

PROTOTYPE MODEL PREDIKSI PERIODE ULANG KEJADIAN GEMPA BUMI DENGAN IDENTIFIKASI PENGENALAN POLARITAS MEKANISME SUMBER GEMPA BUMI MELALUI KLASIFIKASI BOLA FOCAL MENGGUNAKAN TEKNIK ANFIS DAN PCA

Wiko Setyonegoro¹, Nazori AZ²

Program Studi Magister Ilmu Komputer, Program Pascasarjana, Universitas Budi Luhur
Jl. Raya Ciledug, Petukangan Utara, Kebayoran Lama, Jakarta Selatan 12260
Telp. (021) 5853753, Fax. (021) 5869225
¹wiko.setyonegoro@yahoo.co.id, ²nazori.agani@gmail.com

ABSTRAK

Kejadian bencana gempa bumi telah menimbulkan korban jiwa dan materi dalam jumlah yang cukup banyak. Penduduk yang bermukim pada wilayah rawan gempa bumi tidak mengetahui kapan dan dimana gempa bumi akan terjadi secara tiba-tiba, sehingga timbulnya korban jiwa dan materi akibat gempa bumi tak terhindarkan. Melalui tesis ini diangkat tema tujuan penelitian mengenai upaya prediktabilitas periode ulang kejadian gempa bumi beserta identifikasi mekanisme sumber gempa bumi pada studi kasus wilayah Sumatra. Untuk melakukan prediksi gempa bumi dilakukan pembelajaran terhadap data historis kejadian gempa bumi. Sistem pembelajaran data ini menggunakan teknik ANFIS. Pada teknik ini susunan data historis disusun menjadi interval kejadian rata-rata gempa bumi harian dalam setahun. Output yang akan diperoleh adalah model periode ulang kejadian gempa bumi rata-rata harian dalam setahun. Parameter mekanisme sumber digambarkan sebagai citra bola focal dari mekanisme sumber terjadinya gempa bumi di bawah permukaan bumi, dimana pada bola tersebut terdapat bagian yang diarsir menurut polaritas yang dapat menggambarkan bagaimana arah, tekanan, regangan, tumbukkan dan luasan antar blok sesar yang terjadi. Model periode ulang kejadian gempa bumi yang telah dipelajari terhadap waktu oleh ANFIS, selanjutnya dilakukan pengenalan polaritasnya melalui teknik pengenalan citra pada bola focal menggunakan metode principal component analysis PCA. Hipotesis penelitian ini akan membuktikan apakah panjang data pembelajaran dan kerapatan selang data pembelajaran akan menunjukkan akurasi model?. Validitas akurasi ketepatan model prediksi periode ulang gempa bumi tersebut diuji melalui Koefisien korelasi, RMSE dan Uji selang penerimaan hipotesis. Hasil yang diperoleh melalui tesis ini menunjukkan, model prediksi periode ulang kejadian gempa bumi untuk rata-rata periode ulang bulanan menunjukkan koefisien korelasi 0.014562, artinya masih berada pada selang nilai yang memenuhi dengan kriteria korelasi yang lemah, sedangkan koefisien korelasi rata-rata periode ulang 10 harian yang lebih rapat dengan nilai lebih mendekati 1 menunjukkan korelasi kuat dengan nilai -0.161. Sehingga melalui pengujian ini dapat diduga kuat bahwa kerapatan panjang data observasi yang dipelajari oleh ANFIS akan sangat mempengaruhi akurasi dari model prediksi gempa bumi.

Kata Kunci : Gempa bumi, prediksi, periode ulang, ANFIS, PCA

1. PENDAHULUAN

Gempabumi terjadi akibat pergerakan kerak bumi. Terjadi pergerakan relatif dari blok satu dengan lainnya terhadap ruang dan waktu, sehingga menimbulkan perbedaan tegangan dan rekahan yang mengakibatkan patahan kerak bumi. Proses terbentuknya tegangan atau rekahan ini akan menimbulkan gempabumi yang terjadi secara tiba-tiba ditengah tengah pemukiman penduduk. Hingga mengakibatkan timbulnya korban jiwa dan materi akibat guncangan dari gempabumi tersebut.

Para peneliti bidang geofisika mencoba mengamati periode ulang waktu terjadinya gempabumi pada wilayah yang sama dengan tujuan agar penduduk yang akan terdampak oleh bencana gempabumi tersebut dapat mengetahui kondisi aktivitas seismik di wilayah tersebut[1].

Pengamatan kejadian gempabumi dari tinjauan geologi dan geofisika dari segi spasial mengalami kendala terhadap waktu dan sulit untuk memprediksi kapan waktu terjadinya gempabumi. Sehingga dirasakan pentingnya untuk mencoba menerapkan jaringan syaraf tiruan untuk mempelajari data historis kejadian gempabumi untuk dapat menentukan prediksi periode ulang kejadian gempabumi. Selain pembelajaran data historis berdasarkan waktu, tetap diperhatikan parameter yang selalu mempengaruhi pengulangan kejadian gempabumi pada suatu wilayah penelitian. Parameter tersebut adalah tipe mekanisme sesar sumber terjadinya gempabumi dibawah permukaan bumi. Mekanisme sumber gempabumi ini dapat dikenal dengan istilah bola focal[1].

Perkembangan riset sistem pengenalan bola focal merupakan hal yang penting, hal ini dikarenakan oleh

pemanfaatan identifikasi parameter sesar dapat membantu para peneliti atau petugas operator monitoring gempa bumi dalam mempelajari dan menganalisa suatu deformasi kerak bumi yang terjadi akibat gempa bumi pada suatu wilayah penelitian. Dengan melakukan pengenalan polaritas dan posisi dari ciri-ciri dan karakteristik bola focal yang selanjutnya kita dapat membandingkan dan menampilkan data kejadian gempa bumi[2].

Secara umum sistem pengenalan bola focal menggunakan PCA mempunyai beberapa tahapan yaitu pendeteksian bola focal, ekstraksi bola focal, dan pengenalan bola focal. Pendeteksian bola focal adalah tahap untuk menentukan dan memisahkan bagian dari suatu citra diam (*still image*) yang terdefinisi sebagai bola focal, dan ekstraksi bola focal merupakan pengambilan bagian dari fitur-fitur bola focal, setelah ekstraksi maka masuk pada tahapan pengenalan bola focal yaitu mengenali bola focal dengan ciri dan karakteristik tertentu untuk mengetahui identitas[3].

Dalam pengenalan bola focal kita dapat melakukan klasifikasi bola focal terhadap beberapa jenis sesar, diantaranya secara umum adalah sesar naik, sesar turun atau sesar mendatar, diakumulasikan dengan kombinasi nilai strike, slip, rake dan dip[4].

Klasifikasi bola focal yang penulis lakukan adalah dengan parameter mekanisme fokus sesar yaitu dengan memanfaatkan jarak antar komponen bola focal dan dilakukan pengukuran jarak, yang telah diambil dari penentuan titik-titik terpenting dari komponen bola focal. Melalui penelitian ini diharapkan pengenalan bola focal dari suatu kejadian gempa bumi dapat membantu analisa suatu event gempa bumi, sehingga identifikasi sesar yang terjadi pada suatu area penelitian dapat diinterpretasikan dengan baik[4].

Para ahli seismolog mengacu pada arah slip dalam gempa bumi dan orientasi sesar yang terjadi sebagai mekanisme fokus. Mereka menggunakan informasi dari alat pengukur gempa bumi (seismogram) untuk menghitung mekanisme fokus dan biasanya menampilkannya pada peta sebagai "bola focal" simbol. Simbol ini adalah proyeksi pada bidang horizontal dari bagian bawah dari kulit bola imajiner (sphere focal) berlokasi disekitar sumber gempa. Sebuah garis menjelaskan dimana bidang patahan memotong *shell*[4].

Berdasarkan latar belakang, identifikasi, dan batasan masalah, maka permasalahan penelitian dapat dirumuskan dengan melihat bahwa data kejadian gempa bumi merupakan deret waktu non linear, maka dapat dilakukan suatu pembelajaran terhadap data historis kejadian gempa bumi dengan melakukan pengaturan data historis gempa bumi menjadi selang interval kejadian gempa bumi. Teknik ini menggunakan ANFIS. Sehingga dari hasil pembelajaran data tersebut memungkinkan dapat dihasilkan model prediksi periode ulang kejadian gempa bumi pada suatu wilayah penelitian tertentu. Lebih lanjut, model prediksi ini kemudian dilakukan identifikasi tipe mekanisme sumber gempa buminya menggunakan teknik PCA.

Berdasarkan rumusan masalah, maka tujuan penelitian dapat dirangkum sebagai berikut :

1. Pembelajaran data historis gempa bumi untuk memperoleh model prediksi periode ulang kejadian gempa bumi.
2. Pengenalan citra bola focal pada model untuk identifikasi tipe mekanisme sumber gempa bumi yang mengalami perulangan kejadian.
3. Pengujian validitas model prediksi periode ulang kejadian gempa bumi menggunakan koefisien korelasi, RMSE dan Uji Hipotesa.

2. LANDASAN TEORI DAN KERANGKA KONSEP


2.1 Tinjauan Pustaka

2.1.1. Konsep ANFIS dan Logika Fuzzy

ANFIS merupakan suatu teknik optimasi yang menggabungkan konsep *neural-network* dengan *fuzzy logic*. *Neural-network* mengenal pola-pola dan menyesuaikan pola terhadap perubahan lingkungan, sedangkan *fuzzy logic* menggabungkan pengetahuan manusia dan mencari kesimpulan untuk membuat suatu keputusan. ANFIS juga dapat diterapkan secara langsung dalam bidang pemodelan, pengambilan keputusan, pengolahan sinyal, dan kontrol[5].

Adaptive-network merupakan struktur jaringan yang terdiri dari simpul-simpul (*nodes*) dan hubungan langsung antar simpul, dimana sebagian atau seluruh simpul adalah adaptif sehingga outputnya tergantung pada keterkaitan parameter dengan simpul tersebut, dan aturan pembelajaran (*learning rule*) menentukan bagaimana parameter-parameter tersebut berubah untuk meminimalkan kesalahan (*error*)[5].

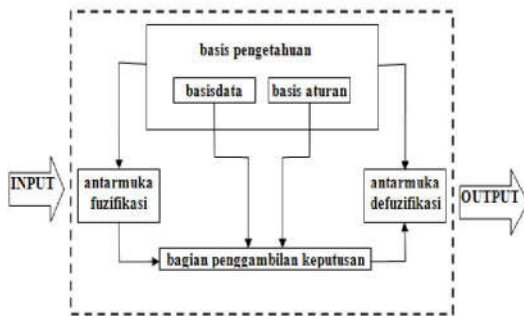
Pada gambar 1 diperlihatkan contoh jaringan umpan maju beberapa lapis (*multilayer feedforward network*) dimana masing-masing simpul menjalankan fungsi tertentu (fungsi simpul) pada sinyal yang masuk sebagaimana pengaruh parameter terhadap simpul tersebut. Formula dari fungsi simpul bisa bervariasi antara satu simpul dengan simpul yang lain, dan pemilihan fungsi simpul tergantung pada fungsi input-output secara keseluruhan. Himpunan parameter suatu jaringan adaptif merupakan gabungan himpunan parameter masing-masing simpul adaptif. Dalam usaha mendapatkan pemetaan input-output yang diinginkan, parameter-parameter ini diperbaharui berdasarkan data latih yang diberikan[5].



Gambar 1. Jaringan adaptif (*Adaptive network*)[5]

Menurut Jang 1997, FIS terdiri dari 5 (lima) bagian :

- 1) Basis aturan (*rule base*), terdiri dari sejumlah aturan jika-maka fuzzy;
- 2) Basis data (*database*) yang mendefinisikan fungsi keanggotaan dari himpunan fuzzy yang digunakan dalam aturan fuzzy; biasanya, basis aturan dan basis data digabung dan disebut basis pengetahuan (*knowledge base*).
- 3) Satuan pengambil-keputusan (*decision-making unit*) yang membentuk operasi inferensi pada aturan (*rule*);
- 4) Antarmuka fuzzifikasi (*fuzzification interface*) yang merubah input ke dalam derajat yang sesuai dengan nilai linguistik (*linguistik value*);
- 5) Antarmuka defuzzifikasi (*defuzzification interface*) yang merubah hasil fuzzy inferensi ke bentuk output yang kompak;



Gambar 2. Sistem inferensi Fuzzy[5].

ANFIS adalah suatu metode yang mana dalam melakukan penyetelan aturan digunakan algoritma pembelajaran terhadap sekumpulan data. Pada ANFIS juga memungkinkan aturan-aturan untuk beradaptasi. Pada ANFIS, jaringan syaraf digunakan untuk mengimplementasikan *Fuzzy Inference System*. Selanjutnya melalui tesis ini akan dibuat suatu model prototipe periode ulang kejadian gempa bumi menggunakan ANFIS.

2.1.2. Konsep Logika Fuzzy

Logika adalah metode atau teknik yang diciptakan untuk meneliti ketepatan penalaran. Logika mengkaji prinsip-prinsip penalaran yang benar dan penalaran kesimpulan yang absah. Ilmu ini pertama kali dikembangkan sekitar 300 SM oleh Aristoteles dan dikenal sebagai logika tradisional atau logika klasik. Dasar pemikiran logika klasik adalah logika benar dan salah yang disimbolkan dengan 0 (untuk logika salah) dan 1 (untuk logika benar).

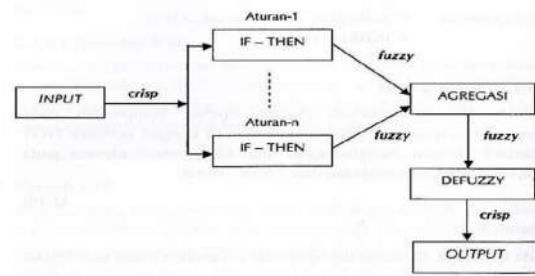
Perkembangan terakhir ilmu logika di bidang komputer adalah logika fuzzy. Logika ini memiliki nilai kekaburan atau kesamaran (*fuzziness*) antara benar dan salah. Dalam teori logika fuzzy suatu nilai bisa bernilai benar dan salah secara bersamaan, namun besarnya kebenaran dan kesalahan suatu nilai tergantung pada bobot keanggotaan yang dimilikinya.

Logika fuzzy adalah teknologi berbasis aturan yang dapat merpresentasikan ketidakpresisian seperti yang telah

disebutkan, dengan menciptakan aturan yang menggunakan nilai subjektif atau nilai yang mendekati. Logika fuzzy dapat menjelaskan fenomena atau proses tertentu secara linguistik, kemudian merepresentasikannya dalam sejumlah kecil aturan yang fleksibel. Organisasi dapat menggunakan logika fuzzy untuk menciptakan sistem peranti lunak yang menangkap pengetahuan tersirat yang mengandung ambiguitas linguistik[6].

Menurut Sri Kusumadewi pengertian logika fuzzy adalah suatu cara untuk memetakan suatu ruang input ke dalam suatu ruang output[7].

Sistem inferensi fuzzy (*Fuzzy Inference System*) merupakan kerangka komputasi yang didasarkan pada teori himpunan fuzzy, aturan fuzzy berbentuk IF- THEN, dengan penalaran fuzzy[7] (gambar 3).



Gambar 3. Diagram Blok Sistem Inferensi Fuzzy[7].

Sistem inferensi fuzzy menerima *input crisp*. *Input* ini kemudian dikirim ke basis pengetahuan yang berisi n aturan fuzzy dalam bentuk IF-THEN. *Fire strength* akan dicari pada setiap aturan. Apabila jumlah aturan lebih dari satu, maka akan dilakukan agregasi dari semua aturan. Selanjutnya, pada hasil agregasi akan dilakukan *defuzzy* untuk mendapatkan nilai *crisp* sebagai *output* sistem.

Fuzzy inference system adalah proses merumuskan pemetaan dari *input* yang diberikan ke *output* dengan menggunakan logika fuzzy. Pemetaan tersebut akan menjadi dasar dari keputusan yang akan dibuat. Proses *fuzzy logic* melibatkan fungsi keanggotaan, operator logika fuzzy, dan aturan jika maka (*if- then rule*)[8]. Dalam membangun sistem yang berbasis pada aturan fuzzy maka akan digunakan variabel linguistik. Variabel linguistik adalah suatu interval numerik dan mempunyai nilai-nilai linguistik, yang semantiknya didefinisikan oleh fungsi keanggotaannya.

2.2. Tinjauan Studi dan Novelities

Penelitian mengenai pengembangan model prediksi dengan menggunakan ANFIS telah dilakukan pada penelitian terdahulu untuk bidang cuaca dan gempa bumi yang dilakukan oleh Suwarman R, Adrian CP dan Syamsul A dan Elohasen P 2012. Metode yang dilakukan adalah melakukan pembelajaran data historis melalui pengaturan selang interval data bulanan secara temporal. Dimana pada penelitian ini prediksi untuk selanjutnya disebut sebagai periode ulang. Periode ulang

kejadian gempa bumi dengan menggunakan ANFIS disini memiliki kebaruan (*novelties*) riset dari penelitian sebelumnya. Kebaruan yang diangkat adalah tema prediksi ANFIS pada curah hujan dimodelkan untuk periode ulang kejadian data nonlinear gempa bumi. Model prediksi periode ulang secara statistika dalam waktu diintegrasikan dengan model lainnya secara spasial sebagai *cross check*, yaitu identifikasi tipe model periode ulang mekanisme sumber gempa bumi pada wilayah yang sama.

2.3. Struktur output FIS untuk Training Data ANFIS

Fismat1 merupakan struktur FIS *output* berhubungan dengan *error training* minimal. Merupakan struktur FIS yang digunakan untuk memperlihatkan sistem fuzzy saat tidak ada *data checking* yang digunakan sebagai validasi model. Saat opsi *data checking* yang digunakan, output yang disimpan adalah *error checking* minimum.

2.3.1. Error Training

Error training berbeda dengan harga *output data training*, dan output FIS berhubungan dengan nilai *input data training* yang sama. *Error training trnError* menyimpan *root mean squared error* (RMSE) dari *set data training* pada setiap epoch. fismat1 menggambarkan struktur FIS ketika *error training minimum*.

2.3.2. Ukuran Langkah (Step - Size)

Anfis yang menggunakan *command line*, ukuran langkah mencatat ukuran langkah selama training. Plot ss memberikan profil ukuran langkah, yang berfungsi sebagai acuan untuk mengatur ukuran langkah awal dan tingkat kenaikan dan penurunan.

Ukuran langkah (*step-size*, ss) untuk anfis fungsi *command-line* diperbaharui berdasarkan ketentuan:

- Jika error saat training 4 kali berurutan errornya berkurang, peningkatan ukuran langkah (*ssinc*) dengan perkalian dengan suatu konstanta yang lebih besar dari satu.
- Jika error yang dialami dua training yang berurutan yang satu meningkat dan satunya turun, penurunan ukuran langkah (*ssdec*) dengan perkalian dengan suatu konstanta yang lebih kecil dari satu.

Nilai default ukuran langkah awal adalah 0.01; harga default untuk masing-masing *ssinc* dan *ssdec* adalah 1.1 dan 0.9. Semua nilai ini bisa diubah.

2.3.3. Data Checking

Data checking, *chkData*, digunakan untuk menguji kapasitas FIS secara umum pada masing-masing epoch. *Data checking* memiliki format yang sama dengan *data training*, dan unsurnya secara umum berbeda dengan *data training*.

Data checking penting dalam pembelajaran (*training*) untuk jumlah input yang besar, dan/atau data mengandung *noise*. Secara umum kita ingin FIS untuk menjejaki set data input/output dengan baik. Karena struktur model yang digunakan untuk anfis adalah *fixed*, ada kecenderungan model untuk *overfitting* data yang sedang diuji, khususnya harga

training epoch yang besar. Jika terjadi *overfitting*, kita tidak dapat mengharapkan FIS untuk merespon dengan baik set data yang lain, khususnya jika data disertai *noise*. Suatu validasi atau *checking set data* diperlukan dalam mengatasi masalah tersebut. Data ini digunakan untuk validasi model *fuzzy inference*, dengan menyertakan data *checking* pada model, dan melihat seberapa baik model merespon data tersebut. Saat opsi *data checking* digunakan, data *checking* diaplikasi ke model pada masing-masing training epoch.

2.3.4. Struktur FIS Output untuk Data Checking

Output dari *anfis command line*, fismat2, merupakan struktur *output* FIS dengan *error checking* minimum. Ini merupakan struktur FIS yang akan digunakan untuk perhitungan selanjutnya jika *data checking* digunakan untuk validasi.

2.3.5. Error Checking

Error checking merupakan perbedaan antara harga *output data checking*, dan *output* dari FIS berhubungan dengan harga *input data checking* yang sama. *Error checking chkError* menyimpan RMSE *data checking* pada masing-masing epoch. fismat2 merupakan gambaran struktur FIS saat *error checking* nya minimum. Secara umum, pembelajaran dengan anfis akan baik apabila *data training* yang digunakan anfis untuk mengestimasi parameter-parameter fungsi keanggotaan merepresentasikan semua pola (*feature*) data yang ada. Sering terjadi, dalam beberapa kasus data yang dikumpulkan menggunakan pengukuran yang mengandung *noise*, dan data training tidak mampu merepresentasikan semua pola data yang akan ditampilkan dalam model. Sehingga diperlukan validasi model.

2.3.6. Konsep Principal Component Analysis (PCA)

PCA merupakan salah satu metode ekstraksi fitur secara statistik. PCA merupakan sebuah cara untuk mengidentifikasi pola dalam kumpulan data untuk mencari persamaan dan perbedaannya. PCA sangat cocok untuk menemukan pola dalam data berdimensi tinggi. Dalam konteks pengenalan polaritas, PCA mencari *eigenface* yang merupakan kumpulan dari *eigenvector*. *Eigenface* adalah *principal component* (ciri-ciri penting) dari distribusi citra polaritas yang didapatkan dari *eigenvector* dengan *eigenvalue* terbesar. Untuk mendapatkan *eigenface*, PCA melakukan perhitungan matrik kovarian dari kumpulan citra polaritas latih setelah dilakukan normalisasi. *Eigenface* tersebut akan menjadi dasar perhitungan *face space* yang merepresentasikan nilai bobot individu yang mewakili satu atau lebih citra data. Nilai bobot inilah yang digunakan untuk mengenali citra bola focal uji dengan mencari jarak nilai bobot citra bola focal uji dengan nilai bobot citra bola focal latih. Perhitungan jarak nilai bobot dapat dilakukan dengan perhitungan jarak Euclidian (*Euclidian Distance*) [9].

2.3.6.1. Metode Eigenface

Pemrosesan awal pada citra 2 (dua) dimensi yang dipakai perlu dilakukan. Tujuan pemrosesan awal adalah untuk

mempercepat kinerja dan memperkecil ukuran memori yang digunakan dalam pengenalan objek 3 (tiga) dimensi. Pemrosesan awal dilakukan dengan mengekstrak ciri dari citra berdimensi N menjadi citra berdimensi M dimana $M < N$. Citra 2 (dua) dimensi dari objek 3 (tiga) dimensi dengan berbagai sudut pandang yang akan dikenali dikumpulkan untuk mewakili objek tersebut sebagai citra acuan. Ekstraksi ciri dilakukan pada kumpulan tersebut untuk mendapat informasi ciri objek. Hasil ekstraksi ciri kemudian digunakan untuk proses pengenalan objek 3 (tiga) dimensi. Pengertian nilai eigen dan eigen vektor dapat lebih dipahami jika ditinjau dalam bentuk persoalan fisis. Andaikan terdapat selimut membran elastik 2 (dua) dimensi yang dapat dinyatakan dalam koordinat x dan y, membran tersebut mendapat perlakuan fisik yakni dapat ditekan, ditarik maupun dirotasi terhadap titik asal[9].

2.3.6.2. Representasi Citra Acuan


Mendesripsikan suatu objek dalam sebuah ruang citra penuh (spasial) tidaklah optimal jika digunakan untuk mengenal objek tiga (3) dimensi. Bentuk representasi citra acuan yang digunakan adalah representasi *eigenface* atau ruang *eigen*. Ide dasar dari representasi ini adalah merepresentasi sekumpulan citra atau ciri suatu citra dalam sebuah ruang transformasi dimana setiap ciri tidak berkorelasi[10].

Bentuk representasi ruang *eigen* dapat diperoleh dengan melakukan transformasi Karhunen-oeve atau *Principal Component Analysis* (PCA) terhadap sekumpulan citra acuan. Hasil transformasi ini adalah vektor basis ortonormal yang digunakan untuk membentuk suatu sub ruang vektor yang disebut ruang cirri. Sebuah ruang citra dapat dipandang sebagai sebuah vektor[11]. Sebuah citra dengan lebar w dan tinggi h akan membentuk vektor yang mempunyai komponen sebanyak $w \cdot h$ dengan ukuran $1 \cdot (w \cdot h)$. Vektor ini disusun dengan melakukan penggabungan terhadap baris citra yang disusun berdampingan satu sama lain. Menghitung nilai eigenvalue (λ) dan eigenvektor (U_i) dari A_1 .

2.3.6.3. Tinjauan Objek Penelitian *Principal Component Analysis* (PCA)

Gempabumi terjadi akibat sesar pada dua bidang blok lapisan tanah yang mengalami pergerakan satu terhadap lainnya. Dalam menggambarkan suatu proses pergerakan sesar penyebab gempabumi terdapat beberapa parameter mekanisme sumber gempabumi yang diklasifikasikan menurut beberapa besaran, diantaranya ; magnitudo (M_w), strike (θ), Dip (ϕ), Slip (m), rake (α), A (m^2) dan depth (m), masing-masing menggambarkan energi gempabumi, arah sesar, kemiringan penunjaman sesar, ukuran deformasi penurunan tanah dan luasan sesar. Beberapa parameter tersebut dapat digambarkan sebagai bola focal.

Pengenalan bola focal menggunakan PCA dilakukan dengan mengenali klasifikasi dan variasi bola focal terhadap pola karakteristik jenis-jenis bola focal (gambar 4).



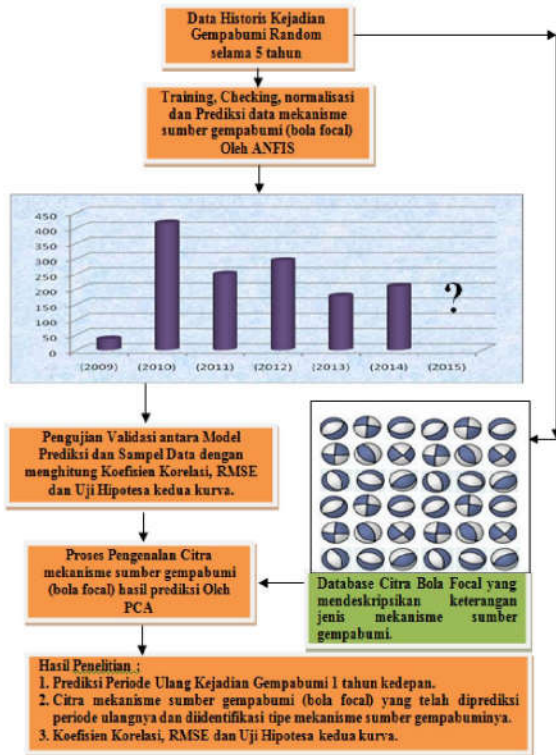
Gambar 4. Schematic diagram dari mekanisme bola focal. Memberikan informasi mengenai pola sesar yang terjadi saat kejadian gempabumi[4]

2.4. Kerangka Konsep / Pola Pikir Pemecahan Masalah

Berdasarkan identifikasi masalah, tujuan penelitian, kajian teori dan studi dari penelitian, maka dapat dibangun kerangka konsep penelitian tentang Prototipe Model Prediksi Periode Ulang Kejadian Gempabumi Dengan Identifikasi Pengenalan Polaritas Mekanisme Sumber Gempabumi Melalui Klasifikasi Bola Focal menggunakan Teknik ANFIS dan PCA.

Bola focal pada model yang telah dikenali dari database mengenai jenis mekanisme sumber gempabuminya diidentifikasi terjadi kembali periode ulangnya untuk jenis mekanisme sumber yang dapat dikenali (gambar 5).

Aplikasi yang dibuat mendukung menginterpretasikan analisis karakteristik sesar gempabumi pada bola focal, sehingga memberikan informasi yang saling terkait sebagai proses pengenalan (otensifikasi) prediksi periode ulang kejadian dari tipe mekanisme sesar pada suatu wilayah penelitian. Inputan yang diperlukan dalam aplikasi ini adalah berupa gambar bola focal dengan dimensi dan resolusi yang sama dalam bentuk citra skala abu-abu (arsiran) beserta inputan *class*. Klasifikasi yang sama untuk tipe bola focal yang sama, untuk mengenali berbagai tipe kombinasi pressure dan tension dari bola focal, juga kombinasi dari nilai parameter stike, dip, slip, rake pada sesar normal, naik, dan mendatar. Persentase keberhasilan pengenalan objek citra berdasarkan pengenalan tipe sesar pada bola focal ditunjukkan oleh hasil running program Matlab.



Gambar 5. Kerangka konsep prediksi periode ulang kejadian gempabumi dengan pengenalan citra bola focal mekanisme sumber gempabumi.

2.5. Hipotesis

Berdasarkan kerangka konsep teknik ANFIS dan PCA yang telah dikemukakan maka pernyataan penelitian ini dapat dirumuskan sebagai berikut :

1. Dugaan bahwa semakin rapat selang interval dan panjang data historis yang digunakan dalam proses pembelajaran data ANFIS, maka akan semakin akurat model prediksi periode ulang gempabumi yang dihasilkan.
2. Diduga validitas model dengan sampel data historis observasi pada hasil model prediksi periode ulang kejadian gempabumi akan memiliki koefisien korelasi baik, tingkat RMSE (*error*) kecil dan uji hipotesa yang memenuhi.

3. METODOLOGI DAN RANCANGAN PENELITIAN

3.1. Metoda Penelitian Prediksi Periode Ulang Gempabumi Menggunakan ANFIS

Metode dalam melakukan prediksi periode ulang kejadian gempabumi dilakukan melalui perhitungan secara matematis dan statistik data prediksi beberapa titik kedepan $x(t + p)$ berdasarkan harga lampau sampai $x(t)$ yang diketahui adalah menentukan harga D (jumlah titik) dan Δ (jarak) data lampau yang digunakan metode standar dalam persamaan berikut[5]:

$$x(t - (D-1)\Delta), \dots, x(t - \Delta), x(t) \dots \dots \dots (3.1)$$

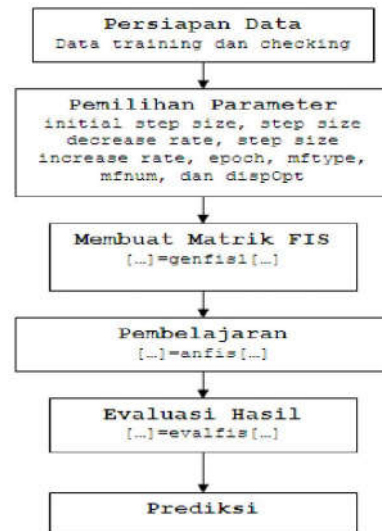
Selain menentukan harga D dan Δ yang sesuai, juga dilakukan pemilihan jumlah iterasi (perulangan) untuk pembelajaran (training) sampai diperoleh kesalahan terkecil dan tipe fungsi keanggotaan (*member function type, mftype*). Disini digunakan harga $D = 4$, berarti prediksi berdasarkan 4 data yang diketahui, iterasi = 200, dan *mftype* = *gbelmf*, sedangkan untuk harga Δ dilakukan penyesuaian terhadap panjang data input yang digunakan. Langkah-langkah aplikasi anfis untuk prediksi [5]:

3.1.1. Metode Pengumpulan Data Pada ANFIS

Sebelum diolah dengan ANFIS terlebih dahulu data dinormalisasi dengan membagi data parameter gempabumi masing-masing data harian dengan nilai parameter gempabumi tinggi selama pengukuran kemudian hasilnya dilakukan rata-rata berjalan (*moving average*) untuk mengurangi fluktuasi dan menghilangkan frekwensi tinggi (*low pass filter*), dengan persamaan berikut :

$$x_n = \frac{x_{t-2} + 2x_{t-1} + 6x_t + 2x_{t+1} + x_{t+2}}{12} \dots \dots (3.2)$$

dimana x_n dan x_t masing-masing adalah hasil *moving average* data ke n dan data normalisasi rata-rata harian ke t (gambar 6)[5].



Gambar 6. Flowchart prediksi periode ulang kejadian gempabumi dengan menggunakan ANFIS.

Ada dua jenis data yang disiapkan yaitu data training dan data checking. Disini data dibuat dalam bentuk matrik hanya berisi angka dan disimpan dengan dalam tipe file : *.txt, *.dat, *.m dan lain-lain. Data training dan checking tersebut dapat ditempatkan dalam satu file maupun dalam masing-masing file yang terpisah.


Untuk data yang disimpan dalam satu file, pembagian antara *data training* dan *checking* akan dilakukan dengan menggunakan *script* Matlab. Data tersebut disusun dalam bentuk matrik $N \times 5$. N adalah jumlah baris yang tergantung pada panjang data, sedangkan 5 adalah jumlah kolom, (4 kolom untuk vektor input yang akan ditraining dan kolom terakhir untuk vektor output)[5].

Prediksi berdasarkan 4 data yang diketahui, jadi $x(t+1)$, diprediksi menggunakan harga $x(t)$, $x(t-1)$, $x(t-2)$, $x(t-3)$. Sebagai contoh prediksi rata-rata 10 harian dengan panjang data 5 tahun ($5 \times 12 \times 3 = 180$ rata-rata 10 harian). Training dengan ANFIS dilakukan dengan menggunakan tambahan data sepanjang prediksi yang akan dibuat 30 hari untuk prediksi 1 tahun kedepan. Sebagai dari tersebut sebagai data training dan sebagian lagi sebagai *data checking*[5].


Model prediksi ANFIS adalah data program pembelajaran deret waktu *non-linear*. Dengan melihat nilai dari besarnya magnitudo gempabumi adalah akar dari fungsi nonlinier deret waktu, maka fungsi tersebut dapat didekati dengan metode pembelajaran gempabumi dari pengamatan data historis, kemudian interval dari kejadian gempabumi dikelompokkan menjadi deret waktu. Untuk mempelajari deret waktu data sejarah gempabumi, diperlukan alat batu pemrograman. Sebagai analisis dalam membangun model / metode, sintaks pemrograman dirancang dengan menggunakan Matlab berbasis ver 7.0.1 / R2008. Matlab memiliki *toolbox* program aplikasi yang disebut sebagai ANFIS, sebagai parameternya adalah *checking data* dan *training data*. Model prediksi ANFIS dikembangkan untuk memprediksi parameter gempabumi, dalam hal ini magnitudo.

Pengembangan prototipe ini dirancang dengan menggunakan fasilitas GUI (*Graphic User Interface*) yang disediakan dalam MATLAB ver 7.0.1. GUI dibuat untuk kemudahan dalam menggunakan program, sehingga *user* / pengguna program dapat lebih mudah menganalisis parameter input dan output yang diperlukan dalam menjalankan program. Aplikasi *Adaptive Neuro-Fuzzy* (ANFIS) diharapkan dapat banyak membantu menganalisis gempabumi secara statistika. Dalam analisa program ANFIS data disusun kedalam rata-rata harian kejadian gempabumi sebagai hasil normalisasi dari data acak N kejadian selang *Time series* magnitudo data ANSS dan Geofon GFZ (gambar 6)[1].

Untuk melakukan prediksi gempabumi dibutuhkan data historis gempabumi dalam kasus ini diambil 4 tahun rentang panjang data. Rentang data gempabumi merupakan suatu data dengan deret waktu yang non linier (acak), untuk melakukan prediksi gempabumi, data historis tersebut harus dikelompokkan kedalam selang waktu terlebih dahulu, sehingga program ANFIS dapat mempelajari prediksi melalui selang waktu tersebut. Dalam format acak sederhana (random) data gempa yang merusak, contoh: Pada 2004-2008 USGS dalam interval (t), pada gambar 7



Gambar 7. Data historis Selang acak kejadian gempabumi.



Gambar 8. Selang Interval Tahun Kejadian Gempabumi.

3.1.2. Penentuan Parameter pada ANFIS

Sebagian besar dari parameter yang digunakan masih harga *default*nya, kecuali ukuran langkah yang diperkecil *range* menjadi masing-masing 0.01 (*initial step size*), 0.5 (*step size decrease rate*), 1 (*step size increase rate*) dan *epoch*=200 (iterasi). Parameter lainnya, *mftype*='gbellmf', *mfnum*=2, *inmf*type=2, *outmf*type='linear' dan *dispOpt*='1' (*default*)[5].

3.1.3. Membuat Matriks FIS

Menggunakan fungsi *genfis1*, yaitu membuat matrik FIS tipe sugeno tanpa *cluster*.

```
fis = genfis1(data_training, numMFs, inmftype, outmftype)
```

3.1.4. Proses Pembelajaran Data

Menggunakan data training, data checking dan matrik FIS yang sudah dipersiapkan sebelumnya.

```
[mattraining_fis, training_error]=anfis(data_training, fis_training, [], [], data_checking);
```

3.1.5. Evaluasi Hasil

Memanggil hasil pembelajaran, dengan menggunakan fungsi *evalfis*.

```
data_input=[data_training(:,1:4); data_checking(:,1:4)];
prediksi_anfis=evalfis(data_input, mattraining_fis);
```

3.1.6. Prediksi


Hasil prediksi merupakan panjang data model prediksi periode ulang kejadian gempabumi rata-rata harian dengan

panjang data 5 tahun ($5 \times 12 \times 3 = 180$ rata-rata 10 harian). Dapat juga disebut selama 1 tahun panjang data.

3.2. Metoda Penelitian Pengenalan Bola Focal Menggunakan PCA

Data yang terkandung dalam sebuah bola focal dalam suatu kejadian gempabumi mengandung informasi parameter yang penting dalam menjelaskan karakteristik mekanisme terjadinya sesar penyebab gempabumi. Pada gambar 9 merupakan parameter yang terkandung dalam bola focal.

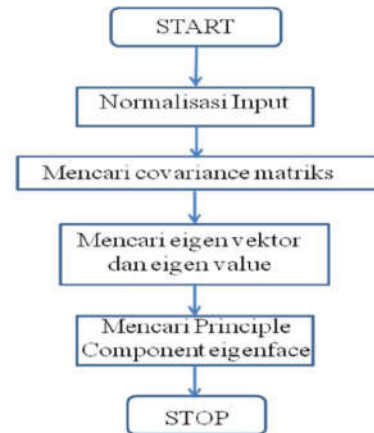
GFZ Event - GFZ MOMENT TENSOR SOLUTION
 13/12/11 13:00:58.01 Greece
 Epicenter: 39.09 22.38 MW 4.3
 Depth 13 No. of sta: 23
 NP1: Strike= 89 Dip=42 Slip= -99
 NP2: 283 49 -80



Gambar 9. Citra bola focal beserta variasi karakteristik polaritasnya[12].

Metoda ini didasari oleh data yang diperoleh pada proses terjadinya gempabumi. Setelah gempa terjadi, para seismolog membuat grafis mekanisme focal, secara informal disebut sebagai bola focal, untuk menunjukkan gerakan sesar (*faulting*) yang menghasilkan gempa bumi. Mekanisme bola focal, juga dikenal sebagai solusi *fault-plane*, didasarkan pada waktu pertama tiba gelombang P, dan digunakan untuk menunjukkan arah dan polaritas gerakan pada sesar menggunakan lingkaran besar dengan 2 kurva berpotongan pada bola focal (gambar 9).

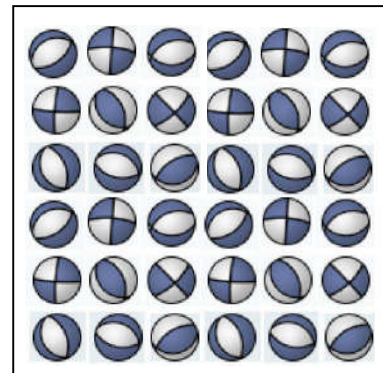
Data parameter mekanisme sumber gempabumi (bola focal) akan dikenali variasinya dengan menggunakan teknik PCA untuk mengenali polaritas bola focal yang telah diprediksi periode ulang kejadian gempabuminya (gambar 10).



Gambar 10. Alur proses pengenalan karakteristik bola focal.

3.2.1. Metoda Pengumpulan Data Pada PCA

Database dari sekumpulan data mekanisme sumber gempabumi yang telah diklasifikasikan sebagai bentuk-bentuk penggambaran tipe sesar penyebab terjadinya gempabumi. Tipe sesar yang merupakan bentuk polaritas yang umum pada bola focal disusun menjadi data bola focal yang siap untuk dilakukan pengenalan dengan menggunakan teknik PCA (gambar 11)



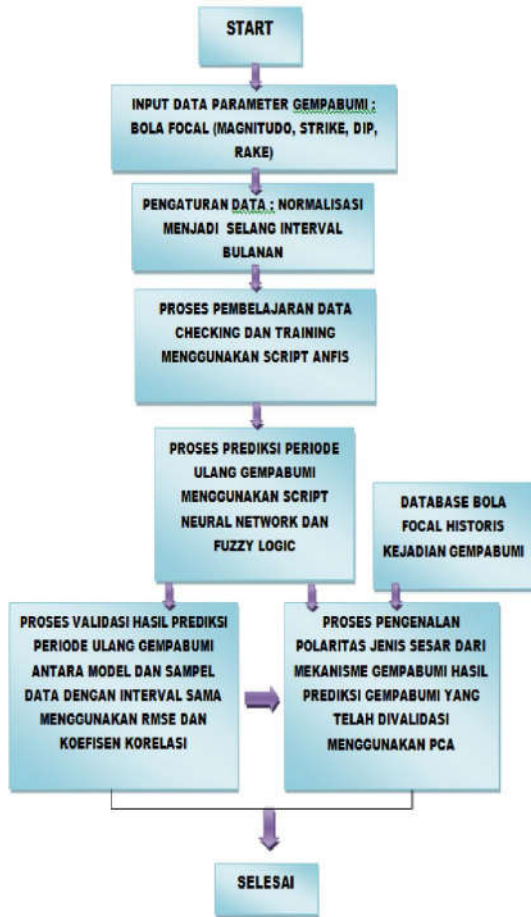
Gambar 11. Database Citra Bola Focal yang mengandung keterangan jenis mekanisme sumber gempabumi.

3.3. Perancangan Aplikasi Sistem Pada Diagram Alur Penelitian

Dalam proses pembuatan aplikasi ini terlebih dahulu dibuat diagram alur, agar jalannya program dapat diikuti dan dipahami. Parameter mekanisme sumber gempabumi terdiri dari beberapa besaran, diantaranya ; magnitudo (M_w), strike ($^\circ$), Dip ($^\circ$), Slip (m), A (m^2) dan depth (m) (gambar 12).

Masing-masing menggambarkan energi gempabumi, arah sesar, kemiringan penunjaman sesar, ukuran deformasi penurunan tanah dan luasan sesar. Untuk kejadian rata-rata bulanan pada kurva model prediksi periode ulang kejadian gempabumi terdapat informasi citra bola focal sebagai cerminan dari informasi proses mekanisme sumber gempabumi yang terjadi. Citra bola focal yang telah diprediksi dapat

dikenali kembali dengan melihat database historis kejadian gempabumi (gambar 12)[4].



Gambar 12. Diagram Alur Penelitian aplikasi prediksi periode ulang kejadian gempabumi secara keseluruhan.

3.4. Teknik Pengujian Sistem Pada Kurva Model

3.4.1. Analisis Koefisien Korelasi Model dan Sampel Data

Analisis Korelasi *Pearson* dimaksudkan untuk mengetahui eratnya hubungan antara 2 (dua) variabel, rumusnya :

$$r = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{[\sum (x - \bar{x})^2][\sum (y - \bar{y})^2]}}$$

Atau

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{[n(\sum x^2) - (\sum x)^2][n(\sum y^2) - (\sum y)^2]}}$$

r = koefisien korelasi
 n = ukuran sampel
 x = nilai var bebas
 y = nilai var terikat

Dari hasil yang diperoleh dengan rumus di atas, dapat diketahui tingkat pengaruh variabel X dengan variabel Y. Pada hakikatnya, nilai r dapat bervariasi dari -1 hingga +1, atau secara matematis dapat ditulis menjadi $-1 \leq r \leq +1$

1. Bila $r = 0$ atau mendekati 0, maka korelasi antar kedua variabel sangat lemah atau tidak terdapat hubungan antara variabel X terhadap variabel Y.
2. Bila $r = +1$ atau mendekati +1, maka korelasi antar kedua variabel dikatakan positif.
3. Bila $r = -1$ atau mendekati -1, maka korelasi antar kedua variabel dikatakan negatif.

Untuk dapat menginterpretasikan besar kecilnya koefisien korelasi antar kedua variabel, Penulis menyajikan keceratan hubungan sesuai dengan standar yang dikemukakan oleh Sugiyono dalam bentuk tabel berikut ini :

Tabel 1. Kriteria Nilai Korelasi[13]

$-1 \leq r \leq +1$	Tingkat Keceratan
0,80 – 1,00	Korelasi sangat kuat atau sempurna
0,60 – 0,79	Korelasi kuat
0,40 – 0,59	Korelasi sedang
0,20 – 0,39	Korelasi rendah
0,00 – 0,19	Tidak ada korelasi atau korelasi lemah

3.4.2. Analisis Rancangan Pengujian Hipotesis

Berdasarkan kerangka pemikiran, maka diajukan rumus hipotesis sebagai jawaban sementara yang akan diuji dan dibuktikan kebenarannya. Rumusan hipotesisnya adalah sebagai berikut[13] :

Untuk melihat apakah variabel independen secara bersama-sama (serentak) mempunyai pengaruh yang signifikan terhadap variabel dependen. Melalui uji statistik dengan langkah-langkah sebagai berikut :

Ho : $\rho = 0$ (tidak berkorelasi)

Ho : $\rho \neq 0$ (ada berkorelasi)

Taraf signifikansi $\alpha = 0.05$


Berdasarkan dasar signifikansi, kriterianya adalah :

- Jika signifikansi > 0.05 maka H_0 diterima.

- Jika signifikansi < 0.05 maka H_0 ditolak.

Uji statistik dengan daerah kebebasan $df = n-2$

$$t = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}} \dots\dots\dots(3.6)$$



Gambar 13. Daerah penolakan dan penerimaan H_0

Setelah diperoleh nilai t_{hitung} , selanjutnya dibandingkan dengan t_{tabel} pada $\alpha = 5\%$ dan $df = n-2$ untuk pengujian dua pihak, dengan ketentuan sebagai berikut :

1. -Jika $t_{hitung} \geq t_{tabel}$ atau $-t_{hitung} \leq -t_{tabel}$ maka H_0 ditolak.
 -Jika $t_{hitung} < t_{tabel}$ atau $-t_{hitung} < -t_{tabel}$ maka H_0 diterima.
2. Berdasarkan dasar signifikansi, kriterianya adalah :
 - Jika signifikansi > 0.05 maka H_0 diterima.
 - Jika signifikansi < 0.05 maka H_0 ditolak.

3.4.3. Analisa Root Mean Square Error (RMSE)

The Root Mean Square Kesalahan (RMSE) (juga disebut root mean square deviation, rmsd) adalah ukuran yang sering digunakan dari perbedaan antara nilai yang diprediksi oleh model dan nilai-nilai yang diamati dari lingkungan yang sedang dimodelkan. Ini perbedaan individu juga disebut residu, dan RMSE yang berfungsi untuk menggabungkan data ke dalam ukuran tunggal daya prediksi. RMSE dari prediksi model dengan sehubungan dengan estimasi X_{model} variabel didefinisikan sebagai akar kuadrat dari rata-rata kuadrat error:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$

di mana X_{obs} diamati nilai dan X_{model} dimodelkan nilai pada waktu / tempat i.

Nilai RMSE yang dihitung akan memiliki unit, dan RMSE untuk nilai model prediksi dapat untuk alasan ini tidak secara langsung dibandingkan dengan nilai RMSE untuk data lingkungan yang diamati dll Namun, nilai RMSE dapat digunakan untuk membedakan kinerja model dalam periode kalibrasi dengan periode dari validasi serta membandingkan kinerja model individu dengan model prediksi lainnya.

4. PEMBAHASAN HASIL PENELITIAN

4.1. Input Data Pembelajaran 5 tahun parameter magnitudo

Tabel 2. Sampel Input data observasi gempabumi yang akan dipelajari oleh model

Nomor	Lat	Long	Magnitudo
1	-1.56	99.44	4.50
2	5.52	94.70	4.73
3	0.35	98.42	4.64
4	-1.95	99.48	4.55

Bola Foral	Informasi Mekanisme Sumber
	Strike ke Barat Daya, Sesar Naik Oblique, Deformasi Vertikal
	Strike ke Selatan Sesar Turun Oblique, Deformasi Vertikal

Gambar 14. Sampel input database parameter mekanisme sumber gempabumi yang akan diidentifikasi.

4.2. Hasil dan Pembahasan Prototipe Model

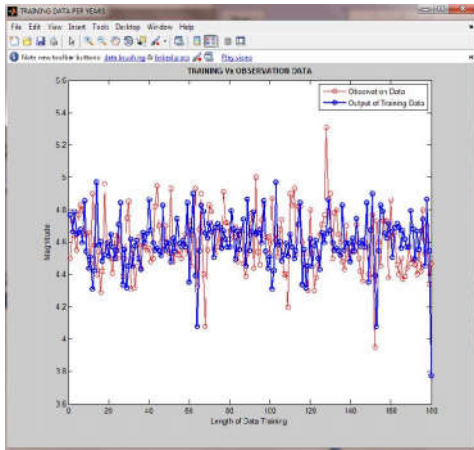
4.2.1. Hasil Prediksi Nilai Parameter Magnitudo

Pada setiap aplikasi sistem informasi yang dikembangkan pasti akan memiliki tampilan untuk output bagi pengguna sistem. *Output* dari model prototipe berikut ini adalah proses training data yang dilakukan pada ANFIS dengan parameter magnitudo. Error yang diperoleh dari beberapa langkah *training dan checking data*.

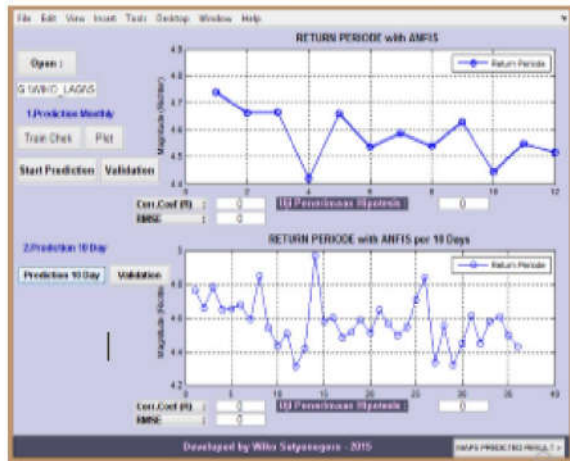
```

Start training ANFIS ...
1    0.0832138
2    0.0826895
3    0.0821641
4    0.0816328
5    0.0810917
Step size increases to 0.011000 after epoch 5.
6    0.0805381
7    0.0799127
8    0.0792697
9    0.0786103
Step size increases to 0.012100 after epoch 9.
10   0.0779364
    
```

Hasil pembelajaran *training dan checking* data observasi gempabumi selama 5 tahun telah dipelajari oleh ANFIS dan di plot secara overlay dengan data observasi sesungguhnya, sehingga terlihat bahwa ANFIS telah melakukan pengenalan terhadap pola perilaku kejadian gempabumi pada suatu wilayah yang dalam hal ini studi kasus di wilayah Sumatra (gambar 15).



Gambar 15. Plot hasil *training* dan *checking data* oleh ANFIS.



Gambar 16. Plot hasil Prediksi rata-rata bulanan dan rata-rata 10 harian untuk parameter magnitudo oleh FIS.

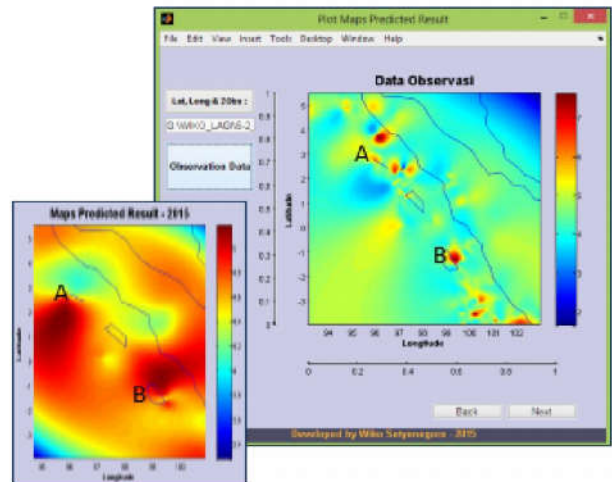
Kemudian data observasi gempa bumi yang telah dipelajari perilakunya, diprediksi menggunakan FIS (*Fuzzy Inference System*) yang ditampilkan pada gambar 16.

Output yang dihasilkan pada proses prediksi melalui tampilan kurva, ditampilkan juga dalam bentuk kolom hasil prediksi melalui command Matlab (Tabel 3).

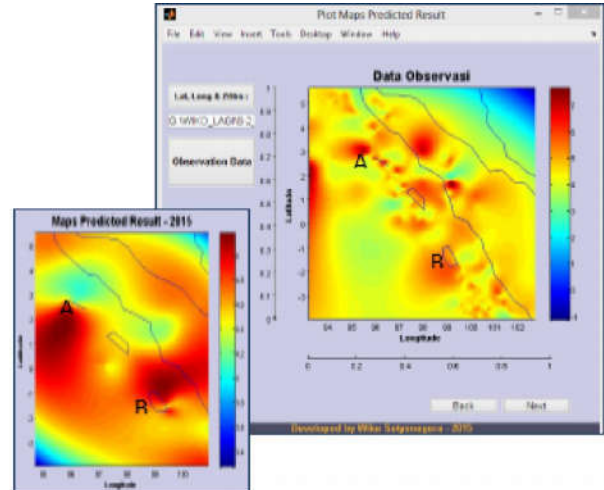
Tabel 3. Tampilan hasil prediksi gempa bumi rata-rata 10 harian.

Nomor	Lat Rata 10 Hr	Long Rata 10 Hr	Val 10 Hr
1	-1.56	99.44	4.77
2	5.52	94.70	4.66
3	0.35	98.42	4.79

Hasil prediksi gempa bumi yang diperoleh selanjutnya diplot pada peta untuk menampilkan anomali wilayah yang berpotensi menghasilkan energi gempa bumi lebih besar dibandingkan dengan area sekitarnya. Peta prediksi gempa bumi wilayah Sumatra tahun 2015 ditampilkan pada gambar 17 berdampingan dengan data historis observasi gempa bumi tahun 2009 – 2011 (2 tahun), dengan tujuan agar dapat divalidasi konsistensi anomali kejadian gempa bumi pada peta.



Gambar 17. Peta 3D model prediksi periode ulang gempa bumi tahun 2015 (1) dibandingkan dengan data historis observasi kejadian gempa bumi tahun 2009 – 2011.

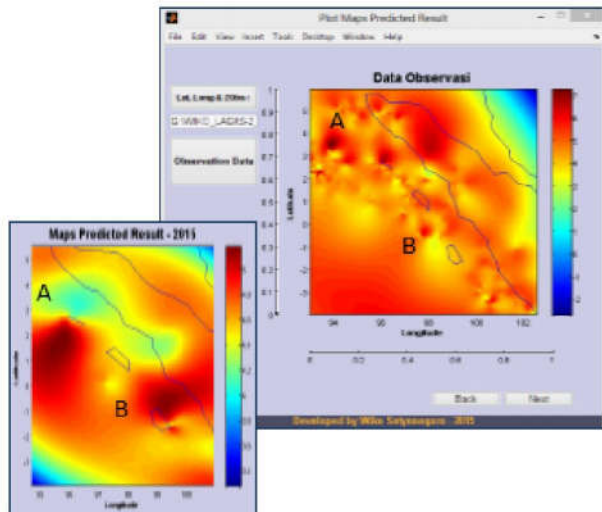


Gambar 18. Peta 3D model prediksi periode ulang gempa bumi tahun 2015 (2) dibandingkan dengan data historis observasi kejadian gempa bumi tahun 2011 – 2013.

Pada gambar 18, peta model prediksi dan data observasi 2009 – 2011 menunjukkan akumulasi anomali terkonsentrasi pada area A Pulau Siberut, dan B, Pulau Nias, anomali ini tidak berbeda jauh dengan anomali data observasi 2011 – 2013 yang

ditampilkan pada gambar 18. Mengenai akurasi prediksi model dijelaskan pada pembahasan selanjutnya.

Untuk plot anomali data historis observasi gempa bumi tahun 2013 – 2014 pada gambar 19 anomali data observasi gempa bumi terlihat pada area lainnya, namun masih menunjukkan anomali yang sesuai dengan peta hasil prediksi model.



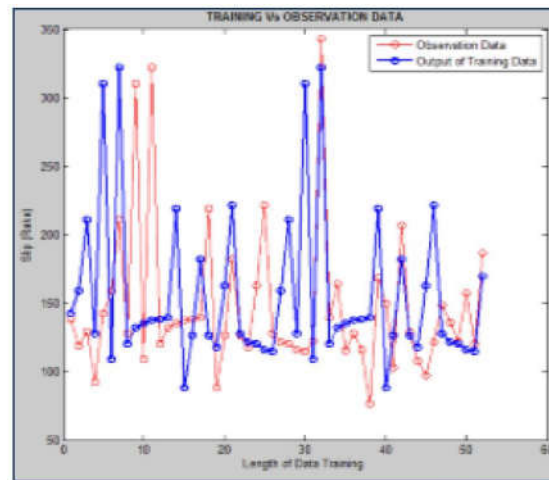
Gambar 19. Peta 3D model prediksi periode ulang gempa bumi tahun 2015 dibandingkan dengan data historis observasi kejadian gempa bumi tahun 2013 – 2014.

4.2.2. Hasil Prediksi Parameter Mekanisme Sumber Gempabumi (Bola Focal)


Output Prediksi Periode Ulang kejadian gempa bumi dengan parameter Bola Focal bulanan dan 15 Harian. Output dari model mekanisme sumber berikut ini adalah proses training data yang dilakukan pada ANFIS dengan parameter mekanisme sumber gempa bumi : Strike, Dip dan rake. Error yang diperoleh dari beberapa langkah *training dan checking data* diperlihatkan melalui beberapa keterangan dibawah ini.

Hasil pembelajaran *training dan checking* data observasi gempa bumi selama 2 tahun telah dipelajari oleh ANFIS dan di plot secara overlay dengan data observasi sesungguhnya, sehingga terlihat bahwa ANFIS telah melakukan pengenalan terhadap pola perilaku kejadian gempa bumi pada suatu wilayah yang dalam hal ini studi kasus di wilayah Sumatra (gambar 20).

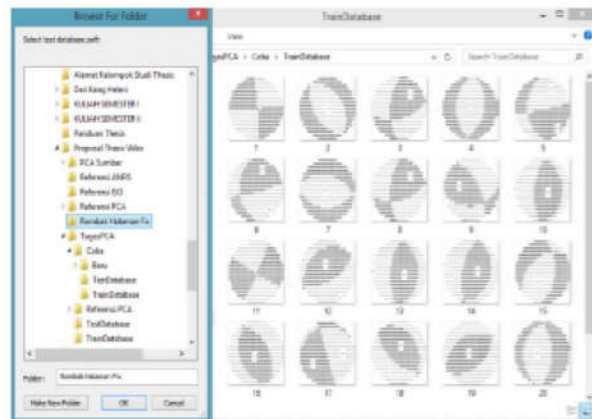
Kemudian data observasi gempa bumi yang telah dipelajari perilakunya, diprediksi menggunakan FIS (*Fuzzy Inference System*) yang ditampilkan pada gambar 20. Output yang dihasilkan pada proses prediksi melalui tampilan kurva, ditampilkan juga dalam bentuk kolom hasil prediksi rata-rata bulanan dan rata-rata 15 harian melalui command Matlab.



Gambar 20. Hasil *Training and Checking* data untuk parameter mekanisme sumber gempa bumi / bola focal (strike).



Gambar 21. Prediksi gempa bumi untuk parameter mekanisme sumber gempa bumi / bola focal dalam rata-rata bulanan.




Gambar 22. Database tipe bola focal dengan ukuran dimensi sama yang akan ditraining untuk mengenali bola focal hasil prediksi.


Dari kurva pada gambar 20 ditampilkan masing-masing nilai parameter bola focal dari bulan ke-1 sampai dengan bulan ke 12. Identifikasi tipe mekanisme sumber gempa bumi dengan PCA dilakukan dengan menjalankan program “*Start Recognition (PCA)*”, maka akan tampil jendela “*browse for*

Folder” untuk menuju direktori database tipe-tipe bola focal yang akan ditraining oleh PCA. Data yang akan ditraining dan data yang siap untuk diidentifikasi merupakan citra image dengan ukuran dimensi yang sama (gambar 21).

Setelah ditraining kemudian dilanjutkan dengan menuju direktori dimana data hasil prediksi yang akan diidentifikasi ditunjukkan pada gambar 23.



Gambar 23. Perintah input data image yang akan dikenali oleh database tipe mekanisme sumber gempa bumi (bola focal).



Gambar 24. Hasil prediksi parameter mekanisme sumber gempa bumi (bola focal) yang akan diidentifikasi menggunakan PCA.

Dengan ukuran dimensi yang sama maka proses identifikasi bola focal menghasilkan output tipe mekanisme sumber (bola focal) dari bulan ke-1 sampai bulan ke-12.

Tabel 4. Hasil Identifikasi tipe bola focal hasil prediksi gempa bumi tahun 2015.

No	Bulan	Hasil Identifikasi dan Prediksi
1	1	Strike ke Barat Daya, Sesar Naik oblique, Deformasi Horizontal
2	2	Strike ke Barat, Sesar naik oblique, Deformasi Horizontal
3	3	Strike ke Utara, Sesar naik Oblique, Deformasi Vertikal
4	4	Strike ke Arah Barat Laut, Sesar naik oblique, Deformasi Vertikal
5	5	Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal
6	6	Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal
7	7	Strike ke Arah Barat, Sesar naik oblique, Deformasi Vertikal
8	8	Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal
9	9	Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal
10	10	Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal
11	11	Strike ke Arah Selatan, Sesar naik oblique, Deformasi Vertikal
12	12	Strike ke Arah Selatan, Sesar naik oblique, Deformasi Vertikal

Pembahasan tabel 4, menerangkan bahwa identifikasi untuk hasil prediksi gempa bumi berorientasi pada Strike ke Arah Barat Daya, Sesar naik oblique, Deformasi Vertikal, hal ini menjelaskan perilaku yang sesungguhnya dari pergerakan dinamika lempeng penyebab gempa bumi di bagian Barat Sumatra.

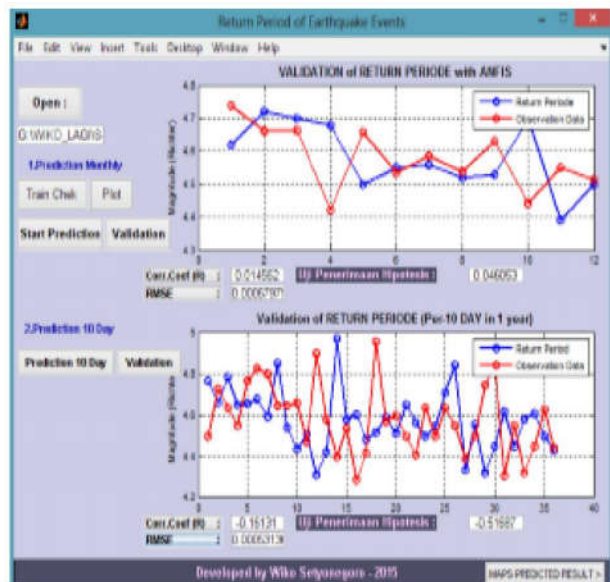
4.3. Pengujian Validasi

Berdasarkan output prediksi periode ulang kejadian gempa bumi untuk parameter Magnitudo, diperoleh hasil pengujian validasi menggunakan koefisien korelasi, RMSE dan

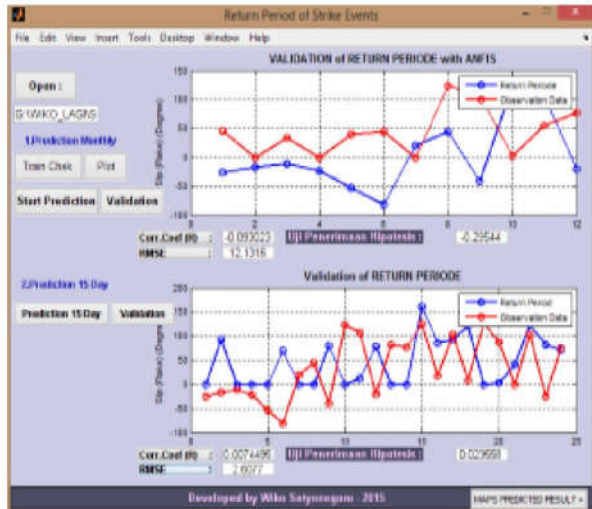
uji penerimaan hipotesis diperoleh beberapa kesimpulan dan analisis diantaranya adalah dari hasil yang diperoleh dengan perumusan di atas, nilai koefisien korelasi (r) dapat diketahui tingkat pengaruh variabel X dengan variabel Y . Pada hakikatnya, nilai r dapat bervariasi dari -1 hingga $+1$, atau secara matematis dapat ditulis menjadi $-1 \leq r \leq +1$

Bila $r = 0$ atau mendekati 0 , maka korelasi antar kedua variabel sangat lemah atau tidak terdapat hubungan antara variabel X terhadap variabel Y . Bila $r = +1$ atau mendekati $+1$, maka korelasi antar kedua variabel dikatakan positif. Bila $r = -1$ atau mendekati -1 , maka korelasi antar kedua variabel dikatakan negatif.

Hasil yang diperoleh melalui perumusan pengujian untuk parameter magnitudo menunjukkan, model prediksi periode ulang kejadian gempa bumi untuk rata-rata periode ulang bulanan menunjukkan koefisien korelasi 0.014562 , artinya masih berada pada selang nilai yang memenuhi dengan kriteria korelasi yang lemah, sedangkan koefisien korelasi rata-rata periode ulang 10 harian yang lebih rapat dengan nilai lebih mendekati 1 menunjukkan korelasi kuat dengan nilai -0.1613 (gambar 25). Sedangkan untuk parameter bola focal pada gambar 26, ditunjukkan bahwa nilai koefisien korelasi lebih kuat pada selang bulanan (implikasi) akan tetapi memiliki RMSE yang besar dibandingkan rata-rata 15 harian.



Gambar 25. Pengujian validasi model prediksi dengan menggunakan teknik koefisien korelasi, RMSE dan Uji hipotesa antara model dan sampel data observasi untuk parameter Magnitudo. Prediksi tahun 2015 rata-rata bulanan dan 10 harian dari pembelajaran data historis gempa bumi tahun 2009 – 2014.



Gambar 26. Pengujian validasi model prediksi dengan menggunakan teknik koefisien korelasi, RMSE dan Uji hipotesa antara model dan sampel data observasi untuk parameter mekanisme sumber gempa bumi (bola focal). Prediksi tahun 2015 rata-rata bulanan dan 15 harian dari pembelajaran data historis gempa bumi tahun 2013 – 2014.

Pada gambar 25 dan 26 diperlihatkan bahwa, hasil kalkulasi Nilai RMSE yang dihitung untuk membandingkan kinerja model dengan data sampel observasi. Terlihat bahwa nilai RMSE untuk parameter magnitudo antara kurva model dan data observasi menunjukkan nilai error 0.0006797 pada prediksi bulanan dan 0.000531 pada prediksi 10 harian, nilai RMSE terlihat lebih kecil pada selang prediksi 10 harian yang lebih rapat. Begitupun nilai RMSE untuk parameter mekanisme sumber, antara kurva model dan data observasi menunjukkan nilai error 12.1316 pada prediksi bulanan dan 2.6077 pada prediksi 10 harian, nilai RMSE terlihat lebih kecil pada selang prediksi 10 harian yang lebih rapat.

4.4. Analisis Rancangan Pengujian Hipotesis

Berdasarkan kerangka pemikiran, maka diajukan rumus hipotesis sebagai jawaban sementara yang akan diuji dan dibuktikan kebenarannya.

Untuk melihat apakah variabel independen secara bersama-sama (serentak) mempunyai pengaruh yang signifikan terhadap variabel dependen. Melalui uji statistik dengan langkah-langkah sebagai berikut :

Ho : $\rho = 0$ (tidak berkorelasi)

Ha : $\rho \neq 0$ (ada berkorelasi)

Taraf signifikansi $\alpha = 0.05$

Berdasarkan dasar signifikansi, kriterianya adalah :

- Jika signifikansi > 0.05 maka H_0 diterima.

- Jika signifikansi < 0.05 maka H_0 ditolak.

Uji statistik dengan daerah kebebasan $df = n-2$

$$t = \frac{r}{\sqrt{\frac{1 - r^2}{n - 2}}}$$

Setelah diperoleh nilai t_{hitung} , selanjutnya dibandingkan dengan t_{tabel} pada $\alpha = 5\%$ dan $df = n-2$ untuk pengujian dua pihak, dengan ketentuan sebagai berikut :

Jika $t_{hitung} \geq t_{tabel}$ atau $-t_{hitung} \leq -t_{tabel}$ maka H_0 ditolak.

-Jika $t_{hitung} < t_{tabel}$ atau $-t_{hitung} < -t_{tabel}$ maka H_0 diterima.

Berdasarkan dasar signifikansi, kriterianya adalah :

- Jika signifikansi > 0.05 maka H_0 diterima.

- Jika signifikansi < 0.05 maka H_0 ditolak.

Dengan melihat harga t_{hitung} pada output model prediksi rata-rata bulanan, signifikansi < 0.05 dengan nilai 0.046, mengindikasikan pengujian hipotesis ditolak karena berada pada daerah penolakan H_0 melalui taraf signifikansi, sehingga melalui beberapa alasan yaitu panjang data pembelajaran yang kurang atau rata-rata selang tidak rapat, dan untuk prediksi rata-rata 10 harian signifikansi > 0.05 dengan nilai -0.516, hipotesis pun ditolak. Sehingga melalui pengujian ini dapat diduga kuat bahwa kerapatan panjang data observasi yang dipelajari oleh ANFIS akan sangat mempengaruhi akurasi dari model prediksi gempa bumi.

5. KESIMPULAN

Berdasarkan tujuannya, dari hasil pengolahan data diperoleh beberapa kesimpulan, yaitu :

1. Ditampilkan output hasil pembelajaran data historis 5 tahun kejadian gempa bumi berupa tampilan model prediksi periode ulang kejadian gempa bumi untuk parameter rata-rata magnitudo bulanan dan rata-rata 10 harian. Hasil prediksi ditampilkan dalam angka dan plot 3D distribusi anomali hasil prediksi gempa bumi.
2. Ditampilkan hasil model prediksi periode ulang kejadian gempa bumi dari pembelajaran data historis 2 tahun untuk parameter rata-rata bola focal bulanan dan rata-rata 15 harian. Ditampilkan juga, identifikasi pengenalan citra bola focal sebagai hasil model prediksi gempa bumi beserta keterangan hasil identifikasi tipe mekanisme sumber gempa bumi yang mengalami perulangan kejadian di wilayah Sumatra
3. Diperoleh hasil Pengujian validitas model prediksi periode ulang kejadian gempa bumi menggunakan koefisien korelasi, RMSE dan Uji Hipotesa.

Hasil ini sesuai dengan hipotesa awal bahwa koefisien korelasi rata-rata periode ulang 10 harian yang lebih rapat dibandingkan rata-rata periode ulang bulanan akan memiliki korelasi yang kuat karena data yang dipelajari akan lebih rapat. Begitupun dengan nilai RMSE terlihat lebih kecil pada selang prediksi 10 harian yang lebih rapat. Sama halnya RMSE untuk parameter mekanisme sumber, antara kurva model dan data

observasi menunjukkan nilai eror yang memenuhi pada prediksi 10 harian, nilai RMSE terlihat lebih kecil pada selang prediksi 10 harian yang lebih rapat.

Hasil pengujian hipotesa dengan melihat harga t_{hitung} pada output model prediksi rata-rata bulanan, mengindikasikan pengujian hipotesis ditolak karena berada pada daerah penolakan H_0 melalui taraf signifikansi, sehingga melalui beberapa alasan yaitu panjang data pembelajaran yang kurang atau rata-rata selang tidak rapat, sedangkan untuk prediksi rata-rata 10 hipotesis diterima. Sehingga melalui pengujian ini dapat diduga kuat bahwa kerapatan dan panjang data observasi yang dipelajari oleh ANFIS akan sangat mempengaruhi akurasi dari model prediksi gempabumi

DAFTAR PUSTAKA

- [1] Sumarwan R, dan Permadhi, Y, F., *Aplikasi Metode ANFIS untuk Prediksi Curah Hujan di Pulau Jawa Bagian Barat*. 2010
- [2] USGS. *Moment Tensor Solutions*. [http://www.iris.edu/hq/programs/education_and_outreach /animations/25](http://www.iris.edu/hq/programs/education_and_outreach/animations/25), (Diakses tanggal 12 Desember 2013).
- [3] Achmad Hidayatno. *Penentuan Wilayah Wajah Manusia pada Citra Berwarna Berdasarkan Warna Kulit Dengan Metode Template Matching*, jurnal Universitas Diponegoro, Vol. 5 No. 2 Juli – Desember 2006
- [4] ANSS. *Advanced National Seismic System - Focal Mechanism*. <http://earthquake.usgs.gov/monitoring/?source=sitenav>, (Diakses tanggal 12 Desember 2013).
- [5] Jang JSR, Tsai Sun C., Mizutani E. *Neuro-Fuzzy and Soft Computing, a Computational Approach to Learning and Machine Intelligence*, Prentice Hall, Upper Saddle River, NJ 07458. 1997
- [6] Laudon, Kenneth C and Laudon, Jane P., *Sistem Informasi Manajemen*, Jakarta: Salemba Empat, 2008
- [7] Kusumadewi, Sri., and Hartati, Sri., *Neuro Fuzzy Integrasi sistem Fuzzy dan Jaringan Syaraf*. Yogyakarta: Graha Ilmu, 2010
- [8] Goupeng Z. *Data Analysis With Fuzzy Inference System. In Computational Intelligence: Method and Application*. Singapore: School of Computer Engineering, Nanyang Technological University, 2006
- [9] Nazori. *Bahan Pengajaran Kuliah Teknik Komputasi, Implementasi dengan Matlab*. Magister Komputer Universitas Budi Luhur. 2011
- [10] Chandra Sekaran S et al. *An Eigenspace Update Algorithm for Image Analysis*, Department of Electrical and Computer Engineering University of California, Santa Barbara, 1997
- [11] Romdhani. *Face Recognition Using Principal Component Analysis*, http://eeapp.elec.gla.ac.uk/~romdhani/pca_doc/pca_doc_toc.htm. 1997. (Diakses tanggal 12 Desember 2014).
- [12] Geofon, *Moment Tensor Solutions*. <http://geofon.gfz-potsdam.de/eqinfo/list.php?mode=mt>, (diakses tanggal 12 Desember 2013).