

TESIS

**OPTIMASI SIMULTAN SELEKSI FITUR DAN
HIPERPARAMETER BERBASIS STABILITY-AWARE COST
FUNCTION DAN PUMA OPTIMIZER UNTUK KLASIFIKASI
MULTI-KELAS CITRA TORAKS**



Oleh:

Baiq Titik Haerani

NIM: 24206051010

PROGRAM STUDI INFORMATIKA
PROGRAM MAGISTER FAKULTAS SAINS DAN TEKNOLOGI
UIN SUNAN KALIJAGA

YOGYAKARTA

2026

PERNYATAAN KEASLIAN

PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini:

Nama : Baiq Titik Haerani
NIM : 24206051019
Jenjang : Magister
Program Studi : Informatika

Menyatakan bahwa naskah tesis ini secara keseluruhan adalah hasil penelitian/karya saya sendiri, kecuali pada bagian-bagian yang dirujuk sumbernya.

Yogyakarta, 17 Agustus 2026

Saya yang menyatakan,



Baiq Titik Haerani
NIM: 18206050010

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

HALAMAN PENGESAHAN



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Marsda Adisucipto Telp. (0274) 540971 Fax. (0274) 519739 Yogyakarta 55281

PENGESAHAN TUGAS AKHIR

Nomor : B-1924/Un.02/DST/PP.00.9/08/2026

Tugas Akhir dengan judul : Optimasi Simulatan Seleksi Fitur Dan Hiperparameter Berbasis Stability-Aware Cost Function Dan Puma Optimezer untuk Klasifikasi Multi-Kelas Citra Toraks

yang dipersiapkan dan disusun oleh:

Nama : BAIQ TITIK HAERANI, S.Pd
Nomor Induk Mahasiswa : 24206051010
Telah diujikan pada : Rabu, 12 Agustus 2026
Nilai ujian Tugas Akhir : A

dinyatakan telah diterima oleh Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta

TIM UJIAN TUGAS AKHIR



Valid ID: 6a85a6861fa0

Ketua Sidang

Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng.
SIGNED



Valid ID: 6a854eab77f2d

Penguji I

Dr. Agung Fatwanto, S.Si., M.Kom.
SIGNED



Valid ID: 6a868184f088ab

Penguji II

Usfita Kiftiyani, M.Sc., Ph.D
SIGNED



Valid ID: 6a87838b6d6fa

Yogyakarta, 12 Agustus 2026
UIN Sunan Kalijaga
Dekan Fakultas Sains dan Teknologi

Prof. Dr. Dra. Hj. Khurul Wardati, M.Si.
SIGNED

NOTA DINAS PEMBIMBING

NOTA DINAS PEMBIMBING

Kepada Yth,
Dekan Fakultas Sains dan Teknologi
UIN Sunan Kalijaga
Yogyakarta

Assalamu 'alaikum wr. wb.

Setelah melakukan bimbingan, arahan, dan koreksi terhadap penulisan tesis yang berjudul:

“OPTIMASI SIMULTAN SELEKSI FITUR DAN HIPERPARAMETER BERBASIS STABILITY-AWARE COST FUNCTION DAN PUMA OPTIMIZER UNTUK KLASIFIKASI MULTI-KELAS CITRA TORAKS”

Yang ditulis oleh:

Nama : Baiq Titik Haerani

NIM : 24206051010


Jenjang : Magister

Program Studi : Informatika

Saya berpendapat bahwa tesis tersebut sudah dapat diajukan kepada Magister Informatika UIN Sunan Kalijaga Yogyakarta untuk diujikan dalam rangka memperoleh gelar Magister Informatika.

Wassalamu 'alaikum wr. wb.

Yogyakarta, 17 Agustus 2026
Pembimbing


Prof. Dr. Ir. Shofwatul 'Uyun, S.T.,
M.Kom., IPM., ASEAN Eng
NIP: 19820511 200604 2 002

ABSTRAK

Klasifikasi citra Chest X-ray berbasis deep learning umumnya menghasilkan representasi fitur berdimensi tinggi sehingga memerlukan seleksi fitur dan optimasi hiperparameter untuk meningkatkan efisiensi serta performa model. Pendekatan optimasi simultan berbasis wrapper telah banyak digunakan, namun sebagian besar masih mengandalkan fungsi objektif yang hanya mempertimbangkan classification error sehingga belum memperhatikan stabilitas performa selama proses validasi. Penelitian ini bertujuan mengembangkan dan mengevaluasi Proposed Stability-Aware PUMA Framework, yaitu framework optimasi simultan yang mengintegrasikan seleksi deep feature dan optimasi hiperparameter menggunakan Puma Optimizer dengan Stability-Aware Cost Function (SACF) sebagai fungsi objektif. SACF mengombinasikan classification error, error variance, dan feature ratio untuk mengoptimalkan akurasi klasifikasi, konsistensi performa validasi, serta kompleksitas model secara simultan. Eksperimen dilakukan pada 532 citra Chest X-ray empat kelas. Sebanyak 1.280 deep feature diekstraksi menggunakan MobileNetV2 sebagai fixed feature extractor, kemudian dioptimalkan secara simultan bersama hiperparameter Support Vector Machine (SVM) dan Random Forest (RF). Evaluasi meliputi pengujian performa klasifikasi, studi ablasi, analisis konvergensi, pengujian ketahanan terhadap Gaussian noise dan Speckle noise, serta validasi statistik. Hasil penelitian menunjukkan bahwa framework yang diusulkan mampu mereduksi lebih dari 50% deep feature dengan tetap mempertahankan performa klasifikasi yang kompetitif. Studi ablasi membuktikan bahwa kombinasi classification error, error variance, dan feature ratio menghasilkan performa optimasi yang lebih baik dibandingkan penggunaan masing-masing komponen secara terpisah. Selain itu, framework yang diusulkan menunjukkan proses optimasi yang lebih konsisten, konvergensi yang lebih stabil, serta ketahanan yang kompetitif terhadap degradasi citra. Temuan ini menunjukkan bahwa integrasi SACF dalam optimasi simultan mampu menghasilkan solusi yang lebih seimbang dengan mempertimbangkan akurasi, stabilitas, dan efisiensi representasi fitur, sehingga berpotensi meningkatkan kemampuan generalisasi pada klasifikasi multi-kelas citra Chest X-ray.

Kata kunci: Chest X-ray; deep feature selection; optimasi hiperparameter; Puma Optimizer; Stability-Aware Cost Function; optimasi simultan.

ABSTRACT

Deep learning-based chest X-ray image classification generally produces high-dimensional feature representations, requiring feature selection and hyperparameter optimization to enhance the model's efficiency and performance. The wrapper-based simultaneous optimization approach has been widely used, but most still rely on an objective function that only considers classification error, thus not taking into account performance stability during the validation process. This research aims to develop and evaluate the Proposed Stability-Aware PUMA Framework, which is a simultaneous optimization framework that integrates deep feature selection and hyperparameter optimization using the Puma Optimizer with the Stability-Aware Cost Function (SACF) as the objective function. SACF combines classification error, error variance, and feature ratio to simultaneously optimize classification accuracy, validation performance consistency, and model complexity. Experiments were conducted on 532 four-class chest X-ray images. A total of 1,280 deep features were extracted using MobileNetV2 as a fixed feature extractor, and then simultaneously optimized along with the hyperparameters of Support Vector Machine (SVM) and Random Forest (RF). Evaluation includes testing classification performance, ablation study, convergence analysis, and robustness testing against Gaussian noise and speckle noise, as well as statistical validation. The research results show that the proposed framework is capable of reducing more than 50% of deep features while maintaining competitive classification performance. The ablation study proves that the combination of classification error, error variance, and feature ratio yields better optimization performance compared to using each component separately. Additionally, the proposed framework demonstrates a more consistent optimization process, more stable convergence, and competitive resilience against image degradation. These findings indicate that the integration of SACF in simultaneous optimization can produce more balanced solutions by considering accuracy, stability, and feature representation efficiency, thereby potentially enhancing generalization capabilities in multi-class chest X-ray image classification.

Keywords: Chest X-ray, deep feature selection, hyperparameter optimization, Puma Optimizer, stability-aware cost function, simultaneous optimization.

MOTTO

"Dan orang-orang yang bersungguh-sungguh untuk (mencari keridaan) Kami, benar-benar akan Kami tunjukkan kepada mereka jalan-jalan Kami."

(QS. Al-Ankabut [29]: 69)

"Bukan tentang seberapa cepat mencapai tujuan, tetapi tentang seberapa teguh bertahan dalam setiap proses."

"Yesterday I was clever, so I wanted to change the world. Today I am wise, so I am changing myself."

— *Jalaluddin Rumi*

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur Alhamdulillah rabbil'alamin penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan tesis ini yang berjudul “Optimasi Simultan Seleksi Fitur Dan Hiperparameter Berbasis Stability-Aware Cost Function Dan Puma Optimizer Untuk Klasifikasi Multi-Kelas Citra Toraks” sebagai salah satu syarat untuk memperoleh gelar Magister pada Program Studi Magister Informatika di UIN Sunan Kalijaga Yogyakarta.

Penyusunan tesis ini tentunya tidak lepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, dengan segala hormat dan ketulusan, penulis menyampaikan terima kasih dan penghargaan yang sebesar-besarnya kepada:

1. Prof. Noorhaidi Hasan, S.Ag., M.A., M.Phil., Ph.D., selaku Rektor UIN Sunan Kalijaga Yogyakarta.
2. Prof. Dr. Dra. Hj. Khurul Wardati, M.Si., selaku Dekan Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta.
3. Dr. Ir. Sumarsono, S.T., M.Kom., selaku Ketua Program Studi Magister Informatika, Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta.
4. Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng., selaku dosen pembimbing tesis atas bimbingan, arahan, kesabaran, dan motivasi yang telah diberikan selama proses penyusunan tesis ini. Bimbingan beliau sangat berarti dalam

mengarahkan penulis hingga tesis ini dapat terselesaikan dengan baik.

5. Agus Mulyanto, S.Si., M.Kom., M.Kom. selaku dosen pembimbing akademik yang telah membimbing selama proses studi yang kurang lebih dua tahun.
6. Seluruh dosen dan staf pengajar di Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta, yang telah memberikan ilmu dan wawasan selama masa studi.
7. Lembaga Pengelola Dana Pendidikan (LPDP) dan Kementerian Agama Republik Indonesia (Kemenag RI) atas dukungan finansial melalui Program Beasiswa Santri Berprestasi (PBSB), yang memungkinkan penulis menempuh pendidikan magister ini dengan optimal.
8. Kedua orang tua tercinta beserta seluruh keluarga yang senantiasa memberikan doa, kasih sayang, motivasi, dan dukungan tanpa henti sehingga penulis dapat menyelesaikan studi ini dengan baik.
9. Rekan-rekan seperjuangan dan sahabat selama proses studi yang selalu memberikan semangat, kebersamaan, dan dukungan selama masa perkuliahan maupun penyusunan tesis ini. Kebersamaan tersebut menjadi pengalaman yang sangat berharga bagi penulis.
10. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu, yang telah memberikan bantuan, doa, dan dukungan baik secara langsung maupun tidak langsung selama proses penyusunan tesis ini.

Penulis menyadari bahwa karya ini masih memiliki keterbatasan. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan demi perbaikan di masa yang akan datang. Semoga tesis ini dapat memberikan manfaat bagi perkembangan ilmu pengetahuan serta menjadi referensi bagi penelitian selanjutnya,

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Yogyakarta, 17 Agustus 2026

Penulis,



Baiq Titik Haerani

NIM: 18206050010

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR ISI

TESIS.....	i
PERNYATAAN KEASLIAN	ii
HALAMAN PENGESAHAN	iii
NOTA DINAS PEMBIMBING	iv
ABSTRAK.....	v
ABSTRACT	vi
MOTTO	vii
KATA PENGANTAR.....	viii
DAFTAR ISI	xi
DAFTAR TABEL	xiv
DAFTAR GAMBAR.....	xv
DAFTAR ISTILAH.....	xvi
DAFTAR SINGKATAN.....	xvii
BAB I.....	1
PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah	6
C. Batasan Masalah.....	7
D. Tujuan Penelitian.....	8
E. Manfaat Penelitian.....	9
BAB II	11
KAJIAN PUSTAKA DAN LANDASAN TEORI.....	11
A. Kajian Pustaka.....	11
B. Landasan Teori.....	17
1. Transfer Learning dan Arsitektur MobileNetV2	17
2. Seleksi Fitur	23

3.	Optimasi Hiperparameter	27
4.	Simultaneous Binary–Continuous Optimization	31
5.	Metaheuristic Optimization dan Puma Optimizer	35
6.	Fungsi Objektif dan Stability-Aware Optimization.....	39
7.	Evaluasi Kinerja Model Klasifikasi.....	46
8.	<i>Citra Radiologi Paru (Chest X-Ray)</i>	50
BAB III		54
METODE PENELITIAN		54
A. Desain Penelitian.....		54
B. <i>Dataset Preparation</i>		55
1.	Dataset Penelitian	55
2.	Pembagian Dataset	56
3.	Prapemrosesan Citra	57
4.	Augmentasi Data	57
C. Deep Feature Representation.....		58
1.	Ekstraksi Deep Feature	58
2.	Pembentukan Feature Matrix.....	59
D. Proposed Stability-Aware PUMA Framework.....		60
1.	Pembentukan Kandidat Solusi.....	60
2.	Evaluasi Kandidat Solusi.....	61
3.	Proses Optimasi	62
4.	Penentuan Solusi Optimum	63
E. Pembangunan Model Klasifikasi Akhir		64
1.	Pembentukan Data Latih	64
2.	Pelatihan Model Klasifikasi.....	65
3.	Pembentukan Model Akhir.....	65
F. Evaluasi Eksperimental		65
1.	Perbandingan Framework.....	66

2.	Evaluasi Performa Klasifikasi	66
3.	Evaluasi Efisiensi Seleksi Fitur	67
4.	Evaluasi Robustness	67
5.	Studi Ablasi	67
6.	Analisis Konvergensi.....	68
7.	Analisis Statistik.....	68
8.	Lingkungan Eksperimen.....	69
BAB IV		71
HASIL DAN PEMBAHASAN		71
A. Hasil Penelitian.....		71
1.	Hasil Optimasi Simultan Seleksi Fitur dan Hiperparameter.....	71
2.	Hasil Evaluasi Performa Model Klasifikasi	74
3.	Evaluasi Ketahanan Model terhadap Degradasi Citra	77
4.	Studi Ablasi Stability-Aware Cost Function	81
5.	Analisis Konvergensi Algoritma	85
6.	Analisis Statistik.....	89
B. Pembahasan.....		91
1.	Framework Optimasi Simultan Seleksi Fitur dan Hiperparameter Berbasis <i>Puma Optimizer</i>	92
2.	Kontribusi Stability-Aware Cost Function terhadap Kualitas Solusi Optimasi.....	96
3.	Efektivitas <i>Framework</i> pada Klasifikasi Multi-Kelas Citra Radiologi Paru.....	100
4.	Implikasi Penelitian terhadap Pengembangan Optimasi Simultan Berbasis Stability-Aware Cost Function	104
BAB V		110
PENUTUP		110
A. Kesimpulan.....		110

B. Saran.....	112
DAFTAR PUSTAKA	115

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahul.....	14
Tabel 3. 1 Distribusi Dataset Penelitian	56
Tabel 3. 2 Pembagian Dataset Penelitian	56
Tabel 4. 1 Hasil Optimasi Simultan Seleksi Fitur dan Hiperparameter	72
Tabel 4. 2 Hasil Evaluasi Performa Model Klasifikasi pada Data Bersih.....	75
Tabel 4. 3 Hasil Studi Ablasi Stability-Aware Cost Function.....	82
Tabel 4. 4 Hasil Uji Friedman dan Wilcoxon Signed-Rank Test.....	89

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR GAMBAR

Gambar 3. 1 Flowchart Penelitian	54
Gambar 4. 1 Confusion Matrix Hasil Klasifikasi Menggunakan Baseline Framework, PSO Framework, dan Proposed Stability-Aware PUMA Framework pada Data Bersih	76
Gambar 4. 2 Kurva Ketahanan (Robustness) Baseline Framework, PSO Framework, dan Proposed Stability-Aware PUMA Framework terhadap Gaussian Noise dan Speckle Noise pada classifier Support Vector Machine dan Random Forest.	79
Gambar 4. 3 Kurva Studi Ablasi Stability-Aware Cost Function pada Gaussian Noise dan Speckle Noise menggunakan Support Vector Machine dan Random Forest	84
Gambar 4. 4 Kurva Konvergensi PSO dan Proposed Stability-Aware PUMA Framework pada 10 Independent Runs menggunakan classifier Support Vector Machine dan Random Forest.....	86

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR ISTILAH

Augmentasi Data (Data Augmentation)	: Teknik memperbanyak variasi data latih secara buatan tanpa mengubah label kelas asli.
Kebocoran Data (Data leakage)	: Kondisi ketika informasi dari data uji atau validasi secara tidak sengaja mencemari proses pelatihan model.
Penyetelan Hiperparameter (Hyperparameter Tuning)	: Proses mencari konfigurasi parameter internal terbaik yang mengendalikan proses pembelajaran model.
Seleksi Fitur (Feature Selection)	: Proses memilih subset fitur yang paling relevan dan membuang fitur yang redundan.
Stabilitas (Stability)	: Konsistensi performa atau hasil seleksi model terhadap variasi pembagian data latih.
Validasi Silang (Cross-Validation)	: Teknik evaluasi model dengan membagi data menjadi beberapa bagian (fold) secara berulang.

DAFTAR SINGKATAN

AI	: <i>Artificial Intelligence</i>
AUC	: <i>Area Under the Receiver Operating Characteristic Curve</i>
CAD	: <i>Compute-Aided Diagnosis</i>
CNN	: <i>Convolutional Neural Network</i>
CXR	: <i>Chest X-ray</i>
F1	: <i>F1-Score</i>
NFE	: <i>Number of Function Evaluations</i>
PO	: <i>Puma Optimizer</i>
PSO	: <i>Particl Swarm Optimization</i>
RF	: <i>Random Forest</i>
SACF	: <i>Stability-Aware Cost Function</i>
SVM	: <i>Support Vector Machine</i>

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

BAB I

PENDAHULUAN

A. Latar Belakang

Penyakit paru, seperti pneumonia, tuberkulosis, dan Coronavirus Disease 2019 (COVID-19), masih menjadi penyebab utama morbiditas dan mortalitas di berbagai negara sehingga memerlukan diagnosis yang cepat dan akurat untuk mendukung pengambilan keputusan klinis (World Health Organization, 2024). Salah satu modalitas pencitraan yang paling banyak digunakan dalam diagnosis penyakit paru adalah Chest X-ray (CXR) karena memiliki biaya relatif rendah, waktu pemeriksaan singkat, serta tersedia secara luas di berbagai fasilitas pelayanan kesehatan (Cleverley dkk., 2020; Rubin dkk., 2020). Namun demikian, interpretasi citra CXR masih bergantung pada pengalaman radiolog sehingga berpotensi menimbulkan variasi diagnosis, terutama pada kondisi beban kerja yang tinggi, keterbatasan tenaga spesialis, serta kemiripan karakteristik visual antarpenyakit (Brady, 2017). Kondisi tersebut mendorong berkembangnya sistem Computer-Aided Diagnosis (CAD) berbasis Artificial Intelligence (AI) sebagai pendukung proses interpretasi citra medis.

Perkembangan Deep Learning menjadikan Convolutional Neural Network (CNN) sebagai pendekatan utama dalam pengembangan sistem CAD karena mampu mempelajari representasi visual secara otomatis tanpa memerlukan proses ekstraksi fitur secara manual (Litjens dkk., 2017). Keterbatasan jumlah citra medis berlabel kemudian mendorong pemanfaatan transfer learning, yaitu pendekatan yang

memanfaatkan model pralatih untuk menghasilkan representasi fitur yang efektif pada domain dengan data pelatihan yang terbatas (Morid dkk., 2021; Pan & Yang, 2010). Salah satu arsitektur yang banyak digunakan adalah MobileNetV2 karena menawarkan keseimbangan antara efisiensi komputasi dan kemampuan representasi fitur melalui mekanisme inverted residual dan linear bottleneck (Sandler dkk., 2018). Pemanfaatan MobileNetV2 sebagai deep feature extractor telah menunjukkan performa yang kompetitif pada klasifikasi berbagai penyakit paru berbasis citra CXR (Oh dkk., 2020; Rajaraman dkk., 2022).

Meskipun demikian, representasi deep feature yang dihasilkan MobileNetV2 memiliki dimensi yang tinggi sehingga tidak seluruh fitur memberikan kontribusi yang sama terhadap proses klasifikasi. Sebagian fitur bersifat redundan, kurang relevan, atau memiliki korelasi yang tinggi sehingga meningkatkan kompleksitas komputasi, memperbesar risiko overfitting, dan menurunkan kemampuan generalisasi model (Li dkk., 2018; Rostami dkk., 2021). Oleh karena itu, seleksi fitur menjadi tahapan penting untuk memperoleh subset fitur yang lebih representatif tanpa menghilangkan informasi diskriminatif yang diperlukan dalam proses klasifikasi (Pudjihartono dkk., 2022; Theng & Bhoyar, 2024).

Selain kualitas representasi fitur, performa model klasifikasi juga dipengaruhi oleh konfigurasi hiperparameter yang mengendalikan kapasitas dan mekanisme pembelajaran classifier (Probst dkk., 2019). Pada *Support Vector Machine* (SVM), parameter penalti dan kernel memengaruhi pembentukan batas keputusan, sedangkan pada *Random Forest* (RF), parameter seperti jumlah pohon dan kedalaman maksimum menentukan kompleksitas model ensemble (Breiman, 2001; Cortes &

Vapnik, 1995) Dengan demikian, kualitas model tidak hanya bergantung pada subset fitur atau hiperparameter secara individual, tetapi juga pada interaksi keduanya. Perubahan subset fitur dapat mengubah karakteristik ruang fitur sehingga konfigurasi hiperparameter yang sesuai dapat berbeda, sementara perubahan hiperparameter dapat memengaruhi efektivitas subset fitur yang digunakan. Hubungan interdependen tersebut menjadi dasar pengembangan *joint optimization*, yaitu optimasi seleksi fitur dan hiperparameter secara simultan dalam satu ruang pencarian (Binder dkk., 2020; Schneider dkk., 2023).

Dinamika optimasi menjadi lebih kompleks pada klasifikasi multi-kelas, ketika classifier harus membentuk pemisahan antar beberapa kategori secara simultan. Pada citra CXR, karakteristik patologi antar-kelas dapat memiliki kemiripan visual sehingga pemisahan kelas bergantung pada representasi fitur yang mampu mempertahankan informasi diskriminatif sekaligus konfigurasi classifier yang sesuai (Brady, 2017; Rajaraman dkk., 2022). Oleh karena itu, optimasi seleksi fitur dan hiperparameter secara simultan memberikan pendekatan yang terintegrasi untuk mengevaluasi kombinasi representasi dan konfigurasi model dalam satu proses pencarian (Binder dkk., 2020; Schneider dkk., 2023).

Permasalahan tersebut merupakan permasalahan optimasi berdimensi tinggi yang banyak diselesaikan menggunakan algoritma metaheuristik karena mampu memperoleh solusi berkualitas tanpa melakukan pencarian secara exhaustive (Houssein dkk., 2021; Talbi, 2009) Berbagai algoritma telah dikembangkan untuk menyelesaikan permasalahan seleksi fitur maupun optimasi hiperparameter, termasuk algoritma metaheuristik generasi baru seperti Puma Optimizer yang

memiliki kemampuan eksplorasi dan eksploitasi adaptif selama proses pencarian solusi (Abdollahzadeh, Khodadadi, Mirjalili, dkk., 2024). Namun demikian, penerapan Puma Optimizer pada optimasi simultan seleksi deep feature dan hiperparameter untuk klasifikasi multi-kelas citra Chest X-ray masih sangat terbatas.

Keterbatasan tersebut menjadi semakin relevan pada permasalahan klasifikasi multi-kelas, karena peningkatan jumlah kelas target memperbesar kompleksitas ruang keputusan (decision space) yang harus dipelajari oleh classifier. Pada klasifikasi biner, batas keputusan (decision boundary) yang dibentuk relatif tunggal, sehingga interaksi antara subset fitur yang dipilih dan konfigurasi hiperparameter classifier cenderung lebih sederhana untuk dioptimalkan secara terpisah tanpa kehilangan banyak informasi. Sebaliknya, pada klasifikasi multi-kelas, classifier harus membentuk beberapa batas keputusan secara bersamaan untuk memisahkan setiap pasangan kelas, sehingga subset fitur yang optimal bagi satu pasang kelas belum tentu optimal bagi pasangan kelas lainnya (Probst dkk., 2019). Kondisi ini menyebabkan hubungan antara seleksi fitur dan konfigurasi hiperparameter menjadi semakin saling bergantung (interdependent) seiring bertambahnya jumlah kelas, sehingga optimasi yang dilakukan secara terpisah berisiko menghasilkan kombinasi subset fitur dan hiperparameter yang hanya optimal secara agregat, tetapi tidak konsisten optimal pada seluruh kelas. Dengan demikian, semakin banyak jumlah kelas yang diklasifikasikan, semakin besar pula urgensi untuk mengoptimalkan subset fitur dan hiperparameter secara simultan, agar diperoleh konfigurasi yang mempertimbangkan interaksi antar-kelas secara menyeluruh, dan bukan hanya interaksi rata-rata yang bersifat agregatif

sebagaimana lazim terjadi pada pendekatan optimasi sekuensial. Pertimbangan inilah yang mendasari pemilihan konteks klasifikasi multi-kelas citra Chest X-ray empat kategori sebagai studi kasus pada penelitian ini.

Selain keterbatasan pada strategi optimasi, penelitian terdahulu umumnya masih menggunakan classification error sebagai fungsi objektif utama dalam mengevaluasi kualitas solusi. Pendekatan tersebut hanya berorientasi pada peningkatan akurasi tanpa mempertimbangkan konsistensi performa model selama proses validasi maupun efisiensi representasi fitur yang digunakan (Abdollahzadeh & Gharehchopogh, 2022). Literatur mengenai algorithmic stability menunjukkan bahwa stabilitas merupakan salah satu indikator yang berkaitan erat dengan reliabilitas dan kemampuan generalisasi model (Bousquet & Elisseeff, 2002; Khair & Dhanalakshmi, 2022; Nogueira dkk., 2018). Dengan demikian, kualitas solusi optimasi seharusnya tidak hanya ditentukan oleh tingkat kesalahan klasifikasi, tetapi juga oleh konsistensi performa dan efisiensi model.

Berdasarkan uraian tersebut, masih terdapat kesenjangan penelitian berupa belum terintegrasinya optimasi simultan seleksi deep feature dan hiperparameter dengan fungsi objektif yang secara eksplisit mempertimbangkan akurasi, stabilitas, dan kompleksitas model dalam satu kerangka optimasi terpadu. Selain itu, pemanfaatan Puma Optimizer untuk menangani ruang pencarian biner dan kontinu secara simultan pada klasifikasi multi-kelas citra Chest X-ray masih belum banyak dilaporkan. Kesenjangan tersebut menjadi dasar penelitian ini untuk mengembangkan Stability-Aware Cost Function (SACF) sebagai fungsi objektif yang mengintegrasikan classification error, error

variance, dan feature ratio, serta mengimplementasikannya pada framework optimasi simultan berbasis Puma Optimizer. Framework yang diusulkan diharapkan mampu menghasilkan kombinasi subset deep feature dan konfigurasi hiperparameter yang tidak hanya memberikan performa klasifikasi yang tinggi, tetapi juga lebih stabil, efisien, dan memiliki kemampuan generalisasi yang lebih baik.

B. Rumusan Masalah

Berdasarkan latar belakang penelitian, rumusan masalah dalam penelitian ini adalah sebagai berikut.

1. Bagaimana mengembangkan framework optimasi simultan berbasis Puma Optimizer dengan representasi biner–kontinu untuk mengoptimalkan seleksi deep feature dan hiperparameter secara terpadu pada klasifikasi multi-kelas citra Chest X-ray?
2. Bagaimana mengembangkan Stability-Aware Cost Function (SACF) yang mengintegrasikan classification error, error variance, dan feature ratio sebagai fungsi objektif dalam optimasi simultan seleksi deep feature dan hiperparameter pada klasifikasi multi-kelas citra Chest X-ray?
3. Bagaimana efektivitas framework yang diusulkan dalam meningkatkan performa klasifikasi, stabilitas proses optimasi, efisiensi seleksi deep feature, dan ketahanan model terhadap degradasi citra dibandingkan dengan metode optimasi pembandingan?

C. Batasan Masalah

Agar penelitian terarah dan sesuai dengan tujuan yang ingin dicapai, ruang lingkup penelitian dibatasi pada beberapa aspek berikut.

1. Penelitian dibatasi pada klasifikasi multi-kelas citra Chest X-ray yang terdiri atas empat kategori, yaitu Normal, COVID-19, Viral Pneumonia, dan Bacterial Pneumonia, sehingga tidak mencakup klasifikasi penyakit paru lainnya maupun skenario klasifikasi multi-label.
2. Representasi fitur citra diperoleh menggunakan MobileNetV2 sebagai deep feature extractor. Penelitian ini tidak membahas perbandingan dengan arsitektur Convolutional Neural Network (CNN) lainnya.
3. Optimasi simultan dilakukan terhadap seleksi deep feature dan hiperparameter pada dua algoritma klasifikasi, yaitu Support Vector Machine (SVM) dan Random Forest (RF). Algoritma klasifikasi maupun ruang hiperparameter lainnya tidak menjadi ruang lingkup penelitian.
4. Framework yang dikembangkan menggunakan Puma Optimizer sebagai algoritma optimasi utama. Algoritma metaheuristik lainnya hanya digunakan sebagai metode pembandingan pada tahap evaluasi dan tidak menjadi objek pengembangan penelitian.
5. Penelitian menggunakan Stability-Aware Cost Function (SACF) yang mengintegrasikan classification error, error variance, dan feature ratio sebagai fungsi objektif. Penelitian ini tidak

membahas optimasi bobot fungsi objektif maupun pengembangan formulasi fungsi objektif alternatif.

6. Validasi SACF dibatasi pada studi ablasi (ablation study) untuk mengevaluasi kontribusi masing-masing komponen penyusun fungsi objektif. Penelitian ini tidak mencakup analisis terhadap variasi skema pembobotan maupun pendekatan optimasi multiobjektif.
7. Penelitian difokuskan pada pengembangan dan validasi framework optimasi berbasis eksperimen komputasional. Oleh karena itu, implementasi sistem Computer-Aided Diagnosis (CAD) pada lingkungan klinis, integrasi dengan sistem informasi rumah sakit, serta evaluasi terhadap aspek operasional pelayanan kesehatan tidak menjadi ruang lingkup penelitian.

D. Tujuan Penelitian

Berdasarkan rumusan masalah, penelitian ini bertujuan untuk:

1. Mengembangkan Stability-Aware Cost Function (SACF) yang mengintegrasikan classification error, error variance, dan feature ratio sebagai fungsi objektif untuk mengevaluasi kualitas solusi optimasi secara lebih komprehensif pada klasifikasi multi-kelas citra Chest X-ray.
2. Mengembangkan framework optimasi simultan seleksi fitur dan hiperparameter berbasis Puma Optimizer melalui representasi biner-kontinu sehingga proses seleksi deep feature dan optimasi hiperparameter dapat dilakukan secara terpadu dalam satu proses optimasi.

3. Mengevaluasi efektivitas framework yang diusulkan dalam meningkatkan performa klasifikasi, stabilitas optimasi, efisiensi seleksi fitur, serta ketahanan model terhadap degradasi citra akibat Gaussian Noise dan Speckle Noise dibandingkan dengan pendekatan optimasi konvensional.

E. Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat baik secara teoritis maupun praktis.

1. Manfaat Teoretis

- a) Memberikan kontribusi terhadap pengembangan metode optimasi berbasis metaheuristik melalui integrasi Stability-Aware Cost Function dalam proses optimasi simultan biner-kontinu.
- b) Memperkaya kajian mengenai penerapan Puma Optimizer pada permasalahan seleksi deep feature dan optimasi hiperparameter secara simultan.
- c) Menjadi referensi bagi penelitian selanjutnya yang mengembangkan metode optimasi pada klasifikasi citra medis maupun permasalahan optimasi berdimensi tinggi lainnya.

2. Manfaat Praktis

- a) Menyediakan framework optimasi yang mampu memilih subset deep feature dan konfigurasi hiperparameter secara simultan sehingga proses klasifikasi menjadi lebih efektif dan efisien.

- b) Memberikan alternatif metode untuk meningkatkan stabilitas dan performa klasifikasi citra Chest X-Ray, termasuk pada kondisi citra yang mengalami gangguan Gaussian Noise maupun Speckle Noise.
- c) Menjadi dasar pengembangan sistem Computer-Aided Diagnosis (CAD) yang lebih andal dalam mendukung analisis citra radiologi, sesuai dengan ruang lingkup penelitian yang berfokus pada evaluasi metode komputasi.

BAB V

PENUTUP

A. Kesimpulan

Penelitian ini berhasil mengembangkan framework optimasi simultan seleksi fitur dan hiperparameter berbasis Puma Optimizer dengan mengintegrasikan Stability-Aware Cost Function (SACF) sebagai fungsi objektif pada klasifikasi multi-kelas citra radiologi paru. Berbeda dengan pendekatan optimasi konvensional yang memperlakukan seleksi fitur dan optimasi hiperparameter sebagai dua proses yang terpisah, framework yang dikembangkan mengevaluasi kedua komponen tersebut secara simultan dalam satu ruang pencarian. Pendekatan ini memungkinkan proses optimasi mempertimbangkan keterkaitan antara representasi fitur dan konfigurasi model sehingga menghasilkan konfigurasi yang lebih sesuai dengan karakteristik classifier yang digunakan. Dengan demikian, tujuan utama penelitian untuk mengembangkan mekanisme optimasi simultan yang lebih terintegrasi berhasil dicapai.

Temuan penelitian menunjukkan bahwa efektivitas optimasi simultan tidak ditentukan oleh satu konfigurasi optimum yang bersifat universal, tetapi oleh kemampuan framework dalam menghasilkan solusi yang adaptif terhadap karakteristik algoritma pembelajaran. Konfigurasi optimum yang berbeda pada Support Vector Machine dan Random Forest menunjukkan bahwa kualitas solusi merupakan hasil interaksi antara representasi deep feature, konfigurasi hiperparameter, dan mekanisme pembelajaran masing-masing classifier. Selain itu, hasil studi ablasi memperlihatkan bahwa perubahan komposisi fungsi objektif menghasilkan karakteristik solusi yang berbeda, yang

menegaskan bahwa proses optimasi tidak hanya dipengaruhi oleh kemampuan algoritma metaheuristik dalam mengeksplorasi ruang solusi, tetapi juga oleh informasi yang digunakan untuk mengevaluasi setiap kandidat solusi selama proses pencarian.

Makna ilmiah utama dari penelitian ini terletak pada penerapan Stability-Aware Cost Function sebagai fungsi objektif yang memperluas cara mengevaluasi kualitas solusi optimasi. Integrasi classification error, error variance, dan feature ratio menunjukkan bahwa kualitas solusi tidak cukup dinilai berdasarkan tingkat kesalahan klasifikasi semata, tetapi juga perlu mempertimbangkan konsistensi performa dan efisiensi representasi fitur secara bersamaan. Dengan demikian, SACF tidak hanya berfungsi sebagai ukuran evaluasi pada akhir proses optimasi, tetapi menjadi mekanisme yang secara aktif mengarahkan eksplorasi ruang solusi menuju konfigurasi yang lebih seimbang. Perspektif ini menunjukkan bahwa perancangan fungsi objektif memiliki peran yang sama pentingnya dengan algoritma optimasi dalam menentukan kualitas solusi yang dihasilkan.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa framework yang dikembangkan mampu menghasilkan konfigurasi model yang adaptif terhadap karakteristik data dan classifier, sehingga efektivitas optimasi tidak hanya tercermin dari performa klasifikasi, tetapi juga dari kualitas proses pencarian solusi yang dibangun. Penelitian ini memberikan kontribusi metodologis melalui pengembangan framework optimasi simultan yang mengintegrasikan seleksi fitur, optimasi hiperparameter, dan evaluasi berbasis Stability-Aware Cost Function dalam satu mekanisme optimasi. Kontribusi tersebut memperluas konsep optimasi simultan dari sekadar strategi pencarian parameter

menjadi pendekatan yang mengevaluasi hubungan antarkomponen model secara terpadu, sehingga memberikan landasan bagi pengembangan metode optimasi yang lebih adaptif, efisien, dan mampu diterapkan pada berbagai permasalahan klasifikasi berbasis machine learning di masa mendatang.

B. Saran

Berdasarkan hasil penelitian dan kontribusi metodologis yang telah diperoleh, beberapa saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut.

1. Mengembangkan fungsi objektif yang lebih adaptif: Penelitian ini menggunakan *Stability-Aware Cost Function* (SACF) dengan bobot yang telah ditentukan sebelumnya. Penelitian selanjutnya dapat mengembangkan fungsi objektif yang mampu menyesuaikan bobot *classification error*, *error variance*, dan *feature ratio* secara dinamis selama proses optimasi sehingga mekanisme evaluasi solusi menjadi lebih adaptif terhadap karakteristik data dan model.
2. Memperluas ruang pencarian optimasi simultan: Optimasi dalam penelitian ini terbatas pada seleksi fitur dan hiperparameter *classifier*. Penelitian berikutnya dapat mengintegrasikan variabel keputusan lain, seperti parameter *deep feature extractor*, strategi *data augmentation*, metode *ensemble learning*, atau parameter arsitektur *deep learning*, sehingga optimasi dilakukan terhadap sistem klasifikasi secara lebih menyeluruh.
3. Mengevaluasi *framework* pada berbagai arsitektur ekstraksi fitur: Penelitian ini menggunakan MobileNetV2 sebagai *deep*

feature extractor. Pengujian menggunakan arsitektur lain, seperti EfficientNet, DenseNet, ConvNeXt, atau Vision Transformer, diperlukan untuk mengetahui konsistensi efektivitas *framework* optimasi simultan terhadap representasi fitur yang berbeda.

4. Meningkatkan cakupan evaluasi untuk menguji kemampuan generalisasi: Pengujian pada penelitian ini masih terbatas pada satu dataset klasifikasi multi-kelas citra radiologi paru. Penelitian selanjutnya disarankan mengevaluasi *framework* pada dataset multi-institusi, dataset dengan karakteristik distribusi kelas yang berbeda, maupun berbagai domain citra medis lainnya agar kemampuan generalisasi metode dapat dinilai secara lebih komprehensif.
5. Membandingkan *framework* dengan algoritma optimasi metaheuristik lainnya. Meskipun *Puma Optimizer* menunjukkan kemampuan dalam menyelesaikan optimasi simultan pada penelitian ini, evaluasi komparatif dengan algoritma metaheuristik yang lebih beragam, seperti Grey Wolf Optimizer, Harris Hawks Optimizer, Arithmetic Optimization Algorithm, atau algoritma generasi terbaru, dapat memberikan pemahaman yang lebih mendalam mengenai efektivitas dan karakteristik masing-masing metode pada permasalahan optimasi simultan.
6. Mengembangkan pendekatan optimasi simultan menuju sistem Optimasi yang lebih otomatis. Penelitian selanjutnya dapat mengintegrasikan *framework* yang dikembangkan dengan pendekatan Automated Machine Learning (AutoML), Neural Architecture Search (NAS), atau optimasi multiobjektif

sehingga proses pencarian konfigurasi model menjadi lebih otomatis, adaptif, dan mampu menangani permasalahan klasifikasi dengan tingkat kompleksitas yang lebih tinggi.



DAFTAR PUSTAKA

- Abdollahzadeh, B., & Gharehchopogh, F. S. (2022). A multi-objective optimization algorithm for feature selection problems. *Engineering with Computers*. <https://doi.org/10.1007/s00366-021-01369-9>
- Abdollahzadeh, B., Khodadadi, N., Barshandeh, S., & ... (2024). Puma optimizer (PO): a novel metaheuristic optimization algorithm and its application in machine learning. *Cluster* <https://doi.org/10.1007/s10586-023-04221-5>
- Abdollahzadeh, B., Khodadadi, N., Mirjalili, S., & Zamani, H. (2024). Puma Optimizer (PO): A novel metaheuristic optimization algorithm and its engineering applications. *Engineering Applications of Artificial Intelligence*, 127, 107321. <https://doi.org/10.1016/j.engappai.2023.107321>
- Binder, M., Moosbauer, J., Thomas, J., & Bischl, B. (2020). Multi-objective hyperparameter tuning and feature selection using filter ensembles. *Proceedings of the 2020 Genetic and Evolutionary Computation Conference*, 471–479. <https://doi.org/10.1145/3377930.3389815>
- Blank, J., & Deb, K. (2020). Pymoo: Multi-Objective Optimization in Python. *IEEE Access*, 8, 89497–89509. <https://doi.org/10.1109/ACCESS.2020.2990567>
- Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization. *ACM Computing Surveys*, 35(3), 268–308. <https://doi.org/10.1145/937503.937505>
- Bousquet, O., & Elisseeff, A. (2002). Stability and generalization. *Journal of Machine Learning Research*, 2, 499–526.
- Brady, A. P. (2017). Error and discrepancy in radiology: inevitable or avoidable? *Insights into Imaging*, 8(1), 171–182. <https://doi.org/10.1007/s13244-016-0534-1>

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>
- Chandrashekar, G., & Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1), 16–28.
<https://doi.org/10.1016/j.compeleceng.2013.11.024>
- Cleverley, J., Piper, J., & Jones, M. M. (2020). The role of chest radiography in confirming covid-19 pneumonia. *BMJ*, m2426.
<https://doi.org/10.1136/bmj.m2426>
- Cortes, C., & Vapnik, V. (1995a). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Cortes, C., & Vapnik, V. (1995b). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197.
<https://doi.org/10.1109/4235.996017>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016a). *Deep learning*. MIT Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016b). *Deep learning*. MIT Press.
- Guyon, I., & De, A. M. (2003). An Introduction to Variable and Feature Selection André Elisseeff. Dalam *Journal of Machine Learning Research* (Vol. 3).
- Houssein, E. H., Mahdy, M. A., Shebl, D., & ... (2021). A survey of metaheuristic algorithms for solving optimization problems. *Metaheuristics in* https://doi.org/10.1007/978-3-030-70542-8_21
- Jacobi, A., Chung, M., Bernheim, A., & Eber, C. (2020). Portable chest X-ray in coronavirus disease-19 (COVID-19): A pictorial

- review. *Clinical Imaging*, 64, 35–42.
<https://doi.org/10.1016/j.clinimag.2020.04.001>
- Jorge Nocedal, & Stephen J. Wright. (2006). *Numerical Optimization*. Springer New York. <https://doi.org/10.1007/978-0-387-40065-5>
- Kennedy, J., & Eberhart, R. (1997). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1942–1948.
<https://doi.org/10.1109/ICNN.1995.488968>
- Khaire, U. M., & Dhanalakshmi, R. (2022). Stability of feature selection algorithm: A review. *Journal of King Saud University - Computer and Information Sciences*, 34(4), 1060–1073.
<https://doi.org/10.1016/j.jksuci.2019.06.012>
- Khan, S. (2025). Advanced Feature Selection Techniques in Medical Imaging—A Systematic Literature Review. *Computers, Materials & Continua*, 85(2), 2347–2401.
<https://doi.org/10.32604/cmc.2025.066932>
- Li, J., Cheng, K., Wang, S., Morstatter, F., Trevino, R. P., Tang, J., & Liu, H. (2018). Feature Selection. *ACM Computing Surveys*, 50(6), 1–45. <https://doi.org/10.1145/3136625>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sanchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
<https://doi.org/10.1016/j.media.2017.07.005>
- Marler, R. T., & Arora, J. S. (2010). The weighted sum method for multi-objective optimization: new insights. *Structural and Multidisciplinary Optimization*, 41(6), 853–862.
<https://doi.org/10.1007/s00158-009-0460-7>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46–61.
<https://doi.org/10.1016/j.advengsoft.2013.12.007>

- Morales-Hernández, A., Van Nieuwenhuyse, I., & Rojas Gonzalez, S. (2023). A survey on multi-objective hyperparameter optimization algorithms for machine learning. *Artificial Intelligence Review*, 56(8), 8043–8093. <https://doi.org/10.1007/s10462-022-10359-2>
- Morid, M. A., Borjali, A., & Del Fiol, G. (2021). A scoping review of transfer learning research on medical image analysis using ImageNet. *Computers in Biology and Medicine*, 128, 104115. <https://doi.org/10.1016/j.compbiomed.2020.104115>
- Nadimi-Shahraki, M. H., Asghari Varzaneh, Z., Zamani, H., & Mirjalili, S. (2022). Binary Starling Murmuration Optimizer Algorithm to Select Effective Features from Medical Data. *Applied Sciences*, 13(1), 564. <https://doi.org/10.3390/app13010564>
- Nogueira, S., Sechidis, K., & Brown, G. (2018). On the stability of feature selection algorithms. *Journal of Machine Learning Research*, 18(174), 1–54.
- Oh, Y., Park, S., & Ye, J. C. (2020). Deep Learning COVID-19 Features on CXR Using Limited Training Data Sets. *IEEE Transactions on Medical Imaging*, 39(8), 2688–2700. <https://doi.org/10.1109/TMI.2020.2993291>
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Probst, P., Wright, M. N., & ... (2019). Hyperparameters and tuning strategies for random forest. ... *Reviews: data mining and* <https://doi.org/10.1002/widm.1301>
- Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O'Sullivan, J. M. (2022). A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction. *Frontiers in Bioinformatics*, 2. <https://doi.org/10.3389/fbinf.2022.927312>
- Rajaraman, S., Guo, P., Xue, Z., & Antani, S. K. (2022). A Deep Modality-Specific Ensemble for Improving Pneumonia Detection

- in Chest X-rays. *Diagnostics*, 12(6), 1442.
<https://doi.org/10.3390/diagnostics12061442>
- Rostami, M., Berahmand, K., Nasiri, E., & Forouzandeh, S. (2021). Review of swarm intelligence-based feature selection methods. *Engineering Applications of Artificial Intelligence*, 100, 104210.
<https://doi.org/10.1016/j.engappai.2021.104210>
- Rubin, G. D., Ryerson, C. J., Haramati, L. B., Sverzellati, N., Kanne, J. P., Raoof, S., Schluger, N. W., Volpi, A., Yim, J.-J., Martin, I. B. K., Anderson, D. J., Kong, C., Altes, T., Bush, A., Desai, S. R., Goldin, onathan, Goo, J. M., Humbert, M., Inoue, Y., ... Leung, A. N. (2020). The Role of Chest Imaging in Patient Management during the COVID-19 Pandemic: A Multinational Consensus Statement from the Fleischner Society. *Radiology*, 296(1), 172–180. <https://doi.org/10.1148/radiol.2020201365>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510–4520.
<https://doi.org/10.1109/CVPR.2018.00474>
- Schneider, L., Bischl, B., & Thomas, J. (2023). Multi-Objective Optimization of Performance and Interpretability of Tabular Supervised Machine Learning Models. *GECCO 2023 - Proceedings of the 2023 Genetic and Evolutionary Computation Conference*, 538–547. <https://doi.org/10.1145/3583131.3590380>
- Talbi, E.-G. (2009). *Metaheuristics: From Design to Implementation*. John Wiley & Sons.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). *A Survey on Deep Transfer Learning* (hlm. 270–279).
https://doi.org/10.1007/978-3-030-01424-7_27
- Theng, D., & Bhoyar, K. K. (2024). Feature selection techniques for machine learning: a survey of more than two decades of research. *Knowledge and Information Systems*, 66(3), 1575–1637.
<https://doi.org/10.1007/s10115-023-02010-5>

- Tijjani, S., Ab Wahab, M. N., & Mohd Noor, M. H. (2024). An enhanced particle swarm optimization with position update for optimal feature selection. *Expert Systems with Applications*, 247, 123337. <https://doi.org/10.1016/j.eswa.2024.123337>
- World Health Organization. (2024). Global tuberculosis report 2024. Dalam *World Health Organization*.
- Xue, B., Zhang, M., Browne, W. N., & Yao, X. (2016). A Survey on Evolutionary Computation Approaches to Feature Selection. *IEEE Transactions on Evolutionary Computation*, 20(4), 606–626. <https://doi.org/10.1109/TEVC.2015.2504420>
- Yang, X.-S. (2020). Nature-inspired optimization algorithms: Challenges and open problems. *Journal of Computational Science*, 46, 101104. <https://doi.org/10.1016/j.jocs.2020.101104>

