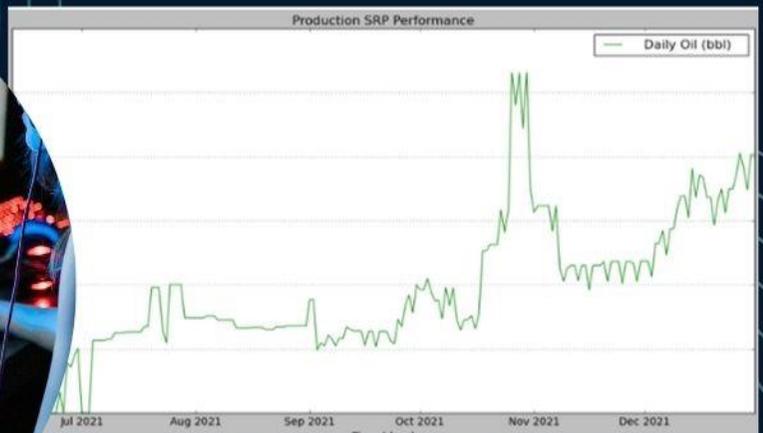




IMPLEMENTASI MACHINE LEARNING (DECISION TREE) DALAM PENENTUAN KANDIDAT REAKTIVASI IDLE WELL



PENULIS :
BONI SWADESI
HARIYADI
DAMAR NANDIWARDHANA
HERRY SOFYAN
NARAYA RAMADHANI PADALAS
GEOVANNY BRANCHINY IMASULY
EGA DIMAS SAPUTRA



LPPM UPN "VETERAN" YOGYAKARTA
TAHUN 2024



IMPLEMENTASI *MACHINE LEARNING (DECISION TREE)* DALAM PENENTUAN
KANDIDAT REAKTIVASI *IDLE WELL*

Penulis :

Boni Swadesi

Hariyadi

Damar Nandiwardhana

Herry Sofyan

Naraya Ramadhani Padalas

Geovanny Branchiny Imasuly

Ega Dimas Saputra

Editor : Naraya Ramadhani Padalas

Hak cipta dilindungi oleh undang-undang

Dilarang mengutip atau memperbanyak sebagian atau seluruh isi buku ini dalam bentuk apapun, baik secara elektronik maupun mekanis, termasuk memfotocopy, merekam, atau dengan sistem penyimpanan lainnya, tanpa izin tertulis dari Penulis

Desain Sampul dan Editing:

Penerbit LPPM UPN Veteran Yogyakarta

Cetakan Pertama, 2024

ISBN: 978-623-389-309-1



Diterbitkan oleh:

Penerbit LPPM UPN Veteran Yogyakarta

Jl. Padjajaran 104 (Lingkar Utara), Condongcatur, Yogyakarta, 55283

Telp. (0274) 486188,486733, Fax. (0274) 486400

Dicetak Oleh:

Lembaga Penelitian dan Pengabdian kepada Masyarakat, UPN Veteran Yogyakarta

Jl. Padjajaran 104 (Lingkar Utara), Condongcatur, Yogyakarta, 55283

Telp. (0274) 486188,486733, Fax. (0274) 486400

KATA PENGANTAR

Puji syukur kami panjatkan ke hadirat Allah SWT, yang telah memberikan rahmat dan hidayah-Nya sehingga kegiatan dengan buku Implementasi *Machine Learning (Decision Tree)* Dalam Penentuan Kandidat Reaktivasi *Idle Well* telah selesai dilaksanakan.

Buku ini ini disusun dalam rangka membantu kalangan akademik dan dunia industri dalam penentuan kandidat reaktivasi *idle well*. Tahapan pertama yang di lakukan adalah menetapkan masalah untuk pemahaman terhadap faktor-faktor yang mempengaruhi *idle well*, dan informasi tentang perkembangan terkini dalam memprediksi penentuan kandidat reaktivasi *idle well*. *Machine Learning (ML) (Decission Tree (DT))* untuk dapat mengatasi masalah akurasi dan kompleksitas data, serta membuat pola klasifikasi yang efisien dan akurat, maka dikembangkan *Web Application* yang dapat membantu pengambil keputusan dalam menentukan sumur mana yang harus direaktivasi yang dapat memberikan solusi terbaik untuk permasalahan peningkatan perolehan minyak.

Penulis menyadari masih banyak kekurangan dalam penulisan buku ini. Kekurangan yang ada akan menjadi cambuk untuk melaksanakan perbaikan dalam penulisan buku kegiatan yang lebih baik di masa yang akan datang. Semoga buku ini dapat memberikan manfaat bagi sivitsas akademika, dosen, mahasiswa dan masyarakat di masa sekarang maupun yang akan datang.

Hormat Kami,

Tim Penulis

DAFTAR ISI

| | Halaman |
|--|---------|
| KATA PENGANTAR | ii |
| DAFTAR ISI..... | iii |
| DAFTAR GAMBAR | v |
| BAB I PENDAHULUAN..... | 1 |
| BAB II SUMUR TUA | 5 |
| BAB III MEKANISME PRODUKSI AIR DAN GAS..... | 9 |
| 1. <i>CHAN'S DIAGNOSTIC PLOT</i> | 9 |
| 1.1 Reservoir Reserves..... | 10 |
| 1.2 Decline Curve Analysis | 11 |
| 1.3 Inflow Performance Relationship (IPR) | 14 |
| 1.4 Artificial Lift Methods..... | 16 |
| 2. <i>DRILLING METHOD</i> | 19 |
| 2.1 Completion | 19 |
| 2.2 Workover..... | 20 |
| 2.3 Penggantian <i>Zone</i> Produktif..... | 22 |
| 2.4 Stimulasi..... | 25 |
| 3. <i>FORECASTING METHODS</i> | 26 |
| 3.1 Qualitative Forecasting Methods..... | 26 |
| 3.2 Quantitative Forecasting Methods..... | 28 |
| 3.3 Time Series Methods..... | 29 |

| | | |
|--|--|----|
| 3.4 | Decomposition..... | 30 |
| 3.5 | Forecasting Error Accuracy..... | 30 |
| 3.6 | Preprocessing data..... | 31 |
| 3.7 | Postprocessing data | 31 |
| 4. | <i>ARTIFICIAL INTELLIGENCE, MACHINE LEARNING, AND DEEP LEARNING</i> | 35 |
| 4.1 | <i>Supervised Machine Learning</i> | 37 |
| 4.2 | Unsupervised Machine Learning..... | 38 |
| 4.3 | Semi-Supervised Machine Learning | 39 |
| 4.4 | Model Development with Decision Tree | 39 |
| 5. | <i>APPLICATION OF MACHINE LEARNING IN RESERVOIR & PRODUCTION ENGINEERING</i> | 41 |
| 5.1 | <i>Reservoir fluid properties</i> | 42 |
| 5.2 | <i>Rock properties</i> | 43 |
| 5.3 | <i>Enhanced oil recovery</i> | 44 |
| 5.4 | Well test analysis..... | 45 |
| 5.5 | <i>Formation damage</i> | 45 |
| 5.6 | <i>Asphaltene</i> | 46 |
| 5.7 | Production pipelines | 47 |
| BAB IV MACHINE LEARNING MODEL DEVELOPMENT (DECISION TREE)..... | | 49 |
| BAB V PENUTUP | | 62 |

DAFTAR GAMBAR

| | Halaman |
|---|---------|
| Gambar 4. 1 Removing unnecessary columns..... | 50 |
| Gambar 4. 2 Replace columns with empty data | 51 |
| Gambar 4. 3 Label Encoder | 51 |
| Gambar 4. 4 Min-Max-Scaler | 52 |
| Gambar 4. 5 Visualization Tree Reactivation Candidate..... | 54 |
| Gambar 4. 6 Result Tree | 56 |
| Gambar 4. 7 Performance Index illustration (accuracy, precision, recall, F1-score)..... | 56 |
| Gambar 4. 8 Performance Index illustration (confusion matrix) | 57 |
| Gambar 4. 9 Area Under Curve (AUC) | 58 |
| Gambar 4. 10 Receiver Operating Characteristic (ROC) | 59 |
| Gambar 4. 11 Water Chan Diagnostic | 60 |
| Gambar 4. 12 Well Production (Daily Oil (bbl) | 61 |

DAFTAR TABEL

| | Halaman |
|--|---------|
| Tabel 2. 1 Perbandingan <i>Multi Screening Method & Decision Trees</i> | 7 |

BAB I PENDAHULUAN

SKK Migas memiliki misi untuk mewujudkan produksi minyak sebesar 1 juta barel per hari pada tahun 2030 sesuai dengan laporan tahunan SKK Migas tahun 2022 dan menjadi tantangan bagi industri hulu migas di Indonesia (Retno L.P. Marsud 2021). Dalam mencapainya merupakan tantangan berat karena mengandalkan lapangan-lapangan tua atau *mature (brownfield)* yang mengupayakan eksploitasi hidrokarbon tersisa, daripada membuat sumur baru yang memerlukan investasi besar dalam pengeboran maupun fasilitas produksi, dan sering kali melibatkan ketidakpastian yang lebih besar dalam hal sumber daya (hidrokarbon) yang dapat ditemukan, maka dilakukan pengembangan riset dan inovasi yang berfokus pada produksi *Idle well (IW)* pada lapangan *mature* untuk peningkatan perolehan minyak dalam menunjang ketahanan energi nasional (Kemen. ESDM. 2020).

Salah satu lapangan *mature* yang ada di Indonesia dan di eksploitasi SKK Migas untuk mewujudkan misi 1 juta barrel minyak per hari tahun 2030 dan merupakan objek dalam penelitian ini adalah lapangan Cepu, namun kondisi saat ini memiliki kecenderungan penurunan produksi karena seiring dengan dilakukan kegiatan produksi migas pada lapangan tersebut (Putra.2022). Lapangan Cepu dalam metode produksinya menggunakan metode *artificial lift (sucker rod pump, electric submersible pump, dan natural)* dengan yang dominan yang sesuai dengan karakter lapangan tua pada lapangan ini yakni *Sucker Rod Pump (SRP)*. Lapangan Cepu memiliki banyak sumur yang tidak termanfaatkan atau disebut sebagai *Idle well (IW)*, yang disebabkan oleh permasalahan *high watercut (HWC)* dan terdapat 11 struktur aktif (780 sumur) dan 39 struktur Non-Aktif (566 Sumur).

Evaluasi *Idle well* (IW) dapat dilakukan dengan menggunakan metode *multi screening* untuk analisis *Chan Plot Diagnostic*, *production well history* dan *well integrity* secara *quantitative* berdasarkan *well history* dan *well diagram* salah satu lapangan yang sudah mencoba melakukan reaktivasi dan berjalan baik yaitu lapangan Sangasanga (Putra.2022). Selain itu dari penampang sumur dan sebaran sumur yang dapat memprediksi sumur-sumur mana memiliki potensi untuk dilakukan perawatan maupun reaktivasi dan sumur terpilih dilakukan reaktivasi sesuai dengan program yang telah disusun sebelumnya pada lapangan Cepu (Ardi, Swadesi, and Suhascaryo, 2022), dan hal ini juga dilakukan dalam penelitian (Alfarizi, Suhascaryo, and Swadesi 2023).

Penggunaan metode *multi screening* untuk evaluasi IW memiliki kekurangan, dalam hal akurasi penentuan kandidat reaktivasi dan kompleksitas data (data yang sangat besar dan sulit atau tidak mungkin untuk diproses menggunakan metode *multi screening*) untuk mengidentifikasi masalah penentuan kandidat reaktivasi *idle well* dengan tepat sehingga tingkat keberhasilan upaya pengolahannya rendah (Mukhanov, Garcia, and Torres 2018). Secara umum akar permasalahannya adalah ketidakkonsistenan penilaian manusia, serta tidak adanya kriteria dalam pola klasifikasi yang tepat (Mukhanov, Garcia, and Torres 2018), yang merupakan kunci dalam penentuan kandidat reaktivasi IW dalam interpretasi atau analisis produksi. Meskipun mengandalkan penilaian yang profesional dari manusia adalah hal yang umum, ada nilai yang signifikan dalam mengupayakan konsistensi dan mungkin sulit untuk membedakan dengan jelas (Garcia, Mukhanov, and Torres 2019), maka digunakan model algoritma *machine learning* untuk penelitian yakni *decision tree* dalam penentuan kandidat reaktivasi *idle well*, karena akurat dalam mengklasifikasi data untuk penentuan kandidat reaktivasi, dapat menangani data yang kompleks dengan baik, termasuk data yang *noise*

dan tidak lengkap, serta mampu membuat pola klasifikasi yang mudah dipahami dan diinterpretasikan berdasarkan atribut dalam data. Tahap selanjutnya, berdasarkan metode pemboran dengan *completion*, *workover*, *stimulation*, dan pengantian *zone* produktif (Haryanto. 2019), maupun desain pompa (*artificial lift*) dalam pekerjaan reaktivasi, karena akan bervariasi tergantung pada kondisi spesifik sumur, lokasi, dan karakteristik formasi.

Hal ini menunjukkan adanya peluang untuk peningkatan produksi dari pemanfaatan IW apabila dilaksanakan secara tepat dengan penerapan *Artificial Intelligence* (AI) (*Machine Learning* (ML) dengan model *Decision Tree* (DT)), ini melibatkan statistik dengan kecepatan dan skala tinggi untuk mempelajari pola dari kumpulan data dan unggul dalam memprediksi hasil, berbeda dengan rekayasa perangkat lunak konvensional, di mana aturan didefinisikan secara lebih eksplisit. (Garcia, Mukhanov, and Torres 2019), dan dimana Industri minyak dan gas sedang mengalami revolusi dalam istilah otomatisasi dan transformasi digital (Bizhani and Kuru 2022).

Salah satu penelitian oleh (Garcia, Mukhanov, and Torres 2019), dengan penerapan ML yakni “*Chan Plot Signature Identification as a Practical Machine Learning Classification Problem*”, yang dimodel dengan algoritma *supervised*, khususnya *Support Vector Machines* (SVM), untuk mengklasifikasikan dan membedakan pola *water control diagnostic* yang berbeda dengan hasil. Model SVM dipilih karena kemampuannya untuk mempelajari fungsi *nonlinear* dan efektifitasnya dalam masalah klasifikasi. Model lain yang termasuk *nearest neighbor*, *decision tree*, *random forest*, *logistic regression* dan *naïve Bayes*.

Penggunaan AI yakni ML dengan model dalam penelitian ini adalah DT dalam penentuan reaktivasi IW, yang dimana data historis tentang IW dan keputusan reaktivasi sebelumnya dikumpulkan dan disiapkan untuk pelatihan model. Variabel atau atribut yang relevan untuk penentuan reaktivasi dipilih

yang dapat mencakup parameter operasi, historis produksi, kondisi fisik, dan lainnya. Model DT dilatih dengan menggunakan data historis yang telah dipersiapkan dan akan mempelajari pola dalam data untuk memprediksi keputusan reaktivasi. Hasil prediksi dari model DT akan membantu mengambil keputusan dalam menentukan sumur mana yang harus direaktivasi yang dapat memberikan solusi terbaik untuk permasalahan peningkatan perolehan minyak dalam upaya eksploitasi hidrokarbon tersisa yang berfokus pada produksi IW, dengan salah satu penyebabnya adalah HWC pada lapangan Cepu. Model DT ini dapat digunakan untuk mengklasifikasikan sumur-sumur tersebut ke dalam berbagai kategori, seperti sumur yang layak direaktivasi, yang memerlukan perawatan, atau yang harus ditutup, sehingga dapat mengambil tindakan yang sesuai. Selain mencari penyebabnya, harus ada optimasinya dengan metode pemboran yang pernah di lakukan maupun desain pompanya.

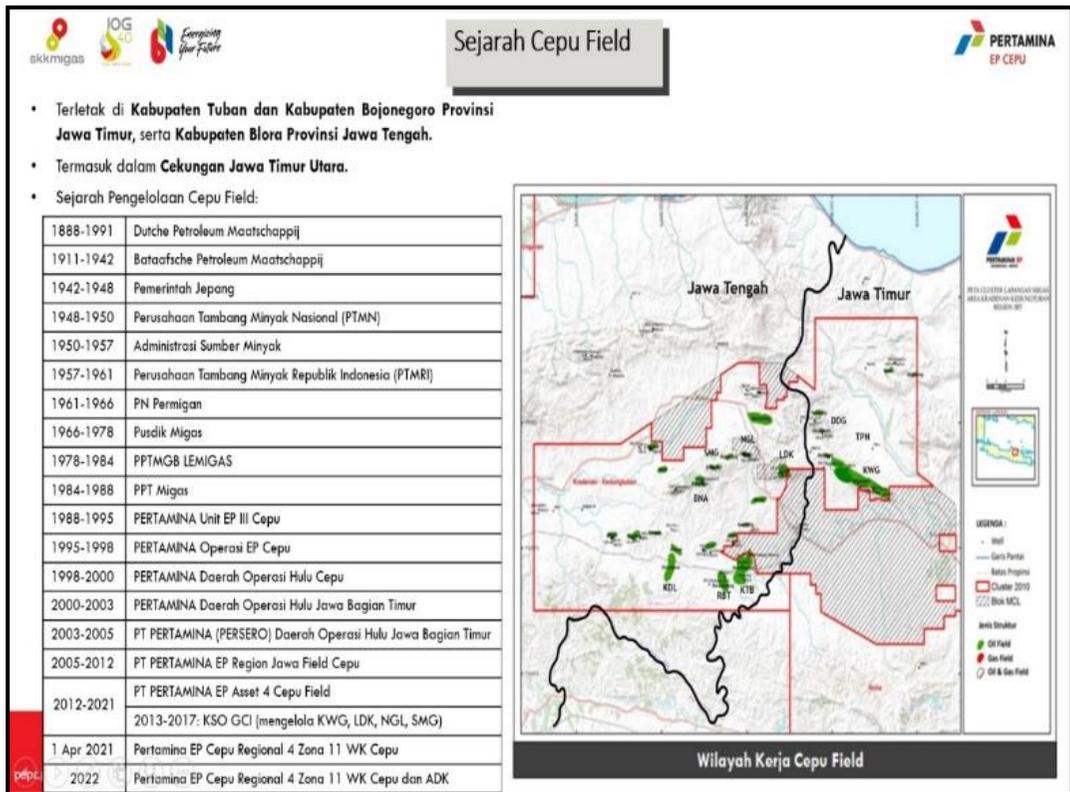
BAB II SUMUR TUA

Pendekatan *machine learning* menawarkan potensi besar dalam menangani berbagai tantangan yang dihadapi oleh industri ini, termasuk penurunan produksi dan peningkatan biaya operasional. Pemahaman terkait latar belakang dan tujuan dari penerapan teknologi ini, eksplorasi sejarah, karakteristik, dan tantangan unik harus dilakukan dalam pekerjaan sumur tua. Kondisi dan potensi sumur tua sangat penting untuk diketahui sebelum kita dapat menerapkan *machine learning* untuk menentukan kandidat reaktivasi yang tepat.

Cekungan-cekungan ini terbentuk sejak Awal Tersier berkaitan dengan penunjaman Lempeng Indo-Australia dibawah Lempeng Eurasia. Sejak itu pula terbentuk sebagai *foreland basin* atau *back-arc basin* (Hamilton, 1979) hingga kini. Secara fisiografi, Cekungan Rembang berupa antiklinorium yang dihasilkan dari inversi dan reaktivasi sesar-sesar lama. Hal ini menyebabkan terbentuknya perlipatan dan pensesaran. Pola struktur lipatan berarah timur laut – barat daya dan barat – timur. Sejak Eosen-Awal Oligosen transgresi dan penurunan cekungan berlangsung menyebabkan transgresi di zona ini, sehingga membentuk *isolated carbonate mound* di struktur tinggian (*high*).

Saat *rifting* Awal Miosen terjadi penggenangan sebagai hasil naiknya muka laut (Darman dan Sidi, 2000). Selanjutnya influks sedimen klastik, delta progradasi dari utara (Koesoemadinata dan Pulunggono, 1975). Miosen Akhir sampai Pliosen Tengah (7-3,6 jtl) mengalami kontraksi membentuk sesar naik (dari selatan) dan lipatan *en echelon* (barat – timur). Pliosen Akhir sampai Holosen (3,6-0 jtl) di selatan Zona Rembang (Zona Kendeng) dipengaruhi oleh sesar naik (utara) dan pengangkatan. Pengangkatan dibarengi dengan influks volkaniklastik dari *volcanic arc* ke utara (Soeparjadi

et al., 1975). Sejak pembentukan Zona Rembang, Lunt (1991) menyebut zona ini sebagai zona yang dipengaruhi oleh kompleksitas interplay antara proses struktur dan sedimentasi.



Gambar 2. 1 Sejarah Cepu Field

Permasalahan *idle well* antara lain terjadi penurunan volume produksi, peningkatan persentase *watercut* (Alfarizi, Suhascaryo, and Swadesi 2023), adanya *skin* pada sumur, pengelolaan sumur yang tidak tepat, penyemaman yang tidak merata yang dapat mengakibatkan *hold up* dan *channeling* di *casing* (Desyta, Kasmungin, and Wibowo 2018), terjadinya normal *displacement*, *multilayer channeling*, *rapid channeling* dan memberikan kebutuhan algoritma yang optimal untuk segmentasi dan deteksi beberapa *plot*

diagnostic (Garcia, Mukhanov, and Torres 2019) , mengevaluasi dan memilih sistem *artificial lift* (Erazo-Bone. 2022), mengembangkan model *decision tree* untuk mengidentifikasi dan mengkategorikan masalah ini secara akurat dan menunjukkan keefektifan pendekatan *model decision tree* dalam mendiagnosis dan mengklasifikasikan masalah (Bangert 2019), sehingga dapat memberikan strategi dan solusi yang diusulkan untuk mengelola kandidat *idle well*.

Tabel 2. 1 Perbandingan *Multi Screening Method & Decision Trees*

| <i>Criteria</i> | <i>Multi Screening</i> | <i>Decision Tree</i> |
|-------------------------------|--|--|
| Penentuan Kandidat Reaktivasi | Data historis yang sederhana dan mudah diolah secara manual. | Data historis yang kompleks, serta membuat model klasifikasi dengan tepat |
| Akurasi penentuan reaktivasi | Cenderung lebih rendah dengan teknik statistic dan analisis data manual. | Cenderung lebih tinggi dengan teknik machine learning. |
| Ketidakkonsistenan data | Lebih sensitif, karena data tidak akurat yang dapat menyebabkan <i>idle well</i> diklasifikasikan sebagai layak untuk direaktivasi, meskipun sebenarnya tidak. | Lebih tahan, karena mampu meningkatkan kualitas data dan mengurangi dampak Ketidakkonsistenan dalam menghasilkan prediksi yang akurat. |
| Kompleksitas data | Menggunakan data yang sederhana dan mudah diolah secara manual, karena sulit untuk | Menggunakan data yang kompleks dan beragam, sehingga menghasilkan prediksi yang lebih akurat |

| <i>Criteria</i> | <i>Multi Screening</i> | <i>Decision Tree</i> |
|--|--|--|
| | memahami hubungan antara parameter dan tidak akurat untuk penentuan kandidat reaktivasi <i>idle well</i> dengan kondisi yang kompleks. | untuk penentuan kandidat reaktivasi <i>idle well</i> dengan kondisi yang kompleks. |
| Kemampuan mempelajari pola dan tren | Tidak, karena keputusan reaktivasi <i>idle well</i> didasarkan pada penilaian manusia. | Ya, karena keputusan reaktivasi <i>idle well</i> didasarkan pada data dan analisis yang kuat. |
| Rentan terhadap bias dan kesalahan manusia | Ya, memerlukan interpretasi hasil oleh manusia. | Tidak, mampu membuat prediksi berdasarkan data dan bukan interpretasi manusia |
| keuntungan | Cepat, efisien, relative murah berdasarkan pengetahuan dan pengalaman. | Lebih akurat dan mampu menangkap hubungan kompleks dalam data dengan pengetahuan machine learning. |
| Kekurangan | Kurang Optimal | Optimal |

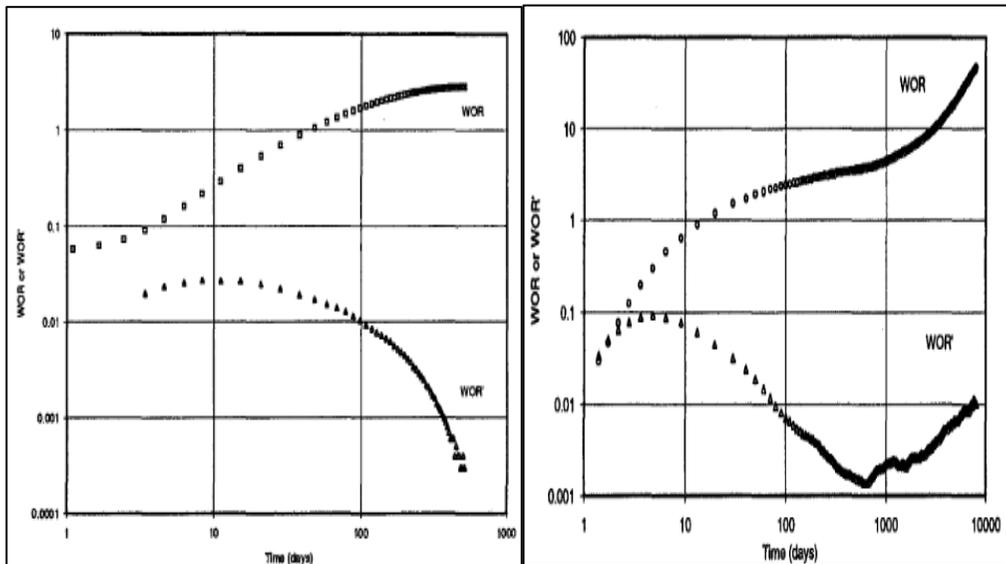
BAB III MEKANISME PRODUKSI AIR DAN GAS

Eksplorasi sejarah dan tantangan yang dihadapi oleh sumur tua, termasuk permasalahan penurunan volume produksi dan peningkatan persentase *watercut* telah dilakukan. Pengetahuan tentang kondisi sumur tua ini sangat penting untuk mengidentifikasi potensi sumur *idle* yang layak untuk direaktivasi. Melanjutkan ke bab ini, kita akan fokus pada mekanisme produksi air dan gas, yang merupakan salah satu faktor kunci dalam menentukan efektivitas reaktivasi sumur. Dengan memahami metode diagnostik seperti Chan's Diagnostic Plot dan teknik-teknik analisis lainnya, kita dapat mengidentifikasi masalah produksi air dan gas yang berlebihan serta mengambil langkah-langkah korektif yang diperlukan. Metode diagnostik tersebut :

1. *CHAN'S DIAGNOSTIC PLOT*

Metode Chan merupakan metode untuk mengetahui mekanisme produksi air dan gas yang berlebih pada sumur produksi, dengan menghubungkan *plot log* dari *WOR (Water Oil Ratio) versus time* atau *GOR (Gas Oil Ratio) versus time*, dan dari hubungan ini akan mendapatkan karakteristik tren yang berbeda untuk mekanisme yang berbeda. Sebelum menganalisa *diagnostic plots*, diperlukan beberapa data untuk membuat plot antara lain:

1. *Data Actual* dari sejarah produksi sumur, baik air, gas atau minyak
2. *WOR (Water Oil Ratio)* dan *WOR Derivatives*
3. Produktif Minyak Kumulatif atau efisiensi *recovery*
4. Laju penurunan minyak dan gas



Gambar 3. 1 *Indication of Water Coning and Channeling (Chan 1995)*

Sering berjalannya waktu, *Plot Log WOR* dapat mengidentifikasi trend produksi dan permasalahan dalam mekanisme produksi. *Log Plots WOR Derivatives* digunakan untuk membandingkan permasalahan produksi air yang berlebihan, baik *water coning*, *multilayer channeling* atau permasalahan lainnya, dan untuk mengetahui permasalahan *water coning* atau *channeling*. Nilai dari tahapan *WOR*, kecuali *WOR derivatives* yang mempunyai perubahan positif (ke atas) yang konstan dan lambat, *WOR derivatives* yang dihasilkan oleh *coning* menunjukkan nilai yang menurun, sedangkan *WOR* dan *WOR derivatives* untuk *channeling* tetap pada tahap awal sampai perubahan yang signifikan ke arah yang positif.

1.1 Reservoir Reserves

Dalam pengembangan dan eksploitasi suatu lapangan minyak, ada beberapa tahapan yang perlu dipertimbangkan. Salah satu aspek penting yang sering dipertanyakan adalah jumlah keseluruhan atau total

hidrokarbon yang dapat diproduksi di permukaan. Hal ini memerlukan pemahaman tentang cadangan reservoir. Cadangan mempunyai pengertian yang bermacam-macam, dan ada beberapa istilah yang dikaitkan dengan pengertiannya, seperti:

Cadangan minyak dan gas awal, yang mencakup hidrokarbon yang dapat diproduksi dan tidak dapat diproduksi, mengacu pada total volume hidrokarbon yang ada di reservoir.

a) *Initial oil/gas in place*, yang mencakup hidrokarbon yang dapat diproduksi dan tidak dapat diproduksi, mengacu pada total volume hidrokarbon yang ada di reservoir.

$$OOIP = 7758 \times \frac{V_b \times \phi \times (1 - S_{wi})}{B_{oi}}$$

b) *Recovery factor*, mengacu pada perbandingan antara hidrokarbon yang dapat diperoleh atau diproduksi (*recoverable reserve*) terhadap jumlah minyak awal di reservoir.

$$E_d = 41,815 \left(\frac{\phi (1 - S_{wi})}{B_{ab}} \right) 0,1611 \left(\frac{k}{\mu_{ab}} \right) 0,0979 (S_{wi})^{0,3722} \left(\frac{P_b}{P_a} \right)^{0,1741}$$

c) *Ultimate recovery*, yaitu jumlah hidrokarbon yang dapat diproduksi sampai batas ekonomisnya.

d) *Recoverable reserve*, yaitu jumlah cadangan hidrokarbon yang mungkin dapat diproduksi dengan teknologi yang ada pada saat itu.

1.2 Decline Curve Analysis

Decline curve adalah salah satu bentuk analisis data yang paling banyak digunakan ketika mengevaluasi cadangan dan memprediksi produksi di masa depan. Teknik *decline curve analysis* didasarkan pada asumsi bahwa tren produksi di masa lalu dan faktor-faktor pengendalinya akan terus berlanjut di masa depan, sehingga dapat diekstrapolasi dan dijelaskan dengan matematis.

Metode ekstrapolasi "tren" yang digunakan untuk memperkirakan kinerja di masa depan harus memenuhi persyaratan bahwa faktor-faktor yang menyebabkan perubahan kinerja di masa lalu (penurunan laju aliran), akan berperilaku sama di masa depan. *decline curve* ini ditandai oleh tiga faktor:

- a) *Initial production rate*, atau *rate* pada waktu tertentu
- b) *Curvature of the decline*
- c) *Rate of decline*

Arps (1945) mengusulkan bahwa "*curvature*" dalam *production rate versus time curve* dapat dinyatakan secara matematis oleh persamaan hiperbolik. Arps mengenali tiga jenis perilaku *rate-decline* berikut:

- a) *Exponential decline*: Hubungan garis lurus akan terjadi ketika *flow rate versus time* yang diplot pada skala *semi log* dan juga ketika *low rate versus cumulative production* diplot pada skala *Cartesian*.
- b) *Harmonic decline*: *Rate versus cumulative production* adalah garis lurus pada skala *semi log*. semua jenis *decline curve* lainnya memiliki beberapa kelengkungan. Ada beberapa teknik pergeseran yang dirancang untuk meluruskan kurva yang dihasilkan dari memplot *flow rate versus time* pada skala *log-log*.
- c) *Hyperbolic decline*: Tak satu pun dari skala *plotting* di atas, yaitu *Cartesian*, *semi log*, atau *log-log*, akan menghasilkan hubungan garis lurus untuk penurunan *hyperbolic decline*. Namun, jika *flow rate* diplot terhadap waktu pada kertas *log-log*, kurva yang dihasilkan dapat diluruskan dengan Teknik menggeser (*shifting*).

| Case | b | Rate-Time Relationship |
|-------------|-------------|--|
| Exponential | b = 0 | $q_t = q_i \exp(-D_i t)$ |
| Hyperbolic | $0 < b < 1$ | $q_t = \frac{q_i}{(1 + bD_i t)^{1/b}}$ |
| Harmonic | b = 1 | $q_t = \frac{q_i}{(1 + D_i t)}$ |

Gambar 3. 2 Decline Curve Type (Ahmed 2010)

dimana

q_t = flow rate at time t , MMscf/day

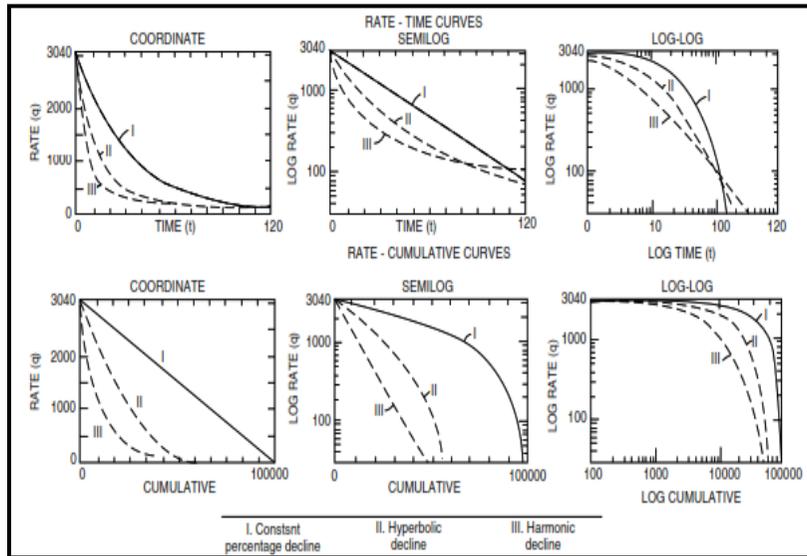
q_i = initial flow rate, MMscf/day

t = time, days

D_i = initial decline rate, day^{-1}

b = Arps' decline-curve exponent

Setiap jenis *decline curve* memiliki kelengkungan (*curvature*) yang berbeda, karakteristik dari setiap jenis *decline*, ketika *flow rate* diplot terhadap waktu atau terhadap produksi kumulatif pada skala *Cartesian*, *semi log*, dan *log-log*. Karakteristik utama dari *decline curve* ini dapat digunakan untuk memilih model *flow rate decline* yang sesuai untuk menggambarkan *rate time relationship* dari sistem hidrokarbon.



Gambar 3. 3 Classification of production decline curves (Ahmed 2010)

1.3 Inflow Performance Relationship (IPR)

IPR digunakan untuk mengevaluasi kemampuan reservoir dalam produksi. Kurva IPR adalah grafik hubungan antara *flowing bottom-hole pressure* dan *production rate*. Besarnya kemiringan kurva IPR disebut "indeks produktivitas" (PI atau J), yaitu, di mana J adalah indeks produktivitas. Rupanya J tidak konstan di daerah aliran dua fasa.

Kurva IPR sumur biasanya dibuat menggunakan model aliran masuk reservoir, yang bisa dari landasan teoretis maupun landasan empiris. Sangat penting untuk memvalidasi model ini dengan aplikasi lapangan.

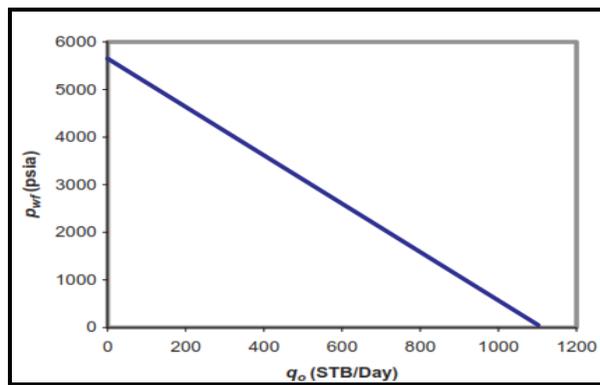
$$J = \frac{q}{(P_e - P_{wf})}$$

a) IPR Single-Phase Reservoir

Semua model reservoir inflow minyak yang disajikan pada bagian sebelumnya diturunkan berdasarkan asumsi *single-phase flow*. Asumsi ini berlaku untuk reservoir minyak dengan *undersaturated*, atau bagian reservoir yang tekanannya di atas tekanan titik gelembung (*Bubble point*). Persamaan ini mendefinisikan indeks produktivitas (J) untuk *flowing bottom-hole pressure* di *bubble-point pressure* sebagai berikut:

$$J^* = \frac{q}{(p_i - p_{wf})}$$

$$= \frac{kh}{162,6B_o\mu_o \left(\log t + \log \frac{k}{\phi\mu_o C_t r_w^2} - 3,23 + 0,87S \right)}$$



Gambar 3. 4 Under-Saturated Condition IPR Graph (Guo, Liu, and Tan 2017)

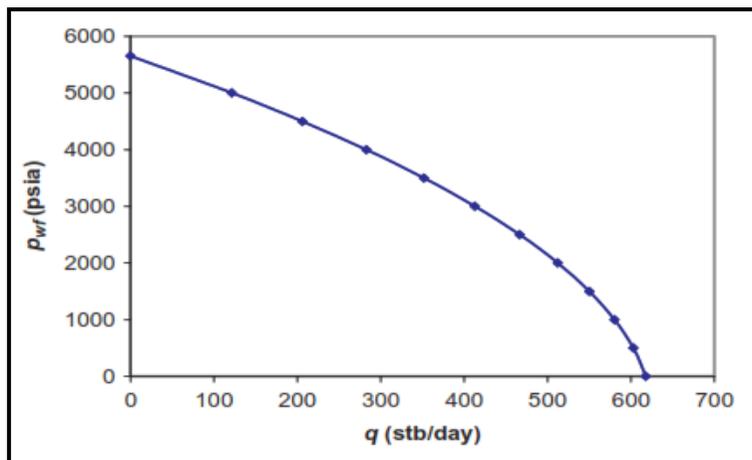
b) IPR Two-Phase Reservoir

Nilai tekanan di bawah tekanan bubblepoint sesuai dengan model IPR linier yang disajikan pada bagian sebelumnya. Gas larutan keluar dari minyak di bawah tekanan titik gelembung dan menjadi gas bebas. Gas bebas menempati sebagian ruang pori, mengurangi aliran minyak. Dengan mengurangi permeabilitas relatif, efek ini dapat diukur. Selain itu, viskositas minyak meningkat seiring penurunan kandungan gas larutan.

Pada tekanan lubang bawah tertentu, kombinasi efek permeabilitas relatif dan viskositas menghasilkan laju produksi minyak yang lebih rendah. Kurva IPR menyimpang dari tren linier di bawah tekanan titik balon. Berkurangnya tekanan meningkatkan penyimpangan. Jika tekanan reservoir lebih besar dari tekanan titik gelembung awal, reservoir disebut "reservoir dua fase".

Memodelkan IPR reservoir dua fase, satu-satunya persamaan yang tersedia adalah persamaan empiris. Persamaan empiris termasuk persamaan Vogel (1968) yang diperluas oleh Standing (1971), persamaan Fetkovich (1973), persamaan Bandakhlia dan Aziz (1989), persamaan Chang (1992), dan persamaan Retnanto dan Economides (1998). Industri masih menggunakan persamaan Vogel. Itu ditulis sebagai berikut:

$$q = q_{max} \left[1 - 0.2 \left(\frac{p_{wf}}{\bar{p}} \right) - 0.8 \left(\frac{p_{wf}}{\bar{p}} \right)^2 \right]$$



Gambar 3. 5 Saturated Condition IPR Graph (Guo, Liu, and Tan 2017)

1.4 Artificial Lift Methods

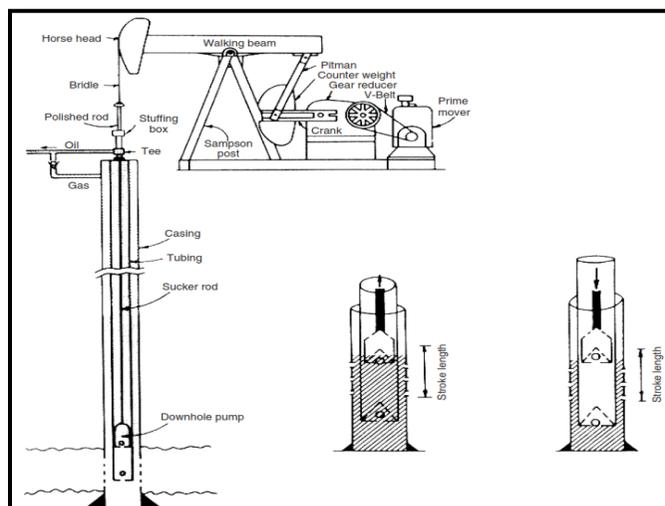
Selama berlangsungnya produksi tekanan reservoir akan mengalami penurunan. Bila pada suatu saat tekanan reservoir sudah tidak

mampu lagi untuk mengalirkan minyak sampai permukaan atau laju aliran yang dihasilkan sudah sangat tidak ekonomis lagi, maka untuk mengangkat minyak dari dasar sumur digunakan cara yang disebut pengangkatan buatan atau *artificial lift* dan yang umum digunakan meliputi:

a. Pompa Angguk (*Sucker Rod Pump*)

Sucker Rod Pump (Pompa Angguk) adalah merupakan salah satu metode pengangkatan buatan yang banyak digunakan saat ini, dimana untuk mengangkat minyak dari dalam sumur ke permukaan digunakan pompa dengan *rod* (tangkai pompa).

Pompa angguk banyak digunakan di lapangan minyak dan dipakai untuk sumur-sumur lurus dan vertikal. Pompa angguk (*sucker rod*) sangat dikenal di lapangan karena terhadap fluktuasi laju aliran produksi, tidak mudah rusak, mudah diperbaiki, biaya operasi dan biaya perawatan relatif lebih murah.

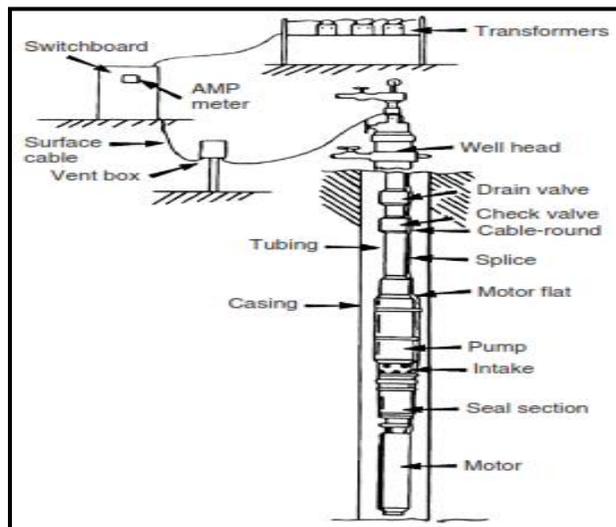


Gambar 3. 6 *Sucker rod pump system diagram* (Golan and Whitson, 1991), (Guo, Boyun; Lyons, William; Ghaleb 2007)

b. *Electrical Submersible Pump (ESP)*

Electric Submersible Pump (ESP) adalah pompa yang dimasukkan ke dalam lubang sumur yang digunakan untuk memproduksi minyak secara artificial lift (pengangkatan buatan) dan digerakkan oleh motor listrik. Peralatan pompa Listrik submersible terdiri dari *pump sentrifugal*, *protector* dan motor listrik. Unit ini ditenggelamkan di cairan, disambung dengan tubing dan motornya dihubungkan dengan kabel ke permukaan yaitu dengan switchboard dan transformator. Pompa ESP terdiri dari pompa sentrifugal bertingkat banyak berputar 3,475 – 3,500 RPM, 60 Hz dengan motor listrik induksi sinkron kutub 3 fase, berbentuk sangkar.

Pompa ESP biasanya dipakai untuk laju produksi 200 – 2,500 STB/day, walaupun dapat digunakan untuk produksi sampai 95,000 STB/day. Pompa ESP umumnya digunakan pada sumur miring di daerah lepas pantai. Di daratan hanya digunakan untuk laju produksi tinggi yaitu di atas 2,000 STB/day, karena pompa anggur akan lebih ekonomis untuk sumur dengan laju produksi rendah.



Gambar 3. 7 Instalasi Electric Submersible Pump (Centriflift-Hughes, Inc., 1998). (Guo, Boyun; Lyons, William; Ghalambor 2007)

2. DRILLING METHOD

2.1 Completion

Setelah sumur dibor, langkah selanjutnya adalah menyempurnakan sumur (kompleksi) untuk memungkinkan fluida mengalir ke permukaan. Jenis kompleksi sumur ini memiliki banyak pilihan, tergantung pada beberapa factor (Rubiandini 2009), diantaranya adalah :

- a. Biaya
- b. Diperlukannya *well stimulation*
- c. Masalah produksi khusus, seperti *sand control* atau *artificial lift*
- d. Jenis pendorong reservoir
- e. Lokasi batas gas-minyak dan air-minyak
- f. Kemungkinan dilaksanakannya *secondary recovery* dimasa yang akan datang

Metoda *well completion* terbagi atas dua bagian utama yaitu *bottom hole completion* dan *tubing completion*. *Bottom hole completion* dapat dilakukan secara

uncased hole completion (tanpa penahan) atau secara *cased hole completion* (dengan penahan) yang diperforasi. Pada *tubing completion* diusahakan agar mampu mengangkat fluida yang telah berada dalam lubang sumur ke permukaan dengan semaksimal mungkin.

Kemungkinan penggunaan *secondary recovery* di masa mendatang Metode *well completion* terdiri dari dua komponen utama yakni, *bottom hole completion* dan *tubing completion*. *Bottom hole completion* dapat dilakukan secara *uncased hole completion* atau secara *cased hole completion* yang diperforasi.

2.2 *Workover*

Well service operation adalah pekerjaan rutin yang harus dilakukan selama sumur berproduksi, yang berfungsi untuk memperbaiki atau meningkatkan produktivitas sumur, sedangkan *workover* adalah pekerjaan perbaikan yang dikategorikan cukup berat (Rubiandini 2009).

Terdapat beberapa perbaikan sumur yang mendasar, yang biasanya dilakukan oleh *service company*, yang bertujuan untuk memperbaiki atau memperbaharui serta memperpanjang umur sumur berproduksi, dapat dibedakan menjadi:

a. Operasi *Swabbing*

Swabbing adalah proses pengeluaran fluida yang terakumulasi di dasar sumur yang disebabkan oleh sumur berhenti mengalir secara alami. Kejadian ini terjadi disebabkan bila tekanan formasi tidak cukup untuk mengangkat kolom fluida yang terakumulasi di dasar sumur ke permukaan.

b. *Sand Control dan Sand Clean-Out*

Penurunan produktivitas sumur dapat disebabkan oleh beberapa hal yaitu :

- kondisi reservoir
- kondisi produksi
- proses penyumbatan pada tubing
- lubang bor dan perforasinya
- kerusakan mekanis

Plugging/penyumbatan pada tubing, lubang bor dan perforasinya dapat disebabkan oleh:

- pasir
- partikel-partikel formasi termasuk batuanannya
- partikel-partikel lumpur

- endapan parafin
- *aspalt scale*
- *collapse* pada *tubing/casing*.

Terproduksinya pasir dalam sumur dapat menimbulkan bermacam-macam masalah, diantaranya yaitu:

- Kerusakan peralatan dan fasilitas produksi
- Peyumbatan aliran fluida produksi dalam pipa alir
- Masalah-masalah lain yang sangat mengganggu produktivitas sumur hal-hal yang perlu dipertimbangkan sebelum melakukan kerja ulang (*workover*) karena adanya masalah pasir, adalah:

c. *Gravel Pack*

Gravel pack merupakan *workover* yang terbaik untuk *single completion* dengan *zone* produksi yang panjang. Pelaksanaanya adalah sebagai berikut:

1. Pembersihan perforasi dengan clean fluid sebelum *gravel pack* dipasang.
2. Penentuan ukuran *gravel pack* sesuai dengan ukuran butiran pasir formasi.
3. *Squeeze gravel pack* ke dalam lubang perforasi, digunakan *water wet gravel* jika digunakan *oil placement fluid*.
4. Produksikan sumur dengan segera setelah *packing*, aliran produksi dimulai dengan laju produksi rendah kemudian dilanjutkan dengan kenaikan laju produksi sedikit demi sedikit.
5. Metoda ini merupakan metoda pengontrolan pasir yang paling sederhana dan paling tua umurnya. Pada prinsipnya, adalah *gravel* yang ditempatkan.

d. *Sand Consolidation*

Sand consolidation dengan menggunakan material plastik. Pemilihan metoda ini cocok untuk *zone* produksi yang pendek. Cara pelaksanaannya adalah sebagai berikut:

1. *Clean fluid* secara *uniform*
2. Menginjeksikan material plastik ke *zone* produktif
3. Membersihkan pasir yang kotor dengan *HF acid-mutual solvent*
Merupakan teknik dengan menginjeksikan resin ke dalam formasi, dimana resin tersebut diharapkan mengikat butir pasir, sehingga berfungsi sebagai material penyemen.

e. *Resin Coated Gravelpack*

Injeksi dengan menggunakan *plastic coated sand* dan *viscous placement fluid*, biasanya metoda ini dipakai pada *zone* yang panjangnya medium, dimana pasir telah diproduksi dan memperlihatkan gejala *caving*. Metoda yang digunakan adalah “*sand lock*”, yaitu dengan memasukkan resin pembungkus gravel ke dalam formasi. Resin disini akan membentuk jaringan batu pasir sintetis yang sangat permeabel.

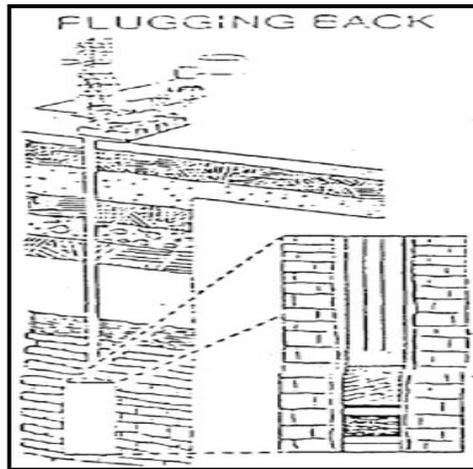
2.3 Penggantian Zone Produktif

Dengan berjalannya waktu produksi sumur maka formasi/reservoir akan mengalami penurunan produksi. Penurunan produksi ini dapat disebabkan oleh karena tidak tepatnya desain peralatan atau formasi tersebut cadangannya sudah habis (Rubiandini 2009).

Apabila cadangan suatu formasi sudah berkurang, maka perlu melakukan perubahan *zone* produksi. Hal ini dapat dilakukan dengan menggunakan beberapa metoda antara lain :

1. *Plugging Back*

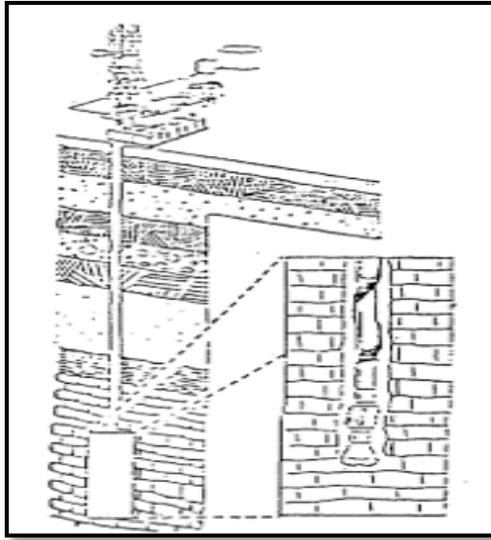
Plugging back adalah prosedur umum yang dilakukan untuk menutup *zone* produksi yang paling terbawah, sehingga tidak terjadi proses aliran antar *zone* atau merupakan persiapan untuk melakukan *side tracking*.



Gambar 3. 8 *Plugging Back* (Rubiandini 2009)

2. *Drilling Deeper*

Drilling deeper adalah prosedur *workover* yang biasa dilakukan untuk membor formasi yang mungkin mengandung minyak yang berada dibawah *zone* produksi terbawah sumur tersebut. Prosedurnya biasa memerlukan operasi *squeezing* dari lubang perforasi yang ada. Operasi pemboran dilakukan untuk mencapai *zone* berikutnya.



Gambar 3. 9 *Drilling Deeper* (Rubiandini 2009)

3. *Sidetracking*

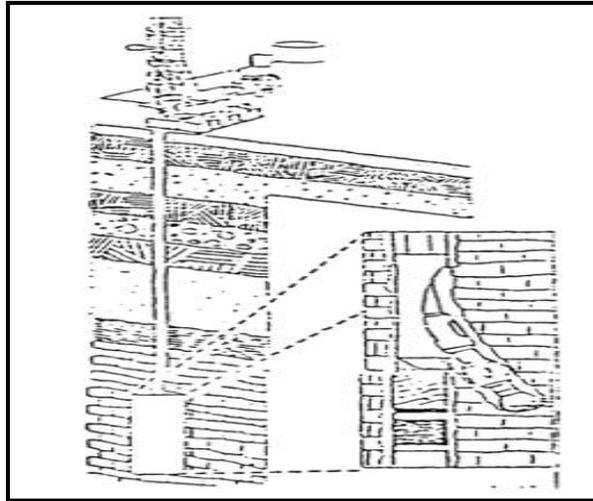
Sidetracking adalah operasi *workover* dengan menggunakan prinsip-prinsip pemboran berarah. *Sidetracking* dilakukan untuk mengganti *zone* produksi atau relokasi *zone* produksi. Tujuan dilakukan *sidetracking* adalah sebagai berikut:

- a. Adanya peralatan yang tidak terambil selama pemboran
- b. Untuk menghindari *zone -zone* yang dapat membahayakan pemboran
- c. Relokasi lubang bor untuk mencapai daerah pengurasan yang lebih baik.

Drilling deeper dan *sidetracking* memerlukan peralatan-peralatan berat untuk mendukung pelaksanaan operasi tersebut seperti:

- a. *Heavy duty production rig*
- b. *Circulating equipment*
- c. *Additional power*

Untuk sumur dengan tekan tinggi, harus didukung dengan BOP.



Gambar 3. 10 Sidetrack Drilling (Rubiandini 2009)

2.4 Stimulasi

Proses perbaikan formasi di sekitar lubang sumur untuk meningkatkan kapasitas produksinya dikenal sebagai stimulasi (Rubiandini 2009). Stimulasi dapat berupa:

- a. *Acidizing*
- b. *Acidizing-Fracturing*

Acidizing fracturing hampir sama dengan acidizing ini dilakukan dengan menginjeksikan fluida (cair) ke formasi di bawah kondisi bertekanan sehingga formasi dapat meretakkan di sekitar lubang bor.

- c. *Hydraulic Fracturing*

d. Proses peretakan formasi dengan menginjeksikan fluida (cair) ke formasi dibawah kondisi bertekanan sehingga dapat meretakan formasi disekitar lubang bor. Biasanya dalam fluida dicampur dengan material pengganjal, sehingga pada saat tekanan peretakan diturunkan maka formasi yang sudah retak tidak tertutup lagi. *Hydraulic Fracturing* merupakan fluida peretak yang dapat membawa pengganjal masuk ke rekahan, tetapi tidak membawanya lagi ke luar, disebut *breaker*. Tujuan dari stimulasi

adalah untuk meningkatkan *productivity* dengan meningkatkan permeabilitas sumur, baik dengan menghilangkan *scale* disekitar rekah-rekahan atau memperpanjang rekahan disekitar lubang bor.

3. **FORECASTING METHODS**

Peramalan adalah upaya untuk memprediksi peristiwa di masa depan. Peramalan adalah langkah pertama dalam proses pengambilan keputusan. Tujuan dari prediksi adalah berpikir tentang apa yang mungkin terjadi. Permintaan suatu produk di masa depan, misalnya. Pada dasarnya, prediksi hanyalah perkiraan. Namun, peramalan lebih dari sekedar perkiraan ketika dilakukan dengan teknik peramalan yang tepat, dengan menggunakan *standar deviasi absolut*, *mean square error*, dan *mean absolute persentase error* (Iswahyudi 2016).

3.1 **Qualitative Forecasting Methods**

Secara umum, metode peramalan kualitatif tidak objektif dan dipengaruhi oleh pendidikan, pengalaman, dan emosi, maupun hasil dari setiap prediksi dapat berbeda. Model statistik juga dapat digunakan dalam pengambilan keputusan saat peramalan menggunakan metode kualitatif untuk prediksi (Iswahyudi 2016). Beberapa metode peramalan kualitatif antara lain:

a) *Delphi Method*

Metode Delphi pertama kali dikembangkan oleh *Rand Corporation* pada tahun 1950-an. Langkah-langkah dalam metode *delphi* sebagai berikut:

1. Menentukan berapa jumlah pakar sebagai partisipan.
2. Memperoleh prediksi dari seluruh pakar melalui kuesioner
3. Ringkasan hasil dan membagikan dengan kepada partisipan dengan pertanyaan yang baru.

4. Ringkasan revisi peramalan dan kembangkan dengan pertanyaan baru.
5. Langkah 4 dapat diulang jika perlu.
6. Semua hasil akhir akan dibagikan kepada semua peserta.

b) Market Research

Teknik peramalan yang didasarkan pada temuan penelitian yang dilakukan oleh tenaga pemasar produk atau pihak marketing. Ini dapat digunakan untuk membuat produk baru atau meningkatkan desain produk yang sudah ada.

c) Management Estimate

Teknik peramalan yang didasarkan pada pemikiran manajer senior. Situasi di mana intuisi dari sekelompok kecil individu yang memiliki pengalaman yang cukup untuk memberikan pendapat kritis dan relevan sangat sensitif terhadap metode ini.

d) Historical Analogy

Metode peramalan yang didasarkan pada model data sebelumnya. Metode terbaik untuk mengganti produk di pasar ketika ada pengganti langsung adalah analogi historis.

e) Structured Group Methods

Metode kluster terstruktur adalah metode peramalan yang bergantung pada interaksi ahli. Para ahli atau kelompok biasanya tidak bertemu secara langsung; sebaliknya, mereka memberikan pendapat mereka secara terpisah, tanpa berbicara dengan satu sama lain. Ini disebabkan oleh kemungkinan pengaruh antar anggota kelompok dapat menyebabkan pendapat yang bias, serta mendapatkan angka estimasi yang konsisten, orang yang bersangkutan menerima umpan balik yang sangat berbeda dari para ahli lainnya.

3.2 *Quantitative Forecasting Methods*

Metode peramalan kuantitatif dibedakan menjadi dua bagian, yaitu sebagai berikut:

- a) Suatu metode peramalan yang didasarkan pada penggunaan pola asosiasi antara suatu variabel ramalan dengan deret waktu atau *time series*.
- b) Metode peramalan berdasarkan model analisis hubungan antara variabel peramalan dan variabel lain yang mempengaruhinya, kecuali waktu, disebut kausal.
- c) Metode Kausal

Tujuan utama metode kausal adalah untuk menghipotesiskan komponen yang diduga menunjukkan hubungan kausal dengan salah satu atau lebih variabel bebas; tujuan utama metode ini adalah untuk menemukan pola hubungan antara variabel independen dan menggunakan pola ini untuk memprediksi nilai variabel dependen. Ada banyak cara berbeda untuk menggunakan teknik kausalitas, seperti:

1. Metode regresi dan korelasi

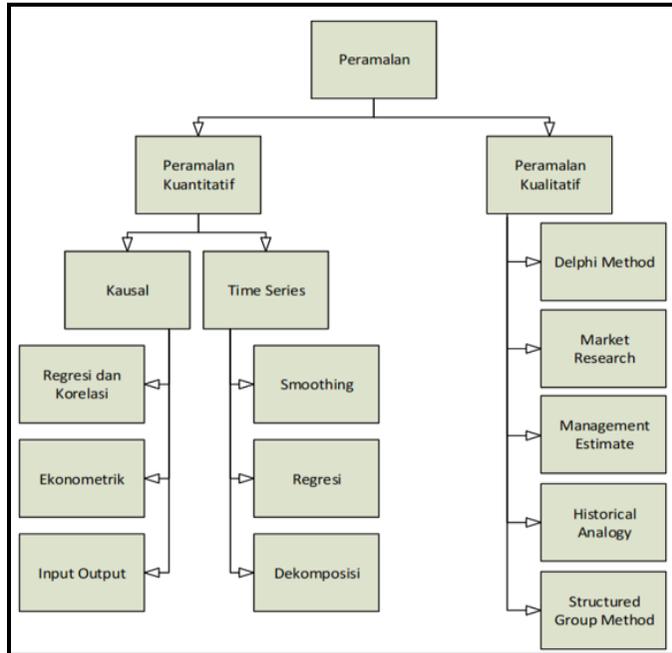
Metode ini biasanya digunakan untuk meramalkan hal-hal seperti penjualan, laba, situasi keuangan, permintaan, dan sebagainya. Ini membutuhkan data triwulanan dari beberapa tahun sebelumnya.

2. Metode Ekonometrik

Metode ini bergantung pada prediksi sistem persamaan regresi yang diestimasi secara bersamaan.

3. Metode *Input – Output*

Metode ini digunakan untuk meramalkan tren ekonomi jangka panjang; ini sering digunakan untuk meramalkan penjualan untuk sektor dan subsektor industri, dan membutuhkan data dari sepuluh hingga lima belas tahun yang lalu.



Gambar 3. 11 Forecasting Methods (Iswahyudi 2016)

3.3 Time Series Methods

Metode *Time Series* merupakan analisis sekumpulan data yang memiliki fungsi waktu. Metode ini mengasumsikan pola yang berulang dari waktu ke waktu. Analisis deret waktu dapat digunakan untuk menunjukkan bagaimana jumlah untuk produk tertentu berubah dari waktu ke waktu. Perubahan sesekali dalam data digunakan untuk memprediksi kebutuhan analisa informasi di masa depan (Iswahyudi 2016). Metode *time series* terdiri dari beberapa metode, yaitu sebagai berikut:

a) *Smoothing*

Metode *smoothing* dapat mengurangi ketidakteraturan musiman dalam data historis, meskipun sangat akurat untuk peramalan jangka pendek dan tidak begitu akurat untuk peramalan jangka panjang. Ada berbagai jenis metode *smoothing*. yaitu sebagai berikut:

1. *Moving Average*
2. *Weighted Moving Average*
3. *Exponential Smoothing*

b) Regresi

Metode ini dapat digunakan untuk peramalan baik dalam jangka pendek maupun jangka panjang, yang membutuhkan data tahunan. Hasil lebih baik jika analisa memiliki lebih banyak data. Bentuk fungsional teknik ini adalah:

1. Linier
2. Kuadratik

3.4 *Decomposition*

Metode ini menentukan kombinasi fitur yang ada untuk memprediksi hasil prediksi. Metode prediksi tertua adalah metode dekomposisi. Ada beberapa pendekatan alternatif untuk mendekomposisi deret waktu, semuanya ditujukan untuk mengisolasi setiap komponen (Iswahyudi 2016). Langkah-langkah perhitungannya adalah sebagai berikut.

- a. Memprediksi fungsi Y normal
- b. Perhitungan nilai indeks;
- c. Menggabungkan pembelian indeks dan memprediksi pembelian baru.

3.5 *Forecasting Error Accuracy*

Keakuratan dan presisi hasil peramalan memainkan peran penting dalam perusahaan mana pun, terlepas dari proses bisnis yang ada. Kesalahan peramalan menyebabkan kesalahan perencanaan, jadi kesalahan ini berisiko dan harus dijaga serendah mungkin. Diharapkan hasil prediksi akan memberikan gambaran yang mendekati realitas situs (Iswahyudi 2016). Akurasi dan presisi dapat dinyatakan sebagai presisi

kesalahan prediksi. Keakuratan hasil prediksi suatu metode dapat dihitung dengan berbagai cara:

3.6 Preprocessing data

Data *Preprocessing* berarti langkah-langkah yang perlu diambil sebelum menggunakan data dengan tujuan untuk pemrosesan, karena memastikan bahwa data siap digunakan dengan cara yang optimal, meminimalkan kesalahan, dan memaksimalkan hasil analisis (Abdolhossein H S. 2020).

3.7 Postprocessing data

Metode analisis statistik digunakan untuk mengevaluasi kinerja model. Hal ini umumnya dilakukan dengan membandingkan prediksi model dengan nilai eksperimen dengan memperkenalkan berbagai perhitungan (Abdolhossein H S. 2020).

a. Mean absolute error (MAE)

Dalam teknik ini, adalah rata-rata dari nilai absolut dari kesalahan. Ini hanyalah rata-rata dari nilai absolut perbedaan antara nilai aktual dan prediksi. MAE juga disebut sebagai fungsi kerugian karena tujuannya adalah untuk meminimalkan fungsi kerugian ini.

b. Mean squared error (MSE)

Sebagai rata-rata kesalahan kuadrat, MSE juga dianggap *loss function* yang perlu diminimalkan. Salah satu alasan MSE itu berat digunakan dalam aplikasi ML dalam dunia nyata karena kesalahan yang lebih besar akan dipertimbangkan lebih ketika menggunakan MSE sebagai fungsi tujuan dibandingkan dengan MAE. (Belyadi and Haghightat.2021).

c. *Root mean square error (RMSE)*

Dispersi data sekitar nol dihitung menggunakan teknik ini. Umumnya, semakin kecil nilai yang dihasilkan oleh suatu model, semakin akurat model tersebut dalam memprediksi nilai yang diukur.

d. *Coefficient of determination (R²)*

Parameter ini digunakan untuk mengukur seberapa dekat nilai prediksi dengan nilai eksperimen. Hal ini dilakukan dengan membandingkan nilai R², dan nilai R² yang lebih dekat setara dengan model yang lebih akurat (Abdolhossein H S. 2020).

e. *Evaluation Metrics for Classification Models*

Salah satu metode yang paling populer adalah *confusion matrix* yang merupakan cara terbaik untuk mengukur kemanjuran dari model ML, dengan menggunakannya dapat menghitung *accuracy*, *precision*, *recall*, dan *F1-score* untuk mendapatkan performa model. Ini juga dapat digunakan untuk masalah biner dan multikelas (Verdhan 2020). Dalam bentuknya yang paling sederhana, matriks ini direpresentasikan sebagai matriks 2×2.

| | Actual Condition | | Accuracy | | |
|-------------------------|--------------------------------------|------------------------------|-------------------------------|-------------------------------------|---|
| | Condition +ve | Condition -ve | 85% | | |
| Predicted Condition +ve | 131 | 24 | Precision 84.52% | False discovery rate 15.48% | Precision - % of true predictions are actually true? FDR - % of true predictions are actually false? |
| Predicted Condition -ve | 3 | 27 | False omission rate 10.00% | Negative predictive value 90.00% | FOR - % false predictions are actually true? NPV - % false predictions are actually false? |
| Prevalence 72% | Sensitivity, Recall TPR 97.76% | Fallout FPR 47.06% | +ve likelihood ratio 2.08 | -ve likelihood ratio 0.04 | LR+ - ratio of TPE to FPR LR- - ratio of FNR to TNR |
| | Miss Rate FNR 2.24% | Specificity TNR 52.94% | F1 Score 28 | | |

Sensitivity - % of actual positive recalled correctly?
 Miss Rate - % of actual positive predicted wrongly?
 Fallout - % of actual negatives predicted wrongly?
 Specificity - % of actual negatives recalled correctly?
 F1 Score mean of precision & recall

Gambar 3. 12 Confusion matrix (Verdhan 2020)

- a) *Accuracy* adalah berapa banyak prediksi yang dibuat dengan benar.

$$Accuracy = \frac{Number\ of\ correct\ predictions}{Number\ of\ all\ predictions}$$

Akurasi memberikan pemahaman umum tentang akurasi model dalam hal memprediksi kelas yang benar, satu masalah utama dalam menggunakan akurasi saat mengevaluasi model klasifikasi adalah ketika terdapat distribusi kelas yang tidak seimbang dalam kumpulan data. *Matriks confusion* menunjukkan prediksi yang benar dan salah pada setiap kelas. Jika ada dua kelas yang diprediksi oleh model klasifikasi ML, *Matriks confusion* menunjukkan prediksi benar dan salah pada setiap kelas. Dalam masalah klasifikasi biner ketika model regresi logistik digunakan *Matriks confusion* adalah matriks 2x2.

Idenya adalah untuk memaksimalkan kejadian positif dan negatif sebenarnya serta meminimalkan kejadian *false positive* dan *false negative*. *Confusion matrix* dengan dua kelas (*predicted condition +ve*

dan *predicted condition -ve*) dengan terminologi yang dijelaskan di atas. *Precision* dan *Recall* adalah metrik yang digunakan untuk mengevaluasi model klasifikasi. Parameter ini memberikan lebih banyak wawasan tentang keakuratan model (Verdhan 2020).

- b) *Precision*: mewakili prediksi positif dan berapa banyak yang benar-benar positif (Verdhan 2020). serta persamaan 4.23.

$$Precision = \frac{True\ positive}{Predicted\ results} = \frac{True\ positive}{True\ positive + false\ positive} \dots\dots\dots$$

Recall atau *sensitivity*: bagaimana semua peristiwa positif yang sebenarnya terjadi dan berapa banyak yang bisa di prediksi.

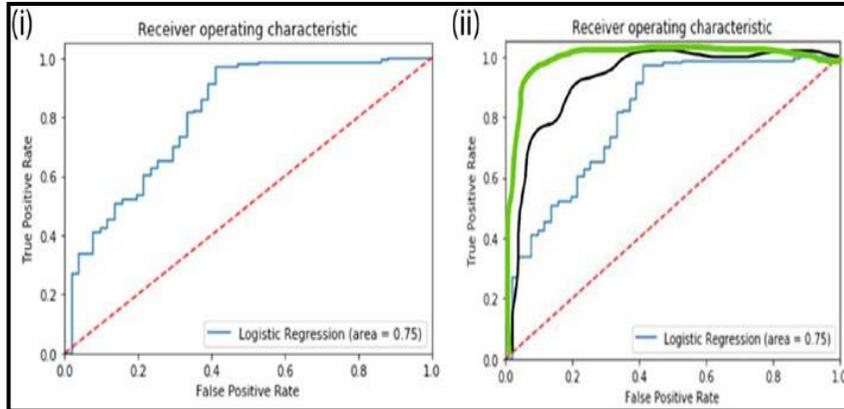
- c) *Specificity* atau *true negative grate*

Kekhususannya keluar dari hal-hal negatif yang sebenarnya dan berapa banyak yang diprediksi dengan benar (Verdhan 2020), serta persamaan 4.25.

$$true\ negative\ rate = \frac{True\ negative}{True\ negative + false\ negative}$$

- *ROC curve* dan *AUC value*

ROC atau karakteristik pengoperasian penerima digunakan untuk membandingkan model yang berbeda. Ini adalah plot antara *TPR* (*true positive rate*) dan *FPR* (*false positive rate*). *Area under curve* ROC (*AUC*) adalah ukuran seberapa baik suatu model. Semakin tinggi nilai *AUC* maka semakin baik modelnya, seperti digambarkan pada Gambar 4.12. Garis lurus pada sudut 45° mewakili akurasi 50%. Model yang baik adalah yang memiliki luas di atas 0,5 dan berada di sudut kiri atas grafik yang berwarna hijau tampaknya menjadi model terbaik di sini (Verdhan 2020).



Gambar 3. 13 ROC Curve

- *Gini coefficient*
 untuk mengukur kesesuaian model. Secara formal, ini adalah rasio area dalam ROC *curve* dan merupakan versi skala dari AUC. Mirip dengan nilai AUC, *Gini coefficient* yang bernilai lebih tinggi lebih disukai (Verdhan 2020).

$$GI = 2 \times AU - 1)$$

- *F1-score*
 Rata-rata harmonik antara presisi dan recall dan semakin tinggi *F1-score*, semakin baik (Verdhan 2020).

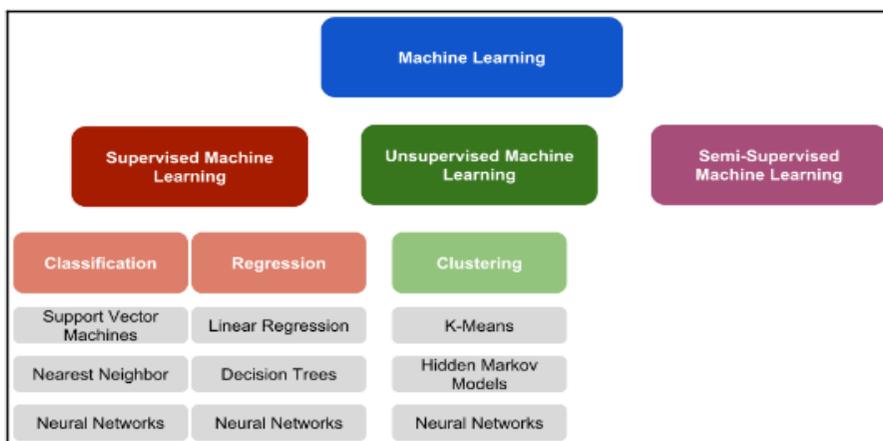
$$F_{1,score} = 2 \frac{Precision \times recall}{Precision + recall}$$

4. ARTIFICIAL INTELLIGENCE, MACHINE LEARNING, AND DEEP LEARNING

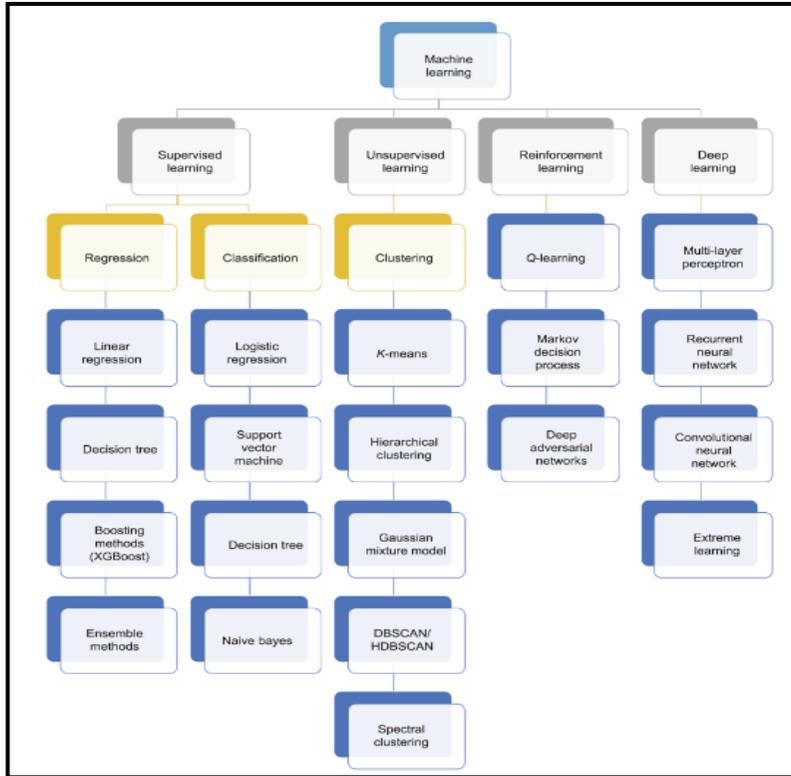
Artificial Intelligence mencakup semua topik lainnya hanya fokus pada *Machine Learning*. *Machine Learning* adalah proses pemrograman komputer untuk belajar dari data historis untuk membuat prediksi pada data baru. *Machine Learning* adalah subdisiplin dan mengacu pada teknik statistik, dimana mesin bekerja berdasarkan hubungan timbal balik yang

dipelajari. Berdasarkan data yang dikumpulkan atau dikumpulkan, algoritma dipelajari secara mandiri oleh computer (Villán 2019).

Dalam konteks *Machine Learning*, ada tiga pendekatan utama yakni *Supervised Machine Learning*, *Unsupervised Machine Learning*, and *Semi-Supervised*. Pendekatan-pendekatan tersebut dapat dilihat pada diagram berikut, untuk melengkapinya dan telah menyertakan tiga teknik paling umum untuk menyelesaikan masalah *Classification*, *Regression*, and *Clustering*.(Villán 2019).



Gambar 3. 14 *The most common techniques for Classification, Regression, and Clustering (Villán 2019)*



Gambar 3. 15 *Technique Machine Learning*

Perbedaan utama antara pendekatan ini adalah prosedur pembelajarannya, yang akan dibahas selanjutnya.

4.1 *Supervised Machine Learning*

Supervised learning dilakukan dengan menggunakan kumpulan sampel dengan nilai keluaran yang sesuai (keluaran yang diinginkan) untuk setiap sampel. Metode *machine learning* ini disebut *supervised* karena mengetahui jawaban yang benar untuk setiap contoh *training dan algoritme supervised learning* menganalisis data training untuk membuat prediksi pada data training. Selain itu, prediksi ini dapat dikoreksi berdasarkan perbedaan antara prediksi dan keluaran yang diinginkan. Berdasarkan koreksi ini, *algoritme* dapat belajar dari kesalahan untuk menyesuaikan parameter internalnya. Dengan cara ini, dalam *supervised*

learning, *algoritme* menyesuaikan fungsi secara iteratif, yang paling mendekati hubungan antara kumpulan sampel dan keluaran yang diinginkan terkait. (Villán 2019)

Masalah Supervised *learning* dapat dikelompokkan lebih lanjut ke dalam kategori berikut:

a) *Classification*

Ketika variabel keluaran berupa kategori, seperti warna (merah, hijau, atau biru), ukuran (besar, sedang, atau kecil), atau jenis kelamin (laki-laki atau perempuan), masalah tersebut dapat dianggap sebagai masalah klasifikasi. Dalam masalah klasifikasi, algoritma memetakan input ke label output.

b) *Regression*

Ketika variabel keluaran adalah nilai nyata, seperti umur atau berat badan, masalah pembelajaran yang diawasi dapat diklasifikasikan sebagai masalah regresi. Dalam masalah regresi, algoritma memetakan input ke output yang berkelanjutan.

4.2 Unsupervised Machine Learning

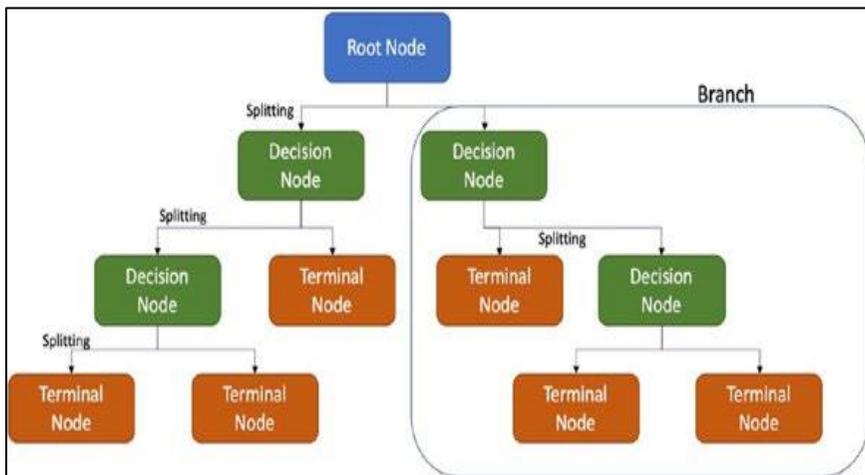
Dalam *unsupervised learning*, tidak ada keluaran berlabel. Dalam pengertian ini, ada kumpulan sampel, tetapi nilai keluaran yang sesuai untuk setiap sampel hilang (koleksi sampel belum diberi label, diklasifikasikan, atau dikategorikan). Tujuan *unsupervised learning* adalah untuk memodelkan dan menyimpulkan struktur atau distribusi yang mendasarinya dalam kumpulan sampel. Oleh karena itu, dalam *unsupervised learning*, algoritme tidak menemukan output yang tepat, tetapi mengeksplorasi data dan dapat membuat inferensi dari data yang mencoba mengungkap struktur tersembunyi di dalamnya. Pengelompokan, atau pengurangan dimensi, adalah dua *algoritme* yang paling umum digunakan dalam *unsupervised learning* (Villán 2019).

4.3 Semi-Supervised Machine Learning

Seperti namanya, *Semi-supervised* dapat dilihat sebagai kompromi antara learning *supervised* dan tidak diawasi karena menggunakan data berlabel dan tidak berlabel untuk pelatihan. Dalam pengertian ini, masalah di mana memiliki sejumlah besar input data, dan hanya beberapa data yang diberi label, dapat diklasifikasikan sebagai masalah *learning semi-supervised*. Banyak masalah *machine learning* dunia nyata dapat diklasifikasikan sebagai semi-supervised karena bisa sangat sulit, mahal, atau memakan waktu untuk melabeli semua data dengan benar (Villán 2019).

4.4 Model Development with Decision Tree

Decision tree dapat digunakan untuk memprediksi variabel kontinu dan variabel kategori. Dalam kasus *regression tree*, nilai yang dicapai oleh *terminal node* adalah rata-rata dari nilai-nilai yang berada di wilayah tersebut. Sedangkan dalam kasus *classification tree* adalah cara observasinya. penting untuk mengetahui elemen dasar DT.



Gambar 3. 16 The decision tree consists of the root node, decision node, terminal node, and branch (Verdhan 2020)

1. *Root node* adalah seluruh populasi yang dianalisis dan ditampilkan di bagian atas *decision tree*.
2. *Decision node* mewakili *subnode* yang selanjutnya dipecah menjadi *subnode*.
3. *Terminal node* adalah elemen terakhir dalam *decision tree*. Pada dasarnya ketika sebuah *node* tidak dapat membagi lebih jauh, itu adalah akhir dari jalur tersebut. *Node* itu disebut terminal node atau juga disebut sebagai *leaf*.
4. *Branch* adalah bagian dari *tree*, atau juga disebut *subtree*.
5. *Parent node* dan *child* adalah referensi yang dibuat untuk *node* saja. *Node* yang terbagi adalah *parent node* dan *subnodenya* disebut *child nodes*.

DT memberikan cara untuk mendefinisikan proses pengambilan keputusan sebagai jalur potensial yang dibangun di atas *node* dan *branch*. Setiap *node* pada *tree* adalah sebuah atribut dan setiap nilai yang mungkin dari suatu atribut adalah sebuah *branch*. Ada 3 fitur utama yang harus dipertimbangkan ketika menggunakan algoritma (Garcia, Mukhanov, and Torres 2019):

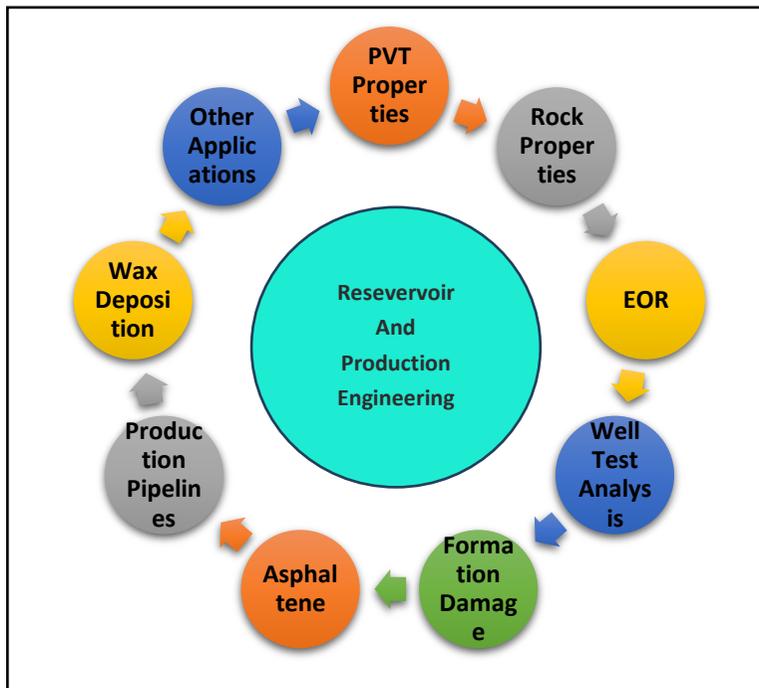
- a. Pesan untuk *node*: Atribut yang paling penting atau relevan harus berada di urutan teratas. Untuk mencapai hal ini ada banyak metode untuk mengklasifikasikan semua *node* seperti *Gini Index* dan *Information Gain*.
- b. Diskritisasi nilai-nilai *branch*: DT merupakan proses diskrit, sehingga setiap nilai atribut harus didefinisikan sebagai nilai diskrit.
- c. Jumlah level pada *tree*: Semakin banyak level menghasilkan batas keputusan yang lebih kompleks namun hasilnya lebih baik. Ada batasan praktis ketika algoritme mulai menghadapi *overfitting*.

DT sangat mudah diimplementasikan, dipahami, dan direpresentasikan dalam grafik. Ini sangat praktis untuk masalah kecil karena sangat efisien dan memberikan hasil yang dapat diterima (banyaknya atribut dan nilai yang mungkin)(Garcia, Mukhanov, and Torres 2019). Dalam kumpulan data dengan N atribut, menentukan atribut untuk berada di *root* atau *node* internal bisa jadi rumit dan menantang. Beberapa kriteria terpenting dalam pemilihan atribut (Belyadi and Haghghat 2021). Entropy: Dalam menentukan *node* terpilih, menggunakan nilai *Entropy* dari setiap kriteria dengan data sampel yang digunakan. *Node* yang terpilih adalah kriteria dengan *entropy* yang paling kecil.

$$E(S) = \sum_{i=1}^c -P_i \log_2 P_i$$

5. APPLICATION OF MACHINE LEARNING IN RESERVOIR & PRODUCTION ENGINEERING

Penerapan *artificial intelligence (AI)* di bidang *reservoir* dan *production engineering*. Menurut literatur, model intelligent memiliki aplikasi yang luas di berbagai bidang *reservoir* dan *production engineering*. Di sini, penerapan model model intelligent kan dibahas dalam sembilan topik berbeda, yaitu, *Reservoir fluid properties*, *Rock properties*, *Enhanced oil recovery*, *Well test analysis*, *Formation damage*, *Asphaltene*, *Production pipelines*, *Wax deposition*, dan *other application*.



Gambar 3. 17 Aspects in reservoir and production engineering

5.1 Reservoir fluid properties

a) One-phase properties

Ini adalah tugas penting untuk secara akurat menentukan *pressure-volume temperature (PVT)* minyak dan gas karena signifikansinya yang tinggi untuk perhitungan keseimbangan material karena parameter ini secara langsung memengaruhi kinerja dan evaluasi reservoir serta operasi dan desain produksi. Dalam industri, data eksperimen yang andal sangat dibutuhkan, namun, dalam banyak kasus, data eksperimen hampir tidak tersedia. Korelasi *PVT* dan *equation of state (EOS)* adalah dua pendekatan untuk memperkirakan properti *PVT* ketika data eksperimental *PVT* tidak tersedia. Kegunaan *EOS* membutuhkan prosedur yang memakan waktu dan mahal untuk menentukan komposisi rinci *crude oil*. Korelasi *PVT* berguna karena

kemampuannya untuk memprediksi properti *PVT* hanya dengan menggunakan beberapa parameter seperti berat jenis minyak dan gas, specific gravity (SG) dan *reservoir temperature/pressure*.

b) *Two-phase properties*

Interfacial tension (IFT) dan *minimum miscibility pressure (MMP)* adalah salah satu *two-phase properties* yang paling penting dari fluida reservoir. Namun, *IFT* dibahas di bagian ini, sedangkan *MMP* dianggap sebagai bagian dari *EOR (enhanced oil recovery)* karena sangat penting dalam proses injeksi gas. Signifikansi *IFT* dipahami dengan baik karena memiliki peran penting dalam banyak proses industri dan engineering. Penerapan *AI* dalam memprediksi nilai *IFT* campuran biner dimulai pada tahun 2009 ketika Kumar mengembangkan model prediksi untuk memperkirakan *IFT* pada *crystal/solution interface* dengan bantuan *ANN*. Sejak kemudian, model cerdas telah digunakan oleh banyak peneliti di bidang studi ini.

5.2 Rock properties

Pengetahuan yang komprehensif tentang karakteristik reservoir sangat penting *dalam* simulasi reservoir dan studi pemodelan. Proses mendefinisikan properti reservoir yang berbeda disebut sebagai karakterisasi reservoir, yang merupakan bagian penting dari manajemen *reservoir modern*. *Porosity*, *permeability*, *fluid distributions*, dan distribusi ukuran *pore/grain* merupakan karakteristik utama dari reservoir hidrokarbon.

Sampel batuan (*cores*) iasanya tersedia untuk lokasi sumur yang *terbatas*, yang membuat penentuan karakteristik reservoir menjadi masalah yang kompleks. Parameter ini secara konvensional dihitung menggunakan *seismic survey*, *production data*, *well tests*, *well logs*, dan *core data*. Karena pentingnya karakteristik reservoir dan permintaan untuk penentuannya yang

akurat, teknik *AI* diterapkan untuk memperkirakan secara tepat parameter ini dengan menggunakan data yang mudah didapat sejak awal 1990-an.

5.3 Enhanced oil recovery

Oil recovery dari reservoir dengan proses *primary* and *secondary* hampir tidak melebihi 30% - 50%. Hasil lapangan mengungkapkan bahwa setelah fase *primary* and *secondary* produksi minyak, dua pertiga dari *original oil in place* akan tertinggal di dalam media berpori. Alasan utama untuk efisiensi *recovery* tersebut dapat didaftar sebagai *macroscopic* dan *microscopic heterogeneities*, karakteristik fluida yang berbeda (densitas dan viskositas), berbagai *IFT* dan *wettability*, dan kekuatan pendorong yang berbeda. Metode *tertiary* dari *oil recovery*, yang dikenal sebagai proses EOR, telah menarik perhatian yang semakin besar dalam beberapa dekade terakhir sejak harga minyak dan peningkatannya secara luar biasa.

a) *Enhanced oil recovery processes*

Penerapan model *AI* di bidang proses *EOR* sudah ada sejak tahun 1990-an. Pada tahun 1995, Gharbi, memperkenalkan aplikasi *ANN* pertama di bidang ini. bertujuan untuk memprediksi skenario efisiensi dari *water flooding (immiscible displacement)*. Dalam karya lain, model cerdas *NF* dikembangkan oleh Nikraves, untuk meningkatkan pengelolaan dari *waterflood* di *tight fractured* reservoir. ada tahun 1998, Elkamel menggunakan *ANN* untuk memprediksi dan mengoptimalkan efisiensi *waterflooding* pada reservoir yang heterogen.

b) *Minimum miscibility pressure*

MMP adalah *property two-phase* yang penting dari fluida reservoir. Dalam proses injeksi *miscible* gas, injeksi pressure harus cukup tinggi (lebih tinggi dari *MMP*) agar injeksi gas *miscible* dalam fluida reservoir. Jika tidak, t proses injeksi dianggap sebagai injeksi *immiscible* gas. *Miscibility* dapat dicapai melalui kontak pertama atau beberapa proses

kontak. Tekanan terendah dimana gas yang diinjeksikan dapat mencapai *miscibility* dengan reservoir minyak disebut MMP.

5.4 Well test analysis

Well testing adalah subdivisi dari reservoir dan *production engineering*, yang biasanya dianggap sebagai langkah signifikan menuju karakterisasi reservoir hidrokarbon secara kualitatif dan kuantitatif. Identifikasi model interpretasi dari *well test* dan estimasi parameter reservoir adalah dua bagian penting dari proses analisis *well test process*. Informasi yang diberikan oleh *well test* juga penting untuk memperkirakan kapasitas produktif reservoir dan tekanan rata-rata. Analisis kinerja reservoir dan memprediksi produksinya di masa depan didasarkan pada informasi yang tepat tentang sifat dan keadaan reservoir. Umumnya, analisis *well test oil* dan gas dilakukan untuk mencapai beberapa tujuan:

- a. Mengkarakterisasi reservoir dan mengevaluasi kondisi sumur
- b. Memprediksi *skin factor* (ukuran *formation damage*)
- c. Mendeskripsikan reservoir melalui perhitungan parameter reservoir
- d. Menentukan zona produktif dari sumur bor.

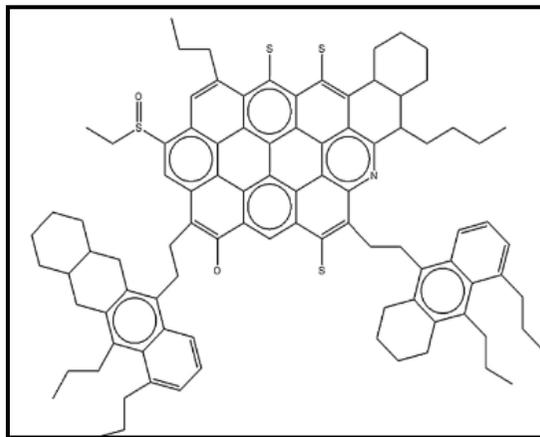
5.5 Formation damage

Masalah yang tak terhindarkan dan tidak diinginkan dalam industri perminyakan yang terjadi selama langkah yang berbeda dari pengembangan lapangan minyak dan produksi disebut sebagai *formation damage*. Banyak faktor yang dapat *controllable* dan *uncontrollable* yang dapat menyebabkan masalah ini. Dengan kata lain, setiap faktor yang dapat menyebabkan terganggunya kesetimbangan yang ada (antara fasa yang berbeda) di dalam media berpori berpotensi dianggap sebagai penyebab dari *formation damage*. *Formation damage* dapat sangat mengurangi permeabilitas reservoir dan kinerja sumur. Menurut Porter, *formation damage* tidak dapat dianggap sebagai masalah yang dapat dibalikkan. Mempertimbangkan faktanya,

prediksi akurat *formation damage* sebelum terjadinya dapat menjadi kontribusi besar bagi industri perminyakan.

5.6 Asphaltene

Asphaltene adalah senyawa molekul yang sangat kompleks yang ada sebagai fraksi berat dalam petroleum. Makromolekul berat ini tidak larut dalam pelarut nonpolar (yaitu, n-heptana). Namun, larut dalam pelarut aromatik seperti toluena. Asphaltene terdiri dari cincin aromatik dengan cabang alkana yang panjang, yang dikenal sebagai fraksi minyak dengan nilai berat molekul, polaritas, dan aromatisitas tertinggi. Dalam struktur seperti itu, komponen anorganik (nitrogen dan sulfur) mungkin ada bersama dengan logam seperti vanadium dan nikel.



Gambar 3. 18 *Hypothetical asphaltene molecule*
(Hemmati-Sarapardeh, 2008)

Asphaltene berpotensi merusak formasi minyak dan peralatan produksi. Jika sistem minyak menjadi tidak stabil, molekul *asphaltene* dapat *flocculate*, *precipitate*, dan deposit. Kestabilan asphaltene dapat terganggu ketika sifat termodinamika campuran (*pressure*, *temperature*, *composition*) berubah. *precipitation* dan *deposition* aspal dapat menyebabkan masalah *formation damage* katastrofik dalam hal *suthroat plugging* pori dan perubahan

wettability selama berbagai fase pengembangan lapangan (pengeboran, produksi, dan injeksi). Oleh karena itu, sangat penting untuk memprediksi fenomena ini sehingga tindakan pencegahan dapat dilakukan.

5.7 Production pipelines

Pipeline adalah sarana transportasi minyak dan gas bumi yang paling ekonomis dan efisien dalam jarak jauh di lingkungan yang berbeda karena tingkat kecelakaannya yang lebih rendah dibandingkan dengan jalan raya dan rel kereta api; namun, mengalami korosi dan degradasi. Menurut statistik, *pipeline networks* tersebar lebih dari 2000 km di lebih dari 60 negara di seluruh dunia. Jelas, insiden mengakibatkan kerugian ekonomi yang sangat besar serta dampak lingkungan yang sangat besar seperti tumpahan minyak. ehubungan dengan laporan *CONCAWE (Conservation of Clean Air and Water in Europe)*, *natural hazards*, *mechanical*, *operational*, *corrosion*, pihak ketiga adalah penyebab kegagalan *oil pipeline*. Sesuai dengan peran penting *pipeline*, perlu untuk memprediksi kondisinya sebelum terjadi kecelakaan.

a. Wax

Wax deposition merupakan masalah yang signifikan dalam industri minyak dan gas yang dapat menyebabkan masalah *oil production reduction*, *pipeline plugging*, dan *formation damage* *Wax precipitation* menjadi perhatian di bidang kondensat *crude oil* dan gas, ketika suhu turun di bawah suhu tertentu yang dikenal sebagai *wax appearance temperature*. Oleh karena itu beberapa bermaksud untuk memanfaatkan teknik AI di bidang ini untuk memprediksi *wax deposition* atau karakteristiknya sebelum terjadinya.

b. Other applications

Teknik AI memiliki aplikasi lain selain bidang yang disebutkan di atas. Dalam beberapa dekade terakhir, teknik pemodelan ini telah digunakan di berbagai bidang seperti *artificial lift*, *inflow performance*

relationship (IPR), multiphase flow, pressure gradient, dan unconventional reservoir.

BAB IV MACHINE LEARNING MODEL DEVELOPMENT (DECISION TREE)

Sebelumnya, kita telah membahas secara mendalam mengenai mekanisme produksi air dan gas, termasuk metode-metode diagnostik seperti *Chan's Diagnostic Plot* dan analisis cadangan reservoir. Pengetahuan tentang pola produksi air dan gas serta teknik evaluasi cadangan ini memberikan dasar yang kuat untuk memahami kondisi operasional dan tantangan yang dihadapi dalam produksi minyak dan gas. Memasuki Bab ini, kita akan menerapkan konsep-konsep tersebut dalam pengembangan model *machine learning*, khususnya *decision tree*, untuk mengidentifikasi kandidat reaktivasi sumur *idle*. Dengan menggunakan data produksi historis dan parameter operasi yang relevan, model *decision tree* akan membantu dalam memprediksi dan mengklasifikasikan sumur mana yang memiliki potensi terbesar untuk reaktivasi, meningkatkan efisiensi dan efektivitas dalam pengelolaan sumur.

a. *Data Collection (Idle Well)*

Studi ini menggunakan data lapangan (*well history*) dan kumpulan data awal terdiri dari parameter IW dalam penentuan reaktivasi, metode pemboran dan desain pompa yang pernah dilakukan pada sumur tersebut, karena merupakan suatu pendekatan untuk mengidentifikasi kandidat sumur yang memiliki potensi yang akan di reaktivasi berdasarkan berbagai parameter dan faktor yang diukur atau diamati.

b. *Data Preprocessing*

Data Preprocessing dilakukan setelah data *collection* dengan tujuan untuk pemrosesan berupa *Idle wells Status Database* untuk menentukan kandidat potensial IW yang cocok pada saat dilakukan reaktivasi dan di interpretasikan karena memastikan bahwa data siap

digunakan dengan cara yang optimal, meminimalkan kesalahan, dan memaksimalkan hasil analisis dengan algoritma *machine learning* yang akan digunakan. Pada tahapan ini untuk *Cleaning*, *Label Encoder*, *Data Normalization*, dan *Train-Test Split*, berupa *cleaning dataset*, mengubah kolom label kategori menjadi numerik, *Normalization* dengan skala 0 sampai 1, dan membagi dataset menjadi *train-set* dan *test-set*.

c. *Sub-Proses Data Cleaning*

Data Cleaning dilakukan untuk membersihkan data mentah (*raw*) dari *noise*, kesalahan, atau, inkonsistensi agar data tersebut menjadi lebih relevan dan konsisten. Pada penelitian ini *Data Cleaning* digunakan untuk menghapus baris dengan data kosong (*missing value*) dan menghapus kolom tidak penting. Penghapusan *missing value* dilakukan pada kolom 'KKKS', 'WK', 'Zona', 'Field', 'Location', 'Initial Well', 'Last Well', 'Last Well Test(BOPD)', 'Last Well Test(MMSCFD)', 'Well Cum Prod(Gp, MMSCF)', 'HC Remaining Potential(Gas, MMSCF)', 'Expected Gain(Qgi, MMSCFD)', 'Expected Gain(Qoi, BOPD)', dengan menggunakan fungsi `data.drop(columns=[col for col in data_remove if col in data.columns], inplace=True)` dan untuk mengisi data yang kosong (-) dengan fungsi `replace()` seperti `data.replace({'Lifting Method': {'-': 'Jet Pump'}}, inplace=True)`.

```
#removing unnecessary columns
# Preparing the column list to drop
data_remove = ['KKKS', 'WK', 'Area', 'Zona', 'Field', 'Location',
               'Initial Well', 'Last Well', 'Last Well Test(BOPD)', 'Last Well T

data.drop(columns=[col for col in data_remove if col in data.columns], inplace=T
data
```

Gambar 4.1 *Removing unnecessary columns*

Variable yang digunakan dalam membangun model yaitu *Well Name*, *Area*, *Well Type*, *Well Cum Prod(Np, MBO)*, *HC Remaining Potential (Oil, MBO)*, *Doability*, *Recommendation*, dan *Potential Status*.

```
data.replace({'Lifting Method': {'-': 'Jet Pump'}}, inplace=True)

data.replace({'Doability': {'-': 'H'}}, inplace=True)

data.loc[data['Recommendation']=='P&A']
```

Gambar 4. 2 *Replace columns with empty data*

d. *Sub-Proses Label- Encoder*

Label Encoder adalah tahapan untuk mengkonversi kolom bertipe kategori menjadi numerik. Hal ini perlu dilakukan karena sebagian besar algoritma *machine Learning* yang tidak mampu mengolah data dalam bentuk kategori. Pada dataset terdapat lima kolom bertipe kategori seperti: *well type*, *Lifting Method*, *Doability*, *Recommendation*, dan *Potential Status*.

```
LE = LabelEncoder()
for col in fitur_encoding:
    data[col] = LE.fit_transform(data[col])

# Optional: create mapping
label_mapping = {index: label for index, label in enumerate(LE.classes_)}
print(f'Label mapping for {col}:', label_mapping)

Label mapping for Well Type: {0: 'Gas', 1: 'Injector', 2: 'Oil'}
Label mapping for Lifting Method: {0: 'ESP', 1: 'Jet Pump', 2: 'Natural', 3: 'SRP'}
Label mapping for Doability: {0: 'H', 1: 'L', 2: 'M'}
Label mapping for Recommendation: {0: 'Hold', 1: 'Kategori Sumur Tua', 2: 'P&A', 3: 'WO', 4: 'WS'}
Label mapping for Potential Status: {0: 'Potential', 1: 'Tidak Potential'}
```

Gambar 4. 3 *Label Encoder*

Selanjutnya setiap nilai kategori pada kolom-kolom tersebut di konversi menjadi bentuk numerik dengan penentuan nilai secara otomatis menggunakan fungsi *LabelEncoder()* pada *library sklearn*. *Flowchart* dari *Sub-Proses Label Encoder*.

e. *Sub-Proses Data Normalization (Scaling Data)*

Data Normalization pada *machine learning* merupakan suatu proses untuk mengubah skala data numerik dalam dataset ke dalam rentang yang lebih standar atau normal (0 dan 1), karena salah satu data nilainya ribuan sedangkan yang lain nilainya puluhan, yang nantinya mempengaruhi model dan cenderung memprediksi ke data yang nilainya besar dalam data yang bentuknya distribusi nilai bervariasi. Maka, digunakan fungsi *MinMaxScaler()*, dapat dilihat gambar di bawah ini sebagai berikut:

```
scaler = MinMaxScaler() #Mendefinisikan MinMaxScaler
data[fitur_normalisasi] = scaler.fit_transform(data[fitur_normalisasi]) #Menerap

print("Fitur yang di normalisasi")
print(data[fitur_normalisasi].describe().T[['min','max']]) #Cek nilai min dan ma
```

Gambar 4. 4 Min-Max-Scaler

f. *Train-set & Test-set Split*

Langkah dalam data *processing* untuk membangun model prediksi dengan membagikan data dari 618 data IW untuk *training set* 70% sebesar 432.6 data untuk melatih model dan *testing set* 30% sebesar 185.4 data untuk menguji kinerja model yang sudah di latih, dan *Flowchart* dari *tran test split*.

g. *Model Decision Tree*

Penentuan kandidat reaktivasi IW dengan DT dapat digunakan untuk membuat keputusan yang paling cocok untuk direaktivasi berdasarkan kriteria-kriteria tertentu. Dalam pemilihan model untuk IW yang akan di reaktivasi berdasarkan data yang dimiliki tergantung dari jenis atribut data, ukuran data, dan memilih algoritma yang dapat menghasilkan hasil prediksi yang akurat yang sesuai dengan tujuan. Pemilihan model dengan DT merupakan pendekatan yang baik untuk menentukan IW yang paling layak untuk di reaktivasi dan dioptimalkan dengan metode pemboran dan desain pompa yang cocok untuk IW yang pernah dilakukan, serta model ini yang umumnya digunakan dalam masalah klasifikasi, dan dapat menyelesaikan masalah ketidakseimbangan distribusi kelas dan dimensionalitas tinggi pada *dataset idle well* serta mampu meningkatkan kinerja algoritma klasifikasi.

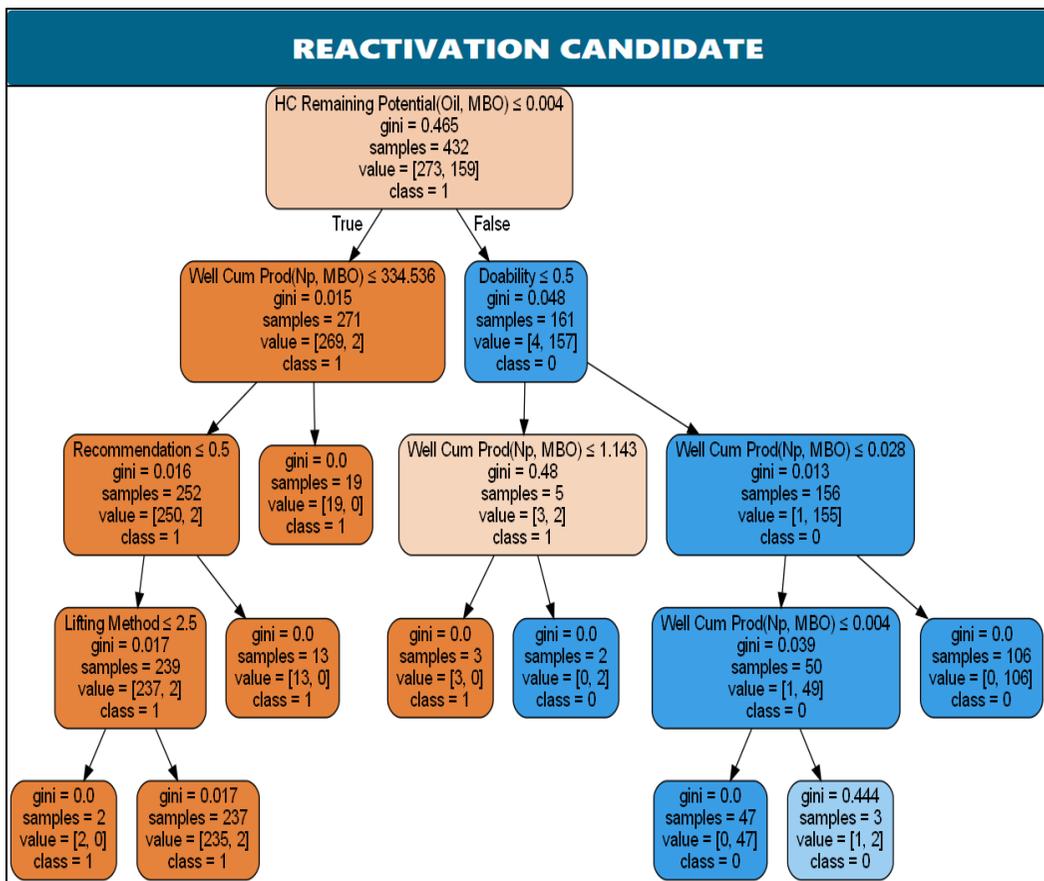
Adapun input yang digunakan pada pemodelan ini adalah *train-set* (x_{train} , y_{train}) hasil dari tahapan *Train Test Split*. Tahapan pengolahan data, seperti: *Modelling Decision Tree*, *Confusion Matrix*, *Accuracy Area Under Curve (AUC)*, *Accuracy Receiver Operating Characteristic (ROC)*.

h. *Manual Calculation Decision Tree*

Perhitungan penentuan kandidat reaktivasi IW dengan menggunakan model DT, dengan pemikiran bahwa yang mempengaruhi sumur tersebut di idamkan. Langkah-langkah untuk mengubah data menjadi *Tree* dengan Menentukan *Node* terpilih dan Menyusun *Tree*.

Decision Tree Sklearn

Berdasarkan hasil prediksi model kandidat IW dengan model DT agar lebih sesuai dan tujuannya untuk meningkatkan kegunaan hasil, serta juga memvisualisasi hasil untuk memahami pola atau tren yang terdapat dalam data yang dapat membantu dalam mengoptimalkan reaktivasi sumur yang sebagai kandidat potensial.



Gambar 4. 5 Visualization Tree Reactivation Candidate

Gambar 4.5. menunjukkan model *decision tree* yang digunakan untuk memprediksi kelas (1 atau 0) terdapat 5 fitur yaitu *HC Reamaining 'Potential (Np, MBO)*, *Well Cum Prod (Np, MBO)*,

Doability, Recommendation, Lifting Method. Berikut ini penjelasan detail setiap fitur dalam tree:

1. *Root Node*

Root Node merupakan Kotak persegi panjang yang mewakili pertanyaan atau Keputusan, karena pertanyaan pada node ini diajukan untuk setiap sampel data. *Text: Well Cum Prod (Np, MBO) <= 334.536* yang dimana, jika jawabannya "Ya", ikuti cabang ke kiri yang berarti cabang ini mewakili sampel data dengan *HC Remaining Potential (Oil, MBO) ≤ 0.004*. Jika jawabannya "Tidak", ikuti cabang ke kanan yang berarti Cabang ini mewakili sampel data dengan *HC Remaining Potential (Oil, MBO) > 0.004*. Node selanjutnya adalah *Lifting method ≤ 2.5*, dan sampai seterusnya hingga mencapai daun (*leaf*), yang Dimana merupakan kelas akhir dari sampel yang di tentukan.

2. *Gini: 0.465* (Tingkat ketidakpastian tinggi), diartikan ukuran ketidakpastian dalam node. Semakin tinggi Gininya, semakin beragam kelas data dalam node tersebut.
3. *Samples: 432* (Jumlah data yang digunakan untuk membangun model), diartikan jumlah sampel data yang mencapai node tersebut.
4. *Value: [273, 159]* (Jumlah data dikelas 1 dan 0), diartikan Distribusi kelas data dalam node tersebut. Nilai pertama menunjukkan jumlah sampel kelas 1, dan nilai kedua menunjukkan jumlah sampel kelas 0.
5. *Class: 1* (Kelas yang paling banyak muncul).

Diikuti seterusnya dan sebagai contoh dalam penentuan kandidat reaktivasi dilihat pada *leaf tree* terakhir, sebagai berikut:

1. *Root Node Text: Lifting Method <= 2.5*
2. *Gini: 0.0* (Tingkat ketidakpastian 0) diartikan ukuran ketidakpastian dalam node dan gininya tidak beragam kelas data dalam node tersebut.

3. Samples: 2 (Jumlah data yang digunakan untuk membangun model), diartikan jumlah sampel data yang mencapai node tersebut.
4. Value: [2, 0] (Jumlah data dikelas 1 dan 0), diartikan Distribusi kelas data dalam node tersebut. Nilai pertama menunjukkan jumlah sampel kelas 1, dan nilai kedua menunjukkan jumlah sampel kelas 0.
5. Class: 1 (Kelas yang paling banyak muncul).

```
data.loc[ data["Lifting Method"]<=0.0]
```

| | Well Name | Well Type | Lifting Method | Well Cum Prod(Np, MBO) | HC Remaining Potential(Oil, MBO) | Doability | Recommendation | Potential Status |
|-----|-----------|-----------|----------------|------------------------|----------------------------------|-----------|----------------|------------------|
| 208 | NGL-P-001 | 2 | 0 | 0.009577 | 0.087935 | 2 | 4 | 0 |
| 232 | TPN-004 | 2 | 0 | 0.011768 | 1.000000 | 0 | 4 | 0 |

Gambar 4. 6 Result Tree

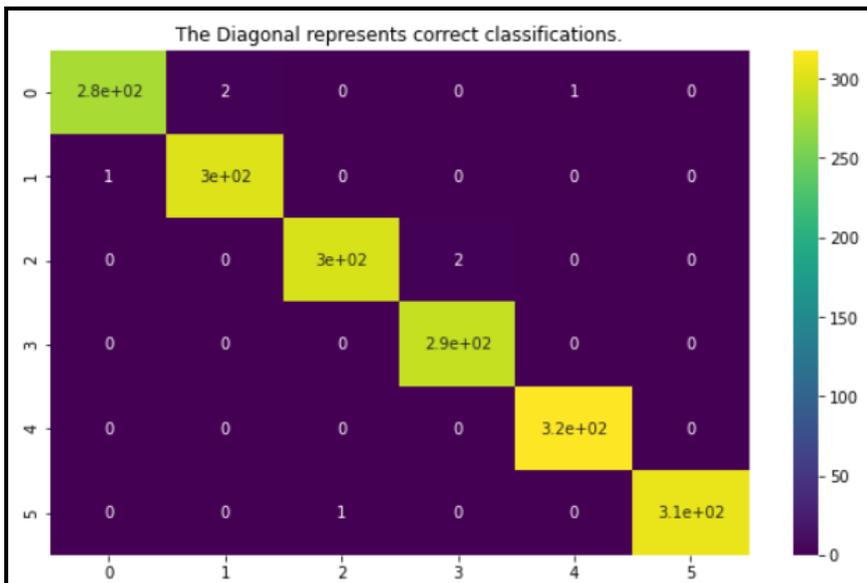
Evaluation Index Performance

Evalusi Indeks Performansi dengan model metode analisis statistik digunakan untuk mengevaluasi kinerja dengan melibatkan perhitungan metrik evaluasi seperti *accuracy*, *precision*, *recall*, *F1-score*, dan lainnya.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 1.00 | 0.99 | 0.99 | 280 |
| 1 | 0.99 | 1.00 | 1.00 | 302 |
| 2 | 1.00 | 0.99 | 1.00 | 301 |
| 3 | 0.99 | 1.00 | 1.00 | 290 |
| 4 | 1.00 | 1.00 | 1.00 | 318 |
| 5 | 1.00 | 1.00 | 1.00 | 309 |
| accuracy | | | 1.00 | 1800 |
| macro avg | 1.00 | 1.00 | 1.00 | 1800 |
| weighted avg | 1.00 | 1.00 | 1.00 | 1800 |

Gambar 4. 7 Performance Index illustration (accuracy, precision, recall, F1-score)

Penentuan kandidat reaktivasi IW, metrik-metrik ini akan membantu dalam mengevaluasi seberapa baik model dapat *mengidentifikasi* sumur yang layak direaktivasi berdasarkan kriteria yang ditetapkan. Misalnya, *precision* yang tinggi akan menunjukkan bahwa dari sumur yang dipilih sebagai kandidat reaktivasi, sebagian besar benar-benar layak direaktivasi. *Recall* yang tinggi, di sisi lain, menunjukkan bahwa model mampu mengidentifikasi sebagian besar sumur yang sebenarnya layak direaktivasi. Menemukan keseimbangan yang tepat antara *precision* dan *recall* adalah kunci dalam mengevaluasi kinerja model dalam penentuan kandidat reaktivasi IW.

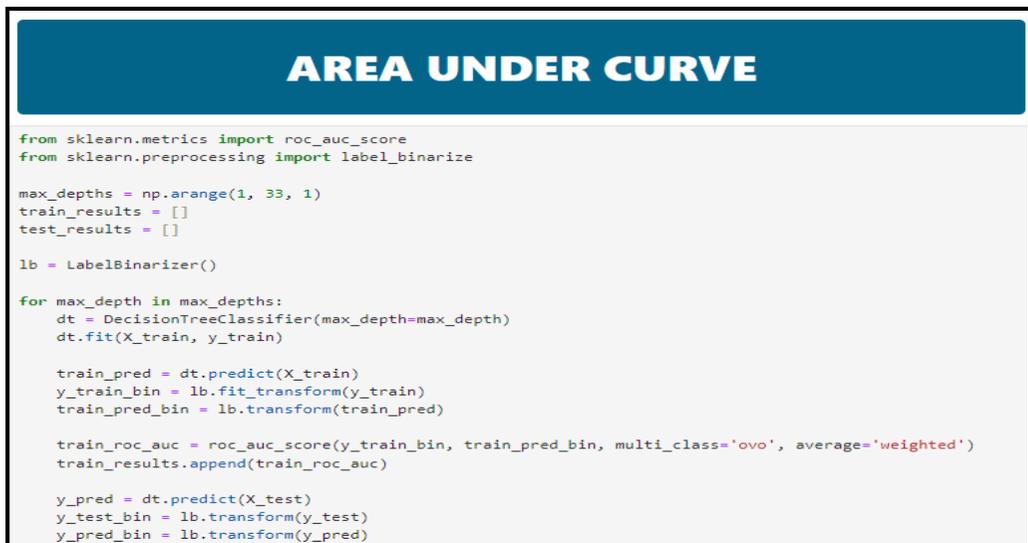


Gambar 4. 8 *Performance Index illustration (confusion matrix)*

Berdasarkan gambar tersebut untuk *Good* model mempunyai TP dan TN tinggi versus FP dan FN rendah. Jika sumur layak di reaktivasi = *positif* dan jika sumur tidak layak di reaktivasi = *negative*. Hal ini umumnya dilakukan dengan membandingkan prediksi model dengan nilai-nilai eksperimental dengan memperkenalkan berbagai

pendekatan perhitungan kesalahan, sehingga dapat membantu indeks performansi dalam mengevaluasi kinerja model prediksi dalam penentuan kandidat reaktivasi IW, secara obyektif dengan menggunakan nilai-nilai indeks performansi dan dapat melihat model prediksi memenuhi harapan dan persyaratan yang telah ditetapkan untuk pengambilan keputusan dan perencanaan operasional di lapangan.

Selain itu, dalam penelitian menggunakan *Area Under the Curve (AUC)* dan *Operating Characteristic Curve (ROC)* yang digunakan untuk mengevaluasi kinerja model klasifikasi.



```
from sklearn.metrics import roc_auc_score
from sklearn.preprocessing import label_binarize

max_depths = np.arange(1, 33, 1)
train_results = []
test_results = []

lb = LabelBinarizer()

for max_depth in max_depths:
    dt = DecisionTreeClassifier(max_depth=max_depth)
    dt.fit(X_train, y_train)

    train_pred = dt.predict(X_train)
    y_train_bin = lb.fit_transform(y_train)
    train_pred_bin = lb.transform(train_pred)

    train_roc_auc = roc_auc_score(y_train_bin, train_pred_bin, multi_class='ovo', average='weighted')
    train_results.append(train_roc_auc)

y_pred = dt.predict(X_test)
y_test_bin = lb.transform(y_test)
y_pred_bin = lb.transform(y_pred)
```

Gambar 4.9 *Area Under Curve (AUC)*

```
RECEIVER OPERATING CHARACTERISTIC

from sklearn.metrics import roc_curve, auc
import matplotlib.pyplot as plt

DT = DecisionTreeClassifier()

# Existing models are now defined
models = [DT]
modelnames = ['Decision tree']

for i, x in enumerate(models):

    # Fit the model
    x.fit(X_train, y_train)
```

Gambar 4. 10 Receiver Operating Characteristic (ROC)

Kandidat Potensi Reaktivasi

Kandidat Potensi Reaktivasi berdasarkan Potential Status dan Area sumur merupakan dua faktor penting dalam mengidentifikasi kandidat potensi reaktivasi sumur. Kombinasi kedua faktor ini dapat membantu perusahaan minyak dan gas dalam proses pengambilan keputusan, serta memprioritaskan reaktivasi sumur dan meningkatkan peluang untuk mewujudkan produksi minyak sebesar 1 juta barel per hari pada tahun 2030.

1. Potential Status

Potential Status berdasarkan hasil dari *Entropy model* dan *Tree Results* dengan warna merah (*red*) untuk tidak potential dengan nilai 0 dan warna hijau muda (*light green*) untuk potential dengan nilai 1.

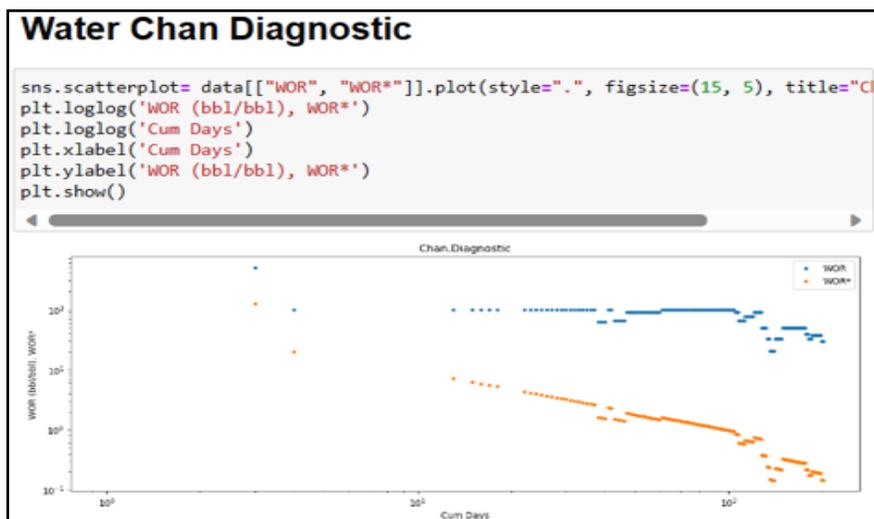
2. Area Sumur

Hasil dari setiap sumur berdasarkan area terhadap *Well Cum Prod (Np, MBO)* dan *HC Remaining Potential (Oil, MBO)* dalam bentuk *ranking*. Sumur potensi tertinggi sampai terendah berdasarkan *Color scale table* yang digunakan untuk dapat membantu

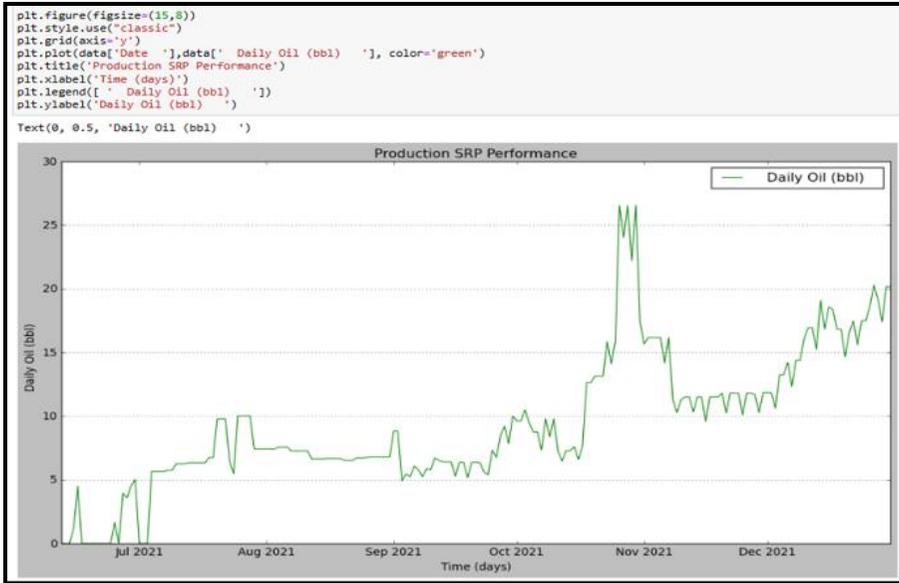
mengidentifikasi sumur yang tidak ekonomis dan sumur yang berpotensi untuk direaktivasi.

Evaluasi Kandidat Potensi Reaktivasi

Setelah Penentuan Sumur Reaktivasi berdasarkan model *decision tree*, maka dilakukan *Chan Diagnostic Plot* yang digunakan untuk menganalisis mekanisme produksi air dan gas yang berlebihan dalam sumur produksi minyak. Metode ini mengamati plot log-log antara *Water Oil Ratio (WOR)* dan *WOR derivative* terhadap waktu untuk mengetahui apakah terjadi *water coning*, *water channelling* atau *gas coning*, *Well Production History* untuk menganalisis kinerja, potensi, dan masalah yang terjadi pada sumur, *Decline Curve* digunakan untuk estimasi umur sumur, dan *Flowchart selection reactivation candidate* dapat dilihat lebih detail pada Lampiran A.6.



Gambar 4. 11 Water Chan Diagnostic



Gambar 4. 12 Well Production (Daily Oil (bbl))

BAB V PENUTUP

Dalam meningkatkan produksi pada lapangan tua (*Mature*), maka dilakukan pengembangan riset dan inovasi yang berfokus pada produksi *Idle well* (IW) pada lapangan *mature* untuk Peningkatan Perolehan Minyak dalam mewujudkan produksi minyak sebesar 1 juta barel per hari pada tahun 2030. Pada Lapangan Cepu, terdapat 11 struktur aktif (780 sumur) dan 39 struktur Non-Aktif (566 Sumur) dan terdapat dua ratus sepuluh (210) sumur *producer*, dua puluh (20) sumur *injector* dan tiga (3) sumur yang *P&A*, pada struktur aktif dan 385 sumur pada struktur non aktif, sehingga lapangan ini memiliki peluang untuk dilakukan peningkatan produksi dengan pemanfaatan *idle well*. Dalam penentuan kandidat sumur reaktivasi yang potential sesuai dengan pola kriteria dari model *decision tree*, didapatkan 2 kandidat sumur potential dari 618 *idle well*. Tahapan proses penentuan kandidat dilakukan *classification* dari model *decision tree* dan didapatkan kandidat potential, maka dilakukan evaluasi lebih lanjut dengan *chan diagnostic*, *well production performance*, dan *decline curve analysis*, pada kandidat sumur reaktivasi.

a. *Decision Tree Classifier Idle Well Reactivation*

Pada tahapan *Decision Tree Classifier Diagnostics Idle Well Reactivation* dilakukan untuk menganalisis sumur potensial dan tidak potensial dari data *IW Reactivation.xlsx*. Selanjutnya dilakukan beberapa proses dalam *classification* dari model *decision tree*, yakni *Diagnostics*, *Remove & Replace data*, *Labelencoder* (terdapat proses *Normalization*), *Confusion matrix*, *Entropy model*, *Accuracy Under Curve (AUC) score*, dan *Receiver Operating Curve (ROC)*.

Berdasarkan *implementasi dan hasil pengujian yang telah dilakukan, didapatkan 2 kandidat potential reaktivasi berdasarkan Lifting method (ESP) yaitu sumur NGL-P-001 dan TPN-004 yang dilihat dari Well Cum Prod (Np, MBO) dan HC Remaining Potential (Oil, MBO), serta issues explanation NGL-P-001 yakni lokasinya sudah sesuai, wellhead sudah di setujui, flowline sudah tersedia dengan program change to ESP tetapi menunggu pergerakan rig 350 HP, sedangkan issues explanation TPN-004 yakni lokasinya sudah sesuai, wellhead sudah di setujui tetapi menunggu perbaikan Jembatan oleh PEMDA (Database for Idle Wells Regional 4), dengan work description untuk kedua kandidat reaktivasi yaitu pump changes atau repair.*

Tahapan selanjutnya menetapkan pewarnaan baris berdasarkan nilai 'Well Cum Prod (Np, MBO)' dan 'HC Remaining Potential (Oil, MBO)' menggunakan ambang batas dan warna yang ditentukan dalam `scale_table`, ini mengulangi setiap baris `scale_table` untuk menentukan warna yang sesuai untuk setiap metrik, memungkinkan pendekatan yang fleksibel dan berbasis data untuk mewarnai DataFrame dengan kategori menengah ("Fair") dengan menghitung median (kuartil 0.25, 0.50, 0.75) untuk `Prod (Np, MBO)` dan `HC Remaining Potential (Oil, MBO)`. Kategori "Good" dan "Very Good" ditentukan oleh kuartil atas. Warnanya telah disesuaikan dengan menyertakan biru untuk kategori "Very Good", mempertahankan skema warna sebelumnya untuk kategori lainnya, pada aplikasi idle well reactivation dashboard. Hal ini juga dibuktikan dengan nilai AUC dan ROC sebesar 0.99 yang menunjukkan bahwa model klasifikasi mampu membedakan idle well yang layak atau tidak layak direaktivasi dengan baik.

b. Evaluation Chan Diagnostics

Evaluasi *chan diagnostics* didapatkan berdasarkan hasil dari *proses desicion tree classifier idle well* yang di dapatkan sumur TPN-004 yang berdasarkan *history* sumurnya aktif dari tahun 2018-2022 dan NGL-P-01 yang sumurnya terjadi *stuck production* 2018-2022, sehingga evaluasi ini hanya berfokus pada sumur TPN-004.

Hasil evaluasi bahwa sumur TPN-004 tahun 2018, 2019 dan 2021 menunjukkan indikasi Normal Displacement with High WOR, karena defleksi Derivate Water Oil Ratio (WOR*) curve dan Water Oil Ratio (WOR) menunjukkan pendesakan normal, dan WOR* tidak menunjukkan channeling ataupun coning dan pada tahun 2020 dan Tahun 2022 sumur menunjukkan indikasi Near Wellbore Water Channeling dapat tiba-tiba terjadi selama produksi dan pendesakkan normal. Pada awalnya WOR konstan dengan berjalannya waktu dengan harga WOR diatas 1. Kemudian WOR naik sangat cepat dengan slope sekitar 3.

c. Evaluation Well Production Performance

Evaluasi *well production performance* terhadap data *Gross (blpd)*, *Net (bopd)*, dan *water (bwpd)* dari sumur TPN-004 dari tahun 2018-2022 sebagai sumur potential dengan *well cumulative production (Np, MBO)* sebesar 132.2 MBO dan *HC Remaining Potential (Oil, MBO)* sebesar 52.42 MBO. Berdasarkan Gambar 5.33 - Gambar 5.37, yang dimana terjadi tren produksi yang fluktuasi perubahan volume produksi dengan *Gross production* dan *Net production* mengalami penurunan akan tetapi *watercut* mengalami peningkatan dan sumur tidak berproduksi pada waktu tertentu, dan ini juga bermanfaat untuk mengevaluasi kinerja sumur, mengidentifikasi masalah sumur

potential, merencanakan dan mengoptimalkan produksi minyak, serta membuat keputusan dalam pengembangan sumur.

d. Decline Curve Analysis

Penentuan jenis *decline curve* dilakukan dengan menggunakan metode *Fitting Curve*. Metode ini mirip dengan metode *trial and error*, untuk analisis penurunan perilaku produksinya dilakukan terhadap *decline curve* dengan asumsi variasi harga b antara 0 sampai 1, serta hasil penyesuaian empat model *decline* diterapkan didapatkan hasil dari model yang berbeda-beda terhadap data produksi.

a. Exponential

Nilai MSE sebesar 1147.32, RMSE sebesar 33.87, dan nilai R^2 sebesar 0.501.

b. Hyperbolic

Nilai MSE sebesar 1106.60, nilai RMSE sebesar 33.27, dan nilai R^2 sebesar 0.519. Model ini menyertakan koefisien *decline* negatif (b) sebesar -1.578, yang dapat mengindikasikan masalah dalam proses penyesuaian model, karena biasanya b diperkirakan berkisar antara 0 dan 1.

c. Harmonic

Nilai MSE sebesar 1201.24, nilai RMSE sebesar 34.66, dan nilai R^2 sebesar 0.478.

d. Stretched Exponential

Nilai MSE sebesar 1142.35, nilai RMSE sebesar 33.80, dan nilai R^2 sebesar 0.504. Model ini menyertakan koefisien beta sebesar 1,196. Model *Stretched Exponential* (SED) bisa digunakan untuk *decline curve analysis* (DCA). SED merupakan model yang lebih fleksibel dibandingkan model tradisional seperti *Arps hyperbolic decline*,

karena dapat memberikan perkiraan yang lebih akurat untuk produksi di masa depan, terutama untuk data dengan kompleksitas yang tinggi.

Initial Production Rate (q_i) setiap model ditentukan sekitar 151.3, *Initial Decline Rate* (d_i), dan *Decline Coefficient* (b atau β) bervariasi antar model. Berdasarkan hasil ini, model hiperbolik menunjukkan kesesuaian tertinggi dengan data observasi menurut nilai R^2 , meskipun dengan kekhawatiran terhadap nilai b negatifnya.

Empat model dari *decline* dengan *Exponential*, *Hyperbolic*, *Harmonic*, dan *Stretched Exponential*. Kesesuaian setiap model dihitung menggunakan parameternya masing-masing yang meminimalkan dengan *Mean Squared Error (MSE)* antara prediksi model dengan data sebenarnya. Terlihat jelas dari grafik Gambar 5.39, bahwa semua model memberikan kesesuaian yang serupa dengan data sebenarnya dan untuk memilih model terbaik, digunakan nilai MSE terendah yang, dimana semakin rendah MSE maka semakin baik kecocokannya dan model *Hyperbolic* dan *Stretched Exponential* dan menghasilkan nilai terendah, sehingga menunjukkan bahwa model tersebut mungkin paling sesuai di antara model-model yang dipertimbangkan. Hasil dari *forecast production rate vs cumulative oil production* digunakan untuk memprediksi produksi minyak di masa depan, dan didapatkan *cumulative oil* sebesar 4451.22 bbl.

DAFTAR PUSTAKA

- Ahmed, Tarek. 2010. Reservoir Engineering Handbook *Reservoir Engineering Handbook*.
- Alfarizi, Ardi, Nur Suhascaryo, and Boni Swadesi. 2023. “Technical and Economical Study on Increasing Oil Production in Old Wells (Traditional) by Performing Well Maintenance in the CP Field.” *Journal of Petroleum and Geothermal Technology* 4(1): 46.
- Amin Nizar, M. et al. 2019. “Reviving Idle Wells and Unlocking Potential Production Gain in Offshore Sarawak through Exposing BCO-LRLC Opportunities.” *International Petroleum Technology Conference 2019, IPTC 2019*.
- Ardi, Suhascaryo, and Swadesi, 2022. “Kajian Teknis Dan Ekonomis Peningkatan Produksi Minyak Pada Sumur Tua (Tradisional) Dengan Melakukan Perawatan Sumur Di Lapangan Cepu D.” Program Studi, Magister Teknik, and Fakultas Teknologi Mineral.
- Bangert, Patrick. 2019. “Diagnosing and Predicting Problems with Rod Pumps Using Machine Learning.” *SPE Middle East Oil and Gas Show and Conference, MEOS, Proceedings 2019-March(c)*: 1–13.
- Belyadi, Hoss, and Alireza Haghghat. 2021. Machine Learning Guide for Oil and Gas Using Python *Machine Learning Guide for Oil and Gas Using Python*.
- Bizhani, Majid, and Ergun Kuru. 2022. “Towards Drilling Rate of Penetration Prediction: Bayesian Neural Networks for Uncertainty Quantification.” *Journal of Petroleum Science and Engineering* 219(September): 111068. <https://doi.org/10.1016/j.petrol.2022.111068>.
- Chan, K. S. 1995. “Water Control Diagnostic Plots.” *Proceedings - SPE Annual Technical Conference and Exhibition Sigma*: 755–63.

- Desyta, Putri, Sugiatmo Kasmungin, and Djunaedi Agus Wibowo. 2018. "Analisa Perencanaan Reaktivasi Sumur Lapangan 'Pad' Untuk Zona 'A.'" *Jurnal Penelitian Dan Karya Ilmiah Lembaga Penelitian Universitas Trisakti* 3(2): 51–56.
- Ekpenyong, Victor, and Amieibibama Joseph. 2022. "Idle Wells Reactivation-The Kenyon International Story." *Society of Petroleum Engineers - SPE Nigeria Annual International Conference and Exhibition, NAIC 2022* (August): 1–11.
- Erazo-Bone, Romel et al. 2022. "Smart Solution To Selecting Artificial Lift And Improve Oil Production Using Machine Learning." *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology 2022-July*: 1–10.
- Fedriando, Fedriando et al. 2019. "New Perspective to Unlock Opportunities in Mature Field: Sanga-Sanga Block, Indonesia." *Society of Petroleum Engineers - SPE/IATMI Asia Pacific Oil and Gas Conference and Exhibition 2019, APOG 2019*: 1–12.
- Garcia, Carlos A., Akhan Mukhanov, and Henry Torres. 2019. "Chan Plot Signature Identification as a Practical Machine Learning Classification Problem." *International Petroleum Technology Conference 2019, IPTC 2019*: 1–19.
- Guo, Boyun; Lyons, William; Ghalambor, Ali. 2007. *Petroleum Production Engineering (A Computer-Assisted Approach)*.
- Guo, Boyun, Xinghui Liu, and Xuehao Tan. 2017. *Petroleum Production Engineering: Second Edition* *Petroleum Production Engineering: Second Edition*.
- Haryanto, Elin et al. 2019. "Standardization of Inactive Wells Audit Process."
- Hemmati-Sarapardeh, Abdolhossein. 2008. *Applications of Artificial Intelligence Techniques in the Petroleum Industry*.

- Iswahyudi, Christian. 2016. “Pengantar Forecasting (Teknik Peramalan).” : 1–10.
- Mirza, Mohammad Ali, Mahtab Ghoroori, and Zhangxin Chen. 2022. “Intelligent Petroleum Engineering.” *Engineering* 18: 27–32. <https://doi.org/10.1016/j.eng.2022.06.009>.
- Mukhanov, Akhan, Carlos Arturo Garcia, and Henry Torres. 2018. “Water Control Diagnostic Plot Pattern Recognition Using Support Vector Machine.” *Society of Petroleum Engineers - SPE Russian Petroleum Technology Conference 2018, RPTC 2018*.
- Peng, Yi, and Petrochina Riped. 2019. “SPE-196159-MS Artificial Intelligence Applied in Sucker Rod Pumping Wells: Intelligent Dynamometer Card Generation, Diagnosis, and Failure Detection Using Deep Neural Networks.” 2: 196159.
- Putra, Gatmasada Riandi, 2022. “Pemanfaatan Idle Well Sebagai Program Kerja Reaktivasi Dengan Metode Multi Screening Dan Rencana Optimasi Sucker Rod Pump Pada Lapangan Sangasanga.” Program Studi, Magister Teknik, and Fakultas Teknologi Mineral.
- Retno L.P. Marsud. 2021. “Laporan Kinerja.” *Laporan Kinerja Ditjen MIGAS* 53(9): 1689–99.
- Rubiandini, Rudi. 2009. “Teknik Operasi Pemboran I.”
- Verdhan, Vaibhav. 2020. Supervised Learning with Python *Supervised Learning with Python*.
- Villán, Alberto Fernández. 2019. 369 Journal of Petrology *Mastering OpenCV 4 with Python*.

ISBN 978-623-389-309-1



9 786233 893091