

Prediksi Muka Air Tanah Perkotaan Menggunakan Hybrid ANFIS-PSO: Studi Kasus Kota Semarang

Oasiska Nuhananing Suharyanto^{1*}, Muhammad Helmi², dan Jafron Wasiq Hidayat³

¹Program Magister Ilmu Lingkungan, Universitas Diponegoro, Indonesia; email: oasiska.ns@gmail.com

²Departemen Oseanografi, Fakultas Perikanan dan Ilmu Kelautan, Universitas Diponegoro, Indonesia

³Departemen Biologi, Fakultas Sains dan Matematika, Universitas Diponegoro, Indonesia

ABSTRAK

Prediksi muka air tanah merupakan hal krusial untuk perencanaan pengelolaan sumber daya air tanah yang berkelanjutan, khususnya di daerah urban seperti Kota Semarang yang rentan terhadap penurunan muka air tanah. Penelitian ini bertujuan mengembangkan model prediksi MAT satu bulan ke depan dengan mengoptimalkan algoritma *Adaptive Neuro-Fuzzy Inference System* (ANFIS) menggunakan *Particle Swarm Optimization* (PSO). Data sekunder dari ESDM Jawa Tengah periode Juni 2019 hingga Agustus 2024 dari tujuh sumur pantau dianalisis dengan variabel *input* muka air tanah bulan sebelumnya (GWL t-1), curah hujan, evapotranspirasi, dan temperatur. Evaluasi kinerja model menggunakan koefisien determinasi (R^2) dan *Root Mean Square Error* (RMSE). Hasilnya menunjukkan akurasi yang bervariasi antar lokasi, dengan R^2 tertinggi 92,77% (RMSE 19,62%) di SMKN 1 Semarang dan R^2 terendah 62,71% (RMSE 16,27%) di PT Savana Tirta Makmur. Variasi akurasi ini diduga kuat dipengaruhi oleh karakteristik akuifer dan kondisi lingkungan setempat yang tidak seragam. Secara keseluruhan, model ANFIS-PSO terbukti robust dalam memprediksi fluktuasi muka air tanah non-linier. Model ini dapat dijadikan sebagai alat pendukung keputusan yang berharga bagi para pemangku kebijakan, misalnya untuk memitigasi risiko overdraft air tanah dan menyusun strategi konservasi yang lebih efektif di Kota Semarang.

Kata kunci: pemodelan, air tanah, ANFIS-PSO, Kota Semarang

ABSTRACT

Accurate groundwater level (GWL) prediction is crucial for sustainable water resource management, particularly in urban areas like Semarang City, which faces challenges of over-extraction and land subsidence. This study aims to develop a one-month-ahead GWL prediction model by optimizing an Adaptive Neuro-Fuzzy Inference System (ANFIS) with Particle Swarm Optimization (PSO). Secondary data from the Central Java Energy and Mineral Resources Agency (ESDM), spanning from June 2019 to August 2024, was analyzed from seven monitoring wells. The input variables included the previous month's GWL (GWL t-1), rainfall, evapotranspiration, and atmospheric temperature. The model's performance was evaluated using the coefficient of determination (R^2) and Root Mean Square Error (RMSE). The results indicate varying predictive accuracy across locations. The highest accuracy was achieved at SMKN 1 Semarang with an R^2 of 92.77% (RMSE 19.62%), while the lowest was at PT Savana Tirta Makmur with an R^2 of 62.71% (RMSE 16.27%). This variability in performance is likely attributable to site-specific hydrogeological conditions. The ANFIS-PSO model demonstrates overall effectiveness in capturing the non-linear dynamics of groundwater fluctuations. The study concludes that the model provides a valuable decision-support tool for policymakers in Semarang to develop proactive groundwater conservation strategies and mitigate the risks associated with over-exploitation.

Keywords: modeling, groundwater level, ANFIS-PSO, Semarang City

Citation: Suharyanto, O. N., Helmi, M., dan Hidayat, J. W. (2025). Prediksi Muka Air Tanah Perkotaan Menggunakan Hybrid ANFIS-PSO: Studi Kasus Kota Semarang. *Jurnal Ilmu Lingkungan*, 23(5), 1394-1403, doi:10.14710/jil.23.5.1394-1403

1. PENDAHULUAN

Air tanah merupakan sumber daya air vital yang menyangga kebutuhan domestik, industri, dan pertanian di seluruh dunia. Dalam konteks perkotaan, tekanan terhadap sumber daya ini semakin meningkat seiring dengan laju urbanisasi dan

pertumbuhan ekonomi. Kondisi ini seringkali berujung pada eksploitasi berlebihan yang mengakibatkan penurunan muka air tanah secara signifikan. Pengukuran muka air tanah melalui sumur pantau atau piezometer menjadi indikator kunci untuk memantau kesehatan akuifer (Fetter, 2001).

Penurunan elevasi muka air tanah yang terus-menerus tidak hanya mengindikasikan kelangkaan air tetapi juga mencerminkan tekanan berat pada akuifer akibat ketidakseimbangan antara eksploitasi dan pengisian ulang (*recharge*) (Alley, Reilly, & Franke, 1999).

Kota Semarang menjadi contoh nyata dari permasalahan kompleks ini. Sebagai kota pesisir dengan perkembangan yang pesat, Semarang menghadapi tantangan kritis penurunan muka air tanah dan dampak ikutannya, yaitu penurunan permukaan tanah (*land subsidence*). Berdasarkan tren eksploitasi, diprediksi bahwa elevasi muka air tanah di Kota Semarang akan terus menurun tanpa adanya intervensi dan perencanaan yang efektif (Marfai & King, 2008). Penurunan tekanan piezometrik akibat pengambilan air tanah secara masif menyebabkan tanah kehilangan penyangga alami, sehingga mudah terkompaksi oleh beban infrastruktur (Koch, et al., 2019). Data lapangan menunjukkan laju penurunan tanah yang mengkhawatirkan, misalnya di Kecamatan Genuk yang mencapai 8.1-15 cm/tahun dan di Kecamatan Semarang Utara serta Barat antara 4.1-12 cm/tahun (Ismanto, Wirasatriya, Helmi, Hartoko, & Prayogi, 2009). Fenomena ini memperparah risiko banjir rob dan kerusakan infrastruktur, sehingga pengelolaan air tanah yang berkelanjutan menjadi sebuah keharusan. Pengelolaan yang efektif memerlukan perencanaan berbasis data yang mengintegrasikan aspek teknis, lingkungan, sosial, dan kebijakan (Suni & Legono, 2021). Dalam aspek teknis, kemampuan untuk memprediksi fluktuasi muka air tanah di masa depan merupakan fondasi yang sangat penting.

Upaya pemodelan dan prediksi muka air tanah secara umum dapat dikelompokkan menjadi tiga pendekatan utama: berbasis fisika, statistik, dan kecerdasan buatan (*machine learning*). Pemodelan berbasis fisika, seperti MODFLOW (Ostad-Ali-Askari & Shayannejad, 2021), mengandalkan persamaan matematis yang merepresentasikan proses hidrogeologi. Meskipun memberikan pemahaman fisika yang mendalam, pendekatan ini memerlukan data parameter yang sangat banyak dan komputasi yang intensif, serta sering kali terhambat oleh sifat non-linear dan non-stasioner dari dinamika air tanah (Karki, Srivastava, Kalin, Mitra, & Singh, 2021). Di sisi lain, pemodelan statistik (contohnya ARIMA (Gibrilla, Anornu, & Adomako, 2018)) dapat menjadi alternatif, namun kemampuannya untuk menangkap hubungan non-linear yang kompleks sering kali terbatas (Xianglin, et al., 2025).

Kelemahan-kelemahan inilah yang melatari berkembangnya penerapan *machine learning* dalam hidrogeologi. Algoritma machine learning, seperti *Artificial Neural Network* (ANN) dan *Adaptive Neuro-Fuzzy Inference System* (ANFIS), memiliki keunggulan dalam mempelajari pola dari data historis tanpa harus memahami mekanisme fisika yang rumit, sehingga

lebih efisien dan efektif untuk mensimulasikan fluktuasi muka air tanah yang kompleks (Nayak, Sudheer, & Rangan, 2005). ANFIS, khususnya, telah terbukti handal karena menggabungkan kemampuan pembelajaran dari *neural network* dengan logika linguistik yang mudah diinterpretasi dari sistem fuzzy (Boo, et al., 2024). Studi oleh Navale dan Mhaske (2023) di India menunjukkan kinerja ANFIS yang lebih baik dibandingkan ANN dalam memprediksi MAT di beberapa titik pantau. Lebih lanjut, optimasi terhadap parameter ANFIS menggunakan algoritma seperti Particle Swarm Optimization (PSO) telah berhasil meningkatkan akurasinya, seperti yang ditunjukkan oleh penelitian Cui et al. (2022).

Meskipun efektivitas ANFIS dan ANFIS-PSO telah diuji di berbagai lokasi, penerapannya untuk kondisi spesifik Kota Semarang masih belum banyak dieksplorasi. Karakteristik akuifer, pola eksploitasi, dan kondisi meteorologi di Semarang yang unik menuntut sebuah model prediktif yang khusus dikembangkan dan divalidasi untuk wilayah ini. Selain itu, integrasi variabel-variabel meteorologi seperti curah hujan dan evapotranspirasi—seperti yang dilakukan Samani et al. (2022)—dalam kerangka model ANFIS-PSO untuk konteks Indonesia masih perlu dikaji lebih dalam.


Berdasarkan identifikasi kesenjangan (*research gap*) tersebut, penelitian ini bermaksud untuk mengembangkan model prediksi muka air tanah satu bulan ke depan di Kota Semarang dengan menggunakan algoritma *Adaptive Neuro-Fuzzy Inference System* (ANFIS) yang dioptimasi oleh *Particle Swarm Optimization* (PSO). Model ini akan memanfaatkan data historis muka air tanah dan data meteorologi untuk menangkap dinamika non-linear sistem air tanah di Semarang. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan alat bantu keputusan (*decision support tool*) yang akurat bagi para pemangku kebijakan dalam merumuskan strategi konservasi dan pengelolaan air tanah yang berkelanjutan, guna mengatasi tantangan kritis yang dihadapi Kota Semarang.

2. METODE PENELITIAN

2.1. Wilayah Penelitian

Kota Semarang berlokasi di bagian utara Pulau Jawa. Secara geografis Kota Semarang terletak di koordinat 6°58' LS dan 110°25' BT. Semarang merupakan ibukota Provinsi Jawa Tengah, dengan luas area 373,7 km² dan populasi penduduk 1,7 juta jiwa (BPS 2024).

Tujuh titik sumur pantau di Kota Semarang adalah Dinas Lingkungan Hidup (DLH) Kota Semarang, PT Bitratex Industri, Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Jawa Tengah, PT Savana Tirta Makmur, Kawasan Industri Candi, Sekolah Menengah Kejuruan (SMK) Negeri 1 Kota Semarang, dan Teknik Geologi Universitas Diponegoro (UNDIP).



Gambar 1. Titik Lokasi Penelitian

2.2. Kebutuhan Data

Pada penelitian ini pemodelan dilakukan menggunakan bahasa pemrograman python. Dilakukan pemodelan menggunakan 4 (empat) nilai masukan (*input*) yaitu:

1. Muka air tanah satu bulan sebelumnya (GWL t-1) dalam satuan m (meter). Data ini didapatkan dari ESDM Provinsi Jawa Tengah. Hasil rekap harian yang didapatkan diubah menjadi data bulanan dengan metode agregasi data rerata.
2. Curah hujan, merupakan variabel dalam satuan mm (milimeter). Data didapatkan dari Pusdataru Jawa Tengah. Hasil rekap harian yang didapatkan diubah menjadi data bulanan dengan metode agregasi data kumulatif.
3. Evapotranspirasi merupakan variabel dalam satuan mm/hari (milimeter per hari). Data didapatkan dari *website* openmeteo. Hasil rekap harian diubah menjadi data bulanan dengan metode agregasi data rerata.
4. Temperatur atmosfer merupakan variabel dalam satuan °C (derajat celcius). Data didapatkan dari *website* openmeteo. Hasil rekap harian diubah menjadi data bulanan dengan metode agregasi data rerata.

Data yang digunakan dalam periode Juni 2019 hingga Agustus 2024. Data yang sudah dipisahkan untuk tiap titik lokasi kemudian dilakukan pemisahan data pelatihan (*training data*) dan data uji. (*test data*), dengan persentase 70% dan 30% secara berurutan.

2.3. Pra Pengolahan

Data diolah pertama dengan agregasi data. Agregasi data adalah proses dimana data yang dikumpulkan setiap harinya diubah menjadi data bulanan dengan menggunakan metode statistik tertentu. Tujuan agregasi data adalah untuk menyederhanakan data, mengurangi gangguan (*noise*), dan memudahkan analisis dalam jangka waktu yang panjang (Hyndman & Athanasopoulos, 2021). Rumus agregasi data rerata bulanan ada pada persamaan (1).

$$\text{Rerata Bulanan} = \frac{\sum \text{Data Harian}}{\text{Jumlah Hari}} \quad (1)$$

Selain agregasi data dengan rerata bulanan, agregasi bisa dilakukan secara kumulatif (Shumway &

Stoffer, 2017). Rumus agregasi data total bulanan ada pada persamaan (2).

$$\text{Total Bulanan} = \sum \text{Data Harian} \quad (2)$$

Sebagian besar algoritma *machine learning* tidak dapat bekerja dengan kumpulan data yang tidak lengkap, sehingga diperlukan pengisian data yang hilang dengan data yang masuk akal, hal ini dikenal sebagai imputasi data (Irnawan, Hidayah, & Nugroho, 2021).

Pemilihan metode imputasi menggunakan KNN (*K-Nearest Neighbor*) dilakukan karena KNN memiliki akurasi paling tinggi dibandingkan dengan metode lain dalam memprediksi nilai hilang dalam data (Memon, Wamala, & Kabano, 2023). Imputasi KNN merupakan metode pengisian data hilang/*missing value* (MV) menggunakan metode *k-Nearest Neighbor*.


Selanjutnya dilakukan normalisasi data. Normalisasi merupakan tahap yang penting agar perbandingan kemiripan antar urutan waktu tidak terpengaruh oleh variasi dalam amplitudo dan offset (Lima & Souza, 2023). Normalisasi dilakukan dengan normalisasi Yeo-Johnson. Rumus normalisasi Yeo-Johnson ada pada persamaan (3).

$$\psi(\lambda, x) = \begin{cases} \frac{(x+1)^\lambda - 1}{\lambda} & (x \geq 0, \lambda \neq 0) \\ \log(x+1) & (x \geq 0, \lambda = 0) \\ \frac{\{(-x+1)^{2-\lambda} - 1\}}{(2-\lambda)} & (x < 0, \lambda \neq 2) \\ -\log(-x+1) & (x < 0, \lambda = 2) \end{cases} \quad (3)$$

2.4. Algoritma ANFIS-PSO

Adaptive Neuro-Fuzzy Interference System (ANFIS) merupakan metode yang diajukan pada tahun 1993 oleh Jang sebagai metode yang mengkombinasikan kemampuan penafsiran dari sistem fuzzy dan kemampuan belajar mandiri dari *neural network*, sehingga menghasilkan metode dengan akurasi dan penafsiran yang tinggi (Zhang & Chen, 2024).

ANFIS terdiri dari 5 (lima) lapisan (Jang, 1993). Lapisan pertama adalah fuzzifikasi tiap variabel masukan. Lapisan kedua pengaplikasian aturan fuzzy. Lapisan ketiga normalisasi dalam pembebanan di tiap aturan fuzzy. Lapisan keempat adalah defuzzifikasi. Lapisan kelima adalah variabel keluaran.



Gambar 2. Lima lapisan ANFIS

Lapisan pertama pada persamaan (4)

$$O_i^1(x_1) = \mu_{A_i}(x_1)$$

$$O_i^1(x_2) = \mu_{B_i}(x_2)$$

$$O_i^1(x_3) = \mu_{C_i}(x_3) \quad (4)$$

Lapisan kedua pada persamaan (5)

$$O_i^2 = w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \times \mu_{C_i}(x_3) \quad (5)$$

Lapisan ketiga pada persamaan (6)

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_i w_i} \quad (6)$$


Lapisan keempat pada persamaan (7)

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x_1 + q_i x_2 + r_i x_3 + s_i) \quad (7)$$

Lapisan kelima pada persamaan (8)

$$O_i^5 = \sum_i \bar{w}_i f_i = \bar{w}_1 f_1 + \bar{w}_2 f_2 + \bar{w}_3 f_3 \quad (8)$$

Algoritma *Particle Swarm Optimization* (PSO) pertama kali dikenalkan oleh Kennedy dan Eberhart di tahun 1995, yang dimodelkan dari perilaku ikan dan burung. Algoritma PSO mampu menemukan solusi optimal dengan mempertimbangkan semua usaha partikel untuk menemukan posisi terbaik dengan merubah posisinya dalam ruang pencarian (Kennedy & Eberhart, 1995).



Gambar 3. Prinsip PSO (*Particle Swarm Optimization*) (Olsson, 2011)

Hybrid ANFIS-PSO (Adaptive Neuro Fuzzy Inference System-Particle Swarm Optimization) merupakan gabungan algoritma ANFIS yang dioptimasi parameter ANFIS. Pada *system fuzzy* terdapat dua bagian; sebab (*premise/antecedent*) dan akibat (*consequent*). Fungsi algoritma PSO adalah untuk membantu ANFIS tidak terjebak pada *local optima* sehingga meningkatkan akurasi prediksi dan performa ANFIS secara umum (Aljarah & Ludwig, 2013).

2.5. Evaluasi Model

Dua pengukuran akurasi pemodelan yang seringkali digunakan adalah *Root Mean Square Error* (RMSE) dan *Coefficient of Determination* (R^2). RMSE merupakan metode kuantifikasi galat dengan menghitung deviasi antara nilai prediksi dengan nilai aktual. Sementara R^2 adalah ukuran sejauh mana dua variabel saling berhubungan secara linear. Dalam hal ini dua variabel tersebut adalah nilai prediksi dan nilai aktual.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{x}_i - x_i)^2}{N}} \quad (9)$$

Pada persamaan (9) notasi N adalah populasi, i adalah indeks, $\hat{x}_i$ adalah nilai prediksi, dan x_i adalah nilai observasi, dan N adalah jumlah populasi.

$$R^2 = (r)^2 \quad (10)$$

Pada persamaan (10) menunjukkan hubungan antara koefisien determinasi dan koefisien korelasi. Notasi R^2 adalah koefisien determinasi, sementara notasi r adalah koefisien korelasi.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (11)$$

Pada persamaan (11) notasi x_i adalah nilai x ke i (begitu juga untuk y_i), dan $\bar{x}$ adalah nilai rerata x dalam populasi (begitu juga dengan $\bar{y}$).

3. HASIL DAN PEMBAHASAN

Hasil pemodelan menunjukkan bahwa kinerja model ANFIS-PSO dalam memprediksi muka air tanah bervariasi antar tujuh titik sumur pantau di Kota Semarang (Tabel 1). Nilai koefisien determinasi (R^2) pada data uji (*testing*) berkisar dari 62,71% hingga 92,77%, sedangkan *Root Mean Square Error* (RMSE) juga menunjukkan variasi yang lebar. Variabilitas kinerja ini mengindikasikan bahwa keakuratan model tidak seragam dan sangat bergantung pada kondisi spesifik masing-masing lokasi. Faktor-faktor seperti kualitas data, karakteristik hidrogeologi setempat, dan desain pengamatan diduga menjadi penyebab utama perbedaan tersebut.

Salah satu faktor dominan yang mempengaruhi akurasi model adalah kelengkapan data historis. Terdapat korelasi yang jelas antara tingginya presentase data hilang dengan rendahnya nilai R^2 . Sebagai contoh, PT Savana Tirta Makmur, yang memiliki nilai R^2 terendah (62,71%), juga mengalami tingkat *missing data* tertinggi, yaitu mencapai 72%. Sebaliknya, lokasi dengan data yang lebih lengkap, seperti di Teknik Geologi Universitas Diponegoro (data hilang 13%), menunjukkan kinerja model yang lebih baik. Temuan ini konsisten dengan prinsip bahwa kualitas dan kuantitas data input merupakan fondasi untuk membangun model prediktif yang andal (Barocas, Hardt, & Narayanan, 2023). Untuk penelitian selanjutnya, penerapan metode imputasi data, seperti *K-Nearest Neighbor* (KNN), sangat disarankan untuk mengisi celah data yang hilang guna meningkatkan stabilitas hasil pemodelan.

Selain kualitas data, variabilitas karakteristik hidrogeologi dan perbedaan skala pengukuran juga berkontribusi terhadap variasi akurasi. Model ini menggunakan data curah hujan, evapotranspirasi, dan temperatur dari stasiun cuaca yang lokasinya terpisah dari sumur pantau. Dalam realitanya, respons akuifer terhadap curah hujan tidak bersifat instan (*real-time*) tetapi melibatkan proses infiltrasi dan pergerakan air tanah yang kompleks, yang sangat dipengaruhi oleh jenis tanah, batuan, dan tutupan lahan di setiap lokasi (Helmi, Setiyono, Bambang, & Yusuf, 2022) (Hadi, et

al., 2016). Oleh karena itu, sebelum menyusun model, penting untuk melakukan uji signifikansi statistik (seperti analisis korelasi (Helsel, Hirsch, Ryberg, Archfield, & Gilroy, 2020) atau uji *Granger causality* (Kim, Jang, Choi, & Kwak, 2023)) terhadap semua variabel input terhadap muka air tanah untuk memastikan bahwa setiap variabel yang digunakan memang memiliki pengaruh yang signifikan secara statistik (Yoon, Hyun, Ha, Lee, & Kim, 2016).

Ketidakcocokan antara lokasi *input* meteorologi dan *output* muka air tanah ini dapat menyebabkan bias, karena model menggunakan hujan pada waktu t^* , padahal mungkin terdapat *time lag* (penundaan) sehingga hujan pada waktu $t-1^*$ atau $t-2^*$ lebih relevan. Hal ini sesuai dengan penelitian Quinonero, et al., (2009) bahwa perbedaan titik pengamatan data dapat mempengaruhi penyusunan model. Oleh karena itu, eksperimen dengan memasukkan variabel *lag time* untuk curah hujan dalam model perlu dipertimbangkan di masa depan untuk lebih menangkap dinamika hidrogeologi yang spesifik.

Berdasarkan temuan variasi akurasi yang kuat kaitannya dengan lokasi, pendekatan pengelolaan air tanah yang seragam untuk seluruh Kota Semarang mungkin kurang optimal. Hasil ini menguatkan perlunya strategi berbasis zonasi. Zonasi dapat dikembangkan dengan mempertimbangkan karakteristik hidrogeologi, pola penggunaan lahan, dan kerentanan penurunan muka air tanah. Teknik analisis seperti *Principal Component Analysis* (PCA) dapat digunakan untuk mengelompokkan wilayah dengan karakteristik serupa (Amanah, Putranto, & Helmi, 2019). Hasil zonasi tersebut kemudian dapat menjadi dasar untuk menyusun kebijakan dan rencana konservasi air tanah yang lebih tepat sasaran (Hartoko, Wirasatria, Helmi, & Rochaddi, 2008).

Secara keseluruhan, meskipun memiliki variasi kinerja, model ANFIS-PSO (*Adaptive Neuro Fuzzy Inference System – Particle Swarm Optimization*) telah menunjukkan kemampuannya dalam memprediksi fluktuasi muka air tanah dengan tingkat akurasi yang memadai di beberapa lokasi. Model ini berpotensi untuk dikembangkan lebih lanjut sebagai alat pendukung keputusan. Namun, implementasinya harus mempertimbangkan kondisi lokal. Keberhasilan prediksi sangat bergantung pada kelengkapan data dan pemahaman terhadap kondisi hidrogeologi masing-masing zona, sehingga pendekatan pengelolaan yang spasial dan adaptif menjadi kunci keberhasilan konservasi air tanah di Kota Semarang.

Hasil evaluasi model mengungkapkan fenomena yang menarik di mana akurasi testing ($R^2_{te} = 92.77\%$; $RMSE_{te} = 0.1962$) secara konsisten melampaui akurasi training ($R^2_{tr} = 49.91\%$; $RMSE_{tr} = 0.2811$) di semua lokasi penelitian. Meskipun tidak umum dalam pemodelan konvensional, fenomena ini justru mengindikasikan keunggulan model ANFIS-PSO dalam hal generalisasi. Optimasi dengan PSO diduga berperan sebagai natural regularizer yang mencegah overfitting terhadap data training, sehingga model lebih fokus pada pembelajaran pola fundamental sistem. Temuan ini sejalan dengan penelitian Cui et al. (2022) yang melaporkan pola serupa pada pemodelan hidrologi dengan *hybrid intelligence systems*.


Beberapa faktor dapat menjelaskan fenomena ini dalam konteks pembagian data 70:30. Pertama, terdapat kemungkinan bahwa 30% data *testing* mengandung pola yang lebih sederhana atau variabilitas yang lebih rendah dibandingkan 70% data *training*. Data *testing* mungkin berasal dari periode dengan fluktuasi air tanah yang lebih stabil, sementara data training mencakup dinamika yang lebih kompleks. Kedua, efek sampling acak dapat menyebabkan data testing terpilih dari rentang nilai yang relatif homogen dan bebas dari outlier yang terdapat dalam data training. Ketiga, proporsi 70% data training mungkin belum cukup untuk merepresentasikan seluruh kompleksitas sistem, namun cukup untuk menangkap pola dasar yang justru lebih mudah diaplikasikan pada data *testing*.

Dua interpretasi utama dapat diambil dari temuan ini. Di satu sisi, hal ini dapat menunjukkan kemampuan generalisasi model yang sangat baik. Di sisi lain, terdapat kemungkinan bahwa hasil ini dipengaruhi oleh faktor stokastik dalam pembagian data. Untuk memverifikasi keandalan temuan, diperlukan validasi lebih lanjut menggunakan *cross-validation* dengan berbagai skenario pembagian data dan periode observasi yang lebih panjang.


Secara praktis, hasil ini memberikan indikasi positif bahwa model ANFIS-PSO berpotensi untuk diimplementasikan dalam sistem prediksi air tanah di Kota Semarang. Kemampuan generalisasi yang ditunjukkan model ini merupakan aset berharga untuk aplikasi nyata, meskipun validasi lebih komprehensif tetap diperlukan sebelum implementasi skala penuh. Temuan ini sekaligus menegaskan pentingnya optimasi algoritma dalam mengembangkan model prediktif yang handal untuk sistem hidrologi yang kompleks.

Tabel 1. Hasil Pemodelan ANFIS-PSO di Tiap Titik Lokasi


Lokasi	Hasil			
	R^2_{tr}	$RMSE_{tr}$	R^2_{te}	$RMSE_{te}$
SMKN 1 Kota Semarang	0,4991	0,2811	0,9277	0,1962
Teknik Geologi Universitas Diponegoro	0,7660	0,2753	0,8926	0,2001
Dinas Lingkungan Hidup Kota Semarang	0,3414	0,3610	0,8341	0,2936
Kawasan Industri Candi	0,5829	0,2950	0,8333	0,2316
PT Bitratex Industries	0,4037	0,3284	0,6894	0,2948
BPBD Provinsi Jawa Tengah	0,1579	0,3505	0,6479	0,1774
PT Savana Tirta Makmur	0,0956	0,3553	0,6271	0,1627




Gambar 4. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di SMKN 1 Kota Semarang




Gambar 5. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di Teknik Geologi UNDIP




Gambar 6. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di Dinas Lingkungan Hidup Kota Semarang




Gambar 7. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di PT Bitratex Industries



Gambar 8. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di BPBD Provinsi Jawa Tengah



Gambar 9. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di Kawasan Industri Candi



Gambar 10. Perbandingan Nilai Muka Air Prediksi terhadap Aktual di PT Savana Tirta Makmur

Gambar 4-10 merupakan grafik perbandingan antara nilai prediksi dan aktual muka air tanah yang ternormalisasi, yang menunjukkan kinerja model ANFIS-PSO dalam memprediksi fluktuasi muka air tanah di lokasi penelitian.

Berdasarkan analisis visual terhadap Gambar 4 (SMKN 1 Kota Semarang), Gambar 5 (Teknik Geologi UNDIP), Gambar 6 (Dinas Lingkungan Hidup Kota Semarang), dan Gambar 9 (Kawasan Industri Candi) menunjukkan bahwa garis prediksi secara umum mampu mengikuti pola fluktuasi data aktual dengan cukup baik, khususnya pada periode dimana muka air tanah memiliki tren yang stabil. Hal ini terlihat dari kemiripan pola naik-turun antara kurva prediksi dan aktual pada sebagian besar rentang waktu. Kesesuaian ini menunjukkan bahwa model ANFIS-PSO berhasil menangkap hubungan non-linear antara variabel *input* (GWL $t-1$, curah hujan, evapotranspirasi, dan temperatur) dengan *output* (GWL t). Kemampuan ini konsisten dengan studi sebelumnya oleh Cui et al. (2022) yang menyatakan bahwa sistem *hybrid neuro-fuzzy* efektif dalam memodelkan dinamika hidrologi yang kompleks.

Berdasarkan analisis visual terhadap Gambar 7 (PT Bitratex Industri), Gambar 8 (BPBD Provinsi Jawa Tengah), dan Gambar 10 (PT Savana Tirta Makmur) grafik perbandingan antara nilai prediksi dan aktual muka air tanah yang ternormalisasi menunjukkan bahwa model ANFIS-PSO secara umum mampu mereproduksi pola fluktuasi muka air tanah dengan tingkat akurasi yang memadai. Kurva prediksi berhasil mengikuti tren pergerakan data aktual, khususnya pada pola naik-turun jangka menengah, yang mengindikasikan bahwa model telah berhasil menangkap hubungan non-linear antara variabel *input* (GWL $t-1$, curah hujan, evapotranspirasi, dan temperatur) dengan *output* (GWL t). Namun, teramati adanya deviasi yang signifikan pada beberapa titik tertentu, terutama saat terjadi fluktuasi ekstrem

dimana model cenderung tidak responsif dalam menangkap amplitudo puncak dan lembah.

Penyimpangan-penyimpangan nilai prediksi terhadap nilai aktual dapat dijelaskan oleh beberapa faktor kunci. Pertama, keterbatasan data *input* dimana variabel curah hujan pada waktu (t) mungkin tidak langsung berkorelasi dengan muka air tanah pada waktu yang sama akibat proses infiltrasi dan pergerakan air tanah yang membutuhkan waktu (*time lag effect*). Kedua, karakteristik hidrogeologi lokal yang tidak homogen di sekitar sumur pantau menyebabkan respons akuifer terhadap *recharge* yang tidak seragam. Ketiga, adanya *missing data* yang mencapai 72% di beberapa lokasi berpotensi memperkenalkan noise dalam proses training model. Meskipun terdapat deviasi tersebut, secara keseluruhan model menunjukkan konsistensi dalam memprediksi tren dasar fluktuasi muka air tanah. Temuan ini konsisten dengan nilai statistik yang diperoleh, dimana R^2 testing mencapai 92.77% untuk beberapa lokasi, mengkonfirmasi bahwa model ANFIS-PSO memiliki reliabilitas yang cukup baik untuk aplikasi perencanaan pengelolaan air tanah jangka menengah di Kota Semarang, dengan catatan perlu penyempurnaan lebih lanjut untuk meningkatkan akurasi pada kondisi ekstrem.

4. KESIMPULAN

Berdasarkan seluruh analisis yang telah dilakukan, dapat disimpulkan bahwa model ANFIS-PSO menunjukkan kemampuan yang efektif dalam memprediksi dinamika muka air tanah di Kota Semarang. Hasil penelitian mengkonfirmasi bahwa model ini mampu menangkap pola non-linear sistem air tanah dengan tingkat akurasi yang bervariasi antar lokasi, dimana nilai R^2 tertinggi mencapai 92,77% pada data testing. Variasi kinerja model tersebut secara fundamental dipengaruhi oleh tiga faktor utama: kualitas dan kelengkapan data historis, karakteristik hidrogeologi lokal yang spesifik, serta

ketidaksesuaian skala antara titik pengukuran data meteorologi dan pemantauan air tanah.

Temuan menarik dimana akurasi testing lebih baik daripada training mengindikasikan bahwa optimasi PSO berperan sebagai natural regularizer yang mencegah overfitting dan meningkatkan kemampuan generalisasi model. Hasil penelitian ini tidak hanya membuktikan keandalan pendekatan hybrid intelligence dalam pemodelan hidrogeologi, tetapi juga menyediakan basis ilmiah yang kuat untuk pengembangan perencanaan konservasi air tanah yang lebih efektif di Kota Semarang.

Diajukan beberapa rekomendasi untuk pengembangan penelitian selanjutnya. Sistem pemantauan terintegrasi yang menyediakan data real-time dan berkualitas tinggi. Eksperimen dengan variabel lag time untuk menangkap delay respons hidrogeologi. Pendekatan manajemen secara zonasi berdasarkan karakteristik hidrogeologi spesifik lokasi. Integrasi dengan kebijakan tata ruang untuk pengelolaan air tanah yang berkelanjutan.

DAFTAR PUSTAKA

- Abdi, E., Ali, M., Santos, C. A., Olusola, A., & Ghorbani, M. (2024). Enhancing groundwater level prediction accuracy using interpolation techniques in deep learning models. *Groundwater for Sustainable Development*, 1-14.
- Aljarah, I., & Ludwig, S. (2013). A New Approach for Parameter Estimation of Fuzzy Inference Systems Using Particle Swarm Optimization. In *Proceedings of the IEEE Congress on Evolutionary Computation (CEC)*, (pp. 2034–2041).
- Alley, W., Reilly, T., & Franke, O. (1999). *Sustainability of Ground Water Resources*. U.S. Geological Survey Circular.
- Amanah, T., Putranto, T., & Helmi, M. (2019). Application of cluster analysis and principal component analysis for assessment of groundwater quality - A study in Semarang, Central Java, Indonesia. *IOP Conference Series: Earth and Environmental Science*.
- Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness in Machine Learning*.
- Boo, K. B., El-Shafie, A., Othman, F., Khan, M. H., Birima, A., & Ahmed, A. N. (2024). Groundwater level forecasting with machine learning models: A review. *Water Research*, 1-18.
- Cui, F., Al-Sudani, Z. A., Hassan, G. S., Afan, H. A., Ahammed, S. J., & Yaseen, Z. M. (2023). Boosted artificial intelligence model using improved alpha-guided grey wolf for groundwater level prediction: Comparative study and insight for federated learning technology. *Journal of Hydrology*.
- Fetter, C. (2001). *Applied Hydrogeology*. Prentice Hall.
- Gibrilla, A., Anornu, G., & Adomako, D. (2018). Trend Analysis and ARIMA Modelling of Recent Groundwater Levels in the White Volta River basin of Ghana. *Groundwater for Sustainable Development*, 150-163.
- Hadi, F., Thapa, R. B., Helmi, M., Hazarika, M. K., Madawalagama, S., & Deshapriya, L. N. (2016). Urban Growth and Land Use/Land Cover Modeling in Semarang, Central Java, Indonesia. *Asian Conference on Remote Sensing, ACRS*, (pp. 2341-2350).
- Hartoko, A., Wirasatria, A., Helmi, M., & Rochaddi, B. (2008). Aplikasi Teknologi Geomatika Untuk Pemetaan Penurunan Tanah (Land Subsidence) di Pesisir Kota Semarang. *Journal of Marine Science*, 13-18.
- Helmi, M., Setiyono, H., Bambang, A. N., & Yusuf, M. (2022). Effect rainfall season on coastal flood in Semarang City, Central, Java, Indonesia. *International Journal of Health Sciences*, 7584-7595.
- Helsel, D. R., Hirsch, R. M., Ryberg, K. R., Archfield, S. A., & Gilroy, E. J. (2020). Statistical Methods in Water Resources. In U. G. Survey, *Hydrologic Analysis and Interpretation*. USGS.
- Hyndman, R., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*.
- Irnanawati, F. D., Hidayah, I., & Nugroho, L. E. (2021). Metode Imputasi pada Data Debit Daerah Aliran Sungai Opak, Provinsi DI Yogyakarta. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 301-311.
- Ismanto, A., Wirasatriya, A., Helmi, M., Hartoko, A., & Prayogi, P. (2009). Model sebaran penurunan tanah di wilayah pesisir Semarang. *International Journal of Marine Science*, 189-196.
- Jang, J. S. (1993). ANFIS: Adaptive Network Based Fuzzy Inference System. *IEEE Transactions on Systems, Man, and Cybernetics*, 665-685.
- Karki, R., Srivastava, P., Kalin, L., Mitra, S., & Singh, S. (2021). Assessment of impact in groundwater levels and stream-aquifer interaction due to increased groundwater withdrawal in the lower Apalachicola-Chattahoochee-Flint (ACF) River Basin using MODFLOW. *Journal of Hydrology: Regional Studies*.
- Kelly-Fair, M., Gopal, S., Koch, M., Kusumaningrum, H. P., Helmi, M., Khairunnisa, D., & Kaufman, L. (2022). Analysis of Land Use and Land Cover Changes through the Lens of SDGs in Semarang, Indonesia. *Sustainability*.
- Kennedy, J., & Eberhart, R. (1995). Particle Swarm Optimization. *IEEE International Conference on Neural Networks*, 1942-1948.
- Kim, D., Jang, C., Choi, J., & Kwak, J. (2023). A Case Study: Groundwater Level Forecasting of the Gryorae Area in Actual Practice on Jeju Island Using Deep-Learning Technique. *Water*.
- Koch, M., Gaber, A., Darwish, N., Bateman, J., Gopal, S., & Helmi, M. (2019). Estimating land subsidence in relation to urban expansion in Semarang city, Indonesia, using InSAR and optical change detection methods. *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, (pp. 9686-9689).
- Lima, F. T., & Souza, V. M. (2023). A Large Comparison of Normalization Methods on Time Series. *Big Data Research*, 1-15.
- Marfai, M., & King, L. (2008). Potential vulnerability implications of coastal inundation due to sea level rise for the coastal zone of Semarang city, Indonesia. *Environmental Geology*, 1235-1245.
- Memon, S. M., Wamala, R., & Kabano, I. H. (2023). A comparison of imputation methods for categorical data. *Informatics in Medicine Unlocked*, 1-9.
- Navale, V., & Mhaske, S. (2023). Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS) model for Forecasting Groundwater Level in the Pravara River Basin. *Modeling Earth Systems and Environment*, 2663-2676.

- Suharyanto, O. N., Helmi, M., dan Hidayat, J. W. (2025). Prediksi Muka Air Tanah Perkotaan Menggunakan Hybrid ANFIS-PSO: Studi Kasus Kota Semarang. *Jurnal Ilmu Lingkungan*, 23(5), 1394-1403, doi:10.14710/jil.23.5.1394-1403
- Nayak, P. C., Sudheer, K. P., & Rangan, D. (2005). Fuzzy computing based rainfall-runoff model for real time flood forecasting. *Hydrological Processes*, 955-968.
- Olsson, A. E. (2011). *Particle Swarm Optimization: Theory, Techniques and Applications*. New York: Nova Science Publishers.
- Ostad-Ali-Askari, K., & Shayannejad, M. (2021). Quantity and Quality Modelling of Groundwater to Manage Water Resources in Isfahan-Borkhar Aquifer. *Environment Development and Sustainability*.
- Quinonero-Candela, J., Sugiyama, M., Schwaighofer, A., & Lawrence, N. D. (2009). *Dataset Shift in Machine Learning*. The MIT Press.
- Samani, S., Vadiati, M., Azizi, F., Zamani, E., & Kisi, O. (2022). Groundwater Level Simulation Using Soft Computing Methods with Emphasis on Major Meteorological Components. *Water Resources Management*, 3627-3647.
- Shumway, R., & Stoffer, D. (2017). *Time Series Analysis and Its Applications: With R Examples*. Springer.
- Suni, Y. P., & Legono, D. (2021). Manajemen Sumber Daya Air Terpadu dalam Skala Global, Nasional, dan Regional. *Jurnal Teknik Sipil*, 77-88.
- Xianglin, D., Tariq, A., Jamil, A., Aslam, R. W., Zafar, Z., Bailek, N., . . . Soufan, W. (2025). Advanced machine vision technique for groundwater level prediction modeling geospatial and statistical research. *Advances in Space Research*, 2652-2668.
- Yonekura, K., Miyazaki, S., Aichi, M., Nishizu, T., Hasegawa, M., & Suzuki, K. (2025). Prediction of Underground Level in Indonesian Tropical Peatland Forest Plantations using Machine Learning. *Artificial Intelligence in Geoscience*, 1-7.
- Yoon, H., Hyun, Y., Ha, K., Lee, K.-K., & Kim, G.-B. (2016). A Method to Improve the Stability and Accuracy of ANN- and SVM- Based Time Series Models for Long-Term Groundwater Level Predictions. *Computers & Geosciences*, 144-155.
- Zhang, D., & Chen, T. (2024). Scikit-ANFIS: A Scikit-Learn Compatible Python Implementation for Adaptive Neuro-Fuzzy Interference System. *International Journal of Fuzzy System*, 2039-2057.