

OPTIMASI PENENTUAN STATUS AKTIVITAS GUNUNG MERAPI MENGUNAKAN METODE *HYBRID ANFIS* DAN *PARTICLE SWARM OPTIMIZATION (PSO)*

*Optimization of the Activity sSatus of Mount Merapi using a hybrid method ANFIS
and Particle Swarm Optimization (PSO)*

Bagus Fatkhurrozi^{1*}, M. Aziz Muslim², Didik R. Santoso³

¹ Program Studi Teknik Elektro Universitas Tidar

Jl. Kapten Suparman 39 Magelang Telp. (0293)364113

² Jurusan Teknik Elektro, Fakultas Teknik, Universitas Brawijaya

Jl Raya M.T Haryono 167 Malang Indonesia 65145

³ Jurusan Fisika, Fakultas MIPA, Universitas Brawijaya

Jl Veteran Malang 65145

*Email : bagusf@untidar.ac.id

ABSTRAK

Tujuan penelitian ini adalah membuat model penentuan status aktivitas Gunung Merapi menggunakan metode hybrid ANFIS dan Particle Swarm Optimization (PSO). Data yang digunakan adalah data sekunder hasil pemantauan dari aktivitas kegempaan, deformasi tanah, dan geokimia Gunung Merapi. Data pelatihan menggunakan periode data prekursor erupsi Gunung Merapi tahun 1997, 1998, 2001, dan 2006. Data pengujian menggunakan data prekursor erupsi Gunung Merapi tahun 2010. Dari proses penelitian diperoleh hasil yaitu pada proses pelatihan, RMSE hybrid ANFIS-PSO sebesar 0,0877 dan MAPE pelatihan ANFIS-PSO sebesar 16,2518%. Pada proses pengujian, metode hybrid ANFIS-PSO dapat memperbaiki MAPE hasil pengujian ANFIS yang sebesar 10,2041% menjadi 8,3333%.

Kata kunci : status aktivitas, Gunung Merapi, ANFIS, PSO

ABSTRACT

The purpose of this study is to model the activity status of Mount Merapi using a hybrid method ANFIS and Particle Swarm Optimization (PSO). The data used is secondary data monitoring of seismic activity, ground deformation, and geochemistry of Mount Merapi. Training data using the data period precursor eruption in 1997,1998, 2001, and 2006. Test data using data precursor eruption in 2010. In the process of training the RMSE hybrid ANFIS-PSO is 0.0877. using criterion MAPE, during training ANFIS-PSO produce MAPE 16.2518%. During testing process, a hybrid method ANFIS-PSO can improve the ANFIS MAPE test results by 10.2041% to 8.3333%.

Key word : activity status, Mount Merapi, ANFIS, PSO

PENDAHULUAN

Gunung Merapi termasuk gunung berapi yang paling aktif di dunia. Sampai 2010, erupsi yang tercatat sudah mencapai 84 kali kejadian. Secara rata-rata selang waktu erupsi Merapi terjadi antara 2-5 tahun (periode pendek), sedangkan selang waktu periode menengah setiap 5-7 tahun (BPPTK).

Setiap kali terjadi erupsi disamping sering mengakibatkan korban meninggal, juga akan menimbulkan dampak kerugian yang sangat besar. Sejak pertengahan tahun 1500-an telah terjadi kira-kira 7.000 kematian yang

disebabkan oleh aktivitas vulkanis Gunung Merapi. Ratusan desa telah dimusnahkan bersama dengan ribuan hektar tanah pertanian dan hutan selama 300 tahun. Efek letusan terus meningkat dan lebih membinasakan karena meningkatnya kepadatan penduduk di sekitar Merapi (Wilson dkk, 2007).

Peringatan dini diperlukan untuk mengurangi risiko bencana bagi masyarakat. Sistem berfungsi untuk menyampaikan informasi terkini status aktivitas Gunung Merapi dan tindakan-tindakan yang harus diambil oleh berbagai pihak. Ada empat tingkat status aktivitas untuk mitigasi bencana erupsi Gunung Merapi, yaitu:

Aktif Normal, Waspada, Siaga, dan Awas (BPPTK).

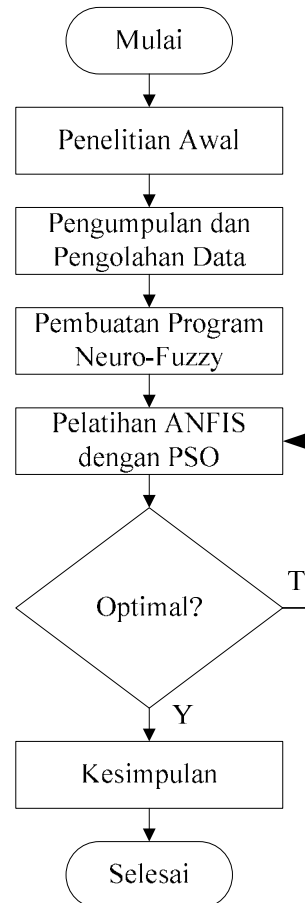
Metode hybrid Adaptive Neuro-Fuzzy Inference System (ANFIS)-Particle Swarm Optimization (PSO) telah digunakan oleh beberapa peneliti sebelumnya. Allaoua, dkk (2009) menyatakan bahwa kontroler ANFIS yang optimal dapat dirancang menggunakan algoritma PSO dalam sistem pengendalian kecepatan motor DC.

Penggunaan implisit logika fuzzy dengan jaringan syaraf dapat meningkatkan kemampuan prediksi jaringan syaraf dengan bantuan data keuangan nyata *time-series*. PSO berdasarkan pelatihan algoritma memberikan kemampuan peramalan yang lebih baik sehubungan dengan MSE dan MAE di semua tiga kawasan peramalan dibandingkan dengan ANFIS dan jaringan syaraf tiruan standar. (Jha dkk, 2009).

Dalam paper terdahulu, kami telah menggunakan menggunakan *Adaptive Neuro Fuzzy Inference System* (ANFIS) dalam Penentuan Status Aktivitas Gunung Merapi (Fatkhurrozi dkk, 2012). Dalam paper ini kami menggunakan metode hybrid Anfis dan Particle Swarm Optimization (PSO) pada penentuan status aktivitas Gunung Merapi.

METODE PENELITIAN

Penelitian awal yaitu mempelajari penelitian (riset) yang yang terkait dengan topik, kemudian dilakukan pengumpulan dan pengolahan data. Tahap selanjutnya adalah pembuatan program neuro-fuzzy dengan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Program ANFIS dibuat dengan pelatihan PSO. Setelah program selesai kemudian dilakukan pengujian, jika sudah didapatkan hasil yang baik (error dan epoch sudah optimal) maka akan dilanjutkan ke tahap selanjutnya, yaitu penarikan kesimpulan. Digram alir metodologi penelitian ditunjukkan pada Gambar 1.

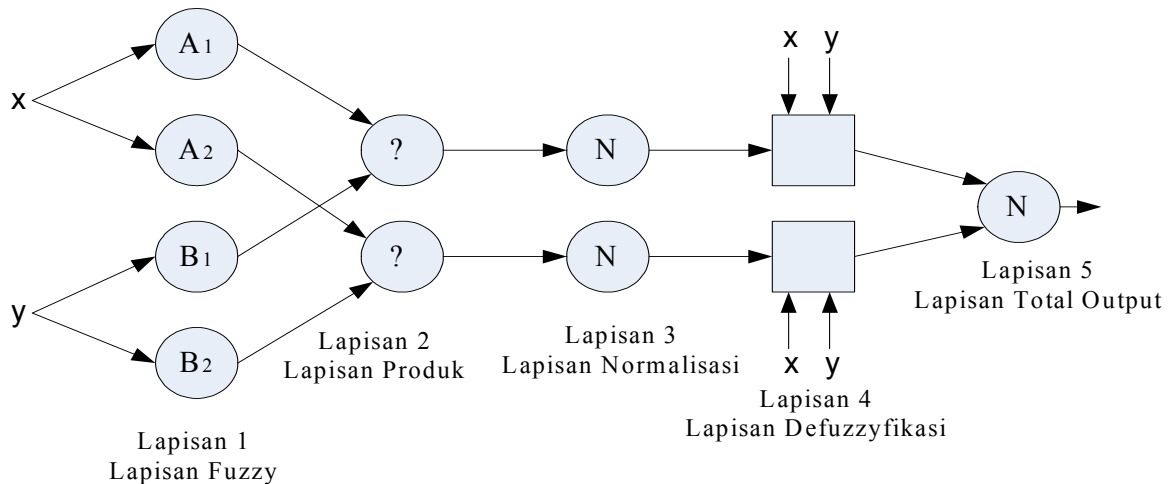


Gambar 1. Diagram alir metode penelitian

Adaptive Neuro-Fuzzy Inference System (ANFIS)

Salah satu kombinasi logika fuzzy dengan jaringan syaraf tiruan adalah *Adaptive Neuro Fuzzy Inference System* (ANFIS). Struktur jaringan ANFIS ditunjukkan pada Gambar 2. Struktur ini menggambarkan proses yang terdapat pada sistem logika fuzzy. Proses pembelajaran jaringan syaraf tiruan digunakan untuk mengoptimalkan nilai parameter fuzzyfikasi.

Dalam sistem Neuro-Fuzzy terdapat lima lapisan proses yang mana fungsi dan persamaan masing-masing lapisannya dijelaskan sebagai berikut:



Gambar 2. Struktur Anfis

Lapisan 1: Lapisan Fuzzyfikasi

Jadikan $O_{1,i}$ menjadi output setiap node pada lapisan 1. Setiap node i pada lapisan ini adalah node adaptif dengan fungsi node $O_{1,i} = \mu_{A_i}(x)$ untuk $i = 1, 2$; atau $O_{1,i} = \mu_{B_i}(y)$ untuk $i = 1, 2$, dengan x adalah input ke node i dan A_i adalah label linguistik (kecil, besar, dan sebagainya) yang sesuai dengan fungsi node ini. Di bagian lain $O_{1,i}$ adalah fungsi keanggotaan dari A_1 dan derajat keanggotaannya spesifik untuk pemberian x yang memadai pengkuantisasi A_i . Fungsi keanggotaan

yang banyak digunakan adalah bentuk Bell (lonceng) dan Gaussian.

Fungsi keanggotaan bentuk Bell dinyatakan dengan:

$$f(x, a, b, c) = \frac{1}{1 + \frac{x - c^{2b}}{a}} \quad (1)$$

dengan parameter b biasanya positif. Parameter c letaknya di tengah kurva. Fungsi keanggotaan Gaussian dinyatakan dengan:

$$f(x, a, b, c) = \frac{1}{1 + \frac{x - c^{2b}}{a}} \quad (2)$$

Lapisan 2: Lapisan Produk

Setiap node pada lapisan ini terdiri atas operator prod t-norm sebagai fungsi node. Lapisan ini mensintesisasikan pentransmision informasi dengan lapisan 1 dan perkalian semua sinyal yang masuk dan mengirim

produk keluar. Output dari lapisan produk dinyatakan dengan:

$$O_{2,i} = \mu_{A_j}(x) \cdot \mu_{B_j}(y) = W_j \quad (3)$$

Setiap node pada lapisan ini melayani sebagai ukuran kekuatan dari rule (aturan). Output pada lapisan ini bertindak sebagai fungsi bobot.

Lapisan 3: Lapisan Normalisasi

Setiap node pada lapisan ini menormalisasi fungsi bobot yang didapat dari lapisan produk sebelumnya. Output normalisasi dihitung dengan:

$$f(x, a, b, c) = \frac{1}{1 + \frac{x - c^{2b}}{a}} \quad (4)$$

Lapisan 4: Lapisan Defuzzyfikasi

Node pada lapisan ini adalah adaptif alami. Output defuzzyfikasi dari lapisan ini dihitung dengan formula:

$$O_{4,i} = O_{3,i}(\alpha_{4,i} = O_{3,i}(\alpha_i x) + \beta_i y + \gamma_i) \quad (5)$$

dengan α_i , β_i and γ_i adalah linier parameter konsekuen kesesuaian node i .

Lapisan 5: Lapisan Total Output

Node tunggal pada lapisan ini mensintesisasikan informasi yang dikirimkan dengan lapisan 4 dan mengembalikan keseluruhan output menggunakan fungsi tetap berikut:

$$f(x, a, b, c) = \frac{1}{1 + \frac{x - c^{2b}}{a}} \quad (6)$$

(Sumathi, 2010).

Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) merupakan salah satu metode optimasi yang dikembangkan oleh Dr. Eberhart dan Dr. Kennedy pada tahun 1995. PSO diinspirasi oleh perilaku sosial yang ada di sekitar kita, seperti perilaku sekumpulan burung dan juga sekumpulan ikan.

Berdasarkan penelitian pada sekawanan burung yang terbang bersama, diketahui bahwa mereka dapat menemukan makanan lebih mudah dibandingkan dengan burung yang terbang sendirian. Hal tersebut membuat seolah-olah ada sebuah informasi yang dibagikan di dalam sekawanan burung tersebut.

Sama halnya dengan pengamatan perilaku sekumpulan orang, dimana perilaku setiap individu juga mengacu kepada sebuah standar perilaku yang disahkan oleh kelompok tersebut, contohnya seperti tradisi dan adat istiadat, dan juga standar perilaku lain yang disesuaikan dengan pengalaman masing-masing individu. Asumsi-asumsi tersebut menjadi konsep dasar dari PSO.

Pada awalnya, PSO dikembangkan melalui simulasi dari sekawanan burung yang terbang pada ruang dua dimensi. Posisi dari setiap agen diwakili oleh koordinat X dan Y, dan kecepatan dari agen juga diekspresikan dengan v_x (kecepatan pada sumbu X) dan v_y (kecepatan pada sumbu Y). Posisi agen yang ada dapat dimodifikasi oleh informasi kecepatan dan juga posisi agen yang lalu.

Di dalam PSO, *partikel* (solusi yang mungkin) yang ada terbang di sebuah ruang pencarian yang multidimensional. Saat terbang, setiap *partikel* menyesuaikan posisi mereka berdasarkan pengalaman yang mereka miliki dan juga berdasarkan pengalaman yang dimiliki oleh *partikel* tetangga mereka, sehingga *partikel-partikel* tersebut akan memanfaatkan posisi terbaik yang ditemukan baik oleh dirinya sendiri dan juga *partikel* lain. Dengan demikian, evolusi pada PSO hanya mengarah pada hasil yang terbaik.

Algoritma PSO

Algoritma PSO dimulai dengan membangkitkan sejumlah nilai awal acak. Jika $x_i(t)$ menyatakan posisi partikel i dalam ruang pencarian pada *timestep*; kecuali dinyatakan lain, t menunjukkan langkah-langkah waktu diskrit. Posisi partikel diubah dengan

menambahkan kecepatan, $v_i(t)$, untuk posisi saat ini, yaitu

$$x_i(t) = x_i(t-1) + v_i(t) \quad (7)$$

Vektor kecepatan mendorong proses optimasi, dan mencerminkan baik pengetahuan pengalaman dari partikel dan pertukaran informasi sosial dari lingkungan partikel. Pengetahuan pengalaman dari sebuah partikel umumnya disebut sebagai komponen kognitif, yang sebanding dengan jarak partikel dari posisi sendiri yang terbaik (disebut sebagai posisi *personal best* partikel) yang ditemukan sejak langkah pertamanya. Pertukaran informasi sosial disebut sebagai komponen sosial dari persamaan kecepatan.

Untuk *global best* PSO, atau *gbest* PSO, lingkungan untuk setiap partikel adalah keseluruhan kawanan (*swarm*). Jaringan sosial yang digunakan oleh *gbest* PSO mencerminkan topologi *star*. Untuk topologi lingkungan *star*, komponen sosial dari *update* kecepatan partikel mencerminkan informasi yang diperoleh dari semua partikel dalam kawanan tersebut. Dalam hal ini, informasi sosial adalah posisi terbaik yang ditemukan oleh kawanan, disebut sebagai $p(t)$.

Untuk *gbest* PSO, kecepatan partikel i dihitung sebagai:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t) [y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t) [p_j(t) - x_{ij}(t)] \quad (8)$$

dengan $v_{ij}(t)$ adalah kecepatan partikel i dalam dimensi $j = 1, \dots, n_x$ pada *timestep*, $x_{ij}(t)$ adalah posisi partikel i dalam dimensi j pada *timestep*, c_1 dan c_2 adalah konstanta percepatan positif yang digunakan untuk skala kontribusi dari masing-masing komponen kognitif dan sosial, dan $r_{1j}(t), r_{2j}(t) \sim U(0, 1)$ adalah nilai acak dalam rentang $[0, 1]$, sampel dari distribusi seragam. Nilai-nilai acak memperkenalkan elemen stokastik untuk algoritma.

Posisi terbaik pribadi, y_i , terkait dengan partikel i adalah posisi terbaik partikel yang ada sejak langkah pertamanya. Mempertimbangkan masalah minimisasi, posisi terbaik pribadi pada langkah waktu berikutnya, $t + 1$, dihitung sebagai:

$$y_i(t+1) = \begin{cases} y_i(t) & \text{jika } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{jika } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (9)$$

dengan $f: R \rightarrow R^{n_x}$ adalah fungsi fitness. Seperti EA, fungsi fitness mengukur seberapa dekat solusi yang sesuai adalah dengan optimal, yaitu fungsi fitness mengkuantifikasi kinerja, atau kualitas, dari partikel (atau solusi).

Posisi terbaik secara global, $\hat{y}(t)$, pada *timestep*, didefinisikan sebagai:

$$\hat{y}(t) \in \{y_0(t), \dots, y_{n_s}(t)\} | f(\hat{y}(t)) = \min \{f(y_0(t)), \dots, f(y_{n_s}(t))\} \quad (10)$$

dengan n_s adalah jumlah total partikel dalam kawanan tersebut. Penting untuk dicatat bahwa definisi dalam persamaan menyatakan bahwa \hat{y} adalah posisi terbaik yang ditemukan oleh salah satu partikel, biasanya dihitung sebagai posisi terbaik dari personal terbaik. Posisi *global best* juga dapat dipilih dari partikel kawanan saat ini, dalam hal ini:

$$\hat{y}(t) = \min \{f(x_0(t)), \dots, f(x_{n_s}(t))\} \quad (11)$$

(Engelbrecht, 2007)

HASIL DAN PEMBAHASAN

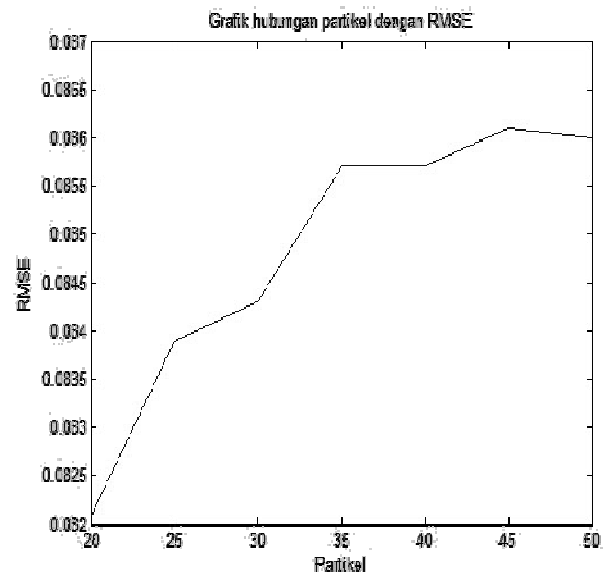
Proses penentuan status aktivitas Gunung Merapi mempertimbangkan data-data input yang sudah diperoleh sebelumnya. Data yang digunakan pada proses pelatihan adalah data erupsi tahun 1995-2008 sebanyak 346 pasangan data, kemudian parameter akhir jaringan digunakan pada proses pengujian dengan data erupsi tahun 2010 sebanyak 49 pasangan data.

Pada metode *hybrid ANFIS-PSO*, pemilihan jumlah partikel dan jumlah iterasi memegang peranan penting untuk menentukan hasil optimasi yang diperoleh. Pengujian dilakukan terhadap *hybrid ANFIS-PSO* dengan jumlah *partikel* yang berbeda-beda, tetapi dengan jumlah iterasi, w_{min} dan w_{max} masing-masing 0.4 dan 0.9 serta kombinasi c_1 dan c_2 yang sama, yaitu 1.496.

Proses pelatihan

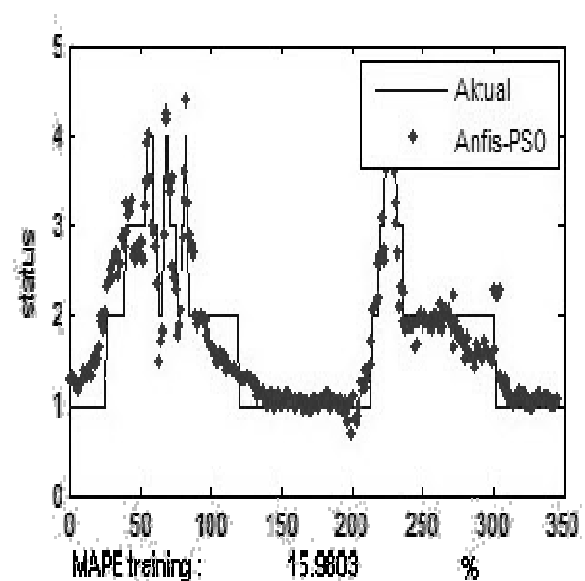
Pada proses pelatihan dengan *hybrid ANFIS-PSO*, jumlah partikel berpengaruh terhadap terhadap RMSE yang dihasilkan.

Jumlah partikel yang besar menyebabkan nilai RMSE yang dihasilkan juga bertambah besar. Proses pelatihan dilakukan dengan jumlah partikel dari 20 sampai 50 partikel dengan kenaikan setiap 5 partikel. Jumlah partikel berpengaruh terhadap RMSE yang dihasilkan, dimana semakin banyak partikel, RMSE cenderung akan semakin bertambah. Pengaruh jumlah partikel terhadap RMSE ditunjukkan pada Gambar 3.



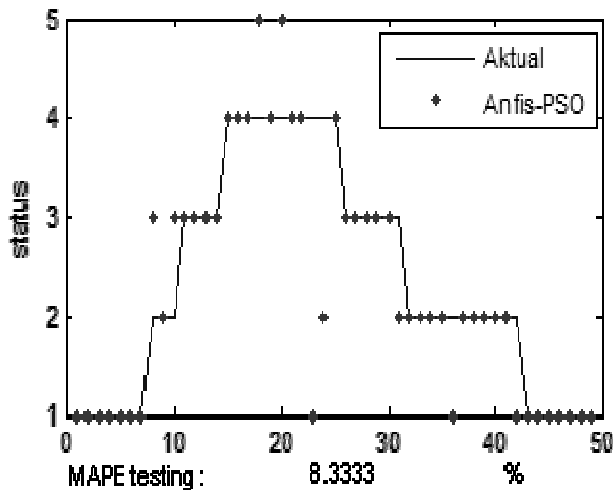
Gambar 3. Pengaruh jumlah partikel terhadap RMSE

Kesalahan rata-rata (MAPE) yang dihasilkan sebesar 15,9803% dengan grafik perbandingan antara status aktivitas gunung Merapi aktual dengan hasil dari pelatihan *hybrid ANFIS-PSO* ditunjukkan pada Gambar 4.



Gambar 4. Grafik perbandingan status aktual dengan pelatihan *hybrid ANFIS-PSO*

Hasil dari proses pelatihan kemudian digunakan pada proses pengujian. Hasil pengujian memberikan rata kesalahan (MAPE) sebesar 8,3333 % yang hasilnya ditunjukkan pada Gambar 5.



Gambar 5. Grafik perbandingan pengujian status aktual dan hybrid ANFIS-PSO

Dari grafik perbandingan pengujian antara status aktual dengan hasil pengujian *hybrid ANFIS-PSO* dapat dilihat bahwa secara garis besar hasil penentuan dengan *hybrid ANFIS-PSO* sudah mendekati nilai aktual status aktivitas Gunung Merapi. Perbedaan terbesar terjadi pada periode status Awas. Pada pekan ke-20 nilai *hybrid ANFIS-PSO* berada di atas status aktual, hal ini karena terjadinya peningkatan yang signifikan gejala-gejala prekursor erupsi. Selanjutnya pada pekan ke-21 sampai pekan ke-25 hasil dari *hybrid ANFIS-PSO* berada di bawah nilai aktual. Hal ini terjadi karena gejala-gejala prekursor erupsi Gunung Merapi mengalami penurunan yang cukup tinggi setelah terjadinya erupsi.

Analisis hasil penentuan status aktivitas Gunung Merapi dengan hybrid ANFIS-PSO

Pada proses pelatihan, jumlah partikel berpengaruh terhadap RMSE dan MAPE yang dihasilkan. Semakin banyak partikel yang digunakan, RMSE juga semakin tinggi. Setiap

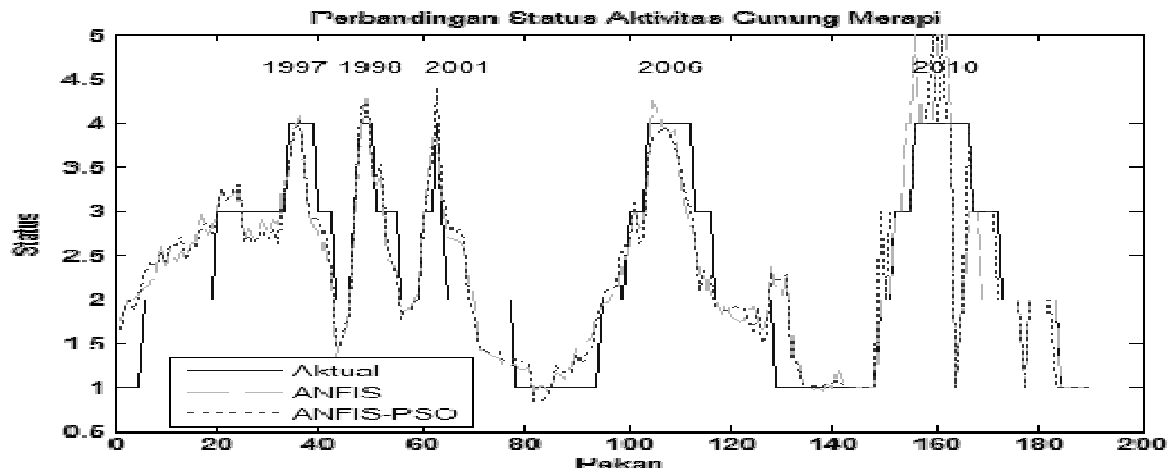
partikel mempunyai pengetahuan yang berbeda-beda. Semakin banyak partikel, maka akan semakin banyak informasi yang masuk, dan itu juga sebanding dengan jumlah kesalahan informasi dari tiap partikel.

Pada proses pengujian, penentuan status aktivitas Gunung Merapi dengan metode hybrid ANFIS-PSO mempunyai perilaku hampir sama dengan penentuan menggunakan ANFIS. Ia juga terpengaruh dengan data yang kurang memenuhi syarat sebagai data peramalan *time series*, akan tetapi dapat memberikan error kesalahan rata-rata lebih kecil dibanding dengan ANFIS, yaitu MAPE-nya sebesar 8,3333%.

Hasil pengujian yang diperoleh menunjukkan bahwa penggunaan algoritma *hybrid ANFIS-PSO* memberikan hasil MAPE yang rata-rata lebih kecil dibanding dengan menggunakan ANFIS, dengan pengujian terbaik diberikan oleh *hybrid ANFIS-PSO* pada epoch ke-100 dengan MAPE sebesar 8,3333%. MAPE hasil pengujian ANFIS stabil, tidak terpengaruh oleh jumlah epoch yang digunakan, yaitu sebesar 10,7143%.

Hasil perbandingan hasil pengujian dengan ANFIS dan hybrid ANFIS-PSO ditunjukkan pada Gambar 6. Pada proses pelatihan, yaitu pada periode erupsi tahun 1997,1998, 2001,dan 2006, ANFIS dapat mengenali status aktual dibanding metode hybrid ANFIS-PSO. Hal ini dapat dilihat pada MAPE ANFIS yang sebesar 15,2084% sedangkan MAPE hybrid ANFIS-PSO 15,9803%.

Pada proses pengujian, yaitu pada periode erupsi 2010, metode hybrid ANFIS-PSO lebih baik dalam menentukan status aktivitas Gunung Merapi dibandingkan dengan ANFIS. Hybrid ANFIS-PSO dapat memperbaiki MAPE ANFIS yang sebesar 10,2041% menjadi 8,3333%. Algoritma PSO menghasilkan solusi yang lebih optimal bila dibandingkan dengan algoritma ANFIS karena algoritma PSO memiliki memori sendiri untuk menyimpan nilai *localbest* dan *globalbest* dimana hal ini penting dalam pengupdatean posisi dari partikel.



Gambar 6. Grafik perbandingan status aktual dengan hasil ANFIS dan hybrid ANFIS-PSO

Tabel 1. Perbandingan waktu komputasi ANFIS dan ANFIS-PSO

Epoch		50	100	150	200	250	300	350	400	450	500
Waktu (det)	ANFIS	16	22	28	34	40	46	52	58	64	70
	Anfis-PSO	13	17	19	23	25	28	30	34	38	42

ANFIS-PSO, ini karena pada PSO ada proses nilai random (acak) pada waktu inialisasi.

Pada proses pengujian, yaitu pada saat status awas, baik metode ANFIS maupun hybrid ANFIS-PSO mempunyai tingkat kesalahan yang cukup besar. Hal ini karena erupsi Gunung Merapi 2010, merupakan erupsi besar pertama setelah 80 tahun sejak erupsi besar tahun 1930 atau 1931.

Pengaruh jumlah epoch terhadap waktu komputasi ditunjukkan oleh Tabel 1. Dari hasil tersebut dapat disimpulkan bahwa jumlah epoch berpengaruh terhadap waktu komputasi. Semakin banyak epoch maka waktu komputasi akan semakin lama. Waktu komputasi dari hybrid ANFIS-PSO lebih singkat dibanding dengan ANFIS. Pada ANFIS, setiap kenaikan epoch 50, maka waktu komputasi akan bertambah 6 detik. Sedangkan pada ANFIS-PSO, setiap kenaikan epoch 50, waktu komputasi akan naik bervariasi antara 2-4 detik.

KESIMPULAN

Jumlah partikel yang memberikan hasil MAPE yang optimal dalam penentuan status aktivitas gunung Merapi sebanyak 50 buah partikel. RMSE dan MAPE hasil dari ANFIS lebih stabil dibandingkan hasil dari hybrid

Waktu komputasi tidak terpengaruh oleh laju pembelajaran maupun jumlah partikel, akan tetapi terpengaruh oleh jumlah epoch. Semakin banyak epoch, waktu komputasi akan semakin lama dengan waktu komputasi ANFIS-PSO lebih singkat dibanding ANFIS.

Dalam proses pengujian, penggunaan algoritma *hybrid ANFIS-PSO* dapat memberikan MAPE dibanding dengan menggunakan ANFIS, dengan pengujian terbaik terjadi pada epoch ke-100 dengan MAPE sebesar 8,3333%.

Pengembangan penelitian dapat dilakukan dengan topologi PSO yang berbeda sehingga diharapkan dapat memberikan struktur sosial yang lebih baik.

Dikarenakan MAPE hasil pengujian yang masih cukup tinggi, diperlukan penelitian lebih lanjut dengan metode optimasi yang lain.

DAFTAR PUSTAKA

Allaoua, B., Laoufi, A., Gasbaoui, B. dkk. 2009. *Neuro-Fuzzy DC Motor Speed Control Using Particle Swarm Optimization*. Leonardo Electronic Journal of Practices

and Technologies, Issue 15. ISSN 1583-1078. Page: 1-18.

BPPTK. *Informasi Merapi–Pemantauan*. bgl.esdm.go.id. 20 Juni 2011.

Engelbrecht, AP. 2007. *Computational Intelligence An Introduction Second Edition*. John Wiley and Sons, Ltd. Chichester.

Fatkhurrozi, B., Muslim, M, A., dan Didik R, S. 2013. Penggunaan Adaptive Neuro Fuzzy Inference System (ANFIS) dalam Penentuan Status Aktivitas Gunung Merapi. *Jurnal EECCIS*. Vol. 6 No. 2. 113-118.

Jha, GK., Thulasiram, RK., dan Thulasiram, P. 2009. *Comparison of Adaptive Neuro-Fuzzy and Particle Swarm Optimization Based Neural Network Models for Financial Time Series Prediction*. ASAAC. Ontario.

Wilson, T., Kaye, G., Stewart, C. dkk. 2007. *Impacts of the 2006 eruption of Merapi volcano, Indonesia, on agriculture and infrastructure*. GNS Science Report 2007/07.

Sumathi, S., dan Surekha, P. 2010. *Computational Intelligence Paradigms, Theory and Applications using MATLAB*. CRC Press. Boca Raton.