

Diagnosa Skizofrenia Menggunakan Transformasi Sinyal *Electroencephalography* (EEG) ke *Frequency-domain* dengan *Deep Learning*

Dea Luthfina Azzahra, Mera Kartika Delimayanti

Teknik Informatika, Teknik Informatika dan Komputer, Politeknik Negeri Jakarta
Depok, Jawa Barat

dea.luthfina.azzahra.tik21@mhs.w.pnj.ac.id, mera.kartika@tik.pnj.ac.id

Abstract - *Electroencephalogram (EEG)* is a non-invasive tool for monitoring brain activity and diagnosing neurological and psychological disorders, including schizophrenia, a chronic mental illness affecting millions. This study aims to improve the classification accuracy of schizophrenia patients and healthy individuals using EEG signals. Non-public data underwent preprocessing and feature extraction using Real Fast Fourier Transform (RFFT) to transform them into the frequency domain, although this transformation results in a loss of temporal information. Two deep learning model architectures were tested: 1D Convolutional Neural Network (1D CNN) and Long Short-Term Memory (LSTM). Test results show that LSTM achieved 97% accuracy, 96% precision, 98% recall, and 97% F1-Score, outperforming 1D CNN. However, testing with new data revealed that 1D CNN was more consistent in identifying schizophrenic subjects, while LSTM erroneously classified several schizophrenia patients as healthy. Therefore, 1D CNN demonstrated better generalization capability for schizophrenia diagnosis.

Keywords: *deep learning, EEG, RFFT, LSTM, schizophrenia, 1D-CNN*

Abstrak - *Electroencephalogram (EEG)* adalah alat non-invasif untuk memantau aktivitas otak dan mendiagnosis gangguan neurologis serta psikologis, termasuk skizofrenia, suatu gangguan mental kronis yang memengaruhi jutaan orang. Penelitian ini bertujuan meningkatkan akurasi klasifikasi pasien skizofrenia dan individu sehat menggunakan sinyal EEG. Data non-publik diproses dan diekstraksi fiturnya menggunakan Real Fast Fourier Transform (RFFT) untuk mengubahnya ke domain frekuensi, meskipun transformasi ini menyebabkan hilangnya informasi temporal. Dua arsitektur model *deep learning* diuji: 1D Convolutional Neural Network (1D CNN) dan Long Short-Term Memory (LSTM). Hasil pengujian menunjukkan, bahwa LSTM mencapai *accuracy* 97%, *precision* 96%, *recall* 98%, dan *F1-Score* 97%, yang lebih unggul dari 1D CNN. Namun, pengujian dengan data baru menunjukkan, bahwa 1D CNN lebih konsisten dalam mengidentifikasi subjek skizofrenia, sementara LSTM keliru mengklasifikasikan beberapa pasien skizofrenia sebagai sehat. Oleh karena itu, 1D CNN menunjukkan kemampuan generalisasi yang lebih baik untuk diagnosa skizofrenia.

Kata kunci: *deep learning, EEG, RFFT, LSTM, skizofrenia, 1D-CNN*

I. PENDAHULUAN

Skizofrenia menyerang sekitar 20 juta orang di seluruh dunia, menurut laporan World Health Organization (WHO) [3]. Skizofrenia adalah gangguan kejiwaan yang sangat mempengaruhi persepsi dan hubungan sosial seseorang. Gangguan ini secara serius merusak cara berpikir, mengekspresikan emosi, serta persepsi terhadap realitas. Gangguan aktivitas saraf pada penderita skizofrenia dapat mempengaruhi kemampuan kognitif, pengendalian emosi, dan fungsi memori [1]. Meskipun penyebab skizofrenia belum sepenuhnya dipahami, tetapi banyak penelitian

menunjukkan bahwa kelainan struktur dan fungsi otak berperan dalam perkembangan penyakit tersebut [10].

Skizofrenia didiagnosis secara tradisional melalui wawancara dengan pasien untuk menanyakan gejala klinis yang mereka alami. Namun, cara ini terkadang kurang akurat karena beberapa pasien mungkin menyembunyikan gejalanya. Selain itu, para ahli sering mengalami kesulitan membedakan skizofrenia dari penyakit lain yang memiliki gejala serupa. Oleh karena itu, berbagai teknik telah dikembangkan untuk meningkatkan pemantauan aktivitas otak, seperti *magnetic resonance imaging*

(MRI), *functional magnetic resonance imaging* (fMRI), dan sinyal otak *electroencephalography* (EEG) [6]. Sinyal otak EEG mendapat banyak perhatian dalam diagnosis skizofrenia karena sifatnya yang non-invasif dan mudah digunakan [9].

Electroencephalogram (EEG) adalah sinyal yang menunjukkan aktivitas listrik yang dihasilkan oleh banyak neuron di otak. Dalam konteks skizofrenia, EEG membantu melihat aktivitas listrik di otak secara langsung, sehingga bisa memberikan wawasan tentang gangguan saraf yang terkait dengan penyakit mental [4], [8]. Sifat EEG yang dinamis membuatnya sangat cocok untuk menangkap perubahan aktivitas otak seiring waktu. Hal ini penting untuk memahami mekanisme dasar skizofrenia [2].

Sinyal EEG menunjukkan informasi kompleks di otak yang berdimensi tinggi dan sulit dianalisis secara langsung. Oleh karena itu, dibutuhkan metode bantu untuk mengekstraksi informasi penting. Ekstraksi fitur adalah cara efektif untuk mempelajari data sinyal EEG, karena dapat merangkum informasi dari banyak sinyal menjadi fitur yang lebih sedikit tanpa menghilangkan makna aslinya. Untuk penyakit skizofrenia, metode ekstraksi fitur dari *time-domain* dan *frequency-domain* telah digunakan untuk mengukur perubahan kondisi otak melalui sinyal EEG [12].

Deep learning membawa revolusi dalam berbagai bidang analisis dan klasifikasi gambar medis. Model *deep learning* sangat berguna untuk mengekstrak fitur kompleks dari data dan mengenali pola yang rumit. Algoritma ini sangat cocok untuk tugas yang melibatkan analisis multidimensional data dan *sequence data*, seperti sinyal EEG [11].

Dalam penelitian ini, penulis mengusulkan pendekatan berbasis *Real Fast Fourier Transform* (RFFT) untuk mengubah sinyal *electroencephalography* (EEG) dari *time-domain* ke *frequency-domain*. Transformasi ini bertujuan untuk mengekstraksi karakteristik penting dari sinyal EEG yang sulit diamati secara langsung dalam bentuk mentahnya. Setelah proses ekstraksi fitur, data kemudian dianalisis menggunakan dua arsitektur *deep learning*, yaitu *1D Convolutional Neural Network* (1D CNN) dan *Long Short-Term Memory* (LSTM). Kedua model ini dipilih karena kemampuannya dalam mengenali pola sekuensial dan spasial pada data berdimensi tinggi seperti sinyal EEG. Tujuan utama dari metode ini adalah untuk mengklasifikasikan sinyal EEG ke dalam dua

kategori, yaitu subjek sehat dan pasien skizofrenia, dengan tingkat akurasi yang tinggi.

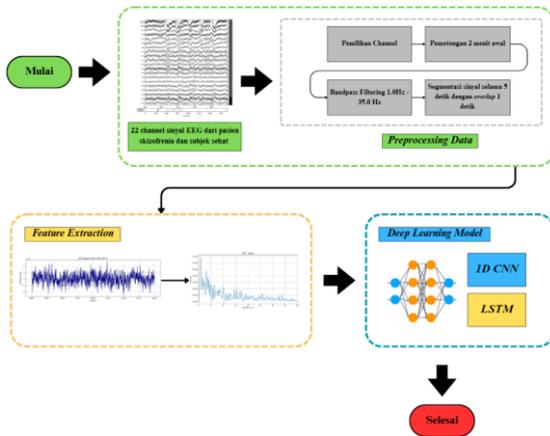
Penggunaan EEG sebagai kandidat biomarker dalam deteksi dan pemahaman gangguan psikiatrik, termasuk skizofrenia, telah banyak dikaji. Gosala et al. [5] menggunakan dataset RepOD dan menerapkan *Wavelet Scattering Transform* (WST) untuk klasifikasi skizofrenia, serta membandingkannya dengan *Continuous* dan *Discrete Wavelet Transform* (CWT dan DWT). Hasilnya menunjukkan bahwa metode ensemble unggul untuk fitur CWT dan DWT, sementara metode tradisional lebih efektif untuk WST, dengan *Decision Tree* mencapai akurasi 97%.

Bagherzadeh et al. [1] mengusulkan pendekatan berbasis *effective connectivity* dan *deep learning*, yaitu model EfficientNetB0-LSTM, yang juga menggunakan dataset RepOD dan mencapai akurasi 99%.

Sementara itu, Shoeibi et al. [10] memanfaatkan *CNN-LSTM* dengan normalisasi *z-score* dan *L2* pada sinyal EEG berdurasi 25 detik. Dengan *k-fold cross-validation* ($k=5$), model ini mencatatkan akurasi hingga 99%, menunjukkan keunggulan pendekatan *deep learning* dibandingkan metode konvensional.

II. METODOLOGI PENELITIAN

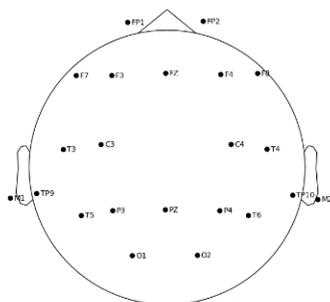
Penelitian ini menggunakan pendekatan kuantitatif karena analisis data dilakukan dengan membandingkan kinerja model yang telah diuji sebelumnya menggunakan metrik evaluasi tertentu untuk menentukan model terbaik. Jenis penelitian ini merupakan riset eksperimental, di mana data dikumpulkan melalui eksperimen dengan cara menguji dua jenis arsitektur model, kemudian hasilnya disimpan dan dianalisis untuk mendapatkan performa model yang paling optimal. Rancangan dari penelitian yang akan dilakukan disajikan pada Gambar 1.



Gambar 1. Rancangan Penelitian

Dataset yang digunakan bersifat non-publik, yang didapatkan dari tim MedTech IMERI FKUI. Data yang diberikan akan direkam dengan alat EEG yang berbeda, yaitu alat dengan 32 *channel* dengan *low pass* sebesar 70.0Hz dan 25 *channel* dengan *low pass* sebesar 35.0Hz. Namun, kedua jenis rekaman ini memiliki *sampling rate* yang sama, yaitu sebesar 250.0Hz. Rata-rata keseluruhan rekaman sebesar 30 menit. Terdapat 9 subjek sehat dan 9 subjek yang mengidap skizofrenia yang akan dianalisis dalam penelitian ini. Sinyal EEG direkam dengan persetujuan pasien (*informed consent*) yang diberikan sebelum perekaman data EEG dan data sinyal EEG ini direkam pada akhir tahun 2017 hingga awal tahun 2018.

Karena adanya perbedaan nama *channel* dan jumlah *channel*, tahap pertama yang dilakukan adalah memilih irisan dari kedua jenis *channel* tersebut. Didapatkan total 22 *channel* yang sama yang akan dianalisa. *Channel-channel* tersebut adalah FP1, FP2, F3, F4, F7, F8, FZ, T1, T2, T3, T4, T5, T6, C3, C4, P3, P4, PZ, O1, O2, A1, A2. Lalu, dilakukan penyesuaian nama *channel* terhadap *library* MNE sebagai alat manipulasi sinyal EEG. Hasil dari pemilihan *channel* dan penyesuaian nama *channel* terdapat pada Gambar 2.

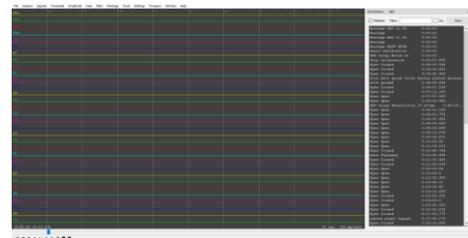


Gambar 2. Topografi Peletakkan *Channel*

Sebelum data diproses oleh model *deep learning*, dilakukan tahap data *preprocessing* untuk memastikan kualitas dan konsistensi data. *Preprocessing* bertujuan untuk meningkatkan performa model dengan menyediakan *input* yang lebih representatif dan terstruktur, sehingga model dapat belajar pola dari data secara lebih efektif. *Preprocessing* dilakukan dengan beberapa tahapan.

A. Pemotongan 2 Menit Awal

Untuk menghindari “kesalahpahaman” *deep learning* dalam mengklasifikasikan rekaman sinyal EEG, sinyal EEG akan dipotong dari dua menit awal saat rekaman belum mulai tampak adanya perubahan amplitudo atau saat masih persiapan perekaman. Gambar 3 menunjukkan sinyal EEG pada dua menit pertama yang akan dihilangkan. Pada gambar tersebut, perubahan amplitudo pada sinyal EEG belum terlihat secara jelas.



Gambar 3. Dua Menit Awal Rekaman Sinyal EEG

B. *Bandpass Filtering*

Dilakukan proses *low pass filtering* dengan batas frekuensi 35.0 Hz dan *high pass filtering* dengan batas frekuensi sebesar 1.00Hz untuk data dengan *low pass filter* sebesar 70.0Hz. Tujuan dari filtrasi ini adalah untuk menghilangkan komponen frekuensi tinggi dan rendah yang tidak relevan, seperti *noise* atau artefak otot (EMG), sehingga sinyal EEG yang diperoleh lebih bersih dan representatif terhadap aktivitas otak yang berada pada rentang frekuensi 1.00Hz sampai 35.0Hz.

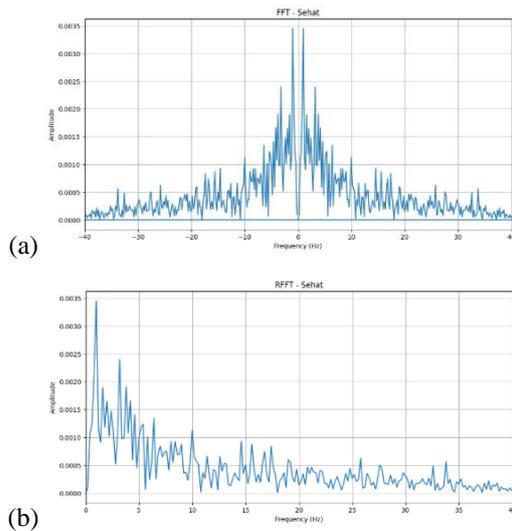
C. Segmentasi Sinyal

Penelitian ini menggunakan *library* MNE untuk melakukan segmentasi sinyal selama 5 detik dengan *overlap* selama 1 detik. Segmentasi selama 5 detik dipilih karena dianggap ideal untuk menjaga keseimbangan antara kestabilan pola sinyal dan kemampuan menangkap fitur transien. Jendela yang lebih pendek (2–3 detik) sering kali tidak cukup stabil, sementara jendela yang terlalu panjang (8–10 detik) berisiko menghaluskan fitur penting dalam sinyal EEG. *Overlap* selama 1 detik memastikan kesinambungan antarsegmen dan mengurangi

hilangnya informasi transisional yang dapat terjadi pada batas *epoch* yang konstan [7].

Setelah dilakukan *preprocessing*, data akan berbentuk *epoch-epoch* kecil yang sudah tersegmentasi selama 5 (lima) detik dengan *overlap* selama 1 (satu) detik. Setelah itu, kumpulan segmen data ini akan melewati proses *feature extraction*.

Feature extraction dilakukan dengan mengubah data sinyal EEG dari *time-domain* ke *frequency-domain* menggunakan *Real Fast Fourier Transform (RFFT)*. *RFFT* sendiri merupakan salah satu jenis *Fast Fourier Transform (FFT)*. Penggunaan *RFFT* bertujuan untuk mengambil dan memproses komponen frekuensi positif saja dari segmen sinyal EEG, karena sinyal EEG bersifat real dan komponen frekuensi negatifnya bersifat simetris sehingga tidak memberikan informasi tambahan. Selain itu, *RFFT* digunakan juga untuk menghemat penggunaan memori. Gambar 4 menunjukkan perbandingan antara hasil ekstraksi fitur menggunakan *FFT* dan *RFFT*.



Gambar 4. Perbedaan Sinyal dengan (a) *FFT* dan Sinyal dengan (b) *RFFT*

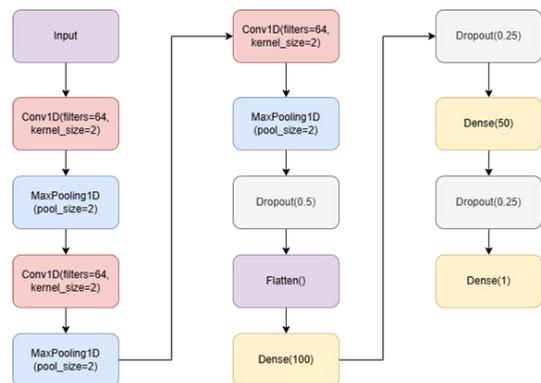
Data sinyal yang telah disegmentasi dibaca menggunakan *library MNE*. Fungsi tersebut akan mengembalikan *array* berisi info jumlah *epoch*, jumlah *channel*, dan jumlah *data point*. Dengan *sampling rate* sebesar 250.0 Hz dan durasi 5 detik, maka jumlah *data point* dalam setiap *epoch* adalah $250.0 \times 5 = 1250$. Namun, karena fungsi segmentasi pada *library MNE* menggunakan rentang waktu yang mencakup titik awal dan akhir waktu, maka jumlah *data point* menjadi 1251. Selanjutnya, dilakukan transformasi menggunakan *RFFT*, yang mana bagian spektrum frekuensi positif yang

diambil menggunakan *library scipy.signal* dengan fungsi *rfft()*. Karena jumlah *data point* awal (1251) merupakan bilangan ganjil, maka hasil *RFFT* terdiri dari $(1251 // 2) + 1 = 626$ titik frekuensi. Oleh karena itu, jumlah *data point* hasil ekstraksi fitur dari setiap segmen sinyal setelah *RFFT* adalah 626.

Setelah melalui proses *RFFT*, setiap segmen sinyal akan berbentuk *array* dengan dimensi jumlah_channel x jumlah_titik_waktu_positif. Setiap segmen ini kemudian disimpan dan dikelompokkan ke dalam dua kelas, yaitu kelas Sehat dan kelas Skizofrenia.

Sebelum data diproses oleh model *deep learning*, dataset akan dibagi menjadi 3 (tiga) kelompok, yaitu data latih (*training data*) sebesar 70%, data uji (*validation data*) sebesar 20%, dan data uji (*testing data*) sebesar 10% dari total keseluruhan *dataset*. Pembagian data ini dilakukan dengan alasan proporsi data validasi lebih besar dibandingkan dengan data uji untuk mengoptimalkan proses pemantauan dan penyetelan *parameter* model selama pelatihan. Data validasi yang banyak diharapkan dapat membantu dalam mencegah *overfitting*.

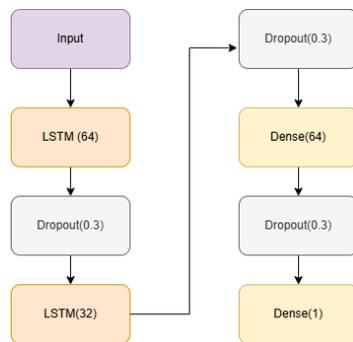
Tahap akhir dari penelitian ini adalah pelatihan model *deep learning*. Seperti yang telah disebutkan sebelumnya, terdapat dua arsitektur model yang akan diuji, yaitu *1D CNN* dan *LSTM*. Gambar 5 merupakan lapisan *1D CNN* yang akan digunakan pada penelitian ini.



Gambar 5. Arsitektur Model *1D CNN*

Lapisan *input* pada model menerima data dengan dimensi (jumlah_channel, jumlah_datapoint) yang berarti model memperoleh masukan berupa 22 *channel* dan 626 *data point* untuk setiap segmen sinyal. Selanjutnya, model menggunakan lapisan *Conv1D* dengan 64 *filter* dan *kernel_size* sebesar 2, serta menggunakan fungsi *aktivasi Rectified Linear Unit (ReLU)*. Lapisan ini diikuti oleh *MaxPooling1D*

dengan *pool_size* sebesar 2. Kombinasi *Conv1D* dan *MaxPooling1D* ini diulang sebanyak tiga kali untuk memungkinkan model mengekstraksi fitur yang relevan secara lebih efektif dan mengenali pola dari kedua kelas data. *Flatten layer* digunakan untuk mengubah data multidimensi menjadi satu dimensi sebelum memasuki *dense layer* atau *fully connected layer*. Digunakan pula *dropout layer* untuk mengurangi risiko *overfitting* dengan mengabaikan sejumlah unit selama pelatihan. Terakhir, data diproses oleh *dense layer* dengan satu *neuron* dan fungsi aktivasi *sigmoid* yang berfungsi untuk melakukan klasifikasi biner, yaitu menentukan apakah segmen data berasal dari subjek sehat atau pasien skizofrenia.



Gambar 6. Arsitektur Model LSTM

Arsitektur kedua yang digunakan pada penelitian ini adalah RNN atau dengan layer *Long Short Term Memory (LSTM)* pada Gambar 6. Penggunaan layer ini bertujuan untuk menyimpan informasi dari data sekuensial seperti sinyal EEG, sehingga model mampu mengenali pola yang berkaitan antar waktu. Setelah input layer, data akan melewati LSTM layer dan dropout layer untuk mengurangi kemungkinan *overfitting*. Setelah melewati dua kali LSTM layer dan dropout layer, model akan melewati dense layer untuk klasifikasi.

Selain arsitektur model, didefinisikan pula *hyperparameter* dari model yang akan dikembangkan yang tertuang dalam Tabel 1. Kelima *hyperparameter* model disamakan agar dapat dibandingkan dan diambil model dengan akurasi terbaik.

Tabel 1. Hyperparameter Model

Hyperparameter	ID-CNN & LSTM
Batch Size	128
Optimizer	Adam
Loss Function	binary_crossentropy
Learning Rate	0.0001
Epochs	100

Selanjutnya, digunakan fungsi *myCallback* untuk menghentikan *training* model apabila beberapa kondisi sudah terpenuhi. Kondisi-kondisi tersebut adalah *accuracy*, *val_accuracy*, *loss*, dan *val_loss*. Penggunaan *Callbacks* ini bertujuan untuk menghemat waktu pelatihan serta menghemat penggunaan sumber daya komputasi.

Selain menggunakan fungsi *myCallback()*, dilakukan juga *EarlyStopping* selama proses pelatihan model. Tujuannya adalah untuk menghentikan pelatihan secara otomatis apabila nilai *val_accuracy* tidak mengalami peningkatan selama 10 *epochs* berturut-turut.

Model selanjutnya akan dievaluasi untuk dapat mengetahui model terbaik yang bisa mengklasifikasikan kelas sehat dan kelas skizofrenia. Model dievaluasi menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-Score*.

a) Confusion Matrix

Confusion matrix digunakan untuk memvisualisasikan dan merangkum performa suatu algoritma klasifikasi atau model. Gambar 7 merupakan rumus dari *confusion matrix*.

		Predicted	
		0	1
Actual	0	TN	FP
	1	FN	TP

Gambar 7. Confusion Matrix

Confusion matrix pada Gambar 6 memiliki nilai sebagai berikut:

- *True Positive (TP)*: data skizofrenia diklasifikasi sebagai skizofrenia
- *True Negative (TN)*: data sehat yang diklasifikasikan sebagai sehat
- *False Positive (FP)*: data skizofrenia yang diklasifikasikan sebagai sehat.
- *False Negative (FN)*: data sehat yang diklasifikasikan sebagai skizofrenia.

b) Accuracy

Accuracy digunakan untuk mengevaluasi sejauh mana model klasifikasi bekerja dengan benar secara keseluruhan.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

c) *Precision*

Precision mengukur seberapa baik model menghindari kesalahan false positive.

$$Precision = \frac{TP}{TP + FP}$$

d) *Recall*

Recall mengukur kemampuan model untuk mendeteksi semua instance positif dengan benar.

$$Recall = \frac{TP}{TP + FN}$$

e) *F1-Score*

F1-score mengukur harmonic mean dari precision dan recall.

$$F1\ Score = 2 \times \frac{(Recall \times Precision)}{(Recall + Precision)}$$

III. HASIL DAN PEMBAHASAN

A. Kebutuhan Perangkat Keras dan Perangkat Lunak

Kebutuhan perangkat keras dideskripsikan guna memastikan sistem memiliki infrastruktur yang memadai untuk merancang aplikasi dengan optimal dan mendukung proses pengolahan data secara efisien. Tabel 2 menjelaskan lebih rinci mengenai spesifikasi perangkat keras yang dibutuhkan pada penelitian ini.

Tabel 2. Kebutuhan Perangkat Keras

Nama	Deskripsi
CPU	Intel i7-7770HQ
RAM	16.0GB
GPU	GTX 950M
Operating System	Windows 10

Selain kebutuhan perangkat keras, kebutuhan perangkat lunak juga penting untuk diidentifikasi. Tabel 6 menunjukkan perangkat lunak dan library yang dibutuhkan dalam penelitian ini. *Library-library* tersebut ditulis dalam bahasa pemrograman Python dan digunakan untuk melakukan analisis data, manipulasi data, prapemrosesan data, pengembangan model *deep learning*, hingga evaluasi model.

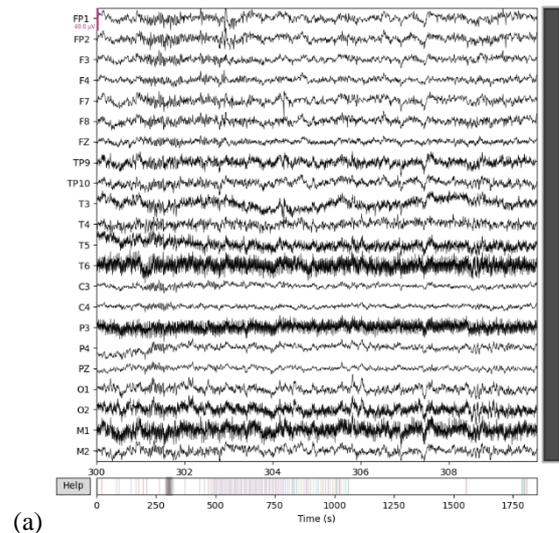
Tabel 3. Kebutuhan Perangkat Lunak

Nama	Versi
numpy	2.0.2
mne	1.10.0
scipy	1.15.3
scikit-learn	1.5.1

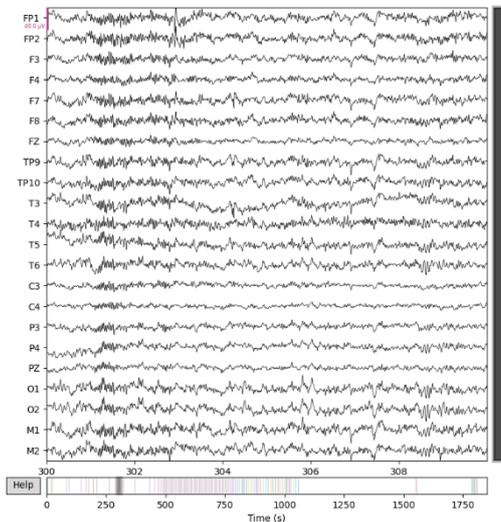
tensorflow	2.16.1
matplotlib	3.10.0
pandas	2.2.2
tqdm	4.67.1

B. Preprocessing Data

Jika data memiliki *low pass filter* sebesar 70.0Hz, data akan melalui proses *low pass filter* sebesar 35.0Hz. Gambar 8 merupakan visualisasi data sebelum dilakukan *filtering* (a) dan sesudah dilakukan *filtering* (b).



(a)



(b)

Gambar 8. (a) Sebelum Difilter (b) Sesudah Difilter

Setelah difilter, data akan disegmentasi sepanjang 5 detik dengan *overlap* sebesar 1 detik. Tabel 4 merupakan hasil segmentasi dari sinyal yang ada, untuk data kelas sehat.

Tabel 4. Hasil Segmentasi *Raw Data* Kelas Sehat

Subjek	Sehat	
	<i>Epochs</i>	Durasi
h01	432	30:52
h02	505	42:16
h03	425	35:44
h04	492	30:24
h05	603	34:52
h06	429	30:38
h07	450	30:11
h08	568	32:04
h09	422	39:56
TOTAL	4326	5:20:17

Selanjutnya, Tabel 5 merupakan hasil segmentasi sinyal untuk kelas skizofrenia.

Tabel 5. Hasil Segmentasi *Raw Data* Kelas Skizofrenia

Subjek	Skizofrenia	
	<i>Epochs</i>	Durasi
s01	428	30:35
s02	451	32:08
s03	450	32:05
s04	492	34:52
s05	428	30:34
s06	427	30:31
s07	465	33:03
s08	502	35:31
s09	456	32:27
TOTAL	3280	4:28:26

Pada *library* MNE, *Epochs* tersebut akan berbentuk *array*. Bentuk *array* yang ada adalah (jumlah_ *epoch*, jumlah *channel*, jumlah *timepoint*). Setiap subjek memiliki jumlah *epoch* yang berbeda disebabkan total panjang rekaman yang berbeda-beda. Total *time point* berjumlah 1251 dalam segmen data selama 5 detik.

Hanya data dari subjek 01 hingga 07 pada masing-masing kelas yang akan digunakan untuk pelatihan dan validasi model *deep learning*. Sementara itu, data dari subjek 08 dan 09 akan digunakan untuk pengujian model. Maka dari itu, total *array* untuk pelatihan model yang dimiliki kelas sehat adalah (3336, 22, 1251), sedangkan untuk kelas skizofrenia *array* akan berbentuk (3141, 22, 1251).

C. Feature Extraction

Data yang sudah melalui *preprocessing* data akan masuk ke tahapan *feature extraction*. Pada tahap ini, setiap *epoch* atau segmen data akan diubah dari *time-*

domain ke *frequency-domain*. Tabel 5 merupakan hasil *epoch* yang sudah melalui *feature extraction*.

Tabel 6. Banyak Data Setiap Kelas

Kelas Data	Banyak Data	Bentuk Array
Sehat	4326	(22, 626)
Skizofrenia	3280	(22, 626)

RFFT hanya akan mengambil nilai unik atau nilai positif dari hasil *FFT*. Maka dari itu, *time point* dari setiap *epoch* berjumlah 626. Pada tahap ini, setiap *epoch* atau segmen data akan disimpan secara terpisah, tidak lagi dalam satu *array* besar. Hal tersebut dilakukan untuk mempermudah pengolahan *dataset* kedepannya, yaitu tahap pelabelan data.

Setelah melalui proses *feature extraction*, maka *dataset* siap dilatih menggunakan model *deep learning*. Kedua kelas data yang sudah diproses tersebut akan disimpan pada dua *folder* berbeda. Namun, sebelum dilatih, *dataset* harus dibagi terlebih dahulu.

D. Pengembangan dan Evaluasi Model *Deep Learning*

Karena perbedaan jumlah data pada setiap kelas, kedua kelas akan disamakan jumlah datanya. Setelah itu, data akan dibagi menjadi 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk data uji. Tabel 7 menunjukkan jumlah masing-masing data.

Tabel 7. Pembagian *Dataset*

Jenis Data	Banyak Sampel
<i>Training Data</i>	70% (4397 sampel)
<i>Validation Data</i>	20% (1256 sampel)
<i>Testing Data</i>	10% (629 sampel)

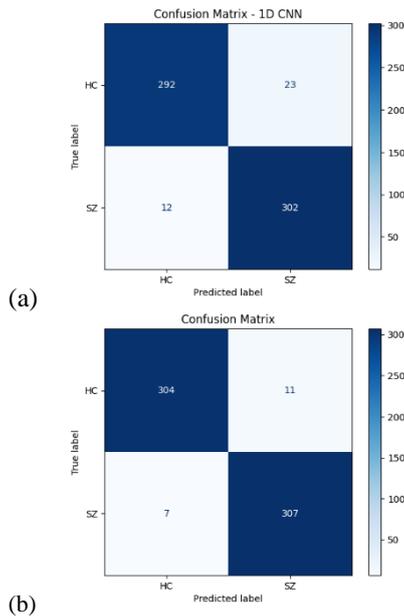
Selanjutnya, dilakukan proses pelatihan model *deep learning* untuk kedua arsitektur model, yaitu *1D CNN* dan *LSTM*. Tabel 8 membandingkan metrik evaluasi dari kedua jenis arsitektur tersebut.

Tabel 8. Perbandingan Metrik Evaluasi *1D CNN* dan *LSTM*

Metrik	<i>1D CNN</i>	<i>LSTM</i>
<i>Accuracy</i>	0.94	0.97
<i>Precision</i>	0.93	0.96
<i>Recall</i>	0.96	0.98
<i>F1-Score</i>	0.94	0.97

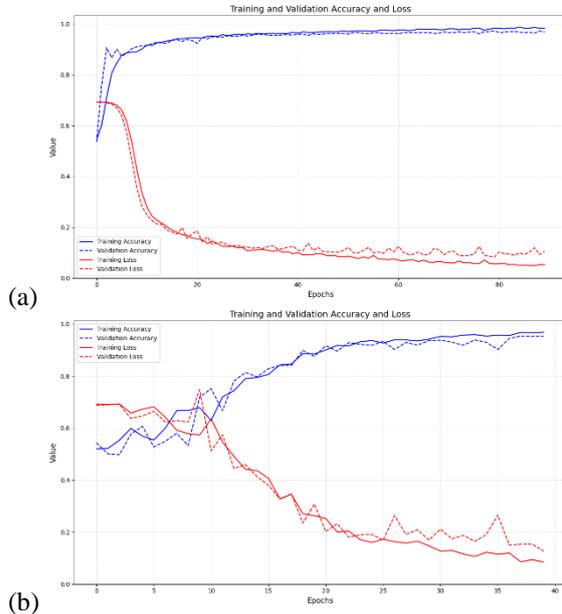
Dapat disimpulkan, bahwa arsitektur *LSTM* lebih unggul jika dibandingkan dari keseluruhan metrik evaluasinya. Selanjutnya, dibandingkan juga *confusion matrix* dari kedua arsitektur tersebut yang

disajikan pada Gambar 8 (a) untuk *ID CNN* dan 8 (b) untuk *LSTM*.



Gambar 8. *Confusion Matrix* (a) *ID CNN* dan (b) *LSTM*

Sebagai parameter tambahan, dibandingkan juga grafik *accuracy* dan *loss* pada setiap arsitektur. Gambar 10 (a) merupakan grafik milik *ID CNN* dan 10 (b) merupakan grafik milik *LSTM*.



Gambar 9. Grafik *Accuracy* dan *Loss* (a) *ID CNN* dan (b) *LSTM*

E. Pengujian Model *Deep Learning*

Model yang dikembangkan dalam penelitian ini masih melakukan deteksi pada segmen-segmen sinyal EEG berdurasi lima detik. Namun, dalam

praktik medis, rekaman sinyal EEG untuk keperluan diagnosis skizofrenia umumnya memiliki durasi hingga tiga puluh menit. Oleh karena itu, pada tahap pengujian model, penulis melakukan evaluasi terhadap kemampuan model dalam mengklasifikasikan satu rekaman EEG subjek secara penuh.

Hasil dari pengujian merupakan persentase dari kedua kelas yang ada. Penilaian terhadap kesesuaian prediksi dilakukan dengan melihat nilai probabilitas yang dihasilkan oleh model. Kelas yang diprediksi oleh model dianggap benar apabila memiliki nilai probabilitas tertinggi dibandingkan kelas lainnya. Sebagai contoh, jika data berasal dari subjek dengan skizofrenia, maka nilai probabilitas untuk kelas skizofrenia harus lebih tinggi daripada kelas sehat agar prediksi tersebut dinyatakan sesuai.

Terdapat 4 subjek yang akan diuji, yaitu h08, h09, s08, dan s09. Tabel 9 merupakan hasil pengujian dari keempat subjek pada kedua jenis arsitektur.

Tabel 9. Hasil Pengujian *ID CNN* dan *LSTM*

Subjek	<i>ID CNN</i>	<i>LSTM</i>
h08	Sehat (93.87%)	Sehat (97.56%)
h09	Skizofrenia (80.46%)	Sehat (99.82%)
s08	Skizofrenia (79.88%)	Sehat (61.16%)
s09	Skizofrenia (76.10%)	Sehat (100%)

Dapat disimpulkan dari percobaan diatas, bahwa model *ID CNN* lebih baik mengenali kedua kelas data dibandingkan dengan model *LSTM*. Model *LSTM* salah mengenali 3 subjek yang sangat krusial, sedangkan model *ID CNN* hanya salah mengenali satu subjek saja. Dalam dunia medis, lebih baik salah mengenali yang sehat sebagai sakit, dibandingkan sebaliknya.

F. Analisa Model *Deep Learning*

Meskipun pada saat pelatihan model *deep learning* model *LSTM* menunjukkan performa terbaik, tetapi saat diuji secara keseluruhan dengan data baru, *ID CNN* lebih baik mengenali kedua kelas data. Fenomena ini menunjukkan adanya ketidaksesuaian antara performa model pada metrik evaluasi dan kemampuannya dalam menggeneralisasi pada kasus-kasus spesifik, terutama pada kelas "Skizofrenia". Salah satu faktor yang mungkin berkontribusi terhadap perbedaan kinerja ini adalah sifat dari transformasi *Real Fast Fourier Transform*

(*RFFT*) yang digunakan untuk mengubah sinyal EEG dari *time-domain* ke *frequency-domain*. Meskipun *RFFT* efektif dalam mengekstraksi karakteristik frekuensi, *RFFT* menyebabkan hilangnya informasi temporal atau urutan waktu dalam sinyal asli. Karena *LSTM* secara khusus dirancang untuk memproses data sekuensial dan menangkap dependensi temporal, hilangnya informasi ini setelah *RFFT* dapat membatasi kemampuan *LSTM* untuk memanfaatkan sepenuhnya kekuatan arsitekturnya dalam mengenali pola-pola halus yang bergantung pada waktu yang mungkin krusial untuk diagnosis skizofrenia. Sebaliknya, *1D CNN*, yang berfokus pada ekstraksi fitur tanpa terlalu bergantung pada urutan temporal setelah transformasi frekuensi, mungkin lebih *robust* terhadap hilangnya informasi ini.

IV. KESIMPULAN DAN SARAN

Setelah melakukan analisis dan pengujian terhadap kedua model, didapatkan model terbaik adalah *LSTM* dengan metrik evaluasi terbaik yaitu sebesar 97% pada *accuracy*, 96% untuk *precision*, 98% untuk *recall*, dan *F1-Score* sebesar 97%. Namun, saat diuji dengan data baru berupa rekaman penuh subjek, *1D CNN* menunjukkan kemampuan yang lebih baik dalam mengenali data skizofrenia dibandingkan dengan *LSTM*. Dalam konteks diagnosis medis seperti skizofrenia, kemampuan model untuk secara akurat mengidentifikasi kasus-kasus positif (penderita skizofrenia) adalah hal yang sangat krusial.

Sebagai saran untuk pengembangan lebih lanjut, model klasifikasi yang dikembangkan dapat disempurnakan dengan beberapa saran. Pertama, penting untuk mengidentifikasi perbedaan karakteristik sinyal EEG antara pasien skizofrenia dan individu sehat secara klinis guna memperoleh fitur tambahan yang lebih relevan. Selain itu, analisis terhadap pola khas seperti anomali gelombang theta, gamma, serta penurunan potensi ERP (misalnya P300 dan *MMN*) dapat dimanfaatkan sebagai biomarker tambahan. Optimalisasi analisis temporal juga disarankan dengan mempertimbangkan perubahan sinyal dalam durasi lebih panjang melalui teknik *overlap* dan segmentasi berurutan, agar konteks waktu sinyal dapat ditangkap secara lebih menyeluruh. Terakhir, data yang digunakan merupakan data yang masih memiliki banyak *noise*, maka dari itu penting untuk mengenali artefak atau

noise dan menghilangkannya sebelum dilatih menggunakan model *deep learning*.

V. REFERENSI

- [1] S. Bagherzadeh, M. S. Shahabi, and A. Shalhaf, "Detection of schizophrenia using hybrid of deep learning and brain effective connectivity image from electroencephalogram signal," *Computers in Biology and Medicine*, vol. 146, Jul. 2022, doi: 10.1016/j.compbiomed.2022.105570.
- [2] C. Barros, B. Roach, J. M. Ford, A. P. Pinheiro, and C. A. Silva, "From Sound Perception to Automatic Detection of Schizophrenia: An EEG-Based Deep Learning Approach," *Frontiers in Psychiatry*, vol. 12, Feb. 2022, doi: 10.3389/fpsyt.2021.813460.
- [3] C. Ciprian, K. Masychev, M. Ravan, A. Manimaran, and A. Deshmukh, "Diagnosing schizophrenia using effective connectivity of resting-state EEG data," *Algorithms*, vol. 14, no. 5, 2021, doi: 10.3390/a14050139.
- [4] J. N. de Boer et al., "Acoustic speech markers for schizophrenia-spectrum disorders: A diagnostic and symptom-recognition tool," *Psychological Medicine*, vol. 53, no. 4, pp. 1302–1312, Mar. 2023, doi: 10.1017/S0033291721002804.
- [5] B. Gosala, P. Dindayal Kagate, P. Jain, R. Nath Chaurasia, and M. Gupta, "Wavelet transforms for feature engineering in EEG data processing: An application on Schizophrenia," *Biomedical Signal Processing and Control*, vol. 85, Aug. 2023, doi: 10.1016/j.bspc.2023.104811.
- [6] M. Hussain, N. A. Alsalooli, N. Almaghrabi, and E. U. H. Qazi, "Schizophrenia Detection on EEG Signals Using an Ensemble of a Lightweight Convolutional Neural Network," *Applied Sciences (Switzerland)*, vol. 14, no. 12, Jun. 2024, doi: 10.3390/app14125048.
- [7] M. Umair et al., "Decentralized EEG-based detection of major depressive disorder via transformer architectures and split learning," *Frontiers in Computational Neuroscience*, vol. 19, 2025, doi: 10.3389/fncom.2025.1569828.
- [8] S. Karthik and M. Sudha, "Predicting bipolar disorder and schizophrenia based on non-overlapping genetic phenotypes using deep neural network," *Evolutionary Intelligence*, vol. 14, no. 2, pp. 619–634, Jun. 2021, doi: 10.1007/s12065-019-00346-y.
- [9] S. K. Khare, V. Bajaj, S. Siuly, and G. R. Sinha, "Classification of schizophrenia patients through empirical wavelet transformation using electroencephalogram signals," in *Modelling and Analysis of Active Biopotential Signals in Healthcare, Volume 1*, Institute of Physics Publishing, 2020, pp. 1-1-1–25. doi: 10.1088/978-0-7503-3279-8ch1.
- [10] A. Shoeibi et al., "Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models," *Frontiers in Neuroinformatics*, vol. 15, Nov. 2021, doi: 10.3389/fninf.2021.777977.
- [11] S. Srinivasan and S. Duella Johnson, "A novel approach to schizophrenia Detection: Optimized preprocessing and deep learning analysis of multichannel EEG data," *Expert Systems with Applications*, vol. 246, Jul. 2024, doi: 10.1016/j.eswa.2023.122937.
- [12] J. Sun et al., "A hybrid deep neural network for classification of schizophrenia using EEG Data," *Scientific Reports*, vol. 11, no. 1, Dec. 2021, doi: 10.1038/s41598-021-83350-6.