

OPTIMASI ALGORITMA *RANDOM FOREST* MENGGUNAKAN *PSO* UNTUK KLASIFIKASI KANKER PAYUDARA DENGAN CITRA *MAMMOGRAMS*

¹Alfreda Cecio Salwa Alexita, ²Pramesti Kusumaningtyas, ³Mohammad Rofi'i

¹Jurusan Teknik Elektromedis
Sekolah Tinggi Ilmu Kesehatan Semarang
alfredaalexita12@gmail.com

²Jurusan Teknik Elektromedis
Sekolah Tinggi Ilmu Kesehatan Semarang
pramesti@stikessemarang.ac.id

³Jurusan Teknik Elektromedis
Sekolah Tinggi Ilmu Kesehatan Semarang
mrofiti@stikessemarang.ac.id

Article history:

Received 30th of January 2025

Revised 10th of February 2025

Accepted 12th of February 2025

Abstract

This research focuses on improving breast cancer classification through a combination of Random Forest and Particle Swarm Optimization (PSO) algorithms. Being the most common cancer among women worldwide, breast cancer requires an effective diagnostic screening method. Traditional methods such as manual examination and x-ray imaging are time-consuming and prone to errors. This research applies machine learning techniques, specifically Random Forest, for image classification based on mammograms. The methodology involves data collection, image preprocessing (including image resize, grayscale, and image segmentation using Sobel Edge Detection and Adaptive Thresholding), feature extraction via Local Binary Pattern (LBP), and classification via Random Forest optimized with PSO. PSO helps to identify the optimal hyperparameters and improves the accuracy of the Random Forest model. Model evaluation is done using confusion matrix which includes accuracy, precision, and recall values. The testing experiment showed that the PSO-optimized Random Forest model achieved an accuracy of 88.37%, outperforming the standard Random Forest model which achieved 86.05%. This shows that PSO significantly improves classification accuracy. This research contributes to the development of an easy-to-use diagnostic tool to assist specialists in accurately identifying breast cancer stages, and suggests future investigations should incorporate additional machine learning algorithms and utilize higher-standard DICOM images to improve training and testing data.

Keywords: Breast Cancer, Random Forest, PSO

Pendahuluan

Kanker payudara di banyak negara merupakan kanker yang paling sering terjadi di dunia khususnya bagi kaum wanita[1]. Berdasarkan data dari *Global Cancer Observatory (Globocan)* tahun 2020, tercatat 68.858 kasus baru kanker payudara, yang menyumbang 16,6% dari total 396.914 kasus kanker baru di Indonesia. Angka ini menunjukkan kanker payudara menjadi penyebab utama kanker pada perempuan di Indonesia[2]. Menurut para ahli medis, sel-sel abnormal yang tidak terkendali di payudara menjadi penyebab penyakit kanker payudara. Jika terdeteksi tumor, yang pertama akan dilakukan oleh dokter adalah menentukan apakah pertumbuhannya masih dalam stadium rendah atau sudah cukup tinggi[3]. Salah satu metode yang dapat digunakan untuk mendeteksi kanker payudara adalah menggunakan *x-ray* untuk mengambil gambar *mammograms*. Pemeriksaan secara manual seperti ini membutuhkan waktu yang relatif lama dan seorang ahli yang kompeten. Selain itu, ada kemungkinan para ahli pun masih membuat kesalahan dalam melakukan pemeriksaan citra tersebut[4]. Penelitian tentang proses klasifikasi kanker payudara semakin meningkat seiring dengan kemajuan model pembelajaran *machine learning* dan *deep learning*. Proses ini dilakukan dengan mengobservasi pola gambar tertentu untuk memastikan apakah sel-sel yang menyebabkan kanker ada atau tidak pada jaringan tubuh[5]. Berbagai metode kecerdasan buatan yang digunakan dalam deteksi kanker payudara antara lain adalah dengan *Logitboost*, *Bagging*, *KNN* dan *random forest* dan algoritma *Random Forest* terbukti menghasilkan nilai akurasi yang tinggi diantara beberapa metode tersebut[1] [6].

Algoritma *Random Forest* menggunakan pendekatan yang melibatkan penggabungan berbagai prediksi dari banyak pohon keputusan sehingga menghasilkan hasil yang akurat dan stabil. Setiap pohon keputusan terbentuk secara independen dengan sample acak dari data pelatihan dan subset acak dari fitur, kemudian hasil dari setiap pohon digabungkan dan disimpulkan menggunakan hasil suara terbanyak[6]. Algoritma *Random Forest* memiliki kemampuan untuk menangani data dengan dimensi tinggi dan dapat mengurangi overfitting pada model[7]. Meskipun bekerja baik dengan

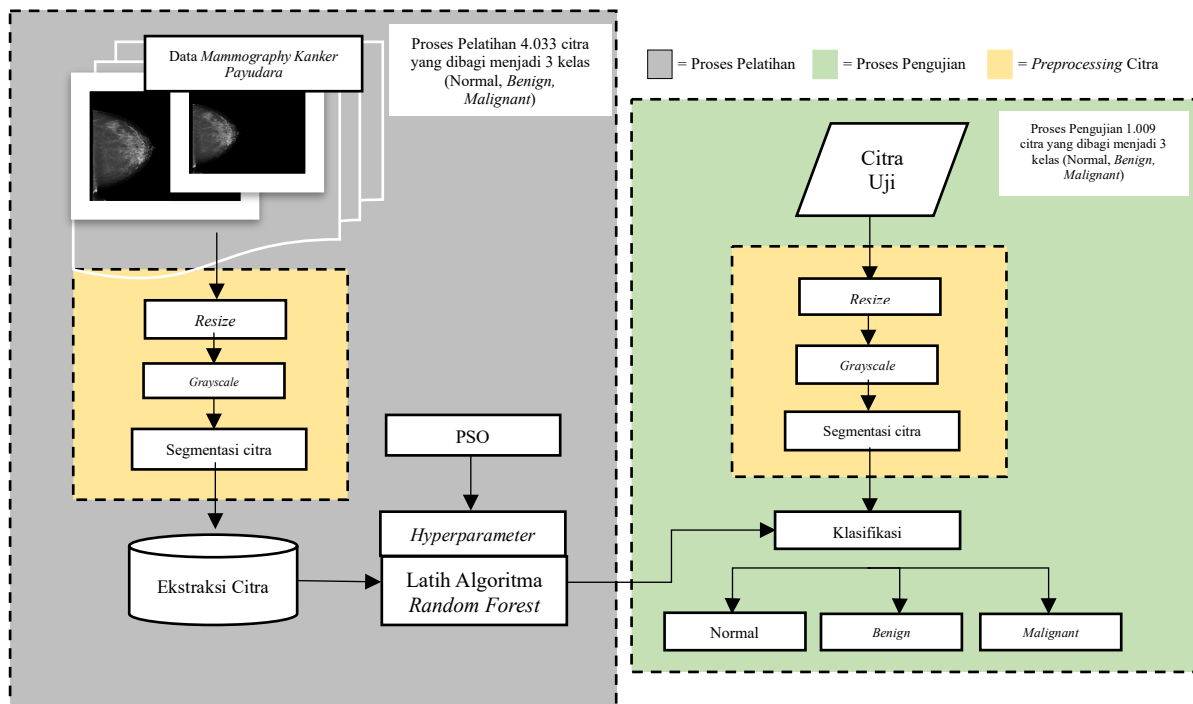
banyak fitur, *Random Forest* bisa mengalami penurunan efisiensi pada dataset dengan dimensi yang sangat tinggi jika tidak dilakukan tuning *hyperparameter* yang tepat. Kinerja *Random Forest* sangat bergantung pada pemilihan *hyperparameter* seperti jumlah pohon dalam hutan ($n_estimators$), kedalaman maksimum pohon (max_depth), dan jumlah fitur yang dipilih untuk pemisahan di setiap node ($max_features$). Pemilihan nilai *hyperparameter* yang tidak optimal dapat mengakibatkan kinerja model yang kurang maksimal[8] [9] [10].

Salah satu pendekatan yang digunakan untuk mengoptimalkan *hyperparameter Random Forest* adalah dengan menggunakan algoritma optimasi metaheuristik, salah satunya adalah *Particle Swarm Optimization (PSO)*[11]. *PSO* merupakan algoritma optimasi berbasis populasi yang meniru perilaku kawanan dalam mencari solusi terbaik di ruang pencarian[12]. *PSO* telah terbukti efektif dalam berbagai bidang optimasi, termasuk pemilihan *hyperparameter* pada model pembelajaran mesin[13] [14] [15]. Optimasi *hyperparameter* dengan *PSO* bekerja dengan merepresentasikan setiap partikel sebagai sekumpulan nilai *hyperparameter Random Forest* yang dievaluasi berdasarkan kriteria tertentu, seperti akurasi atau nilai kesalahan prediksi. Dengan mekanisme eksplorasi dan eksploitasi yang dimiliki *PSO*, partikel-partikel tersebut akan bergerak menuju solusi optimal berdasarkan pengalaman individu maupun kolektif dalam populasi. Dengan demikian, *PSO* dapat membantu dalam menemukan kombinasi *hyperparameter* terbaik tanpa harus melakukan pencarian secara *brute-force* yang memerlukan komputasi tinggi[16] [17].

Fokus dari penelitian ini adalah mengimplementasikan algoritma *Random Forest* yang dioptimasi dengan *PSO* untuk klasifikasi kanker payudara menggunakan citra *mammograms*. Beberapa metode segmentasi dan ekstraksi fitur yang telah dipilih dan digabungkan dengan menggunakan *PSO* ini untuk pengambilan gambar yang lebih baik serta lebih efisien dari basis data gambar[18]. Diharapkan dapat membantu dokter spesialis untuk meminimalisir kesalahan pembacaan hasil citra dalam identifikasi tingkatan kanker payudara yang dideteksi secara akurat.

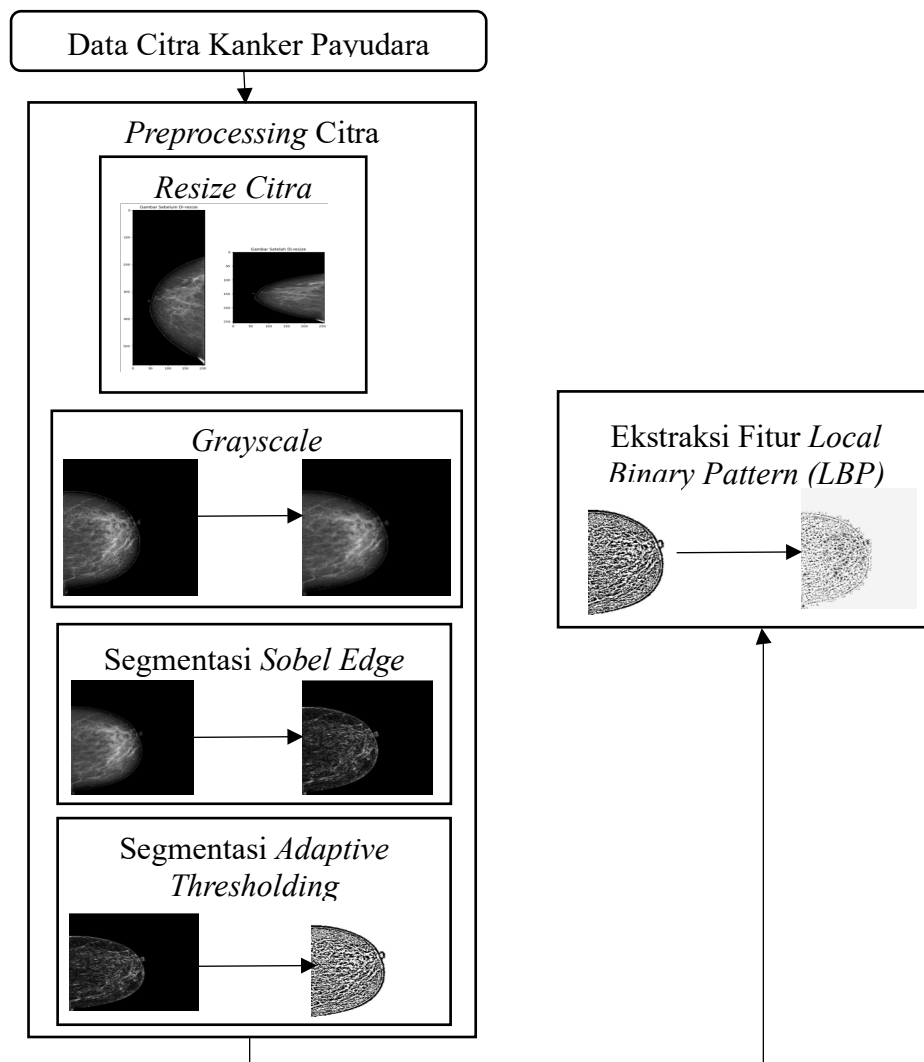
Metode Penelitian

Penelitian ini melalui beberapa tahapan yang meliputi pengumpulan data, *preprocessing* citra, penerapan model algoritma *Random Forest* yang dioptimasi dengan *PSO*, identifikasi hasil klasifikasi, dan evaluasi nilai akurasi. Tahapan penelitian diuraikan pada Bagan 1 dibawah ini.



Bagan 1. Tahapan Penelitian

Penelitian ini terdiri dua proses yaitu proses pelatihan (*training*) seperti pada Bagan 1. berwarna abu-abu dan proses pengujian (*testing*) seperti pada Bagan 1. berwarna hijau. Tentunya kedua proses ini perlu dilakukan pengumpulan *dataset* citra *mammography* kanker payudara. Pengumpulan data untuk penelitian ini menggunakan akses *website Kaggle* dengan sumber <https://www.kaggle.com/datasets/tranthiphuongngan/newdatasetmamogram>. *Dataset* yang dikumpulkan sebanyak 646 berisikan citra *mammography* penyakit kanker payudara dengan pembagian kelas 226 citra normal, 225 citra *benign* (jinak), 195 citra *malignant* (ganas). Pengolahan citra kanker payudara melalui tahapan *preprocessing* citra, ekstraksi ciri, dan klasifikasi. Tahapan tersebut dapat dilihat pada Bagan 2.



Bagan 2. Pengolahan Citra

Tahapan *preprocessing* citra ini meliputi tiga proses inti pengolahan citra yaitu dimulai dengan (1) proses *resize* citra yakni menormalisasikan citra secara keseluruhan ke ukuran 256 x 256 piksel, selanjutnya (2) proses mengubah citra menjadi skala keabuan (*grayscale*). Dimana citra ini menunjukkan derajat keabuan, warna hitam memiliki intensitas paling rendah sedangkan warna putih memiliki intensitas paling tinggi[19]. Kemudian (3) dilakukan proses segmentasi citra. Metode segmentasi citra yang dipilih adalah *Sobel Edge Detection* dan *Adaptive Thresholding*.

Metode segmentasi *Sobel Edge Detection* atau penentuan tepian suatu objek dalam citra merupakan proses untuk mengenali objek-objek bagian tepi citra secara keseluruhan[20]. Adapun proses segmentasi selanjutnya berupa metode *Adaptive Thresholding* yang merupakan metode segmentasi citra dimana membedakan objek dari latar belakang berdasarkan tingkat kecerahannya atau gelap terangnya[21]. Metode ini menghasilkan citra biner dengan nilai intensitas piksel sebesar 0 dan 1, yang menghasilkan citra kanker tanpa background, seperti yang ditunjukkan pada Bagan 2.

Setelah dilakukan proses segmentasi citra, citra gambar mulai dilakukan ekstraksi fitur. Ekstraksi fitur merupakan langkah yang penting untuk membedakan tekstur makrostruktur (perulangan periodik pada pola lokal)[22]. Metode ekstraksi fitur *Local Binary Pattern (LBP)* memiliki daya pembeda yang jelas serta memiliki toleransi terhadap perubahan *grayscale* yang *monotatic* sehingga efektif dalam mendeskripsikan tekstur. *Local Binary Pattern (LBP)* lebih sering digunakan dalam pengolahan citra digital dibandingkan metode lainnya[23].

Jika semua proses pengolahan citra telah selesai dilakukan, maka data citra akan diseleksi dengan menerapkan algoritma *Random Forest*. Algoritma *Random Forest* juga dikenal sebagai Pohon Acak, merupakan metode pembelajaran mesin populer dalam *machine learning* yang dikembangkan oleh Leo Breiman dan Adele Cutler[24]. *Random forest* terdiri dari sekumpulan Decision tree yang telah dilakukan training menggunakan varian yang berbeda, dan setiap karakter dibagi menjadi tree/pohon yang dipilih dari subset atribut secara acak[25]. Parameter tiap pohon nya mencakup (1) jumlah pohon (*n_estimators*) yaitu jumlah total pohon keputusan yang akan dibangun. (2) maksimum kedalaman (*max_depth*) yaitu batas kedalaman maksimum untuk setiap pohon yang dapat membantu mengontrol *overfitting*. (3) jumlah fitur yang dipilih (*max_features*) yaitu jumlah fitur yang akan dipertimbangkan saat mencari split terbaik di setiap node[26].

Tiap pohon akan menghasilkan nilai terbaik untuk parameter, hal ini ditentukan secara otomatis dengan pendekatan optimasi *Particle Swarm Optimization (PSO)* dengan pemilihan fitur segmentasi dan ekstrasi citra yang dipilih[18]. Terdapat beberapa komponen pada algoritma *PSO*, antara lain *Personal Best (pbest)* dan *Global Best (gbest)*[27]. Dalam *Global Best PSO (gbest)*, segerombolan partikel yang bergerak melalui ruang pencarian multidimensi akan menyesuaikan posisi dan kecepatannya berdasarkan posisi terbaik bagi mereka sendiri (posisi terbaik pribadi) dan posisi terbaik bagi seluruh segerombolan (posisi terbaik global). Sedangkan *Personal Best (pbest)* merupakan segerombolan partikel yang mencapai posisi terbaik dengan membandingkan nilai fitness pada posisi partikel saat ini dengan sebelumnya[28]. Adapun *pseudo-code* sebagai struktur umum algoritma *PSO* ditunjukkan pada Gambar 1.

```

procedure AlgoritmaPSO
begin
  t = 0
  inisialisasi posisi partikel ( $x_{i,j}^t$ ), kecepatan ( $v_{i,j}^t$ ),  $Pbest_{i,j}^t = x_{i,j}^t$ ,
  hitung fitness tiap partikel, dan  $Gbest_{g,j}^t$ 
  do
    t = t + 1
    update kecepatan  $v_{i,j}(t)$ 
    update posisi  $x_{i,j}(t)$ 
    hitung fitness tiap partikel
    update  $Pbest_{i,j}(t)$  dan  $Gbest_{g,j}(t)$ 
  while (bukan kondisi berhenti)
end

```

Gambar 1. Pseudo-code Algoritma PSO

Sumber : I. Cholissodin and E. Riyandani, “Buku Ajar Swarm Intelligence,” no. June, pp. 1–198, 2016.

Pengujian model dievaluasi dengan menghitung akurasi hasil. Perhitungan akurasi dengan *confusion matrix* didapatkan menggunakan persamaan sebagai berikut.

$$Akurasi = \frac{(True\ Positif + True\ Negatif)}{Jumlah\ Data} \dots\dots\dots(1)$$

$$Presisi = \frac{True\ Positif}{(True\ Positif + False\ Positive)} \dots\dots\dots(2)$$

$$Recall = \frac{True\ Positif}{(True\ Positif + False\ Negative)} \dots\dots\dots(3)$$

$$Spesifisitas = \frac{True\ Negatif}{(True\ Positif + False\ Positive)} \dots\dots\dots(4)$$

$$F1 - Score = 2 \times \frac{presisi \times recall}{presisi + recall} \dots\dots\dots(5)$$

Dimana, TP didefinisikan sebagai positif, data diprediksi menjadi positif dan TN didefinisikan sebagai negatif, data diprediksi menjadi negatif. Sedangkan FN kebalikan dari TP yaitu data positif diprediksi negatif dan FP berlawanan dengan TN data negatif diprediksi positif[29].

Hasil dan Pembahasan

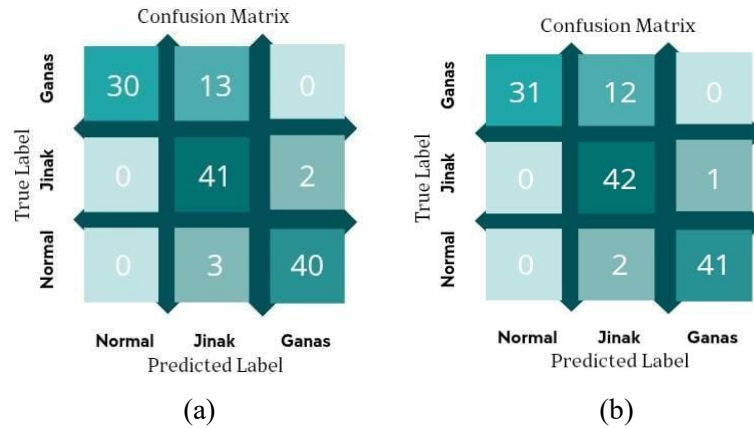
Algoritma *Random Forest* diterapkan pada data citra yang telah melewati pengolahan praproses. Dari beberapa pemilihan fitur dan kombinasi fitur-fitur yang terpilih seperti fitur yang diekstraksi menggunakan fitur segmentasi pengembangan dan ekstraksi fitur tekstur ini dioptimalkan menggunakan teknik optimasi berupa *Particle Swarm Optimization (PSO)*.

```
param_grid = {
    'n_estimators': [50, 100, 200, 300],
    'max_depth': [None, 10, 20, 30, 40],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'bootstrap': [True, False]
}
```

Gambar 2. Penerapan Model *Random Forest*

Parameter yang digunakan untuk penerapan model *Random Forest* pada Gambar 2. meliputi *n_estimators*, *max_depth*, *min_samples_split*, *min_samples_leaf*, dan *bootstrap*. Masing-masing parameter tersebut memiliki value yang akan diuji, dimana *n_estimators* akan menguji jumlah pohon sebesar 50, 100, 200, dan 300. Lalu, *max_depth* akan mengukur kedalaman maksimum pohon sebesar 10, 20, 30, dan 40. Kemudian, *min_samples_split* akan mengukur jumlah sample minimum yang diperlukan untuk membagi node internal sebesar 2, 5, dan 10. Selanjutnya, *min_samples_leaf* akan mengukur jumlah sampel minimum untuk berada di simpul daun dengan nilai 1, 2, dan 4. Adapun *bootstrap* ini menentukan apakah sampel *bootstrap* digunakan saat membangun pohon. Jika salah, seluruh kumpulan data digunakan untuk membangun setiap pohon.

Setelah ditemukannya model *Random Forest* yang memiliki parameter optimal, model *random forest* tersebut akan menghasilkan identifikasi citra. Identifikasi citra inilah yang akan menghasilkan klasifikasi tingkatan kanker payudara pada data pengujian (*testing*) berdasarkan *database* yang telah dibuat dari hasil data pelatihan (*training*). Hasil dari identifikasi citra menggunakan optimasi *Particle Swarm Optimization (PSO)* maupun hanya *Random Forest* saja akan disajikan dalam bentuk *confusion matrix* seperti pada Gambar 3.



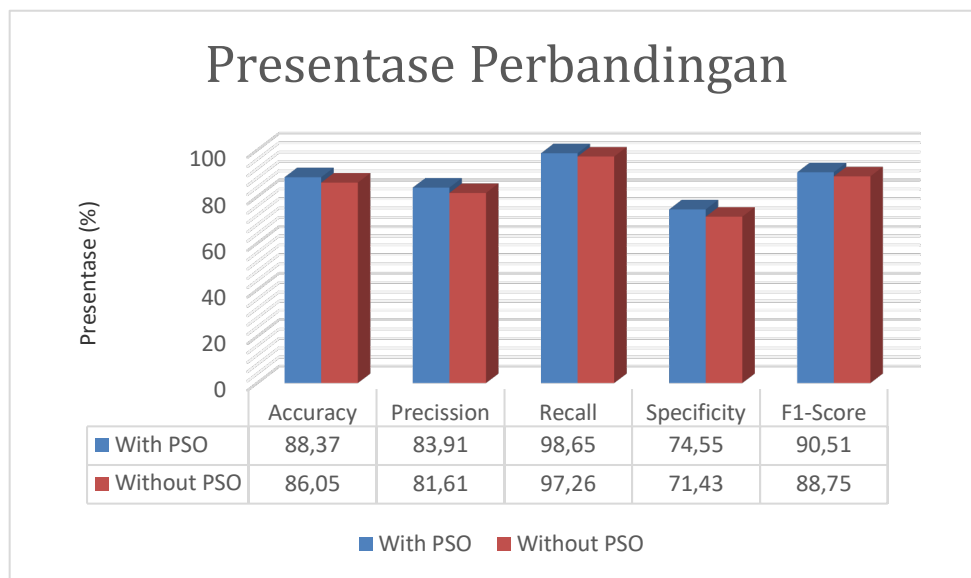
Gambar 3. Confusion Matrix (a) RF + PSO (b) RF tanpa PSO

Berdasarkan Gambar 3 diatas maka didapatkan nilai dari *true positive* (TP), *false positive* (FP), *false negative* (FN) dan *true negative* (TN). Dengan nilai tersebut dapat menentukan tingkat akurasi program baik menggunakan *Particle Swarm Optimization* (PSO) maupun hanya *Random Forest*. Nilai tersebut akan disajikan pada Gambar 4.

Matrix Evaluasi		Matrix Evaluasi	
TP = 73	FP = 14	TP = 71	FP = 16
TN = 41	FN = 1	TN = 40	FN = 2

Gambar 4. Matrix Evaluasi (a) RF + PSO (b) RF tanpa PSO

Sehingga setelah didapatkan hasil dari klasifikasi dari masing-masing algoritma, maka dapat dibandingkan keakuratan pengujian algoritma *Random Forest* menggunakan *Particle Swarm Optimization* dengan hanya *Random Forest* saja seperti pada Grafik 1.



Grafik 1. Presentase Perbandingan PSO-RF dan RF

Hasil dari pemodelan dengan menggunakan algoritma *Random Forest* terhadap fitur yang telah dioptimasi oleh *Particle Swarm Optimization* (PSO) menunjukkan bahwa hasil akurasi pada model *Random Forest* yang dioptimasi PSO lebih baik dan akurat dengan nilai akurasi sebesar 88,37%, precision 83,91%, recall 98,65%, specificity 74,55%, dan f1-score 90,51%. Sedangkan, nilai akurasi yang hanya menggunakan algoritma *Random Forest* saja menghasilkan nilai akurasi sebesar 86,05%,

precision 81,61% recall 97,26%, specificity 71,43%, dan f1-score 88,75%.

Kesimpulan

Penelitian ini berhasil merancang aplikasi website citra *mammograms* menggunakan algoritma *Random Forest* yang dioptimasi dengan *Particle Swarm Optimization (PSO)* sebagai klasifikasi tingkatan penyakit kanker payudara. Model *PSO-RF* ini menghasilkan nilai akurasi sebesar 88,37%. Setelah itu, hasil model *Random Forest* ini dibandingkan dengan tanpa menggunakan optimasi *PSO* menghasilkan nilai akurasi 86,05% dan menunjukkan bahwa metode *PSO-RF* ini mengungguli nilai tingkat keakurasian. Dapat dibuktikan bahwa penggunaannya mudah digunakan, serta lebih efisien dalam mengoptimasikan data citra dalam jumlah banyak.

Dari penelitian yang telah dilakukan, ada beberapa saran untuk pengembangan dalam penelitian selanjutnya, yaitu terdapat penambahan algoritma *machine learning* sebagai pembanding tingkat keakurasian dalam pengklasifikasian dan dilakukan proses lebih lanjut menggunakan data citra asli yang berstandar *DICOM (Digital Imaging and Communications in Medicine)* sebagai input data citra baik data *training* maupun data uji.

Daftar Pustaka

- [1] V. Angkasa and J. J. Pangaribuan, "Information System Development Komparasi Tingkat Akurasi Random Forest Dan Knn Untuk Mendiagnosis Penyakit Kanker Payudara," *J. Inf. Syst. Dev.*, vol. 7, no. 1, pp. 37–38, 2022, [Online]. Available: <http://dx.doi.org/10.19166/xxxx>
- [2] A. Maresa, M. Riski, and S. Ismed, "Hubungan sikap dan keterpaparan informasi dengan pengetahuan remaja putri tentang kanker payudara," *J. 'Aisyiyah Palembang*, vol. 8, no. 1, pp. 233–243, 2023.
- [3] S. Łukasiewicz, M. Czezelewski, A. Forma, J. Baj, R. Sitarz, and A. Stanislawek, "Łukasiewicz.Pdf," *Cancers (Basel)*, vol. 13, p. 4287, 2021.
- [4] H. Soekersi, Y. Azhar, and K. S. Akbari, "Peran Mammografi Untuk Skrining Kanker Payudara: Sebuah Tinjauan Pustaka," *J. Indones. Med. Assoc.*, vol. 72, no. 3, pp. 144–150, 2022, doi: 10.47830/jinma-vol.72.3-2022-627.
- [5] V. R. Allugunti, "Breast cancer detection based on thermographic images using machine learning and deep learning algorithms," *Int. J. Eng. Comput. Sci.*, vol. 4, no. 1, pp. 49–56, 2022, doi: 10.33545/26633582.2022.v4.i1a.68.
- [6] P. Palimkar, R. N. Shaw, and A. Ghosh, "Machine Learning Technique to Prognosis Diabetes Disease: Random Forest Classifier Approach," *Lect. Notes Networks Syst.*, vol. 218, pp. 219–244, 2022, doi: 10.1007/978-981-16-2164-2_19.
- [7] J. Ddos and H. W. Aripardono, "JTIM : Jurnal Teknologi Informasi dan Multimedia Perbandingan Support Vector Machine , Random Forest Classifier , dan K-Nearest Neighbour dalam Pendeteksian Anomali," vol. 7, no. 1, pp. 23–33, 2025.
- [8] C. J. K. Fouodo, L. L. Kronziel, I. R. König, and S. Szymczak, "Effect of hyperparameters on variable selection in random forests," pp. 1–20, 2023, [Online]. Available: <https://arxiv.org/pdf/2309.06943.pdf>
- [9] P. Probst, M. N. Wright, and A. L. Boulesteix, "Hyperparameters and tuning strategies for random forest," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 9, no. 3, p. e1301, May 2019, doi: 10.1002/WIDM.1301.
- [10] Nursalman and Mustikasari, "Pengaruh Penyetelan Hyperparameter Terhadap Kinerja Prediksi Random Forest pada Pendeteksian Spam," 2020.
- [11] N. Zhu, C. Zhu, L. Zhou, Y. Zhu, and X. Zhang, "Optimization of the Random Forest Hyperparameters for Power Industrial Control Systems Intrusion Detection Using an Improved Grid Search Algorithm," *Appl. Sci.*, vol. 12, no. 20, 2022, doi: 10.3390/app122010456.
- [12] O. Pahlevi, "JITE (Journal of Informatics and Telecommunication Engineering) Data Mining Optimization Based on Particle Swarm Optimization For Diagnosis of Inflammatory Liver Disease," *Jite*, vol. 5, no. 1, pp. 152–159, 2021, [Online]. Available: <http://ojs.uma.ac.id/index.php/jite>
- [13] P. R. Lorenzo, J. Nalepa, M. Kawulok, L. S. Ramos, and J. R. Pastor, "Particle swarm optimization for hyperparameter selection in deep neural networks," *GECCO 2017 - Proc. 2017 Genet. Evol. Comput. Conf.*, pp. 481–488, Jul. 2017, doi: 10.1145/3071178.3071208/SUPPL_FILE/P481-RIBALTA_LORENZO.ZIP.
- [14] M. Tayebi and S. El Kadhali, "Deep Neural Networks Hyperparameter Optimization Using Particle Swarm Optimization for Detecting Frauds Transactions," pp. 507–516, 2022, doi: 10.1007/978-981-16-5559-3_42.
- [15] Y. Li and Y. Zhang, "Hyper-parameter estimation method with particle swarm optimization," 2020, [Online]. Available: <http://arxiv.org/abs/2011.11944>
- [16] M. G. El-Shafiey, A. Hagag, E. S. A. El-Dahshan, and M. A. Ismail, "A hybrid GA and PSO optimized approach

- for heart-disease prediction based on random forest,” *Multimed. Tools Appl.*, vol. 81, no. 13, pp. 18155–18179, 2022, doi: 10.1007/s11042-022-12425-x.
- [17] A. J. Malik, W. Shahzad, and F. A. Khan, “Network intrusion detection using hybrid binary PSO and random forests algorithm,” *Secur. Commun. Networks*, vol. 8, no. 16, pp. 2646–2660, Nov. 2015, doi: 10.1002/SEC.508.
- [18] M. Subramanian, V. Lingamuthu, C. Venkatesan, and S. Perumal, “Content-Based Image Retrieval Using Colour, Gray, Advanced Texture, Shape Features, and Random Forest Classifier with Optimized Particle Swarm Optimization,” *Int. J. Biomed. Imaging*, vol. 2022, 2022, doi: 10.1155/2022/3211793.
- [19] Asiva Noor Rachmayani, *No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title*. 2015.
- [20] M. Yunus, “Perbandingan Metode-Metode Edge Detection Untuk Proses Segmentasi Citra Digital,” *J. Teknol. Inf.*, pp. 146–160, 2012, doi: 10.36382/jti-tki.v3i2.110.
- [21] M. Orisa and T. Hidayat, “Analisis Teknik Segmentasi Pada Pengolahan Citra,” *J. Mnemon.*, vol. 2, no. 2, pp. 9–13, 2019, doi: 10.36040/mnemonic.v2i2.84.
- [22] A. T. Lodong, A. W. Widodo, and M. A. Rahman, “Penentuan Mutu pada Citra Buah Jeruk Keprok menggunakan Metode Local Binary Pattern (LBP),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, pp. 1616–1622, 2023.
- [23] D. Retnoningrum, A. W. Widodo, and M. A. Rahman, “Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binary Pattern (LBP),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2611–2618, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [24] Z. Jin, J. Shang, Q. Zhu, C. Ling, W. Xie, and B. Qiang, “RFRSF: Employee Turnover Prediction Based on Random Forests and Survival Analysis,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12343 LNCS, pp. 503–515, 2020, doi: 10.1007/978-3-030-62008-0_35.
- [25] A. Fauzi, R. Supriyadi, and N. Maulidah, “Deteksi Penyakit Kanker Payudara dengan Seleksi Fitur berbasis Principal Component Analysis dan Random Forest,” *J. Infortech*, vol. 2, no. 1, pp. 96–101, 2020, doi: 10.31294/infortech.v2i1.8079.
- [26] H. Akbar, “Pengembangan Framework Kankernet Berdasarkan Convolutional Neural Networks Dan Model Pso Untuk Penyakit Kanker Serviks,” *Digilib.Esaunggul.Ac.Id*, 2021, [Online]. Available: https://digilib.esaunggul.ac.id/public/UEU-Research-23648-16_0893.pdf
- [27] I. Cholissodin and E. Riyandani, “Buku Ajar Swarm Intelligence,” no. June, pp. 1–198, 2016.
- [28] A. M. Rizki and A. L. Nurlaili, “Algoritme Particle Swarm Optimization (PSO) untuk Optimasi Perencanaan Produksi Agregat Multi-Site pada Industri Tekstil Rumahan,” *J. Comput. Electron. Telecommun.*, vol. 1, no. 2, pp. 1–9, 2021, doi: 10.52435/complete.v1i2.73.
- [29] S. Naufalrifqi, “Optimasi Random Forest Untuk Diagnosis Penyakit Ginjal Kronik Dengan Menggunakan Particle Swarm Optimization,” *Senamika*, pp. 393–400, 2022, [Online]. Available: <https://conference.upnvj.ac.id/index.php/senamika/article/view/2185%0Ahttps://conference.upnvj.ac.id/index.php/senamika/article/download/2185/1671>