

Deep learning untuk pendeteksian penyakit kanker payudara dengan optimasi Adam

Irmawati^{1*}, Yuris Alkhalifi², Agung Fazriansyah³,
Mohammad Syamsul Azis⁴, Kudiantoro Widiyanto⁵

Program Studi Sistem Informasi¹³⁴,

Program Studi Teknologi Komputer², Teknologi Informasi⁵

Fakultas Teknik dan Informatika¹²³⁴⁵

Universitas Bina Sarana Informatika¹²³⁵ Universitas Nusa Mandiri⁴

irmawati.iat@bsi.ac.id, yuris.yak@bsi.ac.id, agung.fzr@bsi.ac.id,
mohammad.myz@nusamandiri.ac.id, kudiantoro.kdw@bsi.ac.id

Received: November 24, 2022. **Revised:** December 29, 2022. **Accepted:** January 24, 2023. **Issue Period:** Vol.7 No.1 (2023), Pp.124-136

Abstrak: Kanker payudara merupakan penyebab kematian kedua pada pasien wanita di dunia. Kanker payudara telah menyebabkan kematian di lebih dari 100 negara. Diagnosis dini pasien kanker payudara menjadi penting guna mengurangi kemungkinan kematian. Peneliti fokus pada deteksi akurat kanker payudara, metode diagnostik otomatis dan diagnosis kanker payudara. Makalah ini mengusulkan optimasi Adam untuk Deep Learning Algorithm untuk mengklasifikasikan deteksi kanker payudara. Penelitian ini bertujuan untuk mengatasi masalah ketidakstabilan data dan overfitting, serta memperbarui bobot jaringan pada data latih deep learning. Dalam penelitian ini, penulis melakukan eksperimen dengan kombinasi tiga lapisan tersembunyi dan kecepatan pembelajaran untuk meningkatkan akurasi klasifikasi. Eksperimen menggunakan kumpulan data kanker payudara yang di dapat dari Studi UCI: kumpulan data WBCD (Asli) adapun hasil eksperimen menunjukkan bahwa skema yang diusulkan mencapai akurasi 96,3% untuk mengklasifikasikan kanker payudara.

Kata Kunci : Data Mining, Deep Learning, Adam Optimizer, Klasifikasi, Kanker Payudara

Abstract: Breast cancer is the second leading cause of death in female patients in the world. Breast cancer has caused death in more than 100 countries. Early diagnosis of breast cancer patients is important to reduce the possibility of death. Researchers focus on accurate breast cancer detection, automated diagnostic methods and breast cancer diagnosis. This paper proposes Adam's optimization for Deep Learning Algorithm to classify breast cancer detection. This study aims to overcome the problem of data instability and overfitting, as well as update network weights on deep learning training data. In this study, the authors conducted experiments with a combination of three hidden layers and learning speed to improve classification accuracy. The experiment used the breast cancer data set obtained from the UCI Study: the WBCD data set (Original) while the experimental results



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

showed that the proposed scheme achieved 96.3% accuracy for classifying breast cancer.

Keywords: *Data Mining, Deep Learning, Adam Optimizer, Classification, Breast Cancer*

I. PENDAHULUAN

Kanker payudara dapat terjadi pada pria dan wanita, tetapi jauh lebih sering terjadi pada wanita dan merupakan kanker yang paling banyak didiagnosis pada wanita. Kanker payudara adalah jenis kanker paling agresif yang diderita oleh wanita di seluruh dunia dan menjadi penyebab kematian kedua di antara pasien kanker wanita [1]. Pertumbuhan sel payudara yang tidak normal akan menyerang sel-sel di sekitar payudara lebih cepat dan menyebar ke bagian tubuh lainnya [2]. Kanker payudara memiliki dua kelas yang berbeda yaitu jinak dan ganas. Tumor jinak, biasanya dikenal sebagai non-kanker, dibiarkan begitu saja oleh dokter tanpa mengangkatnya karena tidak terlalu agresif terhadap jaringan lain, tetapi kadang-kadang dapat tumbuh menyebabkan rasa sakit atau lainnya. Di sisi lain, tumor ganas atau dikenal sebagai kanker terlalu agresif dan memiliki kemampuan untuk merusak jaringan di sekitarnya dan jika pasien didiagnosis ganas maka dokter melakukan biopsi untuk mengetahui agresivitas atau tingkat keparahan tumor [3]. Tumor ganas berjalan melalui jaringan tubuh yang sehat dan menghancurkannya [4]. Penyebab utama penyakit kanker payudara terutama terkait dengan pasien yang mewarisi mutasi genetik pada gen mereka [5]. Tanda-tanda kanker payudara mungkin termasuk benjolan di payudara, perubahan bentuk payudara, lesung pipit pada kulit, cairan yang keluar dari puting susu, dan kemudian menyebar ke area tubuh lainnya. Kanker payudara adalah kanker yang paling sering didiagnosis dan penyebab utama kematian akibat kanker dengan jumlah persentase 11,6%. Pada tahun 2018 kanker payudara di dunia ada sekitar 2,1 juta kasus. Penyakit ini merupakan kanker yang paling sering didiagnosis di sebagian besar negara (154 dari 185) dan juga merupakan penyebab utama kematian akibat kanker di lebih dari 100 negara.[6]. Klasifikasi merupakan proses data mining yang bertujuan untuk membagi data ke dalam kelas-kelas untuk memudahkan pengambilan keputusan, karena itu merupakan tugas penting dalam bidang medis. Ada banyak peneliti yang sudah melakukan penelitian untuk memprediksi kanker payudara, namun dalam penelitian ini penulis mengusulkan Deep Learning menggunakan optimasi Adam. Karena teknik *deep learning* memiliki keunggulan dapat mengevaluasi sejumlah besar data dengan lebih tepat dan lebih cepat, sehingga menghasilkan pengurangan kesalahan selama proses pendeteksian [7].

II. METODE DAN MATERI

Berbagai metode dapat diterapkan untuk klasifikasi kanker payudara untuk membedakan antara dua jenis tumor payudara yaitu Jinak dan Ganas [3]. Penelitian terdahulu yang sudah dilakukan mengenai klasifikasi kanker payudara yang dilakukan [8] yang berjudul “*Breast cancer disease classification using fuzzy-ID3 algorithm with FUZZYDBD method: automatic fuzzy database definition*” Model yang diusulkan adalah metode FUZZYDBD untuk mengklasifikasikan penyakit kanker payudara pada tiga dataset yaitu dataset WBCD (Asli), WDBC (Diagnostik) dan dataset Coimbra dan menghasilkan akurasi yang lebih tinggi, yaitu dengan memperoleh hasil sebesar 94.362, 94.362, 70.690. Penelitian yang dilakukan [9] berjudul “*Decision support system for breast cancer prediction*” Model yang diusulkan adalah Support Vector Machine (SVM) pada dataset WBCD menghasilkan akurasi 86.100. Penelitian yang dilakukan oleh [10] yang berjudul “*Using Feature Selection Techniques to Improve the Accuracy of Breast Cancer Classification*” Model yang diusulkan adalah C4.5 algorithm untuk mengklasifikasikan penyakit kanker payudara pada dataset WBCD menghasilkan akurasi 92.970. Dataset yang digunakan untuk penelitian ini merupakan data sekunder atau data publik yang diambil dari *UCI Machine Learning*. Eksperimen ini dilakukan dengan menggunakan set data kanker payudara, yaitu: dataset WBCD (Asli). Database Kanker Payudara Wisconsin, yang dikenal sebagai kumpulan data WBCD



(Asli), terdiri dari satu atribut target diantaranya yaitu kelas jinak dan ganas. Dan berisi sembilan atribut prediktif, ketebalan rumpun, keseragaman ukuran sel, keseragaman bentuk sel, adhesi marginal, ukuran sel epitel tunggal, kromatin hambar, inti telanjang, nukleolus normal dan mitosis. Serta satu atribut non-prediktif dalam kumpulan data ini adalah nomor ID. Dataset terdiri dari 699 kasus, 458 sampel jinak dan 241 sampel ganas. Ini memiliki 16 nilai yang hilang, dan penghapusan daftar telah diterapkan untuk menangani data yang hilang, yang mengarah ke 683 *instances*.


Tabel 1. merupakan Tabel kumpulan data kanker payudara yang digunakan pada penelitian ini, berdasarkan jumlah atribut, jumlah *instances* dan jumlah kelas.

Tabel 1. Rincian Dataset Kanker Payudara

Dataset	Jumlah Atribut	Jumlah Instance	Jumlah Kelas
WBCD (Original)	11	683	2

Eksperimen penelitian dilakukan sesuai dengan tahapan-tahapan sebagaimana disajikan pada Gambar 1. Penelitian dimulai dari melakukan eksplorasi dataset, data *preprocessing*, split data, normalisasi data, membangun arsitektur model *deep learning*, *training* dan *validation* model, serta *evaluation model*.





Gambar 1. Tahapan Penelitian

Penjelasan dari setiap tahapan diatas dijelaskan sebagai berikut:

1. Eksplorasi Data terdiri dari mengecek dimensi data, mengecek tipe data, mengecek data kosong, dan statistik distribusi label target.
2. Data Preprocessing terdiri dari *cleaning* data yaitu menghapus kolom “*id*” pada dataset asli (WBCD). Kemudian mengubah nama *class* fitur (sebagai kelas target) menjadi fitur dengan nama “*diagnosis*”, hal tersebut dilakukan karena jika tidak mengubah nama kelas fitur maka akan dibaca sebagai fungsi. *Features Encoding* yaitu melakukan konversi nilai pada variable dalam bentuk kategorikal ke dalam bentuk numerik menggunakan teknik *Label Encoding* pada atribut target dari ketiga dataset tersebut. *Label Encoder* dari library *Scikit Learn*. Kemudian merubah label target klasifikasi dari “*category*” menjadi “*numeric*”, pada dataset WBCD (asli). berubah “*malignant*” menjadi “1” dan “*benign*”



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

menjadi “0”. *Ekstraksi Features (dummy)* pada penelitian ini bertujuan untuk mengubah data input menjadi kolom biner untuk setiap kategori semua fitur input yang sebelumnya telah mengalami proses *fuzzifikasi* dimana setiap atribut yang telah dihasilkan berada dalam nilai himpunan fuzzy (rendah, sedang , tinggi). Merujuk pada penelitian yang dilakukan [8]

Split Data: 80% data *training*, 20% data *testing*, data *training* digunakan untuk membangun dan melatih model, data *testing* yang akan digunakan untuk evaluasi model dan pengujian model.

3. Normalisasi Data menggunakan *Min-Max Scaler* dari *scikit learn* untuk merubah range dengan skala input menjadi 0-1.
4. Model Arsitektur Deep Learning dibuat terdiri dari input layer, hidden layer dan output layer.

Tabel 2. Model Arsitektur Deep Learning

Arsitektur	layer
Model-A	Satu input layer (6), satu hidden layer (15), satu output layer (1)
Model-B	Satu input layer (6), dua hidden layer (15), satu output layer (1)
Model-C	Satu input layer (6), tiga hidden layer (15), satu output layer (1)
Model-D	Satu input layer (6), empat hidden layer (15), satu output layer (1)
Model-E	Satu input layer (6), lima hidden layer (15), satu output layer (1)

Eksperimen dilakukan dengan beberapa variasi *setting hyperparameter*. Evaluasi *performance model* dilakukan dengan membandingkan hasil skor *metric performance*. Eksperimen masing-masing akan dilakukan dengan jumlah epoch 20 dengan *batch size* 5. Variasi Model Deep Learning dengan parameter dan nilainya sebagaimana pada Tabel 3.

Tabel 3. Parameter Model

Parameter	Nilai Parameter
<i>Aktivasi Input Layer</i>	<i>ReLU (Rectified Linear Unit)</i>
<i>Aktivasi Hidden Layer</i>	<i>ReLU (Rectified Linear Unit)</i>
<i>Aktivasi Output</i>	<i>Sigmoid</i>
<i>Neuron</i>	6, 15, 1
<i>Epoch</i>	20
<i>Batch Size</i>	5
<i>Loss Function</i>	<i>Binary Crossentropy</i>
<i>Jenis Layer</i>	<i>Dense</i>

Berdasarkan komposisi pada Tabel tersebut, eksperimen akan dilakukan terhadap model dengan optimasi Adam. Optimasi menggunakan nilai *learning rate* 0.1, 0.01 dan 0.001 disajikan pada Tabel 4.



Tabel 4. Parameter Optimasi

Optimasi	Learning Rate
Adams (Adaptive Moments Estimation)	0.1
	0.01
	0.001

5. Training dan Validation Model

Eksperimen dilakukan dengan bantuan *google colab*, bahasa pemrograman yang digunakan *python*. Spesifikasi komputer yang digunakan untuk *running* program sebagaimana disajikan dalam Tabel 5.

Tabel 5. Spesifikasi Komputer

Operating System	Windows 10 Pro 64-bit
Processor	Intel ® Core™ i5-2430M CPU @2.40GHZ 4CPUs, ~2.4GHz
Memory	8192MB RAM
Hardisk	1 TB

Evaluasi model menggunakan *data testing*. Proses evaluasi menggunakan *scikit-learn libraries*. *Metrics performance* yang digunakan untuk mengevaluasi model yaitu *accuracy*, *f1-score*, *precision*, dan *recall*.

III. PEMBAHASA DAN HASIL

1. Eksplorasi data dimulai dengan mengecek dimensi data, mengecek tipe data, mengecek data yang kosong dan mengecek distribusi data label target dengan tujuan memastikan kembali terkait jumlah data dan tipe data. Adapun hasil dari eksplorasi data sebagai berikut:

Tabel 6. Dimensi Data

Dataset	Jumlah Instance	Jumlah Atribut
WBCD (Original)	683	11

Berdasarkan Tabel 6 jumlah *instance* dataset WBCD (original) sebanyak 683 dengan jumlah atribut 11.

Tabel 7. Tipe Data

WBCD	Tipe Data
ID	int
<i>clumpthickness</i>	object
<i>uniformitycellsize</i>	object
<i>uniformitycellshape</i>	object
<i>marginaladhesion</i>	object
<i>singleepithelialsize</i>	object
<i>bareuclei</i>	object
<i>chromatin</i>	object
<i>nucleoli</i>	object
<i>mitoses</i>	object
<i>class</i>	object
...	...



Pada tabel 7. diatas, dataset WBCD memiliki atribut dengan tipe data sebanyak satu int dan sepuluh object.

Tabel 8. Missing Values

WBCD	Missing Values
<i>clumpthickness</i>	0
<i>uniformitycellsize</i>	0
<i>uniformitycellshape</i>	0
<i>marginaladhesion</i>	0
<i>singleepithelialsize</i>	0
<i>barenuclei</i>	0
<i>chromatin</i>	0
<i>nucleoli</i>	0
<i>mitoses</i>	0
<i>class</i>	0
...	...


Berdasarkan hasil tabel 8. setelah dilakukan pengecekan data apakah masih terdapat data yang kosong. Dari hasil yang disajikan tidak terdapat data yang kosong baik di dataset WBCD

Tabel 9. Distribusi Label Target

Dataset	Target Class	Jumlah	Total Instance
WBCD	<i>benign</i>	444	683
	<i>malignant</i>	239	

Berdasarkan Tabel 9 Setiap dataset memiliki dua *target class*. Dataset WBCD memiliki dua target yaitu "*malignant*" dan "*benign*".

Dataset WBCD dengan target kelas "*benign*" memiliki jumlah 444 data dan target kelas "*malignant*" memiliki jumlah 239 data dengan total *instance* 683. Berikut visualisasi distribusi data kelas target dataset WBCD.



Gambar 2. Distribusi Kelas Target Dataset WBCD.

- Preprocessing dimulai dengan *cleaning data*, menghapus kolom *id* pada dataset WBCD. Sehingga jumlah atribut setelah dilakukan penghapusan untuk dataset WBCD menjadi 10 atribut. Kemudian mengubah *feature class* dengan nama "*diagnosis*", jika tidak dirubah nama *features class* akan terbaca sebagai fungsi. Kemudian melakukan *feature encoding* yang dilakukan dengan menggunakan *library* label *encoder* dari *scikit learn* untuk mengubah label target klasifikasi menjadi numerik. Adapun hasil dari proses *feature encoding* di sajikan pada tabel 4.5. Pada dataset WBCD label "*benign*" menjadi



“0” dan label “*malignant*” menjadi “1”. Ekstraksi fitur yang dilakukan hanya untuk atribut data yang bertipe object dan menghasilkan jumlah kolom sebanyak 28 pada dataset WBCD. Hal ini karena ekstraksi fitur membentuk isian data pada setiap kolom atribut menjadi kolom baru yang mewakili setiap isi data dan atribut menjadi satu kolom dengan nilai biner yaitu 1 atau 0.

Tabel 10. Hasil Label Encoder

Dataset	Kategori	Label Encoder
WBCD	<i>benign</i>	0
	<i>malignant</i>	1

Sepuluh *instances* data yang sudah dilakukan proses *feature encoding* dan ekstraksi fitur disajikan pada Tabel 11.

Tabel 11 Dataset WBCD setelah Feature Encoding

Clumpthickness_High	Clumpthickness_Low	...	diagnosis
0	0	...	0
0	0	...	0
0	1	...	0
0	0	...	0
0	0	...	0
1	0	...	1
0	1	...	0
0	1	...	0
0	1	...	0
0	0	...	0

3. Hasil Split Data

Pembagian split data pada penelitian ini *data training* 80%, *data testing* 20%, untuk hasil split dataset WBCD pada data train dihasilkan sebanyak 546 data dan 137 data test

Tabel 12. Split Data

Diagnosis	WBCD	
	<i>train</i>	<i>test</i>
0	357	87
1	189	50
Total	546	137

4. Normalisasi Data

Tujuan dari normalisasi data untuk merubah range input data menjadi 0-1, berikut hasil dari normalisasi data pada input data WBCD.

array([[1., 0., 0., ..., 0., 1., 0.],

[0., 1., 0., ..., 0., 1., 0.],



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

[0., 0., 1., ..., 0., 1., 0.],

...,

[0., 1., 0., ..., 0., 1., 0.],

[0., 1., 0., ..., 0., 1., 0.],

[1., 0., 0., ..., 0., 1., 0.]]

5. Hasil Arsitektur Model

Hasil arsitektur model pada dataset WBCD untuk kelima skenario model deep learning yaitu model A pada Tabel 13, model B pada Tabel 14, model C pada Tabel 15, model D pada Tabel 16 dan model E pada Tabel 17 beserta jumlah parameternya.

Tabel 13. Model A Dataset WBCD

Layer (Type)	Output Shape	Param
input (Dense)	(None, 6)	168
dense (Dense)	(None, 15)	105
output (Dense)	(None, 1)	16
Total params: 289		
Trainable params: 289		
Non-trainable params: 0		

Tabel 14. Model B Dataset WBCD

Layer (Type)	Output Shape	Param
input (Dense)	(None, 6)	168
dense_3 (Dense)	(None, 15)	105
dense_4 (Dense)	(None, 15)	240
output (Dense)	(None, 1)	16
Total params: 529		
Trainable params: 529		
Non-trainable params: 0		

Tabel 15. Model C Dataset WBCD

Layer (Type)	Output Shape	Param
input (Dense)	(None, 6)	168
dense_9 (Dense)	(None, 15)	105
dense_10 (Dense)	(None, 15)	240
dense_11 (Dense)	(None, 15)	240
output (Dense)	(None, 1)	16
Total params: 769		
Trainable params: 769		
Non-trainable params: 0		



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

Tabel 16. Model D Dataset WBCD

Layer (Type)	Output Shape	Param
input (Dense)	(None, 6)	168
dense_18 (Dense)	(None, 15)	105
dense_19 (Dense)	(None, 15)	240
dense_20 (Dense)	(None, 15)	240
dense_21 (Dense)	(None, 15)	240
output (Dense)	(None, 1)	16
Total params: 1,009		
Trainable params: 1,009		
Non-trainable params: 0		

Tabel 17. Model E Dataset WBCD

Layer (Type)	Output Shape	Param
input (Dense)	(None, 6)	168
dense_30 (Dense)	(None, 15)	105
dense_31 (Dense)	(None, 15)	240
dense_32 (Dense)	(None, 15)	240
dense_33 (Dense)	(None, 15)	240
dense_34 (Dense)	(None, 15)	240
output (Dense)	(None, 1)	16
Total params: 1,249		
Trainable params: 1,249		
Non-trainable params: 0		

6. Hasil Training dan Validasi Model

Hasil *training* dan *validation* model untuk dataset kanker payudara yaitu dataset WBCD disajikan pada Tabel 18, untuk nilai *accuracy* (Acc) *training* model terbaik dihasilkan pada Model-D algoritma *deep learning* dengan *learning rate* 0,01 dan *hidden layer* empat sebesar 0.9817 dengan nilai *loss* (L) paling minimumnya sebesar 0.0637 pada *learning rate* 0.01 dan *hidden layer* empat. Kemudian nilai *validation accuracy* (VAcc) terbaik pada Model-B dengan *hidden layer* dua dan Model-E dengan *hidden layer* lima algoritma *Deep Learning* pada *learning rate* 0.01 sebesar 0.9635, dan nilai *validation loss* (VL) paling minimum terdapat pada Model-C algoritma *Deep Learning* dengan *learning rate* 0.01 dan *hidden layer* tiga sebesar 0.1106.

Tabel 18. Hasil Training dan Validation Model Dataset WBCD

Arsitektur Model	Learnng Rate	Batch Size	Training		Validation	
			Acc	Loss	VAcc	VLoss
A	0.1	20	0.9780	0.1265	0.9549	0.1375
	0.01	20	0.9780	0.0670	0.9562	0.1279
	0.001	20	0.9707	0.0796	0.9489	0.1212
B	0.1	20	0.6538	0.6527	0.6566	0.6350
	0.01	20	0.9799	0.0781	0.9635	0.1269
	0.001	20	0.9799	0.0770	0.9562	0.1142
C	0.1	20	0.9762	0.1024	0.9489	0.1785
	0.01	20	0.9780	0.0932	0.9562	0.1106



	0.001	20	0.9799	0.0771	0.9489	0.1122
D	0.1	20	0.6538	0.6513	0.6350	0.6594
	0.01	20	0.9817	0.0637	0.9489	0.1860
	0.001	20	0.9780	0.0748	0.9562	0.1111
E	0.1	20	0.6538	0.6516	0.6350	0.6630
	0.01	20	0.9707	0.0932	0.9635	0.9707
	0.001	20	0.6538	0.6457	0.6350	0.6562

7. Hasil Akurasi

Tabel 19. menjelaskan hasil akurasi yang di dapat dari penelitian yang telah dilakukan dataset WBCD dihasilkan akurasi tertinggi pada dataset WBCD adalah 96,3% pada *learning rate* 0,01 dengan Model-B *hidden layer* 2 dan Model-E *hidden layer* 5.

Tabel 19. Hasil Accuracy

Learning Rate	Hasil Model Deep Learning (%)				
	Model-A	Model-B	Model-C	Model-D	Model-E
0.1	94.8	63.5	94.8	63.5	63.5
0.01	95.6	96.3	95.6	94.8	96.3
0.001	94.8	95.6	94.8	95.6	63.5

8. Hasil Presisi

Tabel 20 menjelaskan hasil presisi yang di dapat dari penelitian yang telah dilakukan dataset WBCD dihasilkan presisi tertinggi pada dataset WBCD adalah 95,4% pada *learning rate* 0,01 dengan Model-B *hidden layer* 2 dan Model-E *hidden layer* 5.

Tabel 20. Hasil Presisi

Learning Rate	Hasil Model Deep Learning (%)				
	Model-A	Model-B	Model-C	Model-D	Model-E
0.1	94.0	31.7	94.0	31.7	31.7
0.01	94.6	95.4	94.7	94.0	95.4
0.001	94.9	94.7	94.0	94.7	31.7

9. Hasil Recall

Tabel 21 menjelaskan hasil recall yang di dapat dari penelitian yang telah dilakukan dataset WBCD dihasilkan recall tertinggi pada dataset WBCD adalah 97,1% pada *learning rate* 0,01 dengan Model-B *hidden layer* 2 dan Model-E *hidden layer* 5.

Tabel 21. Hasil Recall

Learning Rate	Hasil Model Deep Learning (%)				
	Model-A	Model-B	Model-C	Model-D	Model-E
0.1	95.1	50	95.1	50	50
0.01	96.5	97.1	96.1	95.1	97.1
0.001	95.1	96.1	95.1	96.1	50

10. Hasil f1 Score



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

Tabel 22 menjelaskan hasil *f1-score* yang di dapat dari penelitian yang telah dilakukan dataset WBCD dihasilkan *f1-score* tertinggi pada dataset WBCD adalah 96,1% pada *learning rate* 0,01 dengan Model-B *hidden layer* 2 dan Model-E *hidden layer* 5.

Tabel 22. Hasil *f1 score*

Learning Rate	Hasil Model Deep Learning (%)				
	Model-A	Model-B	Model-C	Model-D	Model-E
0.1	94.5	39	94.5	39	38.8
0.01	95.3	96.1	95.3	94.5	96.1
0.001	94.5	95.3	94.5	95.3	38.8

11. Model Prediktif yang diusulkan

Berikut ini rekapitulasi hasil eksperimen akurasi, presisi, recall, *f1 score* yang sudah diujikan dataset kanker payudara WBCD.

Table 23. Rekapitulasi Score

Metric Performance				
Dataset	Accuracy	Precision	Recall	f1 Score
WBCD	96.3	95.4	97.1	96.1

Hasil pengujian menunjukan *metric Performance* dataset kanker payudara, Hasil terbaik dataset WBCD memiliki *accuracy* terbaik 96.3%, *precision* 95.4%, *recall* 97.1% dan *f1 score* 96.1%.

IV. KESIMPULAN

Berdasarkan analisis dan pembahasan hasil penelitian, dapat disimpulkan:

1. Arsitektur Model *Deep Learning* dapat digunakan untuk mengklasifikasikan penyakit kanker payudara.
2. Penggunaan optimasi Adam dan variasi *hidden layer* mendapatkan *score metrics performance* yang berbeda-beda.
3. Model *Deep Learning* yang diusulkan mendapatkan *score metric performance* terbaik memiliki *accuracy* terbaik 96.3%, *precision* 95.4%, *recall* 97.1% dan *f1 score* 96.1%.

REFERENASI

- [1] H. B. Lee And W. Han, "Unique Features Of Young Age Breast Cancer And Its Management," J. Breast Cancer, Vol. 17, No. 4, Pp. 301–307, 2014.
- [2] V. Chaurasia And S. Pal, "Applications Of Machine Learning Techniques To Predict Diagnostic Breast Cancer," Sn Comput. Sci., Vol. 1, No. 5, Pp. 1–11, 2020.
- [3] R. A. Khan, T. Suleman, M. S. Farooq, M. H. Rafiq, And M. A. Tariq, "Data Mining Algorithms For Classification Of Diagnostic Cancer Using Genetic Optimization Algorithms," Ijcsns Int. J. Comput. Sci. Netw. Secur., Vol. 12, No. March, Pp. 207–211, 2017.
- [4] E. Alickovic And A. Subasi, Normalized Neural Networks For Breast Cancer Classification, Vol. 73. Springer International Publishing, 2020.
- [5] W. Majeed Et Al., "Breast Cancer: Major Risk Factors And Recent Developments In Treatment," Asian Pacific J. Cancer Prev., Vol. 15, No. 8, Pp. 3353–3358, 2014.
- [6] F. Bray, J. Ferlay, I. Soerjomataram, R. L. Siegel, L. A. Torre, And A. Jemal, "Global Cancer Statistics 2018: Globocan Estimates Of Incidence And Mortality Worldwide For 36 Cancers In 185 Countries," Ca. Cancer J. Clin., Vol. 68, No. 6, Pp. 394–424, 2018.



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).

- [7] A. E. Minarno And E. A. Hakim, “Klasifikasi Citra Thorax X - Ray Menggunakan Transfer Learning Inception V3,” Pp. 53–62, 2021.
- [8] N. F. Idris And M. A. Ismail, “Breast Cancer Disease Classification Using Fuzzy-Id3 Algorithm With Fuzzydbd Method: Automatic Fuzzy Database Definition,” *Peerj Comput. Sci.*, Vol. 7, Pp. 1–22, 2021.
- [9] M. Pyingkodi, M. M., Shanthi, S., Saravanan, T. M., Thenmozhi, K., Nanthini, K., Hemalatha, D., ... & Dhivya, “Performance Study Of Classification Algorithms Using The Breast Cancer Dataset,” *Int. J. Futur. Gener. Commun. Netw.*, 2020.
- [10] H. Saoud, A. Ghadi, M. Ghailani, And B. A. Abdelhakim, *Using Feature Selection Techniques To Improve The Accuracy Of Breast Cancer Classification*, Vol. 1. Springer International Publishing, 2019.



DOI: 10.52362/jisamar.v7i1.1015

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).