

LUIZ FELIPE NIEDERMAIER CUSTÓDIO

Integração mundial de bases de dados de *Improved and Enhanced Oil Recovery (IOR/EOR)*: predições e análises estratégicas por meio de algoritmos de Inteligência Artificial

Área de concentração:
Engenharia de Petróleo

Orientador:
Prof. Dr. Cleyton de Carvalho Carneiro

Co-orientador:
Prof. Dr. Rafael dos Santos Gioria

Colaboradores:
Profs. Drs. Marcio Augusto Sampaio Pinto,
Caetano Rodrigues Miranda e Jean Vicente
Ferrai

São Paulo
2019

LUIZ FELIPE NIEDERMAIER CUSTÓDIO

Integração mundial de bases de dados de *Improved and Enhanced Oil Recovery (IOR/EOR)*: previsões e análises estratégicas por meio de algoritmos de Inteligência Artificial

Monografia apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Engenheiro de Petróleo.

Área de concentração:
Engenharia de Petróleo

Orientador: Prof. Dr. Cleyton de Carvalho Carneiro

Co-orientador: Prof. Dr. Rafael dos Santos Gioria

Colaboradores: Prof. Dr. Marcio Augusto Sampaio Pinto e Prof. Dr. Jean Vicente

Santos
2019

Este exemplar foi revisado e alterado em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo,

Assinatura do autor _____

Assinatura do orientador _____

Catálogo-na-Publicação

Luiz Felipe Niedermaier Custódio

Integração mundial de bases de dados de Improved and Enhanced Oil Recovery (IOR/EOR): predições e análises estratégicas por meio de algoritmos de Inteligência Artificial / L. F. N. C. -- São Paulo, 2019.

157 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e de Petróleo.

1.Enhanced Oil Recovery 2.Improved Oil Recovery 3.Artificial Intelligence 4.Data Management 5.Screening I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Minas e de Petróleo II.t.

À minha família.

AGRADECIMENTOS

Gostaria de, em primeiro lugar, agradecer profundamente a toda a minha família que, sem dúvidas, foi de extrema importância durante a minha graduação. Palavras não descrevem o quanto eu simplesmente amo vocês.

Em segundo lugar, agradeço aos meus orientadores professores Dr. Cleyton de Carvalho Carneiro e Dr. Rafael dos Santos Gioria, por abraçarem e acreditarem na minha ideia e acompanharem de perto o desenvolvimento desse trabalho, além de me incentivarem a tornar isso uma iniciativa empreendedora, que sei ainda ter muito o que melhorar. Sou muito grato também aos professores Dr. Jean Vicenti Ferrari e Dr. Marcio Augusto Sampaio por auxílio nas análises e em *insights* diversos. Tenho grande apreço por tudo que aprendi com os senhores, em que o profissionalismo, a vontade de ensinar, as vossas conquistas e as intensas lutas como docentes do curso de Engenharia de Petróleo na Poli-USP em Santos são fascinantes e exemplares.

Obrigado também ao Prof. Dr. Caetano Rodrigues Miranda pela oportunidade de Iniciação Científica junto ao grupo NanoPetro ainda no segundo ano da graduação, e por agora nos últimos meses iniciarmos uma abordagem de integração entre os resultados desse TCC com previsões via dinâmica molecular, que acredito que possa dar bons frutos no futuro.

Agradeço ainda aos colegas do LASG/InTRA pelo companheirismo nas infinitas horas de labuta (e descontração também) na rotina do laboratório. Agradeço também à ajuda com feedbacks, opiniões e críticas diversas que pude obter por parte do Arthur Henrique, do Eng. Bruno Schaefer com sua experiência de trabalho em campo *offshore*, do M. Sc. Paulo Ranazzi com sua bagagem científica crítica e de todos os demais da Poli Santos que, de alguma forma ou outra, me ajudaram.

Sou muito grato também por ao longo dessa trajetória ter conquistado a amizade de grandes pessoas e que hoje se tornaram excelentes profissionais como Gabriel André Silvério, Milena Christy, Jonathan Mendes, Crhis Moreira, Douglas Barbosa, Lucas Renan da Silva, Fernando Ferreira Silva, Bárbara Leliard, Rafael Tavares, Cassia Oliveira, Fernando Bonsucesso, Maryam Furlan, Leticia Santos, dentre outros com os quais pude contar em diversos momentos e poder compartilhar muitas risadas e conversas falando desde sobre questões existenciais até futilidades da vida. Nesse ínterim, certamente vocês se tornaram um alicerce fundamental para constituir quem eu sou hoje.

Por fim, gostaria de agradecer à Escola Politécnica da USP e a todos os contribuintes do Estado de São Paulo por, indiretamente ou não, manterem uma universidade pública e de qualidade e por eu ter sido contemplado com bolsas de estudo ao longo da faculdade. Sem dúvida esses anos foram extremamente intensos e produtivos, e sinto que o que aprendi aqui permitiu-me caminhar um passo além na curva de aprendizado da vida e ver que, principalmente, tenho ainda muito o que aprender e retornar à sociedade por esse investimento em minha formação.

*“Life is a play that does not allow testing. So, sing, cry, dance, laugh and live intensely,
before the curtain closes and the piece ends with no applause”*

Charles Chaplin

RESUMO

Os métodos de *Improved* e *Enhanced Oil Recovery* (IOR/EOR) apresentam ampla relevância para garantir melhor eficiência na recuperação de petróleo. O desenvolvimento e aplicação de algoritmos de Inteligência Artificial, por outro lado, tem sido cada vez mais difundido. A partir de algoritmos de *Machine Learning* aplicados a uma base de dados mundial, este trabalho visa observar a dinâmica das variáveis que influenciam nos métodos de IOR/EOR, além de desenvolver uma sistemática de predição (*screening*) dos métodos de IOR/EOR mais adequados para cada campo de produção. Uma base de dados foi contruída totalizando 1035 projetos de IOR/EOR, localizados em 28 países ao redor do mundo, mais de 30 métodos de IOR/EOR e 323 variáveis. A compilação dos dados foi feita a partir de artigos científicos, relatórios de órgãos especializados, além de apresentações para investidores de companhias operadoras, dentre outras fontes. A base de dados resultante, inédita contém seis principais conjuntos de variáveis para cada reservatório: (i) registros de localização; (ii) métodos de recuperação envolvidos; (iii) propriedades geológicas e petrofísicas dos reservatórios; (iv) níveis de maturidade e lucratividade; (v) fator de recuperação e propriedades termodinâmicas; (vi) empresas operadoras e demais particularidades. Após etapas de pré-processamento incluindo uniformização, ajustes e limpeza das variáveis, foram executadas análises por redes neurais artificiais não supervisionadas, a partir de algoritmos de Self-Organizing Maps. Utilizaram-se: as component plots para observar interrelações entre variáveis; a imputação para a predição do método de IOR/EOR mais indicado para os campos de interesse; e a dissimilaridade do seno para obter-se reservatórios análogos. Tal integração de diversas bases de dados dos métodos de IOR/EOR em diferentes regiões do mundo como fonte de treinamento e aprendizado de redes neurais artificiais não supervisionadas é considerado inédito, possibilitando confirmar informações da literatura e trazer insights acerca das aplicações, vantagens e limitações de cada método de IOR/EOR. Os resultados do screening também trazem inovações: foi possível incluir preço do barril de petróleo e, de maneira implícita, fatores como disponibilidade de recursos e aspectos regulatórios, e validar o modelo com casos reais em que aspectos espacialmente próximos aos campos de produção mostraram ser mais relevantes na escolha do método de IOR/EOR do que exclusivamente propriedades petrofísicas dos reservatórios, tornando-se uma ferramenta relevante para embasar e agilizar as tomadas de decisões no desenvolvimento de um campo de produção.

Palavras chave: *Enhanced Oil Recovery; Improved Oil Recovery; Artificial Intelligence; Data Management; Screening.*

ABSTRACT

Enhanced and Enhanced Oil Recovery (IOR/EOR) methods consist of extremely relevant activities to ensure a better oil recovery economy. The development and application of Machine Learning algorithms, on the other hand, has been increasingly widespread. This study presents results from a worldwide integrative reservoir database in which Enhanced/Improved Oil Recovery (EOR/IOR) methods were applied. The goal was to investigate the influence of 323 variables related to EOR/IOR methods, using data from 1035 production oil reservoirs around the world. For this, it was developing a methodology using an artificial intelligence (AI) algorithm capable of screening the most appropriate EOR/IOR methods for each oilfield. The worldwide database integrated different sources with global, regional and local records, containing five sets of variables related to production fields: (i) location records; (ii) recovery methods involved; (iii) geological and core analysis properties of the reservoirs; (iv) levels of maturity, success, and profitability of methods and projects; and (v) recovery factor. Correlation and significance analyzes were used to identify and/or remove inappropriate variables. AI algorithm based on Self-Organizing Maps (SOM) was applied, resulting in maps used to observe the influence and relations of the variables. Cosine similarity was applied for screening EOR/IOR methods based on unidentified reservoir properties. The integration of several EOR/IOR methods from various regions of the world as a training and learning source of AI algorithms is considered an unprecedented approach. The SOM analysis confirmed information already supported by literature regarding reservoir engineering. It also provided insights about applications, advantages, and limitations for each EOR method. Indirect factors as costs, raw material availability and industrial value chain characteristics were contemplated by the spatial variables included on the input data. Screening analysis applied to several case studies suggested the most suitable EOR methods for each reservoir. Because it is a georeferenced database, it was possible to include non-technical aspects in the screening methodology. Raw material availability, onshore/offshore location, environmental, regional, and local issues were indirectly considered using spatial coordinates variables. Real cases in which spatial proximity aspects were used showed to be more relevant in choosing the EOR/IOR method than using only reservoir petrophysical properties without spatial information. The worldwide database and the methodology developed become relevant tools to decision making in reservoirs development. Additionally, variables related to EOR/IOR methods performance applied to the reservoirs represent a complementary information source that can be used in further investigations. An innovative methodology is applied, consisting of the SOM algorithm application to obtain the EOR/IOR screening and interrelation of methods variables. The analyzes made it possible to screen more suitable methods based on both petrophysical and non-technical variables, reinforcing the need to use the spatial variables.

Keywords: *Enhanced Oil Recovery; Improved Oil Recovery; Artificial Intelligence; Data Management; Screening.*

SUMÁRIO

RESUMO	8
ABSTRACT	9
1 INTRODUÇÃO	16
1.1 OBJETIVOS	20
1.1.1 Objetivos Específicos	20
1.2 RELEVÂNCIA DA PESQUISA	21
1.2.1 Quanto à difusão do uso do EOR.....	21
1.2.2 Quanto ao uso de Bases de Dados Integradas em algoritmos de Inteligência Artificial	28
1.2.3 Quanto ao potencial de aplicação de EOR no Brasil.....	28
1.2.1 Quanto à interdisciplinaridade na aplicação de EOR	30
2 REVISÃO BIBLIOGRÁFICA.....	32
2.1 Enhanced Oil Recovery.....	32
2.2 Redes Neurais Artificiais	33
2.2.1 Self Organizing Maps	35
2.3 Medidas de similaridade.....	36
2.4 Screening de métodos de Enhanced Oil Recovery	40
2.4.1 Estado da arte sobre metodologias de <i>screening</i> aplicadas a métodos de EOR.....	40
2.4.2 Softwares e alternativas comerciais de <i>screening</i> de EOR.....	51
3 MATERIAIS E MÉTODOS	53
3.1 Estruturação da Base de Dados.....	55
3.2 Pré-processamento	62
3.2.1 Limpeza.....	62

3.2.2	Gerenciamento de variáveis.....	65
3.3	Processamento e metodologia de análise.....	67
3.3.1	Análise Exploratória	67
3.3.2	Análises por Inteligência Artificial – Self-Organizing Maps.....	68
3.3.3	Interpretações e Validações.....	69
3.3.4	<i>Screening</i> de métodos de EOR.....	70
4	RESULTADOS E DISCUSSÕES.....	72
4.1	Inteligência Artificial: Self-Organizing Maps em abordagem mundial para EOR	78
4.1.1	Interpretação das component plots e da matriz-U.....	79
4.1.2	Métodos térmicos	90
4.1.3	Injeção de gases	96
4.1.4	Injeção de produtos químicos	102
4.2	<i>Screening</i> de métodos de EOR.....	107
4.2.1	Caso 1.1.....	109
4.2.2	Caso 2.1.....	114
4.2.3	Caso 2.2.....	115
4.2.4	Caso 2.3.....	118
4.2.1	Resultados adicionais: influência do preço do barril de petróleo	122
5	CONCLUSÕES.....	123
6	REFERÊNCIAS	131
7	APÊNDICE.....	144

LISTA DE ILUSTRAÇÕES

Figura 1 Diferentes meios possíveis de recuperação de petróleo nas diversas fases de desenvolvimento de um campo de petróleo..	17
Figura 2. Preços do barril de petróleo Brent (nominal e descontada a inflação tendo como base os EUA) e número de papers presentes na base <i>OnePetro</i> relativos a cada categoria de EOR ao longo do tempo. Dados do número de papers foram obtidos apartir dos resultados de pesquisa no <i>OnePetro</i> e os dos preços de barril de petróleo são provenientes de relatório da U.S. Energy Information Administration (2019). O preço descontado a inflação também fora incluído para se obter uma comparação mais justa cenários econômicos distintos.	23
Figura 3. Número de registro de trabalhos relacionados ao tópico " <i>Enhanced Oil Recovery</i> " na base Web of Science, para cada categoria. Verifica-se uma grande interdisciplinarietà em tópicos de pesquisa relacionados ao EOR.	31
Figura 7. Métodos de EOR abordados por coletânea de trabalhos científicos que mais receberam citações nas diferentes bases de científicas e que desenvolveram ou aplicaram metodologias de <i>screening</i> de EOR.	42
Figura 8. Variáveis levadas em conta por coletânea de trabalhos científicos que mais receberam citações nas diferentes bases de científicas e que desenvolveram ou aplicaram metodologias de <i>screening</i> de EOR.	44
Figura 10. Ilustração das principais classes de fontes utilizadas para a constituição da base de dados relativa à implementação de métodos de EOR em escala global.	58
Figura 11. Exemplo de crude oil assay, fornecida pela TOTAL (2019) com principais dados do óleo processado proveniente do campo de <i>Dalia</i> , na Angola....	60
Figura 12. Exemplo de crude oil assay, fornecida pela <i>British Petroleum</i> (2019) com principais dados do óleo processado proveniente do campo de <i>Clair</i> , pertencente ao Reino Unido, no Mar do Norte.....	61
Figura 13. Etapas relativas ao pré-pocessamento da base de dados.	67
Figura 14. Etapas realizadas no processamento e análise dos dados.	68
Figura 15. Logos das principais aplicadoras de projetos de EOR presentes na base de dados. Verifica-se grande diversificação de players no setor no mundo, havendo desde empresas que atuam em escala regional e focadas no upstream,	

especialmente nos EUA, até companhias com reconhecida atuação global e abarcando as diversas etapas da cadeia de valor da indústria de petróleo.	72
Figura 16. Localização dos principais campos de produção de petróleo presentes na base de dados.	73
Figura 17. Ilustração de alguns dos países com projetos de implementação de EOR presentes na base de dados consolidada.	74
Figura 18. Scatterplot de parte do conjunto de variáveis. As amostras em vermelho representam projetos de EOR com alocação como mal sucedida; amostras em azul representam aplicação bem sucedida.	75
Figura 19. Matriz de correlação para intervalo básico de variáveis, selecionadas após limpeza dos dados.	76
Figura 20. Scatterplot de parte do conjunto de variáveis, com transformação log-normal realizada para as distribuições que demonstraram pertinência à sua aplicação (as que iniciam com <i>Log</i> no respectivo nome). Na diagonal, os histogramas são aproximados pela função de densidade kernel. As amostras em azul representam projetos de EOR onshore; as amostras em verde representam projetos de EOR executados em campos offshore.	77
Figura 22. Ilustração exemplificando a leitura e interpretação das component plots.	81
Figura 23. Component plots das variáveis básicas do modelo.	82
Figura 24. Preços do barril de petróleo Brent (nominal e descontada a inflação tendo como base os EUA) e número de projetos de EOR presentes na base de dados consolidada relativos a cada categoria de EOR ao longo do tempo.	84
Figura 25. Participação/porcentagem de <i>marketshare</i> do número de projetos de EOR presentes na base de dados consolidada relativos a cada categoria de EOR ao longo do tempo.	87
Figura 26. <i>Component plots</i> geradas pelo mapa auto-organizado obtido a partir da base de dados após a análise exploratória.	88
Figura 27. Component plots mostrando distribuição dos países (Ct_) e métodos de EOR. Vale ressaltar que as variáveis relativas aos países (Ct_) não foram utilizadas para o treinamento SOM, porém podem ser observadas conjuntamente no mapa auto-organizado, para compreensão em contraste com as demais variáveis	89
Figura 28. Component plots referentes às variáveis analisadas para os métodos térmicos.	91

Figura 29. Mapas das variáveis utilizadas para análise do método de combustão in situ.	95
Figura 30. Components plots que foram analisadas em conjuntos o método de injeção de hidrocarbonetos.	98
Figura 31. Components plots das variáveis com interrelações analisadas junto ao método de injeção de dióxido de carbono.	100
Figura 32. Component plots das variáveis cujas interrelações com os métodos de injeção de polímeros e surfactantes foram analisadas.	104
Figura 33. Exemplo da utilização da similaridade do cosseno para identificação de campos similares e respectivos métodos de EOR aplicados. Cada coluna representa um reservatório na base de dados.	108
Figura 34. Dissimilaridade do seno em relação ao campo do caso 1.1.	110
Figura 35. Dissimilaridade do seno em relação ao campo do caso 2.1.	114
Figura 36. Dissimilaridade do seno em relação ao campo do caso 2.2.	117
Figura 37. Dissimilaridade do seno em relação ao campo do caso 2.3.	119
Figura 38. Principais conclusões gerais e inovações observadas com o desenvolvimento do trabalho.	124
Figura 39. Síntese das principais limitações e desafios encontrados ao longo do desenvolvimento do trabalho, além de melhorias a serem implementadas.	128
Figura 40. Esquema ilustrando possíveis trabalhos futuros e novas abordagens envolvendo a exploração e análises diversas a partir base de dados consolidada acerca de projetos de EOR em escala mundial.	130

LISTA DE TABELAS

Tabela 1. Exemplo mostrando a frequência que cada palavra ocorre em determinados textos. Tal atribuição possui uso similar à determinação de variáveis categóricas para compor a base de dados de métodos de EOR desse trabalho, como litologia (se arenito, arenito inconsolidado, carbonato, calcário, dolomita, etc), método de EOR utilizado (injeção de vapor, surfactante, polímero, etc), nível de sucesso do projeto de EOR, dentre outras.....	38
Tabela 2. Mercado global anual e projeções de vendas de produtos surfactantes voltados para o segmento de EOR..	86
Tabela 3. Principais dutos operantes onshore de dióxido de carbono no mundo, cujo transporte é direcionado principalmente campos de petróleo para aplicação de EOR.	101
Tabela 4. Propriedades de reservatório utilizadas como input pelos artigos e pela imputação SOM.	112
Tabela 5. Ordens de classificações e respectivas pontuações atribuídas a cada método de EOR para cada caso de campo.	113


1 INTRODUÇÃO

A indústria do petróleo teve seu princípio no século XIX, junto à 2ª Revolução Industrial, e atualmente configura-se como uma das mais resilientes do planeta, colocando à prova sua capacidade de se reinventar sob diversas transformações econômicas e geopolíticas do planeta. Hoje, mais do que nunca, com a emergência de fontes alternativas e no contexto da Indústria 4.0, a cadeia produtiva de petróleo busca formas de tornar-se mais competitiva frente a novos desafios, seja por exemplo alcançando novas fronteiras exploratórias em águas ultra profundas e reservas não convencionais, até o enfrentamento de complexidades operacionais e logísticas, bem como o emprego de métodos avançados com o intuito de maximizar a produção de óleo dos reservatórios. Concomitantemente a isso, e conforme aponta o BP Statistical Review of World Energy June 2019, as previsões de desenvolvimento dos países ressaltam a carência de um fornecimento de energia e espera-se que o petróleo seja o principal recurso energético nas próximas décadas, e gás natural como o “combustível do século XXI”, tratando-se assim de uma questão de segurança energética chave no mundo atual. Além disso, em consonância com o que aponta o World Energy Outlook 2017 da International Energy Agency, o crescimento da população mundial e o desenvolvimento calcado na utilização do petróleo como matéria prima, não só como parte fundamental da matriz energética global, mas também como fonte de uma série de produtos que constituem a base da sociedade moderna, promove um consequente aumento na demanda de sua produção.

Nesse contexto, os métodos de recuperação melhorada e avançada de petróleo, ou Improved and Enhanced Oil Recovery (IOR/EOR), atualmente constituem tópicos que se encontram no estado da arte de aplicação em reservatórios, e vêm sendo uma grande oportunidade para promover maior sustentabilidade a campos que deixaram de ser tão produtivos ou economicamente viáveis por métodos convencionais ou com produções declinantes. Nos métodos de Improved Oil Recovery (IOR), também chamados de recuperação secundária, água ou gás natural são injetados nas formações rochosas como meio de se fornecer uma fonte externa de energia ao reservatório. Os métodos de Enhanced Oil Recovery (EOR), por sua vez, conhecidos também por recuperação terciária ou avançada, consistem na extração de petróleo de um campo a partir da injeção de fluidos que não apenas fornecem

energia extra ao reservatório, mas também modificam as propriedades do petróleo e sua interação com a formação rochosa, a fim de extraí-lo de forma mais eficiente (AL-MJENI, 2011). Técnicas de EOR podem extrair de 30% a 60% ou mais do óleo de um reservatório, em comparação com os 20% a 40% obtidos, em geral, a partir recuperação primária e secundária, resultando em uma grande quantidade de petróleo remanescente (HASHEMI-KIASARI et al., 2014; KANG et al., 2014; TAKASSI et al., 2017). De acordo com o Departamento de Energia dos EUA, existem três técnicas principais para EOR: (1) métodos térmicos; (2) injeção de gases; e (3) injeção de produtos químicos. Essas técnicas consistem nos principais meios de prolongar a vida útil dos campos de petróleo e promover um incremento substancial na produção de petróleo, conforme exemplifica a Figura 1. Cada um dos métodos de EOR tende a ser aplicado a determinados tipos de reservatório, não havendo um método que seja globalmente o melhor. O sucesso da implementação desses métodos é dependente tanto das diversas propriedades de rochas e fluidos do reservatório, como também do modelo estrutural, de fatores geográficos, logísticos, econômicos, dentre outros.

Figura 1 Diferentes meios possíveis de recuperação de petróleo nas diversas fases de desenvolvimento de um campo de petróleo. Nota-se uma grande variedade entre os métodos de recuperação terciária, que constituem o EOR e *Improved Oil Recovery* (IOR).



Adaptado de KOKAL (2011)

Em decorrência do grande número de variáveis relevantes na compreensão e seleção de métodos de IOR/EOR para um determinado campo, o advento de ferramentas de Inteligência Artificial (IA) tem se mostrado promissor e eficiente em aplicações na indústria de petróleo e gás (AMINZADEH, 2005). Isso acontece dada a capacidade e versatilidade dos algoritmos de IA em processar dados multidimensionais, complexos e altamente não lineares. Como mencionado por RANSBOTHAM et al. (2017) e LEE (2014) tecnologias disruptivas inerentes à Indústria 4.0 têm se mostrado promissoras na abordagem de tais problemas de uma maneira integrada, oferecendo assim vantagens estratégicas na detecção de padrões, no entendimento de fenômenos complexos e na construção de modelos preditivos e de suporte à tomada de decisão para as empresas.

O advento tecnológico e a computação de alto desempenho promoveram o desenvolvimento de sistemas mais robustos e complexos de Redes Neurais Artificiais RNAs. Adicionalmente, o aumento da capacidade de processamento de dados, tanto em CPU's, que se caracterizam por processamento sequencial, quanto em GPU's, próprias para processamento paralelo, propiciaram um momento favorável ao desenvolvimento de pesquisas que relacionam variáveis de forma não linear. Diversos métodos baseados em IA possibilitam o aperfeiçoamento do processo de interpretação, a partir da atribuição de parâmetros sistemáticos e semiautomáticos. São exemplos de técnicas de inteligência artificial os algoritmos de *machine learning*, capazes de prover treinamento e aprendizagem a partir de amplas bases de dados (*big data*), com a finalidade de segmentar e classificar grupamentos com base na similaridade entre padrões de amostras, ou mesmo predizer parâmetros em regiões espúrias ou com dados ausentes. Dentre as técnicas de *machine learning*, as redes neurais artificiais, sejam estas supervisionadas ou não supervisionadas, demonstram amplas possibilidades de aplicação na solução de tais problemas. O método Mapas Auto-Organizáveis, do inglês *Self-Organizing Maps* (SOM) (KOHONEN, 2001) consiste em uma técnica com abordagem não-supervisionada que utiliza a quantização vetorial em um espaço n-dimensional, para estabelecer relações topológicas e topográficas projetadas em um mapa, a partir de medidas do vetor similaridade. Para isso, o método adota elementos matemáticos como a unidade de melhor ajuste (BMU, do inglês, *best matching unit*) e a aprendizagem competitiva, o que proporciona a redução de dimensionalidade do espaço n-vetorial das variáveis

consideradas no problema. O método destaca-se por ser uma abordagem guiada pelo dado, o que possibilita estabelecer três principais vantagens, a saber: (i) identificação de relações de similaridade entre agrupamentos de dados; (ii) análise visual de fácil compreensão na forma de mapas do espaço multidimensional estudado; e (iii) identificação e individualização de padrões, observando constituição, geometria e abrangência das classes geradas, o que a torna eficiente na análise de conjuntos de dados de alta dimensionalidade.

Somado a isso, é crescente a quantidade de artigos científicos e relatórios confiáveis elaborados por consultorias e órgãos administrativos de vários países voltados para segurança energética. Estes trabalhos costumam conter dados, ainda que esparsos e de maneira não estruturada, acerca de métodos de recuperação de petróleo. Tais bases de dados, além de reunirem informações sobre campos e métodos mais tradicionais de EOR, como injeção de vapor e injeção de hidrocarboneto em reservatórios convencionais, por vezes também disponibilizam informações sobre novas tecnologias, a exemplo do *Low Salinity Waterflooding* (LSWF). Além disso, algumas bases de dados disponibilizam informações sobre a aplicação de IOR/EOR em novas fronteiras exploratórias, tais como águas ultra profundas e reservatórios não convencionais, a exemplo de campos do *Shale Gas/Shale Oil* nos EUA. Ainda que em diferentes formatos, bastante fragmentados e dispersos, essas diferentes fontes de dados, com o devido tratamento e processamento, possuem amplo potencial informativo. Estas informações reunidas possibilitam a construção de uma base de dados mundial, abrangente e confiável, com relevantes informações sobre EOR, capaz de promover estudos dirigidos utilizando técnicas avançadas de análises, envolvendo as abordagens por Inteligência Artificial.

Dada a relevância do desenvolvimento dos métodos de IOR/EOR para se potencializar a produção de petróleo e da IA como uma vantagem potencialmente estratégica na análise e resolução de problemas complexos, é então pertinente a convergência de ambas as técnicas disruptivas na avaliação de amplos bancos de dados de EOR (BRAVO et al., 2012). Essa abordagem integrada proporciona novas perspectivas de investigação. Assim, busca-se não apenas investigar relações das diversas variáveis com a eficiência dos tratamentos de IOR/EOR, mas também desenvolver um sistema inteligente de triagem de IOR/EOR e de suporte à decisão no desenvolvimento de campos de petróleo.

A complexidade da aplicação dos métodos de IOR/EOR e a possibilidade de se integrar diferentes bases de dados, formando um banco de dados global e coeso, consistem em elementos que proporcionam alcançar um melhor entendimento acerca dos métodos de recuperação. Além disso, torna-se possível desenvolver uma rotina sistemática de seleção (*screening*) do método de EOR mais adequado, a partir do uso de estratégias computacionais, que auxiliam na interpretação de dados e nas tomadas de decisões, diminuindo riscos e incertezas associados, e proporcionando a maximização do fator de recuperação e eficiência operacional.

1.1 OBJETIVOS

Como objetivo principal, esta pesquisa visa analisar, selecionar e prever parâmetros e métodos de recuperação mais adequados para cada campo de produção, tomando como base projetos reais da aplicação de IOR/EOR em escala mundial, integrados a partir de uma base de dados única, processada por algoritmos de Inteligência Artificial.

1.1.1 Objetivos Específicos

- I. Identificar relações diretas ou indiretas entre propriedades petrofísicas, fatores econômicos e do fator de recuperação de petróleo para os diferentes métodos de EOR, ampliando a análise da dinâmica de reservatórios;
- II. Buscar possíveis particularidades de classes de métodos de EOR, a saber: térmicos, injeção de gases, químicos e outros;
- III. Compreender, via abordagem orientada pelos dados (*data-driven*), a aplicabilidade, limitações e potencial estratégico de desenvolvimento de cada método de EOR, realizando uma ampla e efetiva comparação entre as diferentes técnicas de recuperação de petróleo;
- IV. Estruturar uma rotina sistemática baseada em IA, capaz de desenvolver *screening* e predição sobre método de EOR mais adequado, para orientar à tomada de decisão relacionada a cada tipo de reservatório de interesse.

1.2 RELEVÂNCIA DA PESQUISA

1.2.1 Quanto à difusão do uso do EOR

A busca por alternativas que permitam uma melhor eficiência no processo de produção do petróleo cresce à medida em que aumenta a sua respectiva demanda. Da mesma maneira, buscam-se alternativas para aumento da recuperação de petróleo em campos maduros, à medida em que diminuem as reservas de petróleo *onshore* e de margem continental. Ao longo do ciclo de vida de um campo, os reservatórios perdem a capacidade de produzir óleo naturalmente, por meio de sua energia primária, o que acarreta em considerável quantidade de óleo não recuperado. Outrossim, parte do petróleo produzido no mundo vem de campos de petróleo maduros, que estão na segunda metade de seus ciclos de produção e, em muitos casos, a descoberta e exploração de novas reservas pode ser dispendiosa e demorada. Conforme afirmam ALVARADO & MANRIQUE (2010), dos cerca de 3 trilhões de barris de petróleo conhecidos em reservatórios convencionais, cerca de menos de um terço foi produzido e consumido no mundo desde o início da exploração e produção de petróleo. Espera-se que um terço adicional do petróleo existente seja produzido por técnicas além das atividades tradicionais de petróleo e gás. Dentre essas técnicas, despontam os métodos de EOR que, apesar da demanda de investimentos, são comercialmente viáveis.

De acordo com KOKAL & ABDULAZIZAL-KAABI (2010), a dinâmica que governa a eficiência dos métodos de EOR é, todavia, complexa e demonstra ser desafiadora, tanto tecnicamente como economicamente, exigindo a avaliação de uma ampla gama de parâmetros. Devido a fatores como a alta sensibilidade técnica, o elevado custo envolvido, a dependência de fatores externos e a complexidade de análise, têm-se buscado novos meios de realizar a seleção dos métodos de EOR mais adequados para cada reservatório. É frequente nas empresas, no entanto, um dilema entre concentrar investimentos na exploração, com o propósito de encontrar novos campos de petróleo, ou aplicar métodos de EOR a campos já maduros. Somado a isso, muitas vezes as incertezas geológicas e econômicas associadas à exploração de novos campos costumam ser muito elevadas. Em campos maduros, o conhecimento acerca do comportamento dos respectivos reservatórios tende a possibilitar a aplicação de EOR com menores incertezas, diminuindo os riscos financeiros e ambientais associados. Contudo, muitas empresas tendem a não aplicar


métodos avançados de recuperação em reservatórios que, em princípio, possuiriam grandes potenciais de ganhos. Historicamente, a implementação de métodos EOR era por parte das operadoras uma tomada de decisão tardia, considerada apenas quando a produção proveniente de métodos de recuperação primários e secundários já encontravam-se exauridos. Alguns fatores podem contribuir para que as companhias não utilizem os métodos de EOR como prática comum, a saber: (i) complexidade dos fenômenos envolvidos; (ii) ausência de conhecimento técnico especializado; (iii) demanda por pesquisa e estudos mais detalhados acerca da aplicação das tecnologias de EOR no portfólio de reservatórios da empresa; e (iv) possibilidade de explorar novas reservas com *paybacks* menores, (v) a falta de recomendações específicas de possíveis métodos de EOR candidatos à aplicação, dentre outros fatores. Hoje em dia, a maioria dos campos de produção no mundo apresentam curvas de produções em declínio. Nesse cenário, as longas investigações tradicionais de EOR não se encaixam no fluxo de trabalho da economia moderna em ampla variedade de campos. O fato é que, para atingir o fator de recuperação máximo, torna-se necessário o planejamento da aplicação de EOR nos estágios iniciais de desenvolvimento de um campo, bem como monitorar os eventos à medida em que estes acontecem, para maior controle e otimização do resultado (SCHLUMBERGER, 2019).

Segundo ALVARADO & MANRIQUE (2010), a falta de equipes de engenheiros e geocientistas pode estar associada ao colapso do preço do petróleo nos anos 80 e 90 e à eliminação progressiva de centros de pesquisa e desenvolvimento nas principais empresas de petróleos. Conforme pode-se observar na [figura 2](#), que relaciona o número de *papers* presentes na base *OnePetro* relativos a cada categoria de EOR com o preço de petróleo, de maneira geral, verifica-se, especialmente até os anos 2010, uma tendência de aumentos/reduções no preço de petróleo estarem possivelmente associados com elevação/quedas nos anos subsequentes do número de papers sobre cada método de EOR. É possível observar ainda certa latência, ou tempo de resposta, para um aumento no preço do petróleo acarretar em um aumento no número de trabalhos científicos acerca dos métodos de EOR, o que corrobora a influência do preço do petróleo no desenvolvimento das técnicas de EOR nas décadas supracitadas. Tal estado, influenciado pela constante e, por vezes, brusca variação do preço do petróleo, impactou fortemente a tomada de decisões para uso de EOR

nas últimas duas décadas. Isso ocasionou em perdas de janelas de oportunidades, sobretudo quando se trata de aumentar a recuperação de petróleo. Contudo, especialmente a partir de 2011, nota-se que apesar da queda do preço do petróleo e de reduções temporárias no número de trabalhos científicos, o número de trabalhos científicos continuou elevado. Tal fato pode estar associado, dentre outros fatores, com: (i) o prognóstico de previsões de aumento futuro do preço do petróleo; (ii) crescentes investimentos em pesquisa na área por parte de muitas empresas operadoras que enxergam um horizonte propício para a aplicação de EOR; interesse de órgãos governamentais, vislumbrando meios de garantir segurança energética de suas nações; e surgimento de novas fronteiras exploratórias como Shale Gas e Pré-Sal que vem se mostrando como potenciais categorias de reservas para a implementação de métodos de EOR.

Figura 2. Preços do barril de petróleo Brent (nominal e descontada a inflação tendo como base os EUA) e número de papers presentes na base OnePetro relativos a cada categoria de EOR ao longo do tempo. Dados do número de papers foram obtidos apartir dos resultados de pesquisa no OnePetro e os dos preços de barril de petróleo são provenientes de relatório da U.S. Energy Information Administration (2019). O

preço descontado a inflação também fora incluído para se obter uma comparação mais justa cenários econômicos distintos*.



(Autoria Própria)

* Em economia, o valor nominal é medido em termos de dinheiro, enquanto o valor real é medido em relação à valoração de bens ou serviços. Um valor real é aquele que foi ajustado pela inflação, permitindo a comparação de quantidades como se os preços dos bens não tivessem mudado em média. Alterações no valor em termos reais, portanto, incluem o efeito da inflação. Em contraste com um valor real, um valor nominal não foi ajustado pela inflação e, portanto, as mudanças no valor nominal refletem pelo menos em parte o efeito da inflação. Os Preços Reais do Petróleo são calculados dividindo o preço nominal em um determinado mês pela razão do Índice de Preços ao Consumidor (IPC) naquele mês para o IPC em algum período "base". Conseqüentemente, todos os preços reais são expressos em dólares "atuais" e qualquer preço do ano atual pode ser comparado diretamente com quaisquer preços reais projetados ou passados. Dessa forma, o preço real do petróleo permite uma comparação mais justa entre projetos de EOR feitos em dados e cenários políticos-econômicos diferentes.

*distintos**.

A utilização de EOR, atualmente, ainda é pouco expressiva globalmente, com cerca de 4 a 6% da produção mundial de petróleo (FAROUQ, 2012; KOKAL & KAABI, 2010). No entanto, conforme mostra o gráfico da [Figura 2](#), nas últimas décadas a aplicação de EOR tem apresentado crescimento elevado em projetos, tanto em pilotos quanto em campos em pleno desenvolvimento. Motivados também por uma questão de segurança energética de recursos minerais, diversos países passaram a adotar incentivos fiscais para se melhorar a recuperação e estender a vida útil de reservas já depletadas, maduras ou marginais, como por exemplo nos EUA, países do Mar do Norte e Argentina (BUCKNER, 1994; HUSTAD & AUSTELL, 2004; CROOKS, 2008). Torna-se evidente, então, o potencial de crescimento dessas aplicações, tanto com o uso de métodos de EOR já consolidados no mercado, quanto devido à inovação e criação de novas tecnologias de recuperação (TABER et al., 1997; MASHAYEKHIZADEH et al., 2014).

Observa-se, atualmente, uma tendência de se avaliar possíveis implementações de métodos de EOR desde os estágios iniciais da produção. Essa tendência possibilita o desenvolvimento do campo alinhado com perspectivas de longo prazo e maximização do retorno sobre o investimento. As instalações de produção (*offshore* ou *onshore*) tem sido projetadas levando em consideração um horizonte aplicações dos métodos de EOR ao longo do ciclo de vida do campo, e demandam tecnologias e equipamentos específicos. Da mesma forma, o planejamento da aplicação de EOR o mais cedo possível permite a otimização da logística e do fornecimento de insumos futuros necessários para os diversos mecanismos de injeção no reservatório.

No início do ciclo de vida de um campo de produção as informações disponíveis acerca das características dos reservatórios costumam ser escassas, tornando muitas vezes inviável realizar estudos envolvendo simulação de reservatórios e análises detalhadas que envolvam aspectos referentes a logística e aspectos regulatórios. Além disso, muitas empresas de pequeno a médio porte por vezes não dominam o conhecimento necessário para realizar uma análise holística e breve sobre os fatores envolvidos para a aplicação do EOR. Estas empresas por vezes são operadoras, prestadoras de serviços, distribuidoras e fabricantes de uma variedade de equipamentos e produtos químicos, e outros *stakeholders*, inseridas em tal cadeia de

valor, interessados em saber sobre a viabilidade da aplicação de EOR em uma determinada região, porém limitadas pelo custo envolvido para desenvolver o estudo específico.

Ao longo da exploração e desenvolvimento de um campo cada informação adicional obtida é utilizada para se melhorar as probabilidades das projeções. Engenheiros de reservatórios estão em uma posição única, uma vez que a maioria dos reservatórios estão em profundidades de milhares de pés e suas características e comportamento não podem ser observados diretamente. Esses reservatórios só podem ser sondados e amostrados de forma muito limitada e, conseqüentemente, seus comportamentos devem ser conceituados e preditos de alguma forma. A situação é ainda mais complicada pelo fato de que muito pouco se sabe sobre um reservatório em sua descoberta, a fim de desenvolvê-lo da maneira mais eficiente. Uma grande quantidade de produção e outros dados relacionados ao reservatório só está disponível em fases posteriores, quando as reservas parcialmente produzidas e as condições termodinâmicas já não são mais iguais às iniciais. Como apontado, a recuperação final da maioria dos reservatórios de petróleo é, em geral, bastante limitada. No entanto, a coleta de dados no início do desenvolvimento de campo é enfatizada por profissionais experientes, uma vez que podem ser identificados campos semelhantes em outras regiões do mundo com desafios parecidos. Dessa forma, "lições aprendidas" no desenvolvimento de campos análogos ao redor do mundo podem ser incorporadas no processo de decisão em fases posteriores.

Conforme MASHAYEKHIZADEH et al. (2014) e BOURDAROT & GHEDA (2011), o sucesso da implementação de qualquer projeto de EOR é considerado dependente de uma ampla gama de variáveis. Além disso, embora os desafios relacionados ao desenvolvimento de cada campo possam apresentar características gerais de natureza similar e o uso de casos semelhantes auxilie e muito na agilidade do processo de decisão, nenhuma solução única funciona perfeitamente para todos os reservatórios. Cada reservatório é único em seu caráter e desempenho, e precisa ser avaliado individualmente. Em decorrência disso, a avaliação completa da escala de campo de um projeto EOR é uma tarefa muito dispendiosa e demorada. Dessa forma, um eficiente trabalho de seleção do melhor método EOR para um determinado reservatório baseado em dados reais pode reduzir o custo computacional, além de

economizar tempo de recursos humanos qualificados na execução e planejamento de simulações e ajustes de histórico.

Uma possível abordagem para tal processo de triagem de métodos de EOR seria por meio do estudo, caso a caso, de projetos anteriormente desenvolvidos (GHARBI & GARROUCH, 2001; MORENO et al., 2014). Isso demandaria a confecção de planilhas de critérios ou a construção de metodologias baseadas na ponderação de diferentes fatores para seleção do método de EOR. Estes formatos de triagem de EOR, contudo, apresentam limitações, especialmente nas seguintes condições: (i) casos pouco explorados, onde o conhecimento à priori é reduzido; (ii) quando o número de variáveis é grande e suas relações são altamente complexas; e (iii) quando a dinâmica dos reservatórios muda significativamente ao longo da produção de um campo, exigindo constantes atualizações.

Conforme ilustram ALVARADO & MANRIQUE (2010), uma conclusão ingênua comum, geralmente resultante de decisões financeiras pouco estruturadas, é adiar os projetos de EOR até que o limite econômico da recuperação primária ou secundária seja atingido. Esse tipo de tomada de decisão pressupõe que condições favoráveis ou não para o processo de EOR encontradas em um reservatório, em determinado momento, prevalecerão pelo resto do ciclo de vida produtivo do campo, além de levar a perdas relativas ao intervalo específico de oportunidade. Um exemplo ilustrativo é perda de pressão que ocorre no reservatório, processo análogo ao de abrir uma garrafa de refrigerante com escape do gás e “perda” do potencial dessa energia.

Torna-se necessário, portanto, o uso de uma sistemática que permita certa flexibilidade tanto em relação às possibilidades de soluções viáveis oferecidas, como em relação a sua evolução dinâmica com o tempo. Se o processo de seleção for executado uma vez e nunca revisado à medida que os reservatórios mudam suas condições físicas e termodinâmicas, a triagem pode apresentar uma data limitada em que é válida. Dessa forma, torna-se relevante o conhecimento global dos métodos de EOR comparativamente, um com o outro, além das particularidades de cada classe de método de EOR e o desenvolvimento de rotinas flexíveis que auxiliem na tomada de decisão acerca do desenvolvimento de um campo de petróleo.

1.2.2 Quanto ao uso de Bases de Dados Integradas em algoritmos de Inteligência Artificial

PEDERSEN et al. (2006) discutem e comparam os processos de tomada de decisão quantitativos e qualitativos, bem como a abordagem de questões delicadas, mas importantes na análise e tomada de decisão de projetos de EOR. Os profissionais relativos à engenharia de reservatórios concentram-se na análise quantitativa dos mecanismos de produção e na avaliação de reservas e desempenho (simulação de reservatórios), entre muitas outras tarefas analíticas. Desse modo, a tomada de decisão se baseia em aspectos quantificáveis de um determinado problema, como o Valor Presente Líquido do projeto, para que decisões racionais possam ser tomadas. As maiores dificuldades surgem quando questões não quantificáveis se tornam parte do problema de decisão. As considerações sociais e ambientais, por exemplo, geralmente se apresentam como aspectos qualitativos de um problema, que podem ser difíceis de se colocar em termos quantificáveis. Para a aplicação dos métodos de EOR, fatores como fontes de matérias-primas (por exemplo, água, gás e produtos químicos para injeção), descarte de subprodutos ou resíduos, e a proximidade de fornecedores de equipamentos e insumos e de prestadores de serviço especializados, constituem um grupo de variáveis que, muitas vezes, apresentam sua quantificação limitada. Conforme ALVARADO & MANRIQUE (2010), construir um modelo de decisão que se concentre nos critérios relevantes é um pré-requisito para o sucesso do modelo. Porém, outros indicadores ou formas de se avaliar devem ser utilizados para problemas difíceis de se quantificar. Dessa forma, a criação de uma metodologia de análise e predição que apresente um equilíbrio e alie variáveis qualitativas e quantitativas, é um aspecto importante e que pode ser de substancial valia.

1.2.3 Quanto ao potencial de aplicação de EOR no Brasil

Dentre as novas fronteiras exploratórias brasileiras, a Bacia de Santos destaca-se por ser a maior bacia sedimentar offshore do Brasil, com área total superior a 350.000 km² que se estende de Cabo Frio (RJ) a Florianópolis (SC) (Moreira, 2007). Segundo informações do Plano de Negócios e Gestão da Petrobras para o quinquênio


2017-2021, a média de produção diária da camada Pré-sal foi de 1.456 barris por dia em janeiro de 2019, em que nos últimos 60 meses a produção média de óleo do Brasil cresceu 28%, resultado do acréscimo de 310% da produção do Pré-sal e retração de 31% da produção do Pós-sal (PETROBRAS, 2019). Dentre os campos existentes na Bacia de Santos, o campo de Libra, primeiro campo leilado sob a regra da partilha da produção no Pré-sal, possui um volume recuperável de óleo estimado entre 9 e 15 bilhões de barris. Apesar de Libra estar no início do desenvolvimento produtivo, já estão sendo aplicadas técnicas especiais de recuperação de petróleo. Se tomada a estimativa mais conservadora (9 bilhões), conseguindo um incremento de 1% no fator de recuperação, e considerando 60 dólares o preço médio do barril, haverá um aumento da receita bruta do consórcio em mais de USD 5 bilhões.

Somada ao potencial produtivo do Pré-sal, há também uma significativa quantidade de campos com produções declinantes ou desativados no Brasil. Estes campos ainda possuem substancial quantidade de óleo passível de ser recuperado, especialmente nas bacias sedimentares *onshore*, em sua maioria localizadas na região Nordeste do país. Com o intuito de incentivar a produção em campos maduros o governo federal brasileiro lançou o Programa de Revitalização das Atividades de Exploração e Produção de Petróleo e Gás Natural em Áreas Terrestres (REATE 2020), com incentivos fiscais para a produção em campos maduros (FAVARO, 2019). O programa visa a revitalização do setor que pode ser um importante vetor do desenvolvimento regional, viabilizando uma indústria onshore competitiva, com produção crescente e com estímulo à criação de empresas nacionais, incluindo as startups (empresas de base tecnológica) e a atração de investimentos estrangeiros, levando uma pluralidade de operadores e diversidade de fornecedores de produtos e serviços (MINISTÉRIO DE MINAS E ENERGIA, 2019). Além disso, e diante da necessidade de revitalizar a produção em campos maduros, o CNPE (Conselho Nacional de Política Energética), por meio da resolução 17/2017 delegou à ANP conceder redução de royalties, de 10% para até 5%, sobre a produção incremental dos campos - mediante pedido da empresa operadora e comprovado o benefício econômico para os entes federados (DELGADO, 2019).

1.2.1 Quanto à interdisciplinaridade na aplicação de EOR

O estudo e a aplicação de tópicos relacionados aos métodos de EOR costumam envolver diversas áreas da ciência, como ilustra a [Figura 3](#). Além disso, conforme afirma SHENG (2013), o planejamento, condução e a execução de um projeto de EOR requer especialistas e experiência em diferentes disciplinas. De forma realista, um grupo de especialistas em métodos de EOR pode não estar prontamente disponível em uma companhia, e ainda que esse grupo de especialistas esteja disponível, eles podem ter experiência limitada em enfrentar desafios especiais em um projeto específico. Como o desenvolvimento de projetos de EOR costuma envolver custos da ordem de dezenas milhões de dólares ou mais, a experiência necessária pode não ser totalmente obtida via livros didáticos, podendo ser interessante uma abordagem suporta pela experiência de projetos de campo reais. Além disso, uma consideração adicional importante na tomada de decisão relativa ao desenvolvimento de campos de petróleo é o viés cognitivo, que pode assumir várias formas, uma das quais representando as limitações cognitivas da mente humana (WELSH et al., 2005; BEGG et al., 2003). Para mitigar tal viés cognitivo, existem diversas abordagens, dentre as quais a baseada em dados coletados acerca da implementação de projetos de EOR no mundo. Nesse contexto, estratégias orientadas por dados podem ser utilizadas como parte do processo de suporte à tomada de decisão. Dessa forma, ao invés de depender somente do conhecimento e das experiências sobre os campos de produção advindos de apenas alguns especialistas, inúmeros conhecimentos e diversas experiências podem ser incorporados ao problema de decisão.

Figura 3. Número de registro de trabalhos relacionados ao tópico "*Enhanced Oil Recovery*" na base Web of Science, para cada categoria. Verifica-se uma grande interdisciplinariedade em tópicos de pesquisa relacionados ao EOR.



Dados provenientes da plataforma Web of Science.

Dada a relevância dos métodos de EOR como tecnologia para se potencializar a produção de petróleo, e da IA como uma vantagem estratégica na análise e resolução de problemas complexos, é então pertinente a convergência de ambas as técnicas na avaliação de amplos bancos de dados de EOR por meio de novas perspectivas. Essa integração proporciona a investigação das relações de diversas variáveis com a eficiência dos tratamentos de EOR. Além disso, com o advento de uma sistemática integrativa, torna-se viável o suporte à decisão na produção de campos de petróleo de interesse, tais como os da bacia de Santos e de campos (Pré-Sal e Pós-Sal), cuja aplicação de métodos EOR apresenta-se em latentes perspectivas de maior aproveitamento de suas reservas.

2 REVISÃO BIBLIOGRÁFICA

2.1 *Enhanced Oil Recovery*

As reservas de hidrocarbonetos possuem, originalmente, uma determinada quantidade de energia denominada energia primária ou natural, decorrente das temperaturas e pressões reinantes no reservatório, aliada a certas características geológicas. Tal energia primária é responsável pela produção inicial de petróleo de um dado reservatório. Contudo, nesse processo ocorre uma dissipação de parte dessa energia, causada pela descompressão dos fluidos do reservatório e pelas resistências encontradas ao fluírem em direção aos poços de produção, associadas às forças viscosas e capilares presentes no meio poroso, o que acarreta em uma redução da pressão do reservatório durante sua vida produtiva e, conseqüentemente, decréscimo da produtividade dos poços.

Segundo MEEHAN, (2011), há três principais linhas de ação por meio das quais métodos de EOR podem reduzir ou mitigar os efeitos da dissipação de energia primária e promover recuperação do óleo presente no reservatório:

- a) Métodos térmicos, via fornecimento de calor ao reservatório, de forma que se possa principalmente reduzir a viscosidade do óleo e favorecer o seu escoamento. Dentre eles, são incluídos: a injeção de vapor contínua, injeção de vapor alternada ou cíclica, injeção de vapor assistida pela gravidade, aquecimento eletromagnético, combustão *in situ*, dentre outros.
- b) Injeção de fluidos, como água, hidrocarbonetos (especialmente metano, etano e componentes mais leves), dióxido de carbono, nitrogênio, gases de combustão, dentre outros, com o intuito de manter a pressão do reservatório no intuito e promover o deslocamento do óleo e/ou gás. Tais processos podem ser contínuos ou alternados, havendo ainda variações quanto à miscibilidade do fluido injetado com óleo do reservatório
- c) Injeção de produtos químicos, com o objetivo de alterar propriedades reológicas e/ou físico-químicas do sistema, dentre os quais destacam-se injeção de surfactante, polímero, géis, dentre outros, havendo ainda a possibilidade de combinação dentre eles.

2.2 Redes Neurais Artificiais

TEAHAN (2010) definiu que a Inteligência Artificial é o estudo do desenvolvimento de sistemas computacionais que exibam alguma forma de inteligência, frequentemente associados à capacidade de máquinas (ou computadores) mimetizar funções "cognitivas" naturalmente humanas ou biológicas, como "aprendizado", "solução de problemas", "evolução", dentro outros. Para o autor, a IA resultou em muitos avanços na ciência da computação, levando ao desenvolvimento de áreas como: redes neurais artificiais (RNA's), computação evolucionária, aprendizado de máquinas, processamento de linguagem natural, dentre outros.

A Inteligência Artificial é tradicionalmente definida como uma área da computação que dispõe de algoritmos (sequência de regras e procedimentos), capazes de simular o raciocínio humano e, essencialmente, perceber informações do entorno, além de tomar decisões e ações que permitam melhorar o sucesso de uma tarefa desempenhada, tudo isso em um formato simplificado de como um sistema biológico faz, como por exemplo o cérebro. RUSSELL & NORVIG (1995) relatam que os conceitos originais de Inteligência Artificial tiveram abordagens diversas ao longo das últimas décadas, mas sempre evocando a capacidade de desenvolver raciocínio ou mesmo ação baseado em aprendizado. O [Quadro 1](#) traz algumas das principais definições de Inteligência Artificial.

Quadro 1- Definições originais de IA sintetizadas em quatro categorias principais (traduzido de RUSSELL & NORVIG, 1995).

"O novo e excitante esforço para fazer os computadores pensarem... máquinas com mentes, no sentido pleno e literal" (HAUGELAND, 1985)	"O estudo das faculdades mentais através do uso de modelos computacionais" (CHARNIAK E MCDERMOTT, 1985)
"[A automação de] atividades que associamos ao pensamento humano, atividades como tomadas de decisões, resolução de problemas, aprendizado ..." (BELLMAN, 1978)	"O estudo das computações que possibilitam perceber, raciocinar e agir" (WINSTON, 1992)

"A arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas" (KURZWEIL, 1990)	"Um campo de estudo que procura explicar e emular o comportamento inteligente em termos de processos computacionais" (SCHALKOFF, 1990)
"O estudo de como fazer computadores fazer coisas em que, no momento, as pessoas são melhores" (RICH E KNIGHT, 1991)	"O ramo da ciência da computação que se preocupa com a automação do comportamento inteligente" (LUGER E STUBBLEFIELD, 1993)

Definições de AI acima, organizados em quatro categorias:

Sistemas que pensam como humanos.	Sistemas que pensam racionalmente.
Sistemas que agem como seres humanos.	Sistemas que agem racionalmente.

Em relação às ferramentas de IA, as Redes Neurais Artificiais (RNA's) destacam-se por consistirem em modelos matemáticos e computacionais bioinspirados no sistema nervoso central de um animal. As RNAs são sistemas artificiais paralelos distribuídos e bioinspirados no funcionamento do cérebro humano. São compostas por unidades de processamento simples, denominadas neurônios artificiais, que calculam e associam determinadas funções matemáticas, normalmente não-lineares, conforme o ajustamento iterativo de pesos associados a esses parâmetros que armazenam o conhecimento adquirido para o modelo, de acordo com as variáveis de entrada. Dessa forma, as RNAs se assemelham ao cérebro em dois aspectos principais: (i) conhecimento é adquirido através do processo de aprendizagem; (ii) forças de conexão entre os neurônios (sinapses-pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido. Tal característica permite às RNAs benefícios como (a) não-linearidade, (b) adaptabilidade, (c) informação contextual, (d) tolerância a falhas, (e) uniformidade de análise e projeto, dentre outros (HAYKIN, 1999).

Dentre os tipos de RNAs existentes, uma importante característica de classificação entre variedades de redes se dá pelo formato de aprendizagem. Quando a aprendizagem é realizada de maneira supervisionada, no treinamento prévio um agente externo indica à rede a resposta desejada para o padrão de entrada, em que a saída desejada é conhecida e informada para que a rede compare com a saída processada. Se houver erro, a rede busca corrigi-lo até que forneça uma saída igual

a saída desejada. Já na aprendizagem não supervisionada, não há saída informada para comparação, e a rede atualiza seus pesos a partir de iterações, sem o uso de pares entrada-saídas desejadas. Nesse âmbito, RNA's não supervisionadas possuem capacidade de organizar dados multidimensionais complexos em clusters, mantendo e evidenciando relações de similaridade e dissimilaridade, mostrando-se ideal para problemas onde os padrões são desconhecidos ou indeterminados.

2.2.1 Self Organizing Maps


No âmbito das RNA's, os Self-Organizing Maps (SOM) consistem em uma técnica de classificação com abordagem não-supervisionada que utiliza a quantização vetorial em um espaço n-dimensional e que foi introduzida pelo professor finlandês Teuvo Kohonen na década de 1980. (KOHONEN 2001; FESSANT & MIDENET 2002; KALTEH et al., 2008; WANG 2003).

Os SOM são uma abstração computacional, baseada em modelos biológicos de sistemas neurais e na especialização das diferentes regiões do cérebro humano em suas respectivas funções. O objetivo do aprendizado nos mapas auto-organizados é então fazer com que diferentes grupos de neurônios artificiais da rede respondam de maneira semelhante se especializem em processar e interpretar determinados padrões de entrada, de maneira análoga a como as informações visuais, auditivas ou outras informações sensoriais são tratadas em partes separadas do córtex cerebral no cérebro humano.

Conforme Haykin (2008), os mapas auto-organizáveis diferem de outras redes neurais artificiais não apenas por aplicarem aprendizado competitivo, em que os neurônios vencedores são os que apresentam maior representatividade no conjunto de um cluster. Estas redes também diferem em relação ao aprendizado de correção de erros (como *backpropagation*), por utilizar uma função de vizinhança com o intuito de preservar as propriedades topológicas do espaço de entrada. Além disso, processos essenciais no ambiente dos SOM incluem também a cooperação. Neste caso, o neurônio vencedor determina a localização espacial e cooperação com uma vizinhança topológica de neurônios excitados, influenciada pelo raio de vizinhança, que inicialmente é grande e tende a decrescer em função de distância de base radial, levando à ordenação topológica e à convergência. Na sequência ocorre a adaptação

sináptica, onde neurônios excitados atualizam a cada iteração o seus valores individuais através de ajustes adequados aos seus pesos sinápticos.

Figura 4. Representação da transformação de um conjunto de vetores n-dimensionais em mapas com dimensionalidade reduzida, com a preservação das relações topológicas e topográficas e de similaridade. Além disso, nota-se a equivalência existente as diferentes formas de representação dos dados no espaço n-dimensional.



Tais características atribuem aos SOM a propriedade de transformar um conjunto multidimensional em bidimensional, preservando relações topológicas e topográficas. Isso possibilita a avaliação da similaridade das relações existentes entre vetores de entrada, tendo-se como resultado um conjunto das características do espaço de entrada, possibilitando visualizações de baixa dimensão de conjuntos de dados com grandes números de variáveis, conforme ilustra a [Figura 4](#). Além disso, a adição de elementos ao novo mapa se dá de tal forma que os conjuntos de dados similares sejam posicionados topologicamente próximos uns dos outros, conforme suas interrelações de similaridade ou dissimilaridade sejam preservadas.

2.3 Medidas de similaridade

Antes de comprometer recursos para um grande projeto de desenvolvimento de EOR, é essencial estimar a resposta do reservatório ao longo do tempo. Um método de prever a resposta do reservatório é o estudo de reservatórios com propriedades geológicas, petrofísicas e de fluido semelhantes em que foram aplicados métodos de

EOR anteriormente. A modelagem via simulações numéricas pode fazer um excelente trabalho na previsão da resposta do reservatório, mas é totalmente dependente das informações e suposições usadas e requer tempo, recursos humanos e computacionais para ser realizada. Além disso, em muitos casos dados insuficientes impedem uma modelagem adequada. Predições orientadas por dados e reservatórios análogos, por outro lado, podem ser ferramentas de grande valia para se contornar tais limitações. Em especial o estudo de reservatórios análogos permite identificar quais foram os principais desafios presentes em campos com características semelhantes e acelerar o fluxo de trabalho.

A medida de similaridade em um contexto de mineração de dados é uma distância cuja dimensão representa o quão diferentes duas amostras são uma da outra (AGGARWAL, 2015). Se essa distância for pequena, será o alto grau de similaridade. As medidas de distância de uma maneira geral podem ser definidas como medidas de similaridade, e dissimilaridade: a primeira é utilizada para definir o grau de semelhança entre as instâncias e realizam o agrupamento de acordo com a sua coesão, e a segunda de acordo com as diferenças dos atributos das instâncias.

Deve-se tomar cuidado ao calcular a distância entre dimensões/recursos não relacionados. Os valores relativos de cada variável devem ser normalizados, ou uma atributo com maior amplitude de valores pode acabar dominando o cálculo da distância. A similaridade costuma ser medida no intervalo $[0,1]$ para algumas metodologias e $[-1,1]$ para outras.

A distância euclidiana é o método mais comum e intuitivo de obtenção da similaridade entre duas amostras no espaço multidimensional. A distância euclidiana também é conhecida como simplesmente distância. Quando os dados são variáveis contínuas, normalmente costumam ser a melhor medida de similaridade. A distância euclidiana entre dois vetores amostra, A e B, é o comprimento do menor caminho que os liga.

A similaridade do cosseno mede a semelhança entre dois vetores por meio do produto escalar interno normalizado do espaço (HAN, 2011). É medido pelo cosseno do ângulo entre dois vetores e determina se dois vetores estão apontando aproximadamente na mesma direção. É frequentemente usado para medir a similaridade de documentos na análise de texto. Conforme exemplo didático feito por (HAN, 2011), um documento pode ser representado por milhares de atributos, cada

um registrando a frequência de uma palavra específica (como uma palavra-chave) ou frase no documento. Assim, cada documento é um objeto representado pelo que é chamado de vetor termo-frequência. Por exemplo, na Tabela 1, observa-se que o Documento1 contém cinco instâncias da palavra equipe, enquanto o futebol ocorre duas vezes. A palavra treinador está ausente no documento inteiro, conforme indicado por um valor de contagem de 0. Esses dados podem ser altamente assimétricos.

Tabela 1. Exemplo mostrando a frequência que cada palavra ocorre em determinados textos. Tal atribuição possui uso similar à determinação de variáveis categóricas para compor a base de dados de métodos de EOR desse trabalho, como litologia (se arenito, arenito inconsolidado, carbonato, calcário, dolomita, etc), método de EOR utilizado (injeção de vapor, surfactante, polímero, etc), nível de sucesso do projeto de EOR, dentre outras.

Documento	equipe	treinador	hóquei	futebol	beisebol	vitória	derrota	tempora da
Documento1	5	0	3	2	0	2	0	0
Documento2	3	0	2	1	0	1	0	1
Documento3	0	7	0	1	2	3	0	0
Documento4	0	1	0	1	2	0	3	0

Adaptado de HAN et al., (2011)

Portanto, é um julgamento da orientação e não da magnitude (como ocorre na distância euclidiana): dois vetores com a mesma orientação têm uma similaridade do cosseno de 1, e dois vetores a 90° têm uma similaridade de 0 e dois vetores diametralmente opostos (180°) têm uma semelhança de -1, independentemente de sua magnitude. Seno e o cosseno são cofunções, isto é, as suas relações são complementares, sendo equivalente o uso do seno entre os vetores amostras, porém significando a dissimilaridade entre tais vetores. A [Figura 5](#) ilustra a diferença entre a similaridade do cosseno e da distância euclidiana para dois vetores amostra A e B.

Tal como nos vetores de frequência de palavras no contexto de mineração de textos e processamento de linguagem natural, os vetores relativos a cada reservatório da base de dados consolidada utilizada nesse trabalho também tornaram-se longos e esparsos (ou seja, possuem muitos valores 0). Dessa forma, as medidas tradicionais de distância podem em alguns casos não funcionar muito bem para esses dados numéricos esparsos. Por exemplo, dois vetores relativos aos campos de produção A e B podem ter muitos valores 0 em comum. A pode assumir valor 1 para o método de EOR de injeção de vapor e 0 para os demais, e valor 1 para a litologia dolomítica e zero para as demais. O campo B, por sua vez, pode apresentar valor 1 para o método de EOR de injeção de surfactante e zero para os restantes, e valor 1 para a litologia

arenito inconsolidado. Apesar de possuírem diversos valores 0 em comum, tais campos A e B não compartilham características em conjunto, não sendo, portanto, semelhantes em relação a essas variáveis utilizadas como exemplo. Como forma de comparação de similaridade que se concentre nas variáveis categóricas que os dois vetores reservatórios possuem em comum, é interessante então o uso de uma medida para dados numéricos que ignore valores nulos de tais atributos para obtenção de reservatórios análogos.

Figura 5. Representação esquemática em três dimensões das medidas de similaridade do cosseno e da distância euclidiana entre dois vetores. Enquanto a distância euclidiana refere-se ao comprimento do menor caminho entre as duas amostras, a similaridade do seno nos informa sobre o ângulo formado pelos vetores das duas amostras no espaço n-dimensional.




Figura adaptada de WANG & CHEN (2017)

Como a base de dados consolidada acerca dos métodos de EOR possui tanto variáveis categóricas (que levam a dados esparsos) quanto numéricas, é pertinente ainda a comparação sobre tais diferentes perspectivas de se obter o grau de similaridade entre dois reservatório: o uso da distância euclidiana, que conforme visto na seção 2.2.1 é a base da metodologia SOM adotada, comparada com a similaridade do cosseno/dissimilaridade do seno entre as instâncias de reservatórios da base de dados. Além disso, por a derivada do cosseno de ângulos perto de zero ser muito baixa, a variação do cosseno entre vetores que possuam grande grau de similaridade

torna-se baixa, podendo tornar difícil a visualização nuances entre reservatórios com alto grau de similaridade. A sua co-função seno, por outro lado, possui valor de derivada mais acentuada para ângulos próximos de zero, sendo mais adequado, portanto, para o estudo de fenômenos cujos vetores no espaço apontam para direções muito próximas uma das outras, podendo-se nesse caso destacar com mais facilidade determinadas diferenças de interesse.

2.4 Screening de métodos de Enhanced Oil Recovery

2.4.1 Estado da arte sobre metodologias de screening aplicadas a métodos de EOR

No decorrer das últimas duas décadas inúmeros trabalhos foram apresentados propondo um guia técnico para a seleção e implementação um método apropriado de EOR compatível com um tipo específico de reservatório. Dentre esses, os que receberam mais citações ao longo do tempo por parte da comunidade científica e/ou mais recentes são apresentados nas figuras [6](#) e [7](#) a seguir. Tais figuras condensam, respectivamente, informações a respeito dos métodos de EOR (dividindo-se nas suas principais classes – métodos térmicos, injeção de gases, injeção de produtos químicos, e outros) que cada artigo científico avalia como potenciais de aplicação nos campos de interesse e as variáveis (propriedades petrofísicas do reservatório, propriedades a respeito da composição e comportamento do óleo, da água da formação, propriedades termodinâmicas e variáveis de projetos – associadas ao quão bem sucedido ou não fora a implementação do projeto de EOR e escala de implementação) que utiliza para realizar a avaliação do método de EOR mais adequado. A partir dessa coletânea de artigos mais citados, por sua vez, os que mais obtiveram destaque ou que mais trouxeram inovações robustas, em suas respectivas épocas, em relação à metodologia de *screening* são também detalhados nos parágrafos abaixo.

TABER et al. (1997), com base em experiência real de projetos de EOR, inovaram em determinar faixas de aplicação de variáveis para cada método. Os métodos de EOR considerados foram: 1- injeção de nitrogênio e gás de combustão; 2- injeção de hidrocarboneto; 3- injeção de CO₂; 4- injeção de gases miscíveis; 5- injeção de surfactante, polímero e ASP; 6- injeção de polímero; 7- combustão in-situ;

8- injeção de vapor; e 9- mineração de superfície. Já as variáveis consideradas foram: °API, composição do óleo, viscosidade, saturação de óleo, litologia da formação, espessura da formação, permeabilidade, profundidade e temperatura. Tal artigo inovou ao levar à compilação de tabelas para orientar a escolha de possíveis métodos de EOR mais adequados para as faixas de valores de cada propriedade. Tal artigo veio a se tornar referência para muitos trabalhos subsequentes, tanto nessa mesma temática de *screening* de EOR, como para desenvolvimento de simulações de reservatórios, dentro outros. Além disso, tal trabalho em específico é citado mais de mil vezes nas diferentes bases científicas.

Métodos de EOR abordados	Trabalhos que realizam screening de EOR	Autores	Térmicos															Injeção de gases										Químicos					Outros	
			Low Salinity (LSFW)	Vapor	Água quente	Combustão	SAGD	Vapor cíclico	Hidrocarb. misc.	Hidrocarb. imisc.	Gás pobre	Gás rico	Gás ácido misc.	CO2 miscible	CO2 imiscível	Nitrog. miscível	Nitrogen imiscível	Gás de comb. misc.	Gás de comb. imisc.	Nitratos/Azotos	Air	WAG	Polímero	Surfactante	Alkaline	Alkaline Surfactante	Alka Surf Poly	Microbial	Partículas termicamente ativadas (TAP)	Aquecimento eletromagnético				
		Parkinson et al. (1994)	X		X			X	X					X	X									X										
		Diaz et al. (1996)									X																							
		Taber et al. (1997)	X					X	X			X																						
		Gharbi (2000)	X	X	X			X	X			X	X				X					X	X	X										
		Jensen et al. (2000)									X	X					X		X							X								
		Shokir et al. (2002)	X		X			X				X										X												
		Alvarado et al. (2008)																				X	X	X										
		Portillo et al. (2010)							X	X		X	X				X		X		X	X												
		Dickson et al. (2010)	X	X		X	X	X	X			X	X				X					X			X									
		Al-Adasani (2010)	X	X	X			X	X			X	X				X		X			X	X		X	X								
		Soleimani et al. (2011)	X		X	X																X			X									
		Lee et al. (2011)	X		X			X				X										X												
		Bourdarot & Ghedan (2011)	X		X			X				X										X	X											
		Kamari et al. (2014)	X	X	X			X				X	X									X	X	X		X								
		Nageh et al. (2015)	X	X	X			X	X			X	X				X		X		X	X			X									
		Suleimanov et al. (2016)			X			X	X			X	X		X	X	X					X	X											
		Eghbali et al. (2016)	X					X				X										X												
		Ramos & Akanji (2017a)	X	X				X			X	X					X					X	X			X								
		Ramos & Akanji (2017b)	X	X	X			X			X	X	X				X					X	X			X								
		Singh & Cai (2018)										X										X												
		James et al. (2018)	X		X			X		X	X	X	X	X			X	X	X				X	X	X	X								
		Smalley et al. (2018)						X				X	X																					

(Autoria própria).

Figura 5. Variáveis levadas em conta por coletânea de trabalhos científicos que mais receberam citações nas diferentes bases de científicas e que desenvolveram ou aplicaram metodologias de *screening* de EOR.

Trabalhos que realizam screening de EOR	Variáveis consideradas	Prop. Petrofísicas Reservat.										Prop. óleo			Água da formação			Prop. Termod.				Variáveis de projeto							
		Litologia	Compressibilidade	Profundidade	Temperatura	Espessura payzone	Mergulho da formação	Porosidade	Permeabilidade média	Variação de permeabilidade	Dykstra Parsons	°API	Viscosidade	Saturação inicial de óleo	Óleo restante in place (ROIp)	Teor de argila	Água formação	Salinidade	Dureza da água	Molhabilidade	Pressão mín. de miscib.	Pressão atual	Pressão inicial	Fratura	Área (acres)	Preço do barril	Maturidade/escala	Bem sucedido	Lucratividade
Parkinson et al. (1994)	X			X	X			X			X	X	X																
Díaz et al. (1996)			X			X					X			X						X									
Taber et al. (1997)	X		X	X	X			X			X	X	X																
Gharbi (2000)	X		X	X	X	X										X	X												
Jensen et al. (2000)																													
Shokir et al. (2002)			X				X	X			X	X	X												X				
Alvarado et al. (2008)			X	X	X			X	X		X	X	X			X		X				X							
Portillo et al. (2010)	X		X	X	X		X	X			X	X	X									X							
Dickson et al. (2010)																													
Al-Adasani (2010)	X			X	X		X	X			X	X	X																
Soleimani et al. (2011)					X		X	X																					
Lee et al. (2011)			X	X			X	X			X	X	X																
Bourdarot & Ghedan (2011)	X		X		X		X	X				X	X				X	X			X	X							
Kamari et al. (2014)																													
Nageh et al. (2015)	X		X	X	X			X	X		X	X	X								X	X	X						
Suleimanov et al. (2016)	X		X	X	X			X			X	X	X																
Eghbali et al. (2016)			X	X				X			X	X																	
Ramos & Akanji (2017a)			X	X	X		X	X			X	X	X									X	X						
Ramos & Akanji (2017b)			X				X	X				X																	
Singh & Cai (2018)		X	X	X									X									X	X						
James et al. (2018)			X	X			X	X														X	X						
Smalley et al. (2018)	X		X	X			X	X			X	X				X		X		X		X	X	X					
Khojastehmehr et al. (2019)	X		X	X	X			X			X	X	X																
Zhang et al. (2019)			X	X	X		X	X			X	X	X																
Khazali et al. (2019)	X		X	X			X	X			X	X	X																

(Autoria própria).

GHARBI (2000) realiza o *screening* por meio de sistema inteligente que combina simulador baseado no método de diferenças finitas, junto a conjuntos de regras de decisão. As equações de balanço são resolvidas pelo método explícito com uso de modelo composicional em que, para se minimizar o custo da simulação, foram utilizados apenas dois parâmetros de comparação. Tal simulador foi então integrado a vários conjuntos de regras "If-Then-Do" para formar a estrutura de tomada de decisão. No entanto, apenas guias técnicos de triagem foram usados no sistema especialista, sem associação de variáveis de avaliação econômica. Conforme o autor destaca, a parte mais difícil ao desenvolver o sistema especialista de escolha é a aquisição do conhecimento para modelar esse conjunto de regras.

AL-ADASANI et al. (2010) atualiza o trabalho feito por TABER (1997) com avanços realizados na área de EOR, incluindo na metodologia de *screening* a adição das faixas de porosidade e permeabilidades a subcategorias de injeção de gás miscível. Porém, ao contrário de Taber, se baseia mais na revisão bibliográfica de artigos, verificando avanços científicos, em detrimento de experiências reais conduzidas em campos de produção de petróleo.

DICKSON et al. 2010 fazem a triagem e ranqueamento de processos de EOR para diversos reservatórios junto à análise de simulações. Tais análises foram realizadas em recortes de modelos geológicos simplificados, sem quaisquer restrições no nível da instalação para o método de EOR selecionado. A metodologia, utilizada também pela ExxonMobil e outras companhias operadoras, realiza uma triagem de uma variedade de técnicas de EOR. Todas estas foram baseadas em propriedades do reservatório e critérios técnicos, com a inovação de integrar critérios de recomendações de planilhas anteriores, tais como as de TABER et al. (1997). As dez propriedades utilizadas como critérios de seleção foram: salinidade da formação, viscosidade e °API do óleo, pressão, temperatura, profundidade, espessura e ângulo de mergulho do reservatório e saturação de óleo. Os intervalos dos critérios de triagem são plotados como barras horizontais e a propriedade do reservatório é plotada como uma linha vertical, em que cada uma das dez variáveis para o campo é comparada para verificar se atende aos critérios de triagem pré-estabelecidos em planilhas. A aplicação do método de EOR para um determinado campo passa no teste de triagem relativo a uma determinada variável se, para essa propriedade, o valor que ocorre no

campo se encontra dentro do range estabelecido pelo critério de triagem, passando a receber uma pontuação de +10. Já os métodos de EOR, cujo intervalo recomendado a priori para a variável não engloba o valor que ocorre no reservatório, recebem uma pontuação de -10. Tal atribuição de pontuações ocorre independentemente do quão distante o valor da propriedade do reservatório esteja do intervalo recomendado pela literatura. Nos casos em que algumas variáveis do campo não possuam dados disponíveis, são utilizadas correlações entre propriedades, por exemplo, entre $^{\circ}$ API e viscosidade; permeabilidade e porosidade, dentre outras.

PORTILLO et al. (2011), além da triagem técnica binária e predição de possível desempenho via *benckmarking*, inovam identificando projetos em que foram implementados EOR que possuam similaridades ao campo em estudo. Novamente, também são comparadas 10 propriedades com os critérios de triagem definidos por autores da área, em que uma pontuação entre 0 e 1 é atribuída, conforme atendidos os requisitos, para 16 métodos de EOR. Uma pontuação de 1 é atribuída quando a propriedade está dentro do intervalo estabelecido por TABER (1997), e zero quando fora, o que possibilita, portanto, atribuições intermediárias. As variáveis utilizadas como parâmetros foram: $^{\circ}$ API, saturação inicial de óleo, temperatura do reservatório, porosidade, pressão, profundidade, espessura da formação, viscosidade, ponto de bolha e permeabilidade média. Por fim, identificam que o campo de Cocorná na Colombia, foco central do artigo, possui grandes semelhanças com os campos Guapo (Fm. Cruse E&F), Tia Juana (Fm. Lagunillas Inferior) e Fazenda Alegre (Fm. Urucutuca), mostrando que pode enriquecer bastante a análise e o planejamento da implementação de EOR.

AL ADASANI & BAI (2011) construíram um banco de dados relativo a EOR com base em 652 projetos, realizando a análise da distribuição das variáveis e atualização dos critérios de *screening* desenvolvidos por TABER et al. (1996). O banco de dados desenvolvido lista as propriedades básicas de rochas e fluidos dos reservatórios e atributos dos respectivos projetos. As variáveis utilizadas para formular os critérios de *screening* foram: litologia e valores médios de $^{\circ}$ API, viscosidade e temperatura, porosidade, saturação inicial e final do óleo, permeabilidade e profundidade. A planilha de *screening* proposta é desenvolvida utilizando três abordagens: (1) pela adoção dos valores mínimos, máximos e médios; (2) a partir das tendências observadas com a variável aumento da recuperação de petróleo, em barris por dia; e (3) baseado na

análise da distribuição dos dados por meio de *boxplots*, apoiando a seleção, implementação e desenvolvimento da aplicação de métodos de EOR.

LEE et al. (2011) utilizam uma Rede Neural Artificial do tipo Backpropagation para realizar a seleção do método de EOR. A RNA desenvolvida no estudo citado apresenta quatro camadas, sendo uma camada de entrada e outra de saída, junto a duas camadas ocultas. A camada de entrada é composta pelos principais parâmetros do reservatório, que no caso do artigo são considerados: profundidade, temperatura, porosidade, permeabilidade, saturação inicial do óleo, gravidade do óleo e viscosidade do óleo *in situ*. Já a camada de saída é composta pelos cinco métodos EOR a serem avaliados: 1- injeção de vapor; 2- injeção de CO₂ miscível; 3- injeção de hidrocarboneto miscível; 4- combustão *in situ*; e 5- injeção de polímeros. A base de dados utilizada apresentou 71 instâncias de entrada (71 reservatórios), sendo dividida em treinamento e validação. O número de neurônios foi otimizado durante o treinamento por tentativa e erro. Depois de treinada, a RNA foi aplicada a outros campos não utilizados no treinamento, trazendo como exemplos o *screening* aplicado a conhecidos projetos de EOR de sucesso mundial - campos de Cold Lake, Wason Denver, Twofredsand Cocorná.

ZERAFAT et al. (2011) realizam o *screening* por meio de Rede Neural Artificial Bayesiana, a fim de classificar os métodos de EOR mais adequados para posterior avaliação por critérios econômicos e ambientais. Para tanto, a partir de dados do Departamento de Energia dos EUA, consolidaram um banco de dados acerca da aplicação das técnicas de EOR, contendo as variáveis porosidade, permeabilidade, profundidade e temperatura do reservatório e °API e viscosidade do óleo. Por conta da limitação de dados da base de dados final e buscando manter consistência na predição, os métodos de EOR considerados foram apenas injeção de vapor, combustão *in-situ*, CO₂ miscível, hidrocarboneto miscível e de polímero. A técnica de aprendizado de rede bayesiana foi aplicada a dados coletados pertencentes a 10 reservatórios a sudoeste do Irã. Como conclusão, mostram que a injeção de CO₂ é apontada como a mais promissora entre várias técnicas de EOR para tais campos analisados.

ALVARADO (2013) apresentaram uma análise sobre o potencial de recuperação melhorada de petróleo (EOR) e seus desafios em ambientes *offshore*. O autor discorreu sobre como os critérios de triagem e os fluxos de trabalho

desenvolvidos recentemente podem ser adaptados para avaliação do potencial de EOR em ambientes *offshore*. Os resultados desta análise mostraram que há diversas oportunidades de aplicação de EOR em ambiente *offshore*, mas destacaram ser necessária uma análise mais rigorosa das possíveis oportunidades para sua avaliação.

KANG et al (2016) apresentaram uma análise dos métodos de injeção miscível de gases e de polímeros, em ambiente *offshore*, que fora desenvolvida a partir de uma base de dados composta por 19 casos de experiências de campo e de projetos pilotos bem-sucedidos.

EGHBALI et al. (2016) criaram um sistema baseado em regras lógicas fuzzyficadas para selecionar, dentre quatro métodos de EOR, o mais apropriado para um determinado campo com base nas variáveis API, viscosidade, permeabilidade, profundidade e temperatura. Os métodos de EOR considerados são injeção de: CO₂ miscível, hidrocarboneto miscível, polímero e de vapor. Os critérios utilizados para projetar as regras *fuzzy* são definidos com base nas planilhas de triagem propostas por TABER (1997). Nesse processo de conversão dos critérios de triagem em regras *fuzzy*, cinco conjuntos difusos gaussianos são considerados para cada parâmetro de entrada com os atributos linguísticos de “Muito baixo”, “Baixo”, “Médio”, “Alto” e “Muito alto”, exceto para o parâmetro de permeabilidade, que possui três conjuntos difusos, representados por “Baixo”, “Médio” e “Alto”. Os resultados obtidos foram comparados com experiências de campo, mostrando ser eficaz para uma estimativa rápida para se avaliar a aplicabilidade dos métodos de EOR a um reservatório específico. Contudo, verificam-se limitações no sentido de levar em conta apenas cinco variáveis e quatro possíveis métodos de EOR.

KHOJASTEHEMEHR et al. (2019), utilizaram uma metodologia denominada *Technique for order of Preference by Similarity to Ideal* (TOPSIS) para selecionar métodos de EOR em reservatórios de petróleo iranianos *onshore* e *offshore*. Para tanto, foram atribuídos pesos a cada variável conforme quão ou não relevantes fossem consideradas. Tal método de triagem foi empregado para selecionar o mais adequado dentre 10 métodos de EOR. Os valores ideais dos critérios desejados para cada método de EOR foram atribuídos conforme as tabelas desenvolvidas por TABER (1997). Tal metodologia apresentou como vantagem o fato de não necessitar diretamente de uma ampla e extensiva base de dados. No entanto, a definição das

soluções idealmente melhores e extremos piores mostraram-se distantes de situações de projetos reais (por exemplo, permeabilidades de 15 mil mD e saturações médias de óleo no reservatório acima de 90%, etc), tendo ainda um certo grau de subjetividade na inclusão desses casos ideais. Além disso, em um problema real podem existir vários cenários ótimos possíveis, com diferentes combinações de valores para as diferentes variáveis. Ressalta-se como fator crítico, também, que na elaboração de uma matriz de pesos para cada atributo não é possível considerar que diferentes variáveis podem gerar influências significativamente distintas para os diferentes métodos de EOR.

ZHANG et al. (2019) desenvolvem um sistema de seleção híbrido para métodos de EOR, combinando *screening* convencional e o método baseado em processos decisórios *random forest*. Para tanto, foi consolidada uma base de dados contendo projetos de EOR em mais de 10 países, envolvendo os métodos de EOR injeção de vapor, combustão *in situ*, água quente, injeção miscível e imiscível de CO₂, hidrocarboneto e nitrogênio, além dos métodos químicos de injeção de polímero, injeção de surfactante e microbial, e as variáveis litologia, porosidade, permeabilidade média, profundidade, °API, viscosidade, temperatura, saturação de óleo final. O trabalho foi o primeiro do gênero a levar em consideração a espessura da formação, porém sem considerar o tipo litológico no estudo de caso de *screening* apresentado. Para evitar o viés dos especialistas, os fatores de ponderação para cada técnica de EOR foram determinados por meio da aplicação do algoritmo de *Random Forest*, e o sistema de pontuação foi então estabelecido pela fuzzyficação dos atributos das variáveis, porém sem levar em consideração os diferentes comportamentos para os diferentes métodos de EOR. A pontuação das propriedades do reservatório/fluido foi realizada a partir da fuzzificação que fora determinada pelas diretrizes de triagem convencionais. Tal fuzzyficação foi desenvolvida utilizando funções trapezoidais de pertinência para cada parâmetro, apresentando valor 100 se dentro do *range* ideal definido pelos intervalos interquartis, 0 se fora do *range* máximo especificado, e valores intermediários variando segundo uma função linear caso entre tais limites. Ao final, os autores apresentaram o *screening* para o campo de Midway-Sunset, nos EUA. Em comparação com os trabalhos anteriores, ZHANG et al. (2019) desenvolveram uma abordagem mais robusta, ao conseguir incluir um maior número de variáveis no

processo de tomada de decisão tomando como base experiências reais de campo, além de se conseguir reduzir significativamente o viés dos especialistas.

A partir de revisão bibliográfica dos principais artigos científicos que realizam o *screening* de métodos de EOR, pode-se observar que a maior parte é baseada na confecção de tabelas, em que se usa critérios rígidos para cada variável definidos por especialistas, o que observou-se ser uma das principais limitações de tais metodologias. Contudo, há também trabalhos, especialmente os mais recentes, que buscam superar tal limitação ao desenvolver-se sistemática, baseadas em análises estatísticas, lógica *fuzzy* e até redes neurais não supervisionadas. Apesar disso, é possível observar que permanece um desafio a inclusão de um maior número de métodos de EOR ou de variáveis associadas em tais novas sistemáticas. Além disso, em extensa pesquisa observa-se que não encontrou-se trabalhos do gênero que consigam, de alguma forma, incluir aspectos locais e não tangíveis diretamente, como por exemplo relacionados ao suprimento da cadeia de valor necessária à implementação de projetos de EOR, dentre outros.

2.4.2 Softwares e alternativas comerciais de *screening* de EOR

Em pesquisa acerca de *softwares* e opções comerciais na indústria de petróleo que realizam *screening* de métodos de EOR, foram encontradas algumas alternativas:

- I. O “EORgui”, baseado nas tabelas de TABER et al. (1997) permite, para um dado campo de interesse, selecionar dentre nove possíveis métodos de EOR;
- II. Sword realiza seleção do método de EOR com base em soluções analíticas analisadas, práticas de campo e conhecimento e experiência de especialistas;
- III. SelectEOR executa estudos de triagem levando em consideração dezessete métodos de EOR e faz previsões usando catorze configurações possíveis, sendo lançado no mercado em 2009 para o *Alberta Research Council*, e é baseado no *software* anterior chamado PRIZE.
- IV. *Screening 2.0* é uma ferramenta de *software* desenvolvida pela ECOPETROL S.A., e pode aplicar critérios de triagem de dezoito


métodos EOR. Esta ferramenta considera critérios de seleção como os desenvolvidos por TABER et al. (1997);

- V. O IORSys é um *software* desenvolvido pelo RIPED (Research Institute of Petroleum Exploration & Development, PetroChina), e baseado no *Screening* 2.0. Sua principal aplicação é a avaliação do potencial de EOR dentre nove métodos de EOR possíveis, além de permitir a identificação de possíveis campos análogos.

3 MATERIAIS E MÉTODOS

A sequência desenvolvida neste trabalho foi subdividida em quatro etapas, a saber: estruturação da base de dados, pré-processamento, processamento e interpretações. Uma síntese da rotina metodológica desenvolvida está apresentada na [Figura 9](#).

Figura 9. Fluxograma da metodologia iterativa desenvolvida.



(Autoria própria).

3.1 Estruturação da Base de Dados

A base de dados compilada contém 1035 instâncias, cada uma referindo-se a um projeto de EOR ao redor do mundo, contando com ao todo 323 variáveis para análise. A aquisição da base foi feita por meio da junção de dados públicos oriundos de diversas fontes, cuja síntese das principais fontes de dados podem ser observadas na [Figura 10](#). Devido a motivos estratégicos e possíveis finalidades comerciais desse trabalho não todas as fontes são explicitadas e/ou detalhadas, porém dentre elas encontram-se:

- i. Artigos científicos considerados referências na aplicação de EOR. Tais artigos trouxeram informações de interesse em temas relacionados às atividades de recuperação avançada de petróleo no mundo. Além disso, alguns artigos, por exemplo, explicitam o estado da arte na aplicação de determinadas classes de EOR; outros, por sua vez, focam-se em reportar experiências de campos de produção em que foram implementados métodos de EOR. Contudo, não foram incluídos na base dados provenientes de artigos que se referiam a somente estudos de simulação simples, injeção de traçadores ou testes de viabilidade técnica com escopo limitado. Por questões estratégicas, com finalidades empreendedoras, optou-se por não se listar todos os artigos científicos utilizados na confecção da base de dados. Porém com a finalidade de ilustração alguns exemplos de classes de trabalhos do gênero utilizados como fontes foram:
 - a. Levantamentos abrangentes e estudos da aplicação de métodos de EOR em reservatórios de determinadas regiões específicas do mundo ou determinadas bacias sedimentares, como do Mar do Norte (AWAN et al., 2008), de shale oil (JIA & SHENG, 2017; WANG et al., 2017, ALHARTHY et al., 2018; ALFARGE & KHASHAN, 2018), carbonatos (MANRIQUE et al., 2014), reservatórios offshore (BONDOR et al., 2005) e campos no Brasil, a exemplo Peregrino na Bacia de Campos (HAN et al., 2012; KRISTOFFERSEN et al., 2017), dentre outros.
 - b. Conjunto de experiências de campo acerca de um método em específico, como injeção de CO₂ associada com captura e armazenamento de carbono (LAKE et al., 2019; OLEA, 2017; SAINI,

2017; OUGHTON, 2016; etc), injeção alternada de água com gás (BELAZREG & MAHMOOD, 2019), uso de métodos de EOR microbiais (SHE et al., 2019), injeção de água de baixa salinidade (CHAVAN et al., 2019; ARIANI, 2018), injeção de produtos químicos (MAHRAN et al., 2018; ALSOFI, 2019), combustão in-situ (TURTA et al., 2007), dentre outros.

- c. Artigos com informações amplas, porém menos estruturadas ou com dados pontuais, a exemplo de JIN et al. (2018), JIEXIANG et al. (2008), REN et al. (2009), MENEZES (2015), LI (2009), MITRA et al. (2005), SANCHEZ (2005), MOREL (2015), REN et al. (2011), SECCOMBE et al. (2010), SUN et al. (2011), BRODIE et al. (2012), CORREIA et al. (2018), PIZARRO et al. (2018), WEI et al. (2004), YOUYI et al. (2012), DOVAN et al. (1990), HUANG et al. (2010), WANG et al. (2019), JONES et al. (2015), etc.

- ii. Relatórios e bases de dados de órgãos e institutos internacionais. Estes relatórios são voltados para pesquisa e/ou aplicação de políticas visando segurança energética, como *International Energy Agency (IEA)*, *Center for Strategic and International Studies (CSIS)*, *Global Carbon Capture and Storage Institute (CCSI)*, *OPEC (Organization of the Petroleum Exporting Countries)*, dentre outros;
- iii. Órgãos reguladores e de pesquisa de diversos países. Referem-se a instituições, tais como: *Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, Brasil)*, *United States Geological Survey (USGS)*, *U.S. Department of Energy e Energy Information Administration/Department of Energy (DOE/EIA)*, *Federal Energy Regulatory Commission (FERC)*, *National Petroleum Directorate (NPD, Noruega)*, *Oil and Gas Authority (Reino Unido)*, *Comisión Nacional de Hidrocarburos (CNH, México)*, *Instituto Nacional de Petróleo (INP, Moçambique)*;
- iv. Apresentações para investidores e relatórios de companhias operadoras dos campos. Tais dados foram coletados, especialmente, de empresas integradas (*Major Integrated Companies*, cujas atividades abrangem a exploração, produção, transporte, refino, distribuição e venda ao mercado consumidor) como *Shell*, *Petrobras*, *Equinor*, *British Petroleum*, *Occidental Petroleum*, *Total*

e *Cenovus*. Também foram coletadas algumas informações de empresas classificadas independentes (não integradas, cujas receitas provém majoritariamente do segmento *upstream*, ou seja da venda da produção de petróleo a outros atores da cadeia de valor), a exemplo de *Apache Corporation*, *Canadian Natural Resources*, *Denbury Resources* e *Anadarko Petroleum*. A obtenção desses documentos foi feita por meio de sites e/ou de material publicado livremente pelas próprias empresas.

Figura 6. Ilustração das principais classes de fontes utilizadas para a constituição da base de dados relativa à implementação de métodos de EOR em escala global.



- v. Revistas e sites de notícias especializados no setor de petróleo e negócios, trazendo matérias sobre desenvolvimentos em diversos campos de petróleo ao redor do mundo, a exemplo de *A Barrel Full*, *Offshore-Technology*, *Oil & Gas Journal*, *REUTERS*, *RigZone*, *Energy Voice*, *Bloomberg*.
- vi. Levantamentos e dados disponíveis publicamente de consultorias estratégicas voltadas para o setor de óleo e gás e energia, a exemplo de *Energy Intelligence*, *Wood Mackenzie*, *IHS Markit*.
- vii. Livros contendo estudos de casos e exemplos reais de aplicação de EOR. Tratam-se de livros que trazem informações sobre projetos pilotos, ou mesmo sobre estudos de casos sobre os campo de produção, como: *Enhanced Oil Recovery - Field Case Studies*, *Modern Chemical Enhanced Oil Recovery - Theory and Practice*, e *Petroleum Engineering Handbook*, em seus volumes V - *Reservoir Engineering and Petrophysics* e VI - *Emerging and Peripheral Technologies*.
- viii. Crude oil assays, como as disponibilizadas para fins comerciais por empresas operadoras, a exemplo de *British Petroleum* (2019), *Equinor* (2019), *ExxonMobil* (2019) e *Total* (2019). Por conta de no pré-processamento do petróleo para as refinarias muitos dos componentes indesejados para o refino serem retirados e algumas propriedades alteradas, as variáveis coletadas das Crude oil assays, em geral, foram apenas densidade, °API, viscosidade nas temperaturas disponíveis e número ácido total (mgKOH). Dois exemplos de crude oil assays utilizadas são apresentados nas figuras [11](#) e [12](#).

Figura 7. Exemplo de crude oil assay, fornecida pela TOTAL (2019) com principais dados do óleo processado proveniente do campo de Dalia, na Angola.

		Crude DALIA				TBP					
		Country Angola				DISTILLATION					
Density at 15°C, kg/m3	915.4	Assay Date 09/mar/15				°C	wt%	vol%	°C	wt%	vol%
%API	23.0					080	0.74	100	460	57.10	59.86
Bbl/mt	6.882					090	0.98	130	480	60.65	63.32
Acidity, mg KOH/g	149					100	1.29	168	500	64.07	66.64
Sulphur, wt%	0.508					120	2.16	2.74	520	67.36	69.82
Hydrogen Sulphide, mg/kg	<1					140	3.44	4.24	540	70.50	72.83
Mercaptan Sulphur, mg/kg	10					160	5.15	6.22	560	73.47	75.68
Viscosity, cSt at 10 °C	224.0					180	7.12	8.45	580	76.27	78.35
Viscosity, cSt at 50 °C	27.6					200	9.00	10.54			
Pour Point, °C	-51					220	11.18	12.91			
Total Nitrogen, wt%	0.212					240	14.47	16.45			
Wax, wt%	-	wt% vol%				260	18.37	20.60			
Wax Appearance Temperature, °C	-					280	22.28	24.71			
RVP at 37.8 °C, kPa	9	Ethane	0.00	0.00	300	26.13	28.73				
Water, vol%	-	Propane	0.00	0.00	320	30.00	32.72				
NaCl, mg/kg	-	Iso-Butane	0.00	0.01	340	33.92	36.74				
Nickel, mg/kg	213	n-Butane	0.02	0.03	360	37.89	40.77				
Vanadium, mg/kg	8.6					380	41.87	44.78			
Iron, mg/kg	-					400	45.80	48.71			
Mercury, µg/kg	-					420	49.66	52.55			
						440	53.43	56.27			

PROPERTIES OF TBP CUTS																	
LIGHT NAPHTHA	Cuts	Yield	Yield	Den 15°C	S	RSH	RON	MON				Napht.	Aro.	RVP			
	°C	wt%	vol %	kg/m3	wt%	mg/kg	clear	clear				vol%	vol%	kPa			
	15-65	0.38	0.52	672	0.0075	1	78.6	75.8				219	0.1	-			
	15-80	0.64	0.85	690	0.0079	3	76.9	73.7				36.8	0.4	-			
HEAVY NAPHTHA	Cuts	Yield	Yield	Den 15°C	S	RSH						Napht.	Aro.				
	°C	wt%	vol %	kg/m3	wt%	mg/kg						vol%	vol%				
	80-150	3.51	4.18	768	0.0154	8						74.0	3.2				
	80-175	5.89	6.89	782	0.0215	9						71.9	5.1				
	100-150	2.95	3.50	774	0.0165	8						74.1	3.7				
KEROSENE	Cuts	Yield	Yield	Den 15°C	S	RSH	Smoke	Acidity	Cetane	Freez. Pt			Aro.	Visc cSt			Flash
	°C	wt%	vol %	kg/m3	wt%	mg/kg	Pt mm	mgKOH/g	Index	°C			vol%	50°C			Point
	150-230	8.44	9.36	826	0.051	10	22	0.49	31.0	-83			12.0	12			57.5
	175-230	6.07	6.65	835	0.059	10	21	0.64	31.5	-79		13.7	13			70.4	
	150-250	12.16	13.33	835	0.065	10	21	0.81	33.6	-78		14.7	14			62.7	
GASOIL	Cuts	Yield	Yield	Den 15°C	S		Anilin		Cetane	Cloud Pt	CFPP	Pour Pt	Visc cSt	Visc cSt	UOPK	Flash	
	°C	wt%	vol %	kg/m3	wt%		Point °C		Index	°C	°C	°C	50°C	100°C		Point	
	175-400	39.18	40.82	879	0.274		63		42.0	-47	-50	-54	3.7	16	11.5	90.5	
	230-400	33.12	34.18	887	0.314		65		43.5	-47	-48	-48	4.8	19	11.5	107.1	
	230-375	28.19	29.24	883	0.283		64		43.0	-55	-55	-56	4.0	17	11.5	105.2	
VACUUM DISTILLATE	Cuts	Yield	Yield	Den 15°C	S	Conrad.	Anilin	Ni	Va	Total N	Bas N	Pour Pt	Visc cSt	Visc cSt	UOPK	Asp C7	
	°C	wt%	vol %	kg/m3	wt%	wt%	Point °C	mg/kg	mg/kg	wt%	mg/kg	°C	100°C	150°C		wt %	
	375-550	31.13	30.50	934	0.53	0.3	81	0	0	0.151	489	14	12.3	4.2	11.7	0.0	
	375-565	33.31	32.58	936	0.54	0.4	82	1	0	0.161	516	16	13.3	4.5	11.7	0.0	
	375-580	35.40	34.57	937	0.55	0.6	82	1	0	0.172	542	17	14.4	4.7	11.8	0.1	
	400-580	30.47	29.64	941	0.56	0.7	83	1	0	0.191	595	22	18.0	5.5	11.8	0.1	
RESIDUE	Cuts	Yield	Yield	Den 15°C	S	Conrad.	Acidity	Ni	Va	Total N		Pour Pt	Visc cSt	Visc cSt	Pene	Asp C7	
	°C	wt%	vol %	kg/m3	wt%	wt%	mgKOH/g	mg/kg	mg/kg	wt%		°C	100°C	150°C	mm/10	wt%	
	> 375	59.12	56.22	963	0.72	8.4	1.1	36	15	0.352		-3	64	13	-	1.4	
	> 550	28.00	25.73	996	0.92	17.4	0.2	76	31	0.577		51	1230	99	144	2.8	
	> 565	25.81	23.64	1000	0.94	18.7	0.1	82	33	0.599		54	1760	124	107	3.1	
	> 580	23.73	21.65	1003	0.96	20.0	0.1	88	36	0.621		57	2570	160	82	3.3	

This crude oil data sheet is for information purposes only. No guaranty is given as to its accuracy or as to any consequences arising from TOTAL DTS / AM mar/15

Fonte: TOTAL (2019)

Figura 8. Exemplo de crude oil assay, fornecida pela British Petroleum (2019) com principais dados do óleo processado proveniente do campo de Clair, pertencente ao Reino Unido, no Mar do Norte.

Source of Sample		Light Hydrocarbon Analysis				Assay Summary / TBP Data							
Reference:	B18CLR2	H2S*	ppm wt	-	Gravity (°API) 23.3								
Name:	Clair	Methane	%wt	0.00	Sulphur (%wt) 0.47								
Origin:	North Sea - UK	Ethane	%wt	0.01	Yield on Crude %wt %vol								
Sample Date:	09/10/2018	Propane	%wt	0.08	Gas to C4 0.35 0.55								
		Isobutane	%wt	0.06	Light Distillate to 149°C 6.85 8.40								
Comments:		n- Butane	%wt	0.18	Kerosene 149 - 232°C 7.95 9.05								
		Isopentane	%wt	0.19	Gas Oil 232 - 369°C 25.50 26.45								
		n- Pentane	%wt	0.24	Vacuum Gas Oil 369°C - 550°C 33.65 32.60								
		Cyclopentane	%wt	0.02	Residue above 550°C 25.70 22.95								
		C6 paraffins	%wt	0.65	Volume expansion: -0.1 percent vol on crude distributed across whole distillation								
		C6 naphthenes	%wt	0.51									
		Benzene	%wt	0.14									
		*Dissolved in liquid											

Cut Data	Crude	Distillates								Residues				
		Light Naphtha	Heavy Naphtha	Kero	Light Gas Oil	Heavy Gas Oil	Light Vacuum Gas Oil	Heavy Vacuum Gas Oil	AtRes	VacRes				
Start (°C API)		C5	95	149	175	232	342	369	509	550	369	509	550	585
End (°C API)		95	149	175	232	342	369	509	550	585	FBP	FBP	FBP	FBP
Yield on crude (% wt)	100	2.30	4.55	2.30	5.60	19.95	5.55	27.65	6.05	4.40	59.40	31.75	25.70	21.30
Yield on crude (% vol)	100	3.00	5.40	2.75	6.30	20.85	5.60	26.85	5.75	4.15	55.55	28.70	22.95	18.80
Density at 15°C (kg/litre)	0.9138	0.7004	0.7695	0.7751	0.8136	0.8748	0.9083	0.9409	0.9603	0.9746	0.9773	1.0114	1.0241	1.0351
Total Sulphur (% wt)	0.47	<0.001	0.001	0.005	0.015	0.179	0.468	0.561	0.711	0.728	0.685	0.794	0.814	0.831
Mercaptan Sulphur (ppm wt)	2	2	2	5	3	4	-	-	-	-	-	-	-	-
Total Nitrogen (ppm wt)	2300	0	0	0.1	1	46	260	1300	3100	4000	3900	6100	6800	7400
Basic Nitrogen (ppm wt)	862	-	-	-	-	34	165	470	955	1285	1424	2256	2561	2825
Acidity (mgKOH/g)	1.17	0.010	0.014	0.023	0.012	0.24	1.06	1.84	2.18	1.95	1.51	1.22	0.99	0.79
Viscosity at 20°C (cSt)	101.8	-	-	-	-	-	-	-	-	-	-	-	-	-
Viscosity at 30°C (cSt)	58.14	-	-	-	-	-	-	-	-	-	-	-	-	-
Viscosity at 40°C (cSt)	35.95	-	-	-	1.349	-	-	-	-	-	-	-	-	-
Viscosity at 50°C (cSt)	23.71	-	-	-	-	3.241	9.114	-	-	-	-	-	-	-
Viscosity at 60°C (cSt)	-	-	-	-	1.042	-	-	38.06	376.7	1422	1076	-	-	-
Viscosity at 100°C (cSt)	-	-	-	-	-	1.42	2.932	9.434	44.16	111.8	1019	3402	16740	70830
Viscosity at 120°C (cSt)	-	-	-	-	-	-	-	-	-	-	46.08	916.7	3572	12270
Viscosity at 150°C (cSt)	-	-	-	-	-	-	-	-	-	-	-	204.9	608.6	1638
Paraffins (%wt)	-	62.26	36.15	54.15	-	-	-	-	-	-	-	-	-	-
Naphthenes (%wt)	-	31.50	40.20	34.29	-	-	-	-	-	-	-	-	-	-
Aromatics (%wt)	-	6.23	23.65	11.56	-	30.4	-	-	-	-	-	-	-	-
n- Paraffins (%wt)	-	24.93	18.34	30.84	-	-	-	-	-	-	-	-	-	-
Research Octane Number	-	71	61	-	-	-	-	-	-	-	-	-	-	-
Smoke Point (mm)	-	-	-	-	22.5	14.3	-	-	-	-	-	-	-	-
Aromatics (%vol)	-	-	-	-	13.3	26.9	-	-	-	-	-	-	-	-
Naphthalenes (%wt)	-	-	-	-	1.37	7.94	-	-	-	-	-	-	-	-
Pour Point (°C)	-24	-	-	-	-	-18	6	27	-	-	27	72	84	96
Cloud Point (°C)	-	-	-	-	-	-17	7	-	-	-	-	-	-	-
Freeze Point (°C)	-	-	-	-	-51.0	-12.5	-	-	-	-	-	-	-	-
Cetane Index ASTM D4737-9	-	-	-	-	40.5	43.0	47.9	-	-	-	-	-	-	-
Refractive index at 70°C	-	-	-	-	1.4275	1.4631	1.4841	1.5000	1.5154	-	-	-	-	-
Aniline Point (°C)	-	-	-	-	-	-	65.2	75.5	82.1	83.4	-	-	-	-
Wax (%wt)	4.0	-	-	-	0.0	13	6.1	6.0	7.1	8.3	6.5	7	6.9	6.6
Carbon Residue (%wt)	5.7	-	-	-	-	-	-	0.06	1.36	3.63	9.58	17.9	21.7	25.5
Asphaltenes (%wt)	0.9	-	-	-	-	-	-	-	-	-	15	2.8	3.3	3.9
Vanadium (ppm wt)	4	-	-	-	-	-	-	-	-	-	6	12	15	18
Nickel (ppm wt)	11	-	-	-	-	-	-	-	-	-	18	35	43	51
Iron (ppm wt)	2	-	-	-	-	-	-	-	-	-	3	6	7	8

The information in this assay was prepared by BP Oil International Limited. It is for information purposes only and we are not soliciting or suggesting any action based upon it. While this material is based upon information that we consider reliable, nevertheless it may not be accurate or applicable to the circumstances of any particular case. We cannot accept any liability for any loss arising from the use of this information and any inaccuracies, errors or omissions in this assay.

This assay is © BP Oil International Limited. None of the material in this assay is to be incorporated or distributed in any work or publication in any form without the prior written consent of BP Oil International Limited.

Fonte: British Petroleum (2019)

Tais bases de dados abordam desde campos e métodos mais tradicionais de EOR, como injeção de vapor e injeção de hidrocarboneto em reservatórios convencionais, até novas tecnologias, a exemplo de *Low Salinity Water Flooding* (LSWF). Além disso, são abordadas as aplicações de EOR em novas fronteiras exploratórias, como campos em águas ultra profundas e reservatórios não convencionais, como os *Shale Gas/Shale Oil* nos EUA. Ainda que em diferentes formatos, bastante fragmentadas e dispersas, essas diferentes fontes de dados, com o devido tratamento e processamento, possuem o potencial de constituir uma base de dados única, mundial, abrangente e adequada para estudos dirigidos que se utilizam das técnicas avançadas de análise.

A integração das bases de dados, dispostas originalmente em diversos formatos diferentes (planilhas diversas, PDFs, textos, apresentações, etc) foi realizada sempre que viável, com o auxílio de algoritmos em *Python* e/ou *Visual Basic* (VBA), para automatização de determinadas etapas do trabalho de transferência dos dados. Utilizando-se da estrutura e processos de automatização já implementados, foi buscada a ampliação constante da base de dados. Isso ocorreu pela complementariedade de informações sobre as variáveis que não coletadas das bases supracitadas, ou mesmo via outras fontes que se mostraram pertinentes. Tal complementariedade teve o intuito de tornar a base de dados cada vez mais robusta e confiável.

3.2 Pré-processamento

3.2.1 Limpeza

De forma a tornar a base de dados o mais consistente possível, como ilustrado pela [figura 13](#), foi realizado um trabalho inicial de pré-processamento dos dados, envolvendo as seguintes etapas:

- i. **remoção de ruídos**, como por exemplo espaços extras, caracteres inválidos para o propósito de interesse, erros de alinhamento e de tabulação etc;
- i. **remoção de informações espúrias e/ou inválidas**, o que proporcionou uma pré-seleção das variáveis;

- ii. **uniformização das variáveis**, a partir de conversões de unidades, tendo em vista em reuni-las em uma identidade numérica comum (de pés para metros, km^2 para acres, etc); Quando disponível apenas densidade em gramas por centímetros cúbicos, foi transformada para API, já que a escala API apresenta uma distribuição mais adequada para visualização dos dados, além de ser padronizada na indústria de petróleo e seu uso amplamente comum. Além disso, em muitos casos tinha-se a composição do óleo por frações de hidrocarbonetos, porém manteve-se apenas o °API por se julgar que, junto a viscosidade e demais parâmetros, possui uma adequada representatividade acerca das respectivas características óleo para o objetivo proposto.
- iii. **remoção de campos duplicados e mesclagem de informações**, que proporcionou a integração de dados complementares, presentes para um mesmo campo em diferentes bases de dados. Para isso, iniciou-se a identificação de cada campo/reservatório, com atribuição de um número ID. Foram excluídos os casos em que haviam registros duplicados referentes ao mesmo projeto, decorrentes da presença em publicações de anos e periódicos diferentes, mas que se referiam ao mesmo reservatório. Nesses casos, optou-se pelo dado que fosse mais recente e que pertencesse à fonte de dados avaliada como mais confiável;
- iv. **inspeção geral do conjunto de dados**, verificando possíveis inconsistências ou discrepâncias, bem como verificação de valores atípicos por meio de ferramentas como intervalos dos valores, filtros de planilhas, tabelas dinâmicas, *boxplots* e definição de limite inferior e de limite superior por meio da determinação dos respectivos intervalos interquartis;
- v. **remoção de dados que apontavam inconsistências**, desenvolvida a partir de pesquisas mais detalhadas e individualizadas sobre os respectivos campos, que apontavam a não veracidade de informações coletadas; além disso, é feita a exclusão de outliers, como por exemplo permeabilidades máximas da ordem de 20000 mD devido à presença de fraturas, que poderiam levar a tendências não realísticas se fossem levadas em conta. Quando disponível, traçaram-se os histogramas e buscou-se a medida de tendência média que melhor representasse - que em geral foi média ou moda, nos casos da presença de valores extremos e/ou uma faixa de

valores com alta frequência ajustada conforme a largura das barras dos histogramas. Projetos de EOR mal sucedidos são considerados a parte, uma vez que seus insucessos podem ter sido tanto causados tanto por aspectos técnicos como por questões políticas específicas, que podem não diretamente contribuir para uma adequada seleção e entendimento da dinâmica dos métodos de EOR.

- vi. **desenvolvimento de subcasos**, realizada para campos em que fora constatada aplicação de mais de um método de EOR em diferentes reservatórios ou companhias com diferentes operações; além disso, há campos que possuem duas ou mais formações geológicas com características substancialmente diferentes. Assim, tratou-se como amostras distintas campos que abrangessem duas ou formações geologicamente diferentes, a exemplo de poços que atravessam formações produtoras tanto da Bacia de Santos como do Pré-Sal. Outro exemplo disso, é o campo de South Belridge, em que parte das reservas encontram-se na Formação Tulare, da idade do Pleistoceno, e outra parte na Formação Diatomita, da idade do Plioceno-Mioceno. O petróleo da Formação Tulare é bruto pesado, com uma gravidade específica de 10–13 API e um baixo teor de enxofre de 0,23%, enquanto o óleo do Diatomita é classificado como bruto médio, com um índice API de 25–30
- vii. **identificação e correção de padrões de inconsistências**, em que ao longo do processo de aquisição das primeiras bases de dados, em que procurou-se identificar quais eram os tipos de erros de associados, bem como fazer perguntas acerca das respectivas origens e causas dos respectivos problemas detectados. Com base nisso, obteve-se um melhor embasamento para, à medida que a metodologia de processamento foi evoluindo, buscar alternativas mais automatizadas e criteriosas para se corrigir tais erros e, assim, facilitar a integração de novas bases de dados complementares;
- viii. **geração de médias geométricas para equilibrar valores de propriedades**, necessário para variáveis como permeabilidade e viscosidade, uma vez que média geométrica é uma medida de tendência apropriada quando os valores mudam de forma exponencial. Dessa maneira, foram normalizados os alcances que podem ser alcançados,

garantindo o equilíbrio entre valores intervalares das bases originais, além caracterizar estabilidade em relação a *outliers*;

- ix. **agrupamento de valores e respectivo cálculo de médias**, como por exemplo para o preço do petróleo, em que se calculou as médias aritméticas referentes a cada mês do histórico, resultando em um valor por mês

3.2.2 Gerenciamento de variáveis

Para tornar a estrutura das variáveis apropriada à aplicação das técnicas de IA, e com o objetivo de extrair o máximo possível de informações, foi feito o gerenciamento das variáveis por meio de:

- i. **desmembramento ou junção de variáveis**, em que para variáveis que apresentavam intervalos numéricos, como porosidade, permeabilidade, profundidade, viscosidade, °API, temperatura do reservatório, criou-se novas colunas extraíndo os respectivos valores mínimos, máximos, médios, bem como o tamanho de tal intervalo;
- ii. **normalização de variáveis**, de forma a evitar diferenças nos pesos de treinamento das RNA's. Em virtude da transformação na distribuição de dados que técnicas de normalização promovem, cabe ressalva que ao se normalizar dados de um mesmo atributo mas de duas localidades diferentes, poderá estar se perdendo informações relativas à heterogeneidade geológica;
- iii. **transformação de variáveis categóricas em binárias**, possibilitando a análise de uma diversidade de atributos; para as variáveis qualitativas (país, tipo de EOR, empresa operadora, estado, formação, produção prévia e maturidade, avaliação, lucratividade, escopo do projeto, dentre outras) criou-se novas variáveis a partir das respectivas categorias de cada variável, em que cada célula recebia 1 se apresenta tal atributo ou 0 caso não
- iv. **combinação de variáveis de bases distintas com acepções semelhantes**, permitindo remoção de determinados dados que sejam considerados redundantes para o escopo estabelecido;

- v. para os métodos de EOR, **dividiu-se em relação às diferentes categorias** (métodos térmicos, injeção de gás, injeção de produtos e outros), subcategorizando-se ainda em relação ao tipo de método térmico utilizado, ao tipo de gás injetado e ao tipo de produtos químicos utilizados. Além disso, para a injeção de gás, classificou-se também para se o processo é miscível ou não e também quanto ao método de injeção, subdividindo-se: em se o processo é de injeção contínua de gás; se alternada com água (WAG - *Water Alternating Gas*), se ocorre injeção simultânea de água e gás, se é com redução da taxa de injeção de gás e aumento da de água com o tempo (TWAG - *Tapered Water Alternating Gas*); e ainda se é associado com projetos de estocagem e armazenamento de CO₂ (CCS - *Carbon Capture and Storage*). Dessa forma, foi possível reduzir o número de variáveis associadas aos métodos de EOR, além de agrupar em classes de interesse métodos de EOR que se encontravam originalmente extremamente especificados (por exemplo, se em um projeto o método aplicado foi injeção de CO₂ imiscível alternado com água (CO₂_imisc_WAG), a nova classificação o dividiu em três classes: injeção de gás tipo CO₂, processo miscível; injeção do tipo alternada com água).
- vi. **criação de novas variáveis com atributos grandezas físicas de interesse**, a partir da combinação de propriedades anteriores, favorecendo novos parâmetros e enriquecendo a análise; a exemplo de variáveis conjugadas, pode se citar, por exemplo, a obtenção de: (a) latitude e longitude a partir de código em VBA linkado a API do Google (ferramenta que permite obter coordenadas a partir de registro de localização) que georreferencia dados como estado, condado, província, distrito e/ou município em que o campo se localiza a valores de coordenadas, (b) obtenção do coeficiente de mobilidade do óleo obtido pela razão entre permeabilidade e viscosidade do óleo, (c) eficiência de deslocamento obtida pela diferença entre saturação final e inicial, dividida pela saturação inicial, dentre outras variáveis.
- vii. aplicação de transformação logarítmica para variáveis que mostraram apresentar distribuição log-normal, dentre elas: permeabilidades,

viscosidades mínimas, máximas e médias e densidade de poços por área.

As variáveis obtidas e a estrutura geral da base de dados processada e respectivos significados podem ser consultadas no [anexo 2](#), cuja legenda explicativa encontra-se no [anexo 1](#).

Figura 9. Etapas relativas ao pré-processamento da base de dados.



3.3 Processamento e metodologia de análise

3.3.1 Análise Exploratória

Como etapa seguinte, foi realizada uma análise exploratória. A etapa buscou, por meio de técnicas estatísticas, identificar variáveis que poderiam apresentar maior relevância para o problema em questão. Para tanto, foram desenvolvidas matrizes de correlação de *Pearson*, *Spearman* e *Scatterplots*, tendo em vista um entendimento inicial de tal conjunto de dados. Posteriormente, foram executados testes de significância, tendo por objetivo selecionar variáveis que, a princípio, demonstram maior relação com a dinâmica interna dos fatores que afetam a aplicação dos métodos de EOR. Dessa forma, primeiramente, fora desenvolvido um inicial entendimento da

base de dados formada, verificando estatisticamente se a sua construção e se a aplicação da metodologia proposta seria adequada a tal problema e banco de dados.

3.3.2 Análises por Inteligência Artificial – Self-Organizing Maps

No âmbito das RNA's, os *Self-Organizing Maps* (SOM) consistem em uma técnica de clusterização com abordagem não-supervisionada e que utiliza a quantização vetorial em um espaço n-dimensional (KOHONEN 2001). Os dados estimados pela técnica têm como base as distâncias entre os vetores disponíveis (FESSANT & MIDENET 2002; KALTEH et al. 2008; WANG 2003). Para a análise e *screening* é utilizada a rotina proposta por CARNEIRO (2012), utilizada por esses autores para a classificação de dados geológicos. No entanto, neste trabalho, é feita a adaptação para as variáveis relacionadas à dinâmica dos reservatórios de petróleo, em que processo de estimativa tradicional é dado por substituição, onde os valores são produzidos a partir dos vetores das *Best Matching Units* (BMU's).

Figura 10. Etapas realizadas no processamento e análise dos dados.



(Autoria própria)

Tais dados são formatados para a leitura vetorial das amostras a serem analisadas, e como variáveis de entrada são utilizadas as variáveis selecionadas pelos testes estatísticos descritos. Cada campo de produção é tratado como um vetor, ou instância, cujas propriedades (ou variáveis) são apresentados a partir de colunas na base de dados. A base de dados integrada, então, foi introduzida no algoritmo SOM, desenvolvido em linguagem MatLab, onde foi introduzido um espaço de dados de forma aleatória no conjunto n-dimensional. Uma grade hexagonal foi escolhida como formato de visualização, e a superfície de um hipervolume toroidal foi utilizada para a projeção dos neurônios ou BMU's para, respectivamente, manter relações de similaridade e topológicas, e evitar efeitos indesejáveis de borda. Após a geração do mapa auto organizado, foram produzidas as imagens da Matriz-U e das *component plots*. Estas componentes possibilitam visualizar e quantificar a contribuição das variáveis analisadas para cada neurônio resultante no mapa auto-organizável, sendo possível verificar interrelações entre as respostas das variáveis analisadas. A matriz-U possibilitou, então, a classificação dos dados relacionada ao vetor similaridade, construído a partir das instâncias originais.

Cada neurônio que possua instâncias de reservatórios associados no mapa auto-organizado foi representado por um BMU, ou seja, um “mini-cluster” das instâncias de entrada, agrupando reservatórios ou campos de produção com características análogas. Como resultados, teremos os BMU's para cada amostra e variável analisada, bem como BMU's para esses mesmos parâmetros nas amostras com análises incompletas, permitindo separação e a identificação de padrões conforme quão similares forem em relação aos demais. A [Figura 14](#) resume tais etapas.

3.3.3 Interpretações e Validações

Com parte da análise das imagens geradas, foi realizado um procedimento integrado, fazendo uso tanto de interpretações quantitativa quanto qualitativas. São utilizados de maneira conjunta scatterplots, histogramas e correlação intervariáveis junto à observação das *component plots* geradas pelo SOMs. Hipóteses são construídas com base na análise conjunta das variáveis, buscando validação das inferências realizadas com a literatura e observações de campo. Com isso, espera-se contribuir para os estudos relacionados à análise da dinâmica de reservatórios baseado em análises multivariadas.

3.3.4 *Screening* de métodos de EOR

Para a realização da predição dos métodos de EOR foram utilizados campos em que artigos recentes de referência também realizam *screening*. Dessa maneira a metodologia desenvolvida pôde ser validada com os devidos parâmetros de comparação. Isso possibilitou o traçado de uma comparação equilibrada entre os diferentes *screenings*. Assim, tornou-se possível verificar o quão inovador e assertiva e inovadora seria ou não a proposta apresentada no presente trabalho. Para tanto, caso o campo utilizado pelos artigos como exemplo esteja presente na base de dados, sua respectiva amostra é excluída do treinamento. Caso o artigo utilizado como comparação não mencione, por motivos diversos, a exemplo de confidencialidade, acerca de qual campo se trata, buscou-se na base de dados verificar se ocorria a presença dele e, então, sua exclusão é também realizada, cuja busca é realizada por meio da similaridade do cosseno. Também foram excluídos da base de dados de treinamento campos em que a indicação de sucesso da aplicação de EOR tenha sido apresentada como não satisfatória.

Também é inovadora a utilização do cosseno similaridade (e seu complementar dissimilaridade do seno) entre os vetores amostras para se identificar reservatórios análogos. Em decorrência de a derivada do cosseno de ângulos perto de zero apresentar baixos valores, a variação do cosseno entre vetores que possuam grande grau de similaridade torna-se baixa, podendo tornar difícil a visualização de nuances entre reservatórios com alto grau de similaridade em relação às propriedades analisadas. A sua co-função seno, por outro lado, possui valor de derivada mais acentuada para ângulos próximos de zero, podendo ser mais adequada, portanto, para o estudo de fenômenos cujos vetores no espaço apontam para direções muito próximas uma das outras, destacando com mais facilidade determinadas diferenças de interesse. Como os reservatórios presentes na base de dados consolidada possuem um significativo número de vetores análogos relativamente similares, e cujas nuances que se deseja observar são o objeto de estudo, optou-se então por utilizar dissimilaridade do seno para a construção dos gráficos de visualização de reservatórios análogos. É importante ressaltar que, na prática, as duas formas são medidas complementares de uma mesma grandeza, a similaridade (ou dissimilaridade)

Apesar de ser conceitualmente diferente da distância euclidiana, utilizada como medida de similaridade na metodologia SOM, visa-se verificar a similaridade ou não entre diferentes reservatórios sob outra perspectiva (dissimilaridade do seno), buscando assim enriquecer a análise. Além disso, para verificação da consistência da metodologia de triagem desenvolvida, como ilustra a [figura 7](#), são buscados de forma iterativa artigos que tratem da aplicação de EOR em reservatórios análogos ao submetido ao *screening*, com o intuito de validar ou não os resultados obtidos e implementar possíveis melhorias. Caso as previsões realizadas e resultados obtidos não se demonstrem satisfatórios, é focado esforço em uma ou mais das seguintes abordagens, conforme se verificar necessário: ampliar a base de dados; refinar o processo de limpeza e tratamento dos dados; e/ou ajustar de forma aprimorada parâmetros de treinamento da rede neural.

4 RESULTADOS E DISCUSSÕES

A base de dados integrada totalizou 323 variáveis, 1035 reservatórios, operados por 73 empresas operadoras, e distribuídos em 28 países.

Conforme ilustra a [figura 15](#), verifica-se no mundo grande diversidade de atores na implementação de projetos de EOR, havendo desde empresas globalmente conhecidas e integradas ao longo de toda a cadeia produtiva de petróleo e de comercialização de derivados (a exemplo de British Petroleum, Chevron, China National Offshore Oil Corporation, Equinor, ExxonMobil, Petrobras, Petronas, etc) até empresas independentes e muitas vezes com atuação regional (como Anadarko, Apache, Athabasca, Canadian Natural Resources, Carrizo, Continental Resources, etc), mas que representam por significativa parcela da liderança na execução de projetos de EOR. Apesar de variáveis referentes às companhias operadoras dos campos de produção em muitos casos apresentarem significativa correlação com o restante das variáveis contidas na base, optou-se por retirá-las do treinamento, com o intuito de enfatizar a análise da aplicação dos métodos de EOR.


Figura 11. Logos das principais aplicadoras de projetos de EOR presentes na base de dados. Verifica-se grande diversificação de players no setor no mundo, havendo desde empresas que atuam em escala regional e focadas no upstream, especialmente nos EUA, até companhias com reconhecida atuação global e abarcando as diversas etapas da cadeia de valor da indústria de petróleo.



(Autoria própria).

Observa-se também a existência de projetos de aplicação de EOR em um grande número de países e com significativa distribuição global, revelando a disseminação das técnicas de EOR ao longo do tempo. Porém, como ilustram as figuras 15 e 16, nota-se uma certa concentração em países que, de uma forma ou de outra, fomentam condições próprias para a implementação de projetos de EOR. Dentre tais regiões, destacam-se a China, a América do Norte e países banhados pelo Mar do Norte.

Figura 12. Localização dos principais campos de produção de petróleo presentes na base de dados. As coordenadas foram obtidas a partir de registros de localização consultados por API (*Application Programming Interface*) disponibilizada pelo Google, e cujo processo de obtenção foi automatizado por código linkado em VBA (*Visual Basic for Applications*).



(Autoria própria).


Figura 13. Ilustração de alguns dos países com projetos de implementação de EOR presentes na base de dados consolidada. Há desde nações desenvolvidas da América do Norte e Europa com grande demanda energética e com um já grande número de projetos de EOR implantados, até países da América Latina, Oriente Médio e África com uma escala relativamente menor de adoção de técnicas avançadas de recuperação de petróleo.



(Autoria própria).


Os resultados da análise exploratória e testes estatísticos forneceram um total de 171 variáveis com correlação que indicam significância relacional e que foram consideradas como diretamente pertinentes aos objetivos desse trabalho. As demais variáveis que não foram incluídas na análise podem ser o foco de outras investigações futuras, ainda que apresentem significativos graus de correlação com o conjunto de variáveis elegidas. Informações detalhadas sobre as variáveis selecionadas podem ser vistas na quinta coluna da planilha de variáveis (anexo X). A matriz de correlação e respectivos scatter plots de um subconjunto da base de dados final podem ser observados, respectivamente e parcialmente, nas figuras [18](#), [19](#) e [20](#).

Figura 14. *Scatterplot* de parte do conjunto de variáveis. As amostras em vermelho representam projetos de EOR com alocação como mal sucedida; amostras em azul representam aplicação bem sucedida. Na diagonal, os histogramas são aproximados pela função de densidade kernel, por meio da qual pode-se observar variáveis em que a transformação logarítmica log-normal pode ser pertinente.. Procedimentos semelhantes foram feitos utilizando *boxplots*.




(Autoria própria).

Figura 15. Matriz de correlação para intervalo básico de variáveis, selecionadas após limpeza dos dados. Observa-se pares de correlação vazios, o que é decorrente de um baixo número ou ausência após processamento e limpeza de valores significativos correspondentes para duas variáveis em uma mesma amostra.



(Autoria própria).

Figura 16. Scatterplot de parte do conjunto de variáveis, com transformação log-normal realizada para as distribuições que demonstraram pertinência à sua aplicação (as que iniciam com Log no respectivo nome). Na diagonal, os histogramas são aproximados pela função de densidade kernel. As amostras em azul representam projetos de EOR onshore; as amostras em verde representam projetos de EOR executados em campos offshore. Em comparação com projetos onshore, verificam-se poucos campos offshore em que foram aplicados métodos de EOR (67 registros na base de dados consolidada constaram aplicação offshore de EOR), sendo um reflexo dos desafios inerentes a aplicação de métodos de EOR em ambientes offshore e da consequente ainda incipiente experiência da indústria de maneira geral nesse cenário.




(Autoria própria)

4.1 Inteligência Artificial: Self-Organizing Maps em abordagem mundial para EOR

A aplicação da técnica SOM às variáveis selecionadas como mais adequadas da base de dados mundial resultou em mapas auto-organizados com tamanho de 12 por 12 células, o que consiste em uma rede neural artificial de 144 neurônios transformados em BMUs. Os mapas auto-organizados gerados para as variáveis selecionadas foram representados nas figura [26](#) e [27](#). O erro de quantização foi de 4.21 e o topográfico de 0.0262. Tais erros foram considerados aceitáveis, uma vez que se trata de uma análise mundial, o que remete ao comum distanciamento topológico e topográfico das amostras no espaço das variáveis. As variáveis referentes aos países foram retiradas do treinamento da rede, porém foram projetadas na configuração do mapa, para efeitos de comparações dos registros, conforme mostra a figura [27](#). Um exemplo da equivalência entre as representações das transformações espaciais realizada pelo SOM é mostrado na figura [21](#), em que observa-se a planificação dos respectivos hipertoróides das variáveis referentes a alguns países.

Figura 21. Exemplo da planificação realizada pelo algoritmo SOM ao planificar as projeções dos hipertoróides para a forma de *component plots*, permitindo realizar-se a leitura e interpretação dos dados. Para as variáveis dos nove países presentes na figura, verifica-se a existência de grande número de reservatórios com implantação de projetos de EOR nos EUA (circulado em azul), cuja influência é associada com o quão quente é a cor nos mapas.




(Autoria própria)

4.1.1 Interpretação das component plots e da matriz-U

Como exemplo didático, a [Figura 22](#) ilustra como é realizada a interpretação e leitura dos dados clusterizados pelo algoritmo SOM. A representação bidimensional pode ser apresentada pelas *component plots*, onde os valores das variáveis são dispostos em escala de cores. Assim, a variação dos valores das variáveis é escalonada entre cores mais frias (azuis), representando baixos valores e cores quentes (vermelhos), representando os altos valores. Já na Matriz-U, outro formato de visualização dos mapas auto-organizados, as cores quentes representam alta dissimilaridade entre os neurônios adjacentes, enquanto que as cores frias representam alta similaridade, ou seja, proximidade de distância entre os neurônios no espaço n-dimensional. Na [Figura 22](#) nota-se que os agrupamentos 1 e 2 apresentam campos de produção com baixos °APIs e altas viscosidades. Tais regiões possuem continuidade topológica: a parte da esquerda se conecta com a da direita em cada um dos mapas, fato decorrente do recorte e da planificação das superfícies hipertoroidais. Já os agrupamentos 3 e 4 são compostos principalmente por reservatórios com óleos de altos °APIs e baixas viscosidades. Os neurônios das regiões 3 e 4 também apresentam conectividade topológica, porém agora pelas extremidades inferior e superior dos mapas. A região 5 do mapa, que se encontra na região central dos mapas, possui neurônios nas cores azul claro e amarelo, representam em geral reservatórios com óleos de °APIs e viscosidades médias. Vale lembrar que a configuração do mapa e respectivos pares BMUs/neurônios são inicializados de maneira aleatória, mas que porém o agrupamentos de dados e relações de vizinhança tende a se manterem, em que as respectivas posições apenas transladam conforme diferentes treinamentos sejam feitos. Dessa forma, se nesse treinamento as amostras de dados referentes à região 1 encontram-se no canto inferior esquerdo dos mapas, próximos à região 4, em um novo treinamento tais conjuntos de dados podem assumir novas posições nos mapas, contudo tendem a permanecer próximos, mantendo as relações topológicas e de similaridade entre tais grupos de dados. Ainda no exemplo da [Figura 22](#), observa-se que o agrupamento 6, formado por reservatórios principalmente do Mar do Norte (Noruega), apresentam óleos com °APIs altos e viscosidades baixas. O agrupamento 7, por sua vez, tende a ser composto por reservatórios principalmente do Brasil, com óleos de °APIs baixos a médios e viscosidades médias a altas nos neurônios inferiores; e °APIs

médios a altos e viscosidades médias nos neurônios superiores. As regiões circuladas em amarelo representam campos da Venezuela, que encontram-se majoritariamente no interior das regiões 1 e 2, que possuem óleos com baixos °API e altas viscosidades. A região circulada em preto na Matriz-U representa casos de reservatórios que possuem baixo grau de dissimilaridade com os seus vizinhos próximos, o que pode ser visto pelas cores mais frias em tais neurônios da matriz-U. Já a região destacada em verde na Matriz-U representa casos de reservatórios que possuem alto grau de dissimilaridade com os seus vizinhos próximos, o que pode ser visto pelas cores mais quentes em tais neurônios da matriz-U. Tal pouca similaridade nessa região é decorrente da influência das demais variáveis no cálculo da distância euclidiana entre os vetores reservatórios


Figura 17. Ilustração exemplificando a leitura e interpretação das component plots. A interpretação dos mapas é realizada de forma conjunta, identificando regiões de neurônios representativos de determinados e buscando interrelações com outras variáveis. A região assinalada com **1** nos mapas representa o mesmo conjunto de dados para as component plots de todas as variáveis, variando apenas o atributo a que se está se referindo: °API, viscosidade média, se o reservatório é localizado no Brasil, se localizado na Noruega, se localizado na Venezuela.



(Autoria própria)

Uma análise inicial dos mapas foi feita em conjunto com os *scatter plots*. Dessa maneira tornou-se possível observar, a partir dos gráficos de dispersão, se determinada inferência faz sentido. Foram identificados alguns padrões que demonstram relações já esperadas, como por exemplo o *API_avg* e a *Viscos_cP_avg* do óleo serem, aproximadamente, inversamente correlacionados. Os mapas também mostraram que grupamentos com alta mobilidade do óleo apresentam baixas viscosidade e alta a médias permeabilidades. Os mapas também evidenciaram que, geralmente, regiões de reservatórios com maiores profundidades possuem menor porosidade e temperaturas mais elevadas. Isso pode ser explicado, respectivamente, pelo grau de compactação e gradiente geotérmico à medida em que a profundidade aumenta. Além disso, verificou-se relação aproximadamente inversa entre porosidade e compressibilidade, o que estaria relacionado ao fato de que formações mais porosas tendem a ser mais suscetíveis ao efeito da atuação da pressão. É importante ressaltar que as variáveis *API_avg*, *Viscos_cP_avg*, *Permeab_avg* tiveram suas distribuições logaritmizadas, e que as escalas refletem tais valores.

Figura 18. *Component plots* das variáveis básicas do modelo.




Fonte: Autoria Própria

Outras variáveis analisadas em mapa foram: Real_Oil_Price_USD (preço real do barril de petróleo) e Nominal_Crude_Oil_Price (preço nominal do barril de petróleo, considerando inflação), também presentes na [figura 23](#). Os mapas demonstraram a suavização dos valores em datas inferiores a 1980. Isso pode ser atribuído ao fato de existirem relativamente poucos registros de projetos de EOR anteriores a 1980. Atribui-se ainda o fato de que a técnica EOR não seria tão difundida à época, além do que o preço do barril de petróleo era relativamente baixo. Isso, provavelmente, inibiu a aplicação de determinadas classes de métodos de EOR. A partir da posição do BMU na Matriz-U foram verificados quais neurônios representam tais projetos de EOR. Notou-se, portanto, que os BMUs estão associados à região inferior direita dos mapas. Os BMUs representativos de projetos com datas de até 1985 também representam campos de EOR com início anterior a 1970. Isso pode estar associado ao fato de que as demais variáveis exerceram maior influência para que tais projetos fossem representados por neurônios com Start_date superior a 1980. Além disso, nota-se poucos projetos com Start_date acima de 2015. Tal ausência de projetos mais recentes é, de maneira análoga, também representada pela *component plot* Start_date, em que se verifica que os projetos de EOR com data de início superior a 2015 estão sendo representados majoritariamente por neurônios próximos à região central do mapa. Contudo, não é possível afirmar que na última década haja, mundialmente, poucos projetos de EOR que foram implementados. O baixo número constatado referente a esse período pode estar relacionado ao fato de que os resultados e demais dados acerca da aplicação de EOR mais recentes ainda não e/ou divulgados pelas empresas operadoras ou em artigos científicos, e, portanto, não foram contemplados na estruturação da base de dados no presente momento.

Tais resultados obtidos via SOM relativos à variação do número de projetos de EOR também podem ser corroborados pelo gráfico da [figura 24](#). Como não foi possível se obter as datas finais da implementação dos projetos de EOR para todos os campos, optou-se por o número de projetos de EOR por ano no gráfico levar em consideração apenas suas respectivas datas de início. Caso fossem consideradas toda a extensão de aplicação de EOR na construção do gráfico, possivelmente o número de projetos de EOR em cada ano tende a aumentar, uma vez que considera não apenas o início, como toda a suas respectivas vigências.

As principais desvantagens verificadas ao longo dessas décadas de aplicação dos métodos de EOR incluem altos investimentos exigidos (como adequações de instalações de compressão, injeção e tratamento), que, na maioria dos casos, são investimentos *front-end* com retornos dados em um longo intervalo de tempo/payback e seus altos custos operacionais. Conforme observado no gráfico da figura 16, com exceção dos métodos térmicos de injeção de vapor, que tendem a ser aplicados em reservatórios mais rasos do que 900 m, e de processos miscíveis em áreas onde o gás de injeção barato encontra-se disponível foram os que mais encontraram aplicação comercial até a década de 80, até 1990, as outras classes de processos de EOR, na melhor das hipóteses, situaram-se na fronteira entre lucro e prejuízo: isso os tornou particularmente vulneráveis às quedas do preço do petróleo devido à sua baixa maturidade tecnológica e de aplicação em escala comercial. Além disso, em tal período o maior número de projetos e as maiores produções de petróleo decorrente da implementação de métodos de EOR ocorreu nos EUA. Dentre os motivos para isso, destaca-se por os EUA ser uma área madura, um grande número de campos de petróleo depletados, com alta disponibilidade de tecnologia e infraestrutura além de uma situação política estável, tornando-o o lugar ideal para implementação de projetos pilotos e comerciais de EOR em tais períodos.

Figura 19. Preços do barril de petróleo Brent (nominal e descontada a inflação tendo como base os EUA) e número de projetos de EOR presentes na base de dados consolidada relativos a cada categoria de EOR ao longo do tempo. Os dados relativos aos os preços de barril de petróleo, por sua vez, foram obtidos de relatório da U.S. Energy Information Administration (2019). O preço descontado a inflação também foi incluído para se obter uma comparação mais justa entre cenários econômicos distintos.



Fonte: Autoria Própria

Observando-se conjuntamente os gráficos das figuras [2](#), [24](#) e [25](#), nota-se em especial um aumento significativo do número de papers e de projetos de EOR relacionados a injeção de produtos químicos, em especial da injeção de polímero e surfactante. Tal fato pode estar associado com o barateamento de produtos de químicas fina e o desenvolvimento de novos compostos que motivaram o estudo e a aplicação em variadas condições de reservatório. Conforme a tabela 2, a venda de produtos químicos, em especial surfactantes, por parte da indústria química vem crescendo vigorosamente ano a ano, com projeções de aumento. Como exemplo disso, as empresas Stepan e Nalco, operando sobre a join-venture Tiorco, criaram um canal integrado de vendas e serviços que se beneficia do amplo alcance da Nalco nos mercados globais de energia upstream, seu recentemente adquirido conhecimento em polímeros e reservatórios EOR e os recursos globais de tecnologia e fabricação de surfactantes da Stepan. Além disso empresas como BASF, Dow, Oxiteno, Croda, dentre outras, desenvolveram linhas específicas de polímeros e surfactantes (*Aspiro*,

Elevate, Ultroil, etc) desenhadas para a aplicação em projetos de EOR, incluindo o uso de blends de co-solventes e co-surfactantes aniônicos e não aniônicos para redução da tensão interfacial e aditivos para alteração de molhabilidade.


Tabela 2. Mercado global anual e projeções de vendas de produtos surfactantes voltados para o segmento de EOR. Valores em milhões de dólares.

Região	2016	2017	2018	2019	2020	2021	2022	2023	CAGR% (2017–2023)
América do Norte	3,123	3,327	3,532	3,739	3,946	4,153	4,362	4,571	5.4
Europa	382	410	438	467	496	526	556	587	6.2
Asia-Pacífico	323	351	380	409	440	472	504	538	7.4
LAMEA	825	888	953	1,019	1,086	1,155	1,226	1,298	6.5
Total	4,653	4,976	5,303	5,634	5,968	6,306	6,648	6,994	5.8

Apdaptado de AMR Analysis (2018)

Isso, por sua vez, pode ser um dos fatores associados à redução do número de projetos em que houve injeção de vapor, uma vez que essas duas tecnologias tendem a atuar em reservatórios com características semelhantes (óleos pesados a viscosos e permeabilidades significativamente altas). Todavia, observa-se que em decorrência de fatores como o estímulo à produção de oil sands no Canadá e outras fronteiras exploratórias com óleo pesado, houve aumento considerável do número de trabalhos e campos de produção mostrando a aplicação de SAGD. Além disso, com já grande número de papers, mais recentemente a injeção de água de baixa salinidade vem se mostrando como potencial técnica de aplicação em diversos reservatórios após implementações bem-sucedidas e cuja dinâmica dos fenômeno envolvidos ainda não são totalmente compreendidas. Também vem crescendo a pesquisa acerca da injeção de CO₂ e sua implementação, o que em parte é ensejada por conta de ser uma tecnologia que está dentro das indicadas para redução da emissão de gases de efeito estufa, além de satisfatórios resultados operacionais que vem apresentando em muitos reservatórios.

Figura 20. Participação/marketshare do número de projetos de EOR presentes na base de dados consolidada relativos a cada categoria de EOR ao longo do tempo. Observa-se maturidade dos métodos térmicos e relativa expansão da adoção de injeção de dióxido de carbono e de produtos químicos. Outras novas tecnologias também vêm despontando recentemente, a exemplo de *Low Salinity Waterflooding* e *microbial*.



Fonte: Autoria Própria

Figura 21. *Component plots* geradas pelo mapa auto-organizado obtido a partir da base de dados após a análise exploratória. É importante notar que as bordas opostas dos mapas planejados são na verdade vizinhos, ou seja, o lado extremo esquerdo está conectado ao direito, e o inferior ao superior. Para *component plots*, cores quentes (vermelhos) representam os valores mais elevados para cada variável, enquanto que cores frias (azuis) representam os valores mais baixos para cada variável. Já para a Matriz-U, último mapa da figura, vermelhos indicam alta dissimilaridade, enquanto azuis indicam regiões de maior similaridade entre neurônios adjacentes. Fonte: Autoria Própria





Figura 22. *Component plots* mostrando distribuição dos países (Ct_) e métodos de EOR. Vale ressaltar que as variáveis relativas aos países (Ct_) não foram utilizadas para o treinamento SOM, porém podem ser observadas conjuntamente no mapa auto-organizado, para compreensão em contraste com as demais variáveis. Cores quentes (vermelhos) representam os valores mais elevados para cada variável, enquanto que cores frias (azuis) representam os valores mais baixos para cada variável. Fonte: Autoria Própria




4.1.2 Métodos térmicos

A análise dos mapas também possibilitou observar os parâmetros de reservatórios referentes aos métodos térmicos. Tais técnicas de recuperação, geralmente, apresentam altos valores coincidentes com óleos de alta viscosidade, baixos valores de °API, bem como com baixos valores de profundidades. Tais observações podem ser corroboradas pelo fato de que maiores reduções de viscosidade provocam aumento da mobilidade do óleo e da eficiência de varrido, já que o óleo pesado apresenta características de variar mais a sua viscosidade, facilitando-se o fluxo

4.1.2.1 Injeção de vapor

Para profundidades maiores, a pressão do reservatório tende a ser mais elevada, e conseqüentemente o calor latente, em que passa a se requerer uma maior temperatura para efetivamente converter água injetada em vapor. A [Figura 28](#) mostra que a injeção de vapor (Therm_Steam, Therm_Steam_drive e Therm_Steam_solv) apresenta maiores valores associados menores profundidades (Depth_ft_avg). Outras características das ocorrências destes métodos são as regiões coincidentes com resultados econômicos menos favoráveis (Profit_Yes) em reservatórios mais profundos (Depth_ft_avg), além de baixos valores para ocorrência *offshore* (Offshore_yes), o que indica a baixa aplicação do método em campos *offshore*. Contudo, conforme também é possível observar nos mapas, tal efeito decorrente de reservatórios mais profundos pode ser atenuado caso se tenha formações com maiores valores de permeabilidade (Permeab_media_mD), já que tal propriedade, além de permitir maior escoamento do óleo, também afeta as vazões de injeção e produção. Para zonas com menores valores de permeabilidade, são requeridos maiores valores de pressão para manter o escoamento (lei de Darcy), o que pode tornar o processo inviável em maiores profundidades.

Figura 23. Component plots referentes às variáveis analisadas para os métodos térmicos.



(Autoria Própria)

Nos métodos de injeção de vapor, a maior fonte de perda calor é a própria formação rochosa, já que cerca de apenas 20% é efetivamente transferido para a redução da viscosidade do óleo (SHENG, 2013). Destaca-se ainda que a injeção de vapor apresenta, em geral, baixa eficiência de deslocamento do óleo (Displacement_efficiency), levando a saturações finais mais altas. Contudo, tende a apresentar significativos índices de sucesso (Proj_eval_Succ e Profit_Yes) de aplicação, especialmente em reservatórios com permeabilidades maiores do que a média do conjunto. É somado a isso o fato de em campos de produção *onshore* os custos serem relativamente mais baixos, levando inclusive a altas de densidades de poços produtores e injetores por unidade de área (Prod_well_dens e Inj_well_dens), operados em diversos casos por empresas de médio porte nos EUA e Canadá, ou ainda a estatal Venezuelana (PDVSA). Tal maior número de poços para uma mesma área produtora pode ser desenvolvida por meio de processos como *infill drilling*, que consiste na perfuração de novos poços com um adensamento da malha prévia de

poços do campo produtor. *Infill drilling* é um meio de melhorar a eficiência da varredura, aumentando o número de poços em uma área. A distância entre poços e a área drenada por um poço correlaciona-se com o espaçamento do poço (Figura 26). Nos Estados Unidos, um espaçamento típico é expresso em termos de acres. Por exemplo, o termo "espaçamento de 40 acres" refere-se a poços verticais que podem drenar uma área de 40 acres. Uma milha quadrada contém 640 acres, então há 16 áreas com 40 hectares cada em uma milha quadrada. Portanto, o número de poços que podem ser perfurados em uma milha quadrada com espaçamento de 40 hectares é de 16. *Infill drilling* é um método convencional usado para acelerar a produção a partir de reservas comprovadas e até recentemente não era pensado como um método pelo qual um operador poderia aumentar as quantidades de reservas passíveis de recuperação. Conforme observado nos mapas, um adensamento do número de poços na malha (ou redução do espaçamento entre os poços – representado nos mapas pelo valor inverso das variáveis Prod_well_dens e Inj_well_dens) é frequente em projetos de injeção de vapor/métodos térmicos (Therm_Steam, Therm_Steam_drive, Therm_Steam_solv, Therm_Eletrom). Além disso, por inspeção da base de dados, observou-se que o adensamento da malha de poços (*Infill Drilling*) tende a ser uma prática frequente em uma variedade de circunstâncias, incluindo, mas não limitado a, o seguinte: reservatórios com características conjuntas de permeabilidade (Permeab_mD_avg) e viscosidade do óleo (Viscos_cP_avg) que dificultem a drenagem do óleo; reservatórios onde grandes bolsões de hidrocarbonetos encontram-se isolados devido ao espaçamento de poços existentes, formações heterogêneas em que a eficiência de varrido é bastante limitada durante a injeção de água; formações com falhas ou altamente compartimentadas em que a área de drenagem do reservatório pelo poço é dificultada por limites físicos. O espaçamento entre poços no desenvolvimento de um campo é reduzido para fornecer o acesso às partes ainda não varridas ou contatadas de um reservatório. Modificações nos padrões de disposição e alocação de poços e o aumento da densidade de poços podem mudar os padrões de varredura e aumentar a eficiência da varredura, particularmente em reservatórios heterogêneos. Tal adensamento da malha de poços pode melhorar a eficiência de recuperação, mas também pode ser mais cara do que um processo de deslocamento pela injeção de fluidos. *Infill drilling* geralmente acelerará a produção de petróleo de um reservatório devido à diminuição do espaçamento entre injetor e produtor. Por a maioria dos reservatórios serem

heterogêneos ou seja, nem todas as partes do reservatório estão conectadas umas às outras, procedimentos de *infill drilling* podem permitir a produção de petróleo a partir de partes do reservatório que tenderiam a ser ignoradas em injeções de água com maiores padrões de espaçamento de poços, possibilitando assim aumentar significativamente a quantidade de reservas de óleo passíveis de serem recuperadas. Eficiências volumétricas mais elevadas da aplicação dos métodos de EOR tendem a ser alcançadas somente quando uma porcentagem muito elevada das "ilhas" de rochas porosas e permeáveis que constituem a formação produtora está ligada a pelo menos um par de poços de produção e injeção. Isso traz à tona a influência da heterogeneidade da formação no fator de recuperação de petróleo. É óbvio que, para um determinado ambiente deposicional, quanto menor o espaçamento do poço, maior é o número de corpos porosos e permeáveis conectados um par de poços de produção + injeção, e, portanto, o maior é a eficiência dos processos de injeção de fluidos e a recuperação do petróleo. Restrições econômicas óbvias limitam o número de poços que podem ser perfurados em um campo de petróleo contendo uma determinada quantidade de petróleo no lugar. Como consequência, é obrigatório que os locais de poços de *infill drilling* (seja para poços produtores ou injetores de fluidos) sejam cuidadosamente selecionados para otimizar o desempenho do reservatório usando o número mínimo de poços.

Assim, e com base nos mapas, observa-se que a injeção de vapor tende a requerer maiores porosidades e saturações de óleo. Dessa maneira, o calor tende a ser absorvido pelo óleo que se deseja produzir, e não por outros fluidos presentes no meio. Dessa maneira o calor também não se dissipa pela formação rochosa, o que poderia tornar o processo antieconômico. Constata-se ainda que a injeção de vapor tende a ser mais utilizada em formações areníticas (Lit_Sand). Além disso, verifica-se que tal método possui projetos relativamente já antigos (menores valores de Start_date). Tais projetos já possuem um maior grau de maturidade tecnológica. Assim, as injeções de vapor tendem a ser aplicáveis e economicamente viáveis em casos onde, geralmente, outros métodos não teriam êxito (Profit_Yes, Proj_successfull), a exemplo dos óleos de altíssimas viscosidades (Viscos_avg_cP). Além disso, há inovações como por exemplo a iniciativa de se associar células solares como fonte de energia para aquecimento do vapor, o que pode vir expandir sua aplicação (O'DONNELL, 2015; SANDLER, 2014) em novos cenários.


4.1.2.2 Combustão *in-situ*

A combustão *in situ* é comumente utilizada após a aplicação de outros métodos de recuperação. Isso acontece para não se consumir frações de hidrocarbonetos mais leves, que poderiam apresentar valor econômico significativo. Estes óleos mais leves apresentam maior valor comercial e são mais fáceis de produzir. Conforme a [Figura 29](#), tende a ser aplicada em saturações iniciais mais baixas e permeabilidades maiores que 100 mD para se facilitar o fluxo.

Conforme observa-se nos mapas, os altos valores referentes às aplicações do método de combustão *in-situ* (EOR_Comb) não costumam coincidir com reservatórios com óleos de °API abaixo de 20 ou acima de 40. Os mapas também evidenciam que o método também não coincide com óleos extremamente viscosos (Visc_avg_cP), caso em que se resultaria em combustível em excesso prejudicando o sucesso comercial, além de tornar o movimento da frente de combustão mais lento. Óleos pesados depositam muito combustível e dificultam o escoamento; óleos leves volatilizam, não fornecendo coque e, conseqüentemente, não auto alimenta a combustão.

Também nota-se o método de combustão é utilizado em profundidades médias (Depth_avg_ft), já que rasos limitam as pressões de injeção. O uso em menores profundidades reduz os custos excessivos de compressão, além de evitar fraturamento da sapata ou até mesmo da formação rochosa devido à injeção de comburente a alta pressão que seria necessário em profundidades maiores. Além disso, nota-se que é comum utilizar combustão *in situ* com injeção de água, o que pode ser explicado porque com a combustão *in loco* ela se transforma em vapor, atravessando a frente de combustão e aquecendo o reservatório a frente dela, processo esse também chamado de combustão direta com injeção de água.

Figura 24. Mapas das variáveis utilizadas para análise do método de combustão *in situ*.



(Autoria Própria)

4.1.3 Injeção de gases

4.1.3.1 Injeção de hidrocarbonetos

O método de injeção de hidrocarbonetos e metano/etano (GasInj_type_Hidroc e GasInj_type_Meth_et), mostrado nos mapas da [Figura 30](#), apresenta relação tanto com campos *onshore* como *offshore*. A injeção de gás miscível, MGI, é o processo EOR mais amplamente aplicado para reservatórios de óleos leves (API_avg) e com baixas permeabilidades (Permeab_avg_mD), como por exemplos em campos do Mar do Norte (observado nas componentes Ct_Gbr, Ct_Nor, Ct_Scot – que se referem, respectivamente, aos países Reino Unido, Noruega e Escócia).

Nota-se, também a partir dos mapas, que a injeção de hidrocarboneto (GasInj_type_Hidroc, GasInj_type_Meth_et) tende a ser utilizada em óleos de maior °API (API_avg), com maiores porcentagens de componentes C2-C6 e maiores profundidades (Depth_ft_avg). O gás injetado torna-se miscível com óleo quando, através de múltiplos contatos com o óleo do reservatório, hidrocarbonetos leves suficientes se concentram no gás para que o gás e o líquido se tornem mutuamente solúveis. Perto da miscibilidade, são desenvolvidas baixas tensões interfaciais entre o óleo e o gás, reduzindo a final de óleo, conforme pode-se observar nos mapas e aumentando a recuperação. As relações de fase entre o gás injetado e o óleo do reservatório determinarão a pressão necessária para o deslocamento miscível e a formação de indergitações viscosas (ou *fingers*), cuja ocorrência leva a uma produção antecipada de gás em detrimento do óleo. Uma alta concentração de C2-C5 no óleo do reservatório o torna favorável para esse processo de recuperação. O gás lean/seco e o N₂ (GasInj_type_Nitrog) exigem que uma pressão mais alta seja miscível com óleo que o CO₂ ou o gás enriquecido, podendo-se observar que a maioria desses projetos se encontram em regiões dos mapas que agrupam reservatórios em que foram aplicados processos imiscíveis. Dessa forma, enriquecer o gás com frações mais pesadas de gás na primeira porção de gás injetado, ou injetar em alta pressão ajuda a desenvolver a miscibilidade.

Como exemplo disso, há campos do Pré-Sal em que o gás é injetado a alta pressão e que, devido às altas profundidades, garante-se a não ocorrência da fratura da formação. Assim torna-se possível promover mais facilmente a miscibilidade do óleo com componentes que normalmente não seriam miscíveis a pressões razoáveis,


sem ocasionar fraturamento da formação. Contudo, há a necessidade de fonte próxima de fornecimento, que apesar de no Pré-Sal poços próximos produzirem grande quantidade de gás e assim haver atualmente constância no suprimento, há incertezas geológicas sobre o nível ideal de reinjeção de gás natural e também a tendência de se buscar monetizar o gás produzido pela bacia (ALMEIDA, E. et al.). No pré-sal, a comercialização do gás produzido pode se tornar realidade com construção da rota 4, escoando assim gás para o continente, e levando a opção por injeção de outros componentes, a exemplo do CO₂. Assim, a decisão sobre quanto gás injetar leva em conta não apenas parâmetros técnicos, mas também as vantagens econômicas da reinjeção quando comparada com a opção do aproveitamento comercial do gás, que atualmente também é visto como uma das opções de transição energética para uma economia de baixo carbono. Conforme gráfico da figura, tal tendência pode ser observada em escala mundial, em que é possível notar a queda ao longo das últimas décadas da participação da injeção de gás hidrocarboneto em novos projetos de EOR, perdendo espaço para alternativas como injeção de nitrogênio e dióxido de carbono, esse cuja injeção também é motivada por aspectos ambientais relativos ao armazenamento e estocagem de carbono.

Exemplo ainda da importância do critério relativo à relação entre as pressões de injeção e a profundidade (Depth_ft_avg) é o caso ocorrido em 2011, no Campo de Frade, Brasil, operado então pela Chevron. Na ocasião, alterou-se o ponto de injeção de fluido previsto em projeto, com o intuito de modo a otimizar a recuperação, para uma profundidade próxima ao topo do reservatório. Com isso, e conforme descreve Relatório de Investigação de Incidente da ANP (2016), ultrapassou-se o gradiente de fratura da rocha selante. Isso ocasionou em inevitável rompimento, seguido pela e propagação de fraturas no sentido de menor resistência da rocha selante, promovendo abertura anômala vertical até a superfície e liberação de óleo para o mar. Dessa forma, as profundidades do reservatório configuram como um critério relevante para a aplicação de tais métodos.

Dada a grande mobilidade do gás, a injeção de água conjunta promove uma melhor razão de mobilidades e da eficiência de varrido. Além disso, é possível observar que os altos valores de injeção de hidrocarbonetos tendem a coincidir com baixas saturações finais (Satur_end) de óleo e com uma boa eficiência de

deslocamento (Displacement_efficiency), o que leva à retirada de significativa parte do óleo residual.

Figura 25. Components plots que foram analisadas em conjuntos o método de injeção de hidrocarbonetos.



(Autoria Própria)

A injeção de hidrocarbonetos, segundo a leitura dos mapas, está ainda associada a baixos preços do barril de petróleo (Real_Oil_Price_USD). Tal interrelação pode ser associada ao fato de baixos preços do barril no mercado implicarem também, em geral, em menores preços de venda dos diferentes componentes de gás derivados de petróleo, o que resulta em um desestímulo ao processamento e venda a um baixo preço no mercado consumidor, levando a muitas operados a optarem por reinjetar o gás em tais cenários de baixos preços do barril de petróleo. Contudo, tal método de injeção pode apresentar limitação relacionada à disponibilidade de gás para injeção, especialmente em cenários com preços do barril

de petróleo mais altos (Real_Oil_Price_USD), não havendo preços compatíveis para aplicação no reservatório, ou quando não há campos vizinhos produzindo gás com pureza que possa ser injetado, ou ainda em casos onde não é viável o escoamento por fornecedores para o campo de produção. Vale ressaltar ainda a necessidade de instalações adicionais para condicionamento e pressurização do fluido a ser injetado.

A injeção de gás hidrocarboneto possui ainda limitações ligadas à baixa viscosidade e densidade do gás, com risco de formação de fingers e de segregação gravitacional. Com o intuito de reduzir tais efeitos, processos de injeção de água alternada com gás (WAG – component plots: GasInj_WAG, GasInj_SWAG e TWAG) vem sendo aplicados em reservatórios mais suscetíveis a esses fenômenos. Conforme pode-se observar nos mapas da figura, em campos que cujos graus de heterogeneidade (Dykstra_Parsons) são significantes e que tiveram aplicação de WAG, nota-se que foi possível obter alta eficiência de deslocamento (Displacement_efficiency) além de ampliar os tipos de reservatórios em que é viável sua aplicação. Além disso, utilizando-se juntamente ainda de processos miscíveis (GasMisc_Miscible), verifica-se maiores valores de eficiência de deslocamento (Displacement_efficiency) e menores de saturação final (Satur_end). Tal fato pode ser associado com o de que um dos efeitos da presença significativa de heterogeneidades (que pode ser em parte representada pelo coeficiente de Dykstra_Parsons) no reservatório é reduzir a transferência de massa entre as fases de petróleo e gás, resultando em uma maior zona de transição sem equilíbrio, menor região de miscibilidade e, portanto, uma injeção menos eficiente.


4.1.3.2 Injeção de dióxido de carbono

A injeção de CO₂ (GasInj_type_CO2), é mostrada nos mapas da [Figura 31](#) como associada a uma ampla variedade de óleos quanto ao seu °API (API_avg). Isso acontece por conta do CO₂ possuir maior miscibilidade, tanto com hidrocarbonetos leves, quanto pesados. Ou seja, é comum utilizá-lo em reservatórios em que já foram, inclusive, aplicados anteriormente outros métodos de recuperação, e que apresentam menores saturações de óleo (Prev_prod_WF e Satur_start). Dos campos que tiveram previamente injeção de água, verifica-se que grande parte dos reservatórios têm boa resposta à injeção de água. Tal fato, por um lado, em alguns casos pode levar a não

justificar investimentos para um incremento pequeno de produção advindo de EOR. Nestas circunstâncias muitos poços desses reservatórios produzem, atualmente, com alto corte de água, atrasando o retorno de ganho adicional de óleo advindo de métodos de EOR. Por outro lado, em determinados casos, verifica-se uma promissora associação da injeção de anterior de água com a injeção de CO₂, levando a saturações finais baixas e bons índices de sucesso.

Relacionado a isso, também se observa que o método GasInj_type_CO2 é aplicado a uma gama variada de profundidades (Depth_ft_avg), uma vez que a pressão necessária para se obter miscibilidade é relativamente menor do que a exigida para a injeção do gás pobre, por exemplo. Por meio dos mapas também nota-se a coincidência da injeção de CO₂ com reservatórios de baixas permeabilidades e óleos de baixa viscosidade. Isto se deve ao fato de, respectivamente, se evitar a segregação gravitacional e obter razão de mobilidades mais favorável.

Figura 26. Components plots das variáveis com interrelações analisadas junto ao método de injeção de dióxido de carbono.



(Autoria Própria)

Por meio de inspeção a tais campos na base de dados, percebe-se ainda que o método é amplamente utilizado em locais que possuem infraestrutura para fornecimento de CO₂. Em alguns casos isto pode ocorrer no próprio campo produtor, como por exemplo no Pré-Sal em que há reservatórios que apresentam alta produção de CO₂. Em outros casos, observa-se uma rede de dutos transportadores de dióxido de carbono das indústrias para as operadoras dos campos de produção que aplicam a injeção de CO₂, conforme detalhado na tabela 3.

Nota-se, ainda segundo os mapas, que a injeção de CO₂ tem sido empregada cada vez mais recentemente (altos valores de GasInj_type_CO₂). O método possui, portanto, amplo potencial para expansão, dada a sua aplicabilidade a uma gama variada de tipos de reservatórios, além vir avançando em termos de grau de maturidade, fator esse também impulsionado por tecnologias como *Carbon Capture & Storage* (CCS) e pela transição para um consumo energético baseado em baixo carbono.

Tabela 3. Principais dutos onshore de CO₂ no mundo, cujo transporte é direcionado principalmente campos de petróleo para aplicação de EOR.

Duto	País	Empresa operadora	Capacidade de transporte de CO ₂ (Mt/ano)	Extensão (km)	Ano em que foi finalizado	Fonte de captura do CO ₂
Cortez	USA	Kinder Morgan	19.3	808	1984	McElmo Dome
Sheep Mountain	USA	BP Amoco	9.5	660	–	Sheep Mountain
Bravo	USA	BP Amoco	7.3	350	1984	Bravo Dome
Canyon Reef	USA	Kinder Morgan	5.2	225	1972	Gasification plants
Carriers						
Val Verde	USA	Petrosource	2.5	130	1998	Val Verde Gas Plants
Bati Raman	Turkey	Turkish Petroleum	1.1	90	1983	Dodan Field
Weyburn	USA & Canada	North Dakota Gasification Co.	5	328	2000	Gasification Plant
Total			49.9	2582		

Adaptado de GALE, (2014)

4.1.4 Injeção de produtos químicos

4.1.4.1 Injeção de polímero

Em relação ao método de injeção de polímero (ChemInj_Polim), com base nos mapas da [figura 32](#), destaca-se grande aplicação em reservatórios com em geral médias viscosidades (Viscos_avg_cP) e permeabilidades (Permeab_media_mD). Nestas situações o polímero atua promovendo uma razão de mobilidades mais favorável e, conseqüentemente, uma frente de deslocamento mais uniforme. Se a permeabilidade for mais baixa, uma vazão econômica pode não ser atingida.

Nota-se também, ainda por meio dos mapas, que reservatórios que possuem água de formação com elevada concentração de cátions divalentes, como dolomita e calcário, tendem a não coincidirem com a aplicação da injeção de polímeros. Isso ocorre porque a água de elevada dureza pode levar à degradação da viscosidade da solução, com redução acentuada do controle de mobilidade desejado, predominando o seu emprego em formações areníticas. Em sua maioria, polímeros podem sofrer degradação de suas propriedades reológicas quando utilizados em reservatórios com temperaturas (Temper_F_avg) e profundidades altas (Depth_ft_avg).


Além disso, tal injeção tende a ser associada a saturações finais de óleo (Satur_end) relativamente mais altas, uma vez que não consegue retirar todo o óleo residual. Contudo, a injeção de polímeros é capaz de promover a antecipação da produção do óleo e de receitas e a um conseqüente Valor Presente Líquido (VPL) mais alto, levando a projetos que podem possuir bons índices de sucesso, mesmo em projetos pilotos (Proj_scope_Pilot).

Observa-se também grande utilização da injeção de polímero na China (Ct_Chi), em que um exemplo é o caso do campo de petróleo de Daqing (WANG, 2003). Em tal campo, o custo das injeções de polímeros foi de cerca de US \$ 9 por barril de petróleo, quase o mesmo custo da injeção de água. As principais razões verificadas para a lucratividade (Proj_eval_Succ) da injeção de polímeros foram: (i) alta recuperação incremental (cerca de 12% óleo original no reservatório), (ii) alta taxa de produção (cerca de 4 vezes a da injeção de água) e conseqüente antecipação de receitas pela melhor eficiência de varrido (iii) baixa relação água-óleo (diminuição de cerca de 5 vezes). Além disso, soma-se o baixo custo dos produtos da indústria química chinesa, que pode ser associado à aplicação menos rigorosa de legislações,

ciclos de aprovação mais rápidos e acesso privilegiado à terra, água, tratamento de resíduos, energia e matérias-primas, além de incentivos por parte dos formuladores de políticas governamentais (MCKINSEY, 2018; ATKEARNEY, 2016).

A deposição sedimentar que ocorre ao longo de milhões de anos é fortemente influenciada pelas diferentes condições prevalecentes. As propriedades do reservatório são raramente uniformes verticalmente ou horizontalmente. Consequentemente, para o caso da entrada de água e/ou fluidos na formação através de um injetor não costuma ser uniforme sobre toda a seção transversal vertical da formação. Isso leva a má eficiência de varredura e menor recuperação de óleo. Nesse sentido, busca-se fechar ou minimizar os pontos de entrada excessivos de água e “thief zones”, aplicando uma variedade de tecnologias e ferramentas disponíveis, como por exemplo o uso de produtos químicos para bloqueio de água ou projetos especiais de completação. Da mesma forma, zonas problemáticas responsáveis pela alta razão água/óleo ou gás/óleo tendem a ser isoladas buscando maximizar os retornos financeiros dos projetos.

Figura 27. Component plots das variáveis cujas interrelações com os métodos de injeção de polímeros e surfactantes foram analisadas.



(Autoria Própria)

4.1.4.2 Injeção de surfactante

Para a recuperação avançada via injeção de solução de surfactante, percebe-se pela análise dos mapas da [Figura 32](#), que tal método tende a ser utilizado em reservatórios onde já foi realizada injeção de água e, principalmente, em formações areníticas. Pode-se observar que a aplicabilidade em carbonatos (Lit_Dolo(s)) ou reservatórios com água de elevada salinidade é limitada (Formation_water_ppm), devido à elevada adsorção de surfactante em tais casos. Surfactantes catiônicos que não sofrem tal adsorção vêm sendo utilizados em alguns projetos pilotos, porém verifica-se que sua aplicabilidade é restrita em escala comercial devido ao elevado custo associada a produtos de química fina em muitos países. Todavia, há avanços recentes com o uso junto a polímeros que agem como agentes de sacrifício em tal processo.

Com base nos mapas observa-se ainda que está associada a formações com valores de porosidade em geral menores de 20%. Tal fato pode ser explicado por em espaços confinados serem onde há maior potencial de redução das forças interfaciais e dos bolsões de óleo causados pelo efeito Jamin do aprisionamento por forças capilares. Os mapas também demonstram que os surfactantes são mais utilizados em reservatórios com óleos de °API acima de 28. Isso acontece porque para óleos mais pesados tal método tende a se tornar antieconômico, uma vez que requer a injeção de maiores volumes de surfactante e de polímero associado para promover controle da viscosidade e mobilidade.

Além disso, os mapas demonstram poucas aplicações deste método em campos *offshore*. Isso decorre de fatores como o grande espaçamento entre poços em tal cenário, o que gera grandes tempos de retorno (*payback*) da injeção de produtos químicos. Além disso, há necessidade de volumes maiores para se obter real atuação na área injetada, o que tende a prejudicar a viabilidade econômica de métodos químicos.


Contudo, observa-se que há grande aplicação da injeção de surfactantes e polímeros (seja surfactante e polímero ou ainda juntamente com porção alcalina e formação do tensoativo *in-situ*) em campos *onshore* de produção, sobretudo na China (Ct_Chi). Verifica-se investimentos massivos das estatais CNOOC e SINOPEC, além de uma indústria química pujante e que tem produzido tais insumos químicos a um baixo custo, quando comparada a países desenvolvidos. Além disso, nota-se que tendem a ser projetos relativamente mais novos (Start_date), com significativo potencial de desenvolvimento e de aplicação.

4.2 *Screening de métodos de EOR*

Como resultados da predição realizada pelos SOMs, foram geradas as tabelas [4](#) e [5](#), cujos resultados são comparados com os dos artigos de referência. Na tabela 4 há os dados dos campos utilizados pelos respectivos artigos, enquanto na tabela 5 são comparados os métodos de EOR sugeridos pela predição via SOM com os dos artigos. Além disso, são gerados os gráficos das figuras [34](#), [35](#), [36](#) e [37](#) que representam campos similares aos que os artigos realizaram *screening*, utilizando como medida comparativa a dissimilaridade do seno.

Como exemplo didático, a [Figura 33](#) traz a aplicação da similaridade do cosseno para identificação de campos análogos aos do caso 2.3, e os respectivos métodos de EOR que foram aplicados, identificados pela cor da legenda. Cada coluna do gráfico representa um reservatório (ou instância) na base de dados de treinamento, sendo que quanto mais similar for em relação ao caso base, maior a tendência de os vetores referentes ao par de reservatórios estarem na mesma direção, e maior será o valor do cosseno do ângulo formado entre o respectivo par de reservatórios, indicando maior similaridade entre os mesmos. Em particular para tal caso, nota-se grande similaridade do reservatório em questão com outros reservatórios em que tiveram a aplicação de métodos térmicos. Além disso, observa-se que tal tendência não é, contudo, exclusiva, havendo a aplicação de outros métodos de EOR em campos relativamente também similares, o que pode sugerir que outros fatores, além de propriedades petrofísicas e técnicas, podem também influenciar na tomada de decisão acerca de qual método de EOR fora o escolhido para cada campo.

Figura 28. Exemplo da utilização da similaridade do cosseno para identificação de campos similares e respectivos métodos de EOR aplicados. Cada coluna representa um reservatório na base de dados, sendo que quanto mais similar ao caso base, maior o valor do cosseno do ângulo formado entre o respectivo par de reservatórios, indicando maior similaridade entre os mesmos.



(Autoria Própria)


4.2.1 Caso 1.1

ZHANG 2019 realizou o *screening* para o campo de Midway-Sunset, localizado no condado de Kern County, San Joaquin Valley, California nos EUA (caso 1.1 da [Tabela 4](#)). Como tal campo está presente na base de dados consolidada, e como não fora mencionado pelo artigo demais detalhes do projeto (empresa operadora, bloco do campo, etc), e com o intuito de buscar reduzir vieses do sistema de *screening*, tal campo fora excluído do conjunto de dados utilizado para o treinamento da rede.

Em consonância com os resultados do artigo, a imputação SOM também apontou injeção de vapor como sendo principal candidato. Contudo, a comparação dos métodos subsequentes na ordem de preferência dada por ZHANG (2019) com a obtida pelo SOM revela diferenças significativas. Segundo o artigo, os próximos candidatos na lista de preferência de métodos de EOR, após injeção de vapor e combustão *in-situ*, seriam métodos relacionados à injeção miscível e/ou imiscível de CO₂ e N₂, seguida por último pela injeção de polímero. Já de acordo com os resultados obtidos via SOM, após a injeção de vapor, destaca-se a injeção de polímero e demais métodos térmicos de EOR, como SAGD, aquecimento eletromagnético e vapor cíclico.

Dentre os fatores que podem ser associados à maior pontuação recebida pela injeção de polímero, pode ser associada ao fato de predição via SOM considerar a variável referente à litologia (arenito). O trabalho de ZHANG (2019) não leva em conta no sistema de decisão de *screening* tal parâmetro. Além disso, na base de dados constituída para a predição via SOM há campos com características semelhantes na China em que houveram projetos de injeção de vapor, bem como de polímero e/ou surfactante (LI, 2006; XIONG, 2009; SONG, 2002), conforme pode ser observado na [Figura 34](#). A predição de injeção de polímero como potencial método de EOR para o campo de Midway-Sunset também pode ser relacionado a fatos estritamente técnicos. Em um primeiro *screening* via SOM não foram incluídas coordenadas espaciais como variáveis. Isso não propiciou a consideração de fatores como disponibilidade e viabilidade econômica para aquisição insumos. O trabalho de ZHANG (2019) também não levou em conta tais variáveis.

Figura 29. Dissimilaridade do seno em relação ao campo do caso 1.1. Observa-se grande semelhança com projetos em que ocorreram injeção de polímero, vapor e CO2, cuja diversidade, apesar da significativa semelhança, mostra-se motivada por fatores regionais aos campos e não exclusivamente dependentes das propriedades dos reservatórios. Como caso especial, destacam-se campos de Bohai Bay, bacia sedimentar na Cina, que caracteriza-se por ser um dos poucos casos de aplicação offshore de injeção de vapor.



(Autoria Própria)

Contudo, procurando investigar mais a fundo tal resultado, e realizando novo *screening* considerando como parte do conjunto de variáveis para treinamento as informações de longitude e latitude do campo de Midway-Sunset (35.203169,-119.565699), métodos relacionados a injeção de vapor passaram a ser os mais indicados em detrimento da injeção de polímero. Tal fato pode ser associado, dentre outros fatores, a: menores custos da indústria química chinesa (POLTRONIERI & ARMELIN, 2014), tornando o uso de métodos químicos mais atrativo em tais casos, bem como ao relativo alto custo de produtos de química fina nos EUA; à já existência na Califórnia de fornecedores e prestadores de serviços especializados na injeção de vapor; existência de dutos que realizam a captura e armazenamento de CO2 próximos a campos como Cymric, bem como a particularidades relativas a salinidade e dureza

da água da formação. Como caso especial, destacam-se campos de Bohai Bay, bacia sedimentar na China, que caracteriza-se por ser um dos poucos casos de aplicação de injeção de vapor. O campo é operado pela *China National Offshore Oil Corporation* (CNOOC), e as reservas são estimadas em 2,3 bilhões de toneladas (Yu, 2001). Em tal bacia, o petróleo pesado offshore é dividido em duas classes: tipo I, cuja viscosidade do óleo está entre 350mPa.s-10000mPa.s e Tipo II, a viscosidade do óleo desses está acima de 10000mPa.s. A produção de tal campo de maneira viável por meio de injeção de vapor se tornou possível graças a diversas inovações realizadas em termos de completação junto ao uso de géis para injeção.

Já a diferença em relação à sugestão de aplicação de métodos térmicos de EOR, ZHANG 2019 aponta apenas injeção de vapor e combustão in-situ como métodos de EOR de aplicação preferencial, enquanto o *screening* via SOM aquecimento eletromagnético, SAGD e vapor cíclico também mostram-se como possíveis alternativas. Tais sugestões apontadas pelo SOM podem ser corroboradas ao se pesquisar informações mais detalhadas acerca da aplicação de EOR no campo de Midway-Sunset (MCKAY, 2003; LOLLEY, 1999; CHONA, 1996; SAINI, 2016) e em campos com propriedades de reservatório semelhantes como os de Cymric (FONG, 2001; KUMAR, 1995) e Gudao (SUN et al. 2011; LIU et al. 2014; FENG et al. 2014).

Tabela 4. Propriedades de reservatório utilizadas como input pelos artigos e pela imputação SOM.

ID	Referência	EOR aplicado no campo	Campo	Caso	Area (acres)	Litologia	Porosidade (%)	Permeabilidade (mD)	Profundidade (ft)	°API	Viscosidade (cP)	Temperatura (°F)	Saturação de óleo (%)	Espessura da formação (ft)
2001	ZHANG et al. (2019)	Steam	Midway Sunset	1.1		Sand*	24	1500	1000	11.3	24000	220	40	205
2011		Polymer	Não mencionado pelo artigo	2.1	40	Lime	10	16	7900	30	3	150	75	
2012	KHAZALI et al. (2019)	Nitrogen Immiscible	Não mencionado pelo artigo	2.2	14300	Dolo	17	175	1400	30	6	82	52	
2013		Steam	Não mencionado pelo artigo	2.3	18	Sand	38	2800	1000	13	35	220	60	

(Autoria Própria)

Tabela 5. Ordens de classificações e respectivas pontuações atribuídas a cada método de EOR para cada caso de campo. (Autoria Própria)


Referência	Caso	Categoria	1° EOR	2° EOR	3° EOR	4° EOR	5° EOR	6° EOR	7° EOR	8° EOR	9° EOR	10° EOR
ZHANG, Na et al. Development of a hybrid scoring system for EOR screening by combining conventional screening guidelines and random forest algorithm. Fuel, v. 256, p. 115915, 2019.	1.1	Artigos	Steam (100.0000)	Comb (96.0000)	Nitrog Immisc (93.3000)	Hot water (86.0000)	Co2 Misc (73.5000)	Co2 Immisc (72.5000)	Poly (68.8000)	Microb (53.0000)	Hydroc Misc (50.9000)	Surf (8.0000)
		Imputação SOM	Poly (0.2149)	SAGD (0.1990)	Electromag heat (0.1465)	Steam Solv (0.1243)	Hot water (0.1043)	Steam (0.0878)	Cycl steam (0.0822)	Comb (0.0409)	Surf Poly (0.0000)	Chem (0.0000)
KHAZALI, Nastaran; SHARIFI, Mohammad; AHMADI, Mohammad Ali. Application of fuzzy decision tree in EOR screening assessment. Journal of Petroleum Science and Engineering, v. 177, p. 167-180, 2019.	2.1	Artigos	Poly (52.0000)	Co2 Immisc (35.0000)	Co2 Misc (13.0000)	Comb (11.0000)	Steam (0.0000)	Nitrog Immisc (0.0000)	Microb (0.0000)	Hydroc Misc (0.0000)	Hydroc Immisc (0.0000)	Acid Gas Misc (nan)
		Imputação SOM	Surf Poly (0.3673)	Poly (0.2176)	Co2 Cont2WAG (0.145)	Co2 TWAG (0.1124)	Co2 Cont (0.0901)	Chem Poly Surf (0.0257)	Co2 Misc WAG CCS (0.0178)	Chem (0.0078)	Alkal (0.0039)	WAG (0.0039)
	2.2	Artigos	Nitrog Immisc (84.0000)	Poly (15.0000)	Co2 Misc (3.0000)	Co2 Immisc (1.0000)	Steam (0.0000)	Microb (0.0000)	Hydroc Misc (0.0000)	Hydroc Immisc (0.0000)	Comb (0.0000)	Acid Gas Misc (nan)
		Imputação SOM	Co2 Cont or WAG (0.3080)	Surf Poly (0.2806)	CO2 WAG CCS (0.2002)	Co2 Immisc (0.0617)	Comb (0.0735)	Nitrog Immisc (0.0703)	Nitrog Misc (0.0000)	Cycl steam (0.0000)	Co2 WAG CCS (0.0000)	Co2 WAG (0.0000)
	2.3	Artigos	Steam (63.0000)	Poly (37.0000)	Nitrog Immisc (0.0000)	Microb (0.0000)	Hydroc Misc (0.0000)	Hydroc Immisc (0.0000)	Comb (0.0000)	Co2 Misc (0.0000)	Co2 Immisc (0.0000)	Acid Gas Misc (nan)
		Imputação SOM	Poly (0.4069)	SAGD (0.1790)	Electromag heat (0.1265)	Steam Solv (0.0843)	Hot water (0.0843)	Steam (0.0678)	Cycl steam (0.0422)	Comb (0.0009)	Surf Poly (0.0000)	Chem (0.0000)

4.2.2 Caso 2.1

KHAZALI 2019 realizou o *screening* para três campos localizados nos EUA cujos nomes não foram mencionados no artigo. Contudo, como é necessário verificar se tal amostra faz parte da base de dados, e caso faça parte que seja excluído do treinamento, buscou-se então por meio da dissimilaridade do seno campo a campo verificar se há algum campo com tais características.

Para o primeiro caso do artigo (caso 2.1 da tabela 4) foi possível identificar que se trata provavelmente do campo Cottonwood Creek, em Wyoming, informação cujas propriedades de reservatório podem ser confirmadas na página 294 do livro "*Enhanced Oil Recovery Field Case Studies*" e também por XIE (2005) e ELSAYED (1993). A partir dos dados propostos para o caso 1 do artigo de KHAZALI (2019), tanto a metodologia do artigo como a imputação via SOM apontaram como métodos indicados o uso de polímero, seguido por injeção miscível/imiscível de CO₂.

Figura 30. Dissimilaridade do seno em relação ao campo do caso 2.1. Observa-se grande semelhança com projetos em que ocorreram injeção de CO₂, seguida por injeção de hidrocarbonetos e por métodos químicos.



(Autoria Própria)

Considerando-se apenas as variáveis utilizadas por KHAZALI 2019, observa-se grande semelhança do campo do caso 1 com outros campos, porém em que ocorreram a injeção de CO₂, conforme pode-se observar na [Figura 35](#). Dentre eles, destacam-se Weyburn-Midale, em Saskatchewan, no Canadá - atualmente o maior projeto de armazenamento e captura de carbono do mundo, operado por companhias como Cenovus e Apache e cujas características também são similares a de Cottonwood Creek. O CO₂ é fornecido por meio de um gasoduto de 320 km de extensão (concluído em 1999) a partir da fábrica de síncios da Dakota Gasification Company, movida a lenhito, em Beulah, Dakota do Norte, caracterizando-se por ser primeira instância de transferência transfronteiriça de CO₂. Tal projeto destaca a capacidade de cooperação e incentivo internacional visando o desenvolvimento das tecnologias de mitigação de gases de efeito estufa e em campos mais ao sul dos EUA, evidenciando que soluções do gênero podem ser economicamente atrativas. Dessa forma, apesar de tais campos possuírem características muitas vezes semelhantes, a injeção de CO₂ aparece como a escolhida nesses casos possivelmente não apenas pelo apelo ambiental das tecnologias de CCS, como também pela disponibilidade de grande fonte de dióxido de carbono próxima.


4.2.3 Caso 2.2

Para o segundo caso abordado pelo artigo, o campo presente na base de dados construída que indicou maiores semelhanças com o utilizado por KHAZALI (2019) no *screening* foi de Yates, no Texas, conforme corroboram artigos citados abaixo. O campo de Yates é um reservatório dolomítico fraturado cujas reservas são estimadas em torno de 4,2 bilhões de barris na formação de San Andres (o principal reservatório). O campo produz desde 1927 e o fator de recuperação médio da formação de San Andres é apontado como apenas 35% OOIP após produção primária e uso de injeção de água e de gás DELAMAIDE, (2014). A formação de San Andres é uma formação de dolomita fraturada e molhável a óleo; contudo, não há um consenso claro na literatura encontrada acerca de suas características petrofísicas: a porosidade e permeabilidade da matriz média são relatadas desde como sendo da ordem de 17% e 35 mD,

respectivamente (CHENG & KWAN, 2012), 15% e 100 md (CHEN, LUCAS, NOGARET, YANG E KENYON, 2001), até permeabilidade de um Darcy, conforme estudo petrofísico detalhado (TINKER & MRUK, 1995). Todavia, assumiu-se relativa similaridade dos dados mencionados pelo autor com os do campos de Yates, baseado nos trabalhos supracitados e também em demais artigos (CRAIG, 1990; GILMAN, 1995; WINTERFELD, 1996).

De acordo com a ordem de métodos de EOR sugerida por KHAZALI (2019) para o caso 3, os principais métodos de EOR sugeridos foram injeção de nitrogênio imiscível e de polímero, enquanto a imputação SOM (excluindo do treinamento o dado referente ao campo de Yates) apontou injeção de CO₂ (contínuo ou alternado com água) como primeira opção e injeção de surfactante e polímero como segunda alternativa. Tanto a ordem de métodos de EOR dada pela árvore de decisão fuzzy do artigo como a sugerida pela imputação SOM mostram-se coerentes com critérios de *screening* tradicionais, como os exemplificados por MASHAYEKHIZADEH (2014). Por os processos de injeção imiscível de CO₂ e de N₂ atuarem principalmente como mecanismos de manutenção de pressão quando comparado a métodos miscíveis, os *ranges* de aplicabilidade tornam-se menos restritivos. Por não requererem que ocorra a miscibilidade com o óleo, podem ser aplicados a profundidades (da ordem de mil pés) e °APIs menores.

Figura 31. Dissimilaridade do seno em relação ao campo do caso 2.2. Observa-se grande semelhança com projetos em que ocorreram injeção de CO₂, seguida por injeção de produtos químicos.



. (Autoria Própria)

No campo de Yates, além da execução de projetos de injeção imiscível de CO₂ no campo de Yates, também houveram testes acerca da aplicação de injeção de surfactante/polímero (STANDNES, 2002; AYIRALA, 2002) e declarados como bem sucedidos, corroborando também os resultados de ambos *screenings*, embora não tenha sido encontrado informações acerca de projeto e/ou estudos acerca da injeção de nitrogênio em tal campo. Tal fato pode estar associado, por exemplo, a fatores como maior custo e energia envolvidos para se liquefazer e separar nitrogênio quando se comparado ao dióxido de carbono.

Tais observações podem ser reforçadas pelo gráfico da [Figura 36](#), em que se observa que dentre os campos que possuem menor grau de dissimilaridade do seno estão injeção de CO₂ e surfactante e polímero.

4.2.4 Caso 2.3

Em relação ao terceiro caso de campo abordado por KHAZALI (2019), encontrou-se grandes semelhanças com reservatórios da bacia de Tulare (BARWIS, 2012; DJABBARAH, 1990; CHIOU, 1995; AGARWAL, 2013). Cabe observação em relação à temperatura *in-situ* do reservatório dada pelo artigo, que está significativamente alta (220 °F) para uma seção geológica relativamente rasa e com baixo °API, o que pode indicar inconsistência nos dados fornecidos pelo artigo, mas que também pode ser em decorrência de alguma real anomalia geotectônica ou do gradiente térmico do campo utilizado como referência por KHAZALI (2019). Apesar de gerar dúvidas acerca da validade do valor do dado em relação à temperatura e de não ter sido encontrado na literatura campos semelhantes (rasos e com óleos pesados) com temperatura tão alta, e visando realizar análises suportadas por experiências reais, adotou-se então como sendo a formação de Tulare, possivelmente campos pertencentes a essa bacia, a exemplo de Cymric e South Belridge que possuem características muito próximas às relatadas no campo do caso 3 do artigo e em que realizou-se injeção de vapor.

A árvore de decisão fuzzy utilizada por KHAZALI (2019), aponta preferência pela injeção de vapor seguida pela de polímero, com pontuação zero para os outros dois métodos avaliados. Porém cabe ressalva em relação ao resultado de KHAZALI (2019) caso a temperatura do campo utilizada como referência tenha de fato sido 220°F, que na maioria das condições pode tornar inviável a injeção de polímero. A imputação SOM, por sua vez, ao realizar o *screening* sem a inclusão das coordenadas espaciais e tomando como referência a temperatura do campo de Tulare, indica a aplicação de polímero, seguida por SAGD, aquecimento eletromagnético e variações de métodos de injeção de vapor. Tal resultado é corroborado pelos valores de dissimilaridade do seno em relação ao campo de Tulare nos EUA, em que se observa maior similaridade com campos de injeção de polímero na China e El Tordillo, na Argentina, podendo ser confirmado por *screenings* tradicionais que abordam variáveis como °API, viscosidade permeabilidade, mas também demais condições específicas favoráveis à injeção de polímero, como baixo grau de dureza e alto grau de heterogeneidade - valores de Dykstra-Parsons maiores que 0.7. Além

Figura 32. Dissimilaridade do seno em relação ao campo do caso 2.3. Observa-se grande semelhança com projetos em que ocorreram injeção de polímero na China, seguida por injeção de vapor nos EUA.



(Autoria Própria)

Com em geral menor semelhança do ângulo entre os vetores dos campos em relação aos de Tulare, seguem projetos de injeção de vapor, especialmente nos EUA. Conforme é possível notar na [Figura 37](#), há uma pluralidade de projetos de aplicação de métodos térmicos nessas zonas produtoras, em que ainda que se consituam reservatórios com características parcialmente semelhantes, levam a uma pluralidade de empresas e presentes. Tal diversidade de players/atores nesses campos em parte se dá tanto por políticas de incentivos locais, como por disponibilidade próxima de fontes de água para injeção, como pelas características de tais reservatórios, com baixas profundidades levando a menores custos de perfuração e injeção de vapor. Corroborando tais observações, ao se considerar as variáveis referentes às informações espaciais do campo de Belridge (35.3949641, -119.7476299) no *screening*, o método de EOR sugerido via SOM passou a ser injeção de vapor, seguida pelos demais métodos térmicos em detrimento da injeção de produtos químicos, relevando a influência da presença de campos próximos e, indiretamente, consequente infraestrutura e rede de prestadores de serviços especializados em métodos térmicos e fornecedores de insumos locais.

Dessa forma, verifica-se que os resultados do *screening* que leva em conta as coordenadas dos campos faz sentido, pois diferentes países possuem indústrias com diferentes graus de desenvolvimentos e acesso a recursos, bem como questões ambientais e logísticas distintas que podem estar implícitas. Por exemplo, nos EUA enquanto o uso de surfactantes e polímeros para injeção pode ser inviável devido ao alto custo da indústria de química fina, campos localizados próximos aos dutos de dióxido de carbono nos EUA possuem grande possibilidade de utilização desse CO₂ para injeção nos reservatórios. Já na China, em decorrência do baixo custo da indústria química, a aplicação de produtos químicos torna-se economicamente mais atraente. Somado a isso, ferramentas complementares para um processo de gestão eficaz do gerenciamento de reservatórios pode incluir: estudos sísmicos 3-D ao longo do tempo para estabelecer melhor locação para novos poços injetores e produtores; maior eficiência de varredura permitido pelo aumento da densidade de poços (*infill drilling*) juntamente ao monitoramento rigoroso do avanço de fluidos

injetados em zonas de alta permeabilidade; busca pela melhoria nos perfis de produção e injeção; manutenção de pressão do reservatório; minimização das instalações de superfície; e o acesso a ferramentas que possibilitem predições e tomadas ágeis de decisão em tempo real. Para melhor eficiência no monitoramento em um projeto de gerenciamento de reservatórios podem ser utilizados traçadores químicos. Estes traçadores químicos consistem em elementos de polímero impregnados com produtos químicos únicos localizados em pontos estratégicos ao longo da completação do poço. Uma vez em contato com fluido alvo (óleo ou água), a matriz começa a liberar traçadores químicos únicos. Estes traçadores são monitorados através da amostragem periódica na cabeça de poço e posteriormente analisados para produzir perfis de concentração de produtos químicos únicos. Vários traçadores únicos permitem uma avaliação qualitativa da contribuição zonal, localizando avanços hídricos e dos perfis de óleo. Isso permite a identificação antecipada de produção excessiva de água, contribuição de cada zona para a produção e reduz a necessidade de operações intervenção direta.

4.2.1 Resultados adicionais: influência do preço do barril de petróleo

Em testes de casos isolados realizou-se *screening* para campos de interesse dos artigos considerando o preço do barril do petróleo real (valor ajustado pela inflação para se permitir comparações mais justas em diferentes intervalos de tempo) como uma das variáveis de treinamento, simulando-se assim diferentes cenários econômicos.

Como parte dos resultados parciais, em alguns testes em que num *screening* inicial não fora considerado o preço do barril e nos quais injeção de polímero, injeção de água e de vapor são os métodos indicados, não observou-se significativa variação do método de EOR indicado ao se realizar o *screening* para diferentes preços de óleo. Já em testes em que no *screening* inicial, sem considerar o preço do barril de petróleo, e nos quais foram apontados os métodos de injeção de gás e surfactante como métodos de EOR indicados, observou-se significativa variação do método de EOR indicado para os diferentes cenários econômicos.

Contudo, é necessário um maior número de testes e análises para se confirmar e investigar mais a fundo tais resultados, o que pode vir a ser escopo de futuros trabalhos.

5 CONCLUSÕES

Com base no estudo desenvolvido, verifica-se que os diversos métodos de recuperação, sejam eles avançados ou não, constituem-se em uma ferramenta estratégica e de grande importância para um pleno desenvolvimento da produção de reservatórios de petróleo. Os resultados além de confirmarem informações já respaldadas pela literatura no que concerne engenharia de reservatórios, também permitiram trazer *insights* acerca de demais aspectos, mostrando-se um campo oportuno a aplicação de técnicas de machine learning em tal problemática. As figuras [38](#) e [39](#) sintetizam as principais conclusões obtidas no desenvolvimento desse trabalho.

Como parte dos resultados, observou-se que comparando a análise estatística com os mapas foi obtida boa correlação com os modelos reais e teóricos relativos a EOR, além de se permitir inferir que a integração e tratamento das diferentes fontes de dados foi realizada de maneira bem sucedida, permitindo constituir um dataset amplo e coeso acerca dos métodos EOR utilizados em escala mundial. Além disso foi possível analisar a dinâmica dos métodos de EOR de maneira mais global e holística, analisando diversas variáveis de forma integrada, permitindo entender mais a fundo não apenas as aplicações, vantagens e limitações de cada método de EOR, como também os custos envolvidos e comparar uns com os outros. Limitações das visualizações do mapas foram identificadas ao suavizar valores extremos (não foi possível visualizar de maneira clara nos mapas, por exemplo, reservatórios com óleos de °API abaixo de 11 ou acima de 40 e permeabilidades abaixo de 5 mD ou acima de 2 mil mD). Contudo, tal suavização, apesar de influenciar negativamente na visualização de valores extremos das variáveis, foi um dos fatores que levou a um bom agrupamento e predição dos dados.

É também possível notar que a viabilidade dos projetos de EOR tende a se tornar um desafio em formações de baixas permeabilidades e espessuras da zona produtora (*net pay*) associadas a óleos extremamente viscosos, com altas temperaturas e salinidades,

Também verifica-se que é desafiadora a aplicação de EOR em ambientes offshore, em que a viabilidade técnica/econômica podem ser prejudicadas devido a fatores como grandes profundidades, implicando seja em perdas de

calor ou energia na injeção de fluidos no reservatório, seja em maiores distâncias entre os poços, exigindo maior volume de produtos injetados e dificuldades. Dificuldades da aplicação offshore de EOR se mostram fortemente influenciadas ainda também pelos sistemas de produção offshore costumam a apresentar peculiaridades como: limitação de espaço e de capacidade de processamento de fluidos e de carga para instalação de equipamentos adicionais necessários para EOR; necessidade de obras e adaptações ou para instalação de novos sistemas, além de questões não solucionadas em relação à incompatibilidade entre, por exemplo, produtos químicos de EOR produzidos, como surfactante, e os utilizados na planta separação, como quebradores de emulsões, sequestrantes, dentre outros. Nesse sentido, verifica-se falta de experiência da indústria do petróleo na aplicação de métodos de EOR em ambiente offshore, sobretudo em lâmina d'água profunda, indicando sua implantação ainda ser incipiente e um desafio com grande potencial de ser superado.

Figura 33. Principais conclusões gerais e inovações observadas com o desenvolvimento do trabalho.



(Autoria Própria)

Nos casos onde se mostra viabilidade técnica para implementação de métodos de EOR, as principais barreiras para aplicação de EOR passam a ser fatores como: falta de atratividade econômica devido aos altos custos envolvidos,

tempo de retorno do investimento em campos marginais relativamente longo se comparado a outros projetos; vencimento da garantia de propriedade sobre os recursos petrolíferos, como ocorre nos regimes de concessão com prazo de 27 anos presentes na Bacia de Campos; a falta de corpos técnicos nas empresas e experiência na seleção, implementação e condução de projetos de EOR; a preferência por projetos com retornos com menores *paybacks*; e o fato de que as companhias de petróleo são bem experientes em julgar o risco e os possíveis retornos associados aos poços de perfuração, enquanto a quantificação do risco e possíveis retornos dos projetos de EOR é difícil de calcular e de se avaliar com antecedência. Apesar dos principais métodos já serem conhecidos há décadas, os projetos de recuperação melhorada ainda representam uma parcela pequena da produção mundial. Muitas companhias petrolíferas estão a perder oportunidades para maximizar o retorno do seu investimento, em contraposição com projetos que possuem tempos de retornos mais rápidos que tendem a se tornarem preferidos em cenários político-econômicos instáveis. Como mostrado, ainda há poucas regiões no mundo onde eles foram implantados em larga escala, mesmo em campos terrestres. Além disso, a aplicação de EOR se tornou um negócio especializado entre os operadores e algumas prestadoras de serviços, e as habilidades, tecnologias e conhecimentos necessários não estão amplamente disponíveis. Atualmente, seis empresas de petróleo e gás de médio porte operam a maioria dos projetos de injeção dióxido de carbono em reservatórios dos Estados Unidos. Contudo, em muitos casos, quando bem direcionada e planejada a utilização de métodos de EOR se mostram como potencialmente o único meio de se produzir o óleo remanescente de um reservatório de forma economicamente viável. Ademais, nota-se que tem havido crescente sinergia entre os métodos de recuperação de petróleo e com opções como *infill drilling*, poços horizontais e técnicas de estimulação de poços e de completação especial, possibilitando maximizar o desenvolvimento de um campo de petróleo.

Engenheiros de reservatórios encontram-se em uma posição única, uma vez que a maioria dos reservatórios estão em profundidades de milhares de pés e suas características e comportamento não podem ser observados diretamente além de suas modelagens numéricas poderem ser inviáveis no escopo de muitos

projetos em empresas operadoras. Esses reservatórios só podem ser sondados e amostrados de forma muito limitada e, porém, devem de, alguma maneira, possuírem seus comportamentos conceituados e preditos para que o desenvolvimento do campo de produção possa ser adequadamente planejado. A situação é ainda mais complicada pelo fato de que muito pouco se sabe sobre um reservatório em sua descoberta, a fim de desenvolvê-lo da maneira mais eficiente. Uma grande quantidade de dados relacionados ao reservatório só está disponível em fases posteriores, quando as reservas já foram produzidas após o desenvolvimento abaixo do ideal. Além disso, verifica-se que a recuperação final da maioria dos reservatórios de petróleo é bastante limitada. Nesse sentido, a busca por coleta de dados, ainda que simplificados, é então muitas vezes enfatizada por profissionais experientes, uma vez que podem ser identificados campos semelhantes em outras regiões do mundo com desafios parecidos. Além disso, e com base nos resultados desse trabalho, verificou-se que "lições aprendidas" no desenvolvimento de campos análogos ao redor do mundo podem ser incorporadas no processo de decisão em campos similares.

Observa-se então que o uso de ferramentas de redes neurais como o SOMs aplicado a tal problemática foi pertinente, possibilitando a análise dos métodos de EOR de uma maneira visual, simplificada e em sua totalidade. Além disso, foi possível verificar que, mesmo com dados faltantes, é possível obter uma boa acurácia na predição do método de EOR mais apropriado para cada campo, possibilitando incorporar experiências de projetos anteriores no processo de decisão. A rotina de metodologia ora apresentada aplicada a uma base de dados robusta, consiste em ferramenta relevante para *screening* em estágio inicial do desenvolvimento de um reservatório. Além disso, a metodologia também pode servir para aplicações em empresas interessadas em atuar na cadeia de valor do campo, que não possuem dados ou metodologias adequadas para avaliar tais processos, agilizando assim a tomada de decisão. O banco de dados global inédito desenvolvido nesta pesquisa, possibilita realizar comparações não apenas entre os diferentes métodos de EOR, como também de similaridades entre diferentes campos em diferentes regiões do mundo. Isso permite o desenvolvimento de panoramas sobre os principais *players* e empresas atuantes na cadeia de valor de EOR. Torna-se possível classificar em

nível global, continental e até nacional, servindo como suporte à tomada de decisão, e agregando valor aos fluxos de trabalho de avaliações geológicas e econômicas mais detalhadas.

Uma abordagem baseada em RNA não supervisionada foi utilizada nesse trabalho pela primeira vez, tendo como base a extensa literatura consultada em aplicações relacionados a métodos de EOR. Além disso, são pela primeira vez incluídas variáveis referentes à salinidade da formação e da água injetada, preço do barril de óleo, coordenadas geográficas, sucesso do projeto, dentre outras. A visualização de variáveis obtidas por correlação para os diferentes métodos de EOR também consiste em abordagem inédita. Especificamente, por meio do registro das coordenadas espaciais dos campos de produção verifica-se que foi possível incluir na metodologia do *screening* aspectos pouco tangíveis de maneira quantitativa, como disponibilidade de insumos, infraestrutura local, fatores regulatórios, legislação e políticas de incentivos propícias. Limitações do *screening*, especialmente quando se deseja considerar aspectos não tangíveis, podem ser relevantes caso aspectos espaciais próximos aos campos de interesse se alterem subitamente. Além disso, avanços nas fronteiras de aplicação de novos métodos de EOR por meio de pesquisa aplicada podem ser difíceis de se incluir na base de dados logo que lançados no mercado, podendo tornar alguns critérios de seleção obsoletos. Contudo, como mudanças em infraestrutura e marcos regulatórios na maioria dos casos tendem a possuir uma inércia relativamente grande para ocorrerem, a metodologia desenvolvida pode continuar sendo válida por bastante tempo em muitas situações, e que, somadas a constantes atualizações da base de dados, possui o potencial de acelerar a tomada de decisão e o prosseguimento para as próximas etapas de planejamento da aplicação de um método de EOR.

Figura 34. Síntese das principais limitações e desafios encontrados ao longo do desenvolvimento do trabalho, além de possíveis melhorias a serem implementadas.



(Autoria Própria)

Também é inovadora a utilização do cosseno similaridade (e seu complementar dissimilaridade do seno) entre os vetores amostras para se identificar reservatórios análogos, em que apesar de ser conceitualmente diferente da distância euclidiana, pôde-se corroborar os resultados obtidos pela metodologia SOM, que por sua vez toma a distância euclidiana como base para identificar relações de similaridade entre os campos de produção. Além disso, foi possível validar a inserção do posicionamento espacial ao explicitar casos reais, em que aspectos espacialmente próximos aos campos produtores mostraram mais relevantes na escolha do método de EOR a ser aplicado do que exclusivamente as propriedades petrofísicas do reservatório.

Outro ponto a ter em mente é que, embora os problemas possam ser de natureza similar e o uso de casos semelhantes auxilie e muito na agilidade do processo de decisão, nenhuma solução única funciona perfeitamente para todos os reservatórios e durante todo o seu plano de desenvolvimento. Cada reservatório é único em seu caráter e desempenho, e precisa ser avaliado individualmente. Nesse sentido, o uso do procedimento apresentado aqui para

treinar a rede neural artificial permite que o sistema seja adaptável, tanto em termos de atualização da base de dados, como em relação às variáveis utilizadas. Desse modo, pode-se incluir ou excluir determinados parâmetros conforme o objetivo desejado. Esta premissa permite melhorar a confiança na tomada de decisões e estimula a busca por práticas mais adequadas para garantir que as técnicas que mais agreguem valor sejam selecionadas. Assim, a proposta de um método de EOR com base em evidências fundamentadas pode ajudar a implementar mais rapidamente e a obter antecipadamente benefícios econômicos adicionais.


Observou-se um grande desafio em lidar com dados escassos e valores de variáveis assumindo a representatividade da constituição de um campo inteiro, o que muitas vezes pode não ser factível. Mais dados não necessariamente significam melhores dados. De fato, às vezes pode significar menos. Assim, a inclusão de dados mais precisos de um maior número de campos de forma que se consiga refinar a base de dados de forma que os dados sejam mais representativos é crucial para o contínuo aumento da confiabilidade da base de dados e das previsões realizadas. Além disso, segundo PRESS (2016) e a IBM (2017), a maior parte do trabalho realizado por cientistas de dados em projetos ligados ao desenvolvimento de modelos de exploração e análise de dados se concentra, contudo, na coleta e armazenamento dos dados. Em busca de reduzir tal processo e focar o tempo no desenvolvimento dos modelos, processo que agrega mais valor, é essencial buscar automatizar e organizar determinadas etapas da pesquisa, coleta, ingestão e processamento dos dados.

Melhorias e processos ainda a serem implementadas em tal metodologia incluem: (a) complementação com outras fontes de dados e refinamento da base de dados; (b) análise mais detalhada de parâmetros como erro topológico e erro de quantização, objetivando obter mapas de maior qualidade; (c) aprofundamento da análise das variáveis envolvidas, incluindo aspectos mais específicos e (d) refinar e validar de maneira rigorosa o *screening* com mais trabalhos e em demais cenários.

Para trabalhos futuros, possíveis abordagens tendo como fonte a base de dados consolidada podem envolver: (a) integração com simulações de dinâmica molecular em que, utilizando a base de dados como principal input, pode-se

obter parâmetros termodinâmicos e de petrofísica especial de interesse, como molhabilidade aproximada, tensão interfacial e pressão mínima de miscibilidade para cada reservatório; (b) estudo da cadeia de valor envolvida nos métodos de recuperação avançada de petróleo; e (c) análise da competitividade e posicionamento estratégico dos principais players do mercado. Conforme ilustra a [Figura 40](#), tais passos podem vir a dar suporte à estruturação de um modelo de negócios robusto capaz de fornecer informações estratégicas para empresas operadoras e companhias interessadas na cadeia de valor de EOR. Além disso, há a possibilidade de se vir fornecer um portfolio de serviços que permita a agilização da tomada de decisão no desenvolvimento de um campo de petróleo e ganhos de insights por meio de abordagens orientadas por dados.

Figura 35. Esquema ilustrando possíveis trabalhos futuros e novas abordagens envolvendo a exploração e análises diversas a partir base de dados consolidada acerca de projetos de EOR em escala mundial. Tal conjunto de trabalhos é visto como uma oportunidade de se embasar a construção de uma iniciativa empreendedora capaz fornecer um portfolio de serviços que possam ser de interesse para uma diversidade de *players*: empresas operadoras, especialmente pequenas e médias; atores inseridos na cadeia de valor de EOR, como fornecedores de produtos químicos, equipamentos e serviços especializados para tal setor; órgãos especializados e de consultoria interessados na obtenção de informações estratégicas, dentre outros.



(Autoria Própria)

6 REFERÊNCIAS

ALVARADO, V., MANRIQUE, E. **Enhanced oil recovery: field planning and development strategies**. Gulf Professional Publishing, 2010.

AGARWAL, Anshul et al. **Solar-generated steam for heavy-oil recovery: a coupled geomechanical and reservoir modeling analysis**. In: SPE Western Regional & AAPG Pacific Section Meeting 2013 Joint Technical Conference. Society of Petroleum Engineers, 2013.

AGGARWAL, Charu C. **Data mining: the textbook**. Springer, 2015.

AMINZADEH, F. (2005). **Applications of AI and soft computing for challenging problems in the oil industry**. Journal of Petroleum Science and Engineering, 47(1–2), 5–14. Disponível em: <<https://doi.org/10.1016/j.petrol.2004.11.011>>. Acesso em 25 maio 2019.

AYIRALA, Subhash C. **Surfactant-induced relative permeability modifications for oil recovery enhancement**. 2002.

BARWIS, John H.; MCPHERSON, John G.; STUDLICK, Joseph RJ (Ed.). **Sandstone petroleum reservoirs**. Springer Science & Business Media, 2012

BASKARAN, Vijai Kumar et al. **Application of integrated petroleum reservoir study for intervention and field development program in western onshore field, India**. Egyptian Journal of Petroleum, v. 26, n. 4, p. 981-994, 2017.

BEGG, S.H., BRATVOLD, R.B., CAMPBELL, J.M., 2003. **SHRINKS OR QUANTS: Who Will Improve Decision-Making** (SPE-84238). In: SPE Annual Technical Conference and Exhibition, Denver, 5-8 de outubro.

BRAVO, C., SAPUTELLI, L., RIVAS, F., PÉREZ, A.G., NIKOLAOU, M., ZANGL, G., DE GUZMAN, N., MOHAGHEGH, S. and NUNEZ, G., 2012. **State of the art of artificial intelligence and predictive analytics in the E&P industry: A technology survey**, Society of Petroleum Engineers Western Regional Meeting 2012 2012, pp. 12-33. Disponível em: <<https://www.scopus.com/record/display.uri?eid=2-s2.0-84861610856&origin=inward&txGid=239a4af997f92c6e2f44819860cbf2ce>>. Acesso em 15 agosto. 2019

BOURDAROT, G., GHEDAN, S.G. (2011). **EOR Screening criteria as applied to a group of offshore Carbonate oil reservoirs**. In: SPE Reservoir Characterisation and Simulation Conference and Exhibition. Abu Dhabi, UAE.

BUCKNER, L.A., 1994. **Tax Incentive for Enhanced Oil Recovery Projects** (SPE-27781). In: SPE/DOE Improved Oil Recovery Symposium, Tulsa, April 17–20.

BRITISH PETROLEUM. **Crude assays**. BP. Disponível em: <<https://www.bp.com/en/global/bp-global-energy-trading/features-and-updates/technical-downloads/crudes-assays.html>> Acesso em 1 nov. 2019.

BP Statistical Review of World Energy June 2019. Disponível em: <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2018-full-report.pdf>> Acesso em 13 outubro. 2019.

BREIMAN, L. (1996) **Bagging predictors**. Machine Learning, forthcoming.

BRODIE, J.A., JHAVERI, B.S., MOULDS, T.P., HETLAND, S.M. “**Review Of Gas Injection Projects In BP**”. SPE Improved Oil Recovery Symposium, SPE-154008-MS, Tulsa, Oklahoma, USA, 14-18 abr. 2012

CARNEIRO, C.C.; FRASER, S.; SILVA, A. M.; BARROS, C. E. DE M.; CRÓSTA, A. P. (2012) **Semiautomated geologic mapping using self-organizing maps and airborne geophysics in the Brazilian Amazon**. Geophysics, v. 77, p. 17-24.

CÉRÉGHINO, R., AND Y.-S. PARK (2009), **Review of the self-organizing map (SOM) approach in water resources: commentary**. Environmental Modelling & Software, 24, 945–947.

CHENG, Aaron et al. **Optimal Injection Design Utilizing Tracer and Simulation in a Surfactant Pilot for a Fractured Carbonate Yates Field**. In: SPE Improved Oil Recovery Symposium. Society of Petroleum Engineers, 2012.

CHIOU, R. C. S. et al. **South Belridge Tulare Simulation Study: Steamflood in a Heterogeneous Stratified Reservoir**. SPE Reservoir Engineering, v. 10, n. 02, p. 137-142, 1995.

CHONA, R. A. et al. **Evaluation of a horizontal infill well in a mature cyclic-steam project**. In: International Conference on Horizontal Well Technology. Society of Petroleum Engineers, 1996.

CORREIA, Manuel Gomes et al. **Scaling Up Highly Permeable Thin Layers Into Flow Simulation**. SPE Reservoir Evaluation & Engineering, v. 21, n. 02, p. 501-520, 2018.

CRAIG, D. H. **Yates and other Guadalupian (Kazanian) oil fields, US Permian basin**. Geological Society, London, Special Publications, v. 50, n. 1, p. 249-263, 1990.

CROOKS, N., 2008. **Neuquén governor: Country to implement Oil Plus program—Argentina**. New Sage Energy, Notícia de imprensa, 24 de setembro. Disponível em: <<http://www.newsage.ca/PressReleases/PressReleaseDetails/2008/NeuquengovernorCountrytoimplementOilPlusprogramArgentina/default.aspx>>. Acesso em 14 julho. 2019.

DAVIES, D.L., BOULDIN, D.W. (1979) **A cluster separation measure: IEEE Transactions on Pattern Analysis and Machine Intelligence**, 1, no. 2, 224-227.

DELAMAIDE, Eric et al. **Chemical EOR in low permeability reservoirs**. In: SPE EOR Conference at Oil and Gas West Asia. Society of Petroleum Engineers, 2014.

DELGADO, F.; QUINTELLA, C.; NETO, A.; GOUVÊA, A.; GOMES, C.; LAMASSA, D.; FERNANDES, G.; CHAMBRIARD, M.; AZEVEDO, M.; NEVES, P.; CARNEIRO, P.; ROITMAN, T.; TOLEDO, T. (2019). **ROYALTIES E EOR EM CAMPOS MADUROS NO BRASIL: DISCUSSÕES SOBRE ALÍQUOTAS E ARRECADAÇÕES**. Caderno de Opinião: FGV Energia.

DICKSON, J.L., LEAHY-DIOS, A., WYLIE, P.L., 2010. **Development of improved hydrocarbon recovery screening methodologies**. In: SPE Improved Oil Recovery Symposium. Tulsa, Oklahoma, USA. Lee, J., Kao, H. A., & Yang, S. (2014).

DJABBARAH, N. F. et al. Laboratory design and field demonstration of steam diversion with foam. In: SPE California Regional Meeting. Society of Petroleum Engineers, 1990.

DOVAN, H. T. et al. **Dos cuadradas offshore polymer flood**. In: SPE California Regional Meeting. Society of Petroleum Engineers, 1990.

ELSAYED, S. A. et al. **Multidisciplinary reservoir characterization and simulation study of the Weyburn unit**. Journal of Petroleum Technology, v. 45, n. 10, p. 930-973, 1993.

EL-KHATIB, Noaman AF et al. **The modification of the dykstra-parsons method for inclined stratified reservoirs**. SPE Journal, v. 17, n. 04, p. 1,029-1,040, 2012.

Energy Information Administration. Disponível em: <<https://www.eia.gov/>>. Acesso em: 22 maio. 2019.

EQUINOR. **Crude oil assays**. Equinor. Disponível em: <<https://www.equinor.com/en/what-we-do/crude-oil-and-condensate-assays.html>>. Acesso em 1 nov. 2019.

EXXONMOBIL. **Assays available for download**. ExxonMobil. Disponível em: <<https://corporate.exxonmobil.com/Crude-oils/Crude-trading/Assays-available-for-download>>. Acesso em 1 nov. 2019.

FAVARO, C. **O "Onshore estava hibernado, diz secretário"**. Disponível em: <<https://economia.estadao.com.br/noticias/geral,onshore-no-pais-estava-hibernado-diz-secretario,70002953891>>. Acesso em 28 de agosto de 2019.

FAROUQ, S. M. A., 2012. **The Unfulfilled Promise of Enhanced Oil Recovery—What Lies Ahead?**. SPE Distinguished Lecturer Program.

FENG, Qihong et al. **Development of Thin Layer Ultra-Heavy Oil Reservoirs with Horizontal Well Steamflooding and Treatment Technology for Steam Breakthrough**. In: SPE International Heavy Oil Conference and Exhibition. Society of Petroleum Engineers, 2014.

FONG, W. S. et al. **Analysis of a Successful Cyclic Steam Process at Cymric Field**, California. In: SPE International Thermal Operations and Heavy Oil Symposium. Society of Petroleum Engineers, 2001.

GALE, John; DAVISON, John. **Transmission of CO₂—safety and economic considerations**. *Energy*, v. 29, n. 9-10, p. 1319-1328, 2014.

GHARBI, R.B., GARROUCH, A.A., 2001. **The performance of miscible enhanced oil recovery displacements in geostatistically generated permeable media using horizontal wells**. *J. Por Med.* 4 (2), 113–126.

GILMAN, J. R. et al. **Application of short-radius horizontal boreholes in the naturally fractured Yates field**. *SPE Reservoir Engineering*, v. 10, n. 01, p. 10-15, 1995.

GREEN, Todd; REESE, Michael; HENRY, Manus. Two-phase CO₂ measurement and control in the Yates oil field. *Measurement and Control*, v. 41, n. 7, p. 205-207, 2008.

FESSANT, F., MIDENET, S. (2002) **Self-organizing Map for Data Imputation and Correction in Surveys**. *Neural Computation Applications* 10, 300–310.

KALTEH, A. M.; HJORTH, P.; BERNDTSSON, R. (2008) **Review of the self-organizing map (SOM) approach in water resources: Analysis, modelling and application**. *Environmental Modelling & Software*, v. 23, n. 7, p. 835–845. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S1364815207001879>. Acesso em 17 julho 2019.

HAN, Jiawei; PEI, Jian; KAMBER, Micheline. **Data mining: concepts and techniques**. Elsevier, 2011.

HAN, Liqun et al. **Customizing drill-in fluid for Peregrino project in Brazil: Laboratory development and field experience**. In: SPE International Symposium and Exhibition on Formation Damage Control. Society of Petroleum Engineers, 2012.

HUANG, Ji-hong et al. **Production Performance of In-Situ Combustion in Heavy Oil Reservoir after Steam Injection** [J]. Xinjiang Petroleum Geology, v. 5, 2010.

HUSTAD, C.W., AUSTELL, J.M., 2004. **Mechanisms and Incentives to Promote the Use and Storage of CO₂ in the North Sea**. In: Roggenkamp, M.M., Hammer, U. (Eds.), European Energy Law Report I, pp. 355–380, Intersentia.

HAYKIN, S. (2008). "9. **Self-organizing maps**". Neural networks - A comprehensive foundation (3rd ed.). Prentice-Hall. ISBN 978-0132733502

HASHEMI-KIASARI, H., HEMMATI-SARAPARDEH, A., MIGHANI, S., MOHAMMADI, A.H., SEDAEE-SOLA, B., 2014. **Effect of operational parameters on SAGD performance in a dip heterogeneous fractured reservoir**. Fuel 122, 82–93.

IBM. 2017. **Breaking the 80/20 rule: How data catalogs transform data scientists' productivity**. Disponível em: <<https://www.ibm.com/cloud/blog/ibm-data-catalog-data-scientists-productivity>>. Acesso em 12. Out. 2019.

JENSEN, Jerry L. et al. **A new method for estimating the Dykstra-Parsons coefficient to characterize reservoir heterogeneity**. SPE Reservoir Engineering, v. 5, n. 03, p. 369-374, 1990.

JIEXIANG, Wang; NA, Li; HONGGUO, Sun. **Experiment study of improved oil recovery through air foam flooding in heterogeneous reservoir**. Petroleum Drilling Techniques, v. 36, n. 2, p. 4, 2008.

JIN, Zhou et al. **Study on the EOR experiment and field test of air foam flooding in Wuliwan oilfield**. In: IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2018. p. 012015.

JONES, C., ROSS, M., GETLIFF, J. et al. "**Captain Field Injector Performance, Historical Perspective and Recent Improvements**". SPE European Formation Damage Conference and Exhibition, SPE-174183-MS, Budapest, Hungary, 3-5 jun. 2015.

KANG, P.-S., LIM, J.-S., HUH, C., 2014. **Screening criteria for application of EOR processes in offshore fields**. In: The Twenty-Fourth

International Ocean and Polar Engineering Conference. International Society of Offshore and Polar Engineers, Busan, Korea.

KOHONEN T. (2001) **Self-Organizing Maps**. Third Extended Edition, Springer Series, Information Sciences, 30, 501 p.

KOKAL, S., AL-KAABI, A. “**Enhanced Oil Recovery: challenges & opportunities**”. Global Energy Solutions, World Petroleum Council, 2010. Disponível em: <http://www.world-petroleum.org/docs/docs/publications/2010yearbook/P64-69_Kokal-Al_Kaabi.pdf>. Acesso em: 18 agosto. 2019.

KUMAR, M. et al. **Cyclic steaming in heavy oil diatomite**. In: SPE Western Regional Meeting. Society of Petroleum Engineers, 1995.

LI, Zhaowen et al. **CO2 sequestration in depleted oil and gas reservoirs—caprock characterization and storage capacity**. Energy Conversion and Management, v. 47, n. 11-12, p. 1372-1382, 2006.

LI, Zhenquan et al. **The feasibility studies of polymer foam flooding in Gudao oilfield**. In: SPE Asia Pacific Oil & Gas Conference and Exhibition. Society of Petroleum Engineers, 2006.

LI, Zhuang. **Deployment optimization of SAGD pilot design in thin bed and extra-heavy oil reservoir of Block D229**. Fault-Block Oil & Gas Field, v. 16, n. 6, p. 79-81, 2009.

LIU, Hao et al. **Oil Recovery for heavy oil by displacing agent/foam assisted steam flooding: laboratory experiments, numerical simulations and field performances**. In: SPE International Heavy Oil Conference and Exhibition. Society of Petroleum Engineers, 2014.

LOLLEY, C. S. et al. **Recipe for heating and recovering an 800 foot column of heavy oil, Potter sands, Midway-Sunset field, California**. In: International Thermal Operations/Heavy Oil Symposium. Society of Petroleum Engineers, 1999.

KRISTOFFERSEN, Øystein et al. **Short Term Production Optimization Using a Model of the Peregrino Field, Brazil**. In: OTC Brasil. Offshore Technology Conference, 2017.

MANRIQUE, E. et al. **Colloidal Dispersion Gels (CDG): Field Projects Review**. In: SPE EOR Conference at Oil and Gas West Asia. Society of Petroleum Engineers, 2014.

MALIK, Qamar M. et al. **CO₂ Injection in the Weyburn field of Canada: optimization of enhanced oil recovery and greenhouse gas storage with horizontal wells**. In: SPE/DOE improved oil recovery symposium. Society of Petroleum Engineers, 2000.

MASHAYEKHIZADEH, V., KORD, S., DEJAM, M., 2014. **EOR Potential within Iran**. *Spe. Top. Rev. Por Med.: Int. J.* 5 (4), 325–354.

MCKAY, Charles et al. **Successful horizontal producers in Midway-Sunset thermal operations**. In: SPE Western Regional/AAPG Pacific Section Joint Meeting. Society of Petroleum Engineers, 2003.

MEEHAN, Nathan. **Advanced Reservoir Management and Engineering**. Gulf Professional Publishing, 2011.

MENCONI, F. et al. (2013). **Inyección de geles en el yacimiento El Tordillo: Desde los pilotos hasta la Masificación**. *Petrotecnia* (Revista do Instituto Argentino de Petróleo e Gas), No. 2, Abril 2013. pp: 42–55.

MENEZES, E.M.V. “DESPACHO DO SUBSECRETÁRIO EXECUTIVO Nº 1.153/2015 - DOU 13.8.2015”, Agência Nacional de Petróleo, Gás Natural e Biocombustíveis, 12 ago. 2015. Disponível em: <[http://nxt.anp.gov.br/NXT/gateway.dll/leg/despachos/2015/agosto/despachos/2015/153/2015.xml?f=templates\\$fn=document-frame.htm\\$3.0\\$q=\\$x=>](http://nxt.anp.gov.br/NXT/gateway.dll/leg/despachos/2015/agosto/despachos/2015/153/2015.xml?f=templates$fn=document-frame.htm$3.0$q=$x=>)>. Acesso:

Ministério de Minas e Energia. (21 de Agosto de 2019). **MME lança Programa de Exploração e Produção de Petróleo e Gás Natural em Terra - REATE 2020**. Acesso em 25 de Agosto de 2019, disponível em Ministério de Minas e Energia: http://www.mme.gov.br/web/guest/pagina-inicial/outras-noticias/-/asset_publisher/32hLrOzMkWWb/content/mme-lanca-programa-de-exploracao-e-producao-de-petroleo-e-gas-natural-em-terra-reate-2020?redirect=http%3A%2F%2Fwww.mme.gov.br%2Fweb%2Fguest%2Fpagina-inic

MITRA, Shankar et al. **Three-dimensional structural model of the Cantarell and Sihil structures, Campeche Bay, Mexico**. AAPG bulletin, v. 89, n. 1, p. 1-26, 2005.

MOREL, D. C. et al. **Dalia/camelia polymer injection in deep offshore field angola learnings and in situ polymer sampling results**. In: SPE Asia Pacific Enhanced Oil Recovery Conference. Society of Petroleum Engineers, 2015.

MORENO, J.E., GURPINAR, O.M., LIU, Y., AL-KINANI, A., CAKIR, N., 2014. EOR Advisor system: **A comprehensive approach to EOR selection**. In: International Petroleum Technology Conference. International Petroleum Technology Conference, Kuala Lumpur, Malaysia.

NJIEKAK, Gautier et al. **CO2 rock physics as part of the Weyburn-Midale geological storage project**. International Journal of Greenhouse Gas Control, v. 16, p. S118-S133, 2013.

PARK, Y.-S., J. TISON, S. LEK, J.-L. GIRAUDEL, M. COSTE, AND F. DELMAS. 2006. **Application of a self-organizing map to select representative species in multivariate analysis: A case study determining diatom distribution patterns across France**: Ecological Informatics, 1, 247–257, doi: 10.1016/j.ecoinf.2006.03.005.

O'DONNELL, John Setel et al. **Systems and methods for selectively producing steam from solar collectors and heaters for processes including enhanced oil recovery**. U.S. Patent n. 9,200,799, 1 dez. 2015.

ORR JR, F. M; JENSEN, C.M. **Interpretation of pressure-composition phase diagrams for CO2/crude-oil systems**. Society of Petroleum Engineers Journal, v. 24, n. 05, p. 485-497, 1984.

PEDERSEN, F.B., HANSSEN, T.H., AASHEIM, T.I., 2006. **How Far Can a State-of-the-Art NPV Model Take You in Decision Making?** (SPE-99627). In: SPE EUROPEC/EAGE Annual Conference and Exhibition, Vienna, Junho 12–15.

PIZARRO, Jorge Oscar De Santanna et al. **Challenges in implementing an EOR project in the pre-salt province in Deep Offshore Brasil**. In: SPE EOR Conference at Oil and Gas West Asia. Society of Petroleum Engineers, 2012.

PETROBRAS (2019). **Plano Estratégico 2040 e Plano de Negócios e Gestão 2019-2023**. Disponível em:<<http://www.petrobras.com.br/lumis/portal/file/fileDownload.jsp?fileId=8A193576677E04D201678026C9604B26>>. Acesso em: 23 agosto. 2019.

POLTRONIERI, O. C. C.; ARMELIN, N. A. **Surfactants For Ceor: A Review Of State-Of-The-art Technologies And Challenges Towards Their Use In Commercial Scale**. Rio Oil & Gas Expo and Conference 2014.

PRESS, Gil. **Cleaning big data: Most time-consuming, least enjoyable data science task, survey says**. Forbes, March, v. 23, p. 15, 2016.

RANSBOTHAM, S. E D. KIRON. **“Analytics as a Source of Business Innovation: the increased ability to innovate with analytics is producing a surge of benefits across industries.”**. MIT MBA Sloan Management Review. Boston, USA. 28 fev. 2017. Disponível em: <<https://sloanreview.mit.edu/projects/analytics-as-a-source-of-business-innovation/>>. Acesso em: 13 outubro. 2018.

R. AL-MJENI, S. ARORA, P. CHERUKUPALLI, J.V. WUNNIK, J. EDWARDS, B.J. FELBER, O. GURPINAR, G.J. HIRASAKI, C.A. MILLER, C. JACKSON, M.R. KRISTENSEN, F. LIM, R. RAMAMOORTHY. **Has the time come for EOR?** Oilfield Rev. 22 (4) (2011) 16–35

RAMEY JR, H. J. et al. **Case history of South Belridge, California, in-situ combustion oil recovery**. In: SPE/DOE Enhanced Oil Recovery Symposium. Society of Petroleum Engineers, 1992.

REN, Bo et al. **Laboratory assessment and field pilot of near miscible CO₂ injection for IOR and storage in a tight oil reservoir of Shengli Oilfield China**. In: SPE Enhanced Oil Recovery Conference. Society of Petroleum Engineers, 2011.

REN, S. R. et al. **EOR technology of profile control and displacement process by air foam injection in Zhongyuan Oilfield**. Acta Petrolei Sinica, v. 30, n. 3, p. 413-416, 2009.

RUSSELL, S. J; NORVIG. P. 1995. **Artificial intelligence: a modern approach**. Prentice Hall, Englewood Cliffs, New Jersey. 932p. Service innovation and smart analytics for Industry 4.0 and big data environment. Procedia CIRP, 16, 3–8. <https://doi.org/10.1016/j.procir.2014.02.001>

SAINI, Dayanand et al. **A pseudo-SAGD scoping model for evaluating economic viability of heavy oil projects**. Journal of Petroleum Science and Engineering, v. 137, p. 125-133, 2016.

SANCHEZ BUJANOS, Jose Luis et al. Nitrogen injection in the Cantarell complex: results after four years of operation. In: SPE Latin American and Caribbean Petroleum Engineering Conference. Society of Petroleum Engineers, 2005. **Review of a forgotten technology with high potential-The world largest nitrogen based IOR project in the supergiant field cantarell, Mexico**. In: SPE Russian oil and gas exploration & production technical conference and exhibition. Society of Petroleum Engineers, 2014.

SANDLER, Joel et al. **Solar-generated steam for oil recovery: reservoir simulation, economic analysis, and life cycle assessment**. Energy conversion and management, v. 77, p. 721-732, 2014.

Schlumberger. (23 de Outubro de 2019). **Technical Challenges: Enhanced Oil Recovery**. Fonte: Enhanced Oil Recovery (EOR) | Schlumberger: <https://www.slb.com/technical-challenges/enhanced-oil-recovery>

SECCOMBE, Jim et al. **Demonstration of low-salinity EOR at interwell scale, Endicott field, Alaska**. In: SPE improved oil recovery symposium. Society of Petroleum Engineers, 2010

SHENG, James (Ed.). **Enhanced oil recovery field case studies**. Gulf Professional Publishing, 2013.

SNELL, J. S. et al. **Yates field steam pilot applies latest seismic and logging monitoring techniques**. In: SPE Annual Technical Conference and Exhibition. Society of Petroleum Engineers, 1999.

SONG, Wanchao et al. **Application of a new crosslinked polymer displacement technology at Bo-19 Block in Gudao oilfield**. In: SPE Asia Pacific Oil and Gas Conference and Exhibition. Society of Petroleum Engineers, 2002.

STANDNES, Dag C. et al. **An evaluation of spontaneous imbibition of water into oil-wet carbonate reservoir cores using a nonionic and a cationic surfactant**. Energy & Fuels, v. 16, n. 6, p. 1557-1564, 2002.

SUN, Fang Jian et al. **Advancement and application of thermal recovery technology in heavy oil reservoir in Shengli petroleum province**. In: International Petroleum Technology Conference. International Petroleum Technology Conference, 2011

SUN, Yongtao et al. **Enhance offshore heavy oil recovery by cyclic steam-gas-chemical co-stimulation**. In: SPE Heavy Oil Conference and Exhibition. Society of Petroleum Engineers, 2011.

TABER, J.J., Martin, F., Seright, R., 1997. **EOR Screening criteria revisited-part 1: Introduction to screening criteria and enhanced recovery field projects**. SPE Res. Eng. 12 (03), 189–198.

TAKASSI, M.A., Zargar, G., Madani, M., Zadehnazari, A., 2017. **The preparation of an amino acid–based surfactant and its potential application as an EOR agent**.

TEAHAN W.J (2010) **Artificial Intelligence – Agents and Environments**. 1st edition.

TOTAL S.A. **Crude Assays**. Total Oil Trading S.A. Disponível em: https://www.totsa.com/pub/crude/crude_assays.php?rub=1. Acesso em 1 nov. 2019.

VESANTO, J.; Himberg, J.; Alhoniemi, E.; Parhankangas, J. (2000) **SOM Toolbox for Matlab 5**. Technical Report A57, v. 2, n. 0, p. 59.

WANG, S. (2003) **Application of self-organising maps for data mining with incomplete data sets**. p. 42–48.

WANG, Leilei; CHEN, Zhigang; WU, Jia. **An opportunistic routing for data forwarding based on vehicle mobility association in vehicular ad hoc networks**. Information, v. 8, n. 4, p. 140, 2017.

WANG, Yong et al. **Numerical calculation and analysis on phase behavior of fireflood exhaust from HQ-1 well in Xinjiang oilfield**. In: IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2019. p. 022024.

WEI, Xiao-ming; ZHENG, Meng; BAI, Yong-lin. **Viscosity reduction mechanism by aqueous solution of surfactant** [J]. Special Oil & Gas Reservoirs, v. 4, 2004.

WELSH, M.B., BEGG, S.H., 2007. **Modeling the Economic Impact of Cognitive Biases on Oil and Gas Decisions** (SPE-110765). In: SPE Annual Technical Conference and Exhibition, Anaheim, 11-14 novembro.

WINTERFELD, Philip H. et al. **Development of dual-permeability thermal simulator and validation for Yates field**. In: SPE/DOE Improved Oil Recovery Symposium. Society of Petroleum Engineers, 1996.

World Energy Outlook 2018. International Energy Agency.

XIE, Xina et al. Improved oil recovery from carbonate reservoirs by chemical stimulation. SPE Journal, v. 10, n. 03, p. 276-285, 2005.

XIONG, S. et al. **Petroleum sulfonates as oil displacement agents and application to Gudao oil field**. Petroleum Science and Technology, v. 27, n. 4, p. 357-367, 2009.

YELLIG, W. F. et al. **Determination and Prediction of CO₂ Minimum Miscibility Pressures** (includes associated paper 8876). Journal of Petroleum Technology, v. 32, n. 01, p. 160-168, 1980.

YOUYI, Zhu et al.. **The research progress in the alkali-free surfactant-polymer combination flooding technique**. Petroleum exploration and development, v. 39, n. 3, p. 371-376, 2012

7 APÊNDICE

Apêndice 1. Legenda de caracterização das variáveis descritas na tabela [\(anexo 2\)](#)

	Variável categórica original
	Variável originada do desmembramento de outra variável (transformação de categórica em binária)
	Variável numérica original com intervalo
	Variável originada de variável numérica com intervalo
	Atributo resultante da combinação de outras duas ou mais variáveis
	Variável numérica, sem modificação em sua estrutura (alteração no máximo de unidades medida visando padronização)
	Variáveis categóricas mantidas como originalmente sem alteração em sua estrutura

Apêndice 2. Tabela contendo a descrição das variáveis da base de dados estruturada e que foram selecionadas para a análise. A primeira seção (em cinza) representa essencialmente as informações descritivas disponíveis para os campos ou reservatórios em que foram aplicados métodos de EOR presentes na base de dados.

Abreviação da variável	Descrição da variável	Transformação log-normal
ID	Número de identificação do respectivo campo de produção (CP) ou reservatório	
Fn	Nome do CP (<i>Field name</i>)	
Pz	Nome da zona produtora (<i>Pay zone</i>)	
Cty	Condado em que se localiza o CP (<i>County</i>)	
Pvc	Província em que se localiza o CP (<i>Province</i>)	
Stt	Estado em que se localiza o CP (<i>State</i>)	
Area	Região administrativa em que se localiza o CP	
Loc	Variável localização, resultado da combinação das variáveis "Area", "County", "Province" e "State"	

Adr	Referência construída a partir de dados de localização para obtenção das coordenadas georreferenciadas	
Coord	Coordenadas geográficas obtidas via algoritmo em VBA a partir de "Adress"	
País em que se localiza o campo de produção	Variável original referente ao país de localização do projeto	
Ct_Arg	Argentina	
Ct_Bra	Brasil	
Ct_Can	Canadá	
Ct_Chi	China	
Ct_Col	Colômbia	
Ct_Deu	Alemanha	
Ct_Dnk	Dinamarca	
Ct_Egy	Egito	
Ct_Fra	França	
Ct_Gbr	Reino Unido	
Ct_Hun	Hungria	
Ct_Idn	Indonésia	
Ct_Ind	Índia	
Ct_Italia	Italia	
Ct_Lby	Líbia	
Ct_Mexico	México	
Ct_Mys	Malásia	
Ct_Nld	Holanda	
Ct_Nor	Noruega	
Ct_Oma	Omã	
Ct_Scot	Escócia	
Ct_Tto	Trindade e Tobago	
Ct_Tur	Turquia	
Ct_UAE	Emirados Árabes Unidos	
Ct_USA	Estados Unidos da América	
Ct_Ven	Venezuela	
Ct_Vnm	Vietnam	
Classificação de EOR nas classes: (i) injeção de gás, detalhando quanto ao tipo de gás injetado, se o processo é miscível ou não e se é injeção contínua, periodizada ou decrescente; (ii) injeção de produtos químicos e possíveis combinações; (iii) uso de métodos térmicos	Variável original referente ao tipo de método de EOR aplicado	
GasInj_type_Air_Foam	Injeção de ar/espuma	
GasInj_type_CO2	Injeção de dióxido de carbono	
GasInj_type_Foam	Injeção de foamer/surfactante	
GasInj_type_Hidroc	Injeção de gás hidrocarboneto	
GasInj_type_Meth_et	Injeção de metano/etano	
GasInj_type_Nitrog	Injeção de nitrogênio	
GasMisc_Miscible	Injeção com processo miscível; os imiscíveis recebem valor zero nessa coluna	

GasInj_Continue	Injeção contínua de gás	
GasInj_SWAG	Injeção simultânea de água e gás (Simultaneous Water Alternating Gas)	
GasInj_TWAG	Injeção alternada de gás e água com redução paulatina da quantidade de gás injetada e aumento da de água (Tapered Water Alternate Gas)	
GasInj_WAG	Injeção alternada de gás e água (Water Alternate Gas)	
ChemInj_Alcal	Injeção de Alkaline	
ChemInj_LSWF	Injeção de água de baixa salinidade (Low Salinity Waterflooding)	
ChemInj_Micel_polim	Injeção de solução micelar e polimérica	
ChemInj_Polim	Injeção de polímero	
ChemInj_Surf	Injeção de surfactante	
ChemInj_Surf_pol_or_ASP	Injeção de surfactante, polímero ou ASP (Alkaline–surfactant–polymer)	
ChemInj_Surf_polim	Injeção de surfactante e polímero	
Therm_Cyc_steam	Injeção vapor cíclico	
Therm_Eletrom	Aquecimento eletromagnético	
Therm_SAGD	Vapor assistido pela gravidade (Steam-assisted gravity drainage)	
Therm_Steam	Injeção de vapor	
Therm_Steam_drive	Injeção de vapor assistido	
Therm_Steam_solv	Injeção de vapor e solvente	
Operator_company	Variável original referente à empresa operadora	
Op_Aera Energy	Aera Energy	
Op_Anadarko	Anadarko	
Op_Apache	Apache	
Op_Bayou State	Bayou State	
Op_Berry	Berry	
Op_BP (British Petroleum)	BP (British Petroleum)	
Op_Breitburn Energy	Breitburn Energy	
Op_Cano	Cano	
Op_Carrizo	Carrizo	
Op_Cenovus	Cenovus	
Op_Chaparral Energy	Chaparral Energy	
Op_Cheo	Cheo	
Op_Chevron	Chevron	
Op_CNOOC (China National Offshore Oil Corporation)	CNOOC (China National Offshore Oil Corporation)	
Op_CNPC (China National Petroleum Corporation)	CNPC (China National Petroleum Corporation)	
Op_CNRL (Canadian Natural Resources)	CNRL (Canadian Natural Resources)	
Op_Conoco Canada	Conoco Canada	
Op_ConocoPhillips	ConocoPhillips	
Op_Continental Resources	Continental Resources	
Op_Core Energy	Core Energy	
Op_Daqing Administration Bureau	Daqing Administration Bureau	
Op_Daqing Oilfield Company Ltd	Daqing Oilfield Company Ltd	

Op_Denbury Resources	Denbury Resources	
Op_Derek Oil & Gas Corp	Derek Oil & Gas Corp	
Op_Devon	Devon	
Op_Devon Canada	Devon Canada	
Op_Elf Aquitaine	Elf Aquitaine	
Op_Encore Acquisition	Encore Acquisition	
Op_Energen Resources	Energen Resources	
Op_Eni	Eni	
Op_Equinor	Equinor	
Op_ExxonMobil	ExxonMobil	
Op_Fasken	Fasken	
Op_Great Western	Great Western	
Op_Hassie	Hassie	
Op_Hess	Hess	
Op_Husky Oil	Husky Oil	
Op_Imperial Oil	Imperial Oil	
Op_Jiangnan Petroleum Administration Bureau	Jiangnan Petroleum Administration Bureau	
Op_Kinder Morgan	Kinder Morgan	
Op_Lundion OI	Lundion OI	
Op_Marathon	Marathon	
Op_MegaWest Energy Corp	MegaWest Energy Corp	
Op_Merit Energy	Merit Energy	
Op_Naftex	Naftex	
Op_Nederlandse Aardolie Maatschappij (NAM)	Nederlandse Aardolie Maatschappij (NAM)	
Op_New Horizon	New Horizon	
Op_Nitrogen Talisman	Nitrogen Talisman	
Op_Norsk Hydro	Norsk Hydro	
Op_Occidental	Occidental	
Op_Omimex	Omimex	
Op_ONGC (Oil and Natural Gas Corporation - India)	ONGC (Oil and Natural Gas Corporation - India)	
Op_Orla Petco	Orla Petco	
Op_PDVSA E&P	PDVSA E&P (Petróleos de Venezuela)	
Op_Pemex	Pemex	
Op_Pengrowth Corporation	Pengrowth Corporation	
Op_Penn West Energy Trust	Penn West Energy Trust	
Op_Petrobras	Petrobras	
Op_PetroRio	PetroRio	
Op_Petrotrin	Petrotrin	
Op_PT Caltex	PT Caltex	
Op_Resolute Natural Resources	Resolute Natural Resources	
Op_Scimitar	Scimitar	
Op_Seneca Resources	Seneca Resources	
Op_Shell	Shell	
Op_Sinopec (China Petroleum & Chemical Corporation)	Sinopec (China Petroleum & Chemical Corporation)	
Op_Stanberry Oil	Stanberry Oil	
Op_Stockdale	Stockdale	

Op_Tabula Rasa	Tabula Rasa	
Op_Tecpetrol	Tecpetrol	
Op_Texaco	Texaco	
Op_Tidelands	Tidelands	
Op_Total	Total	
Op_TPAO (Türkiye Petrolleri Anonim Ortaklığı)	TPAO (Türkiye Petrolleri Anonim Ortaklığı)	
Op_Trinity	Trinity	
Op_Whiting Petroleum	Whiting Petroleum	
Op_Wintershall Holding AG	Wintershall Holding AG	
Op_Xinjiang Petroleum Adm. Bureau	Xinjiang Petroleum Adm. Bureau	
Op_XTO Energy Inc.	XTO Energy Inc.	
Op_Zueitina Oil	Zueitina Oil	
Latitude	Latitude e longitude obtidas via API do Google Maps e automação via código em VBA com base nas informações de "Area", "County", "Province" e "State"	
Longitude		
Area_acres	Área em acres (1 acre = 4046,86 m ²)	X
Start_date	Data inicial de aplicação do EOR no CP	
Nominal_Crude_Oil_Price	Preço nominal do barril de petróleo em dólares para o ano de início do projeto de EOR (inflação)	
Real_Oil_Price_USD	Preço real do barril de petróleo em dólares para o ano de início do projeto de EOR	
Offshore_Yes	Se o campo de produção é offshore	
Onshore_Yes	Se o campo de produção é onshore	
Depth_subsea_ft	Profundidade média da lâmina d'água para reservatórios offshore	
No_wells_inj	Número de poços injetores no CP	X
Prod_well_density	Densidade de poços produtores (No_Wells_inj/Area_acres)	X
No_wells_prod	Número de poços produtores no CP	X
Prod_well_density	Densidade de poços produtores (No_Wells_prod/Area_acres)	X
Ratio_prod_inj	Razão entre número de poços produtores e injetores (No_wells_prod/No_wells_inj)	X
Injected_salinity	Salinidade da água injetada, em g/L=ppm	
Lithology	Constituição litológica	
Lit_Carbonate	Carbonato	
Lit_Chalk	Chalk	
Lit_Cong	Conglomerado	
Lit_Dolo	Dolomita	
Lit_Dolo_Lime_Sand	Dolomita/Calcário/Arenito	
Lit_Dolo_Sand	Dolomita/Arenito	
Lit_Dolo_Trip	Dolomita/Tripolita	
Lit_Lime	Calcário	
Lit_Lime_Dolo	Calcário/Dolomita	
Lit_Lime_Sand	Calcário/Arenito	
Lit_Sand	Arenito	
Lit_Sand_cong	Arenito/Conglomerado	
Lit_Tripol	Tripolita	
Lit_Unc_sand	Arenito inconsolidado	

Fract	Se o reservatório é naturalmente fraturado	
Porosity (%)	Intervalo numérico de porosidade da formação	
Poros_min	Porosidade mínima	
Poros_max	Porosidade máxima	
Poros_avg	Porosidade média	
Poros_range	Diferença entre os valores máximos e mínimos	
Permeab (mD)	Intervalo numérico de permeabilidade da formação	
Permeab_min	Permeabilidade mínima	X
Permeab_max	Permeabilidade máxima	X
Permeab_avg	Permeabilidade média	X
Permeab_range	Diferença entre os valores máximos e mínimos	
Depth (ft)	Intervalo numérico de profundidade da formação	
Depth_min	Profundidade mínima	
Depth_max	Profundidade máxima	
Depth_avg	Profundidade média	
Depth_range	Diferença entre os valores máximos e mínimos	
Reservoir_thickness	Espessura do reservatório incluindo zonas não produtoras de óleo (<i>net gross</i>)	
Pay_zone	Espessura da formação produtora, em pés (<i>net pay</i>)	
Dip	Ângulo de mergulho médio da formação	
°API	Intervalo numérico de °API do óleo do CP	
API_min	°API mínimo	
API_max	°API máximo	
API_avg	°API médio	
API_range	Diferença entre os valores máximos e mínimos	
Viscosity (cP)	Intervalo numérico de viscosidade do óleo do CP	
Viscos_cP_min	Viscosidade mínima	X
Viscos_cP_max	Viscosidade máxima	X
Viscos_cP_avg	Viscosidade média	X
Viscos_cP_range	Diferença entre os valores máximos e mínimos	
Oil_mobility	Mobilidade do óleo, obtida pela razão entre permeabilidade da formação e viscosidade do óleo	
Temperature (°F)	Intervalo numérico de temperatura do reservatório	
Temper_F_min	Temperatura mínima	
Temper_F_max	Temperatura máxima	
Temper_F_avg	Temperatura média	
Temper_F_range	Diferença entre os valores máximos e mínimos	
Compressibility	Compressibilidade da formação rochosa	
Dykstra Parsons	Indicação estatística do nível de heterogeneidade de uma formação rochosa. Quanto maior o seu valor, mais heterogênea tende a ser a rocha (EL-KHATIB, 2012; JENSEN, 1990)	
MMP MPa	Dado real de pressão mínima de miscibilidade, em Mpa, do fluido injetado com o óleo para o reservatório em questão.	
MMP Yellig MPa	Estimativa da pressão mínima de miscibilidade dada por YELLIG et al. (1980) e calculada para cada reservatório da base de dados a partir das informações disponíveis	
MMP Orr and Jensen MPa	Estimativa da pressão mínima de miscibilidade dada por ORR & JENSEN (1984) e calculada para cada reservatório da base de dados a partir das informações disponíveis	
Bubble_pressure_MPa	Pressão de bolha associada ao reservatório, em MPa	
Bo	Fator volume de formação do óleo	
Previous_Production	Método de produção prévia utilizada antes da aplicação de EOR	

Prev_prod_C	Produção prévia com injeção de Vapor cíclico	
Prev_prod_GI	Produção prévia com injeção de gás (<i>Gas injection</i>)	
Prev_prod_HC	Produção prévia com injeção de hidrocarbonetos	
Prev_prod_HW	Produção prévia com injeção de água quente (<i>hot water</i>)	
Prev_prod_None	Sem produção prévia	
Prev_prod_Prim	Produção prévia primária sem método adicional	
Prev_prod_Prim_GI	Produção prévia primária e injeção de gás	
Prev_prod_Prim_GI_WF	Produção prévia primária, injeção de gás e de água	
Prev_prod_Prim_WF	Produção prévia primária e de água	
Prev_prod_S	Produção prévia com injeção de vapor	
Prev_prod_SAGD	Produção prévia com injeção de vapor assistido pela gravidade (<i>Steam-assisted gravity drainage</i>)	
Prev_prod_SD	Produção prévia com injeção de vapor assistido	
Prev_prod_SF SD SS	Produção prévia com injeção de vapor, vapor assistido e <i>steam soak</i>	
Prev_prod_SS	Produção prévia com <i>steam soak</i>	
Prev_prod_WAG	Produção prévia com injeção alternada de água e gás	
Prev_prod_WF	Produção prévia com injeção de água	
Prev_prod_WF_GI	Produção prévia com injeção de água e de gás	
Oil_saturation_start	Intervalo de saturação inicial de óleo no reservatório	
Satur_start	Saturação inicial média no reservatório	
Oil_saturation_end	Intervalo de saturação final de óleo no reservatório	
Satur_end	Saturação final média no reservatório	
Geological_age	Idade geológica da formação rochosa do reservatório. Foi estabelecida para cada período geológico a idade aproximada em milhões de anos, seguindo a seguinte classificação: - Cenozóico: terciário (1.6 a 66) - Mesozoico: cretáceo (66 a 138), jurássico (138 a 205), triássico (205 a 240) - Paleozoico: permiano (240 a 290), pensilvânio (290 a 330), mississipiano (330 a 360), devoniano (360 a 410), siluriano (410 a 435)	
Displacement efficiency	Eficiência de deslocamento obtida via ("Satur_start" - "Satur_end")/"Satur_start"	
Project_maturity	Variável original referente à maturidade do projeto	
Proj_matur_C	Completo (<i>Completed</i>)	
Proj_matur_HF	Parcialmente completo (<i>Half finished</i>)	
Proj_matur_JS	Acabou de iniciar (<i>Just started</i>)	
Proj_matur_NC	Fase final (<i>Nearing completion</i>)	
Proj_matur_T	Finalizado (<i>Terminated</i>)	
Proj_matur_TS	Suspendido temporariamente (<i>Temporarily suspended</i>)	
Tot_prod_b_d	Produção diária média em barris logo antes da aplicação dos métodos de EOR	
Enh_prod_b_d	Produção diária média em barris durante o tempo de aplicação dos métodos de EOR	
Enh_percent	Porcentagem da produção mantida ou melhorada obtida via ("Enh_prod_b_d"-"Tot_prod_b_d")/Enh_prod_b_d	
Project_evaluation	Variável original referente à avaliação do projeto	

Proj_eval_Disc	Desencorajador (Discouraging)	
Proj_eval_Prom	Promissor (Promising)	
Proj_eval_Succ	Bem-sucedido (Successful)	
Proj_eval_TETT	Muito cedo para se determinar (Too early to tell)	
Project_Profit	Variável original referente à lucratividade do projeto	
Profit_Break_even	Receita - custos = lucro = nulo	
Profit_Good	Boa lucratividade	
Profit_Loss	Com prejuízo	
Profit_Yes	Projeto lucrativo	
Profit_Prom	Promissor de ser lucrativo	
Profit_TETT	Muito prematuro para se afirmar	
Profit_Pft	Projeto com lucro	
Project_scope	Variável original referente ao escopo do projeto	
Proj_scope_RW	Escala de reservatório	
Proj_scope_Exp L	Expansão provável	
Proj_scope_Exp UL	Expansão improvável	
Proj_scope_Field	Escala de campo	
Proj_scope_FW	Escala de campo (2)	
Proj_scope_LW Exp L	Escala de campo com expansão provável	
Proj_scope_P Exp L	Projeto piloto com expansão provável	
Proj_scope_P Exp UL	Projeto piloto com expansão improvável	
Proj_scope_Pilot	Projeto piloto, com provável expansão	
Nominal Oil Price USD	Valor nominal do preço do petróleo. O valor nominal é medido em termos de dinheiro da época, não sendo ajustado pela inflação.	
Real Brent Oil Price USD	Valor real do preço do petróleo. O valor real do preço do petróleo é medido em relação à valoração de bens e serviços. Dessa forma, é ajustado pela inflação, permitindo a comparação de valores em diferentes intervalos de tempo como se os preços dos bens e o poder aquisitivo da moeda não tivessem mudado em média. Os Preços Reais do Petróleo são calculados dividindo o preço nominal em um determinado mês pela razão do Índice de Preços ao Consumidor (IPC) naquele mês para o IPC em algum período "base". No caso, foi utilizado o IPC dos EUA. Consequentemente, todos os preços reais são expressos em dólares "atuais" e qualquer preço do ano atual pode ser comparado diretamente com quaisquer preços reais projetados ou passados. Dessa forma, o preço real do petróleo permite uma comparação mais justa entre projetos de EOR implementados em cenários políticos-econômicos distintos.	