



UNIVERSITAS INDONESIA

**WAVELET TRANSFORM UNTUK MENINGKATKAN
KEMAMPUAN ESTIMASI DATA LOG PADA JARINGAN
BACKPROPAGATION**

THESIS

MUHAMMAD HAIKAL S.

0906576574

**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
PROGRAM PASCA SARJANA FISIKA
JAKARTA
JUNI 2011**



UNIVERSITAS INDONESIA

**WAVELET TRANSFORM UNTUK MENINGKATKAN
KEMAMPUAN ESTIMASI DATA LOG PADA JARINGAN
BACKPROPAGATION**

THESIS

Diajukan sebagai salah satu syarat untuk memperoleh gelar magister

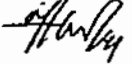
MUHAMMAD HAIKAL S.

0906576574

**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
PROGRAM PASCA SARJANA FISIKA
KEKHUSUSAN GEOFISIKA RESERVOAR
JAKARTA
JUNI 2011**

HALAMAN PERNYATAAN ORISINALITAS

Tesis ini adalah hasil karya saya sendiri,
dan semua sumber baik yang dikutip maupun dirujuk
telah saya nyatakan dengan benar.

Nama : Muhammad Haikal S.
NPM : 0906576574
Tanda Tangan : 
Tanggal : April 2011

HALAMAN PENGESAHAN

Tesis ini diajukan oleh

Nama : Muhammad Haikal S.

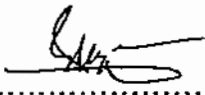
NPM : 0906576574

Program Studi : Geofisika Reservoir

Judul Tesis : Wavelet Transform Untuk Meningkatkan Kemampuan Estimasi Data
Log Pada Jaringan Back Propagation

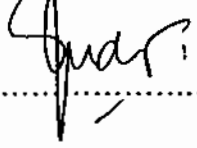
Telah berhasil dipertahankan di hadapan Dewan penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Magister Sains pada Program Studi Geofisika Reservoir, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Indonesia.

DEWAN PENGUJI

Pembimbing : Prof. Dr. Suprayitno Munadi (.....)

Penguji : Dr. Abdul Haris (.....)

Penguji : Dr. Waluyo (.....)

Penguji : Ricky Adi Wibowo (.....)

Ditetapkan di : Jakarta

Tanggal : 9 Juli 2011

KATA PENGANTAR/ UCAPAN TERIMA KASIH

Mengerjakan karya tulis ini memberi saya waktu untuk sedikit lebih dekat dan lebih lama mengamati perilaku data log sonik/kecepatan dan data log densitas. Kendati persamaan untuk menyatakan hubungan antara kedua data log tersebut telah ditemukan (Gardner, 1974), tetap saja pada kenyataannya ada hubungan yang lebih kompleks antara kedua data tersebut.

Neural network menjadi solusi lain agar model lebih mendekati nilai pengukuran dan wavelet transform menjadi bagian yang melengkapi proses estimasi data ini. Kendati telah demikian banyak ditemukan berbagai solusi yang terus mengalami kemajuan untuk mengestimasi nilai yang tidak diketahui dengan menggunakan nilai yang diketahui, namun tetap akan ada nilai kesalahan dari model yang dihasilkan, sekecil apapun itu.

Sebagai manusia, saya sepenuhnya menyadari bahwa tidak ada sebuah karya yang benar-benar sempurna. Thesis ini, selain merupakan syarat untuk memperoleh gelar magister sains dari Universitas Indonesia juga menjadi karya yang ditujukan untuk menempa diri saya sendiri, menjadi awal baru untuk melewati fase-fase panjang pembelajaran selanjutnya seperti juga sebuah jaringan syaraf tiruan yang terus menjadi semakin baik dari nilai error/kesalahan yang dikenali dan diperbaiki dalam setiap tahapnya.

Terimakasih yang tulus saya ucapkan kepada seluruh dosen di geofisika reservoir UI terutama Prof. Dr. Suprayitno Munadi yang telah bersedia membimbing saya. Kepada kedua orang tua dan adik-adik saya yang penuh cinta di manapun mereka berada. Kepada Putri suciati, Msi yang telah bersedia meluruskan saya dalam berbagai kesalahan dan tidak kalah hebat dengan fungsi aktivasi dalam sebuah jaringan backpropagation. Terimakasih juga kepada semua pihak lain yang tidak dapat saya sebutkan satu per satu, yang serupa node terhubung pada jaringan dan terus berubah nilainya seiring waktu sehingga pada akhirnya diharapkan mencapai kestabilan dalam kedewasaan, sebuah jaringan yang menuju garis asimtotik keparipurnaan. Terimakasih.

Jakarta, 13 Juni 2011

Penulis

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR
UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Muhammad Haikal S.
NPM : 0906576574
Program Studi : Geofisika Reservoir
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Jenis Karya : Tesis

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty- Free Right)** atas karya ilmiah saya yang berjudul:

Wavelet Transform Untuk Meningkatkan Kemampuan Estimasi Data Log Pada Jaringan Back Propagation. Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Jakarta

Pada tanggal : 9 Juli 2011

Yang menyatakan



(Muhammad Haikal S)

ABSTRAK

Nama : Muhammad Haikal S
Program Studi : Geofisika Reservoir
Judul : Wavelet Transform Untuk Meningkatkan Kemampuan Estimasi Data Log Pada Jaringan Back Propagation

Dalam geofisika dan *reservoir engineering*, metode *neural network* lazim digunakan untuk melakukan prediksi hubungan antara data log dengan data seismik atau data log lainnya, sehingga dengan data log yang tersedia dapat diperkirakan log lain yang tidak tersedia datanya, bahkan dipergunakan juga untuk melakukan karakterisasi reservoir. Namun metode ini juga memiliki sejumlah kekurangan dalam penerapannya guna memprediksi hubungan antara satu jenis data dengan jenis data yang lain. Masalah umum yang ditemui adalah metode ini sulit diterapkan pada data yang terbatas.

Para praktisi pasar modal menggunakan metode *wavelet transform* untuk meningkatkan kemampuan jaringan pada *neural network* untuk mengenali deret data yang polanya belum pernah ditemui dalam dataset pelatihan. Metode ini telah terbukti efektif dalam prediksi pergerakan harga dan permintaan yang kerap mengalami perubahan trend maupun pola pergerakannya. Kami menerapkan metode ini untuk meningkatkan nilai validasi dari *log* hasil estimasi dengan data yang terbatas.

Studi ini menunjukkan hasil proses *wavelet transform* pada data log yang diklasifikasikan dengan jaringan kompetitif akan menjadi bagian yang dapat memberikan arti penting untuk meningkatkan kemampuan generalisasi jaringan *backpropagation*.

Kata Kunci : *neural network*, *wavelet transform*

ABSTRACT

Name : Muhammad Haikal S
Study Program : Geofisika Reservoar
Tittle : Wavelet Transform to Enhance the Ability of Backpropagation
Network to Estimate Log Data

In geophysics and reservoir engineering, the neural network method commonly used to predict the relationship between log data and seismic data or another log data, thus with the available log data, we can expect any logs which have no data, even also can be used to perform reservoir characterization. However this method has some lacks in its application to predict the relationship between one data with the other data types. The common problem encountered is the reduction of network ability for data prediction if its applied on limited input data.

Practitioners of capital market use wavelet transform methods to increases the network ability in neural network to recognized data series, which never found in training dataset. This method has been effectively proven to predict price and demand movement, which usually changes both in trend or movement pattern. We applied this method to increase the validation value of the estimated log on limited input data.

This study shows that the classified result of wavelet transform using competitive network will be an important part to enhance generalization of backpropagation network.

Keywords : *neural network, wavelet transform*

DAFTAR ISI

HALAMAN PERNYATAAN ORISINALITAS	iii
HALAMAN PENGESAHAN	iv
KATA PENGANTAR/ UCAPAN TERIMA KASIH	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xi
DAFTAR TABEL	13
1 PENDAHULUAN	14
1.1 Latar Belakang	14
1.2 Permasalahan.....	15
1.3 Tujuan Penelitian	16
2 TEORI DASAR.....	17
2.1 Transformasi Fourier.....	17
2.2 Short Time Fourier Transform (STFT).....	18
2.3 Wavelet Transform.....	24
2.4 Diskrit Wavelet Transform	26
2.5 Neural Network.....	28
2.6 Backpropagation	31
2.7 Jaringan Kompetitif.....	35
2.8 Persamaan Gardner	36
3 DATA & PENGOLAHAN DATA.....	37
3.1 Data	37
3.2 Pengolahan Data.....	39

4	HASIL DAN ANALISA	42
4.1	Hasil	42
4.2	Analisa.....	54
5	KESIMPULAN	55
6	SARAN.....	57
7	DAFTAR PUSTAKA.....	58



DAFTAR GAMBAR

<i>Gambar 2.2-1. Sinyal stationer (a) dan sinyal non-stationer (b) (Polikar, 2003)</i>	19
<i>Gambar 2.2-2 Hasil FT sinyal stationer (a) dan sinyal non stationer (b)</i>	20
<i>Gambar 2.2-3. Window function pada t' yang berbeda (Polikar, 1999)</i>	22
<i>Gambar 2.2-4. Gaussian function dengan nilai a yang berbeda-beda (polikar, 2003)</i>	23
<i>Gambar 2.2-5 Hasil STFT dengan lebar window function yang berbeda-beda (Polikar, 2003)</i>	24
<i>Gambar 2.4-1. Skema DWT</i>	26
<i>Gambar 2.4-2. Skema SWT</i>	27
<i>Gambar 2.5-1. Elemen dan konektivitas neural network (Loh, 2003)</i>	28
<i>Gambar 2.5-2. Linear threshold unit</i>	29
<i>Gambar 2.6-1. Contoh arsitektur backpropagation</i>	32
<i>Gambar 2.6-2. Flowchart backpropagation</i>	34
<i>Gambar 3.1-1 Lokasi lapangan Bonsville di Forth Worth Basin, Amerika (Hardage, 1996)</i>	37
<i>Gambar 3.1-2 Sektor lepas pantai Belanda, area penelitian (blok F3) ditandai dengan panah. (Schroot & Schüttenhelm, 2003)</i>	38
<i>Gambar 3.1-3 Posisi sumur yang digunakan pada lapangan F3</i>	38
<i>Gambar 3.1-4 Posisi sumur yang digunakan pada lapangan Bonsville</i>	39
<i>Gambar 3.2-1 Skema pengolahan data</i>	41
<i>Gambar 4.1-1. Hasil prediksi dan nilai sebenarnya, blind test di F0201 (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.</i>	42
<i>Gambar 4.1-2. Crossplot hasil prediksi dan nilai sebenarnya blind test di F0201, (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.</i>	43
<i>Gambar 4.1-3 Hasil prediksi dan nilai sebenarnya, blind test di F0304 (a) tanpa pre-processing dengan wavelet transform . (b dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.</i>	45
<i>Gambar 4.1-4 Crossplot hasil prediksi dan nilai sebenarnya blind test di F0304, (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.</i>	46
<i>Gambar 4.1-5 Hasil prediksi dan nilai sebenarnya, blind test di F0601 (a) tanpa pre-processing dengan wavelet transform . (b dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.</i>	47

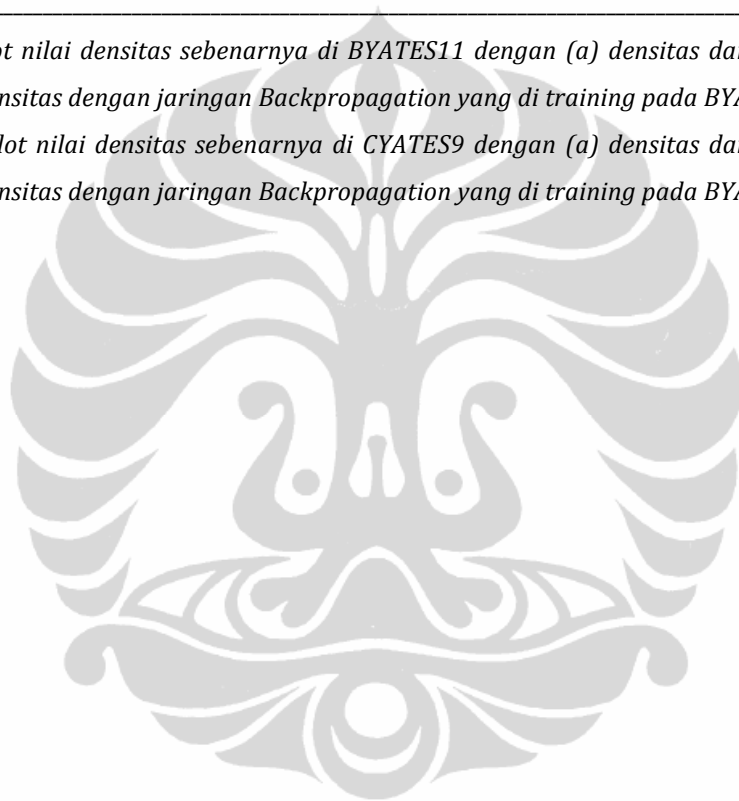
Gambar 4.1-6 Crossplot hasil prediksi dan nilai sebenarnya blind test di F0601, (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform. _____ 48

Gambar 4.1-7 (a) Estimasi densitas dengan menggunakan persamaan gardner pada BYATES11 (b) estimasi densitas pada well BYATES11 dengan jaringan Backpropagation yang di training pada BYATES18D _____ 50

Gambar 4.1-8 (a) Estimasi densitas dengan menggunakan persamaan gardner pada CYATES9 (b) estimasi densitas pada well CYATES9 dengan jaringan Backpropagation yang di training pada BYATES18D _____ 51

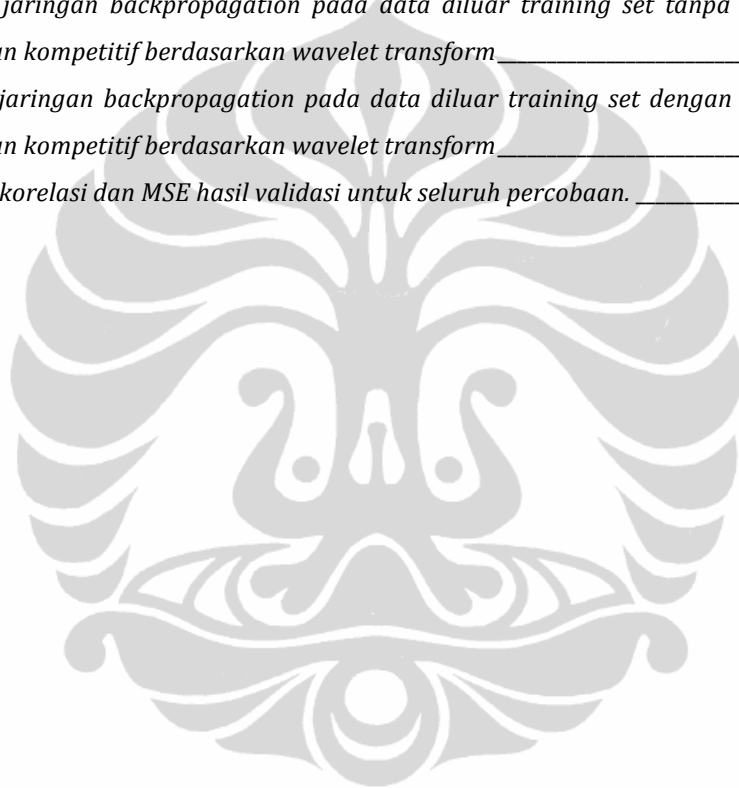
Gambar 4.1-9 Cross plot nilai densitas sebenarnya di BYATES11 dengan (a) densitas dari persamaan Gardner (b) estimasi densitas dengan jaringan Backpropagation yang di training pada BYATES18D _ 52

Gambar 4.1-10 Cross plot nilai densitas sebenarnya di CYATES9 dengan (a) densitas dari persamaan Gardner (b) estimasi densitas dengan jaringan Backpropagation yang di training pada BYATES18D _ 53



DAFTAR TABEL

<i>Tabel 1. Validasi jaringan backpropagation pada data diluar training set tanpa klasifikasi dengan jaringan kompetitif berdasarkan wavelet transform</i>	44
<i>Tabel 2. Validasi jaringan backpropagation pada data diluar training set dengan menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform</i>	44
<i>Tabel 3. Validasi densitas dari persamaan gardner</i>	49
<i>Tabel 4. Validasi jaringan backpropagation pada data diluar training set tanpa menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform</i>	49
<i>Tabel 5. Validasi jaringan backpropagation pada data diluar training set dengan menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform</i>	49
<i>Tabel 6. Koefisien korelasi dan MSE hasil validasi untuk seluruh percobaan.</i>	55



1 PENDAHULUAN

1.1 Latar Belakang

Menurut Poulton (2002) aplikasi *neural network* dalam *processing* data seismik awalnya banyak terfokus pada *horizon tracing* (Liu et al., 1989), *bright spot detection* (Huang et al., 1989), *first-break picking* (Dai and MacBeth, 1997; McCormack, 1990), *trace editing* (McCormack, 1990; Upham and Cary, 1991; Chen et al., 1991). Pengembangan selanjutnya meliputi *stacking velocity picking* (Schmidt and Hadsell, 1992), *deconvolution* (Wang and Mendel, 1992), *multiple attenuation* (Caldero'n-Mac'ias et al., 1997; Essenreiter et al., 1998), koreksi NMO (Caldero'n-Mac'ias et al., 1998), dan *seismic crew-noise identification* (Buffenmyer et al., 1999).

Dua usaha signifikan dalam aplikasi *neural network* untuk inversi seismik menurut Poulton adalah Liu & Liu (1998) dan Hampson et al (2000). Liu & Liu (1998) menjelaskan bagaimana melakukan *joint inversion* data seismik dan *low-pass filtered* data log *sonic* untuk memprediksi *sonic*, *density*, dan *shale logs* yang baru. Hampson et al (2000) memprediksi nilai porositas dari data seismik atribut menggunakan *neural network*. Secara garis besar, penelitian ini bertujuan untuk meningkatkan kemampuan jaringan untuk memprediksi nilai log dari log lain yang tersedia.

Data log yang diukur secara langsung di bawah permukaan merupakan data yang umumnya dipakai untuk melakukan verifikasi dan validasi pada data seismik yang didapat dari pengukuran pada permukaan. Hal ini dikarenakan pengukuran secara langsung pada bawah permukaan menjadikan data log lebih diterima dan dipercaya tingkat kebenarannya. Namun data log sendiri keberadaannya tidak selalu lengkap, hanya beberapa sumur memiliki log yang lengkap sedangkan sumur lain hanya memiliki sebagiannya saja. Seringkali terjadi sepotong data tidak tersedia di dalam log sebagai akibat dari kondisi sumur pada saat *logging*, misalnya dinding sumur terkuras dan ukuran lubang terlalu besar sehingga mempengaruhi pengukuran alat tertentu seperti log atau densitas (Harsono, 1994).

Hubungan antara data log yang tersedia dengan log yang ingin diprediksi dapat membantu memperkirakan nilai dari log yang tidak tersedia, sehingga dapat memberikan gambaran yang lebih baik untuk kondisi lapangan yang menjadi area penelitian.

Kemampuan *neural network* untuk mengenali pola dan menemukan hubungan non linear antara data input dan target dimanfaatkan untuk memperkirakan nilai log yang tidak diketahui dari pola hubungan antara log-log yang tersedia.

Namun metode *neural network* memiliki beberapa keterbatasan yang menjadi kendala untuk mendapatkan hasil prediksi yang baik. Praktisi matematika dan pasar modal menggunakan metode *wavelet transform* untuk meningkatkan kemampuan *neural network* dalam melakukan prediksi data *time series*. Penerapan *wavelet transform* untuk membentuk masukan pada pelatihan *neural network* terbukti meningkatkan kemampuan jaringan dalam mengenali data yang belum pernah ditemui pada data pelatihan.

Penelitian ini difokuskan untuk menerapkan *wavelet transform* dalam aplikasi *neural network* guna meningkatkan kemampuan jaringan untuk log yang tidak tersedia berdasarkan hubungan antara target dengan data log lain yang tersedia. Hasil dari jaringan tanpa menggunakan metode *wavelet transform* dan hasil estimasi dengan persamaan Gardner akan dibandingkan dengan hasil estimasi dari jaringan yang memanfaatkan *wavelet transform* untuk membuktikan hipotesis bahwa *wavelet transform* dapat meningkatkan kemampuan jaringan dalam melakukan estimasi.

1.2 Permasalahan

Salah satu *software* komersil yang menerapkan metode *neural network* untuk prediksi log dari data log lain yang tersedia adalah Hampson-Russel dari CGG Veritas. Dalam *technical note* dari *software* Hampson-Russel dijelaskan bahwa salah satu kendala dalam menerapkan *neural network* untuk memprediksi nilai log properties adalah *Performance* yang buruk bila hasil pelatihan diterapkan di luar dataset yang digunakan dalam pelatihan akibat adanya kemungkinan solusi yang belum

terwakilkan pada dataset pelatihan. Terbatasnya data akan semakin meningkatkan ketidak terwakilan pola solusi pada dataset pelatihan.

1.3 Tujuan Penelitian

Tujuan penelitian ini adalah menguji solusi dengan mengaplikasikan klasifikasi menggunakan wavelet transform sebagai bagian dari input data untuk meningkatkan kemampuan generalisasi dari neural network sehingga masih dapat mengenali pola yang sedikit berbeda dari pola yang terdapat dalam dataset pelatihan meskipun dengan data yang terbatas (hanya satu log).

Output yang diharapkan dari penelitian ini adalah pembuktian bahwa penggunaan *Wavelet Transform* dalam pembentukan jaringan *backpropagation* untuk mengestimasi data log, dapat memberikan jaringan *backpropagation* dengan kemampuan generalisasi yang lebih baik.

2 TEORI DASAR

2.1 Transformasi Fourier

Transformasi secara matematis diterapkan pada suatu sinyal dengan tujuan untuk mendapatkan lebih banyak informasi yang tidak secara langsung dapat dibaca pada sinyal mentah. Ada banyak transformasi yang dapat diterapkan pada suatu sinyal, salah satu yang paling populer adalah transformasi fourier (FT) yang diberi nama sesuai dengan tokoh utamanya Joseph Fourier yang pada 1807 mengemukakan ide bahwa semua fungsi dapat diekspresikan sebagai penjumlahan berbobot dari fungsi dasar trigonometri. Kendati pada saat tersebut teori nya mendapat berbagai kritikan keras dari para matematikawan terkemuka, 150 tahun kemudian setelah Cooley dan Tukey pada 1965 mengemukakan algoritma *Fast Fourier Transform* yang berasal dari ide awal Fourier, menempatkan FT sebagai transformasi yang paling umum dan paling dikenal hingga sekarang (Polikar, 1999)

Sebagian besar sinyal diukur dan kemudian disajikan dalam domain waktu, termasuk sinyal seismik dan data sumur. Rekaman seismik misalnya, merupakan rekaman digital amplitude dari geophone dalam rentang waktu tertentu. Transformasi fourier dimaksudkan untuk mengetahui frekuensi yang terkandung dalam sinyal seismik.

Frekuensi sendiri merupakan banyaknya getaran setiap satu satuan waktu (detik/*secon*). Bila dalam satu detik terjadi satu getaran maka disebut frekuensi getaran tersebut adalah 1 hertz (hz). Informasi mengenai frekuensi diperlukan dalam berbagai aplikasi, misalnya saja untuk memisahkan *noise* dari data rekaman, dapat dilakukan dengan memisahkan frekuensi antara *noise* dengan frekuensi sinyal, dengan hanya meloloskan frekuensi sinyal maka akan didapatkan data yang telah relative bersih dari *noise*.

FT memisahkan sebuah sinyal dalam fungsi eksponensial kompleks pada frekuensi yang berbeda-beda, secara matematis dapat dituliskan sebagai berikut :

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-2i\pi ft} dt \dots\dots\dots(2.1)$$

Sedangkan kebalikannya, untuk mendapatkan kembali sinyal dalam domain waktu dari domain frekuensi dapat dilakukan melalui persamaan Invers Fourier Transform (IFT) :

$$x(t) = \int_{-\infty}^{\infty} X(f)e^{2i\pi ft} df \dots\dots\dots(2.2)$$


dalam persamaan (...) dan (...) **f** adalah frekuensi, **t** adalah waktu, **X(f)** adalah sinyal dalam domain frekuensi sedangkan **x(t)** adalah sinyal dalam domain waktu. Fungsi kompleks $e^{-2i\pi ft}$ dapat dituliskan juga sebagai berikut :

$$\cos 2\pi ft + I \sin 2\pi ft \dots\dots\dots(2.3)$$


Dapat dilihat bahwa sesungguhnya cara kerja FT adalah dengan melakukan perkalian semua nilai pada tiap titik *sample* signal dalam domain waktu dengan fungsi kompleks di mana bagian real nya merupakan fungsi cosinus dan bagian imajinernya adalah fungsi sinus dari frekuensi tertentu kemudian menjumlahkannya. Bila banyak bagian dari sinyal input mengandung frekuensi dari fungsi kompleks maka hasil perkalian dan penjumlahan secara total pada sepanjang domain waktu untuk frekuensi tersebut akan lebih besar dibandingkan dengan frekuensi yang sedikit dikandung oleh sinyal inputnya.

2.2 Short Time Fourier Transform (STFT)

Transformasi fourier memberikan informasi mengenai frekuensi yang terdapat pada sinyal, namun kita akan kehilangan informasi mengenai waktu di mana frekuensi tersebut terdapat.. Sebagai ilustrasi dapat dilihat pada gambar berikut :



(a)




(b)


Gambar 2.2-1. Sinyal stationer (a) dan sinyal non-stationer (b) (Polikar, 2003)

Gambar 2.1(a) memperlihatkan sebuah sinyal yang terdiri dari 3 frekuensi, ketiga frekuensi penyusunnya terdapat di seluruh bagian sinyal, sedangkan gambar 2.1(b) memperlihatkan sebuah sinyal yang tersusun dari tiga frekuensi yang sama namun frekuensi rendah hanya terdapat pada sepertiga bagian dari sinyal dalam domain waktu sedangkan di belakangnya terdapat sinyal dengan frekuensi tinggi dan yang lebih tinggi lagi menyusul di belakang. Dengan menggunakan FT maka kita dapat menganalisa kandungan frekuensi kedua sinyal tersebut, namun yang akan kita

dapatkan hanyalah kandungan frekuensinya saja tanpa perbedaan antara sinyal pertama yang mengandung ketiga frekuensi pada seluruh bagian sinyal dengan sinyal kedua di mana hanya mengandung sinyal frekuensi tunggal tertentu pada tiap bagian dalam domain waktu.



(a)



(b)

Gambar 2.2-2 Hasil FT sinyal stationer (a) dan sinyal non stationer (b)

Sinyal pada gambar 2.2(a) dikenal dengan sebutan sinyal stasioner, yaitu di sepanjang sinyal tersebut tidak terdapat perbedaan kandungan frekuensi, sedangkan untuk sinyal yang mengalami perubahan kandungan frekuensi disebut dengan sinyal non-stasioner seperti sinyal pada gambar 2.2(b).

Ilustrasi dari hasil kedua sinyal tersebut memperlihatkan bahwa FT hanya cocok untuk melakukan analisa sinyal yang bersifat stasioner saja. FT dapat juga diterapkan pada sinyal non-stasioner bila tidak diperlukan informasi di mana frekuensi penyusunnya terdapat dalam sinyal tersebut.


Untuk mendapatkan informasi mengenai kandungan frekuensi dalam domain waktu tertentu, dikembangkanlah metode *short time fourier transform* (STFT) yang pada prinsipnya membagi sinyal dalam segment yang cukup kecil (*window*) dan melakukan analisa seperti transformasi fourier untuk setiap *window* dari sinyal, di mana dalam setiap *window* tersebut, sinyal dapat dianggap stasioner.

STFT ini merupakan modifikasi pertama yang dilakukan pada TF. Denis Gabor adalah orang pertama yang melakukan modifikasi dari FT ke STFT pada 1946. Banyak metode yang nyaris serupa dikemukakan pada sekitar akhir 1940 hingga awal 1970-an, pada umumnya perbedaan masing-masing metode yang diajukan terletak pada pemilihan *window function* (Polikar, 1999).

Persamaan STFT secara umum adalah :

$$STFT_x^{(w)}(t, f) = \int_t [x(t)w^*(t - t')]e^{-i2\pi ft} dt \dots\dots\dots(2.4)$$

$x(t)$ adalah sinyal dalam domain waktu, $w(t)$ adalah *window function* yang digunakan. Sedangkan *asterix* (*) merupakan *complex conjugate* sehingga *window function* bersifat 21 int21 21 21 21 21 terhadap posisinya. Gambar berikut dapat memberikan gambaran dari penggunaan *window function* dalam STFT.



Gambar 2.2-3. Window function pada t' yang berbeda (Polikar, 1999)


Gambar di atas menunjukkan empat *window function* dengan parameter frekuensi yang sama pada empat posisi yang berbeda dalam domain waktu (t'), ke-empat *window function* ini menjadi pembatas tiga FT pada tiga waktu yang berbeda, sehingga hasil dari STFT memberikan *true frequency representation* (TFR) dari sinyal.

Dengan kata lain, operasi yang dilakukan dalam STFT adalah melakukan FT pada interval waktu tertentu yang dibatasi dengan *window function* dengan frekuensi tertentu, selanjutnya *window function* digeser dengan interval tertentu hingga mencapai akhir dari sinyal, operasi yang sama dilakukan dalam setiap interval baik interval waktu maupun frekuensi.

Salah satu bentuk *window transform* yang sering digunakan adalah fungsi Gaussian yang dapat dituliskan sebagai berikut :

$$W(t)=\exp(-a(t^2)/2) \dots\dots\dots(2.5)$$

Dimana **w(t)** merupakan *window function*, **t** merupakan waktu dan **a** adalah konstanta yang mengontrol lebar *window function*. Berikut hasil *plotting* dari fungsi Gaussian di atas dengan komponen **a** yang berbeda-beda untuk menunjukkan bagaimana variable **a** mengontrol lebar *window function* yang digunakan.

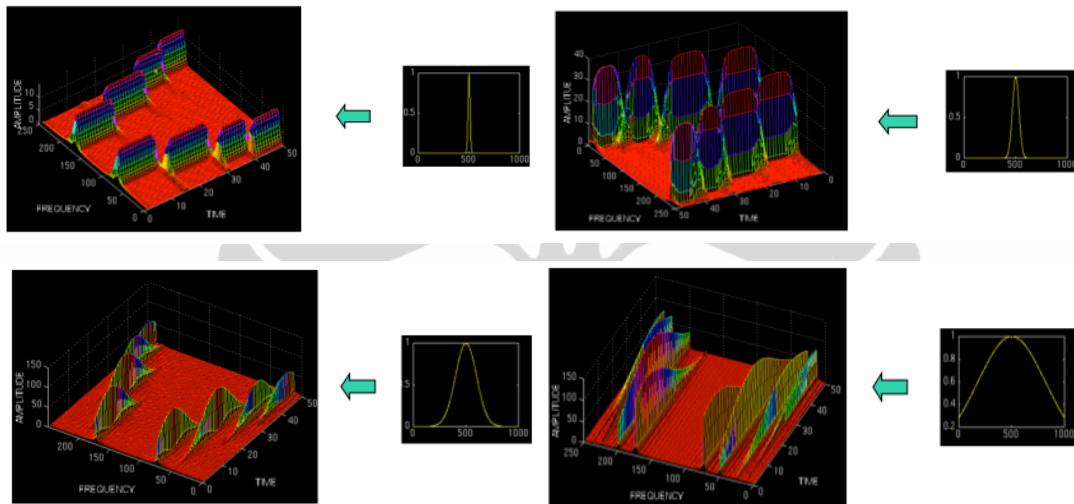


Gambar 2.2-4. Gaussian function dengan nilai a yang berbeda-beda (polikar, 2003)

Dari *window function* yang digunakan dapat dilihat bahwa penggunaan *window function* yang cukup sempit akan memberikan resolusi waktu yang lebih baik dibandingkan dengan penggunaan *window function* yang lebih lebar. Masalahnya adalah penggunaan *window function* yang sempit akan memberikan resolusi frekuensi

yang lebih buruk dibandingkan penggunaan *window function* yang lebih lebar. Hal ini sesuai dengan prinsip ketidakpastian Heisenberg (Heisenberg, 1972??), dimana disebutkan suatu sinyal atau fungsi (waktu) kontinu tidak mungkin terlokalisasi dengan baik dalam domain waktu dan frekuensi secara bersama-sama.

Perhatikan gambar berikut untuk melihat perbandingan hasil STFT menggunakan *window function* dengan nilai a yang berbeda-beda.



Gambar 2.2-5 Hasil STFT dengan lebar *window function* yang berbeda-beda (Polikar, 2003)

Gambar 2.5 menggambarkan permasalahan resolusi yang terdapat dalam STFT secara lebih jelas. Penggunaan *window function* yang sempit memberikan resolusi waktu yang baik, namun resolusi frekuensinya rendah, dan sebaliknya penggunaan *window function* yang lebar memberikan resolusi frekuensi yang baik, namun resolusi waktu berkurang.

2.3 Wavelet Transform

wavelet transform (WT) dikembangkan sebagai suatu solusi untuk mengatasi permasalahan resolusi yang ditemui dalam STFT. Pada dasarnya wavelet analisis dilakukan dengan cara mengalikan sinyal dalam domain waktu dengan suatu *window function*, namun jika dalam STFT fungsi yang sama digunakan untuk menganalisa

sinyal pada sepanjang waktu dan seluruh frekuensi sedangkan dalam wavelet analisis dilakukan perubahan lebar dari *window function* yang dilakukan untuk setiap komponen spektral yang sedang dianalisa.

Wavelet yang digunakan sebagai *window function* dalam WT disebut dengan *mother wavelet*. Wavelet ini kemudian berfungsi sebagai prototype untuk melakukan analisa sinyal. Wavelet akan digeser dengan interval tertentu sepanjang sinyal (translasi) dan akan mengalami perubahan skala yang berkorespondensi dengan frekuensi. Karena mempertimbangkan berbagai tingkat resolusi pada skala (frekuensi) dan waktu, wavelet transform merupakan bagian dari *multi resolution analysis*.

Faktor skala merupakan hal yang nyaris sama dengan factor skala pada peta, dimana skala yang tinggi menggambarkan penampakan yang lebih luas sedangkan skala yang rendah memberikan gambaran detail. Dalam wavelet transform skala yang tinggi (frekuensi rendah) memberikan gambaran informasi global dari sebuah sinyal sedangkan dengan skala rendah (frekuensi tinggi) memberikan gambaran detail dari sinyal.

Penskalaan dalam operasi matematika pada wavelet tidak lain adalah dilatasi (menarik/melebarkan wavelet) atau melakukan kompresi/memampatkan wavelet yang bertindak sebagai prototype atau *mother wavelet*. Secara lebih sederhana factor skala dapat tuliskan sebagai $1/f$. dimana faktor skala yang besar bearti wavelet menjadi semakin lebar, dan sebaliknya faktor skala yang kecil bearti akan semakin mengkompres wavelet.

Untuk menganalisa frekuensi tinggi maka digunakan *window* yang sempit guna memberikan resolusi waktu yang baik sedangkan untuk menganalisa frekuensi rendah digunakan *window* yang lebih lebar untuk mendapatkan resolusi frekuensi yang lebih baik.

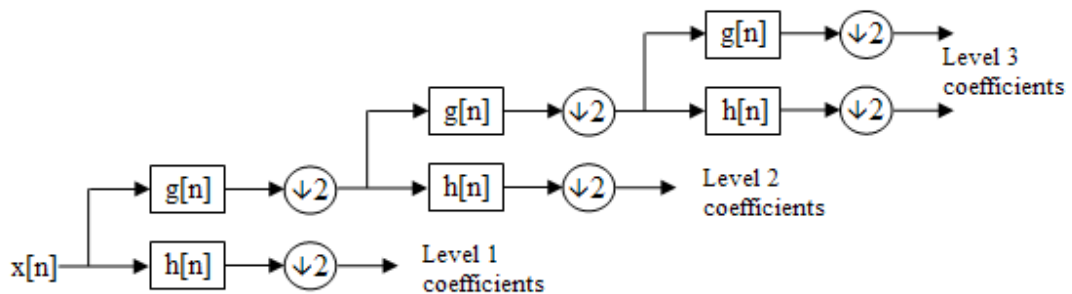
2.4 Diskrit Wavelet Transform

Metode WT yang paling awal dikenal adalah *Continues Wavelet Transform* (CWT). Namun secara praktiknya, untuk melakukan perhitungan pada komputer sebenarnya dilakukan dengan mengambil interval tertentu dalam faktor skala dan waktu (dilatasi) atau dengan kata lain *resampling* dari CWT yang dikenal dengan *Discrete Wavelet Transform* (DWT). Hal ini karena CWT akan menghasilkan banyak *redundant data* yang tidak praktis serta menyita sumberdaya komputasi. *Discrete Wavelet Transform* (DWT) kemudian menjadi populer diterapkan untuk melakukan dekomposisi terutama untuk sinyal diskrit, termasuk data sumur atau rekaman data seismik.

Dalam DWT maka ditentukan interval pada sumbu waktu maupun frekuensi. Mother wavelet di “rescaled” atau di dilatasi dengan skala dyadic (2^n) dan ditranslasikan pada integer. Persamaan DWT dapat dituliskan sebagai berikut :

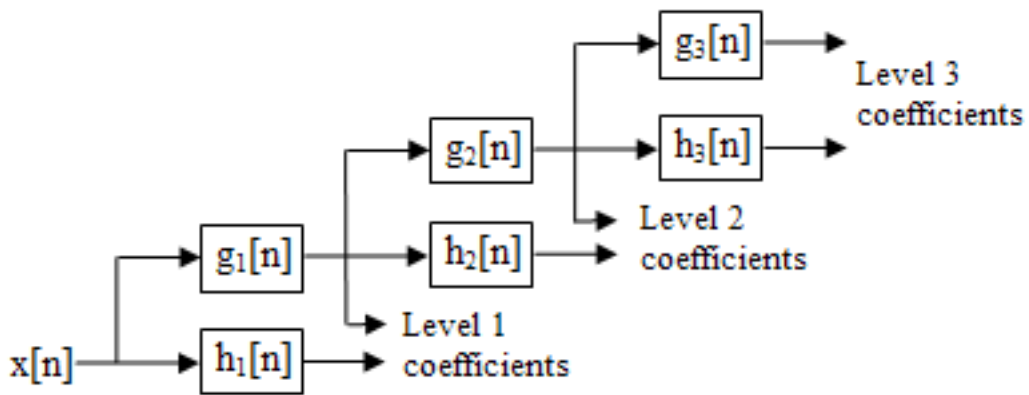
$$f(t) = \sum_k c_{j0} \theta_{j0}(t) + \sum_{j>j0} \sum_k w_{j,k} 2^{\frac{1}{2}j} \psi(2^j t - k) \dots\dots\dots(2.6)$$

di mana j adalah dilatasi atau indeks dari level, k adalah translasi atau faktor skala, θ_{j0} merupakan fungsi penskalaan aproksimasi atau rata-rata dan $c_{j0} - w_{j,k}$ adalah fungsi penskalaan detail. Dengan menentukan interval maka jumlah koefisien dalam transformasi dikurangi tanpa kehilangan informasi yang berarti dari sinyal saat ditransformasikan. Skemanya dapat digambarkan seperti gambar berikut ini :




Gambar 2.4-1. Skema DWT

$g[n]$ merupakan *low pass filter* sedangkan $h[n]$ merupakan *high pass filter*. Setiap level, maka output dari $g[n]_{j-1}$ akan dilakukan *subsampling* sehingga jumlah sample menjadi setengahnya. Proses *subsampling* ini akan mengurangi jumlah sample dan resolusi dari translasi. Untuk membentuk *network* yang mengenali perubahan pola di sepanjang sinyal, maka digunakan *Stationary Wavelet Transform* (SWT) yang ide dasarnya sebenarnya sama, hanya saja yang dikenakan *subsampling* pada tiap level bukanlah output dari *low pass filter* melainkan *wavelet* yang digunakan dalam analisa. Skema SWT dapat digambarkan sebagai berikut :



Gambar 2.4-2. Skema SWT

Dengan :




filter dari $j+1$ merupakan *upsampled* dari wavelet filter j hal ini dapat berlaku karena ketika wavelet dalam domain waktu mengalami *stretching* maka spectrum nya akan menjadi lebih kecil dan bandwidth nya menjadi makin sempit, hal sebaliknya berlaku bila wavelet dikompres.

2.5 Neural Network

Neural Network (NN) atau jaringan syaraf tiruan adalah sistem yang melakukan proses terhadap masukan dengan meniru karakteristik jaringan syaraf biologi. Jaringan syaraf biologi, seperti otak manusia misalnya, memiliki struktur yang kompleks dan memiliki kemampuan luar biasa, dimana jaringan tersebut terdiri dari neuron-neuron yang saling terhubung lewat penghubung yang disebut sinapsis. *Neural network* dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi :

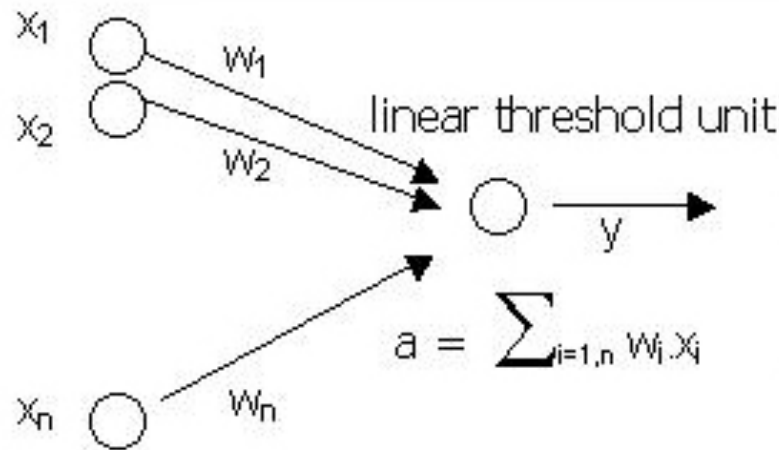
1. *Processing* data terjadi pada banyak elemen sederhana (*neuron*)
2. Sinyal dikirimkan diantara *neuron-neuron* melalui penghubung
3. Penghubung antar *neuron* memiliki bobot yang akan memperlemah atau memperkuat sinyal
4. Untuk menentukan *output*, setiap *neuron* menggunakan fungsi aktivasi. Besar *output* selanjutnya dibandingkan dengan suatu ambang batas.

Sebagai contoh, dapat digambarkan dengan jaringan sederhana yang menggunakan fungsi *threshold* sebagai fungsi aktivasi berikut. Secara sederhana proses yang berlaku pada *neural network* diawali dengan *neuron* akan menerima informasi dari sejumlah *node* masukan (x_1 , x_2 dan x_3) kemudian masukan tersebut akan dikalikan dengan bobot yang dilambangkan dengan W .



Gambar 2.5-1. Elemen dan konektivitas neural network (Loh, 2003)

kemudian dengan sebuah fungsi penjumlahan dari hasil perkalian antara input dan factor bobot dijumlahkan sebelum dilanjutkan pada sebuah fungsi aktivasi (*threshold*) dan nilai dari output y akan ditentukan dari nilai fungsi penjumlahan apakah melewati ambang batas *threshold* atau belum.



Gambar 2.5-2. Linear threshold unit

Beberapa fungsi aktivasi yang sering digunakan antara lain adalah fungsi threshold seperti contoh di atas, fungsi sigmoid dan fungsi identitas.

1. Fungsi aktivasi *threshold* (ambang batas)

$$f(x) = 1, x \geq a$$

$$f(x) = 0, x < a$$

untuk beberapa kasus, fungsi *threshold* yang dibuat tidak bernilai 0 atau 1 tapi -1 atau 1 (dikenal dengan *threshold* bipolar)

2. Fungsi Sigmoid biner

$$f(x) = \frac{1}{1+e^{-x}} \dots \dots \dots (2.7)$$

fungsi sigmoid sering dipakai karena nilainya antara 0 dengan 1 dan dapat diturunkan dengan mudah $f'(x) = f(x)(1 - f(x))$

3. Fungsi identitas

$$f(x) = x \dots\dots\dots(2.8)$$

Fungsi identitas sering dipakai bila output yang diinginkan berupa sembarang bilangan riil bukan hanya pada range 0 hingga 1 atau dari -1 hingga 1 saja.

Bila arsitektur jaringan telah ditentukan maka jaringan perlu dilatih sebelum benar-benar diterapkan. Proses pelatihan jaringan ini dilakukan dengan mengumpan masukan (data pelatihan) ke dalam jaringan untuk diproses sehingga jaringan dapat belajar mengenali informasi dari pola yang terdapat dalam data pelatihannya.

Aplikasi NN/jaringan syaraf tiruan ini telah dimanfaatkan dalam berbagai bidang dari astronomi hingga seismologi, kedokteran, bidang control dan lain-lain. Secara umum penerapan NN digunakan paling banyak pada tiga bidang berikut (siang, 2005) :

1. Pengenalan Pola (*Pattern recognition*)

NN dapat digunakan untuk mengenali pola seperti huruf, angka, suara, atau tanda tangan manusia yang sudah sedikit mengalami perubahan. Hal ini seperti layaknya kemampuan otak manusia yang masih dapat mengenali wajah yang mengalami perubahan setelah sekian lama tidak dilihat.

2. *Signal processing*

NN digunakan untuk meningkatkan S/N ratio misalnya untuk *multipleattenuation* (Calderón-Macías et al., 1997; Essenreiter et al., 1998) atau *seismic crew-noise identification* (Buffenmyer et al., 1999) dalam bidang seismik. Contoh lain adalah pemanfaatan NN untuk menekan *noise* pada pesawat telepon.

3. Peramalan (*forecasting*)

Pemanfaatan NN dalam aplikasi peramalan atau estimasi dimungkinkan mengingat pola dan membuat generalisasi dari apa yang sudah ada sebelumnya. Kemampuan generalisasi ini merupakan fokus utama dalam

penelitian ini, yaitu memanfaatkan *wavelet transform* untuk meningkatkan kemampuan generalisasi dari jaringan.

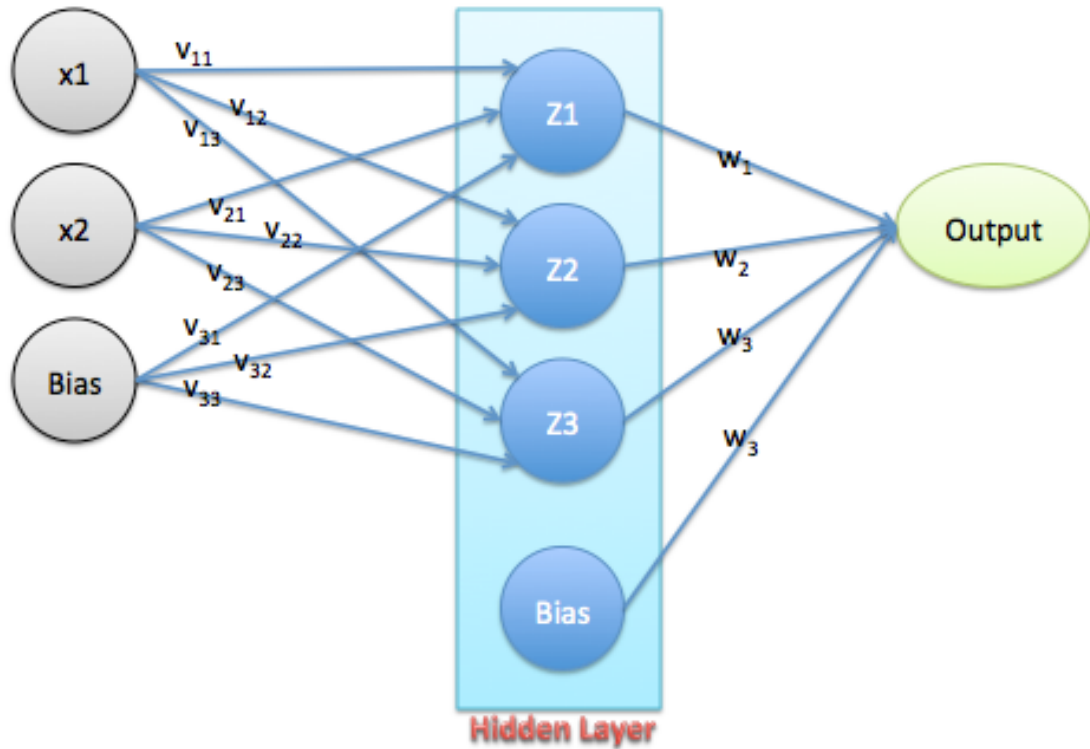
2.6 Backpropagation

Kelemahan NN pada masa awal perkembangannya adalah kemampuannya yang terbatas, karena baru diterapkan dengan menggunakan *layer* tunggal saja. Kekurangan ini menyebabkan NN kurang efektif diterapkan dalam berbagai aplikasi terutama bila digunakan untuk menganalisa atau mengestimasi pola data yang rumit. Hal ini menyebabkan perkembangan NN sempat terhenti pada tahun 1970-an.

Penemuan *backpropagation* yang dapat terdiri dari lebih dari satu *layer* kembali membuka minat terhadap potensi NN untuk menyelesaikan berbagai macam masalah. Terlebih kemudian sedikit demi sedikit ditemukan berbagai aplikasi yang dapat diselesaikan dengan *backpropagation*.

Backpropagation dikembangkan untuk mengatasi keterbatasan jaringan dengan *layer* tunggal untuk mengenali pola. Cara yang digunakan adalah dengan menambahkan *layer* tersembunyi antara *output* dengan input. Walaupun semakin banyak *layer* yang digunakan memberikan manfaat dalam beberapa kasus, namun pelatihannya memerlukan waktu komputasi yang lebih lama, sehingga secara umum *backpropagation* akan dimulai dengan menggunakan satu *layer* tersembunyi terlebih dahulu, kemudian ditambah jika masih dianggap kurang mampu mengenali pola data masukan.

Contoh arsitektur sederhana dari *backpropagation* dapat di gambarkan dengan skema seperti gambar 7 di mana 2 buah masukan (x_1 & x_2) ditambah bias akan diproses melewati sebuah *layer* tersembunyi yang memiliki 3 unit dan satu bias, untuk menghasilkan output y . garis v dan w adalah garis bobot dari input ke *layer* tersembunyi dan garis bobot dari *layer* tersembunyi ke output.



Gambar 2.6-1. Contoh arsitektur backpropagation

Dalam *backpropagation*, fungsi aktivasi yang umum dipakai adalah fungsi *sigmoid biner* atau *sigmoid bipolar*. *Sigmoid bipolar* dapat dituliskan dalam persamaan berikut seperti berikut :

$$f(x) = \frac{2}{1+e^{-x}} - 1 \quad \dots\dots\dots (2.9)$$

Sedangkan fungsi *sigmoid biner* dapat dituliskan sebagai berikut :

$$f(x) = \frac{1}{1+e^{-x}} \quad \dots\dots\dots (2.10)$$

Dengan menggunakan kedua fungsi *sigmoid* ini maka hasil keluaran dari tiap unit akan berada di range antara 0 hingga 1 (untuk *sigmoid biner*) atau antara -1 dan 1 (untuk *sigmoid bipolar*) untuk itu, bila target yang diinginkan >1 maka data perlu ditransformasikan terlebih dahulu sehingga semua pola memiliki range yang sama

seperti fungsi aktivasi yang digunakan. Alternatif lain adalah dengan menggunakan fungsi *sigmoid* pada selain layer output, sedang untuk layer output tetap menggunakan fungsi identitas.

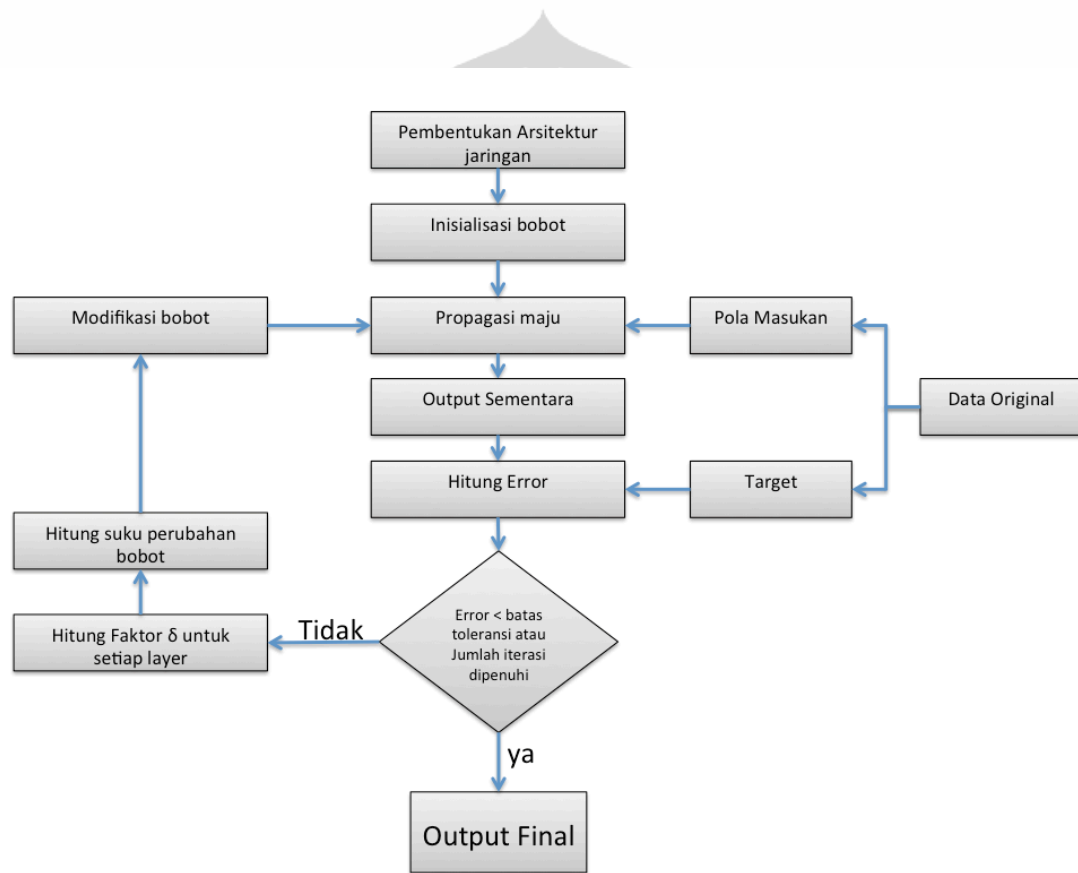
Tahap pelatihan pada NN dengan arsitektur *backpropagation* dilakukan melalui 3 tahapan atau fase seperti yang dijabarkan oleh Siang dalam bukunya (Siang, 2005). Fase pertama adalah fase maju. Pola masukan dihitung maju mulai dari *layer* input hingga *layer output* menggunakan fungsi aktivasi yang telah ditentukan. Fase kedua adalah fase mundur. Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Dimulai dari garis bobot yang berhubungan langsung dengan *layer output*, kesalahan yang terjadi dipropagasi mundur. Fase ketiga adalah modifikasi bobot untuk menurunkan tingkat *error* yang terjadi.

Dalam propagasi maju, sinyal masukan akan diteruskan ke *layer* tersembunyi dengan bobot yang telah ditentukan terlebih dahulu sebagai bobot awal (bilangan acak kecil) kemudian dihitung keluaran pada setiap unit *layer* tersembunyi tersebut sesuai dengan fungsi aktivasi yang digunakan untuk diteruskan ke *layer* selanjutnya hingga terakhir tiba pada *layer output*. Keluaran jaringan dibandingkan dengan target yang ingin dicapai, selisih antara target dengan hasil keluaran adalah *error* yang terjadi. Bila *error* yang terjadi lebih kecil dari batas toleransi yang diinginkan maka proses pelatihan dihentikan, bila tidak maka proses pelatihan akan dilanjutkan ke iterasi berikutnya.

Fase kedua adalah propagasi mundur berdasarkan selisih antara target dengan keluaran dari masing-masing unit pada tiap layer dihitung faktor δ sebagai faktor yang menjadi dasar perubahan bobot semua garis yang berada dalam arsitektur jaringan. Dimulai dari garis yang berhubungan langsung dengan output kemudian mundur ke *layer* di belakangnya.

Setelah semua faktor δ dihitung, maka fase selanjutnya adalah fase ketiga yaitu perubahan bobot. Bobot pada setiap garis dimodifikasi secara bersamaan. Perubahan bobot untuk tiap garis dihitung berdasarkan faktor δ *layer* di atasnya.

Ketiga fase ini diulang berkali-kali hingga kondisi penghentian terpenuhi. Kondisi penghentian yang umum digunakan adalah nilai *error* atau jumlah perulangan atau iterasi yang telah dilakukan. Iterasi akan dihentikan bila setelah sejumlah iterasi tidak juga dicapai tingkat *error* yang lebih kecil dari batas toleransi, atau batas toleransi telah dicapai sebelum jumlah iterasi yang dilakukan mencapai jumlah iterasi yang telah ditetapkan.



Gambar 2.6-2. Flowchart backpropagation

pada prinsipnya metode pelatihan dalam *backpropagation* ini menggunakan metode pencarian titik minimum untuk menemukan bobot yang menghasilkan error yang minimum. Dalam proses pencarian bobot ini terdapat dua metode perubahan atau modifikasi bobot yang dapat diterapkan. Metode modifikasi bobot yang pertama dapat dilakukan secara *incremental*, di mana bobot dimodifikasi setiap satu pola

selesai diumpakan pada jaringan. Metode modifikasi yang lain adalah secara berkelompok (*batch*), di mana dalam metode modifikasi berkelompok ini akan dihitung error dan faktor δ untuk semua pola masukan, kemudian dijumlahkan untuk menghasilkan bobot yang baru.

2.7 Jaringan Kompetitif

Jaringan yang digunakan untuk melakukan klasifikasi pola masukan pada jaringan *backpropagation* menggunakan aturan yang ditemukan oleh kohonen. Jaringan ini pada dasarnya memiliki arsitektur yang sama dengan jaringan *backpropagation* hanya saja jaringan ini tidak menggunakan hasil kali vektor masukan dengan bobot untuk menentukan *output* nya.

Bobot awal ditentukan secara acak sesuai jumlah *cluster* data yang diinginkan kemudian dilakukan pengujian setiap vektor masukan untuk menentukan vektor bobot yang menjadi pemenang. Bobot terus diubah selama iterasi dan perubahan bobot yang sudah tidak signifikan dapat menjadi kondisi penghentian iterasi selain membatasi jumlah iterasi sejak awal.

Langkah pengelompokan pola pada jaringan kohonen adalah sebagai berikut (Siang, 2005) :

1. Inisialisasi
 - a. Bobot (random)
 - b. Laju pemahaman
 - c. Bentuk dan jari-jari topologi sekitar bobot pemenang
2. Tentukan kondisi penghentian iterasi
3. Hitung nilai total dari selisih antara data dengan bobot $D(j) = \sum_i (w_{ij} - x_i)^2$ untuk semua kelas yang ingin dibentuk (j)
4. Modifikasi bobot dengan D(j) terendah
5. Modifikasi laju pemahaman
6. Uji kondisi penghentian iterasi

2.8 Persamaan Gardner

Persamaan ini sangat populer dalam *petroleum exploration*. Persamaan Gardner menyatakan hubungan empiris antara densitas dengan kecepatan yang diperoleh dari hasil pengukuran laboratorium dengan menggunakan core batuan yang diambil dari sumur. Data menunjukkan terdapat hubungan yang sistematis antara densitas dan kecepatan (Gardner, Gardner & Gregory, 1974) yang dinyatakan dalam persamaan berikut :

$$\rho = 0.23V^{0.25} \dots\dots\dots(2.11)$$

dengan :

$$\rho = \text{densitas } \left(\frac{g}{cc}\right)$$

V= kecepatan (ft/s)


Jika tidak terdapat data densitas namun terdapat data log sonik, maka densitas dapat diestimasi dari nilai log sonik. Hasil estimasi dari persamaan ini akan menjadi bahan perbandingan yang digunakan dalam dalam analisa hasil dari studi ini.

3 DATA & PENGOLAHAN DATA

3.1 Data

Data yang digunakan dalam studi ini adalah data *well* dari lapangan F3 yang terletak di *North Sea* wilayah Belanda dan dari lapangan Boonsville. Aplikasi pertama diterapkan untuk melakukan estimasi log GR dengan input dari log sonik pada *well* yang terdapat di F3. Untuk data dari lapangan Boonsville, aplikasi ini diterapkan untuk mendapatkan estimasi log densitas dari data log sonik. Selain menggunakan jaringan *backpropagation* pada data Boonsville di terapkan juga persamaan Gardner untuk melakukan estimasi densitas dari data log sonik sebagai perbandingan kinerja jaringan yang dihasilkan.


Penggunaan data dua lapangan yang berbeda dengan target yang berbeda dimaksudkan untuk menguji metode mendapatkan jaringan *backpropagation* menggunakan WT bersifat umum dan dapat diterapkan pada lapangan-lapangan lain dengan pola data yang berbeda.




Gambar 3.1-1 Lokasi lapangan Boonsville di Forth Worth Basin, Amerika (Hardage, 1996)



Gambar 3.1-2 Sektor lepas pantai Belanda, area penelitian (blok F3) ditandai dengan panah. (Schroot & Schüttenhelm, 2003)



Gambar 3.1-3 Posisi sumur yang digunakan pada lapangan F3



Gambar 3.1-4 Posisi sumur yang digunakan pada lapangan Bonsville

3.2 Pengolahan Data

Data yang menjadi target adalah log GR (API) dan densitas (g/cc) dan inputnya adalah log sonik. Penentuan log GR dan log densitas dari data log sonik akan dilakukan dengan tiga cara, melalui persamaan Gardner, menggunakan NN, dan terakhir dengan menggunakan NN dengan data input yang telah memasukkan hasil klasifikasi berdasarkan dekomposisi dengan wavelet transform.

Arsitektur NN yang digunakan dalam penentuan hubungan antara log sonik dengan log densitas dan GR adalah *backpropagation* dengan menggunakan 1 *layer* tersembunyi yang memiliki 50 node dan menghasilkan satu nilai output untuk setiap pola. Arsitektur jaringan *backpropagation* yang digunakan sama agar dapat menunjukkan perbandingan kemampuan generalisasi jaringan yang dihasilkan.

Tahap pertama adalah tahap *pre-processing*. Dalam tahap ini, dilakukan penyusunan data *input* dan data *target* ke dalam elemen matrix sehingga dapat mempermudah *processing data*. *Wavelet transform* diterapkan pada data input awal, kemudian diklasifikasikan menggunakan jaringan kompetitif, hasilnya akan ikut diperhitungkan

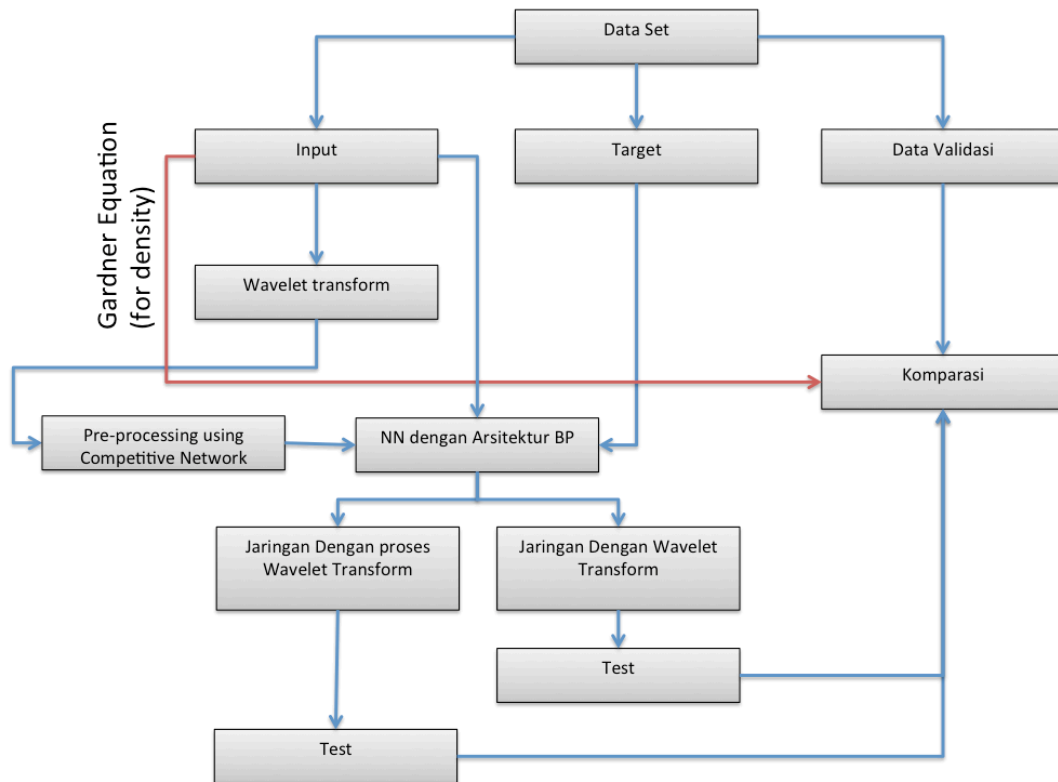
sebagai input pada NN. Pada tahap *pre-processing* ini dibentuk juga arsitektur jaringan yang akan digunakan.

Tahap selanjutnya adalah tahap pelatihan/*training*. Pada tahap ini dilakukan inisiasi bobot awal pada arsitektur NN yang telah dibentuk pada tahap *pre-processing*. Kemudian dilakukan propagasi maju, propagasi mundur, dan perubahan bobot secara berulang-ulang hingga dicapai nilai *error* yang dapat diterima (batas toleransi).

Dalam proses pelatihan ini, satu batasan iterasi lagi diterapkan dengan membagi data yang diketahui menjadi tiga bagian yaitu bagian yang murni diikutsertakan dalam pelatihan, bagian yang digunakan untuk validasi, serta bagian yang digunakan untuk melakukan test. Komposisinya adalah 80% data pelatihan, 10% data validasi, dan 10% data untuk tahap *testing*. Batasan iterasi selain batas toleransi *error* adalah setiap *epoch* (perulangan setelah semua pola pelatihan diumpangkan pada jaringan), jaringan diuji pada data validasi (data pada *log* yang diketahui targetnya namun tidak diikutsertakan dalam pelatihan). Bila *error* pada data validasi ini masih terus turun, maka iterasi akan dilanjutkan hingga mencapai batas toleransi *error* atau batas iterasi (1000 kali), namun bila enam kali iterasi hasil *error* pada data validasi makin besar, maka pelatihan dihentikan. Hal ini dimaksudkan agar tidak terjadi *overfitting*, dimana jaringan sudah secara khusus mengambil sifat-sifat dari data pelatihan dan kehilangan kemampuan untuk mengenali sedikit perubahan yang terjadi (generalisasi). Bobot terakhir yang digunakan adalah bobot pada iterasi yang menghasilkan *error* validasi terkecil.

Tahap terakhir adalah *blind test* pada sumur atau lain yang datanya tidak diikutsertakan dalam proses pelatihan jaringan. *Blind test* dilakukan untuk mengetahui performa jaringan dalam melakukan estimasi.

Skema pengolahan data secara keseluruhan dalam penelitian ini dapat digambarkan dengan *flow chart* seperti berikut.



Gambar 3.2-1 Skema pengolahan data


Log densitas pada lapangan Bonsville yang menjadi data target akan diperoleh melalui tiga cara yaitu dengan menggunakan persamaan Gardner, dengan melakukan pelatihan neural network tanpa *preprocessing* menggunakan klasifikasi berdasarkan WT dan terakhir dengan menggunakan jaringan yang memanfaatkan hasil klasifikasi berdasarkan WT untuk membentuk data input.

Mean Square Error dan koefisien korelasi dari hasil *blind test* yang diperoleh akan dibandingkan antara satu cara dengan cara lainnya untuk melihat penurunan atau peningkatan kemampuan validasi dari jaringan yang telah melalui *training*.

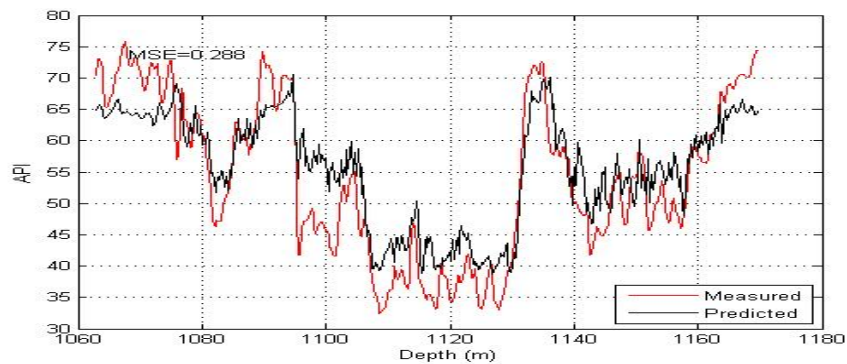
4 HASIL DAN ANALISA

4.1 Hasil

Proses pelatihan dilakukan untuk data pada sumur F03-02 antara marker FS6 dan FS2, *log* sonik digunakan sebagai input untuk mengetahui *log* GR tanpa melakukan *wavelet transform* dan klasifikasi menggunakan jaringan kompetitif sebelumnya.



(a)




(b)


Gambar 4.1-1. Hasil prediksi dan nilai sebenarnya, blind test di F0201 (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.

Saat diuji pada well F0201 diperoleh hasil dengan nilai MSE sebesar 0.626. Sedangkan dengan menggunakan cara kedua (menggunakan *wavelet transform* dan klasifikasi dengan jaringan kompetitif) pada tahap *pre-processing* data diperoleh hasil yang menunjukkan nilai MSE sebesar 0.288, perbandingan antara keduanya dapat

dilihat pada gambar 4.1-1. Perbedaan yang signifikan tercermin juga pada nilai koefisien korelasi seperti terlihat pada gambar 4.1-2 berikut.



(a)



(b)

Gambar 4.1-2. Crossplot hasil prediksi dan nilai sebenarnya blind test di F0201, (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.


Blind test juga dilakukan pada sumur F0304 dan F0601 yang terdapat pada lapangan F3. Hasil yang diperoleh ditunjukkan dalam tabel-1 dan tabel-2.

Tabel 1. Validasi jaringan backpropagation pada data diluar training set tanpa klasifikasi dengan jaringan kompetitif berdasarkan wavelet transform


	<i>F0201</i>	<i>F0304</i>	<i>F0601</i>
<i>MSE</i>	<i>0.626</i>	<i>0.364</i>	<i>0.76</i>
<i>R</i>	<i>0.31</i>	<i>0.41</i>	<i>0.041</i>

Tabel 2. Validasi jaringan backpropagation pada data diluar training set dengan menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform

	<i>F0201</i>	<i>F0304</i>	<i>F0601</i>
<i>MSE</i>	<i>0.282</i>	<i>0.136</i>	<i>0.416</i>
<i>R</i>	<i>0.91</i>	<i>0.92</i>	<i>0.82</i>

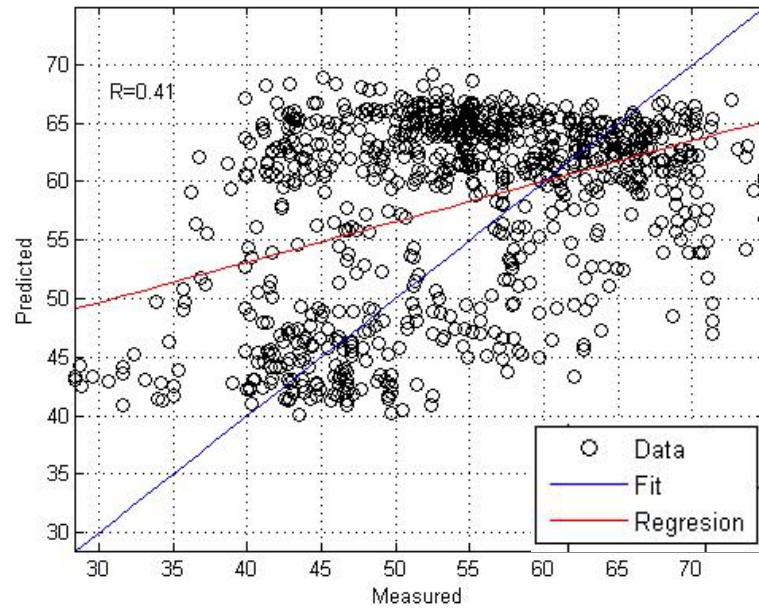


(a)




(b)

Gambar 4.1-3 Hasil prediksi dan nilai sebenarnya,blind test di F0304 (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.

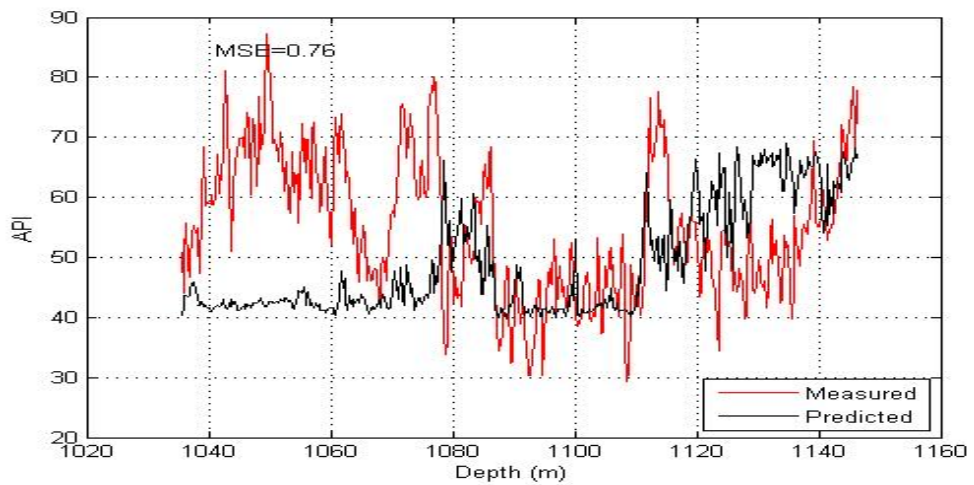


(a)




(b)

Gambar 4.1-4 Crossplot hasil prediksi dan nilai sebenarnya blind test di F0304, (a) tanpa pre-processing dengan wavelet transform. (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.




(a)




(b)

Gambar 4.1-5 Hasil prediksi dan nilai sebenarnya, blind test di F0601 (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.



(a)



(b)

Gambar 4.1-6 Crossplot hasil prediksi dan nilai sebenarnya blind test di F0601, (a) tanpa pre-processing dengan wavelet transform . (b) dengan pre-processing input menggunakan klasifikasi berdasarkan wavelet transform.

Tidak seperti percobaan pada lapangan F3 untuk percobaan dengan data pada lapangan Bonsville dilakukan pada keseluruhan data well. *Training* untuk mengestimasi log densitas dari log sonik dilakukan pada well BYATES18D kemudian dilakukan *blind test* pada kedua sumur lainnya (CYATES9 & BYATES11). MSE dan koefisien korelasi dari percobaan pada data Bonsville ditunjukkan oleh tabel-3 dan tabel-4.

Tabel 3. Validasi densitas dari persamaan gardner

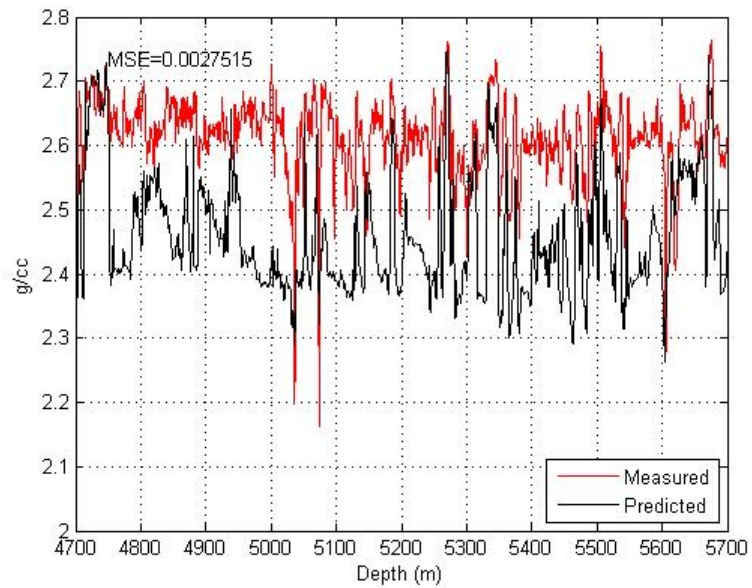
	<i>BYATES11</i>	<i>CYATES9</i>
<i>MSE</i>	<i>0.0027515</i>	<i>0.002402</i>
<i>R</i>	<i>0.5</i>	<i>0.58</i>

Tabel 4. Validasi jaringan backpropagation pada data diluar training set tanpa menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform


	<i>BYATES11</i>	<i>CYATES9</i>
<i>MSE</i>	<i>0.00167</i>	<i>0.00124</i>
<i>R</i>	<i>0.56</i>	<i>0.78</i>

Tabel 5. Validasi jaringan backpropagation pada data diluar training set dengan menggunakan klasifikasi jaringan kompetitif berdasarkan wavelet transform

	<i>BYATES11</i>	<i>CYATES9</i>
<i>MSE</i>	<i>0.0000572</i>	<i>0.00106</i>
<i>R</i>	<i>0.83</i>	<i>0.86</i>

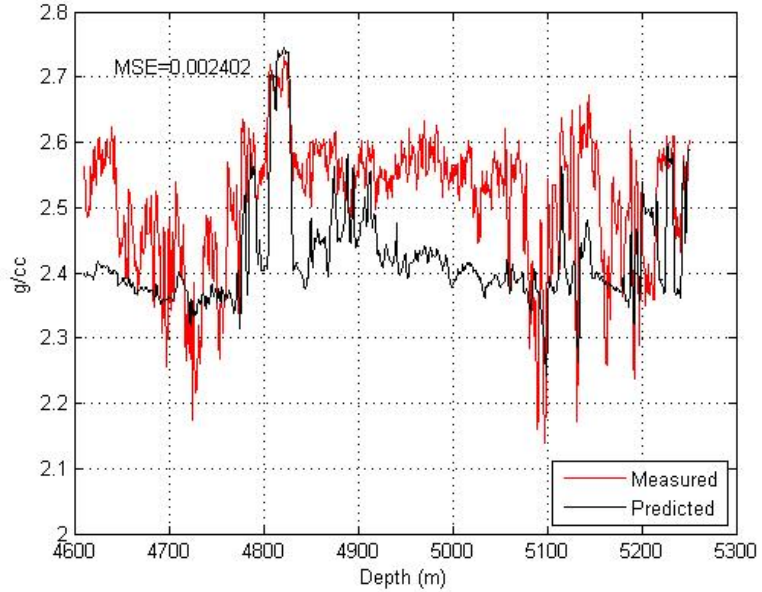


(a)




(b)

Gambar 4.1-7 (a) Estimasi densitas dengan menggunakan persamaan gardner pada BYATES11 (b) estimasi densitas pada well BYATES11 dengan jaringan Backpropagation yang di training pada BYATES18D




(a)




(b)

Gambar 4.1-8 (a) Estimasi densitas dengan menggunakan persamaan gardner pada CYATES9 (b) estimasi densitas pada well CYATES9 dengan jaringan Backpropagation yang di training pada BYATES18D






(a)



(b)

Gambar 4.1-9 Cross plot nilai densitas sebenarnya di BYATES11 dengan (a) densitas dari persamaan Gardner (b) estimasi densitas dengan jaringan Backpropagation yang di training pada BYATES18D



(b)

Gambar 4.1-10 Cross plot nilai densitas sebenarnya di CYATES9 dengan (a) densitas dari persamaan Gardner (b) estimasi densitas dengan jaringan Backpropagation yang di training pada BYATES18D

4.2 Analisa

Mengestimasi nilai log dari log lain yang tersedia menggunakan *neural network* umumnya memerlukan lebih dari satu log sebagai input agar jaringan dapat menentukan hubungan antara log input dengan target yang diinginkan. Sehingga dapat dipahami mengapa nilai validasi dari jaringan *backpropagation* menggunakan log sonik untuk mengestimasi log GR pada lapangan F3 memberikan hasil yang buruk.

Pada tabel hasil *blind test* untuk lapangan F3 (tabel.1 dan tabel.2), dapat dilihat bahwa jaringan *backpropagation* biasa tidak mampu memberikan hasil prediksi yang cukup mendekati nilai sebenarnya. Nilai koefisien korelasi yang terbesar untuk jaringan yang dilatih pada F0304 hanya 0.41 yaitu pada F0304. Dengan memasukkan hasil klasifikasi berdasarkan *wavelet transform* hanya dengan memanfaatkan log sonik maka log GR dapat diprediksi dengan cukup baik. Nilai koefisien korelasi terkecil masih mencapai 0.82. hal ini menunjukkan kontribusi yang cukup besar dari klasifikasi berdasarkan *wavelet transform* sebelum menjadi masukan yang diumpankan pada proses pelatihan jaringan.

Percobaan estimasi log densitas dari log sonik pada data Bonsville menunjukkan hasil yang cukup baik, nilai koefisien korelasi terkecil masih dapat mencapai 0.83 hanya dengan menggunakan data sonik. Nilai ini jauh lebih baik dari pada bila menggunakan persamaan gardner untuk mengestimasi densitas, nilai koefisien korelasi antara data sebenarnya dengan hasil prediksi hanya mencapai 0.58.

Perbedaan hasil yang ditunjukkan pada penerapan data yang berada di luar *training set* membuktikan bahwa kemampuan generalisasi jaringan dengan menggunakan klasifikasi berdasarkan wavelet transform sebagai masukan, lebih baik dari pada jaringan yang tidak menggunakan wavelet transform pada tahap pembentukan data input.

5 KESIMPULAN

Tabel.6 menunjukkan nilai koefisien korelasi dan MSE dari semua uji coba yang dilakukan dalam penelitian ini. Metode yang diusulkan memiliki nilai koefisien yang lebih tinggi dengan error yang lebih kecil dibandingkan dengan penggunaan metode *backpropagation* biasa dan gardner equation untuk menentukan densitas.

Tabel 6. Koefisien korelasi dan MSE hasil validasi untuk seluruh percobaan.

Lapangan	Training Set	Method		F0201	F0304	F0601
F3	F0302	Conventional BP	MSE	0.626	0.364	0.76
			R	0.31	0.41	0.041
		Proposed BP	MSE	0.282	0.136	0.416
			R	0.91	0.92	0.82
				BYATES11	CYATES9	
Bonsville	BYATES18D	Gardner Equation	MSE	0.0027515	0.002402	
			R	0.5	0.58	
		Conventional BP	MSE	0.00167	0.00124	
			R	0.56	0.78	
		Proposed BP	MSE	0.0000572	0.00106	
			R	0.83	0.86	

Pada dasarnya, dengan hanya menggunakan satu log akan sangat sulit bagi jaringan *backpropagation* untuk melakukan estimasi data log lainnya. Penggunaan atribut tidak lazim digunakan untuk mengestimasi nilai log dari log lainnya. Studi ini menunjukkan bahwa attribute turunan yang berupa hasil klasifikasi data menggunakan jaringan kompetitif berdasarkan *wavelet transform* dapat membantu meningkatkan kemampuan generalisasi jaringan *backpropagation* meskipun data yang tersedia terbatas (hanya digunakan 1 jenis log untuk melakukan estimasi nilai log lainnya).

Perbedaan tingkat kesalahan (*Mean Square Error*) dan koefisien korelasi pada uji coba jaringan untuk mengenali pola yang sama sekali tidak ditemui pada data pelatihan (*blind test*) menunjukkan bahwa jaringan yang pada pelatihannya

memasukkan hasil klasifikasi berdasarkan *wavelet transform* sebagai input memiliki kemampuan generalisasi yang lebih baik (MSE turun secara signifikan) dari pada jaringan dengan data yang terbatas dan yang tidak melewati tahap *preprocessing* seperti yang dilakukan dalam studi ini.

Kesimpulan akhir yang dapat diambil adalah klasifikasi berdasarkan *wavelet transform* pada proses *preprocessing* atau pembentukan masukan pelatihan jaringan, akan meningkatkan kemampuan jaringan *back propagation* untuk mengestimasi nilai data log yang diinginkan.



6 SARAN

Hasil penelitian ini masih merupakan tahap awal yang dapat dielaborasi lebih lanjut. Penelitian ini baru sekedar membuktikan bahwa dekomposisi dengan wavelet transform dapat berperan untuk meningkatkan kemampuan jaringan backpropagation dalam melakukan estimasi nilai log yang ditunjukkan lewat peningkatan nilai validasi dari jaringan hasil pelatihan. Beberapa saran yang dapat menjadi perhatian bagi penelitian selanjutnya adalah :

1. Perlu dilakukan pengujian pada pasangan log dengan tipe lain seperti log resistivitas, saturasi, porositas dan lain-lain.
2. Quality control terhadap nilai log dengan data core akan menjadi point yang sangat mendukung hipotesis bila dapat dilakukan sebelum dipergunakan sebagai input dan target dalam menerapkan metode ini.
3. Sejauh ini, hasil penelitian ini baru dapat digunakan untuk mengestimasi data log dari data log tipe lain yang diketahui. Hasil ini dapat diperluas penggunaannya bila pengujian menggunakan metode yang sama dengan input trace seismik dan target data log berhasil dilakukan.

7 DAFTAR PUSTAKA

- Buffenmyer, V., Poulton, M. and Johnson, R. (2000). Identification of seismic crew noise in marine surveys by neural networks. *Leading Edge*, 19, 370–376.
- Calderón-Macías, C., Sen, M., and Stoffa, P. (1997). Hopfield neural networks, and mean field annealing for seismic deconvolution and multiple attenuation. *Geophysics*, 62, 992–1002.
- Calderón-Macías, C., Sen, M., and Stoffa, P. (1998). Automatic NMO correction and velocity estimation by a feedforward neural network. *Geophysics*, 63, 1696–1707.
- Chen, J., Liu, X., and Gu, X. (1991) Pattern recognition approach for automatic editing of seismic traces. 61st Ann. Internat. Mtg., Soc. Expl. *Geophysics*, 306–308.
- Dai, H., & McBeth, C. (1994). Split shear-wave analysis using an artificial neural network. *First Break*, 12, 605–613.
- Essenreiter, R., Karrenbach, M., and Treitel, S. (1998). Multiple reflection attenuation in seismic data using backpropagation. *IEEE Trans. Signal Processing*, 46, 2001–2011.
- Gardner, L.W. & Gregory, A.R. (1974). Formation velocity and density - the diagnostic basics for stratigraphic traps. *Geophysics*, 39, 770–780.
- Harsono, A. (1994), Teknik Evaluasi Log. *IATMI*, Chapter 19, 2-3.
- Liu, X., Xue, P., and Li, Y. (1989). Neural network method for tracing seismic events. 59th Ann. Internat. Mtg., Soc. Expl. *Geophys*, 716–718.
- Liu, Z., and Liu, J. (1998). Seismic-controlled nonlinear extrapolation of well parameters using neural networks. *Geophysics*, 63, 2035–2041.
- Loh, RH. (2003). Time series forecast with neural network and wavelet techniques. *The University of Queensland*, 7-18.

Polikar, R. (1999), The story of wavelet, in *Physics and Modern Topics in Mechanical and Electrical Engineering*, (ed. Mastorakis, N). *World Scientific and Eng. Society Press*, 192-197.

Polikar, R. (2003), The wavelet tutorial: Science Magazine's NetWatch Department, *Science*, 300, 873.

Poulton, M. (2002) Neural networks as an intelligence amplification tool: A review of applications. *Geophysics*, 67, 979–993.

Siang, J, J. (2005) Jaringan syaraf tiruan dan pemogramannya menggunakan MATLAB. Penerbit Andi.

