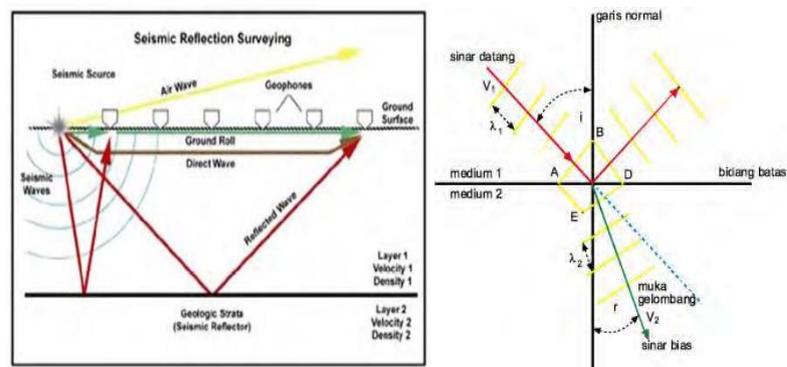


BAB III TEORI DASAR

3.1 Konsep Dasar Seismik Refleksi

Seismik refleksi dalam dunia *oil and gas* memiliki kontribusi yang sangat besar dalam menentukan titik pemboran karena memiliki rasio kesuksesan yang besar. Seismik refleksi merupakan metode yang didasarkan pada analisis refleksi gelombang seismik dari lapisan-lapisan batuan bawah permukaan. Survei seismik untuk eksplorasi memiliki konsep dengan mengirimkan sinyal gelombang yang memantul kembali ke permukaan bumi. Sumber gelombang buatan dibutuhkan guna menciptakan gelombang yang diinginkan dengan menggunakan dinamit jika survei di darat dan *air gun* jika survei dilakukan di laut. Alat untuk merekam gelombang seismik di darat berupa *geophone* dan *hidrophone* untuk di laut. (Zain, 2017).

Gelombang datang yang menuju pada beberapa litologi lapisan batuan akan mengalami proses penyerapan, pemantulan dan pembiasan. Adapun untuk respon batuan terhadap respon gelombang yang datang akan dapat berbeda-beda tergantung oleh sifat fisik pada suatu batuan yang meliputi umur batuan, kepadatan, densitas, kedalaman batuan, dan porositas. Gelombang yang akan dapat terpantul selanjutnya akan di respon atau tertangkap oleh *geophone* pada permukaan dan dapat diteruskan pada instrumen untuk selanjutnya direkam. Hasil rekaman dari gelombang akan menghasilkan penampang seismik.



Gambar 3.1 Proses Seismik Refleksi

Gelombang seismik dan gelombang cahaya memiliki respon yang sama, maka dari itu hukum-hukum yang digunakan pada gelombang seismik dan gelombang cahaya sama. Adapun hukum-hukum yang digunakan adalah sebagai berikut, prinsip Huygens mempunyai dasar bahwa setiap titik pada muka gelombang merupakan sumber dari gelombang baru yang menjalar dalam bentuk bola. Hal ini mengungkapkan sebuah mekanisme dimana sebuah pulsa seismik akan kehilangan energi dengan bertambahnya kedalaman. Selanjutnya gelombang yang terpantul akan mengikuti hukum pemantulan gelombang, yaitu hukum Snellius dimana gelombang akan dipantulkan atau dibiaskan pada bidang batas antara dua medium. Hukum Snellius tersebut dapat dinyatakan dengan persamaan matematis sebagai berikut:

$$\frac{\sin \theta_1}{\sin \theta_2} = \frac{v_1}{v_2} = \frac{n_2}{n_1}$$

Dengan keterangan :

v_1 = kecepatan gelombang pada medium 1 (n_1)

v_2 = kecepatan gelombang pada medium 2 (n_2)

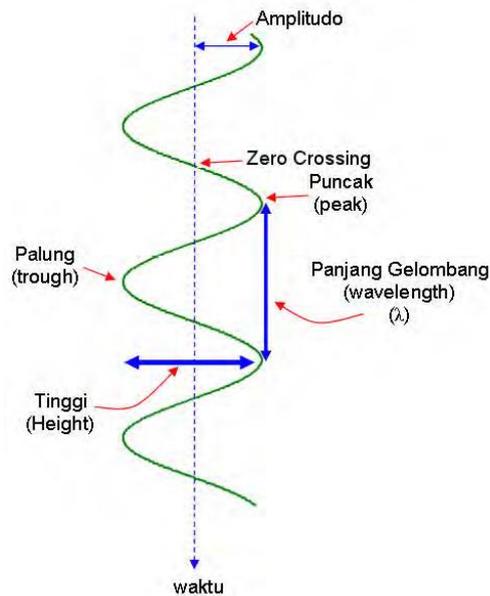
θ_1 = sudut pantul gelombang P

θ_2 = sudut bias gelombang P

Ketika gelombang seismik melalui lapisan batuan dengan impedansi akustik yang berbeda dari lapisan batuan yang dilalui sebelumnya, maka gelombang akan terbagi. Gelombang tersebut sebagian terefleksikan kembali ke permukaan dan sebagian diteruskan merambat dibawah permukaan. Selanjutnya prinsip Fermat menyatakan bahwa gelombang yang menjalar dari satu titik ke titik yang lain akan memilih lintasan dengan waktu tempuh tercepat.

3.2 Komponen Seismik Refleksi

Komponen seismik refleksi menunjukkan komponen sebuah gelombang (*seismic trace*) seperti amplitudo, puncak, palung, *zero crossing*, tinggi dan panjang gelombang. Kemudian dari parameter data dasar tersebut dapat diturunkan beberapa komponen lain seperti impedansi akustik, koefisien refleksi, polaritas, fasa, resolusi vertikal, *wavelet*, dan sintetik *seismogram*.



Gambar 3.2 Komponen dasar tras seismik (Abdullah, 2007)

3.2.1 Impedansi Akustik

Impedansi akustik atau *acoustic impedance* (AI) adalah kemampuan batuan untuk dapat melewatkan gelombang seismik yang melaluinya. Secara fisis, impedansi akustik merupakan hasil perkalian antara kecepatan gelombang dengan densitas batuan. Semakin keras suatu medium yang dilewatinya, maka nilai impedansi akustik akan semakin besar, sehingga dapat dituliskan :

$$AI = \rho \cdot V$$

Dengan keterangan :

AI = impedansi akustik (m/s. gr/m³)

ρ = densitas (gr/m³)

V = kecepatan gelombang seismik (m/s)

Kecepatan memiliki peran yang lebih penting dalam mengontrol nilai impedansi akustik karena perubahan kecepatan lebih signifikan dari pada perubahan densitas secara lateral maupun vertikal. Perubahan nilai impedansi akustik dapat menandakan perubahan karakteristik batuan seperti perubahan litologi, porositas kekerasan dan kandungan fluida. Impedansi akustik dapat dianalogikan yakni berbanding lurus dengan kekerasan batuan dan berbanding terbalik dengan porositas.

3.2.2 Koefisien Refleksi

Koefisien refleksi atau *reflectivity* merupakan suatu nilai yang mempresentasikan bidang batas antara dua medium yang memiliki impedansi akustik yang berbeda. Pada saat gelombang seismik membentuk sudut datang tegak lurus terhadap bidang pantul (*normal incidence*), maka koefisien refleksi dapat dinyatakan sebagai berikut:

$$R_c = \frac{(AI_2 - AI_1)}{(AI_2 + AI_1)}$$

Dengan keterangan :

R_c = koefisien refleksi

AI_1 = impedansi akustik lapisan atas

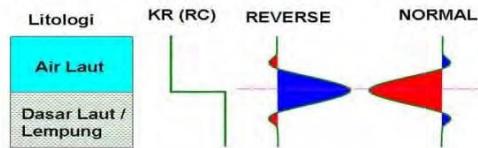
AI_2 = impedansi akustik lapisan bawah

Koefisien refleksi mempunyai nilai antara -1 sampai 1 . Jika impedansi akustik pada suatu lapisan lebih besar dari impedansi akustik lapisan di atasnya, atau gelombang merambat dari batuan dengan nilai densitas/kecepatan rendah ke batuan dengan harga densitas/kecepatan yang lebih tinggi, maka nilai koefisien refleksi akan positif. Harga kontras impedansi akustik dapat pula diperkirakan dari amplitudo refleksinya, semakin besar amplitudonya semakin besar refleksi dan kontras impedansi akustiknya (Sukmono, 1999).

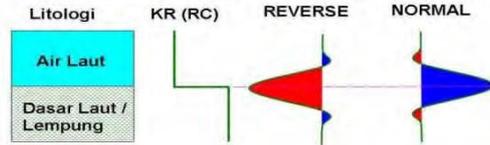
3.2.3 Polaritas

Polaritas adalah penggambaran koefisien refleksi sebagai suatu bentuk gelombang yang bernilai positif atau negatif. Jika $Z_2 > Z_1$ maka akan didapatkan bentuk puncak (*peak*), dan akan mendapatkan palung (*trough*) jika $Z_2 < Z_1$. Karena terdapat ketidakpastian dari bentuk gelombang seismik yang direkam maka dilakukan pendekatan bentuk polaritas yang berbeda yaitu polaritas normal dan polaritas terbalik (*reverse*). Saat ini terdapat dua jenis konvensi polaritas yaitu Standard SEG (*Society of Exploration Geophysicist*) dan Standard Eropa dan keduanya saling berkebalikan.

STANDAR SEG (ZERO PHASE)



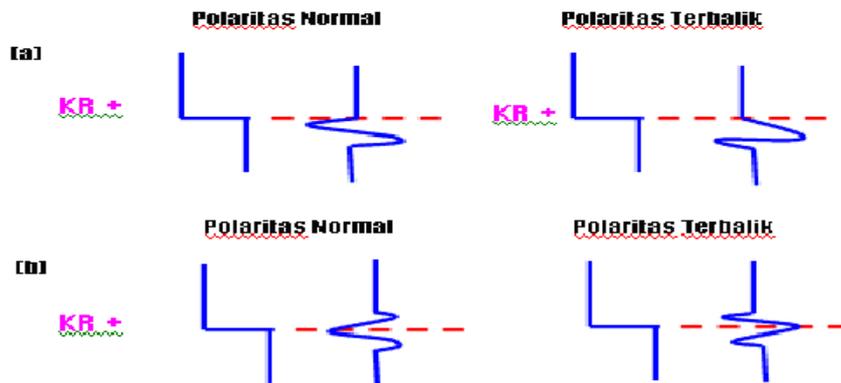
STANDAR EROPA (ZERO PHASE)



Gambar 3.3 Polaritas normal dan polaritas *reverse* (Abdullah, 2007)

3.2.4 Fasa

Sebuah *wavelet* memiliki panjang yang terbatas dengan fasa tertentu. Didalam istilah eksplorasi seismik, fasa sebuah *wavelet* dikenal sebagai fasa minimum, fasa nol dan fasa maksimum.



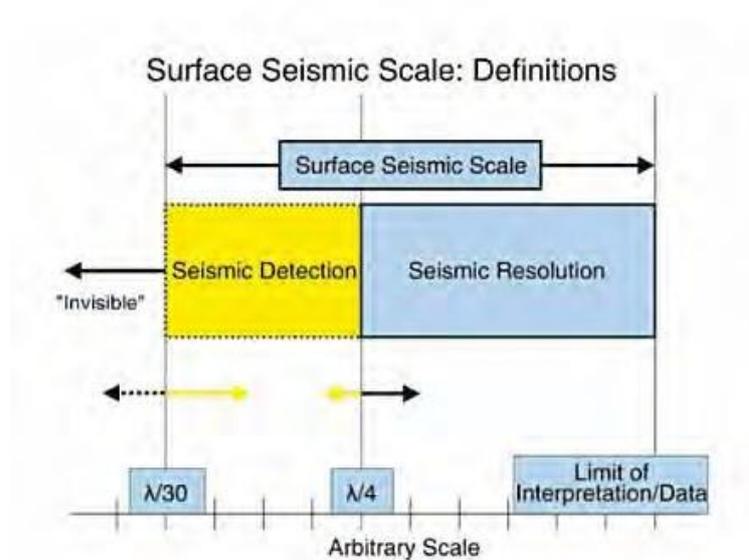
Gambar 3.4 Macam-macam fasa pada *wavelet* (Sukmono, 2000)

Sebagaimana ditunjukkan oleh gambar di atas, fasa minimum dicirikan jika sebagian besar energi amplitudo *wavelet* berada diawal, fasa nol dengan simetris di tengah-tengah dan fasa maksimum diakhir *wavelet*.

3.2.5 Resolusi Vertikal Seismik

Resolusi seismik adalah kemampuan gelombang seismik untuk memisahkan dua reflektor yang berdekatan. Ketebalan minimal yang masih dapat dibedakan disebut dengan ketebalan *tuning* (*tuning thickness*). Besarnya ketebalan *tuning*

adalah $\frac{1}{4}$ panjang gelombang seismik (λ), dimana $\lambda = v/f$ dengan v adalah kecepatan gelombang seismik (kompresi) dan f adalah frekuensi. Dimana kecepatan akan bertambah seiring bertambahnya kedalaman, sedangkan frekuensinya semakin rendah. Dengan demikian ketebalan *tuning* bertambah besar.



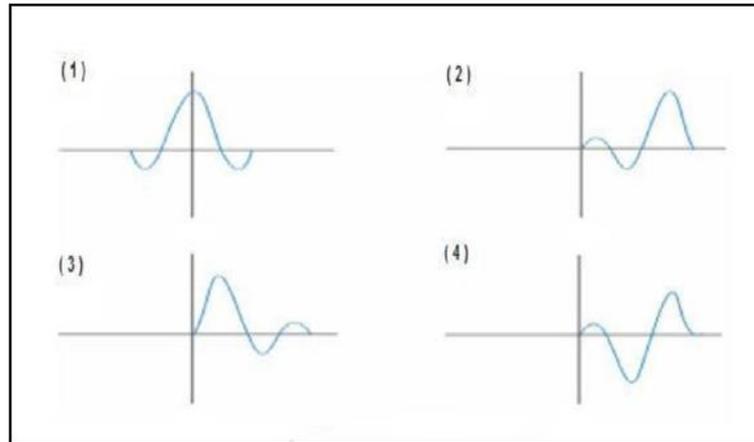
Gambar 3.5 Resolusi dan deteksi dari seismik ditunjukkan dengan persamaan gelombang seismik

Sedangkan deteksi seismik dapat dirumuskan hingga $\lambda/30$. artinya jika ketebalan dari *reservoir* masih diatas seismik deteksinya, maka *reservoir* tersebut masih dapat dideteksi oleh seismik. Resolusi ini sangat penting untuk diketahui karena sebagai justifikasi selanjutnya dalam tahap interpretasi selanjutnya, seperti *picking well bottom*, *picking horizon* dan analisa *window* pada analisa atribut seismik. Karena pada tahap tersebut perlu diketahui apakah pada ketebalan *reservoir* diatas resolusi seismiknya. Jika tebalnya di atas resolusinya, maka kita bisa membuat *picking well bottom* dan *picking bottom reservoir* di seismik. Sedangkan, pada analisa atribut kita bisa menggunakan analisa *window* antar horizon.

3.2.6 Wavelet

Wavelet adalah gelombang harmonik yang mempunyai interval amplitudo, panjang gelombang, frekuensi dan fasa tertentu. Dalam perekaman gelombang seismik, *wavelet* adalah gelombang pendek yang dihasilkan oleh sumber seperti

dinamit atau *airgun*. Gelombang pendek ini kemudian menjalar ke dalam bumi, terpantulkan dan terekam sebagai tras seismik pada *geophone* atau *hidrophone*. Ada empat jenis *wavelet* yang umum diketahui, yaitu *zero phase*, *minimum phase*, *maximum phase* dan *mixed phase*.



Gambar 3.6 Jenis-jenis *wavelet* berdasarkan konsentrasi energinya (Sukmono,1999)

1. *Zero Phase Wavelet*

Wavelet berfase nol konsentrasi energi maksimum di tengah dan waktu tunda nol, sehingga *wavelet* ini mempunyai resolusi dan *standout* yang maksimum. *Wavelet* berfase nol *wavelet* yang lebih baik dari semua jenis *wavelet* yang mempunyai *spectrum amplitude* yang sama.

2. *Maximum Phase Wavelet*

Wavelet berfase maksimum memiliki energi yang terpusat secara maksimal di bagian akhir dari *wavelet* tersebut, jadi merupakan kebalikan dari *wavelet* berfase minimum.

3. *Minimum Phase Wavelet*

Wavelet berfase minimum energi yang terpusat pada bagian depan. Dibandingkan jenis *wavelet* yang lain dengan spektrum amplitudo yang sama, *wavelet* berfase minimum mempunyai perubahan atau pergeseran fasa terkecil pada tiap-tiap frekuensi. Dalam terminasi waktu, *wavelet* berfase minimum memiliki waktu tunda terkecil dari energinya.

4. *Mixed Phase Wavelet*

Wavelet berfasa campuran *wavelet* yang energinya tidak terkonsentrasi di bagian depan maupun di bagian belakang.

3.2.7 *Seismogram Sintetik*

Sintetik *seismogram* adalah data seismik buatan yang dibuat dari data sumur yaitu log kecepatan dan densitas dengan menggunakan *wavelet* dari data seismik. Dengan mengalikan kecepatan dengan densitas maka akan mendapatkan deret koefisien refleksi. Koefisien refleksi ini kemudian dikonvolusikan dengan *wavelet* sehingga akan didapatkan *seismogram* sintetik pada daerah sumur tersebut. Konvolusi merupakan cara untuk mengombinasikan dua buah deret angka yang menghasilkan deret angka yang ketiga. Di dalam dunia seismik, deret-deret angka tersebut adalah *wavelet* sumber gelombang, reflektivitas bumi dan rekaman seismik.

$$S(t) = W(t) * r(t) + n(t)$$

Dengan keterangan :

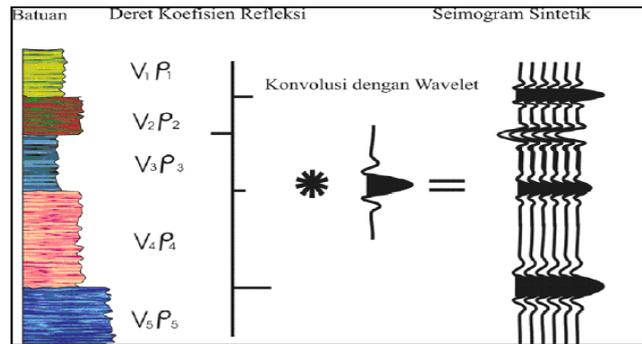
$S(t)$ = *trace* seismik

$W(t)$ = *wavelet* hasil dari ekstraksi seismik

$r(t)$ = koefisien refleksi hasil perkalian *p wave* dengan *density*

$n(t)$ = noise

Seimogram sintetik digunakan untuk mengikat data seismik dan juga data sumur. Data sumur berada dalam domain kedalaman (*depth*) sedangkan pada data seismik sendiri berada dalam domain waktu (TWT), maka tahap awal yang dilakukan adalah konversi data kedalaman pada sumur ke domain waktu pada seismik dengan langkah pembuatan *seismogram* sintetik dari sumur.

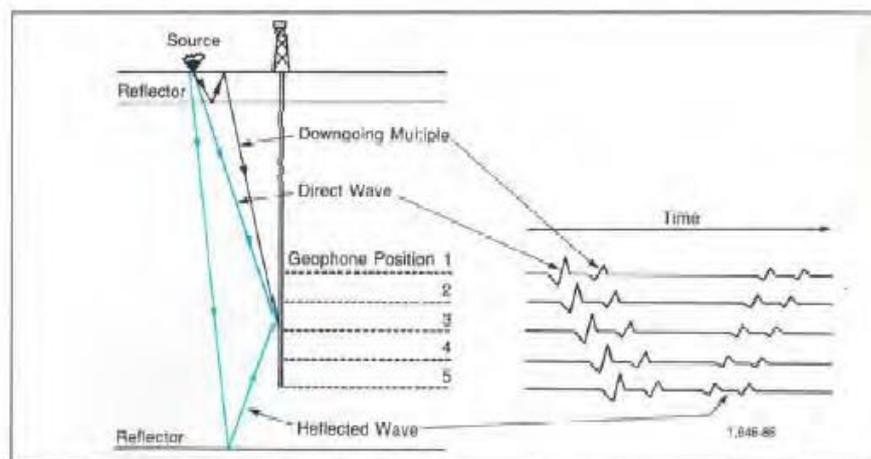


Gambar 3.7 Sintetik *seismogram* yang didapat dengan mengkonvolusikan koefisien refleksi dengan *wavelet* (Chevron Development Team, 2007)

Menurut Sukmono (1999), *seismogram* sintetik memiliki kelemahan yaitu umumnya dibuat dengan menggunakan frekuensi yang bernilai sama untuk keseluruhan penampang seismik, padahal frekuensi yang dipakai tersebut umumnya diambil dari zona target. Hal ini yang dapat menyebabkan *mis tie* atau kesalahan dalam pengikatan data pada di luar daerah zona target tersebut.

3.3 Checkshot

Tujuan dari survei *checkshot* adalah untuk mendapatkan hubungan domain waktu dan kedalaman yang digunakan untuk melakukan proses pengikatan data sumur dengan data seismik. Akusisi data *checkshot* dapat dilihat pada gambar berikut.



Gambar 3.8 Survei *checkshot* (Sukmono, 2007)

Pada prinsipnya survei *checkshot* sama seperti survei pada seismik, akan tetapi posisi *geophone* pada *checkshot* di letakkan di dalam lubang sumur, sedangkan sumber seismiknya diletakkan di permukaan dekat mulut sumur. Sehingga, di

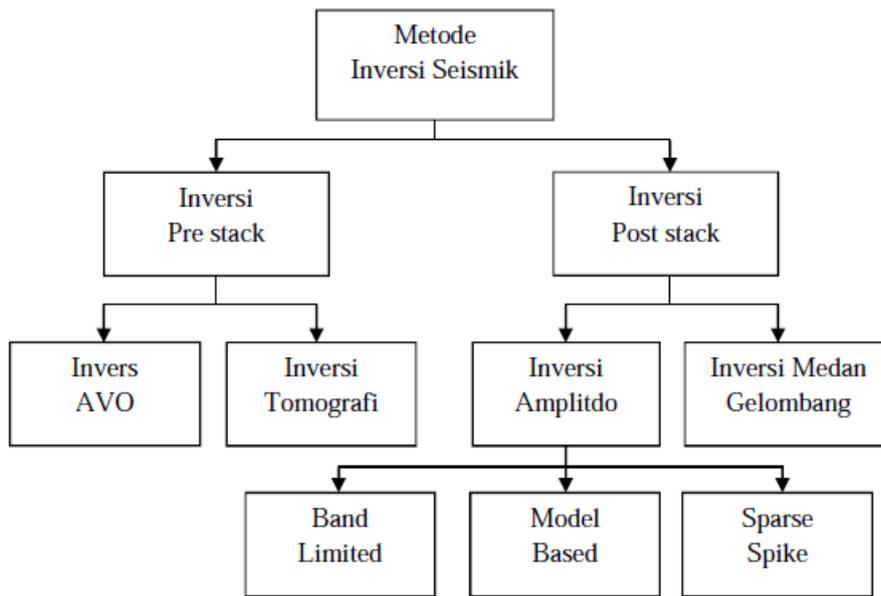
dapatkan waktu *one way time* yang direkam oleh *geophone* pada kedalaman tertentu. Dari sinilah dapat diketahui hubungan waktu penjalaran gelombang seismik pada sumur tersebut.

3.4 Well Seismic Tie

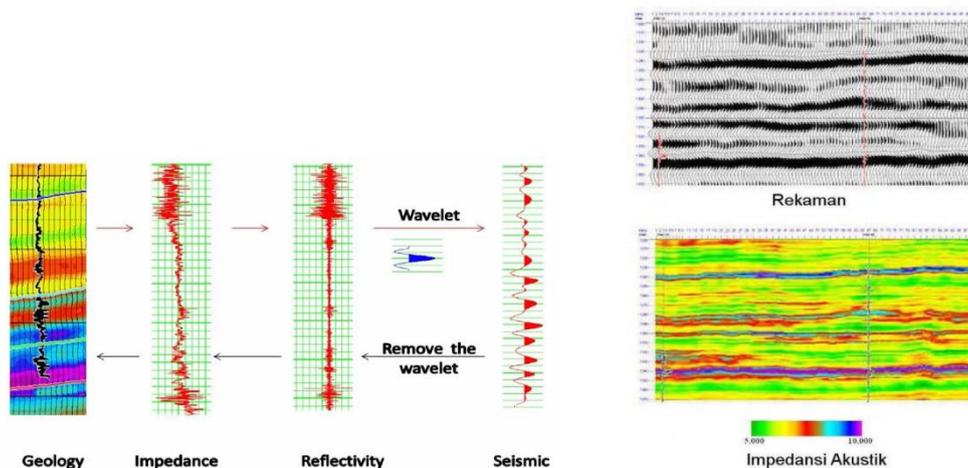
Well seismic tie adalah proses pengikatan data sumur dengan data seismik. Proses ini dilakukan untuk menyamakan domain sumur dengan seismik, karena domain sumur adalah kedalaman dalam meter, sedangkan domain seismik adalah waktu dalam satuan milisekon. Tujuan akhir dari proses pengikatan ini adalah untuk mengetahui posisi atau marker geologi pada data seismik. *Wavelet* yang digunakan sebaiknya mempunyai frekuensi dan *bandwidth* yang sama dengan penamapang seismik. Hal ini akan mempermudah pengikatan data sumur dengan data seismik. *Seismogram* sintetik final merupakan superposisi dari refleksi-refleksi semua reflektor. *Seismogram* sintetik biasanya ditampilkan dengan format dengan rekaman seismik. *Seismogram* sintetik berguna untuk mendiagnosa karakter refleksi dari setiap horizon (Hardiyansah, 2015).

3.5 Seismik Inversi

Pengertian secara lebih spesifik tentang seismik inversi dapat didefinisikan sebagai suatu teknik pembuatan model bawah permukaan dengan menggunakan data seismik sebagai *input* dan data sumur sebagai kontrol (Sukmono, 2000). Definisi tersebut menjelaskan bahwa metode inversi merupakan kebalikan dari pemodelan dengan metode ke depan (*forward modelling*) yang berhubungan dengan pembuatan *seismogram* sintetik berdasarkan model bumi. Russell (1998) membagi metode seismik inversi ke dalam dua kelompok, yaitu inversi *pre stack* dan inversi *post stack*. Pada penelitian ini akan dibahas inversi *post stack* yang berhubungan dengan inversi amplitudo, di mana dalam inversi ini terdiri dari beberapa algoritma, yaitu inversi *bandlimited* (rekursif), inversi *model based* dan inversi *spirse spike*.



Gambar 3.9 Klasifikasi metode inversi seismik (Russell, 1998)



Gambar 3.10 Konsep dari inversi Impedansi Akustik

3.5.1 Inversi Seismik Rekursif/*Bandlimited*

Inversi rekursif adalah algoritma inversi yang mengabaikan efek *wavelet* seismik dan memperlakukan seolah-olah *trace* seismik merupakan kumpulan koefisien refleksi yang telah di *filter* oleh *wavelet* fasa nol. Metode ini paling awal digunakan untuk menginversi data seismik dengan persamaan dasar:

$$r_i = \frac{\rho_{i+1} V_{i+1} - \rho_i V_i}{\rho_{i+1} V_{i+1} + \rho_i V_i} = \frac{Z_{i+1} - Z_i}{Z_{i+1} + Z_i}$$

Dengan keterangan:

r = koefisien refleksi

ρ = densitas

V = kecepatan gelombang P

Z = impedansi akustik (AI)

Metode ini paling awal digunakan untuk impedansi lapisan ke $i+1$ dapat dihitung dari lapisan ke i dengan persamaan:

$$Z_{i+1} = Z_i * \frac{1+r_i}{1-r_i}$$

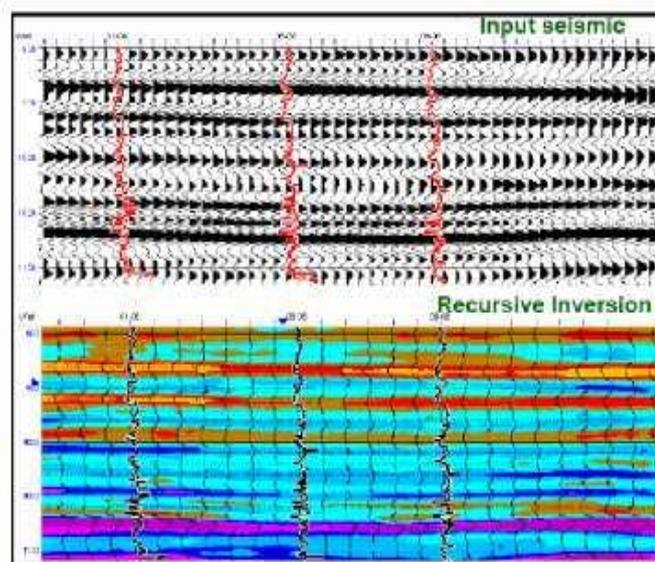
Dimulai dari lapisan pertama, impedansi lapisan berikutnya ditentukan secara rekursif dan tergantung nilai impedansi akustik lapisan di atasnya dengan perumusan sebagai berikut:

$$Z_n = Z_i * \prod \frac{1+r_i}{1-r_i}$$

Dengan keterangan :

Z = impedansi akustik

r = koefisien refleksi



Gambar 3.11 *Input dan Output Inversi Seismik Bandlimited* (Russell, 1996)

Keuntungan metode *bandlimited* yaitu metode ini merupakan metode yang sederhana dengan algoritma yang terbatas yang memberikan hasil berupa resolusi dengan *bandwidth* yang sama dengan data seismik.

Kekurangan menggunakan metode inversi *bandlimited* diantaranya:

1. Proses inversi tidak menggunakan estimasi *wavelet*.
2. Sensitif terhadap *noise* akibat tidak memperhitungkan bentuk *wavelet* dasar, sehingga dapat menghasilkan lapisan baru yang semu karena data seismik yang mengandung *noise* akan terbawa dalam proses inversi.
3. Seismik inversi rekursif didasarkan pada dekonvolusi klasik yang mengasumsikan reflektivitas *random* dan *wavelet* dengan fasa minimum atau fasa nol, akibatnya hanya dihasilkan *wavelet* berfrekuensi tinggi dan tidak mencakup deret koefisien refleksi secara lengkap.
4. Sangat bergantung dengan penentuan AI lapisan pertama. Apabila tidak tepat akan terjadi penumpukan masalah.

3.5.2 Inversi Seismik Model Based

Metode inversi berbasis model (*model based inversion*) disebut juga metode *blocky* karena impedansi akustik tersusun dari blok-blok kecil. Konsep inversi dengan metode ini dimulai dengan membuat model awal impedansi akustik dengan ukuran blok yang telah ditentukan. Koefisien refleksi diturunkan dari impedansi akustik dan dikonvolusikan dengan *wavelet* yang menghasilkan *seismogram* sintetik pada tiap-tiap *trace*. Secara matematis, *model based inversion* dapat dirumuskan dengan :

$$St = Wt * RCt + nt$$

Dengan keterangan :

St = *trace* seismik

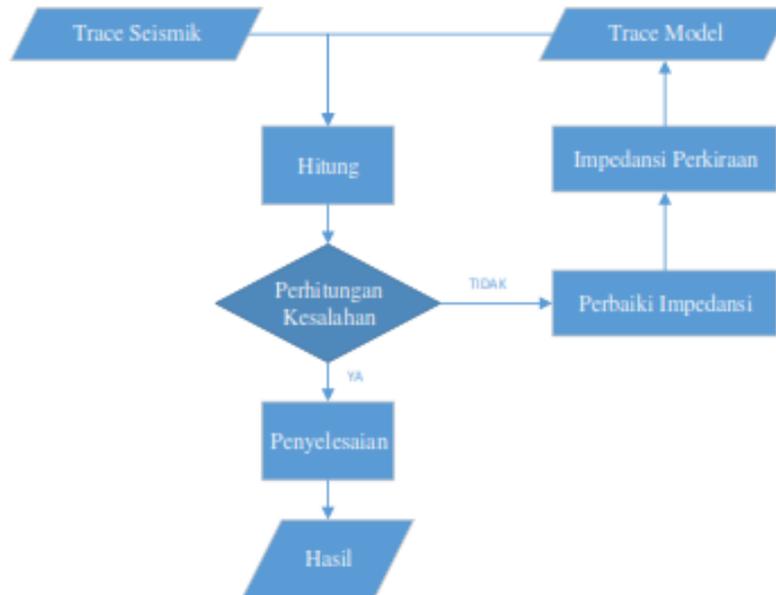
Wt = *wavelet* seismik

RCt = reflektivitas bumi

nt = *noise*

Prinsip sederhana metode ini adalah membuat model geologi, kemudian model tersebut dibandingkan dengan data seismik (tras seismik asli), diperbaharui secara iteratif sehingga didapatkan kecocokan yang lebih baik dengan data seismik. Semakin banyak iterasinya maka koefisien korelasi antara seismik sintetik dan seismik riilnya akan semakin besar dan *error*-nya semakin kecil (Danusaputro, 2010). Pembangunan model awal yang baik merupakan salah satu kunci utama

dalam menghasilkan hasil inversi yang akurat. Metode ini dikembangkan untuk mengatasi masalah yang tidak dapat dipecahkan menggunakan metode rekursif diantaranya yaitu pengaruh akumulasi *noise*, *bad amplitude* dan *bandlimited* seismik data (Sukmono, 2000). Teknik ini dapat dijelaskan melalui diagram alir berikut:



Gambar 3.12 Alur Metode Inversi *Model Based* (Rachman, 2009).

Keuntungan penggunaan metode inversi berbasis model antara lain:

1. Metode ini menghindari inversi secara langsung dari data seismik melainkan menginversi model geologinya.
2. Resolusi meningkat karena proses inversi dilakukan dengan data dari model geologi.
3. Nilai kesalahan terdistribusi dalam solusi dari proses inversi.
4. Dapat memberikan kemenerusan lateral impedansi akustik yang baik dalam membedakan lapisan antar batuan.

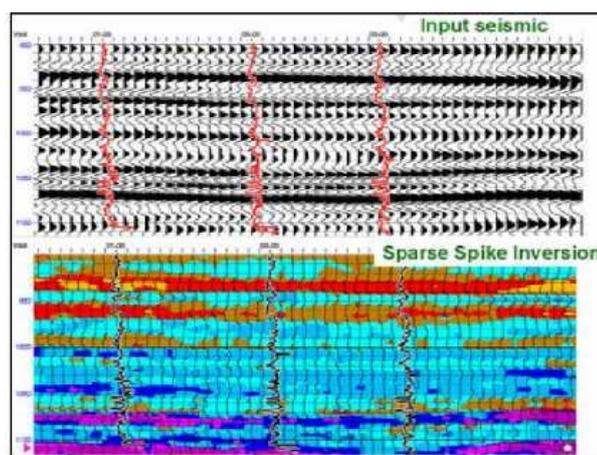
Kekurangan menggunakan metode inversi berbasis model adalah:

1. Sangat bergantung pada *wavelet* dan model geologi.
2. Sifat sensitif terhadap bentuk *wavelet*, dimana dua *wavelet* berbeda dapat menghasilkan *trace* seismik yang sama.

3. Sifat ketidakunikan untuk *wavelet* tertentu dimana semua hasil sesuai dengan *trace* seismik pada lokasi sumur yang sama.
4. Kesalahan pada estimasi *wavelet* dan pembuatan model geologi akan memengaruhi hasil inversi.
5. Membutuhkan banyak sumur untuk menghasilkan kualitas data yang lebih baik.
6. Frekuensi tinggi pada hasil inversi disebabkan oleh model geologinya bukan dari data seismik.

3.5.3 Inversi Seismik *Sparse Spike*

Metode *sparse spike* ini mengasumsikan bahwa reflektivitas yang sebenarnya dapat diasumsikan sebagai seri dari *spike-spike* besar yang bertumpukan dengan *spike-spike* yang lebih kecil sebagai *background*. Kemudian, dilakukan estimasi *wavelet* berdasarkan asumsi model tersebut. *Sparse spike* mengasumsikan bahwa hanya *spike* yang besar yang penting. Inversi ini mencari lokasi *spike* yang besar dari *trace* seismik. *Spike-spike* tersebut terus ditambahkan sampai *trace* dimodelkan secara akurat. Inversi *sparse spike* menggunakan parameter yang sama dengan inversi *model based*. Parameter yang utama adalah parameter untuk menghitung berapa banyak *spike* yang akan dipisahkan dalam setiap *trace*. *Spike* yang baru lebih kecil daripada *spike* sebelumnya (Hampson dan Russel, 2006).



Gambar 3.13 *Input dan Output* Inversi Seismik *Sparse Spike* (Russel, 1996)

Hasil inversi menggunakan metode *sparse-spike* didapatkan solusi yang *unique* karena informasi frekuensi rendah juga masuk kedalam solusi inversi dan kita

mendapatkan hasil inversi secara geologi. *Constraint* digunakan untuk mengatur toleransi inversi terhadap nilai *error* yang terjadi selama proses inversi. Inversi dengan metode ini baik digunakan untuk data yang memiliki nilai *noise* yang tinggi.

Keuntungan penggunaan metode inversi *sparse spike* antara lain:

1. Data yang digunakan dalam perhitungan sama seperti pada proses inversi rekursif.
2. Baik untuk diaplikasikan pada target yang memiliki reflektivitas yang tinggi. Informasi frekuensi rendah termasuk dalam solusi secara matematik.
3. Tidak terlalu bergantung pada model awal.

Kekurangan metode inversi *sparse spike* antara lain:

1. Secara statistik, subjek metode *inverse* jenis ini digunakan untuk data yang mempunyai masalah *noise*.
2. Tidak dapat diaplikasikan pada reflektivitas yang rendah.
3. Dapat menghasilkan solusi *event* lebih sedikit dari *event* geologi.

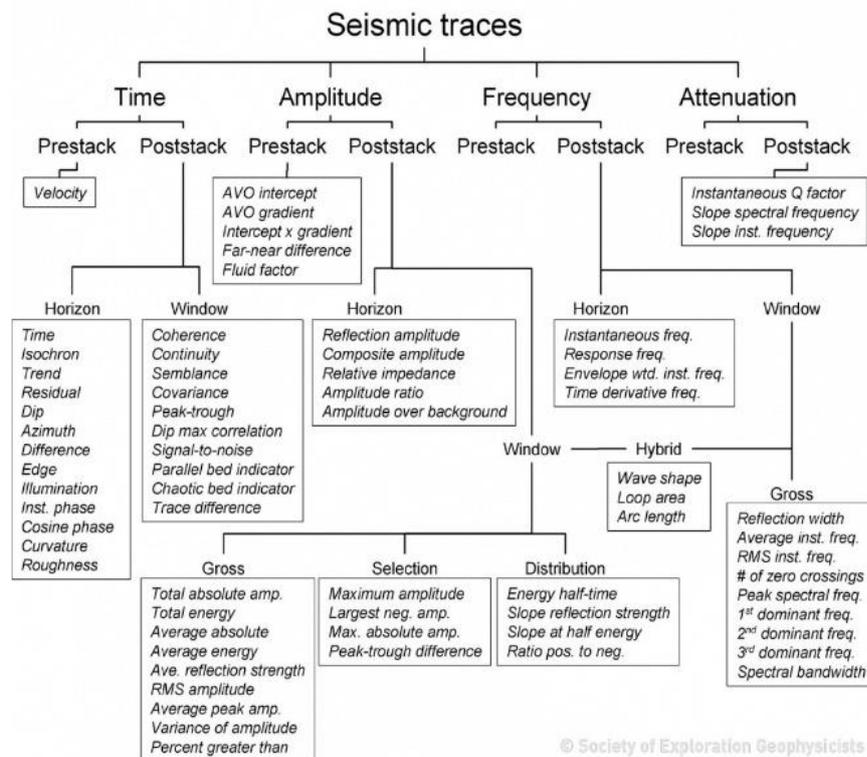
3.6 Atribut Seismik

Atribut seismik dapat didefinisikan sebagai semua informasi berupa besaran spesifik dari geometri, kinematika, dinamika atau statistik yang diperoleh dari data seismik, yang diperoleh melalui pengukuran langsung maupun logis atau berdasarkan pengalaman (Chien dan Sidney, 1997).

Data seismik tidak selalu memberikan informasi parameter petrofisika atau geologi. Keberadaan data *well log* dapat membantu memperlihatkan relasi antara data seismik dan parameter log, namun relasi ini sangat sulit ditentukan. Dalam hal ini atribut seismik dapat memberikan bantuan yang berarti. Jika terdapat relasi antara parameter geologi dan atribut seismik pada suatu titik *well log* maka parameter geologi diluar titik *well log* ini dapat diekstrapolasi. Oleh karena itu atribut seismik menyediakan tambahan informasi parameter petrofisika atau geologi yang penting bagi para *interpreter* untuk meningkatkan kesensitifan data seismik.

Semua atribut horizon dan formasi tidak independen satu sama lainnya. Perbedaannya hanya dalam hal detail analisisnya pada informasi dasar gelombang seismik terkait dengan *display* hasilnya. Informasi dasar tersebut adalah waktu, amplitudo, frekuensi, dan atenuasi, yang kemudian digunakan sebagai dasar klasifikasi atribut (Brown, 2000).

Setiap atribut seismik memiliki kelebihan dan kekurangan masing-masing. Pada sifat *reservoir* tertentu, beberapa atribut lebih sensitif dibandingkan dengan atribut lainnya, sedangkan atribut yang lain mungkin juga dapat menampilkan informasi bawah permukaan yang mula-mula tersembunyi menjadi lebih baik, atau bahkan dapat mendeteksi *Direct Hydrocarbon Indicator* (DHI).



Gambar 3.14 Klasifikasi seismik atribut (SEG, 2015)

3.7 Metode Seismik Multiatribut

Analisa seismik multiatribut adalah salah satu metode statistik yang menggunakan lebih dari satu atribut untuk memprediksi beberapa properti fisik dari bumi. Pada analisa ini dicari hubungan antara log dengan data seismik pada lokasi sumur, kemudian menggunakan hubungan tersebut untuk memprediksi atau mengestimasi *volume* dari properti log pada semua lokasi pada *volume* seismik.

Statistik dalam karakteristik *reservoir* digunakan untuk mengestimasi dan membuat simulasi hubungan spasial variabel pada nilai yang diinginkan pada lokasi yang tidak mempunyai data sampel terukur. Hal tersebut didasarkan pada kenyataan yang sering terjadi di alam, yaitu pengukuran suatu variabel di suatu area yang berdekatan adalah sama. Kesamaan antara dua pengukuran tersebut akan menurun seiring dengan bertambahnya jarak pengukuran.

3.7.1 Atribut Internal

Atribut seismik dapat dibagi ke dalam dua kategori:

1. *Horizon based attributes* dihitung sebagai nilai rata-rata antara dua horizon.
2. *Sample based attributes* merupakan transformasi dari *tras input* untuk menghasilkan *tras output* lainnya dengan jumlah yang sama dengan *tras input* (nilainya dihitung sampel per sampel).

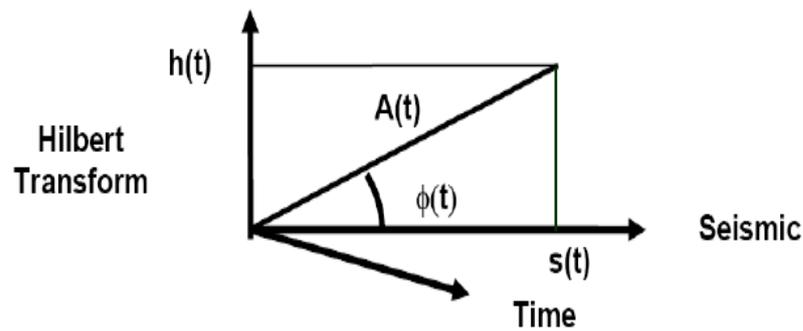
Atribut yang digunakan dalam analisa multiatribut menggunakan perangkat lunak EMERGE harus dalam bentuk *sample based attributes*. Atribut-atribut tersebut dapat dikelompokkan kedalam enam kategori, yaitu :

1. Atribut Sesaat (*Instantaneous Attribute*) atau Atribut Kompleks

Atribut kompleks pertama kali diperkenalkan oleh Taner dkk. Macam-macam atribut sesaat yaitu:

- a. Kuat refleksi
- b. Fasa sesaat
- c. Frekuensi sesaat
- d. Kosinus fasa sesaat
- e. Polaritas semu
- f. *Amplitude weighted cosine*
- g. *Amplitude weighted frequency*
- h. *Amplitude weighted phase*

Atribut tersebut dihitung dari *tras kompleks* $C(t)$, yang terdiri dari *tras seismik* $s(t)$ dan transformasi Hilbertnya $h(t)$, yang merupakan pergeseran fasa sebesar 90° dari *trace* seismik.



Gambar 3.15 Penulisan tras kompleks dalam bentuk polar (Russell, 2006)

Penulisan tras kompleks dalam bentuk polar, seperti yang terlihat pada Gambar 3.15, memberikan dua atribut dasar, yaitu kuat refleksi $A(t)$ dan fasa sesaat $\Phi(t)$.

$$\begin{aligned}
 C(t) &= s(t) + ih(t) \\
 &= A(t)e^{i\phi(t)} \\
 &= A(t)\cos\phi(t) + iA(t)\sin\phi(t) ; i = \sqrt{-1}
 \end{aligned}$$

Sehingga,

$$\begin{aligned}
 A(t) &= \sqrt{s(t)^2 + h(t)^2} \\
 \phi(t) &= \tan^{-1} \left[\frac{h(t)}{s(t)} \right]
 \end{aligned}$$

Atribut dasar yang ketiga adalah frekuensi sesaat yang merupakan turunan waktu dari fasa sesaat. Persamaan frekuensi sesaat tersebut dapat ditulis sebagai berikut:

$$\omega(t) = \frac{d\phi(t)}{dt}$$

Atribut-atribut lainnya merupakan kombinasi dari tiga atribut dasar tersebut, seperti berikut:

- $\cos\phi(t)$ = kosinus fasa sesaat
- $A(t)\cos\phi(t)$ = amplitudo dikalikan kosinus fasa sesaat
- $A(t)\phi(t)$ = amplitudo dikalikan fasa sesaat
- $A(t)\omega(t)$ = amplitudo dikalikan frekuensi sesaat

2. Atribut Jendela Frekuensi (*Windowed Frequency Attributes*)

Set atribut tersebut didasarkan pada *windowed frequency analysis* atau analisa frekuensi menggunakan *window*. Pada proses ini, *fourier transform* dari setiap tras seismik pada proses tersebut diambil sebanyak 64 sampel (*default*). Dari *window*

ini, baik amplitudo frekuensi rata-rata maupun amplitudo frekuensi dominan digunakan, kemudian nilainya ditempatkan pada tengah-tengah *window*. Sebanyak 32 sampel dan atribut frekuensi yang baru kemudian dipilih untuk *window* baru, lalu dihitung, dan demikian seterusnya. Macam-macam dari atribut ini yaitu :

- a. *Average frequency amplitude*
- b. *Dominant frequency*

3. Atribut *Filter Slice*

Set ketiga dari atribut terdiri dari *narrow band filter slices* dari tras seismik. Enam *slices* yang digunakan adalah sebagai berikut:

- a. 5/10 – 15/20 Hz
- b. 15/20 – 25/30 Hz
- c. 25/30 – 35/40 Hz
- d. 35/40 – 45/50 Hz
- e. 45/50 – 55/60 Hz
- f. 55/60 – 65/70 Hz

4. Atribut Turunan (*Derivative Attributes*)

Set keempat dari atribut didasarkan pada turunan pertama atau kedua dari tras seismik ataupun dari *amplitude envelope* (amplitudo sesaat). Turunan tersebut dihitung melalui cara berikut:

$$d1 = \frac{S_i - S_{i-1}}{\Delta t}$$

$$d2 = \frac{d1_i - d1_{i-1}}{\Delta t} = \frac{S_i - 2S_{i-1} - S_{i-2}}{\Delta t^2}$$

Dengan keterangan:

- S_i = sampel tras seismik atau *amplitude envelope* ke i
- $d1_i$ = turunan pertama dari i
- $d2_i$ = turunan kedua dari i
- Δt = *interval sampling*

Macam-macam dari atribut ini antara lain:

- a. *Derivative of the seismic trace*
- b. *Derivative instantaneous amplitude*
- c. *Second derivative of the seismic trace*
- d. *Second derivative instantaneous amplitude*

5. *Integrated Attributes*

Jenis kelima dari atribut yang terdapat pada EMERGE didasarkan pada integrasi dari tras seismik atau kuat refleksi. Nilai integrasi dihitung dengan cara berikut:

$$I_i = S_i + I_{i+1}$$

Dengan keterangan :

S_i = sampel ke-i dari tras seismik atau nilai kuat refleksinya

I_i = nilai integrasi

Sebagai catatan bahwa ini merupakan penjumlahan berjalan (*running sum*). Integrasi seimik pada akhir penjumlahan berjalan di *filter* menggunakan 50 titik, sehingga dihasilkan tras seimik dengan frekuensi rendah. Integrasi dari kuat refleksi dinormalisasi dengan membagi hasil integrasi dengan perbedaan antara sampel minimum dan maksimum dari keseluruhan sampel. Macam-macam atribut ini yaitu:

- a. *Integrated seismic trace*
- b. *Integrated reflection strength*

6. Atribut Waktu (*Time Attributes*)

Atribut terakhir dari EMERGE adalah atribut waktu. Atribut tersebut sangat sederhana, merupakan nilai waktu dari tras seismik, sehingga membentuk sebuah fungsi "*ramp*" yang dapat menambah sebuah *trend* dalam menghitung parameter *reservoir*. Perangkat lunak EMERGE lalu mencari hubungan antara properti log dan kombinasi atribut dari tras seismik pada interval target.

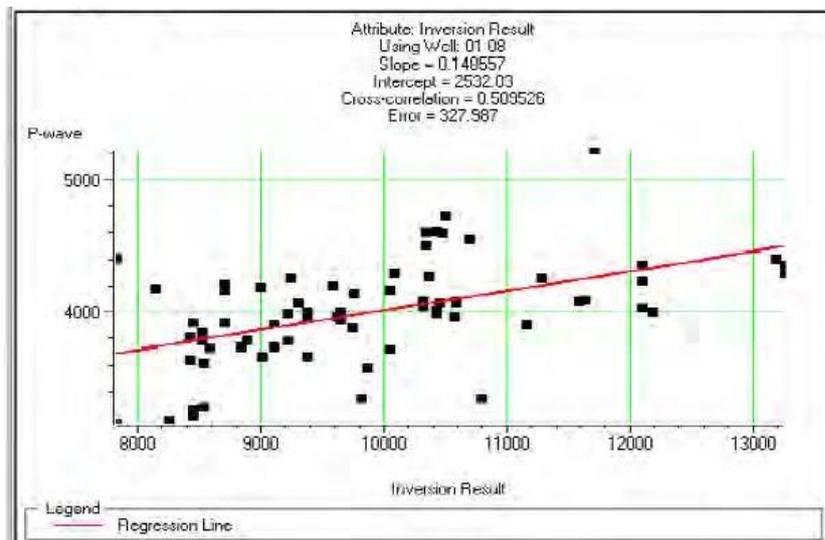
3.7.2 Crossplot

Salah satu cara untuk mengukur korelasi antara data target dan atribut adalah dengan melakukan *crossplot* antara keduanya. Gambar 3.16 memperlihatkan *crossplot* target (*P-wave*) sebagai sumbu vertikal dengan suatu atribut tertentu, dalam hal ini hasil inversi. Hubungan linier antara log target dan atribut ditunjukkan oleh sebuah garis lurus yang memenuhi persamaan:

$$y = a + b * x$$

Koefisien a dan b pada persamaan ini diperoleh dengan meminimalisasikan *mean-square prediction error* :

$$E^2 = \frac{1}{N} \sum_{i=1}^N (y_i - a - b * x_i)^2$$

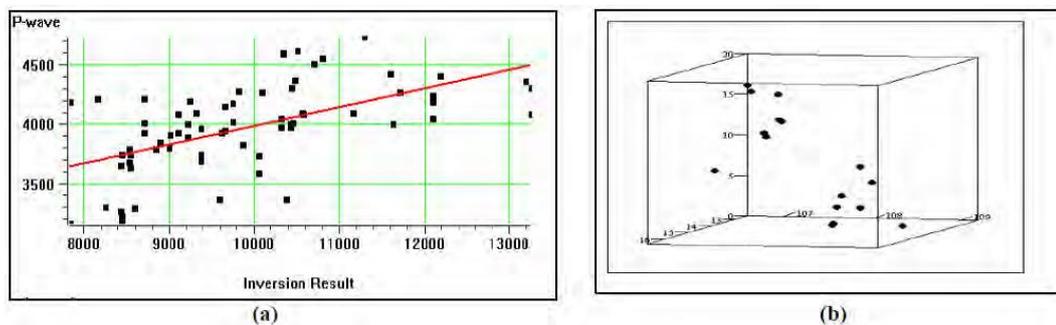


Gambar 3.16 Konvensional *Crossplot* antara log target dan atribut seismik (Russell,2006)

Dengan mengaplikasikan garis linier tersebut, dapat diprediksi atribut mana yang cocok digunakan untuk menyusun log target. Dalam kasus multiatribut, semua yang dimasukkan akan secara otomatis diperingkat oleh sistem, dari yang memiliki korelasi paling tinggi dan nilai *error* yang paling kecil ke atribut yang memiliki korelasi lebih rendah dan *error* yang lebih besar (Russell, 2006). Prediksi *error* tersebut merupakan perbedaan RMS antara target log sebenarnya dan target log prediksi.

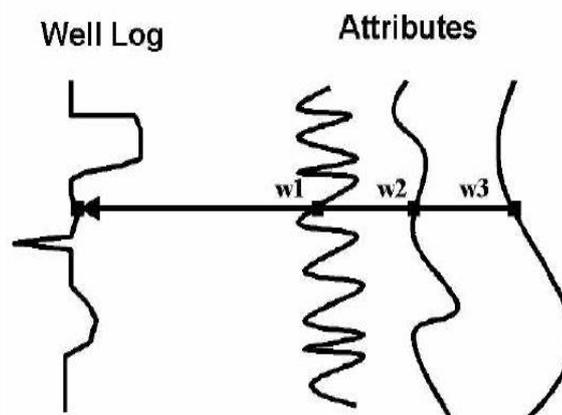
3.7.3 Regresi Linear Multiatribut

Regresi linear multiatribut merupakan pengembangan dari *crossplot* konvensional. Metode tersebut bertujuan untuk mencari sebuah operator yang dapat memprediksi log sumur dari data seismik didekatnya. Pada kenyataannya, kita menganalisa data atribut seismik dan bukan data seismik itu sendiri. Salah satu alasan mengapa hal tersebut dilakukan karena menggunakan data atribut seismik lebih menguntungkan daripada data seismik itu sendiri. Banyak dari atribut tersebut bersifat non linier, sehingga mampu meningkatkan kemampuan prediksi.



Gambar 3.17 Ilustrasi *Cross-plot* menggunakan (a) satu atribut dan (b) dua atribut (Russel, 2006)

Pengembangan (*extension*) analisa linier konvensional terhadap *multiple* atribut (regresi linier multiatribut) dilakukan secara langsung. Sebagai penyederhanaan, kita mempunyai tiga atribut seperti yang terlihat pada Gambar 3.18.



Gambar 3.18 Contoh kasus tiga atribut seismik, tiap sampel log target dimodelkan sebagai kombinasi linier dari sampel atribut pada interval waktu yang sama. (Russell, 2006)

Cara memilih kombinasi atribut yang paling baik untuk memprediksi log target adalah dengan melakukan sebuah proses yang dinamakan *step-wise regression*:

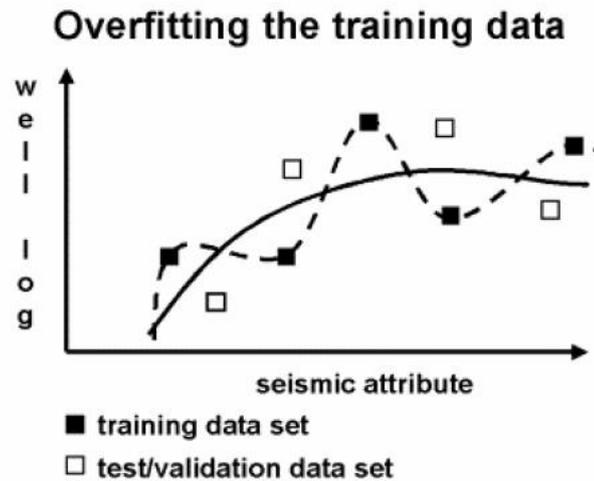
1. Mencari atribut tunggal pertama yang paling baik menggunakan *trial and error*. Prediksi *error* setiap atribut yang terdapat pada *software* dihitung. Atribut terbaik adalah atribut yang memberikan prediksi *error* terendah. Atribut tersebut selanjutnya akan disebut atribut a.
2. Mencari pasangan atribut yang paling baik dengan mengasumsikan anggota pasangan yang pertama adalah atribut a. Pasangan yang paling baik adalah pasangan yang memberikan *error* paling kecil. Atribut ini selanjutnya akan disebut atribut b.
3. Mencari tiga buah atribut yang berpasangan paling baik, dengan mengasumsikan dua buah anggota yang pertama atribut a dan atribut b. Tiga buah atribut yang paling baik adalah yang memberikan *error* prediksi paling kecil.

Prediksi tersebut terus berlangsung sebanyak yang diinginkan. *Error* prediksi, E_n , untuk n atribut selalu lebih kecil atau sama dengan E_{n-1} untuk $n-1$ atribut, tidak peduli atribut mana yang digunakan. Oleh karena itu dibutuhkan validasi untuk mengetahui jumlah atribut yang paling baik untuk digunakan.

3.7.4 Validasi Silang

Pertanyaan selanjutnya yang harus dijawab adalah kapan kita harus berhenti menambahkan jumlah atribut. Bagaimanapun juga transformasi multiatribut dengan jumlah atribut $N+1$ selalu mempunyai prediksi *error* lebih kecil atau sama dengan transformasi dengan N atribut. Menambah jumlah atribut sama dengan mencari kurva regresi yang cocok untuk sebuah plot data, dengan menggunakan polinomial yang ordenya semakin besar.

Apabila jumlah atribut yang digunakan semakin banyak, maka *error* prediksi akan semakin berkurang. Masalah yang kemudian timbul adalah biasanya data yang dihasilkan akan buruk bila diterapkan pada data baru (yang tidak termasuk dalam data *training*), karena atribut tersebut terlalu dicocokkan dengan data *training*. Hal tersebut biasa disebut dengan *overtraining*.



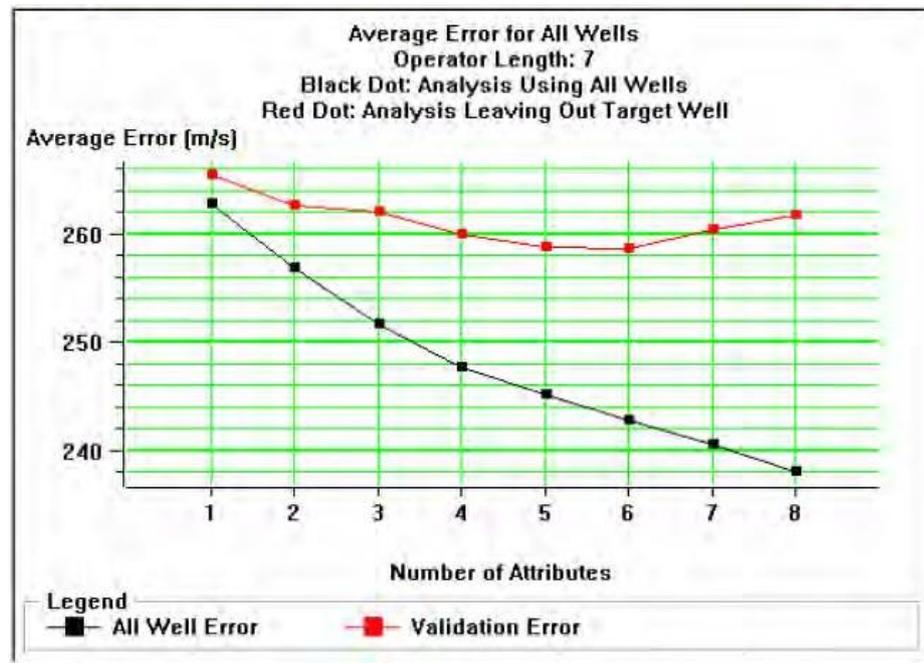
Gambar 3.19 Ilustrasi Validasi Silang (Rusnel, 2006)

Kedua kurva digunakan untuk mencocokkan data. Kurva putus-putus menunjukkan korelasi yang baik dengan data *training*. Namun, buruk jika kemudian digunakan set data validasi. Untuk mengukur validitas dari jumlah atribut yang digunakan, dilakukan prosedur sebagai berikut. Misalnya, terdapat tiga buah atribut dan lima buah *well*. Untuk perhitungan pertama, sumur pertama tidak diikuti pada perhitungan pertama. Kemudian koefisien regresinya dihitung tanpa menggunakan data dari sumur pertama. Berdasarkan nilai koefisien yang dihasilkan, prediksi *error* kemudian dihitung dari sumur satu dengan rumus:

$$E^2 = \frac{1}{N} \sum_{i=1}^N (\varphi_i - w_0 - w_1 A_{1i} - w_2 A_{2i} - w_3 A_{3i})^2$$

Hal tersebut adalah *error* validasi untuk sumur satu. Proses tersebut kemudian diulang untuk sumur 2, sumur 3, dan sumur 4. *Error* rata-ratanya dihitung dengan:

$$E_{avg} = \frac{(E_1 + E_2 + E_3 + E_4 + E_5)}{5}$$



Gambar 3.20 Contoh *Plot Validation Error* dan *Prediction Error* (Russel 2006)

Kurva berwarna hitam menunjukkan *error* prediksi yang dihitung menggunakan data *training*. Kurva berwarna merah menunjukkan *error* validasi dengan tidak mengikutkan satu sumur dalam perhitungannya (data validasi). Berdasarkan gambar tersebut dapat dilihat bahwa digunakan lebih dari enam atribut. *Error* validasinya bertambah besar, yang artinya terjadi *overtraining*.

3.7.5 Probabilistic Neural Network (PNN)

Jaringan Syaraf Tiruan (JST) atau yang sering biasa disebut *Artificial Neural Network (ANN)* merupakan sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf pada makhluk hidup. *Neural network* dikembangkan sebagai model matematika yang menyerupai pola pikir manusia atau jaringan syaraf makhluk hidup, dengan asumsi bahwa proses informasi terjadi pada banyak elemen sederhana yang disebut dengan neuron., sinyal yang melewati antar neuron menggunakan hubungan tertentu, setiap penghubung antar neuron mempunyai bobot (*weight*) yang bersesuaian dengan mengalikan sinyal yang dikirimkan. Bobot ini dapat memperkuat maupun memperlemah sinyal, setiap neuron menggunakan fungsi aktivasi terhadap *input* (jumlah sinyal *input* yang terboboti) untuk menentukan sinyal *output*.

Secara garis besar *neural network* mempunyai dua tahap pemrosesan informasi, yaitu tahap pelatihan dan tahap pengujian. Pertama adalah tahap pelatihan (*training*), tahap pelatihan dimulai dengan memasukkan pola-pola pelatihan ke dalam jaringan, dengan menggunakan pola-pola ini ke dalam jaringan akan mengubah bobot yang menjadi penghubung antar node. Kedua adalah tahap pengujian (*testing*) pada tahap ini dilakukan pengujian terhadap suatu pola masukan yang belum pernah dilatihkan sebelumnya (data uji) menggunakan bobot-bobot yang telah dihasilkan pada tahap pelatihan. Diharapkan bobot-bobot hasil pelatihan yang sudah menghasilkan error minimal juga akan memberikan *error* yang kecil pada tahap pengujian.

Probabilistic Neural Network (PNN) merupakan algoritma klasifikasi dan merupakan suatu algoritma *neural network* yang menggunakan fungsi probabilistik, tidak membutuhkan set data yang besar dalam tahap pembelajarannya, serta memiliki kelebihan yaitu dapat mengatasi waktu pelatihan yang lama, terjebak pada global minimum dan sulitnya perancangan arsitektur jaringan. PNN dapat digunakan untuk mengklasifikasikan secara akurat pada beberapa penelitian. Namun, PNN memiliki masalah pada penentuan parameter *smoothing* yang biasanya ditentukan dengan cara *trial and error* atau *user defined*.

1. Arsitektur PNN

Arsitektur PNN didasarkan pada penghitungan nilai fungsi kepekatan peluang ($f_i(x)$) untuk setiap data (vektor). Fungsi ($f(x)$) merupakan fungsi pengambilan keputusan *Bayes* ($g(x)$), untuk data (vektor) x dan x_{ij} yang telah dinormalisasi. Persamaan fungsi $f_i(x)$ atau $g_i(x)$ dituliskan sebagai berikut (Specht, 1992).

$$f_i(x) = g_i(x) = \frac{1}{(2\pi)^{\frac{p}{2}} \sigma^p M_i} \sum_{j=1}^{M_i} \left[\exp \left(-\frac{((x - x_{ij})^T \cdot (x - x_{ij}))}{2 \cdot \sigma^2} \right) \right]$$

Dengan keterangan .:

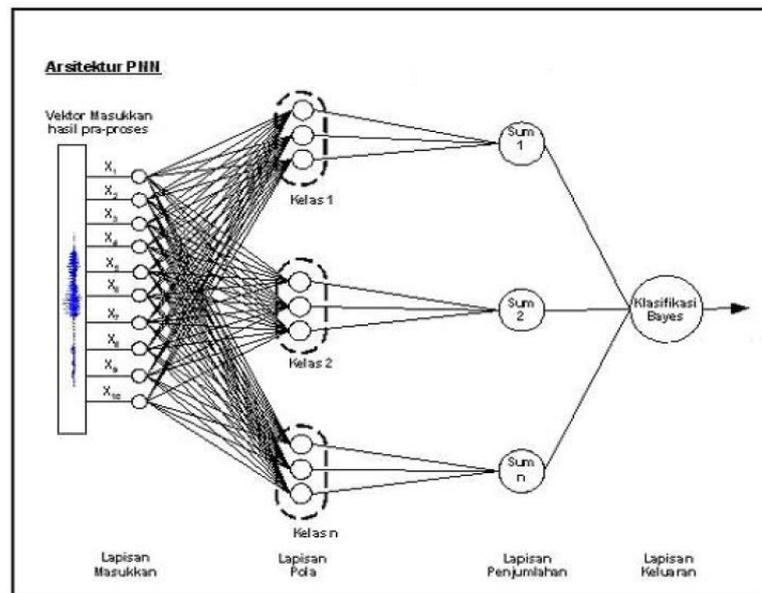
T = transpose

i = jumlah kelas (1, 2, ..., K)

j = jumlah pola

- x_{ij} = vektor pelatihan ke j dari kelas i
- x = vektor pengujian
- M_i = jumlah vektor pelatihan dari kelas i
- ρ = dimensi vektor x
- σ = faktor penghalus (standar deviasi)

Struktur arsitektur PNN, disajikan pada Gambar 3.21 di bawah ini.



Gambar 3.21 Arsitektur PNN

Posisi node-node yang dialokasikan dalam PNN setelah lapisan input, yakni :

1. Node lapisan pola (*Pattern Layer*), digunakan 1 node pola untuk setiap data pelatihan yang digunakan. Setiap node pola, merupakan perkalian titik (*dot product*) dari vektor masukan x yang akan diklarifikasikan, dengan vektor bobot x_{ij} , yaitu $Z_i = x \cdot x_{ij}$, kemudian dilakukan operasi *non linier* terhadap Z_i sebelum menjadi keluaran yang akan mengaktifkan lapisan penjumlahan, operasi *non linier* yang digunakan $\exp[(Z_i - 1)/\sigma^2]$, dan bila x dan x_{ij} dinormalisasikan terhadap panjang vektor, maka persamaan yang digunakan pada lapisan pola, adalah:

$$\exp \left[- \frac{(x - x_{ij})^T (x - x_{ij})}{2\sigma^2} \right]$$

2. Node lapisan penjumlahan (*Summation Layer*), menerima masukan dari node lapisan pola yang terkait dengan kelas yang ada, persamaan yang digunakan pada lapisan ini adalah:

$$\sum_{i=1}^N \exp \left[- \frac{(x - x_{ij})^T (x - x_{ij})}{2\sigma^2} \right]$$

3. Node lapisan keluaran (*Output layer*), menghasilkan keluaran biner (0,1) dan hanya mempunyai variabel bobot tunggal C_k . C_k dihitung menggunakan persamaan:

$$C_k = - \frac{h_{jk} l_{jk} m_{ik}}{h_{ik} l_{ik} m_{jk}}$$

Dengan keterangan :

m_{ik} = jumlah pelatihan pola dari kelas Θ_{ik}

m_{jk} = jumlah pelatihan pola dari kelas Θ_{jk}

2. Cara Kerja PNN

Probabilistic neural network dapat digunakan untuk menyelesaikan masalah klasifikasi. Misalkan terdapat Q pasangan vektor input dan target, dengan target terdiri dari K elemen, maka pada target, satu elemen akan bernilai 1, dan elemen-elemen lainnya akan bernilai 0. Sehingga tiap-tiap vektor input akan berhubungan dengan 1 vektor dari K kelas. Bobot-bobot input pada lapisan pertama akan bernilai sama dengan vektor input, (misal : P). Output lapisan pertama a_1 , merupakan hasil aktivasi dari jarak antara vektor input dengan bobot input dikalikan dengan bias. Nilai a_1 ini akan mendekati 1 apabila vektor input mendekati vektor bobot, (jarak mendekati 0). Apabila input vektor dekat dengan beberapa bobot input, maka akan ada beberapa elemen a_1 yang dekat dengan 1. Output lapisan pertama ini akan menjadi input bagi lapisan output. Pada lapisan output, bobot-bobot lapisan akan dibuat sama dengan vektor-vektor target. Tiap-tiap vektor target ini akan bernilai 1 hanya pada baris yang berhubungan dengan vektor input tertentu, yang lainnya akan bernilai 0. Neuron pada lapisan output akan menjumlahkan hasil perkalian antara bobot output dikalikan dengan a_1 (n2).

Output jaringan akan bernilai 1 apabila n_2 besar, sebaliknya akan bernilai 0 jika n_2 kecil.

3. Algoritma PNN

Langkah-langkah pelatihan (*training*) pada PNN adalah sebagai berikut :

- a. Inisialisasi
 - Melakukan inisialisasi bobot (*weight*) awal pada *radial basis layer* yang dilambangkan sebagai W dengan *transpose* matriks $R \times Q$ dari vektor *training*.
 - Melakukan inisialisasi bobot bias.
- b. Menghitung jarak (*distance*) dari data input (P) dengan bobot awal (W).
- c. Menghitung nilai aktivasi dari jarak antara bobot awal dengan data input ($W-P$), dengan menggunakan fungsi *radial basis (radbas)*.
- d. Mencari bobot baru dan bobot bias yang baru dengan menggunakan metode LMS
- e. Masuk ke dalam *competitive layer*, menghitung output dari jaringan.
- f. Simpan bobot awal dan bobot akhir ke dalam *database* berupa *file*.

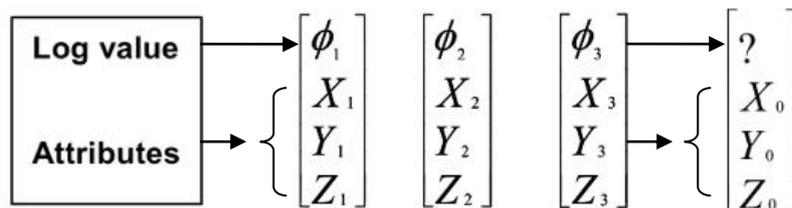
Sedangkan untuk langkah-langkah pengenalan (*recognition*) adalah sebagai berikut :

- a. Mengambil target, bobot awal dan bobot akhir dari *database*
- b. Meneruskan sinyal input ke *hidden layer (radial basis layer)* dan mencari jarak antara data input dengan bobot awal.
- c. Mencari nilai aktivasi dengan menggunakan fungsi *radial basis (radbas)*.
- d. Menghitung *output* dari jaringan
- e. Membandingkan hasil *output* dengan target.
- f. Menampilkan hasil pengenalan.

Penggunaan multiatribut pada dasarnya dilakukan dengan mencari hubungan statistik antara data log dan set dari atribut seismik pada lokasi sumur, lalu memanfaatkan hubungan tersebut untuk membuat suatu volum properti log yang diinginkan. Multiatribut merupakan suatu proses ekstraksi beberapa atribut dari data seismik yang mempunyai korelasi yang baik terhadap data log yang pada

akhirnya digunakan untuk memprediksi data log pada setiap lokasi di volum seismik. Untuk menentukan atribut seismik yang akan digunakan dalam proses tersebut, dilakukan uji statistik antara kedua data tersebut (data log dan atribut seismik), sehingga dapat diketahui hubungan antara keduanya. Regresi multiatribut dapat berjalan dengan baik apabila ada relasi *linear* fungsional yang baik di antara log yang diprediksi dan atribut seismik. Pada kasus hubungan yang *non linear* kita dapat mengaplikasikan transformasi tersebut dengan metoda *neural network* sebagai algoritma prediksi.

Dalam penelitian ini, *neural network* yang digunakan adalah *Probabilistic Neural Network* (PNN). Transformasi multiatribut menggunakan *Probabilistic Neural Network* merupakan skema interpolasi secara matematis yang menggunakan arsitektur *neural network* dalam penerapannya. Dalam pendekatan PNN, bobot dikalkulasikan menggunakan konsep “jarak” dalam spasi atribut antara titik yang diketahui nilainya dan titik yang tidak diketahui. Ide dasar di balik PNN adalah menggunakan kumpulan dari satu atau lebih nilai terukur (variabel independen) untuk memprediksi nilai variabel dependen tunggal.



Pemecahan masalah dengan cara membandingkan atribut baru dan atribut yang telah diketahui. Nilai yang diestimasi merupakan kombinasi linear dari nilai training yang diketahui:

$$\phi_0 = W_1 * \phi_1 + W_2 * \phi_2 + W_3 * \phi_3$$

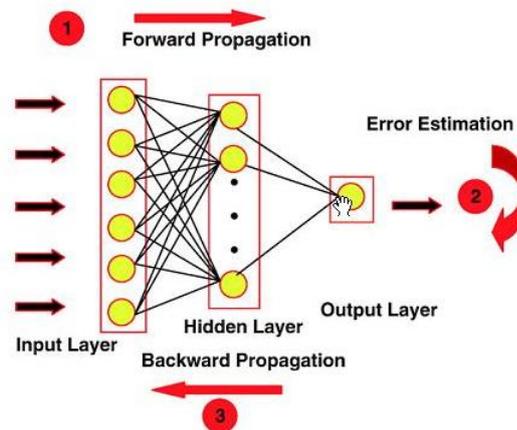
Dengan keterangan :

ϕ = nilai *porosity*

W = bobot

Dalam prakteknya, penggunaan PNN dapat dibagi menjadi empat langkah, yaitu:

- Analisis regresi *stepwise* multi linier dan validasi
- Training neural network* untuk menentukan hubungan non linier antara atribut seismik dan properti reservoir di lokasi sumur
- Menerapkan *neural network* yang telah di *training* pada data volume seismik
- Validasi hasil dengan satu sumur dan memprediksi dari sumur lainnya.



Gambar 3.21 Lapisan dan aliran sinyal dalam algoritma *artificial neural network* secara umum

Prinsip *neural network* mulai dikembangkan sejak 1969 dan pada tahun 1988 Specht menemukan metoda *probabilistic neural networks* (PNN). Penerapan paling umum dari *probabilistic neural network* dalam interpretasi seismik adalah untuk menghubungkan seperangkat atribut seismik yang diukur di lokasi N ke nilai log sumur tunggal L. Data *well log* difilter *lowpass* ke frekuensi *nyquist* yang diwakili oleh interval sampel seismik dan kemudian diatur sehingga kedua set data sampel sama. Nilai-nilai PNN melakukan interpolasi menggunakan bobot probabilitas Gaussian p (disebut “jarak” oleh Hampson *et al.*, 2001) yaitu :

$$Pnk(\sigma) = \exp \left| - \sum_{j=1}^J \left(\frac{a_{jk} - a_{jn}}{2\sigma_j} \right)^2 \right|$$

Dimana vektor σ menunjukkan bahwa bobot probabilitas adalah fungsi dari parameter *smoothing* yang tidak diketahui. Parameter σ_j merupakan suatu parameter untuk setiap atribut yang tidak diketahui nilainya dan akan diperoleh

melalui proses optimasi *non linier*. Hampson *et al.*, (2001) kemudian mendefinisikan nilai log yang diprediksi Lk menjadi :

$$\hat{Lk}(\sigma) = \frac{\sum_{n=1}^N Pnk(\sigma) Ln}{\sum_{n=1}^N Pnk(\sigma)}$$

Fungsi obyektif digunakan untuk meminimalkan kesalahan antara nilai k yang diukur dengan log yang diprediksi :

$$[E(\sigma)] = \sum_{k=1}^K [Lk - Lk(\sigma)]^2$$

Setelah “dilatih” untuk mendapatkan nilai dari σ , maka persamaan diatas dapat digunakan untuk memprediksi nilai log Lk untuk setiap sumur dan dapat disebarkan pada volume seismik.

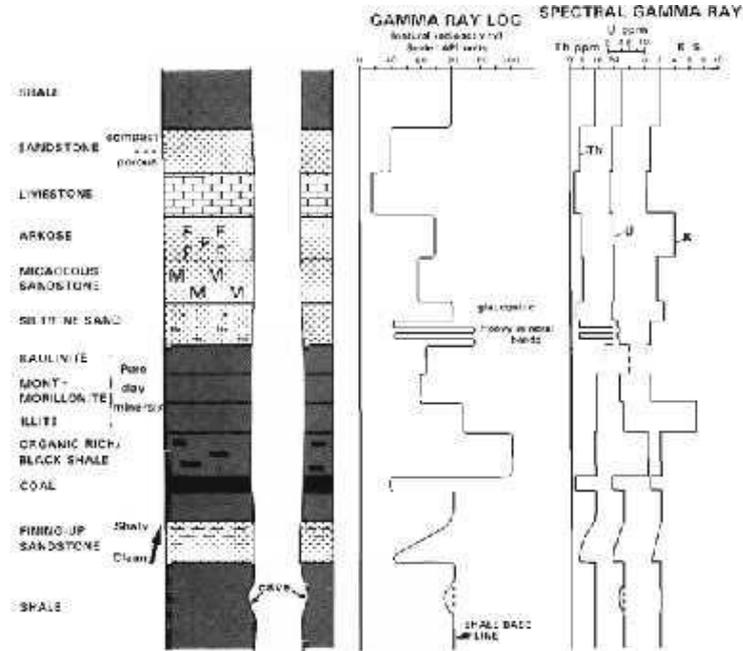
3.8 Konsep Dasar *Well Logging*

Log adalah suatu grafik kedalaman atau waktu dari satu set data yang menunjukkan parameter yang diukur secara berkesinambungan di dalam sebuah sumur. Kurva log memberikan informasi tentang sifat-sifat batuan dan fluida yang terkandung didalamnya. Investigasi geologi dan seismik mampu memberikan gambaran potensi hidrokarbon di bawah permukaan. Namun, hasil dari seismik saja masih belum cukup dikarenakan hasil dari seismik masih menimbulkan keambiguitasan. Evaluasi formasi dengan menggunakan data sumur (*well logging*) memberikan input respon geologi secara langsung kondisi bawah permukaan dengan akurasi yang lebih tinggi dibandingkan data seismik. Sehingga data log dijadikan kontrol dari data seismik salah satunya untuk mengidentifikasi hidrokarbon.

3.8.1 Log Gamma Ray

Prinsip kerja log *gamma ray* adalah merekam pancaran radioaktif alami bumi yang terkandung dalam batuan secara natural. Sinar radioaktif yang direkam berupa *Uranium-U*, *Thorium-Th* dan *Potassium-K* yang secara kontinu memancarkan *gamma ray* dalam bentuk pulsa-pulsa energi radiasi tinggi. Parameter yang direkam adalah jumlah dari pulsa yang tercatat per satuan waktu.

Log *gamma ray* ini bertujuan untuk mengidentifikasi kadar lempung pada suatu formasi. Batupasir yang tidak memiliki kandungan *shale* memiliki material radioaktif sedikit sehingga memberikan bacaan *gamma ray* log yang rendah. Sementara bila kandungan *shale* meningkat, maka nilai *gamma ray* log juga akan semakin meningkat yang disebabkan peningkatan konsentrasi material radioaktif dalam *shale*. Tetapi ada juga litologi yang memiliki jenis radioaktif yang sama dengan lempung sehingga log *gamma ray* memerlukan perbandingan dengan log lainnya.



Gambar 3.21 Grafik log *gamma ray* terhadap respon litologi (Rider, 2002)

3.8.2 Log Sonic

Log *sonic* sering digunakan untuk mengetahui porositas litologi dan untuk membantu interpretasi data seismik, terutama untuk mengkalibrasi kedalaman formasi. Log *sonic* bekerja berdasarkan kecepatan rambat gelombang suara. Gelombang suara dipancarkan ke dalam suatu formasi kemudian akan dipantulkan kembali dan diterima oleh *receiver*. Waktu yang dibutuhkan gelombang suara untuk sampai ke penerima disebut “*Interval Transit Time*” (Δt). Besarnya selisih waktu tersebut tergantung pada jenis batuan dan besarnya porositas batuan tersebut sebagai fungsi dari parameter elastik seperti K (*bulk modulus*), μ (*shear modulus*) dan ρ (densitas) yang terkandung dalam persamaan kecepatan gelombang (V_p) dan (V_s). Pada batuan yang porositasnya kecil maka kurva log *sonic* akan memperlihatkan harga yang tinggi. Sementara batuan dengan porositas besar, maka kurva log *sonic* akan berharga rendah.

3.8.3 Log Density

Prinsip kerja log densitas adalah memancarkan sinar *gamma* energi menengah ke dalam suatu formasi sehingga akan bertumbukan dengan elektron-elektron yang ada. Tumbukan tersebut akan menyebabkan hilangnya energi sinar *gamma* yang kemudian dipantulkan dan diterima oleh detektor yang akan diteruskan untuk direkam ke permukaan. Hal ini mengindikasikan fungsi dari harga rata-rata kerapatan batuan. Semakin banyak energi yang hilang, maka densitas batuan semakin besar, begitu pula sebaliknya. Kegunaan lain dari log densitas adalah menentukan harga porositas batuan, mendeteksi adanya gas, menentukan densitas batuan dan hidrokarbon serta bersama dengan log *neutron* dapat digunakan untuk menentukan zona yang terisi fluida.

3.8.4 Log Neutron

Log *neutron* merekam *Hydrogen Index* (HI) dari suatu formasi. HI merupakan indikator kelimpahan kandungan hidrogen dalam formasi. Satuan pengukuran dinyatakan dalam satuan PU (*porosity unit*). Prinsip kerja dari log ini adalah menembakkan partikel *neutron* berenergi tinggi ke dalam formasi. Tumbukkan *neutron* dengan atom H akan menyebabkan energi *neutron* melemah. Kemudian

detektor akan mengukur jumlah partikel neutron yang kembali dari formasi. Semakin banyak atom H dalam formasi, maka partikel *neutron* yang kembali akan semakin sedikit. Batubara pada log *neutron* biasanya memberikan respon defleksi yang relatif lebih besar dibandingkan dengan batupasir, karena batubara lebih kompak. Besarnya porositas batuan sama dengan jumlah energi *neutron* yang hilang, karena atom hidrogen terkonsentrasi pada pori yang terisi fluida (air atau minyak). Zona gas sering diidentifikasi dengan menggabungkan log *neutron* dan log densitas. Penggabungan log *neutron* dan log porositas selain sangat baik untuk penentuan harga porositas, mengidentifikasi litologi dan untuk mengevaluasi kandungan serpih. Pori yang terisi oleh gas akan memiliki pola kurva log *neutron* yang lebih rendah dari yang seharusnya (*gas effect*). Hal ini terjadi karena konsentrasi hidrogen dalam gas lebih kecil dibandingkan pada minyak dan air.