



UNIVERSITAS
SURABAYA

PENGUKUHAN GURU BESAR UNIVERSITAS SURABAYA

Selasa, 3 Maret 2026

Dari Perilaku Serigala ke Kecerdasan Mesin: Peran Grey Wolf Optimizer dalam Pembelajaran Mesin Modern

Prof. Dr. Joko Siswantoro, S.Si., M.Si., HCIA-AI, CADS.

Guru Besar dalam Bidang Pembelajaran Mesin
Fakultas Teknik



**Dari Perilaku Serigala ke Kecerdasan Mesin:
Peran Grey Wolf Optimizer dalam
Pembelajaran Mesin Modern**



Orasi Ilmiah

**Disampaikan pada Pengukuhan Guru Besar
dalam Bidang Pembelajaran Mesin
pada Fakultas Teknik Universitas Surabaya
Surabaya, 3 Maret 2026**

Oleh.

Prof. Dr. Joko Siswantoro, S.Si., M.Si., HCIA-AI., CADS.

Assalamu'alaikum Warahmatullahi Wabarakatuh.

Yang saya hormati,

Ketua LLDIKTI Wilayah VII

Ketua Umum, Pembina, Pengurus dan Pengawas Yayasan Universitas Surabaya

Rektor dan para Wakil Rektor serta Ketua LPPM Universitas Surabaya

Ketua, Sekretaris dan para anggota Senat Universitas Surabaya

Pimpinan Fakultas/Politeknik di lingkungan Universitas Surabaya

Ketua Program Studi dan rekan sejawat di lingkungan Universitas Surabaya

Serta para hadirin dan undangan yang berbahagia.


Puji syukur kita panjatkan kehadirat Allah SWT, Tuhan yang Maha Esa, yang telah memberikan nikmat dan karuniaNya sehingga kita dapat berkumpul pada acara yang berbahagia ini. Sholawat serta salam semoga selalu tercurahkan kepada junjungan kami Nabi Muhammad SAW.

Hadirin yang saya hormati, pada era digital saat ini, kita hidup dalam dunia yang dipenuhi pilihan dan kompleksitas. Dari diagnosis medis hingga sistem transportasi cerdas, dari pengolahan data bisnis hingga pengembangan kecerdasan buatan, semuanya menghadapi satu pertanyaan mendasar yaitu “Bagaimana kita menemukan solusi terbaik di antara begitu banyak kemungkinan?” Jawaban atas pertanyaan tersebut membawa kita pada konsep optimasi, dan menariknya, inspirasi solusi tersebut sering kali datang bukan hanya dari matematika, tetapi dari alam. Oleh karena itu pada kesempatan yang berbahagia ini izinkan saya untuk berbagi wawasan mengenai peran Grey Wolf Optimizer dalam pembelajaran mesin modern.

1. Memahami Pembelajaran Mesin: Bagaimana Mesin Belajar dari Data

Pembelajaran mesin (*mechine learning*) adalah cabang dari kecerdasan artifisial yang bertujuan untuk membuat mesin/komputer mampu belajar tanpa harus diprogram secara eksplisit [1]. Maksudnya, komputer tidak harus diberikan satu per satu aturan “jika begini maka begitu” seperti pada kecerdasan artifisial tradisional, tetapi komputer belajar mengenali pola dari contoh yang diberikan, seperti diilustrasikan pada Gambar 1. Cara belajar ini mirip anak kecil belajar membedakan kucing dan anjing. Ketika orang tua menunjukkan beberapa contoh gambar kucing dan anjing sambil memberi tahu “ini kucing, ini anjing”, anak mulai menangkap ciri-ciri umum, misalnya bentuk telinga, moncong, tekstur bulu, bukan menghafal satu gambar tertentu.

Dalam pembelajaran mesin, untuk membuat komputer bisa mengenali kucing dan anjing. Komputer diberi banyak contoh gambar yang sudah dilabeli “kucing” atau “anjing” sebagai data latih, kemudian algoritma menyesuaikan parameter model selama proses pelatihan (*training*) agar prediksinya makin benar. Ukuran “belajarnya” adalah kinerja yang membaik seiring pengalaman/data bertambah. Tujuan pentingnya bukan sekadar benar pada gambar yang pernah dilihat, tetapi mampu mengenali kucing/anjing lain yang baru, misalnya ras berbeda, sudut kamera berbeda, atau pencahayaan berbeda. Kemampuan “tetap bisa mengenali pada contoh baru” ini disebut generalisasi, dan menjadi konsep inti dalam pembelajaran mesin modern. Sehingga pembelajaran mesin dapat dipandang sebagai suatu proses membangun model yang kinerjanya meningkat melalui pengalaman (data), dengan tujuan utama mencapai generalisasi yang baik pada data baru [2].




Gambar 1. Pendekatan: (a) Kecerdasan Artifisial Tradisional (b) Pembelajaran Mesin.

Dalam proses pelatihan, model menerima data sebagai input, menghasilkan prediksi, kemudian membandingkan hasil prediksi tersebut dengan jawaban yang benar menggunakan sebuah fungsi yang disebut *loss function*. Fungsi ini digunakan sebagai indikator seberapa jauh hasil prediksi menyimpang dari target yang diharapkan. Proses training berlangsung secara iteratif dengan tujuan meminimalkan nilai kerugian tersebut, sehingga model secara bertahap meningkatkan kemampuannya dalam menangkap pola data. Kerangka ini dikenal sebagai *empirical risk minimization*, yaitu upaya menemukan konfigurasi model yang memberikan kinerja terbaik berdasarkan pengalaman data [3], [4].

Terdapat dua komponen penting yang perlu dibedakan dalam pelatihan model pembelajaran mesin, yaitu parameter dan *hyperparameter*. Proses pelatihan dapat dianalogikan seperti penyulingan minyak wangi dari bunga, seperti diilustrasikan pada Gambar 2. Dalam analogi ini, data berperan sebagai bunga yang menjadi bahan utama, sementara proses pelatihan merupakan proses penyulingan yang bertujuan mengekstraksi esensi terbaik dari bahan tersebut. Parameter dapat dipandang sebagai hasil penyulingan yang diperoleh dari bunga melalui proses tersebut. Nilai parameter, seperti bobot dan bias pada jaringan saraf atau koefisien pada model regresi, terbentuk secara bertahap selama pelatihan dan menentukan bagaimana model memetakan input menjadi output serta menghasilkan keputusan.


Sebaliknya, *hyperparameter* merupakan pengaturan yang ditentukan sebelum proses penyulingan dimulai. Dalam analogi penyulingan minyak wangi, *hyperparameter* dapat diibaratkan sebagai besarnya api, suhu pemanasan, tekanan, atau lamanya waktu penyulingan yang telah ditetapkan sebelumnya. *Hyperparameter* tidak dihasilkan dari data, tetapi ditentukan diawal untuk mengendalikan bagaimana proses ekstraksi berlangsung. Pengaturan ini sangat memengaruhi kualitas hasil akhir, karena menentukan dinamika proses belajar, stabilitas pelatihan, serta kemampuan model untuk menghasilkan representasi yang mampu digeneralisasikan pada data baru. Dengan demikian, keberhasilan pembelajaran mesin tidak hanya bergantung pada kualitas data sebagai bahan baku, tetapi juga pada keseimbangan antara hasil ekstraksi (parameter) dan pengaturan proses (*hyperparameter*) yang tepat [5]



Gambar 2. Ilustrasi proses pelatihan model pembelajaran mesin.

Algoritma optimasi memiliki peran sentral dalam kedua aspek tersebut. Untuk parameter model, algoritma optimasi berfungsi sebagai mekanisme yang secara sistematis memperbarui nilai parameter agar fungsi kerugian semakin kecil. Pendekatan berbasis gradien (Gambar 3), seperti gradient descent pada Persamaan (1), dimana $\mathbf{W}$ adalah parameter model, η adalah *learning rate*, $\nabla \text{Loss}(\mathbf{W}^{(k)})$ adalah gradien dari *loss function*, dan $k = 1, 2, \dots, n$ adalah indeks iterasi. Pendekatan ini memanfaatkan informasi gradien untuk menentukan arah perubahan parameter yang paling efektif, sebagaimana diimplementasikan dalam metode backpropagation pada jaringan saraf [6]. Sementara itu, optimasi *hyperparameter* berfokus pada pencarian konfigurasi pengaturan yang menghasilkan kinerja terbaik. Karena ruang pencarian *hyperparameter* sering kali kompleks, berdimensi tinggi, dan gradien dari fungsi objektifnya tidak dapat dihitung secara eksak, metode optimasi tingkat lanjut, termasuk *grid search* [7], *random search* [8], optimasi Bayesian [9], maupun pendekatan metaheuristik [10] digunakan untuk menemukan kombinasi yang optimal secara efisien.

$$\mathbf{W}^{(k+1)} = \mathbf{W}^{(k)} - \eta \nabla \text{Loss}(\mathbf{W}^{(k)}) \quad (1)$$



Gambar 3. Ilustrasi pelatihan model pembelajaran mesin berbasis gradien.

Selain parameter dan *hyperparameter*, kualitas model pembelajaran mesin juga sangat dipengaruhi oleh fitur/variabel input yang digunakan sebagai representasi data. Banyaknya fitur yang tersedia dalam dataset belum tentu menjamin kinerja model menjadi lebih baik. Sebagian fitur dapat bersifat redundan, tidak relevan, atau saling berkorelasi tinggi, sehingga justru menambah noise, meningkatkan kompleksitas model, dan mendorong *overfitting* [11]. Oleh karena itu, pemilihan fitur menjadi tahap penting untuk mendapatkan fitur yang benar-benar informatif. Pemilihan fitur dapat dipandang sebagai masalah optimasi, karena


tujuannya adalah mencari subset fitur yang menghasilkan model dengan kinerja terbaik menurut fungsi objektif yang ditetapkan [12].

Dengan demikian, pembelajaran mesin modern dapat dipahami sebagai proses optimasi berlapis yang melibatkan penyesuaian parameter dan pemilihan *hyperparameter* serta pencarian subset fitur secara simultan. Perspektif ini membuka ruang bagi penggunaan metode optimasi yang lebih adaptif dan fleksibel, termasuk algoritma metaheuristik berbasis inspirasi alam seperti Grey Wolf Optimizer [13], yang dirancang untuk menavigasi ruang solusi yang kompleks dan membantu meningkatkan efektivitas proses pembelajaran mesin.


2. Belajar dari Alam: Grey Wolf Optimizer dan Strategi Berburu Serigala

Metaheuristik adalah strategi tingkat-atas untuk menyelesaikan masalah optimasi yang sulit, seperti ruang solusinya sangat besar, banyak jebakan optimum lokal, dan metode eksak terlalu mahal secara komputasi. Secara umum, masalah optimasi dapat dipahami sebagai upaya mencari nilai variabel keputusan (*decision variables*) yang membuat suatu fungsi objektif mencapai nilai terbaik, yaitu minimum atau maksimum, sesuai tujuan yang ditetapkan. Berbeda dari heuristik biasa yang sering spesifik untuk satu masalah, metaheuristik bersifat umum dan menyediakan kerangka pencarian yang dapat dipakai lintas masalah dengan cara mengatur kombinasi mekanisme eksplorasi (menjelajah banyak kemungkinan) dan eksploitasi (memperbaiki solusi yang sudah bagus). Karena itu metaheuristik dipakai ketika tujuan praktisnya adalah memperoleh solusi yang “sangat baik” dalam waktu wajar, meskipun tanpa jaminan selalu mencapai optimum global [14].

Grey Wolf Optimizer (GWO) adalah algoritma optimasi metaheuristik yang terinspirasi dari perilaku sosial dan strategi berburu serigala abu-abu (*Canis lupus*) di alam [13]. Serigala hidup dalam struktur sosial yang sangat terorganisir, dengan hirarki kepemimpinan yang jelas, yaitu serigala α sebagai pemimpin utama, β sebagai penasihat, δ sebagai pendukung, dan ω sebagai anggota lainnya, seperti pada Gambar 4 [15]. Inspirasi utama lainnya berasal dari cara serigala berburu secara berkelompok. Proses optimasi GWO mengikuti tiga tahap utama dalam strategi berburu serigala, yaitu mencari mangsa (*exploration*), mengepung mangsa (*encircling*), dan menyerang mangsa (*exploitation*), seperti pada Gambar 5 [16].




Gambar 4. Hirarki sosial serigala abu-abu.



Gambar 5. Setrategi berburu serigala abu-abu.

Dalam konteks optimasi, mangsa adalah solusi optimum yang dicari. Sedangkan struktur hirarki sosial serigala abu-abu dimodelkan secara matematis sedemikian rupa sehingga solusi terbaik (serigala yang paling dekat ke solusi optimum) dianggap sebagai α , solusi terbaik kedua dan ketiga sebagai β dan δ . Karena pada kondisi riil solusi optimal tidak diketahui posisi eksaknya, maka semua serigala bergerak mengikuti arah pergerakan serigala α , β , dan δ , seperti diilustrasikan pada Gambar 6. Pada tahap eksplorasi, serigala menyebar untuk menjelajahi ruang solusi secara luas agar tidak terjebak pada solusi lokal. Ketika kandidat solusi yang menjanjikan ditemukan, serigala mulai mengepung mangsa, yaitu memperbarui posisi berdasarkan estimasi lokasi terbaik yang dipandu oleh α , β , dan δ .



Gambar 6. Perubahan posisi serigala abu-abu dalam mencari solusi optimal.

Pergerakan serigala dalam GWO dimodelkan sebagai proses pembaruan posisi kandidat solusi di ruang pencarian. Untuk mensimulasikan perilaku mengepung mangsa, posisi setiap serigala diperbarui berdasarkan jaraknya terhadap

estimasi posisi mangsa. Misalkan $\vec{X}(t)$ adalah posisi serigala pada iterasi ke- t , dan $\vec{X}_p(t)$ adalah estimasi posisi mangsa (solusi terbaik yang diketahui saat itu), maka jarak antara serigala dan mangsa dihitung menggunakan Persamaan (2).

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (2)$$

Posisi baru serigala kemudian diperbarui menggunakan Persamaan (3) berikut.

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (3)$$

Dimana $\vec{A}$ dan $\vec{C}$ adalah vektor koefisien yang mengontrol dinamika eksplorasi dan eksploitasi, yang masing-masing didefinisikan seperti pada Persamaan (4) dan (5),

$$\vec{A} = 2a \cdot \vec{r}_1 - a \quad (4)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (5)$$

dengan $\vec{r}_1$ dan $\vec{r}_2$ adalah vektor acak dalam rentang $[0,1]$, dan a adalah parameter kontrol yang nilainya berkurang secara linear dari 2 menuju 0 sepanjang iterasi, seperti pada Persamaan (6),

$$a = 2 \left(1 - \frac{t}{T}\right) \quad (6)$$

dengan t adalah iterasi saat ini dan T adalah maksimum iterasi. Penurunan nilai a ini berfungsi untuk menggeser perilaku algoritma dari eksplorasi global menuju eksploitasi lokal seiring mendekatnya solusi ke optimum.

Berbeda dengan algoritma optimasi lain yang hanya mengikuti satu solusi terbaik, Grey Wolf Optimizer memanfaatkan tiga kandidat solusi terbaik sekaligus, yaitu α , β , dan δ . Posisi setiap serigala omega diperbarui berdasarkan kombinasi posisi ketiga pemimpin tersebut. Jarak terhadap masing-masing pemimpin dihitung menggunakan Persamaan (7)-(9),

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (7)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (8)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (9)$$

kemudian dihitung tiga estimasi posisi serigala menggunakan Persamaan (10)-(12),

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \quad (10)$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \quad (11)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (12)$$

dengan $\vec{A}_j$ dan $\vec{C}_j$, $j = \alpha, \beta, \delta$ adalah vektor koefisien yang masing didefinisikan seperti pada Persamaan (4) dan (5). Posisi baru serigala pada iterasi berikutnya dihitung sebagai rata-rata dari ketiga estimasi pada Persamaan (10)-(12) seperti pada persamaan (13).

$$\vec{X}(t + 1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (13)$$

Secara umum Langkah-langkah algoritma GWO adalah sebagai berikut:

1. Inisialisasi posisi serigala $\vec{X}_i, i = 1, 2, \dots, n$
2. Inisialisasi $a, \vec{A}$, dan $\vec{C}$
3. Hitung nilai fungsi objektif setiap serigala
4. Tentukan $\vec{X}_\alpha, \vec{X}_\beta, \vec{X}_\delta$ dari nilai fungsi objektif
5. Perbarui posisi semua serigala menggunakan Persamaan (13)
6. Perbarui $a, \vec{A}$, dan $\vec{C}$
7. Hitung nilai fungsi objektif setiap serigala
8. Tentukan $\vec{X}_\alpha, \vec{X}_\beta, \vec{X}_\delta$ dari nilai fungsi objektif
9. Ulangi langkah 5-8 sampai iterasi maksimum tercapai.

3. Evolusi Grey Wolf Optimizer: Adaptasi dan Pengembangan untuk Tantangan Modern

Perkembangan GWO tidak berhenti pada formulasi awalnya sebagai algoritma *swarm intelligence* yang terinspirasi perilaku berburu serigala abu-abu, tetapi terus mengalami evolusi untuk menjawab tantangan optimasi modern yang semakin kompleks, seperti ruang solusi berdimensi tinggi, fungsi objektif nonlinier, serta permasalahan multimodal dan multi objektif. Berbagai adaptasi dan pengembangan telah dilakukan untuk meningkatkan kemampuan eksplorasi global, mempercepat konvergensi, serta menjaga keseimbangan antara eksplorasi dan eksploitasi. Evolusi perkembangan GWO dilakukan melalui beberapa strategi yaitu integrasi mekanisme chaos, strategi parameter adaptif, hybridisasi dengan algoritma lain, dan modifikasi struktur populasi guna mengatasi keterbatasan versi dasar seperti risiko terjebak pada optimum lokal [17]. Beberapa modifikasi GWO yang diaplikasikan dalam pembelajaran mesin dirangkum pada Tabel 1.

Tabel 1. Rangkuman beberapa modifikasi GWO yang diaplikasikan dalam pembelajaran mesin.

Varian	Tujuan modifikasi	Ide modifikasi utama
RW-GWO	Meningkatkan eksplorasi dan mengurangi risiko konvergensi prematur.	- Menambahkan random walk pada serigala pemimpin agar dapat bergerak acak namun terarah. - Serigala lain tetap mengikuti pemimpin seperti pada GWO standar.
MGWO	Memperkaya diversitas populasi sehingga pencarian tidak mudah terjebak pada optimum lokal.	- Menginjeksikan <i>chaotic map (logistic)</i> ke koefisien pengendali gerak $\vec{A}$ dan $\vec{C}$. - Menambahkan operator mutasi Differential Evolution (DE) untuk membangkitkan kandidat solusi yang lebih eksploratif.
EN-GWO	Menyeimbangkan eksplorasi–eksploitasi secara lebih efektif dan memperkaya pencarian lokal.	- Mengganti penurunan linier parameter a menjadi penurunan nonlinier. - Menambahkan <i>neighborhood-based learning</i>: membangkitkan kandidat tetangga dan menyeleksi solusi terbaik antara hasil GWO dan hasil kandidat tetangga.
MIGWO	Meningkatkan kualitas pembaruan posisi dan memperkuat eksplorasi global.	- Pembaruan posisi dibuat berbobot dinamis berdasarkan nilai fungsi objektif dan kemajuan antargenerasi. - Eksplorasi diperkuat melalui hibridisasi dengan DE/best/2/bin dan lompatan Levy pada serigala pemimpin untuk mengurangi jebakan optimum lokal.
GJO–GWO	Menggabungkan konvergensi cepat GJO dengan eksplorasi GWO agar tidak terjebak optimum lokal.	- Memasukkan struktur hierarki dan peran serigala α ke dalam dinamika GJO. - Pembaruan populasi menjadi fungsi nonlinier dari tiga posisi utama (jaket jantan, jaket betina, serigala α) menggunakan interpolasi Lagrange tiga titik.
GWO–GOA	Menjaga keseimbangan eksplorasi–eksploitasi dan mengurangi jebakan lokal.	- Menggabungkan eksploitasi terarah GWO (mengikuti pemimpin) dengan dinamika kawanan GOA. - Pembaruan posisi memadukan arahan dua pemimpin (α dan β), lalu ditambah operator <i>crossover</i> dan <i>mutation</i> untuk meningkatkan keragaman populasi.

3.1. Random Walk Grey Wolf Optimizer

Random Walk Grey Wolf Optimizer (RW-GWO) [18] merupakan pengembangan dari GWO yang bertujuan meningkatkan kemampuan eksplorasi dan mengurangi risiko konvergensi prematur dengan memodifikasi mekanisme pergerakan serigala pemimpin. Pada GWO standar, semua serigala memperbarui posisi mengikuti serigala serigala α , β dan δ , termasuk posisi serigala α juga mengikuti serigala β dan δ serta serigala β mengikuti serigala δ . Hal ini berpotensi membatasi kemampuan algoritma dalam menemukan solusi global. RW-GWO mengatasi hal ini dengan menambahkan mekanisme random walk pada para pemimpin, sehingga mereka dapat bergerak secara acak namun terarah untuk menjelajahi ruang solusi secara lebih luas. Setelah posisi pemimpin diperbarui

melalui random walk, serigala lain tetap mengikuti pemimpin sebagaimana pada GWO standar. Secara matematis, random walk didefinisikan sebagai akumulasi langkah acak seperti pada Persamaan (14),

$$W_N = \sum_{i=1}^N s_i \quad (14)$$

dengan s_i adalah ukuran langkah yang dibangkitkan secara random dari distribusi Cauchy untuk memungkinkan lompatan sesekali yang membantu keluar dari jebakan optimum lokal tanpa menambah jumlah evaluasi fungsi objektif. Pembaruan posisi pemimpin dilakukan menggunakan mekanisme random walk seperti pada Persamaan (15),

$$\vec{X}_j(t+1) = \vec{X}_j(0) + \sum_{i=1}^N \alpha_i s_i \quad (15)$$

dengan $\alpha_i > 0$ mengontrol ukuran langkah yang dibuat menurun secara linier dari 2 ke 0 sepanjang iterasi agar terjadi transisi eksplorasi ke eksploitasi.

3.2. Modified Grey Wolf Optimizer

Modified Grey Wolf Optimizer (MGWO) [19] merupakan modifikasi GWO untuk meningkatkan kinerjanya dengan dua mekanisme utama, yaitu memasukkan *chaotic map (logistic)* ke koefisien pengendali gerak dan menambahkan mutasi berbasis *Differential Evolution* (DE). Modifikasi ini akan memperkaya diversitas populasi sehingga pencarian tidak mudah terjebak pada optimum lokal. Ide utamanya, koefisien pengendali pergerakan serigala pada GWO, yaitu $\vec{A}$ dan $\vec{C}$, tidak lagi hanya bergantung pada vektor acak biasa $\vec{r}_1$ dan $\vec{r}_2$, tetapi diganggu oleh variabel chaos $y(t)$ sehingga lintasan pencarian menjadi deterministik namun sulit diprediksi sehingga lebih beragam dan tidak mudah macet di optimum lokal. Secara matematis, koefisien dimodifikasi dengan mengalikan komponen acak $\vec{r}_1$ dan $\vec{r}_2$ dengan variabel chaos $y(t)$, seperti pada Persamaan (16)-(18),

$$\vec{A} = 2a \cdot \vec{r}_1 y(t) - a \quad (16)$$

$$\vec{C} = 2 \cdot \vec{r}_2 y(t) \quad (17)$$

$$y(t) = ry(t-1)(1-y(t-1)) \quad (18)$$

di mana $y(t)$ adalah variabel chaos pada iterasi ke- t , dengan $y(t) \in (0,1)$, dan r adalah parameter kontrol yang biasanya diset nilainya dengan 4 untuk memastikan tingkat chaos maksimum. Umumnya, $y(t-1)$ diinisialisasi dengan nilai acak pada rentang 0,0001 hingga 0,9999. Selain itu, nilai $y(t-1)$ dihindari menggunakan 0,25, 0,5, dan 0,75 karena nilai-nilai tersebut dapat menghasilkan pola yang tidak *chaotic* ketika dikombinasikan dengan parameter r .

Selain itu, MGWO juga menambahkan operator mutasi DE untuk membangkitkan kandidat solusi baru yang lebih eksploratif. Strategi mutasi DE umumnya didefinisikan seperti pada Persamaan (19),

$$\mathbf{v} = \mathbf{z}_{r1} + F(\mathbf{z}_{r2} - \mathbf{z}_{r3}) \quad (19)$$

dimana $\mathbf{z}_{r1}, \mathbf{z}_{r2}, \mathbf{z}_{r3}$ adalah vektor random dalam populasi dan $F \in [0,2]$ adalah faktor yang mengontrol variasi diferensial. $(\mathbf{z}_{r2} - \mathbf{z}_{r3})$. Dalam MGWO strategi mutasi yang digunakan adalah DE/best/1, seperti didefinisikan pada Persamaan (20), untuk membangkitkan mutasi serigala.

$$\mathbf{v} = \mathbf{z}_{best} + F(\mathbf{z}_{r2} - \mathbf{z}_{r3}) \quad (20)$$

Dimana, $\mathbf{z}_{best}$ adalah serigala yang paling dekat dengan solusi optimum, sedangkan $\mathbf{z}_{r2}$ dan $\mathbf{z}_{r3}$ serigala yang dipilih secara random dari kawanan.

3.3. Exponential Neighborhood Grey Wolf Optimizer

Exponential Neighborhood Grey Wolf Optimizer (EN-GWO) [20] memodifikasi GWO melalui dua mekanisme utama, yaitu pengaturan ulang dinamika eksplorasi–eksploitasi dengan mengganti penurunan linier parameter adaptif a menjadi penurunan nonlinier sehingga porsi eksplorasi dan eksploitasi tidak lagi seimbang dan penambahan strategi pencarian berbasis tetangga (*neighborhood-based learning*) yang menggabungkan perilaku perburuan local (individual) dan global. Secara matematis, modifikasi pertama dinyatakan dengan pembaruan a seperti pada Persamaan (21),

$$a = 2 \left(1 - \frac{t^2}{T^2} \right) \quad (21)$$

dengan t adalah iterasi saat ini dan T adalah maksimum iterasi. Modifikasi kedua dimulai dengan menghitung kandidat posisi hasil GWO $X_{i,GWO}(t)$, kemudian menghitung radius menggunakan jarak Euclidean antara posisi saat ini $X_i(t)$ dengan $X_{i,GWO}(t)$ seperti pada Persamaan (22).

$$R_i(t) = \| X_i(t) - X_{i,GWO}(t) \| \quad (22)$$

Berdasarkan radius $R_i(t)$, kemudian didefinisikan tetangga dari $X_i(t)$, seperti pada Persamaan (23).

$$N_i(t) = \{X_j(t) \mid D(X_j(t), X_i(t)) \leq R_i(t)\} \quad (23)$$

Selanjutnya, dikonstruksi kandidat baru berbasis tetangga, seperti pada Persamaan (24),

$$X_{NL}(t) = X_i(t) + rand \times (X_n(t) - X_r(t)) \quad (24)$$

dengan $X_n(t)$ tetangga yang dipilih acak dari $N_i(t)$ dan $X_r(t)$ serigala yang dipilih acak dari populasi. Terakhir, dilakukan seleksi serigala terbaik untuk iterasi berikutnya, seperti pada Persamaan (25).

$$X_i(t+1) = \begin{cases} X_{i,GWO}(t), & \text{jika } f(X_{i,GWO}) > f(X_{NL}) \\ X_{NL}(t), & \text{untuk yang lainnya} \end{cases} \quad (25)$$

3.4. Multi-strategy Improved Grey Wolf Optimizer

Multi-strategy Improved Grey Wolf Optimizer (MIGWO) [21] memodifikasi GWO standar terutama pada strategi pembaruan posisi serigala serta penguatan eksplorasi global. Pada pembaruan posisi, MIGWO tidak merata-ratakan kontribusi serigala pemimpin tetapi memberi bobot dinamis berdasarkan nilai fungsi objektif dan tingkat perbaikan nilai fungsi objektif antargenerasi sehingga serigala pemimpin yang lebih baik memberi pengaruh lebih besar. Posisi baru dihitung sebagai kombinasi berbobot dari tiga kandidat $\vec{X}_1, \vec{X}_2, \vec{X}_3$ seperti pada Persamaan (26).

$$\vec{X}(t+1) = w_1 \vec{X}_1 + w_2 \vec{X}_2 + w_3 \vec{X}_3 \quad (26)$$

Penguatan eksplorasi global dilakukan melalui hibridisasi dengan *Differential Evolution* (DE) serta lompatan *Levy* pada serigala pemimpin untuk mengurangi risiko terjebak pada optimum lokal. Strategi mutasi DE/best/2/bin diterapkan untuk menghasilkan kandidat mutasi di sekitar solusi terbaik $\vec{X}_\alpha$ seperti pada Persamaan (27),

$$\vec{v}_i = \vec{X}_\alpha + F(\vec{X}_{r1} - \vec{X}_{r2}) + F(\vec{X}_{r3} - \vec{X}_{r4}) \quad (27)$$

dengan $\vec{X}_{r1}$ dan $\vec{X}_{r3}$ dipilih dari serigala β dan δ , $\vec{X}_{r2}$ dan $\vec{X}_{r4}$ dipilih dari serigala omega. Untuk mempertahankan lebih banyak informasi asli mengenai lokasi mangsa oleh serigala α , informasi dari $\vec{X}_\alpha$ diintegrasikan ke dalam $\vec{v}_i$ menggunakan operasi *crossover*. Selanjutnya untuk meningkatkan peluang keluar dari jebakan optimum lokal, serigala pemimpin diberi mekanisme *Levy-flight* dengan probabilitas p_l , seperti pada Persamaan (28),

$$\vec{X}_{i,baru}[j] = \begin{cases} \vec{X}_i[j] \times Levy(\theta), & rand < p_l, i \in \{\alpha, \beta, \delta\} \\ \vec{X}_i[j], & \text{untuk yang lain} \end{cases} \quad (28)$$

dengan $Levy(\theta)$ adalah langkah acak yang mengikuti distribusi Levy.

3.5. Hibrida Golden Jackal Optimizer dengan Grey Wolf Optimizer

Golden Jackal Optimizer (GJO) [22] adalah algoritma optimasi metaheuristik yang memodelkan perilaku sepasang jakal emas (*Canis aureus*), jantan dan betina, saat berburu mangsa. Hibrida GJO–GWO [23] menggabungkan kekuatan GJO yang cepat konvergen dengan strategi pencarian GWO, khususnya memasukkan struktur hierarki dan peran serigala α untuk memperkuat kemampuan eksplorasi agar tidak mudah terjebak optimum lokal. Pada fase iterasi akhir, kerjasama antara serigala α , jakal jantan, dan jakal betina diklaim mampu mempercepat pembaruan populasi sehingga konvergensi menuju optimum global lebih cepat tercapai.

Secara konseptual, perubahan penting dalam hibrida GJO-GWO adalah persamaan pembaruan populasi GJO yang semula merata-ratakan kontribusi jakal jantan dan jakal betina menjadi suatu fungsi nonlinier dari tiga posisi utama, yaitu posisi jakal jantan $Y_1(t)$, posisi jakal betina $Y_2(t)$, dan dan posisi serigala α $Y_3(t)$. Untuk memastikan ketiganya benar-benar berinteraksi dan tetap konvergen, metode ini menggunakan interpolasi Lagrange tiga titik sebagai persamaan pembaruan populasi baru $Y(t + 1)$ sebagai kombinasi dari $Y_1(t), Y_2(t), Y_3(t)$, seperti pada Persamaan (29).

$$Y(t + 1) = \sum_{i=1}^3 \frac{Y_i(t)}{3} \prod_{\substack{j=1 \\ j \neq i}}^3 \frac{Y(t) - Y_j(t)}{Y_i(t) - Y_j(t)} \quad (29)$$

3.6. Hibrida Gray Wolf Optimizer dengan Grasshopper Optimization Algorithm

Grasshopper Optimization Algorithm (GOA) [24] adalah algoritma optimasi metaheuristik yang meniru perilaku kawanan belalang, yaitu interaksi sosial saat bergerak, untuk menyeimbangkan eksplorasi dan eksploitasi dalam pencarian solusi. Hibrida GWO–GOA [25] menggabungkan kekuatan eksploitasi terarah dari GWO yang mengikuti pergerakan serigala pemimpin dengan karakter eksploratif GOA yang berupa dinamika kawanan untuk memperluas pencarian. Penggabungan ini menjadikan proses optimasi tidak cepat terkunci pada solusi lokal dan keseimbangan eksplorasi–eksploitasi menjadi lebih baik. Salah satu modifikasi kunci yang digunakan adalah pembaruan posisi serigala yang memadukan arahan dua pemimpin yaitu serigala α dan β dengan rata-rata pergeseran dari posisi saat ini, seperti pada Persamaan (30).

$$R(t + 1) = R + f_1 \cdot rand \cdot \frac{(R_\alpha - R) + (R_\beta - R)}{2} \quad (30)$$

Sedangkan pembaruan posisi serigala α dan β hanya ditentukan oleh serigala α , seperti pada Persamaan (31).

$$R(t + 1) = R + f_1 \cdot rand \cdot (R_\alpha - R) \quad (31)$$

Selain itu, untuk meningkatkan keragaman populasi dan menekan konvergensi prematur, setelah pembaruan posisi disisipkan operator *crossover* dan *mutation*.

4. Dari Inspirasi ke Implementasi: Peran GWO dalam Pembelajaran Mesin Modern

4.1. Mencari Kombinasi Terbaik: Optimasi Hyperparameter dengan GWO

Untuk menentukan kombinasi *hyperparameter* terbaik dari sebuah model pembelajaran mesin, GWO bekerja dengan gagasan sederhana namun sangat kuat yaitu serigala bukan lagi seekor hewan tapi berupa vektor dengan komponen *hyperparameter* dari model pembelajaran mesin. Sehingga posisi $\vec{X}(t)$ pada algoritma GWO bukanlah koordinat fisik tetapi merupakan koordinat di ruang pencarian *hyperparameter*. Secara umum tahapan dalam optimasi *hyperparameter* menggunakan GWO adalah pengodean *hyperparameter* menjadi vektor, insialisasi populasi, evaluasi nilai fungsi objektif, dan pembaruan posisi serigala menggunakan GWO sampai maksimum iterasi tercapai [26].

Proses pengodean *hyperparameter* adalah mengubah *hyperparameter* menjadi vektor posisi $\vec{X}(t)$. Sebagai contoh pada optimasi hyperparameter Support Vector Machine (SVM), vektor posisi $\vec{X}(t)$ berisi koefisien regularisasi C , koefisien kernel γ , jenis kernel K , atau orde kernel polinomial r . Jika sebelum klasifikasi terdapat tahap pemilihan fitur atau pengurangan dimensi maka parameter dari tahap tersebut juga dapat dioptimasi menggunakan GWO [10], [27], [28]. Selain *hyperparameter* model SVM, GWO juga diaplikasikan untuk mengoptimasi *hyperparameter* dari model *deep learning* seperti model *Convolutional Neural Network* (CNN). Untuk model CNN vektor posisi $\vec{X}(t)$ dapat berisi jumlah lapisan konvolusi, jumlah filter, ukuran kernel, ukuran pooling, *dropout rate*, maupun *learning rate* [19], [20], [26].

Dalam optimasi hyperparameter berbasis GWO, fungsi objektif adalah fungsi yang digunakan untuk menilai kualitas tiap kandidat *hyperparameter* (posisi serigala). Evaluasi fungsi objektif pada optimasi hyperparameter berbasis GWO dilakukan dengan mengaitkan setiap posisi serigala sebagai satu konfigurasi *hyperparameter* terhadap kinerja model pada data yang terpisah. Pertama, dataset dibagi menjadi data latih dan data uji. Selanjutnya, untuk setiap serigala, nilai-nilai pada vektor posisinya diinterpretasikan sebagai hyperparameter model, kemudian model dilatih menggunakan data latih dengan konfigurasi hyperparameter tersebut sehingga diperoleh model terlatih. Setelah itu, model dievaluasi menggunakan data uji untuk menghitung nilai fungsi objektif.

Pada tugas klasifikasi, beberapa peneliti menggunakan *akurasi* model, seperti pada Persamaan (32), sebagai fungsi objektif yang dimaksimumkan [26], [28]. Karena banyak implementasi GWO dirumuskan sebagai masalah minimisasi, akurasi sering ditransformasikan menjadi bentuk ekuivalen seperti $1 - \text{akurasi}$ [10] atau $-\text{akurasi}$ [27] sebagai fungsi objektif. Selain akurasi, *cross entropy* pada Persamaan (33), juga digunakan sebagai fungsi objektif yang diminimumkan pada optimasi hyperparameter model CNN [19]. Pada optimasi *hyperparameter Fully Convolution Encoder Decoder Network* (FCEDN) untuk segmentasi citra [20], *Jaccard coefficient* pada Persamaan (34) yang dimaksimumkan digunakan sebagai

fungsi objektif karena lebih representatif daripada akurasi pada segmentasi piksel. Rangkuman aplikasi GWO untuk optimasi hyperparameter model pembelajaran mesin dapat dilihat pada Tabel 2.

$$Akurasi = \frac{\text{Banyaknya data yang tepat diklasifikasikan}}{\text{Banyaknya data uji}} \quad (32)$$

$$Cross\ entrpy = - \sum_{i=1}^N y_i \log p_i \quad (33)$$

$$J = \frac{1}{N} \sum_{i=1}^N \frac{\varepsilon + \sum_{i=1}^r \sum_{j=1}^c y(i,j) \hat{y}(i,j)}{\varepsilon + \sum_{i=1}^r \sum_{j=1}^c y(i,j) + \sum_{i=1}^r \sum_{j=1}^c \hat{y}(i,j) - \sum_{i=1}^r \sum_{j=1}^c y(i,j) \hat{y}(i,j)} \quad (34)$$

Tabel 2. Rangkuman aplikasi GWO untuk optimasi hyperparameter model pembelajaran Mesin

Tugas	Varian GWO	Model	Hyperparameter	Fungsi Objectif
Klasifikasi citra buah [10]	GWO standar	SVM	ambang untuk <i>variant threshold feature selection</i> , koefisien regularisasi, koefisien kernel	$1 - akurasi$
Deteksi kecacatan perangkat lunak [27]	RW-GWO	SVM	jumlah komponen PCA, koefisien regularisasi, koefisien kernel, kernel	$-akurasi$
Deteksi kerusakan <i>Wheelset Bearings</i> [28]	GWO standar	SVM	koefisien regularisasi, koefisien kernel, orde kernel polinomial	$akurasi$
Deteksi kanker cervic [19]	MGWO	CNN	jumlah filter, ukuran kernel, <i>dropout rate</i> , <i>learning rate</i>	$cross\ entropy$
Deteksi kanker kulit [26]	GWO standar	CNN	jumlah lapisan konvolusi, jumlah filter, ukuran kernel, ukuran pooling, <i>dropout rate</i>	$akurasi$
Segmentasi citra kanker kulit [20]	EN-GWO	FCED N	jumlah filter, ukuran kernel, <i>dropout rate</i>	$Jaccard\ coefficient$

4.2. Memilih yang Penting: GWO untuk Seleksi Fitur untuk Model yang Lebih Efisien

Berbeda dari optimasi *hyperparameter* dimana setiap posisi serigala terdiri dari *hyperparameter* model, pada pemilihan fitur (*feature selection*) setiap serigala pada GWO direpresentasikan sebagai vektor kandidat subset fitur. Jika pada dataset terdapat N fitur, maka ruang pencariannya bersifat kombinatorial dengan 2^N kemungkinan subset . Karena itu, posisi serigala bukan koordinat fisik, melainkan

koordinat di ruang solusi subset fitur, yang berupa vektor biner dengan N komponen, $x = (x_1, x_2, \dots, x_N), x_i \in \{0,1\}$. Secara umum tahapan dalam seleksi fitur menggunakan GWO mirip dengan tahapan dalam optimasi *hyperparameter*, yaitu insialisasi populasi, evaluasi nilai fungsi objektif, dan pembaruan posisi serigala menggunakan GWO sampai maksimum iterasi tercapai. Bedanya adalah populasi serigala yang umumnya berupa vektor dengan komponen bilangan riil perlu ditransformasi terlebih dahulu menjadi vektor biner menggunakan sebuah fungsi transfer tertentu [29].

Evaluasi fungsi objektif pada pemilihan fitur berbasis GWO dilakukan melalui prosedur *wrapper* yang mengaitkan setiap posisi serigala dengan kinerja model klasifikasi. Pertama, posisi serigala yang semula bernilai kontinu ditransformasikan menjadi vektor biner menggunakan fungsi transfer yang ditetapkan sehingga diperoleh representasi subset fitur. Beberapa fungsi transfer yang umum digunakan adalah fungsi sigmoid [21], [29], [30] dan fungsi undak [23], [25], masing-masing seperti pada Persamaan (35) dan (36). Selanjutnya, jika komponen ke- i pada vektor biner bernilai 1 maka fitur ke- i dimasukkan ke dalam subset fitur terpilih, sedangkan jika bernilai 0 maka fitur tersebut dibuang. Setelah subset fitur terpilih terbentuk, dataset dibagi menjadi data latih dan data uji (misalnya 60:40 atau 70:30 sesuai rancangan eksperimen). Model klasifikasi kemudian dilatih menggunakan data latih yang hanya memuat fitur-fitur terpilih, dan kinerjanya dievaluasi pada data uji yang juga direduksi dengan subset fitur yang sama.

$$f(x) = \frac{1}{1 + e^{10(x-0.5)}} \quad (35)$$

$$f(x) = \begin{cases} 1, & x > 0.5 \\ 0, & x \leq 0.5 \end{cases} \quad (36)$$

Nilai fungsi objektif dihitung dari hasil evaluasi model klasifikasi, umumnya berupa akurasi yang dimaksimumkan [29] atau bentuk ekuivalennya seperti $1 - akurasi$ yang diminimumkan [30]. Pada beberapa penelitian, fungsi multi objektif yang menyeimbangkan antara akurasi dan banyaknya fitur terpilih juga digunakan untuk mengevaluasi posisi serigala (dalam hal ini fitur terpilih) seperti pada Persamaan (37) [21], [23],

$$f = (1 - \lambda) \frac{n}{N} + \lambda(1 - akurasi) \quad (37)$$

dengan n dan N masing-masing adalah jumlah fitur terpilih dan jumlah semua fitur serta λ adalah bilangan riil positif kurang dari 1. Pada seleksi fitur untuk data teks [25], fungsi objektif yang digunakan adalah *mean absolute different* (MAD) seperti pada Persamaan (38),

$$MAD = \frac{1}{Sf_i} \sum_{k=1}^j |m_{ik} - \overline{m}_l|, \quad \overline{m}_l = \frac{1}{Sf_i} \sum_{k=1}^j m_{ik} \quad (38)$$

dengan Sf_i adalah jumlah fitur terpilih pada dokumen i , m_{ik} adalah bobot fitur k pada dokumen i , dan j adalah pada dokumen asal. Rangkuman aplikasi GWO untuk pemilihan fitur dapat dilihat pada Tabel 3.

Tabel 3. Rangkuman aplikasi GWO untuk pemilihan fitur

Varian GWO	Model	Fungsi Transfer	Fungsi Objectif
GWO [29]	KNN	Sigmoid	<i>akurasi</i>
GWO [30]		Sigmoid	$1 - akurasi$
MIGWO [21]	KNN	Sigmoid	$(1 - \lambda) \frac{n}{N} + \lambda(1 - akurasi)$
GJO-GWO [23]	KNN	Fungsi undak	$(1 - \lambda) \frac{n}{N} + \lambda(1 - akurasi)$
GWO-GOA [25]	Fuzzy c-means	Fungsi undak	<i>mean absolute difference</i>

5. Kesimpulan

Pembelajaran mesin adalah cabang kecerdasan artifisial yang membuat komputer belajar dari data untuk mengenali pola dan menghasilkan prediksi pada data baru. Proses belajar ini bertumpu pada optimasi untuk memperbarui parameter model pada saat pelatihan agar kinerja model meningkat. Selain itu, optimasi juga diperlukan untuk *hyperparameter*, yaitu pengaturan yang ditetapkan sebelum proses pelatihan dan sangat menentukan stabilitas proses belajar serta kemampuan generalisasi model. Masalah optimasi juga berkaitan dengan pemilihan fitur. Dalam pembelajaran mesin, fitur yang banyak dalam dataset tidak menjamin kinerja model menjadi baik. Fitur redundan atau tidak relevan dapat meningkatkan kompleksitas model dan menurunkan kinerjanya. Sehingga diperlukan metode optimasi untuk mencari subset fitur yang paling informatif agar model mencapai kinerja terbaik. Grey Wolf Optimizer (GWO) adalah algoritma optimasi metaheuristik yang meniru perilaku sosial dan strategi berburu serigala abu abu. Dalam GWO, solusi tiga terbaik diperlakukan sebagai pemimpin, yaitu serigala α , diikuti β dan δ . Ketiga serigala tersebut digunakan untuk memandu pergerakan populasi sehingga terjadi keseimbangan antara eksplorasi ruang solusi dan eksploitasi solusi yang menjanjikan. Berbagai variasi GWO dikembangkan untuk memperkuat eksplorasi, mempercepat konvergensi, dan mengurangi risiko terjebak pada optimum lokal. Variasi tersebut misalnya melalui random walk pada pemimpin, pemanfaatan chaos dan mutasi berbasis *Differential Evolution*, penggunaan parameter nonlinier, pembelajaran berbasis tetangga, pembaruan berbobot, *Levy flight*, serta hibridisasi dengan algoritma lain.

Dalam pembelajaran mesin, GWO banyak dimanfaatkan untuk optimasi *hyperparameter* karena setiap posisi serigala dapat merepresentasikan satu kombinasi *hyperparameter* yang dievaluasi melalui proses pelatihan menggunakan data latih diikuti dengan penentuan nilai fungsi objektif menggunakan data uji. GWO juga digunakan untuk seleksi fitur karena serigala dapat merepresentasikan subset fitur, kemudian subset tersebut dinilai berdasarkan kinerja model sehingga diperoleh fitur yang lebih ringkas tanpa mengorbankan kinerja model. Dengan cara ini, GWO dan variasinya membantu membangun model yang lebih efisien, stabil, dan memiliki generalisasi yang lebih baik.

Daftar Pustaka

- [1] A. L. Samuel, "Some studies in machine learning using the game of checkers," *IBM J. Res. Dev.*, vol. 3, no. 3, pp. 210–229, 1959.
- [2] Tom M. Mitchell, *Machine Learning*. Redmond, WA: McGraw-Hill, 1997.
- [3] C. M. Bishop, *Pattern recognition and Machine Learning*, 1st ed. New York, NY: Springer, 2006.
- [4] T. Hastie, R. Tibshirani, and J. Friedman, *The elements of statistical learning* New York, 2nd ed. New York, N.Y: Springer New York, 2009.
- [5] K. P. Murphy, *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [6] S. Santra, J.-W. Hsieh, and C.-F. Lin, "Gradient descent effects on differential neural architecture search: A survey," *IEEE Access*, vol. 9, pp. 89602–89618, 2021.
- [7] H. Larochelle, D. Erhan, A. Courville, J. Bergstra, and Y. Bengio, "An empirical evaluation of deep architectures on problems with many factors of variation," in *Proceedings of the 24th international conference on Machine learning*, 2007, pp. 473–480.
- [8] J. Bergstra and Y. Bengio, "Random search for hyper-parameter optimization," *J. Mach. Learn. Res.*, vol. 13, no. 1, pp. 281–305, 2012.
- [9] J. Snoek, H. Larochelle, and R. P. Adams, "Practical bayesian optimization of machine learning algorithms," *Adv. Neural Inf. Process. Syst.*, vol. 25, 2012.
- [10] J. Siswantoro, "Enhanced Support Vector Machine Based on Grey Wolf Optimizer for Fruits Image Classification using MPEG-7 Color and Texture Features Fusion," *Int. J. Intell. Eng. Syst.*, vol. 17, no. 3, pp. 1–11, 2024.
- [11] J. Siswantoro, H. Arwoko, and M. Widiastri, "Indonesian fruits classification from image using MPEG-7 descriptors and ensemble of simple classifiers," *J. Food Process Eng.*, vol. 43, no. 7, pp. 1–13, 2020, doi: 10.1111/jfpe.13414.
- [12] J. N. Wijaya and J. Siswantoro, "Systematic Literature Review of Hybrid Metaheuristic Algorithms for Feature Selection in Classification Tasks," in *2025 International Conference on Information Management and Technology (ICIMTech)*, 2025, pp. 103–108.
- [13] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey wolf optimizer," *Adv. Eng. Softw.*, vol. 69, pp. 46–61, 2014.
- [14] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," *ACM Comput. Surv.*, vol. 35, no. 3, pp. 268–308, 2003.
- [15] L. D. Mech, "Alpha status, dominance, and division of labor in wolf packs," *Can. J. Zool.*, vol. 77, no. 8, pp. 1196–1203, 1999.
- [16] C. Muro, R. Escobedo, L. Spector, and R. P. Coppinger, "Wolf-pack (*Canis lupus*) hunting strategies emerge from simple rules in computational simulations," *Behav. Processes*, vol. 88, no. 3, pp. 192–197, 2011.
- [17] S. N. Makhadmeh *et al.*, "Recent advances in Grey Wolf Optimizer, its versions and applications," *Ieee Access*, vol. 12, pp. 22991–23028, 2023.

- [18] S. Gupta and K. Deep, "A novel Random Walk Grey Wolf Optimizer," *Swarm Evol. Comput.*, vol. 44, pp. 101–112, 2019, doi: <https://doi.org/10.1016/j.swevo.2018.01.001>.
- [19] S. Jain, A. Jain, and M. Jangid, "MGWO-CNN: hyperparameter optimization of CNN classifier for cervical cancer detection using Modified Grey Wolf Optimizer," *Sci. Rep.*, 2025.
- [20] R. Mohakud and R. Dash, "Skin cancer image segmentation utilizing a novel EN-GWO based hyper-parameter optimized FCEDN," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 10, Part B, pp. 9889–9904, 2022, doi: <https://doi.org/10.1016/j.jksuci.2021.12.018>.
- [21] J. Huang, X. Deng, and L. Hu, "Enhanced grey wolf optimizer with hybrid strategies for efficient feature selection in high-dimensional data," *Inf. Sci. (Ny)*, vol. 705, p. 121958, 2025, doi: <https://doi.org/10.1016/j.ins.2025.121958>.
- [22] N. Chopra and M. Mohsin Ansari, "Golden jackal optimization: A novel nature-inspired optimizer for engineering applications," *Expert Syst. Appl.*, vol. 198, p. 116924, 2022, doi: <https://doi.org/10.1016/j.eswa.2022.116924>.
- [23] G. Liu, Z. Guo, W. Liu, F. Jiang, and E. Fu, "A feature selection method based on the Golden Jackal-Grey Wolf Hybrid Optimization Algorithm," *PLoS One*, vol. 19, no. 1, p. e0295579, Jan. 2024, [Online]. Available: <https://doi.org/10.1371/journal.pone.0295579>.
- [24] S. Z. Mirjalili, S. Mirjalili, S. Saremi, H. Faris, and I. Aljarah, "Grasshopper optimization algorithm for multi-objective optimization problems," *Appl. Intell.*, vol. 48, no. 4, pp. 805–820, 2018, doi: 10.1007/s10489-017-1019-8.
- [25] R. Purushothaman, S. P. Rajagopalan, and G. Dhandapani, "Hybridizing Gray Wolf Optimization (GWO) with Grasshopper Optimization Algorithm (GOA) for text feature selection and clustering," *Appl. Soft Comput.*, vol. 96, p. 106651, 2020, doi: <https://doi.org/10.1016/j.asoc.2020.106651>.
- [26] R. Mohakud and R. Dash, "Designing a grey wolf optimization based hyper-parameter optimized convolutional neural network classifier for skin cancer detection," *J. King Saud Univ. Inf. Sci.*, vol. 34, no. 8, pp. 6280–6291, 2022.
- [27] M. Z. F. N. Siswantoro, S. Rochimah, and D. Sunaryono, "Software Defect Detection Using Optimized Support Vector Machine Based on Grey Wolf Optimizer with Random Walk," in *2024 4th International Conference of Science and Information Technology in Smart Administration (ICSINTESA)*, 2024, pp. 390–395.
- [28] T. Wang, H. Meng, F. Zhang, and R. Qin, "Fault Detection of Wheelset Bearings through Vibration-Sound Fusion Data Based on Grey Wolf Optimizer and Support Vector Machine," *Technologies*, vol. 12, no. 9, p. 144, 2024.
- [29] I. Shahin, O. A. Alomari, A. B. Nassif, I. Afyouni, I. A. Hashem, and A. Elnagar, "An efficient feature selection method for arabic and english speech emotion recognition using Grey Wolf Optimizer," *Appl. Acoust.*, vol. 205, p. 109279, 2023, doi: <https://doi.org/10.1016/j.apacoust.2023.109279>.
- [30] H. Asemi and N. Farajzadeh, "Improving EEG signal-based emotion recognition using a hybrid GWO-XGBoost feature selection method,"

Biomed. Signal Process. Control, vol. 99, p. 106795, 2025, doi:
<https://doi.org/10.1016/j.bspc.2024.106795>.

Ucapan Terima Kasih

Hadirin yang saya hormati, sebelum saya mengakhiri pidato ini, saya juga ingin mengucapkan terima kasih pada semua pihak yang telah berjasa dalam perjalanan hidup saya. Mereka yang telah memberikan fasilitas, layanan, semangat, inspirasi, kerjasama, dukungan, dan bantuan sehingga saya berada pada titik ini, yaitu:

1. Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia serta Lembaga Layanan Pendidikan Tinggi Wilayah VII Jawa Timur atas fasilitas dan layanan yang telah diberikan dalam perjalanan karir saya sebagai dosen hingga memperoleh JAD Profesor di Fakultas Teknik Universitas Surabaya.
2. Pembina, Pengawas, Ketua Umum, dan Pengurus Yayasan Universitas Surabaya; Rektor dan Para Wakil Rektor serta Ketua Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Surabaya; dan Ketua, Sekretaris dan Anggota Senat Universitas Surabaya atas dukungan dan semangat yang diberikan kepada saya dalam proses pengusulan jabatan Profesor.
3. Dekan dan Wakil Dekan Fakultas Teknik; Ketua, Sekretaris, dan Anggota Senat Fakultas Teknik; Manajer Administrasi Fakultas, Para Kaprodi Teknik Informatika terdahulu, Kaprodi Magister Informatika dan teman-teman dosen dan tendik di Prodi Teknik Informatika dan Prodi Magister Informatika Universitas Surabaya atas dukungan dan kerjasama yang diberikan.
4. Istri saya tercinta, Endah Saptawati, dan ketiga anak saya, Kakak Zain beserta istri, Mas Rizqi, dan Adik Ni'mah yang telah banyak berkorban untuk saya, serta medoakan dan mendukung karir saya.
5. Bapak dan Ibu di Lamongan, serta Alm. Bapak Mertua dan Ibu Mertua saya di Ketintang atas bimbingan, doa dan berbagai dukungan yang telah diberikan kepada saya.
6. Para Mantan Ketua Departem MIPA Universitas Surabaya beserta seluruh staf yang telah membantu saya selama berkarir di Universitas Surabaya.
7. Direktur, Manajer, dan Staf di semua Direktorat, khususnya Direktorat SDM Universitas Surabaya; Sekretaris, Manajer, dan staf LPPM Universitas Surabaya atas layanan dan bantuannya dalam mendukung proses pengusulan kenaikan jabatan akademik ini.
8. Guru-guru saya di SDN Karanglangit, SDN Laren 2, SDN Gedangan, SMPN 1 Lamongan, dan SMAN 2 Lamongan. Bapak dan Ibu dosen dan pembimbing saya pada saat menempuh pendidikan S1 di Jurusan Matematika Unair, S2 di Prodi Magister Matematika ITB, dan S3 di *Center For Artificial Intelligence Technology, Faculty of Information Science and Technology*, Universiti Kebangsaan Malaysia yang membentuk kemampuan akademik dan juga non akademik saya.
9. Teman-teman seperjuangan pada saat saya menempuh pendidikan S1, S2, dan S3.
10. Kolega-kolega dari Perguruan Tinggi lain dan Mitra dari Dunia Usaha dan Dunia Industri serta undangan lain yang telah berkenan untuk hadir pada acara ini.
11. Seluruh panitia acara pengukuhan profesor hari ini, yang tidak bisa saya

sebutkan satu persatu, yang telah membantu sehingga acara ini dapat berlangsung dengan baik.

Ijinkan saya menutup orasi ini dengan sebuah pantun berikut:

Serigala alpha memimpin kawanan,

Menjaga arah dalam rimba pencarian.

Dari alam kita belajar membangun kecerdasan mesin masa depan,

Terima kasih atas perhatian dan kebersamaan, mohon maaf atas segala kekurangan.

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

DAFTAR RIWAYAT HIDUP



A. Data Pribadi

Nama	: Prof. Dr. Joko Siswantoro, S.Si., M.Si., HCIA-AI., CADS.
Tempat/Tanggal Lahir	: Lamongan, 9 Desember 1974
Alamat Rumah	: Jl. Ketintang Baru Tengah 20, Surabaya
Jabatan Akademik	: Guru Besar 850
Bidang Keahlian	: Pembelajaran Mesin
NIP/NIDN/NUPTK	: 198032 / 0709127402 / 6541752653130103
Institusi	: Universitas Surabaya
Alamat Institusi/Telp	: Raya Kalirungkut, Surabaya, 031-2981150
Program Studi (Prodi)	: Informatika (S2)
Institusi	: Baik Sekali
SK Akreditasi Prodi	: 070/SK/LAM-INFOKOM/Ak.P/M/VIII/2025
Mata Kuliah yang Diampu	: <i>Algorithm and Programing, Object Oriented Programing, Digital Image Processing, Michine Learning, Deep Learning, Computer Vision</i>
Research Interest	: <i>Michine Learning, Deep Learning, Computer Vision</i>
ID. SINTA	: 5972761
ID. Scopus	: 56192714800
ID. Web of Science (WoS)	: AAG-3863-2020
Alamat e-mail	: joko_siswantoro@staff.ubaya.ac.id

B. Pendidikan Formal

Nama Lembaga	Tahun Lulus
Pendidikan Sarjana Sains Matematika (S.Si), Jurusan Matematika, FMIPA Universitas Airlangga, Surabaya	1997
Pendidikan Magister Sains Matematika (M.Si), Prodi Magister Matematika, FMIPA Institut Teknologi Bandung, Bandung	2002
Pendidikan Doctor of Philosophy (Ph.D.), Computer Science Center For Artificial Intelligence Technology, Faculty of Information Science and Technology, Universiti Kebangsaan Malaysia, Bangi, Malaysia	2016

C. Pendidikan Tambahan

Pelatihan/Penataran/Magang	Tahun
Certified Associate Data Scientist	2026
NVIDIA Instructor - Fundamentals of Deep Learning	2025
TensorFlow Developer Professional Certificate	2024
Huawei Certified ICT Associate – Artificial Intelligence	2024
Pelatihan Asesor Beban Kerja Dosen	2021

D. Jumlah Publikasi dan H-indeks

Jumlah artikel terindeks Scopus	:	35
H-indeks Scopus	:	14
Jumlah artikel terindeks WoS	:	20
H-indeks WoS	:	13
H-indeks Google Scholar	:	17
SINTA Score Overall	:	2.346

E. Publikasi Artikel di Jurnal Internasional

KC Febryanto, IA Androfaza, LA Wadagraprana; (...); **Siswantoro, Joko** (2026) *BPMN graph transformation: A unified multi-format parser library for standardized graph-based business process model integration*, SoftwareX 33 (**Scopus Q2**)

Zahir, Nur Zahira Mohamed and Hashim, Suhaizal; (...); **Siswantoro, Joko** (2025) *Unveiling Effective CSCL Constructs for STEM Education in Malaysia and Indonesia*. Journal of Advanced Research in Applied Sciences and Engineering Technology, 46 (1). pp. 97-106. ISSN 2462-1943 (**Scopus Q2**)

Wariky, Vincentius Christian and **Siswantoro, Joko** and Benarkah, Njoto (2025) *Volume Prediction of Axisymmetric Fruits Using Optimized Convolutional Neural Networks with Transfer Learning Strategy*. International Journal on Advanced Science, Engineering and Information Technology (IJASEIT), 15 (2). 436–443. ISSN 2088-5334; e-ISSN 2460-6952 (**Scopus Q2**)

Sunaryono, Dwi and Sarno, Riyanarto; (...); **Siswantoro, Joko** (2025) *Augmented Data Low Confidence (ADLC): A Confidence-Driven Data Augmentation Framework With Ensemble Optimization for Enhanced Machine Learning Performance*. IEEE Access, 13. pp. 201439-201459. (**Scopus Q1**) & (**WoS Indexed**)

Siswantoro, Joko (2024) *Enhanced Support Vector Machine Based on Grey Wolf Optimizer for Fruits Image Classification using MPEG-7 Color and Texture Features Fusion*. International Journal of Intelligent Engineering and Systems, 17 (3). pp. 1-11. ISSN 2185-3118 (**Scopus Q2**)

Naufal, Mohammad Farid and **Siswantoro, Joko** and Soebroto, Juan Timothy (2024) *Transliterating Javanese Script Images to Roman Script using Convolutional Neural Network with Transfer Learning*. International Journal on Informatics Visualization, 8 (3). pp. 1460-1468. ISSN 2549-9610; E-ISSN 2549-9904 (**Scopus Q3**)

Sebayang, A.H. and Kusumo, Fitranto; (...); **Siswantoro, Joko** and Veza, Ibharn and Mofijur, M. and Chia, Shir Reen (2023) *Optimization of biodiesel production from rice bran oil by ultrasound and infrared radiation using ANN-GWO*. Fuel, 346. p. 128404. ISSN 0016-2361 (**Scopus Q1**) & (**WoS Indexed**)

Sunaryono, Dwi and **Siswantoro, Joko**; (...); Susilo, Rahadian Indarto (2023) *Optimized One-Dimension Convolutional Neural Network for Seizure Classification from EEG Signal based on Whale Optimization Algorithm*. International Journal of Intelligent Engineering and Systems, 16 (3). pp. 310-322. ISSN 2185-310X; E-ISSN:2185-3118 (**Scopus Q2**) & (**WoS Indexed**)

Sunaryono, Dwi and **Siswantoro, Joko**; (...); Akbar, Naufal Rafi (2022) *Hybrid One-Dimensional CNN and DNN Model for Classification Epileptic Seizure*. International Journal of Intelligent Engineering and Systems, 15 (6). pp. 492-502. ISSN 2185-310X; E-ISSN 2185-3118 (**Scopus Q2**)

Sunaryono, D., Sarno, R., **Siswantoro, Joko**. *Gradient Boosting Machines Fusion for Automatic Epilepsy Detection from EEG Signals Based on Wavelet Features*. Journal of King Saud University Computer and Information Sciences Open source preview, 2022, 34(10), pp. 9591–9607 (**Scopus Q1**) & (**WoS Indexed**)

Siswantoro, Joko and Asmawati, Endah and Siswantoro, M. Z. F. N (2022) *A Rapid And Accurate Computer Vision System For Measuring The Volume Of Axi-Symmetric Natural Products Based On Cubic Spline Interpolation*. Journal of Food Engineering, 333. p. 111139. (**Scopus Q1**) & (**WoS Indexed**)

Sunaryono, Dwi and **Siswantoro, Joko; (...)**; Rekha, Kana (2022) *Enhanced Salp Swarm Algorithm Based On Convolutional Neural Network Optimization For Automatic Epilepsy Detection*. Journal of Theoretical and Applied Information Technology, 100 (19). pp. 5615-5623. ISSN 1817-3195 . (**Scopus Q4**) & (**WoS Indexed**)

Sunaryono, Dwi, and **Siswantoro, Joko** and Anggoro, Radityo (2021) *An Android Based Course Attendance System Using Face Recognition*. Journal of King saud University-Computer and Information Sciences, 33 (3). pp. 304-312. (**Scopus Q1**) & (**WoS Indexed**)

Pratomo, AH, Nugraha, A.F, **Siswantoro, Joko**, (2021) *Algorithm Border Tracing Vs Scanline In Blob Detection For Robot Soccer Vision System*, International Journal of Advances in Soft Computing and Its Applications Open source preview, 2019 (**Scopus Q2**)

Siswantoro, Joko and Arwoko, Heru and Widiastri, Monica (2020) *Indonesian Fruits Classification From Image Using MPEG-7 Descriptors And Ensemble Of Simple Classifiers*. Journal of Food Process Engineering, 43 (4). pp. 1-13. ISSN 1745-4530 (**Scopus Q2**) & (**WoS Indexed**)

Silitonga, Arridina Susan and **Siswantoro, Joko; (...)**; Ong, Hwai Chyuan (2020) *Biodiesel synthesis from Ceiba pentandra oil by microwave irradiation-assisted transesterification: ELM modeling and optimization*. Renewable Energy, 146. pp. 1278-1291. (**Scopus Q1**) & (**WoS Indexed**)

Ong, Hwai Chyuan and **Siswantoro, Joko; (...)**; Sutrisno, Joko (2019) *Biodiesel production from Calophyllum inophyllum-Ceiba pentandra oil mixture: Optimization and characterization*. Journal of Cleaner Production, 219. pp. 183-198. ISSN 0959-6526 (**Scopus Q1**) & (**WoS Indexed**)

Silitonga., K, **Siswantoro, Joko**, (et,al) *Evaluation of the engine performance and exhaust emissions of biodiesel-bioethanol-diesel blends using kernel-based extreme learning machine*. Energy , 2018, 159, pp. 1075–1087, (**Scopus Q1**) & (**WoS Indexed**)

Siswantoro, Joko and Prabuwono, Anton Satria; (...);Bahari, Idrus (2017) *Hybrid Neural Network and Linear Model for Natural Produce Recognition Using Computer Vision*. Journal ICT Research and Applications, 11 (2). pp. 184-198. ISSN 2338-5499.
(Scopus Q2) & (WoS Indexed)

Kusumo, F and **Siswantoro, Joko**; (...); and Mahlia, T M I (2017) *Optimization Of Transesterification Process For Ceiba Pentandra Oil: A Comparative Study Between Kernel-Based Extreme Learning Machine And Artificial Neural Networks*. Energy, 134. pp. 24-34. ISSN 0360-5442.
(Scopus Q1) & (WoS Indexed)

Siswantoro, Joko and Prabuwono, Anton Satria; (...);Idrus, Bahari (2016) *A Linear Model Based On Kalman Filter For Improving Neural Network Classification Performance*. Expert Systems with Applications, 49 (1). pp. 112-122. ISSN 0957-4174.
(Scopus Q1) & (WoS Indexed)

Siswantoro, Joko and Prabuwono, Anton Satria and Abdullah, *Volume Measurement Algorithm For Food Product With Irregular Shape Using Computer Vision Based On Monte Carlo Method*, J of ICT Research and Applications, 2014, 8 (1) pp.1-17 (Scopus Q2) & (WoS Indexed)

Siswantoro, Joko and Prabuwono, Anton Satria ; (...);Idrus, Bahari (2014) *Monte Carlo Method with Heuristic Adjustment for Irregularly Shaped Food Product Volume Measurement*. The Scientific World Journal . (Scopus Q1) & (WoS Indexed)

F. Publikasi Artikel di Jurnal Nasional

Benarkah, Njoto and **Siswantoro, Joko** and Ikhsan, Muhammad (2025) *Development of a Mobile Application Using Convolutional Neural Networks for Recognizing Indonesian Traditional Snacks*. Teknika, 14 (2). pp. 239-245. ISSN 2549-8037, EISSN 2549-8045 (SINTA 3)

Siswantoro, Joko and Rahmadiarto, Januar and Naufal, Mohammad Farid (2024) *Facial Expression Recognition to Detect Student Engagement in Online Lectures*. Teknika, 13 (2). pp. 226-232. ISSN 2549-8037, E-ISSN 2549-8045 (SINTA 3)

Naufal, Mohammad Farid and **Siswantoro, Joko** and Wicaksono, Muhammad Ghifari Kusuma (2023) *Klasifikasi Tulisan Tangan Pada Resep Obat Menggunakan Convolutional Neural Network*. Techno.com, 22 (2). pp. 508-526. ISSN 1412-2693, e-ISSN : 2356-2579

Sugiarto, David and **Siswantoro, Joko**; (...); Idrus, Bahari (2023) *Mobile Application for Medicinal Plants Recognition from Leaf Image Using Convolutional Neural Network*. Indonesian Journal of Information Systems (IJIS), 5 (2). pp. 43-56. ISSN 2623-0119; E-ISSN 2623-2308

Averina, Anasthasya and Hadi, Helen and **Siswanto, Joko** (2022) *Analisis Sentimen Multi-Kelas Untuk Film Berbasis Teks Ulasan Menggunakan Model Regresi Logistik*. *Teknika*, 11 (2). pp. 123-128. ISSN 2549-8037, EISSN 2549-8045 (**SINTA 3**)

G. Artikel Seminar Internasional dan Nasional

Widiasri, Monica, **Siswanto, Joko**, Duanto AK. *An Ensemble Convolutional Neural Network Approach for Image Classification of Indonesian Endemic Fruits*. InE3S Web of Conferences 2026 (Vol. 687, p. 02012). EDP Sciences. (**Scopus indexed**)

Wijaya JN, **Siswanto, Joko**. Systematic Literature Review of Hybrid Metaheuristic Algorithms for Feature Selection in Classification Tasks. In 2025 International Conference on Information Management and Technology (ICIMTech) 2025 Aug 28 (pp. 103-108). IEEE. (**Scopus indexed**)

Sunaryono, Dwi and **Siswanto, Joko; (...)**; Sabilla, Shoffi Izza (2023) *Epilepsy Detection using Combination DWT and Convolutional Neural Networks Based on Electroencephalogram*. In: 2023 International Seminar on Intelligent Technology and Its Applications (ISITIA), 26-27 July 2023, Surabaya, Indonesia. (**Scopus indexed**)

Siswanto, Joko and Artadana, Ida Bagus Made and Siswanto, M. Z. F. N (2022) *Leaf geometric properties measurement using computer vision system based on camera parameters*. In: International Conference On Informatics, Technology, And Engineering 2021 (InCITE 2021): Leveraging Smart Engineering, 25 - 26 August 2021, Surabaya, Indonesia (Virtual/Online). (**Scopus indexed**)

Siswanto, Joko and Arwoko, Heru and Siswanto, M. Z. F. N (2020) *Fruits Classification from Image using MPEG-7 Visual Descriptors and Extreme Learning Machine*. In: The 2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), 10 December 2020, Grand Inna Malioboro Hotel, Yogyakarta. (**Scopus indexed**)

Widiasri, Monica and Santoso, Liem Peter and **Siswanto, Joko** (2019) *Computer vision system in measurement of the volume and mass of egg using the disc method*. In: International Conference on Informatics, Technology and Engineering 2019, 22-23 Agustus 2019, Bali. (**Scopus indexed**)

Siswanto, Joko and Artadana, Ida Bagus Made (2019) *Image Based Leaf Area Measurement Method Using Artificial Neural Network*. In: 2019 International Conference of Artificial Intelligence and Information Technology (ICAIIIT), 13-15 March 2019, Yogyakarta. (**Scopus indexed**)

Siswanto, Joko and Asamawati, Endah (2017) *A new framework for measuring volume of axisymmetric food products using computer vision system based on cubic spline interpolation*. Proceeding 2016 2nd International Conference on Science in Information Technology Icsitech 2016 Information Science for Green Society and Environment, pp. 74–78, 7852611, **(Scopus indexed)**

Siswanto, Joko and Hilman, M.Y. and Widiastri, Monica (2017) *Computer vision system for egg volume prediction using backpropagation neural network*. In: International Conference on Informatics, Technology and Engineering 2017 (InCITE 2017), 24-25 August 2017, Bali. **(WoS Indexed)**

Sabilla, Shoffi Izza and Sarno, Riyanarto and **Siswanto, Joko** (2017) *Estimating Gas Concentration using Artificial Neural Network for Electronic Nose*. Conference Paper Procedia Computer Science, 124. pp. 181-188. ISSN 1877-0509. **(Scopus indexed) & (WoS Indexed)**

Siswanto, Joko and Prabuwo, Anton Satria and Abdullah, Azizi and Bahari, Idrus (2016) *Automatic Image Segmentation using Sobel Operator and k-Means Clustering: A Case Study in Volume Measurement System for Food Products*. In: The 2015 International Conference on Science in Information Technology (ICSITech 2015) , 27-28 Oktober 2015, Yogyakarta. **(Scopus indexed) & (WoS Indexed)**

Siswanto, Joko and Asmawati, Endah (2016) *A New Framework for Measuring Volume of Axisymmetric Food Product using Computer Vision System Based on Cubic Spline Interpolation*. 2nd Int Conference on Science in Information Technology (ICSITech) **(WoS Indexed)**

Siswanto, Joko and Prabuwo, Anton Satria and Abdullah, Azizi (2013). *Real World Coordinate from Image Coordinate Using Single Calibrated Camera Based on Analytic Geometry* Conference Paper. Communications in Computer and Information Science, 378 pp.1-11 **(Scopus indexed)**

H. Penulisan Buku

Joko Siswanto, Azizi Abdullah, Anton Satria Prabuwo, Bahari Idrus. (2022) *Sistem Penglihatan Komputer : Pengukuran Isipadu Produk Secara Kaedah Monte Carlo*, Penerbit Universiti Selangor Malaysia, 158 p. ISBN : 9789672518907

Arif H., Endah A., Fitri D. K., **Joko Siswanto**, Joice R. J., *Matematika Farmasi Edisi revisi*, MNC Publishing, 250 p. ISBN : 9786024620967

Iswadi, Hazrul and Asmawati, Endah and Juliana, Joice Ruth and Kartikasari, Fitri Dwi and **Siswanto, Joko** and Herlambang, Arif (2017) *Kalkulus Edisi Revisi*, Media Nusa Creative, Malang. ISBN 978-602-6743-20-6

Herlambang, Arif and Asmawati, Endah and Kartikasari, Fitri Dwi and **Siswanto, Joko** and Juliana, Joice Ruth (2012) *Matematika Farmasi*, Bayumedia Publishing, Malang. ISBN 978-602-7705-31-9

Juliana, Joice Ruth and **Siswanto, Joko** and Asmawati, Endah and Herlambang, Arif (2011) *Metode Numerik dengan Scilab*, Bayumedia Publishing, Malang. ISBN 978-602-9136-57-9

I. Paten dan Hak Cipta

Hak Cipta	Tahun
Klasifikasi Penyakit Daun Padi dari Citra Digital Menggunakan Convolutional Neural Network, No. Permohonan : EC002025034422, (Hak Cipta)	2025
Pembuatan Aplikasi Penghitungan Sel Darah pada Citra Mikroskop dengan Metode Instance Segmentation. No. Permohonan : EC002025041679, (Hak Cipta)	2025
Aplikasi Pendeteksi Kantuk pada Orang Berdasarkan Citra Ekspresi Wajah. No. Permohonan : EC002025041667, (Hak Cipta)	2025
Pengenalan Masakan Nusantara Dari Citra Untuk Menentukan Jenis dan Menampilkan Jumlah Kalori Masakan Nusantara. No. Permohonan : EC002025029487, (Hak Cipta)	2025
Aplikasi Deteksi Tingkat Kesegaran Buah Apel, Pisang, Dan Jeruk Menggunakan Convolutional Neural Network. No. Permohonan : EC002024241290, (Hak Cipta)	2024
Aplikasi Mobile Pengenalan Huruf Hiragana Menggunakan Convolutional Neural Network Untuk Pembelajaran. No. Permohonan : EC00202205093, (Hak Cipta)	2022
Modul Aplikasi Majority Voting Untuk Deteksi Penyakit Epilepsi Menggunakan Sinyal Electroencephalogram (EEG). No. Permohonan : EC00202277110, (Hak Cipta)	2022
Program ini digunakan untuk menentukan referensi yang paling tepat dari pustaka yang ada di perpustakaan menggunakan algoritma FP Growth. No. Permohonan : EC00202151475, (Hak Cipta)	2021

Aplikasi Attendance Online System Sebagai Sarana Absensi Siswa Sebagai Penunjang Pembelajaran. No. Permohonan : EC00201932055, (Hak Cipta)	2018
Aplikasi Attendance Online System Sebagai Sarana Absensi Siswa Sebagai Penunjang Pembelajaran. No. Permohonan : EC00201932055 (Hak Cipta)	2018
Aplikasi Virtual Reality untuk Pembelajaran Fisika Gerak Parabola. No. Permohonan : EC00202117662 (Hak Cipta)	2018

J. Pengalaman Kerja

Nama Lembaga					Tahun
Dosen Tetap	Fakultas Teknik	Universitas Surabaya			1997 - Sekarang


K. Pengalaman Organisasi

Nama Organisasi					Tahun
Kepala Prodi Teknik Informatika	Universitas Surabaya				2020-Sekarang
Kepala Laboratorium Intelligent System Prodi Teknik Informatika	Universitas Surabaya				2017-2021

L. Prestasi/Penghargaan yang Pernah diperoleh

Prestasi/Penghargaan	Lembaga Pemberi	Tahun
Ketua Tim Hibah Penelitian Fundamental Reguler Tahun Anggaran 2025	Dirjen Riset dan Pengembangan Kemendiktisaintek	2025
Ketua Tim Hibah Penelitian Publikasi Berkualitas	Universitas Surabaya	2023
Koordinator Program Kompetisi Kapus Merdeka (PK-KM) Prodi Teknik Informatika Tahun Anggaran 2023	Dirjen Pendidikan Tinggi, Riset dan Teknologi, Kemendikbud-saintek	2023
Koordinator Program Kompetisi Kapus Merdeka (PK-KM) Prodi Teknik Informatika Tahun Anggaran 2022	Dirjen Pendidikan Tinggi, Riset dan Teknologi, Kemendikbudristek	2022
Ketua Tim Hibah Penelitian Dasar	Universitas Surabaya	2022

Ketua Unggulan 2020	Tim Perguruan	Hibah Tinggi	Penelitian Anggaran	Dasar	Dirjen Pendidikan Tinggi, Riset dan Teknologi, Kemendikbudristek	2020
---------------------------	------------------	-----------------	------------------------	-------	---	------



Inspiring & Transforming Students' Lives

www.ubaya.ac.id