

**PREDIKSI TINGKAT KEBERHASILAN DESAIN *HYDRAULIC
FRACTURING* PADA *SHALE GAS* RESERVOIR
MENGUNAKAN *ARTIFICIAL NEURAL NETWORK***

TUGAS AKHIR

Diajukan guna penyusunan tugas akhir Program Studi Teknik Perminyakan

Oleh

ISMI RALDA

173210326



PROGRAM STUDI TEKNIK PERMINYAKAN

UNIVERSITAS ISLAM RIAU

PEKANBARU

2021

PREDIKSI TINGKAT KEBERHASILAN DESAIN *HYDRAULIC FRACTURING* PADA *SHALE GAS RESERVOIR* MENGGUNAKAN *ARTIFICIAL NEURAL NETWORK*

TUGAS AKHIR

Diajukan guna penyusunan tugas akhir Program Studi Teknik Perminyakan

Oleh

ISMI RALDA

NPM 173210326



Perpustakaan Universitas Islam Riau

Dokumen ini adalah Arsip Miik :

PROGRAM STUDI TEKNIK PERMINYAKAN

UNIVERSITAS ISLAM RIAU

PEKANBARU




2021

HALAMAN PENGESAHAN

Nama : Ismi Ralda
NPM : 173210326
Program Studi : Teknik Perminyakan
Judul Tugas Akhir : *Prediksi Tingkat Keberhasilan Desain Hydraulic Fracturing Pada Shale Gas Reservoir Menggunakan Artificial Neural Network*

Telah berhasil dipertahankan dihadapan 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 : Tomi Erfando, S.T., MT. ()
Penguji I : Dike Fitriansyah Putra, ST.,M.Sc.,MBA. ()
Penguji II : Idham Khalid, S.T., M.T. ()

Ditetapkan di : Pekanbaru

Tanggal : 15 Desember 2021

Disahkan oleh:

**KETUA PROGRAM STUDI
TEKNIK PERMINYAKAN**



Novia Rita, S.T., M.T.

**DOSEN PEMBIMBING TUGAS
AKHIR**

DIVERIFIKASI
fandotomi@gmail.com at 19:09:43, 23/12/2021

Tomi Erfando, S.T., MT

PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya telah 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, 1 Desember 2021



Ismi Ralda
173210326



KATA PENGANTAR

Rasa syukur saya ucapkan kepada Allah SWT berkat rahmat dan karunia-Nya sehingga penulis bisa diberikan kesempatan untuk 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. Kedua orang tua, Ayah dan Mama yang telah memberikan dukungan moral, material, dan doa yang senantiasa mengiringi penulis.
2. Bapak Tomi Erfando, S.T., M.T selaku dosen pembimbing dalam penulisan tugas akhir ini yang telah meluangkan banyak waktu, tenaga dan fikiran sehingga tugas akhir ini bisa selesai.
3. Bapak Idham Khalid, S.T, M.T., selaku pembimbing akademik yang telah memberi arahan dan nasihat selama perkuliahan di Teknik Perminyakan.
4. Ketua dan Sekretaris Program Studi Perminyakan serta dosen-dosen lainnya yang belum bisa saya sebutkan satu persatu dalam tugas akhir ini, yang telah membantu dan mengajari penulis selama masa perkuliahan.
5. Laboratorium Teknik Perminyakan, khususnya laboratorium simulasi reservoir.
6. Sahabat dan senior: Bang Aznil Arif ,Bang Muhammad Bakti Setiawan S.T., Bang Alfi Syahri Layali S.T., Herry,Tari, Afifah, Novan, Aulia, Tito dan juga teman-teman lainnya di kampus yang tidak bisa disebutkan satu persatu.

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, 21 September 2021

Ismi Ralda

DAFTAR ISI

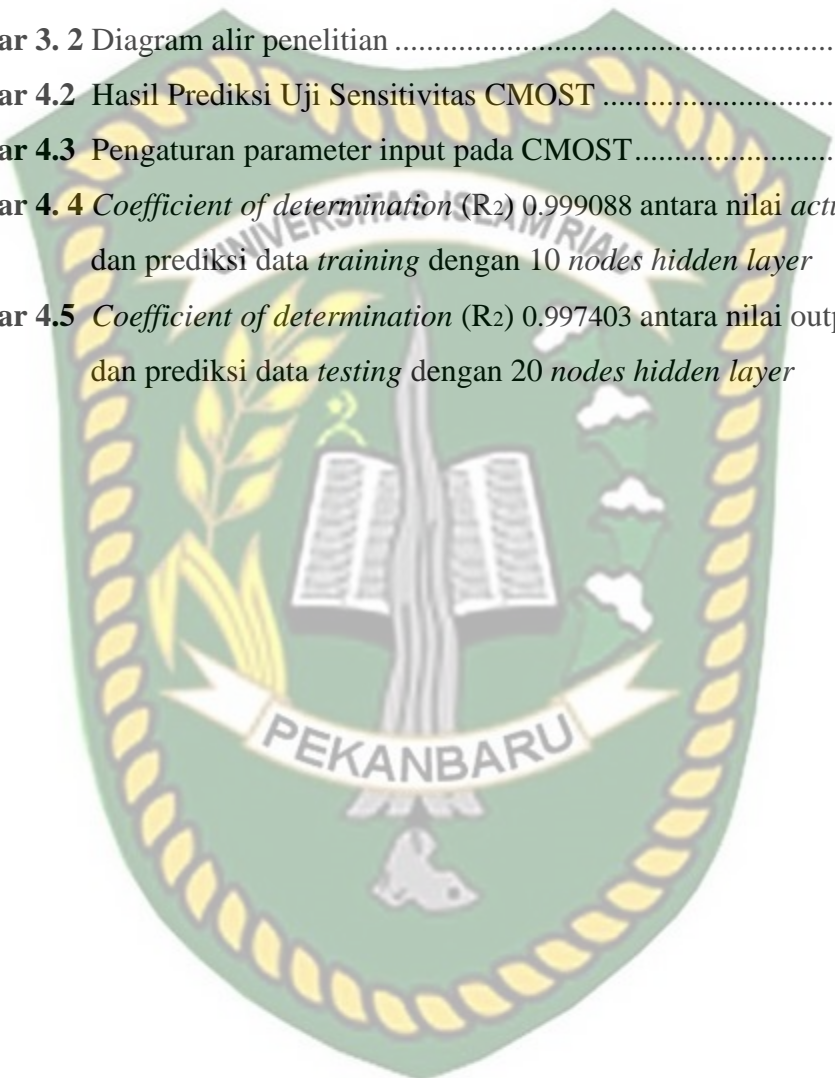
HALAMAN PENGESAHAN	i
PERNYATAAN KEASLIAN TUGAS AKHIR	ii
KATA PENGANTAR	iii
DAFTAR ISI	iv
DAFTAR GAMBAR	vi
DAFTAR TABEL	vii
DAFTAR LAMPIRAN	viii
DAFTAR SINGKATAN	ix
ABSTRAK	x
ABSTRACT	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tujuan Penelitian.....	2
1.3 Manfaat Penelitian.....	2
1.4 Batasan Masalah.....	3
BAB II TINJAUAN PUSTAKA	4
2.1. <i>Hydraulic Fracturing</i>	4
2.2. <i>Artificial Neural Network</i>	6
BAB III METODOLOGI PENELITIAN	8
3.1. Data Yang Dibutuhkan.....	8
3.2 Pemodelan ANN	11

3.3. Diagram Alir Penelitian	12
3.4 Jadwal Penelitian.....	12
BAB IV HASIL DAN PEMBAHASAN	14
BAB V PENUTUP.....	20
5.1 KESIMPULAN	20
5.2 SARAN	20
DAFTAR PUSTAKA.....	21
LAMPIRAN.....	25



DAFTAR GAMBAR

Gambar 2. 1 Jaringan Neuron Tiga <i>Layer</i>	7
Gambar 3. 1 Model Reservoir Sector Model.....	10
Gambar 3. 2 Diagram alir penelitian	12
Gambar 4.2 Hasil Prediksi Uji Sensitivitas CMOST	15
Gambar 4.3 Pengaturan parameter input pada CMOST.....	16
Gambar 4. 4 <i>Coefficient of determination</i> (R^2) 0.999088 antara nilai <i>actual</i>	18
dan prediksi data <i>training</i> dengan 10 <i>nodes hidden layer</i>	
Gambar 4.5 <i>Coefficient of determination</i> (R^2) 0.997403 antara nilai output.....	18
dan prediksi data <i>testing</i> dengan 20 <i>nodes hidden layer</i>	



DAFTAR TABEL

Tabel 3.1 Properti Fluida Lapangan Barnett	8
Tabel 3.2 Karakteristik Reservoir Lapangan Barnett	9
Tabel 3.3 Data Range <i>Settings</i>	10
Tabel 3.4 Jadwal Penelitian	13
Tabel 4.1 Nilai <i>Mean Square Error</i> (MSE) dan <i>coefficient correlation</i> (R) pada jumlah <i>nodes hidden layer</i> yang berbeda dengan menggunakan 157 data.....	17



DAFTAR LAMPIRAN

LAMPIRAN I	Data dan Hasil Prediksi	25
LAMPIRAN II	Pemrograman <i>Phyton</i>	29



Dokumen ini adalah Arsip Milik :
Perpustakaan Universitas Islam Riau

DAFTAR SINGKATAN

<i>ANN</i>	<i>Artificial Neural Network</i>
<i>CMG</i>	<i>Computer Modelling Group</i>
<i>RF</i>	<i>Recovery Factor</i>
<i>R²</i>	<i>Cooficient determination</i>
<i>RMSE</i>	<i>Root Mean Square Error</i>
<i>MAPE</i>	<i>Mean Absolute Precentage Error</i>
<i>AI</i>	<i>Artificial Inttelegence</i>
<i>BP</i>	<i>Back Propagation</i>
<i>BHP</i>	<i>Bottom Hole Pressure</i>
<i>C_p</i>	<i>Centipoise</i>
<i>Ft</i>	<i>Feet</i>
<i>mD</i>	<i>mili Darcy</i>



PREDIKSI TINGKAT KEBERHASILAN DESAIN *HYDRAULIC FRACTURING* PADA *SHALE GAS RESERVOIR* MENGGUNAKAN *ARTIFICIAL NEURAL NETWORK*

ISMI RALDA

173210326

ABSTRAK

Hydraulic fracturing adalah suatu elemen kunci untuk teknik perminyakan sejak lebih dari 50 tahun, dan menjadi suatu cara yang paling alternatif dalam meningkatkan *recovery* pada *reservoir shale gas* dengan permeabilitas sangat kecil antara 0,01 sampai 0,00001 md. Metode ANN ini merupakan salah satu metode *deep learning* dari data *input* dan menghasilkan data *output*. Dengan menggunakan ratusan data diharapkan mendapatkan hasil prediksi dari RF menggunakan metode ANN secara optimal maka akan dilakukan *trial and error* pada jumlah *nodes hidden layer*. Adapun tujuan penelitian ini adalah untuk memprediksi tingkat keberhasilan kinerja *hydraulic fracturing* menggunakan *Artificial Neural Network* (ANN). Metode yang digunakan dalam penelitian ini adalah metode *simulation research* menggunakan CMG GEM untuk pemodelan simulasi reservoir dan sensitivitas data menggunakan CMG CMOST dengan input parameter mekanika batuan, komposisi mineral batuan, *fracture half length*, *fracture spacing*, *fracture width* dan permeabilitas formasi dan *output* berupa *recovery factor* menggunakan *Artificial Neural Network* dengan metode *Back Propagation* Sehingga dapat menghasilkan prediksi yang akurat. Dengan menggunakan 157 data dengan rasio 75% dari hasil model perhitungan RF dari *software* CMG untuk di-*training* dan 25% dari hasil model untuk di-*testing*. Supaya mendapatkan hasil prediksi dari RF menggunakan metode ANN secara optimal maka akan dilakukan *trial and error* pada jumlah *nodes hidden layer*. Didapatlah *nodes hidden layer* yang optimal dan stabil pada *nodes* 10 dengan nilai RMSE dan MAPE pada data *training* bernilai 0.048843; 0.561355 dan pada data *testing* 0.084627; 0.963113. Nilai analisis statistik lainnya seperti *Coefficient determination* (R^2) yaitu 0.999088 untuk data *taining* dan 0.997403 untuk data *testing*. Dapat disimpulkan pada penelitian ini bahwa penggunaan ANN dalam prediksi RF menggunakan 10 *nodes hidden layer* terbukti sangat bagus dan berhasil.

Kata Kunci: *Shale Gas, Hydraulic Fracturing, Artificial Intelegence, Artificial Neural Networks (ANN).*

THE SUCCESSFUL PREDICTION OF HYDRAULIC FRACTURING DESIGN IN SHALE GAS RESERVOIR BY USING ARTIFICIAL NEURAL NETWORK

ISMI RALDA

173210326

ABSTRACT

Hydraulic fracturing is a key element for petroleum engineering since more than 50 years, and is the most alternative way to increase recovery in shale gas reservoirs with very small permeability between 0.01 to 0.00001 md. This ANN method is a deep learning method from input data and produces output data. By using hundreds of data, it is expected to get prediction results from RF using the ANN method optimally, trial and error will be carried out on the number of hidden layer nodes. The purpose of this study is to predict the success rate of hydraulic fracturing performance using artificial neural network (ANN). The method used in this study is a simulation research method using CMG GEM for reservoir simulation modeling and data sensitivity using CMG CMOST with input rock mechanics parameters, rock mineral composition, fracture half length, fracture spacing, fracture width and formation permeability and output in the form of recovery factor. using Artificial Neural Network with Back Propagation method so that it can produce accurate predictions. By using 157 data with a ratio of 75% of the results of the RF calculation model from the CMG software for training and 25% of the model results for testing. In order to get the prediction results from RF using the ANN method optimally, trial and error will be carried out on the number of hidden layer nodes. The optimal and stable hidden layer nodes are obtained at nodes 10 with RMSE and MAPE values in the training data worth 0.048843; 0.561355 and on testing data 0.084627; 0.963113. Other statistical analysis values such as Coefficient determination (R²) are 0.999088 for taining data and 0.997403 for testing data. It can be concluded in this study that the use of ANN in RF prediction using 10 hidden layer nodes has proven to be very good and successful.

Keywords: *Shale Gas, Hydraulic Fracturing, Artificial Intelligence, Artificial Neural Networks (ANN).*

BAB I PENDAHULUAN

1.1 Latar Belakang

Natural gas yang biasanya diproduksi dari *shale formation* disebut *shale gas* yang memiliki permeabilitas antara 0.01- 0.00001 md karena permeabilitas batuan yang sangat kecil maka upaya yang dilakukan untuk meningkatkan konduktivitas aliran sekitar sumur yaitu menggunakan metode *hydraulic fracturing* (National Energy Technology Laboratory Prepared, 2009).

Penelitian yang dilakukan oleh (Bastos Fernandes et al., 2020) membahas ada beberapa parameter yang mempengaruhi keberhasilan dari *hydraulic fracturing*, untuk itu perlu dilakukan pemahaman terhadap parameter yang mempengaruhinya. Parameter yang mempengaruhi *hydraulic fracturing* yaitu: properti rekahan, seperti bentuk rekahan, panjang rakahan, lebar rekahan, tinggi rekahan, permeabilitas formasi, dan lain-lain. Yang memainkan peran penting dalam menentukan keberhasilan pengembangan *shale*. Desain rekahan memiliki 2 hal yang diharapkan yaitu untuk desain properti *fracture* yang lebih optimal, *recovery* yang diharapkan dan yang terpenting untuk pengembalian ekonomi yang lebih maksimal. Ia juga membahas faktor-faktor yang dapat mempengaruhi keefetifan *hydraulic fracturing*.

Penelitian yang dilakukan oleh (He et al., 2019) juga melakukan *hydraulic fracturing* menggunakan metode *Artificial Neural Network* dengan menginjeksikan campuran air, pasir, dan berbagai bahan kimia tambahan ke dalam lubang sumur pada tekanan yang cukup di Barnett *Shale* dan berhasil meningkatkan produksi gas secara signifikan dengan *coeficient determination* (r^2) dari hasil *running Artificial Neural Network* adalah 0,93699 dan dinilai cukup berhasil diterapkan. Oleh karena itu, model dan metode ini digunakan untuk pengujian simulasi lebih lanjut. Sejak operasi komersial pertama di *shale* Barnett, kombinasi *hydraulic fracturing* dan pengeboran horizontal telah mengubah *shale* yang tidak produktif menjadi ladang gas alam terbesar di Amerika Serikat.

Tantangan yang dihadapi pada reservoir *shale gas* berbeda dengan reservoir konvensional, salah satunya adalah sifat porositas ganda dari reservoir *shale gas*. Reservoir *shale gas* memiliki persamaan dengan reservoir karbonat dimana memiliki volume penyimpanan yang berbeda yaitu porositas matriks dan *natural fracture*. *Natural fracture* memiliki sifat plastis yang umumnya tertutup disebabkan oleh tekanan *overburden* batuan. Akibatnya reservoir *shale gas* tidak dapat diproduksi tanpa *stimulasi hydraulic fracturing* karena permeabilitasnya yang sangat rendah. *Hydraulic Fracturing* diharapkan dapat mengaktifkan kembali dan menghubungkan kembali rekahan alami (Hamada, 2017).

Dengan mengamati parameter *desain hydraulic fracturing* seperti *half length*, *width*, *heights*, dan permeabilitas terhadap RF. Maka akan dilakukan penelitian dengan menggunakan salah satu metode dari *Artificial Intelligence* (AI) yang disebut *Artificial Neural Networks* (ANN) untuk menunjukkan pengaruh parameter tersebut terhadap *Design Hydraulic Fracturing*. Oleh karena itu, dalam penelitian ini berfokus kepada pengaplikasian ANN menggunakan *software* Anaconda dengan bahasa pemrograman *python* dalam memprediksi nilai RF yang sebelumnya telah diperhitungkan dengan menggunakan *software Computer Modeling Group* (CMG).

1.2 Tujuan Penelitian

Adapun tujuan yang peneliti lakukan adalah untuk memprediksi tingkat keberhasilan desain *Hydraulic fracturing* pada *shale gas* dengan menggunakan *Artificial Neural Network* (ANN).

1.3 Manfaat Penelitian

Terdapat beberapa manfaat yang diperoleh dari penelitian ini adalah :

1. Penelitian ini diharapkan dapat mempercepat waktu prediksi keberhasilan *hydraulic fracturing* dari parameter *poisson ratio*, *fracture width*, *fracture half length*, *fracture spacing* dan permeabilitas formasi.
2. Penelitian ini diharapkan dapat meningkatkan akurasi tingkat keberhasilan *Design Hydraulic Fracturing* pada reservoir *shale gas*.

1.4 Batasan Masalah

Untuk memperoleh hasil penelitian yang lebih terarah dan tidak menyimpang dari tujuan penelitian, maka penelitian ini membatasi mengenai beberapa hal sebagai berikut :

1. Penelitian Ini menggunakan pemodelan dari simulator *Computer Modelling Group* (CMG).
2. Penelitian ini hanya berfokus pada *Hydraulic Fracturing* menggunakan salah satu metode *Artificial Intelegent* yaitu *Artificial Neural Network* (ANN) dengan algoritma prediksi yang digunakan yaitu algoritma *backpropagation*.
3. Metode *Hydraulic Fracturing* digunakan pada *shale gas*.
4. Hanya menggunakan satu model lapangan reservoir yang berkarakteristik *Shale gas reservoir*.
5. Tidak menggunakan model *geomechanics*.
6. Model reservoir yang terdiri dari komposisi gas didapat dari grup CMG.
7. Penelitian ini tidak membahas tentang keekonomian.

BAB II TINJAUAN PUSTAKA

2.1. *Hydraulic Fracturing*

Hydraulic fracturing adalah praktik stimulasi formasi yang digunakan untuk menciptakan permeabilitas tambahan dalam formasi produksi. Dengan menciptakan permeabilitas tambahan, *hydraulic fracturing* memfasilitasi migrasi fluida ke lubang sumur untuk tujuan produksi. Banyak bidang berproduksi hanya karena proses *hydraulic fracturing*. Aplikasi dari generasi pertama *fracturing* pada dasarnya adalah perawatan kecil untuk melewati kerusakan fluida pengeboran dekat lubang sumur ke formasi dengan permeabilitas dalam kisaran *milidarcy* (Manuel et al., 2015).

Desain *hydraulic fracturing* memerlukan pertimbangan teknik yang cukup untuk menentukan properti rekahan di tempat, seperti bentuk rekahan, panjang rekahan, lebar rekahan, tinggi rekahan, permeabilitas formasi dan lain-lain (He et al., 2019). Yang memainkan peran penting dalam menentukan keberhasilan pengembangan *shale*. Desain rekahan membutuhkan penentuan yang diharapkan properti *fracture*, *recovery* yang diharapkan dan yang terpenting, untuk pengembalian ekonomi yang lebih maksimal.

Menurut (Fei et al., 2016) pada penelitian yang dia lakukan ada beberapa masalah yang perlu dipertimbangkan saat menggunakan teknik *Hydraulic farcturing* antara lain kehilangan panjang *fracture* yang efektif, pemulihan cairan beban rendah, waktu arus laju alir dan ketersediaan air.

Formasi Barnett merupakan salah satu lapangan yang melakukan proyek *hydraulic fracturing* yang terbesar di dunia. Barnett telah memulai *fracturing* sumur horizontal pertama 2003-2004 telah dimulai, metode *hydraulic fracturing* yang dapat meningkatkan perkiraan *recovery* akhir dari 11 hingga 18% (Jamshidnezhad et al., 2020).

Menurut (Economides & Nolte, 2015) pada penelitian yang dilakukan faktor keberhasilan pada sumur horizontal dari penerapan rekahan yaitu *maximum stress horizontal*, serta jumlah dan jarak perekahan.

Untuk merancang *treatment hydraulic fracturing*, pertama-tama perlu diprediksi pertumbuhan geometri rekahan sebagai fungsi parameter *treatment*. Panjang, tinggi, dan lebar rekahan menentukan geometri rekahan, yang pada akhirnya mempengaruhi produksi minyak/gas dari reservoir rekahan. Pertumbuhan aktual geometri rekahan pada formasi heterogen merupakan fenomena yang kompleks dan sangat sulit untuk diprediksi secara pasti. Selama bertahun-tahun, bagaimanapun, berbagai model digunakan untuk menentukan perkembangan geometri rekahan (Taylor, 2018).

2.1.1. Faktor yang mempengaruhi keberhasilan *hydraulic fracturing*

Untuk hasil dari stimulasi dengan menggunakan metode *hydraulic fracturing* itu juga tergantung dari faktor yang mempengaruhinya.

1. *Poisson Ratio*

Menurut Sun *Poisson rasio* dapat mencerminkan kekuatan *fracture shale* selama rekahan, dan salah parameter penting keberhasilan *hydraulic fracturing* dimana dapat mencerminkan kemampuan *shale* untuk mempertahankan rekahan buatan setelah rekahan. Rickman dan Mullen baru-baru ini menyarankan bahwa sampel *shale* dengan *rasio Poisson* rendah dan *modulus Young* yang tinggi dapat lebih mudah dilakukan *hydraulic fracturing* (Rickman, 2018).

2. Panjang Setengah Rekahan (*Fracture Half Length*)

Panjang rekahan (f_x) merupakan salah satu bagian yang digunakan dalam perancangan desain optimasi perekahan (Rachmat & Nugroho, 2010). Terbentuknya rekahan biasanya lebih cenderung ke bawah yang menunjukkan adanya pendesakan rekahan sehingga *fracture* yang terbenstuk cenderung lebih kecil (Latumaerissa et al., 2015).

3. Lebar Rekahan (*Fracture width*)

Fracture width adalah jarak antara dua *fracture* yang saling berhadapan. Menurut penelitian yang dilakukan (Daneshy, 2010) salah satu faktor penting dalam

menentukan desain *hydraulic fracturing* adalah *fracture width*. Ada tiga hal yang diidentifikasi dalam dimensi desain rekahan yaitu panjang, lebar dan tinggi rekahan.

4. Permeabilitas formasi

Pada lapangan Khaleel yang mempunyai nilai permeabilitas yang rendah dan tidak dilakukan *hydraulic fracturing* pada tahap produksi *primary* hanya mendapatkan *recovery factor* sebesar 5%, maka dari itu *hydraulic fracturing* dilakukan untuk meningkatkan kontak antara reservoir dan lubang sumur (Al Kalbani et al., 2018).

5. *Fracture spacing*

Menurut penelitian yang dilakukan oleh (Guo et al., 2018) jika *fracture spacing* terlalu kecil, interaksi antar rekahan akan menjadi lebih jelas dan membuat produksi gas menjadi tidak baik. Jadi, penting untuk mempelajari efek *fracture spacing* pada kinerja produksi *shale gas*. Dapat diketahui bahwa pengaruh *fracture spacing* terhadap kinerja produksi gas sangat signifikan. Juga, dari hasil, kita dapat menemukan bahwa semakin kecil *fracture spacing*, semakin banyak gas kumulatif produksi (Guo et al., 2018).

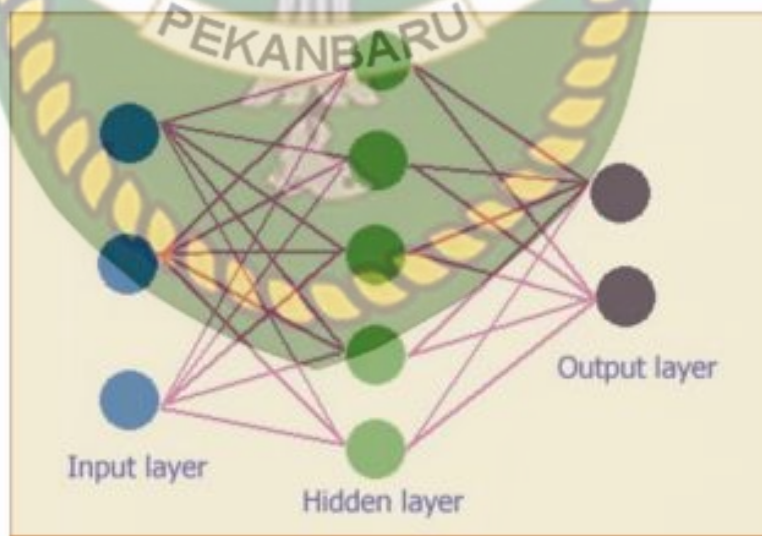
2.2. *Artificial Neural Network*

Artificial Neural Network adalah model matematika yang telah ada selama hampir enam dekade. Baru-baru ini, ANN diperkenalkan dalam ilmu geosains dan teknik reservoir untuk meramalkan distribusi spasial parameter di mana sebelumnya terdapat ketidakpastian substansial yang khas dari data geologi yang tidak teratur secara spasial (Shafiei et al., 2013).

Deep learning merupakan teknik pembelajaran berbasis jaringan syaraf tiruan atau *Artificial Neural Network* yang dipengaruhi oleh susunan neuron seperti yang terletak di otak manusia (Temizel et al., 2020). Teknik ini menggunakan susunan multilayer dan model yang memiliki banyak lapisan untuk diproses dan diperoleh informasi tentang data representasi dengan berbagai tingkat proses pembelajaran data (Temizel et al., 2020). *Artificial neural network* merupakan interkoneksi tipikal dapat

dipandang sebagai struktur *multilayer*. *Artificial Neural Network* adalah kumpulan neuron yang tersusun dalam formasi tertentu. Neuron dikelompokkan menjadi lapisan. Jaringan *multilayer* biasanya terdiri dari lapisan *input*, satu atau lebih lapisan tersembunyi, dan lapisan *output*. Gambar 2.1 menunjukkan lapisan *input*, satu lapisan *hidden*, dan satu lapisan *output*, semuanya terhubung dengan tepat, tetapi dengan aliran searah (Mohaghegh, 2000).

Faktor pembobotan harus ditentukan, dan ini merupakan *running Artificial Neural Network* melalui penyesuaian berulang bobot sambungan hingga presisi yang sesuai dari parameter *output* yang diinginkan dapat diperkirakan dengan tingkat presisi yang dapat diterima. Ketepatan model ANN bergantung pada topologi representasi *input-output*, karena lebih dari satu lapisan tersembunyi dapat diperkenalkan untuk menghasilkan pola kalkulasi dan bobot bersyarat yang berbeda. Pelatihan berusaha untuk mengidentifikasi pola internal yang optimal untuk ANN, dan analogi dengan model neuron-akson dari otak untuk identifikasi pola adalah asal dari nama Jaringan ANN.



Gambar 2. 1 Jaringan Neuron Tiga *Layer*

BAB III METODOLOGI PENELITIAN

3.1. Data Yang Dibutuhkan

a. Simulasi Reservoir

Pada penelitian ini, pemodelan dilakukan dengan menggunakan *software* CMG (GEM). Penelitian ini dilakukan di lapangan X yang mana model reservoir memiliki dimensi 66 x 20 x 3. Parameter yang dibutuhkan dalam membangun model reservoir adalah *rock properties* dan *formation properties*.

Tabel 3.1 Properti Fluida Lapangan Barnett

Komposisi	Fraksi Mol	Komposisi	Fraksi mol
N ₂	1.9	C3	10.62
O ₂	0.25	n- C4	4.4
CO ₂	0.66	i- C4	2.6
H ₂	0.07	n- C5	1.02
C1	60.61	i- C5	1.3
C2	16.56		

Sumber : (Johnson et al., 2015).

b. Data Reservoir

Data reservoir merupakan data sekunder yang membahas tentang kondisi *shale gas reservoir* di Barnett adalah sebagai berikut:

Tabel 3.2 Karakteristik Reservoir Lapangan Barnett

Data reservoir		
Jenis formasi	<i>Shale gas</i>	
Kedalaman	5463	Ft
Gradien tekanan pori	0.54	psi/ft
Tekanan inisial	2950	psi/ft
BHP	500	Psi
<i>Production Time</i>	6	Year
Temperatur Reservoir	150	°F
Viscositas gas	0.0201	Cp
Saturasi gas awal	0.70	
Kompresibilitas total	3×10^{-6}	psi ⁻¹
Permeabilitas Matrix	0.00015	Md
Porositas Matrix	0.06	
Konduktivitas <i>Fracture</i>	1	md-ft
<i>Half-length Fracture</i>	500	ft
<i>Fracture spacing</i>	100	ft
<i>Poisson Ratio</i>	0.25	
<i>Fracture width</i>	5	Ft

Sumber : (Jamshidnezhad et al., 2020) dan (Roussel & Sharma, 2011).

Selanjutnya dilakukan pembuatan sensitivitas data dan *running* menggunakan CMG CMOST dengan *input range* parameter dan *output* berupa *recovery factor*. Pemilihan parameter yang akan digunakan sebagai *input* dalam CMG dan ANN didasari oleh beberapa penelitian yaitu (Keenan, 2015) yang diperkuat dengan data tambahan dari penelitian sebelumnya oleh (Oraon & Chatterjee, 2015).

Tabel 3.3 menunjukan parameter beserta *range* minimum, dan maximum.


Tabel 3.3 Data Range Settings

Properti	Satuan	Nilai	
		<i>Lower limit</i>	<i>Upper Limit</i>
<i>Poisson Ratio</i>		0.6	0.25
<i>Fracture Spacing</i>	Psi	80	200
<i>Fracture Half length</i>	Ft	300	700
<i>Fracture width</i>	ft	3.65	6.25
Permeabilitas Formasi	Md	0.00001	0.001

Sumber : (Jamshidnezhad et al., 2020), (Keenan, 2015) dan (Oraon & Chatterjee, 2015).

c. Model Reservoir

Permodelan yang dilakukan dalam penelitian ini dilakukan menggunakan *software* CMG, sumber model diperoleh dari *group* CMG terdapat pada Lampiran di bawah :



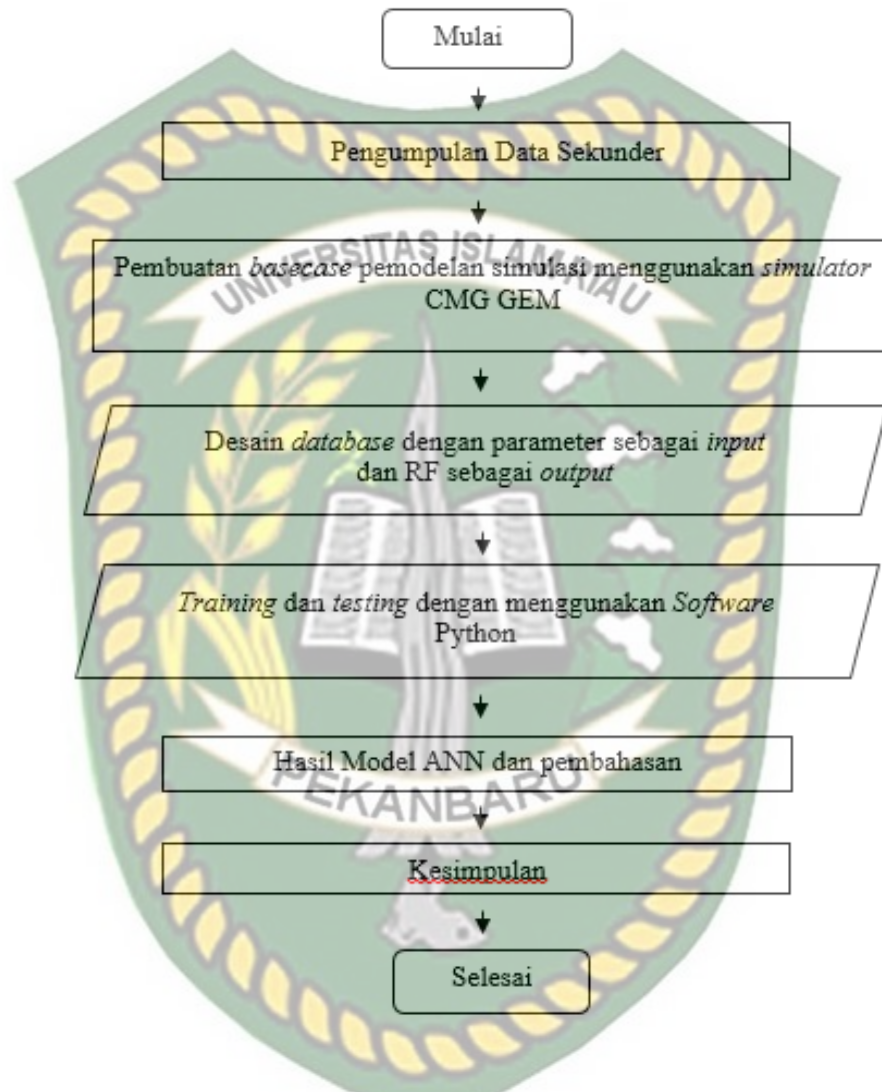
Gambar 3. 1 Model Reservoir Sector Model

Pemodelan simulasi lapangan Barnett ini adalah model reservoir dengan karakteristik batuan *shale gas*, memiliki jumlah *layer* 3 dengan grid 66 x 20 x 3 dengan ukuran grid mewakili ukuran reservoir 9900 ft arah *i*, 4000 ft arah *j* dan 45 ft arah *k*. Model *hydraulic fracturing* yang digunakan yaitu *planar fracture* arah horizontal karena arah rambat rekahan tegak lurus terhadap arah horizontal utama minimum penekanan (Chen Et Al., 2020). Penelitian yang dilakukan (Bunger et al., 2012) menunjukkan bahwa untuk reservoir dengan kontras tegangan tinggi model *fracture hydraulic planar* adalah yang paling disarankan. *Fracture* akan tumbuh di sepanjang jalan dengan hambatan terkecil, *fracture* akan tumbuh secara vertikal ketika gangguan tegangan lebih kuat dari perbedaan tegangan antar-lapisan. Dengan demikian apabila arah *stress* utama terkecil pada arah horizontal maka rekahan yang terjadi adalah rekahan vertikal, sedangkan apabila *stress* utama terkecil pada arah vertikal maka rekahan yang terbentuk adalah rekahan horizontal. Dipengaruhi oleh distribusi tegangan *interlayer* dan gangguan tegangan, patahan di zona tegangan tinggi dapat berubah bentuk, merusak efektivitas rekahan.

3.2 Pemodelan ANN

Setelah dilakukannya *running* terhadap data input sesuai dengan *range* yang telah ditentukan menggunakan CMG CMOST, maka akan terbentuk beberapa skenario data simulasi yang digunakan kembali untuk membangun model ANN. Dalam penelitian ini algoritma yang akan digunakan adalah algoritma *backpropagation* dengan 1 *Input Layer*, 1 *Hidden Layer*, 1 *Output*. Langkah pertama adalah melakukan pengimputan data pada *software* ANN yaitu *software* Anaconda terhadap *input* data yang dinormalisasikan menggunakan normalisasi *min max*. Data tersebut akan dibagi menjadi 75% untuk *Training* dan 25% untuk *Testing* dan *validation*.

3.3. Diagram Alir Penelitian



Gambar 3. 2 Diagram alir penelitian

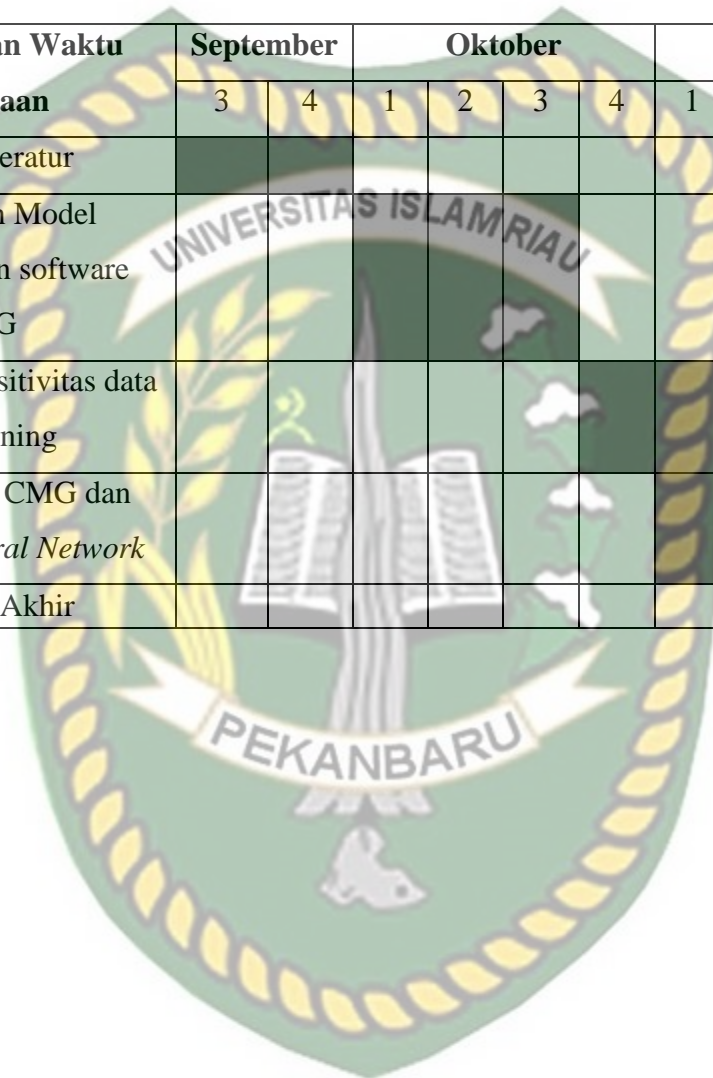
3.4 Jadwal Penelitian

Penelitian ini dilakukan di Laboratorium Simulasi Teknik Perminyakan Universitas Islam Riau dengan menggunakan data sekunder yakni data yang berasal dari buku, jurnal dan bulan referensi lainnya yang berhubungan dengan penelitian

ini. Penelitian ini akan dilaksanakan dalam waktu 3,5 Bulan dari bulan September 2021 sampai dengan bulan Desember 2021.

Tabel 3.4 Jadwal Penelitian

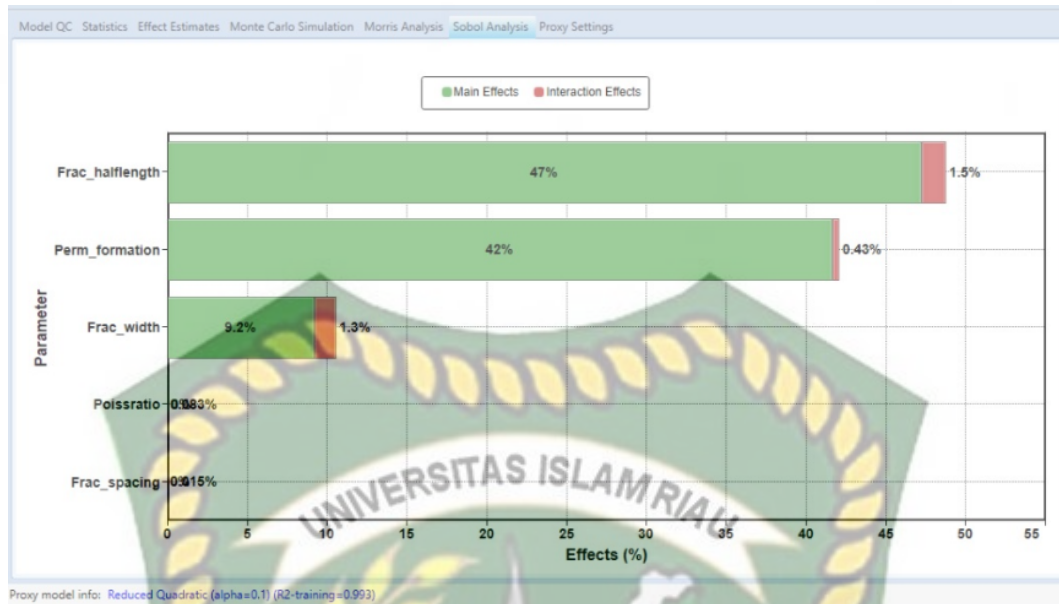
No	Kegiatan dan Waktu Pelaksanaan	September		Oktober				November				Desember	
		3	4	1	2	3	4	1	2	3	4	3	4
1	Studi Literatur												
2	Pembuatan Model menggunakan software CMG												
3	Pembuatan sensitivitas data dan running												
4	Analisa hasil CMG dan <i>Artificial Neural Network</i>												
5	Laporan Akhir												



BAB IV HASIL DAN PEMBAHASAN

Pada penelitian ini peneliti melakukan prediksi terhadap keberhasilan *hydraulic fracturing* menggunakan metode *Artificial Neural Network* dengan algoritma *Back Propagation* (BP). Dalam penelitian ini, digunakan *high parameter* untuk memprediksi parameter mana yang paling baik dalam desain *hydraulic fracturing* berdasarkan nilai *Recovery Factor* menggunakan metode *Artificial Neural Network*. Adapun *high parameter* yang didefinisikan paling berpengaruh terhadap desain *hydraulic fracturing* pada *shale gas* reservoir (Rezaei et al., 2020). *High parameter* tersebut adalah *fracture half length* yang mana digunakan ada 5 parameter yang digunakan pada penelitian ini yaitu *poison ratio*, permeabilitas formasi, *fracture width*, *fracture spacing* dan *fracture half length*. Seperti yang ditunjukkan pada gambar dibawah Pada pengujian sensitivitas data menggunakan CMOST diperoleh Prediksi faktor yang paling berpengaruh terhadap desain *hydraulic fracturing* adalah *fracture half length* dimana hal ini menunjukkan bahwa ketika titik pengamatan semakin dekat dengan jarak antar patahan, patahan setengah panjang dan interaksinya berkontribusi pada 20% dari perubahan penipisan tekanan pori. Diamati bahwa interaksi antara *fracture half length* dan jarak patahan memiliki pengaruh yang paling signifikan berdampak pada tegangan horizontal minimum pada suatu titik di dalam spasi (Rezaei et al., 2020).

Pada penelitian ini dilakukan uji sensitivitas untuk mengetahui parameter mana yang paling berpengaruh terhadap desain *hydraulic fracturing*. Gambar 4.2 di bawah merupakan pengujian sensitivitas menggunakan CMG CMOST menunjukkan parameter yang paling berpengaruh adalah *fracture half length*.



Gambar 4.2 Hasil Prediksi Uji Sensitivitas CMOST

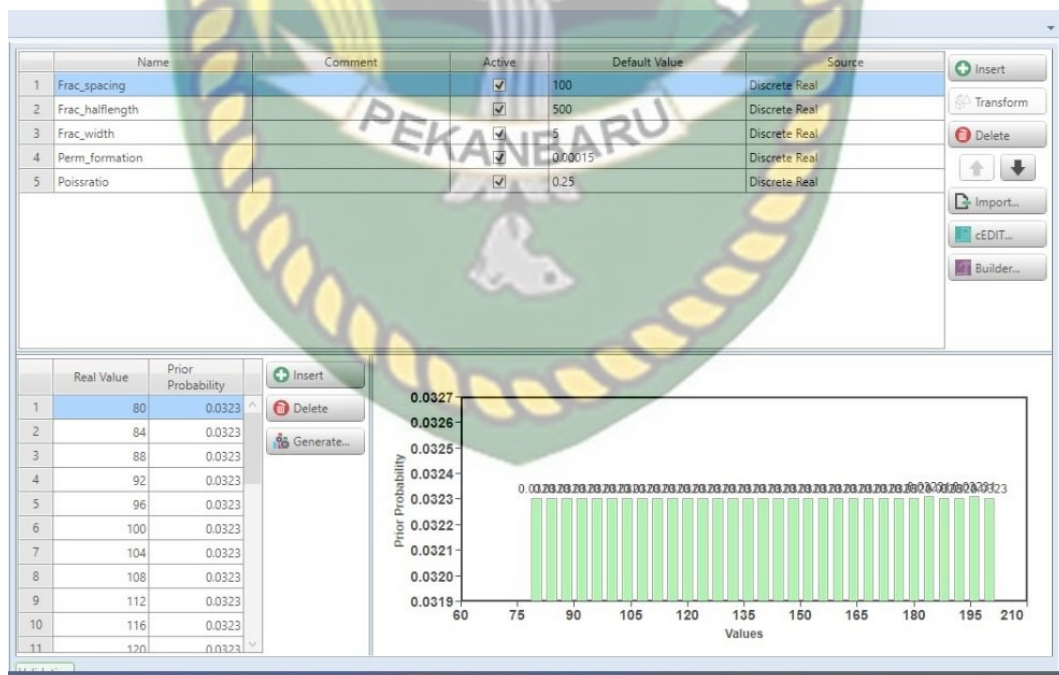
Pemodelan reservoir dilakukan dengan menggunakan software CMG Gem kemudian melakukan sensitifitas data menggunakan CMG Cmost terhadap parameter *lower* dan *upper* yang kemudian akan terbentuk 157 skenario data simulasi yang digunakan kembali sebagai input dalam membangun model ANN. Kemudian data diambil untuk nantinya dilakukan untuk memprediksi nilai RF menggunakan ANN BP. Pada penelitian ini peneliti melakukan prediksi terhadap keberhasilan desain *hydraulic fracturing* menggunakan *Artificial Neural Network* dengan algoritma *Back Propagation* (BP).

Pada penelitian ini metode *Back propagation* dengan menggunakan *Software Anaconda* dengan bahasa pemrograman *python*. Menurut (Syahrudin & Kurniawan, 2018) Bahasa pemrograman *python* adalah Bahasa interpretative multiguna yang salah satu bahasa pemrograman yang baru di masa sekarang, pada bahasa pemrograman ini kita lebih simpel dan singkat dalam membuat sebuah Program, setiap program yang dibuat akan membutuhkan inputan dan hasil outputan.

Pada penelitian yang dilakukan (Chamidah et al., 2016) menyebutkan bahwa pembangunan bahasa pemrograman *Artificial Neural Network-Back Propagation* langkah pertama diawali dengan menginputkan dataset yang berfungsi sebagai input *layer*. Kemudian dilakukan normalisasi data dengan range nilai *output* ke

dalam range *input* dengan cara normalisasi data ke dalam range 0 sampai 1 agar *output* bisa di dormalisasi. Dimana input pada penelitian ini adalah 5 parameter yaitu *poisson ratio*, *fracture half length*, *fracture width*, permeabilitas formasi dan *fracture spacing* dan data *output* berupa *recovery factor*. Hal yang harus diperhatikan untuk memperoleh model ANN yang bagus yaitu dengan menggunakan metode *trial and error* (Noureldien & El-Banbi, 2015). Dimana hal ini dilakukan untuk menentukan jumlah *nodes* yang paling optimal di *hidden layer*. (Kholis, 2015) menyatakan bahwa jumlah *nodes* harus melebihi jumlah input *layer* dan tidak lebih dari dua kali jumlah input *layer*.

Gambar 4.3 merupakan input parameter pada CMG CMOST sehingga didapat 157 data skenario beserta distribusi datanya. Prediksi menggunakan ANN BP membutuhkan kombinasi data *training* dan *testing* dengan rasio 75% : 25% seperti pada penelitian yang dilakukan (Shafiei et al., 2013). Dimana data *training* yang digunakan untuk membangun dan membentuk data yang sedangkan data *testing* digunakan untuk memprediksi serta mengukur validasi keakuratan model. Setiap data *training* dan data *testing* akan memberikan nilai RSME, r^2 dan MAPE.



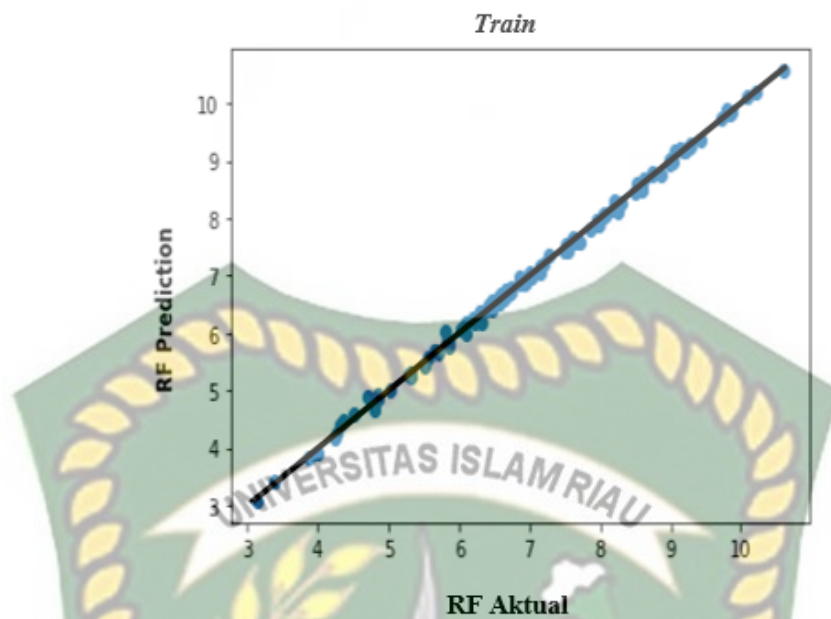
Gambar 4.3 Pengaturan parameter input pada CMOST

Setiap jumlah hidden *layer* akan mempengaruhi nilai r^2 , RMSE dan MAPE. Pada penelitian ini dilakukan menggunakan *trial and error* dengan jumlah *layer* 10. Tabel dibawah ditunjukkan hasil dari masing-masing *trial* dan *error* yang dilakukan. Dengan menggunakan 157 dataset dan *range* jumlah *nodes hidden layer* diantara 3 hingga 10, maka akan dicari nilai MSE yang terendah pada data *training* dan *testing*.

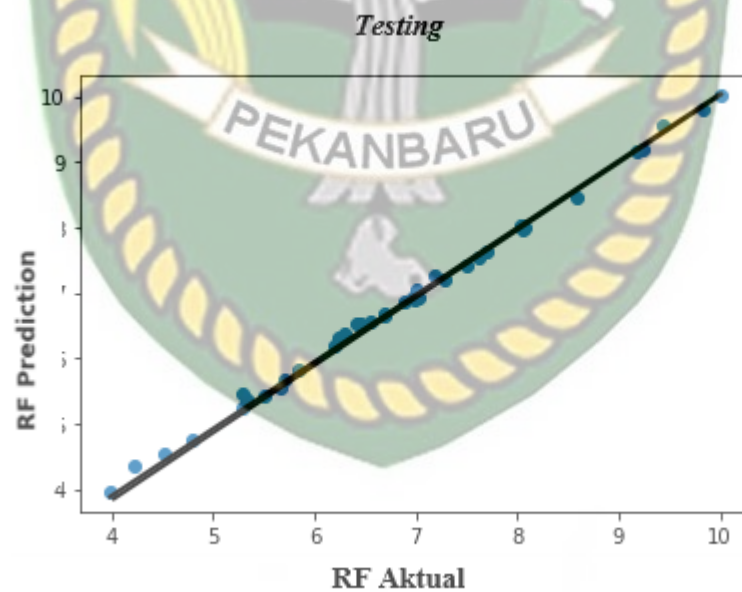
Tabel 4.1 Nilai *Mean Square Error* (MSE) dan *coefficient correlation* (R) pada jumlah *nodes hidden layer* yang berbeda dengan menggunakan 157 data.

Jumlah <i>nodes</i> pada <i>hidden</i> <i>layer</i>	R^2		RMSE		MAPE	
	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
3	0.9521517	0.9821350	0.353166	0.2247437	4.340316	3.102757
4	0.987498	0.969213	0.173662	0.322103	1.965788	3.209834
5	0.994691	0.991371	0.119756	0.147778	1.367590	1.626548
6	0.994765	0.978499	0.122807	0.207607	1.379651	2.311474
7	0.9953167	0.987585	0.115353	0.161544	1.306072	1.6510456
8	0.997359	0.990648	0.082169	0.166677	0.948360	1.4937571
9	0.998299	0.993913	0.069826	0.111792	0.832218	1.150161
10	0.999088	0.997403	0.048843	0.084627	0.561355	0.963113

Tingkat keakurasian data salah satunya dapat dilihat pada *coefficient determination* (r^2) yang merupakan hubungan antara data aktual dengan data prediksi. Pada penelitian ini diperoleh nilai optimum pada *hidden layer* 10 yaitu 0.999088 untuk data *training* dan 0.997403 untuk data *testing*. Berikut adalah grafik hasil optimum antara data aktual dengan data prediksi.



Gambar 4.4 *Coefficient of determination (R²) 0.999088 antara nilai actual dan prediksi data training dengan 10 nodes hidden layer*



Gambar 4.5 *Coefficient of determination (R²) 0.997403 antara nilai output dan prediksi data testing dengan 10 nodes hidden layer*

Pada penelitian ini ditunjukkan bahwa semakin banyak jumlah *nodes* yang digunakan maka akan semakin bagus dan semakin cepat diperoleh nilai *output* yang

optimum, namun hal ini membutuhkan waktu yang lebih lama untuk mendapatkan data *training* dan *testing*. Nilai RMSE dan MAPE memiliki hubungan yang berbanding terbalik dengan r^2 . Semakin kecil nilai MSE hingga mendekati nilai 0 maka prediksi dari ANN tersebut akan semakin bagus, dan semakin besar nilai R hingga mendekati angka 1 maka korelasi antara *output* dan prediksi tidak jauh berbeda (Wahyu Widayati, 2013). Menurut (Maricar, 2019) MAPE (*Mean Absolut Percentage Error*) merupakan perhitungan yang digunakan untuk menghitung rata-rata presentase kesalahan mutlak. Penelitian yang dilakukan (Margi S & Pendawa, 2015) menyebutkan bahwa MAPE merupakan pengukuran kesalahan yang menghitung ukuran persentase penyimpangan antara data aktual dengan data peramalan. Kemampuan peramalan sangat baik jika memiliki nilai MAPE kurang dari 10% dan mempunyai kemampuan peramalan yang baik jika nilai MAPE kurang dari 20%.

Pada penelitian ini diperoleh tingkat keakurasian dari pemodelan ANN dikategorikan bagus karena nilai errornya yaitu 0.999088 dan 0.997403 hampir mendekati nilai 1 dan juga nilai eror bahwa tidak mencapai 1% yaitu sebesar 0.048843 untuk data *training* dan 0.084627 untuk data *testing*. Salah satu penyebabnya yaitu karena data merupakan hasil simulasi yang konsisten sehingga dapat membantu dalam pemodelan ANN. Hal ini membuktikan bahwa hasil prediksi model ANN BP pada penelitian ini terbilang sangat bagus dan hampir mendekati hasil dari model CMG dalam perhitungan *recovery factor*.

BAB V PENUTUP

5.1 KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dijelaskan sebelumnya, maka kesimpulan yang diperoleh yaitu faktor dan parameter yang paling berpengaruh pada desain *hydraulic fracturing* adalah *fracture half length* sekitar 49% diikuti oleh permeabilitas formasi sebesar 42%. Implementasi metode *Artificial Neural Network* untuk memprediksi parameter yang paling berpengaruh terhadap desain *hydraulic fracturing* menghasilkan validasi keakuratan yang sangat tinggi. Terbukti dengan menggunakan 10 *hidden nodes* diperoleh nilai *Coefficient of Determination* (R^2) pada data *training* dan data *testing* sebesar 0.999088 dan 0.997403 serta nilai MAPE 0.561355 untuk data *training* dan 0.963113 untuk data *testing*.

5.2 SARAN

Berdasarkan kesimpulan dari penelitian yang telah dilakukan, peneliti menyarankan untuk melakukan prediksi *full data* dengan data *geomechanics* dan menggabungkan dengan *software Fraccade* untuk mendesain desain rekahan dan fluida perakah *hydraulic fracturing* yang lebih kompleks..

DAFTAR PUSTAKA

- Al Kalbani, M., Al Saadi, H., Mirza, M., Kurniadi, S. D., Hilal, A., Al Kalbani, M. S., & Kelkar, S. (2018). *Bypassing Skepticism To Add Reserve: Cases Of Successful Hydraulic Fracturing In Karim Formation*. Society of Petroleum Engineers - SPE International Hydraulic Fracturing Technology Conference and Exhibition 2018, IHFT 2018. <https://doi.org/10.2118/191436-18ihft-ms>.
- Bastos Fernandes, F., Campos, W., Alves Botelho, M. O., & Queiroz Ferreira Braga, L. F. de. (2020). *Geomechanics and Flow Parameters that Influence Shale Gas/Shale Oil's Design*. Journal of Petroleum & Environmental Biotechnology, 11(1). <https://doi.org/10.35248/2157-7463.20.11.399>.
- Bunger, A. P., Zhang, X., & Jeffrey, R. G. (2012). *Parameters Affecting The Interaction Among Closely Spaced Hydraulic Fractures*. SPE Journal, 17(1), 292–306. <https://doi.org/10.2118/140426-PA>.
- Chamidah, N., . W., & Salamah, U. (2016). *Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi*. Jurnal Teknologi & Informasi ITSmart, 1(1), 28. <https://doi.org/10.20961/its.v1i1.582>.
- Chen, M., Zhang, S., Xu, Y., Ma, X., & Zou, Y. (2020). *A Numerical Method For Simulating Planar 3D Multi-Fracture Propagation In Multi-Stage Fracturing Of Horizontal Wells*. Petroleum Exploration and Development, 47(1), 171–183. [https://doi.org/10.1016/S1876-3804\(20\)60016-7](https://doi.org/10.1016/S1876-3804(20)60016-7).
- Daneshy, A. (2010). *Hydraulic Fracturing To Improve Production*. The Way Ahead, 06(03), 14–17. <https://doi.org/10.2118/0310-014-twa>.
- Economides, M., & Nolte, K. (2015). *Reservoir Stimulation*. Schlumberger. New York, 824. 9788578110796.
- Fei, Y., Perdomo, M. G., Nguyen, V. Q., Lei, Z., Pokalai, K., Sarkar, S., & Haghghi, M. (2016). *Simulation of hydraulic fracturing with propane-based fluid using a fracture propagation model coupled with multiphase flow simulation in the Cooper Basin, South Australia*. The APPEA Journal, 56(1), 415. <https://doi.org/10.1071/aj15030>.

- Guo, C., Wei, M., & Liu, H. (2018). *Study Of Gas Production From Shale Reservoirs With Multi-Stage Hydraulic Fracturing Horizontal Well Considering Multiple Transport Mechanisms*. Plos One, 13(1), 1–21. <https://doi.org/10.1371/journal.pone.0188480>.
- Hamada, G. (2017). *Comprehensive Evaluation and Development of Unconventional Hydrocarbon Reserves as Energy Resource*. Archives of Petroleum & Environmental Biotechnology Comprehensive Evaluation and Development of Unconventional. Petro and Envi Biotech, APEB-102.
- He, Q., Zhong, Z., Alabboodi, M. (2019). *Artificial Intelligence Assisted Hydraulic Fracture Design in Shale Gas Reservoir*. SPE-196608-MS Desain.
- Jamshidnezhad, M., Wang, X., & Speight, J. (2020). *Barnett Shale Case studies*. Science direct.
- Joslin, K., Ghedan, S. G., Abraham, A. M., & Pathak, V. (2017). *EOR In Tight Reservoirs, Technical And Economical Feasibility*. Society of Petroleum Engineers - SPE Unconventional Resources Conference 2017, February, 267–284. <https://doi.org/10.2118/185037-ms>
- Keenan, J. (2015). *Stress Prediction, Fracture Detection, and Multiple Attribute Analysis of Seismic Attributes in a Barnett Shale Gas Reservoir, Fort Worth Basin, Texas*. Department of Geophysics. Texas.
- Kholis, I. (2015). *Analisis Variasi Parameter Backpropagation Artificial Neural Network Terhadap Pengenalan Pola Data Iris*. Jurnal Teknik & Ilmu Komputer, 4(14), 1–10.
- Latumaerissa, A. G. Y. M., Fathaddin, M. T., & Widi, C. (2015). *Evaluasi Hydraulic Fracturing Sumur Id-18, Id-25, Dan Id-29 Pada Lapangan A. 53(9)*, Seminar Nasional Cendekiawan 2015 . 1689–1699.
- Manuel, F., Prof, S., & José, A. (2015). *Hydraulic Fracturing Design : Best Practices For A Field Development Plan*. Thesis to obtain the Master of Science Degree in Energy Engineering and Management Examination Committee.
- Margi S, K., & Pendawa, S. (2015). *Analisa Dan Penerapan Metode Single Exponential Smoothing Untuk Prediksi Penjualan Pada Periode Tertentu*. (Studi Kasus: PT.Media Cemara Kreasi). *Prosiding SNATIF, 1998*, 259–266.
- Maricar, M. A. (2019). *Analisa Perbandingan Nilai Akurasi Moving Average Dan Exponential*

Smoothing Untuk Sistem Peramalan Pendapatan Pada Perusahaan XYZ. Jurnal Sistem Dan Informatika, 13(2), 36–45.

Mohaghegh, S. (2000). *Virtual-Intelligence Applications In Petroleum Engineering: Part I - Artificial Neural Networks*. JPT, Journal of Petroleum Technology, 52(9). <https://doi.org/10.2118/58046-ms>.

National Energy Technology Laboratory Prepared. (2009). *Modern Shale Gas*. Development in the United States: A Primer. Oklahoma City, 73142 405-516-4972.

Noureldien, D. M., & El-Banbi, A. H. (2015). *Using Artificial Intelligence In Estimating Oil Recovery Factor*. Society of Petroleum Engineers -SPE North Africa Technical Conference and Exhibition 2015, NATC 2015, September, 1464–1485. <https://doi.org/10.2118/175867-ms>.

Oraon, B., & Chatterjee, A. B. (2015). *Shale Reservoir Characterization & Well Productivity Analysis - Case Studies US Shale Plays (Eagle Ford and Niobrara)*. 1–20. Biennial International Conference & Exposition.India.

Rachmat, S., & Nugroho, spto edi. (2010). *Pengaruh Ukuran Butir Dan Penempatan Proppant Terhadap Optimasi Perekahan Hidraulik Sumur Minyak*. 107–118.

Rezaei, A., Nakshatrala, K. B., Siddiqui, F., Dindoruk, B., & Soliman, M. (2020). *A Global Sensitivity Analysis And Reduced-Order Models For Hydraulically Fractured Horizontal Wells*. Computational Geosciences, 24(3), 995–1029. <https://doi.org/10.1007/s10596-019-09896-7>.

Rickman. (2018). *Environmental Effects Fractureability Evaluation Of Shale Gas Reservoirs*. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 0(0), 1–9. <https://doi.org/10.1080/15567036.2019.1651425>.

Roussel, N. P., & Sharma, M. M. (2011). *Optimizing Fracture Spacing And Sequencing In Horizontal-Well Fracturing*. SPE Production and Operations, 26(2), 173–184. <https://doi.org/10.2118/127986-PA>.

Shafiei, A., Dusseault, M. B., Zendeboudi, S., & Chatzis, I. (2013). *A New Screening Tool For Evaluation Of Steamflooding Performance In Naturally Fractured Carbonate Reservoirs*. Fuel, 108, 502–514. <https://doi.org/10.1016/j.fuel.2013.01.056>

- Syahrudin, A. N., & Kurniawan, T. (2018). *Input Dan Output Pada Bahasa Pemrograman Python (Studi Kasus : STMIK Sumedang)*. Jurnal Dasar Pemograman Python STMIK, January, 2–5.
- Taylor, P. (2018). *A Review of Hydraulic Fracture Models and Development of an Improved Pseudo-3D Model for Stimulating Tight Oil / Gas Sand Access details : Access Details : [subscription number 922857386] Energy Sources , Part A : Recovery , Utilization , and Environmen*. June. <https://doi.org/10.1080/15567030903060523>
- Temizel, C., Canbaz, C. H., Saracoglu, O., Putra, D., Baser, A., Erfando, T., Krishna, S., & Saputelli, L. (2020). *Production Forecasting in Shale Reservoirs Using LSTM Method in Deep Learning*. <https://doi.org/10.15530/urtec-2020-2878>.
- Wahyu Widayati, C. S. (2013). *Komparasi Beberapa Metode Estimasi Kesalahan Pengukuran*. Jurnal Penelitian Dan Evaluasi Pendidikan, 13(2), 182–197. <https://doi.org/10.21831/pep.v13i2.1409>
- Ren, L., Zhao, J., & Hu, Y. (2014). *Hydraulic Fracture Extending Into Network In Shale: Reviewing Influence Factors And Their Mechanism*. Scientific World Journal, 2014. <https://doi.org/10.1155/2014/847107>.