Klasifikasi Alzheimer Berdasarkan Sinyal EEG Menggunakan Model 1D CNN

1st Inayatur Rodliyah
Fakultas Teknik Biomedis
Telkom University Purwokerto
Purwokerto, Indonesia
inayatur@student.telkomuniversity.ac.id

2nd Dodi Zulherman
Fakultas Teknik Biomedis
Telkom University Purwokerto
Purwokerto, Indonesia
zulherman@telkomuniversity.ac.id

3rd Sevia Indah Purnama
Fakultas Teknik Biomedis
Telkom University Purwokerto
Purwokerto, Indonesia
seviaindah@telkomuniversity.ac.id

Abstrak* — Penyakit Alzheimer merupakan gangguan neurodegenerative yang ditandai dengan penurunan fungsi kognitif dan memori. Metode konvensional seperti MRI dan PET memiliki keterbatasan karena biaya tinggi dan prosedur yang invasive. Penelitian ini menggunakan sinyal Elektroensefalografi (EEG) sebagai metode alternatif yang lebih sederhana dan non-invasif, dengan mengembangkan model klasifikasi alzheimer dua kelas yaitu individu sehat (healthy control) dan kelas alzheimer menggunakan metode One-Dimensional Convolutional Neural Network (1D CNN). Dataset yang digunakan merupakan dataset EEG publik yaitu Kaggle dan Open Science Framework (OSF) dengan beberapa kanal sinyal otak, dan jumlah total rekaman dataset pertama dan dataset kedua yaitu 852117 rekaman. Tahapan penelitian meliputi preprocessing data, pembagian data dengan data latih 60%, data uji 20% dan data validasi 20% menggunakan metode stratified split, dan pelatihan model dengan optimizer Adam dan Teknik earlystopping. Hasil penelitian menunjukkan model mencapai akurasi hingga 99% pada dataset pertama, namun mengalami penurunan performa pada dataset kedua dengan akurasi sekitar 61%-66%. Penelitian ini menunjukkan bahwa 1D CNN berpotensi digunakan sebagai metode deteksi dini Alzheimer berbasis EEG yang sederhana dan non-invasive.

***Kata kunci*— Elektroensefalografi (EEG), Alzheimer, *One-Dimensional Convolutional Neural Network* (1D CNN), *deep learning*, klasifikasi**

I. PENDAHULUAN

Penyakit Alzheimer merupakan jenis demensia yang paling umum dan menjadi salah satu masalah kesehatan global yang terus meningkat [1]. Penyakit ini ditandai oleh degenerasi sel saraf secara meningkat yang menyebabkan penurunan fungsi memori, kemampuan berpikir, dan aktivitas sehari-hari serta penderita dapat mengalami kesulitan mengenali anggota keluarga maupun lingkungan sekitar [2][3].

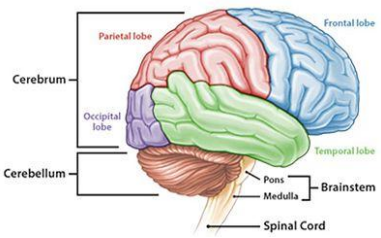
Metode diagnosis yang umum digunakan yaitu *Magnetic Resonance Imaging* (MRI), *Positron Emission Tomography* (PET), pemeriksaan neuropsikologi, dan analisis cairan serebrospinal. Metode-metode tersebut memerlukan biaya yang relatif tinggi dan tidak selalu tersedia pada seluruh fasilitas kesehatan. Oleh karena itu, diperlukan metode alternatif yang lebih sederhana, cepat dan ekonomis [4] [5]. Elektroensefalografi (EEG) merupakan teknik perekaman aktivitas listrik otak yang bersifat non-invasif. Pada penderita alzheimer terjadi perubahan pola aktivitas EEG yaitu peningkatan gelombang frekuensi rendah seperti pita delta dan pita theta dan peningkatan aktivitas gelombang alpha dan beta [6] [7].

Perkembangan *deep learning* memungkinkan proses ekstraksi fitur dilakukan secara otomatis tanpa memerlukan *feature engineering* yang kompleks. Salah satu metode yang banyak digunakan untuk data sinyal adalah *One-Dimensional Convolutional Neural Network* (1D CNN). Metode ini mampu mempelajari pola temporal pada sinyal EEG secara efektif sehingga berpotensi meningkatkan akurasi kalsifikasi alzheimer [8] [9]

II. KAJIAN TEORI

A. Otak

Otak manusia merupakan sistem biologis paling kompleks, dengan otak yang matang terdiri dari lebih 100 miliar neuron. Otak manusia terdiri dari tiga bagian utama yaitu otak besar (serebrum), otak kecil (serebelum), dan batang otak *(brainstorm)*. Otak besar dibagi menjadi dua hemisfer (kiri dan kanan), dan terdiri dari empat lobus yaitu lobus frontal, lobus parietal, lobus temporal, dan lobus oksipital. Otak kecil mengontrol gerakan volunter dan menerima informasi sensorik dari otak dan sumsum tulang belakang untuk menyempurnakan aktivitas motorik. Otak kecil juga membantu fungsi kognitif seperti perhatian, Bahasa, respon senang, dan memori rasa takut. Batang otak berfungsi sebagai jembatan yang menghubungkan otak besar dan otak kecil ke sumsum tulang belakang, juga menampung pusat utama dalam menjalankan fungsi otonom seperti bernafas, dan lainnya [10].

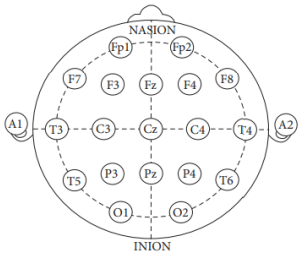


GAMBAR 1
(Anatomi Otak Manusia [11])

Otak merupakan organ kecil yang tersimpan di dalam batok kepala yang merupakan pusat sistem saraf dan berfungsi sebagai pusat kendali dan koordinasi seluruh aktivitas biologis, fisik, dan sosial dari seluruh tubuh. Batok kepala manusia rata-rata mampu menampung volume sekitar 1700 ml yang berisi 1400 ml (80%) otak, 150 ml (10%) cairan otak. Manusia terlahir dengan berat sekitar 1300-1400 gram (2% berat tubuh). Otak merupakan sumber dari seluruh pemikiran, perasaan, keinginan, dan juga merupakan penjaga memori. Di dalam otak terdapat 100 miliar sel neuron yang mampu membangun 10000 cabang dendrit bahkan bisa mencapai 100.000, sehingga akan terbentuk 1000 triliun sinapsis [12]

B. *Electoencephalograpy* (EEG)

Aktivitas neuron otak dapat direkam dengan menggunakan elektroda yang ditempatkan di kulit kepala, yaitu menggunakan *Electroenchephalography* (EEG). EEG memungkinkan untuk melihat bentuk gelombang otak yang terbagi menjadi 5 frekuensi dan kondisi yang berbeda yaitu gelombang delta ketika tertidur nyenyak, gelombang theta ketika tidur ringan dan relaksasi, gelombang alpha ketika mata terpejam dan melamun, gelombang beta ketika dalam kesadaran penuh dan fokus, dan gelombang gamma memproses informasi dan kesadaran tinggi [4].

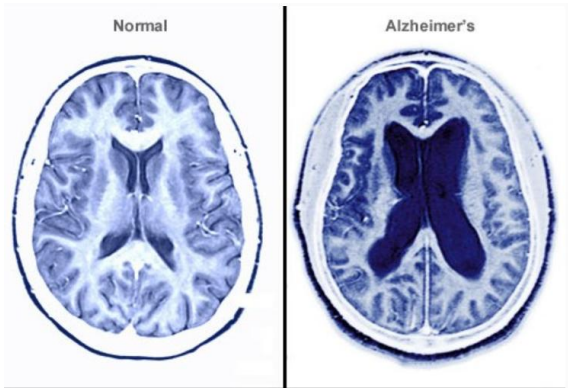


GAMBAR 2
(Penempatan EEG International 10-20 System [13])

Electroencephalography (EEG) merupakan metode perekaman aktivitas listrik otak menggunakan elektroda yang ditempatkan pada permukaan kulit berdasarkan sistem penempatan elektroda internasional 10-20. EEG banyak digunakan karena relatif murah, bersifat non-invasif, dan dapat merekam aktivitas listrik otak secara langsung. Kanal elektroda yang diletakkan mewakili lobus otak yang berbeda. Lobus frontal (Fp1, Fp2, F3, Fz, F4, F7, F8), lobus temporal (T3, T4, T5), dan lobus sentral (C3, Cz, C4) [14] [15]. Secara umum sinyal EEG dibagi menjadi beberapa rentang frekuensi, yaitu delta (0.5-4 Hz), theta (4-8 Hz), alpha (8-13), beta (13-30 Hz), dan gamma (>30 HZ). Setiap rentang frekuensi memiliki karakteristik yang berbeda dan berkaitan dengan kondisi fisiologis tertentu pada otak [16].

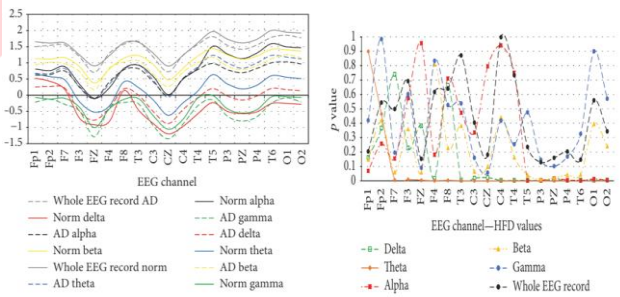
C. Penyakit Alzheimer

Penyakit Alzheimer merupakan gangguan *neurodegenarif* progresif yang menyebabkan penurunan fungsi kognitif, memori, kemampuan berpikir, dan perilaku [17]. Penyakit ini menjadi penyebab utama demensia pada populasi lanjut uji yang ditandai dengan kerusakan neuron yang berlangsung secara bertahap [1].



GAMBAR 3
(Otak Individu Sehat dan Penderita Alzheimer [18])

Perubahan biologis utama pada penderita alzheimer meliputi pembentukan β-amyloid dan *neurofibrillary tangles* yang menyebabkan terganggunya komunikasi antar sel saraf [3][18]. Seiring perkembangan penyakit, penderita akan mengalami kesulitan mengingat informasi, gangguan bahasa, kemampuan mengambil keputusan, dan kehilangan kemampuan melakukan aktivitas sehari-hari [19].



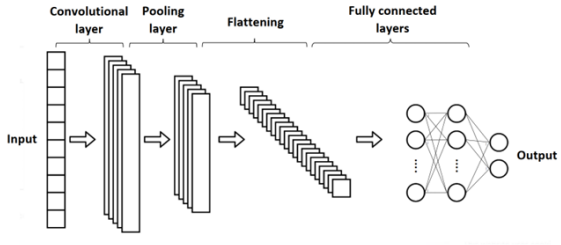
GAMBAR 4
(EEG *Biomarkers* [20])

Gambar 4 Kompleksitas sinyal EEG pada penderita Alzheimer secara konsisten lebih rendah dibandingkan dengan individu sehat. Hal ini menunjukkan bahwa aktivitas otak penderita Alzheimer memiliki pola yang lebih sederhana dibandingkan individu sehat. Ketika sinyal dibagi lagi ke dalam beberapa pita frekuensi, semakin terlihat perbedaannya, terutama pada pita delta, theta, dan alpha. Pita theta menunjukkan perbedaan yang paling kuat, karena hasil statistik menunjukkan pemisahan yang jelas antara penderita Alzheimer dengan individu sehat [20]

D. *One-Dimensional Convolutional Neural Network*

Convolitional Neural Network (CNN) merupakan salah satu metode *deep learning* yang banyak digunakan dalam tugas klasifikasi karena dapat melakukan ekstraksi fitur secara otomatis. Pada data sinyal satu dimensi seperti EEG, *One-Dimensional Convolutional Neural Network* (1D CNN) digunakan untuk melakukan operasi konvolusi pada data satu dimensi [9].

Arsitektur 1D CNN umumnya terdiri dari *convolutional layer, pooling layer, flatten layer*, dan *fully connected layer. Convolution layer* berfungsi mengekstraksi fitur penting dari sinyal EEG, sedangkan *pooling layer* untuk mengurangi dimensi data dan kompleksitas komputasi. Setelah proses ektrakssi fitur selesai, data akan diteruskan ke *fully connected lalyer* untuk melakukan klasifikasi kelas [21]

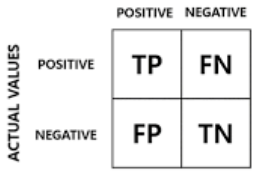


GAMBAR 5
(Arsitektur Model 1D CNN [9])

Keunggulan utama dari 1D CNN yakni kemampuannya dalam mempelajari pola temporal secara otomatis tanpa memerlukan proses ekstraksi fitur manual yang kompleks. Maka dari itu metode banyak digunakan pada berbagai penelitian klasifikasi sinyal biomedis, termasuk EEG untuk deteksi penyakit *neurodegenerative* [9].

E. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengukur kemampuan sistem dalam mengklasifikasikan data EEG secara tepat. Seperti *accuracy, precission, recall, F1-score*, dan *confusion matrix. Confusion matrix* terdiri dari empat komponen utama *True Positive* (TP) adalah jumlah data positif yang diprediksi benar, *True Negative* (TN) merupakan jumlah data negatif yang diprediksi benar, *False Positive* (FP) yaitu jumlah data negatif yang diprediksi positif, dan *False Negative* (FN) adalah jumlah data positif yang diprediksi negatif.



GAMBAR 6
(Metrik Evaluasi [22])

Akurasi adalah ukuran seberapa banyak prediksi yang benar dari semua prediksi yang dibuat oleh model.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Presisi adalah rasio antara prediksi positif yang benar dengan total prediksi positif.

$$Precission = \frac{TP}{TP + FP} \quad (2)$$

Recall atau sensitivitas mengukur seberapa banyak kasus positif dari semua data yang aktualnya positif. *Recall* adalah rasio antara prediksi positif yang benar dengan total jumlah data yang sebenarnya positif.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-score adalah rata-rata harmonis antara presisi dan *recall*, memberikan keseimbangan antara presisi dan *recall*, yang berguna ketika keduanya sama pentingnya.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

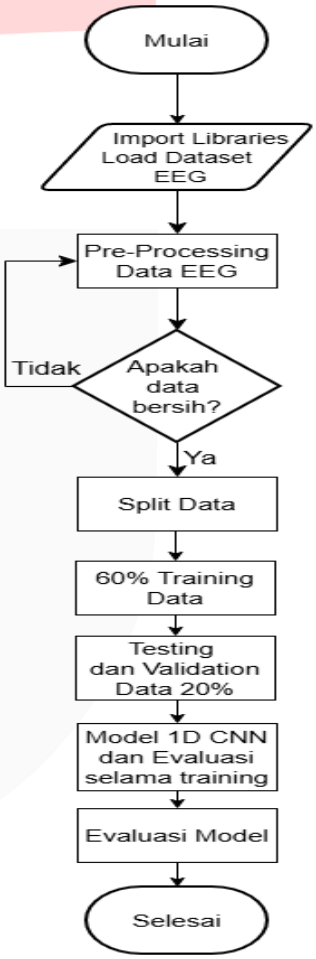
III. METODE

A. Dataset

Data yang digunakan dalam analisis adalah data sekunder https://www.kaggle.com/datasets/ucimachinelearning/eeg-alzheimers-dataset dan https://osf.io/2v5md/overview. Dataset pertama yang digunakan dalam penelitian ini merupakan data tabular (csv) berdasarkan penempatan elektroda EEG standar berdasarkan sistem internasional 10 – 20 yang didapat dari Kaggle oleh UCI *Machine Learning* [23]. Dataset kedua yang digunakan dalam penelitian ini merupakan data .txt berdasarkan penempatan elektroda dalam kondisi mata terbuka dan mata tertutup, yang didapat dari *Open Science Framework* (OSF) [24].

B. Perancangan Sistem

Proses perancangan sistem melibatkan pemilihan metode *One-Dimensional Convolutional Neural Network* (1D CNN) yang sesuai untuk data sinyal EEG, pengaturan parameter penting seperti *learning rate, epoch,* dan *batch size*, serta penentuan arsitektur jaringan CNN yang digunakan dalam klasifikasi Alzheimer. Hasil perancangan sistem diharapkan mampu menghasilkan model yang dapat mengenali model pola sinyal EEG penderita Alzheimer dengan akurasi tinggi. Alur kerja sistem secara keseluruhan dapat dilihat pada gambar berikut.



GAMBAR 7
(Perancangan Sistem 1D CNN)

a. Mulai
Ketika sistem dijalankan dan dataset EEG didapatkan maka proses perancangan sistem dimulai

b. *Import Libraries* dan *Load Dataset EEG*
Library yang diperlukan untuk dataset pertama dan dataset kedua diimpor agar semua fungsi yang dibutuhkan dalam sistem dapat digunakan secara baik.

Load dataset EEG untuk dataset pertama membaca file .csv dan untuk dataset kedua membaca file .txt

c. *Preprocessing* Data EEG

Untuk dataset pertama *preprocessing* yang dilakukan meliputi normalisasi, pemeriksaan *outlier*, pelabelan data, dan *reshape* data.

Untuk dataset kedua meliputi *filtering* sinyal, *standarisasi channel* EEG, pelabelan data, penanganan ketidakseimbangan data, normalisasi, dan *reshape* data

d. Apakah data bersih?

Jika data bersih maka lanjut ke proses selanjutnya jika data tidak bersih maka akan dilakukan *preprocessing* tambahan.

e. Split Data

Data dibagi menjaddi tiga yaitu 60% data latih, 20% data validasi, dan 20% data uji.

f. Model 1D CNN dan Evaluasi selama *training*

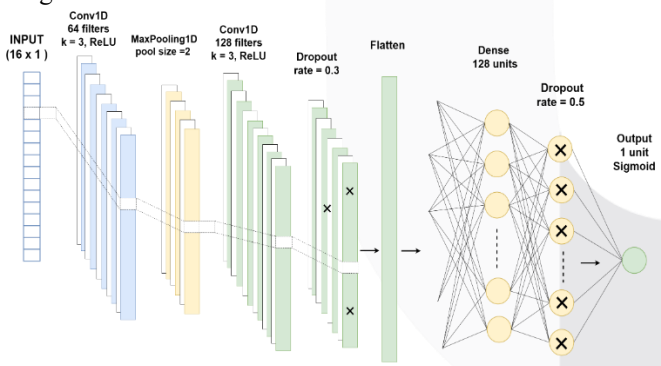
Model dikompilasi menggunakan *optimizer Adam* dengan fungsi *binary cross entropy loss* untuk dataset pertama dan *sparse categorical crossentropy* untuk dataset kedua. Model diecaluasi menggunakan metrik akurasi, presisi, *recall, F1-score*, dan *confusion matrix*.

g. Selesai

Proses klasifikasi selesai dan sistem menghentikan eksekusi

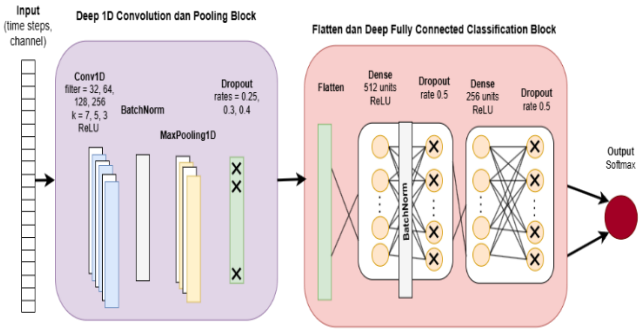
C. Arsitektur Model 1D CNN

Arsitektur model CNN yang diracanag terdiri dari beberapa lapisan yang berfungsi untuk mengekstraksi fitur dan melakukan klasifikasi terhadap sinyal EEG. Model dikembangkan dan dijalankan menggunakan Google Colab dengan bantuan *TensorFlow*



GAMBAR 8
(Arsitektur Model Dataset Pertama)

Model CNN dilatih menggunakan data EEG dari dataset Kaggle EEG *Alzheiemer's Dataset* terdiri dari 17 kolom dengan 16 kanal EEG dan 1 kolom label status.



GAMBAR 9
(Arsitektur Model Dataset Kedua)

Model CNN dilatih menggunakan data sinyal EEG dari dataset kedua yang telah melaui tahap *preprocessing* termasuk *filtering, segmentasi,* dan penyeimbangan data. Data yang digunakan merupakan hasil segmentasi sinyal EEG dalam bentuk *time-series* yang telah disesuaikan dengan format input model 1D CNN

D. Variasi *Hyperparameter*

Variasi *hyperparameter* digunakan untuk mengetahui pengaruh parameter terhadap performa model. Parameter yang di variasikan yaitu parameter *learning rate, batch size,* dan jumlah *epoch*.

TABEL 1
(Varaiasi *Epoch)*

Percobaan	*Epoch*	*Learning Rate*	*Batch Size*
1	15	0.001	32
2	25		
3	50		

Pada Tabel 1 percobaan 1, 2, dan 3 memvariasikan jumlah *epoch* dengan nilai *learning rate* 0.001 dan *batch size* 32 untuk melihat pengaruh lama pelatihan terhadap kemampuan model dalam mempelajari pola data.

TABEL 2
(Variasi *Learning Rate)*

Percobaan	*Learning Rate*	*Batch Size*	*Epoch*
1	0.001	32	25
4	0.0005		
5	0.0001		

Pada Tabel 2 memvariasikan jumlah *learning rate* dengan nilai lebih kecil yaitu 0.0005 dan 0.0001 untuk menganalisis pengaruh kecepatan pembelajaran model terhadap kestabilan dan konvergensi proses *training*, dengan *batch size* 32 dan *epoch* 25.

TABEL 3
(Variasi *Batch Size)*

Percobaan	*Batch Size*	*Epoch*	*Learning Rate*
6	16	25	0.001
2	32		
7	64		

Pada Tabel 3 memvariasikan jumlah *batch* size yaitu 16 dan 64 dengan *learning rate* 0.001 dan *epoch* 25 untuk mengetahui pengaruh ukuran *batch* terhadap stabilitas gradien serta perfoma model. Dengan adanya variasi ini, diharapkan dapat memperoleh kombinari *hyperparameter* yang paling optimal dalam menghasilkan performa klasifikasi yang baik

IV. HASIL DAN PEMBAHASAN

A. Hasil Performa model

Tahap evaluasi model dilakukan untuk mengukur performa model terhadap data yang tidak digunakan selama proses pelatihan. Evaluasi dilakukan dengan menggunakan data *testing* untuk memastikan bahwa model tidak hanya memiliki performa yang bagus pada data *training*, namun juga dapat memberikan prediksi yang akurat pada data baru. Pada penelitian ini, evaluasi pada masing-masing variasi *hyperparameter* menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*.

TABEL 4
(Hasil Performa Model Dataset Pertama)

Percobaan ke	*Accuracy*	*Precission*	*Recall*	*F1-score*
1	99.86%	99.90%	99.87%	99.88%
2	99.86%	99.88%	99.88%	99.88%
3	99.88%	99.90%	99.90%	99.90%
4	99.87%	99.94%	99.84%	99.89%
5	99.89%	99.91%	99.90%	99.91%
6	99.83%	99.90%	99.82%	99.86%
7	99.89%	99.95%	99.87%	99.91%

Berdasarkan hasil dari seluruh percobaan pada dataset pertama, model 1D CNN menunjukkan performa yang tinggi dan konsisten dalam klasifikasi sinyal EEG antara individu sehat dan penderita Alzheimer. Nilai akurasi yang didapatkan berada di antara 99.83%-99.89%, menunjukkan hampir seluruh data *testing* berhasil diklasifikasikan dengan benar oleh model. Nilai *precission, recal* dan *F1-score* pada seluruh percobaan berada di atas 99.00% menunjukkan model memiliki kemampuan yang baik dalam membedakan kelas individu sehat dan penderita Alzheimer.

Nilai *precission* tinggi menunjukkan prediksi posistif yang dihasilkan model Sebagian besar benar, sehingga kesalahan dalam mengklasifikasikan individu sehat sebagai penderita Alzheimer *(false positive)* kecil. Sedangkan nilai *recall* yang tinggi menunjukkan hampir seluruh data penderita alzheimer berhasil terdeteksi dengan baik oleh model, sehingga kesalahan dalam mendeteksi kasus Alzheimer *(false negative)* sedikit.

TABEL 5
(Hasil Performa Model Dataset Kedua)

Percobaan ke	*Accuracy*	*Precission*	*Recall*	*F1-score*
1	65.13%	59.33%	96.22%	73.40%
2	65.21%	59.06%	99.18%	74.03%
3	63.57%	93.19%	29.28%	44.56%
4	64.72%	58.75%	98.85%	73.70%
5	61.60%	96.08%	24.18%	38.63%
6	65.87%	59.72%	97.72%	74.08%
7	65.05%	58.96%	99.01%	73.91%

Berdasarkan hasil seluruh percobaan pada dataset kedua, model 1D CNN yang digunakan menunjukkan performa yang cukup baik, dengan nilai akurasi yang didapatkan antara 61.60% - 65.87%, menunjukkan Sebagian besar data *testing* berhasil diklasifikasikan dengan benar oleh model. Nilai *precission, recall, F1-score* pada semua percobaan menunjukkan pola yang bervariasi. Sebagian besar percobaan nilai *recall* sangat tinggi yaitu di atas 96% menunjukkan hampir seluruh data penderita Alzheimer berhasil terdeteksi dengan baik oleh model. Dalam hal ini berarti kesalahan dalam mendeteksi kasus Alzheimer *(False Negative)* relative kecil. Namun nilai *precision* yang didapatkan rendah berada diantara 58% - 60% pada sebagian percobaan.

Hal ini menunjukkan masih banyak individu sehat yang diklasifikasikan sebagai penderita Alzheimer *(False Positive)*. Meskipun model sangat sensitif dalam mendeteksi Alzheimer, namun model masih kurang optimal dalam membedakan individu sehat. Terdapat beberapa percobaan yang mendapatkan nilai *precision* sangat tinggi namun nilai *recall* yang didapatkan sangat rendah. Kondisi ini menunjukkan model menjadi terlalu konservatif dalam memprediksi Alzheimer, sehingga banyak kasus penderita Alzheimer yang tidak terdeteksi. Hal ini memberikan dampak turunnya nilai *F1-score* yang cukup signifikan

B. Hasil *Confusion Matrix*

Berdasarkan hasil dari seluruh percobaan yang dilakukan untuk dataset pertama dan dataset kedua, evaluasi hasil prediksi model dengan membandingkan nilai aktual dan nilai prediksi menggunakan *confusion* matrix.

TABEL 6
(Hasil *Confusion Matrix* Dataset Pertama)

Percobaan ke	*True Negative (TN)*	*False Negative (FN)*	*False Positive (FP)*	*True Positive (TP)*
1	67221	135	107	102265
2	67208	124	120	102276
3	67221	104	107	102296
4	67258	156	70	102244
5	67239	102	89	102298
6	67149	97	179	102303
7	67279	138	49	102262

Pada Tabel terlihat bahwa hasil *confusion matrix* pada seluruh percobaan nilai TP dan TN mendapatkan hasil yang tinggi, menunjukkan bahwa Sebagian besar data berhasil diklasifikasikan dengan benar oleh model. Sedangkan jumlah kesalahan klasifikasi yang dapat dilihat pada nilai FP dan FN lebih kecil dibandingkan dengan total data yang digunakan. Nilai FP yang kecil artinya model jarang mengklasifikasikan individu sehat sebagai penderita Alzheimer. Hal ini penting karena bisa mengurangi kemungkinan terjadinya diagnosis yang salah pada individu sehat yang tidak mengalami Alzheimer. Begitu juga dengan nilai FN yang kecil menunjukkan model mampu mendeteksi hampir semua kasus alzheimer dengan baik. Dalam dunia kesehatan, kesalahan dalam mendeteksi dapat menyebabkan keterlambatan penanganan.

Berdasarkan hasil seluruh percobaan, jumlah kesalahan klasifikasi cenderung stabil dan tidak memperlihatkan perbedaan yang signifikan antar percobaan. Hal ini menunjukkan model memiliki tingkat konsistensi yang baik dalam melakukan prediksi. Selain itu, tingginya nilai TP dan TN menjelaskan hasil evaluasi sebelumnya yang menunjukkan model memiliki nilai *accuracy, precission, recall,* dan *F1-score* yang tinggi. Berdasarkan hasil *confusion matrix* menunjukkan model 1D CNN yang digunakan dapat melakukan klasifikasi dengan tingkat kesalahan yang kecil dan memiliki keseimbangan yang baik dalam mendeteksi kelas individu sehat dan penderita Alzheimer.

TABEL 7
(Hasil *Confusion Matrix* Dataset Kedua)

Percobaan ke	*True Negative (TN)*	*False Negative (FN)*	*False Positive (FP)*	*True Positive (TP)*
1	207	23	401	585
2	190	5	418	603
3	595	430	13	178
4	186	7	422	601
5	155	1	453	607
6	208	15	400	593
7	189	6	419	602

Pada Tabel 7 terlihat bahwa hasil *confusion matrix* pada seluruh percobaan dataset kedua, mendapatkan nilai yang tinggi pada TP pada hampir semua skenario percobaan yang dilakukan. Menunjukkan Sebagian besar data penderita Alzheimer berhasil diklasifikasikan dengan benar oleh model. Pada beberapa percobaan nilai TN juga cukup tinggi di beberapa percobaan seperti pada percobaan ketiga yang artinya kemampuan model dalam mengenali individu sehat sangat baik. Akan tetapi jumlah kesalahan klasifikasi yang dapat dilihat pada nilai FP dan FN bervariasi antar percobaan. Nilai *False Negative* yang kecil menunjukkan model mampu mendeteksi hampir seluruh penderita Alzheimer dengan baik. Sedangkan nilai *False Positive* yang tinggi menunjukkan Sebagian besar percobaan model masih sering mengklasifikasikan individu sehat sebagai penderita Alzheimer.

Perbedaan performa pada percobaan ketiga yang mana nilai FN sangat tinggi menunjukkan model gagal mendeteksi Sebagian besar penderita Alzheimer yang disebabkan oleh besarnya *epoch* yang digunakan sehingga model mengalami *overfitting* dan menjadi condong ke kelas individu sehat. Berdasarkan seluruh percobaan yang dilakukan pada dataset kedua, model menunjukkan konsistensi yang baik dalam mendeteksi penderita alzheiemer dimana nilai *True Positive* yang tinggi dan nilai *False Negative* rendah. Tetapi masih kurang optimal dalam membedakan individu sehat yang dapat dilihat pada tingginya nilai *False Positive*. Model 1D CNN yang digunakan pada dataset kedua mampu mengklasifikasikan penderita Alzheimer dengan tingkat kesalahan yang kecil, namun model masih harus ditingkatkan untuk mengurangi kesalahan pada individu sehat agar mendapatkan keseimbangan performa yang lebih baik antara kelas individu sehat dan kelas penderita Alzheimer.

C. Analisis Hasil Pengujian Dataset Pertama dan Kedua

Berdasarkan hasil pengujian yang sudah dilakukan, model 1D CNN menunjukkan performa yang berbeda pada dataset pertama dan dataset kedua. Pada dataset pertama, model memperoleh akurasi tertinggi sebesar 99.89%, sedangkan pada dataset kedua akurasi tertinggi diperoleh sebesar 65.87%. perbedaan tersebut menunjukkan data yang digunakan memiliki pengaruh terhadap kemampuan model dalam melakukan klasifikasi. Dataset pertama dari Kaggle dalam bentuk data tabular yang terstruktur sehingga dapat langsung digunakan setelah melalui tahap *pre-processing* sederhana, jumlah data yang digunakan mencapai 848640 rekaman sehingga model memiliki cukup data untuk mempelajari pola kelas individu sehat dan penderita alzheimer .

Pada dataset kedua didapat dari OSF yang tersedia dalam format *Single-Channel Separation*, yaitu setiap kanal EEG disimpan secara terpisah sehingga memerlukan *pre-processing* yang lebih kompleks. Tahap pembacaan data per *channel*, *filtering sinyal* menggunakan *bandpass filter*, *standarisasi channel*, penyeimbangan data menggunakan *random oversampling,* normalisasi, dan *reshape data* sebeleum masuk ke model. Jumlah data pada dataset kedua lebih sedikit dibanding dataset pertama yaitu 3477 rekaman.

Pada dataset pertama, seluruh hasil kombinasi *hyperparameter* menghasilkan performa yang sangat tinggi dengan nilai *accuracy* pada rentang 99.83%-99.89%. Perbedaan nilai *accuracy* antar percobaan kecil, menunjukkan model memiliki kestabilan yang baik terhadap perubahan *hrperparameter*. Nilai *precision, recall,* dan *F1-score* di atas 99%, menunjukkan model dapat mengklasifikasikan data individu sehat dan penderita alzheimer dengan sangat baik pada seluruh pengujian. Hasil yang paling baik didapatkan pada kombinasi *learning rate* 0.001, *batch size* 64, dan *epoch* 25 dengan *accuracy* 99.89%, *precision* 99.95%, *recall* 99.87%, dan *F1-score* 99.91%. Sedangkan variasi *hyperparameter* pada dataset kedua memberikan pengaruh yang lebih besar terhadap performa model. Nilai *accuracy* yang didapat pada rentang 61.60% - 65.87%, sedangkan nilai *recall* menunjukkan variasi yang cukup signifikan. Hasil yang paling baik didapat pada kombinasi *learning rate* 0.001, *batch size* 16, dan *epoch* 25 dengan *accuracy* 65.87%, *precision* 59.72%, *recall* 97.72%, dan *F1-score* 74.08%. Tingginya nilai *recall* menunjukkan model dapat mendeteksi sebagian besar sampel alzheimer dengan baik, walupun nilai *precision* rendah karena tingginya jumlah *false positive*.

Pengaruh variasi *epoch* dapat dilihat dengan jelas pada dataset kedua dibanding dataset pertama. Penambahan *epoch* dari 15 ke 25 meningkatkan *accuracy* dari 65.13% ke 65.21%. Namun saat *epoch* dinaikkan menjadi 50, *accuracy* hanya 63.57% dan *recall* menurun hingga 29.28%. Hal ini menunjukkan penambahan jumlah *epoch* yang terlalu besar tidak selalu meningkatkan performa model dan menyebabkan model kehilangan kemampuan generalisasi terhadap data validasi. *Learning rate* dengan nilai 0.001 mendapatkan hasil yang lebih baik dibanding *learning rate* dengan nilai 0.0005 dan 0.0001 pada dataset pertama maupun dataset kedua.

Learning rate yang terlalu kecil menyebabkan proses pembelajaran lebih lambat sehingga model memerlukan lebih banyak iterasi untuk mencapai kondisi konvergen mengakibatkan performa yang diperoleh pada jumlah *epoch* yang sama menjadi kurang optimal dibanding *learning rate* 0.001. *Batch size* 16 pada dataset kedua menghasilkan performa terbaik. *Batch size* yang lebih kecil memungkinkan model melakukan pembaruan bobot lebih sering sehingga dapat menangkap pola data dengan lebih baik. Sedangkan *batch size* yang terlalu besar cenderung menghasilkan proses pembelajaran lebih stabil namun kurang responsif terhadap variasi data, sehingga performa klasifikasi sedikit mengalami penurunan. Pada dataset pertama pengaruh variasi *batch size* tidak terlalu signifikan karena seluruh percobaan menghasilkan *accuracy* di atas 99%. Secara keseluruhan, hasil penelitian menunjukkan model 1D CNN dapat memberikan performa yang sangan baik untuk dataset pertama dan performa yang cukup baik untuk dataset kedua.

Perbedaan performa lebih banyak dipengaruhi karakteristik dataset daripada *hyperparameter*.

V. KESIMPULAN

Berdasarkan hasil penelitian, sistem klasifikasi alzheimer berdasarkan sinyal EEG menggunakan metode 1D CNN berhasil dikemabngkan dan dievaluasi secara menyeluruh. Penelitian ini menggunakan dataset publik dari Kaggle https://www.kaggle.com/datasets/ucimachinelearning/eeg-alzheimers-dataset dan OSF https://osf.io/2v5md/overview.

Pada dataset pertama diperoleh performa terbaik dengan akurasi 99.89%, *precision* 99.95%, *recall* 99.87%, dan *F1-score* 99.91%. Pada dataset kedua diperoleh performa terbaik dengan akurasi 65.87%, *precision* 59.72%, *recall* 97.72%, dan *F1-score* 74.08%.

Perbedaan hasil pengujian menunjukkan bahwa karakteristtik dataset memiliki pengaruh terhadap performa model. Walau demikian, metode 1D CNN terbukti dapat mengekstraksi karakteristik sinyal EEG secara efektif.

REFERENSI

[1] K. M K and G. M, "Prediction of Alzheimer\'s Disease Using CNN," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 10, no. 7, pp. 902–910, Jul. 2022, doi: 10.22214/ijraset.2022.45357.

[2] W. Xia, R. Zhang, X. Zhang, and M. Usman, "A novel method for diagnosing Alzheimer's disease using deep pyramid CNN based on EEG signals," *Heliyon*, vol. 9, no. 4, Apr. 2023, doi: 10.1016/j.heliyon.2023.e14858.

[3] Y. Sari and Z. Fatah, "Klasifikasi Penyakit Alzheimer Menggunakan Data Mining Decision Tree," pp. 310–315, 2024, doi: 10.59435/gjmi.v2i11.1083.

[4] S. Ehteshamzad, "Assessing the Potential of EEG in Early Detection of Alzheimer's Disease: A Systematic Comprehensive Review (2000-2023)," Aug. 20, 2024, *IOS Press BV*. doi: 10.3233/ADR-230159.

[5] J. Song, E. Cho, H. Lee, S. Lee, S. Kim, and J. Kim, "Development of Neurodegenerative Disease Diagnosis and Monitoring from Traditional to Digital Biomarkers," Feb. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/bios15020102.

[6] A. Parihar Rajiv Gandhi, P. D. Swami, and A. Parihar, "EEG Classification of Alzheimer's Disease, Frontotemporal Dementia and Control Normal Subjects using Supervised Machine Learning Algorithms on various EEG Frequency Bands," 2023. [Online]. Available: https://www.researchgate.net/publication/373302163

[7] C. Qiao *et al.*, "RIPK1-Induced A1 Reactive Astrocytes in Brain in MPTP-Treated Murine Model of Parkinson's Disease," *Brain Sci.*, vol. 13, no. 5, p. 733, Apr. 2023, doi: 10.3390/brainsci13050733.

[8] K. AlSharabi, Y. Bin Salamah, M. Aljalal, A. M. Abdurraqeeb, and F. A. Alturki, "EEG-based clinical decision support system for Alzheimer's disorders diagnosis using EMD and deep learning techniques," *Front. Hum. Neurosci.*, vol. 17, Aug. 2023, doi: 10.3389/fnhum.2023.1190203.

[9] O. Serghini, H. Semlali, A. Maali, A. Ghammaz, and S. Serrano, "1-D Convolutional Neural Network-Based Models for Cooperative Spectrum Sensing," *Future Internet*, vol. 16, no. 1, Jan. 2024, doi: 10.3390/fi16010014.

[10] Kenia A maldonado and Khalid Alsayouri, "Fisiologi Otak," National Library of Medicine. Accessed: Nov. 21, 2025. [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK551718/

[11] R. Nur F, "Otak Sebagai Pemeran Utama bagi Tubuh," Kompasiana. Accessed: Nov. 21, 2025. [Online]. Available: https://www.kompasiana.com/rofidahnurf/6044eb4b8ede48326178f8c2/otak-sebagai-pemeran-utama-bagi-tubuh?page=2&page_images=1

[12] N. F. Saminan, "Frekuensi Gelombang Otak dalam Menangkap Ilmu Imajinasi dan Realita (Berdasarkan Ontologi)," *Jurnal Filsafat Indonesia*, vol. 3, 2020.

[13] S. M. Elgandelwar, V. Bairagi, S. S. Vasekar, A. Nanthaamornphong, and P. Tupe-Waghmare, "Analyzing electroencephalograph signals for early Alzheimer's disease detection: deep learning vs. traditional machine learning approaches," *International Journal of Electrical and Computer Engineering*, vol. 14, no. 3, pp. 2602–2615, Jun. 2024, doi: 10.11591/ijece.v14i3.pp2602-2615.

[14] N. Bayu Aji, dan Handayani Tjandrasa, J. Teknik Informatika, F. Teknologi Informasi Jalan Raya ITS, and J. Timur, "KLASIFIKASI EEG EPILEPSI MENGGUNAKAN SINGULAR SPECTRUM ANALYSIS, POWER SPECTRAL DENSITY DAN CONVOLUTION NEURAL NETWORK."

[15] I. Herdiansyah *et al.*, "Klasifikasi Sinyal EEG Terhadap Tiga Kondisi Pikiran Menggunakan Autoregressive dan Adaptive Backpropagation," 2017.

[16] E. T. Attar, "Review of electroencephalography signals approaches for mental stress assessment," *Neurosciences*, vol. 27, no. 4, pp. 209–215, Oct. 2022, doi: 10.17712/nsj.2022.4.20220025.

[17] M. Aviles, L. M. Sánchez-Reyes, J. M. Álvarez-Alvarado, and J. Rodríguez-Reséndiz, "Machine and Deep Learning Trends in EEG-Based Detection and Diagnosis of Alzheimer's Disease: A Systematic Review," Sep. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/eng5030078.

[18] B. A. Gutierrez and A. Limon, "Synaptic Disruption by Soluble Oligomers in Patients with Alzheimer's and Parkinson's Disease," Jul. 01, 2022, *MDPI*. doi: 10.3390/biomedicines10071743.

[19] "Patofisiologi dari Penyakit Alzheimer," Nurbaiti Haikal. Accessed: Nov. 20, 2025. [Online]. Available: https://nurbaitihaikal.com/patofisiologi-dari-penyakit-alzheimer/

[20] A. H. H. Al-Nuaimi, E. Jammeh, L. Sun, and E. Ifeachor, "Complexity Measures for Quantifying Changes in Electroencephalogram in Alzheimer's

Disease," *Complexity*, vol. 2018, 2018, doi: 10.1155/2018/8915079.

[21] A. Jain, "Understanding the 1D Convolutional Layer in Deep Learning," Medium. Accessed: Nov. 21, 2025. [Online]. Available: https://medium.com/@abhishekjainindore24/understanding-the-1d-convolutional-layer-in-deep-learning-7a4cb994c981

[22] D. H. Seol, J. E. Choi, C. Y. Kim, and S. J. Hong, "Alleviating Class-Imbalance Data of Semiconductor Equipment Anomaly Detection Study," *Electronics (Switzerland)*, vol. 12, no. 3, Feb. 2023, doi: 10.3390/electronics12030585.

[23] UCI Machine Learning Repository, "EEG Alzheimer's Dataset," UCI Machine Learning Repository. Accessed: Dec. 16, 2025. [Online]. Available: https://www.kaggle.com/datasets/ucimachinelearning/eeg-alzheimers-dataset

[24] F. M. R. L. E. B. A. S. L. O. C. Mário L. Vicchietti, "Data from: Computational methods of EEG signals analysis for Alzheimer's disease classification," OSF. Accessed: Jun. 02, 2026. [Online]. Available: https://osf.io/2v5md/overview