

**KLASIFIKASI PENYAKIT ALZHEIMER MENGGUNAKAN METODE
HYBRID INCEPTION V3-RELM**

SKRIPSI



UIN SUNAN AMPEL
S U R A B A Y A

Disusun Oleh
ANNISA WIDYA DWIRANI
09020221024

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA**

2026

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : ANNISA WIDYA DWIRANI

NIM : 09020221024

Program Studi : Matematika

Angkatan : 2021

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "KLASIFIKASI PENYAKIT ALZHEIMER MENGGUNAKAN METODE *HYBRID* INCEPTION V3-RELM". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 6 Januari 2026

Yang menyatakan,



ANNISA WIDYA DWIRANI

NIM. 09020221024

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : ANNISA WIDYA DWIRANI
NIM : 09020221024
Judul skripsi : KLASIFIKASI PENYAKIT ALZHEIMER
MENGGUNAKAN METODE *HYBRID* INCEPTION
V3-RELM

telah diperiksa dan disetujui untuk diujikan.


Pembimbing I


Nurissaidah Wlinnuha, M. Kom
NIP. 199011022014032004

Pembimbing II


Dr. Abdullah Hamid, M.Pd
NIP. 198508282014031003

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya


Dr. Yuniar Farida, M.T
NIP. 197905272014032001

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : ANNISA WIDYA DWIRANI
NIM : 09020221024
Judul Skripsi : KLASIFIKASI PENYAKIT ALZHEIMER
MENGUNAKAN METODE *HYBRID* INCEPTION
V3-RELM

Telah dipertahankan di depan Tim Penguji
pada tanggal 6 Januari 2026

Mengesahkan,
Tim Penguji

Penguji I




Dr. Dian Candra Rini Novitasari, M.Kom
NIP. 198511242014032001

Penguji II




Dr. Ahmad Hanif Asyhar, M.Si
NIP. 198601232014031001

Penguji III



Nurissaidah Ulinnuha, M. Kom
NIP. 199011022014032004

Penguji IV



Dr. Abdullah Hamid, M.Pd
NIP. 198508282014031003

Mengetahui,

Dekan Fakultas Sains dan Teknologi
UIN Sunan Ampel Surabaya



Dr. Saepul Hamdani, M.Pd
NIP. 196507312000031002

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : ANNISA WIDYA DWIRANI
NIM : 09020221024
Fakultas/Jurusan : SAINS DAN TEKNOLOGI / MATEMATIKA
E-mail address : annisawidya38@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

☒ Sekripsi ☐ Tesis ☐ Desertasi ☐ Lain-lain (.....)
yang berjudul :

KLASIFIKASI PENYAKIT ALZHEIMER MENGGUNAKAN METODE HYBRID

INCEPTION VS - FLM

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 6 JANUARI 2026

Penulis



(ANNISA WIDYA DWIRANI)
nama terang dan tanda tangan

ABSTRAK

KLASIFIKASI PENYAKIT ALZHEIMER MENGGUNAKAN METODE *HYBRID INCEPTION V3-RELM*

Alzheimer merupakan penyebab utama demensia yang ditandai oleh kerusakan sel saraf pada area otak yang berperan dalam fungsi kognitif. Diagnosis berbasis citra *Magnetic Resonance Imaging* (MRI) memerlukan analisis yang akurat dan konsisten, sehingga pendekatan *Computer Aided Diagnosis* (CAD) dikembangkan untuk mendukung proses klasifikasi secara otomatis. Penelitian ini bertujuan untuk menerapkan *hyperparameter tuning* guna memperoleh kombinasi parameter terbaik serta mengevaluasi performa optimal model *hybrid Inception v3-Regularized Extreme Learning Machine* (RELM) dalam klasifikasi citra MRI Alzheimer. Metode yang digunakan mengombinasikan *Inception v3* sebagai ekstraktor fitur dan RELM sebagai pengklasifikasi. Evaluasi dilakukan menggunakan *Repeated Stratified K-Fold Cross Validation* (5×5) dengan variasi parameter meliputi nilai regularisasi C , fungsi aktivasi, jumlah neuron, dan *batch size*. Model dikembangkan untuk mengklasifikasikan enam tingkat kondisi kognitif, yaitu *cognitively normal*, *subjective memory complaints*, *early mild cognitive impairment*, *mild cognitive impairment*, *late mild cognitive impairment*, dan *Alzheimer's disease*. Hasil pengujian menunjukkan bahwa kombinasi parameter terbaik diperoleh pada nilai $C = 0.01$, fungsi aktivasi *Swish*, 32768 neuron, dan *batch size* 2048. Konfigurasi tersebut menghasilkan performa klasifikasi dengan *accuracy* sebesar 81,67%, *precision* 82,23%, *recall* 81,76%, *specificity* 96,23%, dan *f1-score* 81,31%. Hasil ini menunjukkan bahwa penerapan *hyperparameter tuning* berperan penting dalam menentukan konfigurasi model yang mampu memberikan performa klasifikasi yang stabil pada model *hybrid Inception v3-RELM*.

Kata kunci: *Alzheimer's Disease*, CNN, Deep Learning, *Inception v3*, MRI, RELM

ABSTRACT

ALZHEIMER'S DISEASE CLASSIFICATION USING THE HYBRID INCEPTION V3-RELM METHOD

Alzheimer's disease is the leading cause of dementia, characterized by damage to nerve cells in areas of the brain responsible for cognitive function. Magnetic Resonance Imaging (MRI)-based diagnosis requires accurate and consistent analysis, which is why the Computer-Aided Diagnosis (CAD) approach was developed to support the automatic classification process. This research aims to apply hyperparameter tuning to obtain the best parameter combination and evaluate the optimal performance of the hybrid Inception v3-Regularized Extreme Learning Machine (RELM) model in Alzheimer's MRI image classification. The method used combines Inception v3 as a feature extractor and RELM as a classifier. The evaluation was conducted using Repeated Stratified K-Fold Cross Validation (5 x 5) with parameter variations including the regularization value C , activation function, number of neurons, and batch size. The model was developed to classify six levels of cognitive condition, namely cognitively normal, subjective memory complaints, early mild cognitive impairment, mild cognitive impairment, late mild cognitive impairment, and Alzheimer's disease. The test results show that the best parameter combination is obtained at a value of $C = 0.01$, the Swish activation function, 32768 neurons, and a batch size of 2048. This configuration yields classification performance with an accuracy of 81.67%, precision of 82.23%, recall of 81.76%, specificity of 96.23%, and an f1-score of 81.31%. These results indicate that the application of hyperparameter tuning plays an important role in determining the model configuration capable of providing stable classification performance for the hybrid Inception v3-RELM model.

Keywords: Alzheimer's Disease, CNN, Deep Learning, Inception v3, MRI, RELM

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PERSETUJUAN PEMBIMBING	ii
PENGESAHAN TIM PENGUJI SKRIPSI	iii
HALAMAN PERNYATAAN KEASLIAN	iv
MOTTO	v
HALAMAN PERSEMBAHAN	vi
KATA PENGANTAR	vii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xvii
ABSTRAK	xix
ABSTRACT	xx
I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	13
1.3. Tujuan Penelitian	13
1.4. Manfaat Penelitian	13
1.5. Batasan Masalah	14
1.6. Sistematika Penulisan	15
II TINJAUAN PUSTAKA	17
2.1. Penyakit Alzheimer	17
2.1.1. <i>Cognitively Normal (CN)</i>	18
2.1.2. <i>Subjective Memory Complaints (SMC)</i>	19
2.1.3. <i>Early Mild Cognitive Impairment (EMCI)</i>	20
2.1.4. <i>Mild Cognitive Impairment (MCI)</i>	21
2.1.5. <i>Late Mild Cognitive Impairment (LMCI)</i>	22
2.1.6. <i>Alzheimer's Disease (AD)</i>	23

2.2. <i>Resize</i>	24
2.3. <i>Image Augmentation</i>	26
2.4. <i>Convolutional Neural Network (CNN)</i>	29
2.4.1. <i>Input Layer</i>	30
2.4.2. <i>Convolution Layer</i>	31
2.4.3. <i>Batch Normalization Layer</i>	32
2.4.4. <i>Rectified Linear Unit (ReLU)</i>	34
2.4.5. <i>Pooling Layer</i>	35
2.4.6. <i>Concatenation Layer</i>	36
2.4.7. <i>Global Average Pooling (GAP) Layer</i>	37
2.4.8. <i>Inception v3</i>	38
2.5. <i>Principal Component Analysis (PCA)</i>	39
2.6. <i>Repeated Stratified K-Fold Cross Validation (CV) Method</i>	41
2.7. <i>Regularized Extreme Learning Machine (RELM)</i>	43
2.7.1. <i>Training RELM</i>	48
2.7.2. <i>Testing RELM</i>	49
2.8. <i>Confusion Matrix</i>	50
2.9. <i>Integrasi Keilmuan</i>	53
2.9.1. <i>Penyakit dalam Perspektif Islam</i>	56
2.9.2. <i>Optimalisasi dalam Perspektif Islam</i>	58
III METODE PENELITIAN	64
3.1. <i>Jenis Penelitian</i>	64
3.2. <i>Jenis dan Sumber Data</i>	64
3.3. <i>Kerangka Penelitian</i>	66
IV HASIL DAN PEMBAHASAN	69
4.1. <i>Preprocessing</i>	69
4.2. <i>Image Augmentation</i>	71
4.3. <i>Feature Learning pada CNN</i>	76
4.3.1. <i>Convolution Layer</i>	76
4.3.2. <i>Batch Normalization Layer</i>	81

4.3.3. <i>Rectified Linear Unit (ReLU)</i>	83
4.3.4. <i>Pooling Layer</i>	85
4.3.5. <i>Concatenation Layer</i>	87
4.3.6. <i>Global Average Pooling (GAP) Layer</i>	89
4.4. Klasifikasi RELM	92
4.4.1. <i>Proses Training</i>	94
4.4.2. <i>Proses Testing</i>	108
4.5. Pengujian Model dan Evaluasi Sistem	111
4.6. Integrasi Keilmuan	121
V PENUTUP	126
5.1. Kesimpulan	126
5.2. Saran	127
DAFTAR PUSTAKA	128
LAMPIRAN	146

UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR TABEL

2.1	Beberapa Fungsi Aktivasi pada ELM	45
4.1	Sampel data <i>training</i>	93
4.2	Sampel data <i>testing</i>	93
4.3	Hasil Terbaik Tiap Kombinasi Fungsi Aktivasi dan Parameter C pada Model Hybrid Inception v3 dan RELM	113
4.4	Perbandingan hasil penelitian dengan penelitian terdahulu menggunakan data ADNI	120
5.1	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 0.01$ dan varian parameter pada penelitian ini	146
5.2	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 0.1$ dan varian parameter pada penelitian ini	147
5.3	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 1$ dan varian parameter pada penelitian ini	149
5.4	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 10$ dan variasi parameter	150
5.5	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 100$ dan varian parameter pada penelitian ini	152
5.6	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 1000$ dan varian parameter pada penelitian ini	153
5.7	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 10000$ dan varian parameter pada penelitian ini	155
5.8	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>sigmoid</i> dengan nilai $C = 100000$ dan varian parameter pada penelitian ini	156
5.9	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU dengan nilai $C = 0.01$ dan varian parameter pada penelitian ini	158
5.10	Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU dengan nilai $C = 0.1$ dan varian parameter pada penelitian ini	159

5.11 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 1$ dan varian parameter pada penelitian ini	 161
5.12 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 10$ dan variasi parameter pada penelitian ini	. . . 162
5.13 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 10$ dan variasi jumlah neuron besar	 163
5.14 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 100$ dan varian parameter pada penelitian ini	. . . 164
5.15 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 1000$ dan varian parameter pada penelitian ini	. . 165
5.16 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 10000$ dan varian parameter pada penelitian ini	. . 167
5.17 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi ReLU	
dengan nilai $C = 100000$ dan varian parameter pada penelitian ini	. 168
5.18 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 0.01$ dan varian parameter pada penelitian ini	. . . 170
5.19 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 0.1$ dan varian parameter pada penelitian ini	. . . 171
5.20 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 1$ dan varian parameter pada penelitian ini	 173
5.21 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 10$ dan variasi parameter pada penelitian ini	. . . 174
5.22 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 10$ dan variasi parameter pada penelitian ini	. . . 175
5.23 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 100$ dan varian parameter pada penelitian ini	. . . 176
5.24 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 100$	 177
5.25 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 1000$	 177
5.26 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i>	
dengan nilai $C = 1000$	 178

5.27 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i> dengan nilai $C = 10000$ dan varian parameter pada penelitian ini	. . . 179
5.28 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>softplus</i> dengan nilai $C = 100000$ dan varian parameter pada penelitian ini	. 180
5.29 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 0.01$ dan varian parameter pada penelitian ini	. . . 182
5.30 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 0.1$ dan varian parameter pada penelitian ini	. . . 183
5.31 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 1$ dan varian parameter pada penelitian ini	 185
5.32 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 10$ dan varian parameter pada penelitian ini	 186
5.33 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 10$ dan variasi parameter	 187
5.34 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 100$ dan varian parameter pada penelitian ini	. . . 188
5.35 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 1000$ dan varian parameter pada penelitian ini	. . 189
5.36 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 10000$ dan varian parameter pada penelitian ini	. . 191
5.37 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>swish</i> dengan nilai $C = 100000$ dan varian parameter pada penelitian ini	. 192
5.38 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i> dengan nilai $C = 0.01$ dan varian parameter pada penelitian ini	. . . 194
5.39 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i> dengan nilai $C = 0.1$ dan varian parameter pada penelitian ini	. . . 195
5.40 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i> dengan nilai $C = 1$ dan varian parameter pada penelitian ini	 197
5.41 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i> dengan nilai $C = 1$ dan varian parameter pada penelitian ini	 198
5.42 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i> dengan nilai $C = 10$ dan variasi parameter	 198

5.43 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 10$ dan variasi parameter	199
5.44 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 100$ dan varian parameter pada penelitian ini . . .	200
5.45 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 1000$ dan varian parameter pada penelitian ini . .	201
5.46 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 1000$ dan varian parameter pada penelitian ini . .	202
5.47 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan $C = 10000$ dan variasi parameter	203
5.48 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan $C = 10000$ pada jumlah neuron besar	204
5.49 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 100000$ dan variasi parameter	204
5.50 Hasil uji coba klasifikasi citra menggunakan fungsi aktivasi <i>mish</i>	
dengan nilai $C = 100000$ dan variasi jumlah neuron	205

UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR GAMBAR

2.1 Struktur fisiologis otak dan neuron pada (a) otak sehat dan (b) otak penderitanya penyakit Alzheimer	18
2.2 Kategori CN	19
2.3 Kategori SMC	20
2.4 Kategori EMCI	21
2.5 Kategori MCI	22
2.6 Kategori LMCI	23
2.7 Kategori AD	24
2.8 Ilustrasi <i>Resize</i>	25
2.9 Arsitektur dasar dari CNN	30
2.10 Ilustrasi proses <i>convolution</i>	32
2.11 Perbandingan grafik sigmoid, tanh, dan ReLU	35
2.12 Ilustrasi proses <i>pooling layer</i>	36
2.13 Ilustrasi <i>concatenation layer</i>	37
2.14 Ilustrasi <i>Global Average Pooling</i>	38
2.15 Arsitektur Inception v3 <i>Feature Learning</i>	39
2.16 Ilustrasi PCA dalam reduksi dimensi fitur	40
2.17 Proses dari <i>Repeated Stratified K-Fold Cross Validation</i>	42
2.18 Arsitektur ELM	44
2.19 <i>Confusion matrix multi-class</i>	50
3.1 Dataset citra MRI Alzheimer (a) CN; (b) SMC; (c) EMCI; (d) MCI; (e) LMCI; (f) AD	65
3.2 Diagram alir pada penelitian ini	66
3.3 Diagram alir tahap klasifikasi	67
4.1 <i>Preprocessing</i> menggunakan <i>resize</i> (a) Citra MRI sebelum dilakukan <i>resize</i> ; (b) Citra MRI setelah dilakukan <i>resize</i>	71

4.2 Hasil augmentasi dengan teknik refleksi (a) Asli; (b) Refleksi Horizontal; (c) Refleksi Vertikal	73
4.3 Hasil augmentasi dengan teknik rotasi	76
4.4 Ilustrasi operasi <i>convolution</i> data masukan dengan <i>filter</i> yang menghasilkan <i>feature map</i>	77
4.5 Visualisasi <i>feature map convolution layer</i> pertama	81
4.6 Visualisasi <i>feature map</i> setelah melewati <i>Batch Normalization Layer</i>	83
4.7 Visualisasi <i>feature map</i> setelah melewati fungsi aktivasi ReLU	84
4.8 Visualisasi <i>feature map</i> setelah melewati <i>pooling layer</i>	87
4.9 Perubahan ukuran <i>feature map</i> setelah proses <i>concatenation</i>	88
4.10 Visualisasi hasil <i>feature map</i> setelah proses <i>concatenation</i>	89
4.11 Ilustrasi perubahan <i>feature map</i> pada arsitektur Inception V3	92
4.12 Hasil <i>confusion matrix</i> model terbaik Inception v3-RELM	116

UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR PUSTAKA

- Abiyev, R. H. & Ismail, A. (2021). COVID-19 and Pneumonia Diagnosis in X-Ray Images Using Convolutional.pdf. *Mathematical Problems in Engineering*, 2021, 1–14.
- ADNI (2024). MRI Brain Images.
- Afza, F., Sharif, M., Khan, M. A., Tariq, U., Yong, H. S., & Cha, J. (2022). Multiclass Skin Lesion Classification Using Hybrid Deep Features Selection and Extreme Learning Machine. *Sensors*, 22(3).
- Ahmad, B., Usama, M., Huang, C. M., Hwang, K., Hossain, M. S., & Muhammad, G. (2020). Discriminative feature learning for skin disease classification using deep convolutional neural network. *IEEE Access*, 8, 39025–39033.
- Ahmed, S. & Cho, S. H. (2020). Hand gesture recognition using an ir-uwb radar with an inception module-based classifier. *Sensors (Switzerland)*, 20(2).
- Ahn, J., Park, J., Park, D., Paek, J., & Ko, J. (2018). Convolutional neural network-based classification system design with compressed wireless sensor network images. *PLoS ONE*, 13(5), 1–25.
- Aisah, S. N., Candra, D., Novitasari, R., & Farida, Y. (2023). Perbandingan Metode Extreme Learning Machine (ELM) dan Kernel Extreme Learning Machine (KELM) Pada Klasifikasi Penyakit Cedera Panggul. *Journal Fourier*, 12(2), 69–78.

Al-Finatunni'mah, A. & Nurhidayati, T. (2020). Pelaksanaan senam otak untuk peningkatan fungsi kognitif pada lansia dengan demensia. *Ners Muda*, 1(2), 139.

Alamsyah, D. & Fachrurrozi, M. (2019). Faster r-cnn with inception v2 for fingertip detection in homogenous background image. *Journal of Physics: Conference Series*, 1196(1).

Alayba, A. M., Senan, E. M., & Alshudukhi, J. S. (2024). Enhancing early detection of alzheimer's disease through hybrid models based on feature fusion of multi-cnn and handcrafted features. *Scientific Reports*, 14.

Ali, F., Khan, S., Abbas, A. W., Shah, B., Hussain, T., Song, D., El-Sappagh, S., & Singh, J. (2022). A two-tier framework based on googlenet and yolov3 models for tumor detection in mri. *All Works*, 72, 4919.

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).

Arisanti, R., Simbolon, S. N., & Pontoh, R. S. (2022). The extension of moore-penrose generalized inverse for extreme learning machine in forecasting usd/idr exchange rate as impact of covid-19. *SICK Publishing Corporation*, (pp. 1–14).

Ashy, M. A. (1999). Health and Illness form an Islamic Perspective. *Journal of Religion and Health*, 38(3), 239–248.

Association, A. (2024). Alzheimer ' s disease facts and figures. *Alzheimers Dement*, 20(5).

- Awaluddin, B.-a., Chao, C.-t., & Chiou, J.-S. (2023). Investigating effective geometric transformation for image augmentation to improve static hand gestures with a pre-trained convolutional neural network. *Mathematics*, 11(23), 4783.
- Bae, J., Kim, M., & Lim, J. S. (2020). Feature extraction model based on inception v3 to distinguish normal heart sound from systolic murmur. *International Conference on ICT Convergence*, 2020-Octob, 460–463.
- Bai, Y. (2022). RELU-Function and Derived Function Review. *SHS Web of Conferences*, 144, 02006.
- Bari Antor, M., Jamil, A. H., Mamtaz, M., Monirujjaman Khan, M., Aljahdali, S., Kaur, M., Singh, P., & Masud, M. (2021). A comparative analysis of machine learning algorithms to predict alzheimer's disease. *Journal of Healthcare Engineering*, 2021.
- Bartlett, P. L. (1998). The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network. *IEEE Transactions on Information Theory*, 44(2), 525–536.
- Benyahia, S., Meftah, B., & L  zoray, O. (2022). Multi-features extraction based on deep learning for skin lesion classification. *Tissue and Cell*, 74.
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., & Pandya, S. (2021). Cnn variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(2470), 1–28.
- Bimo, A. A. (2024). Principal component analysis sebagai teknik reduksi dimensi pada data penjualan rumah di kawasan jabodetabek.

Breijyeh, Z. & Karaman, R. (2021). a comprehensive review on alzheimer's disease. *World Journal of Pharmacy and Pharmaceutical Sciences*, 10(7), 1170.

Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., & Miao, Y. (2023). Review of image classification algorithms based on convolutional neural networks. *remote sensing*, 13(4712), 299–302.

Chen, Q., Wei, H., Rashid, M., & Cai, Z. (2021). Kernel extreme learning machine based hierarchical machine learning for multi-type and concurrent fault diagnosis. *Measurement: Journal of the International Measurement Confederation*, 184(July), 109923.

Cheng, X., Feng, Z. K., & Niu, W. J. (2020). Forecasting monthly runoff time series by single-layer feedforward artificial neural network and grey wolf optimizer. *IEEE Access*, 8, 157346–157355.

Citra R, F., Indriyani, F., & Rahadjeng, I. R. (2024). Klasifikasi tumor otak berbasis magnetic resonance imaging menggunakan algoritma convolutional neural network. *Digital Transformation Technology*, 3(2), 918–924.

Corbi, G., Conti, V., Filippelli, A., Di Costanzo, A., & Ferrara, N. (2015). The Role Of Physical Activity On The Prevention Of Cognitive Impairment. *Translational medicine @ UniSa*, 13(7), 42–6.

Cui, Z., Gao, Z., Leng, J., Zhang, T., Quan, P., & Zhao, W. (2019). Alzheimer's Disease Diagnosis Using Enhanced Inception Network Based on Brain Magnetic Resonance Image. *Proceedings - 2019 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2019*, (pp. 2324–2330).

Dementia, U. K. (2021). What is dementia.

- Deng, W., Zheng, Q., & Chen, L. (2009). Regularized extreme learning machine. (pp. 389–395).
- Dhana, A., Decarli, C., Dhana, K., Desai, P., Krueger, K., Evans, D. A., & Rajan, K. B. (2022). Association of subjective memory complaints with white matter hyperintensities and cognitive decline among older adults in chicago, illinois. *JAMA Network Open*, 5(4), E227512.
- Ding, X. J., Yang, F., Liu, J., & Cao, J. (2020). Extreme Learning Regression for nu Regularization. *Applied Artificial Intelligence*, 34(5), 378–395.
- Dorado, N. C. (2022). *Convolutional Neural Networks based on Brain MRI for Alzheimer's Disease Detection*. Thesis, University of California, Irvine.
- El-Assy, A. M., Amer, H. M., Ibrahim, H. M., & Mohamed, M. A. (2024). A novel cnn architecture for accurate early detection and classification of alzheimer's disease using mri data. *Scientific Reports*, 14(1), 1–19.
- Ertel, M., Sadqui, A., Amali, S., Mahmoudi, I., Bouferma, Y., & Faddouli, N. E. E. (2023). Predicting the severity of new sars-cov-2 variants in vaccinated patients using machine learning. *Journal of Theoretical and Applied Information Technology*, 101(10), 4078–4086.
- Farheen, Ramzan, Muhammad, Usman, Ghani, Khan, Asim, Rehmat, Sajid, & Iqbal (2019). A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer's Disease Stages Using Resting-State fMRI and Residual Neural Networks. *Journal of medical systems*, 44(2), 37.
- Fauzie, A. N. & Yusram, M. (2024). Taklif bagi Penyandang Demensia Perpektif Fikih Ibadah. *Jurnal Kajian Islam*, 1(1), 263–283.

- Ferreira, D., Perestelo-Perez, L., Westman, E., Wahlund, L. O., Sarrisa, A., & Serrano-Aguilar, P. (2014). Meta-review of csf core biomarkers in alzheimer's disease: The state-of-the-art after the new revised diagnostic criteria. *Frontiers in Aging Neuroscience*, 6(MAR), 1–24.
- Gauthier, S., Webster, C., Servaes, S., Morais, J. A., & Rosa-Neto, P. (2022). Alzheimer's Disease International: World Alzheimer Report 2022 – Life after diagnosis. *Alzheimer's Disease International*, (pp. 361–364).
- Ghaffari, H., Tavakoli, H., & Jahromi, G. P. (2022). Deep transfer learning-based fully automated detection and classification of Alzheimer's disease on brain MRI. *British Journal of Radiology*, 95(1136).
- Gholamalinezhad, H. & Khosravi, H. (2020). Pooling Methods in Deep Neural Networks, a Review.
- Gonzalez, R. C. & Woods, R. E. (2019). Digital Image Processing. (pp. 79–85).
- Greenacre, M., Groenen, P. J. F., Hastie, T., D'enza, A. I., Markos, A., Tuzhilina, E., & D'enza, A. I. (2023). Principal component analysis.
- Guan, Q., Wan, X., Lu, H., Ping, B., Li, D., Wang, L., Zhu, Y., Wang, Y., & Xiang, J. (2019). Deep convolutional neural network Inception-v3 model for differential diagnosing of lymph node in cytological images: a pilot study. *Annals of Translational Medicine*, 7(14), 307–307.
- Hicks, S. A., Strumke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 1–9.

Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 42(2), 513–529.

Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1), 489–501.

Indonesia, A. (2019). Statistik tentang demensia.

Iosifidis, A., Tefas, A., & Pitas, I. (2015). Regularized extreme learning machine for large-scale media content analysis. *Procedia Computer Science*, 53, 420–427. INNS Conference on Big Data 2015 Program San Francisco, CA, USA 8-10 August 2015.

Iparraguirre-Villanueva, O., Guevara-Ponce, V., Paredes, O. R., Sierra-Lian, F., Zapata-Paulini, J., & Cabanillas-Carbonell, M. (2022). Convolutional neural networks with transfer learning for pneumonia detection. *International Journal of Advanced Computer Science and Applications*, 13(9), 544–551.

Ismail, M. Y., Sunyoto, A., & Purwanto, A. (2024). Klasifikasi penyakit alzheimer pada citra medis magnetic resonance images dengan arsitektur densenet121. *Jurnal Ilmiah Komputasi*, 23(2), 275–282.

Ji, C. (2018). Understanding Bilinear Image Resizing.

John, W. & Clifford, R. (2023). Depth concatenation using a matrix computation unit. *European Patent Office*, 2(19).

Kang, L., Jiang, J., Huang, J., & Zhang, T. (2020). Identifying early mild cognitive impairment by multi-modality mri-based deep learning. *Frontiers in Aging Neuroscience*, 12(September), 1–10.

- Karakaya, F., Gurkan, C., Budak, A., & Karatas, H. (2022). Classification and segmentation of alzheimer disease in mri modality using deep convolutional neural networks. *European Journal of Science and Technology*, (40), 99–105.
- Kardani, N., Bardhan, A., Roy, B., Samui, P., Nazem, M., Armaghani, D. J., & Zhou, A. (2022). A novel improved harris hawks optimization algorithm coupled with elm for predicting permeability of tight carbonates. *Eng. with Comput.*, 38(Suppl 5), 4323–4346.
- Lazli, L., Boukadoum, M., & Mohamed, O. A. (2019). Computer-aided diagnosis system of alzheimer's disease based on multimodal fusion: Tissue quantification based on the hybrid fuzzy-genetic-possibilistic model and discriminative classification based on the svdd model. *Brain Sciences*, 9(10).
- Li, C., Zhou, J., Dias, D., & Gui, Y. (2022). A kernel extreme learning machine-grey wolf optimizer (kelm-gwo) model to predict uniaxial compressive strength of rock. *Applied Sciences (Switzerland)*, 12(17).
- Liang, C.-S., Li, D.-J., Yang, F.-C., Tseng, P.-T., Carvalho, A. F., Stubbs, B., Thompson, T., Mueller, C., Shin, J. I., Radua, J., Stewart, R., Rajji, T. K., Tu, Y.-K., Chen, T.-Y., Yeh, T.-C., Tsai, C.-K., Yu, C.-L., Pan, C.-C., & Chu, C.-S. (2021). Mortality rates in alzheimer's disease and non-alzheimer's dementias: a systematic review and meta-analysis. *The lancet. Healthy longevity*, 2(8), e479–e488.
- Lim, B. Y., Lai, K. W., Haiskin, K., Kulathilake, K. S. H., Ong, Z. C., Hum, Y. C., Dhanalakshmi, S., Wu, X., & Zuo, X. (2022). Deep learning model for prediction of progressive mild cognitive impairment to alzheimer ' s disease using structural mri. *Frontiers in Aging Neuroscience*, 14(June), 1–10.

- Lin, C., Li, L., Luo, W., Wang, K. C., & Guo, J. (2019). Transfer learning based traffic sign recognition using inception-v3 model. *Periodica Polytechnica Transportation Engineering*, 47(3), 242–250.
- Lin, Q., Che, C., Hu, H., Zhao, X., & Li, S. (2023). A comprehensive study on early alzheimer's disease detection through advanced machine learning techniques on mri data. *Academic Journal of Science and Technology*, 8(1), 281–285.
- Linkon, A. H. M., Labib, M. M., Hasan, T., Hossain, M., & Jannat, M. E. (2021). Deep learning in prostate cancer diagnosis and Gleason grading in histopathology images: An extensive study. *Informatics in Medicine Unlocked*, 24(March), 100582.
- Long, S., Benoist, C., & Weidner, W. (2024). World alzheimer report 2024. *Alzheimer's Disease International*, (pp.94).
- Lumumba, V. W., Kiprotich, D., Makena, N. G., & Kavita, M. D. (2024). Comparative Analysis of Cross-Validation Techniques: LOOCV, K-folds Cross-Validation, and Repeated K-folds Cross-Validation in Machine Learning Models. *UIN Sunan Ampel Surabaya*, 13(5), 127–137.
- Maalej, R. (2022). New MDLSTM Based Designs with Data Augmentation for Offline Arabic Handwriting Recognition. *Multimedia Tools and Applications*, 81, 1–18.
- Markoulidakis, I. & Markoulidakis, G. (2024). Probabilistic confusion matrix: A novel method for machine learning algorithm generalized performance analysis. *Technologies*, 12(7).
- MartíNez-MartíNez, J. M., Escandell-Montero, P., Soria-Olivas, E., MartíN-

- Guerrero, J. D., Magdalena-Benedito, R., & Gómez-Sanchis, J. (2011). Letters: Regularized extreme learning machine for regression problems. *Neurocomput.*, 74(17), 3716–3721.
- Maćkiewicz, A. & Ratajczak, W. (1993). Principal components analysis (pca). *Computers & Geosciences*, 19, 303–342.
- McKhann, G. M., Knopman, D. S., Chertkow, H., Hyman, B. T., Jack Jr, C. R., Kawas, C. H., Klunk, W. E., Koroshetz, W. J., Manly, J. J., Mayeux, R., Mohs, R. C., Morris, J. C., Rossor, M. N., Scheltens, P., Carrillo, M. C., Thies, B., Weintraub, S., & Phelps, C. H. (2012). The diagnosis of dementia due to alzheimer's disease: Recommendation from the national institute on aging alzheimer's association workgroups on diagnostic guidelines for alzheimer's disease. *Alzheimers Dement*, 7(3), 263–269.
- Mercioni, M. A. & Holban, S. (2020). P-Swish: Activation Function with Learnable Parameters Based on Swish Activation Function in Deep Learning. *2020 14th International Symposium on Electronics and Telecommunications, ISETC 2020 - Conference Proceedings*.
- Minfei, L., Yidong, G., Ze, C., Zhi, W., Erik, S., & Branko, Š. (2022). Microstructure-informed deep convolutional neural network for predicting short-term creep modulus of cement paste. *Cement and Concrete Research*, 152(December 2021).
- Misra, D. (2020). Mish: A Self Regularized Non-Monotonic Activation Function. *31st British Machine Vision Conference, BMVC 2020*.
- Mujahid, M., Rustam, F., Alvarez, R., Luis Vidal Mazon, J., Diez, I. d. l. T., &

- Ashraf, I. (2022). Pneumonia classification from x-ray images with inception-v3 and convolutional neural network. *Diagnostics*, 12(5), 1–16.
- Murty, K. G. (2007). Nonlinear Programming Theory and Algorithms. *Technometrics*, 49(1), 105–105.
- Mutemi, A. & Bacao, F. (2023). A numeric-based machine learning design for detecting organized retail fraud in digital marketplaces. *Scientific Reports*, 13(1), 1–17.
- Nasution, M. A. P., Cholissodin, I., & Indriati (2020). Prediksi price earning ratio saham menggunakan algoritme kernel extreme learning machine (studi kasus: Pt telkom). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 4(10), 3455–3462.
- Norhikmah, Lutfhi, A., & Rumini (2022). The effect of layer batch normalization and dropout of cnn model performance on facial expression classification. *International Journal on Informatics Visualization*, 6(2), 481–488.
- O'Donnell, H. (2023). A Review of Primary, Secondary, and Tertiary Prevention Strategies for Alzheimer's Disease. *Undergraduate Journal of Public Health*, 7(0).
- Paraijun, F., Aziza, R. N., & Kuswardani, D. (2022). Implementasi algoritma convolutional neural network dalam mengklasifikasi kesegaran buah berdasarkan citra buah. *Kilat*, 11(1), 1–9.
- Prado, J. J. & Rojas, I. (2021). Machine learning for diagnosis of alzheimer's disease and early stages. *BioMedInformatics*, 1(3), 182–200.

- Priyadharshini, N., Selvanathan, N., Hemalatha, B., & Sureshkumar, C. (2023). A novel hybrid Extreme Learning Machine and Teaching Learning-Based Optimization algorithm for skin cancer detection. *Healthcare Analytics*, 3(March), 100161.
- Purnomo, M. F. Z., Venecianopan, & Aisyah, V. N. (2023). Keterkaitan kesehatan manusia dan peran agama dalam lingkup masyarakat. *Humas UMM*, 1, 73–81.
- Ramaneswaran, S., Srinivasan, K., Vincent, P. M. R., & Chang, C. Y. (2021). Hybrid inception v3 xgboost model for acute lymphoblastic leukemia classification. *Computational and Mathematical Methods in Medicine*, 2021, 1–10.
- Rashid, M., Khan, M. A., Alhaisoni, M., Wang, S. H., Naqvi, S. R., Rehman, A., & Saba, T. (2020). A sustainable deep learning framework for object recognition using multi-layers deep features fusion and selection. *Sustainability (Switzerland)*, 12(12).
- Risal, M., Hamu, A. H., Litaqia, W., Dewi, E. U., Sinthania, D., Fatah, V. F., Raharjo, R., Albyn, D. F., Islamarida, R., Martini, S., Pastari, M., Narulita, S., & Jayanti, D. M. A. D. (2015). *Ilmu Keperawatan Jiwa*. CV. Media Sains Indonesia.
- Rörup, T., Rojas, I., Pomares, H., & Glösekötter, P. (2021). Deep Learning Based Neural Network for Six-Class-Classification of Alzheimer's Disease Stages Based on MRI Images. In I. Rojas, G. Joya, & A. Català (Eds.), *Advances in Computational Intelligence* (pp. 15–23). Cham: Springer International Publishing.
- Sa'idah, S., Suparta, I. P. Y. N., & Suhartono, E. (2022). Modifikasi convolutional neural network arsitektur googlenet dengan dull razor filtering untuk klasifikasi

- kanker kulit. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 11(2), 148–153.
- Salehi, A. W., Baglat, P., Sharma, B. B., Gupta, G., & Upadhy, A. (2020). A CNN Model: Earlier Diagnosis and Classification of Alzheimer Disease using MRI. *Proceedings - International Conference on Smart Electronics and Communication, ICOSEC 2020*, (November), 156–161.
- Sari, M., Tarigan, D. P., & Rafiyah, I. (2022). Hubungan tingkat pendidikan dengan status demensia pada lansia berdasarkan kajian data sekunder di posbindu caringin. *Jurnal Keperawatan Muhammadiyah*, 7(2), 162–170.
- Shamrat, F. M. M., Akter, S., Azam, S., Karim, A., Ghosh, P., Tasnim, Z., Hasib, K. M., De Boer, F., & Ahmed, K. (2023). Alzheimernet: An effective deep learning based proposition for alzheimer's disease stages classification from functional brain changes in magnetic resonance images. *IEEE Access*, 11, 16376–16395.
- Shen, W. & Li, X. (2020). Facial expression recognition based on bidirectional gated recurrent units within deep residual network. *International Journal of Intelligent Computing and Cybernetics*, 13(4), 527–543.
- Shorten, C. & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1).
- Shustanov, A. V. & Yakimov, P. Y. (2019). Modification of single-purpose CNN for creating multi-purpose CNN. *Journal of Physics: Conference Series*, 1368(5).
- Sianturi, A. G. M. (2021). Stadium, diagnosis, dan tatalaksana penyakit alzheimer. *Majalah Kesehatan Indonesia*, 2(2), 39–44.

- Singh, K., Singh, D., & Mishra, N. (2022). Review: Convolutional neural networks and its architecture. *International journal of health sciences*, 6(S1), 9183–9190.
- Siregar, R. G. (2019). Gangguan Berpikir Demensia (Pikun) Pada Lansia. *Jurnal Pendidikan Bahasa dan Sastra Indonesia*, 3(budaya literasi dalam pembelajaran bahasa), 183–187.
- Song, Y., Xu, W., Chen, S., Hu, G., Ge, H., Xue, C., Qi, W., Lin, X., & Chen, J. (2021). Functional mri-specific alterations in salience network in mild cognitive impairment: An ale meta-analysis. *Frontiers in Aging Neuroscience*, 13(July), 1–14.
- Syech Ahmad, M. T. A. & Sugiarto, B. (2023). Implementasi convolutional neural network (cnn) untuk klasifikasi ikan cupang berbasis mobile. *Digital Transformation Technology*, 3(2), 712–723.
- Tang, L., Li, H., Yan, C., Zheng, X., & Ji, R. (2021). Survey on neural architecture search. *Journal of Image and Graphics*, 26(2), 245–264.
- Tay, L., Tan, K., Diener, E., & Gonzalez, E. (2013). Social relations, health behaviors, and health outcomes: a survey and synthesis. *Applied psychology. Health and well-being*, 5(1), 28–78.
- Tian, X., Shi, L., Luo, Y., & Zhang, X. (2024). Garbage Classification Algorithm Based on Improved MobileNetV3. *IEEE Access*, 12(February), 44799–44807.
- Ud din dar, G. M., Bhagat, A., Ansarullah, S. I., Tahar, M., Othman, B., Hamid, Y., Alkahtani, H. K., Ullah, I., & Hamam, H. (2023). A novel framework for classification of different alzheimer ' s disease stages using cnn model. *Multidisciplinary Digital Publishing Institute (MDPI)*, 12(2), 1–14.

- Uddin, A., Talukder, B., Khan, M. M., & Zaguia, A. (2021). Study on Convolutional Neural Network to Detect COVID-19 from Chest.pdf. *Mathematical Problems in Engineering*, 2021, 1–11.
- Vinicius, M., De Mello, C., Vieira, L., Cruz de Souza, L., Gomes, K., & Carvalho, M. (2019). Alzheimer's disease: risk factors and potentially protective measures. *Journal of Biomedical Science*, 26(1), 1–33.
- Várkonyi, D. & Buza, K. (2019). Extreme learning machines with regularization for the classification of gene expression data.
- Wang, C., Chen, D., Hao, L., Liu, X., Zeng, Y., Chen, J., & Zhang, G. (2019). Pulmonary image classification based on inception-v3 transfer learning model. *IEEE Access*, 7, 146533–146541.
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2022). A review on extreme learning machine. *Multimedia Tools and Applications*, 81(29), 41611–41660.
- WHO (2020). Indonesia: Alzheimer/demensia.
- Xie, L., Das, S. R., Wisse, L. E. M., Ittyerah, R., Flores, R. D., Shaw, L. M., Yushkevich, P. A., Wolk, D. A., & Initiative, A. D. N. (2023). Baseline structural mri and plasma biomarkers predict longitudinal structural atrophy and cognitive decline in early alzheimer ' s disease. *Alzheimer's Research & Therapy*, 15(1), 79.
- Xu, X., Wen, H., Lin, H., Li, Z., & Huang, C. (2024). Online detection method for variable load conditions and anomalous sound of hydro turbines using correlation analysis and pca-adaptive-k-means. *Measurement*, 224, 113846.

- Yamanakkanavar, N., Choi, J. Y., & Lee, B. (2020). Mri segmentation and classification of human brain using deep learning for diagnosis of alzheimer's disease: A survey. *Sensors (Switzerland)*, 20(11), 1–31.
- Yaseen, Z. M., Deo, R. C., Hilal, A., Abd, A. M., Bueno, L. C., Salcedo-Sanz, S., & Nehdi, M. L. (2018). Predicting compressive strength of lightweight foamed concrete using extreme learning machine model. *Advances in Engineering Software*, 115, 112–125.
- Yenusi, Y. N., Trihandaru, S., & Setiawan, A. (2023). Comparison of convolutional neural network (cnn) models in face classification of papuan and other ethnicities. *JST (Jurnal Sains dan Teknologi)*, 12(1), 261–268.
- Yu, Q., Miche, Y., Eirola, E., Van Heeswijk, M., SéVerin, E., & Lendasse, A. (2013). Regularized extreme learning machine for regression with missing data. *Neurocomput.*, 102, 45–51.
- Yu, Y., Adu, K., Tashi, N., Anokye, P., Wang, X., & Ayidzoe, M. A. (2020). RMAF: Relu-Memristor-Like Activation Function for Deep Learning. *IEEE Access*, 8, 72727–72741.
- Zhang, R., Zhou, B., Lu, C., & Ma, M. (2022). The performance research of the data augmentation method for image classification. *Mathematical Problems in Engineering*, 2022(1), 2964829.
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). *A review of convolutional neural networks in computer vision*, volume 57. Springer Netherlands.
- Zhao, Y., Xie, K., Zou, Z., & He, J. B. (2020). Intelligent recognition of fatigue and

sleepiness based on inceptionv3-lstm via multi-feature fusion. *IEEE Access*, 8, 144205–144217.

Zhao, Z., Chuah, J. H., Lai, K. W., Chow, C. O., Gochoo, M., Dhanalakshmi, S., Wang, N., Bao, W., & Wu, X. (2023). Conventional machine learning and deep learning in Alzheimer's disease diagnosis using neuroimaging: A review. *Frontiers in Computational Neuroscience*, 17.

Zheng, H., Yang, Z., Liu, W., Liang, J., & Li, Y. (2015). Improving deep neural networks using softplus units. *Proceedings of the International Joint Conference on Neural Networks*, 2015-September, 0–3.

Zhong, Z., Jin, L., & Xie, Z. (2015). High performance offline handwritten chinese character recognition using googlenet and directional feature maps. *International Conference on Document Analysis and Recognition (ICDAR)*, (pp. 846–850).

Zou, C., Amos-Richards, D., Jagannathan, R., & Kulshreshtha, A. (2024). Effect of home-based lifestyle interventions on cognition in older adults with mild cognitive impairment: a systematic review. *BMC geriatrics*, 24(1), 200.