



TESIS - TE142599

**PREDIKSI ZONA RESERVOIR BERBASIS ATRIBUT
DATA LOG SUMUR DENGAN METODE
LEVENBERG - MARQUARDT**

ERNA UTAMI
NRP 2215206702

DOSEN PEMBIMBING
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Adhi Dharma Wibawa, S.T., M.T.

PROGRAM MAGISTER
BIDANG KEAHLIAN TELEMATIKA - CIO
JURUSAN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017



TESIS - TE142599

**PREDIKSI ZONA RESERVOIR BERBASIS ATRIBUT
DATA LOG SUMUR DENGAN METODE
LEVENBERG - MARQUARDT**

ERNA UTAMI
NRP 2215206702

DOSEN PEMBIMBING
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Adhi Dharma Wibawa, S.T., M.T.

PROGRAM MAGISTER
BIDANG KEAHLIAN TELEMATIKA - CIO
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017

LEMBAR PENGESAHAN

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Teknik (M.T)
di
Institut Teknologi Sepuluh Nopember

oleh:

Erna Utami
NRP. 2215206702

Tanggal Ujian : 6 Juni 2017
Periode Wisuda: September 2017

Disetujui oleh:

1. Prof. Dr. Ir. *[Signature]* Mauridhi Hery Purnomo, M.Eng. (Pembimbing I)
NIP. 19580916 198601 1 001

2. Dr. Adhi Dharma Wibawa, S.T., M.T. (Pembimbing II)
NIP. 19760505 200812 1 003

3. Dr. I Ketut Eddy Purnama, S.T., M.T. (Penguji)
NIP. 19690730 1995121001

4. Dr. Supeno Mardj Susiki Nugroho, S.T., M.T. (Penguji)
NIP. 197003 31995121001

5. Dr. Ir. Achmad Affandi, DEA (Penguji)
NIP. 19651014 1990021001

Dekan Fakultas Teknologi Elektro

[Signature]
Dr. Tri Arief Sardjono, S.T., M.T.
NIP. 19700212 1995121001

Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul **“PREDIKSI ZONA RESERVOIR BERBASIS ATRIBUT DATA LOG SUMUR DENGAN METODE LEVENBERG - MARQUARDT”** adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, Juni 2017

Erna Utami

NRP. 2215206702

Halaman ini sengaja dikosongkan

PREDIKSI ZONA RESERVOIR BERBASIS ATRIBUT DATA LOG SUMUR DENGAN METODE LEVENBERG – MARQUARDT

Nama mahasiswa : Erna Utami
NRP : 2215206702
Pembimbing : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.

ABSTRAK

Dalam meningkatkan produksi minyak bumi salah satu cara dengan memperbanyak eksplorasi pada lapangan baru. Metode yang cukup efektif digunakan dalam eksplorasi minyak dan gas bumi adalah metode well logging. Metode well logging merupakan suatu metode perolehan data yang diperlukan untuk mengevaluasi secara kualitatif dan kuantitatif adanya keberadaan hidrokarbon. Di penelitian ini, menggunakan hubungan kualitatif antara data logging sumur dengan zona reservoir di basin Salawati, Irian Jaya area. Empat log sumur sebagai atribut data input diantaranya Log Gamma Ray (GR), Log Resistivity (ILD), Log Densitas (RHOB), Log Neutron (NPHI). Sedangkan formasi zona reservoir dijadikan sebagai data target yang telah diinterpretasi sebelumnya terhadap kurva log. Pada dasarnya data logging sangat kompleks dan tidak linier, sehingga pada proses pelatihan dan pengujian digunakan metode Levenberg - Marquardt. Karena metode levenberg – marquardt merupakan salah satu metode optimasi untuk penyelesaian masalah kuadrat terkecil.

Hasil penelitian ini menunjukkan bahwa hasil training prediksi zona reservoir dengan metode levenberg – marquardt mempunyai nilai Mean Absolute Percentage Error (MAPE) sebesar 0.3803% dengan 500 iterasi. Uji Validasi hasil berdasarkan kurva ROC dengan cross validation folds 10 diperoleh akurasi sebesar 84.9984%. Dengan Area Under ROC sebesar 0.992. Dari nilai area under ROC tersebut, maka dapat dikatakan bahwa prediksi zona reservoir dengan metode levenberg – marquardt mempunyai unjuk kerja “Excellent”. Oleh sebab itu, daerah yang memiliki respon atribut yang sama dengan lapangan yang telah berproduksi, diperkirakan sebagai zona prospek baru reservoir.

Kata kunci: Prediksi zona reservoir, data log sumur, *Neural Network* di Minyak dan Gas, Algoritma *Levenberg - Marquardt*

Halaman ini sengaja dikosongkan

RESERVOIR ZONE PREDICTION USING LOG DATA MULTI WELL BASED ON LEVENBERG MARQUARDT METHOD

By : Erna Utami
Student Identity Number : 2215206702
Supervisor(s) : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
2. Dr. Adhi Dharma Wibawa, S.T., M.T.

ABSTRACT

Well logging is a well-known and effective method for oil and natural gas exploration in new fields in order to enhance oil and gas production. Well Logging is defined as an acquisition method to qualitatively and quantitatively evaluate the existence of hydrocarbon layer in the well. In this research, we studied the relations between well logging data and reservoir zone in Salawati basin, Irian Jaya area. Four well logs with four attributes such as Log Gamma Ray (GR), Log Resistivity (ILD), Log Density (RHOB), and Log Neutron (NPHI) were explored. The reservoir zone data has been previously determined by using log curve whether it is a reservoir zone or not. This data then is being used as a target for learning. Since the logging data is a complex and non-linear, Levenberg-Marquardt (LM) was then implemented as an artificial intelligent algorithm in performing this study. The objective of this work is to build decision support system that will automatically find reservoir zone based on well logging data.

The results of this work showed that Mean Absolute Percentage Error (MAPE) of training for reservoir zone prediction by exploiting Levenberg – Marquardt is 0.3803 % with 500 iteration. Validity test results based on ROC curve with cross validation folds 10 is 84.9984% and area of under ROC is 0.992. This result showed that this method has a high potential to be used in real exploration activities so that the predicting reservoir zone then can be done precisely.

Key words: Reservoir zone prediction, well logging data, Neural Network in oil and gas, Levenberg–Marquardt algorithm.

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Syukur Alhamdulillah penulis panjatkan kehadiran Allah SWT, yang telah memberikan segala rahmat, taufik dan hidayah-Nya yang memungkinkan penulis dapat menyelesaikan tesis ini dengan baik. Penulis bersyukur kepada seluruh pihak yang senantiasa membantu dan mensupport menyelesaikan studi ini. Penulis ucapkan terimakasih kepada:

1. Ya rabbi..atas segala rahmat dan hidayah-Nya penulis dapat menyelesaikan tugas belajar ini.
2. Suami dan anak – anakku tercinta (Hisyam, Aisyah, Zahwa), untuk segala dukungannya yang tidak pernah lelah memberi semangat. Orang tuaku, ibu mertua dan seluruh keluarga besar yang selama ini penulis repotkan, sebagai tempat penitipan anak dan tempat berteduh.
3. Prof. Mauridhi Hery Purnomo dan Dr. Adhi Dharma Wibawa selaku pembimbing yang selalu mengingatkan, memberi dukungan dan semangat untuk menyelesaikan tesis ini.
4. Segenap dosen – dosen Teknik Elektro, khususnya dosen – dosen yang mengajar di Telematika – CIO, terimakasih banyak atas transferan ilmunya dan pengalaman.
5. Kementerian KOMINFO dan Kementerian ESDM yang telah memberikan beasiswa kepada penulis untuk program pascasarjana dengan *cost sharing*.
6. Teman – Teman Telematika (Regular dan CIO) angkatan 2014 dan 2015, terimakasih atas pertemanan kita selama ini. Teman – teman di Lab 401(adik – adik S1, sesama S2, dan senior – senior S3).
7. Terimakasih kepada pihak – pihak yang tidak dapat disebutkan satu persatu.

Penulis menyadari bahwa penyusunan tesis ini jauh dari kesempurnaan, untuk itu penulis mengharapkan kritik dan saran dari semua pihak. Semoga tesis ini bermanfaat bagi kita semua. Allohumma Amin..

Surabaya, Juni 2017

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN KEASLIAN TESIS	iv
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvi
DAFTAR TABEL	xix
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan	3
1.4 Batasan Masalah	4
1.5 Kontribusi	4
1.6 Metodologi Penelitian	4
BAB 2 KAJIAN PUSTAKA	5
2.1 Kajian Penelitian Terkait	5
2.2 Teori Dasar	6
2.2.1 Prospek Kandungan Minyak Bumi	6
2.2.2 Well Logging	9
2.2.3 Data Logging	11
2.2.3.1 Log Gamma Ray (GR)	12
2.2.3.2 Log Densitas	14
2.2.3.3 Log Neutron	15
2.2.3.4 Log Resistivity (ILD Induction Log Deep)	16
2.2.3.5 Porosity Efektif (Peff)	17
2.2.4 Filter data kualitatif permeabilitas dan porositas	18
2.2.5 Metode Principal component analysis (PCA)	20
2.2.6 Metode <i>Partial Least Squares</i> (PLS)	21
2.2.7 Jaringan Syaraf Tiruan	23
2.2.7.1 Struktur Jaringan Syaraf Tiruan	24

2.2.7.2	Arsitektur jaringan Syaraf Tiruan	27
2.2.7.3	Metode Pembelajaran (<i>Learning</i>)	28
2.2.7.4	Algoritma Levenberg – Marquardt Pada Jaringan Syaraf Tiruan	29
2.2.7.5	Tahap Pelatihan.....	32
2.2.7.6	Tahap Pengujian.....	34
2.2.8	Metode Pengujian	34
2.2.9	Evaluasi Kinerja (ROC).....	35
BAB 3	<u>METODOLOGI PENELITIAN</u>	37
3.1	Pengambilan Data.....	38
3.2	Praproses Data	40
3.2.1	Quick Look Analysis	40
3.2.2	Perhitungan Porositas Efektif	41
3.2.3	Pemilihan variable dengan PCA dan PLS	41
3.2.3.1	Analisa PCA.....	42
3.2.3.2	Analisa PLS	45
3.2.4	Normalisasi Data Input Jaringan Syaraf Tiruan	49
3.3	Pembentukan Model Jaringan Syaraf Tiruan Metode Levenberg – Marquardt	49
3.3.1	Pelatihan/ Pembelajaran (<i>Learning</i>)	51
3.3.2	Pengujian (<i>Testing</i>).....	58
3.4	Evaluasi Hasil Uji.....	59
BAB 4	HASIL DAN PEMBAHASAN	61
4.1	Praproses data	61
4.2.1	Hasil Proses Pelatihan	62
4.2.2.	Analisa Hasil Proses Pelatihan	63
4.2.3.	Hasil Proses Pengujian	64
4.2.4.	Analisa Hasil Pengujian.....	65
4.3.	Evaluasi dan Validasi	65
4.4.	Pengujian dengan Jaringan Syaraf Tiruan <i>Backpropagation</i>	68
BAB 5	KESIMPULAN DAN SARAN	71
5.1	Kesimpulan.....	71
5.2	Saran	71
DAFTAR PUSTAKA	73

LAMPIRAN.....	Error! Bookmark not defined.
BIOGRAFI PENULIS	77

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2. 1 Petroleum System[4].....	7
Gambar 2. 2 Profil Rembesan pada Batuan [2].....	8
Gambar 2. 3 Litologi Batuan Endapan [18].....	8
Gambar 2. 4 Skematik diagram dari pengaturan wireline logging [2].....	11
Gambar 2. 5 Respon Log GR terhadap batuan[5].....	13
Gambar 2. 6 Respon log Densitas (a) dan log Neutron (b) di berbagai litologi [6]	14
Gambar 2. 7 Ilustrasi kemampuan Jaringan Saraf Tiruan.....	24
Gambar 2. 8. Elemen Pengolah Informasi (Neuron)	25
Gambar 2. 9 Fungsi Sigmoid Biner[12].....	26
Gambar 2. 10 Fungsi Sigmoid Bipolar[12].....	26
Gambar 2. 11 Jaringan Syaraf Tiruan Feedforward.....	27
Gambar 2. 12 Jaringan Syaraf Tiruan Feedback.....	27
Gambar 3. 1 Alur Penelitian.....	37
Gambar 3. 2 Layout Irian Jaya Area.....	39
Gambar 3. 3 Proses Zonasi pada Kurva Log.....	40
Gambar 3. 4 PCA zonasi 1.....	43
Gambar 3. 5. PCA zonasi 2.....	43
Gambar 3. 6. PCA zonasi 3.....	44
Gambar 3. 7. PCA zonasi 5.....	44
Gambar 3. 8 PLS Zonasi 1.....	46
Gambar 3. 9. PLS zonasi 2.....	47
Gambar 3. 10. PLS zonasi 3.....	47
Gambar 3. 11. PLS zonasi 5.....	48
Gambar 3. 12. Arsitektur Jaringan Syaraf Tiruan Levenberg Marquardt.....	52
Gambar 3. 13. <i>Flowchart</i> pelatihan JST <i>Levenberg Marquardt</i>	56
Gambar 3. 14. Diagram Alir Proses Prediksi.....	58
Gambar 4. 1. Hasil pelatihan JST Levenberg Marquardt.....	63
Gambar 4. 2 Hasil Pengujian JST Levenberg Marquardt.....	64
Gambar 4. 3 ROC pada hasil penelitian.....	66

Gambar 4. 4. Chart presisi, akurasi, dan recall untuk pembagian data.....	68
Gambar 4. 5 Grafik Perbandingan antara Levenberg Marquardt dengan Backpropagation.....	69

DAFTAR TABEL

Tabel 2. 1 Interpretasi log GR terhadap litologi[5].....	13
Tabel 2. 2 Densitas setiap lapisan litologi[5].....	14
Tabel 2. 3 Tabel Ukur Porositas dan Kuantitas[2].....	17
Tabel 2. 4 Tabel Nilai AUC [17]	36
Tabel 3. 1 Data Lokasi Sumur Observasi.....	39
Tabel 3. 2 Karakteristik Permeabilitas.....	41
Tabel 3. 3 Daftar Data Log Yang dianalisa dengan PCA dan PLS.....	42
Tabel 3. 4. Hasil kesimpulan PCA.....	45
Tabel 3. 5. Hasil kesimpulan PLS.....	48
Tabel 3. 6 Struktur JSTyang digunakan.....	51
Tabel 3. 7. Aturan Pembagian Data.....	51
Tabel 4. 1. Hasil Pelatihan dengan Perubahan <i>Learning Rate</i>	62
Tabel 4. 2. Hasil Pengujian dengan Perubahan <i>Learning Rate</i>	64
Tabel 4. 3 Confussion Matrix Penelitian.....	66
Tabel 4. 4 Hasil zona reservoir sumur tes.....	70

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Secara geologi daerah Indonesia timur merupakan daerah kompleks, yang masih komprehensif, sehingga penelitian yang dilakukan di daerah Indonesia Timur dan sekitarnya masih lanjut terus dilakukan. Eksplorasi yang dilakukan di daerah Indonesia Timur semakin intensif seiring dengan berkembangnya tuntutan kebutuhan keberadaan minyak di daerah tersebut. Bertambahnya informasi mengenai lapangan minyak baru yang memiliki prospek kandungan minyak bumi semakin menambah pengetahuan penentuan zona reservoir di daerah Indonesia Timur ini.

Cekungan Salawati terletak di wilayah Papua Barat, tepatnya berada di daerah Kepala Burung pada Pulau Papua sebagai cekungan Tersier penghasil minyak yang besar di kawasan Indonesia Bagian Timur. Cekungan ini berarah timur – barat terletak di batas utara lempeng Benua Australia yang bergerak ke arah utara sebagai pasive margin yang berbatasan dengan lempeng samudera Pasifik yang bergerak relatif ke arah barat dan dibatasi oleh adanya sesar mendatar regional yaitu sesar Sorong. Cekungan Salawati berkembang di sebelah selatan sesar sorong dan perkembangan cekungannya dikontrol oleh pergerakan sesar besar mendatar ini[1]. Cekungan Salawati merupakan satu – satunya cekungan di Indonesia Timur yang telah matang dieksplorasi dan diproduksi.

Batuan sumber daerah Cekungan Salawati berasal dari batulempung dan serpih Formasi Klasafet, batugamping pada Formasi Kais dan batulempung serpih pada Formasi Klasaman awal. Formasi yang diperhitungkan akan menghasilkan hidrokarbon adalah Formasi Kais. Hidrokarbon yang terakumulasi di Formasi Kais selain dari Formasi Kais itu sendiri, juga berasal dari Formasi Klasafet dan Formasi Klasaman.

Batuan reservoir lainnya adalah Klasafet yang berumur Miosen akhir. Jebakan hidrokarbon di Cekungan Salawati terdapat di Formasi Kais berupa

kompleks terumbu karbonat dan karbonat paparan yang tersesarkan. Jebakan dalam jumlah yang lebih kecil ada di formasi Klasafet dan Klasaman.

Batuan penutup(*seal rock*) berupa serpih karbonat dari formasi Klasafet dan batugamping kristalin Formasi Kais. Batuan yang menjadi *overburden* adalah batuan gamping (*limestone*) pada Formasi Kais, dan *clay* pada formasi Klasafet, Klasaman dan Sele.

Beberapa syarat *petroleum system* antara lain adanya batuan induk (*source rock*), batuan reservoir (*reservoir*), migrasi (*migration*), jebakan (*trap*), batuan penutup (*seal*) dan batuan *overurden*. Selain syarat di atas, terdapat juga kriteria lain seperti temperature, berat jenis minyak, porositas, dan permeabilitas reservoir dan parameter lainnya[2].

Minyak bumi yang berada di perut bumi bukan dalam sebuah tempat yang mirip dengan danau atau sejenisnya, melainkan berada pada pori – pori batuan yang bercampur dengan air. Sehingga eksplorasi dilakukan untuk mencari hidrokarbon pada batuan reservoir yang memiliki porositas dan permeabilitas baik.

Untuk memulai kegiatan pengeboran minyak bumi, terlebih dahulu perlu dilakukan evaluasi formasi untuk mengetahui karakteristik formasi batuan yang akan di bor. Tujuan dari evaluasi formasi menurut [3] adalah sebagai berikut:

1. Menentukan ada tidaknya hidrokarbon.
2. Menentukan dimana tepatnya hidrokarbon tersebut berada.
3. Menentukan berapa banyak kandungan hidrokarbon tersebut di dalam formasi.
4. Menentukan apakah hidrokarbon tersebut potensial untuk diproduksi atau tidak.

Banyak jenis metode yang digunakan untuk mengetahui karakteristik formasi batuan, salah satu diantaranya adalah dengan analisis data well logging. Well logging merupakan perekaman karakteristik dari suatu formasi batuan yang diperoleh melalui pengukuran pada sumur bor [3]. Data diperoleh dari logging yang digunakan untuk mengevaluasi secara kuantitas banyak sedikitnya hidrokarbon di lapisan pada keadaan sebenarnya. Sedangkan informasi sifat – sifat batuan dan cairan diperoleh dari kurva log. Dalam mengambil keputusan,

logging merupakan bagian yang penting dari proses pemboran dan penyelesaian sumur. Adalah mutlak untuk mendapatkan data log yang akurat dan lengkap. Biaya logging diperkirakan hanya sekitar 5% dari total biaya eksplorasi sebuah sumur, sehingga adalah kurang bijaksana bila tahap yang penting ini tidak dilaksanakan dengan baik[2].

Untuk menentukan keberadaan minyak bumi di dalam lapisan batuan mineral khususnya dapat diketahui dengan analisa data log berdasarkan log Gamma Ray (GR), metode crossplot antara log densitas (RHOB) dengan log neutron (NPHI) dan log Spontaneous Potential (SP) sebagai pelengkap [2].

Penelitian ini akan menggunakan jaringgan syaraf tiruan metode Levenberg-Marquardt untuk sistem yang kompleks dan tidak linier. Selain dipergunakan untuk memodelkan bisa juga untuk memilih variabel yang mempunyai korelasi tinggi.

Beberapa penelitian sebelumnya telah menggunakan jaringan syaraf tiruan untuk memprediksi permasalahan litologi, namun hasil dari penelitian tersebut rata-rata berupa regresi/korelasi kedekatan data output dengan target maksimal 70%. Regresi ini menunjukkan kedekatan data output sebenarnya dan data prediksi. Dalam penelitian ditargetkan untuk mencapai korelasi 90% dengan cara sebelum data dilatihkan menggunakan jaringan syaraf tiruan dilakukan pre-proses data.

1.2 Rumusan Masalah

Belum adanya *decision support system* yang memprediksi keberadaan zona reservoir menggunakan data well logging yang terdiri dari data log gamma ray (GR), log spontanous potential (SP), log density (RHOB), log neutron (NPIH). Yang disusun suatu metode (sistem) dengan prinsip memberikan pelatihan/pengenalan terlebih dahulu terhadap parameter yang telah didefinisikan sebelumnya pada jaringan syaraf tiruan.

1.3 Tujuan

Penelitian ini bertujuan untuk menerapkan metode levenberg -marquardt untuk proses prediksi zona reservoir. Khususnya penggunaan *Principal*

Component Analysis (PCA) dan *Partial Least Square* (PLS) mereduksi dimensi data dan kemampuan levenberg-marquardt untuk proses pembelajaran dan prediksi zona reservoir pada jaringan syaraf tiruan. Diharapkan hasil yang diperoleh dapat dimanfaatkan pada penelitian selanjutnya.

1.4 Batasan Masalah

Data yang diolah merupakan data well logging. Berupa kurva log yang tela menjadi data digital. Serta peningkatan kualitas data dengan cara mereduksi jumlah data. Diantaranya adalah data well logging yaitu data log gamma ray (GR), log resistivity (ILD), log density (RHOB), log neutron (NPIH).

1.5 Kontribusi

Dengan terciptanya decision support system akan membantu dunia perminyakan dalam membuat keputusan secara cepat keberadaan minyak bumi untuk kelanjutan kegiatan eksplorasi minyak bumi. Dan hal ini menjadi langkah awal untuk melanjutkan tahap eksplorasi selanjutnya, sehingga dapat menghemat waktu dan biaya.

1.6 Metodologi Penelitian

Pada bagian ini diuraikan tahap – tahap yang dilakukan pada penelitian yaitu gambaran umum alur penelitian, pengambilan data dari PUSDATIN ESDM, praproses data, pembuatan model jaringan syaraf tiruan (JST) dengan metode levenberg-marquardt, kemudian dilanjut dengan pelatihan dan pengujian serta dievaluasi dan divalidasi. Dari semua hasil tersebut maka dianalisa untuk membahas untuk keberadaan apakah sumur tersebut merupakan zona reservoir.

BAB 2

KAJIAN PUSTAKA

2.1 Kajian Penelitian Terkait

Berikut merupakan beberapa penelitian sebelumnya yang terkait dengan prediksi zona reservoir menggunakan jaringan syaraf tiruan, antara lain adalah sebagai berikut :

1. Irawan Deni, Utama Widya, “Analisis Data *Well Log* (Porositas, Saturasi Air, dan Permeabilitas) untuk Menentukan Zona Hidrokarbon, Studi Kasus: Lapangan ITS Daerah Cekungan Jawa Barat Utara” [19]. Penelitian ini tentang penentuan zona yang terisi hidrokarbon pada lapangan “ITS” di cekungan Jawa Barat sebelah Utara. Data yang digunakan adalah data log GR, log SP, log resistivitas, log neutron, log densitas, dan data master log. Penentuan kondisi litologi pada zona interest dilakukan dengan menggunakan data master log dan metode crossplot NPHI-RHOB.
2. J. Hou, T. Takahashi, A. Katoh, S. Jaroonsitha, P. Chumsena, “Application of seismic attributes and neural network for sand probability prediction — A case study in the North Malay Basin” [20]. Penelitian ini membahas prediksi karakteristik reservoir litologi, porositas dan ketebalan. Berlokasi di basin Malay Utara terdapat batupasir dimana konturnya belum ada pada beberapa sumur sehingga diprediksi menggunakan jaringan syaraf tiruan dan hasilnya disimulasikan menggunakan Geology Driven Integration (GDI).
3. Khadim.FS, Samsuri Ariffin, Al-Dunainawi Yousif, “ANN-Based Prediction of Cementation Faktor in Carbonate Reservoir” [21]. Penelitian ini membahas tentang prediksi reservoir karbonat berdasarkan faktor sementasi dengan data log sumur (permeabilitas, porositas dan resistivity). Untuk model jaringan syaraf tiruan menggunakan 2 algoritma Gradient Descent dan Levenberg – Marquardt. Dengan performansi kinerja mean square error (MSE) kurang dari ($1*10^{-4}$).
4. Cahaya Rosyidan, Listiana Satiawati, Bayu Satiyawira, “Analisa Fisika minyak (Petrophysics) Dari Data Log Konvensional Untuk Menghitung Sw

Berbagai Metode” [22]. Penelitian evaluasi sifat petrophysics dari data log konvensional untuk menghitung saturasi air dengan berbagai metode.

5. M. P. Muhrami, Makhranii, S. Aswad, “Interpretasi Petrofisika Sumur Log Untuk Menentukan Zona Hidrokarbon Sumur ‘R’ Cekungan Sumatera Selatan” [23]. Dalam penelitian ini, dilakukan penentuan zona yang terisi hidrokarbon sumur “R” di cekungan Sumatera Selatan. Data yang digunakan adalah data log GR, log SP, log resistivitas, log neutron, log densitas. Perhitungan nilai porositas efektif dilakukan melalui integrasi dari analisa data log densitas, log neutron, dan log GR. Hasil interpretasi litologi menunjukkan bahwa reservoir yang mendominasi pada sumur “R” adalah batupasir nilai gamma ray dibawah 50 API.

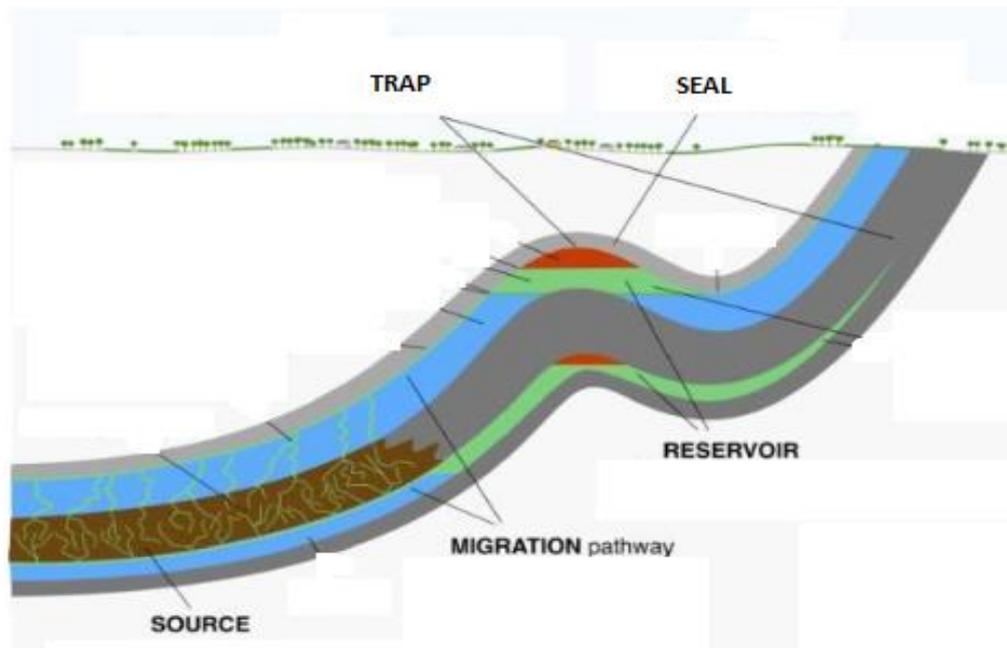
2.2 Teori Dasar

2.2.1 Prospek Kandungan Minyak Bumi

Dalam penentuan lokasi kandungan minyak bumi terlebih dahulu melewati tahap evaluasi formasi. Evaluasi formasi batuan adalah suatu proses analisis ciri dan sifat batuan di bawah tanah dengan menggunakan hasil pengukuran lubang sumur[2]. Evaluasi formasi membutuhkan berbagai macam pengukuran dan analisis yang saling melengkapi satu sama lain. Tujuan utama dari evaluasi formasi adalah untuk mengidentifikasi reservoir, memperkirakan cadangan hidrokarbon, dan memperkirakan perolehan hidrokarbon [2]. Gambar 2.1 menunjukkan struktur dari petroleum system.

Ada 5 faktor kondisi suatu daerah dikatakan berpotensi mengandung minyak bumi menurut [2] atau dengan kata lain dikenal dengan sebutan petroleum system antara lain :

1. Adanya batuan sumber (*source rock*)
2. Adanya perpindahan (*migration*) hidrokarbon dari bebatuan asal menuju ke “bebatuan reservoir”,
3. Adanya batuan berpori (*reservoir rock*),
4. Adanya jebakan/perangkap (*trap*),
5. Adanya lapisan(*seal*) yang *impermeable*.

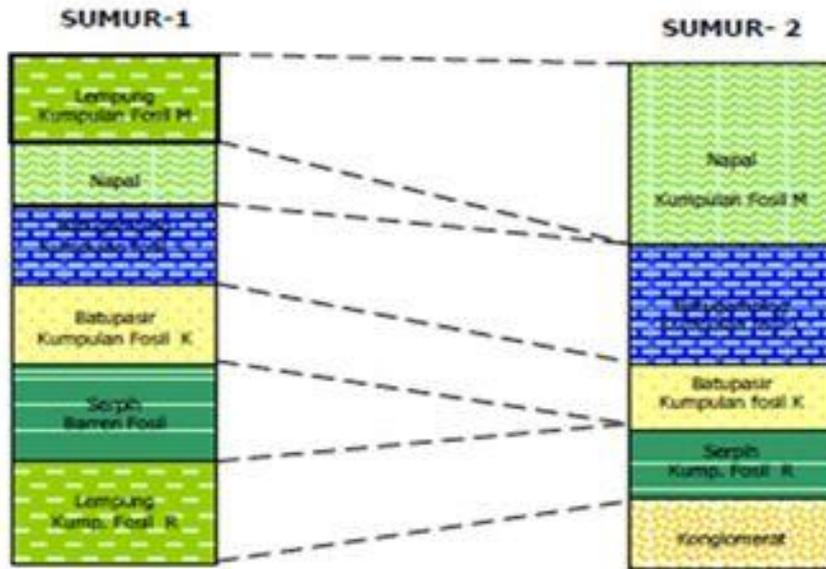


Gambar 2. 1 Petroleum System[4]

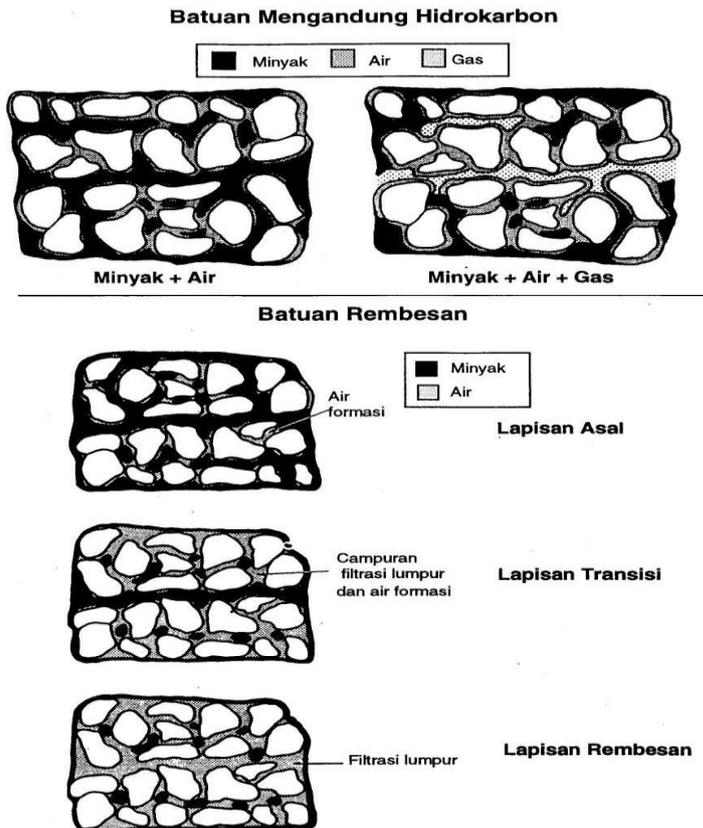
Reservoir yang baik memiliki ciri utama mempunyai porositas dan permeabilitas yang tinggi. *Porositas* adalah presentase volume ruang-ruang kosong yang ada pada batuan sedangkan *permeabilitas* adalah kemampuan batuan dalam mengalirkan fluida naik ke atas. Dengan adanya ruang-ruang kosong pada batuan, akan terdapat lebih banyak ruang untuk menyimpan minyak dan gas. Banyaknya hidrokarbon dapat dianalisa dengan parameter sifat – sifat batuan yaitu porositas dan saturasi air, sedangkan sifat batuan permeabilitas dapat ditunjukkan pada tingkat mana hidrokarbon dapat diproduksi. Untuk *saturasi* adalah bagian dari ruang pori yang berisi air. Gambar 2.2 merupakan gambaran dari batuan kandungan hidrokarbon yang berpori – pori.

Sedangkan litologi menggambarkan bagian padat pada batuan. Pada koneksi interpretasi log reservoir, litologi dijadikan penggambaran lapisan batuan seperti batupasir (*sandstone*), batu gamping (*limestone*), atau dolomit. Litologi dapat menginterpretasikan formasi batuan dan besar pengaruhnya terhadap respon log porositas. Secara teori batuan berpori (umumnya berupa batu pasir atau batu gamping) akan memiliki kandungan electron yang lebih sedikit dibandingkan dengan batuan pejal (*tight*). Untuk batupasir (densitas $\rho = 2,65$ gr/cc) dan batu

gamping ($\rho = 2,71 \text{ gr/cc}$) yang mengandung fluida gas akan memiliki densitas bulk (massa tanah per satuan volume) yang tinggi.



Gambar 2. 2 Profil Rembesan pada Batuan [2]



Gambar 2. 3 Litologi Batuan Endapan [18]

Batuan sumber daerah Cekungan Salawati berasal dari batulempung dan serpih Formasi Klasafet, batugamping pada Formasi Kais dan batulempung dan serpih pada formasi Klasaman awal. Formasi yang diperhitungkan akan menghasilkan hidrokarbon adalah Formasi Kais. Batuan yang berpotensi sebagai batuan reservoir di daerah penelitian adalah batuan karbonat pada reef build up Formasi Kais. Secara umum terdiri dari lime mudstone berwarna abu – abu kecoklatan yang berbutir halus. Batuan yang bertindak sebagai lapisan penutup yang baik pada daerah penelitian adalah sedimen klastik yang terdiri dari batulempung dengan sisipan tipis batulanau dan batugamping dari formasi klasafet dan formasi Klasaman.

2.2.2 Well Logging

Well logging diartikan sebagai “perekaman karakteristik dari suatu formasi batuan yang diperoleh melalui pengukuran pada sumur bor” [3]. Log merupakan suatu grafik kedalaman dari suatu set data yang menunjukkan parameter diukur secara berkesinambungan di dalam sebuah sumur pemboran [2]. Prinsip dasar *well logging* adalah mengukur parameter sifat – sifat fisik dari suatu formasi pada setiap ke dalaman secara kontinyu dari sumur pemboran. Adapun sifat – sifat fisik yang diukur adalah potensial listrik batuan/kelistrikan, tahanan jenis batuan, radioaktivitas, kecepatan batuan, serta kekompakan formasi yang kesemuanya tercermin dari lubang bor.

Tujuan utama kegiatan *well logging* adalah :

1. Menentukan ada tidaknya hidrokarbon
Langkah awal yang dilakukan adalah menentukan apakah di formasi batuan tersebut terdapat hidrokarbon, setelah itu ditentukan jenisnya, minyak atau gas.
2. Menentukan dimana tepatnya hidrokarbon tersebut berada
Evaluasi formasi diharapkan mampu menjelaskan pada kedalaman berapa hidrokarbon tersebut berada dan pada lapisan batuan apa saja.
3. Menentukan berapa banyak kandungan hidrokarbon tersebut di dalam formasi

Berapa banyak hidrokarbon yang terdapat di dalam formasi harus dapat diketahui. Aspek yang paling penting untuk mengetahui hidrokarbon adalah dengan menentukan porositas batuan karena hidrokarbon terdapat di dalam pori-pori batuan.

4. Menentukan apakah hidrokarbon tersebut potensial untuk diproduksi atau tidak.

Untuk menentukan potensial atau tidaknya hidrokarbon yang berada di dalam formasi batuan membutuhkan banyak parameter yang harus diketahui. Parameter yang paling penting adalah permeabilitas batuan, lalu viskositas minyak.

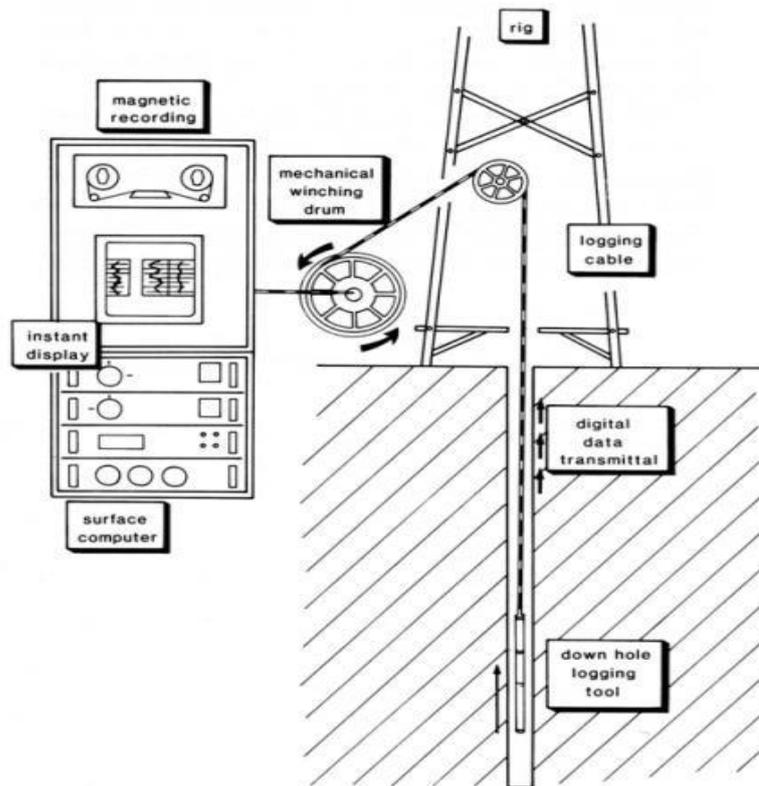
Berdasarkan cara kerjanya well logging terdiri dari 2 jenis yaitu :

1. *Wireline Logging*

Menurut [2], *Wireline logging* dilakukan ketika pemboran telah berhenti dan kabel digunakan sebagai alat untuk mentransmisikan data. Untuk menjalankan *wireline logging*, lubang bor harus dibersihkan dan distabilkan terlebih dahulu sebelum peralatan *logging* dipasang. Hal yang pertama kali dilakukan adalah mengulurkan kabel ke dalam lubang bor hingga kedalaman maksimum lubang bor tersebut. Sebagian besar log bekerja ketika kabel tersebut ditarik dari bawah ke atas lubang bor. Kabel tersebut berfungsi sebagai transmiter data sekaligus sebagai penjaga agar alat *logging* berada pada posisi yang diinginkan.

2. *Logging Well Drilling (LWD)*

Sedangkan LWD adalah teknik pengambilan data log yang dilakukan bersamaan dengan pemboran. Pengambilan data dilakukan secara real time karena selisih waktu pembacaan alat dengan proses pemboran yang berlangsung sangatlah kecil. Peralatan utama pada LWD ada tiga sensor logging di bawah lubang bor, sistem transmisi data, dan penghubung permukaan.



Gambar 2. 4 Skematik diagram dari pengaturan wireline logging [2].

Data log mempunyai resolusi yang lebih baik dan detail mengenai respon bawah permukaan dibandingkan data seismik, sehingga data sumur dijadikan data pengontrol untuk identifikasi batuan bawah permukaan. Data sumur didapatkan dari respon alat yang dimasukkan kebawah permukaan bumi. Log sendiri merupakan suatu grafik kedalaman atau waktu dari satu set data yang menunjukkan parameter yang diukur di dalam sumur .

2.2.3 Data Logging

Data logging dicetak dalam lembaran data logging dimana terdapat nama perusahaan, nomor lubang bor, lokasi pengeboran, jenis log, kedalaman pengeboran, kedalaman alat logging, batas atas logging mulai dieksekusi, batas bawah logging selesai dieksekusi, nama perekam log, nama geologist penanggung jawab serta kedalaman penggunaan chasing. Selain itu lembar data logging juga memuat informasi mengenai grafik hasil pembacaan log gamma ray dan log

densitas yang kemudian dilakukan interpretasi jenis lapisan batuan beserta kedalaman dan ketebalannya.

Secara umum kurva log terdiri dari beberapa jenis log berdasarkan kemampuan dan prinsip kerjanya, antara lain[2],[3] :

2.2.3.1 Log Gamma Ray (GR)

Log Gamma Ray merupakan metode untuk mengukur radiasi sinar gamma yang dihasilkan oleh unsur-unsur radioaktif yang terdapat dalam lapisan batuan di sepanjang lubang bor. Prinsip dari *gamma ray* log adalah perekaman radioaktivitas alami bumi, dimana sinar gamma mampu menembus batuan dan dideteksi oleh sensor sinar gamma yang umumnya berupa detektor sintilasi (penurunan intensitas gelombang). Skala log gamma ray dalam satuan API unit (APIU). Tabel 2.1 adalah interpretasi log GR terhadap litologi.

Fungsi dari log Gamma Ray, antara lain:

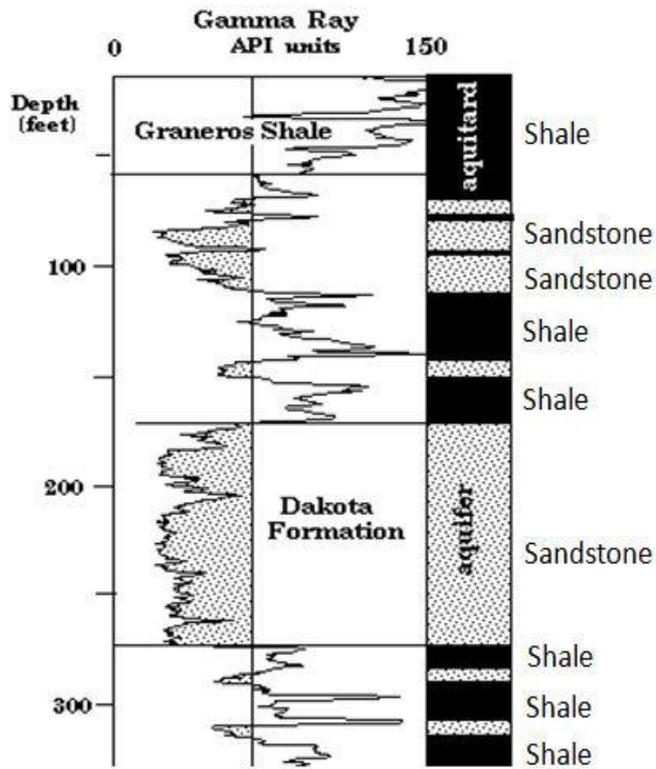
1. Evaluasi kandungan serpih
2. Menentukan lapisan permeabel
3. Evaluasi biji mineral yang radioaktif
4. Evaluasi lapisan mineral yang bukan radioaktif
5. Korelasi log pada sumur berselubung
6. Korelasi antar sumur

Batu kapur / batu gamping dan batupasir memiliki kandungan material radioaktif yang rendah, sehingga akan menghasilkan pembacaan nilai GR yang rendah pula. Seiring dengan bertambahnya kandungan shale dalam batuan, maka kandungan material radioaktif akan bertambah dan pembacaan nilai GR akan meningkat.

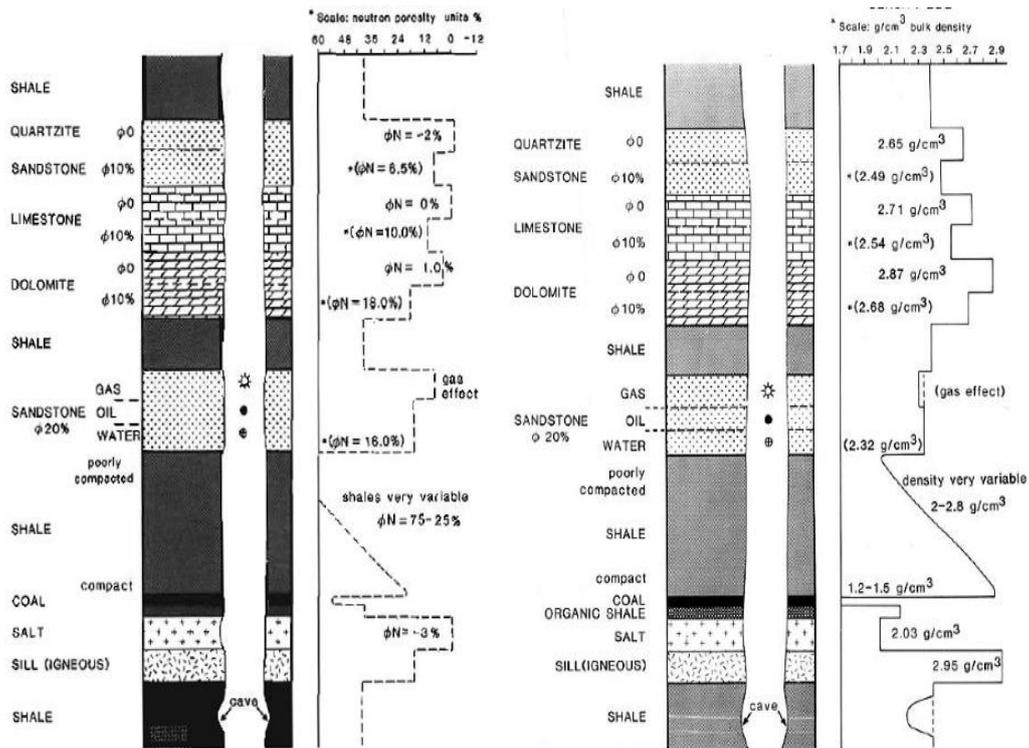
Pengukuran gamma ray log dilakukan dengan menurunkan instrument gamma ray log kedalam lubang bor dan merekam radiasi sinar gamma untuk setiap interval tertentu. Dengan interval perekaman gamma ray sebesar 0.5 feet.

Tabel 2. 1 Interpretasi log GR terhadap litologi[5]

Radioaktif sangat rendah (0 – 32,5 API)	Radioaktif rendah (32,5 – 60 API)	Radioaktif menengah (60 – 100 API)	Radioaktif sangat tinggi (>100 API)
Anhidrit Salt Batubara	Batupasir Batugamping Dolomit	Arkose Batuan granit Lempungan Pasiran Gamping	Batuan serpih Abu vulkanik Bentonit



Gambar 2. 5 Respon Log GR terhadap batuan[5]



(a). Respon log Densitas

(b). Respon log Neutron

Gambar 2. 6 Respon log Densitas (a) dan log Neutron (b) di berbagai litologi [6]

Tabel 2. 2 Densitas setiap lapisan litologi[5]

Jenis batuan	Rapat massa sebenarnya (gr/cc)	Rapat massa saat logging (gr/cc)
Batupasir	2,650	2,684
Batu gamping	2,710	2,710
Dolomit	2,870	2,876

2.2.3.2 Log Densitas

Sinar gamma dari sumber radioaktif dipancar oleh tumbukan dengan elektron di dalam lapisan tanah dan energi sinar gamma akan hilang kepada elektron untuk setiap tumbukan (efek *compton*). Densitas elektron di dalam

material sebanding dengan densitas curahan atau massa (*bulk or mass density*) material [2], seperti terlihat pada tabel 2.2.

Logging densitas dilakukan untuk mengukur densitas batuan disepanjang lubang bor. Densitas yang diukur adalah densitas keseluruhan dari matriks batuan dan fluida yang terdapat pada pori. Prinsip kerja alatnya adalah dengan emisi sumber radioaktif. Semakin padat batuan semakin sulit sinar radioaktif tersebut ter-emisi dan semakin sedikit emisi radioaktif yang terhitung oleh penerima (counter). Log densitas digunakan untuk mengukur densitas semu formasi menggunakan sumber radioaktif yang ditembakkan ke formasi dengan sinar gamma yang tinggi dan mengukur jumlah sinar gamma rendah yang kembali ke detektor.

Fungsi dari Log Density, antara lain:

1. Alat density mengukur berat jenis batuan.
2. Bersama log lain misalnya log neutron, lithologi batuan dan tipe fluida yang dikandung batuan dapat ditentukan.
3. Log density dapat membedakan minyak dari gas.
4. Alat density yang modern juga mengukur PEF (photoelectric effect) yang berguna untuk menentukan lithologi batuan, Log density juga dipakai untuk menentukan V_{clay} .

Pada grafik log densitas gambar 2.5 (a) menunjukkan defleksi ke nilai lebih rendah (kearah kiri) apabila melalui suatu yang mengandung fluida berupa gas, sedangkan (kearah kanan) akan mengalami defleksi ke arah nilai yang lebih tinggi apabila melalui suatu yang mengandung fluida air maupun fluida minyak.

2.2.3.3 Log Neutron

Log neutron digunakan untuk perhitungan porositas batuan, evaluasi litologi, dan deteksi keberadaan gas. Prinsipnya adalah dengan mengukur persentase pori batuan dari intensitas atom hidrogen di dalamnya, yang diasumsikan bahwa hidrogen tersebut akan berupa hidrokarbon maupun air. Hasil pengukuran log neutron kemudian dinyatakan dalam *Porosity Unit* (PU). Log neutron, umumnya tidak terlepas dari log densitas, karena kedua log tersebut

memiliki korelasi dalam menentukan jenis litologi menggunakan analisa *crossplot*.

Neutron Porosity log tidak untuk mengukur porositas sesungguhnya dari batuan, melainkan yang diukur adalah kandungan hidrogen terdapat pada pori-pori batuan. Secara sederhana, semakin berpori batuan semakin banyak kandungan hydrogen dan semakin tinggi indeks hydrogen. Sehingga, shale yang banyak mengandung hydrogen dapat ditafsirkan memiliki porositas yang tinggi pula.

Fungsi dari Log Density, antara lain :

1. Alat neutron dipakai untuk menentukan primary porosity batuan, yaitu ruang pori-pori batuan yang terisi air, minyak bumi atau gas.
2. Bersama log lain misalnya density, dapat menentukan jenis batuan/lithologi serta type fluida yang mengisi pori-pori batuan.

Pada grafik log Neutron gambar 2.5 (b) akan menunjukkan kearah kiri, defleksi ke arah nilai yang lebih tinggi apabila melalui suatu zona berporositas tinggi, dan sebaliknya, grafik akan mengalami defleksi ke kanan apabila melalui zona berporositas rendah.

2.2.3.4 Log Resistivity (ILD Induction Log Deep)

Log Resistivity adalah metoda untuk mengukur sifat batuan dan fluida pori disepanjang lubang bor dengan mengukur sifat tahanan kelistrikannya. Pada dasarnya resistivity untuk mengetahui ada tidaknya batuan yang porous dan permeable mengandung fluida hidrokarbon atau air. Untuk satuan resistivity batuan dideskripsikan dalam Ohmmeter dan pada skala logaritmik nilai diantara 0.2 – 2000 Ohmmeter. Oleh sebab itu, dasar prinsip dari log resistivity yaitu untuk mengukur sifat tahanan kelistrikannya sifat batuan dan fluida pori seperti minyak, air, dan gas disepanjang lubang bor. Tujuan dari induction log adalah mendeteksi lapisan-lapisan fisis yang jauh untuk menentukan resistivitas dan korelasi, tanpa memandang jenis lumpur pemborannya.

Data yang dihasilkan harus diinterpretasi dengan cara melihat tabel nilai tahanan jenis tiap batuan [7], kemampuan penginterpretasi sangat berpengaruh

terhadap hasilnya. Nilai tahanan jenis suatu lapisan batuan atau material berbeda-beda, faktor-faktor yang mempengaruhi perbedaan nilai tahanan jenis adalah: jenis bahan penyusun, kemampuan bahan, porositas, ukuran dan bentuk pori-pori bahan, kandungan dan mutu air serta suhu setiap bahan penyusun formasi batuan[5].

Interpretasi dilakukan untuk mengetahui jenis dan susunan material berdasarkan nilai resistivitas dan pola distribusinya. Interpretasi dilakukan berdasarkan tabel resistivitas material menurut[7],[8]. Tabel nilai tahanan terlampir.

Nilai resistivitas air garam dapat dibedakan dengan baik dari minyak dan gas. Karena air garam memiliki nilai resistivitas sangat rendah sedangkan hidrokarbon (minyak – gas) memiliki nilai resistivitas sangat tinggi. Log resistivitas membantu pekerjaan evaluasi formasi khususnya untuk menganalisa suatu reservoir mengandung air garam (wet) atau mengandung hidrokarbon sehingga log ini digunakan untuk menganalisis Hydrocarbon-Water Contact.

Tabel 2. 3 Tabel Ukur Porositas dan Kuantitas[2]

Porositas (%)	Kelas
(0% – 5 %)	dapat diabaikan (<i>negligible</i>)
(5% – 10%)	buruk (<i>poor</i>)
(10%- 15%)	cukup baik (<i>fair</i>)
(15%- 20%)	baik (<i>good</i>)
(20%- 25%)	sangat baik (<i>very good</i>)
(>25%)	istimewa (<i>excellent</i>)

2.2.3.5 Porosity Efektif (Peff)

Dalam reservoir minyak, porositas menggambarkan persentase dari total ruang yang tersedia untuk ditempati oleh suatu cairan atau gas. Porositas dapat didefinisikan sebagai perbandingan antara volume total pori-pori batuan dengan volume total batuan per satuan volume tertentu Porositas batuan reservoir dapat diklasifikasikan menjadi dua, yaitu:

- Porositas absolut, adalah perbandingan antara volume pori total terhadap volume batuan total yang dinyatakan dalam persen.
- Porositas efektif, adalah perbandingan antara volume pori-pori yang saling berhubungan terhadap volume batuan total (bulk volume) yang dinyatakan dalam persen.

2.2.4 Filter data kualitatif permeabilitas dan porositas

Interpretasi logging merupakan salah satu kegiatan untuk mengidentifikasi lapisan prospek (zona reservoir). Tujuannya untuk mengetahui lapisan permeable dan ketebalan zona reservoir.

Filter data ini bertujuan untuk memilah data kedalaman yang memiliki permeabilitas dan porositas yang baik, untuk permeabilitas sudah diwakili oleh log GR dengan nilai <60 API, sementara untuk porositas dihitung sebagai berikut:

a. Menentukan volume serpih (*shale*)

- V_{sh} GR (Gamma Ray)

Bila tingkat radioaktif *clay* konstan dan tidak ada mineral lain yang radioaktif, maka harga V_{sh} dapat ditulis:

$$V_{sh} = \frac{GR_{log} - GR_{min}}{GR_{max} - GR_{min}} \quad (2.1)$$

keterangan:

GR_{log} = pembacaan GR pada tiap interval kedalaman

GR_{min} = pembacaan GR pada lapisan *non shale*

GR_{max} = pembacaan GR pada lapisan *shale*

b. Menentukan porositas lapisan

1. Neutron Log

Pembacaan neutron log tidak tergantung pada porositas tetapi juga lithologi dan kandungan fluidanya. Oleh karena itu penentuan porositas harus mengetahui lithologinya. Harga dari porositas neutron (Φ_N) dapat diketahui dengan menggunakan persamaan dibawah ini (dalam *limestone unit*):

$$\phi_N = (1.02 \times \phi_{NLog}) + 0.0425 \quad (2.2)$$

keterangan:

ϕ_{Nlog} = porositas yang terbaca pada kurva neutron log

0.0425 = koreksi terhadap *limestone formation*

Lalu besarnya porositas neutron yang telah dikoreksi terhadap *shale* (ϕ_{Nc}) dapat diketahui dari persamaan dibawah ini:

$$\phi_{Nc} = \phi_N - (V_{sh} \times \phi_{Nsh}) \quad (2.3)$$

keterangan:

V_{sh} = volume *shale* (dari GR log)

ϕ_{Nsh} = porositas yang terbaca pada kurva neutron pada lapisan shale

2. Density Log

Dalam menentukan porositas batuan dipengaruhi juga oleh lithologi kandungan fluida batuan. Porositas dari density log biasanya dinotasikan dengan ϕ_D yang mempunyai harga sesuai dengan persamaan dibawah ini:

$$\phi_D = \frac{\rho_{ma} - \rho_b}{\rho_{ma} - \rho_f} \quad (2.4)$$

Lalu besarnya porositas density yang dikoreksi terhadap shale (ϕ_{Dc}) dapat diketahui dari persamaan dibawah ini:

$$\phi_{Dc} = \phi_D - (V_{sh} \times \phi_{Dsh}) \quad (2.5)$$

keterangan:

V_{sh} = volume *shale* (dari GR log)

ϕ_{Dsh} = porositas dari kurva density pada lapisan *shale*

ρ_{ma} = densitas matrik batuan, gr/cc

ρ_b = densitas bulk yang dibaca pada kurva density untuk setiap kedalaman yang dianalisa, gr/cc

ρ_f = densitas fluida (air), gr/cc

c. *Cross over* Neutron-Density Log (Porositi Efektif)

Cross over ini ditunjukkan untuk mengetahui porositas efektif menggunakan Neutron-Density Log, dimana garis-garis (Sandstone, Limestone, Dolomite, dll) merupakan titik lithologi yang jenuh air dan dibagi menjadi bagian-bagian porositas untuk lapisan yang terisi dengan cairan :

$$\phi = \frac{\phi_N + \phi_D}{2} \tag{2.6}$$

Keterangan :

ϕ_N = Porositas dari Neutron Log

ϕ_D = Porositas dari Density Log

2.2.5 Metode Principal component analysis (PCA)

Principal component analysis (PCA) adalah transformasi linear untuk menentukan sistem koordinat yang baru dari dataset. Teknik PCA dapat mengurangi dimensi dari dataset tanpa tidak menghilangkan informasi penting dari dataset [9].

Jumlah komponen sama dengan jumlah variabel asli sehingga tidak ada informasi yang hilang dalam proses. Komponen baru dibangun adalah fungsi linear dari variabel asli dan memiliki dua sifat penting dan berguna, yaitu independen satu sama lain dan nilai eigen yang berhubungan mencerminkan kepentingan relatif mereka.

PCA memerlukan masukan data yang mempunyai sifat zero-mean pada setiap fiturnya[9]. Sifat zero-mean pada setiap fitur data bisa diperoleh dengan mengurangi semua nilai dengan rata – ratanya. Set data X dengan dimensi MxN, M adalah jumlah data dan N adalah jumlah fitur.

$$X = \begin{pmatrix} x_{11} & x_{12} & x_{1j} & x_{1N} \\ x_{21} & \dots & \dots & x_{2N} \\ x_{i1} & \dots & \dots & x_{iN} \\ x_{M1} & x_{M2} & x_{M3} & x_{MN} \end{pmatrix}$$

Untuk fitur ke – j , semua nilai pada kolom tersebut dikurangi dengan rata – ratanya, diformulasikan dengan

$$x_{ij} = x_{ij} - \bar{x}_j \quad (2.7)$$

$i = 1, 2, \dots, M$, dan j adalah kolom ke $-j$.

Perhitungan matriks kovarian dari matriks X yaitu C_x . Formula yang digunakan adalah *dot-product* pada setiap fitur.

$$C_x = \frac{1}{M} X^T \cdot X \quad (2.8)$$

N adalah jumlah fitur, sedangkan X^T adalah matriks transpos dari X .

$$\begin{aligned} C_x &= \frac{1}{M} x \begin{vmatrix} x_{11} & x_{21} & x_{i1} & x_{M1} \\ x_{12} & \dots & \dots & x_{M2} \\ x_{1j} & \dots & \dots & x_{Mi} \\ x_{1N} & x_{2N} & x_{iN} & x_{NM} \end{vmatrix} x \begin{vmatrix} x_{11} & x_{12} & x_{1j} & x_{1N} \\ x_{21} & \dots & \dots & x_{2N} \\ x_{i1} & \dots & \dots & x_{iN} \\ x_{M1} & x_{M2} & x_{Mj} & x_{MN} \end{vmatrix} \\ &= \frac{1}{M} \begin{vmatrix} x_{11} & x_{12} & x_{1j} & x_{1N} \\ x_{21} & \dots & \dots & x_{2N} \\ x_{i1} & \dots & \dots & x_{iN} \\ x_{N1} & x_{N2} & x_{Nj} & x_{NN} \end{vmatrix} \end{aligned}$$

Variabel-variabel baru yang terbentuk hasil dari PCA disebut sebagai *principle component* dan nilai-nilai bentukan dari variabel ini disebut sebagai *principle component score*. Variabel yang baru merupakan kombinasi linear dari variabel-variabel asli. Variabel baru pertama berhubungan dengan *variance maximum* dari data. Variabel baru kedua menunjukkan *variance maximum* yang belum terhitung pada variabel pertama. Variabel baru ketiga menunjukkan *variance maximum* yang belum terhitung pada kedua variabel pertama. Variabel baru ke- p menunjukkan *variance maximum* yang belum terhitung pada $p-1$ variabel terdahulu. Seluruh p variabel baru tidak berkorelasi.

2.2.6 Metode *Partial Least Squares* (PLS)

Partial least squares (PLS) merupakan salah satu metode yang dapat digunakan untuk mengatasi masalah multikolinier. PLS merupakan perpaduan antara *principal component analysis* (PCA) dan regresi linier ganda.. Untuk membentuk hubungan antara peubah respon dan peubah bebas, PLS membentuk peubah bebas yang baru yang disebut faktor, peubah laten, atau komponen, di mana masing-masing komponen yang terbentuk merupakan kombinasi linier dari

peubah-peubah bebas. Tujuan utama dari PLS adalah membentuk komponen yang dapat menangkap informasi dari peubah bebas untuk menduga peubah respon [10].

Metode pendugaan parameter (estimasi) di dalam PLS adalah metode kuadrat terkecil (*least square error methods*). Proses perhitungan dilakukan dengan cara iterasi, dimana iterasi akan berhenti jika telah tercapai kondisi konvergen. Penduga parameter di dalam PLS meliputi 3 hal, yaitu: weight estimate digunakan untuk menciptakan skor variabel laten, estimasi jalur (*path estimate*) yang menghubungkan antar variabel laten dan estimasi loading antara variabel laten dengan indikatornya, means dan lokasi parameter (nilai konstanta regresi, intersep) untuk indikator dan variabel laten.

1. Pendugaan Model Struktural

$$\widehat{\eta}_i^* = \sum_i v_{ji} \xi_i \quad (2.9)$$

dengan v_{ji} dengan $v_{ji} = \text{signcov}(\eta_j, \xi_i)$ untuk $i=1,2,\dots,m$

$$\widehat{\eta}_i^* = v \eta_j + \sum_i v_{li} \xi_i \quad (2.10)$$

dengan $v = \text{signcov}(\eta_l, \eta_i)$

$v_{li} = \text{signcov}(\eta_l, \xi_i)$, untuk $i=1,2,\dots,m$

$\text{signcov}(\eta, \xi) = 1$ Untuk η dan ξ yang berhubungan

0 Untuk η dan ξ yang tidak berhubungan

2. Pembobot Model Pengukuran

$$y_{kj} = \widehat{w}_{ki} \eta_i + e_{ki} \quad (2.11)$$

untuk $k=1,2,\dots,r_j$ dan $j=1,2,\dots,n$,

r_j = banyaknya peubah manifest pada blok ke-j

3. Pendugaan Model Pengukuran

$$\xi_i = \sum_{ki} \widehat{w}_{ki} x_{ki}, \quad (2.12)$$

untuk $k=1,\dots,s_i$ dan $i=1,2,\dots,m$

s_i = banyaknya peubah manifest pada blok ke-i

$$\widehat{\eta}_j = \sum_{kj} \widehat{w}_{kj} y_{kj} , \quad (2.13)$$

untuk $k=1, \dots, r_j$ dan $j=1, 2, \dots, n$

Metode ini berguna untuk menghubungkan dua matriks data, X dan Y, dengan model linear multivariat, tetapi melampaui regresi tradisional karena model juga mengandung struktur X dan Y. PLS berasal kegunaannya dari kemampuannya untuk menganalisis data dengan jumlah banyak, *noise*, kolinear, dan bahkan variabel yang tidak lengkap di kedua X dan Y. PLS memiliki sifat yang diinginkan bahwa ketepatan parameter model meningkat dengan meningkatnya jumlah variabel dan pengamatan yang relevan. Masalah regresi yaitu bagaimana model satu atau beberapa variabel dependen, tanggapan, Y, melalui serangkaian variabel prediktor, X [9].

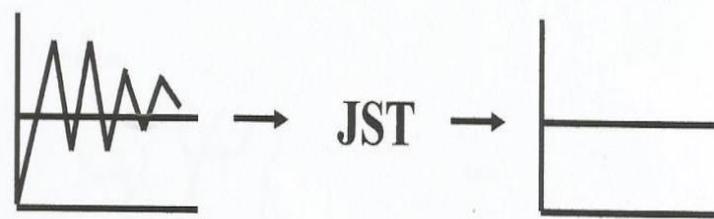
2.2.7 Jaringan Syaraf Tiruan

Pendefinisian jaringan syaraf tiruan dilihat dari fungsi atau struktur rancangan merupakan penyederhanaan dari model otak manusia. Kinerja struktur jaringan syaraf biologi pada otak manusia adalah dengan cara menyampaikan sinyal dari satu neuron ke neuron lain yang berdekatan serta bersesuaian. Hal sama berlanjut untuk neuron yang berikut, sampai pada neuron terakhir yang dikehendaki sinyal tersebut[11].

Tiruan neuron dalam struktur jaringan syaraf tiruan adalah elemen pemroses yang dapat berfungsi seperti sebuah neuron. Kumpulan dari neuron dibuat menjadi sebuah jaringan yang akan berfungsi sebagai alat komputasi yang berbasis computer dengan cara pendekatan perhitungan matematis. Dengan kata lain JST juga dapat dipandang sebagai “sebuah system yang terdiri atas elemen – elemen yang terdistribusi secara parallel dengan kemampuan untuk memperbaiki kinerja melalui proses belajar”.

Pada gambar 2.7 merupakan ilustrasi dari salah satu kemampuan jaringan syaraf tiruan belajar mengingat dan berfikir. Mula – mula JST ditunjukkan dengan beberapa buah pola dengan bentuk sempurna (proses belajar untuk mengingat).

Setelah proses belajar selesai JST diberikan pola yang tidak utuh dan ternyata JST mampu menghasilkan output (berfikir) berupa pola yang sempurna seperti yang pernah dipelajari.



Gambar 2. 7 Ilustrasi kemampuan Jaringan Saraf Tiruan

2.2.7.1 Struktur Jaringan Syaraf Tiruan

Adapun model representatif dari JST tampak pada gambar 2.6. Suatu neuron terdiri dari weight, penjumlahan fungsi keluaran serta dapat juga memakai elemen bias yang mempunyai harga input yang tetap bernilai 1. Gambar 2.8 merupakan unit neuron lapisan j yang diberi pola input X sebanyak i dan bias $\theta=1$, maka secara matematis output Y dapat ditulis:

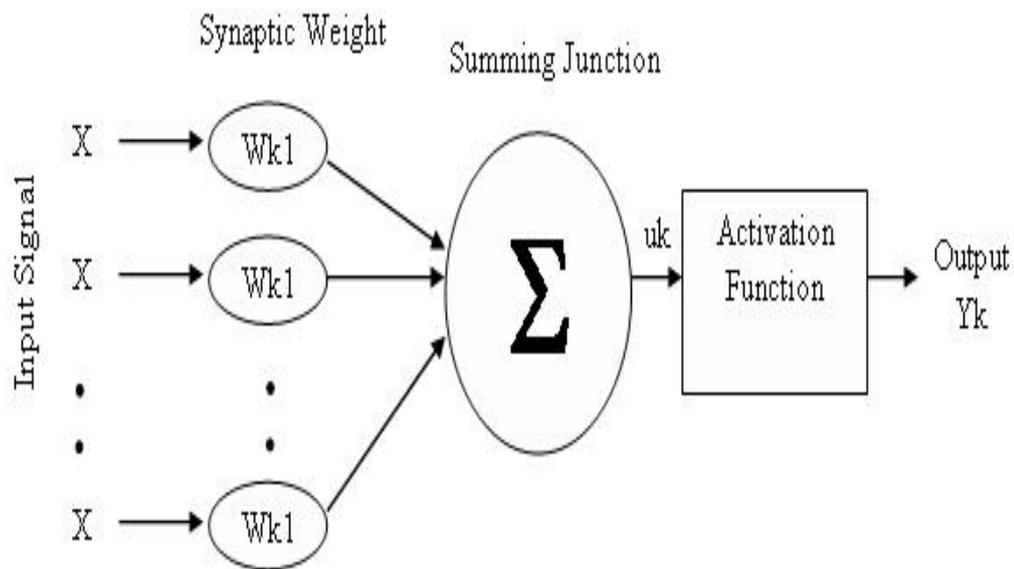
$$NET_j = \sum_{i=0}^n X_{ij}W_{ij} + \theta_{j1}$$

$$Y = f(NE_j) \tag{2.14}$$

Dengan W adalah elemen – elemen *weight input* dan $F(.)$ adalah fungsi keluaran jaringan.

Input X_i yang masuk ke neuron dapat berupa informasi dari luar system atau dari *output* lapisan neuron dengan hirarki yang lebih rendah, jika JST tersebut memiliki banyak lapisan neuron atau *multilayer*. Untuk jaringan syaraf tiruan *multilayer*, maka harga lapisan neuron dengan hirarki paling rendah (lapisan *input*) yang menerima sinyal informasi dari luar (*eksternal*).

JST hanya dapat mengolah *input* bilangan, jika masalah melibatkan besaran kualitatif atau pola gambar, maka pola *input* harus dikuantisasikan ke bilangan yang bersesuaian sebelum diolah dengan jaringan syaraf tiruan.



Gambar 2. 8. Elemen Pengolah Informasi (Neuron)

Elemen *weight* W pada setiap neuron merupakan representasi dari kekuatan sambungan (*strength of synapse*) antar neuron. *Weight* W_{ij} pada model di atas menyatakan kekuatan hubungan antara neuron lapisan i ke lapisan j . Jika neuron pada lapisan i berjumlah n dan m pada lapisan j , maka *weight* W_{ij} berbentuk matrik $m \times n$. Penulisan dari subskrip pada W selalu dari lapisan hirarki tertinggi. Sehingga model *weight* dapat ditulis W_{ij} .

Semua data input yang telah diboboti dengan kekuatan sambungan akan dijumlahkan terlebih dahulu sebelum diolah menjadi *output*. Dan hasil penjumlahan ini biasa ditulis sebagai NET.

Fungsi pengolah data *input* menjadi data *output* disebut fungsi aktifasi neuron $f(x)$. Antara lain[12] :

a. Fungsi Sigmoid Biner

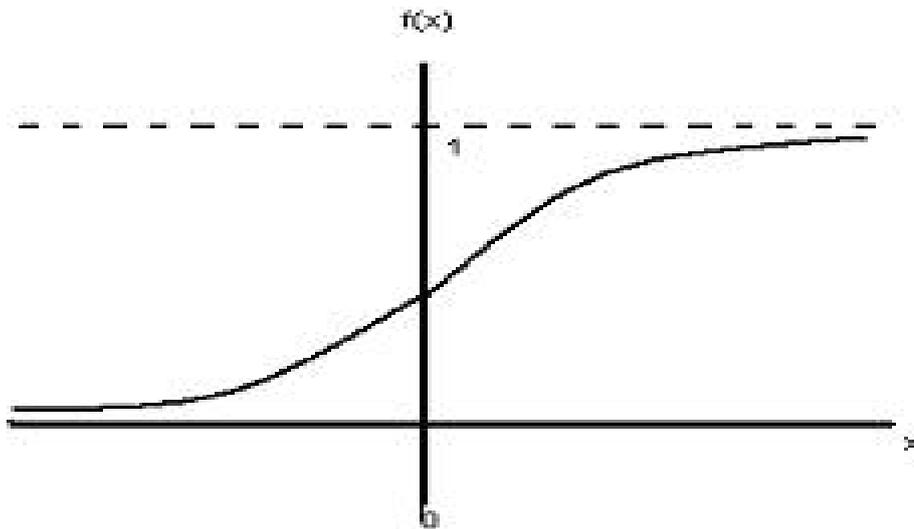
Fungsi sigmoid biner memiliki nilai *range* 0 sampai 1, seperti ditunjukkan pada gambar 2.9 . Fungsi sigmoid Biner seperti persamaan 2.15

$$f(x) = \frac{1}{1+\exp(-x)} \tag{2.15}$$

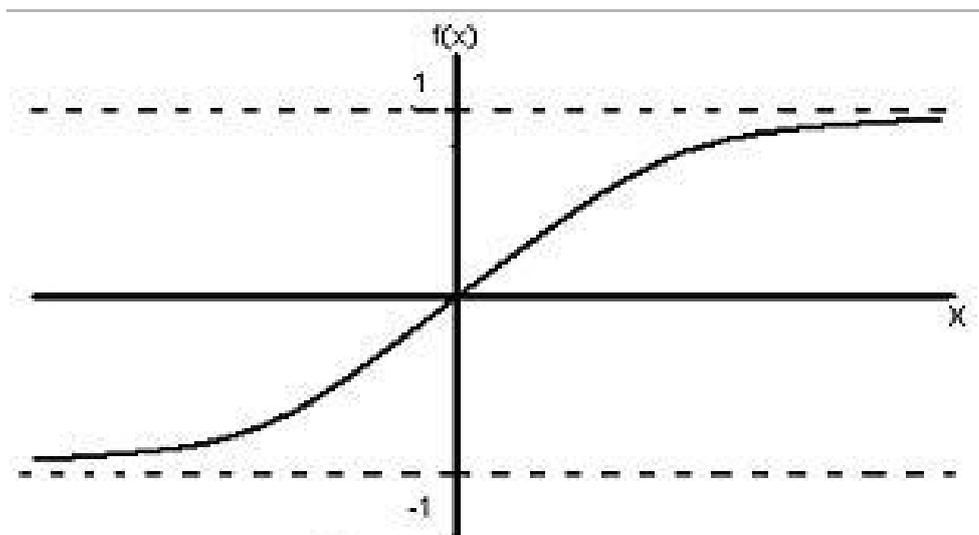
b. Fungsi Sigmoid Bipolar

Fungsi sigmoid bipolar memiliki nilai output range -1 sampai 1, seperti ditunjukkan pada gambar 2.10. Fungsi sigmoid bipolar seperti persamaan 2.16.

$$f(x) = \frac{1-e^{-2x}}{1+e^{-2x}} \quad (2.16)$$



Gambar 2. 9 Fungsi Sigmoid Biner[12]



Gambar 2. 10 Fungsi Sigmoid Bipolar[12]

2.2.7.2 Arsitektur jaringan Syaraf Tiruan

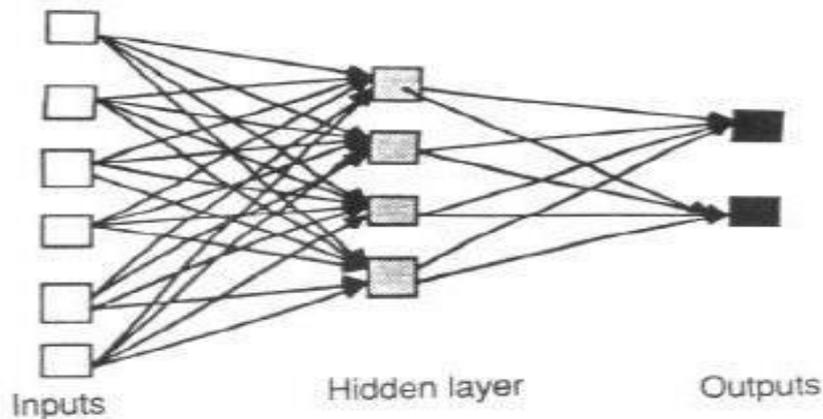
Berdasarkan alir informasi maka JST dapat dibagi menjadi [12]:

a. Jaringan Umpan Balik (*Feed Back Networks*)

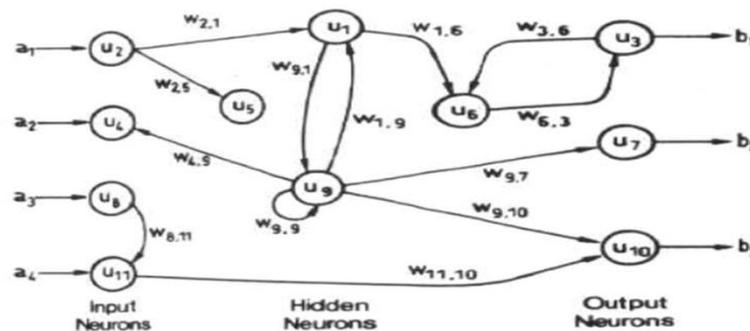
JST dengan umpan balik ini ditandai dengan umpan balik dari output ke input atau dari lapisan dengan hirarki lebih tinggi ke lapisan dengan hirarki yang lebih rendah. Jadi output neuron ke-t, $Y(t)$, ditentukan oleh input neuron $X(t)$ dan output $y(t-1)$, seperti gambar 2.10.

b. Jaringan Umpan Maju (*Feed Forward Networks*)

Pada gambar 2.9 menunjukkan bahwa JST dengan umpan maju yang ditandai dengan alir informasi dari *input* ke *output* atau dari lapisan dengan hirarki lebih rendah ke lapisan dengan hirarki lebih tinggi. Jadi *output* neuron ke-t, $Y(t)$ ditentukan oleh *input* neuron $X(t)$.



Gambar 2. 11 Jaringan Syaraf Tiruan Feedforward



Gambar 2. 12 Jaringan Syaraf Tiruan Feedback

2.2.7.3 Metode Pembelajaran (*Learning*)

Pembelajaran (*learning*) bagi JST merupakan proses mengatur harga dari parameter *weight* untuk mendapatkan harga yang terbaik dengan melatih (*training*) jaringan menurut unjuk kerja system yang dikehendaki.

Tujuan proses ini agar kumpulan pola *input* (*vector input*) yang diberikan menghasilkan pola *output* (*vector output*) yang diinginkan atau paling sedikit mendekati. *Learning* ini dibentuk dengan menerapkan secara berurutan pada pola input dan mengatur bobot jaringan mendekati pola output. Mengikuti suatu algoritma belajar tertentu, sehingga pola *input* menghasilkan pola *output* yang diinginkan. Kemampuan belajar merupakan juga kemampuan untuk mendekati suatu fungsi. Hal ini membuat *fleksibel* untuk digunakan proses identifikasi suatu plant.

Ada dua metode pembelajaran pada *neural network* (JST) yaitu [11]:

a. *Supervised Learning*

Algoritma ini membutuhkan pasangan untuk tiap *vector input* dengan *vector target* (keluaran yang diinginkan). Suatu system JST dilatih dengan cara membandingkan sejumlah pasangan keluaran dengan vector target. Pola *input* dimasukkan ke dalam jaringan yang kemudian diolah untuk menghasilkan *output*, yang disebut *output* jaringan. Selisih dari kedua *output* tersebut menyatakan kesalahan (*error*) yang akan digunakan untuk mengubah *weight* sambungan. Sehingga kesalahan akan semakin kecil dalam siklus pelatihan berikut.

b. *Unsupervised Learning*

Algoritma ini tidak membutuhkan vector target untuk *output*, sehingga tidak ada perbandingan untuk menentukan respon ideal. Kumpulan pola pelatihan hanya terdiri dari vector masukan dan algoritma pelatihan berfungsi sebagai pengubah atau modifikasi *weight* jaringan untuk menghasilkan pola vector, sehingga penerapan dua vector pelatihan suatu vector lain yang cukup sejenis menghasilkan pola keluaran sama. Dalam proses training, jaringan mengklasifikasikan pola – pola masukan menjadi kelompok yang sejenis. Penerapan suatu vector dari suatu kelas tertentu pada masukan akan menghasilkan vector keluaran khusus. Namun tidak ada cara untuk menentukan terlebih dahulu

pada pelatihan, yang akan menghasilkan pola keluaran tertentu dengan satu vector masukan dari kelas tertentu.

2.2.7.4 Algoritma Levenberg – Marquardt Pada Jaringan Syaraf Tiruan

Algoritma Levenberg – Marquardt merupakan pengembangan dari metoda Gauss-Newton. Mula – mula metoda Gauss-Newton menggunakan linierisasi di sekitar harga estimasi bobot terakhir dan menyelesaikan permasalahan *least square* untuk memperoleh vector bobot interkoneksi [12].

Algoritma Levenberg – Marquardt dengan menggunakan pendekatan antara lain:

1. Matrik Hessian

Matriks Hessiam adalah matriks persegi dari turunan parsial orde kedua[13]. Dengan didefinisikan fungsi riil f sebagai berikut: $f(x_1, x_2, \dots, x_n)$. Jika turunan parsial orde kedua untuk semua f terdefinisi, maka matriks Hessian dari fungsi f adalah:

$$H(x) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix} \quad (2.17)$$

2. Matriks Jacobian

Matriks Jacobian adalah matriks yang dibentuk dari gradien fungsi bernilai vector. Matriks Jacobian merupakan matriks yang diperoleh dari *transpose Gradien $f(x)$* .

$$J = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial e_1}{\partial x_2} & \cdots & \frac{\partial e_1}{\partial v_{(1,k)}} \\ \frac{\partial e_1}{\partial v_{(2,1)}} & \frac{\partial e_1}{\partial v_{(2,2)}} & \cdots & \frac{\partial e_1}{\partial v_{(2,k)}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_1}{\partial v_{(j,1)}} & \frac{\partial e_1}{\partial v_{(j,2)}} & \cdots & \frac{\partial e_1}{\partial v_{(i,k)}} \end{bmatrix} \quad (2.18)$$

Algoritma Levenberg-Marquardt menggunakan pendekatan untuk menghitung matrik Hessian, melalui pendekatan metode Newton[13].

$$\Delta X = [J^T + \mu I]^{-1} J^T e \quad (2.19)$$

sehingga perbaikan pembobot dapat ditentukan.

$$X_{(new)} = X_{(old)} + \Delta X$$

$$X = \Delta X + [J^T + \mu I]^{-1} J^T e \quad (2.20)$$

dengan I adalah matriks diagonal. Levenberg-Marquardt menyarankan agar menambahkan suatu nilai scalar yang sama pada masing – masing elemen diagonal yaitu $\mu = dI$, dengan I adalah matrik identitas.

Apabila μ bernilai 0, maka pendekatan ini akan sama seperti metode Newton, namun apabila μ terlalu besar maka pendekatan ini akan sama halnya dengan *gradient descent* dengan *learning rate* yang sangat kecil. Metode Newton sangat cepat dan akurat untuk mendapatkan *error* minimum, oleh karena itu diharapkan algoritma sesegera mungkin apa mengubah nilai μ menjadi sama dengan 0. Untuk itu setelah beberapa iterasi algoritma akan menurunkan nilai μ , kenaikan nilai μ hanya dilakukan apabila dibutuhkan suatu langkah (sementara) untuk menurunkan fungsi kerja. Untuk itu parameter μ dikalikan dengan suatu faktor pengali β .

Pada persamaan (2.21), e adalah vector yang berukuran pn_o yang dapat ditentukan dengan $J^T J$. Dimensi *input* dianggap sebagai n_i , dan dimensi *output* adalah n_o . Jumlah total *pattern* disimbolkan sebagai p . Jika jaringan menggunakan MLP (*Multi Layer Perceptron*), maka diperlukan n_i dimensi *layer input* dan n_o dimensi *layer output*. Jika n_h adalah jumlah neuron pada *hidden layer* yang dipunyai oleh *single hidden layer* sebuah MLP, maka jumlah total bobot dan bias pada MLP menjadi,

$$w = n_i n_h + n_h n_o + n_h + n_o \quad (2.21)$$

Berdasarkan notasi di atas maka dimensi dari matrik Jacobi akan sama dengan $pn_o \times w$ sehingga Hessian menjadi $w \times w$.

$$J = \begin{bmatrix} \frac{\partial e_{11}(x)}{\partial x_1} & \frac{\partial e_{11}(x)}{\partial x_2} & \frac{\partial e_{11}(x)}{\partial x_3} & \dots & \frac{\partial e_{11}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{k1}(x)}{\partial x_1} & \frac{\partial e_{k1}(x)}{\partial x_2} & \frac{\partial e_{k1}(x)}{\partial x_3} & \dots & \frac{\partial e_{k1}(x)}{\partial x_n} \\ \frac{\partial e_{12}(x)}{\partial x_1} & \frac{\partial e_{12}(x)}{\partial x_2} & \frac{\partial e_{12}(x)}{\partial x_3} & \dots & \frac{\partial e_{12}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{k2}(x)}{\partial x_1} & \frac{\partial e_{k2}(x)}{\partial x_2} & \frac{\partial e_{k2}(x)}{\partial x_3} & \dots & \frac{\partial e_{k2}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{kp}(x)}{\partial x_1} & \frac{\partial e_{kp}(x)}{\partial x_2} & \frac{\partial e_{kp}(x)}{\partial x_3} & \dots & \frac{\partial e_{kp}(x)}{\partial x_n} \end{bmatrix} \quad (2.22)$$

- x = fungsi bobot - bobot jaringan dan bias
- $x = [v_{11}, v_{12}, \dots, v_{ij}; v_{01}, v_{02}, \dots, v_{0j}; w_{11}, w_{12}, \dots, w_{jk}; w_{01}, w_{02}, \dots, w_{0k}]$

Matrik Jacobi merupakan matrik turunan pertama dari *error* terhadap bobot dan bias. Matrik Jacobi antara *input node* dan *hidden layer* adalah matrik yang berisi turunan *error* terhadap bobot antara *input node* dan *hidden layer* beserta biasnya.

Matrik Jacobi antara *hidden node* dengan *input node* adalah matrik yang berisi turunan *error* pertama terhadap bobot antara *hidden node* dengan *output node*.

- Elemen dari matrik Jacobi antara *input layer* dan *hidden layer* adalah,

$$\begin{aligned} \frac{\partial e_k}{\partial v_{(i,j)}} &= \frac{\partial (y_k - t_k)}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_{in_k}} \cdot \frac{\partial y_{in_k}}{\partial z_j} \cdot \frac{\partial z_j}{\partial z_{in_j}} \cdot \frac{dz_{in_j}}{\partial v_{ij}} \\ &= 1 \cdot f'(y_{in_k}) \cdot \frac{\partial (w_{ok} \sum_{j=1}^p z_j w_{jk})}{\partial z_j} \cdot f'(z_{in_j}) \cdot \frac{\partial (v_{oj} + \sum_{i=1}^n x_i v_{ij})}{\partial v_{ij}} \end{aligned} \quad (2.23)$$

- Elemen matrik Jacobi untuk bias pada *hidden layer* adalah

$$\frac{\partial e_k}{\partial v_{oj}} = \frac{\partial (y_k - t_k)}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_{in_k}} \cdot \frac{\partial y_{in_k}}{\partial z_j} \cdot \frac{\partial z_j}{\partial z_{in_j}} \cdot \frac{\partial z_{in_j}}{\partial v_{oj}}$$

$$\begin{aligned}
&= 1. f'(y_{in_k}) \cdot \frac{\partial(w_{ok} \sum_{j=1}^p z_j w_{jk})}{\partial z_j} \cdot f'(z_{in_j}) \cdot \frac{\partial(v_{oj} + \sum_{i=1}^n x_i v_{ij})}{\partial v_{ij}} \\
&= f'(y_{in_k}) \cdot w_k \cdot f'(z_{in_j}) \cdot 1
\end{aligned} \tag{2.24}$$

- Elemen matrik Jacobi antara *hidden* dan *output layer*

$$\begin{aligned}
\frac{\partial e_k}{\partial w_{(j,k)}} &= \frac{\partial(y_k - t_k)}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_{in_k}} \cdot \frac{\partial y_{in_k}}{\partial w_{jk}} \\
&= 1. f'(y_{in_k}) \cdot \frac{\partial(w_{ok} + \sum_{j=1}^p z_j w_{jk})}{\partial w_{jk}} \\
&= 1. f'(y_{in_k}) \cdot z_j
\end{aligned} \tag{2.25}$$

- Elemen matrik Jacobi untuk bias pada *output layer* adalah

$$\begin{aligned}
\frac{\partial e_k}{\partial w_{ok}} &= \frac{\partial(y_k - t_k)}{\partial y_k} \cdot \frac{\partial y_k}{\partial y_{in_k}} \cdot \frac{\partial y_{in_k}}{\partial w_{ok}} \\
&= 1. f'(y_{in_k}) \cdot \frac{\partial(w_{ok} + \sum_{j=1}^p z_j w_{jk})}{\partial w_{ok}}
\end{aligned} \tag{2.26}$$

2.2.7.5 Tahap Pelatihan

Tahap pelatihan ini merupakan langkah bagaimana suatu jaringan syaraf itu berlatih, yaitu dengan cara melakukan perubahan bobot sambungan. Sedangkan tahap pemecahan masalah akan dilakukan jika proses belajar tersebut selesai, tahap tersebut merupakan proses pengujian atau *testing*. Secara garis besar algoritma Levenberg-Marquardt merupakan modifikasi dari backpropagation. Terdiri dari dua proses yaitu *feed forward* dan perbaikan pembobot, yang dilakukan secara serentak dengan menghitung matrik Jacobian terlebih dahulu.

1. Proses *feed forward* (Tahap Maju)

- a. Inisialisasi faktor penimbang dengan nilai random yang kecil
- b. Masing – masing *hidden* menjumlahkan faktor penimbang :

$$Z_j = f(Z_{in_j}) \quad (2.27)$$

Karena yang digunakan fungsi sigmoid maka :

$$Z_j = \frac{1}{1+\exp(-Z_{in_j})} \quad (2.28)$$

Kemudian mengirim sinyal tersebut ke semua unit di atasnya (*output unit*). Masing – masing unit output ($Y_k, k = 1,2,3, \dots, m$) dijumlahkan faktor penimbang:

$$Y_{in_k} = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (2.29)$$

Menghitung sesuai dengan fungsi aktivasi:

$$Y_k = f(Y_{in_k}) \quad (2,30)$$

Masing – masing unit output ($Y_k, k = 1,2,3, \dots, m$) menerima pola target sesuai dengan pola masukan saat *training* dan menghitung *error*:

$$\partial_k = (t_k - Y_k) f'(Y_{in_k}) \quad (2.31)$$

Karena $f'(Y_{in_k}) = Y_k$ dengan menggunakan fungsi sigmoid, maka :

$$\begin{aligned} f'(Y_{in_k}) &= f(Y_{in_k})(1 - f(Y_{in_k})) \\ &= Y_k(1 - Y_k) \end{aligned} \quad (2.32)$$

2. Proses perbaikan pembobot

Pada lapisan *output*, diawali dengan membandingkan *output* jaringan dengan *output* target. *Error* yang terjadi digunakan untuk memperbaiki tiap bobot sambungan. *Error* diminimalkan dengan persamaan :

$$E = \frac{1}{2} \sum_{k=1}^m (\beta_k)^2 \text{ dengan } \beta_k = (t_k - Y_k) \quad (2.33)$$

semua *error* yang terjadi dilapisan *output* dibandingkan (diturunkan satu kali) dengan semua bobot – bobot jaringan untuk membentuk matrik Jacobi. Setelah itu dilakukan proses perbaikan / *update* bobot dengan persamaan 2.22 dan 2.23.

2.2.7.6 Tahap Pengujian

Pada tahap ini, pola yang akan dikenali dimasukkan pada *input node* jaringan. Inisialisasi bobot sambungan diambil dari nilai bobot sambungan terakhir pada tahap belajar yang dianggap paling baik. Pola ini dikomputasikan dengan bobot interkoneksi hasil fase pelatihan, dengan persamaan 2.30 sampai 2.34. Nilai inilah yang akan dikirim kelapisan output seperti proses pada *hidden layer*, maka didapat hasil *output* adalah

$$Y_{in_k} = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (2.34)$$

Hasil aktivasi sel – sel pada lapisan keluaran merupakan keputusan dari jaringan syaraf tiruan. Pada perangkat lunak yang dibuat, hasil aktivasi sel sebagai keputusan JST ditampilkan dalam skala kebenaran, skala kebenaran terbesar merupakan keputusan terakhir dari jaringan syaraf tiruan.

2.2.8 Metode Pengujian

Metode pengujian dilakukan dengan maksud untuk menguji tingkat akurasi prediksi secara keseluruhan. Pengujian dilakukan untuk melihat selisih error antara hasil prediksi dengan data sebenarnya, yaitu dengan menggunakan MAPE (*Mean Absolute Percentage Error*). Berikut adalah rumus untuk menghitung MSE dan MAPE sebagai berikut:

$$MSE = \frac{\sum |A_t - F_t|}{n} \quad (2.35)$$

dan

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (2.36)$$

2.2.9 Evaluasi Kinerja (ROC)

Untuk mengukur kinerja suatu sistem atas dasar nilai kesalahan yang terjadi dan tingkat kesuksesan pengenalan suatu sistem (specificity), maka ROC (*Receiver Operating Curve*) dapat digunakan untuk menghitung nilai kesalahan dan nilai kesuksesan suatu system. Serta digunakan dalam mengevaluasi proses klasifikasi, dikarenakan kemampuan evaluasi secara menyeluruh dan cukup baik[14]. Pada sebuah table 2.4 terdiri dari dua buah kelas data yaitu data kelas prediksi (*Predicted Class*) dan data kelas aktual (*Actual Class*). Jika data *predicted class* sama dengan *actual class*, maka data termasuk *True Positif* (TP), sedangkan jika data *predicted class* tidak sama dengan *actual class* tetapi termasuk data hasil klasifikasi maka data tersebut termasuk *False Positive* (FP).

Confusion Matrix digunakan untuk mengevaluasi pengklasifikasian karena mempunyai kemampuan evaluasi secara menyeluruh dan cukup baik [15]. Tabel *confusion matrix* untuk memperkirakan hasil yang benar dan salah pada hasil pengujian. Hasil dari yang diperoleh pada tahap prediksi dilakukan perbandingan yaitu dengan perolehan hasil *true positive*, *false positive*, *true negative*, dan *false negative*.

ROC dapat digunakan sebagai grafik perbandingan antara *True Positive Rate* (TPR) pada sumbu vertical dengan *False Positive Rate* (FPR) pada sumbu horintal. TPR merupakan proporsi data positif teridentifikasi dengan benar antara data *predicted class* dengan *actual class*. Sedangkan FPR merupakan proporsi data negatif teridentifikasi salah sebagai positif pada suatu model klasifikasi[16]. *True positive Rate* dan *False Positive Rate*, dapat dihitung menggunakan persamaan 2.37.

$$TPR = \frac{TP}{TP+FP} \times 100\% \quad (2.37)$$

$$FPR = \frac{FP}{TP+FP} \times 100\% \quad (2.38)$$

Kurva ROC terdapat luasan area di bawah kurva yang dikenal dengan AUC (*Area Under Curve of ROC*). Nilai AUC berkisaran antara 0 sampai dengan

1, semakin mendekati nilai 1 maka semakin baik nilai uji pada karakteristik prediksi tersebut. Nilai kategori AUC [17], dapat dilihat pada table 2.5.

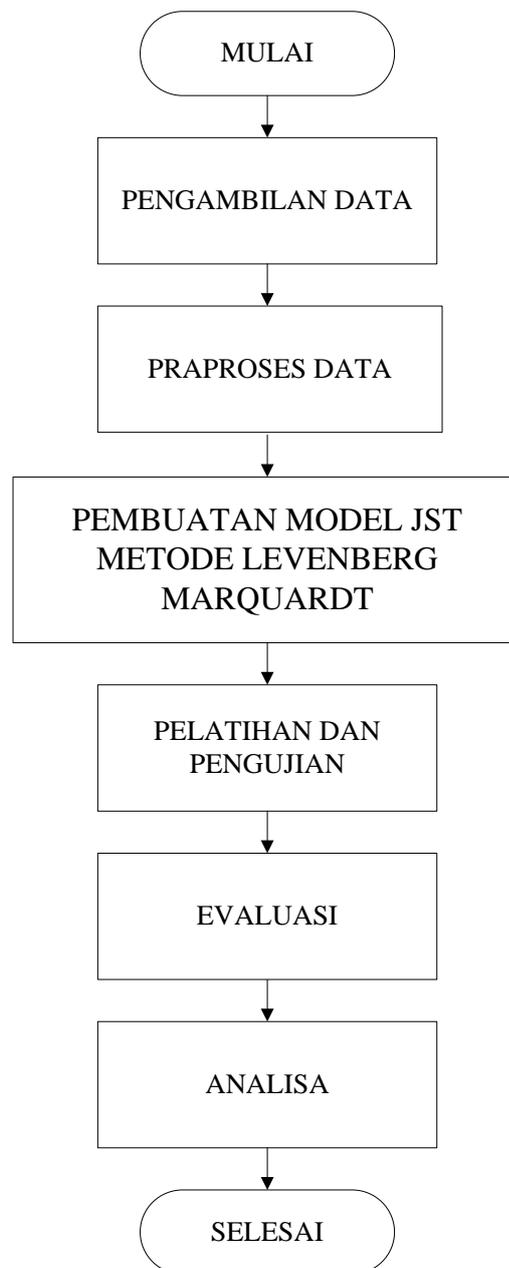
Tabel 2. 4 Tabel Nilai AUC [17]

Range Nilai AUC	Keterangan
0.5 – 0.6	Fail
0.6 – 0.7	Poor
0.7 – 0.8	Fair
0.8 – 0.9	Good
0.9 – 1	Excellent

BAB 3

METODOLOGI PENELITIAN

Dalam penyelesaian dan tercapainya tujuan penelitian ini maka metodologinya adalah sebagai berikut:



Gambar 3. 1 Alur Penelitian

3.1 Pengambilan Data

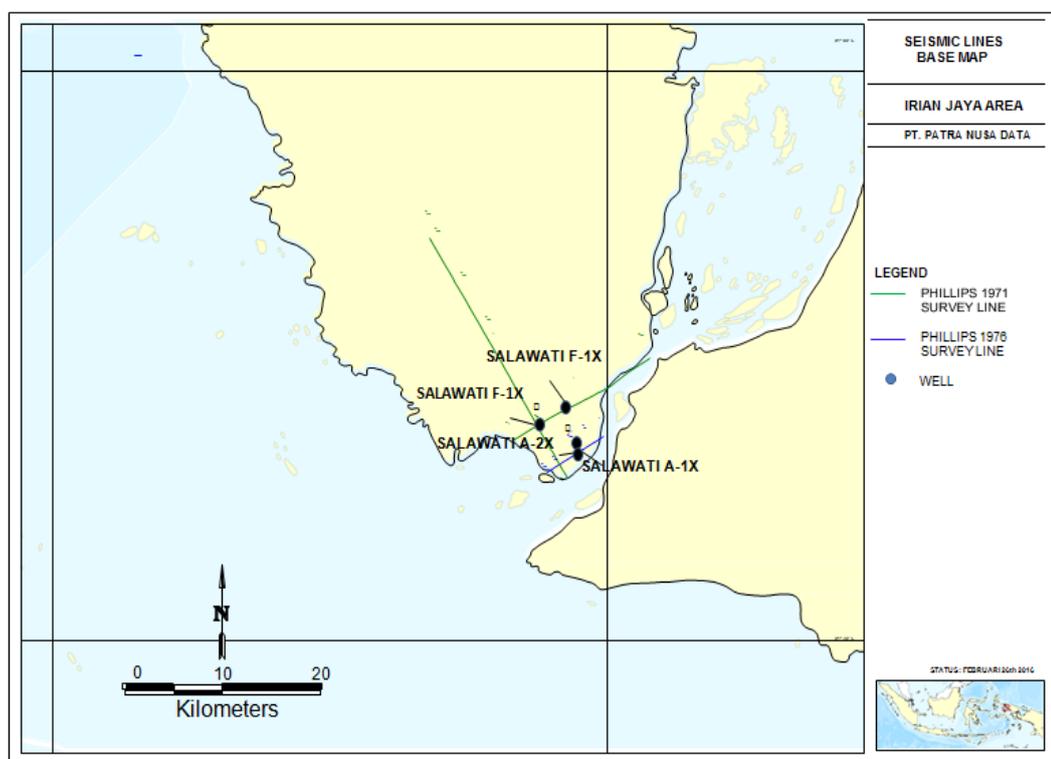
Pengambilan data yaitu data log (sumur) merupakan data sekunder yang diperoleh dari PUSDATIN ESDM (Pusat Data dan Informasi Energi dan Sumber Daya Mineral) di bawah Kementerian ESDM, dengan objek 5 sumur yang berlokasi di Irian Jaya area ditunjukkan pada gambar 3.2 dengan jarak sumur berdekatan dari posisi *latitude* dan *longitude*, secara detail disajikan pada tabel 3.1 sehingga formasi lapisan bumi masih sama dan data yang dilatihkan menjadi lebih baik serta *robust* untuk di tes dan *layout* lokasi sumur.

Gambar 3.2 merupakan sumur observasi dengan data-data yang diambil menggunakan metode *wireline logging* dengan 2 – 3 kali pengukuran variabel lapisan tanah untuk mengetahui lapisan yang memiliki kandungan gas atau minyak bumi. secara detail letak sumur observasi ada pada tabel 3.1. Metode *Wireline logging* yaitu pekerjaan yang dilakukan meliputi pengukuran data-data properti elektrik (resistivitas dan konduktivitas pada berbagai frekuensi), data nuklir secara aktif dan pasif. *Logging tool* (peralatan utama *logging*, berbentuk pipa pejal berisi alat pengirim dan sensor penerima sinyal) diturunkan ke dalam sumur sehingga didapatkanlah data tersebut. Hal ini dapat dimanfaatkan untuk melihat perbedaan karakteristik batuan yang berhubungan dengan batas antara dua lapisan.

Data sumur yang diperoleh berupa kurva log dari lapangan yang sudah di digitalkan dengan format data *.LAS. Tujuan dari pengkonversian dari kurva log menjadi data digital agar lebih mudah untuk menganalisa data tersebut dengan menggunakan *software* yang diinginkan, selanjutnya dikonversikan kembali kedalam kurva log yang siap di analisa dan di interpretasi

Data sumur yang sudah dipilih memiliki format data *.LAS (*Log Ascii File*), agar dapat dilakukan pengolahan data pada software Petrolog 10.2, maka terlebih dahulu dilakukan *converting* data menjadi format data *internal software* (*.log data) kemudian menjadi format (.xlsx). Tujuan dari pengkonversian dari kurva log menjadi data digital agar lebih mudah untuk menganalisa data tersebut dengan menggunakan *software* yang diinginkan, selanjutnya dikonversikan kembali kedalam kurva log yang siap di analisa dan di interpretasi.

Sebelum dilakukan langkah selanjutnya, terlebih dahulu informasi yang ada pada *header log* dilengkapi sesuai yang ada pada *field report*. Hal ini sangat penting dilakukan karena beberapa informasi yang ada dalam *header log* digunakan dalam proses perhitungan selanjutnya.



Gambar 3. 2 Layout Irian Jaya Area

Tabel 3. 1 Data Lokasi Sumur Observasi

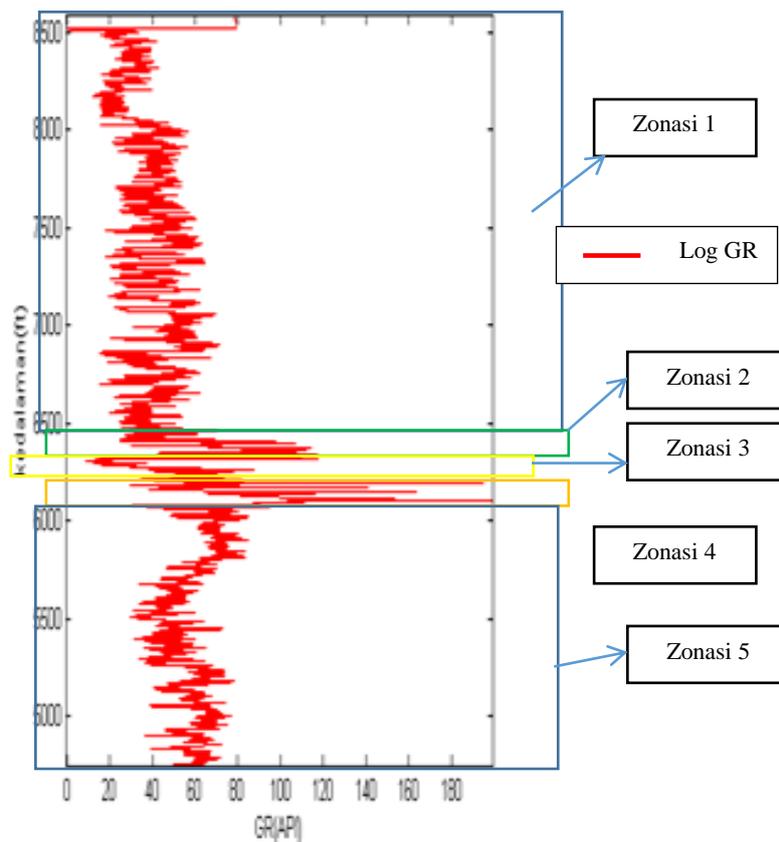
Nama Sumur	Kedalaman (ft)	Jumlah Data Awal	Posisi		Variabel Data Awal
			Longitude	Latitude	
SALAWATI F-1X_PHIND	60 – 7480	14998	130°57'57E	1°17'45S	Dept, GR, SP, Cali, Sg, Med, Msfl, Deep, DT, RHOB,NPHI,DPHI, Pe, DRHO
SALAWATI E-1X PHIND	70 – 7160	14301	130°56'27E	1°18'45S	
JAYA-10 PETTRE	654 – 3362	5417	131°3'49.1E	1°19'56S	
SALAWATI A-1X PHIND	0 – 5900	11801	130°58'13E	1°9'48S	
SALAWATI A-2X PHIND	50 – 5750	11401	130°58'21E	1°20'5S	

3.2 Praproses Data

3.2.1 Quick Look Analysis

Pembagian zonasi, tahap ini dimaksudkan untuk menghitung porositas efektif berdasarkan karakteristik nilai yang seragam, dengan ini maka di plot log GR sebagai representatif permeabilitas lapisan terhadap kedalaman. Log GR adalah kurva gamma ray yang sudah dinormalisasi dengan menggunakan satu nilai mean dan standar deviasi dari sebuah lapangan. Setiap pengukuran gamma ray pada reservoir dapat menghasilkan nilai dan range nilai yang berbeda-beda karena perbedaan kondisi lubang bor dan alat dari masing-masing service company sehingga dibutuhkan sebuah well yang menjadi referensi pada suatu lapangan [17].

Pada penelitian ini digunakan sumur SALAWATI F-1X_PHIND dikarenakan data yang lengkap dan dapat mewakili sumur lainnya dengan lokasi yang berdekatan berdasarkan posisi longitude dan latitude maka nilai formasi lapisan rata-rata sama .



Gambar 3. 3 Proses Zonasi pada Kurva Log

3.2.2 Perhitungan Porositas Efektif

Tabel 3. 2 Karakteristik Permeabilitas

Karakteristik	Nilai
Log GR	<50 mewakili permeabilitas
Volume serpih	<0.3 menunjang nilai permeabilitas
Porositas Efektif	>25% mewakili porositas

Setelah proses zonasi selesai dilakukan perhitungan porositas efektif, perhitungan ini diperlukan karena output yang akan dijadikan sebagai input pelatihan jaringan syaraf tiruan adalah data yang mampu merepresentasikan porositas dan permeabilitas. Karakteristik permeabilitas pada tabel 3.2 sudah diwakili oleh proses zonasi pada tahap 1.

Tahap-tahap untuk mendapatkan porositas efektif [2] diantaranya :

- Nilai – nilai log GR (API) pada sumbu x di plot terhadap kedalaman (ft) pada sumbu y, bagian-bagian dimana *trend*-nya tidak sama dan terjadi defleksi maka dipisahkan seperti gambar 3.3. Hal ini bertujuan agar perhitungan porositas efektif menjadi lebih akurat karena perzonasi memiliki nilai rata-rata yang sama tanpa ada nilai yang terdeviasi terlalu jauh.
- Kemudian langkah selanjutnya dengan menentukan volume serpih (*shale*) menggunakan log gamma ray (V_{sh} GR), yang mana harga V_{sh} dapat ditulis seperti persamaan 2.1, menentukan porositas lapisan dengan persamaan 2.2 sampai dengan persamaan 2.5. Langkah akhir menghitung porositas efektif dengan persamaan 2.6.

3.2.3 Pemilihan variable dengan PCA dan PLS

Praproses data ini meliputi seleksi variabel yang penting, baik itu pengaruh antar variabel *input* (X) menggunakan PCA (*principal component analysis*) ataupun pengaruh variable X terhadap variabel *output* (Y) menggunakan PLS (*partial least squares*) sehingga dapat diketahui variable yang saling

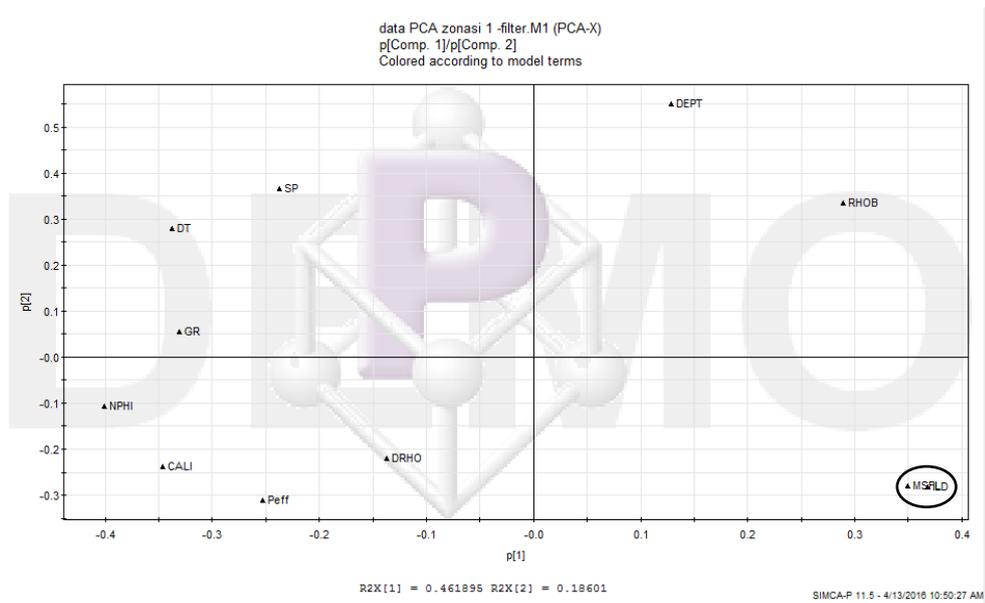
mempengaruhi. Dari sekian banyak variabel yang ada pada data log, maka dipilih hanya data variabel yang memiliki sensitivitas tinggi terhadap variabel lainnya. Dilakukan analisa PCA yaitu analisa korelasi antar variabel X, dan analisa PLS yaitu korelasi antar variabel X dan Y. Dari hasil PCA-PLS didapat kelompok variabel yang berkorelasi tinggi atau sensitiv terhadap perubahan antar variabel sehingga baik sebagai input jaringan syaraf tiruan nantinya. Perangkat lunak yang digunakan adalah SIMCA-P.

Tabel 3. 3 Daftar Data Log Yang dianalisa dengan PCA dan PLS

Jenis Data Log	
DEPT	Kedalaman
GR	Log Gamma Ray
CALI	Log Calliper
SP	Log Spontaneus Potential
ILD	Log Resistivity
MSFL	Log Resistivity
DT	Log Sonic
RHOB	Log Densitas
NPFI	Log Neutron
DRHO	Log Delta Rho
Peff	Porositas Effektif

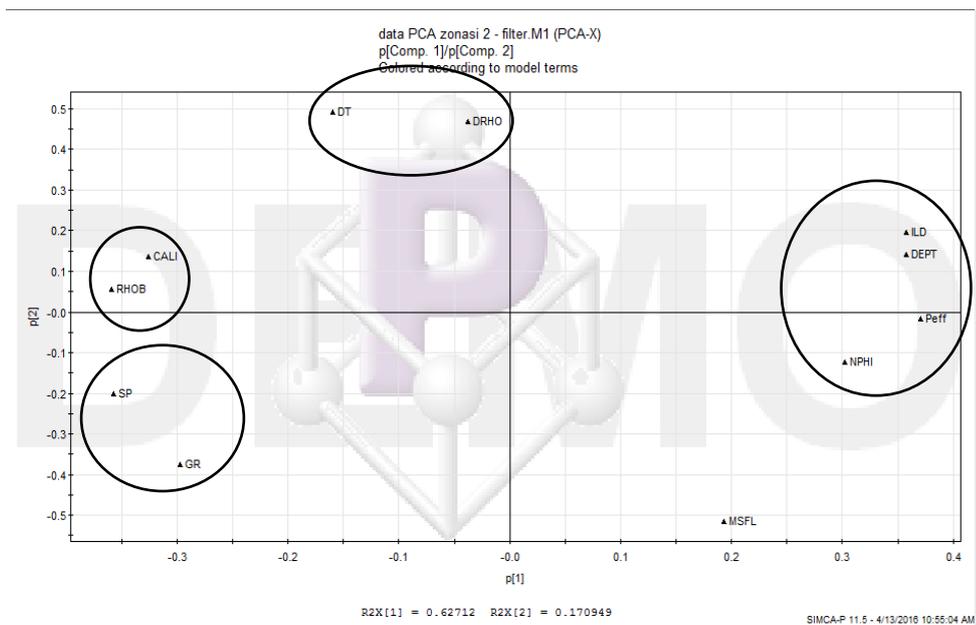
3.2.3.1 Analisa PCA

Analisa PCA ditujukan untuk menetapkan variabel yang penting dalam data sumur ini dengan mengamati kedekatan nilai komponen utama (p) yang divisualisasikan dengan koordinat[9]. Pada gambar 3.4, 3.5, 3.6, dan 3.7 yang merupakan hasil keluaran perangkat lunak SIMCA-P dapat diamati hasilnya sebagai berikut :

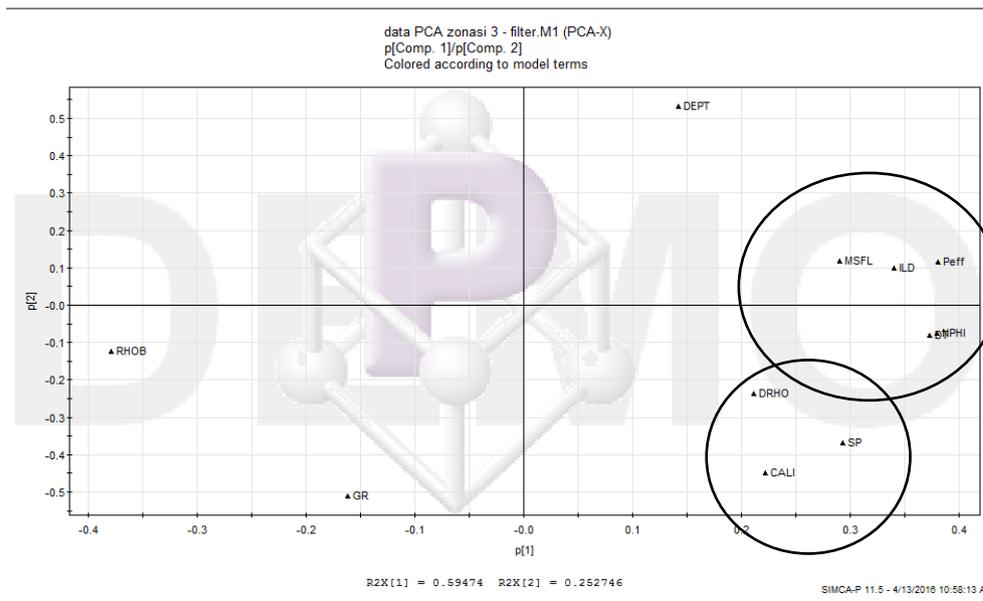


Gambar 3. 4 PCA zonasi 1

Pada gambar 3.4 menunjukkan bahwa data PCA yang tidak multikolinierisasi pada zonasi 1 adalah kelompok MSFL-ILD. Sedangkan dari zonasi 2 ada 4 kelompok variabel yang saling tidak multikolinier diantaranya kelompok CALI – RHOB, ILD – DEPT – Peff – NPHI, SP-GR, DT – DRHO di tunjukkan pada gambar 3.5.

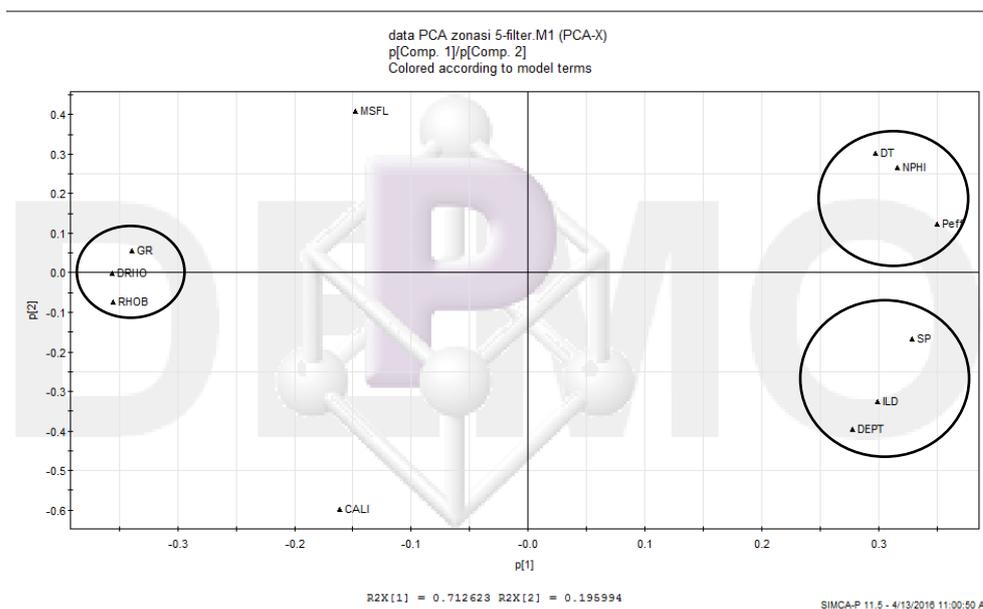


Gambar 3. 5. PCA zonasi 2



Gambar 3. 6. PCA zonasi 3

Pada gambar 3.6 menunjukkan bahwa dari data zonasi 3 tidak multikolinear adalah NPHI – DT – Peff – ILD – MSFL, CALI – SP – DRHO. Sedangkan Zonasi 4 tidak dapat dilakukan PCA karena menunjukkan kekurangan jumlah data hanya 12 buah data saja dan itu tidak relevan untuk PCA dimana PCA harus mencari median dalam prosesnya.



Gambar 3. 7. PCA zonasi 5

Gambar 3.7 menunjukkan bahwa Data Zonasi 5 terdapat 3 kelompok data yang berkorelasi diantaranya cluster DT – NPHI – Peff, SP – ILD – DEPT, GR – DRHO – RHOB.

Pada Gambar 3.4, 3.5, 3.6, dan 3.7 dapat disimpulkan bahwa berdasarkan letak kedekatan koordinat antar variabel di tabel 3.3 sebanyak 3 zonasi dari 4 zonasi yang diamati terdapat 3 variabel yang tidak multikolinearisasi diantaranya Peff, NPHI, ILD. Pada zonasi 1 dan zonasi 3 variabel ILD-MSFL tidak multikolinearisasi namun tidak bisa dimasukkan sebagai variabel penting karena setelah diamati dari data yang didapat, variabel MSFL tidak memiliki nilai atau kosong sejumlah 5886 data dari 6985 data MSFL yang diolah sehingga 78,5 % data MSFL tidak ada dan hal tersebut sangat kurang untuk diambil sebagai data latih JST.

Tabel 3. 4. Hasil kesimpulan PCA

Zonasi	Jenis Data Log
Zonasi 1	MSFL – ILD
Zonasi 2	ILD-DEPT-Peff-NPHI
Zonasi 3	NPHI-DT-Peff-ILD-MSFL
Zonasi 5	DT – NPHI – Peff

Berdasarkan hasil kesimpulan tabel 3.4 bahwa jumlah inputan cukup relevan untuk pembelajaran JST. Kemudian untuk mengetahui hubungan input terhadap output perlu dilakukan analisa PLS.

3.2.3.2 Analisa PLS

Analisa PLS dilakukan untuk menyatakan korelasi input dan output, dalam penelitian ini output yang diinginkan adalah data yang memiliki korelasi permeabilitas karena akan dijadikan sebagai input JST. Oleh karena itu sebagai output Y adalah log GR yang mewakili permeabilitas, pilihan lain dari log GR adalah log SP namun tidak dijadikan sebagai output karena log SP pada

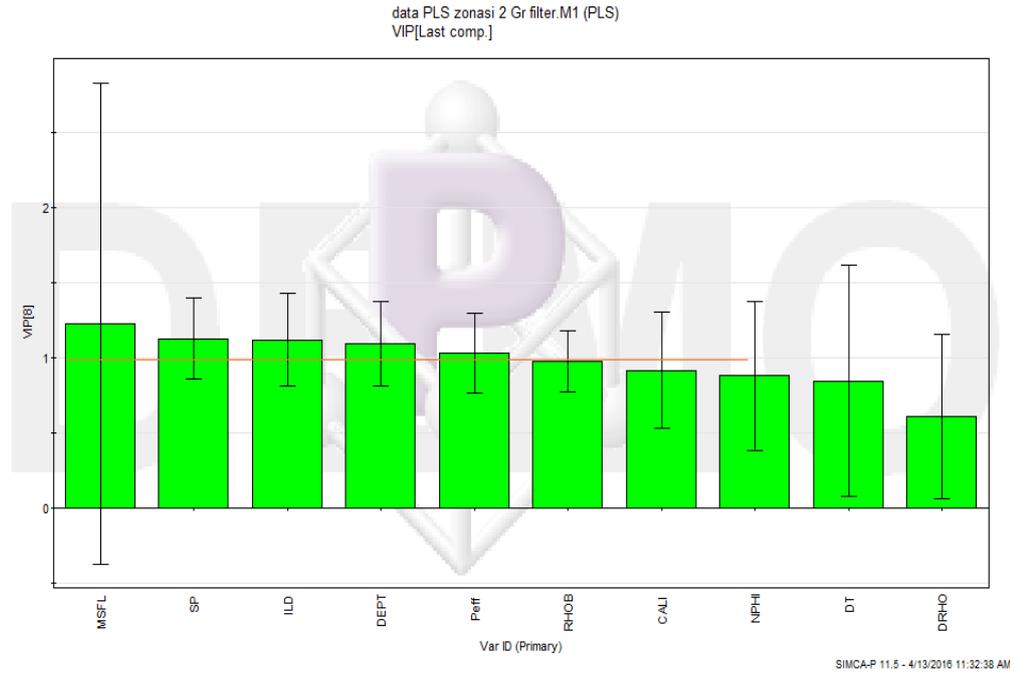
kenyataannya sering mengalami noise data akibat salinitas lapisan sehingga dijadikan sebagai pendukung. Kesimpulannya diperoleh dari analisa *the most important variabel* dengan mengurutkan dari terpenting sampai tidak terpenting berdasarkan korelasinya.

Sumbu y pada gambar 3.8, 3.9, 3.10, dan 3.11 adalah *variable importance for the projection (VIP)* yang menunjukkan seberapa besar pengaruh suatu variabel x terhadap variabel y yang merupakan hasil dari keluaran perangkat lunak SIMCA-P. Nilai VIP lebih dari 1 mengindikasikan variabel x yang penting, nilai kurang dari 0.5 mengindikasikan variabel x yang tidak penting dan nilai antara 0.5 – 1 merupakan variabel dalam zona abu-abu, artinya pengaruh variabel x tersebut terhadap y tergantung dari data set yang digunakan (*SIMCA-P Help*). Pada penelitian maka digunakan batasan nilai minimal 1 untuk menentukan variabel yang berpengaruh dalam penentuan zona reservoir.

Pada gambar 3.8 menunjukkan hasil bahwa data PLS dari zonasi 1 variabel yang tidak multikolinearisasi adalah Peff, NPHI, CALI, ILD, RHOB.



Gambar 3. 8 PLS Zonasi 1

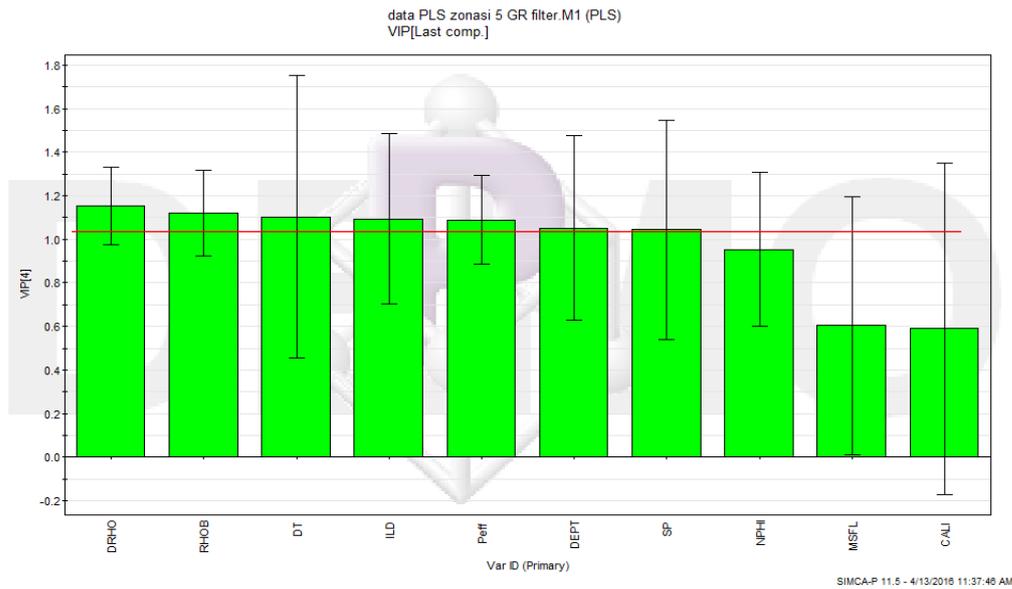


Gambar 3. 9. PLS zonasi 2

Dari data PLS zonasi 2 variabel yang tidak multikolinearisasi adalah MSFL, SP, ILD, RHOB, DEPT, Peff ditunjukkan pada gambar 3.9. Sedangkan pada gambar 3.10 menunjukkan bahwa data PLS dari zonasi 3 variabel yang tidak multikolinearisasi adalah DEPT, Peff, RHOB.



Gambar 3. 10. PLS zonasi 3



Gambar 3. 11. PLS zonasi 5

Pada zonasi 4 tidak dapat dilakukan PLS karena menunjukkan kekurangan data hanya 12 buah data saja dan tidak relevan untuk PLS, PLS harus mencari variansi di dalam data. Dari zonasi 5 variabel tidak multikolinearisasi adalah DRHO, RHOB, DT, ILD, Peff, Dept, SP yang ditunjukkan pada gambar 3.11.

Tabel 3. 5. Hasil kesimpulan PLS

Variabel	Satuan	Jumlah korelasi ≥ 1
RHOB	g/cc	4
DT	us/f	1
ILD	ohmm	3
NPHI	v/v	1
MSFL	ohmm	1
CALI	inch	1
DEPT	ft	3
SP	mv	2
DRHO	g/cc	1
Peff	%	4

Variabel dari masing – masing zonasi dikumpulkan dan diperingkatkan, variabel yang tidak mengalami multikolinear dan diambil kesimpulan dengan PLS ini. Hasil dari peringkat hubungan variabel input X terhadap Y yang paling berkorelasi ≥ 1 disimpulkan pada tabel 3.5. Tabel 3.5 menunjukkan untuk output Y yaitu GR maka variabel X yang berkorelasi tinggi adalah RHOB-ILD-Peff-DEPT.

Hasil analisa PCA diperoleh NPHI – ILD – Peff sebagai parameter yang tidak multikolinearisasi. Dari hasil analisa PLS untuk output GR didapat RHOB, ILD, Peff, DEPT sebagai parameter yang tidak multikolinearisasi. Dari metode PCA – PLS dapat disimpulkan bahwa variabel terpenting dalam data adalah ILD dan Peff. Peff atau porositas efektif dihitung berdasarkan GR – RHOB dan NPHI Sehingga dapat diambil kesimpulan bahwa untuk input untuk JST adalah ILD, RHOB, NPHI, GR, dan Peff.

3.2.4 Normalisasi Data Input Jaringan Syaraf Tiruan

Data log sumur dan porosity efektif merupakan input untuk jaringan syaraf tiruan. Masing – masing data tersebut mempunyai nilai maksimum dan minimum yang berbeda, oleh karena itu sebelum dimasukkan ke jaringan syaraf tiruan nilai, maka dinormalisasi terlebih dahulu. Normalisasi adalah membuat setiap input jaringan berada pada range nilai maksimum dan minimum yang sama, dalam hal ini dibuat pada range maksimum 1 dan minimum 0. Tujuan normalisasi ini untuk mempermudah proses perhitungan *error*, karena jaringan memakai fungsi aktivasi sigmoid biner yang mempunyai nilai ambang antara 1 dan 0. Sehingga output jaringan juga akan berada pada range 0 sampai 1 sesuai dengan nilai target output jaringan.

3.3 Pembentukan Model Jaringan Syaraf Tiruan Metode Levenberg – Marquardt

Pembentukan model prediksi dimaksudkan untuk menentukan parameter dari arsitektur jaringan yang akan digunakan untuk pembelajaran. Pembentukan model prediksi dilakukan dengan menggunakan Jaringan Syaraf Tiruan Levenberg – Marquardt dengan 1 (satu) lapisan tersembunyi. Jumlah variable input yang digunakan dalam penelitian ini sebanyak 5 buah variable. Jumlah *node*

untuk lapisan sama dengan jumlah *variable input*, sedangkan jumlah *node* pada lapisan *output* sama dengan jumlah kategori yang akan diklasifikasikan dan hal ini berbeda untuk setiap model prediksi. Jaringan syaraf tiruan (JST) ini memiliki lapisan *input* dari 5 unit yang merupakan hasil dari data yang telah ternormalisasi. Adapun untuk jumlah *node* pada lapisan tersembunyi (*hidden-node*), pada penelitian ini akan divariasikan untuk mendapatkan hasil yang optimal. Karena jumlah *node* pada lapisan tersembunyi berpengaruh terhadap tingkat generalisasi atau pengenalan pola. Variasi jumlah *hidden-node* yang digunakan adalah 5, 10, 15, 20, 25.

Pada tiap lapisan arsitektur JST juga ditetapkan beberapa parameter yang akan diberikan pada proses pembelajaran dan diuji untuk membentuk model prediksi, antara lain adalah fungsi aktivasi, toleransi *error*, jumlah *epoch* maksimal, laju pembelajaran (*learning rate*) dan fungsi pelatihan (*training function*). Untuk inisialisasi bobot awal digunakan inisialisasi secara *random*. Fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah *trainlm*, sedangkan pada lapisan *output* menggunakan fungsi aktivasi *pureline*. Toleransi kesalahan minimum (*error*) ditentukan pada 0.0001. Toleransi *error* yang cukup kecil diharapkan akan memberikan hasil yang cukup baik. Jumlah *epoch* maksimal yang ditetapkan dalam penelitian ini adalah 1000. Hal ini diperlukan sebagai kriteria henti jaringan disamping toleransi *error* untuk membatasi waktu yang disediakan bagi jaringan dalam melakukan pembelajaran.

Adapun parameter yang divariasikan dalam proses pembelajaran adalah laju pembelajaran (*learning rate*) dan fungsi pelatihan (*training function*). Variasi nilai laju pembelajaran yang digunakan adalah 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9. Laju pembelajaran dapat mempengaruhi konvergensi kecepatan pada proses pembelajaran, sehingga perlu dilakukan percobaan pada laju pembelajaran yang berbeda untuk mendapatkan nilai rentang data yang sesuai. Untuk lebih detail bisa dilihat pada tabel 3.6.

Tabel 3. 6 Struktur JST yang digunakan

KARAKTERISTIK	SPEKIFIKASI
Arsitektur Jaringan	Multi-layer dengan 1 lapisan tersembunyi
Algoritma Pembelajaran	Levenberg Marquardt
Jumlah Node input	5
Jumlah Node lapisan tersembunyi	5, 10, 15, 20, 25
Fungsi aktivasi lapisan tersembunyi	Sigmoid bipolar
Jumlah node lapisan output:	2
Fungsi Aktivasi lapisan output	Pureline
Toleransi Error	0.0001
Laju Pembelajaran	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
Maksimum Epoch	1000

Tabel 3. 7. Aturan Pembagian Data

Pembagian %	Data Latih %	Data Uji %
10	10	90
20	20	80
30	30	70
40	40	60
50	50	50
60	60	40
70	70	30
80	80	20
90	90	10

3.3.1 Pelatihan/ Pembelajaran (*Learning*)

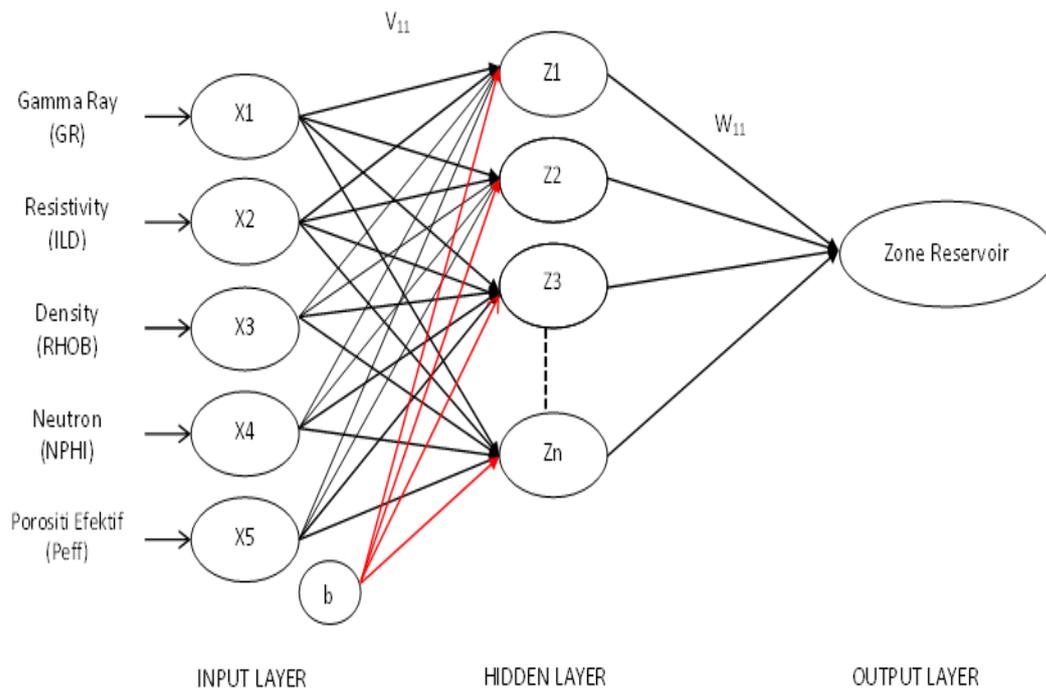
Tujuan dari pelatihan pada jaringan syaraf tiruan adalah untuk memperoleh keseimbangan sistem jaringan saat diberi masukan pola untuk dihafalkan. Sehingga system dapat mengenali pola yang sesuai dengan yang dikenali saat pelatihan jika system diberi pola lain.

Jaringan syaraf tiruan pada penelitian ini menggunakan jaringan multi lapis yang ditunjukkan pada gambar 3.4. Terdapat 3 lapis layer, yaitu :

- Lapisan masukan (*input layer*), terdiri dari 5 neuron
- Lapisan tersembunyi (*hidden layer*), terdiri dari 5-10-15-20-25 neuron
- Lapisan keluaran (*Output layer*), terdiri dari 1 unit neuron.

Metode pelatihan / pembelajaran yang digunakan *supervised learning*. Dengan tujuan untuk menentukan nilai bobot koneksi di dalam jaringan, sehingga jaringan dapat memprediksi dari input ke output sesuai dengan yang diinginkan.

Dalam memprediksi ditentukan melalui satu set pola uji atau data pelatihan (*training data set*). Setiap pasangan pola p terdiri dari vektor input x_{in} dan vektor target t_k . Setelah selesai *learning* jika diberikan masukan x_{in} seharusnya jaringan mempunyai hasil nilai output t_k . Besarnya perbedaan antara nilai target dengan output aktual diukur dengan *error*. Fungsi error yang digunakan pada sistem adalah *Mean Absolute Percentage Error* (MAPE).



Gambar 3. 12. Arsitektur Jaringan Syaraf Tiruan Levenberg Marquardt

Pada arsitektur jaringan ini, keluaran diharapkan mengeluarkan output sebagai prospek keberadaan zone reservoir. Semakin banyak data *learning* maka kemampuan jaringan dalam mengingat semakin baik, akan tetapi membuat proses *learning* menjadi lambat. Proses *learning* jaringan dengan Algoritma *Levenberg – Marquardt* dijelaskan gambar 3.5. Gambar 3.5 adalah proses *flow diagram* perbaikan bobot jaringan, sehingga dihasilkan bobot yang terbaik untuk bisa mengingat pola yang sudah di *learning*.

Prosedur yang dilaksanakan pada penelitian ini adalah sebagai berikut:

1. Pelatihan /Pembelajaran (*learning*) jaringan.

a. Langkah 1

Masukan yang digunakan adalah data log sumur yang digunakan.

b. Langkah 2

Set nilai awal bobot secara random untuk kelima buah bobot yang dipergunakan, yaitu untuk bobot antara *input layer* dengan *hidden layer* (v) dan bobot antara *hidden layer* dengan *output layer* (w).

c. Langkah 3

Menghitung fungsi jaringan secara maju (*feed forward*)

- Setiap *node hidden* (z_j , dimana $j=1, \dots, p$) menjumlahkan sinyal *input* terbobotnya sebaga berikut :

$$z_{nj} = (x_i * v_{ij}) + v_{0j} \quad (3.1)$$

z_{nj} = Sinyal input untuk *hidden node* ke-j

x_i = Nilai pada *input node* ke-i

v_{ij} = Nilai bobot yang menghubungkan *input node* ke-i dengan *hidden node* ke-j.

v_{0j} = Nilai bobot yang menghubungkan *node bias* dengan *hidden node* ke-j.

- Menentukan nilai *hidden node* ke-j dengan menggunakan fungsi aktivasi *sigmoid unipolar*.

$$z_j = f(z_{ij}) = \frac{2}{1 + \exp(-z_{ij})} - 1 \quad (3.2)$$

z_j = Nilai *hidden node* ke-j

- Setiap *node output* (y_k , dimana $k=1, \dots, m$) menjumlahkan sinyal *hidden* terbobotnya sebagai berikut:

$$y_{ik} = (z_j * w_{jk}) + w_{0k} \quad (3.3)$$

y_{ik} = Sinyal *input* untuk *output node* ke-k

z_j = Nilai *hidden node* ke-j

w_{jk} = Nilai bobot yang menghubungkan *hidden node* ke-j dengan *output node* ke-k

w_{0k} = Nilai bobot yang menghubungkan *node bias* dengan *output node* ke-k

p = jumlah *hidden node*

- Menentukan nilai output node ke-j dengan menggunakan fungsi aktivasi *sigmoid*

$$y_k = f(y_{ik}) = \frac{2}{1 + \exp(-y_{ik})} - 1 \quad (3.4)$$

y_k = Nilai *output node* ke-k

d. Langkah 4

Setelah dilakukan perhitungan maju, maka setiap output (y_k) dibandingkan dengan target ($t_k - y$) akan menghasilkan suatu nilai *error*. Jumlah rata – rata *error* ini dapat dihitung dengan persamaan (2.36).

e. Langkah 5

Hitung matrik Jacobian. Matriks Jacobi (J) merupakan turunan pertama dari *error* terhadap bobot dan turunan pertama terhadap bias. Matriks Jacobi antara

input node dan *hidden layer* adalah matrik yang terisi turunan *error* terhadap bobot antara *input node* dan *hidden layer* beserta biasnya.

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial v_{(1,1)}} & \frac{\partial e_1}{\partial v_{(1,2)}} & \dots & \frac{\partial e_1}{\partial v_{(1,j)}} \\ \frac{\partial e_1}{\partial v_{(2,1)}} & \frac{\partial e_1}{\partial v_{(2,2)}} & \dots & \frac{\partial e_1}{\partial v_{(2,j)}} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_1}{\partial v_{(i,1)}} & \frac{\partial e_1}{\partial v_{(i,2)}} & & \frac{\partial e_1}{\partial v_{(i,j)}} \end{bmatrix} \quad (3.5)$$

Matriks Jacobi antara *hidden node* dengan *input node* adalah matrik yang berisi turunan *error* pertama terhadap bobot antara *hidden node* dengan *output node*.

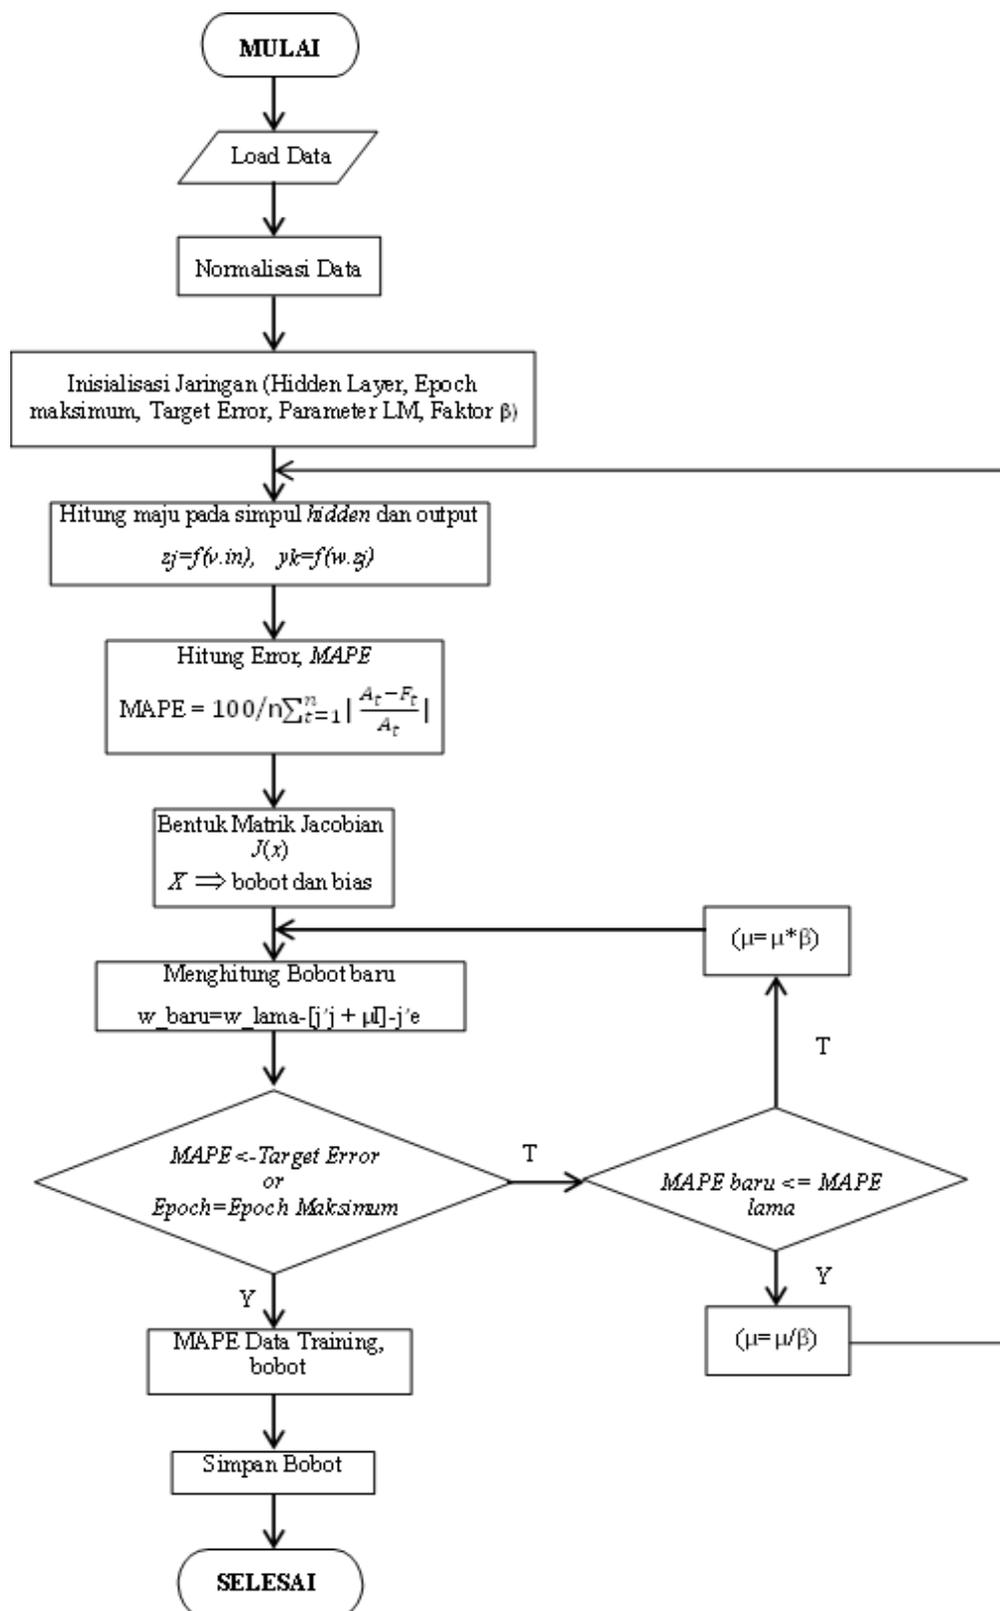
$$J = \begin{bmatrix} \frac{\partial e_1}{\partial v_{(1,1)}} & \frac{\partial e_1}{\partial v_{(1,2)}} & \dots & \frac{\partial e_1}{\partial v_{(1,k)}} \\ \frac{\partial e_1}{\partial v_{(2,1)}} & \frac{\partial e_1}{\partial v_{(2,2)}} & \dots & \frac{\partial e_1}{\partial v_{(2,k)}} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_1}{\partial v_{(j,1)}} & \frac{\partial e_1}{\partial v_{(j,2)}} & & \frac{\partial e_1}{\partial v_{(j,k)}} \end{bmatrix} \quad (3.6)$$

Elemen matriks Jacobi ini dapat dihitung dengan menggunakan aturan rantai dari persamaan (2.20), (2.21), (2.22)

f. Langkah 6

Hitung ΔX (Delta bobot) untuk semua bobot dan bias menggunakan persamaan

$$\Delta X = [J^T J + \mu I]^{-1} \cdot J^T e \quad (3.7)$$



Gambar 3. 13. Flowchart pelatihan JST Levenberg Marquardt

Langkah – langkah dalam perhitungan ΔX adalah,

- Menghitung pendekatan matrik Hessian yaitu dengan mengalikan matrik Jacobi dengan matrik transposnya, $[J^T J]$.
- Menghitung matrik dari hasil penjumlahan matrik Hessian dengan sebuah matrik identitas yang telah dikalikan dengan konstanta $\mu = [J^T J + \mu I]$
 μ = faktor pengali (konstanta *learning*) yang sudah diset oleh user pada saat awal, merupakan konstanta untuk mempercepat proses *learning*.
 I = matrik identitas
- Menghitung invers matrik dari hasil penjumlahan matrik Hessian dengan sebuah matrik identitas $[J^T J + \mu I]^{-1}$.
- Menghitung *gradient* dari *error* pada mesin – masing *node* dengan $J^T e$.
 e adalah vektor yang menyatakan semua *error* pada *output* jaringan
 $e = [t_1 - y_1 \ t_2 - y_2 \ \dots \ t_p - y_p]^T$. Hitung delta bobot yaitu selisih bobot lama dengan bobot sekarang dengan persamaan $\Delta X = [J^T J + \mu I]^{-1} \cdot J^T e$.
Setelah didapat selisih masing – masing pembobot, maka dilakukan pembaharuan (*update*) untuk masing – masing pembobot tersebut. Dengan persamaan,

$$X_{(new)} = X_{(old)} + \Delta X \quad (3.8)$$

Setelah didapat bobot baru dihitung kembali *error* menggunakan persamaan (3.4) jika *error* baru ini berkurang lakukan (μ / β) , dan kembali ke langkah dua sampai langkah ke 7. Jika *error* baru ini tidak berkurang maka lakukan $(\mu x \beta)$ dan kembali ke langkah 5. Lakukan terus sampai *error* sama dengan *error* limit. Setelah *error* limit ini tercapai simpan bobot dan bias yang terakhir dalam sebuah *file*.

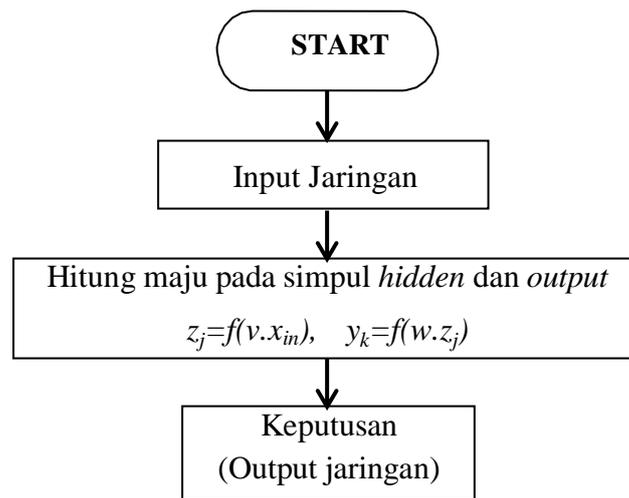
Selama proses pelatihan dilakukan pula proses validasi untuk menguji apakah jaringan sudah memiliki kemampuan yang baik dalam mengenal data baru yang diberikan kepadanya, yang ditunjukkan dengan nilai *Mean Absolute Percentage Error* (MAPE). Pembelajaran model JST levenberg – marquardt

bersifat *iterative* dan diseain untuk meminimalkan MAPE antara *output* yang dihasilkan dan output yang diinginkan (*target*).

Sebelum proses pelatihan terlebih dahulu ditentukan bobot – bobot awal secara random dan toleransi kesalahan minimum. Bobot – bobot awal ini nantinya akan diinisialisasi dan digunakan pada proses umpan maju awal, sedangkan proses umpan maju selanjutnya menggunakan bobot – bobot yang telah mengalami perbaikan. Toleransi kesalahan minimum berfungsi sebagai pembatas berulangnya proses iterasi dalam suatu pelatihan. Proses pelatihan akan terus berulang hingga diperoleh koreksi kesalahan yang sama atau lebih kecil dari toleransi kesalahan minimum.

3.3.2 Pengujian (*Testing*)

Proses pengujian (*testing*) yang dilakukan dipergunakan sebagai langkah pengenalan pola data log sumur yang dipergunakan sebagai *input* terhadap jaringan yang telah mengenal proses *learning*.



Gambar 3. 14. Diagram Alir Proses Prediksi

Pada tahap ini jaringan hanya merespon masukan dan langsung mengeluarkan *output*, tanpa pembelajaran kembali. Proses yang dilakukan hanya proses penghitungan maju (*feed forward*) dengan menggunakan bobot yang sudah tersimpan pada saat pelatihan, maka setiap pola input dilewatkan ke jaring untuk

mendapatkan output jaring. Proses prediksi ini dapat dilihat dari diagram alir pada gambar 3.14.

3.4 Evaluasi Hasil Uji

Hasil dari yang diperoleh pada pembelajaran, kemudian dilanjutkan pada tahap pengujian dengan data uji. Tahap prediksi dilakukan perbandingan dengan perolehan hasil *true positive*, *false positive*, *true negative*, dan *false negative*. ROC dapat digunakan sebagai grafik perbandingan antara *True Positive Rate* (TPR) pada sumbu vertical dengan *False Positive Rate* (FPR) pada sumbu horintal. TPR merupakan proporsi data positif teridentifikasi dengan benar antara data *predicted class* dengan *actual class*. Sedangkan FPR merupakan proporsi data negatif teridentifikasi salah sebagai positif pada suatu model klasifikasi[16]. Dari keempat nilai tersebut membentuk sebuah matrik yang disebut *confussion matrix*.

Halaman ini sengaja dikosongkan

BAB 4

HASIL DAN PEMBAHASAN

4.1 Praproses data

Pada bab ini, dilakukan praproses data, yaitu pembersihan data dengan tujuan untuk menghilangkan *noise* dikarenakan data tidak lengkap dan adanya data yang hilang, dengan cara statistik menggantinya dengan nilai yang paling sering muncul. Kemudian analisa relevansi untuk menghilangkan atribut yang redundant dan tidak relevan dengan penelitian. Yang terakhir adalah transformasi data, pada penelitian ini adalah bersifat kategorikal untuk data target menggunakan metode *Unary Encoding*, dimana data target dipresentasikan dengan kombinasi angka 0 dan 1 (*numerical binary variable*).

Perhitungan porositas efektif dalam reservoir minyak menggambarkan persentase dari total ruang yang tersedia untuk ditempati oleh suatu cairan atau gas dan saling terhubung ruang satu dengan yang lainnya sehingga mempermudah untuk eksplorasi fluida didalamnya. Porositas dapat didefinisikan sebagai perbandingan antara volume total pori-pori batuan dengan volume total batuan per satuan volume tertentu. Karakteristik nilai porositas efektif ditunjukkan pada tabel 2.3. Dari hasil perhitungan dapat diamati bahwa nilai porositas selalu berbanding terbalik dengan besarnya nilai volume shale atau volume lempung dikarenakan batuan shale yang pejal tidak memiliki rongga sehingga tidak dapat menampung fluida maka semakin besar nilai volume shale pada suatu lapisan porous maka semakin kecil pula nilai porositasnya begitupula sebaliknya.

4.2 Pembentukan Model Jaringan Syaraf Tiruan Metode Levenberg – Marquardt

Pada prediksi ini berdasarkan klasifikasi kelas. Data pelatihan untuk menentukan kelas berdasarkan log image sumur tes, log image berisi gambaran reservoir per kedalaman dan didapat dari hasil pengukuran well logging. Pada penelitian ini terbagi menjadi 2 kelas yaitu kelas 1 untuk zona reservoir dan kelas 0 untuk non zona reservoir.

Pengujian jaringan syaraf tiruan meliputi penguji proses learning, dimulai dengan cara pembuatan data set learning dan melakukan learning dengan data set yang sudah terbentuk. Kemudian proses pengujian yaitu menguji jaringan yang sudah dilearning dengan data uji.

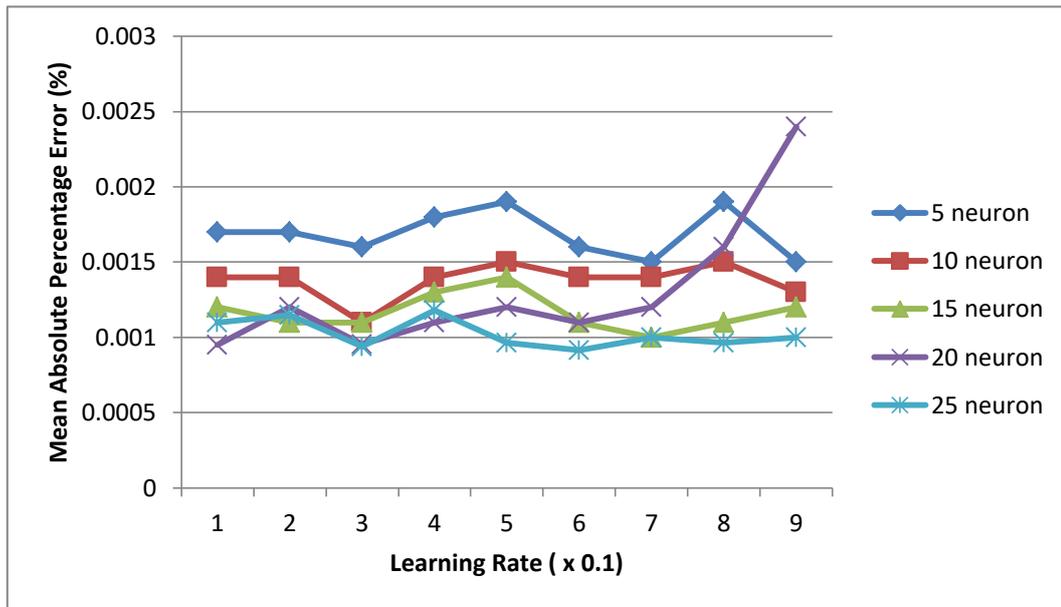
4.2.1 Hasil Proses Pelatihan

Sebelum dilakukan proses pengenalan, jaringan harus dilakukan proses learning terlebih dahulu. Pada tahap pelatihan terjadi pengaturan besar beban (*weight*) dalam jaringan syaraf tiruan. Untuk melakukan proses *learning* perlu satu set data *learning*, oleh sebab itu dibuat set data *learning* terlebih dahulu. Sesuai dengan arsitektur jaringan syaraf tiruan yang telah dibuat, maka set data *learning* ini mengikuti format jaringan. Tahapan pembuatan set data *learning* ini adalah mengikuti alur perolehan data dari PUSDATIN ESDM sebanyak 5 sumur minyak dan diambil datanya sepanjang 6985, setelah itu dilakukan praproses.

Pada pelatihan levenberg marquardt ini setelah melakukan aturan pembagian data, maka diperoleh 70 % data *training* dan 30 % data *testing*. Untuk mengetahui baik atau tidaknya pelatihan dilihat dari nilai atau regresi antara output dan target serta nilai *mean absolute percentage error* (MAPE) yang dihasilkan.

Tabel 4. 1. Hasil Pelatihan dengan Perubahan *Learning Rate*

Learning Rate	<u>Hidden Node</u>				
	5	10	15	20	25
0.1	0.0017	0.0014	0.0012	9.51E-04	0.0011
0.2	0.0017	0.0014	0.0011	0.0012	0.00115
0.3	0.0016	0.0011	0.0011	9.55E-04	0.00094
0.4	0.0018	0.0014	0.0013	0.0011	0.00118
0.5	0.0019	0.0015	0.0014	0.0012	0.000965
0.6	0.0016	0.0014	0.0011	0.0011	0.000915
0.7	0.0015	0.0014	0.001	0.0012	0.001
0.8	0.0019	0.0015	0.0011	0.0016	0.000964
0.9	0.0015	0.0013	0.0012	0.0024	0.001



Gambar 4. 1. Hasil pelatihan JST Levenberg Marquardt

Dari hasil percobaan dengan menggunakan fungsi pelatihan levenberg-marquardt diperoleh bahwa nilai MAPE terkecil adalah 0.000915, berada pada laju pembelajaran 0.6 dengan jumlah *hidden-node* 25. Sedangkan nilai MAPE terbesar adalah 0.0024 berada pada laju pembelajaran 0.9 dengan jumlah *hidden-node* 20. Hal ini ditunjukkan pada tabel 4.1 dan pada gambar 4.1.

4.2.2. Analisa Hasil Proses Pelatihan

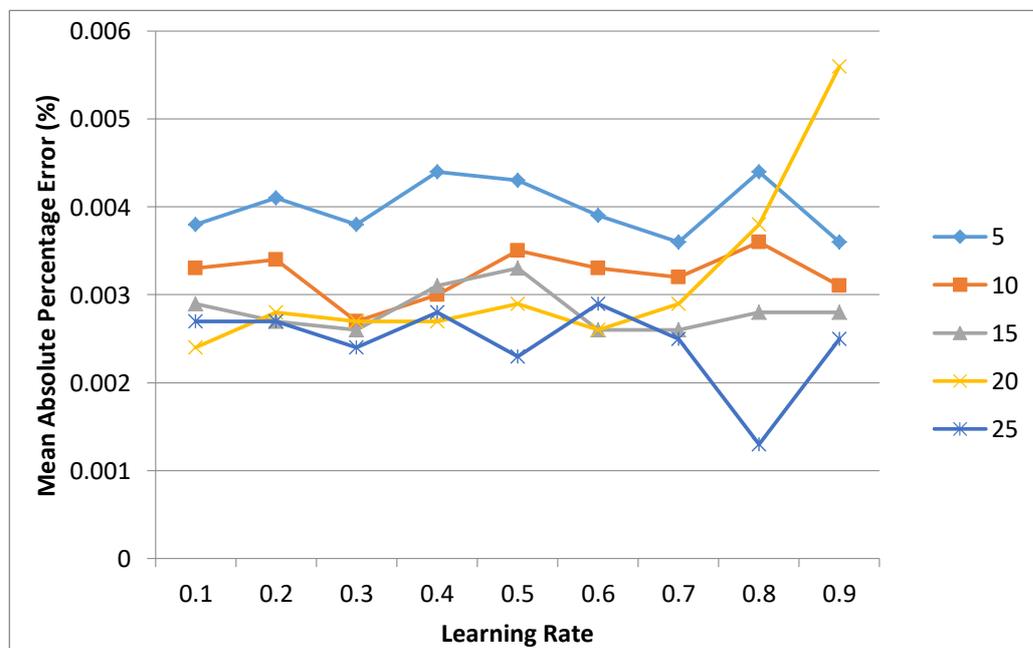
Pada tabel 4.1 merupakan hasil dari pelatihan jaringan syaraf tiruan dengan metode levenberg – marquardt dengan perubahan *learning rate*. Proses pelatihan (*learning*) ini menggunakan konfigurasi jaringan 5 *input*, 1 *hidden layer* dan *output layer*. *Learning rate* dimulai dengan 0.1 sampai dengan 0.9 dan perubahan neuron 5-10-15-20-25 pada *hidden layer*. Pembelajaran dilakukan sebanyak 1000 *epoch* dengan *limit error* 0.00001. Pada gambar 4.9 menunjukkan bahwa pada saat pelatihan dengan *hidden layer* neuron 25 *learning rate* 0.6 mengalami *error mean absolute percentage error* (MAPE) sebesar 9.152×10^{-4} % dengan regresi 0.93378. Proses *learning* dilakukan dengan membandingkan pasangan output jaringan dengan vektor target. Selisih dari keduanya merupakan *error* yang akan digunakan untuk memperbaiki bobot sambungan.

4.2.3. Hasil Proses Pengujian

Tahap terakhir dari pembuatan sistem ini adalah tahap pengujian. Proses pengujian dapat dilakukan setelah jaringan di-*learning* sampai mencapai konvergen, yang berarti *error* telah mencapai nilai yang ditetapkan. Pada pengujian ini, konfigurasi jaringan yang digunakan adalah 5-25-1 dengan *error limit* 0.0001 sedangkan *learning rate* 0.6.

Tabel 4. 2. Hasil Pengujian dengan Perubahan *Learning Rate*

Learning Rate	<u>Hidden Node</u>				
	5	10	15	20	25
0.1	0.0038	0.0033	0.0029	0.0024	0.0027
0.2	0.0041	0.0034	0.0027	0.0028	0.0027
0.3	0.0038	0.0027	0.0026	0.0027	0.0024
0.4	0.0044	0.003	0.0031	0.0027	0.0028
0.5	0.0043	0.0035	0.0033	0.0029	0.0023
0.6	0.0039	0.0033	0.0026	0.0026	0.0029
0.7	0.0036	0.0032	0.0026	0.0029	0.0025
0.8	0.0044	0.0036	0.0028	0.0038	0.0013
0.9	0.0036	0.0031	0.0028	0.0056	0.0025



Gambar 4. 2 Hasil Pengujian JST Levenberg Marquardt

4.2.4. Analisa Hasil Pengujian

Pada percobaan proses pengujian diperoleh bahwa nilai MAPE terkecil adalah 0.0013, berada pada laju pembelajaran 0.8 dengan jumlah hidden-node 25. Sedangkan nilai MAPE terbesar adalah 0.0056 berada pada laju pembelajaran 0.9 dengan jumlah hidden-node 20. Hal ini ditunjukkan pada tabel 4.2 dan pada gambar 4.2.

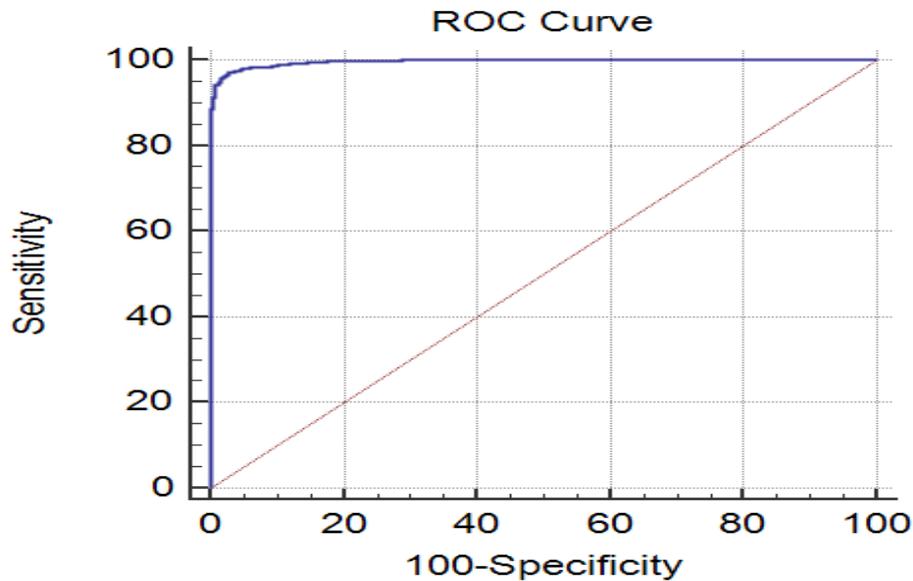
Pengujian dilakukan dengan data log sumur yang tidak di-learning sama sekali. Hasil uji didapatkan zona reservoir secara keseluruhan, artinya zona reservoir yang didapat berporositas baik sampai buruk dan zona reservoir yang permeabel ataupun tidak. Hal ini dikarenakan data latih yang didapatkan dari log image merupakan zona reservoir secara keseluruhan.

4.3. Evaluasi dan Validasi

Kurva ROC pada penelitian ini digunakan sebagai grafik perbandingan antara True Positive Rate (TPR) pada sumbu vertical dengan False Positive Rate (FPR) pada sumbu horintal. TPR merupakan proporsi data positif teridentifikasi dengan benar antara data predicted class dengan actual class. Sedangkan FPR merupakan proporsi data negatif teridentifikasi salah sebagai positif pada suatu model klasifikasi[17].

ROC terdapat luasan area di bawah kurva yang dikenal dengan AUC (*Area Under Curve of ROC*). Nilai AUC berkisaran antara 0 sampai dengan 1, semakin mendekati nilai 1 maka semakin baik nilai uji pada karakteristik prediksi tersebut. Hasil penelitian pencarian nilai ROC untuk prediksi dapat dilihat pada gambar 4.11. Dengan hasil penelitian menunjukkan *Area Under Curve ROC (Receiver Operating Curve)* sebesar 0.966, sehingga dapat disimpulkan bahwa kinerja sistem prediksi menunjukkan "excellent". Dalam prediksi dari sebuah sistem diharapkan dapat melakukan pembedaan semua set data dengan benar. Pada dasarnya, kinerja suatu sistem prediksi tidak dapat bekerja secara 100% benar, akan tetapi kinerja suatu sistem tersebut dapat diukur. Dalam mengukur kinerja sistem prediksi dapat menggunakan *confussion matix*.

Berikut tabel *confussion matrix* yang digunakan dalam penelitian ini, dapat dilihat pada tabel 4.3.



Gambar 4. 3 ROC pada hasil penelitian

Tabel 4. 3 Confussion Matrix Penelitian

		Predicted Class	
		Zona Reservoir	Non Zona Reservoir
Actual Class	Zona Reservoir	TP_A	e_AB
	Non Zona Reservoir	e_BA	TP_B

Pada setiap kelas dalam matrix menyatakan jumlah data dari *actual class* yang hasil prediksi masuk ke dalam *predicted class*. Misalkan saja TP_A adalah jumlah data kelas zona reservoir yang secara benar dipetakan ke dalam kelas zona reservoir. Sedangkan pada e_AB adalah jumlah data pada kelas zona reservoir yang dipetakan secara salah ke kelas non zona reservoir. Berdasarkan *confussion matrix* di atas, maka data yang diprediksi dengan benar adalah TP_A dan TP_B. Sedangkan data yang diprediksi dengan salah adalah e_AB dan e_BA.

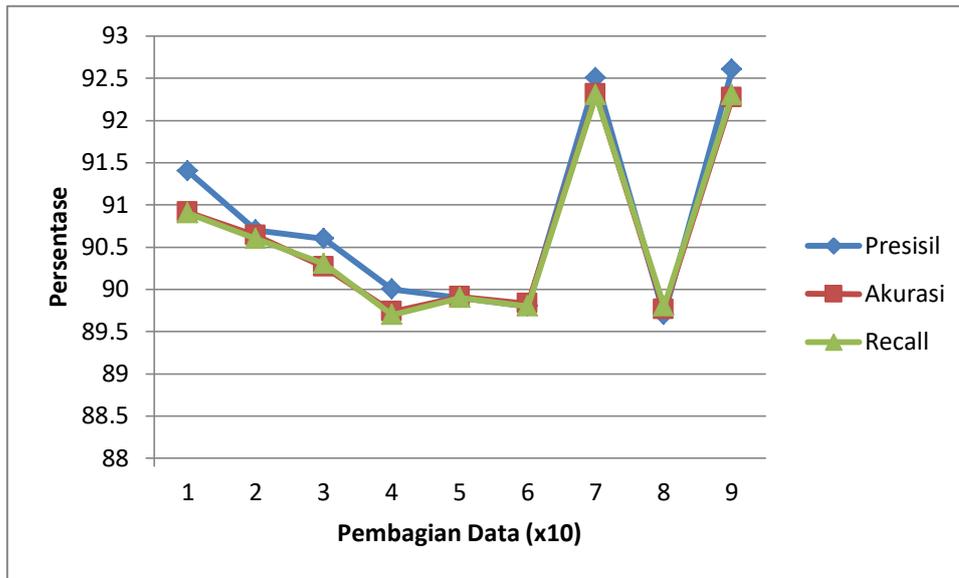
Hasil uji didapatkan zona reservoir secara keseluruhan, artinya zona reservoir yang didapat berporositas baik sampai buruk dan zona reservoir yang permeabel ataupun tidak. Hal ini dikarenakan data latih yang didapatkan dari log image merupakan zona reservoir secara keseluruhan.

Berdasarkan hasil penelitian yang dilakukan terhadap semua input data dengan perbandingan data training dan data test sebesar 70%:30%, diperoleh hasil uji

- TP_A = Zona Reservoir terindikasi benar sebagai Zona Reservoir sejumlah 3742 data
- TP_B = Non Zona Reservoir terindikasi benar sebagai Zona Reservoir sejumlah 3042 data
- e_BA = Non Zona Reservoir terindikasi salah sebagai Zona Reservoir sejumlah 99 data
- e_AB = Zona Reservoir terindikasi salah sebagai Non Zona Reservoir sejumlah 101 data

Validasi didapatkan dari log image sumur tes dan expert pooling validation adalah metode untuk membuktikan bahwa hasil perhitungan, metode, dan input telah sesuai dengan kaidah yang berlaku. Kemudian dihitung banyaknya kesamaan data yang tepat antara validasi dan prediksi, dikarenakan hanya ada dua kelas yaitu 1 dan 0 maka kesamaan data yang dimaksud adalah jika pada kedalaman yang sama hasil validasi kelas 1 dan hasil prediksi kelas 1 juga, begitu pula untuk kelas 0. Jika data hasil validasi dan hasil prediksi pada kedalaman yang sama menunjukkan kelas yang berbeda maka prediksi tidak tepat. Hal ini bertujuan untuk mengetahui ketepatan model dalam memprediksi.

Sehingga diperoleh hasil prediksi dari percobaan yang menunjukkan nilai akurasi, recall, dan presisi dengan pembagian data. bahwa nilai rata – rata akurasi, recall dan presisi terbaik dihasilkan oleh training 70% dan testing 30% dengan nilai 90.9163 %, 90.9%, dan 91.4% yang ditunjukkan pada gambar 4.4.

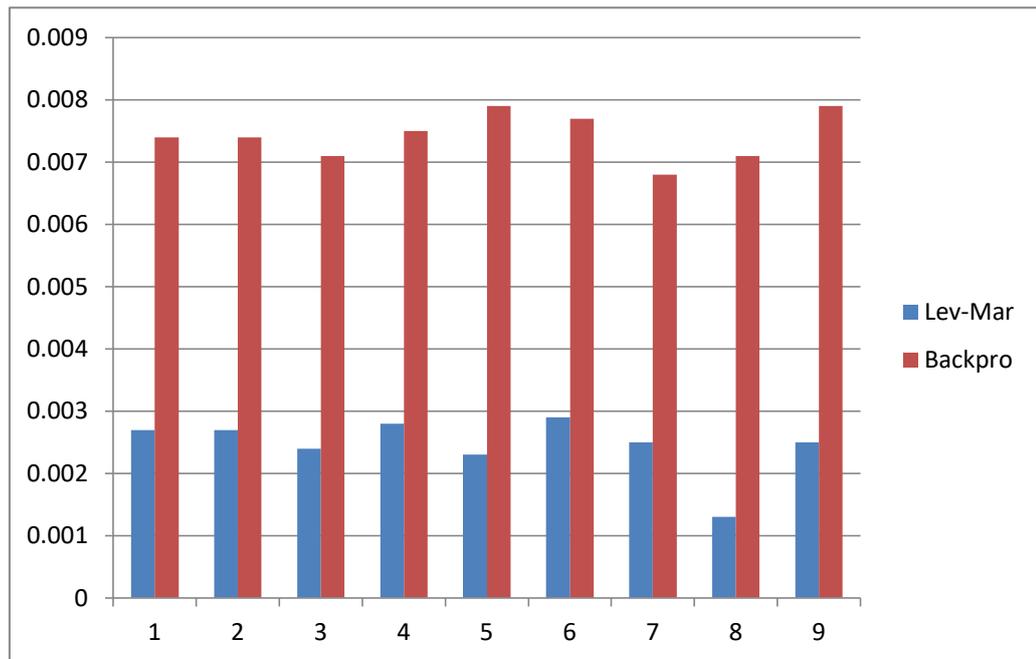


Gambar 4. 4. Chart presisi, akurasi, dan recall untuk pembagian data

4.4. Pengujian dengan Jaringan Syaraf Tiruan *Backpropagation*.

Pada bab sebelumnya telah dijelaskan bahwa metode Levenberg – Marquardt merupakan pengembangan / modifikasi dari metode Backpropagation. Sebagai perbandingan perlu dicoba pengujian dengan metode backpropagation. Secara umum tahap – tahap yang dilakukan pada sistem prediksi dengan JST Backpropagation ini juga sama dengan algoritma Levenberg – Marquardt. Alur atau prosedur program yang dibuat juga sama, kecuali pada proses learning dan mapping. Oleh sebab itu pengujian yang ditunjukkan adalah pada hasil pengenalan (prediksi). Jaringan di-*learning* dengan konfigurasi yang sama, yaitu 5 – 25 – 1 dan error limit 0.0001.

Pada gambar 4.5 merupakan hasil perbandingan antara metode levenberg – marquardt dengan backpropagation. Dari gambar menunjukkan bahwa *error* dari levenberg - marquardt menghasilkan *error* yang kecil dibanding backpropagation. Hal ini menunjukkan bahwa algoritma pelatihan levenberg-marquardt lebih baik dibandingkan dengan algoritma pelatihan backpropagation.



Gambar 4. 5 Grafik Perbandingan antara Levenberg Marquardt dengan Backpropagation

Setelah divalidasi posisi prediksi zona reservoir maka dianalisa zona reservoir yang berpotensi. Porositas dapat didefinisikan sebagai perbandingan antara volume total pori-pori batuan dengan volume total batuan per satuan volume tertentu. Permeabilitas didefinisikan sebagai ukuran media berpori untuk meloloskan/melewatkan fluida. Apabila media berporinya tidak saling berhubungan maka batuan tersebut tidak mempunyai permeabilitas dengan kata lain porositas tinggi tidak menunjukkan bahwa permeabilitas akan baik. Permeabilitas menunjukkan kemampuan batuan tersebut dapat menjadi reservoir produksi. Permeabilitas ditentukan salah satunya menggunakan nilai GR maksimal 60 API untuk lapisan permeabel dan lapisan non-permeabel lebih dari itu. Porositas lapisan ditentukan nilai Peff dengan nilai pada tabel 2.3 sementara untuk lapisan yang cocok dijadikan reservoir produksi adalah lapisan yang berporositas tinggi dan permeabel baik. Oleh karena itu dengan hasil uji dapat dikelompokkan zona reservoir yang cocok untuk reservoir produksi pada tabel 4.3..

Tabel 4. 4 Hasil zona reservoir sumur tes

Kedalaman (ft)	Tebal lapisan (ft)	Tebal lapisan (m)
7724	1	0.3
7726-7730	4	1.22
7732 – 7747	15	4.57

Dimensi dari ketebalannya zona reservoir, dikarenakan tidak ada data luasan maka volume batuan tidak dapat diketahui dan hasil tersebut dari sisi penampang lintang lapisan.

BAB 5

KESIMPULAN DAN SARAN

5.1 KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan dapat disimpulkan bahwa Jaringan Syaraf Tiruan (JST) levenberg – marquardt yang sudah dilatih dengan data yang ada dapat digunakan untuk memprediksi keberadaan reservoir.

Dari hasil penelitian diperoleh kesimpulan :

1. Pengaruh terbesar dalam variable input JST adalah ILD, RHOB, NPFI, GR, Peff, DEPTH setelah melalui PCA dan PLS.
2. Bahwa prediksi zona reservoir dengan menggunakan metode Levenbrg Marquardt menghasilkan nilai akurasi, recall, dan presisi dengan pembagian data bahwa nilai rata – rata akurasi, recall dan presisi terbaik dihasilkan oleh training 70% dan testing 30% dengan nilai 90.91%, 90.9%, dan 91.4% , dengan kesalahan *mean absolute percentage error* (MAPE) sebesar 0.0024%.
3. Dari hasil sebanyak 10 kali percobaan untuk mengukur akurasi dan *recall* model levenberg marquardt menghasilkan dataset sebagai zona reservoir yang sebenarnya sebesar 3742 data dan non reservoir sebesar 3042 data.
4. Prediksi pada sumur tes, menghasilkan zona reservoir mulai kedalaman 7724 ft sampai 7747 ft sehingga prediksi zona reservoir pada sumur tes 20 ft atau 6.09 meter.
5. Pengujian hasil validasi berdasarkan grafik ROC dengan nilai *Area Under ROC* menunjukkan 0.96. Oleh sebab itu, hasil tersebut dapat dikatakan bahwa unjuk kerja nilai *Area Under ROC* menunjukkan ‘*Excellent*’.

5.2 SARAN

Pada penelitian selanjutnya diharapkan dapat mengembangkan dengan menambah jumlah data sumur yang sama lokasi dan mencoba untuk perhitungan keekonomisan dari zona reservoir tersebut. Sehingga hasilnya dapat diterapkan yaitu untuk *decision support system* pada eksplorasi minyak.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- [1] W. Hamilton, "Tectonics of the Indonesian Region," Washington: U.S. Government Printing Office, 1979.
- [2] A. Harsono, *interpretasi logging analisa kualitatif dan kuantitatif*. Yogyakarta: andi publisher, 2001.
- [3] D. V. Ellis and J. M. Singer, *Well Logging for Earth Scientists*. Springer, 2007.
- [4] "Petroleum System." <http://www.geologyin.com/2014/08/petroleum-system.html>, diakses Nopember-2016.
- [5] G. B. Asquith and C. R. Gibson, *Basic Well Log Analysis for Geologists*. Oklahoma, USA: The American Association of Petroleum Geologists, 1982.
- [6] M. Rider, *The Geological Interpretation of Well Logs*, 2nd ed. Interprint Ltd, Malta, 1996.
- [7] J. Milsom, *Field Geophysics*, 3rd ed. West Sussex: John Wiley & Sons, Inc, 2003.
- [8] W. Lowrie, *Fundamental of Geophysics*, Second. New York: Cambridge University Press, 2007.
- [9] G. Vining, *Introduction to Linear Regression Analysis*. New Jersey: John Wiley & Sons, Inc, 2012.
- [10] A. Grag and T. K, "Comparison of regression analysis, Artificial Neural Network and genetic programming in Handling the multicollinearity problem," in *Proceedings of 2012 International Conference on Modelling, Identification and Control*, Wuhan, China, 2012.
- [11] F. Laurene, *Fundamentals Of Neural Networks*. Prentice-Hall International, Inc. New Jersey, USA, 1994.

- [12] M. Hery Purnomo and A. Kurniawan, *Supervised Neural Network dan Aplikasinya*. Graha Ilmu, 2006.
- [13] N. Mohd, A. Khan, and M. Z. Rehman, "CSLM: Levenberg Marquardt Based Back Propagation Algorithm Optimized with Cuckoo Search," *ITB*, vol. Vol.7, No.2, pp. 103–116, 2013.
- [14] C. H.D, S. Juan, and J. Wen, "Automated breast cancer detection and classification using ultrasound images: A survey," *Pattern Recognit.* 431299-317, Jan. 2010.
- [15] H. . Cheng, "Automated breast cancer detection and classification using ultrasound images A survey," *Pattern Recognit.*, vol. 27, pp. 299–317, 2010.
- [16] T. Fawcett, "An Introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, pp. 861–874, 2006.
- [17] A. Kumar Mohanty, S. Beberta, and S. Kumar Lenka, "Classifying Benign and Malignant Mass using GLCM and GLRLM based Texture Features from Mammogram," *Int. J. Eng. Res. Appl. IJERA*, vol. Vol. 1, Issue 3, pp. 687–693.
- [18] A. Satyana, "A 'Terra Incognita' in Petroleum Exploration: New Consideration on The Tectonic Evaluation adn Petroleum Implication," *Proceeding IPA 31st Ann Indones.*, 2007.
- [19] Irawan Deni, Utama Widya, "Analisis Data Well Log (Porositas, Saturasi Air, dan Permeabilitas) untuk menentukan Zona Hidrokarbon, Studi Kasus: Lapangan "ITS" Daerah Cekungan Jawa Barat Utara," *Jurnal Fisika dan Aplikasinya*, Vol. 5, Januari 2006.
- [20] J. Hou, T. Takahashi, A. Katoh, S. Jaroonsitha, P. Chumsena. "Application of seismic attributes and neural network for sand probability prediction — A case study in the North Malay Basin," *Geopersia*, Vol.2, 2015.

- [21] Khadim.FS, Samsuri Ariffin, Al-Dunainawi Yousif, “ANN-Based Prediction of Cementation Faktor in Carbonate Reservoir,” SAI Intelligent Systems Conference 2015, London, UK, November 10-11, 2015.
- [22] Cahaya Rosyidan, Listiana Satiawati, Bayu Satiyawira. “Analisa Fisika minyak (Petrophysics) Dari Data Log Konvensional Untuk Menghitung Sw Berbagai Metode,” Seminar Nasional Fisika (E-Journal),<http://snf-unj.ac.id/kumpulan-prosiding/snf2015>, Vol. IV, Oktober 2015.
- [23] M. P. Muhrami, Makhranii, S. Aswad. “Interpretasi Petrofisika Sumur Log Untuk Menentukan Zona Hidrokarbon Sumur ‘R’ Cekungan Sumatera Selatan,” Jurnal Ecosolum, Vol.3 No.3, Sep-Des 2014.

Halaman ini sengaja dikosongkan

BIOGRAFI PENULIS



Erna Utami, mahasiswa program pascasarjana Magister Teknik di Institut Teknologi Sepuluh Nopember , Fakultas Teknologi Elektro, Bidang Keahlian Telematika – CIO. Merupakan salah satu penerima beasiswa Kementerian KOMINFO dan Kementerian ESDM yang bekerja di Sekolah Tinggi Energi dan Mineral. Lahir di Blora, pada tanggal 21 Mei 1982. Anak ke 3 dari 3 bersaudara. Menempuh pendidikan Diploma 3 di Teknik Fisika

ITS program studi Teknik Instrumentasi pada tahun 2002-2005. Melanjutkan studi Diploma 4 di Akademi Minyak dan Gas Bumi program studi Teknik Instrumentasi dan Elektronika pada tahun 2012 – 2013.

Penulis dapat dihubungi pada email : r_nung@yahoo.com