

**PREDIKSI WATER CONING PADA NATURAL FRACTURED  
CARBONATE RESERVOIR MENGGUNAKAN METODE  
ARTIFICIAL NEURAL NETWORK**

**TUGAS AKHIR**

*Diajukan guna melengkapi syarat dalam mencapai gelar Sarjana Teknik*

**Oleh**

**DESSY NANDISA PUTRI**

**NPM 153210115**



**PROGRAM STUDI TEKNIK PERMINYAKAN**

**UNIVERSITAS ISLAM RIAU**

**PEKANBARU**

**2021**

**PREDIKSI WATER CONING PADA NATURAL FRACTURED  
CARBONATE RESERVOIR MENGGUNAKAN METODE  
ARTIFICIAL NEURAL NETWORK**

**TUGAS AKHIR**

*Diajukan guna melengkapi syarat dalam mencapai gelar Sarjana Teknik*

**Oleh**

**DESSY NANDISA PUTRI**

**NPM 153210115**



**PROGRAM STUDI TEKNIK PERMINYAKAN**

**UNIVERSITAS ISLAM RIAU**

**PEKANBARU**

**2021**

## HALAMAN PENGESAHAN

Nama : Dessy Nandisa Putri  
NPM : 153210115  
Program Studi : Teknik Perminyakan  
Judul Tugas Akhir : Prediksi Water Coning Pada Natural Fractured Carbonate Reservoir Menggunakan Metode Artificial Neural Network

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai salah satu syarat guna memperoleh gelar Sarjana Teknik pada Program Studi Teknik Perminyakan, Fakultas Teknik, Universitas Islam Riau

### DEWAN PENGUJI

Pembimbing : Fiki Hidayat, S.T., M.Eng. (  )  
Penguji I : H. Dike Fitriansyah Putra, S.T., M.Sc., MBA (  )  
Penguji II : M. Ariyon, S.T., M.T. (  )

Ditetapkan di : Pekanbaru

Tanggal : 30 April 2021

### Disahkan Oleh:

KETUA PROGRAM STUDI

TEKNIK PERMINYAKAN

DOSEN PEMBIMBING

TUGAS AKHIR



Novia Rita, S.T., M.T



Fiki Hidayat, S.T., M.Eng

## **PERNYATAAN KEASLIAN TUGAS AKHIR**

Dengan ini saya menyatakan bahwa tugas akhir ini merupakan karya saya sendiri dan semua sumber yang tercantum didalamnya baik yang dikutip maupun dirujuk telah saya nyatakan dengan benar sesuai ketentuan. Jika terdapat unsur penipuan atau pemalsuan data maka saya bersedia dicabut gelar yang telah saya peroleh.

Pekanbaru, 22 April 2021

Dessy Nandisa Putri

153210115

Dokumen ini adalah Arsip Milik :

**Perpustakaan Universitas Islam Riau**

## KATA PENGANTAR

Rasa syukur saya ucapkan kepada Allah SWT berkat rahmat dan karunia-Nya sehingga penulis bisa menyelesaikan tugas akhir ini. Penulisan tugas akhir ini merupakan syarat terakhir untuk mendapatkan gelar Sarjana Teknik, Program Studi Perminyakan, Universitas Islam Riau. Banyak pihak yang telah membantu penulis dalam bentuk pengetahuan, materil maupun moral penulis dalam penyelesaian tugas akhir ini. Oleh sebab itu penulis ingin mengucapkan terimakasih sebesar-besarnya kepada:

1. Bapak Fiki Hidayat, S.T., M.Eng atau kerap disapa dengan Mas Fiki selaku dosen pembimbing dalam penulisan tugas akhir ini yang telah meluangkan banyak waktu, tenaga dan fikiran sehingga tugas akhir ini bisa selesai.
2. Bapak M. Ariyon, S.T., M.T., selaku dosen pembimbing akademik yang telah memberi arahan dan nasihat selama perkuliahan di Program Studi Teknik Perminyakan.
3. Ketua dan Sekretaris Program Studi Teknik Perminyakan serta dosen-dosen lainnya yang belum bisa saya sebutkan satu persatu dalam tugas akhir ini. Terimakasih telah membantu dan mengajari penulis selama masa perkuliahan.
4. Papa saya tercinta Nanang Harianto dan Mama saya Nur Elisa serta adik saya Mifta Rahma Alisha dan juga Keluarga Besar Darman yang tidak pernah berhenti mendoakan saya dan memberikan dukungan penuh baik secara material maupun moral.
5. Keluarga Petronass terkhususnya Bella, Atika, Tiwi, Mulyadi, Rianda, Harry, Lingga dan juga rekan saya Bang Rofiq, Habib, Kiki, Tengku, Bunga, Lianna, Rati yang senantiasa membantu saya tanpa kenal lelah.

Teriring do'a semoga Allah SWT memberi balasan atas segala kebaikan semua pihak yang telah membantu. Semoga tugas akhir ini membawa manfaat bagi pengembangan ilmu pengetahuan.

Pekanbaru, 22 April 2021

Dessy Nandisa Putri

## DAFTAR ISI

<b>HALAMAN PENGESAHAN .....</b>	<b>I</b>
<b>PERNYATAAN KEASLIAN TUGAS AKHIR .....</b>	<b>II</b>
<b>KATA PENGANTAR.....</b>	<b>III</b>
<b>DAFTAR ISI.....</b>	<b>IV</b>
<b>DAFTAR GAMBAR.....</b>	<b>VII</b>
<b>DAFTAR TABEL .....</b>	<b>VIII</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>IX</b>
<b>DAFTAR SINGKATAN.....</b>	<b>X</b>
<b>DAFTAR SIMBOL .....</b>	<b>XI</b>
<b>RINGKASAN .....</b>	<b>XII</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Tujuan Penelitian .....	3
1.3 Manfaat Penelitian .....	3
1.4 Batasan Masalah.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>15</b>
3.1 Metodologi .....	15
3.2 Karakteristik Reservoir .....	16
3.3 Model Simulasi Reservoir.....	17
3.4 Pemodelan <i>Artificial Neural Network</i> .....	19
3.5 Tempat dan Jadwal Penelitian.....	20
3.6 Diagram Alir Penelitian .....	21
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>22</b>
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>31</b>
5.1 Kesimpulan .....	31
5.2 Saran.....	31
<b>DAFTAR PUSTAKA .....</b>	<b>32</b>
<b>LAMPIRAN.....</b>	<b>36</b>

## DAFTAR GAMBAR

<b>Gambar 2.1</b> Fenomena <i>Water Coning</i> .....	6
<b>Gambar 2.2</b> Perbandingan Zona Transisi <i>Natural Fractured Reservoir</i> dengan <i>Reservoir Conventional</i> .....	7
<b>Gambar 2.3</b> Model <i>Fracture</i> oleh Warren dan Root .....	8
<b>Gambar 2.4</b> Efek permeabilitas matriks dan <i>fracture</i> dalam arah horizontal dan vertikal terhadap waktu tembus air dan <i>water</i> .....	9
<b>Gambar 2.5</b> Efek porositas matriks dan <i>fracture</i> terhadap waktu tembus air dan <i>water cut</i> .....	10
<b>Gambar 2.6</b> Skematik Struktur <i>Artificial Neural Network</i> .....	13
<b>Gambar 4.1</b> Pengaturan parameter <i>input</i> pada CMOST .....	23
<b>Gambar 4.2</b> <i>Coefficient of Determination</i> ( $R^2$ ) pada data <i>training</i> dengan 12 <i>hidden nodes</i> .....	26
<b>Gambar 4.3</b> <i>Coefficient of Determination</i> ( $R^2$ ) pada data <i>testing</i> dengan 12 <i>hidden nodes</i> .....	27
<b>Gambar 4.4</b> <i>Coefficient of Determination</i> ( $R^2$ ) pada data <i>training</i> dengan 1 <i>hidden nodes</i> .....	27
<b>Gambar 4.5</b> <i>Coefficient of Determination</i> ( $R^2$ ) pada data <i>testing</i> dengan 1 <i>hidden nodes</i> .....	28
<b>Gambar 4.6</b> Grafik <i>Water Cut</i> terhadap Waktu dalam skala harian ( <i>days</i> ) .....	30

## DAFTAR TABEL

<b>Tabel 2.1</b> Perkembangan Prediksi <i>Water Coning</i> .....	11
<b>Tabel 2.2</b> Kelebihan dan Kekurangan <i>Artificial Neural Network</i> .....	14
<b>Tabel 3.1</b> Reservoir <i>Properties</i> .....	16
<b>Tabel 3.2</b> Matriks <i>Properties</i> .....	16
<b>Tabel 3.3</b> <i>Fracture Properties</i> .....	17
<b>Tabel 3.4</b> <i>Fluid Properties</i> .....	17
<b>Tabel 3.5</b> Hasil Inisialisasi dari Simulasi .....	18
<b>Tabel 3.6</b> Data <i>Range Settings</i> .....	19
<b>Tabel 3.7</b> Jadwal Penelitian.....	20
<b>Tabel 4.1</b> Nilai <i>Coefficient of Determination (R<sup>2</sup>)</i> , <i>Root Mean Square Error</i> (RMSE) dan <i>Mean Absolute Percentage Error</i> (MAPE) pada <i>hidden nodes</i> yang berbeda .....	25

## DAFTAR LAMPIRAN

<b>Lampiran I.</b> Data hasil prediksi 12 <i>hidden nodes</i> untuk data <i>training</i> dan data <i>testing</i> .....	36
<b>Lampiran II.</b> Pengolahan data untuk <i>Experiment ID</i> 223 menggunakan Ms. Excel .....	42
<b>Lampiran III.</b> <i>Coding</i> yang digunakan pada <i>Artificial Neural Network – Back Propagation</i> menggunakan <i>Programming Language Python</i> .....	44

## DAFTAR SINGKATAN

<i>NFCR</i>	<i>Natural Fractured Carbonate Reservoir</i>
<i>ANN</i>	<i>Artificial Neural Network</i>
<i>CMG</i>	<i>Computer Modelling Group</i>
<i>R<sup>2</sup></i>	<i>Coefficient of Determination</i>
<i>RMSE</i>	<i>Root Mean Square Error</i>
<i>MAPE</i>	<i>Mean Absolute Percentage Error</i>
<i>DoE</i>	<i>Design of Experiment</i>
<i>AI</i>	<i>Artificial Intelligence</i>
<i>tBT</i>	<i>Breakthrough Time</i>
<i>PSO</i>	<i>Particle Swarm Optimization</i>
<i>mD</i>	<i>Mili Darcy</i>
<i>STB</i>	<i>Stock Tank Barrel</i>
<i>SCF</i>	<i>Standar Cubic Feet</i>
<i>Cp</i>	<i>Centipoise</i>
<i>Ft</i>	<i>Feet</i>
<i>FN</i>	<i>Fracture Number</i>
<i>Swc</i>	<i>Connate Water Saturation</i>
<i>Sor</i>	<i>Residual Oil Satration</i>
<i>hp</i>	<i>Heigh of Completion Interval</i>
<i>hap</i>	<i>Height Above Perforation</i>
<i>hwb</i>	<i>Breakthrough Height (Cone Height)</i>

## DAFTAR SIMBOL

$\phi_m$	<i>Porositas Matriks</i>
$\phi_f$	<i>Porositas Fracture</i>
$k_{fh}$	<i>Permeabilitas Horizontal Fracture</i>
$k_{fv}$	<i>Permeabilitas Vertikal Fracture</i>
$k_{mh}$	<i>Permeabilitas Horizontal Matriks</i>
$k_{mv}$	<i>Permeabilitas Vertikal Matriks</i>
$q$	<i>Laju Alir</i>
$h$	<i>Ketebalan Zona Minyak</i>
$\mu$	<i>Viskositas</i>
$\rho$	<i>Densitas</i>
$M$	<i>Mobility Ratio</i>
$\Delta\rho$	<i>Water-Oil Density Difference</i>
$Bo$	<i>Oil Formation Volume Factor</i>

# **PREDIKSI WATER CONING PADA NATURAL FRACTURED CARBONATE RESERVOIR MENGGUNAKAN METODE ARTIFICIAL NEURAL NETWORK**

**DESSY NANDISA PUTRI  
NPM 153210115**

## **ABSTRAK**

Tingginya produksi air menjadi salah satu permasalahan utama di industri minyak dan gas bumi. Terbukti di tahun 2017, Al – Azmi melaporkan bahwa produksi air setiap harinya di seluruh dunia mencapai 300 juta barrel dibandingkan dengan produksi minyak yang hanya 80 juta barrel. Fenomena *Water Coning* menjadi salah satu penyebab tingginya produksi air terutama pada *Natural Fractured Carbonate Reservoir* (NFCR). Kehadiran permeabilitas *fracture* menciptakan jalur *permeable* utama sehingga *water breakthrough time* terjadi lebih awal. Meskipun NFCR mengandung hampir 60% cadangan minyak dan 40% cadangan gas namun akibat tingginya jumlah produksi air menyebabkan sumur produksi mati lebih awal tanpa perolehan minyak yang optimum. Oleh karena itu, pada penelitian ini dilakukan prediksi *water coning* melalui *water breakthrough time* pada NFCR sehingga diharapkan terciptanya skema produksi yang optimum agar sumur produksi di NFCR dapat bertahan lebih lama.

Penelitian ini diawali dengan membangun 225 eksperimen dari 6 parameter yaitu permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* dan porositas matriks dan *fracture* sebagai parameter paling dominan terhadap fenomena *water coning* di NFCR. Pembuatan 225 eksperimen menggunakan *Design of Experiment* (DoE) pada *Computer Modelling Group* (CMG - CMOST) software dengan *Water Cut* sebagai respon parameter. Kemudian prediksi *water coning* dilakukan dengan *Artificial Neural Network* berdasarkan validasi keakuratan dari *Coefficient of Determination* ( $R^2$ ) menggunakan *Programming Language Python*.

Berdasarkan hasil penelitian yang telah dilakukan, *Artificial Neural Network* menghasilkan prediksi *water coning* yang akurat dengan waktu yang juga relatif lebih singkat. Melalui *Coefficient of Determination* untuk 12 *hidden nodes* pada *hidden layer*, diperoleh model akurasi senilai 0.998245 untuk data *training* dan 0.991375 untuk data *testing*. Sementara itu, *water breakthrough time* terjadi pada hari ke – 75 setelah sumur pertama kali diproduksikan di tahun 2020 dengan nilai *Water Cut* sebesar 42%. Hasil studi ini berpotensi membawa informasi terbarukan dalam industri minyak dan gas bumi khususnya implementasi *Artificial Neural Network* yang patut dipertimbangkan untuk digunakan dalam melakukan prediksi dengan tingkat keakuratan mencapai 0.913523.

**Kata Kunci :** *Water Coning, Natural Fractured Carbonate Reservoir, Fracture, Artificial Neural Network, Python*

# **WATER CONING PREDICTION IN NATURAL FRACTURED CARBONATE RESERVOIR USING ARTIFICIAL NEURAL NETWORK METHOD**

**DESSY NANDISA PUTRI  
NPM 153210115**

## **ABSTRACT**

*High water production is one of the main problems in the oil and gas industry. Proven in 2017, Al - Azmi reported that daily water production worldwide reached 300 million barrels compared to oil production of only 80 million barrels. The phenomenon Water Coning is one of the causes of high water production, especially in the Natural Fractured Carbonate Reservoir (NFCR). The presence of the permeability fracture creates a pathway permeable major so that the water breakthrough time occurs earlier. Although NFCR contains almost 60% oil reserves and 40% gas reserves, due to the high amount of water production the production wells die early without optimum oil recovery. Therefore, in this study prediction of water coning through water breakthrough time on NFCR is carried out so that it is hoped that an optimal production scheme will be created so the production wells in NFCR can last longer.*

*This research begins by constructing 225 experiments from 6 parameters, namely horizontal matrix and fracture permeability, vertical matrix and fracture permeability and matrix and fracture porosity as the most dominant parameters of the phenomenon water coning in NFCR. Making 225 experiments using the Design of Experiment (DoE) in the Computer Modeling Group (CMG - CMOST) software with Water Cut as a response parameter. Then the prediction water coning made by Artificial Neural Network based validation of the accuracy of the Coefficient of Determination ( $R^2$ ) using the Programming Language Python.*

*Based on the results of the research that has been done, the Artificial Neural Network produces accurate water coning predictions in a relatively shorter time. Through the Coefficient of Determination for 12 hidden nodes in the hidden layer, an accuracy model of 0.998245 is obtained for data training and 0.991375 for data testing. Meanwhile, the water breakthrough time occurred on the 75th day after the well was first produced in 2020 with a value Water Cut of 42%. The results of this study have the potential to bring renewable information in the oil and gas industry, especially the implementation of the Artificial Neural Network which should be considered for use in making predictions with an accuracy of 0.913523.*

**Key Words :** Water Coning, Natural Fractured Carbonate Reservoir, Fracture, Artificial Neural Network, Python

# BAB I PENDAHULUAN

## 1.1 Latar Belakang

Salah satu permasalahan utama di industri minyak dan gas bumi adalah tingginya produksi air (Okon, Appah, & Akpabio, 2018). Berbagai laporan menunjukkan tingginya jumlah air yang terproduksi dibandingkan dengan hidrokarbon yang dihasilkan (Arslan, 2005). Schlumberger (2004) melaporkan bahwa 75% dari total produksi minyak bumi hanya air yang setara dengan 220 juta barel air per hari di seluruh dunia. Di tahun 2017, produksi air setiap harinya di seluruh dunia semakin meningkat mencapai 300 juta barel dibandingkan dengan produksi minyak yang hanya 80 juta barel (Al-Azmi, Aladwani, & Kasaraneni, 2017).

Produksi air yang tinggi umumnya terjadi pada reservoir yang memiliki zona aquifer dibawahnya (*bottom water drive*) (Okon, Appah, & Akpabio, 2018). Pada reservoir dengan *strong bottom water drive*, produksi minyak dari sumur akan menyebabkan ketidakseimbangan antara gaya gravitasi dan viskositas di sekitar interval perforasi (Namani & Asadollahi, 2007; Shadizadeh & D.Ghorbani, 2001). Ketidakseimbangan tersebut mengakibatkan perubahan tekanan disekitar lubang sumur (Okon, Appah, & Akpabio, 2018; Shadizadeh & D.Ghorbani, 2001). Perubahan tekanan ini cenderung meningkatkan *water-oil contact* dengan cepat dan mengubah bentuk *water-oil contact* menjadi kerucut (*water cone*) (Okwananke & Isehunwa, 2008; Ahmed, 2006). Ketika *water cone* menembus bagian bawah interval perforasi maka fenomena ini yang dikenal dengan istilah *water coning* (Safari & Ameri, 2019).

Namun, *water coning* cenderung lebih cepat terjadi di *natural fractured carbonate reservoir* (NFCR) (Golf-Racht & Sonier, 1994). Ini disebabkan karena sifat fisik batuan dan sifat fisik fluida yang terkandung di dalam NFCR (Perez-Martinez & Garza, 2012). *Natural fractured carbonate reservoir* merupakan batuan reservoir dengan *dual-permeability systems* yaitu permeabilitas matriks dan juga permeabilitas *fracture* (Narr, 2006;

Nelson, 2001). Kehadiran *fracture* dengan ciri khas permeabilitas yang tinggi dan porositas yang rendah inilah sebagai penyebab *water coning* lebih cepat terjadi pada reservoir jenis ini. (Abu-Hassoun, 2007). Padahal, reservoir jenis ini mengandung sejumlah besar hidrokarbon yang masih menjadi sumber energi bahan bakar terpenting saat ini (Ramirez, Kazemi, Al-Kobaisi, Ozkan, & Atan, 2007). Ahmed (2010) juga menyatakan bahwa lebih dari 60% cadangan minyak dan 40% cadangan gas terperangkap di *natural fractured carbonate reservoir*. Akan tetapi, produksi air yang tinggi di *natural fractured carbonate reservoir* menyebabkan produksi minyak dari reservoir jenis ini masih agak rendah (Ramirez, Kazemi, Al-Kobaisi, Ozkan, & Atan, 2007). Jumlah produksi air yang tinggi di *natural fractured carbonate reservoir* juga dapat menyebabkan sumur produksi mati lebih awal tanpa perolehan minyak yang optimum (Jin, Wojtanowicz, & Hughes, 2010).

Menanggapi hal tersebut, memprediksi *water coning* di *natural fractured carbonate reservoir* dinilai sebagai solusi praktis untuk permasalahan tersebut. Pada dasarnya, terdapat tiga korelasi yang digunakan sebagai solusi permasalahan *water coning*, salah satunya melalui prediksi *water breakthrough time* (Ahmed, 2010). Penelitian terkait memprediksikan *water coning* melalui *water breakthrough time* telah dilakukan sejak tahun 1965 hingga 2016 oleh para peneliti sebelumnya. Namun, berdasarkan literatur yang telah dipublikasikan penelitian tersebut hanya menggunakan metode *empirical*, *analytical* dan *numerical simulation* (Okon, Appah, & Akpabio, 2018). Ahamdi et al (2013) telah memprediksi *water coning* melalui *water breakthrough time* dengan metode terbarukan. Ahamdi et al menggunakan metode *hybrid*. Dikutip dari Wuryandari & Afrianto (2012) metode *hybrid* adalah kombinasi dari dua metode *Artificial Intelligence*. Dalam hal ini, Ahamdi et al mengkombinasikan *Artificial Neural Network* dan *Fuzzy Logic* dengan menggunakan *low* parameter (laju alir, kedalaman, viskositas dan *fracture number*) sebagai data *input* (Ahamdi, Ebadi, & Hosseini, 2013).

Berdasarkan latar belakang diatas, peneliti tertarik untuk memprediksi *water coning* melalui *water breakthrough time* dengan menggunakan metode *Artificial Neural Network* (ANN). Penelitian ini juga berfokus pada *high* parameter sebagai data *input*. Dalam hal ini, *high* parameter yang dimaksud adalah permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan *fracture* (Namani & Asadollahi, 2007). *Artificial Neural Network* akan mempelajari kinerja dari *high* parameter tersebut dan dapat memprediksikan *water breakthrough time* dalam waktu yang relatif lebih singkat dan hasil yang lebih akurat dengan melakukan 80% *training* dan 20% *testing* pada data *input* (Zendehboudi, Elkamel, & Chatzis, 2014), sehingga memberikan kesempatan dalam merencanakan skema produksi dari sumur di *natural fractured carbonate reservoir* agar bertahan lebih lama. Pengaplikasian *Artificial Neural Network* menggunakan *software* Anaconda Navigator 3.0 dengan *programming language* Python yang mana sebelumnya pemodelan *natural fractured carbonate reservoir* telah diintepretasikan menggunakan *simulation software* (CMG-IMEX) dan skenario data simulasi atau *Design of Experiment* (Doe) yang telah dirancang menggunakan CMOST.

### 1.2 Tujuan Penelitian

Berdasarkan latar belakang diatas, adapun tujuan penelitian tugas akhir ini adalah memprediksi *water coning* melalui *water breakthrough time* dengan permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan *fracture* sebagai data *input* menggunakan metode *Artificial Neural Network* sehingga tercipta skema produksi yang optimum agar sumur produksi di *natural fractured carbonate reservoir* dapat bertahan lebih lama.

### 1.3 Manfaat Penelitian

Adapun manfaat dari penelitian tugas akhir ini adalah:

1. Memperoleh informasi mengenai prediksi *water coning* melalui *water breakthrough time* di *natural fractured carbonate reservoir* dengan

- permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan *fracture* sebagai data *input*.
2. Dapat dijadikan publikasi ilmiah yang berskala nasional maupun internasional sehingga dapat dijadikan referensi untuk penelitian selanjutnya.

#### 1.4 Batasan Masalah

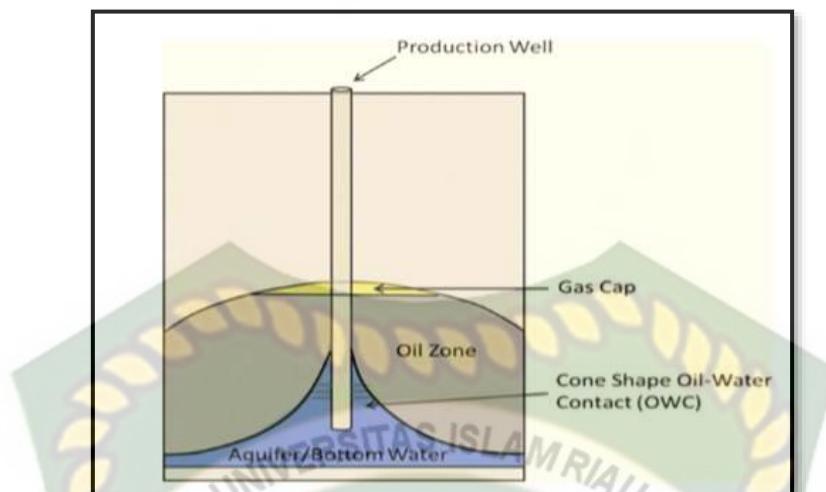
Untuk mendapatkan hasil penelitian yang lebih terarah dan tidak menyimpang dari tujuan yang dimaksud, maka dalam penelitian tugas akhir ini dibatasi pada beberapa hal sebagai berikut:

1. Penelitian ini menggunakan *Reservoir Simulation Software CMG-IMEX* dan *Programming Language Python*.
2. Algoritma yang digunakan dalam penelitian ini adalah *Artificial Neural Network – Back Propagation*.
3. Penelitian ini menggunakan *high* parameter sebagai data *input* yaitu permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan porositas *fracture*.
4. Penelitian dilakukan tanpa adanya pertimbangan *oil production history* dan analisis ekonomi.
5. Penelitian dilakukan dengan menggunakan satu sumur produksi dengan arah vertikal.
6. Penelitian ini tidak mempertimbangkan performa sumur setelah terjadinya *water coning*.

## BAB II TINJAUAN PUSTAKA

*Water Coning* merupakan suatu istilah yang mendeskripsikan fenomena naiknya air dari aquifer membentuk kerucut menuju bagian bawah lubang perforasi pada sumur produksi (Safari & Ameri, 2019). Kekuatan air dari aquifer tersebut juga menyebabkan waktu tembus air (*breakthrough time*) terjadi lebih awal, sehingga peningkatan jumlah air terproduksi menjadi lebih cepat dan dapat mendominasi jumlah total produksi fluida dari reservoir (Ahamdi, Ebadi, & Hosseini, 2013). Secara umum, *water coning* disebabkan oleh ketidakseimbangan antara gaya gravitasi dan viskositas di sekitar interval perforasi (Perez-Martinez & Garza, 2012). Menurut Ahmed (2010), pengertian gaya gravitasi mengacu pada perbedaan densitas fluida di reservoir sehingga memberikan arah vertikal secara langsung terhadap sumur produksi. Sementara itu, viskositas didefinisikan sebagai hubungan antara gradien tekanan dengan kemampuan fluida untuk mengalir melalui reservoir ( $\mu$ ) sebagaimana dijelaskan oleh Hukum Darcy.

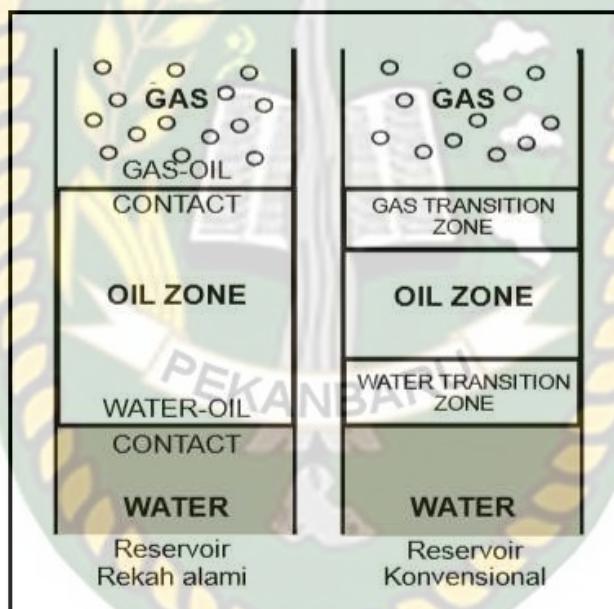
Okwananke et al (2008) menjelaskan bahwa pada mulanya, sebelum sumur berproduksi gaya gravitasi menjadi gaya yang paling dominan dalam mempengaruhi aliran fluida di sumur. Namun, ketika sumur mulai memproduksikan minyak gaya viskositas akan menjadi lebih besar dibanding gravitasi ( $\mu > \rho$ ) sehingga terjadi perubahan gradien tekanan dan juga perubahan aliran fluida menjadi *pseudo-steady state*. Gradien tekanan cenderung meningkatkan *water-oil contact* disekitar sumur dengan cepat kemudian mengubah bentuk *water-oil contact* menjadi kerucut (*water cone*). Ketika *water cone* menembus bagian bawah interval perforasi (*water breakthrough time*) maka *water coning* pun terjadi di sumur produksi.



**Gambar 2.1** Fenomena Water Coning (Zendehboudi, Elkamel, & Chatzis, 2014)

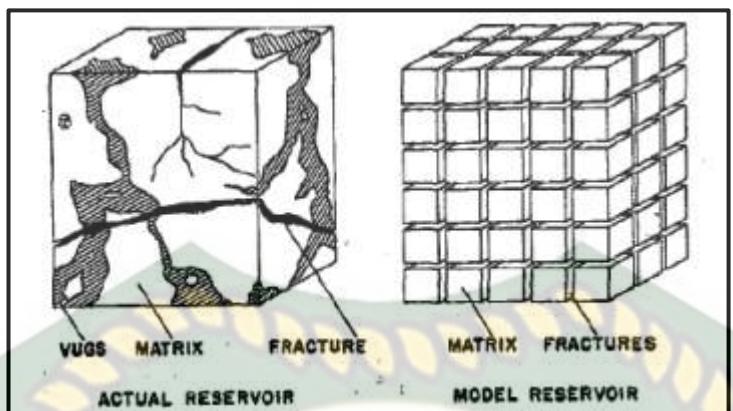
Akan tetapi, kecenderungan *water coning* lebih cepat terjadi di *natural fractured carbonate reservoir* karena bergantung pada sifat fisik batuan dan juga sifat fisik fluida. NFCR dicirikan dengan sistem matriks yang mana setiap matriks dikelilingi oleh *fracture* (Abu-Hassoun, 2007). Adanya *fracture* menciptakan jalur permeabel utama dengan nilai permeabilitas yang tinggi dan volume penyimpanan yang rendah. Sementara matriks sebagai sumber dari hidrokarbon dengan permeabilitas yang rendah dan volume penyimpanan yang besar (Abu-Hassoun, 2007; Ramirez, Kazemi, Al-Kobaisi, Ozkan, & Atan, 2007). Birks mengemukakan bahwa pada umumnya *fracture* yang berukuran 1 mm terjadi setiap 1 ft pada batuan reservoir, maka pertambahan volume pori 1% dan hanya 0.1% apabila *fracture* tersebut terjadi setiap 10 ft. Namun, kontribusi *fracture* terhadap permeabilitas batuan sangat besar. Baker melaporkan bahwa satu celah *fracture* berukuran 0.01 inch (0.254 mm) ekuivalen dengan suatu formasi yang mempunyai permeabilitas 10 md. Karena hal tersebut, maka kehadiran *fracture* dengan nilai permeabilitas yang tinggi inilah sebagai penyebab utama terjadinya *water coning* di NFCR. Ditambah lagi dengan kondisi batuan *carbonate* yang cenderung bersifat *oil wet* (Tobing & Eni, 2013) menjadikan air lebih cepat bergerak menuju *fracture* dan menembus bagian bawah interval perforasi pada sumur produksi.

Selanjutnya, penyebab *water coning* di NFCR adalah tidak adanya zona transisi yang jelas pada reservoir tipe ini (Yasutra, Sukarno, & Mucharam, 2005). Pada kenyataannya, batas antara air dan minyak pada NFCR hanya merupakan garis horizontal baik dalam keadaan statis maupun dinamis. Seperti yang telah diketahui, bahwa dalam keadaan dinamis terjadi perubahan gradien tekanan yang akan mengubah bentuk *water-oil contact* menjadi *water cone*. Tanpa adanya zona transisi yang jelas antara air dan minyak di NFCR maka perubahan gradien tekanan akan semakin cepat juga mengubah bentuk *water-oil contact* di NFCR menjadi *water cone* sehingga air akan semakin cepat menembus bagian bawah interval perforasi (*water breakthrough time*).



**Gambar 2.2** Perbandingan Zona Transisi *Natural Fractured Reservoir* dengan Reservoir *Conventional* (Yasutra, Sukarno, & Mucharam, 2005)

Di tahun 1973, Warren dan Root melakukan investigasi terhadap mekanisme aliran fluida di NFCR. Warren dan Root mengasumsikan bahwa aliran fluida yang terkandung di dalam matriks bergerak menuju *fracture* dan kemudian hanya *fracture* yang mampu mengalirkan fluida menuju sumur produksi (Abu-Hassoun, 2007). Adapun model matriks dan *fracture* yang dikembangkan oleh Warren dan Root sebagai berikut



**Gambar 2.3** Model *Fracture* oleh Warren dan Root (*Abu-Hassoun, 2007*)

Dengan menganalisa respon tekanan terhadap fungsi waktu, Warren dan Root memperoleh 2 parameter utama dalam mekanisme aliran fluida di NFCR. Parameter ini juga dikenal dengan *high* parameter karena memiliki peranan yang sangat dominan terhadap fenomena *water coning* di NFCR. Adapun 2 parameter tersebut adalah sebagai berikut:

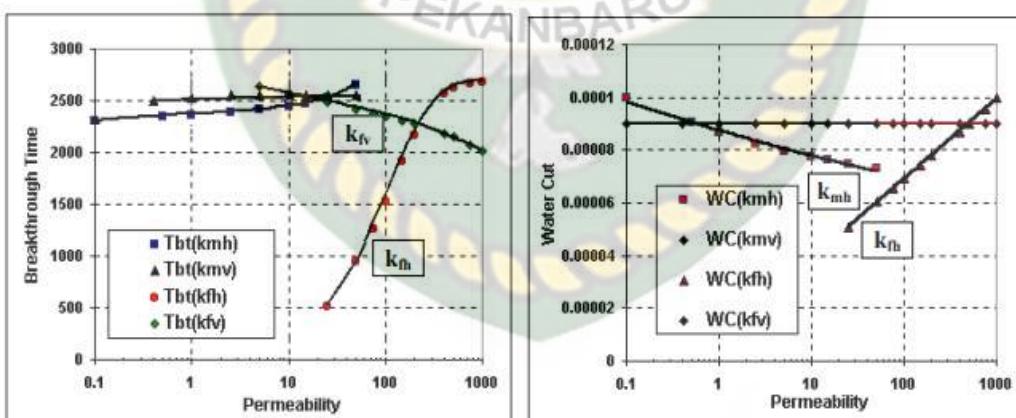
1. Permeabilitas (k)

Permeabilitas merupakan sifat fisik batuan yang menentukan kapasitas dan kemampuan batuan untuk mengalirkan fluida (Ahmed, 2010). Pada *natural fractured carbonate reservoir* yang dikenal dengan *dual-permeability systems* memiliki permeabilitas matriks dan juga permeabilitas *fracture* baik dalam arah horizontal maupun vertikal (Moradi, Dastkhan, Roozbehani, & Montazeri, 2010). Menurut Perez-Martinez (2012), permeabilitas *fracture* merupakan parameter paling penting dalam fenomena *water coning* di NFCR. Permeabilitas *fracture* didefinisikan sebagai kemampuan *fracture* untuk mengalirkan fluida dari matriks menuju lubang sumur. Menurut Golf-Racht et al (1994), dari hasil pengujian sumur permeabilitas *fracture* dapat dihitung dengan persamaan berikut

$$K_f = \frac{1.15 \left[ \frac{q \cdot \mu_o \cdot B_o}{2\pi h} \right]}{m} \quad \dots (2)$$

Bahrami et al (2004) melakukan penelitian berkenaan dengan efek permeabilitas terhadap fenomena water coning di NFCR. Dengan

menggunakan 5 skenario untuk tiap-tiap permeabilitas matriks dan *fracture* dalam arah horizontal maupun vertikal. Hasil penelitian menunjukkan bahwa peningkatan permeabilitas horizontal *fracture* mampu menunda pembentukan *water cone* karena distribusi fluida akan bergerak ke arah horizontal namun akan meningkatkan *water cut* setelah terjadinya *breakthrough*. Sedangkan peningkatan permeabilitas vertikal *fracture* menyebabkan waktu tembus air terjadi lebih awal namun tidak berdampak terhadap *water cut*. Berdasarkan Gambar 2.4 menunjukkan bahwa waktu tembus air (*water breakthrough time*) dominan dipengaruhi oleh permeabilitas horizontal *fracture* dan permeabilitas vertikal *fracture*. Namun, peningkatan nilai *water cut* dominan dipengaruhi oleh permeabilitas horizontal *fracture* dan permeabilitas horizontal matriks. Hal ini linear dengan mekanisme terjadinya *water coning* di NFCR. Permeabilitas *fracture* sebagai jalur permeabel utama menyebabkan waktu tembus air relatif terjadi lebih awal sementara permeabilitas matriks dengan kemampuan untuk mengalirkan fluida dari porositas matriks tentu akan mendukung peningkatan nilai *water cut* di *natural fractured carbonate reservoir* karena porositas matriks memiliki kapasitas yang sangat besar untuk menyimpan fluida.



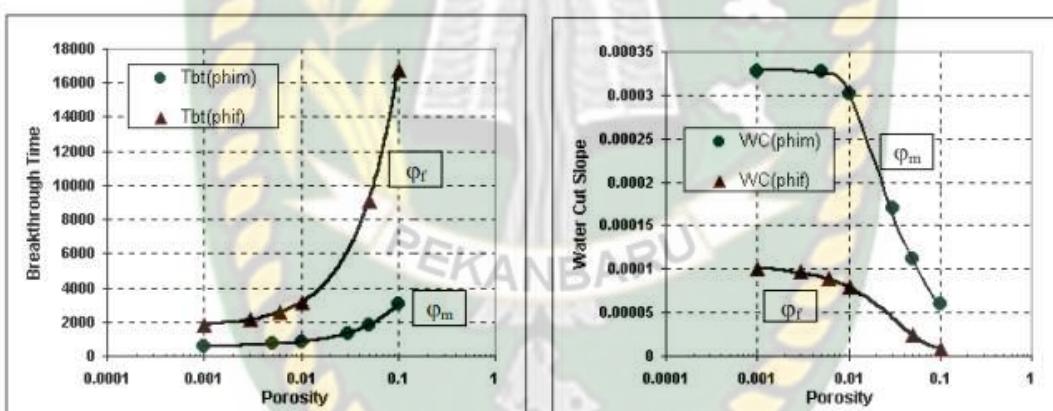
**Gambar 2.4** Efek permeabilitas matriks dan *fracture* dalam arah horizontal dan vertikal terhadap waktu tembus air dan *water cut* (Bahrami, Shadizadeh, & Goodarzniya, 2004)

## 2. Porositas ( $\emptyset$ )

Porositas batuan didefinisikan sebagai kemampuan pori batuan untuk menyimpan fluida (*storage capacity*) (Ahmed, 2010). Di *natural fractured*

*carbonate reservoir* juga memiliki *dual-porosity* yaitu porositas matriks dan juga porositas *fracture*. Dalam hal ini, matriks bertindak sebagai porositas primer yang homogen dan *isotropic* (Abu-Hassoun, 2007).

Kembali mengulas penelitian yang dilakukan Bahrami et al (2004) terkait efek porositas terhadap fenomena *water coning* di NFCR. Dengan tetap menggunakan 5 skenario untuk masing-masing porositas matriks dan porositas *fracture* diperoleh hasil penelitian bahwa waktu tembus air (*water breakthrough time*) dipengaruhi oleh peningkatan nilai porositas *fracture* sementara *water cut* dipengaruhi oleh peningkatan nilai porositas matriks. Hal ini kembali selaras dengan pernyataan (Narr, 2006) bahwa matriks memiliki *bulk porosity* yang besar sehingga memiliki kapasitas penyimpanan yang besar didukung dengan permeabilitas matriks maka semakin meningkatkan nilai *water cut* di NFCR.



**Gambar 2.5** Efek porositas matriks dan *fracture* terhadap waktu tembus air dan *water cut* (Bahrami, Shadizadeh, & Goodarzniya, 2004)

Upaya untuk mendiagnosis permasalahan fenomena *water coning* di sumur produksi telah banyak dilakukan (Appah, 2005). Salah satu korelasi yang digunakan untuk mendiagnosis fenomena *water coning* adalah memprediksi *water breakthrough time* atau dikenal juga dengan waktu tembus air (Ahmed, 2010). *Water breakthrough time* didefinisikan sebagai periode waktu tertentu ketika air dari aquifer mulai menembus bagian bawah interval perforasi (T.H, Y.H, & H.M, 2011). Pada dasarnya, diagnosis terkait memprediksi *water breakthrough time* telah dilakukan sejak tahun 1965

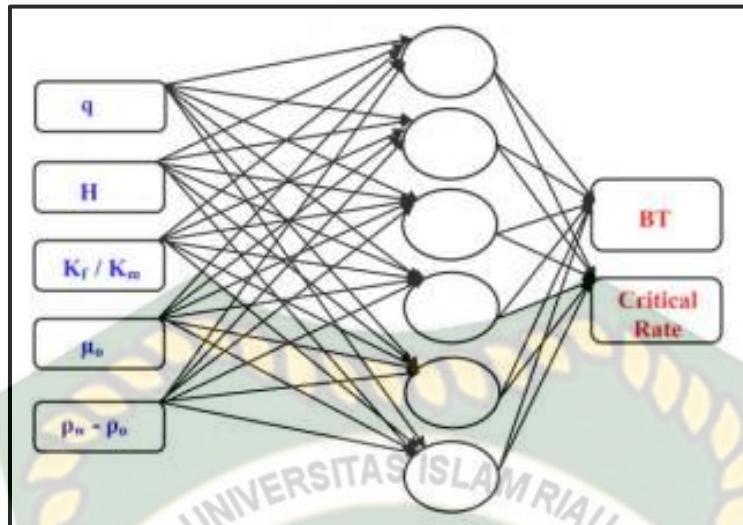
hingga 2016. Berikut peneliti telah merangkum perkembangan penelitian terkait prediksi *water breakthrough time* di sumur vertikal dengan berbagai metode yang digunakan.

**Tabel 2.1** Perkembangan Prediksi *Water Coning*

Peneliti	Metode dan Korelasi
(Sobocinski & Cornelius, 1965)	<p>Empirical  (Sobocinski &amp; Cornelius, 1965) melakukan penelitian berdasarkan data laboratorium di sumur vertikal dengan 2 dimensi parameter yaitu ketinggian <i>water cone</i> dan <i>breakthrough time</i>.</p> $t_{BT} = \frac{20.35\mu_0 \cdot h \cdot \phi \cdot (tD)_{BT}}{(\rho_w - \rho_o) \cdot kv \cdot (1 + M^\alpha)}$
(Bournazel & Jeanson, 1971)	<p>Empirical  (Bournazel &amp; Jeanson, 1971) mengembangkan dimensi parameter <i>breakthrough time</i> dari penelitian sebelumnya.</p> $(tD)_{BT} = \frac{Z}{3 - 0.7Z}$
(Yang & Wattenbarger, 1991)	<p>Analytical  (Yang &amp; Wattenbarger, 1991) mengasumsikan bahwa cara pergerakan air menuju sumur produksi sama dengan pendesakan minyak di piston.</p> $t_{bt} = \frac{\phi \cdot A \cdot (1 - Swc - Sor) [h - h_{wb} - h_{ap} - h]}{q}$
(Recham, Osisanya, & Touami, 2000)	<p>Numerical Simulation &amp; Regression Analysis  (Recham, Osisanya, &amp; Touami, 2000) menggunakan model 3D radial untuk memperoleh korelasi <i>water coning</i> di sumur vertikal.</p> $t_{bt} = 2996(1 + M)^{0.64} \left( \frac{1}{rED} \right)^{1.11} \left( \frac{1}{qD} \right)^{0.68} \left( 1 - \frac{hp}{ho} \right)^{0.65} \left( 1 - \frac{hbp}{ho} \right)^{1.4} \left( 1 - \frac{hap}{ho} \right)^{0.99}$
	Numerical Simulation & Regression Analysis

(Permadi, 2009)	(Permadi, 2009) menggunakan model 2D radial yang homogen dan <i>anisotropic</i> . Pemodelan <i>bottom water-influx</i> menggunakan persamaan dari Carter-Tracy.
	$tbt = 5.3 \times 10^{-2} \left( \frac{\phi^{1.021} \mu w^{0.511} r e^{0.424} k h^{0.745} h^{3.057} (\Delta \rho)^{0.124}}{\mu o^{0.615} q_o^{0.062} k v^{0.850} h p^{0.497} h a p^{0.455}} \right)$

Dewasa ini, metode baru dengan model statistik telah dikembangkan untuk memprediksi *water breakthrough time* di *natural fractured carbonate reservoir* (Kalam, Alnuaim, & Rammay, 2016). Metode baru tersebut menggunakan kecerdasan buatan atau yang dikenal dengan *Artificial Intelligence*. *Artificial Intelligence* memainkan peran penting dalam industri minyak dan gas bumi (Kalam, Alnuaim, & Rammay, 2016). *Artificial Intelligence* adalah bagian dari ilmu komputer yang mempelajari bagaimana membuat mesin (komputer) dapat melakukan pekerjaan seperti dan sebaik yang dilakukan oleh manusia bahkan bisa lebih baik daripada yang dilakukan manusia (Wuryandari & Afrianto, 2012). Pengaplikasian *Artificial Intelligence* dalam memprediksi *water coning* di NFCR pertama kali dilakukan di tahun 2013 oleh (Ahamdi, Ebadi, & Hosseini). *Artificial Neural Network* merupakan jenis *Artificial Intelligence* yang digunakan untuk menentukan *water breakthrough time*. *Artificial Neural Network* adalah sistem pemrosesan informasi yang memiliki karakteristik kinerja tertentu yang sama dengan jaringan saraf (Hizham, Nurdiansyah, & Firmansyah, 2018). *Artificial Neural Network* terdiri atas 3 susunan lapisan yaitu lapisan *input* (*input layer*) yang bertugas menerima data masukan dari variabel X, lapisan tersembunyi (*hidden layer*) yang berfungsi menerima data dari lapisan *input*, dan lapisan *output* (*output layer*) yang menerima data dari lapisan tersembunyi dan menghasilkan data *output* berupa hasil testing dari variabel X menjadi variabel Y (Julpan, Nababan, & Zarlis, 2015; Zendehboudi, Elkamel, & Chatzis, 2014).



**Gambar 2.6** Skematik Struktur *Artificial Neural Network* (Zendehboudi, Elkamel, & Chatzis, 2014)

Ahamdi et al (2013) memprediksi *water breakthrough time* di lapangan *Persian Oil Gulf* dengan menggunakan metode *Hybrid* yaitu kombinasi dari dua metode *Artificial Intelligence* (Wuryandari & Afrianto, 2012). Ahamdi et al (2013) mengkombinasikan *Artificial Neural Network* dan *Fuzzy Logic* dengan menggunakan *low* parameter sebagai data *input*. Variabel *input* tersebut adalah laju alir ( $q$ ), ketebalan zona minyak ( $h$ ), viskositas ( $\mu$ ) dan *fracture number* (FN).

Pengaplikasian *Artificial Neural Network* semakin berkembang. Pada tahun (2014), Zendehboudi et al kembali melakukan prediksi *water breakthrough time* dengan menerapkan ANN-PSO (*Artificial Neural Network - Particle Swarm Optimization*). Penerapan *Particle Swarm Optimization* dimaksudkan untuk meminimalkan nilai error. Penelitian ini juga menggunakan 3 variabel *input* yaitu laju alir ( $q$ ), ketebalan zona minyak ( $h$ ) dan perbandingan permeabilitas *fracture* terhadap permeabilitas matriks ( $k_f/k_m$ ) yang diterima oleh 7 neurons di lapisan tersembunyi (*hidden layer*) untuk menghasilkan 1 *output* yaitu *water breakthrough time*.

Penelitian terakhir terkait pengaplikasian *Artificial Neural Network* dilakukan di tahun (2016). Kalam et al menggunakan *Artificial Neural Network* untuk menggeneralisasikan laju alir kritis (*critical rate*) di

*hydraulically fractured tight oil reservoir*. Dengan menggunakan 7 variabel *input* yaitu konduktivitas *fracture*, permeabilitas reservoir, *anisotropic ratio*, densitas, *water-oil contact*, panjang *fracture* dan viskositas diperoleh nilai error kurang dari 5%. Hal ini menunjukkan bahwa prediksi menggunakan *Artificial Neural Network* lebih akurat dan sukses dikembangkan di industri minyak dan gas bumi (Kalam, Alnuaim, & Rammay, 2016).

Pengaplikasian *Artificial Neural Network* di berbagai bidang tak luput karena *Artificial Neural Network* memiliki berbagai kelebihan. Disamping itu, *Artificial Neural Network* juga memiliki kekurangan untuk beberapa kasus tertentu. Berikut peneliti tampilkan tabel kelebihan dan kekurangan *Artificial Neural Network* (Muzakkir, Syukur, & Dewi, 2014)

**Tabel 2.2** Kelebihan dan Kekurangan *Artificial Neural Network*

Kelebihan	Kekurangan
<i>Performance</i> yang sangat baik pada <i>parallel processing</i> dan kemampuan menoleransi kesalahan sehingga tepat untuk karakteristik data prediksi	Kurang efisien untuk karakteristik data optimasi sehingga memberikan hasil yang belum maksimal akurasinya
Dapat memecahkan problem <i>non-linear</i> yang umum dijumpai di aplikasi	Laju konvergensi yang lambat dibanding jenis AI lainnya karena membutuhkan data <i>training</i> yang besar
Kemampuan memberikan jawaban terhadap <i>pattern</i> yang belum pernah dipelajari ( <i>generalization</i> )	
Dapat secara otomatis mempelajari data numerik yang diajarkan pada jaringan tersebut	

## BAB III METODOLOGI PENELITIAN

### 3.1 Metodologi

Guna memenuhi kebutuhan dataset yang akan digunakan untuk prediksi *water coning* menggunakan *Artificial Neural Network – Back Propagation* maka penulis terlebih dahulu membangun model *base case* untuk menginterpretasikan *natural fractured carbonate reservoir* menggunakan *simulation software* (CMG-IMEX) dan juga CMOST yang berfungsi membantu melakukan *Design of Experiment* (DoE). *Artificial Neural Network – Back Propagation* nantinya akan diakses menggunakan *software Anaconda Navigator 3.0* dengan *programming language* Python. Data yang digunakan dalam penelitian ini pun merupakan data sekunder yang diperoleh dari literatur terpercaya.

Penelitian ini dimulai dari studi literatur, mempersiapkan data-data yang digunakan (Novrianti, 2013) seperti reservoir *properties*, *fluid properties*, matriks dan *fracture properties* kemudian melakukan perhitungan *water breakthrough time* dengan langkah sebagai berikut:

1. Pembuatan *base model* untuk *natural fractured carbonate reservoir* dengan *dual-permeability systems* pada CMG-IMEX.
2. Uji sensitivitas data guna memenuhi kebutuhan dataset dengan 6 parameter sebagai data *input* menggunakan CMOST sehingga diperoleh 225 *Design of Experiment*.
3. Pemodelan *artificial neural network* menggunakan 225 DoE sebagai data *input* pada *input layer*.
4. Penentuan jumlah *hidden layer* dengan pengertian pembelajaran yang tercepat dan terbaik dengan cara *trial and error* dimulai dari 1 *nodes hidden layer* hingga 12 *nodes hidden layer*.
5. Diperoleh nilai  $R^2$ , RMSE dan MAPE sebagai *output layer* dengan nilai keakuratan yang berbeda-beda, maka dipilih nilai  $R^2$  yang paling mendekati angka 1 sebagai validasi keakuratan terbaik dari pemodelan *artificial neural network*.
6. Penelitian selesai.

### 3.2 Karakteristik Reservoir

Lapangan D merupakan lapangan minyak terbesar di dunia dengan panjang mencapai 230 km dan lebar 25 km yang berlokasi di formasi Arab-D. Reservoir di lapangan ini juga terhubung secara langsung dengan *natural fractured carbonate reservoir* sehingga karakterisasi reservoir ini tersusun atas matriks dan *fracture*. Oleh karena itu, reservoir ini memiliki *dual-permeability* yang bersifat heterogen.

#### 3.2.1 Batuan Reservoir

Berikut adalah data batuan reservoir yang digunakan pada saat pemodelan reservoir, yaitu:

**Tabel 3.1 Reservoir Properties**

Properti	Nilai	Satuan
Ketebalan	172	Ft
Kedalaman	2072	Ft
<i>Water-Oil Contact</i>	2020	Ft
<i>Oil Saturation</i>	0.77	
<i>Water Saturation</i>	0.23	

Sumber : (Abu-Hassoun, 2007)

Selanjutnya adalah data matriks dan *fracture* di lapangan D yang digunakan pada saat pemodelan reservoir, yaitu:

**Tabel 3.2 Matriks Properties**

Layer	Grid Thickness (ft)	Matrix Porosity (%)	Matrix Permeability (mD)	Fracture Spacing (ft)	Matrix Compressibility (1/psi)
1	8	0.2	10	300	$1.36516 \times 10^{-3}$
2	60	0.2	30	300	$1.36516 \times 10^{-3}$
3	4	0.2	30	300	$1.36516 \times 10^{-3}$
4	50	0.2	10	300	$1.36516 \times 10^{-3}$
5	50	0.15	40	300	$1.36516 \times 10^{-3}$

**Tabel 3.3 Fracture Properties**

<b>Layer</b>	<b>Fracture Porosity</b>	<b>Fracture Permeability (mD)</b>			<b>Fracture Compressibility (1/psi)</b>
		<b>I</b>	<b>J</b>	<b>K</b>	
1	0.01	10	300	300	$8.39092 \times 10^{-5}$
2	0.01	10	300	300	$8.39092 \times 10^{-5}$
3	0.01	10	300	300	$8.39092 \times 10^{-5}$
4	0.01	10	300	300	$8.39092 \times 10^{-5}$

Sumber : (Abu-Hassoun, 2007)

### 3.2.2 Fluida Reservoir

Zona *aquifer* terletak disekeliling reservoir di Lapangan D. Adapun *aquifer* ini memiliki luas yang tidak terbatas (*infinite*). Selanjutnya, untuk data fluida reservoir yang digunakan pada saat pemodelan dilampirkan dibawah ini:

**Tabel 3.4 Fluid Properties**

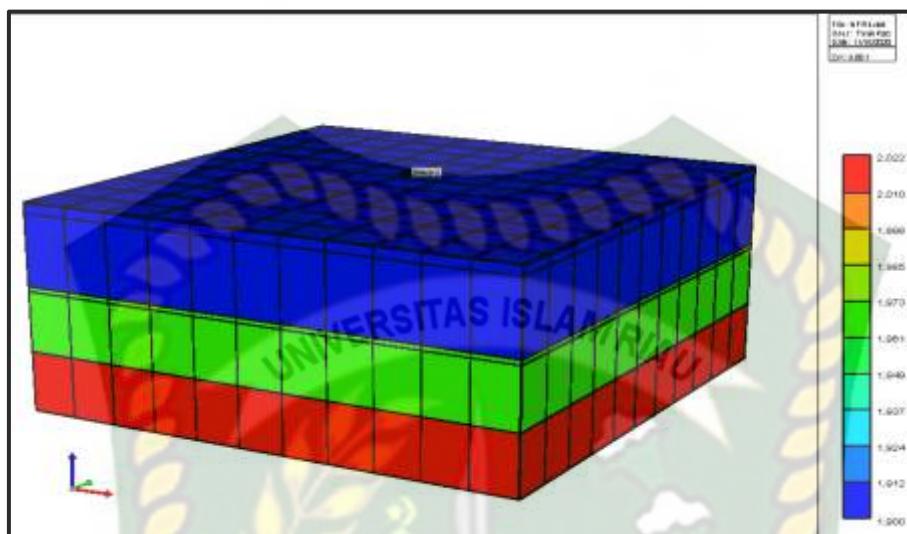
<b>Properti</b>	<b>Nilai</b>	<b>Satuan</b>
Model	<i>Two Phase</i>	
Densitas minyak	52.06	lb/ft <sup>3</sup>
Densitas Air	63.2	lb/ft <sup>3</sup>
Viskositas Air	1	Cp

Sumber : (Abu-Hassoun, 2007)

### 3.3 Model Simulasi Reservoir

Pembuatan model reservoir pada lapangan D menggunakan reservoir *simulation software* CMG-IMEX. Model reservoir pada lapangan ini terdiri dari 11 grid arah sumbu I, 11 grid arah sumbu J dan 5 grid arah sumbu K dengan lebar tiap grid sebesar 300 ft dan ketebalan yang berbeda disetiap layernya. Lapangan D terdiri atas 5 *layer* dimana 4 *layer* dari atas terhubung langsung dengan *natural fractured carbonate* reservoir. Prediksi *water coning* di lapangan D juga menggunakan 1 sumur produksi yang berada di

kedalaman 1972 ft dari batas atas reservoir. Model konseptual reservoir lapangan D dapat dilihat pada gambar berikut:



**Gambar 3.1** Model Konseptual Reservoir

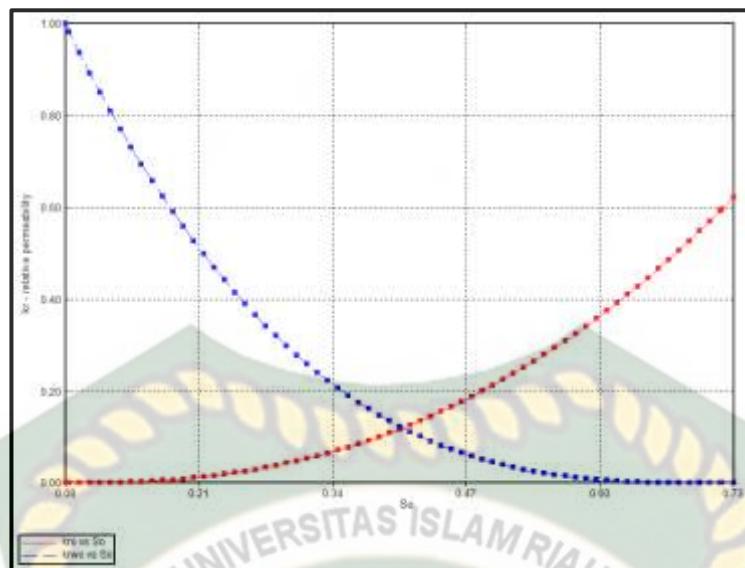
### 3.3.1 Inisialisasi

Setelah melakukan *running* pada model, berikut hasil inisialisasi model konseptual lapangan D yang tercantum pada Tabel 3.5 dan Gambar 3.5:

**Tabel 3.5** Hasil Inisialisasi dari Simulasi

Parameter	Satuan	Nilai
<i>Total Oil in Place</i>	STB	0.17625 E+09
<i>Total Water in Place</i>	STB	0.13678 E+09
<i>Total Gas in Place</i>	SCF	0.449686 E+09

Kurva permeabilitas relative pada Gambar 3.2 menunjukkan *wettability* yang bersifat *oil wet*. Hal ini dikarenakan perpotongan kurva berada pada nilai saturasi air sebesar 0.404 (Ahmed, 2010).



**Gambar 3.2** Kurva Permeabilitas Relatif terhadap Saturasi Minyak

### 3.3.2 Sensitivitas Data

Dengan menggunakan 6 parameter yaitu permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan *fracture* maka uji sensitivitas data untuk menciptakan dataset menggunakan CMOST diatur dalam range *lower limit* (batas terendah) dan *upper limit* (batas tertinggi) sebagai berikut:

**Tabel 3.6** Data Range Settings

<b>Properti</b>	<b>Satuan</b>	<b>Nilai</b>	
		<b>Lower Limit</b>	<b>Upper Limit</b>
Permeabilitas Horizontal Matriks	mD	2	200
Permeabilitas Horizontal <i>Fracture</i>	mD	1	100
Permeabilitas Vertikal Matriks	mD	2	200
Permeabilitas Vertikal <i>Fracture</i>	mD	100	1000
Porositas Matriks ( $\phi_m$ )	%	0.1	0.5
Porositas <i>Fracture</i> ( $\phi_f$ )	%	0.003	0.03

Setelah dilakukan *running* sesuai dengan data range pada tabel, maka akan diperoleh 225 DoE dengan grafik *water cut* terhadap waktu dalam skala tahunan sebagai respon parameter. Selanjutnya dilakukan pengolahan terhadap respon parameter tersebut guna untuk memperoleh waktu tembus air

dalam skala harian (*days*). Prediksi *water coning* yang dilakukan selama 10 tahun terhitung mulai tahun 2020 hingga tahun 2030.

### 3.4 Pemodelan *Artificial Neural Network*

Selanjutnya 225 *Design of Experiment* (DoE) kembali digunakan untuk membangun model *artificial neural network* menggunakan simulator Anaconda Navigator 3.0 dengan *programming language* Python. Dalam penelitian ini algoritma yang digunakan adalah algoritma *backpropagation* serta menggunakan fungsi aktivasi sigmoid bipolar dengan rentang [-1, 1].

Dari 225 DoE yang ada, 80% data digunakan untuk *training* dan 20% data untuk *testing* dan validasi keakuratan model. Kemudian pemilihan arsitektur akan dilakukan dengan cara *trial and error* terhadap jumlah *nodes* pada *hidden layer*. Dalam penelitian ini, akan dimulai dari 1 *nodes* pada *hidden layer* hingga 12 *nodes* pada *hidden layer* sehingga menghasilkan nilai  $R^2$ , RMSE dan MAPE sebagai *output layer* dari *artificial neural network*.

### 3.5 Tempat dan Jadwal Penelitian

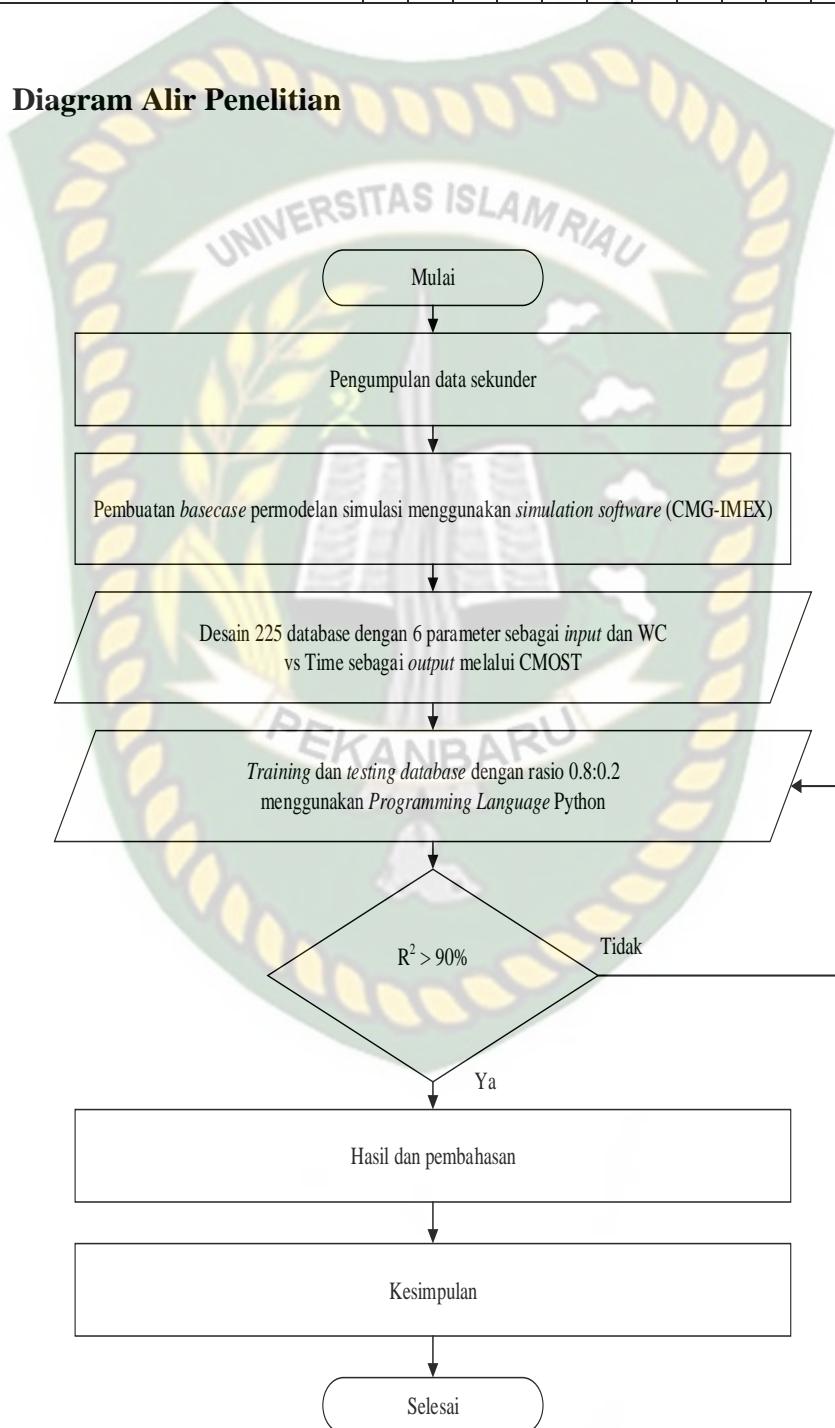
Penelitian ini dilakukan di Laboratorium Simulasi Reservoir Teknik Perminyakan Universitas Islam Riau selama 3 bulan dimulai dari bulan Desember 2020 sampai dengan Februari 2021 dimana penelitian ini menggunakan data sekunder yang diperoleh dari buku, jurnal dan literatur terpercaya.

**Tabel 3.7** Jadwal Penelitian

No	Jenis Kegiatan	Des 2020				Jan 2021				Feb 2021			
		1	2	3	4	1	2	3	4	1	2	3	4
1	Studi Literatur												
2	Pembuatan model dengan CMG IMEX dan perhitungan dengan CMG CMOST												
3	Pengaplikasian ke <i>Artificial Neural Network</i>												

No	Jenis Kegiatan	Des 2020				Jan 2021				Feb 2021			
		1	2	3	4	1	2	3	4	1	2	3	4
4	Analisis Hasil <i>Artificial Neural Network</i>												
5	Hasil dan Pembahasan												

### 3.6 Diagram Alir Penelitian

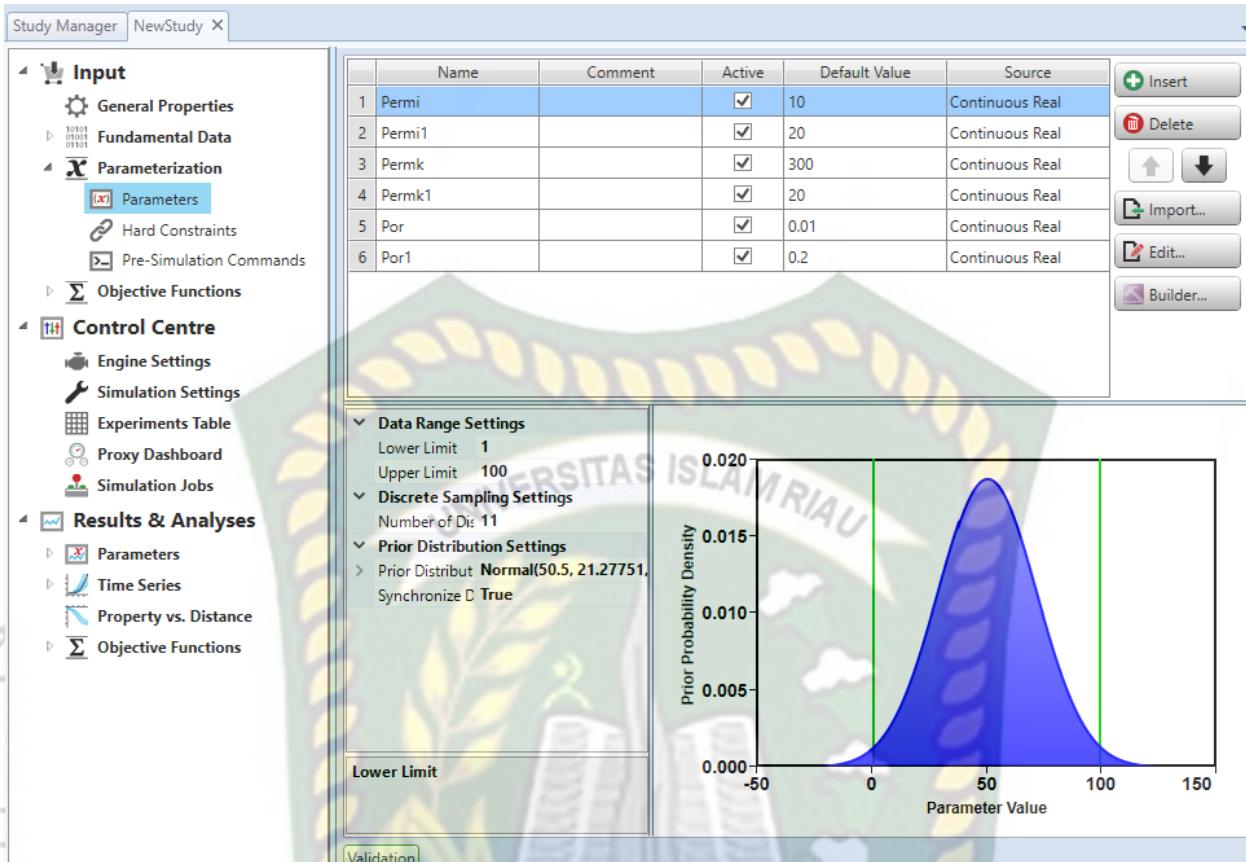


## BAB IV HASIL DAN PEMBAHASAN

*Water coning* di *natural fractured carbonate reservoir* (NFCR) menjadi salah satu permasalahan utama di industri minyak dan gas bumi karena menyebabkan tingginya produksi air tanpa perolehan minyak yang optimum. Ditambah lagi, kecenderungan *water coning* lebih cepat terjadi di *natural fractured carbonate reservoir* akibat *dual-permeability system* pada reservoir jenis ini memberikan dampak terhadap sumur produksi yang mati lebih awal. Berdasarkan literatur yang telah dipublikasikan, memprediksikan waktu tembus air (*water breakthrough time*) menjadi solusi praktis untuk permasalahan ini sehingga skema produksi yang optimum dapat tercipta agar sumur produksi dapat bertahan lebih lama.

Dalam penelitian ini, digunakan *high* parameter untuk memprediksikan *water coning* melalui *water breakthrough time* menggunakan *artificial neural network*. Adapun *high* parameter didefinisikan sebagai parameter yang paling mempengaruhi terjadinya fenomena *water coning* di NFCR (Namani & Asadollahi, 2007; Perez-Martinez & Garza, 2012). *High* parameter tersebut terdiri atas permeabilitas dan porositas yang mana digunakan 6 *operation* parameter untuk penelitian ini yaitu permeabilitas horizontal matriks dan *fracture*, permeabilitas vertikal matriks dan *fracture* serta porositas matriks dan *fracture*.

Dengan menggunakan 6 *operation* parameter tersebut selanjutnya ditentukan *lower limit* dan *upper limit* terhadap masing-masing parameter (Gambar 4.1), maka terbentuk *random sample* sesuai dengan batas terendah dan batas tertinggi dari standar yang telah ditentukan sehingga menghasilkan 225 *Design of Experiment* (DoE) berdasarkan *Responce Surface of Methodology* yang diakses melalui CMOST dari *Computer Modelling Group* (CMG). Setelah kebutuhan dataset terpenuhi maka selanjutnya 225 DoE tersebut kembali digunakan sebagai data *input* untuk membangun arsitektur jaringan *artificial neural network* dengan *output* berupa *water breakthrough time*.



Gambar 4.1 Pengaturan parameter *input* pada CMOST

*Artificial neural network* telah banyak diimplementasikan dalam industri minyak dan gas bumi serta terbukti menjadi sebuah metode yang memiliki akurasi dan performa yang baik dalam melakukan prediksi (Kalam, Alnuaim, & Rammay, 2016; Ahamdi, Ebadi, & Hosseini, 2013). Dalam studi ini, algoritma pembelajaran yang digunakan adalah *Back Propagation* dimana ciri dari algoritma ini adalah meminimalkan error pada *output* yang dihasilkan oleh jaringan *Artificial Neural Network* (Muzakkir, Syukur, & Dewi, 2014). Penerapan *Artificial Neural Network - Back Propagation* terdiri dari 2 tahap yaitu pertama pelatihan (*training*) dimana pada tahap ini diberikan sejumlah data pelatihan dan target dan kedua tahap pengujian (*testing*) atau evaluasi (Wuryandari & Afrianto, 2012). Dalam studi ini, 80% dari dataset digunakan untuk tahap *training* dan 20% dari dataset digunakan untuk tahap *testing* sehingga dari 225 DoE yang digunakan sebagai dataset 180 data bertindak sebagai data *training* dan 45 data bertindak sebagai data

*testing.* Algoritma *Artificial Neural Network - Back Propagation* diakses melalui *software* Anaconda Navigator 3.0 dengan *programming language* Python. Menurut Saragih (2018), Python adalah bahasa pemrograman interpretatif multiguna dengan filosofi perancangan yang berfokus pada tingkat keterbacaan kode. Python juga diklaim sebagai bahasa pemrograman tingkat tinggi (*high level*), memberikan kemudahan dari segi efisiensi waktu, kemudahan dalam pengembangan dan kompatibilitas dengan sistem (Saragih, 2018). Keunggulan dari *programming language* Python menunjukkan bahwa Python lebih mudah dipahami baik untuk pemula maupun programmer karena memiliki bahasa yang lebih mendekati bahasa manusia daripada bahasa mesin. Perintah yang digunakan di Python menggunakan bahasa inggris sehari-hari yaitu *print*, *input* dan lain sebagainya.

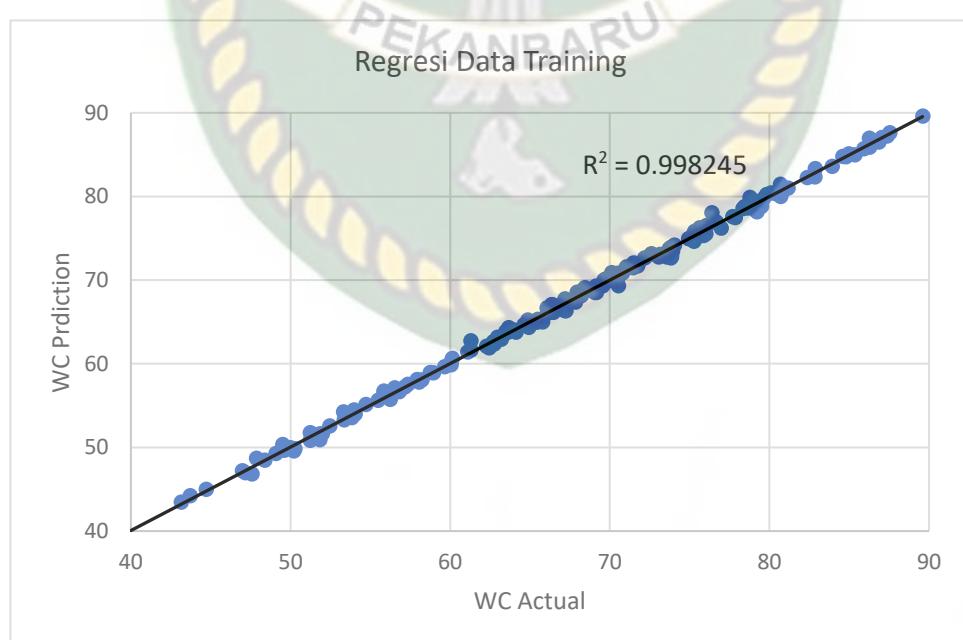
Pembangunan arsitektur jaringan *Artificial Neural Network – Back Propagation* diawali dengan menginputkan dataset yang berfungsi sebagai *input layer*. Kemudian dilakukan normalisasi data supaya dapat membawa range nilai *output* ke dalam range *input* (Chamidah, Wiharto, & Salamah, 2012). Untuk normalisasi data dalam studi ini digunakan metode *Min-Max Normalization* karena mampu memberikan rata-rata akurasi tertinggi dan memerlukan *epoch* yang sedikit (Chamidah, Wiharto, & Salamah, 2012). Adapun cara kerja dari *Min – Max Normalization* dengan me-rescale data dari suatu range ke range baru. Data diskalakan dalam range 0 dan 1. Kemudian untuk memperoleh model *Artificial Neural Network* yang bagus harus dilakukan optimasi dengan menggunakan metode *trial and error* (Noureldien & El-Banbi, 2015). Hal ini bertujuan untuk memberikan kemudahan pada penentuan jumlah *nodes* di *hidden layer* sehingga mampu memperoleh jumlah *nodes* yang optimal pada *hidden layer*. Terdapat *rule of thumb* yang menyatakan bahwa jumlah *nodes* pada *hidden layer* harus melebihi jumlah *input layer* dan tidak lebih dari dua kali jumlah *input layer* sehingga pada penelitian ini digunakan 6 hingga 12 *nodes* pada *hidden layer* sebagai tempat terjadinya proses komputasi terhadap bobot dan bias serta dihitung pula besarnya *output* dari *hidden layer* berdasarkan fungsi aktivasi (Kholis, 2015).

Dalam penelitian ini, digunakan fungsi aktivasi sigmoid bipolar dengan *range output* antara -1 sampai 1 untuk memperoleh nilai  $R^2$  (*Coefficient of Determination*), RMSE (*Root Mean Square Error*) dan juga MAPE (*Mean Absolute Percentage Error*) pada data *training* dan juga data *testing*. Pemilihan fungsi aktivasi sigmoid bipolar didasarkan pada perbandingan terhadap fungsi aktivasi sigmoid biner dengan range 0 sampai 1. Nilai ekstrim 0 yang dihasilkan fungsi sigmoid biner kurang memberikan pengaruh pada perhitungan bobot dan bias pada neuron dibandingkan dengan nilai ekstrim -1 yang dihasilkan fungsi sigmoid bipolar sehingga validasi keakuratan dengan fungsi sigmoid bipolar menjadi lebih bagus (Julpan, Nababan, & Zarlis, 2015).

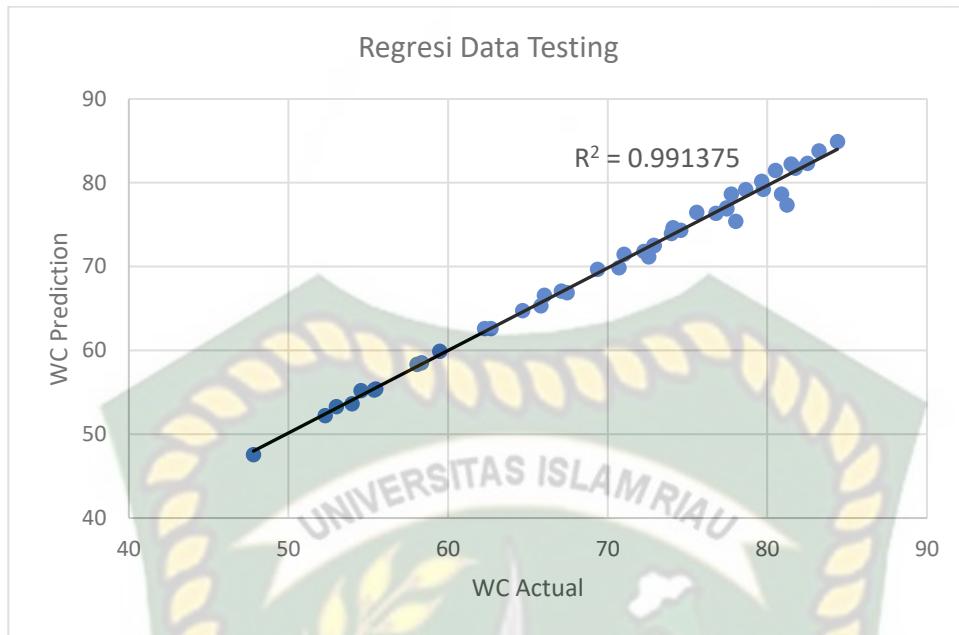
**Tabel 4.1** Nilai *Coefficient of Determination* ( $R^2$ ), *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) pada *hidden nodes* yang berbeda

Jumlah nodes pada <i>Hidden Layer</i>	$R^2$		RMSE		MAPE	
	Training	Testing	Training	Testing	Training	Testing
1	0.913523	0.905338	3.286031	3.373773	3.926051	3.692153
2	0.949834	0.940396	2.516067	2.591402	2.908097	3.005664
3	0.979323	0.953651	1.615317	2.285166	1.867423	2.578478
4	0.982867	0.980049	1.472631	1.519350	1.703637	1.669631
5	0.983729	0.975527	1.425390	1.715444	1.639688	1.932181
6	0.994715	0.984641	0.812330	1.358954	0.985335	1.599101
7	0.991048	0.977602	1.057259	1.641096	1.305583	1.796454
8	0.993619	0.985064	0.892638	1.340108	1.065609	1.545709
9	0.993155	0.981430	0.924526	1.494288	1.107572	1.721391
10	0.995014	0.985301	0.789032	1.329471	0.937472	1.616588
11	0.994840	0.983823	0.802690	1.394707	0.949492	1.573546
12	0.998245	0.991375	0.475603	0.930476	0.565026	0.813265

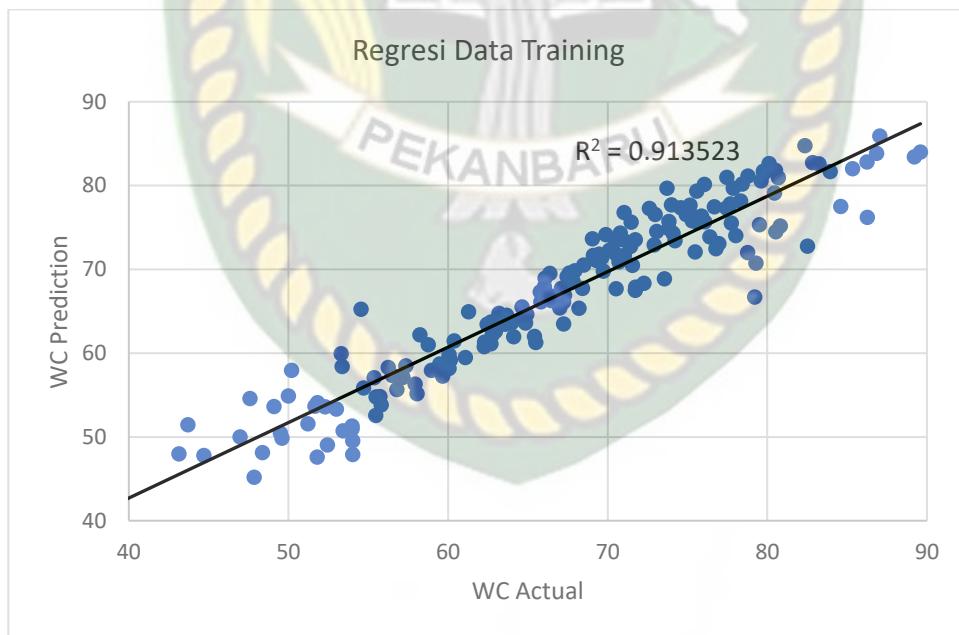
Berdasarkan *rule of thumb*, *nodes* terbaik pada *hidden layer* untuk memperoleh hasil yang optimal dimulai dari sesuai dengan jumlah *input layer* sampai dua kali jumlah *input layer*. Namun, penulis ingin mengamati hasil yang diperoleh jika dimulai dari 1 *nodes* pada *hidden layer*. Dapat dilihat pada Tabel 4.1 bahwa jumlah *nodes* yang nilainya kurang dari jumlah *input layer* memiliki tingkat akurasi yang lebih rendah meskipun telah mendekati angka 1. Hal ini selaras dengan pernyataan Kholis (2015) bahwa semakin banyak jumlah *nodes* pada *hidden layer* maka performa *Artificial Neural Network* semakin baik. Hal ini dibuktikan dengan tingkat akurasi yang tinggi dan tingkat error yang lebih rendah. Pada studi ini, 10 *nodes*, 11 *nodes* dan 12 *nodes* pada *hidden layer* memiliki hasil yang paling optimal terkhusus untuk 12 *nodes*. Nilai *Coefficient of Determination* ( $R^2$ ) pada data *training* mencapai 0.998245 (Gambar 4.2) dan 0.991375 pada data *testing* (Gambar 4.3). Sementara itu, 1 *nodes* dan 2 *nodes* pada *hidden layer* merupakan hasil yang terendah terutama 1 *nodes* dengan nilai *Coefficient of Determination* ( $R^2$ ) pada data *training* 0.913523 (Gambar 4.4) dan 0.905338 (Gambar 4.5) pada data *testing*.



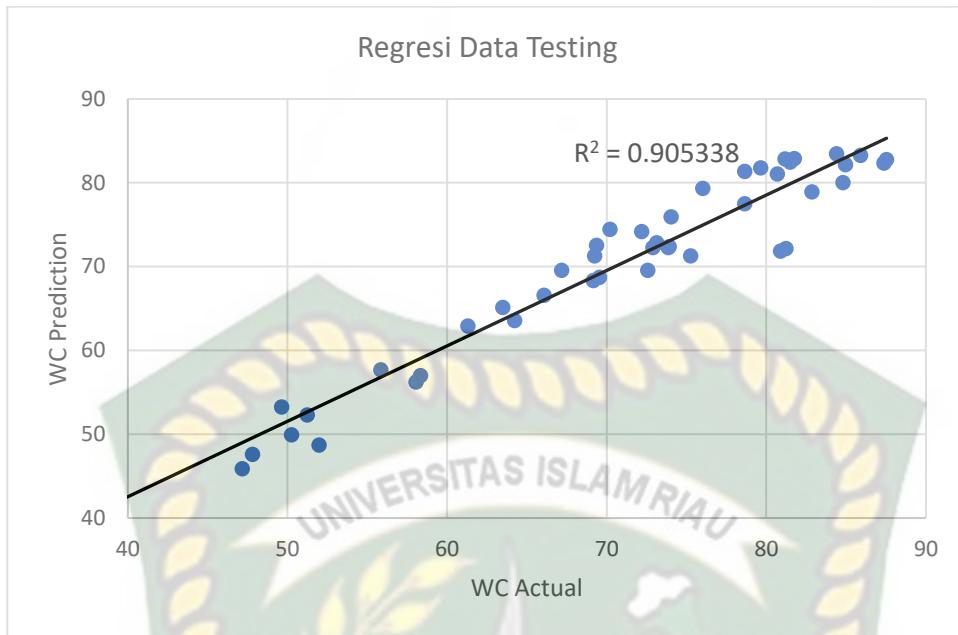
**Gambar 4.2** *Coefficient of Determination* ( $R^2$ ) pada data *training* dengan 12 *hidden nodes*



**Gambar 4.3** Coefficient of Determination ( $R^2$ ) pada data *testing* dengan 12 *hidden nodes*



**Gambar 4.4** Coefficient of Determination ( $R^2$ ) pada data *training* dengan 1 *hidden nodes*



**Gambar 4.5** Coefficient of Determination ( $R^2$ ) pada data testing dengan 1 hidden nodes

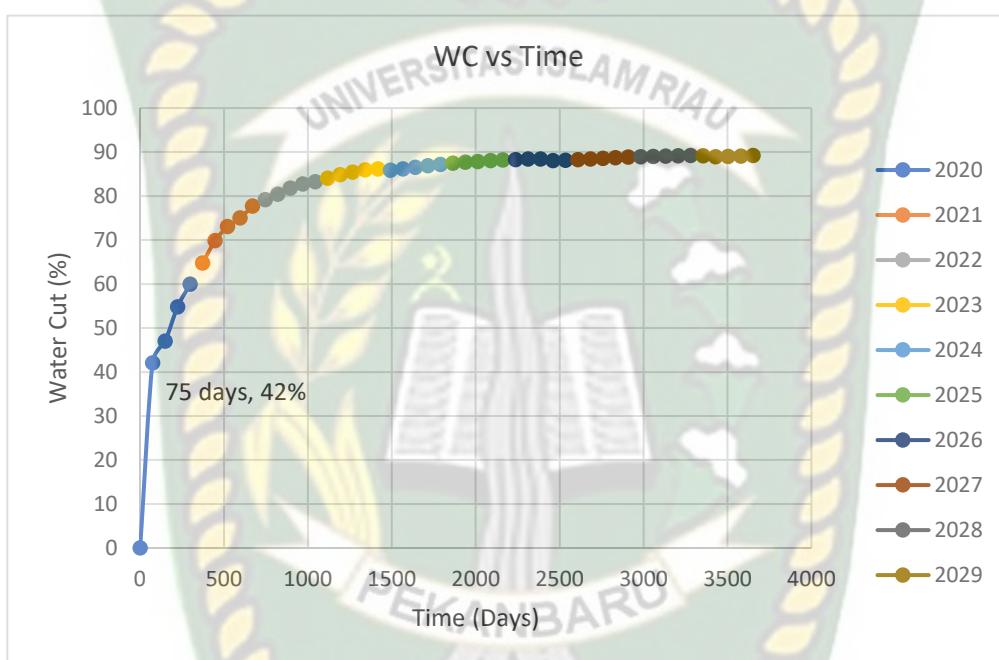
Berdasarkan Tabel 4.1, nilai *Coefficient of Determination* ( $R^2$ ), *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) merupakan model akurasi dari jaringan arsitektur *Artificial Neural Network – Back Propagation*. *Coefficient of Determination* ( $R^2$ ) didefinisikan sebagai hubungan antara data aktual dan data prediksi dimana nilai *Coefficient of Determination* ( $R^2$ ) adalah indikator yang baik untuk menunjukkan kinerja dari *Artificial Neural Network – Back Propagation* (Zendehboudi, Elkamel, & Chatzis, 2014). Semakin kecil nilai *Coefficient of Determination* ( $R^2$ ) hingga mendekati angka 1 maka akurasi suatu prediksi semakin tinggi atau semakin akurat (Ervina, Silvi, & Wisisono, 2018). Kendati demikian, parameter statistik lainnya seperti *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) diperlukan untuk memeriksa keefektifan dari performa *Artificial Neural Network – Back Propagation* (Zendehboudi, Elkamel, & Chatzis, 2014). MAPE atau *Mean Absolute Percentage Error* adalah ukuran akurasi dari suatu prediksi karena memperhitungkan rata – rata persentase kesalahan mutlak. Menurut Moreno (2013) interpretasi dari nilai MAPE apabila kurang dari 10 % (<10%) maka dinyatakan peramalan sangat akurat, 10% hingga 20% (10%-20%) berarti

peramalan akurat, 20% sampai 50% ( 20%-50% ) menyatakan peramalan cukup akurat dan lebih dari 50% ( $>50\%$  ) mengindikasikan bahwa peramalan tidak akurat (Ervina, Silvi, & Wisisono, 2018). Berdasarkan pemaparan diatas, maka prediksi *water coning* pada *natural fractured carbonate reservoir* menghasilkan prediksi yang sangat akurat. Hal ini terbukti dengan nilai yang tertera pada Tabel 4.1. Total keseluruhan untuk nilai *Coefficient of Determination* ( $R^2$ ) dari 1 *hidden nodes* hingga 12 *hidden nodes* hampir mendekati angka 1. Demikian pula dengan nilai *Mean Absolute Percentage Error* (MAPE) untuk 1 *hidden nodes* sampai 12 *hidden nodes* yang secara keseluruhan kurang dari 10%.

Untuk studi ini, performa terbaik dari *Artificial Neural Network – Back Propagation* dalam memprediksi *water coning* di *natural fractured carbonate reservoir* diperoleh melalui 12 *nodes* pada *hidden layer*. Nilai *Coefficient of Determination* ( $R^2$ ) yang paling mendekati angka 1 untuk data *training* dan juga data *testing* yang masing-masing senilai 0.998245 dan 0.991375. Selanjutnya nilai MAPE atau *Mean Absolute Percentage Error* yang bahkan tidak mencapai 1% untuk data *training* dan data *testing* dengan masing-masing senilai 0.565026% dan 0.813265%. Dengan demikian, prediksi *water coning* di *natural fractured carbonate reservoir* menggunakan metode *Artificial Neural Network – Back Propagation* telah berhasil diterapkan dengan validasi keakuratan yang tinggi serta waktu yang relative lebih singkat tentunya.

Berhubung hasil yang diperoleh dari *output layer* pada kinerja *Artificial Neural Network - Back Propagation* adalah nilai *water cut* terhadap waktu dalam skala tahunan (Lampiran 1) maka perlu dilakukan pengolahan data menggunakan Ms. Excel guna memperoleh waktu dalam skala harian (*days*) sehingga waktu tembus air (*water breakthrough time*) bisa diperhitungkan. Dari 225 DoE (*Design of Experiment*) yang digunakan sebagai dataset, maka dipilih 1 DoE terbaik untuk diestimasi waktu ketika air mulai menembus *bottom perforasi* pada sumur produksi. Pemilihan DoE terbaik ini berlandaskan pada nilai *water cut* yang tertinggi. Hal ini linear dengan pernyataan (Perez-Martinez & Garza, 2012; Abu-Hassoun, 2007;

Golf-Racht & Sonier, 1994) bahwa *water coning* di *natural fractured carbonate* resevoir mampu mencapai 30% di awal waktu ketika menembus *bottom* perforasi hingga mendekati 90% dalam kurun waktu yang relatif cepat. *Design of Experiment* (DoE) dengan nomor ID 223 menjadi pilihan terbaik sehingga pada studi ini diperoleh waktu tembus air (*water breakthrough time*) pada hari ke – 75 (Gambar 4.6) setelah sumur pertama kali diproduksikan dengan nilai *water cut* sebesar 42%.



**Gambar 4.6** Grafik *Water Cut* terhadap Waktu dalam skala harian (*days*)

## BAB V KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah dipaparkan sebelumnya, maka dapat disimpulkan bahwa implementasi metode *Artificial Neural Network* untuk prediksi *water coning* menghasilkan validasi keakuratan yang sangat tinggi. Terbukti dengan menggunakan 12 *hidden nodes* diperoleh nilai *Coefficient of Determination* ( $R^2$ ) pada data *training* dan data *testing* senilai 0.998245 dan 0.991375 serta nilai *Mean Absolute Percentage Error* (MAPE) 0.565026% untuk data *training* dan 0.813265% untuk data *testing* yang mana waktu tembus air (*water breakthrough time*) terjadi pada hari ke – 75 dengan persentase *water cut* sebesar 42%.

### 5.2 Saran

Berdasarkan penelitian yang telah dilakukan, penulis menyarankan beberapa hal untuk penelitian selanjutnya, yaitu:

1. Melakukan prediksi *water breakthrough time* untuk seluruh dataset yang digunakan (225 *Design of Experiment*) menggunakan *Simulation Software* terbaru (CMG 2020) sehingga waktu yang dihasilkan untuk menciptakan dataset telah berada dalam skala harian (*days*).
2. Melakukan prediksi *water coning* di *natural fractured carbonate reservoir* menggunakan metode lainnya seperti *Genetic Algorithm*, *Ant Colony Optimization* atau *Particle Swarm Optimization* dengan penambahan parameter *input* seperti *fracture length* dan *fracture spacing*.

## DAFTAR PUSTAKA

- Abu-Hassoun, A. H. (2007). *Simulation of Fluid Flow Mechanism in High Permeability Zones (Super-K) in A Giant Naturally Fractured Carbonate Reservoir*. Texas: Texas A&M University.
- Ahamdi, M. A., Ebadi, M., & Hosseini, S. M. (2013). Prediction Breakthrough Time of Water Coning in The Fractured Reservoirs by Implementing Low Parameter Support Vector Machine Approach. *Elsevier* 579-589, 1-11.
- Ahmed, T. (2006). *Reservoir Engineering Handbook Third Edition*. United States of America: Elsevier.
- Ahmed, T. (2010). *Reservoir Engineering Handbook Fourth Edition*. United States of America: Elsevier.
- Al-Azmi, N. H., Aladwani, F. A., & Kasaraneni, P. R. (2017). Water Control Management Utilizing Downhole Water Sink Technology: Application of a Reservoir in the Middle East. *SPE-187663-MS*, 18.
- Appah, E. a. (2005). Water Coning Diagnosis using Spectral Analysis. *SPE 98816*, 1-8.
- Arslan, O. (2005). *Optimal Operating Strategy for Wells with Downhole Water Sink Completions to Control Water Production and Improve Performance*. Louisiana: Louisiana State University and Agricultural and Mechanical Colleg.
- Bahrami, H., Shadizadeh, S. R., & Goodarzniya, I. (2004). Numerical Simulation of Coning Phenomena in Naturally Fractured Reservoirs. *Iranian Chemical Engineering Congress*, 1-10.
- Bournazel, C., & Jeanson, B. (1971). Fast Water-Coning Evaluation Method. *SPE-3628-MS*, 1-14.
- Chamidah, N., Wiharto, & Salamah, U. (2012). Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *Jurnal ITSMART Vol 1. No 1*, 1-6.
- Ervina, M. E., Silvi, R., & Wisisono, I. R. (2018). Peramalan Jumlah Penumpang Kereta Api di Indonesia dengan Resilient Back-Propagation (RPROP) Neural Network. *Jurnal Matematika "MANTIK" ISSN : 2527-3159*, 1-11.

- Golf-Racht, T. V., & Sonier, F. (1994). Water Coning in a Fractured Reservoir. *SPE 28572*, 1-13.
- Guerriero, V., Mazzoli, S., & Iannace, A. (2012). A Permeability Model for Naturally Fractured Carbonated Reservoir. *Elsevier 115-134*, 1-20.
- Hizham, F. A., Nurdiansyah, Y., & Firmansyah, D. M. (2018). Implementasi Metode Backpropagation Neural Network (BNN) dalam Sistem Klasifikasi Ketepatan Waktu Kelulusan Mahasiswa (Studi Kasus : Program Studi Sistem Informasi Universitas Jember). *BERKALA SAINTEK, VI* (2): 97-105, 1-8.
- Jin, L., Wojtanowicz, A. K., & Hughes, R. G. (2010). An Analytical Model for Water Coning Control Installation in Reservoir with Bottomwater. *SPE-137787-PA*, 1-12.
- Julpan, Nababan, E. B., & Zarlis, M. (2015). Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar dalam Algoritma Backpropagation pada Prediksi Kemampuan Siswa. *Jurnal Teknologi Vol. 02 No. 1*, 1-13.
- Kalam, S., Alnuaim, S. A., & Rammay, M. H. (2016). Application of Artificial Intelligence for Water Coning Problem in Hydraulically Fractured Tight Oil Reservoirs. *OTC-26450-MS*, 1-20.
- Kholis, I. (2015). Analisis Variasi Parameter Backpropagation Artificial Neural Network Terhadap Pengenalan Pola Data Iris. *ResearchGate*, 1-11.
- Moradi, B., Dastkhan, Z., Roozbehani, B., & Montazeri, G. (2010). Modeling of Water Coning Phenomena in a Fractured Reservoir and Design a Simulator. *SPE 132839*, 1-9.
- Muzakkir, I., Syukur, A., & Dewi, I. N. (2014). Peningkatan Akurasi Algoritma Backpropagation dengan Seleksi Fitur Particle Swarm Optimization dalam Prediksi Pelanggan Telekomunikasi yang Hilang. *Jurnal Pseudocode Vol 1 No 1 ISSN 2355 - 5920*, 1-10.
- Namani, M., & Asadollahi, M. (2007). Investigation of Water-Coning Phenomenon in Iranian Carbonate Fractured Reservoirs. *SPE 108254*, 1-11.
- Narr, W. (2006). *Naturally Fractured Reservoir Characterization*. United States of America: Society of Petroleum Engineers.
- Nelson, R. (2001). *Geologic Analysis of Naturally Fractured Reservoir*. United States of America: Elsevier.

- Noureldien, D. M., & El-Banbi, A. H. (2015). Using Artificial Intelligence in Estimating Oil Recovery Factor. *SPE-175867-MS*, 1-22.
- Novrianti. (2013). Estimasi Water Influx dan Luas Aquifer di Lapangan X. *Journal of Earth, Energy and Engineering, ISSN : 2301 - 8097*, 1-4.
- Okon, A. N., Appah, D., & Akpabio, J. U. (2018). A Critical Evaluation of Water Coning Correlations in Vertical Wells. *American Journal of Science, Engineering and Technology*, 1-9.
- Okwananke, A., & Isehunwa, S. O. (2008). Analysis of Water Cresting in Horizontal Wells. *SPE 119733*, 1-9.
- Perez-Martinez, E., & Garza, F. R. (2012). Water Coning in Naturally Fractured Carbonate Heavy Oil Reservoir - A Simulation Study. *SPE 152545*, 1-16.
- Permadi, A. K. (2009). New Empirical Correlation for Predicting Water Breakthrough Time of a Vertical Well in a Bottom-Water Reservoir. *Jurnal Teknologi Mineral*.
- Ramirez, B., Kazemi, H., Al-Kobaisi, M., Ozkan, E., & Atan, S. (2007). A Critical Review for Proper Use of Water/Oil/Gas Transfer Functions in Dual-Porosity Naturally Fractured Reservoirs. *SPE 109821*, 1-12.
- Recham, R., Osisanya, S., & Touami, M. (2000). Effects of Water Coning on the Performance of Vertical and Horizontal Wells-A Reservoir Simulation Study of Hassi R'mel Field, Algeria. *SPE-65506-MS*, 1-12.
- Safari, M., & Ameri, M. J. (2019). Reservoir Control and Identification: Motivated by Water. *IOP Conf. Series: Materials Science and Engineering Vol. 495*, 1-12.
- Saragih, R. R. (2018). Pemrograman dan Bahasa Pemrograman. 1-44.
- Shadizadeh, S., & D.Ghorbani. (2001). Investigation of Water / Gas Coning in Natural Fractued Hydrocarbon Reservoir. *Petroleum Society 2001-014*, 1-6.
- Sobociński, D., & Cornelius, A. (1965). A Correlation for Predicting Water Coning Time. *SPE-894-PA*, 1-7.
- T.H, L., Y.H, J., & H.M, P. (2011). Investigation of Water BT Phenomenon in The Fractured Basement Reservoir Contacted with Bottom Water Aquifer. *SPE 146874*, 1-14.

- Tobing, E. M., & Eni, H. (2013). Peningkatan Perolehan Reservoir Minyak 'R' dengan Injeksi Alkali-Surfaktan-Polimer pada Skala Laboratorium. *Pusat Penelitian dan Pengembangan Teknologi Minyak dan Gas Bumi "LEMIGAS"*, 1-10.
- Wuryandari, M. D., & Afrianto, I. (2012). Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation dan Learning Vector Quantization pada Pengenalan Wajah. *Jurnal Komputer dan Informatika Edisi. I Volume. 1*, 1-7.
- Yang, W., & Wattenbarger. (1991). Water Coning Calculations for Vertical and Horizontal Wells. *SPE-22931-MS*, 1-12.
- Yasutra, A., Sukarno, P., & Mucharam, L. (2005). Kelakuan Produksi Sumur Minyak pada Reservoir Rekah Alami. *IATMI 2005-22*, 1-11.
- Zendehboudi, S., Elkamel, A., & Chatzis, I. (2014). Estimation of Breakthrough Time for Water Coning in Fractured System: Experimental Study and Connectionist Modeling. *Wiley Online Library. 14365*, 1-15.