

PERANCANGAN DAN PENGEMBANGAN PENDETEKSI PENYAKIT MELANOMA MENGGUNAKAN METODE GREY LEVEL CO-OCCURANCE MATRIX (GLCM) DAN METODE KLASIFIKASI CONVOLUTIONAL NEURAL NETWORK (CNN)

Sang Ayu Ketut Devi Saraswati¹, Wahmisari Priharti², Fenty Alia³

^{1,2,3}Fakultas Teknik Elektro, Universitas Telkom

¹devisaraswati@student.telkomuniversity.ac.id, ²wpriharti@telkomuniversity.ac.id,

³aliafenty@telkomuniversity.ac.id

Diterima pada 19 Juli 2022; disetujui pada 28 Oktober 2022; dan diterbitkan pada 2 September 2022.

Abstrak

Melanoma merupakan salah satu jenis penyakit kulit berupa tumor ganas yang berkembang pada sel melanosit penghasil melanin. Penyakit ini merupakan penyakit langka, namun memiliki risiko kematian yang tinggi jika tidak segera ditangani. Salah satu cara yang dapat membantu penanganan melanoma adalah diagnosis secara dini terhadap penyakit tersebut. Pada penelitian ini dirancang sebuah pendeteksi penyakit melanoma menggunakan *Raspberry pi* dan *pi camera* dengan mengimplementasikan metode ekstraksi fitur *Grey Level Co-Occurance Matrix* (GLCM) dan metode klasifikasi *Convolutional Neural Network* (CNN). Citra input akan diolah melalui proses *pre-processing* berupa proses *grayscale*, *image adjustment*, dan *cropping*. Citra hasil *pre-processing* akan diekstraksi menggunakan metode GLCM berdasarkan parameter *contrast*, *correlation*, *entropy*, dan *uniformity*. Tahap terakhir, citra akan diklasifikasikan apakah merupakan penyakit melanoma atau non-melanoma menggunakan metode CNN. Pengujian dilakukan menggunakan dataset yang berjumlah 416 data citra nevus dan melanoma serta citra validasi yang berjumlah 16 sampel citra nevus. Dari hasil pengujian didapatkan hasil akurasi sebesar 85% dengan *F1-score* sebesar 89% sehingga hasil penelitian ini dapat digunakan sebagai salah satu alat bantu untuk proses *screening* kasus penyakit melanoma.

Kata Kunci: *Convolutional Neural Network* (CNN), *Grey Level Co-Occurance Matrix* (GLCM), Melanoma, *Deep Learning*, *Image Processing*.

Abstract

Melanoma is one type of skin disease in the form of a malignant tumor that develops in melanin-producing melanocytes cell. This disease is a rare disease but has a high risk of death if not treated immediately. One way that can help the treatment of melanoma is the early diagnosis of the disease. In this research, a melanoma detector was designed using a raspberry pi and a pi camera by implementing the Gray Level Co-Occurance Matrix (GLCM) feature extraction method and the Convolutional Neural Network (CNN) classification method. The input image will be processed through a pre-processing process in the form of a grayscale, image adjustment, and cropping process. The pre-processed image will be extracted using the GLCM method based on the contrast, correlation, entropy, and uniformity parameters. The last stage is the image will be classified whether it is a melanoma or non-melanoma disease using CNN method. Tests processes were carried out using dataset in the form of 416 images of nevus and melanoma and also validation images, totaling 16 samples of nevus images. From the test results obtained an accuracy of 85% and an F1-score of 89%. So, the result of this research can be used as tool which can help screening process of Melanoma disease case.

Key Words: *Convolutional Neural Network* (CNN), *Grey Level Co-Occurance Matrix* (GLCM), Melanoma, *Deep Learning*, *Image Processing*.

1. Pendahuluan

Diketahui bahwa salah satu penyakit kulit khususnya kanker kulit yang paling berbahaya adalah melanoma [1]. Melanoma adalah salah satu jenis kanker

kulit yang langka dan mematikan. Penyakit ini berkembang pada sel melanosit di mana pertumbuhannya menjadi tidak terkontrol sehingga menghasilkan tumor ganas yang dapat berdampak pada keseluruhan organ

tubuh [2]. Melanoma hanya menyumbang sekitar 1% kasus dari total semua kasus akibat kanker kulit tetapi menyebabkan sebagian besar kematian akibat kanker kulit [3].

Penelitian ini mengacu pada penelitian terdahulu, di mana proses deteksi kanker kulit menggunakan metode *deep learning* yaitu ANN (*Artificial Neural Network*), CNN (*Convolutional Neural Network*), KNN (*K-Nearest Neighbor*), dan RBFN (*Radial Basis Function Neural Network*) dengan penggunaan metode CNN menunjukkan hasil yang lebih baik dibandingkan metode lainnya [4]. Kombinasi antara metode LBP (*Local binary patterns*) dan CNN juga menghasilkan rata-rata akurasi sebesar 92% [4]. Selain itu, Pada penelitian dengan topik klasifikasi kanker payudara menggunakan ekstraksi fitur GLCM (*Grey Level Co-Occurance Matrix*) didapatkan akurasi dalam mendeteksi kanker sebesar 80% [5]. Diperkuat dengan penelitian klasifikasi citra hispatologi kolon menggunakan ekstraksi fitur GLCM didapatkan akurasi yang cukup besar dalam mengklasifikasikan suatu citra [6].

Pada dasarnya, penyakit melanoma dapat *didagnosis* secara visual, baik dengan analisis dermoskopi atau prosedur biopsi. Namun, prosedur yang ada biasanya cenderung memerlukan proses yang lama, mahal dan membutuhkan banyak tenaga profesional yang memungkinkan terjadinya *human error*. Hal ini dapat menyebabkan lamanya penanganan dan besar kemungkinan dapat meningkatkan risiko kematian pada pasien.

Berdasarkan permasalahan-permasalahan yang telah dipaparkan, peneliti memutuskan untuk mengimplementasikan metode ekstraksi fitur GLCM dan metode klasifikasi CNN dalam sistem pendeteksi penyakit melanoma. Tujuan diimplementasikannya metode-metode tersebut adalah untuk mendapatkan informasi tekstur dengan menggunakan metode GLCM dan melakukan klasifikasi terhadap citra *input* yang didapatkan sehingga diharapkan sistem ini dapat mengidentifikasi penyakit melanoma dengan akurat dan dalam waktu yang cepat tanpa membutuhkan banyak biaya. Hasil penelitian ini diambil melalui *pi camera* yang diintegrasikan dengan *Raspberry pi* dan monitor untuk mengambil sampel citra sehingga citra dapat diolah melalui 3 proses *pre-processing*, yaitu proses *grayscale*, *image adjustment*, dan *cropping* dengan tujuan untuk memperbaiki dan meningkatkan kualitas citra *input* agar memudahkan proses ekstraksi GLCM serta citra dapat dengan mudah diklasifikasikan dengan metode CNN.

1.1 State of the art

Berikut merupakan *state-of-the-art* beberapa penelitian yang menggunakan metode berbeda, seperti *vision transformer*, *Res2Net*, *efficientNet*, dan *ResNeXt*

seperti yang ditunjukkan pada Tabel 1.

Tabel 1. State-of-the-art

Ref	Metode	Keterangan	Hasil
[17]	<i>Vision Transformer</i>	<i>Scaling</i> data pada NLP dengan menggunakan <i>vision transformer</i> pada citra.	Akurasi pada <i>ImageNet</i> : 88,55%. <i>ImageNet-Real</i> : 94,55%. CIFAR-100: 94,55%. VTAB: 77,63%
[18]	<i>Res2Net</i>	Kemampuan <i>multi-scaling granular level</i> pada CNN menggunakan <i>Res2Net</i>	Model <i>Res2Net</i> memiliki kemampuan untuk meningkatkan rata-rata presisi sebesar 3,3% dan 3,0%
[19]	<i>Efficient Nets</i>	Menggunakan metode <i>EfficientNet</i> sebagai metode <i>scaling</i> semua dimensi (<i>depth/width/resolution</i>).	<i>EfficientNet-B7</i> memperoleh akurasi sebesar 84,3% pada <i>ImageNet</i> . 91,7% pada CIFAR-100 dan 98,8% pada dataset bunga.
[20]	<i>ResNeXt</i>	<i>ResNeXt</i> merupakan <i>modularized network architecture</i> untuk klasifikasi citra.	<i>ResNeXt</i> memperoleh kenaikan AP sebesar 1,0% pada <i>layer-baseline</i> 50. Namun, tidak mengalami peningkatan pada <i>layer-baseline</i> 10.

2. Dasar Teori dan Metodologi Penelitian

2.1 Image Processing

Pada penelitian ini, tahap pertama pengolahan citra yang dilakukan adalah proses *image processing*. *Image processing* merupakan suatu metode pengolahan citra digital dengan cara memanipulasi dan menganalisisnya, lalu ditransformasikan menjadi citra lain dengan menggunakan teknik tertentu [11]. Fungsi utama dari metode ini adalah untuk memperbaiki citra *input* dari unsur-unsur yang tidak diperlukan. Proses *image*

processing yang dilakukan terdiri dari proses *grayscale*, *image adjustment*, dan *cropping*. *Grayscale* dilakukan untuk mengolah citra berwarna *red green blue* (RGB) menjadi gambar hitam putih agar dapat mempermudah proses ekstraksi fitur GLCM yang akan dilakukan pada citra nantinya karena proses GLCM hanya mengolah data citra dalam bentuk *grayscale*. Metode *image adjustment* dilakukan untuk meningkatkan kualitas dari citra *input* dalam bentuk *grayscale*. Proses *image adjustment* dilakukan dengan memperbaiki kontras dari citra *input*. *Cropping* merupakan teknik yang digunakan untuk membuat citra baru dari sebuah citra yang memiliki ukuran berbeda dengan memotong bagian suatu citra pada koordinat yang diinginkan. Proses ini bertujuan untuk memotong bagian citra yang akan digunakan dan membuang bagian citra yang tidak akan digunakan.

2.2 Ekstraksi Fitur Grey Level Co-Occurance Matrix (GLCM)

Metode GLCM merupakan metode ekstraksi fitur berbasis statistikal orde kedua pada suatu citra dengan mengambil informasi pokoknya [9]. Metode ini berupa perhitungan karakteristik tekstur dengan menggunakan matriks ko-okurensi. Matriks ko-okurensi merupakan suatu matriks antara yang merepresentasikan hubungan ketetangaan antar piksel diseluruh bagian citra di segala arah orientasi dan jarak spasial. Penelitian ini menggunakan beberapa parameter untuk mengukur nilai tekstur dengan menggunakan metode GLCM, yaitu:

1. Entropi

Nilai entropi menunjukkan jumlah informasi yang terdapat pada citra dan diubah dengan tekstur yang berbeda [12]. Semakin meningkat nilai entropi, maka semakin bertekstur suatu citra. Namun ketika nilai 0, maka citra tidak memiliki tekstur.

$$entropi = - \sum_i \sum_j^{L-1} [G(i, j) \cdot \log G(i, j)] \quad (1)$$

2. Korelasi

Korelasi adalah probabilitas hubungan ketetangaan antara dua piksel pada jarak tertentu pada keseluruhan citra.

$$korelasi = \frac{\sum_i^{L-1} \sum_j^{L-1} (i - \bar{x})(j - \bar{y})G(i, j)}{\sigma_x \sigma_y} \quad (2)$$

3. Kontras

Nilai kontras menunjukkan tingkat kedalaman alur pada citra. Semakin tinggi nilai kontras, maka akan semakin besar tingkat kedalaman alur dari citra [12].

$$korelasi = \sum_i \sum_j^{L-1} (i, j)^2 G(i, j) \quad (3)$$

4. Uniformity

Uniformity adalah nilai yang digunakan untuk mendeskripsikan kekasaran tekstur dari sebuah citra. Semakin besar nilai *uniformity*, semakin kasar tekstur dari citra [12].

$$uniformity = \sum_i \sum_j^{L-1} \frac{1}{(i, j)^2 + 1} G(i, j) \quad (4)$$

Dalam penerapannya pada penelitian ini, pada tahap awal untuk mendapatkan nilai matriks dari parameter-parameter tersebut dilakukan proses memasukkan *array* dari gambar input yang akan digunakan. Selanjutnya, dilakukan proses menghitung matriks GLCM. Setelahnya, dilakukan proses menghitung setiap parameter GLCM yang diinginkan yakni, kontras, entropi, *uniformity*, dan korelasi sehingga hasil matriks GLCM dari gambar input bisa didapatkan.

2.3 Convolutional Neural Network

Convolutional neural network (CNN) merupakan salah satu metode *deep learning* yang mampu melakukan pembelajaran mandiri untuk menjalankan beberapa tugas, seperti ekstraksi objek, pengenalan objek, maupun klasifikasi. CNN memiliki cara kerja yang serupa dengan *multi-layer perceptron* (MLP), namun setiap *neuron* pada CNN direpresentasikan dalam bentuk dua dimensi. Operasi linear pada CNN menggunakan operasi konvolusi sehingga CNN hanya bisa digunakan pada data yang berbentuk dua dimensi seperti suara dan citra [7]. CNN memiliki beberapa *layer* utama, yaitu:

1. Convolutional Layer

Convolutional layer melakukan operasi linear berupa operasi konvolusi pada *output* dari proses konvolusi sebelumnya [13]. Proses konvolusi ini memanfaatkan filter sebagai parameter yang akan diperbarui pada proses *learning*. Pada *convolutional layer* terdapat *hyperparameter* yang ditunjukkan pada Tabel 2.

Tabel 2. *Hyperparameter* pada CNN [8].

No	<i>Hyperparameter</i>	Deskripsi
1	<i>Depth</i>	Menunjukkan jumlah <i>filter</i>
2	<i>Stride</i>	Menunjukkan jumlah pergeseran <i>filter</i>
3	<i>Zero-padding</i>	Menunjukkan penambahan nilai dengan intensitas nol pada daerah sekitar perbatasan gambar <i>input</i> .

2. Pooling Layer

Pooling layer melakukan proses reduksi input secara spasial dan mereduksi jumlah parameter dalam jaringan menggunakan operasi *down-sampling* sehingga komputasi dapat dipercepat dan dapat mengontrol terjadinya *overfitting* [14]. *Pooling layer* berjalan secara bebas di setiap kedalaman pada *output* dan akan mengubah ukuran spasialnya.

3. Fully Connected Layer

Fully connected layer adalah layer di mana seluruh *neuron* dari aktivitas sebelumnya terhubung dengan *neuron* pada lapisan setelahnya [15]. Sebelum dimasukkan ke dalam *fully connected layer*, perlu dilakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear.

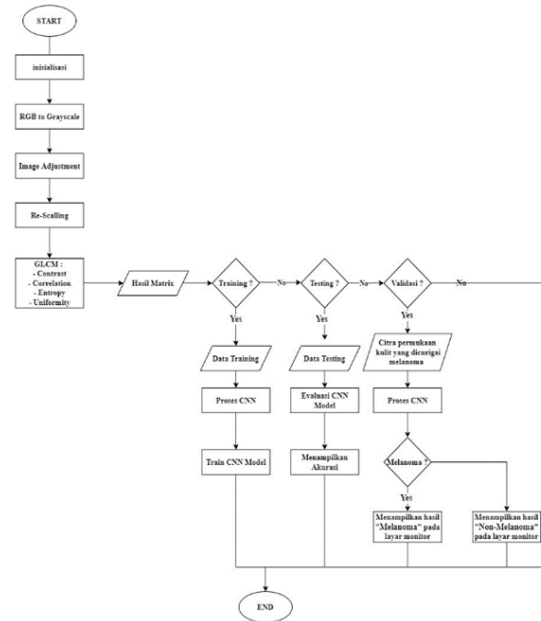
3. Pembahasan

3.1 Gambaran Umum

Citra *input* berupa citra dari permukaan kulit yang dicurigai merupakan melanoma. Data citra *input* terdiri dari 3 data, berupa 2 dataset dan 1 data validasi. Dataset merupakan data citra yang dibagi menjadi 2 kelas, yaitu citra melanoma dan citra yang merepresentasikan non-melanoma. Dataset merupakan data *International Skin Imaging Collaboration* (ISIC) yang didapatkan dari platform *open source* yaitu Kaggle [16]. Masing-masing dataset berformat .jpg dengan ukuran piksel gambar disesuaikan dengan letak lesi dari masing-masing citra *input*. Ukuran keseluruhan citra *input* yang digunakan adalah sebesar 1,06 Gb. Citra ini didapatkan dengan memanfaatkan *pi camera* untuk menangkap citra permukaan kulit tersebut. Citra *input* akan melalui 3 proses *pre-processing*, yaitu proses *grayscale*, *image adjustment*, dan *cropping*. Pada tahap selanjutnya, informasi berupa karakteristik dari masing-masing citra didapatkan melalui proses ekstraksi fitur menggunakan GLCM, di mana karakteristik yang ingin didapatkan berupa nilai matriks dari kontras, korelasi, entropi, dan *uniformity*. Tahap terakhir dari sistem ini adalah melakukan klasifikasi terhadap citra input yang telah melalui proses *pre-processing* dan ekstraksi fitur. Citra akan diklasifikasikan apakah termasuk melanoma ataupun non-melanoma. *Output* dari sistem berupa hasil prediksi kedua kategori tersebut yang ditampilkan pada layar monitor.


3.2 Diagram Alir

Pada penelitian ini dirancang sebuah alat untuk mendeteksi melanoma dengan menerapkan beberapa metode *image processing*, ekstraksi fitur, dan metode klasifikasi CNN. Adapun cara kerja sistem pada penelitian ini ditunjukkan oleh diagram alir pada Gambar 1, dengan rincian sebagai berikut:



Gambar 1. Diagram Alir.

1. Dilakukan proses inisialisasi terhadap direktori yang merupakan letak dari citra *input* yang akan diproses, baik dataset maupun data validasi.
2. Citra *input* akan diolah melalui 3 proses *pre-processing*.
3. Proses *grayscale* akan mengubah citra berwarna (RGB) menjadi citra *grayscale*. Proses ini juga berguna dalam proses GLCM nantinya.
4. Proses *image adjustment* bertujuan untuk mengatur kontras dari citra *input* sehingga menghasilkan citra yang lebih tajam.
5. Proses *cropping* dilakukan untuk membuang bagian dari citra yang tidak akan diproses.
6. Citra akhir dari proses *pre-processing* akan diolah pada proses GLCM untuk mendapatkan informasi unik dari masing-masing citra berupa nilai matriks kontras, korelasi, entropi, dan *uniformity*.
7. Citra *input* berupa data *train* akan memasuki proses *training* sehingga akan menghasilkan *train model*.
8. Citra input berupa data tes akan memasuki proses testing untuk mengevaluasi model dari proses training dan mendapatkan nilai akurasi dari sistem.
9. Citra input berupa data validasi akan memasuki proses validasi untuk mendapatkan prediksi sehingga didapatkan hasil diagnosis *screening* awal berupa melanoma atau non-melanoma.



Gambar 2. Dataset Melanoma.



Gambar 3. Dataset Non-Melanoma.

3.3 Pengambilan Data

Data citra yang digunakan pada penelitian ini terdiri dari 2 jenis data, yaitu dataset (data *train* dan data tes), serta data validasi. *Dataset* ISIC ini terdiri dari dua kategori, yaitu melanoma dan non-melanoma (*nevus* dan *seborrheic keratosis*). Total dataset yang digunakan pada penelitian ini sebanyak 416 data citra. Gambar 2 dan Gambar 3 menunjukkan sampel dari kedua kategori dataset yang digunakan.

Gambar 2 merupakan citra penyakit melanoma yang akan digunakan sebagai dataset. Citra penyakit melanoma berjumlah 315 data citra.

Gambar 3 menunjukkan citra non-melanoma berupa *nevus* dan *seborrheic keratosis*. *Nevus* biasa disebut dengan tahi lalat, sedangkan *seborrheic keratosis* merupakan suatu tumor epidermal yang bersifat jinak dan sering ditemukan pada pasien lanjut usia [10]. Citra non-melanoma berjumlah 91 citra. Data citra yang dipilih merupakan citra di mana objek berupa lesi yang terletak di tengah citra sehingga memudahkan dalam proses *pre-processing*.

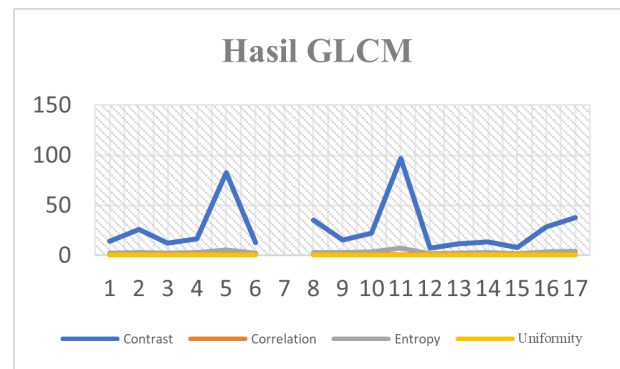
Data validasi merupakan citra *nevus* yang didapatkan melalui permukaan kulit yang ditangkap menggunakan sensor berupa *pi camera*. Data validasi hanya digunakan untuk membuktikan bahwa alat pendeteksi penyakit melanoma yang telah dirancang berjalan dengan baik. Adapun citra validasi yang digunakan ditunjukkan pada Gambar 4.

3.4 Gray Level Co-Occurance Matriks (GLCM) pada Data Validasi

Pada penelitian ini dilakukan pengujian terhadap parameter-parameter ekstraksi fitur GLCM.



Gambar 4. Data Validasi.




Gambar 5. Hasil GLCM.

Parameter-parameter tersebut terdiri dari 4 parameter, yaitu entropi, korelasi, kontras, dan *uniformity*. Parameter-parameter GLCM tersebut menghasilkan matriks sebagai informasi terhadap karakteristik masing-masing citra *input*, baik data *train*, data tes, maupun data validasi. Nilai matriks ini berguna pada proses klasifikasi menggunakan metode CNN dalam mencari pola dan melatih model. Adapun hasil nilai matriks pada 16 data validasi ditunjukkan pada grafik di Gambar 5.

3.5 Klasifikasi menggunakan Convolutional Neural Network (CNN)

Proses *training* dilakukan menggunakan *dataset*, baik data *train* maupun data tes, di mana digunakan 80% *dataset* untuk proses *training* dan 20% dari total *dataset* untuk proses testing. Setelah melalui proses *pre-processing* dan proses ekstraksi fitur, akan dihasilkan matriks dari parameter-parameter GLCM. Informasi penting berupa matriks tersebut akan dipelajari oleh mesin sehingga mesin dapat menemukan pola dalam citra *input* dan melatih model untuk mendapatkan target.

Penelitian ini menggunakan metode klasifikasi CNN dengan mengimplementasikan beberapa *layer* seperti yang ditunjukkan pada Gambar 6. Citra *input* akan melalui operasi konvolusi pada *convolutional layer* dengan fungsi aktivasi *relu*. Lalu, memasuki *pooling layer* yang bertujuan untuk mereduksi ukuran dari citra (mengurangi jumlah parameter). Pada penelitian ini digunakan *max pooling layer*, yakni mengambil nilai



Gambar 6. Convolutional Neural Network.

Tabel 3. Confusion Matrix.

Confusion Matrix		Nilai Prediksi	
		Melanoma a (Negative)	Non-Melanoma (Positive)
Nilai Sebenarnya	Melanoma (Negative)	56 TP	4 FN
	Non-Melanoma (Positive)	11 FP	8 TN

yang paling besar pada bagian tersebut. Berikutnya terdapat proses *flattening*, di mana data *pooling* yang berupa *array* 2 dimensi akan dikonversi menjadi data 1 dimensi. Lalu, digunakan fungsi aktivasi *softmax* pada *fully connected layer*.

Confusion matrix digunakan untuk mengevaluasi model yang telah dihasilkan melalui proses klasifikasi untuk mengetahui performansi dari sistem yang telah dirancang. Metode ini dilaksanakan dengan menampilkan dan membandingkan nilai sebenarnya dengan nilai prediksi yang dihasilkan oleh model. Tabel 3 berikut merupakan tabel *confusion matrix* sistem pada penelitian ini.

Dari tabel *confusion matrix* di atas didapatkan nilai *true positive* (TP), *false positive* (FP), *false negative* (FN), dan *true negative* (TN) secara berturut-turut sebesar 56, 11, 4, dan 8. Performansi dari model klasifikasi dapat ditentukan melalui nilai matriks evaluasi berupa nilai akurasi, *recall*, presisi, dan *F1-score*.

Didapatkan nilai presisi dari model sebesar 84% melalui perhitungan menggunakan persamaan (5).

$$\text{Presisi} = \frac{TP}{TP + FP} \tag{5}$$

Sehingga, Presisi = 0,8358208955 ≈ 0,84

Dilanjutkan dengan menentukan nilai *recall*, yaitu keberhasilan model memprediksi secara tepat kategori positif dibandingkan dengan keseluruhan data yang sebenarnya merupakan nilai positif. Didapatkan nilai *recall* sebesar 94%.

$$\text{Recall} = \frac{TP}{TP + FN} \tag{6}$$

Sehingga, Recall = 0,9333333333 ≈ 0,94

F1-score pada sistem ini bernilai 89% dengan melakukan perhitungan pada persamaan (7).

$$F1 - \text{score} = \frac{2 \times \text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}} \tag{7}$$

Sehingga, F1 – score = 0,8871910112 ≈ 0,89 Nilai akurasi dari sistem dapat ditentukan melalui persamaan (8) sehingga menghasilkan akurasi sebesar 82%.

Sehingga, performa dari model klasifikasi dapat dikatakan sudah cukup baik dengan menggunakan metode ekstraksi GLCM dan klasifikasi CNN untuk memprediksi penyakit melanoma atau non-melanoma yang dapat dilihat berdasarkan nilai matriks evaluasi presisi, *recall*, *F1-score*, dan akurasi secara berturut-turut sebesar 84%, 94%, 89%, dan 82%.

3.6 Diskusi

Berdasarkan pembahasan yang telah dilakukan dan *state-of-the-art* yang telah dipaparkan bahwa keempat parameter dalam GLCM sangat memengaruhi akurasi dari metode yang diusulkan. Parameter entropi, korelasi, kontras, dan *uniformity* sangat penting dalam menentukan karakteristik setiap kelas *dataset* sehingga sistem dapat dengan mudah melakukan klasifikasi menggunakan CNN. Selain itu, jika dibandingkan dengan *state-of-the-art* metode-metode penelitian lainnya, dapat disimpulkan bahwa metode ini merupakan salah satu metode dengan akurasi yang baik.

4. Kesimpulan

Berdasarkan hasil dan analisis data pengujian yang telah dilakukan pada penelitian ini, dapat disimpulkan bahwa rancangan pendeteksi penyakit melanoma pada manusia menggunakan Raspberry pi yang terintegrasi dengan pi camera dan monitor dapat digunakan sebagai salah satu alat bantu untuk proses screening kasus penyakit melanoma. Metode yang digunakan pada penelitian ini adalah metode ekstraksi fitur GLCM dan metode klasifikasi CNN. Didapatkan akurasi pengujian pada sistem pendeteksi melanoma sebesar 82% dan *F1-score* sebesar 89%.

Daftar Pustaka

- [1] Chendage, R. Mente, and S. Pawar, "Detection and Classification of Melanoma Skin Cancer Analysis", International Journal of Scientific Research in Computer Science Engineering and Information Technology, 2021.
- [2] M. Dildar et al, "Skin cancer detection: A review using Deep Learning Techniques," International Journal of Environmental Research and Public Health, vol. 18, no. 10, p. 5479, 2021.

- [3] "Melanoma skin cancer statistics," American Cancer Society. [Online]. Available: <https://www.cancer.org/cancer/melanoma-skin-cancer/about/key-statistics.html>. [Accessed: 27-Oct-2022].
- [4] N. Akmalia, P. Sihombing, and Suherman, "Skin diseases classification using local binary pattern and convolutional neural network," 2019 3rd International Conference on Electrical, Telecommunication and Computer Engineering (ELTICOM), 2019.
- [5] K. Djunaidi et al, "Gray level co-occurrence matrix feature extraction and histogram in breast cancer classification with ultrasonographic imagery," Indonesian Journal of Electrical Engineering and Computer Science, vol. 22, no. 2, p. 795, 2021.
- [6] T. Haryanto et al, "Multipatch-GLCM for texture feature extraction on classification of the colon histopathology images using deep neural network with GPU acceleration," Journal of Computer Science, vol. 16, no. 3, pp. 280–294, 2020.
- [7] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101," Jurnal Teknik ITS, vol. 5, no. 1, 2016.
- [8] Zufar. Muhammad, Setiyono. Budi, "Convolutional Neural Networks Untuk Pengenalan Wajah Secara Real-time", Jurnal Sains dan Seni ITS, 2016.
- [9] P. Mohanaiah et al, "Image Texture Feature Extraction Using GLCM Approach", International Journal of Scientific and Research Publications, 2013.
- [10] "Melanoma death rates in 31 countries between 1985 and 2015," British Journal of Dermatology, vol. 183, no. 6, 2020.
- [11] Silpa Joseph, "Image Processing Techniques And Its Applications: An Overview," International Journal Of Advance Research And Innovative Ideas In Education, vol. 4, no. 3, pp. 2168-2174, May-Jun 2018
- [12] L.-sheng Wei et al, "Skin disease recognition method based on image color and texture features," Computational and Mathematical Methods in Medicine, vol. 2018, pp. 1–10, 2018.
- [13] M. R. Alwanda, R. P. Ramadhan, and D. Alamsyah, "Implementasi metode convolutional neural network Menggunakan Arsitektur Lenet-5 Untuk Pengenalan Doodle," Jurnal Algoritme, vol. 1, no. 1, pp. 45–56, 2020.
- [14] S. Sharma and R. Mehra, "Implications of pooling strategies in convolutional neural networks: A deep insight," Foundations of Computing and Decision Sciences, vol. 44, (3), pp. 303-330, 2019.
- [15] A. Anton et al, "Application of Deep Learning Using Convolutional Neural Network (CNN) Method for Women's Skin Classification," Scientific Journal of Informatics, vol. 8, (1), pp. 144-153, 2021.
- [16] P. L. Santori, "Melanoma detection dataset," Kaggle, 12-May-2020. [Online]. Available: <https://www.kaggle.com/wanderdust/skin-lesion-analysis-toward-melanoma-detection>. [Accessed: 24-Jan-2022].
- [17] A. Dosovitskiy et al, "An image is worth 16x16 words: Transformers for image recognition at scale," arXiv Preprint arXiv:2010.11929, 2020.
- [18] S. Gao et al, "Res2net: A new multi-scale backbone architecture," IEEE Trans. Pattern Anal. Mach. Intell., vol. 43, (2), pp. 652-662, 2019.
- [19] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in International Conference on Machine Learning, 2019.
- [20] S. Xie et al, "Aggregated residual transformations for deep neural networks," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.