tem sido utilizada na escolha e ajuste dos parâmetros de entrada com o objetivo de reduzir ambiguidades.

A inteligência artificial desponta já a algum tempo como nova fronteira exploratória para geofísicos e geólogos que se interessem por tecnologia e novas técnicas de exploração. Essas técnicas são as melhores formas de encarar os novos desafios que se apresentam, tais como conseguir retirar informação relevante, e com confiabilidade, de uma gigantesca quantidade de dados. ■

Inteligência Artificial vs. *Machine Learning* vs. *Deep Learning*

A Inteligência Artificial (IA) tem feito parte de nossas imaginações e fervido em laboratórios de pesquisa desde 1956, quando um punhado de cientistas da computação se reuniu em torno do termo nas [Conferências de Dartmouth](#) e deu origem ao campo da IA.

Nos últimos anos, a IA explodiu, especialmente desde 2015. Muito disso tem a ver com a ampla disponibilidade de GPUs (*Graphics Processing Units*, ou Unidades de Processamento Gráfico), que tornam o processamento cada vez mais rápido, mais barato e mais poderoso. Também tem a ver com o impacto simultâneo de um armazenamento praticamente infinito e uma enxurrada de dados de diversos tipos (todo esse movimento de [Big Data](#)) - imagens, texto, transações, dados de mapeamento, ou o que você imaginar.

O que Inteligência Artificial e *Machine Learning* tem a ver?

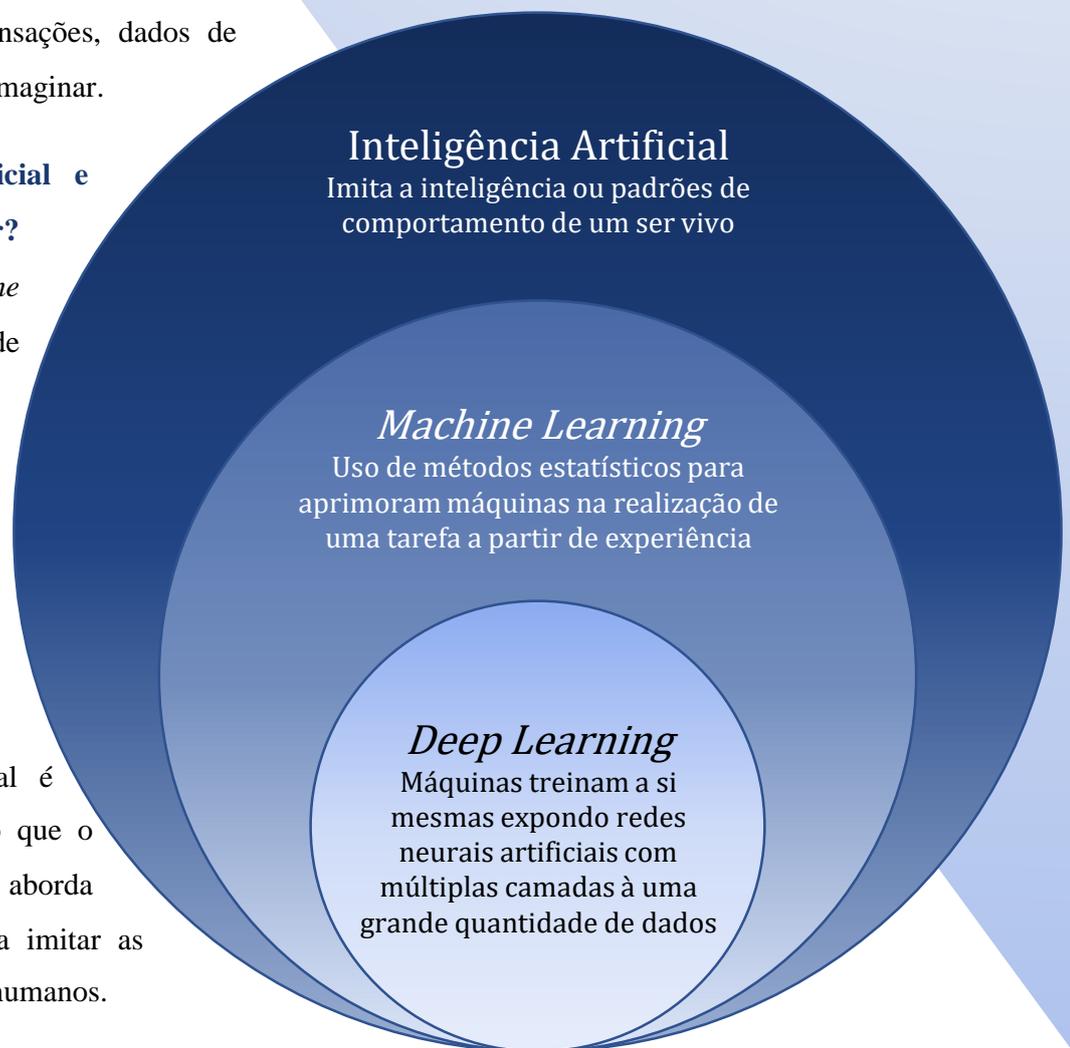
A IA e o *Machine Learning* (aprendizado de máquina) são frequentemente usados de forma intercambiável, mas não são a mesma coisa, e é importante entender como elas podem ser aplicadas de maneiras diferentes.

A inteligência artificial é um conceito mais amplo do que o aprendizado de máquina, que aborda o uso de computadores para imitar as funções cognitivas dos seres humanos.

Quando máquinas executam tarefas baseadas em algoritmos de maneira “inteligente”, isso é AI.

O *Machine Learning* é um subconjunto da inteligência artificial e concentra-se na capacidade das máquinas de receber um conjunto de dados e aprender por si próprios, alterando os algoritmos conforme eles aprendem mais sobre as informações que estão processando.

O treinamento de computadores para pensar como seres humanos é conseguido em parte pelo uso de **redes neurais artificiais (RNA)**. RNA são uma série de algoritmos modelados a partir do cérebro humano. Assim como o cérebro pode reconhecer padrões e nos ajudar a categorizar e classificar informações, as



redes neurais fazem o mesmo com os computadores. O cérebro está constantemente tentando entender a informação que está processando e, para isso, rotula e atribui itens a categorias. Quando nos deparamos com algo novo, tentamos compará-lo a um item conhecido para nos ajudar a entender e dar sentido a ele. Redes neurais artificiais fazem o mesmo para computadores.

E o Deep Learning?

Deep Learning (aprendizado profundo) é uma forma especializada de *Machine Learning* que utiliza diversas camadas de redes neurais para aprender a partir de uma grande quantidade de dados inicialmente fornecidos.

Deep Learning se destaca na identificação de padrões em dados não estruturados - o que conhecemos como mídia, como imagens, som, vídeo e texto - podendo ser usado para reconhecer objetos e traduzir voz em tempo real. Esta tecnologia é usada para melhorar o reconhecimento de voz de assistentes pessoais como Cortana, Siri e Google Now; em sistemas de recomendação de aplicativos como Netflix, Amazon e Spotify; para detecção de fraudes e de spams; em veículos autônomos e até na detecção de anomalias geradas por doenças!

Qual a importância dessas novas tecnologias?

Os últimos anos mostraram que a Inteligência Artificial pode ser usada para automatizar várias tarefas diferentes, antes consideradas de realização exclusivamente humana, como as citadas.

O *Machine Learning* preparou o terreno para o *Deep Learning*, e as redes neurais artificiais ajudarão a construir uma inteligência

artificial mais humana no futuro. Com mais tempo e recursos, as aplicações do aprendizado de máquina são quase infinitas!

Na Geofísica, *Machine Learning* já é aplicado há anos, porém volta e meia este assunto é destacado e debatido na indústria e em centros de pesquisa.

Seguindo essa tendência, a *Society of Exploration Geophysicists* (SEG) lançou duas edições da revista *The Leading Edge*, em [Março de 2017](#) e novamente em [Julho de 2019](#), com artigos sobre *Machine Learning* aplicado à Geofísica. Os editores comentaram um pouco sobre as edições no *podcast* da SEG [Seismic Soundoff](#) (episódios [14](#) e [60](#)).

O assunto também foi comentado em [Março](#) e [Julho](#) de 2019 no *podcast* da *American Association of Petroleum Geologists*, [AAPG's Energy Insights](#).

As pesquisas desenvolvidas ao longo dos anos demonstram o imenso potencial do *Machine Learning* em resolver problemas em geociências, e a quantidade de atividade neste campo não mostra sinais de redução nos próximos anos. ■

Referências:

<https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>

<https://www.datasciencecentral.com/profiles/blog/s/artificial-intelligence-vs-machine-learning-vs-deep-learning>

<https://gaea.com.br/afinal-o-que-e-deep-learning/>

<https://skymind.ai/wiki/use-cases>

Qual é a diferença entre aprendizado supervisionado, não supervisionado, semi-supervisionado e por reforço?

Texto traduzido do blog da NVIDIA. Link da matéria original (em inglês): bit.ly/2OG8drU

Existem algumas maneiras diferentes de montar móveis de madeira. Cada um, idealmente, levará a um sofá ou cadeira completa. Mas, dependendo dos detalhes, uma abordagem fará mais sentido do que as outras.

Tem o manual de instruções e todas as peças certas? Apenas siga as instruções. Pegando o jeito disso? Jogue o manual de lado e vá sozinho. Mas perca as instruções, e cabe a você dar sentido a essa pilha de pregos e tábuas de madeira.

É o mesmo com *deep learning* (aprendizado profundo). Com base no tipo de dados disponíveis e no tópico em questão sendo pesquisado, um cientista escolherá treinar um algoritmo usando um modelo de aprendizado específico.

Em um modelo de aprendizado supervisionado, o algoritmo aprende em um conjunto de dados rotulados, fornecendo uma resposta chave que o algoritmo pode usar para avaliar sua precisão nos dados de treinamento. Um modelo não supervisionado, por outro lado, fornece dados não rotulados que o algoritmo tenta entender extraindo características e padrões por conta própria.

A aprendizagem semi-supervisionada ocupa um meio termo. Ele usa uma pequena quantidade de dados rotulados reforçando um

conjunto maior de dados sem respostas. E o aprendizado por reforço treina um algoritmo com um sistema de recompensa, fornecendo *feedback* quando um agente de inteligência artificial realiza a melhor ação em uma situação particular.

Vamos percorrer os tipos de conjuntos de dados e problemas de cada tipo de aprendizado.



Imagem retirada de [dailymotion.com/video/2uBkJ7M](https://www.dailymotion.com/video/2uBkJ7M)

O que é aprendizado supervisionado?

Se você está aprendendo uma tarefa sob supervisão, alguém está presente para avaliar se você está recebendo a resposta certa. Da mesma forma, na aprendizagem supervisionada, isso significa ter um conjunto completo de dados rotulados durante o treinamento de um algoritmo.

Totalmente rotulado significa que cada exemplo no conjunto de dados de treinamento

é marcado com a resposta que o algoritmo deve criar sozinho. Assim, um conjunto de dados rotulados de imagens de flores diria ao modelo quais fotos eram de rosas, margaridas e narcisos. Quando é mostrada uma nova imagem, o modelo a compara aos exemplos de treinamento para prever o rótulo correto (Fig. 1).

Existem duas áreas principais onde a aprendizagem supervisionada é útil: problemas de classificação e problemas de regressão.

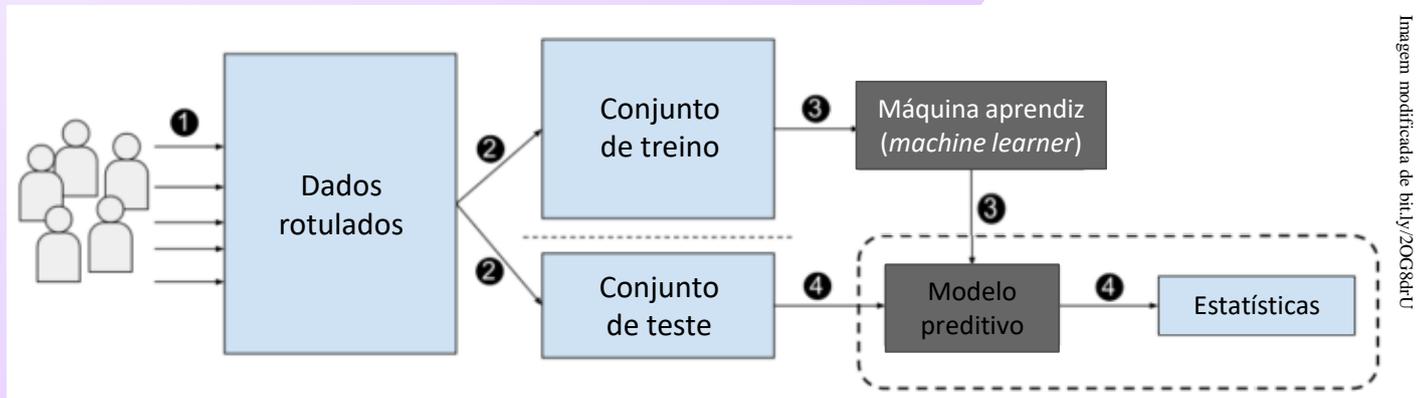


Figura 1. Com o machine learning supervisionado, o algoritmo aprende com os dados rotulados

Problemas de classificação solicitam que o algoritmo preveja um valor discreto, identificando os dados de entrada como membros de uma determinada classe ou grupo. Em um conjunto de dados de treinamento de imagens de animais, isso significaria que cada foto foi pré-rotulada como gato, coala ou tartaruga. O algoritmo é então avaliado pela precisão com que pode classificar corretamente novas imagens de outros coalas e tartarugas (Fig. 2).

Por outro lado, os problemas de regressão observam dados contínuos. Um caso de uso, a regressão linear, deve soar familiar a partir da classe de álgebra: dado um determinado valor x , qual é o valor esperado da variável y ?

Um exemplo de *machine learning* mais realista é o que envolve muitas variáveis, como um algoritmo que prevê o preço de um apartamento em Copacabana com base na metragem quadrada, na localização e na proximidade do transporte público.

A aprendizagem supervisionada é, portanto, mais adequada para problemas onde há um conjunto de pontos de referência disponíveis ou uma verdade básica com a qual treinar o algoritmo. Mas isso nem sempre está disponível.



Figura 2. Gato, coala ou tartaruga? Um algoritmo de classificação pode dizer a diferença.

O que é aprendizado não supervisionado?

Conjuntos de dados limpos e perfeitamente rotulados não são fáceis de encontrar. E, às vezes, os pesquisadores estão fazendo perguntas ao algoritmo para as quais não sabem a resposta. É aí que entra o aprendizado não supervisionado.

Na aprendizagem não supervisionada, um modelo de aprendizagem profunda recebe um conjunto de dados sem instruções explícitas sobre o que fazer com ele. O conjunto de dados de treinamento é uma coleção de exemplos sem um resultado específico desejado ou resposta correta. A rede neural, em seguida, tenta encontrar automaticamente a estrutura nos dados, extraindo recursos úteis e analisando sua estrutura (Fig. 3).

Dependendo do problema em questão, o modelo de aprendizado não supervisionado pode organizar os dados de diferentes maneiras:

1. Agrupamento (*Clustering*): sem ser um ornitólogo experiente, é possível olhar para uma coleção de fotos de aves e separá-las por espécie, contando com sugestões como a cor da pena, o tamanho ou a forma do bico. É assim que o aplicativo mais comum para aprendizado não supervisionado, de agrupamento, funciona: o modelo de *deep learning* procura dados de treinamento semelhantes entre si e agrupa-os.
2. Detecção de anomalias (*Anomaly detection*): os bancos detectam transações fraudulentas ao

comportamento de compra do cliente. Por exemplo, se o mesmo cartão de crédito for usado na Rio de Janeiro e na Bahia no mesmo dia, isso é motivo de suspeita. Da mesma forma, o aprendizado não supervisionado pode ser usado para sinalizar valores discrepantes em um conjunto de dados.

3. Associação (*Association*): Encha um carrinho de compras on-line com fraldas, compota de maçã e xícaras de café e o site só pode recomendar que você adicione um babador e um monitor para bebês ao seu pedido. Este é um exemplo de associação, em que determinados recursos de uma amostra de dados se correlacionam com outros recursos. Ao analisar alguns atributos-chave de um ponto de dados, um modelo de aprendizado não supervisionado pode prever os outros atributos com os quais eles são comumente associados.
4. Autoencodificadores (*Autoencoders*): os autoencodificadores obtêm dados de entrada, compactam-no em um código e tentam recriar os dados de entrada desse código resumido. É como começar com Dom Casmurro, resumir o livro e depois tentar reescrever a história original usando apenas o resumo como referência. Embora seja um truque de *deep learning*, há menos casos do mundo real em

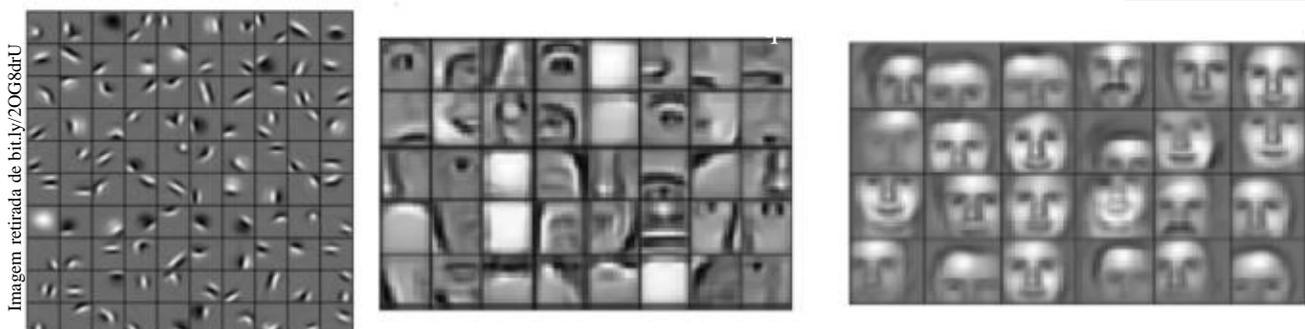


Figura 3. Modelos de aprendizado não supervisionados extraem automaticamente recursos e localizam padrões nos dados.

que um autocodificador simples é útil. Mas adicione uma camada de complexidade e as possibilidades se multiplicam: usando versões barulhentas e limpas de uma imagem durante o treinamento, os autoencodificadores podem remover o ruído de dados visuais como imagens, vídeos ou exames médicos para melhorar a qualidade da imagem.

Como não há elemento de "verdade básica" nos dados, é difícil medir a precisão de um algoritmo treinado com aprendizado não supervisionado. Mas existem muitas áreas de pesquisa onde os dados rotulados são evasivos ou caros demais para serem obtidos. Nesses casos, dar liberdade ao modelo de aprendizado profundo para encontrar padrões próprios pode produzir resultados de alta qualidade.

O que é aprendizado semi-supervisionado?

Pense nisso como um meio-termo. A aprendizagem semi-supervisionada é, na maioria das vezes, exatamente o que parece: um conjunto de dados de treinamento com dados rotulados e não rotulados. Esse método é particularmente útil quando a extração de recursos relevantes dos

dados é difícil, e os exemplos de rotulagem são uma tarefa demorada para os especialistas.

Situações comuns para esse tipo de aprendizado são imagens médicas como tomografia computadorizada ou ressonância magnética. Um radiologista treinado pode passar e rotular um pequeno subconjunto de exames para tumores ou doenças. Seria muito demorado e caro rotular manualmente todas as verificações - mas a rede de aprendizagem profunda ainda pode se beneficiar da pequena proporção de dados rotulados e melhorar sua precisão em comparação com um modelo totalmente não supervisionado.

Um método de treinamento popular que começa com um conjunto bastante pequeno de dados rotulados é o uso de redes adversárias gerais (*general adversarial networks* ou GANs; Figura 4).

Imagine duas redes de aprendizagem profundas na competição, cada uma tentando superar a outra. Isso é uma GAN. Uma das redes, chamada de gerador, tenta criar novos pontos de dados que imitam os dados de treinamento. A outra rede, o discriminador, obtém esses dados recém-gerados e avalia se eles fazem parte dos dados de treinamento ou falsificações. As redes melhoram em um ciclo de *feedback* positivo – à

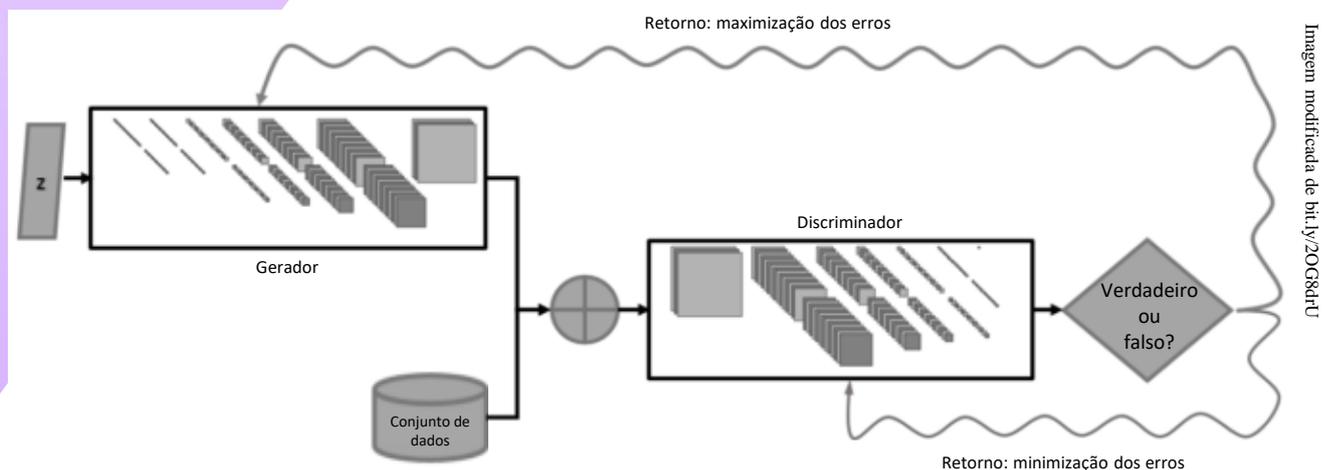


Figura 4. É assim que funciona uma GAN: ao discriminador é mostrado imagens do gerador e do conjunto de dados de treinamento. O discriminador é encarregado de determinar quais imagens fornecidas pelo gerador são reais e quais são falsas.

medida que o discriminador melhora a separação das falsificações dos originais, o gerador melhora sua capacidade de criar falsificações convincentes.

O que é aprendizado por reforço?

Os videogames são repletos de dicas de reforço. Complete um nível e ganhe um distintivo. Derrote o bandido em um certo número de movimentos e ganhe um bônus. Entre em uma armadilha - *game over*.

Essas dicas ajudam os jogadores a aprender como melhorar seu desempenho no próximo jogo. Sem esse *feedback*, eles apenas tomariam ações aleatórias em torno de um ambiente de jogo na esperança de avançar para o próximo nível.

O aprendizado por reforço funciona no mesmo princípio - e, na verdade, videogames são um ambiente de teste comum para esse tipo de pesquisa.

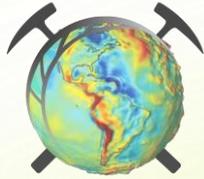
Nesse tipo de aprendizado de máquina, os agentes de AI estão tentando encontrar a maneira ideal de atingir uma meta específica ou melhorar o desempenho em uma tarefa específica. À medida que o agente realiza uma ação que vai em direção ao objetivo, ele recebe uma recompensa. O objetivo geral: prever o melhor próximo passo para ganhar a maior recompensa final.

Para fazer suas escolhas, o agente se baseia tanto em aprendizados de *feedback* passado quanto na exploração de novas táticas que podem representar um retorno maior. Isso envolve uma estratégia de longo prazo - assim como a melhor jogada imediata em um jogo de xadrez não pode ajudá-lo a vencer a longo prazo, o agente tenta maximizar a recompensa cumulativa.

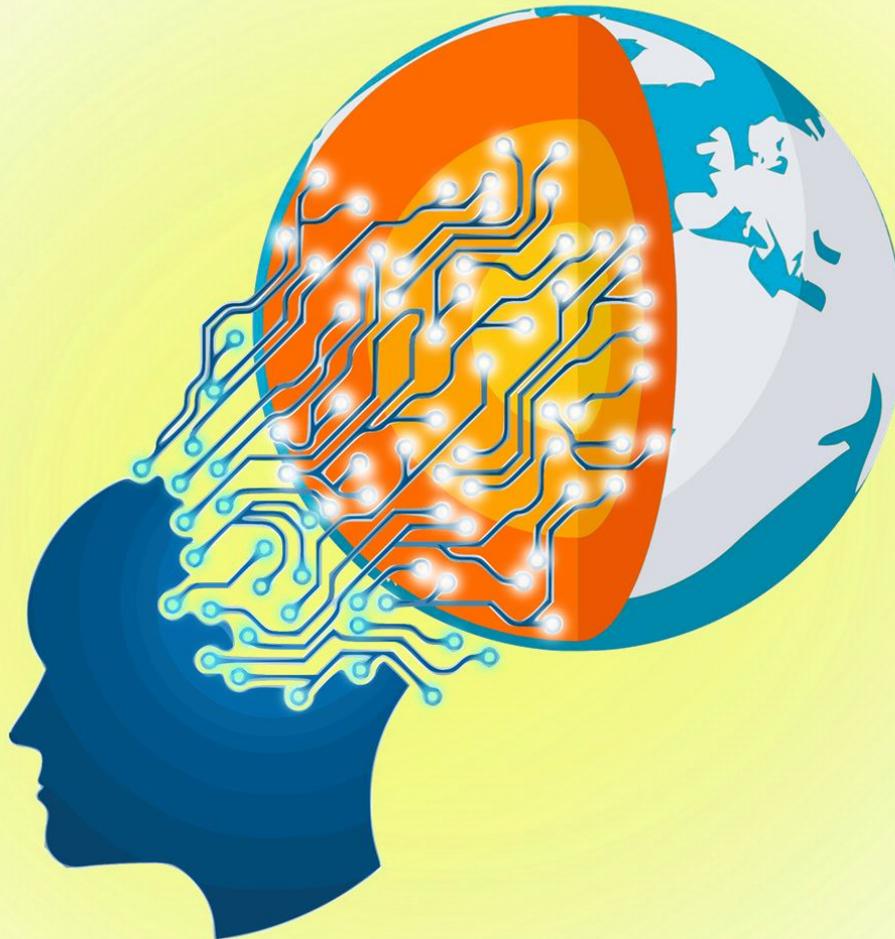
É um processo iterativo: quanto mais

rodadas de *feedback*, melhor a estratégia do agente se torna. Essa técnica é especialmente útil para treinar robôs, que tomam uma série de decisões em tarefas como dirigir um veículo autônomo ou gerenciar estoque em um depósito.

Assim como alunos de uma escola, todo algoritmo aprende de maneira diferente. Mas com a diversidade de abordagens disponíveis, é apenas uma questão de escolher a melhor maneira de ajudar sua rede neural a pegar a manha. ■



Student Chapter
UERJ Geophysical Society



VEM AÍ:

II WORKSHOP DE GEOFÍSICA APLICADA:

MACHINE LEARNING

25 A 27 DE SETEMBRO DE 2019

NA UERJ

Vantagens em ser membro da SEG: *SEG/ExxonMobil Student Education Program* e *SEG/Chevron Student Leadership Symposium*

Nós, da UERJ SEG Student Chapter, estaremos presentes no 89th *Annual Meeting* em San Antonio, no Texas!

É isso mesmo! Depois de muito esforço, atividades e dedicação dos membros, nosso querido capítulo estudantil de Geofísica será representado e apresentado por nosso presidente, Lucas Monteiro, que foi premiado com o *SEG/Chevron Student Leadership Symposium (SLS) Travel Grant*.

Mas afinal o que significa isso?

O SLS, bem como o SEP (*Student Education Program*), é uma das vantagens em ser um membro oficial da SEG, pois te permite competir através das aplicações pelos subsídios de viagem (*Travel Grant*), através do patrocínio de empresas como a *Chevron* (no caso da SLS) ou a *Exxon Mobil* (no caso da SEP).

Cinquenta estudantes ao redor do mundo foram convidados para participar do encontro anual, com todas as despesas pagas (aérea, estadia, alimentação e transporte), além do valor da inscrição no evento, no qual os estudantes participarão, durante dois dias, de um curso com foco nas habilidades de liderança, trabalho em equipe e comunicação, onde apenas os membros diretores do capítulo podem participar, e somente um por capítulo pode ser convidado por ano.

Para ser elegível ao prêmio, é preciso responder cinco perguntas pessoais e complexas de

forma que se possa avaliar as capacidades natas esperadas em um líder, principalmente na parte de inovação e resolução de problemas. Depois disto, o comitê avalia as respostas e seleciona as cinquenta melhores para o prêmio.

Está é a terceira vez que nosso capítulo estará presente no *SEG Annual Meeting*, a primeira tendo ocorrido em 2015, no ano de fundação do nosso capítulo, a segunda em 2016, e agora em 2019. Em pouco mais de quatro anos de existência, fomos em quase todos os anos eleitos para o SLS. E em 2017, o presidente do capítulo na época, Vinicius Riguete, foi eleito para o SEP (ele falou um pouco sobre sua experiência no [podcast da SEG](#)), o que demonstra nosso potencial como capítulo e entidade estudantil.

Esperamos que tenha ficado um gostinho de nossas atividades, e chamado sua atenção para os benefícios em ser membro associado ao *Chapter*. Venha se associar ao UERJ *Student Chapter Geophysical Society* e aprender um pouco mais sobre o mundo maravilhoso da geofísica. Mande um e-mail para segchapter.uerj@gmail.com para poder se inscrever no capítulo. Além disto peça para ser informado sempre que uma nova edição for publicada, para não perder nenhuma novidade!

Na próxima edição, traremos uma reportagem exclusiva sobre como foi o SLS, o *Annual Meeting* e San Antonio. ■

Artigo Técnico

Anomalia Gravimétrica Residual da Bacia de Barreirinhas utilizando Modelagem Crustal

Nelson Ribeiro Filho, Cristiano Mendel Martins, Boris Chaves Freimann e Renata de Sena Santos –
Universidade Federal do Pará (UFPA)

INTRODUÇÃO

A gravimetria é uma técnica amplamente utilizada na prospecção geofísica, sendo capaz de auxiliar o intérprete na identificação de importantes estruturas geológicas comumente encontradas em bacias sedimentares (Telford et al., 1990). Em relação aos reservatórios existentes em bacias sedimentares, essas feições costumam ser destacadas como armadilhas ou trapas. Embora o sinal gravitacional observado seja resultado de todos os efeitos produzidos por fontes próximas, a anomalia gravimétrica devida a uma bacia sedimentar, por exemplo, é presumida como um sinal negativo, já que o contraste de densidade entre as camadas de sedimento que preenchem a bacia e o embasamento crustal é negativo (Blakely, 1996; Telford et al., 1990). Outra possível fonte de influência no sinal de gravidade observado é a superfície que separa a crosta e o manto (descontinuidade de Mohorovicic ou Moho), o que provoca uma alteração na amplitude do sinal que pode torná-lo positivo. Esse fato faz com que a interpretação do sinal gravimétrico observado dependa da separação dos diferentes sinais que estão contidos nas observações (Blakely, 1996; Ribeiro and Mantovani, 2011). Existe um grupo de autores que realiza a separação regional-residual analisando o espectro de anomalia através do domínio de Fourier, dividindo ambas em aquelas que apresentam comprimentos de onda curtos e

grandes (Spector and Grant, 1970). Outro grupo faz essa separação procurando por polinômios que ajustam o comportamento da anomalia, uma vez assumido que o campo gravimétrico regional pode ser aproximado por um polinômio de baixa ordem (Beltrão et al., 1991). Uma terceira possibilidade é incorporar a modelagem crustal a fim de obter informações sobre a contribuição regional, com o objetivo de remover seus efeitos dos dados observados e selecionar o sinal residual verdadeiro, relativo à bacia sedimentar. Dessa forma, aplicamos a modelagem usando o modelo crustal de distribuição de densidade, províncias geológicas e o alívio do projeto GEMMA (GOCE Exploitation for Moho Modeling and Application), que foi proposto por Reguzzoni and Sampietro (2015); Sampietro et al. (2013).

METODOLOGIA DA MODELAGEM CRUSTAL

Seja C uma crosta heterogênea imposta sobre um manto homogêneo. Delimitamos uma região finita no plano horizontal x - y que contém a região correspondente à crosta e o volume total delimitado, definindo-se a espessura da crosta como a diferença entre sua parte superior e inferior. Discretizamos este volume contendo M prismas elementares distribuídos nas direções horizontal e vertical, até que toda a espessura crustal esteja totalmente preenchida. As dimensões dx , dy e

dz são todas conhecidas. Dessa forma, assumimos que o contraste de densidade entre um prisma elementar da crosta e o manto é conhecido e homogêneo dentro de cada um dos prismas, mas podendo apresentar variações internamente. Avaliamos o sinal gravimétrico utilizando os parâmetros geométricos e de densidade fornecidos pelo modelo crustal GEMMA. A diferença entre o sinal gravimétrico observado e aquele calculado pelo conjunto de prismas fornece o sinal gravimétrico residual, que está relacionado à bacia sedimentar. Também aplicamos a técnica de Análise Espectral (Spector and Grant, 1970). Dois filtros foram utilizados para análise de espectro: primeiro o filtro de passagem de banda, para redução de ruído; depois o filtro de separação Gaussiano. Para o método de ajuste polinomial robusto (Beltrão et al., 1991), foi realizada a separação residual regional para polinômios de ordem 1 a 6.

BACIA DE BARREIRINHAS – CONTEXTO GEOLÓGICO

Selecionamos como área de estudo uma porção continental da bacia de Barreirinhas, que está incluída no grupo de bacias denominadas **nova fronteira petrolífera**, localizada na margem equatorial brasileira. A Figura 01 mostra a localização da área de estudo. Essa bacia estende-se por uma área de aproximadamente 85.000 km², mas a área majoritária está submersa a uma profundidade estimada de 6 km (Soares Júnior et al., 2011, 2008).



Figura 01: Mapa de localização da área de estudo. O retângulo tracejado em cor vermelha representa a área onde está localizada a bacia sedimentar de Barreirinhas.

Soares Júnior et al. (2011) mostraram que a formação da bacia está relacionada a vários eventos geológicos que ocorreram, resultando na separação entre placas litosféricas africanas e sul-americanas. Trosdorf Jr et al. (2007) descrevem o desenvolvimento da bacia sobre a bacia do Parnaíba, com embasamento composto por rochas cristalinas, rochas vulcânicas metamórficas e básicas, formando um sistema grabens profundo que é limitado por falhas normais orientadas na direção NW-SE, como ilustrado na Figura 02.

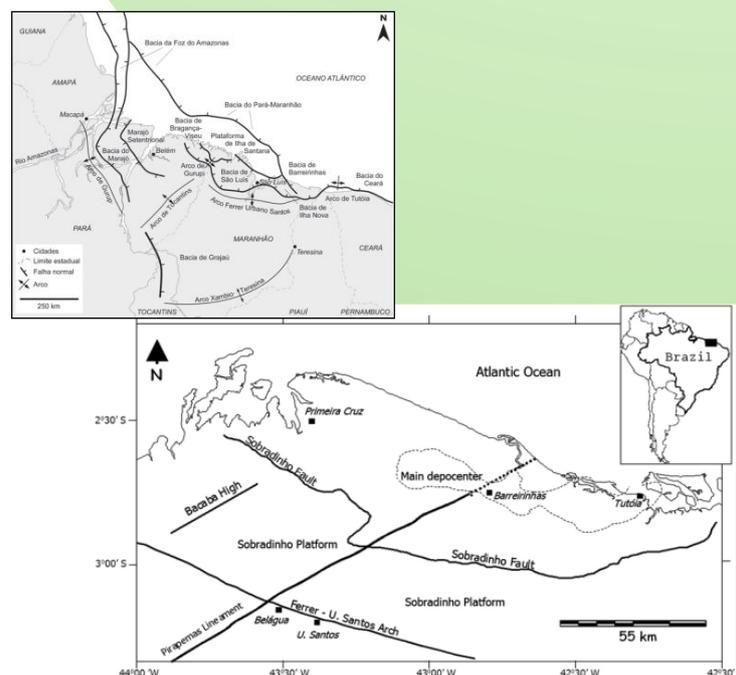


Figura 02: Mapa geológico simplificado da região equatorial do Brasil e mapa tectônico simplificado indicando as falhas e lineamentos existentes na bacia de Barreirinhas, tal qual o seu depocentro crustal. Fonte: Almeida-Filho et al. (2009).

O sinal gravimétrico observado é representado, neste caso, pela anomalia Bouguer simples causada por toda a contribuição na área, que pode ser visualizada na Figura 03. As áreas mais negativas representam a bacia de São Luis e a porção continental da bacia de Barreirinhas.

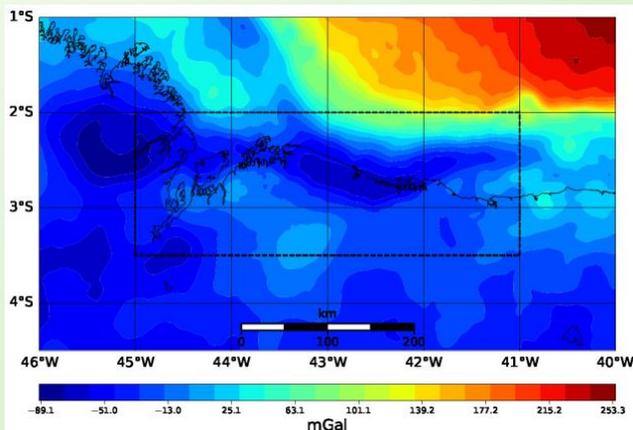


Figura 03: Anomalia gravimétrica Bouguer observada na região que compreende a bacia de Barreirinhas.

RESULTADOS

Aqui apresentamos as soluções para polinômios de 3 e 6 ordens. A Figura 04 indica a solução para a anomalia gravimétrica residual para o polinômio de terceiro e sexto grau, respectivamente. Ambas as soluções aproximaram-se dos critérios estabelecidos para a separação, embora mostrem amplitudes diferentes. Ambos os polinômios escolhidos não foram capazes de ajustar o contorno da bacia. O resultado obtido a partir da análise espectral também é apresentado na Figura 04, e também tem mostrado uma amplitude similar para a anomalia residual e forma similar como também para as técnicas de soluções polinomiais.

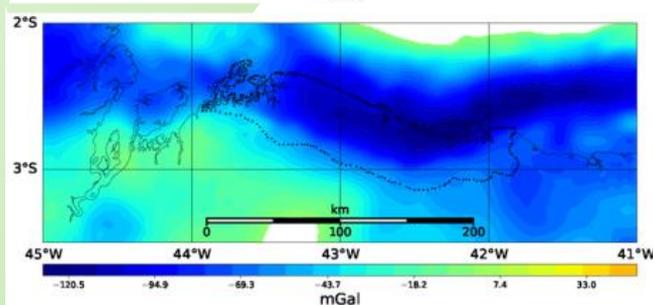
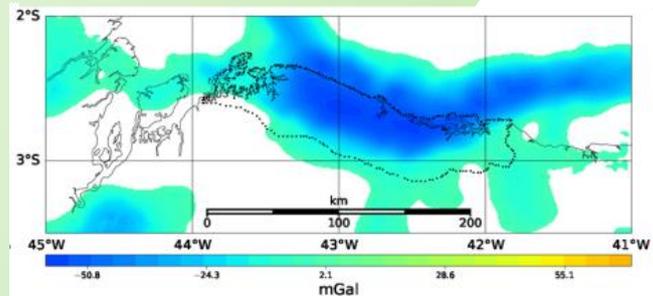
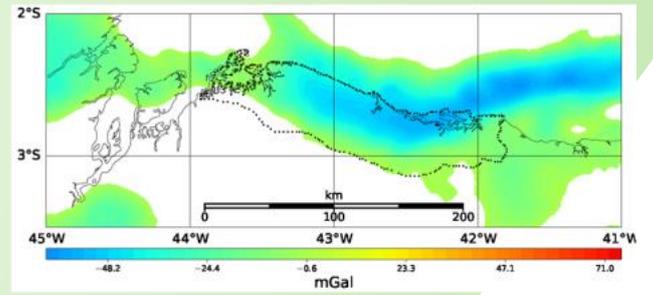


Figura 04: Anomalia gravimétrica residual obtida via ajuste polinomial de grau 3, de grau 6 e através da técnica da análise espectral.

Os polinômios de ordem superior a 6 mostraram-se equivalentes, apresentando forma semelhante para ambos os sinais. Por essa razão, preferimos não mostrar essas soluções. De maneira contrária, a modelagem crustal se mostrou eficiente para o cálculo da anomalia gravimétrica residual. Podemos observar no mapa apresentado na Figura 05 que o procedimento de modelagem desenvolvido delimitou mais efetivamente o contorno da bacia.

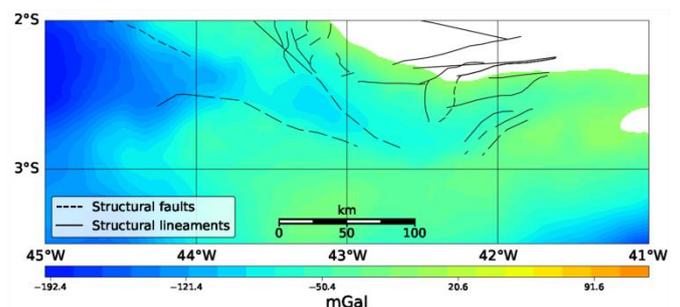


Figura 05: Mapa gravimétrico residual obtido via técnica de modelagem gravimétrica crustal indicando as falhas e lineamentos estruturais e tectônicos existentes na área.

Com informações valiosas, é possível afirmar que a anomalia gravimétrica residual é confinada pelas falhas estruturais mapeadas, a forma da anomalia está associada às posições de falha e a região mais profunda da zona continental da bacia está localizada um pouco mais para o Ocidente, que é diferente de estudos anteriores já apresentados. Também pode haver outras falhas e recursos não mapeados na região, pois todos os contornos da anomalia residual seguem uma direção específica.

CONSIDERAÇÕES FINAIS

Selecionar a melhor anomalia gravimétrica residual é uma tarefa difícil para o intérprete, uma vez que existem muitas técnicas a serem aplicadas, assim como vários resultados possíveis para interpretá-lo. Selecionamos como área de estudo a parte continental da bacia de Barreirinhas, uma vez que essa bacia é assumida como uma das **novas fronteiras petrolíferas**, e aplicamos todas as técnicas conhecidas de separação residual-regional. Adotamos o método de modelagem crustal desenvolvido. Tanto a análise espectral como técnicas robustas de ajuste polinomial não foram efetivas para delinear a bacia a partir do sinal gravimétrico residual, pois o relevo da descontinuidade de Mohorovicic é uma fonte gravimétrica intensa, ou seja, de elevada amplitude. Essa fonte é assumida como um sinal gravimétrico regional, uma vez que a geometria da crosta se sobrepõe, produzindo um efeito com forma de dois lobos, um negativo e outro

positivo, que podem ser escondidos das informações úteis do intérprete (Allen and Allen, 2013; Watts, 2001).

O procedimento de modelagem crustal mostrou-se eficaz na seleção da anomalia gravimétrica residual, uma vez que todos os atributos geométricos da crosta estão presentes no modelo GEMMA. A principal dificuldade para os outros métodos testados é a forma geométrica da crosta nessa área. Dessa maneira, o melhor procedimento a ser adotado nesses tipos de ambientes deve ser aquele que inclui todos os atributos geométricos. Para fins de prospecção de petróleo e gás, nosso procedimento também é efetivo, pois foi detectado o depocentro da bacia, embora com leve deflexão para oeste, e indicando a possível ocorrência de falhas estruturais existentes. Dito isto, este procedimento pode ser aplicado em qualquer bacia sedimentar.

REFERÊNCIAS

- ALLEN, Philip A.; ALLEN, John R. Basin analysis: Principles and application to petroleum play assessment. John Wiley & Sons, 2013.
- ALMEIDA-FILHO, Raimundo et al. Quaternary reactivation of a basement structure in the Barreirinhas Basin, Brazilian Equatorial Margin. *Quaternary Research*, v. 72, n. 1, p. 103-110, 2009.
- BARTHELMES, Director Franz et al. International centre for global earth models (ICGEM). 2016.
- BELTRAO, J. F.; SILVA, J. B. C.; COSTA, J. C. Robust polynomial fitting method for regional gravity estimation. *Geophysics*, v. 56, n. 1, p. 80-89, 1991.
- BLAKELY, Richard J. Potential theory in gravity and magnetic applications. Cambridge university press, 1996.
- REGUZZONI, Mirko; SAMPIETRO, Daniele. GEMMA: An Earth crustal model based on GOCE satellite data. *International Journal of Applied Earth Observation and Geoinformation*, v. 35, p. 31-43, 2015.

- RIBEIRO, Vanessa Biondo; MANTOVANI, Marta Silvia Maria. Campo gravimétrico do complexo alcalino de Tapira (MG): Comparação entre técnicas de interpolação e de separação regional-residual. *Revista Brasileira de Geofísica*, v. 29, n. 3, 2011.
- SAMPIETRO, D.; REGUZZONI, Mirko; NEGRETTI, Marco. The GEMMA crustal model: first validation and data distribution. *ESA Special Publication*, v. 722, p. 30, 2013.
- JÚNIOR, Adilson Viana SOARES; COSTA, João Batista Sena; HASUI, Yociteru. Evolução da margem atlântica equatorial do Brasil: Três fases distensivas. *Geociências (São Paulo)*, v. 27, n. 4, p. 427-437, 2008.
- JUNIOR, Ivo Trosdorf et al. Bacia de Barreirinhas. *Bol. Geociências Petrobrás, Rio J.*, v. 15, n. 2, p. 357-369, 2007.
- SPECTOR, A.; GRANT, F. S. Statistical models for interpreting aeromagnetic data. *Geophysics*, v. 35, n. 2, p. 293-302, 1970.
- TELFORD, William Murray et al. *Applied geophysics*. Cambridge university press, 1990.
- WATTS, Anthony Brian. *Isostasy and Flexure of the Lithosphere*. Cambridge University Press, 2001.

Coletânea *Algoritmos e Lógica da Programação*

Artigo técnico 3: Instruções Primitivas: Atribuição, Entrada e Saída de Dados

por Lucas Guimarães P. Monteiro

Presidente do Student Chapter *State University of Rio de Janeiro Geophysical Society* (UERJ Geophysical Society)**INTRUÇÕES PRIMITIVAS**

Instruções primitivas são os comandos básicos que efetuam tarefas essenciais para a operação dos computadores como entrada e saída de dados, assim como a movimentação destes na memória do programa. Estando presente na maioria absoluta das linguagens da programação, torna óbvio sua existência, pois um programa sem estas instruções é incapaz de se comunicar com o mundo exterior, e, portanto, não possui utilidade alguma ^[1].

No primeiro artigo, vimos o que é um algoritmo e como estruturamos ele, tanto na forma de fluxograma, quanto na forma de pseudocódigo (ou Portugal). No segundo, vimos que os dados e variáveis possuem suas declarações, e que o algoritmo deve obedecer a princípios lógicos bem definidos antes de sua compilação (ou seja, o momento que o programa “roda”).

Neste terceiro artigo, vamos explorar como os dados de um algoritmo podem interagir com o mundo externo, através de **instruções primitivas**. Dentre as principais instruções primitivas podem declarar: os dispositivos de **ENTRADA**, **SAÍDA** e **ATRIBUIÇÃO**.

ATRIBUIÇÃO DE DADOS

A instrução de **atribuição** é a principal maneira de se armazenar uma informação numa variável (Ex_1).

Ex₁:**Pseudocódigo:****ALGORITMO** Atribuição**VAR**

Livro : literal

Quantidade, Codigo : inteiro

Preco, Preco_Total : real

INICIO

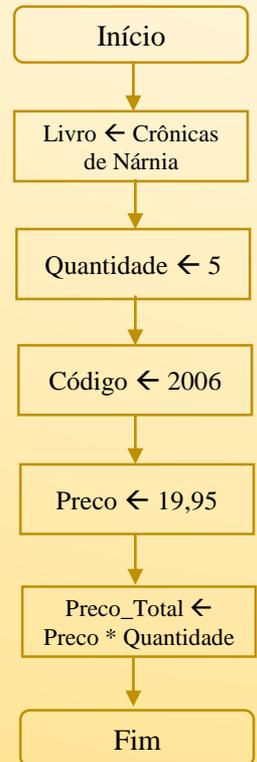
Livro ← “Crônicas de Nárnia”

Quantidade ← 5

Codigo ← 2006

Preco ← 19,95

Preco_Total ← Preco*Quantidade

FIM**Fluxograma:**

O modo de funcionamento de uma atribuição consiste em^[1]:

- Avaliação da expressão;
- Armazenamento do valor resultante na posição de memória correspondente a variável declarada;

SINTAXE: <NOME_VARIÁVEL> ← <EXPRESSÃO>

SAÍDA DE DADOS

É o meio pelo qual as informações são transferidas pelo computador ao usuário ou aos níveis secundários de memória. Assim, as instruções de saída de dados são o meio pelo qual informações contidas na memória dos computadores são colocadas nos dispositivos de saída, para que o usuário possa visualizá-las^[1].

ESCREVA é, a partir de agora, uma palavra reservada e não pode ser usada como nome de variável, de modo que caso haja tal palavra o programa irá automaticamente entender como um comando de saída de dados.

A semântica dessa instrução é simples. Os argumentos do comando são enviados para o dispositivo de saída padrão e exibidos ao usuário. Há a possibilidade de misturar nomes de variáveis com literais na lista do mesmo comando [1].

SINTAXE: **ESCREVA** <DECLARAÇÃO_DE_VARIÁVEIS>
ESCREVA <LITERAL>

Vale destacar as diferenças entre as atribuições dentro do texto. As aspas dentro de uma mensagem, representam a exibição literal daquilo eu está escrito [2], assim:

ESCREVA (“Olá, Mundo”)

Irá exibir ao usuário a frase: *Olá, Mundo* no dispositivo de saída. Para imprimir o valor de uma variável, basta colocar seu identificador corretamente, assim:

abc ← 123

ESCREVA (abc)

Irá exibir ao usuário o valor armazenado na variável abc, que está atribuída com o valor: 123. Contudo, se por outro lado escrevermos este identificador com aspas, iremos imprimir exatamente o nome desta variável:

abc ← 123

ESCREVA (“abc”)

Este comando irá exibir na sua saída a frase: abc. Assim, vemos essencialmente a diferença entre os resultados obtidos pelo abc e pelo “abc”. O primeiro indica o identificador

de uma variável previamente declarada, o segundo, com aspas, indica simplesmente uma sequência de caracteres. Em resumo, as aspas previnem que o algoritmo interprete o conteúdo da cadeia de letras [2]. Vejamos o Ex₂:

Ex₂:

Pseudocódigo

ALGORITMO Saída

VAR

Livro : literal

Quantidade, Código : inteiro

Preço, Preço_Total :real

INICIO

Livro ← “Crônicas de Nárnia”

Quantidade ← 5

Código ← 2006

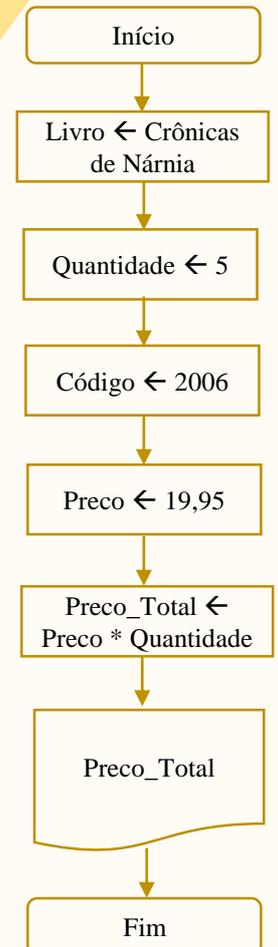
Preço ← 19,95

Preço_Total ← Preço*Quantidade

ESCREVA Preço_Total

FIM

Fluxograma:



ENTRADA DE DADOS

Podemos modificar o algoritmo anterior permitindo um maior controle do usuário na entrada do valor das variáveis para obter diferentes resultados finais. A instrução primitiva de entrada de dados foi criada para suprir esta necessidade.

Assim, **LEIA** passa a ser uma palavra reservada, assim como foi com **ESCREVA**, e não poderá mais ser usada como nome para definir uma variável. Caso contrário o programa ao ler este comando interpretará que

o usuário deve inserir um código de entrada no momento de sua execução.

A semântica da instrução de entrada de dados é inversa à instrução de saída, uma vez que os dados são fornecidos ao computador por meio de um dispositivo de entrada de dados de forma externa, e armazenado nas posições de memória das variáveis já listadas na <DECLARAÇÃO_DE_VARIÁVEIS>, já falada no primeiro artigo. Aqui está pode ser vista no Ex₃:

SINTAXE: LEIA (DECLARAÇÃO_DE_VARIAVEIS)

Ex₃:

Pseudocódigo

ALGORITMO Entrada

VAR

Livro : literal
Quantidade, Codigo : inteiro
Preco, Preco_Total : real

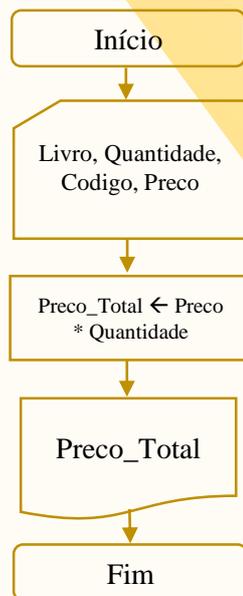
INICIO

LEIA (Livro, Quantidade, Codigo, Preco)
Preco_Total ← Preco*Quantidade

ESCREVA Preco_Total

FIM

Fluxograma:



Contudo, como saber o que escrever em cada uma das variáveis de entrada? O usuário pode sentir dificuldades em escrever as informações se ele não souber o que deve preencher. Assim, devemos atentar ao uso de frases na hora de compilar um programa visando um usuário externo, não sendo necessário à sua utilização para programação uma vez que, o programador sabe quais são as variáveis pedidas (Ex₄).

Ex₄:

Pseudocódigo

ALGORITMO Entrada

VAR

Livro : literal
Quantidade, Codigo : inteiro
Preco, Preco_Total : real

INICIO

ESCREVA (“Por favor, digite o nome do livro, a quantidade, o código e o preço do mesmo”)

LEIA (Livro, Quantidade, Código, Preco)

Preco_Total ← Preco*Quantidade

ESCREVA (“O preço total da sua compra é: ”, Preco_Total)

FIM

Fluxograma:



Assim, resumindo os princípios básicos de um algoritmo padrão e suas principais funções e usos, vamos começar a pôr nossos conhecimentos em prática. Esperamos que você já tenha lido os artigos anteriores e feito nossos exercícios, tendo uma pequena base para os próximos exercícios a serem feitos. Aconselhamos que todos os exercícios sejam resolvidos através do Pseudocódigo.

É altamente recomendável que faça os exercícios de duas maneiras: a primeira, numa folha de papel ou pelo documento de texto (.txt), que não possuem formatação e deixam livre para que você possa fazer um escopo do seu projeto inicial. Após a realização do exercício em via livre, passar os códigos para o nosso compilador já conhecido, o VisualG; deixaremos novamente o link para download.

Com estes passos, tenho certeza que você irá consolidar os conceitos básicos em algoritmos. Este conhecimento servirá de preparação para nossa próxima edição, onde trabalharemos com as **Estruturas de condição**.

EXERCÍCIOS PROPOSTOS

1) No final da execução do fragmento de código abaixo, qual é o valor de n_1 , n_2 e n_3 ?

var n_1, n_2, n_3 : inteiro

$n_1 \leftarrow 10$

$n_2 \leftarrow 30$

$n_3 \leftarrow n_1$

$n_1 \leftarrow n_2$

$n_2 \leftarrow n_3$

2) Quais os valores de v_1 , v_2 e v_3 no final da execução do código abaixo?

var v_1, v_2, v_3 : logico

$v_1 \leftarrow 8 > 9$

$v_2 \leftarrow 8 < 9$

$v_3 \leftarrow v_1 _ v_2$

$v_1 \leftarrow v_3 \wedge v_2$

3) Que problema existe no algoritmo abaixo?

var num1: inteiro

num1 (20 > 9)

4) O que será impresso para cada uma das instruções abaixo?

A. escreva (“numero=”, 78)

B. escreva (“veja esse resultado”)

escreva (78 + 2)

C. escreva (76 > 8 , 8*2, “três”)

D. escreva (“olá”, “olá de novo”, 3<9)

E. escreva (“verdadeiro, 8 = 8”)

F. escreva (8+8, 12<8, “blá blá”)

G. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

escreva (n_1 , n_2)

H. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

escreva (n_1+n_2)

I. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

escreva (“ n_1+n_2 ”)

J. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

escreva (“ n_1+n_2 ”)

K. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

escreva($n_1>n_2$)

L. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

Escreva (“ $n_1 + n_2 =$ ”, $n_1 + n_2$)

M. $n_1 \leftarrow 4$

$n_2 \leftarrow 10$

Escreva(n_1 , “+”, n_2 , “=”, $n_1 + n_2$)

5) Para os problemas a seguir, defina:

. Quais são os valores de entrada;

. Qual será o processamento do algoritmo;

. Quais são os valores de saída;

. Quais são os valores que variam e quais permanecem constantes (fixos) durante à execução do algoritmo;

. O pseudocódigo de cada um:

A. Calcular a área de um triângulo dada a

fórmula $A = \frac{(B*H)}{2}$.

B. Calcular a quantidade de azulejos que são necessários para cobrir uma determinada parede.

C. Calcular a média do peso de uma família de 5 pessoas.

D. Calcular a área de uma circunferência dada

a fórmula $A = \frac{\pi*R^2}{2}$.

6) Escreva um algoritmo para calcular a média entre dois números quaisquer.

7) Leia uma temperatura dada na escala Celsius (C) e imprima o equivalente em Fahrenheit (F). (Fórmula de conversão: $F = \frac{9}{5} * C + 32$)

8) Escreva um algoritmo para calcular o valor de y como função de x, de forma que o usuário entre com o parâmetro x, segundo a função $y(x) = 3x + 2$, num domínio real.

9) Escreva um algoritmo para calcular o consumo médio de um automóvel (medido em Km/l), dado que são conhecidos a distância total percorrida e o volume de combustível consumido para percorrê-la (medido em litros).

10) Leia uma quantidade de chuva dada em polegadas e imprima o equivalente em milímetros (25,4 mm = 1 polegada).

11) Calcule o quadrado de um número, ou seja, o produto de um número por si mesmo.

12) O custo ao consumidor de um carro novo é a soma do custo de fábrica com a porcentagem do distribuidor e dos impostos, ambos aplicados ao custo de fábrica. Supondo que a porcentagem do distribuidor seja de 12% e a dos impostos de 45%, prepare um algoritmo para ler o custo de fábrica do carro e imprimir o custo ao consumidor.

13) O cardápio de uma lanchonete é dado abaixo. Prepare um algoritmo que leia a quantidade de cada item que você consumiu e calcule a conta final:

Hambúrguer.....	R\$ 3,00
Cheeseburger.....	R\$ 2,50
Fritas.....	R\$ 2,50
Refrigerante.....	R\$ 1,00
Milkshake.....	R\$ 3,00

14) Uma companhia de carros paga a seus empregados um salário de R\$ 500,00 por mês mais uma comissão de R\$ 50,00 para cada carro vendido e mais 5% do valor da venda. Elabore um algoritmo para calcular e imprimir o salário do vendedor num dado mês recebendo como dados de entrada o nome do vendedor, o número de carros vendidos e o valor total das vendas.

15) Calcule a média de um aluno na disciplina de MDS. Para isso solicite o nome do aluno, a nota da prova e a nota qualitativa. Sabe-se que a nota da prova tem peso 2 e a nota qualitativa peso 1. Mostre a média como resultado.

16) Faça um algoritmo que solicite que o usuário digite seu nome e a seguir solicite que seja digitada sua idade. Depois que o usuário digitar o nome e a idade, o programa deve exibir na tela duas mensagens: uma com o nome e outra com a idade do usuário. Suponha que o usuário seja o Pedro e tenha 32 anos. Assim, após a digitação dos dados, seu programa deve exibir as seguintes mensagens: “Seu nome é Pedro” e “Você tem 32 anos”.

DESAFIO

Desafio de lógica: Três missionários e três canibais encontram-se na margem esquerda de um rio. Nessa margem também existe um bote que pode transportar uma ou duas pessoas. As seis pessoas pretendem todas passar para a margem direita (usando o bote). No entanto, os missionários têm de arranjar um plano para o conseguir de modo que, em nenhuma circunstância, existam missionários numa margem em minoria relativamente aos canibais, pois têm receio do que lhes possa acontecer. Quando o bote chega à margem, os elementos do bote são contados como estando na margem. Assim, se houver apenas um canibal em uma margem, não podemos enviar a essa margem o bote com um canibal e um missionário, pois, ao chegar à outra margem, serão dois canibais contra um missionário. Lembre-se de que para o bote ir de uma margem a outra é necessário que alguém esteja remando, ou seja, o bote nunca atravessa vazio. Faça um algoritmo que exhiba, passo a passo, como efetuar esta travessia de forma segura.

Referências Bibliográficas

- [1] Ferrari, Fabricio; Cechinel, Cristian. Introdução a Algoritmos e Programação. Versão 2.2
- [2] Apostila de algoritmo e lógica da programação – Algoritmos – Parte 1 – Departamento de Computação e Automação. Centro de Tecnologia. UFRN / UFRN, 2004.

Leitura Complementar

Carvalho, Victorio Albani de. Lógica de programação / Victorio Albani de Carvalho. – Colatina: CEAD / Ifes, 2009.

