

METODE *ENSEMBLE LEARNING* TEKNIK *WEIGHTED VOTING* PADA ARSITEKTUR *ALEXNET*, *VGG-16* DAN *XCEPTION* DALAM KLASIFIKASI PENYAKIT KANKER PAYUDARA

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana
di Jurusan Matematika pada Fakultas MIPA**

Oleh:

SURISTHIA RAHMADITA

NIM 08011382126110



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

METODE *ENSEMBLE LEARNING* TEKNIK *WEIGHTED VOTING* PADA ARSITEKTUR *ALEXNET*, *VGG-16* DAN *XCEPTION* DALAM KLASIFIKASI PENYAKIT KANKER PAYUDARA

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana
di Jurusan Matematika pada Fakultas MIPA**

Oleh:

SURISTHIA RAHMADITA

NIM 08011382126110

Indralaya, 13 Januari 2025

Pembimbing Kedua



Dr. Ir. Herlina Hanum, M.Si.

NIP. 196501081990032007

Pembimbing Utama



Dr. Anita Desiani, S.Si., M.Kom.

NIP. 197712112003122002

Mengetahui,

Ketua Jurusan Matematika



Dr. Dian Cahyawati Sukanda, S.Si., M.Si.

NIP. 197303212000122001

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang beranda tangan di bawah ini:

Nama Mahasiswa : Suristhia Rahmadita
NIM : 08011382126110
Jurusan : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini berasal dari penulis lain baik yang dipublikasikan atau telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 13 Januari 2025
Penulis



Suristhia Rahmadita
NIM. 08011382126110

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang MahaKuasa Allah Subhanahu Wa Ta'ala,

Ayah dan Ibu yang sangat kucinta,

Ayukku tersayang,

Keluarga Besarku,

Semua Dosenku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

" Success is not measured by how much you fall but how much you get up"

-Suristhia Rahmadita

KATA PENGANTAR

Puji syukur atas kehadiran Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “Metode *Ensemble Learning* Teknik *Weighted Voting* Pada Arsitektur *Alexnet*, *VGG-16*, dan *Xception* dalam Klasifikasi Penyakit Kanker Payudara”. Skripsi ini ditulis sebagai salah satu syarat memperoleh gelar sarjana sains studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih yang sebesar-besarnya kepada orang tua tercinta, Ayahku **Supomo** dan Ibuku **Risdalena, S.Pd. Gr.** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendoakan. Penulis juga ingin menyampaikan ucapan terima kasih kepada sebesar-besarnya dan penghargaan setinggi-tingginya kepada:

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya.
2. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua Jurusan Matematika dan Ibu **Des Alwine Zayanti, S.Si., M.Si.** selaku Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan

akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

3. Ibu **Dr. Anita Desiani, S.Si., M.Kom** selaku Dosen Pembimbing Akademik serta Dosen Pembimbing Pertama dan Ibu **Dr. Ir. Herlina Hanum, M.Si.** selaku Dosen Pembimbing Kedua yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan dan didikan yang berharga selama pembuatan skripsi, perlombaan dan proses perkuliahan.
4. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
5. Ayukku tersayang **Morissalia Wahyu Ningtias, S.Kep. Ns.** yang senantiasa memberikan dukungan finansial, semangat dan doa terbaik untuk penulis.
6. **Kakak-kakak tingkat angkatan 2018, 2019 dan 2020 bidang minat komputasi, Tim Komputasi 2021** yang telah banyak membantu serta berbagi ilmu selama proses pembuatan skripsi.
7. **Keluarga Matematika 2021, BPH Sinergi Cita, Asisten Laboratorium Komputasi, Adik Tingkat 2022 Bidang Minat Komputasi** dan rekan-rekan **perlombaan** selama perkuliahan. Terima kasih atas dukungan, pengertian, dan kebaikan kalian.

8. **BPI Laskaria** (Faishal, Ally, Frisca, Mitta, Yolan) terima kasih sudah menjadi orang-orang baik yang memberikan cinta, pengertian, dukungan, dan energi positif.
9. Teman seperjuangan tersayang Adzra Afiifah Nabila, Cindy Lidya Putri, Alda Amalia Mortara, Niken Ayuputri, Mitta Permatasari dan Agdelillah. Terima kasih untuk bantuan, semangat dan kerja samanya.
10. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/i Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan semua pihak yang membutuhkan.

Indralaya, Januari 2025

Penulis

**ENSEMBLE LEARNING METHOD WEIGHTED VOTING TECHNIQUE
ON ALEXNET, VGG-16 AND XCEPTION ARCHITECTURES IN BREAST
CANCER DISEASE CLASSIFICATION**

By:

Suristhia Rahmadita

08011382126110

ABSTRACT

Automatic classification of breast cancer is done by utilizing ultrasound images (USG). Automatic early detection of breast cancer can use several CNN architectures such as AlexNet, VGG-16 and Xception. AlexNet is easy to implement, but less effective in capturing complex features. VGG-16 has a deep layer that can extract complex features, but has the risk of overfitting due to a too large number of parameters. The xception has ability to capture complex features like VGG-16 and produces fewer parameters because it uses depthwise separable convolution, but is vulnerable to outliers. Each architecture has advantages and disadvantages, to obtain better performance, ensemble learning can be used. This research method performs weighted voting by involving NASNetMobile learning to combine the weight results from AlexNet, VGG-16 and Xception. The application of NASNetMobile to the ensemble learning method is used to ensure that the weights obtained are optimal weights because NASNetMobile has the ability to adjust the model using the Neural Architecture Search approach. This method is applied to the classification of breast cancer in 3 classes, namely benign, malignant, and normal. The results of this method obtained the average accuracy, sensitivity, specificity, F1-Score and Cohen's Kappa as 96%, 96%, 98%, 96% and 0.94. The performance results above 90% show that the ensemble learning method of weighted voting technique with NASNetMobile learning is very good in classifying breast cancer. Classification results on the malignant class were excellent with performance above 96%, exceeding that of the normal and benign classes. Although the performance on the normal and benign classes was lower, both still reached above 90%. The results of the application of ensemble learning on average can improve the performance of AlexNet, VGG-16 and Xception by 5%.

Keywords: AlexNet, NASNetMobile, VGG-16, Weighted Voting, Xception

**METODE ENSEMBLE LEARNING TEKNIK WEIGHTED VOTING PADA
ARSITEKTUR ALEXNET, VGG-16 DAN XCEPTION DALAM
KLASIFIKASI PENYAKIT KANKER PAYUDARA**

Oleh:

Suristhia Rahmadita

08011382126110

ABSTRAK

Klasifikasi kanker payudara secara otomatis dilakukan dengan memanfaatkan citra *ultrasound* (USG). Deteksi dini otomatis pada kanker payudara dapat menggunakan beberapa arsitektur CNN seperti *AlexNet*, *VGG-16* dan *Xception*. *AlexNet* mudah diimplementasikan, tetapi kurang efektif dalam menangkap fitur kompleks. *VGG-16* memiliki lapisan mendalam yang dapat mengekstraksi fitur kompleks, namun memiliki resiko *overfitting* akibat jumlah parameter yang terlalu besar. *Xception* memiliki kemampuan menangkap fitur kompleks seperti *VGG-16* dan menghasilkan parameter lebih sedikit karena *depthwise separable convolution*, namun rentan terhadap *outlier*. Masing-masing arsitektur memiliki kelebihan dan kekurangan, untuk memperoleh performa yang lebih baik dapat menggunakan *ensemble learning*. Metode penelitian ini melakukan *weighted voting* dengan melibatkan pembelajaran *NASNetMobile* untuk menggabungkan hasil bobot dari *AlexNet*, *VGG-16* dan *Xception*. Penerapan *NASNetMobile* pada metode *ensemble learning* digunakan untuk memastikan bahwa bobot yang diperoleh merupakan bobot yang optimal karena *NASNetMobile* memiliki kemampuan menyesuaikan model menggunakan pendekatan *Neural Architecture Search*. Metode ini diterapkan untuk klasifikasi kanker payudara pada 3 kelas yaitu *benign*, *malignant*, dan normal. Hasil metode ini diperoleh rata-rata akurasi, sensitivitas, spesifisitas, *F1-Score* dan *Cohen's Kappa* sebesar 96%, 96%, 98%, 96% dan 0,94. Hasil kinerja diatas 90% menunjukkan bahwa metode *ensemble learning* teknik *weighted voting* dengan pembelajaran *NASNetMobile* sangat baik dalam mengklasifikasikan kanker payudara. Hasil pada kelas *malignant* sangat baik dengan kinerja di atas 96%, melebihi kelas normal dan *benign*. Meskipun kinerja pada kelas normal dan *benign* lebih rendah, tetap mencapai di atas 90% Hasil penerapan dari *ensemble learning* rata-rata mampu meningkatkan kinerja dari *AlexNet*, *VGG-16* dan *Xception* sebesar 5%.

Kata Kunci: *AlexNet, NASNetMobile, VGG-16, Weighted Voting, Xception*

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN JUDUL.....	iv
HALAMAN PERSEMBAHAN	iv
KATA PENGANTAR	v
ABSTRACT.....	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR GAMBAR	xii
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2 Perumusan Masalah	7
1.3 Pembatas Masalah.....	7
1.4 Tujuan	8
1.5 Manfaat	8
BAB II TINJAUAN PUSTAKA.....	9
2. 1 Kanker Payudara	9
2. 2 Citra USG.....	10
2. 3 <i>Preprocessing</i> Data	10
2.3.1 Perbaikan Kualitas Citra	10
2.3.2 Augmentasi Citra	10
2.4 Klasifikasi Citra	11
2.5 Convolutional Neural Network (CNN).....	11
2.5.1 <i>Convolutional Layer</i>	12
2.5.2 <i>Batch Normalization</i>	13
2.5.3 Fungsi Aktivasi ReLU.....	14
2.5.4 <i>Max Polling</i>	15
2.5.5 <i>Fully Connected</i>	16

2.5.6 Fungsi Aktivasi <i>Softmax</i>	16
2.5.7 <i>Loss Function</i>	17
2.5.8 <i>Optimization function : Adaptive Moment Estimation (ADAM)</i>	17
2.6 <i>AlexNet</i>	19
2.7 <i>VGG-16</i>	20
2.8 <i>Xception</i>	21
2.9 <i>Ensemble Learning</i>	22
2.10 <i>Weighted Voting</i>	22
2.11 <i>Depthwise Separable Convolution</i>	23
2.12 <i>NASNetMobile (Neural Architecture Search Network)</i>	24
2.13 <i>Confusion Matrix</i>	25
BAB III METODOLOGI PENELITIAN.....	28
3.1. Tempat	28
3.2 Waktu	28
3.3 Alat	28
3.4 Tahap Penelitian.....	28
3.4.1 Pengumpulan Data	29
3.4.2 Augmentasi Citra	29
3.4.3 Tahap <i>Training</i>	29
3.4.4 <i>Testing</i> Data	33
BAB IV PEMBAHASAN.....	35
4.1 Deskripsi Data.....	35
4.2 <i>Preprocessing</i> Data	35
4.3 Operasi Manual Convolutional Neural Network (CNN)	36
4.4 <i>Ensemble Learning</i>	50
4.6 Hasil Penerapan <i>AlexNet</i> , <i>VGG-16</i> , <i>Xception</i> dan <i>Ensemble Learning</i>	54
4.6.1 <i>Training</i>	54
4.6.2 <i>Testing</i>	62
4.7 Evaluasi.....	65
BAB V KESIMPULAN DAN SARAN.....	74
5.1 Kesimpulan	74
5.2 Saran.....	74

DAFTAR PUSTAKA	75
----------------------	----

DAFTAR GAMBAR

Gambar 2. 1 Hasil USG Kanker Payudara.....	9
Gambar 2. 2 <i>Convolutional layer</i>	12
Gambar 2. 3 Matriks (a) <i>Input</i> (b) Nilai Maksimum.....	15
Gambar 2. 4 Arsitektur <i>Alexnet</i>	19
Gambar 2. 5 Arsitektur <i>VGG-16</i>	20
Gambar 2. 6 Arsitektur <i>Xception</i>	21
Gambar 2. 7 Contoh <i>Depthwise Separable Convolution</i>	23
Gambar 2. 8 Arsitektur <i>NASnetmobile</i>	25
Gambar 4. 1 Grafik Nilai Akurasi Pada Proses Training Model <i>AlexNet</i>	55
Gambar 4. 2 Grafik Nilai Loss Pada Proses Training Model <i>AlexNet</i>	56
Gambar 4. 3 Grafik Nilai Akurasi Pada Proses Training Model <i>VGG-16</i>	57
Gambar 4. 4 Grafik Nilai Loss Pada Proses Training Model <i>VGG-16</i>	58
Gambar 4. 5 Grafik Akurasi Pada Proses Training Model <i>Xception</i>	59
Gambar 4. 6 Grafik <i>Loss</i> Pada Proses Training Model <i>Xception</i>	60
Gambar 4. 7 Grafik Akurasi Pada Proses <i>Training Model ensemble learning</i>	61
Gambar 4. 8 Grafik <i>Loss</i> Pada Proses <i>Training Model Ensemble Learning</i>	62

DAFTAR TABEL

Tabel 2. 1 Tabel Kategori Evaluasi Hasil Kinerja	9
Tabel 4. 1 Sampel Data Citra <i>Breast Cancer</i>	35
Tabel 4. 2 Confusion Matrix dari Proses <i>Testing</i>	63
Tabel 4. 3 Perbandingan Hasil Klasifikasi dari Setiap Model	71
Tabel 4. 4 Perbandingan Arsitektur dengan Penelitian Lain.....	73

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kanker merupakan kondisi sel-sel dalam jaringan tubuh mengalami pertumbuhan yang tidak normal dan bersifat ganas. Sel-sel tersebut dapat berkembang tanpa henti dan menyebar ke bagian tubuh lain, yang berpotensi kematian (Achmad, 2022). Pada tahun 2020 menurut data *Global Cancer Observatory* (GLOBOCAN), dari total 19,29 juta kasus kanker, terdapat 2.261.419 kasus kanker payudara dengan jumlah kematian mencapai 684.996 jiwa didunia (Jabeen *et al.*, 2022). Kanker payudara dikelompokkan menjadi 3 tingkat keparahan yaitu normal, *benign* (jinak) dan *malignant* (ganas). Deteksi dan diagnosis dini citra kanker payudara dapat menggunakan pemeriksaan perangkat *ultrasound* (USG) yang menghasilkan citra payudara (Haq *and* Fatichah, 2023). Hasil pemeriksaan citra USG kanker payudara secara manual membutuhkan keahlian khusus untuk melakukan diagnosis. Selain itu, diagnosis oleh ahli radiologi merupakan tugas yang sangat subjektif berpotensi terjadinya kesalahan akibat kondisi individu dan pengalaman (Pesapane *et al.*, 2024). Klasifikasi secara otomatis dapat digunakan untuk membantu melakukan deteksi dini, termasuk pada penyakit kanker payudara. Klasifikasi otomatis saat ini dapat dilakukan dengan menggunakan *deep learning* (Jiang *et al.* 2021).

Convolutional Neural Network (CNN) adalah salah satu metode *Deep learning* yang sering dimanfaatkan dalam pengklasifikasian citra (Alhichri *et al.*, 2021). CNN merupakan jaringan saraf tiruan yang tersusun melalui lapisan konvolusi

lapisan pooling yang beroperasi secara integritas untuk mengekstraksi fitur dan mengenali objek dalam gambar (Erdem *et al.*, 2020). CNN berkembang untuk memenuhi kebutuhan pengolahan data visual seperti pengenalan objek, klasifikasi citra medis dan lainnya (Bhatt *et al.*, 2021). Perkembangan CNN dengan berbagai macam arsitektur seperti *DenseNet*, *Inception*, *ResNet* dan *AlexNet* (Swapna *et al.*, 2020).

AlexNet merupakan salah satu model arsitektur yang mempopulerkan penggunaan *deep learning* setelah kemenangan dalam kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) tahun 2012 (Luo *et al.*, 2022). *AlexNet* memiliki model yang sederhana yang terdiri dari 5 lapisan konvolusi (*convolutional layer*), 3 lapisan *maxpooling*, dan 3 lapisan *fully connected layer* (Luo *et al.*, 2022). Daya komputasi yang diperlukan *AlexNet* sedikit dan mudah untuk diimplementasikan (Tang *et al.*, 2023). Benhassine (2024) menerapkan arsitektur *AlexNet* pada klasifikasi citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi 85,6%, Nawaz (2018) menerapkan arsitektur *AlexNet* pada citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi 75%, Jawad *and* Khursheed (2022) menerapkan arsitektur *AlexNet* pada citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi 85%, dan Wijaya (2024) menerapkan arsitektur *AlexNet* pada klasifikasi citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi 97%, tetapi penelitian tersebut tidak menghitung nilai sensitivitas dan spesifisitas sehingga model kurang memberikan informasi tentang kinerja model.

Arsitektur *AlexNet* yang dangkal membuat *AlexNet* terbatas bekerja dalam menggali fitur-fitur detail pada citra yang lebih kompleks karena memiliki 5 lapisan konvolusi yang relatif sedikit serta memiliki parameter yang besar yaitu 60 juta (Azizah, 2023). Arsitektur yang memiliki lapisan konvolusi yang dalam dibandingkan *AlexNet* dan mampu mengekstraksi fitur-fitur penting untuk dipelajari pada citra kompleks adalah *Visual Geometry Group* (VGG) (Chen *et al.*, 2020).

VGG-16 adalah arsitektur jaringan yang terdiri dari 13 lapisan konvolusi dan 3 lapisan *fully connected* yang terhubung (Mogan *et al.*, 2022). *VGG-16* menggunakan kernel yang relatif kecil yaitu 3x3 karena membutuhkan lebih sedikit operasi dibandingkan kernel besar yang menyebabkan *VGG-16* mampu menggali fitur secara detail dan mendalam karena hanya memproses dan mengenali area citra dengan ukuran kernel 3x3 pada citra dalam setiap kali konvolusi (Desiani *et al.*, 2022). Ashwini (2024) menerapkan arsitektur *VGG-16* pada citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi 91%, Hossain (2023) menerapkan arsitektur *VGG-16* pada citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi yaitu 91%.

Meskipun *VGG-16* menggunakan kernel yang kecil namun menghasilkan jumlah parameter yang besar yaitu 138 juta yang disebabkan oleh total kedalaman 16 lapisan yang dipelajari serta struktur neuron yang terhubung dalam lapisan *fully connected* sebanyak 4096 neuron (Arwinto *et al.*, 2024). Akibat lapisan konvolusi yang mendalam dan jumlah parameter yang besar pada arsitektur *VGG16* mengakibatkan rentan *overfitting* (Khan *et al.*, 201). Lapisan *VGG-16* yang

mendalam menyebabkan *VGG-16* memerlukan daya komputasi dan memori yang besar (Kumaresan *et al.*, 2023).

Arsitektur CNN yang memiliki jumlah parameter yang lebih ringan dari *AlexNet* dan *VGG-16* adalah *Xception* yaitu sebesar 22 juta (Ravikiran *et al.*, 2022). *Xception* terdiri dari 36 lapisan konvolusi, namun menghasilkan jumlah parameter yang lebih sedikit karena lapisan konvolusinya menggunakan *depthwise separable convolution*. Perbedaan *depthwise separable convolution* dengan konvolusi biasa terletak pada prosesnya, konvolusi biasa menerapkan operasi pada seluruh saluran input sekaligus, menghasilkan satu *output channel* per kernel (Khan and Niu, 2021). *Depthwise separable convolution* memisahkan operasi konvolusi menjadi 2 yaitu *depthwise convolution* dan *pointwise convolution*. Setiap saluran dari *input* akan di proses dengan *depthwise convolution* yang memproses setiap saluran *input* secara terpisah (Almogbil *et al.*, 2022). Setelah proses *depthwise convolution* maka akan lanjut ke proses *pointwise convolution* menggabungkan informasi dari semua saluran dengan filter 1x1 untuk mengubah dan menggabungkan saluran-saluran yang telah diproses (Zhang *et al.*, 2020). *Depthwise separable convolution* lebih efisien karena memproses saluran input secara terpisah dan hanya menggunakan filter 1x1 untuk menggabungkannya, sehingga mengurangi beban komputasi dan jumlah parameter tanpa mengorbankan performa model.

Sharma and Kumar (2022) menerapkan arsitektur *Xception* pada klasifikasi citra kanker payudara untuk klasifikasi penyakit kanker payudara dengan hasil akurasi, sensitivitas, spesifisitas, dan *F1-Score* masing-masing diatas 96% tetapi hanya mengklasifikasikan dalam dua kelas yaitu jinak dan ganas. Walaupun jumlah

parameternya hanya 22 juta, pengolahan dengan *Xception* dapat membutuhkan lebih banyak memori karena proses konvolusinya terbagi menjadi 2 tahap yaitu *depthwise convolution* dan *pointwise convolution* sehingga lapisan konvolusi banyak (Benajiba *et al.*, 2024). Selain itu akibat penggunaan 2 konvolusi membuat *Xception* rentan terhadap *outlier* karena kemampuan menangkap detail halus yang tidak relevan dengan data tetapi tetap di pelajari.

Kinerja terbaik dari tiap model dapat digabungkan dengan metode *ensemble learning* untuk mengabaikan kekurangan dari arsitektur *single classifier*. Metode *ensemble learning* adalah metode yang bekerja dengan mengambil bobot kinerja masing-masing arsitektur (Qummar *et al.*, 2019). Beberapa cara teknik *ensemble learning* diantaranya *stacking*, *bagging*, *averaging*, *boosting* dan *weighted voting* (Osamor and Okezie, 2021). Beberapa penelitian yang menggunakan teknik *ensemble learning* diantaranya Moon (2020) menggunakan metode *weighted voting* arsitektur *DenseNet121*, *DenseNet40*, *DenseNet161* dan *VGG* dalam deteksi kanker payudara citra kanker payudara untuk klasifikasi penyakit kanker payudara yang menghasilkan nilai akurasi 90%. Zerouaoui (2024) menggunakan metode *weighted voting* arsitektur *ResNet50* dan *Xception* dalam deteksi kanker payudara citra kanker payudara untuk klasifikasi penyakit kanker payudara yang menghasilkan nilai akurasi 93%. Mohamed (2022) menggunakan *ensemble learning* arsitektur *ResNet50*, *ResNet101* dan *Densenet169* dalam deteksi kanker payudara citra kanker payudara untuk klasifikasi penyakit kanker payudara yang menghasilkan nilai akurasi 92%. *Weighted voting* bekerja dengan cara menentukan hasil akhir

berdasarkan jumlah suara terbanyak, di mana setiap prediksi dari masing-masing metode diberikan bobot tertentu (Deepa *et al.*, 2021).

Namun penelitian-penelitian tersebut hanya menerapkan metode *ensemble* pada tahap pengujian. *Ensemble* yang diterapkan saat pengujian tidak dapat menjamin bahwa bobot yang dihasilkan adalah yang terbaik dan tidak dapat dilakukan pengecekan apakah bobot mengalami *overfitting* terutama pada citra yang memiliki kemiripan (Kesuma *et al.*, 2023). Untuk memastikan bahwa bobot *ensemble* yang digunakan adalah yang terbaik dan tidak menyebabkan *overfitting*, diperlukan model pembelajaran yang efisien dan mendapatkan bobot terbaik seperti *NASNetMobile* untuk memastikan kualitas bobot tersebut. Kelebihan yang dimiliki *NASNetMobile* adalah arsitektur yang efisien untuk bekerja pada *input* yang sederhana (Dishar and Muhammed, 2023). Pembelajaran bobot dengan *NASNetMobile* sederhana namun tetap dapat memastikan bahwa hasil bobot tidak *overfitting*, jumlah parameter *NASNetMobile* sekitar 4 juta (Dishar and Muhammed, 2023). Khan (2022) menerapkan arsitektur *NASNetMobile* pada citra kanker payudara menghasilkan nilai akurasi 93% dalam deteksi kanker payudara, namun hanya mengklasifikasi dalam kelas jinak dan ganas. Kalita (2024) menerapkan arsitektur *NASNetMobile* pada citra kanker payudara menghasilkan nilai akurasi 94% dalam deteksi kanker payudara.

Pada penelitian ini diusulkan metode *ensemble learning* yang menggabungkan hasil *AlexNet*, *VGG-16* dan *Xception* menggunakan teknik *weighted voting* dengan pembelajaran arsitektur *Neural Architecture Search (NASNetMobile)*. Dengan metode *ensemble learning* diharapkan penelitian ini mendapatkan hasil yang

diperoleh tidak mengalami *overfitting* dan menunjukkan kinerja yang baik. Setelah melakukan teknik *weighted voting* berdasarkan hasil *AlexNet*, *VGG-16* dan *Xception*, penelitian ini melakukan pembelajaran menggunakan arsitektur *NASNetMobile*. Pembelajaran *NASNetMobile* digunakan untuk membantu model mempelajari pola pembobotan pada setiap data, sekaligus mencegah *overfitting* dalam proses klasifikasi penyakit kanker payudara. Penelitian ini bertujuan untuk mengklasifikasikan tingkat keparahan penyakit kanker payudara berdasarkan citra USG kanker payudara dengan 3 kelas yaitu normal, *benign* (jinak) dan *malignant* (ganas). Hasil evaluasi kinerja arsitektur dapat diukur berdasarkan akurasi, presisi, *recall*, *f1-score*, sensitivitas, spesififikasi dan *Cohens Kappa*.

1.2 Perumusan Masalah

Bagaimana hasil kinerja metode *ensemble learning* pada arsitektur *AlexNet*, *VGG-16* dan *Xception* menggunakan teknik *weighted voting* dengan pembelajaran *NASNetMobile* dibandingkan hasil kinerja dari arsitektur tunggal *AlexNet*, *VGG-16* dan *Xception* berdasarkan nilai akurasi, presisi, *recall*, *f1-score*, sensitivitas, spesififikasi dan *Cohen's Kappa* dalam klasifikasi citra USG penyakit kanker payudara.

1.3 Pembatas Masalah

Beberapa pembatasan masalah dalam penelitian ini sebagai berikut:

1. Penelitian ini mengklasifikasikan kanker payudara dari *dataset* citra 2 dimensi dan menggunakan tiga label yaitu normal, *malignant* dan *benign*.

2. Ukuran evaluasi kinerja pada model klasifikasi kanker payudara yang digunakan antara lain yaitu nilai akurasi, presisi, *recall*, *f1-score*, sensitivitas, spesififikasi dan *Cohens Kappa*.

1.4 Tujuan

Tujuan dari penelitian ini adalah untuk memperoleh hasil kinerja dari metode *ensemble learning* pada arsitektur *AlexNet*, *VGG-16* dan *Xception* menggunakan teknik *weighted voting* dengan pembelajaran *NASNetMobile* untuk memperoleh hasil yang akurat pada klasifikasi citra USG kanker payudara berdasarkan nilai akurasi, presisi, *recall*, *f1-score*, sensitivitas, spesifisitas dan *Cohens Kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut:

1. Memperoleh model yang dapat mengklasifikasikan kanker payudara pada citra USG 2D untuk deteksi dini kanker payudara.
2. Dapat digunakan sebagai referensi model yang digunakan untuk penelitian lainnya, khususnya dalam klasifikasi kanker payudara pada 2D dan pengembangan *Deep Learning*.

DAFTAR PUSTAKA

- Achmad, A.D., (2022). Klasifikasi breast cancer menggunakan metode logistic regression. *JTRISTE*, 9(1), 143–148. <https://jurnal.kharisma.ac.id/jtriste/article/view/384>.
- Al-Dhabyani W, Gomaa M, Khaled H, Fahmy A (2020). Dataset of breast ultrasound images. Kaggle. <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset>.
- Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., & Alajlan, N. A. (2021). Classification of remote sensing images using efficientnet-b3 CNN model pwith attention. *IEEE Access*, 9, 14078–14094. <https://doi.org/10.1109/ACCESS.2021.3051085>.
- Almogbil, A., Alghamdi, A., Alsahli, A., Alotaibi, J., Alajlan, R., Alghamdi, F., (2022). A Comparison between VGG16 and xception models used as encoders for image captioning. *Computer Science & Information Technology (CS & IT)*, 12(13),185–195.
- Anand, R., Sowmya, V., Vijaykrishnamenon, Gopalakrishnan, E. A., & Soman, K. P. (2021). Modified VGG deep learning architecture for covid-19 classification using bio-medical images. *IOP Conference Series: Materials Science and Engineering*, 1084(1), 012001.
- Arwinto, M. R. A., Susanti, A., Agustin, T., & others. (2024). Analisis performa model deep learning VGG16 dan ResNet dalam klasifikasi jenis tumor otak. *Prosiding Seminar Nasional Amikom Surakarta*, 2, 136–147.
- Ashwini, P., Suguna, N., & Vadivelan, N. (2024). Detection and classification of breast cancer types using VGG16 and ResNet50 deep learning techniques. *International Journal of Electrical and Computer Engineering (IJECE)*, 14(5), 5481–5488.
- Azizah, Q.N., (2023). Health classification of meibomian gland images using keratography 5M based on alexnet model. *Computer Methods and Programs in Biomedicine Jurnal Teknologi Informasi*, 2, 28–33. <https://www.science-direct.com/science/article/abs/pii/S0169260722001286>.
- Benajiba, Y., Chrayah, M., & Al-Amrani, Y. (2024). A hybrid approach with xception and nasnet for early breast cancer detection. *International Journal of Advanced Computer Science & Applications*, 15(4).
- Benhassine, N. E., Boukaache, A., & Boudjehem, D. (2024). Breast cancer image classification using DenseNet201 and AlexNet based deep transfer learning. *Proceedings of the International Conference on Emerging Intelligent Systems for Sustainable Development Atlantis Press International BV*. Angers. <https://doi.org/10.2991/978-94-6463-496-911>.

- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). CNN variants for computer vision: history, architecture, application, challenges and future scope. *Electronics (Switzerland)*, *10*(20), 1–28.
- Bimorogo, S. D. (2020). A comparative study of pretrained convolutional neural network model to identify plant diseases on android mobile device. *International Journal of Advanced Trends in Computer Science and Engineering*, *9*(3), 2824–2833. <https://doi.org/10.30534/ijatcse/2020/539320>
- Chen, W., Yang, B., Li, J., Wang, J., (2020). An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks. *IEEE Access* *8*, 178552–178562. <https://doi.org/10.1109/ACCESS.2020.3027794>.
- Cordonnier, J. B., Loukas, A., & Jaggi, M. (2020). On the relationship between self-attention and convolutional layers. *8th International Conference on Learning Representations, ICLR 2020*.
- Dai, Y., Li, C., Su, X., Liu, H., & Li, J. (2023). Multi-scale depthwise separable convolution for semantic segmentation in street–road scenes. *Remote Sensing*, *15*(10), 1–18.
- Deepa, V., Kumar, C.S., Cherian, T., (2021). Ensemble of multi-stage deep convolutional neural networks for automated grading of diabetic retinopathy using image patches. *Journal of King Saud University – Computer and Information Sciences* *34*(8), 1–11.
- Desiani, A., Adrezo, M., Marselina, N. C., Arhami, M., Salsabila, A., & Al-Filambany, M. G. (2022). A Combination of image enhancement and u-net architecture for segmentation in identifying brain tumors on CT-SCAN images. *2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 423–428.
- Desiani, A., Lestari, A. A., Al-Ariq, M., Amran, A., & Andriani, Y. (2022). Comparison of support vector machine and k-nearest neighbors in breast cancer classification. *Pattimura International Journal of Mathematics (PIJMath)*, *1*(1), 33–42. <https://doi.org/10.30598/pijmathvol1iss1pp33-42>
- Dishar, H. K., and Muhammed, L. A. (2023). Detection brain tumor disease using a combination of xception and nasnetmobile. *International Journal of Advances in Soft Computing & Its Applications*, *15*(3), 330.
- El-Dalahmeh, M., Al-Greer, M., El-Dalahmeh, M., & Short, M. (2020). Time-frequency image analysis and transfer learning for capacity prediction of lithium-ion batteries. *Energies*, *13*(20), 5447.
- Erdem, D., Beke, A., Kumbasar, T., (2020). A deep learning-based pipeline for

- teaching control theory: *Transforming Feedback Control Systems on Whiteboard Into MATLAB*. *IEEE Access*, 8, 84631–84641. <https://doi.org/10.1109/ACCESS.2020.2992614>.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library*, 172(1). https://doi.org/10.1007/978-3-030-32644-9_36
- Haq, D. Z., & Fatichah, C. (2023). Ultrasound image synthetic generating using deep convolution generative adversarial network for breast cancer identification. *IPTEK The Journal for Technology and Science*, 34(1), 12-25.
- Hattiya, T., Dittakan, K., & Musikasuwan, S. (2021). Diabetic retinopathy detection using convolutional neural network: a comparative study on different architectures. *Maharakham International Journal Of Engineering Technology*, 70(1), 7-13.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. 54
- Hossain, A. B. M. A., Nisha, J. K., & Johora, F. (2023). Breast cancer classification from ultrasound images using vgg16 model based transfer learning. *International Journal of Image, Graphics and Signal Processing*, 15(1), 12–22.
- Jabbar, M. A. (2021). Breast cancer data classification using ensemble machine learning. *Engineering & Applied Science Research*, 48(1).
- Jabeen, K., Khan, M. A., Alhaisoni, M., Tariq, U., Zhang, Y. D., Hamza, A., Mickus, A., & Damaševičius, R. (2022). Breast cancer classification from ultrasound images using probability - based optimal deep learning feature fusion. *Sensors*, 22(3).
- Jadon, S. (2020). A survey of loss functions for semantic segmentation. *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*.
- Jawad, M. A., & Khursheed, F. (2022). Deep and dense convolutional neural network for multi category classification of magnification specific and magnification independent breast cancer histopathological images. *Biomedical Signal Processing and Control*, 78, 103935.
- Jinsakul, N., Tsai, C. F., Tsai, C. E., & Wu, P. (2019). Enhancement of deep learning in image classification performance using xception with the swish activation function for colorectal polyp preliminary screening. *Mathematics*, 7(12). <https://doi.org/10.3390/MATH7121170>

- Jiang, Z. P., Liu, Y. Y., Shao, Z. E., & Huang, K. W. (2021). An improved VGG16 model for pneumonia image classification. *Applied Sciences (Switzerland)*, *11*(23).
- Kalita, M., Mahanta, L. B., Das, A. K., & Nath, M. (2024). A new deep learning model with interface for fine needle aspiration cytology image-based breast cancer detection. *Indonesian Journal of Electrical Engineering and Computer Science*, *34*(3), 1739–1752.
- Kayalibay, B., Jensen, G., & van der Smagt, P. (2017). *CNN-based Segmentation of Medical Imaging Data*.
- Kesuma, L.I., Ermatita, Erwin, (2023). ELREI: ensemble learning of resnet, efficientnet, and inception-v3 for lung disease classification based on chest x-ray image. *Journal of Intelligent Engineering and System*. *16*, 149–161.
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, *53*(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Khan, S. I., Shahrior, A., Karim, R., Hasan, M., & Rahman, A. (2022). MultiNet: a deep neural network approach for detecting breast cancer through multi-scale feature fusion. *Journal of King Saud University - Computer and Information Sciences*, *34*(8), 6217–6228.
- Khan, Z., Khan, F., Khan, A., Ur Rehman, Z., Shah, S., Qummar, S., Ali, F., Pack, S., (2021). Diabetic retinopathy detection using VGG a deep learning architecture. *IEEE Access*, 1-10. <https://doi.org/10.1109/ACCESS.2021.3074422>.
- Khan, Z. Y., and Niu, Z. (2021). CNN with depthwise separable convolutions and combined kernels for rating prediction. *Expert Systems with Applications*, *170*, 114528.
- Kumaresan, S., Aultrin, K.S.J., Kumar, S.S., Anand, M.D., (2023). Deep learning-based weld defect classification using VGG16 transfer learning adaptive fine-tuning. *International Journal on Interactive Design and Manufacturing*. <https://doi.org/10.1007/s12008-023-01327-3>.
- Liu, X., Ono, K., & Bise, R. (2024). A data augmentation approach that ensures the reliability of foregrounds in medical image segmentation. *Image and Vision Computing*, *147*, 105056.
- Luo, X., Wen, W., Wang, J., Xu, S., Gao, Y., Huang, J., (2022). Health classification of Meibomian gland images using keratography 5M based on AlexNet model. *Computer Methods Programs Biomedicine*. *219*, 106742.
- Luque, A., Carrasco, A., Martín, A., & de las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary

- confusion matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Mahajan, P., Uddin, S., Hajati, F., & Moni, M. A. (2023). Ensemble learning for disease prediction: A review. *Healthcare*, 11(12), 1808.
- Mogan, J. N., Lee, C. P., Lim, K. M., & Muthu, K. S. (2022). VGG16-MLP: gait recognition with fine-tuned vgg-16 and multilayer perceptron. *Applied Sciences*, 12(15), 2-12. <https://doi.org/10.3390/app12157639>.
- Mohamed, A., Amer, E., Noor Eldin, sara, khaled, jana, Hossam, M., Elmasry, N., & Adnan, G. T. (2022). The impact of data processing and ensemble on breast cancer detection using deep learning. *Journal of Computing and Communication*, 1(1), 27–37. <https://doi.org/10.21608/jocc.2022.218453>
- Moon, W. K., Lee, Y. W., Ke, H. H., Lee, S. H., Huang, C. S., & Chang, R. F. (2020). Computer-aided diagnosis of breast ultrasound images using ensemble learning from convolutional neural networks. *Computer Methods and Programs in Biomedicine*, 190. <https://doi.org/10.1016/j.cmpb.2020.105361>
- Nawaz, W., Ahmed, S., Tahir, A., & Khan, H. A. (2018). Classification of breast cancer histology images using alexnet. *Image Analysis and Recognition: 15th International Conference, ICIAR 2018, Póvoa de Varzim, Portugal, June 27-29, 2018, Proceedings 15*, 869–876.
- Oltu, B., Akşahin, M. F., & Kibaroğlu, S. (2021). A novel electroencephalography based approach for Alzheimer's disease and mild cognitive impairment detection. *Biomedical Signal Processing and Control*, 63, 102223. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.102223>
- Osamor, V. C., & Okezie, A. F. (2021). Enhancing the weighted voting ensemble algorithm for tuberculosis predictive diagnosis. *Scientific Reports*, 11(1), 1–11. <https://doi.org/10.1038/s41598-021-94347-6>.
- Patil, A., and Rane, M. (2021). *Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition*, 21–30.
- Pesapane, F., Gnocchi, G., Quarrella, C., Sorce, A., Nicosia, L., Mariano, L., Bozzini, A. C., Marinucci, I., Priolo, F., Abbate, F., & others. (2024). Errors in radiology: a standard review. *Journal of Clinical Medicine*, 13(15), 4306.
- Purnomo, A., & Tjandrasa, H. (2021). Improved deep learning architecture with batch normalization for eeg signal processing. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 19(1), 19.
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *IEEE Access*, 7, 150530–150539. <https://doi.org/10.1109/ACCESS.2019.2947484>

- Rahimzadeh, M., and Attar, A. (2020). A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*, 19, 100360. <https://doi.org/10.1016/j.imu.2020.100360>
- Ravikiran, H.K., Jayanth, J., Vaz, W.J., Sathisha, M.S., Prashantha, S.J., Madhu, K.M., (2022). Hybrid VGG16-Xception model vs single architecture transfer learning for flower image classification. *International Journal of Horticultural Science and Technology*. 12, 323–342.
- Sharma, S., Kumar, S., 2022. The Xception model: A potential feature extractor in breast cancer histology images classification. *ICT Express* 8, 101–108. <https://doi.org/10.1016/j.icte.2021.11.010>
- Singh, I., Goyal, G., & Chandel, A. (2022). AlexNet architecture based convolutional neural network for toxic comments classification. *Journal of University - Computer and Information Sciences*, 34(9), 7547–7558.
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep learning models for retinal blood vessels segmentation: a review. *IEEE Access*, 7, 71696–71717.
- Swapna, M., Sharma, D. Y. K., & Prasad, D. B. (2020). CNN architectures: Alex Net, Le Net, VGG, Google Net, Res Net. *International Journal of Recent Technology and Engineering (IJRTE)*, 8(6), 953–959.
- Tang, W., Sun, J., Wang, S., & Zhang, Y. (2023). Review of alexnet for medical image classification. *EAI Endorsed Transactions on E-Learning*, 9. <https://doi.org/10.4108/eetel.4389>
- Wang, W., Li, Y., Yan, X., Xiao, M., & Gao, M. (2024). Breast cancer image classification method based on deep transfer learning. *Proceedings of the International Conference on Image Processing, Machine Learning and Pattern Recognition*, 190–197.
- Wijaya, B.A., Hulu, M., Resel, R., Halawa, N., Tarigan, A.A., 2024. Classification of breast cancer with transfer learning on convolutional neural network models. *Sinkron* 8, 1715–1723. <https://doi.org/10.33395/sinkron.v8i3.13792>
- Yin, R., Luo, Z., Zhuang, P., Lin, Z., & Kwoh, C. K. (2021). VirPreNet: A weighted ensemble convolutional neural network for the virulence prediction of influenza a virus using all eight segments. *Bioinformatics*, 37(6), 737–743. <https://doi.org/10.1093/bioinformatics/btaa901>
- Zhang, P., Lo, E., Lu, B., 2020. High performance depthwise and pointwise convolutions on mobile devices. *AAAI 2020 - 34th AAAI Conf. Artif. Intell.* 6795–6802. <https://doi.org/10.1609/aaai.v34i04.6159>
- Zerouaoui, H., Alaoui, O. El, & Idri, A. (2024). New design strategies of deep

heterogenous convolutional neural networks ensembles for breast cancer diagnosis. *Multimedia Tools and Applications*, 1–32.