

Perancangan Sistem Klasifikasi Alzheimer Berbasis Pengolahan Citra MRI Menggunakan Convolutional Neural Network (CNN)

1st Dery Febryanto Bongso

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

deryfbongso@student.telkomuniversity.ac.id

2nd Raditiana Patmasari

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

raditiana@telkomuniversity.ac.id

3rd Sofia Saidah

Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

sofiasaidahsfi@telkomuniversity.ac.id

Abstrak— Penyakit Alzheimer atau *Alzheimer Diseases* (AD) adalah penyakit otak yang menyebabkan penurunan daya ingat, menurunnya kemampuan berpikir dan berbicara, serta perubahan perilaku. Seiring dengan waktu, Penyakit Alzheimer dapat membuat penderitanya tidak mampu melakukan pekerjaan sehari-hari. Penyakit Alzheimer umumnya terjadi pada seseorang yang berusia di atas 65 tahun. Dalam mendeteksi Alzheimer para medis menggunakan pencitraan pada otak salah satu metode yang banyak digunakan *Magnetic Resonance Imaging* (MRI). Dengan perkembangan teknologi pengolahan citra dan komputasi tenaga medis menggunakan deep learning sebagai metode identifikasi. Hal ini dikarenakan deep learning memiliki *average precision* yang tinggi dalam mengklasifikasikan citra. Dari pengujian performa sistem pada sistem yang dirancang berdasarkan hasil terbaik dari setiap skenario dengan ukuran citra 224×224, *optimizer adam*, *learning rate 0,0001*, *epoch 80*, dan *batch size* didapatkan tingkat akurasi sebesar 92%, tingkat presisi sebesar 94%, *recall* sebesar 92%, dan *f1-score* sebesar 93%.

Kata kunci— penyakit alzheimer, convolutional neural network, hidden layer, learning rate, batch rate, resize.

I. PENDAHULUAN

Penyakit Alzheimer atau Alzheimer Diseases (AD) adalah penyakit otak yang menyebabkan penurunan daya ingat, menurunnya kemampuan berpikir dan berbicara, serta perubahan perilaku. Seiring dengan waktu, Penyakit Alzheimer dapat membuat penderitanya tidak mampu melakukan pekerjaan sehari-hari [1], [2]. Penyakit Alzheimer umumnya terjadi pada seseorang yang berusia di atas 65 tahun [2], [3]. Penyebab penyakit Alzheimer masih belum diketahui, tetapi perubahan genetik yang diturunkan dari orang tua diduga dapat meningkatkan risiko terjadinya penyakit ini, selain itu faktor kelainan protein dalam otak diduga dapat merusak sel saraf sehat dalam otak [2], [4].

Angka kejadian penyakit Alzheimer di Indonesia meningkat pesat, dengan perkiraan 1,2 juta orang mengalami demensia pada tahun 2016, dan diperkirakan 2 juta orang dengan demensia pada tahun 2030 serta diperkirakan 4 juta mengalami demensia pada tahun 2050 [5]. Karena sifat perkembangan penyakit Alzheimer yang irreversible maka deteksi sejak dini sangat diperlukan [6]. Dalam mendeteksi Alzheimer para medis menggunakan pencitraan pada otak salah satu metode yang banyak digunakan Magnetic

Resonance Imaging (MRI) [7]. Dengan perkembangan teknologi pengolahan citra dan komputasi paramedis menggunakan deep learning sebagai metode identifikasi. Hal ini dikarenakan deep learning memiliki *average precision* yang tinggi dalam mengklasifikasikan citra [8].

Terdapat beberapa penelitian yang mengembangkan sistem klasifikasi penyakit Alzheimer menggunakan CNN yang digunakan sebagai acuan pada penelitian ini. Penelitian [3] mengembangkan dan membandingkan dua arsitektur yaitu MobileNet dan VGG-16 yang menunjukkan MobileNet memiliki akurasi yang sedikit lebih baik dari VGG-16 dengan presentase pada MobileNet tingkat akurasi ada di 94% sedangkan VGG-16 di 92%. Sementara itu pada penelitian [9] melakukan pengujian dan pengembangan dengan beberapa metode diantaranya GoogleNet, ResNet-18, dan ResNet-152, pada penelitian tersebut memiliki nilai akurasi yang tidak begitu jauh. Pada GoogleNet mendapatkan nilai akurasi 98,8%, ResNet-18 memiliki nilai akurasi 98,01% dan ResNet-152 98,14%. Pada penelitian [10] melakukan menggunakan 8 Layer yang terdiri dari 6 Rectifying Linear Unit (Rel-U) dan 2 Fully Connected Layer yang memiliki hasil akurasi sebesar 97,65%. Dan pada ketiga penelitian yang digunakan sebagai acuan mengambil data MRI dari Kaggle dengan 4 kelas klasifikasi.


Pada Tugas Akhir ini dilakukan sistem identifikasi yang dapat mengklasifikasi stadium penyakit Alzheimer menggunakan metode CNN yang menggunakan 5 hidden layer untuk feature extraction. Klasifikasi stadium diantaranya sebagai berikut yaitu non demented (praklinis AD), very mild demented (MCI due to AD), mild demented (mild), dan moderate demented (Moderate). Metode klasifikasi yang akan digunakan yaitu softmax. Pada penelitian ini terbentuk model berbasis CNN 5 Layer yang tidak overfitting dan underfitting sehingga dapat mengklasifikasi non demented, very mild demented, mild demented dan moderate demented [2].

II. KAJIAN TEORI

A. Penyakit Alzheimer

Penyakit Alzheimer merupakan penyebab umum demensia pada kelompok usia diatas 65 tahun. Penyakit Alzheimer ditandai dengan penurunan daya ingat seiring

dengan waktu penyakit ini dapat memburuk menyebabkan penderitanya mengalami kesulitan dalam melakukan pekerjaan sehari-hari [2], [11]. Penyakit Alzheimer bersifat progresif atau tidak dapat disembuhkan. Ada beberapa faktor yang menyebabkan penyakit Alzheimer diantaranya pengendapan protein beta-amyloid yang menghalangi nutrisi antar sel, pengaruh genetik atau keturunan, gaya hidup tidak sehat[4].[2]. Penelitian ini mengklasifikasikan penyakit Alzheimer menjadi empat jenis, Non-demented, Very Mild Demented, Mild Demented, Moderate Demented. Dapat dilihat pada Gambar 1



Gambar 1. Citra MRI Otak [12]

B. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu algoritma dari deep learning dari pengembangan Multilayer Perceptron (MLP) didesain untuk memproses struktur dua dimensi seperti citra [13]. Pada Gambar 2. merupakan Arsitektur CCN yang dibagi menjadi proses Feature Extraction dan proses Classification yang nantinya akan dibagi menjadi layer-layer penting lainnya.


Bagian Feature Extraction Layer yang digunakan adalah Convolution Layer, aktivasi Rel-U, dan Pooling Layer. Sedangkan, pada bagian Classification menggunakan fully connected Layer, dan fungsi aktivasi.



GAMBAR 2. Arsitektur CNN

C. Convolution Layer

Convolution Layer memiliki peran penting dalam bagaimana CNN beroperasi[10], [12]. Convolution Layer merupakan layer pertama yang melakukan operasi konvolusional diantara filter dan citra sebagai input dari arsitektur CNN. Konvolusi adalah istilah matematis yang digunakan untuk mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang. Pada pengolahan citra, konvolusi berarti mengaplikasikan kernel (filter) pada citra disemua bagian. Filter akan digeser dari sisi kiri ke kanan. Setiap pergeseran akan dilakukan operasi “dot” antar input dan nilai dari filter sehingga menghasilkan output berupa future map seperti pada gambar 2.



GAMBAR 1. Ilustrasi proses Convolution Layer[13]

D. Aktifasi Rel-U


$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (1)$$

Neuron pada feature map harus melewati fungsi aktivasi non-linier (f(x)). Fungsi aktivasi yang digunakan pada umumnya yaitu sigmoid, tanh, dan ReLU. Jika dibandingkan dengan fungsi aktivasi yang lain, ReLU lebih disarankan untuk digunakan karena metode ini dapat mempercepat konvergensi penurunan gradien stokastik dibandingkan dengan fungsi sigmoid. Layer aktivasi yang digunakan diantara convolution dan pooling Layer yaitu Rectified Linear Unit (ReLU).

ReLU adalah sebuah Layer aktivasi pada arsitektur CNN dengan menggunakan fungsi pada Persamaan (1). Fungsi tersebut membatasi nilai 0 pada input value (x) dari citra. Aktivasi ini membuat seluruh value dari piksel yang kurang dari 0 menjadi 0 pada feature map[12], [14].

E. Pooling Layer

CNN tidak hanya mengandung convolution Layer namun juga beberapa pooling Layer. Pooling Layer selalu berada setelah Convolutional Layer. Pooling Layer adalah lapisan tambahan pada algoritma CNN yang menyediakan metode untuk melakukan down sampling peta fitur dengan cara mereduksi input secara spasial (mengurangi jumlah parameter) pada gambar. Tujuannya untuk meringkas dan merangkum keberadaan fitur. Walaupun mengurangi jumlah parameter, informasi terpenting dari bagian tersebut tetap dapat diolah. Operasi pooling diantaranya max pooling, average pooling, stochastic pooling, spectral pooling, spatial pyramid pooling, L2-norm pooling, dan multiscale orderless pooling. Pada aplikasinya, pooling layer yang pada umumnya digunakan adalah max pooling dan mean pooling seperti Gambar 2.5[10], [14].



GAMBAR 4. Ilustrasi Pooling Layer

F. Fully Connected Layer

Feature map yang dihasilkan dari feature extraction layer masih berbentuk multidimensional array, sehingga kita harus melakukan “flatten” atau reshape feature map menjadi

sebuah vektor agar bisa kita gunakan sebagai input dari *Fully-Connected Layer*. *Layer FC* adalah lapisan yang memiliki koneksi penuh ke semua neuron. Lapisan ini berfungsi untuk melakukan transformasi pada dimensi data sehingga data bisa diklasifikasikan secara linier. *Layer FC* memiliki peran sedemikian sehingga output dari *layer FC* dapat diterapkan untuk fungsi softmax atau sigmoid dimana kedua fungsi tersebut bertujuan untuk mengklasifikasi label dari input. Neuron pada *layer FC* tidak terorganisir secara ruang, oleh karena itu tidak mungkin lagi ditempatkan *convolution layer* setelah diterapkan *layer FC*. Tujuan dari dibentuknya *layer FC* adalah untuk merampingkan fitur tingkat tinggi, yang telah di pelajari oleh *Convolutional Layer*, dan untuk menyatukan seluruh elemen [9], [13].

G. Aktifasi Softmax

Aktifasi fungsi yang diterapkan pada akhir dari *layer FC* biasanya berbeda dari aktifasi sebelumnya. Dibutuhkan fungsi aktifasi yang sesuai untuk melakukan tugas yang spesifik. Sebuah fungsi aplikasi yang diterapkan pada klasifikasi multiclass pada umumnya selalu diikuti oleh aktifasi softmax. Klasifikasi softmax merupakan metode regresi logistik yang dapat digunakan untuk mengklasifikasi lebih dari dua kelas. Rumus aktifasi softmax dijelaskan pada persamaan 2.

$$S(y)_i = \frac{e^{y_i}}{\sum_{j=1}^n e^{y_j}} \quad (2)$$

Secara matematis, aktifasi softmax menerapkan metode normalisasi lalu mengkonversi output dari *Layer* terakhir (e^{y_i}) menuju distribusi probabilistik ($S(y)_i$). Keunggulan aktifasi softmax adalah rentang dari probabilitas output berkisar diantara angka 0 dan 1, dan total dari seluruh probabilitas adalah 1.

H. Stochastic Gradient Descent (SGD)

Stochastic Gradient Descent (SGD) merupakan optimizer yang sangat sederhana. proses perbaikan bobot hanya dengan mengkalikan *gradient* dengan *learning rate*. Akan tetapi proses yang sederhana tersebut memiliki waktu yang lama untuk mendekati konvergen [16]. Adapun rumus SGD dijelaskan pada persamaan 3.

$$\theta = \theta - \epsilon \times \nabla_{\theta} j(\theta; x^{(i)}; y^{(i)}) \quad (3)$$

Keterangan:

θ = bobot atau bias

ϵ = Learning Rate

$\nabla_{\theta} j(\theta; x^{(i)}; y^{(i)})$ = gradient terhadap bias, x dan y

x = input

y = Label

I. Stochastic Gradient Descent (SGD)

RMSprop merupakan salah satu optimizer yang mempertahankan rata-rata dari kuadrat gradient untuk setiap bobot [17]. Adapun rumus RMSprop dijelaskan pada persamaan 4.

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2 \quad (4)$$

Keterangan:

$E[g^2]_t$ = rata-rata dari kuadrat gradient setelah proses

optimasi

$E[g^2]_{t-1}$ = rata-rata dari kuadrat gradient sebelum proses optimasi

g = gradient

t = timestamp

J. Adaptive Moment Estimation (Adam)

Adaptive Moment Estimation (Adam) adalah salah satu adaptif *learning rate* optimasi yang mengkombinasikan RMSProp dan momentum [15], [17]. Berdasarkan penelitian [15] Sebelum menggunakan adam sebagai *optimizer*, ada beberapa nilai yang harus diinisialisasikan yaitu:

1. m = 0

2. v = 0

3. $\epsilon = 10^{-8}$

4. t = 0

5. $\beta_1 = 0.9$

6. $\beta_2 = 0.999$

Tahapan – tahapan yang dilakukan pada proses optimasi menggunakan *adam* berdasarkan pada penelitian [15] yaitu :

Tambah t untuk setiap iterasi

$$t = t + 1 \quad (5)$$

Menghitung *gradient*

$$g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1}) \quad (6)$$

Menghitung bias *first moment*

$$m_t \leftarrow \beta_1 m_{t-1} + (1 - \beta_1) g \quad (7)$$

Menghitung bias *second moment*

$$v_t \leftarrow \beta_2 v_{t-1} + (1 - \beta_2) g \cdot g \quad (8)$$

Memperbaiki *first moment*

$$\hat{m}_t \leftarrow \frac{m_t}{1 - \beta_1^t} \quad (9)$$

Memperbaiki *second moment*

$$\hat{v}_t \leftarrow \frac{v_t}{1 - \beta_2^t} \quad (10)$$

Memperbaiki parameter

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (11)$$

Keterangan :

g = gradient

m = first moment

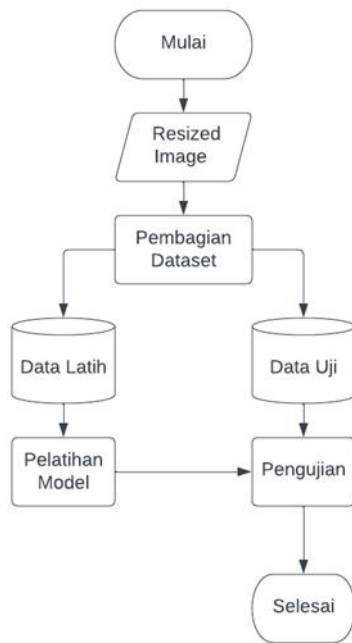
v = second moment

β_1, β_2 = Exponential decay rates.

α = step size atau learning rate

ϵ = angka yang sangat kecil untuk mencegah pembagian dengan nol dalam Implementasi (e. g 10^{-8})

III. PERANCANGANA SISTEM



GAMBAR 2.

Diagram Alur Pelatihan dan Pengujian Model

Pada proses pelatihan model menggunakan CNN dengan arsitektur lima *hidden layer* alur pelatihan dan pengujian model seperti gambar 5. Pada umumnya arsitektur CNN memiliki dua proses utama, yaitu proses *feature extraction* dan *klasifikasi*. Arsitektur CNN memiliki beberapa operasi layer diantaranya yaitu, Convolutional Layer, Aktifasi ReLU, Pooling Layer, Fully Connected Layer, dan diakhiri dengan Aktifasi Softmax. Pada input gambar menggunakan citra MRI *grayscale* dengan ukuran 176×208. Tahap selanjutnya, input citra akan masuk ke dalam proses konvolusi, aktifasi ReLU, dan pooling yang berada pada tahap *feature learning*.

Kemudian masuk ke tahap terakhir yaitu *classification*. Pada tahap ini akan terjadi proses *dropout* yaitu untuk menghilangkan secara sementara *neuron-neuron* yang tidak digunakan dan proses *flatten* (perampingan) yang merupakan proses mengubah *feature map* hasil pooling menjadi *vector*. Proses terakhir adalah aktivasi *softmax*, digunakan untuk menentukan klasifikasi nilai dari kelas citra pada *hidden layer*. Namun hasil dari aktivasi softmax masih berbentuk probabilitas maka agar hasil dapat diklasifikasikan berdasarkan label kelas yang telah ditetapkan dilakukan normalisasi pada hasil prediksi dengan memberi *threshold* pada proses aktivasi softmax.

Adapun *threshold* yang digunakan adalah pada saat hasil probabilitas prediksi melebihi atau sama dengan 0.5, probabilitas yang diprediksi akan memiliki kelas 1, jika dibawah 0,5 maka akan di klasifikasikan sebagai kelas 0. Setelah melalui proses pelatihan model, maka *output* dari arsitektur CNN perlu dilakukan pengujian kembali

kemampuan klasifikasinya dengan mengukur performansi sistem.

Setelah proses pelatihan dan pengujian model dilakukan, maka output dari arsitektur CNN perlu diuji kembali kemampuan klasifikasinya dengan mengukur performa sistem. Terdapat empat parameter yang akan membuktikan kemampuan arsitektur yang diusulkan yaitu diantaranya akurasi, presisi, recall, dan F1-score dengan ditunjukkan pada persamaan 12,13,14, dan 15.

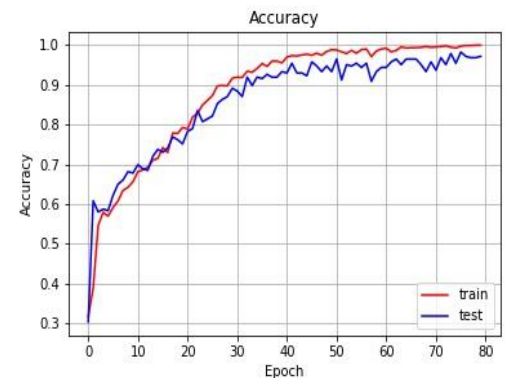
$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (12)$$

$$Presisi = \frac{TP}{TP+FP} \quad (13)$$

$$Recall = \frac{TP}{TP+FN} \quad (14)$$

$$F1score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (15)$$

TP (*True Positive*) merupakan data positif yang di prediksi benar (positif). TN (*True Negative*) merupakan data negatif yang diprediksi benar (negatif). FP (*False Positive*)



merupakan data negatif namun di prediksi sebagai data positif. FN (*False Negative*) merupakan data positif namun di prediksi sebagai data negatif.

IV. HASIL DAN PEMBAHASAN


Terdapat lima skenario yang akan dilakukan pada tahap perancangan pengujian. Skenario yang akan diuji berawal dari pencarian *size* citra, *optimizer*, dilanjutkan mencari *learning rate*, *epoch*, dan *batch size* yang terbaik. Data yang akan diuji adalah citra MRI berukuran 176×208. Jumlah data yang digunakan pada penelitian kali ini adalah 1340 data citra MRI yang bagi menjadi 80% data latih dan 20% data uji. Dari pengujian kelima skenario tersebut dapat diambil hasil yang memiliki nilai akurasi yang tinggi. Skenario tersebut adalah *resize* 224 x 224, *optimizer* Adam, *learning rate* 0.0001, *epoch* 80, dan *batch size* 16. Kinerja terbaik sistem yang didapat dari hasil pengujian dengan skenario tersebut dapat dilihat pada Gambar 6.

```
[INFO] evaluating network...
18/18 [=====] - 0s 7ms/step
          precision    recall  f1-score   support

 MildDemented      0.97      0.98      0.97       97
 ModerateDemented  1.00      0.92      0.96       12
 NonDemented       0.88      0.92      0.90       90
 VeryMildDemented  0.90      0.86      0.88       87

 accuracy          0.92       286
 macro avg         0.94      0.92      0.93       286
 weighted avg      0.92      0.92      0.92       286
```


GAMBAR 6.
Hasil Pengujian



GAMBAR 7.
Confusion Matrix dari Pengujian

Berdasarkan Gambar 7 dapat diketahui bahwa Sebagian besar citra diklasifikasikan dengan benar oleh sistem yang telah dibuat. Terdapat sebanyak 265 citra dari 286 citra diklasifikasikan dengan benar. Kesalahan klasifikasi yang terjadi sebanyak 21 dari 286 citra. Kesalahan tersebut terjadi pada kelas *Mild Demented* sebanyak 2 citra, kelas *Non-demented* sebanyak 7 citra dan kelas *Very Mild Demented* sebanyak 12 citra.

Kita dapat mengetahui apakah model yang dibuat mengalami *overfitting* atau *underfitting* berdasarkan grafik model yang didapat. Berdasarkan Gambar 8 dapat diketahui bahwa model yang telah dibuat memiliki hasil yang tidak *overfitting* karena jarak hasil *training* dan *testing* tidak berjauhan atau berhimpitan begitu pun dengan hasil *training loss* dan *testing loss*.



GAMBAR 8.

Tingkat akurasi dan *loss* yang di dapat dari proses pelatihan model

V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, maka dapat diambil kesimpulan bahwa sistem yang didesain menggunakan CNN dengan 5 *hidden layer* dapat mengklasifikasikan penyakit Alzheimer berdasarkan kelasnya. Adapun parameter yang mempengaruhi sistem dalam mengklasifikasikan penyakit Alzheimer adalah size

citra, optimizer, learning rate, epoch, dan batch size. Dapat dibuktikan dengan pengubahan nilai dari parameter tersebut dapat mempengaruhi perubahan akurasi, presisi, recall, dan f1-score. Hasil pengujian yang telah dilakukan dengan menggunakan lima parameter telah disebutkan menghasilkan performa sistem terbaik dengan nilai akurasi yang tinggi dan sistem yang tidak *overfitting*. Hasil yang diperoleh adalah resize citra 224x224, optimizer Adam, learning rate 0,0001, epoch 80 dan batch size 16 menghasilkan tingkat akurasi sebesar 92%, tingkat presisi sebesar 94%, recall sebesar 92%, dan f1-score sebesar 93%.

REFERENSI

- [1] L. G. Apostolova, "Alzheimer Disease," Continuum (N Y), 2016.
- [2] J. Gaugler, B. James, T. Johnson, J. Reimer, M. Solis, and J. Weuve, "Alzheimer's Disease Facts and Figures," Chicago, 2022. Accessed: Dec. 14, 2022. [Online]. Available: alz.org
- [3] X. Lu, H. Wu, and Y. Zeng, "Classification of Alzheimer's disease in MobileNet," in Journal of Physics: Conference Series, Nov. 2019, vol. 1345, no. 4. doi: 10.1088/1742-6596/1345/4/042012.
- [4] Z. S. Khachaturian, "Conference R Diagnosis of Alzheimer's Disease," 1985. [Online]. Available: <http://archneur.jamanetwork.com/>
- [5] Alzheimer Indonesia, "Statistik Tentang Demensia," alzi.or.id, 2019. <https://alzi.or.id/statistik-tentang-demensia/> (accessed Jan. 06, 2023).
- [6] P. C. Muhammed Raees and V. Thomas, "Automated detection of Alzheimer's Disease using Deep Learning in MRI," in Journal of Physics: Conference Series, May 2021, vol. 1921, no. 1. doi: 10.1088/1742-6596/1921/1/012024.
- [7] M. C. Henry-Feugeas, "MRI of the 'Alzheimer syndrome,'" Journal of Neuroradiology, vol. 34, no. 4. pp. 220–227, Oct. 2007. doi: 10.1016/j.neurad.2007.07.002.
- [8] H. Ji, Z. Liu, W. Q. Yan, and R. Klette, "Early diagnosis of Alzheimer's disease using deep learning," in ACM International Conference Proceeding Series, Jun. 2019, pp. 87–91. doi: 10.1145/3341016.3341024.
- [9] A. Farooq, S. M. Anwar, M. Awais, and S. Rehman, "A Deep CNN based Multi-class Classification of Alzheimer's Disease using MRI," in IEEE Instrumentation and Measurement Society prior to the acceptance and publication., 2017, pp. 1–7.
- [10] S. H. Wang, P. Phillips, Y. Sui, B. Liu, M. Yang, and H. Cheng, "Classification of Alzheimer's Disease Based on Eight-Layer Convolutional Neural Network with Leaky Rectified Linear Unit and Max Pooling," J Med Syst, vol. 42, no. 5, May 2018, doi: 10.1007/s10916-018-0932-7.

- [11] K. A. Jellinger, "Alzheimer 100 - Highlights in the history of Alzheimer research," *Journal of Neural Transmission*, vol. 113, no. 11. pp. 1603–1623, Nov. 2006. doi: 10.1007/s00702-006-0578-3.
- [12] Sarvesh Dubey, "Alzheimer's Dataset (4 class of Images)," Kaggle, 2020.
- [13] Y. N. Fu'Adah, I. Wijayanto, N. K. C. Pratiwi, F. F. Taliningsih, S. Rizal, and M. A. Pramudito, "Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture," in *Journal of Physics: Conference Series*, Mar. 2021, vol. 1844, no. 1. doi: 10.1088/1742-6596/1844/1/012020.
- [14] S. Khan, H. Rahmani, S. Afaq, A. Shah, and M. Bennamoun, "A Guide to Convolutional Neural Networks for Computer Vision."
- [15] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [16] S. Ruder, "An overview of gradient descent optimization algorithms," Sep. 2016, [Online]. Available: <http://arxiv.org/abs/1609.04747>
- [17] G. Habib and S. Qureshi, "Optimization and acceleration of convolutional neural networks: A survey," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 7. King Saud bin Abdulaziz University, pp. 4244–4268, Jul. 01, 2022. doi: 10.1016/j.jksuci.2020.10.004
- 