



Implementasi Metode Convolutional Neural Network untuk Klasifikasi Breast Cancer pada Citra Histopatologi

Muhammad Afrizal Amrustian*, Merlinda Wibowo

Fakultas Informatika, Teknik Informatika, Institut Teknologi Telkom Purwokerto, Purwokerto, Indonesia

Email: ^{1,*}afrizal.amru@ittelkom-pwt.ac.id, ²merlinda@ittelkom-pwt.ac.id

Email Penulis Korespondensi: afrizal.amru@ittelkom-pwt.ac.id

Abstrak—Breast cancer merupakan sebuah tumor yang berbentuk benjolan abnormal pada bagian payudara wanita. Beberapa hal yang menjadi pemicu terjadinya breast cancer pada wanita adalah factor genetik dan gaya hidup. Global Cancer Statistics menyebutkan bahwa dari 2.3 juta kasus breast cancer terdapat 600 ribu kasus yang berujung dengan kematian. Angka kematian akibat kasus breast cancer di Indonesia juga tergolong tinggi, angka kematian di Indonesia akibat breast cancer mencapai 17% untuk setiap 100 ribu penduduk wanita di Indonesia. Salah satu cara untuk mendeteksi penyakit breast cancer adalah penggunaan citra histopatologi. Pasien akan diambil citra dari sel payudaranya, untuk kemudian dipelajari oleh tenaga medis dan didiagnosa. Walaupun citra histopatologi digunakan sebagai salah satu benchmark data untuk diagnosis breast cancer, angka kematian akibat breast cancer masih tergolong tinggi. Salah satu penyebab tingginya angka kematian yang disebabkan breast cancer adalah deteksi penyakit yang lambat sehingga pasien ditangani saat penyakit breast cancer sudah masuk kondisi berat, serta kadang terjadi misdiagnosis. Oleh karena itu untuk mengatasi masalah yang telah dipaparkan, maka penulis mengajukan untuk membuat model klasifikasi breast cancer menggunakan metode Convolutional Neural Network (CNN). Hasil dari penelitian menjelaskan bahwa CNN dapat melakukan klasifikasi kasus breast cancer dengan capaian nilai akurasi sebesar 85%. Selain itu dengan menghitung dengan loss function, model yang dibangun terhindar dari kejadian overfitting.


Kata Kunci: Breast Cancer; CNN; Deep Learning; Loss Funtion; ReLu

Abstract—Breast cancer is a tumor that manifests as an abnormal lump in the breast of a woman. The occurrence of breast cancer in women can be triggered by genetic and lifestyle factors. According to Global Cancer Statistics, 600,000 out of 2.3 million occurrences of breast cancer result in death. The death rate from breast cancer in Indonesia is likewise relatively high, reaching 17% for every 100,000 female inhabitants. Using histological pictures to diagnose breast cancer is one technique. The patient will capture an image of her breast cells, which will be examined and diagnosed by medical personnel. Even if histopathological scans are utilized as a baseline for the detection of breast cancer, the death rate associated with this disease remains rather high. One of the causes for the high mortality rate associated with breast cancer is the late detection of the disease, which results in patients being treated when the disease is in a severe state, and sometimes a misdiagnosis. The authors propose creating a breast cancer classification model utilizing the convolutional neural network (CNN) method in order to address the described issues. The study's findings indicate that CNN can classify breast cancer patients with an accuracy of 85 percent. Moreover, by calculating the loss function, the constructed model prevents overfitting.

Keywords: Breast Cancer; CNN; Deep Learning; Loss Funtion; ReLu

1. PENDAHULUAN

Breast cancer merupakan sebuah tumor yang muncul disebabkan oleh sel yang ada di bagian payudara tumbuh dengan abnormal [1]. Dokter akan mendiagnosa seseorang menderita breast cancer saat dokter menemukan benjolan yang abnormal saat memeriksa hasil x-ray jaringan payudara. Breast cancer dapat ketahui dengan melihat tiga protein yang menjadi penyusun utama breast cancer, yakni Estrogen Receptor (ER), Progesterone Receptor (PR), dan HER2. Gambar 1 merupakan ilustrasi dari jaringan payudara yang terdiagnosa breast cancer, serta perbedaan antara sel sehat dan sel yang abnormal.



Gambar 1. Ilustrasi Breast cancer

Terdapat faktor-faktor yang yang mempengaruhi penyakit breast cancer, faktor-faktor tersebut dapat dilihat pada Tabel 1.



Tabel 1. Faktor-faktor penyebab breast cancer [2]

	Faktor Resiko	Protective	Predisposing	Controversial
Demographic	Jenis Kelamin		v	
	Umur		v	
	Golongan Darah			v
Reproductive	Umur Menstruasi			v
	Menopause		v	
	Kehamilan	v		
	Aborsi			v
	Siklus menstruasi	v		
Hormonal	Karakter Kehamilan	v	v	
	Metode Hormonal kontrasepsi		v	
	Ovulation-stimulating drugs			v
	Postmenopausal hormone therapy		v	
Hereditary	Faktor genetik		v	
	Histori keluarga yang terdianosa breast cancer		v	
Breast Related	Lesser location duration	v		
	More breast density			v
	Benign breast disorders		v	
Lifestyle	Obesitas		v	
	Konsumsi alkohol		v	
	Merokok		v	
	Kopi			v
	Diet		v	
	Banyak kegiatan fisik	v		
Others	Vitamin D	v		
	Durasi tidur			v
	Polusi udara		v	
	Kerja malam		v	
	Socioeconomic status		v	
	Diabetes		v	
	Radiasi		v	


Pada Tabel 1 menyajikan data terkait faktor-faktor dari breast cancer, dari faktor demographic hingga lifestyle. Pada masing-masing faktor terdapat indikator khusus yang menjadi penyebab breast cancer. Terdapat tiga faktor resiko yakni protective yang berarti indikator tersebut akan membantu dalam mencegah terjadinya breast cancer. Predisposing yang bermakna indikator tersebut merupakan pemicu dari breast cancer. Sedangkan controversial masih belum ditentukan dengan pasti bahwa indikator tersebut menjadi penyebab breast cancer.

Breast cancer menjadi jenis kanker yang paling sering terdiagnosa serta memiliki angka kematian yang tinggi pada wanita di seluruh dunia. Global Cancer Statistics menyatakan bahwa kasus breast cancer di seluruh dunia tercatat mencapai 2.3 juta kasus dengan angka kematian mencapai angka 600.000 [3]. Wanita di Indonesia juga tak luput dari tingginya kasus breast cancer ini. Tercatat kasus breast cancer di Indonesia mencapai angka 1000 kasus untuk satu rumah sakit dengan keseluruhan kasus mencapai 42% per 100.000 penduduk wanita di Indonesia dengan angka kematian 17% per 100.000 penduduk wanita [4] [5]. Kematian yang disebabkan oleh breast cancer dikarenakan penyakit ini dapat menular ke organ lain seperti tulang, hati, bahkan hingga ke otak. Diagnosa awal menjadi kunci untuk mengobati penyakit breast cancer. Dengan diagnosa awal yang tepat, pasien bisa mendapatkan penanganan yang tepat untuk mengobati breast cancer dan dapat mencegah kematian yang terjadi akibat dari breast cancer. Namun menurut beberapa penelitian, diagnosa awal terhadap breast cancer masih belum dilakukan dengan tepat dan akurat, sehingga kasus breast cancer menjadi terlambat untuk ditangani bahkan dapat berujung kepada kematian pasien [6].

Pada dunia medis modern saat ini, digital pathology merupakan sebuah kemajuan yang besar. Digital pathology dapat menangkap citra jaringan manusia dengan sangat tajam, sehingga membantu dalam menentukan



penyakit pada manusia. Citra terkait informasi hematoxylin dan eosin sangat membantu dalam mendiagnosa penyakit breast cancer [7]. Gambar 2 mengilustrasikan citra histopatologi yang dapat digunakan untuk mendiagnosa breast cancer.



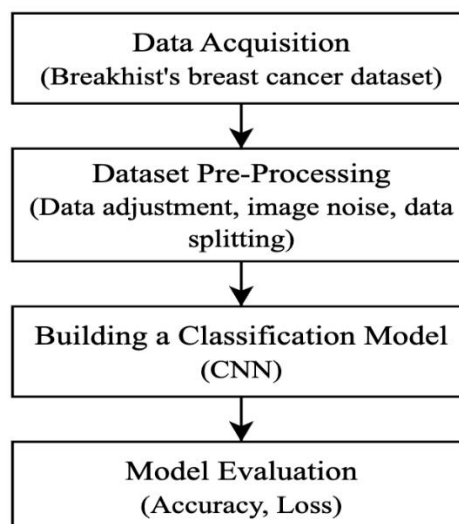
Gambar 2. Citra histopatologi

Proses biopsi merupakan teknik diagnosa kanker dengan mengambil citra jaringan tubuh, proses tersebut menghasilkan sebuah citra histopatologi. Citra histopatologi merepresentasikan jaringan pada tubuh, baik itu jaringan yang sehat maupun yang terindikasi kanker [8]–[10]. Kemudian citra histopatologi menjadi dasar untuk mendeteksi breast cancer. Citra histopatologi akan dicermati oleh radiolog dan dokter untuk menentukan kondisi pasien. Namun kesalahan interpretasi pada citra oleh radiolog dan dokter menjadi hal yang perlu diperhatikan saat ini karena terjadi kasus kesalahan interpretasi breast cancer oleh radiolog dan dokter sebesar 25% [11]. Selain itu, interpretasi citra secara ganda oleh radiolog dan dokter juga memakan biaya lebih, yang mana akan membebani pasien. Oleh karena itu beberapa penelitian untuk mendeteksi breast cancer dengan bantuan komputer marak dilakukan, terutama dengan penggunaan metode deep learning. Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang umum digunakan untuk klasifikasi citra. Penggunaan metode CNN terbukti dapat mengklasifikasi breast cancer dengan akurasi mencapai 84.49% dengan menggunakan layer pada CNN sebanyak 17 layer [12] [13]. Namun dari beberapa penelitian yang telah dipaparkan, masih ada ruang yang dapat ditingkatkan dari sisi akurasi dalam membuat sebuah model klasifikasi untuk breast cancer.

Berdasarkan permasalahan yang telah dipaparkan, penelitian ini bertujuan untuk melakukan implementasi metode CNN untuk klasifikasi breast cancer dengan menggunakan citra histopatologi ke dalam bentuk sistem berbasis web. Dengan dilakukannya penelitian ini, diharapkan dapat membantu diagnosa breast cancer dengan lebih cepat dan akurat. Hasil penelitian pada jurnal ini terbagi menjadi beberapa bagian yakni, metodologi penelitian, hasil, dan kesimpulan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian



Gambar 3. Tahapan Penelitian



2.1.1 Data Acquisition

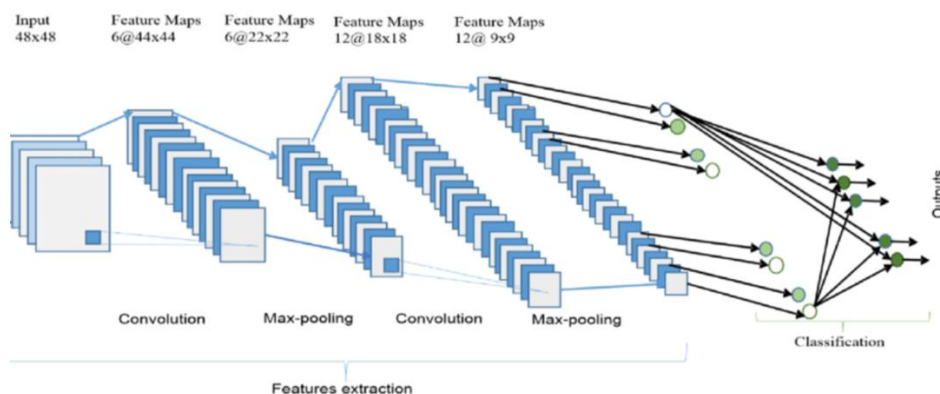
Tahap pertama pada penelitian yang dilakukan adalah data acquisition. Pada tahap ini kami melakukan pengumpulan data, yang mana data yang digunakan adalah The Breast Cancer Histopathological Image Classification (BreakHis) [14], data tersebut bersifat open source dan dapat diunduh secara langsung. Data BreakHis sendiri terdiri dari 9,109 citra histopatologi breast cancer. Citra tersebut diambil dari 82 pasien dengan resolusi yang berbeda. Data BreakHis memiliki dua kelas yakni benign dan malignant, kelas benign merupakan kelas citra yang sehat dan kelas malignant adalah kelas citra yang terdiagnosis breast cancer.

2.1.2 Dataset Pre-processing

Tahapan setelah data didapatkan, kami melakukan pre-processing data. Tahap pre-processing terbagi menjadi tiga bagian yakni data adjustment, image noise, dan data splitting. Langkah pertama adalah data adjustment, pada langkah ini kami melakukan penyesuaian pada data dengan mengumpulkan data ke dalam satu folder, kemudian membuat sebuah dataframe untuk memudahkan dalam mengolah data. Langkah kedua adalah penerapan gaussian image noise pada data citra. Gaussian image noise memiliki fungsi untuk mendeteksi noise pada data citra sehingga akan didapatkan garis tepi dari citra [15].

2.1.3 Building a Classification Model

Tahap ketiga pada penelitian ini adalah pembuatan model klasifikasi. Model yang dibangun menggunakan metode CNN. Metode CNN memiliki kemampuan untuk klasifikasi citra, sehingga banyak digunakan oleh peneliti [16]–[18]. Gambar 4 merupakan arsitektur dari CNN. Pada pembangunan model menggunakan CNN, maka akan rentan terjadi overfitting pada model. Penggunaan sebuah fungsi aktivasi akan menghindarkan sebuah model dari kejadian overfitting [19]. ReLu merupakan fungsi aktivasi yang digunakan pada penelitian ini, selain itu fungsi softmax digunakan untuk melakukan klasifikasi akhir dan fungsi adam menjadi optimizer pada model yang dibangun.



Gambar 4. Arsitektur CNN [20]

2.1.4 Model Evaluation

Evaluasi model dilakukan dengan menghitung loss function. Pada penelitian ini kami menggunakan rumus pixel-wise cross-entropy loss yang dapat dilihat pada persamaan 1 [19].


$$\Phi(x) = \frac{-1}{N} \sum_{i=1}^C (\sum_{x \in S_i} \log(\pi_i(x))) \quad (1)$$

3. HASIL DAN PEMBAHASAN


Pada bagian ini berisi hasil dan pembahasan dari penelitian yang telah dilakukan. Setiap tahap penelitian dijelaskan pada bagian berikut.

3.1 Data Acquisition

Pada tahap ini, kami melakukan proses pengumpulan data. Pengumpulan data dilakukan dengan mengunduh dataset The Breast Cancer Histopathological Image Classification (BreakHis). Data BreakHis kami unduh dari laman Laboratorium Patologi, Anatomi, dan Cytopatologi, Parana Brazil. Data tersebut bersifat open source dan dapat digunakan oleh peneliti manapun. Dataset BreakHis dapat dibagi menjadi dua bagian, yakni benign dan malignant. Data benign merupakan data citra jaringan sel yang sehat dan tidak mengakibatkan dampak buruk bagi sel yang lain. Data malignant adalah data citra jaringan sel yang terdiagnosa breast cancer dan dapat menyebar serta memberikan kerusakan bagi sel yang lain. Gambar 5 merupakan contoh dari data citra histopatologi yang sehat, sedangkan gambar 6 adalah data citra yang terdiagnosa breast cancer.



Gambar 5. Dataset BreakHis dengan kelas Benign



Gambar 6. Dataset BreakHis dengan kelas malignan

3.2 Data Pre-Processing

Pada tahap ini, kami melakukan pengolahan data yang telah diunduh. Langkah awal yang dilakukan adalah menambahkan kelas pada nama file. Berikut adalah pseudocode untuk menambahkan kelas pada nama file menggunakan python.

```

Fungsi untuk penambahan kelas pada nama file
Deklarasi
file_list_0, file_list_1: string
Path_0, path_1: folder
Algoritma:
Path_0 = semua file citra benign+kode pasien+/0
Path_1 = semua file citra malign+kode pasien+/1
For setiap file yang ada di masing-masing folder
    Nama_file_baru_citra_benign = path_0+class0
    Nama_file_baru_citra_malign = path_1+class1
    
```

Langkah penambahan kelas pada nama file berguna untuk memberikan informasi terkait kelas suatu citra ketika akan dibaca. Sehingga hasil dari langkah ini dapat dilihat pada gambar 7 berikut.

```

['10257_idx5_x1401_y1151_class0.png', '10257_idx5_x2051_y801_class1.png']
    
```

Gambar 7. hasil penambahan kelas pada nama file citra


Langkah selanjutnya adalah pembuatan dataframe dari keseluruhan data citra yang ada. Pembuatan dataframe Menggunakan fungsi dataframe pada python, maka hasil dari dataframe yang dibuat dapat dilihat pada gambar 8 berikut.

	image_id	target	patient_id
0	10257_idx5_x1401_y1151_class0.png	0	10257
1	10257_idx5_x2051_y801_class1.png	1	10257
2	10253_idx5_x2001_y1151_class0.png	0	10253
3	10253_idx5_x601_y751_class1.png	1	10253
4	10253_idx5_x801_y701_class1.png	1	10253


Gambar 8. Dataframe yang telah dibuat




Dataframe yang telah dibuat terdiri dari tiga tabel yakni, image_id, target, patient_id. Image_id merupakan nama unik dari setiap data citra. Patient_id merupakan id dari pasien, dan target adalah kelas dari masing-masing citra. Langkah selanjutnya ialah pemrosesan data citra. pada langkah ini metode gaussian dan random noise digunakan untuk menghilangkan noise pada citra, sehingga didapatkan tepi citra secara jelas. Gambar merupakan hasil penerapan metode gaussian pada citra, sedangkan Gambar 9 adalah hasil dari penerapan random noise pada citra, dan Gambar 10 merupakan hasil penggabungan antara proses dengan gaussian dan random noise.



Gambar 9. Hasil penerapan metode gaussian




Gambar 10. Hasil penerapan metode random noise




Gambar 11. Hasil penggabungan antara metode gaussian dan random noise

Hasil akhir tahapan pra-proses data citra pada masing-masing kelas dapat dilihat pada gambar 12 berikut.



Gambar 12. Hasil pra-proses data citra pada kelas benign



Gambar 13. Hasil pra-proses data citra pada kelas malignant



3.3 CNN Model

Tahap ketiga pada penelitian ini adalah pembuatan model. Model dibuat menggunakan metode CNN. Pada arsitektur CNN terbagi menjadi beberapa bagian yakni input layer, convolutional layer, dan fungsi aktivasi. Bagian pertama pada arsitektur CNN yang dibangun adalah input layer, arsitektur yang dibangun memiliki input yang berukuran 50x50x3. Kemudian untuk convolutional layer yang dibangun ada 32 layer. Terakhir, arsitektur yang dibangun menggunakan fungsi aktivasi relu. Berikut ini adalah pseudocode untuk pembuatan model klasifikasi.

```

Fungsi pembuatan model
Deklarasi
BC_Model
Algoritma
BC_Model = BC_Model.add(Conv2D(filters=32, kernel_size=(4,4),
input_shape=(50,50,3), activation='relu'))
BC_Model = BC_Model.add(MaxPool2D(pool_size=(2,2)))
BC_Model.add(Flatten())
BC_Model.add(Dense(128, activation='relu'))
BC_Model.add(Dense(2, activation='softmax'))
    
```

Summary dari model yang dibuat dapat dilihat pada gambar 14 berikut.

Layer (type)	Output Shape	Param #
conv2d_2 (Conv2D)	(None, 22, 22, 32)	1568
conv2d_3 (Conv2D)	(None, 19, 19, 32)	16416
max_pooling2d_2 (MaxPooling2D)	(None, 9, 9, 32)	0
dropout (Dropout)	(None, 9, 9, 32)	0
flatten_2 (Flatten)	(None, 2592)	0
dense_4 (Dense)	(None, 256)	663808
dense_5 (Dense)	(None, 2)	514
Total params: 682,386		
Trainable params: 682,386		
Non-trainable params: 0		

Gambar 14. Summary model klasifikasi

3.4 Model Evaluation

Model yang telah dibuat dievaluasi menggunakan persamaan 1, model dibuat berulang-ulang sebanyak 60 kali perulangan untuk mendapatkan model terbaik. Gambar 15 adalah proses perulangan pada pembuatan model.

```

24978/24978 [=====] - 271s 11ms/step - loss: 0.4468 - accuracy: 0.8030 - val_loss:
0.3852 - val_accuracy: 0.8319
Epoch 2/60
24978/24978 [=====] - 238s 10ms/step - loss: 0.4023 - accuracy: 0.8278 - val_loss:
0.3711 - val_accuracy: 0.8484
Epoch 3/60
24978/24978 [=====] - 234s 9ms/step - loss: 0.3885 - accuracy: 0.8350 - val_loss:
0.3644 - val_accuracy: 0.8446
Epoch 4/60
24978/24978 [=====] - 234s 9ms/step - loss: 0.3782 - accuracy: 0.8392 - val_loss:
0.3625 - val_accuracy: 0.8451
Epoch 5/60
24978/24978 [=====] - 234s 9ms/step - loss: 0.3759 - accuracy: 0.8404 - val_loss:
0.3487 - val_accuracy: 0.8504
Epoch 6/60
24978/24978 [=====] - 233s 9ms/step - loss: 0.3650 - accuracy: 0.8442 - val_loss:
0.3627 - val_accuracy: 0.8450
Epoch 7/60
24978/24978 [=====] - 233s 9ms/step - loss: 0.3591 - accuracy: 0.8480 - val_loss:
0.3655 - val_accuracy: 0.8457
    
```

Gambar 15. Proses perulangan pembuatan model

Setelah model dibuat, maka model akan dievaluasi menggunakan data uji yang telah dibagi sebelumnya. Sehingga nilai akurasi dan nilai loss akan terbagi menjadi dua, yakni nilai dari data latih dan nilai dari data uji. Hasil dari data latih kami sebut sebagai loss dan akurasi, sedangkan hasil dari data uji kami sebut sebagai validasi loss dan validasi akurasi. Nilai validasi loss dan validasi akurasi memiliki fungsi untuk memastikan tidak ada overfitting pada model yang dibangun. Hasil dari evaluasi model dapat dilihat pada tabel 2 dibawah ini.


Tabel 2. Tabel evaluasi

No	Loss	Akurasi	Validasi Loss	Validasi Akurasi
1	0.426670	0.815039	0.385204	0.831946
2	0.397042	0.830016	0.371130	0.840378
3	0.387825	0.834432	0.364391	0.844629




No	Loss	Akurasi	Validasi Loss	Validasi Akurasi
4	0.377981	0.838989	0.362490	0.845134
5	0.372410	0.842023	0.348721	0.850395

Dalam mempermudah pembacaan hasil klasifikasi, maka kami tampilkan juga hasil evaluasi dalam bentuk grafik. Gambar 16 adalah grafik dari nilai akurasi dengan garis biru adalah nilai akurasi dan garis orange adalah nilai dari validasi akurasi.



Gambar 16. grafik akurasi model

Kemudian pada gambar 17 merupakan grafik dari nilai loss pada model. Garis biru adalah nilai loss dan garis orange adalah nilai untuk validasi loss. Seiring berjalannya perulangan pada proses pembuatan model, maka nilai loss dan validasi loss akan ikut menurun. Penurunan nilai loss disebabkan oleh nilai akurasi yang semakin tinggi dan model yang semakin cocok untuk klasifikasi. Nilai loss dan validasi loss juga dapat dijadikan indikator untuk menghentikan proses perulangan pada pembuatan model jika nilai loss dan validasi loss tidak menunjukkan penurunan lagi.



Gambar 17. Grafik nilai loss pada model

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, maka pada bagian ini akan diambil beberapa kesimpulan. Kesimpulan pertama adalah citra histopatologi dapat digunakan sebagai data untuk pembuatan model klasifikasi breast cancer. Kedua, metode CNN dapat melakukan klasifikasi breast cancer melalui citra histopatologi dengan akurasi yang mencapai 85%. Ketiga, evaluasi model dengan perhitungan nilai akurasi dan nilai loss sudah cukup untuk mengevaluasi model yang dibuat. Keempat, berdasarkan evaluasi yang telah dilakukan, yakni menggunakan nilai loss dan validasi loss. Maka model yang dibuat dapat diimplementasikan lebih lanjut ke dalam sebuah sistem, hal tersebut dikarenakan tidak adanya kasus overfitting pada model yang dibuat. Penelitian yang dilakukan memiliki beberapa keterbatasan. Pertama, untuk kasus pada bidang kesehatan perlu dilakukan analisa dan uji coba lapangan yang lebih. Analisa dan uji coba lapangan lebih lanjut dapat dilakukan dengan bekerjasama dengan dokter spesialis kanker dan rumah sakit. Sehingga model dan sistem dapat dikembangkan lebih jauh lagi. Kedua, masih banyak ruang yang bisa dikembangkan dari penelitian yang telah dilaksanakan. Mulai dari pengembangan akurasi model, pengembangan pembacaan data citra, serta pengembangan sistem untuk dapat digunakan.

UCAPAN TERIMAKASIH

Ucapan terima kasih kami ucapkan kepada seluruh tim yang telah membantu pelaksanaan penelitian ini. Kemudian kepada pihak yang telah menyediakan dataset citra histopatologi breast cancer. Tak lupa kami ucapkan kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi yang telah memberikan fasilitas untuk pelaksanaan penelitian. Terakhir untuk Institut Teknologi Telkom Purwokerto yang telah menaungi dan mengawal proses penelitian.

REFERENCES

- [1] A. G. Waks and E. P. Winer, "Breast Cancer Treatment: A Review," *JAMA - Journal of the American Medical Association*, vol. 321, no. 3, pp. 288–300, 2019, doi: 10.1001/jama.2018.19323.



- [2] Z. Momenimovahed and H. Salehiniya, "Epidemiological characteristics of and risk factors for breast cancer in the world," *Breast Cancer: Targets and Therapy*, vol. 11, pp. 151–164, 2019, doi: 10.2147/BCTT.S176070.
- [3] H. Sung et al., "Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries," *CA Cancer J Clin*, vol. 71, no. 3, pp. 209–249, 2021, doi: 10.3322/caac.21660.
- [4] Kemkes, "Penyakit Kanker di Indonesia Berada Pada Urutan 8 di Asia Tenggara dan Urutan 23 di Asia," 2019. <http://p2p.kemkes.go.id/penyakit-kanker-di-indonesia-berada-pada-urutan-8-di-asia-tenggara-dan-urutan-23-di-asia/>
- [5] S. L. Anwar et al., "Pathological profiles and clinical management challenges of breast cancer emerging in young women in Indonesia: A hospital-based study," *BMC Womens Health*, vol. 19, no. 1, pp. 1–8, 2019, doi: 10.1186/s12905-019-0724-3.
- [6] S. L. Anwar et al., "Risk factors of distant metastasis after surgery among different breast cancer subtypes: A hospital-based study in Indonesia," *World J Surg Oncol*, vol. 18, no. 1, pp. 1–16, 2020, doi: 10.1186/s12957-020-01893-w.
- [7] R. Krithiga and P. Geetha, "Breast Cancer Detection, Segmentation and Classification on Histopathology Images Analysis: A Systematic Review," *Archives of Computational Methods in Engineering*, vol. 28, no. 4, pp. 2607–2619, 2021, doi: 10.1007/s11831-020-09470-w.
- [8] E. Deniz, A. Şengür, Z. Kadiroğlu, Y. Guo, V. Bajaj, and Ü. Budak, "Transfer learning based histopathologic image classification for breast cancer detection," *Health Inf Sci Syst*, vol. 6, no. 1, pp. 1–7, 2018, doi: 10.1007/s13755-018-0057-x.
- [9] M. Liu et al., "A Deep Learning Method for Breast Cancer Classification in the Pathology Images," *IEEE J Biomed Health Inform*, 2022, doi: 10.1109/JBHI.2022.3187765.
- [10] Z. Gao, Z. Lu, J. Wang, S. Ying, and J. Shi, "A Convolutional Neural Network and Graph Convolutional Network Based Framework for Classification of Breast Histopathological Images," *IEEE J Biomed Health Inform*, vol. 26, no. 7, pp. 3163–3173, Jul. 2022, doi: 10.1109/JBHI.2022.3153671.
- [11] A. Rodriguez-Ruiz et al., "Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists," *J Natl Cancer Inst*, vol. 111, no. 9, pp. 916–922, 2019, doi: 10.1093/jnci/djy222.
- [12] Z. Zainudin, S. M. Shamsuddin, and S. Hasan, "Deep Layer CNN Architecture for Breast Cancer Histopathology Image Detection," in *The International Conference on Advanced Machine Learning Technologies and Applications (AMLTA2019)*, 2019, pp. 43–51. doi: https://doi.org/10.1007/978-3-030-14118-9_5.
- [13] Z. Zainudin, S. M. Shamsuddin, and S. Hasan, "Deep Learning Layer Convolutional Neural Network (CNN) Scheme for Cancer Image," *IOP Conf Ser Mater Sci Eng*, vol. 551, no. 1, 2019, doi: 10.1088/1757-899X/551/1/012039.
- [14] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, "A Dataset for Breast Cancer Histopathological Image Classification," *IEEE Trans Biomed Eng*, vol. 63, no. 7, pp. 1455–1462, Jul. 2016, doi: 10.1109/TBME.2015.2496264.
- [15] A. Mohammed Abd-alsalam Selami and A. Freidoon Fadhil, "A Study of the Effects of Gaussian Noise on Image Features," *Kirkuk University Journal-Scientific Studies*, vol. 11, no. 3, pp. 152–169, Sep. 2016, doi: 10.32894/kujss.2016.124648.
- [16] P. Oza, P. Sharma, S. Patel, and P. Kumar, "Deep convolutional neural networks for computer-aided breast cancer diagnostic: a survey," *Neural Computing and Applications*, vol. 34, no. 3. Springer Science and Business Media Deutschland GmbH, pp. 1815–1836, Feb. 01, 2022. doi: 10.1007/s00521-021-06804-y.
- [17] F. Gao et al., "SD-CNN: A shallow-deep CNN for improved breast cancer diagnosis," *Computerized Medical Imaging and Graphics*, vol. 70, pp. 53–62, Dec. 2018, doi: 10.1016/j.compmedimag.2018.09.004.
- [18] S. Kaymak, A. Helwan, and D. Uzun, "Breast cancer image classification using artificial neural networks," in *Procedia Computer Science*, 2017, vol. 120, pp. 126–131. doi: 10.1016/j.procs.2017.11.219.
- [19] B. Biswas, S. Kr. Ghosh, and A. Ghosh, "A Robust Multi-label Fruit Classification Based on Deep Convolution Neural Network," 2020, pp. 105–115. doi: 10.1007/978-981-13-9042-5_10.
- [20] M. Z. Alom et al., "A State-of-the-Art Survey on Deep Learning Theory and Architectures," *Electronics (Basel)*, vol. 8, no. 3, p. 292, Mar. 2019, doi: 10.3390/electronics8030292.