

Hierarchical Ensemble Learning untuk Klasifikasi Tumor Payudara pada Citra Ultrasonografi (USG)

Rahmad Hidayat^{1*}, Muhammad Davi¹, Hanafi²

¹Jurusan Teknologi Informasi dan Komputer Politeknik Negeri Lhokseumawe
Jln. B.Aceh Medan Km.280 Buketrata 24301 INDONESIA

Corresponding author : *rahmad_hidayat@pnl.ac.id

²Jurusan Teknik Elektro Politeknik Negeri Lhokseumawe
Jln. B.Aceh Medan Km.280 Buketrata 24301 INDONESIA

Abstrak— Kanker payudara merupakan jenis kanker yang menempati urutan pertama terbanyak di Indonesia, sekaligus sebagai penyumbang kematian akibat kanker tertinggi. Berdasarkan data Globocan tahun 2020, jumlah kasus baru kanker payudara mencapai 68.858 kasus (16,6%) dari total 396.914 kasus baru kanker di Indonesia. Sementara itu, untuk jumlah kematiannya mencapai lebih dari 22 ribu jiwa kasus. Deteksi dini merupakan salah satu faktor penting yang dapat mengurangi rasio mortalitas pasien sampai dengan 43%. Pada tahun 2023, menggunakan dana DIPA PNL pengusul telah melakukan penelitian yang mengembangkan model untuk mendeteksi kanker payudara pada citra Ultrasonografi (USG). Model yang dikembangkan pada penelitian tersebut melakukan ekstraksi fitur tekstur yaitu Gabor dan GLCM (Gray Level Co-occurrence Matrix) dari citra USG payudara. Berdasarkan hasil pengujian didapatkan akurasi sebesar 0.67 (training) dan 0.66 (validasi). sementara itu, loss yang didapat adalah sebesar 0.77 saat training dan 0.84 saat validasi. Akurasi yang didapat pada model tersebut dipandang belum memuaskan sehingga diperlukan pengembangan lebih lanjut. Pada usulan penelitian ini, pengusul mengembangkan model yang melatih beberapa klasifier yaitu Support Vector Machine (SVM), Naïve Bayes, dan Random Forest. Hasil klasifikasi pada satu arsitektur kemudian diinputkan pada klasifier berikutnya secara hierarkis. Hasil akurasi yang didapatkan setelah menambahkan tahapan ensemble meningkat yaitu sebesar 0,96 dan AUC sebesar 0,94.

Kata kunci— kanker payudara, ultrasonografi, machine learning, klasifikasi, ensemble;

Abstract— Breast cancer is the most common type of cancer in Indonesia, as well as the highest contributor to cancer deaths. Based on the 2020 Globocan data, the number of new cases of breast cancer reached 68,858 cases (16.6%) of the total 396,914 new cases of cancer in Indonesia. Meanwhile, the number of deaths reached more than 22 thousand cases. Early detection is an essential factor that can reduce the patient mortality ratio by up to 43%. In 2023, using DIPA PNL funds, the proposer conducted research that developed a model to detect breast cancer in Ultrasonography (USG) images. The model developed in the study extracted texture features, namely Gabor and GLCM (Gray Level Co-occurrence Matrix), from breast ultrasound images. Based on the test results, an accuracy of 0.67 (training) and 0.66 (validation) was obtained. Meanwhile, the loss obtained was 0.77 during training and 0.84 during validation. The accuracy obtained in the model is considered unsatisfactory, so that further development is needed. In this research proposal, the proposer develops a model that trains several classifiers, namely Support Vector Machine (SVM), Naïve Bayes, and Random Forest. The classification results on one architecture are then inputted into the next classifier hierarchically. The accuracy results obtained after adding the ensemble stage increased by 0.96 and AUC by 0.94.

Keywords— breast cancer, ultrasonografi, machine learning, classification, ensemble;

I. PENDAHULUAN

Kanker payudara adalah suatu jenis tumor ganas yang berkembang pada sel-sel payudara. Kanker ini dapat tumbuh jika terjadi pertumbuhan yang abnormal dari sel-sel pada payudara. Sel-sel tersebut membelah diri lebih cepat dari sel normal dan berakumulasi, yang kemudian membentuk benjolan atau massa. Berdasarkan data Globocan tahun 2020, jumlah kasus baru kanker payudara mencapai 68.858 kasus (16,6%) dari total 396.914 kasus baru kanker di Indonesia [1]. Menurut data terakhir WHO, angka kematian karena kanker payudara di Indonesia mencapai 1,41% dari seluruh kematian atau angka kematian disesuaikan dengan usia adalah 2.025 per 100.000 penduduk [2]. Tingginya angka kanker payudara di Indonesia menjadi prioritas penanganan oleh pemerintah.

Tumor payudara ini secara umum dibagi menjadi 2, yaitu benign atau biasa disebut jinak dan malignant atau biasa disebut juga ganas. Tumor payudara jinak ditandai dengan berbentuk benjolan kecil bulat dan lembut. Tumor payudara

dalam tingkat jinak biasanya akan mempunyai keadaan dan pertumbuhan yang tidak bersifat kanker [3]. Pada tumor payudara dalam tingkat ganas ditandai dengan bentuk yang tidak simetris, kasar, terasa nyeri, dan lainnya. Deteksi dini merupakan salah satu cara untuk menekan angka kematian selain menghindari faktor resiko lainnya. USG payudara atau USG mammae adalah salah satu jenis USG yang secara khusus dilakukan untuk memeriksa kondisi payudara dan mendeteksi gangguan serta berbagai bentuk kelainan pada payudara, seperti kista dan tumor [4]. USG payudara relatif mudah dan alatnya bisa ditemukan di FASKES (Fasilitas Kesehatan) 1, namun tenaga ahli (dokter spesialis onkologi) yang dapat menganalisa citra tersebut yang masih sulit ditemui terutama pada Faskes 1. Untuk mengatasi masalah tersebut, saat ini penggunaan CAD (Computed Aided Diagnosis) dalam menganalisa mengklasifikasi citra medis telah banyak dilakukan [5]. Selain karena murah, pengoperasian yang mudah, CAD juga telah dapat memberikan akurasi klasifikasi yang baik. Model yang dikembangkan oleh pengusul pada tahun 2023 juga

menunjukkan performa yang kurang memuaskan, dimana akurasi yang didapat yaitu sebesar 0.67 (training) dan 0.66 (validasi). Sementara itu, loss yang didapat adalah sebesar 0.77 saat training dan 0.84 saat validasi. Pada Gambar 1 menunjukkan hasil pengujian model deteksi tumor payudara pada penelitian sebelumnya secara lebih detail.

Berdasarkan uraian diatas, dapat disimpulkan saat ini terdapat 2 masalah yang saat ini masih menjadi kendala pada model klasifikasi tumor payudara saat ini, yaitu: model deteksi tumor payudara yang dibangun menggunakan arsitektur tunggal belum mampu memberikan performa yang memuaskan, masalah lainnya adalah penggunaan ensemble learning yang telah ada masih sangat bergantung pada konfigurasi data training dan data uji yang memiliki kemiripan serta dalam jumlah yang besar. Pada usulan penelitian ini, tim pengusul mengajukan model ensemble machine learning yang menggabungkan 3 arsitektur yaitu Support Vector Machine (SVM), Naïve Bayes, dan Random Forest. Proses pelatihan dilakukan secara hierarkis, dimana hasil pembelajaran sebuah arsitektur dijadikan input bagi arsitektur lainnya. Hasil klasifikasi masing-masing arsitektur kemudian digabungkan dengan menggunakan metode ensemble voting. Hasil prediksi final didapatkan dari hasil voting terhadap kelas yang sering muncul pada hasil prediksi masing-masing arsitektur..

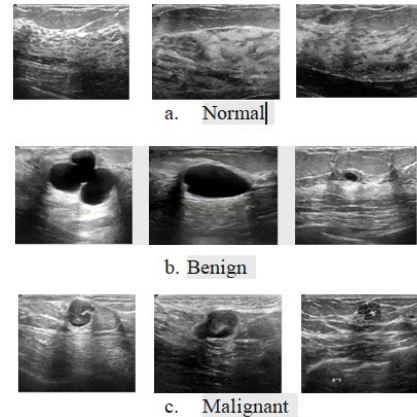
II. METODOLOGI PENELITIAN

Secara umum terdapat 5 tahapan pada usulan penelitian ini yaitu: Dataset, Preprocessing, Klasifikasi, Ensemble dan Prediksi Akhir. Tahap pertama adalah mengumpulkan dan menelaah dataset (BUSI) yang akan digunakan. Pada tahapan Peprocessing, citra yang terdapat

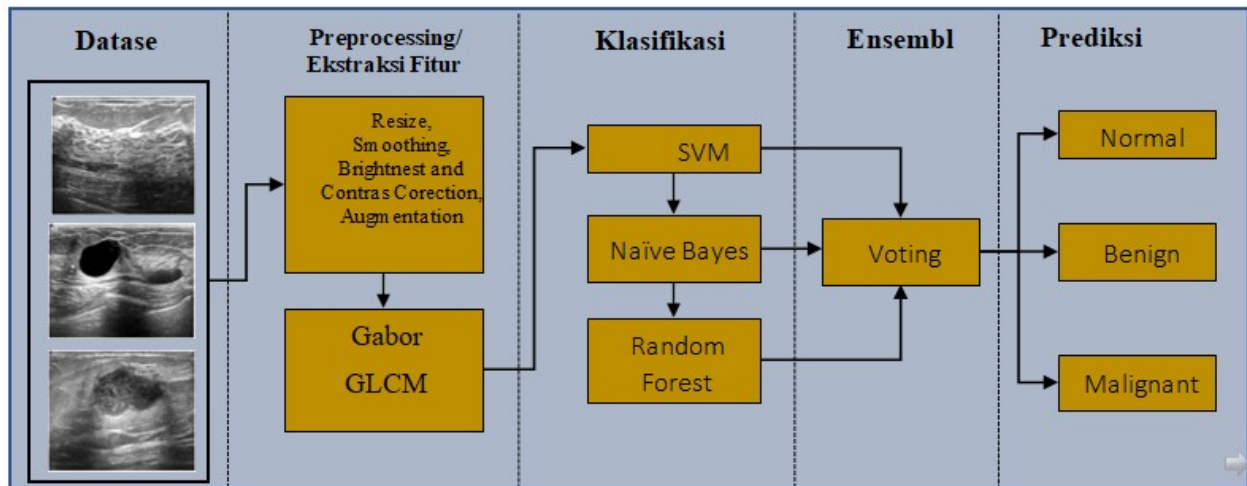
hasil akurasi yang lebih baik. Hasil akurasi akhir didapatkan setelah proses Voting selesai dilakukan. Gambar 3.1 menunjukkan tahapan yang dilakukan pada usulan penelitian ini.

2.1 Dataset Breast Ultrasound Images Dataset (BUSI)

Dataset BUSI merupakan himpunan citra ultrasound yang diambil dari wanita yang berumur dari 25 sampai 75 tahun. Dataset BUSI dikumpulkan mulai tahun 2018 dan diambil dari 600 pasien. Dataset BUSI terdiri dari 780 citra dengan ukuran rata-rata 500x500 piksel. Citra memiliki format PNG dan terdiri dari 3 kelas yaitu kelas normal, kelas benign dan kelas malignant. Gambar 2 menampilkan contoh citra yang terdapat pada masing-masing kelas pada dataset BUSI.



Gambar 2. Contoh citra untuk masing-masing kelas pada dataset BUSI

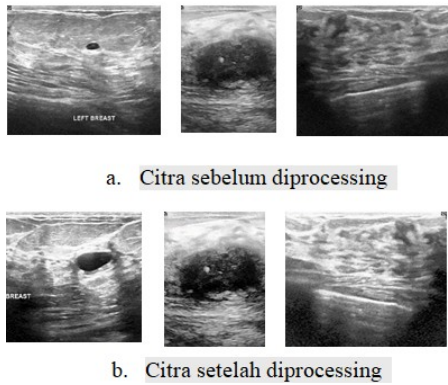


Gambar 1. Model Hierarchical Ensemble Learning untuk Klasifikasi Tumor Payudara pada Citra Ultrasonografi (USG)

dalam dataset diperbaiki, baik dengan melakukan perbaikan kontras, brightness, mengatur (menyeragamkan) ukuran, dan augmentasi. Proses selanjutnya adalah klasifikasi, dimana terdapat dua proses yaitu pelatihan dan prngujian. Pada proses pelatihan, klasifier dilatih secara hierarkis dimana hasil klasifikasi klasifier sebelumnya diinputkan sebagai data pelatihan klasifier berikutnya. Selanjutnya, hasil prediksi dari masing-masing arsitektur kemudian digabungkan (ensemble) dengan menggunakan metode Voting untuk mendapatkan

2.2 Preprocessing

Langkah pre-processing pada dataset dilakukan dengan memperbaiki kontras citra. Metode Histogram Equalization menggunakan komputasi yang sederhana dalam meningkatkan nilai kontras pada citra secara global, terutama jika nilai kontras pada citra terletak pada jarak yang berdekatan. Melalui penyesuaian ini, intensitas kontras dapat terdistribusi dengan lebih baik. Hasil citra sebelum dan setelah dilakukan preprocessing ditampilkan pada Gambar 3.




Gambar 3. Hasil preprocessing pada citra yang terdapat pada dataset BUSI

Untuk meningkatkan akurasi dan mencegah terjadinya overfitting (dimana model memasukan noise dan fitur-fitur yang tidak relevan sebagai bahan pembelajaran) maka dilakukan pendekatan dengan menggunakan data augmentasi. Karakteristik augmentasi yang digunakan pada usulan penelitian ini ditampilkan pada Tabel 1.

Tabel 1. Karakteristik Augmentasi

| Proses | Nilai |
|-----------------|--------|
| Rotation | 45 |
| Horizontal Flip | TRUE |
| Zoom | 0.2 |
| Rescale | 1./255 |

Data augmentasi membangkitkan data training tambahan dari data yang sudah ada dengan melakukan berbagai transformasi. Citra hasil operasi augmentasi ditampilkan pada Gambar 4.



Gambar 4. Citra hasil Augmentasi

2.3 Ekstraksi Fitur

Pada usulan model yang akan dikembangkan pada penelitian ini, terdapat 2 fitur yang akan digunakan dalam melatih klasifier yaitu fitur Gabor dan GLCM. Fitur Gabor merupakan kumpulan filter yang digunakan untuk mengekstrak fitur tekstur dari citra [21]. Gabor filter

merupakan fungsi gaussian yang merupakan hasil modulasi frekuensi dan orientasi sinusoid kompleks. Gaussian filter memiliki kemampuan ekstraksi baik secara spasial maupun domain pada berbagai dimensi [22]. Himpunan filter Gabor diekstraksi dengan ukuran filter σ dan orientasi θ .

Matrik GLCM dihitung dari nilai piksel yang berpasangan dan memiliki nilai intensitas tertentu [23]. Jika jarak antara dua piksel yaitu $(x1,y1)$ dan $(x2,y2)$, dan θ didefinisikan sebagai sudut antara kedua piksel tersebut, maka matriks GLCM merupakan distribusi spasial dari $P_{d,\theta}$. Ekstraksi fitur GLCM dilakukan pada arah sudut dengan jarak 1 piksel dan 4 jenis sudut yang digunakan yaitu 0^0 (180^0), 45^0 (225^0), 90^0 (270^0), 135^0 (315^0).

2.4 Klasifikasi (Proses Pelatihan dan pengujian)

Terdapat tiga klasifier yang digunakan dalam penelitian ini, yaitu: Support Vector Machine (SVM), Naïve Bayes, dan Random Forest. SVM. Penelitian oleh [24] membandingkan performa ketiga klasifier tersebut menggunakan matrik skor akurasi, presisi, recall, dan F1. Ketiga klasifier tersebut memiliki kelebihan dan kekurangannya masing-masing. SVM memiliki akurasi yang baik dan juga memiliki kemampuan yang komplit, tetapi memiliki keterbatasan dalam menangani missing value dalam dataset, dimana Random Forest memiliki kemampuan klasifikasi yang baik dalam dataset yang memiliki missing value. Sementara Naïve Bayes memiliki keterbatasan dalam melakukan klasifikasi pada dataset yang berukuran kecil. Menggabungkan ketiga klasifier tersebut bertujuan untuk mengambil kelebihan masing-masing klasifier, serta dapat saling menutupi kelemahan masing-masing.

Pada proses pelatihan klasifier secara hierarkis, proses pelatihan sebuah klasifier melibatkan hasil klasifikasi oleh klasifier sebelumnya. Hasil pembelajaran yang didapat oleh klasifier A dapat digunakan untuk melatih klasifier B, sehingga performa klasifier B dapat meningkat. Klasifier B mendapat kemampuan klasifikasi yang lebih baik dari klasifier A, karena klasifier B dapat mengambil keunggulan dari klasifier A dan menghindari kekurangannya.

2.5 Metode Ensemble

Hard Voting, yang juga dikenal dengan voting mayoritas, merupakan operasi sederhana dimana hasil prediksi masing-masing arsitektur dan selanjutnya memilih kelas yang paling banyak dipilih arsitektur menjadi hasil prediksi final. Pada penelitian ini, terdapat dua kelas yang menjadi output yaitu kelas benign (tumor jinak) dan kelas malignant (tumor ganas). Tabel 2 menampilkan simulasi Hard Voting dengan menggunakan 3 klasifier.

Tabel 2. Simulasi Hard Voting menggunakan 3 klasifier

| No | Data | Klasifier 1 | Klasifier 2 | Klasifier 3 | Hasil Akhir |
|----|---------|-------------|-------------|-------------|-------------|
| 1 | Citra 1 | Benign | Benign | Malignant | Benign |
| 2 | Citra 2 | Malignant | Benign | Malignant | Malignant |
| 3 | Citra 3 | Benign | Malignant | Benign | Benign |
| 4 | Citra 4 | Malignant | Benign | Malignant | Malignant |
| 5 | Citra 5 | Benign | Benign | Benign | Benign |

Berdasarkan tabel diatas, Citra 1 mendapat hasil prediksi benign pada Klasifier 1 dan Klasifier 2, sementara pada Klasifier 3 mendapatkan hasil prediksi malignant. Maka, untuk Citra 1 pada prediksi akhir adalah benign, karena kelas benign muncul 2 kali yaitu pada Klasifier 1 dan Klasifier 2. Begitu juga proses pengambilan hasil prediksi akhir untuk Citra 2 sampai dengan Citra 5.


III. HASIL DAN PEMBAHASAN

4.1 Eksperimen

Penelitian ini melakukan ekstaksi fitur tekstur yaitu Gabor dan GLCM (Gray Level Co-occurrence Matrix) dari citra USG payudara. Gabor merupakan kumpulan filter yang digunakan untuk mengekstrak fitur tekstur dari citra. Vektor fitur yang terbentuk selanjutnya direduksi dengan menggunakan metode PCA (Principal Component Analisis). Setelah direduksi, vektor fitur selanjutnya digunakan untuk melatih klasifier-klasifier untuk mengklasifikasi kedalam dua kelas yaitu benign (tumor jinak) dan malignant (tumor ganas/kanker). Performa masing-masing klasifier kemudian diukur menggunakan confusion matrix, dan selanjutnya dibandingkan dengan performa model hasil pembelajaran ensemble. Tahapan eksperimen dimulai dengan membagi dataset BUSI dimana sebanyak data digunakan pada proses training, sedangkan sebanyak .. data digunakan pada proses testing. Akurasi model akan diukur dengan membandingkan pengujian dengan menggunakan fitur HOG secara tunggal dan fitur HOG + histogram.

4.2 Dataset

Penelitian ini menggunakan dataset BUSI untuk melatih dan menguji model klasifikasi tumor payudara pada citra USG. Dataset BUSI miliki total citra sebanyak 647 dimana terdapat 437 citra tumor benign (jinak) dan 210 citra tumor tipe malignant (ganas). Fitur GLCM dan Gabor kemudian diekstraksi dari citra-citra tersebut, dimana vektor fitur yang terbentuk kemudian direduksi dan diseleksi dengan metode analisis komponen. Selanjutnya vektor fitur kemudian digunakan untuk melatih model klasifier-klasifier. Gambar 5 menampilkan contoh citra pada dataset BUSI baik tumor yang bertipe benign maupun tumor yang bertipe malignant.



Gambar 5. Citra tumor payudara pada dataset BUSI

4.3 Ekstraksi Fitur

Gabor merupakan kumpulan filter yang digunakan untuk mengekstrak fitur tekstur dari citra. Gabor filter merupakan fungsi gaussian yang merupakan hasil modulasi frekuensi dan orientasi sinusoid kompleks. Gaussian filter memiliki kemampuan ekstraksi baik secara spasial maupun domain pada berbagai dimensi. Hasil ekstraksi fitur gabor pada berbagai sudut dan gelombang ditampilkan pada Tabel 3.

Tabel 3. Hasil Ekstraksi Fitur Gabor

| No | Nama File | Sudut/wavelength | | | | | |
|----|-----------|-----------------------|-----------------------|----|----|------------------------|------------------------|
| | | $\alpha=0.2/\theta=0$ | $\alpha=0.5/\theta=0$ | .. | .. | $\alpha=1.1/\theta=90$ | $\alpha=1.4/\theta=90$ |
| 1 | mal_1 | 186177756 | 166495917 | | | 182014448 | 186177756 |
| 2 | mal_2 | 183278775 | 162605160 | | | 178900130 | 18327877 |
| 3 | mal_3 | 83264948 | 62907127 | | | 78263841 | 83264948 |
| 4 | mal_4 | 83264948 | 62907127 | | | 78263841 | 83264948 |


Ekstraksi fitur GLCM dilakukan pada arah sudut dengan jarak 1 piksel dan 4 jenis orientasi yang digunakan yaitu 00 (1800), 450 (2250), 900 (2700), 1350 (3150). Hasil ekstraksi fitur GLCM pada berbagai orientasi ditampilkan pada Tabel 4.

Tabel 4. Hasil Ekstraksi Fitur GLCM pada Sudut 0⁰

| No | Nama File | Cont | Diss | Homg | Engy | Corr | Asm |
|----|-----------|----------|----------|----------|----------|----------|----------|
| 1 | mal_1 | 0.097136 | 0.034774 | 0.987354 | 0.963086 | 0.852789 | 0.927535 |
| 2 | mal_2 | 0.026533 | 0.010201 | 0.996063 | 0.989055 | 0.712624 | 0.978229 |
| 3 | mal_3 | 0.172714 | 0.057889 | 0.979099 | 0.929339 | 0.914389 | 0.863672 |
| 4 | mal_4 | 0.071709 | 0.031206 | 0.987655 | 0.960653 | 0.812569 | 0.922854 |

4.4 Pelatihan dan Pengujian Performa Model


Setelah model selesai dilatih, selanjutnya dilakukan validasi terhadap performa model dalam melakukan klasifikasi. Pada penelitian ini sebanyak 80% data digunakan sebagai data latih dan sebanyak 20% digunakan sebagai data uji. Pada klasifier pertama didapatkan kurva ROC (Receiver-operating characteristic) seperti yang ditampilkan pada Gambar 6 berikut ini :



Gambar 6. Kurva ROC untuk klasifier 1


Akurasi yang didapat oleh klasifier pertama adalah sebesar 0.96 dengan nilai Area Under the Curve (AUC) sebesar 0,94.

Pada klasifier kedua akurasi yang didapat adalah sebesar 0,93 dan AUC juga sebesar 0,93. Kurva ROC untuk klasifier kedua ditampilkan pada Gambar 7.




Gambar 7. Kurva ROC untuk klasifier 2

Pada klasifier ke tiga akurasi yang didapat adalah sebesar 0,95 dan AUC sebesar 0.93. Gambar 7 menampilkan kurva ROC untuk klasifier ke tiga.



Gambar 7. Kurva ROC untuk klasifier 3

Setelah melalui tahapan ensemble, maka akurasi yang didapat meningkat yaitu sebesar 0,96 dan AUC sebesar 0,94. Kurva ROC untuk model setelah melalui tahapan pembelajaran ensemble ditampilkan pada Gambar 8.



Gambar 8. Kurva ROC untuk model ensemble

IV. KESIMPULAN

Model klasifikasi tumor payudara yang dikembangkan pada penelitian ini telah menunjukkan akurasi yang cukup memuaskan. Berdasarkan hasil pengujian didapatkan akurasi sebesar 0.95 untuk SVM, 0.95 untuk KNN, dan 0.91 untuk Decision Tree. Hasil akurasi yang didapatkan setelah menambahkan tahapan ensemble adalah 0.96 dan AUC sebesar 0,94. Berdasarkan hasil eksperimen, penambahan tahapan pembelajaran ensemble belum meningkatkan akurasi yang signifikan pada dataset yang kecil. Pengembangan model klasifikasi tumor payudara pada tahapan selanjutnya dapat dilakukan pada beberapa tahapan. Tahapan segmentasi dapat ditambahkan untuk melokalisasi area of interest maka. Penambahan tahapan segmentasi dapat menekan waktu pelatihan dan pengujian serta dapat meningkatkan akurasi. Pada citra-citra dengan kontras yang rendah harus terlebih dahulu diperbaiki. Selain itu juga dapat dilakukan dengan menambahkan proses segmentasi segmen baik berdasarkan kemiripan warna, lokasi, dan tepi. Penambahan fitur dan menemukan kombinasi fitur yang tepat pada tahapan klasifikasi juga dapat dilakukan untuk meningkatkan performa model yang dibangun.

REFERENSI

- [1] N. Micallef, D. Seychell, and C. J. Bajada, "Exploring the U-Net ++ Model for Automatic Brain Tumor Segmentation," IEEE Access, vol. 9, pp. 125523–125539, 2021, doi: 10.1109/ACCESS.2021.3111131.
- [2] M. Bella, A. Rasyid, F. Arnia, and K. Munadi, "Histogram Statistics and GLCM Features of Breast Thermograms for Early Cancer Detection," pp. 120–124, 2018.
- [3] A. S. Elkorany, M. Marey, K. M. Almustafa, and Z. F. Elsharkawy, "Breast Cancer Diagnosis Using Support Vector Machines Optimized by Whale Optimization and Dragonfly Algorithms," IEEE Access, vol. 10, no. July, pp. 69688–69699, 2022, doi: 10.1109/ACCESS.2022.3186021.
- [4] J. Zhang, A. Saha, Z. Zhu, and M. A. Mazurowski, "Hierarchical Convolutional Neural Networks for Segmentation of Breast Tumors in MRI With Application to Radiogenomics," vol. 38, no. 2, pp. 435–447, 2019.
- [5] X. Qiao et al., "Improving Breast Tumor Segmentation in PET via Attentive Transformation Based," vol. 26, no. 7, pp. 3261–3271, 2022.
- [6] A. A. Khan and A. S. Arora, "Breast Cancer Detection Through Gabor Filter Based Texture Features Using Thermograms Images," pp. 412–417, 2018.
- [7] T. Nguyen, T. Nguyen, and B. Ngo, "A GLCM Algorithm for Optimal Features of Mammographic Images for Detection of Breast Cancer," pp. 295–299, 2021.
- [8] M. Thohir, D. Candra, and R. Novitasari, "Classification of Colposcopy Data Using GLCM- SVM on Cervical Cancer," pp. 373–378, 2020.
- [9] T. T. Htay and S. S. Maung, "Early Stage Breast Cancer Detection System using GLCM feature extraction and K-Nearest Neighbor (k-NN) on Mammography image," no. Iscit, pp. 171–175, 2018.
- [10] A. Mohammed and R. Kora, "A comprehensive review on ensemble deep learning : Opportunities and challenges," J. King Saud Univ. - Comput. Inf. Sci., vol. 35, no. 2, pp. 757–774, 2023, doi: 10.1016/j.jksuci.2023.01.014.
- [11] T. S. Abraham, "Ensemble Machine Learning Approach for Brain Tumor Classification Analysis," 2022 First Int. Conf. Electr. Electron. Inf. Commun. Technol., pp. 1–6, doi: 10.1109/ICEEICT53079.2022.9768645.
- [12] G. Saranya and H. Victoria, "Classification of Brain Tumors Using Ensemble Learning," 2023 IEEE 12th Int. Conf. Commun. Syst. Netw. Technol., no. MI, pp. 912–917, 2023, doi: 10.1109/CSNT57126.2023.10134687.
- [13] E. A. Nehary, "Classification of Ultrasound Breast Images Using Fused Ensemble of Deep Learning Classifiers," 2022 IEEE Int. Symp.

- Med. Meas. Appl., pp. 1–6, 2022, doi: 10.1109/MeMeA54994.2022.9856496.
- [14] C. Deng, “A Novel Weighted Hierarchical Adaptive Voting Ensemble Machine Learning Method for Breast Cancer Detection,” 2015 IEEE Int. Symp. Mult. Log., pp. 115–120, 2015, doi: 10.1109/ISMVL.2015.27.
- [15] S. Kranthi, K. Kolachina, and R. Agada, “A Comparative Study of Ensemble Deep Learning Models for Skin Cancer Detection,” 2023 11th Int. Conf. Bioinforma. Comput. Biol., pp. 175–181, 2023, doi: 10.1109/ICBCB57893.2023.10246728.
- [16] T. K. Vyas, “A Statistical Classification of the Benign and Malignant Neoplasm using Ensemble Learning and Classification Algorithms .,” 2021 12th Int. Conf. Comput. Commun. Netw. Technol., pp. 1–5, 2021, doi: 10.1109/ICCCNT51525.2021.9579661.
- [17] D. Albashish and S. Sahran, “Multi-scoring Feature selection method based on SVM-RFE for prostate cancer diagnosis,” 2015 Int. Conf. Electr. Eng. Informatics, pp. 682–686, 2015, doi: 10.1109/ICEEI.2015.7352585.
- [18] N. Bhuta, T. Jadhav, S. Shinde, A. Gaikwad, and P. Jangale, “Feature Level Ensemble Learning Technique for Cervical Cancer Cell Classification,” 2023 7th Int. Conf. Comput. Commun. Control Autom., pp. 1–6, 2023, doi: 10.1109/ICCUBEA58933.2023.10392076.
- [19] R. Ali, R. C. Hardie, B. N. Narayanan, and S. De Silva, “Deep Learning Ensemble Methods for Skin Lesion Analysis towards Melanoma Detection,” 2019 IEEE Natl. Aerosp. Electron. Conf., pp. 311–316, 2019.
- [20] E. P. Prakash, “An Intelligent Deep Learning Strategy for Breast Cancer prediction using feature ensemble learning,” 2023 Int. Conf. Res. Methodol. Knowl. Manag. Artif. Intell. Telecommun. Eng., pp. 1–6, 2020, doi: 10.1109/RMKMATE59243.2023.10369538.
- [21] D. Zhang, A. Wong, M. Indrawan, and G. Lu, “Content-based Image Retrieval Using Gabor Texture Features,” IEEE Trans. PAMI, vol. 3656 LNCS, pp. 13–15, 2000.
- [22] A. N. Rumaksari, S. Sumpeno, and A. D. Wibawa, “Background subtraction using spatial mixture of Gaussian model with dynamic shadow filtering,” 2017 Int. Semin. Intell. Technol. Its Appl. Strength. Link Between Univ. Res. Ind. to Support ASEAN Energy Sect. ISITIA 2017 - Proceeding, vol. 2017-Janua, pp. 296–301, 2017, doi: 10.1109/ISITIA.2017.8124098.
- [23] S. Alameen and M. E. M. Gar-Elnabi, “Study of Gicm for Diagnosis of Liver Diseases From Abdominal Ct Images,” no. August, 2016.
- [24] M. Guia and R. R. Silva, “Comparison of Naïve Bayes , Support Vector Machine , Decision Trees and Random Forest on Sentiment Analysis Comparison of Naïve Bayes , Support Vector Machine , Decision Trees and Random Forest on Sentiment Analysis,” Int. Conf. Knowl. Discov. Inf. Retr., no. November, 2019, doi: 10.5220/0008364105250531.