



Kerangka Hybrid Adaptif SVR–PSO untuk Prediksi Tingkat Pengangguran Terbuka

Amali*, Edy Widodo, Ismasari Nawangsih, Andri Firmansyah

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

Email: ^{1,*}amali@pelitabangsa.ac.id, ²ewidodo@pelitabangsa.ac.id, ³ismasari.n@pelitabangsa.ac.id,

⁴andrifirmansyah@pelitabangsa.ac.id

Email Penulis Korespondensi: amali@pelitabangsa.ac.id

Abstrak—Prediksi Tingkat Pengangguran Terbuka (TPT) yang akurat sangat penting untuk mendukung perumusan kebijakan ketenagakerjaan berbasis bukti. Namun, model prediksi konvensional sering kali belum mampu menangkap hubungan nonlinier pada data panel sosial ekonomi. Penelitian ini bertujuan mengembangkan kerangka *Adaptive Hybrid Support Vector Regression–Particle Swarm Optimization* (SVR–PSO) untuk memprediksi Tingkat Pengangguran Terbuka berbasis data panel di Jawa Tengah. Dataset yang digunakan merupakan data panel sosial ekonomi yang menggabungkan dimensi antarwilayah (*cross-sectional*) dan antarwaktu (*temporal*), terdiri atas 315 observasi dari 35 kabupaten/kota selama periode 2017–2025. Variabel prediktor meliputi Tingkat Partisipasi Angkatan Kerja, Rata-rata Lama Sekolah, Upah Minimum, Indeks Pembangunan Manusia, Produk Domestik Regional Bruto per Kapita, Tingkat Kemiskinan, Kepadatan Penduduk, Jumlah Penduduk, dan Laju Pertumbuhan Penduduk. *Particle Swarm Optimization* digunakan untuk mengoptimalkan hiperparameter *Support Vector Regression*, sedangkan kinerja model dievaluasi menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa kerangka *Adaptive Hybrid SVR–PSO* menghasilkan MAE sebesar 0,7715, RMSE sebesar 0,9264, MAPE sebesar 16,78%, dan R^2 sebesar 0,6956. Dibandingkan dengan model SVR dasar, pendekatan yang diusulkan mampu menurunkan nilai MAE, RMSE, dan MAPE masing-masing sebesar 17,77%, 22,33%, dan 11,31%, serta meningkatkan nilai R^2 sebesar 40,41%. Temuan ini menunjukkan bahwa kerangka *Adaptive Hybrid SVR–PSO* mampu meningkatkan akurasi prediksi dan generalisasi model pada data panel sosial ekonomi yang heterogen, sehingga berpotensi menjadi alat pendukung keputusan yang efektif dalam perencanaan pasar kerja dan perumusan kebijakan ketenagakerjaan berbasis data di Jawa Tengah.

Kata Kunci: Adaptive Hybrid SVR–PSO; Data Panel; Particle Swarm Optimization; Support Vector Regression; Tingkat Pengangguran Terbuka

Abstract—Accurate prediction of the Open Unemployment Rate (OUR) is essential for supporting evidence-based employment policies; however, conventional prediction models often struggle to capture nonlinear relationships within panel socioeconomic data. This study proposes an *Adaptive Hybrid Support Vector Regression–Particle Swarm Optimization* (SVR–PSO) Framework for panel-based unemployment prediction in Central Java. The framework was evaluated using socioeconomic panel data integrating cross-sectional and temporal dimensions, consisting of 315 observations from 35 regencies and cities over the 2017–2025 period. Socioeconomic indicators, including labor force participation, education, minimum wage, human development, regional economic output, poverty, population density, population, and population growth, were used as predictor variables. *Particle Swarm Optimization* was employed to optimize the SVR hyperparameters, while prediction performance was assessed using MAE, RMSE, MAPE, and R^2 . The proposed framework achieved an MAE of 0.7715, RMSE of 0.9264, MAPE of 16.78%, and R^2 of 0.6956, outperforming the baseline SVR model by reducing MAE, RMSE, and MAPE by 17.77%, 22.33%, and 11.31%, respectively, while increasing R^2 by 40.41%. These results demonstrate that the proposed *Adaptive Hybrid SVR–PSO* Framework improves predictive accuracy and model generalization across heterogeneous socioeconomic panel observations, providing a robust approach for panel-based unemployment prediction and supporting data-driven regional labor market planning.

Keywords: Adaptive Hybrid SVR–PSO; Data Panel; Particle Swarm Optimization; Support Vector Regression; Open Unemployment Rate

1. PENDAHULUAN

Tingkat Pengangguran Terbuka (TPT) masih menjadi salah satu tantangan sosial ekonomi yang paling persisten di negara-negara berkembang karena secara langsung memengaruhi pertumbuhan ekonomi, distribusi pendapatan, stabilitas pasar tenaga kerja, dan kesejahteraan masyarakat [1], [2], [3]. Meskipun pemerintah telah menerapkan berbagai kebijakan ketenagakerjaan, dinamika pengangguran masih terus berfluktuasi akibat ketidakpastian ekonomi, perubahan demografi, tingkat pendidikan, kebijakan pengupahan, serta kesenjangan pembangunan antarwilayah [4], [5]. Di Indonesia, Provinsi Jawa Tengah merupakan salah satu provinsi dengan jumlah angkatan kerja yang besar serta memiliki keragaman karakteristik sosial ekonomi yang tinggi di antara kabupaten dan kotanya. Perbedaan karakteristik antarwilayah tersebut menyebabkan prediksi tingkat pengangguran menjadi lebih kompleks sehingga memerlukan model analisis yang mampu menangkap heterogenitas karakteristik sosial ekonomi [6], [7]. Oleh karena itu, prediksi Tingkat Pengangguran Terbuka (TPT) yang akurat menjadi sangat penting untuk mendukung perencanaan pasar tenaga kerja dan penyusunan kebijakan ketenagakerjaan daerah yang berbasis bukti di Provinsi Jawa Tengah [8], [9], [10].

Meningkatnya ketersediaan data panel sosial ekonomi regional telah membuka peluang baru dalam pengembangan model prediksi pengangguran berbasis data [11], [12]. Dibandingkan dengan data potong lintang (*cross-sectional*) maupun deret waktu (*time series*) konvensional, data panel mampu menangkap perkembangan temporal sekaligus heterogenitas antarwilayah secara bersamaan, sehingga model prediktif dapat mempelajari dinamika sosial ekonomi baik secara spasial maupun temporal dengan lebih efektif [13], [14]. Dalam konteks prediksi pengangguran, variabel seperti Tingkat Partisipasi Angkatan Kerja (TPAK), Indeks Pembangunan Manusia (IPM), Rata-rata Lama Sekolah (RLS), Upah



Minimum (UM), Produk Domestik Regional Bruto per Kapita (PDRB per Kapita), Tingkat Kemiskinan, Kepadatan Penduduk, Jumlah Penduduk, dan Laju Pertumbuhan Penduduk telah diidentifikasi sebagai determinan penting kondisi pasar tenaga kerja [15], [16]. Namun demikian, hubungan antarvariabel tersebut umumnya bersifat nonlinier dan saling bergantung secara kompleks sehingga sulit dimodelkan menggunakan pendekatan statistik konvensional [17].

Berbagai penelitian telah menerapkan *machine learning* untuk prediksi pengangguran dengan karakteristik data dan pendekatan yang berbeda. Annastasya, Passarella, dan Yamani [18] mengembangkan model *machine learning* untuk memprediksi tingkat pengangguran di Indonesia menggunakan indikator makroekonomi dan membandingkan beberapa algoritma untuk memperoleh model dengan kinerja prediksi terbaik. Liu dan Li [19] mengombinasikan model deret waktu dengan *neural network* untuk memprediksi pengangguran dan menunjukkan bahwa pendekatan gabungan mampu menghasilkan kinerja prediksi yang lebih baik dibandingkan model individual. Sementara itu, Gabrikova, Svabova, dan Kramarova [25] menerapkan *ensemble machine learning* untuk memprediksi durasi pengangguran dan menunjukkan bahwa penggabungan beberapa algoritma dapat meningkatkan kemampuan prediksi dibandingkan pendekatan individual. Pada konteks Jawa Tengah, Badriah, Sanjaya, Barokatuminalloh, dan Prihono [8] menggunakan regresi data panel pada 35 kabupaten/kota selama 2017–2023 untuk menganalisis determinan Tingkat Pengangguran Terbuka (TPT), sehingga telah mempertimbangkan dimensi antarwilayah dan antarwaktu, tetapi penelitian tersebut berfokus pada hubungan determinan, bukan prediksi berbasis *machine learning* [20]. Penelitian-penelitian tersebut menunjukkan bahwa *machine learning* memiliki potensi dalam menangkap hubungan kompleks pada prediksi pengangguran, tetapi masih terdapat keterbatasan dalam mengintegrasikan struktur data panel regional dan temporal dengan optimasi hiperparameter secara otomatis. Selain itu, penelitian yang secara khusus mengombinasikan Support Vector Regression (SVR) dengan Particle Swarm Optimization (PSO) untuk prediksi TPT berbasis data panel kabupaten/kota di Jawa Tengah masih terbatas. Oleh karena itu, penelitian ini mengusulkan Kerangka *Adaptive Hybrid SVR-PSO* yang mengintegrasikan SVR dengan optimasi hiperparameter berbasis PSO untuk memanfaatkan informasi temporal dan regional sekaligus meningkatkan akurasi serta kemampuan generalisasi prediksi TPT pada kondisi sosial ekonomi yang heterogen.


Untuk mengatasi berbagai kesenjangan penelitian tersebut, penelitian ini mengusulkan Kerangka *Adaptive Hybrid SVR-PSO* untuk prediksi Tingkat Pengangguran Terbuka berbasis data panel di Provinsi Jawa Tengah. Berbeda dengan penelitian sebelumnya yang umumnya menggunakan model SVR dengan konfigurasi hiperparameter secara manual atau pendekatan prediksi konvensional, kerangka yang diusulkan mengintegrasikan optimasi hiperparameter adaptif berbasis *Particle Swarm Optimization* (PSO) dengan data panel sosial ekonomi yang heterogen untuk meningkatkan akurasi prediksi dan kemampuan generalisasi model [21]. Berbeda dengan implementasi SVR konvensional yang menggunakan parameter yang dipilih secara manual, kerangka yang diusulkan secara otomatis mencari kombinasi hiperparameter yang optimal sehingga mampu meningkatkan akurasi prediksi, robustnes, serta kemampuan generalisasi pada observasi data panel yang heterogen [22], [23]. Dengan mengintegrasikan proses optimasi ke dalam tahapan prediksi, kerangka ini diharapkan mampu menangkap hubungan nonlinier yang kompleks antarindikator sosial ekonomi sekaligus mempertahankan performa prediksi yang stabil pada berbagai wilayah dan periode pengamatan.

Berdasarkan hal tersebut, tujuan penelitian ini adalah mengembangkan dan mengevaluasi Kerangka *Adaptive Hybrid SVR-PSO* untuk prediksi Tingkat Pengangguran Terbuka berbasis data panel di Provinsi Jawa Tengah melalui integrasi optimasi hiperparameter otomatis berbasis *Particle Swarm Optimization* dengan metode *Support Vector Regression* [24], [25], [26]. Kerangka yang diusulkan bertujuan meningkatkan akurasi prediksi dan kemampuan generalisasi model sekaligus mampu merepresentasikan heterogenitas temporal dan regional pada data panel sosial ekonomi secara lebih efektif.

Kontribusi penelitian ini terdiri atas tiga aspek utama. Pertama, penelitian ini mengusulkan Kerangka *Adaptive Hybrid SVR-PSO* yang mengintegrasikan *Support Vector Regression* dengan optimasi hiperparameter otomatis berbasis *Particle Swarm Optimization* untuk prediksi Tingkat Pengangguran Terbuka berbasis data panel. Kedua, kerangka yang diusulkan secara khusus dirancang untuk mengakomodasi heterogenitas temporal dan regional pada data panel sosial ekonomi Provinsi Jawa Tengah. Ketiga, hasil evaluasi empiris menunjukkan bahwa kerangka yang diusulkan mampu meningkatkan kinerja prediksi pengangguran sehingga dapat dimanfaatkan sebagai alat pendukung keputusan yang praktis dalam perencanaan ketenagakerjaan daerah dan perumusan kebijakan berbasis data.

2. METODOLOGI PENELITIAN

Penelitian ini mengusulkan Kerangka *Adaptive Hybrid SVR-PSO* untuk memprediksi Tingkat Pengangguran Terbuka (TPT) berbasis data panel di Provinsi Jawa Tengah. Kerangka yang diusulkan mengintegrasikan metode *Support Vector Regression* (SVR) dengan *Particle Swarm Optimization* (PSO) untuk memperoleh kombinasi hiperparameter yang optimal secara otomatis sehingga mampu meningkatkan akurasi prediksi dan kemampuan generalisasi model terhadap karakteristik data panel yang heterogen. Tahapan penelitian terdiri atas enam proses utama, yaitu pengumpulan data panel, prapemrosesan data, pengembangan Kerangka *Adaptive Hybrid SVR-PSO*, validasi model, evaluasi kinerja, dan analisis hasil prediksi. Setiap tahapan dirancang secara sistematis, mulai dari persiapan data hingga evaluasi hasil prediksi, untuk memastikan model yang dihasilkan memiliki kinerja yang optimal dan dapat digunakan sebagai pendukung pengambilan keputusan dalam perencanaan ketenagakerjaan daerah. Alur penelitian secara keseluruhan disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data Panel

Data panel sosial ekonomi dikumpulkan dari Badan Pusat Statistik (BPS) Provinsi Jawa Tengah, yang mencakup 35 kabupaten/kota selama periode 2017–2025. Dataset yang digunakan terdiri atas 315 observasi, dengan Tingkat Pengangguran Terbuka (TPT) sebagai variabel target serta sembilan indikator sosial ekonomi, yaitu Tingkat Partisipasi Angkatan Kerja (TPAK), Rata-rata Lama Sekolah (RLS), Upah Minimum (UM), Indeks Pembangunan Manusia (IPM), Produk Domestik Regional Bruto per Kapita (PDRB per Kapita), Tingkat Kemiskinan (TK), Kepadatan Penduduk (KP), Jumlah Penduduk (JP), dan Laju Pertumbuhan Penduduk (LPP) sebagai variabel prediktor. Statistik deskriptif dari seluruh variabel tersebut disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif

Variable	Mean	Std. Dev.	Min	Max
TPT	4.98	1.83	1.76	9.97
TPAK	70.91	3.85	58.73	82.45
RLS	8.00	1.28	6.18	11.49
UM	2,006,318	338,900	1,370,000	3,454,827
IPM	73.20	4.58	64.86	86.23
PDRB per Kapita	43,921	28,734	16,864	167,236
Tingkat Kemiskinan	10.72	3.50	3.80	20.32
Kepadatan Penduduk	2,087	2,399	461	11,878
Jumlah Penduduk	798,016	578,029	122	2,043,077
Laju Pertumbuhan Penduduk	0.84	0.36	0.07	1.81

Tabel 1 menunjukkan statistik deskriptif 10 variabel penelitian berdasarkan 315 observasi dari 35 kabupaten/kota selama periode 2017–2025. TPT memiliki rata-rata sebesar 4,98% dengan standar deviasi 1,83 dan rentang 1,76%–9,97%, yang menunjukkan adanya variasi tingkat pengangguran yang cukup besar antarwilayah. TPAK memiliki rata-rata 70,91% dengan rentang 58,73%–82,45%, sedangkan RLS rata-rata sebesar 8,00 tahun dengan rentang 6,18–11,49 tahun, yang menunjukkan perbedaan partisipasi angkatan kerja dan capaian pendidikan antardaerah. Dari sisi ekonomi, UMK memiliki rata-rata Rp2.006.318 dengan rentang Rp1.370.000–Rp3.454.827, sementara PDRB per kapita menunjukkan rentang yang sangat lebar, yaitu Rp16.864–Rp167.236, yang mengindikasikan heterogenitas kondisi ekonomi regional. IPM memiliki rata-rata 73,20 dengan rentang 64,86–86,23, sedangkan tingkat kemiskinan rata-rata 10,72% dengan rentang 3,80%–20,32%. Kepadatan penduduk, jumlah penduduk, dan laju pertumbuhan penduduk juga menunjukkan variasi yang cukup besar antarwilayah. Secara keseluruhan, statistik deskriptif tersebut mengindikasikan heterogenitas sosial ekonomi yang kuat antar kabupaten/kota di Jawa Tengah, sehingga penggunaan pendekatan berbasis data panel dan model nonlinier seperti Adaptive Hybrid SVR–PSO menjadi relevan untuk menangkap perbedaan karakteristik regional dan temporal dalam prediksi TPT.

2.2. Prapemrosesan Data

Dataset yang telah dikumpulkan diperiksa untuk mengidentifikasi nilai yang hilang (missing values), data duplikat, serta konsistensi tipe data. Seluruh variabel numerik kemudian dikonversi ke dalam format floating-point untuk menjamin konsistensi proses komputasi. Karena metode Support Vector Regression (SVR) sensitif terhadap perbedaan skala fitur,



seluruh variabel prediktor dinormalisasi menggunakan metode Min–Max Scaling sehingga setiap fitur ditransformasikan ke dalam rentang $[0, 1]$.

Persamaan normalisasi dinyatakan sebagai berikut:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

dengan x merupakan nilai asli, $x_{\min}$ dan $x_{\max}$ masing-masing menyatakan nilai minimum dan maksimum dari setiap fitur, sedangkan x' merupakan nilai hasil normalisasi.

Selanjutnya, dataset dibagi menjadi data pelatihan (*training*) dan data pengujian (*testing*) menggunakan rasio 80:20, sehingga diperoleh 252 observasi sebagai data pelatihan dan 63 observasi sebagai data pengujian.

2.3. Pengembangan Kerangka Adaptive Hybrid SVR–PSO

Kerangka yang diusulkan mengintegrasikan Support Vector Regression (SVR) dengan Particle Swarm Optimization (PSO) untuk meningkatkan kinerja prediksi melalui optimasi hiperparameter secara otomatis. Metode SVR memodelkan hubungan nonlinier antara variabel sosial ekonomi dan Tingkat Pengangguran Terbuka (TPT), dengan fungsi regresi yang dinyatakan sebagai berikut:

$$f(x) = w^T \phi(x) + b \quad (2)$$

dengan w merupakan vektor bobot (*weight vector*), $\phi(x)$ menyatakan fungsi pemetaan nonlinier (*nonlinear mapping function*), dan b merupakan nilai bias. Fungsi objektif optimasi dirumuskan sebagai berikut:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3)$$

dengan memenuhi kendala fungsi kerugian (*loss function*) ε -insensitive. Hiperparameter yang dioptimalkan dalam penelitian ini disajikan pada Tabel 2.

Tabel 2. Optimasi Hiperparameter SVR

Hyperparameter	Description	Search Range	Optimal Value
C	Parameter Regularisasi	0.1–100	97.0401
Gamma	Koefisien Kernel	0.001–1	0.9984
Epsilon	Fungsi Kerugian ε -Insensitive	0.01–1	0.3527

Tabel 2 menyajikan hasil optimasi hiperparameter *Support Vector Regression* (SVR) menggunakan algoritma *Particle Swarm Optimization* (PSO). Berdasarkan Tabel 2, terdapat tiga hiperparameter yang dioptimalkan, yaitu C, Gamma (γ), dan Epsilon (ε). Parameter C memiliki rentang pencarian 0,1–100 dan menghasilkan nilai optimal sebesar 97,0401, Gamma memiliki rentang 0,001–1 dengan nilai optimal 0,9984, sedangkan Epsilon memiliki rentang 0,01–1 dengan nilai optimal 0,3527. Kombinasi nilai tersebut diperoleh melalui proses PSO dengan tujuan mencari konfigurasi hiperparameter yang meminimalkan nilai *Root Mean Square Error* (RMSE) pada proses validasi. Nilai C yang relatif tinggi menunjukkan kebutuhan regularisasi yang kuat, sedangkan nilai Gamma yang mendekati batas atas rentang pencarian menunjukkan bahwa fungsi kernel memerlukan sensitivitas yang tinggi dalam menangkap pola nonlinier data. Sementara itu, nilai Epsilon sebesar 0,3527 menunjukkan tingkat toleransi kesalahan yang digunakan model dalam membentuk fungsi regresi. Dengan demikian, sebagaimana ditunjukkan pada Tabel 2, kombinasi C = 97,0401, γ = 0,9984, dan ε = 0,3527 merupakan konfigurasi hiperparameter optimal yang selanjutnya digunakan pada model Adaptive Hybrid SVR–PSO untuk proses prediksi dan evaluasi kinerja.

2.4. Validasi Model

Setiap partikel dalam algoritma Particle Swarm Optimization (PSO) merepresentasikan suatu solusi kandidat yang terdiri atas tiga hiperparameter SVR, yaitu parameter regularisasi (C), koefisien kernel (γ), dan parameter fungsi kerugian ε -insensitive (ε). Nilai *fitness* setiap partikel dievaluasi menggunakan Root Mean Square Error (RMSE) yang diperoleh melalui 5-fold cross-validation. Selama proses optimasi, partikel memperbarui kecepatan (*velocity*) dan posisinya secara iteratif berdasarkan solusi terbaik individu (*personal best* atau pBest) dan solusi terbaik global (*global best* atau gBest) untuk memperoleh kombinasi hiperparameter SVR yang optimal. Pembaruan kecepatan (*Velocity Update*):

$$v_i^{t+1} = wv_i^t + c_1r_1(p_i - x_i) + c_2r_2(g - x_i) \quad (4)$$

Pembaruan posisi (*Position Update*):

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (5)$$

Dalam proses optimasi PSO, bobot inersia (*inertia weight*) digunakan untuk mengendalikan pengaruh kecepatan sebelumnya, sedangkan koefisien kognitif (*cognitive coefficient*) mengatur kecenderungan partikel untuk bergerak menuju solusi terbaik yang pernah ditemukan secara individu (*personal best*). Koefisien sosial (*social coefficient*) mengendalikan pengaruh solusi terbaik yang ditemukan oleh seluruh partikel (*global best*) terhadap pergerakan partikel. Selain itu, bilangan acak (*random numbers*) digunakan untuk memberikan variasi stokastik pada proses pembaruan



kecepatan dan posisi partikel. Dalam penelitian ini, proses optimasi dilakukan menggunakan 20 partikel (*swarm size*) selama 50 iterasi, dengan setiap partikel merepresentasikan kandidat kombinasi hiperparameter SVR yang dievaluasi berdasarkan fungsi objektif yang telah ditentukan.

2.5. Evaluasi Kinerja

Kinerja model dievaluasi menggunakan Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Square Error (RMSE), dan koefisien determinasi (R^2). Sementara itu, nilai RMSE yang diperoleh melalui 5-fold cross-validation digunakan sebagai fungsi *fitness* pada algoritma Particle Swarm Optimization. Metrik evaluasi yang digunakan dinyatakan sebagai berikut.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

dengan y_i menyatakan nilai Tingkat Pengangguran Terbuka (TPT) yang diamati (*observed value*), sedangkan $\hat{y}_i$ merupakan nilai hasil prediksi (*predicted value*).

2.6. Analisis Prediksi

Setelah PSO memperoleh hiperparameter SVR yang optimal, model akhir dilatih kembali (*retrained*) menggunakan data pelatihan dan selanjutnya dievaluasi menggunakan data pengujian. Konfigurasi eksperimen prediksi yang digunakan dalam penelitian ini disajikan pada Tabel 3.

Tabel 3. Konfigurasi Prediksi

Parameter	Nilai
Data Pelatihan	80%
Data Pengujian	20%
Model Regresi	Support Vector Regression (SVR)
Fungsi Kernel	Radial Basis Function (RBF)
Optimasi Hiperparameter	Particle Swarm Optimization (PSO)
Target Prediksi	Tingkat Pengangguran Terbuka (TPT)
Metrik Evaluasi	MAE, MSE, RMSE, R^2

Tabel 3 merangkum konfigurasi prediksi yang digunakan dalam penelitian ini, meliputi pembagian data, model regresi, fungsi kernel, metode optimasi hiperparameter, target prediksi, dan metrik evaluasi. Konfigurasi tersebut menjadi dasar kerangka eksperimen untuk mengevaluasi model Adaptive Hybrid SVR-PSO yang diusulkan.

2.7. Metrik Regresi

Kinerja model dievaluasi menggunakan beberapa metrik regresi yang umum digunakan untuk mengukur tingkat akurasi prediksi. Pemilihan beberapa metrik diperlukan karena setiap metrik memberikan perspektif yang berbeda terhadap kesalahan prediksi dan kemampuan model dalam menjelaskan variasi data aktual. Dalam penelitian ini, evaluasi dilakukan menggunakan *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Ketiga metrik tersebut digunakan secara bersama-sama untuk memberikan penilaian yang lebih komprehensif terhadap kinerja model Adaptive Hybrid SVR-PSO dalam memprediksi Tingkat Pengangguran Terbuka (TPT).

Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata nilai absolut selisih antara nilai aktual dan nilai hasil prediksi. Nilai MAE yang semakin kecil menunjukkan bahwa kesalahan prediksi model semakin rendah. Persamaan MAE dinyatakan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

dengan merupakan nilai aktual, merupakan nilai hasil prediksi, dan merupakan jumlah observasi.

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur rata-rata persentase kesalahan absolut antara nilai aktual dan nilai prediksi. Metrik ini memberikan gambaran mengenai tingkat kesalahan prediksi dalam bentuk persentase sehingga lebih mudah digunakan untuk menginterpretasikan tingkat akurasi model. Semakin kecil nilai MAPE, semakin baik kemampuan model dalam menghasilkan prediksi yang mendekati nilai aktual. Persamaan MAPE dirumuskan sebagai berikut:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (8)$$

Koefisien Determinasi (R^2) digunakan untuk mengukur proporsi variasi nilai aktual yang dapat dijelaskan oleh model prediksi. Nilai R^2 yang semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan yang semakin baik dalam menjelaskan variasi data, sedangkan nilai yang lebih rendah menunjukkan kemampuan penjelasan model yang lebih terbatas. Persamaan koefisien determinasi dinyatakan sebagai berikut:

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (9)$$

dengan $\bar{y}$ merupakan nilai rata-rata dari variabel aktual. Dengan menggunakan MAE, MAPE, dan R^2 secara bersamaan, evaluasi dapat menggambarkan tingkat kesalahan prediksi sekaligus kemampuan model dalam menjelaskan variasi TPT. Hasil dari ketiga metrik tersebut selanjutnya digunakan untuk membandingkan kinerja model Adaptive Hybrid SVR–PSO dengan model baseline yang digunakan dalam penelitian.


3. HASIL DAN PEMBAHASAN

3.1. Statistik Deskriptif Data Panel

Statistik deskriptif menunjukkan adanya variasi yang cukup besar pada variabel-variabel sosial ekonomi antarwilayah dan antarperiode, yang mencerminkan karakteristik heterogen dari dataset panel yang digunakan. Secara khusus, Tingkat Pengangguran Terbuka (TPT) berada pada kisaran 1,76% hingga 9,97%, yang menunjukkan adanya perbedaan kondisi pasar tenaga kerja yang cukup signifikan di antara kabupaten dan kota di Provinsi Jawa Tengah. Karakteristik heterogen tersebut mengindikasikan adanya hubungan yang kompleks antarvariabel sosial ekonomi, sehingga mendukung penerapan Kerangka Adaptive Hybrid SVR–PSO yang diusulkan.

3.2. Analisis Distribusi dan Korelasi


Gambar 2 menunjukkan distribusi Tingkat Pengangguran Terbuka (TPT). Variabilitas yang moderat serta distribusi data yang relatif seimbang menunjukkan bahwa dataset yang digunakan sesuai untuk diterapkan pada pemodelan regresi.



Gambar 2. Distribusi Tingkat Pengangguran Terbuka (TPT)

Gambar 2 menunjukkan distribusi Tingkat Pengangguran Terbuka (TPT) pada seluruh observasi dalam dataset penelitian. Distribusi data terkonsentrasi pada kisaran sekitar 3–6%, dengan frekuensi tertinggi berada pada rentang sekitar 4–5%, sedangkan sebagian observasi lainnya tersebar hingga mendekati 10%. Pola tersebut menunjukkan adanya variasi tingkat pengangguran antarwilayah dan periode pengamatan, tetapi sebagian besar nilai masih berada pada rentang yang relatif terkonsentrasi. Distribusi yang tidak menunjukkan pencilan ekstrem dalam jumlah dominan mengindikasikan bahwa variabel TPT memiliki karakteristik yang cukup representatif untuk digunakan sebagai variabel target dalam pemodelan regresi. Kondisi ini juga memberikan dasar yang memadai untuk penerapan model Adaptive Hybrid SVR–PSO dalam mempelajari hubungan antara TPT dan variabel prediktor yang digunakan dalam penelitian.

Untuk mengkaji lebih lanjut hubungan antarvariabel sosial ekonomi, dilakukan **analisis korelasi Pearson**, sebagaimana ditunjukkan pada Gambar 3.




Gambar 3. Matriks Korelasi Variabel Sosial Ekonomi

Gambar 3 menunjukkan hubungan korelasi antarvariabel sosial ekonomi yang digunakan dalam penelitian. TPT memiliki korelasi negatif sedang dengan TPAK sebesar $-0,45$, sedangkan korelasi dengan variabel lainnya relatif lemah. Korelasi tinggi terlihat pada RLS dengan IPM sebesar $0,97$, RLS dengan PDRB per Kapita sebesar $0,75$, dan IPM dengan PDRB per Kapita sebesar $0,76$, yang menunjukkan adanya keterkaitan kuat antarindikator sosial ekonomi. Hasil ini menjadi pertimbangan dalam pemodelan karena karakteristik hubungan antarvariabel yang cukup kompleks dan berpotensi mengandung multikolinearitas. Hasil analisis korelasi menunjukkan bahwa Tingkat Partisipasi Angkatan Kerja (TPAK/LFPR) memiliki hubungan negatif paling kuat dengan Tingkat Pengangguran Terbuka (TPT). Temuan ini mendukung penerapan Kerangka Adaptive Hybrid SVR–PSO yang diusulkan.

3.3. Kinerja SVR Baseline

Sebagai acuan untuk membandingkan kinerja model, terlebih dahulu dikembangkan model Support Vector Regression (SVR) baseline dengan menggunakan hiperparameter bawaan (*default*). Hasil prediksi model tersebut disajikan pada Gambar 4.



Gambar 4. Hasil Prediksi SVR Baseline

Model SVR baseline menghasilkan kinerja prediksi yang tergolong moderat dengan nilai MAE sebesar $0,9382$, RMSE sebesar $1,1928$, MAPE sebesar $18,92\%$, dan R^2 sebesar $0,4954$. Meskipun model mampu menangkap pola umum Tingkat Pengangguran Terbuka (TPT), masih terdapat kesalahan prediksi yang cukup signifikan. Hal ini menunjukkan bahwa pemilihan hiperparameter secara manual belum mampu memodelkan karakteristik nonlinier pada data panel sosial ekonomi secara optimal.


3.4. Optimasi Adaptive Hybrid SVR–PSO

Kerangka yang diusulkan memanfaatkan Particle Swarm Optimization (PSO) untuk menentukan kombinasi optimal hiperparameter SVR, yaitu C , γ , dan ϵ , secara otomatis. Proses optimasi dilakukan menggunakan 20 partikel selama 50 iterasi, dengan Root Mean Square Error (RMSE) yang diperoleh melalui 5-fold cross-validation sebagai fungsi fitness.

Tabel 4. Hiperparameter SVR Optimal

Parameter	Optimal
C	97.0401
Gamma	0.9984
Epsilon	0.3527
Best RMSE	1.0454

Proses optimasi berhasil memperoleh kombinasi hiperparameter yang optimal, yaitu $C = 97,0401$, $\gamma = 0,9984$, dan $\epsilon = 0,3527$, dengan menghasilkan nilai Root Mean Square Error (RMSE) minimum sebesar $1,0454$ berdasarkan 5-fold cross-validation.



Gambar 5. Kurva Konvergensi PSO

Seperti yang ditunjukkan pada Gambar 5, proses optimasi konvergen dengan cepat pada iterasi-iterasi awal dan mencapai nilai fitness yang stabil setelah kira-kira iterasi kesepuluh. Tidak adanya fluktuasi yang signifikan pada iterasi berikutnya menunjukkan bahwa kawanan (swarm) telah berhasil konvergen menuju optimum global, yang membuktikan efektivitas dan stabilitas algoritma PSO dalam mengoptimalkan hiperparameter SVR.

3.5. Perbandingan Kinerja Prediksi

Hiperparameter teroptimasi yang diperoleh dari PSO selanjutnya digunakan untuk melatih kembali model SVR. Kinerja prediksi yang dihasilkan diilustrasikan pada Gambar 6, sedangkan perbandingan kuantitatif antara SVR baseline dan Framework Adaptive Hybrid SVR–PSO yang diusulkan dirangkum dalam Tabel 5.



Gambar 6. Prediksi Adaptive Hybrid SVR–PSO

Gambar 6 memperlihatkan perbandingan antara nilai TPT aktual dan hasil prediksi *Adaptive Hybrid SVR–PSO* pada data pengujian. Secara umum, garis prediksi mengikuti pola naik-turun nilai aktual dengan cukup baik, termasuk pada beberapa titik dengan perubahan TPT yang relatif tajam. Meskipun masih terdapat selisih pada beberapa observasi, kedekatan pola kedua garis menunjukkan bahwa model mampu menangkap pola dan variasi TPT secara relatif baik. Hasil ini mendukung temuan evaluasi kuantitatif bahwa *Adaptive Hybrid SVR–PSO* memberikan kinerja prediksi yang lebih baik dibandingkan SVR baseline.

Tabel 5. Perbandingan Kinerja

Metrik	SVR Baseline	Adaptive Hybrid SVR–PSO
MAE	0.9382	0.7715
RMSE	1.1928	0.9264
MAPE	18.92	16.78
R ²	0.4954	0.6956

Framework Adaptive Hybrid SVR–PSO yang diusulkan secara konsisten menunjukkan kinerja lebih baik dibandingkan model SVR baseline. Model ini mampu menurunkan nilai MAE sebesar 17,77%, RMSE sebesar 22,33%, dan MAPE sebesar 11,31%, serta meningkatkan nilai R² sebesar 40,41%. Peningkatan tersebut menunjukkan bahwa optimasi hiperparameter menggunakan PSO mampu menghasilkan konfigurasi SVR yang lebih sesuai dengan karakteristik data panel sosial ekonomi. Penurunan ketiga metrik kesalahan menunjukkan berkurangnya penyimpangan antara nilai aktual dan prediksi, sedangkan peningkatan R² menunjukkan kemampuan model yang lebih baik dalam menjelaskan variasi TPT. Dengan demikian, integrasi PSO tidak hanya meningkatkan akurasi prediksi, tetapi juga memperkuat kemampuan generalisasi SVR dalam menangkap pola nonlinier dan heterogenitas antarwilayah pada data panel pengangguran.

Tabel 6. Peningkatan Kinerja

Metrik	Peningkatan
MAE	17.77%
RMSE	22.33%
MAPE	11.31%
R ²	40.41%

Tabel 6 menunjukan Framework Adaptive Hybrid SVR–PSO yang diusulkan mengurangi MAE sebesar 17,77% dan RMSE sebesar 22,33%, yang mengindikasikan peningkatan substansial dalam akurasi prediksi. Selain itu, koefisien determinasi meningkat sebesar kurang lebih 40,41%, membuktikan bahwa PSO secara efektif mengoptimalkan hiperparameter SVR dan meningkatkan kemampuan model dalam menangkap hubungan nonlinier di dalam data sosio-ekonomi panel yang heterogen.



3.6. Pembahasan

Temuan penelitian menunjukkan bahwa optimasi hiperparameter menggunakan *Particle Swarm Optimization* (PSO) memberikan peningkatan kinerja yang konsisten pada model Support Vector Regression (SVR). Sebagaimana ditunjukkan pada Tabel 5 dan Tabel 6, penerapan Adaptive Hybrid SVR–PSO menurunkan MAE dari 0,9382 menjadi 0,7715 atau sebesar 17,77%, menurunkan RMSE dari 1,1928 menjadi 0,9264 atau sebesar 22,33%, serta menurunkan MAPE dari 18,92% menjadi 16,78% atau sebesar 11,31%. Pada saat yang sama, nilai R^2 meningkat dari 0,4954 menjadi 0,6956 atau sebesar 40,41%. Peningkatan tersebut menunjukkan bahwa optimasi tidak hanya mengurangi besarnya kesalahan prediksi, tetapi juga meningkatkan kemampuan model dalam menjelaskan variasi TPT pada data panel sosial ekonomi. Hasil ini konsisten dengan temuan Wardani dan Sugiman (2025) yang menunjukkan bahwa SVR mampu mengungguli VARX dalam prediksi TPT Jawa Barat, dengan RMSE 0,49 dan MAPE 6%, dibandingkan VARX yang menghasilkan RMSE 0,82 dan MAPE 8,4%.

Namun, perbandingan tersebut perlu diinterpretasikan secara hati-hati karena penelitian Wardani dan Sugiman [27] menggunakan data bulanan satu provinsi selama 2018–2023 dan optimasi *Grid Search*, sedangkan penelitian ini menggunakan 315 observasi panel dari 35 kabupaten/kota selama 2017–2025 serta optimasi PSO. Dengan demikian, nilai MAPE 16,78% pada penelitian ini tidak dapat secara langsung dinyatakan lebih baik daripada MAPE 6% pada penelitian Wardani dan Sugiman karena karakteristik data, periode pengamatan, frekuensi data, dan skema validasinya berbeda; kontribusi utama penelitian ini justru terletak pada peningkatan relatif terhadap SVR baseline sebesar 11,31% pada MAPE dan 22,33% pada RMSE dalam struktur data panel regional. Perbandingan dengan Annastasya, Passarella, dan Yamani (2025) [28] juga memberikan perspektif penting. Penelitian tersebut menggunakan data deret waktu nasional Indonesia periode 1970–2023 dan membandingkan delapan algoritma *machine learning*; *Gradient Boosting Regressor* menjadi model terbaik, sedangkan SVR menghasilkan MAPE sekitar 19–20% pada evaluasi *hold-out* 2023 dan *Gradient Boosting* menghasilkan MAPE 14,7%. Dibandingkan temuan tersebut, MAPE sebesar 16,78% pada Adaptive Hybrid SVR–PSO menunjukkan kinerja yang kompetitif, sekaligus memperlihatkan bahwa optimasi hiperparameter dapat meningkatkan SVR dibandingkan konfigurasi baseline pada konteks data panel Jawa Tengah.

Sementara itu, Liu dan Li (2022) [29] menggunakan kombinasi model deret waktu dan *two-weight neural network* untuk prediksi pengangguran di Tiongkok dan menemukan bahwa model gabungan menghasilkan residual yang lebih rendah dibandingkan model individual maupun BP neural network. Temuan tersebut sejalan dengan hasil penelitian ini dalam hal pentingnya mengombinasikan atau mengoptimalkan komponen pemodelan untuk memperoleh kinerja yang lebih baik, tetapi pendekatan Liu dan Li berorientasi pada deret waktu agregat, sedangkan penelitian ini secara khusus memanfaatkan dimensi temporal dan regional dalam data panel. Secara keseluruhan, peningkatan R^2 sebesar 40,41% merupakan temuan yang paling menonjol, karena menunjukkan bahwa optimasi PSO meningkatkan kemampuan SVR dalam menjelaskan variasi TPT secara substansial, sementara penurunan MAE, RMSE, dan MAPE menunjukkan bahwa peningkatan tersebut juga diikuti oleh pengurangan kesalahan prediksi. Oleh karena itu, hasil penelitian memperkuat argumen bahwa integrasi SVR dengan optimasi hiperparameter PSO merupakan pendekatan yang relevan untuk pemodelan TPT berbasis data panel yang heterogen, meskipun perbandingan absolut dengan penelitian terdahulu harus mempertimbangkan perbedaan struktur data dan desain eksperimen.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan Kerangka Adaptive Hybrid SVR–PSO untuk memprediksi Tingkat Pengangguran Terbuka (TPT) berbasis data panel yang mencakup 35 kabupaten/kota di Jawa Tengah selama periode 2017–2025. Kerangka yang diusulkan mengintegrasikan *Support Vector Regression* (SVR) dengan *Particle Swarm Optimization* (PSO) untuk mengoptimalkan hiperparameter model, sehingga diperoleh konfigurasi optimal $C = 97,0401$, $\gamma = 0,9984$, dan $\epsilon = 0,3527$. Hasil evaluasi menunjukkan bahwa model Adaptive Hybrid SVR–PSO menghasilkan MAE sebesar 0,7715, RMSE sebesar 0,9264, MAPE sebesar 16,78%, dan R^2 sebesar 0,6956, serta memberikan peningkatan kinerja dibandingkan SVR baseline dengan penurunan MAE sebesar 17,77%, RMSE sebesar 22,33%, dan MAPE sebesar 11,31%, serta peningkatan R^2 sebesar 40,41%. Hasil tersebut menunjukkan bahwa optimasi hiperparameter berbasis PSO mampu meningkatkan akurasi prediksi sekaligus kemampuan generalisasi SVR dalam menangkap hubungan nonlinier dan heterogenitas temporal maupun regional pada data panel sosial ekonomi. Dengan demikian, Kerangka Adaptive Hybrid SVR–PSO tidak hanya memberikan pendekatan yang efektif untuk prediksi TPT, tetapi juga berpotensi menjadi instrumen pendukung dalam mengidentifikasi pola pengangguran antarwilayah dan mendukung perencanaan serta perumusan kebijakan ketenagakerjaan berbasis data di Jawa Tengah.

REFERENCES

- [1] J. Goh, “Understanding Unemployment: Causes, Consequences, and Solutions,” *International Journal of Advanced Studies in Economics and Public Sector Management*, vol. 13, no. 2, pp. 219–224, Nov. 2025, doi: 10.48028/iiprds/ijasepsm.v13.i2.12.
- [2] Ralita Widyawati, E. Aristyanto, and A. S. Edi, “Pengaruh Tingkat Pengangguran Terbuka, Tingkat Pendidikan, Upah Minimum terhadap Pertumbuhan Ekonomi di Provinsi Jawa Timur Tahun 2017-2024,” *Jurnal Ekonomi, Manajemen Pariwisata dan Perhotelan*, vol. 4, no. 3, pp. 205–222, Jul. 2025, doi: 10.55606/jempper.v4i3.4997.



- [3] S. Izzah Ayustina and H. Harmaini, "Determinan Tingkat Pengangguran Terbuka pada Kabupaten/Kota di Provinsi Banten Tahun 2010-2024," *Jurnal Ekonomi, Manajemen, Akuntansi dan Keuangan*, vol. 7, no. 2, p. 13, Jan. 2026, doi: 10.53697/emak.v7i2.3656.
- [4] G. Andabayeva, V. Movchun, M. Dubovik, G. Kurpebayeva, and X. Cai, "Labor market dynamics in developing countries: analysis of employment transformation at the macro-level," *J. Innov. Entrep.*, vol. 13, no. 1, p. 65, Sep. 2024, doi: 10.1186/s13731-024-00417-0.
- [5] M. Li and W. Gao, "Exploring How Human Capital Development Promotes Economic Transformation," *Journal of Organizational and End User Computing*, vol. 37, no. 1, pp. 1–22, Sep. 2025, doi: 10.4018/JOEUC.388939.
- [6] C. M. Profiroi, A. G. Profiroi, D.-L. Constantin, I. Nica, C. Delcea, and M. R. Brişcariu, "Assessing regional economic Performance: Fuzzy multi-criteria decision making and panel regression approach," *Socioecon. Plann. Sci.*, vol. 100, p. 102245, Aug. 2025, doi: 10.1016/j.seps.2025.102245.
- [7] G. García-Vidal, N. A. Loredó-Carballo, R. Pérez-Campdesuñer, and G. García-Vidal, "Economic Convergence Analyses in Perspective: A Bibliometric Mapping and Its Strategic Implications (1982–2025)," *Economies*, vol. 13, no. 10, p. 289, Oct. 2025, doi: 10.3390/economies13100289.
- [8] L. S. Badriah, M. S. P. Sanjaya, Barokatumnalloh, and Prihono, "Determinants of Open Unemployment Rate in Central Java Province 2017-2023," *The International Conference on Sustainable Economics Management and Accounting Proceeding*, vol. 1, pp. 2178–2188, Aug. 2025, doi: 10.32424/icsema.1.1.155.
- [9] D. A. N. Rohmah, S. Subanti, and Y. Susanti, "Analysis Of Factors Influencing The Poverty Rate In Central Java Province Using Panel Data Regression," *Proceeding of International Conference of Religion, Health, Education, Science and Technology*, vol. 1, no. 1, pp. 274–283, Aug. 2024, doi: 10.35316/icorhestech.v1i1.5645.
- [10] L. A. Putri, "Influence of Population Human Development Index and Unemployment Open to Poverty in Central Java," *Rangkiang: Journal of Islamic Economics and Business*, vol. 3, no. 1, pp. 1–14, Apr. 2025, doi: 10.70072/rangkiang.v3i1.48.
- [11] C. Magazzino, M. Mele, and M. Mutascu, "An artificial neural network experiment on the prediction of the unemployment rate," *J. Policy Model.*, vol. 47, no. 3, pp. 471–491, May 2025, doi: 10.1016/j.jpolmod.2024.10.004.
- [12] A. D. Huruta, "Predicting the unemployment rate using autoregressive integrated moving average," *Cogent Business & Management*, vol. 11, no. 1, Dec. 2024, doi: 10.1080/23311975.2023.2293305.
- [13] D. Shen, P. Ding, J. Sekhon, and B. Yu, "Same Root Different Leaves: Time Series and Cross-Sectional Methods in Panel Data," *Econometrica*, vol. 91, no. 6, pp. 2125–2154, 2023, doi: 10.3982/ECTA21248.
- [14] R. Ma, Y. Ma, and X. Liu, "Time series anomaly detection via temporal relationship graphs and adaptive smoothing," *Appl. Soft Comput.*, vol. 179, p. 113298, Jul. 2025, doi: 10.1016/j.asoc.2025.113298.
- [15] A. Djabal and E. Hariani, "Effect of Wages, Economic Growth, and Human Development Index on the Labor Force Participation Rate," *Airlangga Journal of Innovation Management*, vol. 6, no. 4, pp. 823–838, Dec. 2025, doi: 10.20473/ajim.v6i4.75567.
- [16] W. D. A. P. Ruslan and Devanto Shasta Pratomo, "The Effect of GRDP, Minimum Wages, and Education on Workforce Absorption in Regencies and Cities in East Java," *Journal of Development Economic and Social Studies*, vol. 4, no. 1, pp. 91–109, Jan. 2025, doi: 10.21776/jdess.2025.04.1.08.
- [17] Y. Zhang *et al.*, "Nonlinear relationships and interaction effects of urban built environment on urban vitality based on explainable machine learning," *City and Environment Interactions*, vol. 28, p. 100244, Dec. 2025, doi: 10.1016/j.cacint.2025.100244.
- [18] T. Annastasya, R. Passarella, and Z. Yamani, "Unemployment rate forecasting in Indonesia using macroeconomic indicators with a machine learning approach," *Discover Analytics*, vol. 3, no. 1, p. 15, Sep. 2025, doi: 10.1007/s44257-025-00044-3.
- [19] X. Liu and L. Li, "Prediction of Labor Unemployment Based on Time Series Model and Neural Network Model," *Comput. Intell. Neurosci.*, vol. 2022, pp. 1–8, Jun. 2022, doi: 10.1155/2022/7019078.
- [20] M. Li, Q. Li, Y. Wang, and W. Chen, "Spatial path and determinants of carbon transfer in the process of inter provincial industrial transfer in China," *Environ. Impact Assess. Rev.*, vol. 95, p. 106810, Jul. 2022, doi: 10.1016/j.eiar.2022.106810.
- [21] E. H. I. Eliwa and T. Abd El-Hafeez, "Particle swarm optimization framework for Parkinson's disease prediction," *PeerJ Comput. Sci.*, vol. 11, p. e3135, Sep. 2025, doi: 10.7717/peerj-cs.3135.
- [22] M. ZLOBIN and V. BAZYLEVYCH, "Bayesian Optimization for Tuning Hyperparametr of Machine Learning Models: A Performance Analysis in Xgboost," *Computer systems and information technologies*, no. 1, pp. 141–146, Mar. 2025, doi: 10.31891/csit-2025-1-16.
- [23] J. Díaz-Aparicio, E. Rodríguez-Esparza, J. Fajardo-Calderín, and E. Onieva, "Studying the impact of data preprocessing, hyperparameter tuning and machine learning algorithms in crash prediction explainability," *Array*, vol. 30, p. 100743, Jul. 2026, doi: 10.1016/j.array.2026.100743.
- [24] B. Zeng, X. Shang, R. Lu, and Y. Zhang, "Particle swarm optimization-based NLP methods for optimizing automatic document classification and retrieval," *PLoS One*, vol. 20, no. 7, p. e0325851, Jul. 2025, doi: 10.1371/journal.pone.0325851.
- [25] L. Abualigah, "Particle Swarm Optimization: Advances, Applications, and Experimental Insights," *Computers, Materials & Continua*, vol. 82, no. 2, pp. 1539–1592, 2025, doi: 10.32604/cmc.2025.060765.
- [26] Syahril, R. Medikawati Taufiq, Taslim, D. Torsa, Fajrizal, and S. Handayani, "Optimasi Parameter Support Vector Machine Dengan Particle Swarm Optimization Untuk Prediksi Tunggalan Iuran Sekolah," *Technologica*, vol. 3, no. 2, pp. 75–84, Jul. 2024, doi: 10.55043/technologica.v3i2.162.
- [27] Y. Kusuma Wardani and Sugiman, "Forecasting the unemployment rate in West Java Province using VARX and SVR methods," *Journal of Natural Sciences and Mathematics Research*, vol. 11, no. 2, pp. 153–163, Dec. 2025, doi: 10.21580/jnsmr.v11i2.27602.
- [28] T. Annastasya, R. Passarella, and Z. Yamani, "Unemployment rate forecasting in Indonesia using macroeconomic indicators with a machine learning approach," *Discover Analytics*, vol. 3, no. 1, p. 15, Sep. 2025, doi: 10.1007/s44257-025-00044-3.
- [29] X. Liu and L. Li, "Prediction of Labor Unemployment Based on Time Series Model and Neural Network Model," *Comput. Intell. Neurosci.*, vol. 2022, pp. 1–8, Jun. 2022, doi: 10.1155/2022/7019078.