



Vol. 7 No. 2 (2022) 43 - 52

JOINTECS

(Journal of Information Technology
and Computer Science)

e-ISSN:2541-6448

p-ISSN:2541-3619

Implementasi Metode CNN *Multi-Scale Input* dan *Multi-Feature Network* untuk Dugaan Kanker Payudara

Ghifari Prameswari Natakusumah¹, Ernastuti²

Program Studi Magister Manajemen Sistem Informasi, Pascasarjana, Universitas Gunadarma

¹ghifaripn@student.gunadarma.ac.id, ²ernas@staff.gunadarma.ac.id

Abstract

According to WHO, cancer is one type of disease with a high increase in terms of cases around the world. Breast cancer is the highest contributor to morbidity rates in 2020, which is 2.26 million cases. In determining the patient's prognosis, several examinations are needed, one of them is histopathological analysis. However, histopathological analysis is a relatively tedious and time-consuming process. With the development of deep learning, computer vision can be applied for detection in medical images, which is expected to help improve the accuracy of the prognosis and the speed of identification carried out by experts. Based on this knowledge, this study aims to implement multi-class classification (normal, benign, in situ, invasive) and prediction of normal digital tissue images or has suspected cancer cells using the Convolutional Neural Network with multi-scale and multi-feature network (CNN-G). The dataset used is 400 breast tissue image data which are classified into four classes and labeled by a pathologist. The accuracy result obtained from the training is 0.5375~0.54 and has made an increase when the result was compared to single models (CNN14, CNN42, CNN84). Other model evaluation methods conducted are confusion matrix, precision, recall, and f-1 score.

Keywords: artificial intelligence; breast cancer prediction; convolutional neural network; deep learning; multi-class classification.

Abstrak

Menurut WHO, kanker payudara merupakan penyumbang angka morbiditas tertinggi pada tahun 2020 dengan jumlah 2,26 juta kasus. Dalam menentukan prognosis pasien diperlukan berbagai pemeriksaan, salah satunya adalah analisis histopatologi. Namun, analisis histopatologi adalah proses yang relatif melelahkan dan memakan waktu. Dengan berkembangnya metode *deep learning*, ilmu *computer vision* dapat diterapkan untuk pendeteksian kanker pada citra medis, yang diharapkan dapat membantu meningkatkan akurasi prognosis dan kecepatan identifikasi yang dilakukan oleh para ahli. Berdasarkan pengetahuan tersebut, penelitian ini bertujuan untuk menerapkan klasifikasi multi-kelas (normal, benign, in situ, invasif) dan prediksi citra jaringan digital normal atau telah diduga memiliki sel kanker menggunakan *Convolutional Neural Network* dengan *multi-scale* input dan *multi-feature network* (CNN-G). Dataset yang digunakan adalah 400 data citra jaringan payudara yang diklasifikasikan menjadi empat kelas dan diberi label oleh ahli patologi. Hasil akurasi yang diperoleh dari pelatihan adalah 0,5375~0,54 dan berhasil membuat peningkatan jika dibandingkan dengan model tunggal (CNN14, CNN42, CNN84). Metode evaluasi model lain yang dilakukan adalah *confusion matrix*, *precision*, *recall*, dan *f-1 score*.

Kata kunci: kecerdasan buatan; klasifikasi multi-kelas; machine learning; convolutional neural network; prediksi kanker payudara.



1. Pendahuluan

Kanker merupakan salah satu jenis penyakit dengan peningkatan jumlah kasus yang tinggi di dunia. Berdasarkan data yang diperoleh dari WHO (*World Health Organization*), di tahun 2018 terdapat 18,1 juta

kasus baru dengan angka kematian sebesar 9,6 juta kematian, dimana 1 dari 5 laki-laki dan 1 dari 6 perempuan di dunia mengalami penyakit kanker. Data tersebut menyatakan 1 dari 8 laki-laki dan 1 dari 11 perempuan, meninggal karena kanker. Di Indonesia,

Diterima Redaksi : 08-04-2022 | Selesai Revisi : 09-05-2022 | Diterbitkan Online : 31-05-2022

angka kejadian penyakit kanker di Indonesia sejumlah (136.2/100.000 penduduk) yang berada pada peringkat 8 di Asia Tenggara dan 23 di Asia. Pada tahun 2020, menurut data WHO juga pada tahun 2020 hampir 10 juta kematian disebabkan kanker, dengan kanker payudara memiliki angka morbiditas paling tinggi yaitu sebesar 2,26 juta kasus.

Histopatologi atau studi mempelajari jaringan, memiliki kontribusi besar dalam menentukan prognosis penyakit kanker pada tingkat jaringan. Analisis kuantitatif gambar histopatologis dapat digunakan untuk menentukan perawatan yang sebaiknya dilakukan. Dalam melakukan prognosis untuk penyebaran atau deteksi kanker, pada umumnya dilakukan penelitian atau pemeriksaan pada jaringan pasien dengan bantuan citra medis [1]. Ilmu histopatologi atau ilmu yang mempelajari jaringan berperan besar dalam penentuan prognosis dari kanker tersebut [2]. Pemeriksaan dilakukan oleh ahli histopatologi secara manual dengan bantuan alat mikroskopis.

Dalam pendeteksian kanker pada citra medis digunakan banyak cara, contohnya seperti pada kanker payudara yaitu dengan Mamografi, *Magnetic Resonance Imaging* (MRI), *Computed Tomography* (CT), dan *Ultrasound*. Meskipun metode diagnosis tersebut sudah umum digunakan, diperlukan peningkatan tingkat akurasi. Kualitas set fitur yang didapatkan secara manual dapat memengaruhi langsung keakuratan diagnosis, hal ini membuat dokter yang berpengalaman memiliki peran yang sangat penting dalam proses ekstraksi fitur manual [3]. Namun, analisis histopatologi adalah proses yang relatif melelahkan karena kompleksitas struktur di jaringan berbeda. Ahli patologi membutuhkan banyak keahlian dan keterampilan untuk melakukan analisis.

Pemeriksaan kualitatif atas sejumlah besar data yang disajikan dalam gambar adalah tugas yang melelahkan dan menuntut jam kerja profesional. Selain itu, inspeksi visual gambar oleh para ahli dapat menyebabkan hasil yang kurang akurat karena sifatnya yang subjektif [4]. Penggunaan ilmu *computer vision* untuk pendeteksian penyakit pada citra medis sudah dilakukan hingga saat ini. Hal ini diharapkan dapat membantu meningkatkan keakuratan prognosis dan kecepatan identifikasi yang dilakukan oleh ahli patologi dan ahli histopatologi [5].


Perkembangan ilmu *deep learning* memberikan kontribusi untuk bertambahnya jumlah dan jenis penelitian yang menggunakan ilmu *computer vision* untuk mengatasi permasalahan dalam bidang medis terutama pada pendeteksian penyakit. Salah satu perkembangan algoritma *Convolutional Neural Network* adalah perancangan dengan *multi-scale* dan *multi-feature network*. Pada pemeriksaannya, sel kanker dapat diamati pada tingkat hierarki sel (selular atau sub-selular) dan terdapat berbagai jenis kelainan jika dibandingkan dengan jaringan yang normal. Hasil

area gambar *digital* dari pengujian *staining* memiliki tampilan yang beragam dan dapat mempengaruhi kelancaran analisis gambar [6]. Perancangan CNN *multi-scale* dan *multi-feature network* dilakukan agar model dapat lebih peka dalam menangkap fitur penting dari data yang diberikan [7].

Tujuan penelitian yang dilakukan yaitu untuk menghasilkan klasifikasi dan deteksi tipe kanker payudara berdasarkan data gambar yang telah dibagi menjadi 4 kelas. Hasil temuan dari penelitian diharapkan dapat menjadi salah satu sumber pengetahuan yang berguna bagi masyarakat dan dapat dikembangkan untuk membantu memberikan informasi tambahan kepada ahli patologi atau dokter dalam menentukan keputusan prognosis kanker payudara. Penelitian ini juga dilakukan untuk mengetahui pengaruh dari pembuatan model CNN *multi-scale* dan *multi-feature network* jika dibandingkan dengan menggunakan 1 model CNN.

2. Metode Penelitian

Metode penelitian yang digunakan untuk melakukan klasifikasi dan prediksi kanker dengan 4 kelas dilakukan menggunakan algoritma *deep learning* dengan metode *Convolutional Neural Network* (CNN). Desain model dilakukan dengan pembuatan *input multi-scale* dan *multi-feature network*. Tahapan penelitian dengan metode CNN dapat dijabarkan pada Gambar 1.



Gambar 1. Tahap Penelitian Model CNN untuk Klasifikasi Kanker Payudara

Penelitian dimulai dengan identifikasi masalah yang relevan sebagai topik utama untuk solusi dari penelitian yang dilakukan. Kemudian dilanjutkan dengan tahap studi literatur berupa pembelajaran mengenai teknik pengolahan citra dan analisis mengenai metode yang telah dikembangkan pada penelitian sebelumnya. Pada langkah ketiga dilakukan pengolahan data agar dapat digunakan menjadi dataset dan dilakukan pembagian rasio antara data untuk pelatihan dan pengujian. Kemudian setelah pembagian data dilakukan, digunakan augmentasi data untuk memperbanyak citra tanpa menghilangkan informasi inti dari data serta mengurangi risiko *overfitting* [8]. Tahap selanjutnya yaitu perancangan model CNN *multi-scale*. CNN merupakan algoritma yang dapat melakukan ekstraksi fitur secara hierarkial tanpa penyeleksian manual dan dilakukan secara objektif [9].

Arsitektur CNN terdiri dari beberapa jenis lapisan. Lapisan konvolusi merupakan komponen terpenting dalam membangun CNN. Lapisan konvolusi memiliki seperangkat filter (atau bisa disebut sebagai kernel konvolusional) yang dipasang pada masukan yang datang dan digunakan untuk menghasilkan sebuah keluaran berupa peta fitur (*feature map*). Tahap konvolusi berfokus pada tahap ekstraksi fitur pada masukan dengan membuat *filter* atau *kernel* untuk melakukan operasi matematis pada objek data per bagian dan menyatukan hasil keluarannya dengan ukuran kecil berupa matriks yang disebut sebagai *feature map*. Operasi konvolusi dapat dinotasikan dengan rumus 1 [10].

$$s(i, j) = (I * K)(i, j) \quad (1)$$

Dalam implementasi untuk *machine learning*, masukan yang diberikan umumnya adalah data berupa array multi-dimensi dan kernel terdiri dari parameter berbentuk array multi-dimensi yang diadaptasi oleh algoritma pembelajarannya. Bila terdapat masukan atau input berupa GTambar 2 dimensi, maka dibutuhkan juga kernel 2 dimensi. Operasi konvolusi pada rumus 1 yang dilakukan dapat diuraikan dengan $s(i, j)$ sebagai fungsi konvolusi, i dan j sebagai posisi piksel, dan x sebagai I yaitu *input* piksel gambar dan w sebagai K atau kernel dengan nilai acak.

Pada lapisan bobot di CNN terdapat fungsi aktivasi yang digunakan untuk aktivasi dengan mengambil nilai riil dari *input* dan mengkonversikan nilai tersebut setara dengan jangkauan nilai yang kecil seperti (0,1) dan (-1,1). Fungsi aktivasi juga dapat berfungsi sebagai mekanisme seleksi untuk menentukan nilai pada suatu neuron diteruskan atau tidak sama sekali. Jenis fungsi aktivasi yang dipakai pada penelitian ini adalah fungsi sigmoid yang menghasilkan keluaran dengan jangkauan nilai 0 sampai 1 dan ReLU (*Rectified Linear Unit*) yang memetakan nilai negatif menjadi 0 [11].

Setelah proses konvolusi dibuat dan dihasilkan *feature map*, dilanjutkan ke lapisan *pooling* yang bertugas untuk mengurangi ukuran dimensi dari kumpulan *feature map* yang dihasilkan lapisan konvolusi tanpa mengeliminasi informasi penting yang terdapat pada *feature map* tersebut [12]. Terdapat beberapa jenis operasi *pooling* yang umum digunakan yaitu *max pooling* dan *average pooling* [13].

Operasi *max pooling* dilakukan dengan pengambilan nilai pada *feature map* sesuai dengan ukuran *filter* dan pergeserannya (*stride*). Kemudian pada nilai-nilai yang didapatkan tersebut diambil nilai maksimum sebagai *output feature map* hasil dari proses konvolusi di lapisan sebelumnya [14]. *Average pooling* memiliki operasi yang sama dengan *max pooling* berdasarkan cara kerja dan fungsinya, namun pengambilan nilai didapatkan dengan menghitung nilai rata-rata dari penjumlahan nilai yang diambil oleh *filter* pada satu proses pengambilan [15].

Kemudian dilanjutkan pada *fully-connected layer*. (FC) merupakan lapisan yang digunakan untuk implementasi transformasi dimensi data dengan tujuan agar dapat dilakukan klasifikasi secara linear secara relevan terhadap kelas-kelas yang ada [16,17]. Pada umumnya FC diimplementasikan pada akhir arsitektur hasil transformasi digunakan untuk klasifikasi. Lapisan memiliki jumlah neuron output yang sama dengan jumlah kelas [18].

$$y = f(W^T x + b) \quad (2)$$

Proses dalam lapisan FC dapat direpresentasikan dengan perkalian matriks. Perkalian matriks tersebut disertai penambahan vektor bias dan penerapan fungsi non-linear pada rumus 2 [11] dengan x dan y adalah vektor dari *input* dan *output* aktivasi. W sebagai matriks berisi bobot konektivitas antar unit dan lapisan, serta b merupakan nilai bias vektor.

Evaluasi model dilakukan dengan pembuatan *confusion matrix*, perhitungan nilai *accuracy*, *recall*, *precision* dan *f-1 Score*. Parameter tersebut masing-masing dibuat untuk melihat bagaimana model melakukan klasifikasi pada data yang tersedia. Perhitungan *precision* (P) terdapat pada rumus 3.

$$P = TP / (TP + FP) \quad (3)$$

Perhitungan *precision* digunakan untuk mendapatkan nilai rasio data yang berhasil dideteksi. *Precision* didapatkan dari jumlah data yang berhasil dideteksi pada kelas tersebut dengan benar dan dibagi dengan data keseluruhan yang dideteksi berada pada kelas tersebut. Dengan kata lain, *precision* mengukur rasio jumlah data yang benar dideteksi pada kelas tersebut dari semua data yang terdeteksi berada pada kelas tersebut.

$$R = TP / (TP + FN) \quad (4)$$

Evaluasi selanjutnya adalah perhitungan *recall* pada rumus 4. Perhitungan *recall* (R) dilakukan untuk menghasilkan nilai rasio jumlah data yang berhasil diprediksi dengan benar pada kelas tersebut dengan keseluruhan jumlah data sebenarnya yang berada pada kelas tersebut. Evaluasi selanjutnya yaitu perhitungan *accuracy* pada rumus 5.

$$A = (TP + TN) / (TP + TN + FP + FN) \quad (5)$$

Perhitungan *accuracy* pada model dilakukan untuk mendapatkan nilai rasio data yang berhasil diprediksi dengan benar data positif dan negatif selain dari kelas tersebut dibandingkan dengan total keseluruhan data yang disediakan pada model. Setelah dilakukan perhitungan tersebut, dilanjutkan pada perhitungan *f-1 score*. Perhitungan *f1-score* terdapat pada rumus 6.

$$2 * (Recall * Precision) / (Recall + Precision) \quad (6)$$

Nilai *f1-score* akan didapatkan ketika selesai menghitung nilai *precision* dan *recall*. *F1-score* merupakan nilai harmonis antara nilai *precision* dan

recall yang dibobotkan dengan rumus 6 [19]. Dalam perhitungan nilai *precision*, *recall*, *accuracy*, dan *f1-score*, terdapat nilai atau jumlah dari pengelompokkan hasil klasifikasi data. Nilai tersebut dapat dilihat pada pembuatan *confusion matrix*. Pemetaan nilai pada *confusion matrix* terdapat pada Gambar 2 [20].

Predicted	Performance Measure of the Algorithm		
		Yes	No
	Yes	True Positive	False Positive
	No	False Negative	True Negative

Gambar 2. Ilustrasi *Confusion Matrix*

Pada Gambar 2. terdapat nilai *True Positive* (TP) dan *True Negative* (TN) yang merupakan jumlah data yang berhasil diprediksi benar positif dan negatif. Nilai *False Negative* (FN) merupakan data yang diprediksi sebagai negatif namun pada label merupakan positif. Nilai *False Positive* (FP) merupakan jumlah data yang diprediksi positif namun pada label merupakan data yang negatif [19].

3. Hasil dan Pembahasan

Setelah dilakukan penjabaran metode yang dilakukan dalam penelitian, dilakukan implementasi dan pembahasan dari hasil yang didapatkan. Tahap ini terdiri dari pemahaman mengenai teori, pembuatan model, dan pengukuran performa model yang dibuat. Tahap ini penting dilakukan untuk mengetahui signifikansi dari implementasi metode yang digunakan.

Kanker payudara memiliki beberapa tipe yang diidentifikasi berdasarkan keganasan sel dan pertumbuhan sel pada jaringan payudara. Kanker payudara *in situ* merupakan stadium 0 dan termasuk sebagai kanker non-invasif atau pre-invasif. Kanker payudara *in situ* identik dengan pertumbuhan sel abnormal pada jaringan dengan jumlah yang banyak namun belum menyerang ke bagian jaringan lainnya pada payudara [21].

Tipe selanjutnya adalah kanker payudara invasif. Kanker payudara invasif merupakan penyebaran dari pertumbuhan sel di dalam salah satu bagian pada payudara ke bagian jaringan lain dan bisa menyebar sampai pada jaringan pada bagian tubuh yang lain. Penyebaran umumnya dapat berasal dari 2 daerah yaitu dari saluran air susu yang menembus dinding saluran kemudian menyerang jaringan payudara (*Invasive Ductal Carcinoma*) atau dari lobulus atau kelenjar air susu dan kemudian menyebar (*Invasive Lobular Carcinoma*) [22]. Tipe IDC merupakan tipe paling umum dan lebih dari 80% ditemukan pada pasien kanker payudara invasif [23].

Dataset untuk penelitian merupakan dataset publik yang dapat diakses daring. Dataset BACH (*BreAst Cancer Histology*) ini terdiri dari 400 citra digital jaringan payudara yang sudah diberikan pewarnaan zat hematoxilin-eosin (H&E). Teknik kombinasi pewarnaan ini pertama kali diperkenalkan pada tahun 1876 oleh A. Wissowzsky dan salah satu yang paling banyak digunakan dalam diagnosis medis dan seringkali dijadikan sebagai standar utama. Teknik pewarnaan ini digunakan untuk membedakan antara bagian inti dengan sitoplasma dari suatu sel yang sedang dilakukan pemeriksaan. Berikut jenis data yang dikelompokkan menjadi 4 kelas beserta identifikasi label pada dataset.

Citra Jaringan Normal, merupakan data jaringan yang sudah dikelompokkan dan diberikan label oleh ahli patologi yang memeriksa citra jaringan tersebut. Pada label, citra jaringan normal diberikan label angka 0 sebagai pembeda dan representasi nilai angka untuk pembelajaran pada model. Citra Jaringan *Benign*, merupakan citra jaringan yang memiliki karakteristik bertumor namun dinyatakan oleh ahli patologi sebagai tumor jinak yang walaupun tumbuh abnormal namun tidak menyebar maupun menyerang jaringan lain pada satu organ. Pada label, citra jaringan *benign* diberikan label angka 1 sebagai pembeda dan representasi nilai angka untuk pembelajaran pada model.

Citra Jaringan *In Situ*, merupakan citra jaringan yang memiliki sel kanker, ahli patologi menyebut sel *in situ* sebagai kanker stadium awal. Jenis kanker payudara stadium awal memiliki kesempatan untuk dapat disembuhkan bila dapat terdeteksi sejak awal dan mendapatkan penanganan yang cepat. Citra Jaringan *Invasif*, merupakan citra jaringan yang dinyatakan memiliki sel kanker. Perbedaan dengan kanker *in situ* adalah sel kanker invasif telah berkembang dan menyebar namun masih dalam cakupan jaringan organ payudara. Kanker ini masih dapat diobati bila ditemukan bila masih pada stadium awal ketika ukuran tumor relatif kecil.

Kemudian dilakukan pembagian data yang diperlukan untuk pelatihan dan pengujian pada model. Rasio data pelatihan dengan pengujian yang digunakan adalah 80:20. Jumlah data masing-masing setelah pembagian data dijelaskan pada Tabel 1.

Tabel 1. Pembagian Dataset

Jenis Data	Jumlah	Jumlah Data Per Kelas (4 Kelas)
Pelatihan	240	60
Validasi	80	20
Pengujian	80	20

Sebelum pelatihan model, dilakukan augmentasi data. Augmentasi data merupakan proses memanipulasi data yang dimiliki untuk mendapatkan data untuk pelatihan yang lebih banyak dan beragam, namun tidak menambah jumlah data asli yang dimiliki. Teknik ini


umumnya digunakan untuk penelitian dengan jumlah data yang relatif sedikit (puluhan atau ratusan data).

Pada penelitian ini, dilakukan augmentasi untuk data latih sebanyak 5 kali. Fungsi yang dipakai adalah fungsi *ImageDataGenerator* dengan teknik yang berbeda agar didapatkan variasi bentuk gambar yang didapatkan dengan memakai gambar yang sama. Teknik augmentasi yang dilakukan masing-masing dijelaskan pada Tabel 2.

Tabel 2. Pembagian Dataset

Urutan Augmentasi	Jenis Augmentasi
Pertama	Rescale 1/255
Kedua	Rescale 1/255 dan Vertical Flip
Ketiga	Rescale 1/255 Horizontal Flip
Keempat	Rescale 1/255 dan Rotasi (Tiap 5 Derajat)
Kelima	Rescale 1/255 dan Pergeseran Piksel Gambar (Range -200-200)

Pada langkah selanjutnya dilakukan perancangan model. Arsitektur yang digunakan model adalah VGG-16 berjumlah 3 model sekuensial dengan masing-masing memiliki ukuran *scaling* gambar yang berbeda. Kemudian hasil ekstraksi fitur dari 3 model tersebut digabungkan dan dihubungkan dengan lapisan *fully-connected* dan *dense* yang dibuat sebagai lapisan akhir untuk melakukan klasifikasi dari hasil pelatihan dan pelatihan model. Secara singkat, rancangan model dapat dilihat pada Gambar 3.



Gambar 3. Rancangan Model Induk (CNN-G)

Pada Gambar 3, model induk yang dibuat terdiri dari 3 buah model dengan *input* awal 84px x 84 px, 3 model tersebut melakukan *rescale* ukuran input awal menjadi 42 x 42px, 84 x 84px, dan 14x14px. Di dalam rancangan model induk, 3 model yang menjadi penyusun model induk juga memiliki rancangannya masing-masing. Rancangan masing-masing model tersebut dapat dijabarkan dengan Tabel 3.

Tabel 3. Rancangan Model Induk

Layer	CNN14	CNN42	CNN84
Conv-1	8x8,60	10x10,6	10x10,60
Pool-1	4x4,60	4x4,6	4x4,60
Conv-2	-	7x7,56	-
Pool-2	-	4x4,56	-
Conv-3	-	5x5,120	-
Pool-3	-	2x2,120	-
Dense-1	45	80	45
Dense-Final	4	4	4

Pada Tabel 3 setiap model terdiri dari beberapa lapisan konvolusi (Conv-n) dan lapisan pooling (Pool-n). Setiap lapisan memiliki ukuran input yang berbeda-beda, dengan tujuan agar model dapat belajar dan menangkap informasi yang lebih beragam. Setelah model-model tersebut dibuat, model disatukan dengan 1 lapisan *fully-connected* layer dan lapisan *dense* untuk dilakukan klasifikasi berdasarkan kelas-kelas yang dibutuhkan (4 kelas).


Fungsi aktivasi yang digunakan pada model masing-masing adalah fungsi ReLu, sedangkan pada model gabungan fungsi aktivasi yang digunakan adalah fungsi Sigmoid. Fungsi Sigmoid digunakan pada model akhir karena dapat mengkonversi nilai bobot dalam rentang 0-1. Pada model diberikan teknik regularisasi *dropout* dengan *rate* sebesar 0,25 yang artinya 25% jaringan pada lapisan diberhentikan dan tidak dipakai secara acak untuk menghindari terjadinya *overfitting*.

Proses dilanjutkan ke tahap pelatihan. Pada tahap pelatihan dilakukan inisialisasi *hyperparameter* yang diperlukan. Ukuran *input* pada model yang dipakai pada saat augmentasi adalah 84 x 84px. *Batch size* merupakan ukuran jumlah sampel data yang digunakan sebagai satuan kecil dari *epoch* pada *Neural Network*. Pada penelitian, *batch size* yang dilakukan inisialisasi eksplisit namun akan menyesuaikan pada proses pelatihan. Penentuan *epoch* penting digunakan sebagai penentuan jumlah perulangan pada model pada saat pelatihan dilakukan. Pada proses pelatihan, nilai *epochs* yang digunakan sebagai 15 yang berarti model akan melakukan 15 kali proses penuntasan pada proses pelatihan.

Validation steps dibuat sebagai jumlah langkah validasi ketika *epoch* diinisialisasikan dan berjalan ketika pelatihan sedang dimulai. Pada penelitian penggunaan *validation steps* tidak diinisialisasikan secara eksplisit namun sudah disesuaikan dengan jumlah data pada saat pelatihan, sehingga *validation steps* yang digunakan sebanyak 6 dan 80 pada saat proses prediksi data validasi. *Learning rate* merupakan parameter nilai yang digunakan untuk menyatakan seberapa banyak model harus berubah ketika menangani kesalahan pada setiap kali bobot model diperbarui pada saat pelatihan. Nilai *learning rate* dapat menentukan seberapa cepat model mempelajari data dan berapa banyak informasi yang

hilang saat melakukan pelatihan. Pada penelitian ini nilai *learning rate* yang dipakai sebesar 0,0001. Pengujian data dilakukan dengan inisialisasi fungsi prediksi terhadap data uji yang dipakai.

Setelah pengujian data dilakukan, dilanjutkan dengan evaluasi performa model berdasarkan hasil pelatihan yang dilakukan dan hasil pengujian data yang dilakukan. Evaluasi dilakukan dengan *confusion matrix* dan pengukuran lainnya yang relevan terhadap penelitian yang dilakukan. Evaluasi model diperlukan untuk pemahaman mendalam dan mendapatkan pengetahuan tentang bagaimana model yang dibuat bekerja. Evaluasi model dapat dimulai dari visualisasi tingkat akurasi dan *loss* ketika pelatihan dilakukan. Grafik akurasi dan *loss* model saat pelatihan terdapat pada Gambar 4.



Gambar 4. Grafik Akurasi dan Loss Model

Pada grafik akurasi model, bila grafik semakin menanjak dapat diartikan bahwa model telah berhasil belajar dan mendapatkan nilai akurasi yang lebih besar di setiap iterasi *epochs* yang dilakukan saat pelatihan. Pelatihan dilakukan dengan 240 data yang merupakan data latih yang sudah dibagi pada tahap pembagian dataset. Pada grafik *loss* model, grafik terlihat menurun seiring dengan penambahan *epochs* yang berarti bahwa pada setiap *epochs* model belajar dan mengalami penurunan kehilangan nilai informasi pada pelatihan.


Setelah dilakukan visualisasi dengan grafik, dilanjutkan dengan pengambilan nilai akurasi terbaik pada pelatihan model. Hasil tersebut akan dipakai untuk prediksi data uji. Pada Gambar 5 didapatkan nilai akurasi sebesar 0,5375 ~ 0,54. Setelah hasil akurasi berhasil didapatkan, dilanjutkan dengan pembuatan *confusion matrix* yang hasilnya terdapat pada Gambar 6.

```
print('val_loss:', val_loss)
print('val_acc:', val_accuracy)

C:\Users\Ghifari Prameswari\anaconda3\envs\GPUEnv\lib\site-packages\keras
_generator' is deprecated and will be removed in a future version. Please
warnings.warn('Model.evaluate_generator' is deprecated and '

val_loss: 1.2057366371154785
val_acc: 0.5375000238418579
```

Gambar 5. Nilai Akurasi Terbaik pada Model




Gambar 6. Confusion Matrix Hasil Prediksi Data Validasi

Berdasarkan pada *confusion matrix* yang terdapat pada Gambar 6, diketahui model dapat memprediksi 18 data dengan label 3 (invasif) secara akurat, 8 data dengan prediksi nilai label 2 (*in situ*) yang sesuai dengan label asli, 4 data dengan prediksi nilai label 1 (*benign*) dengan benar, dan 13 data dengan prediksi nilai label 0 (normal) dengan benar. Kemudian dilakukan pengukuran lainnya seperti *precision*, *recall*, dan *f1-score*. Nilai *precision* merupakan parameter tingkat ketepatan antara informasi yang sebenarnya dengan jawaban yang diberikan oleh model. Sedangkan nilai *recall* merupakan parameter tingkat keberhasilan model dalam mendapatkan sebuah informasi. Nilai *f1* merupakan parameter untuk rata-rata nilai keharmonisan antara nilai *precision* dan *recall*. Hasil pengukuran terdapat Gambar 7 berikut.

	precision	recall	f1-score	support
normal	0.50	0.65	0.57	20
benign	0.57	0.20	0.30	20
insitu	0.62	0.40	0.48	20
invasive	0.53	0.90	0.67	20
accuracy			0.54	80
macro avg	0.55	0.54	0.50	80
weighted avg	0.55	0.54	0.50	80

Gambar 7. Pengukuran Performa Model


Pada Gambar 7 diperlihatkan nilai *precision*, *recall*, dan *f1-score* pada masing-masing kelas pada saat model melakukan klasifikasi. Nilai *precision* terbesar pada model yaitu dengan nilai 0,62 pada kelas *in situ*, nilai *recall* terbesar adalah 0,90 pada kelas invasif, dan hasil *f1-score* tertinggi bernilai 0,67 pada kelas invasif. Kemudian pada pengujian dengan menggunakan data uji dihasilkan *confusion matrix* pada Gambar 8 berikut.



Gambar 8. Confusion Matrix Data Uji

Berdasarkan confusion matrix pada Gambar 8, dapat dilihat bahwa model CNN-G berhasil memprediksi 12 data yang berlabel 3 (invasif) dengan akurat. Model juga berhasil memprediksi 1 gambar yang berlabel 2 (*in situ*) sesuai dengan label sebenarnya. Pada prediksi untuk data normal (label 0) dan *benign* (1), model berhasil memberikan prediksi yang benar dengan jumlah data masing-masing 9 dan 2 data.


Setelah itu dilakukan pembangunan model CNN42, CNN14, dan CNN84 sebagai perbandingan performa model dari model CNN-G. Rancangan masing-masing model sama seperti model yang berada di dalam CNN-G. Data yang digunakan untuk pelatihan dan pengujian memiliki jenis dan jumlah yang sama serta rasio pembagian yang sama dengan model CNN-G. Pada Tabel 3 terdapat rancangan model CNN14, CNN42, dan CNN84. Pelatihan menggunakan data dengan rasio jumlah yang sama, dan teknik augmentasi yang sama. Kemudian setelah pelatihan dilanjutkan dengan pembuatan grafik akurasi dan loss dari masing-masing model. Kemudian dilanjutkan dengan tahap pengujian menggunakan data uji dengan jumlah yang sama.




Gambar 9. Grafik Akurasi dan Loss Model CNN42

Pada Gambar 9, terdapat grafik akurasi model CNN42. Garis grafik akurasi cenderung tidak konsisten naik turun, yang berarti bahwa model tidak selalu mendapatkan nilai informasi pada setiap iterasi *epochs* yang diberikan. Pada *epochs* ke-12 hingga ke-14 terdapat penurunan pada grafik yang berarti bahwa model mempelajari data dalam nilai yang sedikit dan hampir tidak mendapatkan nilai informasi.

Pada grafik *loss* model, terlihat bahwa garis pada grafik konstan dan mengalami penurunan *loss* dari awal *epochs* hingga *epochs* ke-12. Penurunan *loss* berarti bahwa model dapat menangani kehilangan informasi hampir di setiap iterasi *epochs* yang diberikan pada saat pelatihan. Kemudian dilanjutkan dengan grafik akurasi dan *loss* pada CNN14 dan CNN84 pada Gambar 10 dan Gambar 11.



Gambar 10. Grafik Akurasi dan Loss Model CNN14




Gambar 11. Grafik Akurasi dan Loss Model CNN84

Pada Gambar 10, terlihat grafik akurasi pada model CNN14 memiliki kenaikan dan penurunan yang sangat tidak konsisten. Garis hasil *training* (biru) dan *validation* (jingga) saling menjauh menunjukkan pelatihan yang kurang efektif. Pada grafik *loss*, garis hasil *training* dan *loss* juga saling menjauh, walaupun tingkat penurunannya cenderung konstan dibandingkan dengan hasil pada grafik akurasi. Pada Gambar 11, grafik akurasi pada model CNN84 terlihat mengalami peningkatan setelah *epoch* ke-4 dan kemudian mengalami kenaikan dan penurunan ketika sudah melalui *epoch* ke-8. Grafik *loss* menunjukkan garis yang lebih teratur menurun. Grafik *loss* yang berangsur menurun menandakan model dapat menangani *error* selama pelatihan berlangsung. Jika dibandingkan dengan ketiga model tersebut, model CNN84 dan CNN42 memiliki karakteristik garis pada grafik *loss* yang lebih baik dibandingkan dengan grafik *loss* pada model CNN14. Setelah grafik dibuat, dilanjutkan dengan pengambilan hasil *validation accuracy* dan *validation loss* pada 3 model tersebut. Perbandingan hasil akurasi dan *loss* dari ketiga model dapat dilihat pada Tabel 4.

Tabel 4. Validation Accuracy and Loss pada 3 Model

Model	Val_Acc	Val_Loss
CNN14	0,324	1,389
CNN42	0,462	1,341
CNN84	0,425	1,264

Pada Tabel 4, terlihat perbandingan nilai *val_acc* dan *val_loss* model. CNN14 memiliki nilai *val_acc* terendah dibandingkan kedua model. CNN42 memiliki nilai *val_acc* tertinggi, dan CNN84 memiliki nilai *val_loss* terendah namun nilai nya tidak berbeda jauh dengan CNN42. Namun, jika dibandingkan dengan model CNN-G masih memiliki nilai *val_acc* yang lebih baik dan nilai *val_loss* yang lebih kecil. Hasil confusion matrix dari data uji pada ketiga model dapat dilihat pada Gambar 12.



Gambar 12. Confusion Matrix 3 Model dari Data Uji

Pada Gambar 12, dapat dilihat bahwa confusion matrix CNN14 tidak dapat memprediksi dan mendeteksi data benign (label 1) dan malignant (label 3) namun dapat memprediksi 12 (label0) data normal secara akurat dan 9 data in situ (label 2). Pada CNN42, model berhasil memprediksi 7 data normal, 2 data benign, dan 10 data invasif namun tidak dapat memprediksi data in situ (label 2). Model CNN84 dapat memprediksi 6 data normal, 8 data benign, dan 2 data invasif dan juga tidak dapat memprediksi data in situ (label 2).

4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan dan hasil yang didapatkan, dapat diambil kesimpulan bahwa model yang dibuat mampu melakukan klasifikasi terhadap 4 kelas untuk membantu dalam melakukan dugaan yang hasilnya dapat dijadikan prognosis untuk mendeteksi sel pada jaringan yang tergolong normal atau diprediksi terkena kanker. Penelitian berhasil dilakukan dengan implementasi model *Convolutional Neural Network* dengan *multi-scale* dan *multi-feature network* (CNN-G) mendapatkan hasil akurasi sebesar 0,5375 dengan ukuran *input* citra yang tergolong kecil terbukti meningkatkan tingkat akurasi dibandingkan bila menggunakan model tunggal CNN14, CNN42, dan CNN84. Model CNN-G dapat lebih mempelajari dan mengambil informasi untuk mendapatkan variasi fitur dengan penggabungan ekstraksi fitur dari 3 model. Nilai *precision*, *recall*, dan *f1-score* pada masing-masing kelas yaitu 0,50, 0,65, dan 0,57 untuk kelas normal, untuk kelas benign yaitu 0,57, 0,20, dan 0,30, untuk kelas in situ yaitu 0,62, 0,40, dan 0,48, dan untuk kelas invasif bernilai 0,53, 0,90, dan 0,67. Model CNN-G berhasil melakukan prediksi benar dengan data terbanyak pada kelas kanker invasif berdasarkan hasil *confusion matrix* data validasi dan data uji. Penggunaan augmentasi data menjadi salah satu kunci penting dalam penelitian dikarenakan data yang dipakai tergolong berjumlah kecil dan model butuh banyak contoh agar dapat mempelajari data. Namun, penelitian ini masih terbuka dan dapat dikembangkan. Beberapa upaya yang dapat dilakukan dalam pengembangan penelitian ini adalah dengan menggunakan sampel data yang lebih banyak dan optimisasi model agar menghasilkan model yang lebih baik dari segi performa dan nilai akurasi.

Daftar Pustaka

- [1] A. Yusnina, I. Muhimmah, and I. Fidianingsih, "Ekstraksi Fitur untuk Sel Abnormal Pleomorfik pada Kanker Payudara," *Automata*, vol. 2, No 2, 2021, [Online]. Available: <https://journal.uui.ac.id/AUTOMATA/article/view/19539>.
- [2] A. S. Hyperastuty, A. Setijo R, and R. R., "Artificial Neural Network dalam Menentukan Grading Histopatologi Kanker Payudara," *J. Biosains Pascasarj.*, vol. 19, no. 2, p. 176, 2017, doi: 10.20473/jbp.v19i2.2017.176-188.
- [3] S. A. Taghanaki, J. Kawahara, B. Miles, and G. Hamarneh, "Pareto-optimal Multi-objective Dimensionality Reduction Deep Auto-encoder for Mammography Classification," *Comput. Methods Programs Biomed.*, vol. 145, pp. 85–93, 2017, doi: 10.1016/j.cmpb.2017.04.012.
- [4] R. Amini, I. Muhimmah, and I. Fidianingsih, "Analisis Fitur untuk Grading Abnormal Sel Mitosis Pada Kasus Kanker Payudara," *Automata*, vol. Vol 2, No, pp. 3–7, 2021, [Online]. Available: <https://journal.uui.ac.id/AUTOMATA/article/view/17384>.
- [5] C. Zhu, F. Song, Y. Wang, H. Dong, Y. Guo, and J. Liu, "Breast Cancer Histopathology Image Classification through Assembling Multiple Compact CNNs," *BMC Med. Inform. Decis. Mak.*, vol. 19, no. 1, pp. 1–17, 2019, doi: 10.1186/s12911-019-0913-x.
- [6] T. S. Sheikh, Y. Lee, and M. Cho, "Histopathological Classification of Breast Cancer Images using a Multi-scale Input and Multi-feature Network," *Cancers (Basel)*, vol. 12, no. 8, pp. 1–21, 2020, doi: 10.3390/cancers12082031.
- [7] H. Che, L. G. Brown, D. J. Foran, J. L. Noshier, and I. Hacıhaliloglu, "Liver Disease Classification from Ultrasound using Multi-scale CNN," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 16, no. 9, pp. 1537–1548, 2021, doi: 10.1007/s11548-021-02414-0.
- [8] C. Shorten and T. M. Khoshgoftaar, "a Survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [9] Z. Wang *et al.*, "Breast Cancer Detection Using Extreme Learning Machine Based on Feature Fusion with CNN Deep Features," *IEEE Access*, vol. 7, no. c, pp. 105146–105158, 2019, doi: 10.1109/ACCESS.2019.2892795.
- [10] A. Anton, N. F. Nissa, A. Janiati, N. Cahya, and P. Astuti, "Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women's Skin Classification," *Sci. J. Informatics*, vol. 8, no. 1, pp. 144–153, 2021, doi: 10.15294/sji.v8i1.26888.
- [11] S. Khan, H. Rahmani, S. A. A. Shah, and M. Bennamoun, *A Guide to Convolutional Neural Networks for Computer Vision*, vol. 8, no. 1. New York: Morgan & Claypool Publishers, 2018.
- [12] B. Sekeroglu and I. Ozsahin, "Detection of COVID-19 from Chest X-Ray Images Using Convolutional Neural Networks," *SLAS Technol.*, vol. 25, no. 6, pp. 553–565, 2020, doi: 10.1177/2472630320958376.
- [13] M. B. Bejiga, A. Zeggada, A. Nouffidj, and F. Melgani, "a Convolutional Neural Network Approach for Assisting Avalanche Search and

- Rescue Operations with UAV Imagery,” *Remote Sens.*, vol. 9, no. 2, 2017, doi: 10.3390/rs9020100.
- [14] R. Magdalena, S. Saidah, N. Kumalasari C.P., and A. T. Putra., “Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural,” *JEPIN (Jurnal Edukasi dan Penelit. Inform.*, vol. 7, no. 3, pp. 335–339, 2021, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jepin/article/view/48195/75676591380>.
- [15] Y. D. Zhang, S. C. Satapathy, S. Liu, and G. R. Li, “A Five-layer Deep Convolutional Neural Network with Stochastic Pooling for Chest CT-based COVID-19 Diagnosis,” *Mach. Vis. Appl.*, vol. 32, no. 1, pp. 1–13, 2021, doi: 10.1007/s00138-020-01128-8.
- [16] A. Al Smadi, A. Mehmood, A. Abugabah, E. Almekhlafi, and A. M. Al-Smadi, “Deep Convolutional Neural Network-based System for Fish Classification,” *Int. J. Electr. Comput. Eng.*, vol. 12, no. 2, pp. 2026–2039, 2022, doi: 10.11591/ijece.v12i2.pp2026-2039.
- [17] T. A. Kalaycı and U. Asan, “Improving Classification Performance of Fully Connected Layers by Fuzzy Clustering in Transformed Feature Space,” *Symmetry (Basel)*, vol. 14, no. 4, p. 658, 2022, doi: 10.3390/sym14040658.
- [18] R. Yamashita, M. Nishio, R. Gian Do Kinh, and K. Togashi, “Convolutional Neural Networks: an Overview and Application in Radiology,” *Insights into Imaging, Eur. Soc. Radiol.*, vol. 9, pp. 611–629, 2018, doi: 10.1007/978-981-15-7078-0_3.
- [19] M. Grandini, E. Bagli, and G. Visani, “Metrics for Multi-Class Classification: an Overview,” pp. 1–17, 2020, [Online]. Available: <http://arxiv.org/abs/2008.05756>.
- [20] J. H. J. C. Ortega, “Analysis of Performance of Classification Algorithms in Mushroom Poisonous Detection using Confusion Matrix Analysis,” *Int. J. Adv. Trends Comput. Sci. Eng.*, vol. 9, no. 1.3, pp. 451–456, 2020, doi: 10.30534/ijatcse/2020/7191.32020.
- [21] M. van Seijen *et al.*, “Ductal Carcinoma In Situ: to Treat or Not to Treat, That is the Question,” *Br. J. Cancer*, vol. 121, no. 4, pp. 285–292, 2019, doi: 10.1038/s41416-019-0478-6.
- [22] H. L. Chung, H. H. Tso, L. P. Middleton, J. Sun, and J. W. T. Leung, “Axillary Nodal Metastases in Invasive Lobular Carcinoma Versus Invasive Ductal Carcinoma: Comparison of Node Detection and Morphology by Ultrasound,” *Am. J. Roentgenol.*, vol. 218, no. 1, pp. 33–41, 2022, doi: 10.2214/AJR.21.26135.
- [23] D. Makower, J. Qin, J. Lin, X. Xue, and J. A. Sparano, “The 21-Gene Recurrence Score in Early Non-Ductal Breast Cancer: a National Cancer Database analysis,” *npj Breast Cancer*, vol. 8, no. 1, pp. 1–7, 2022, doi: 10.1038/s41523-021-00368-9.

Halaman ini sengaja dikosongkan