

**ENSEMBLE LEARNING MENGGUNAKAN WEIGHTED
VOTING DENGAN PEMBELAJARAN PYRAMIDNET PADA
HASIL INCEPTIONV3, MOBILENETV2, DAN VISION
TRANSFORMER DALAM KLASIFIKASI CITRA KANKER
PAYUDARA**

SKRIPSI

Sebagai Salah Satu Syarat untuk Memperoleh Gelar

Sarjana Matematika

Oleh :

**ALDA AMALIA MORTARA
NIM. 08011282126069**



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

2025

LEMBAR PENGESAHAN

**ENSEMBLE LEARNING MENGGUNAKAN WEIGHTED VOTING
DENGAN PEMBELAJARAN PYRAMIDNET PADA HASIL
INCEPTIONV3, MOBILENETV2, DAN VISION TRANSFORMER DALAM
KLASIFIKASI CITRA KANKER PAYUDARA**

SKRIPSI

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

Oleh

**ALDA AMALIA MORTARA
NIM 08011282126069**

Pembimbing Kedua



**Dr. Ir. Herlina Hanum, S.Si., M.Si.
NIP. 196501081990032007**

**Indralaya, 17 Maret 2025
Pembimbing Utama**



**Dr. Anita Desiani, S.Si., M.Kom.
NIP. 197712112003122002**

**Mengetahui,
Ketua Jurusan Matematika**



**Dr. Dian Cahyawati Sukanda, S.Si., M.Si.
NIP. 197303212001122001**

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Alda Amalia Mortara
NIM : 08011282126069
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, 17 Maret 2025

Penulis



A handwritten signature in black ink is placed over a yellow 10000 Indonesian Rupiah postage stamp. The stamp features the text 'REPUBLIK INDONESIA' at the top, '10000' in large numbers, 'METERAI TEMPEL' in the center, and a serial number '9653EAMX130373348' at the bottom. The signature is written in cursive script and is positioned to the right of the stamp.

Alda Amalia Mortara
NIM. 08011282126069

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Kedua orang tuaku tersayang,

Saudara-saudaraku,

Keluarga besarku,

Semua dosenku,

Semua guruku,

Sahabat-sahabatku,

Almamaterku

Motto

"Maka sesungguhnya sesudah kesulitan ada kemudahan. Sesungguhnya sesudah

kesulitan ada kemudahan"

(QS. Al-Insyirah:5-6)

KATA PENGANTAR

Puji syukur kehadirat Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “*Ensemble Learning menggunakan Weighted Voting* dengan Pembelajaran *PyramidNet* pada Hasil *InceptionV3*, *MobileNetV2*, dan *Vision Transformer* dalam Klasifikasi Citra 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 **Mulyadi** dan Ibuku **Roswana** 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. 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.

2. Ibu **Dr. Anita Desiani, S.Si., M.Kom.** selaku 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.
3. Ibu **Dr.Yuli Andriani,S.Si.,M.Si.** selaku dosen pembahas pertama dan Bapak **Drs.Endro Setyo Cahyono, M.Si.** selaku dosen pembahas kedua yang telah memberikan tanggapan, kritik, serta saran yang bermanfaat untuk perbaikan dan penyelesaian skripsi ini. Ibu **Dr.Eka Susanti, S.Si., M.Sc.** selaku dosen pembimbing akademik yang telah membimbing dan mengarahkan urusan akademik penulis.
4. **Seluruh Dosen Jurusan Matematika** FMIPA 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. **Seluruh guru** yang telah memberikan ilmu yang bermanfaat hingga mengantarkan penulis pada pendidikan ini.
6. Kakakku **Ahmad Aldri Mortara**, Adikku **Ahmad Allif Mortara**, serta keluarga besar yang selalu mendoakan dan mendukung penulis dengan tulus.
7. **Kakak-kakak tingkat angkatan 2018, 2019, dan 2020** bidang minat **komputasi** yang telah berbagi ilmu, memberikan bimbingan, serta membantu penulis selama perkuliahan dan penyusunan skripsi.

8. **Tim komputasi 2021, Keluarga Matematika 2021, Asisten Laboratorium Komputasi Matematika, adik-adik tingkat 2022 dan 2023** bidang minat **komputasi**, serta rekan-rekan perlombaan selama perkuliahan. Terima kasih sudah menjadi orang-orang baik di sekeliling penulis yang selalu mendukung, membantu dengan tulus, dan memberikan energi positif.
9. **Laboratorium Komputasi FMIPA Universitas Sriwijaya** yang telah menjadi tempat ternyaman bagi penulis untuk berdiskusi, belajar, dan menyelesaikan skripsi bersama teman-teman seperjuangan.
10. Sahabat seperjuangan penulis **Mitta Permatasari, Suristhia Rahmadita, Niken Ayuputri, Dena Luthfia H, Alya Dwi S, Azizah, Raisyah Salsabilla R**, dan **DG(Saber, Sabci, Memey)**. Terima kasih atas setiap bantuan, dukungan, kerja sama, dan semangat yang kalian berikan.
11. 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 USING WEIGHTED VOTING WITH
PYRAMIDNET ON INCEPTIONV3, MOBILENETV2, AND VISION
TRANSFORMER RESULT IN BREAST CANCER IMAGE
CLASSIFICATION**

**Alda Amalia Mortara
NIM: 08011282126069**

ABSTRACT

Breast cancer is one of the leading causes of death in women. Early detection can be done by classifying ultrasound images (USG) of breast cancer into 3 levels of severity namely normal, benign, and malignant using Deep Learning (DL). DL methods include Convolutional Neural Network (CNN) and transformers. CNN architecture development includes InceptionV3 and MobileNetV2. InceptionV3 recognizes image patterns with various scales using factorized convolutions, but requires large memory and long computation time. MobileNetV2 is more efficient in memory and computation time. However, the bottleneck layer may cause the loss of some important details. CNN uses convolution operations with kernel and stride sizes, so it is limited in capturing global relationships. The transformer method used is Vision Transformer (ViT). ViT captures global relationships by dividing the image into small patches, which are then processed in parallel using self-attention. However, ViT gives higher weight to frequently occurring patterns, making it less optimal for unbalanced data. The weakness of a single architecture can be overcome with ensemble learning. This study applies ensemble learning using weighted voting through PyramidNet. PyramidNet helps the model learn the weights on each data and avoid excessive training. The average ensemble learning performance results obtained 93% accuracy indicating almost completely correct class predictions. Sensitivity 93% shows the model is excellent at classifying data of a certain class. Specificity 93% shows the model is excellent at classifying data that is not a certain class. F1-score of 93% shows the model is balanced in distinguishing each class. Cohen's Kappa of 89% indicates high agreement with the true class. This method improved the performance over a single classifier, with accuracy increasing by 14%, sensitivity of 16.66%, F1-score of 17.33%, and Cohen's Kappa of 24.33%. The class performance exceeded 90% across all evaluation metrics. However, the Cohen's Kappa for each class remained below 90%. The model best predicted the normal class, followed by the malignant, and benign classes. The results prove that the proposed ensemble learning method is effective in the classification of breast cancer ultrasound images.

Keywords: InceptionV3, MobileNetV2, ViT, Ensemble Learning, Weighted Voting.

***ENSEMBLE LEARNING MENGGUNAKAN WEIGHTED VOTING
DENGAN PEMBELAJARAN PYRAMIDNET PADA HASIL
INCEPTIONV3, MOBILENETV2, DAN VISION TRANSFORMER DALAM
KLASIFIKASI CITRA KANKER PAYUDARA***

**Alda Amalia Mortara
NIM: 08011282126069**

ABSTRAK

Kanker payudara merupakan penyebab utama kematian pada wanita. Deteksi dini dapat dilakukan dengan mengklasifikasikan citra *ultrasound* (USG) kanker payudara menjadi 3 tingkat keparahan yaitu normal, *benign*, dan *malignant* menggunakan *Deep Learning* (DL). Metode DL diantaranya *Convolutional Neural Network* (CNN) dan *transformer*. Pengembangan arsitektur CNN diantaranya *InceptionV3* dan *MobileNetV2*. *InceptionV3* mengenali pola citra dengan berbagai skala menggunakan *factorized convolutions*, tetapi membutuhkan memori besar dan waktu komputasi lama. *MobileNetV2* lebih efisien dalam memori dan waktu komputasi. Namun, *bottleneck layer* pada *MobileNetV2* dapat menyebabkan hilangnya beberapa detail citra. CNN menggunakan operasi konvolusi dengan ukuran kernel dan *stride*, sehingga terbatas dalam menangkap hubungan global. Metode *transformer* yang digunakan adalah *Vision Transformer* (*ViT*). *ViT* menangkap hubungan global dengan membagi citra menjadi *patch* kecil, lalu diolah secara paralel menggunakan *self-attention*. Namun, *ViT* memberikan bobot lebih tinggi pada pola yang sering muncul, sehingga kurang optimal untuk data yang tidak seimbang. Kelemahan arsitektur tunggal dapat diatasi dengan *ensemble learning*. Penelitian ini menerapkan *ensemble learning* menggunakan *weighted voting* melalui pembelajaran *PyramidNet*. *PyramidNet* membantu model mempelajari bobot pada setiap data dan menghindari pelatihan yang berlebihan. Hasil rata-rata kinerja *ensemble learning* diperoleh akurasi 93% menunjukkan prediksi kelas yang hampir sepenuhnya benar. Sensitivitas 93% menunjukkan model sangat baik dalam mengklasifikasikan data kelas tertentu. Spesifisitas 93% menunjukkan model sangat baik mengklasifikasikan data yang bukan kelas tertentu. F1-score 93% menunjukkan model seimbang dalam membedakan setiap kelas. *Cohen's Kappa* 89% menunjukkan kesepakatan tinggi dengan kelas sebenarnya. Hal ini memberi peningkatan pada klasifikasi tunggal dengan akurasi sebesar 16,31%, spesifisitas 14%, sensitivitas 16,66%, F1-score 17,33%, dan *Cohen's Kappa* 24,33%. Hasil per kelas sangat baik pada semua metrik evaluasi kinerja yaitu lebih dari 90%. Namun, *Cohen's Kappa* setiap kelas masih di bawah 90%. Model paling baik memprediksi kelas normal, diikuti oleh kelas *malignant*, dan *benign*. Hasil membuktikan metode *ensemble learning* yang diusulkan efektif dalam klasifikasi citra USG kanker payudara.

Kata Kunci: *InceptionV3*, *MobileNetV2*, *ViT*, *Ensemble Learning*, *Weighted Voting*

DAFTAR ISI

| | |
|---|-------------|
| HALAMAN JUDUL..... | i |
| HALAMAN PENGESAHAN..... | ii |
| HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH | iii |
| HALAMAN PERSEMBAHAN..... | iv |
| KATA PENGANTAR..... | v |
| ABSTRACT | viii |
| ABSTRAK | ix |
| DAFTAR ISI..... | x |
| DAFTAR TABEL | xii |
| DAFTAR GAMBAR | xiii |
| BAB I PENDAHULUAN..... | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Rumusan Masalah | 6 |
| 1.3 Pembatasan Masalah | 7 |
| 1.4 Tujuan..... | 7 |
| 1.5 Manfaat | 8 |
| BAB II TINJAUAN PUSTAKA..... | 9 |
| 2.1 Kanker Payudara | 9 |
| 2.2 Perbaikan Citra..... | 9 |
| 2.3 Augmentasi Citra | 10 |
| 2.4 Klasifikasi Citra | 11 |
| 2.4.1 <i>InceptionV3</i> | 11 |
| 2.4.2 <i>MobileNetV2</i> | 21 |
| 2.4.3 <i>Vision Transformer</i> | 24 |
| 2.4.4 <i>Ensemble Learning</i> | 32 |
| 2.4.5 <i>Weighted Voting</i> | 33 |
| 2.4.6 <i>PyramidNet</i> | 33 |
| 2.5 <i>Confusion Matrix</i> | 35 |
| BAB III METODOLOGI PENELITIAN | 38 |
| 3.1 Tempat..... | 38 |
| 3.2 Waktu | 38 |

| | | |
|---|---|------------|
| 3.3 | Alat..... | 38 |
| 3.4 | Tahap Penelitian | 38 |
| BAB IV PEMBAHASAN..... | | 48 |
| 4.1 | Deskripsi Data..... | 48 |
| 4.2 | Operasi Hitung Manual..... | 48 |
| 4.2.1 | Proses <i>Median Filter</i> | 49 |
| 4.2.2 | Proses <i>Contrast Stretching</i> | 50 |
| 4.2.3 | <i>InceptionV3</i> | 51 |
| 4.2.4 | <i>MobileNetV2</i> | 66 |
| 4.2.5 | <i>ViT</i> | 75 |
| 4.2.6 | <i>Ensemble Learning</i> | 92 |
| 4.2.7 | <i>PyramidNet</i> | 94 |
| 4.3 | Hasil <i>InceptionV3</i> , <i>MobileNetV2</i> , <i>ViT</i> dan <i>Ensemble Learning</i> 102 | 102 |
| 4.3.1 | <i>Training</i> | 102 |
| 4.3.2 | <i>Testing</i> | 106 |
| 4.4 | Evaluasi..... | 110 |
| 4.5 | Pembahasan..... | 111 |
| 4.6 | Analisis dan Hasil | 112 |
| BAB V KESIMPULAN DAN SARAN | | 114 |
| 5.1 | Kesimpulan | 114 |
| 5.2 | Saran..... | 115 |

DAFTAR TABEL

| | |
|--|-----|
| Tabel 2. 1 Kategori Kinerja..... | 36 |
| Tabel 4. 1 Sampel Data Citra <i>Breast Cancer</i> | 48 |
| Tabel 4. 3 Hasil Perhitungan Variansi ($\sigma j2$) untuk Setiap <i>Mini Batch</i> | 82 |
| Tabel 4. 4 <i>Confusion matrix</i> dari Proses <i>Testing</i> | 109 |
| Tabel 4. 5 Perbandingan Hasil Klasifikasi dari Setiap Model | 112 |
| Tabel 4. 6 Perbandingan Arsitektur dengan Penelitian Lain | 113 |

DAFTAR GAMBAR

| | |
|---|-----|
| Gambar 2. 1 Hasil USG Kanker Payudara..... | 9 |
| Gambar 2. 2 Hasil augmentasi | 11 |
| Gambar 2. 3 Arsitektur <i>InceptionV3</i> | 12 |
| Gambar 2. 4 Ilustrasi <i>Padding Same</i> | 12 |
| Gambar 2. 5 Ilustrasi Proses <i>Convolution Layer</i> | 13 |
| Gambar 2. 6 Ilustrasi <i>Max Pooling</i> | 16 |
| Gambar 2. 7 Ilustrasi <i>concatenate layer</i> | 17 |
| Gambar 2. 8 Ilustrasi <i>Average Pooling</i> | 18 |
| Gambar 2. 9 Arsitektur <i>MobileNetV2</i> | 22 |
| Gambar 2. 10 Ilustrasi Arsitektur <i>Vision Transformer</i> | 24 |
| Gambar 2. 11 Ilustrasi <i>Transformer Encoder</i> | 28 |
| Gambar 2. 12 Ilustrasi <i>Self Attention</i> | 29 |
| Gambar 2. 13 Ilustrasi <i>Multi-Head Attention</i> | 30 |
| Gambar 2. 14 Arsitektur <i>PyramidNet</i> | 34 |
| Gambar 4.2. Tahapan membagi matriks <i>input</i> menjadi beberapa submatriks..... | 59 |
| Gambar 4. 3 Tahapan membagi matriks <i>input</i> untuk <i>average pooling</i> | 61 |
| Gambar 4. 4 Grafik nilai akurasi pada proses <i>training</i> model <i>InceptionV3</i> | 102 |
| Gambar 4. 5 Grafik nilai akurasi pada proses <i>training</i> model <i>MobileNetV2</i> | 103 |
| Gambar 4. 6 Grafik nilai akurasi pada proses <i>training</i> model ViT | 104 |
| Gambar 4. 7 Grafik akurasi pada proses <i>training</i> model <i>ensemble learning</i> | 105 |

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kanker payudara merupakan penyakit paling umum pada wanita dan menjadi penyebab utama kematian akibat kanker pada wanita (Chen *et al.*, 2023). Kanker payudara memiliki 3 tingkat keparahan yaitu, normal, *benign* (jinak), dan *malignant* (*ganas*). Deteksi dini kanker payudara dapat dilakukan dengan pemeriksaan menggunakan alat yang menghasilkan citra *ultrasound* (USG) untuk mengevaluasi nodul payudara. Diagnosis dapat dilakukan dengan cara mengklasifikasikan citra kanker payudara menjadi 3 kelas. Namun, keakuratan mendiagnosis kanker payudara secara manual dibutuhkan keahlian khusus. Diagnosis manual oleh ahli radiologi merupakan tugas yang subjektif yang berpotensi terjadinya kesalahan akibat kondisi individu dan pengalaman (Sakinah *et al.*, 2020). Klasifikasi kanker payudara telah berkembang dengan memanfaatkan metode *Deep Learning* (DL) (Kawina *et al.*, 2024).

DL adalah metode dalam *machine learning* yang menggunakan jaringan saraf tiruan yang memiliki banyak lapisan untuk memproses data (Alzubaidi *et al.*, 2021). Metode DL yang dapat digunakan untuk klasifikasi citra diantaranya *Convolutional Neural Network* (CNN) dan *transformer*. CNN merupakan jaringan syaraf tiruan yang pada dasarnya terdapat *convolutional layer* diikuti *pooling layer* yang saling terhubung untuk melakukan ekstraksi fitur dan pengenalan objek pada citra (Singh *et al.*, 2022). CNN terus berkembang untuk meningkatkan kinerjanya. Arsitektur perkembangan dari CNN diantaranya *Inception* dan *MobileNet*.

Arsitektur *Inception* menggunakan *multi-scale convolution* yang merupakan lapisan konvolusi dengan berbagai ukuran kernel, sehingga *Inception* dapat mempelajari banyak informasi fitur (Jing *et al.*, 2023). Pada *InceptionV3* terdapat teknik *factorized convolutions* yang di mana kernel besar dibagi menjadi dua operasi konvolusi dengan ukuran kernel yang lebih kecil (Qian, 2023). *Factorized convolutions* dapat membantu model mempelajari fitur dari kombinasi filter yang lebih kecil, sehingga model menangkap informasi pola citra dengan lebih efisien (Bergman, 2019). Sirjani *et al.*, (2023) menerapkan *InceptionV3* pada klasifikasi payudara memperoleh nilai akurasi, presisi, dan sensitivitas masih di bawah 80%. Zhang *et al.*, (2021) mengimplementasikan *InceptionV3* pada klasifikasi kanker payudara menghasilkan nilai sensitivitas 83.56%. Namun, nilai akurasi dan spesifitas masih di bawah 80%. Ali *et al.*, (2023) menggunakan *InceptionV3* pada klasifikasi kanker payudara memperoleh nilai akurasi 83%, presisi 84.5%, sensitivitas dan *F1-score* 83.5%. Namun, penelitian ini hanya melakukan klasifikasi untuk dua kelas. Meskipun *InceptionV3* sangat efektif untuk mempelajari berbagai fitur, penggabungan berbagai skala citra dalam *InceptionV3* menyebabkan penggunaan memori yang lebih besar dan waktu komputasi yang lama, sehingga dibutuhkan arsitektur yang lebih efisien.

Arsitektur *MobileNet* dibangun untuk efisiensi memori dan waktu, karena menggunakan *depthwise separable convolution*(Bouraya and Belangour, 2024). *Depthwise separable convolution* adalah teknik yang membagi proses konvolusi menjadi dua langkah. Pertama, *depthwise convolution*, di mana setiap *channel* diproses secara terpisah dengan *filter* yang berbeda (Chollet, 2014). Kedua,

pointwise convolution yang menggunakan konvolusi 1×1 untuk menggabungkan hasil *depthwise convolution*. Namun, penggunaan *depthwise separable convolution* memiliki keterbatasan dalam menangkap hubungan antar *channel* karena setiap *channel* diproses secara terpisah. Hal ini dapat menyebabkan hilangnya informasi antar *channel*. *MobileNetV2* dibangun untuk mengatasi keterbatasan tersebut dengan menggunakan *bottleneck layer*. *Bottleneck layer* adalah blok arsitektur yang digunakan untuk menangkap hubungan antar *channel* secara lebih efektif (Dani & Handayani, 2024). Keshary Shah *et al.*, (2023) menerapkan *MobileNetV2* untuk klasifikasi kanker payudara namun hanya menghasilkan nilai akurasi, presisi, dan sensitivitas di bawah 85%. Alhajlah, (2024) menerapkan *MobileNetV2* pada klasifikasi kanker payudara. Namun, menghasilkan nilai akurasi dan *F1-score* masih di bawah 80%. Eroğlu *et al.*, (2021) menggunakan *MobileNetV2* pada klasifikasi kanker payudara dan mendapatkan nilai akurasi sebesar 88.05%. Namun, pada penelitian ini tidak mengukur sensitivitas, spesifisitas, dan *F1-score* pada arsitektur *MobileNetV2*. Meskipun *MobileNetV2* lebih efektif menangkap hubungan antar *channel* dibandingkan *MobileNetV1*. Namun, penggunaan *bottleneck layer* dapat menyebabkan hilangnya beberapa detail penting, terutama saat menangani data resolusi tinggi.

Meskipun CNN telah dikembangkan dengan berbagai arsitektur. CNN menggunakan lapisan konvolusi yang bergantung pada ukuran kernel dan *stride*, sehingga dapat membatasi model dalam menangkap hubungan global. Hubungan global merupakan keterkaitan antar fitur di seluruh bagian citra (Kezia, 2024). Hubungan global perlu ditangkap agar model dapat membuat keputusan yang lebih

akurat. Untuk mengatasi hal tersebut, ViT dirancang untuk menangkap hubungan global dalam citra dengan menerapkan *self attention*. Pada ViT, citra dibagi menjadi beberapa *patch* yang kemudian dijadikan vektor satu dimensi (*flattened*) dan dilanjutkan dengan *self attention*. *Self attention* adalah mekanisme yang membuat model untuk mempelajari interaksi antar *patch* secara bersamaan (Dosovitskiy *et al.*, 2021). Dengan *self attention*, ViT mampu memperhatikan hubungan setiap *patch*, sehingga dapat menangkap pola dan struktur citra secara menyeluruh. Gheflati and Rivaz, (2022) menerapkan ViT pada klasifikasi kanker payudara dengan mengklasifikasi 3 kelas dan menghasilkan nilai akurasi sebesar 86.7%. Namun, penelitian ini tidak mengukur sensitivitas dan spesifitas. Pacal, (2022) menerapkan ViT untuk mengklasifikasi kanker payudara dengan mengklasifikasi 3 kelas. Penelitian ini memperoleh nilai presisi sebesar 90%, tetapi nilai akurasi dan sensitivitas masih di bawah 90%. Wei *et al.*, (2024) mengimplementasikan ViT pada klasifikasi *kanker payudara* memperoleh nilai akurasi, presisi, dan *F1-score* 94%. Namun, pada penelitian tersebut hanya mengklasifikasi 2 kelas. Meskipun ViT dapat menangkap fitur global, ViT cenderung kesulitan dalam mengklasifikasikan kelas minoritas karena mekanisme *self-attention* cenderung memberikan bobot perhatian yang lebih tinggi pada pola-pola dominan yang sering muncul. Hal ini berdampak pada penurunan kinerja model dalam mengklasifikasikan data yang tidak seimbang (Chen *et al.*, 2022).

Ensemble learning mengatasi kelemahan masing-masing arsitektur dengan menggabungkan kekuatan masing-masing arsitektur (Desiani *et al.*, 2024). *Ensemble learning* merupakan proses penggabungan bobot kinerja masing-masing

arsitektur. Salah satu teknik *ensemble learning* adalah *weighted voting* (Osamor & Okezie, 2021). *Weighted voting* bekerja memilih suara terbanyak dari prediksi akhir yang dihasilkan oleh masing-masing metode klasifikasi. Pembobotan setiap arsitektur diterapkan untuk memberikan tingkat pengaruh yang berbeda pada prediksi masing-masing metode klasifikasi (Kesuma *et al.*, 2023).

Moon *et al.*, (2020) menerapkan *ensemble learning* dengan *weighted voting* pada hasil arsitektur *VGGNet*, *ResNet*, dan *DenseNet* untuk klasifikasi kanker payudara. Penelitian ini menghasilkan nilai akurasi 90,2%, spesifisitas 92,06%, dan *F1-score* 88,74%. Namun, penelitian ini tidak menghitung *Cohen's Kappa*. Misra *et al.*, (2022) menggunakan metode *Ensemble learning* dengan arsitektur *AlexNet* dan *ResNet* menghasilkan nilai akurasi 90%, sensitivitas 88,89%, spesifisitas 91,1%, dan *F1-score* 89,79%. Namun, penelitian ini hanya mengklasifikasikan citra ke dalam dua kelas, yaitu *benign* dan *malignant*. Penelitian sebelumnya banyak yang menggabungkan hasil akhir klasifikasi tunggal untuk digunakan pada tahap *testing*. Penggunaan *ensemble* pada *testing* tidak menjamin bahwa bobot yang diperoleh akan optimal dan tidak *overfitting* (Kesuma *et al.*, 2023). Ketika bobot yang dihasilkan mengalami *overfitting*, artinya bobot tersebut tidak mampu mengenali pola data baru yang belum pernah dipelajari oleh model (Dogan and Birant, 2019). Untuk memastikan bahwa bobot yang dihasilkan melalui *ensemble* adalah bobot yang terbaik, dibutuhkan model pembelajaran yang dapat menjamin bahwa bobot tersebut optimal dan terhindar dari *overfitting*. *PyramidNet* dapat digunakan sebagai solusi dalam mempelajari bobot karena menggunakan *linear channel growth*. Dalam mekanisme ini, jumlah *channel* meningkat secara bertahap

di setiap *layer*, berbeda dengan CNN konvensional yang meningkatkan jumlah *channel* secara diskrit. Pertambahan *channel* yang lebih halus dapat membantu model menangkap fitur dengan lebih stabil dan mencegah *overfitting* (Han *et al.*, 2017). Liu *et al.*, (2018) menerapkan *PyramidNet* untuk klasifikasi dataset WHOI-*Plankton* dan *Caltech* menghasilkan 83,405%. Namun, hasil rata-rata *F1-score* masih 51,48%. Surya *et al.*, (2024) menerapkan *PyramidNet* pada klasifikasi pada citra medis seperti *X-Rays*, MRIs, and *histopathological slide* dan menghasilkan akurasi 92,5%, presisi 91,3%, *recall* 93,8% dan *F1-score* 92,5%. Namun, pada penelitian tersebut belum menghitung *Cohen's Kappa*.

Penelitian ini mengusulkan metode *ensemble* yang menggabungkan hasil *InceptionV3*, *MobileNetV2*, dan ViT menggunakan teknik *weighted voting* dengan pembelajaran *PyramidNet*. Metode *ensemble learning* akan diterapkan pada tahap *training*. Pembelajaran *PyramidNet* digunakan untuk membantu model mempelajari pola bobot pada setiap data dan menghindari pelatihan yang berlebihan dalam klasifikasi kanker payudara. Penelitian ini mengklasifikasi tingkat keparahan kanker payudara dengan 3 kelas yaitu, normal, *benign*, dan *malignant*. Hasil evaluasi kinerja arsitektur dapat diukur berdasarkan akurasi, sensitivitas, spesifisitas, *F1-score*, dan *Cohen's Kappa*.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini adalah sebagai berikut:

1. Bagaimana kinerja arsitektur *InceptionV3*, *MobileNetV2*, dan ViT dalam klasifikasi citra kanker payudara berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan *Cohen's Kappa*.

2. Bagaimana kinerja metode *ensemble learning* pada hasil arsitektur *InceptionV3*, *MobileNetV2*, dan ViT menggunakan teknik *weighted voting* dengan pembelajaran *PyramidNet* dalam klasifikasi kanker payudara berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan *Cohen's Kappa*.

1.3 Pembatasan Masalah

Beberapa pembatasan masalah dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini mengklasifikasikan kanker payudara dari dataset citra USG dan menggunakan tiga kelas yaitu normal, *benign*, dan *malignant*.
2. Ukuran evaluasi kinerja pada model klasifikasi kanker payudara penelitian ini adalah nilai akurasi, sensitivitas, spesifisitas, *F1-score*, dan *Cohen's Kappa*.

1.4 Tujuan

Tujuan dari penelitian ini adalah sebagai berikut:

1. Untuk mengetahui kinerja dari arsitektur *InceptionV3*, *MobileNetV2*, dan ViT pada klasifikasi citra kanker payudara berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan *Cohen's Kappa*.
2. Untuk mengetahui kinerja dari metode *ensemble learning* menggunakan teknik *weighted voting* dengan pembelajaran *PyramidNet* pada hasil arsitektur *InceptionV3*, *MobileNetV2*, dan ViT pada klasifikasi kanker payudara berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan *Cohen's Kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut:

1. Memperoleh model yang dapat mengklasifikasikan kanker payudara pada citra USG dengan menerapkan metode *ensemble learning* menggunakan teknik *weighted voting* dengan pembelajaran *PyramidNet* pada *InceptionV3*, *MobileNetV2*, dan ViT.
2. Dapat digunakan sebagai referensi model yang digunakan untuk penelitian lainnya, khususnya dalam klasifikasi kanker payudara pada citra USG dan pengembangan *DL*.

DAFTAR PUSTAKA

- Alhajlah, M. (2024). A hybrid features fusion-based framework for classification of breast micronodules using ultrasonography. *BMC Medical Imaging*, 24(1), 1–9. <https://doi.org/10.1186/s12880-024-01425-y>
- Ali, A. M., Benjdira, B., Koubaa, A., El-Shafai, W., Khan, Z., & Boulila, W. (2023). Vision Transformers in image restoration: a survey. *Sensors*, 23(5), 1–32. <https://doi.org/10.3390/s23052385>
- Ali, M. D., Saleem, A., Elahi, H., Khan, M. A., Khan, M. I., Yaqoob, M. M., Farooq Khattak, U., & Al-Rasheed, A. (2023). Breast cancer classification through meta-learning ensemble technique using Convolution Neural Networks. *Diagnostics*, 13(13), 1–19. <https://doi.org/10.3390/diagnostics13132242>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Bagchi, S., & Bathula, D. R. (2022). EEG-ConvTransformer for single-trial EEG-based visual stimulus classification. *Pattern Recognition*, 129, 108757. <https://doi.org/https://doi.org/10.1016/j.patcog.2022.108757>
- Bergman, A. (2019). Factorized Convolution kernels for image processing. In *Stanford EE367*. <https://www.semanticscholar.org/paper/Factorized-Convolution-Kernels-in-Image-Processing-Bergman-Lindell/fc0542127c7bbcd81e4542f93eaeb160cbcd46c#citing-papers>
- Bouraya, S., & Belangour, A. (2024). Evaluating the real-world application efficacy of MobileNet models. *International Journal of Engineering Trends and Technology*, 72(9), 197–202. <https://doi.org/10.14445/22315381/IJETT-V72I9P116>
- Chen, S.-H., Wu, Y.-L., Pan, C.-Y., Lian, L.-Y., & Su, Q.-C. (2023). Breast ultrasound image classification and physiological assessment based on GoogLeNet. *Journal of Radiation Research and Applied Sciences*, 16(3), 1–8. <https://doi.org/10.1016/j.jrras.2023.100628>
- Chen, Y., Gu, X., Liu, Z., & Liang, J. (2022). The Matthews Correlation Coefficient (MCC) is more informative than cohen's kappa and brier score in binary classification assessment. *Remote Sensing*, 14(8), 1–20. <https://doi.org/10.3390/rs14081877>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The Matthews Correlation

- Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment. *IEEE Access*, 9(1), 78368–78381. <https://doi.org/10.1109/ACCESS.2021.3084050>
- Chollet, F. (2014). Xception: deep learning with Depthwise Separable Convolutions. *SAE International Journal of Materials and Manufacturing*, 7(3), 560–566. <https://doi.org/10.4271/2014-01-0975>
- Da Costa, R. F., Hayashi Yelisetty, S. M., Marques, J. C., & Tasinaffo, P. M. (2019). A brief didactic theoretical review on Convolutional Neural Networks, deep belief networks and stacked auto-encoders. *International Journal of Engineering and Technical Research (IJETR)*, 9(12). <https://doi.org/10.31873/ijetr.9.12.35>
- Dani, A. R., & Handayani, I. (2024). Klasifikasi motif batik Yogyakarta menggunakan metode GLCM dan CNN. *Jurnal Teknologi Terpadu*, 10(2), 142–156. <https://doi.org/https://doi.org/10.54914/jtt.v10i2.1451>
- Desiani, A, Adrezo, M., Marselina, N. C., et al. (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. <https://doi.org/10.1109/ICIMCIS56303.2022.10017519>
- Desiani, Anita, Primartha, R., Hanum, H., et al. (2024). Weighted Voting Ensemble Learning of CNN Architectures for Diabetic Retinopathy Classification. *Jurnal Infotel*, 16(1), 136–155. <https://doi.org/10.20895/infotel.v16i1.999>
- Dogan, A., & Birant, D. (2019). A weighted majority voting ensemble approach for classification. *UBMK 2019 - Proceedings, 4th International Conference on Computer Science and Engineering*, 366–371. <https://doi.org/10.1109/UBMK.2019.8907028>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., & Al, E. (2021). An image is worth 16X16 words: Transformers for image recognition at scale. *International Conference on Learning Representations*, 1–22. <https://doi.org/https://doi.org/10.48550/arXiv.2010.11929>
- Eroğlu, Y., Yıldırım, M., & Çınar, A. (2021). Convolutional Neural Networks based classification of breast ultrasonography images by hybrid method with respect to benign, malignant, and normal using mRMR. *Computers in Biology and Medicine*, 133(4), 104–407. <https://doi.org/10.1016/j.compbiomed.2021.104407>
- Fan, H., Xiong, B., Mangalam, K., et al. (2021). Multiscale Vision Transformers. *Proceedings of the IEEE International Conference on Computer Vision*, 6804–6815. <https://doi.org/10.1109/ICCV48922.2021.00675>

- Gheflati, B., & Rivaz, H. (2022). Vision Transformers for classification of breast ultrasound images. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2022*, 480–483. <https://doi.org/10.1109/EMBC48229.2022.9871809>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). *Fundamental concepts of Convolutional Neural Network* (V. E. Balas, R. Kumar, & R. Srivastava (eds.)). Springer International Publishing. https://doi.org/10.1007/978-3-030-32644-9_36
- Han, D., Kim, J., & Kim, J. (2017). Deep pyramidal residual networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9. <https://doi.org/10.1109/CVPR.2017.668>
- He, K., Zhang, X., Ren, S., & Sun, J. (2006). Deep residual learning for image recognition. In *Proc. of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR2016)*, 770–778. <https://doi.org/10.1109/cvpr.2006.130>
- Hendrycks, D., & Gimpel, K. (2023). *Gaussian Error Linear Units (GELUs)*. 1–10. <https://doi.org/10.48550/arXiv.1606.08415>
- Islam, M. R., Rahman, M. M., Ali, M. S., et al. (2024). Enhancing breast cancer segmentation and classification: an ensemble Deep Convolutional Neural Network and U-net approach on ultrasound images. *Machine Learning with Applications*, 16(1), 1–12. <https://doi.org/10.1016/j.mlwa.2024.100555>
- Jadon, S. (2020). A survey of loss functions for semantic segmentation. *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*. <https://doi.org/10.1109/CIBCB48159.2020.9277638>
- Jing, Y., Li, C., Du, T., et al. (2023). A comprehensive survey of intestine histopathological image analysis using machine vision approaches. *Computers in Biology and Medicine*, 165, 107388. <https://doi.org/10.1016/j.combiomed.2023.107388>
- Kandel, I., & Castelli, M. (2020). Transfer Learning with Convolutional Neural Networks for diabetic retinopathy image classification. *Applied Sciences*, 10(6), 1–24. <https://doi.org/10.3390/app10062021>
- Kawina, I., Amarendra, K., & Marapelli, B. (2024). Deep learning and machine learning approach to breast cancer classification with random search hyperparameter tuning. *International Journal of Intelligent Systems and Applications in Engineering*, 12(16), 264–275.
- Keshary Shah, A., Kabore, J., Tarun Sasikumar, S., & Surya, A. (2023). Enhanced

- breast cancer tumor classification using MobileNetV2: a detailed exploration on image intensity, error mitigation, and streamlit-driven Real-time deployment. *Butler Journal of Undergraduate Research*, 10(1), 1–13.
- 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. *International Journal of Intelligent Engineering and Systems*, 16(5), 149–161. <https://doi.org/10.22266/ijies2023.1031.14>
- Kezia. (2024). *Pengenalan karakter tulisan tangan hangeul menggunakan algoritma hybrid Vision Transformer (ViTs) dan Convolutional Neural Network (CNN)* [Universitas Pembangunan Nasional Veteran Jawa Timur]. <https://repository.upnjatim.ac.id/id/eprint/29197>
- Khan, A., Rauf, Z., Sohail, A., et al. (2023). A survey of the Vision Transformers and its CNN-Transformer based variants. *Artificial Intelligence Review*, 56(3), 2917–2970. <https://doi.org/10.1007/s10462-023-10595-0>
- Khan, A., Sohail, A., Zahoor, 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>
- Li, Qiaoliang, Xu, Y., Chen, Z., Liu, D., et al. (2018). Tumor segmentation in contrast-enhanced magnetic resonance imaging for nasopharyngeal carcinoma: deep learning with Convolutional Neural Network. *BioMed Research International*, 2018, 1–8. <https://doi.org/10.1155/2018/9128527>
- Li, Qing, Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical image classification with Convolutional Neural Network. *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014, 2014, 2014, 844–848*. <https://doi.org/10.1109/ICARCV.2014.7064414>
- Liu, J., Du, A., Wang, C., Zheng, H., Wang, N., & Zheng, B. (2018). Teaching Squeeze-and-Excitation PyramidNet for imbalanced image classification with GAN-based curriculum learning. *Proceedings - International Conference on Pattern Recognition, 2018-Augus, 2444–2449*. <https://doi.org/10.1109/ICPR.2018.8546037>
- Lukong, K. E. (2017). Understanding breast cancer – the long and winding road. *BBA Clinical*, 7, 64–77. <https://doi.org/10.1016/j.bbaci.2017.01.001>
- Maslej-Krešňáková, V., El Bouchefry, K., & Butka, P. (2021). Morphological classification of compact and extended radio galaxies using Convolutional Neural Networks and data augmentation techniques. *Monthly Notices of the Royal Astronomical Society*, 505(1), 1464–1475. <https://doi.org/10.1093/mnras/stab1400>

- Misra, S., Jeon, S., Managuli, R., et al. (2022). Bi-Modal Transfer Learning for Classifying Breast Cancers via Combined B-Mode and Ultrasound Strain Imaging. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 69(1), 222–232. <https://doi.org/10.1109/TUFFC.2021.3119251>
- 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, 1–12. <https://doi.org/10.1016/j.cmpb.2020.105361>
- 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), 1–12. <https://doi.org/10.1038/s41598-021-94347-6>
- Pacal, I. (2022). Deep learning approaches for classification of breast cancer in Ultrasound (US) Images. *Journal of the Institute of Science and Technology*, 12(4), 1917–1927. <https://doi.org/10.21597/jist.1183679>
- Qian, Y. (2023). Performance comparison among VGG16, InceptionV3, and ResNet on galaxy morphology classification. *Journal of Physics: Conference Series*, 2580(1), 1–7. <https://doi.org/10.1088/1742-6596/2580/1/012009>
- Setio, P. B. N., Saputro, D. R. S., & Bowo Winarno. (2020). Klasifikasi dengan pohon keputusan berbasis algoritme C4.5. *PRISMA, Prosiding Seminar Nasional Matematika*, 3, 64–71. <https://doi.org/https://journal.unnes.ac.id/sju/index.php/prisma/>
- Singh, K., Singh, D., & Mishra, N. (2022). Review: Convolutional Neural Networks and its architecture. *International Journal of Health Sciences*, 6(S1), 9183–9190. <https://sciencescholar.us/journal/index.php/ijhs/article/view/7074>
- Sirjani, N., Ghelich Oghli, M., Kazem Tarzamni, M., et al. (2023). A novel deep learning model for breast lesion classification using ultrasound images: a multicenter data evaluation. *Physica Medica*, 107, 1–9. <https://doi.org/10.1016/j.ejmp.2023.102560>
- Sivarajah, R. T., Brown, K., & Chetlen, A. (2020). “I can see clearly now.” fundamentals of breast ultrasound optimization. *Clinical Imaging*, 64, 124–135. <https://doi.org/10.1016/j.clinimag.2020.03.012>
- Soomro, T. A., Afifi, A. J., Zheng, L., et al. (2019). Deep learning models for retinal

- blood vessels segmentation: a review. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Surya, B., Venkatesh, B., S Vijayalakshmi, Narayanan, A. H., & Syed, R. (2024). PyramidNet for automated medical image classification. *International Research Journal of Medicine and Surgery*, 1(2), 1–8. <https://doi.org/10.47857/irjmeds.2024.v01i02.007>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception architecture for computer vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016, 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>
- Tragoudaras, A., Stoikos, P., Fanaras, K., et al. (2022). Design space exploration of a sparse MobileNetV2 using high-level synthesis and sparse matrix techniques on FPGAs. *Sensors*, 22(12), 1–16. <https://doi.org/10.3390/s22124318>
- Tummala, S., Kadry, S., Bukhari, S. A. C., & Rauf, H. T. (2022). Classification of brain tumor from magnetic resonance imaging using Vision Transformers Ensembling. *Current Oncology*, 29(10), 7498–7511. <https://doi.org/10.3390/curroncol29100590>
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30, pp. 1–11). Curran Associates, Inc. <https://doi.org/https://doi.org/10.48550/arXiv.1706.03762>
- Wang, S., Yin, Y., Cao, G., Wei, B., Zheng, Y., & Yang, G. (2015). Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, 149(PB), 708–717. <https://doi.org/10.1016/j.neucom.2014.07.059>
- Wei, Y., Ye, J., Li, X., Zhao, Y., & Wang, Y. (2024). Breast ultrasound image BI-RADS classification based on Vision Transformer. 18(2), 32–39. <https://doi.org/https://doi.org/10.48550/arXiv.2110.14731>
- Ye, J. C. (2022). Artificial Neural Networks and Backpropagation. In *Mathematics in Industry* (Vol. 37, Issue 1). https://doi.org/10.1007/978-981-16-6046-7_6
- Yin, R., Luo, Z., Zhuang, P., Lin, Z., & Kwok, 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., Ma, Z., Zhang, Y., Chen, X., & Wang, G. (2021). Improved Inception V3 method and its effect on radiologists' performance of tumor classification with

automated breast ultrasound system. *Gland Surgery*, 10(7), 2232–2245.
<https://doi.org/10.21037/gs-21-328>

Zubair, M., Kim, J., & Yoon, C. (2016). An automated ECG beat classification system using Convolutional Neural Networks. *6th International Conference on IT Convergence and Security, ICITCS 2016*, 1–5.
<https://doi.org/10.1109/ICITCS.2016.7740310>