

Analisis Parameter Windowing STFT Pada Klasifikasi Gerakan Jari Berbasis EMG

Rohadi Widagdo^{*1}, Diyah Utami Kusumaning Putri², Catur Atmaji³

¹ Program Studi Elektronika dan Instrumentasi, DIKE, FMIPA, UGM, Yogyakarta, Indonesia

^{2,3}Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}rohadi.rw@mail.ugm.ac.id, ²diyah.utami.k@ugm.ac.id, ³catur_atmaji@ugm.ac.id

Abstrak

Spectrogram adalah alat penting dalam analisis sinyal, terutama dalam menganalisis sinyal Elektromiografi (EMG) yang fluktuatif dari waktu ke waktu. Kualitas representasi spektrogram dari sinyal EMG sangat dipengaruhi oleh pengaturan parameter dalam metode Short Time Fourier Transform (STFT), seperti ukuran jendela, tumpang tindih, dan jenis jendela. Dalam konteks pengenalan gerakan jari, pemilihan parameter optimal menjadi tantangan besar karena perubahan kecil dalam sinyal EMG dapat secara signifikan memengaruhi akurasi pengenalan. Oleh karena itu, setiap parameter STFT akan memengaruhi kualitas spektrogram, yang memerlukan penelitian untuk menemukan parameter optimal.

Penelitian ini akan menggunakan model pembelajaran mendalam, AlexNet, untuk melakukan pengenalan pada spektrogram data masukan yang dihasilkan dari sinyal EMG yang diproses menggunakan berbagai kombinasi parameter STFT (ukuran jendela, tumpang tindih, dan jenis jendela) untuk lima gerakan jari manusia. Hasil eksperimen menunjukkan bahwa kombinasi parameter dengan ukuran jendela 100, tumpang tindih 50%, dan jenis jendela Hamming memiliki kinerja terbaik dari semua 36 kombinasi parameter. Analisis setiap parameter menunjukkan bahwa ukuran jendela 100 rata-rata lebih baik daripada 200 dan 300, sementara tumpang tindih 50% rata-rata lebih baik daripada 25% dan 75%. Selain itu, jenis jendela Hanning rata-rata lebih baik daripada Hamming, Blackman, dan Tukey dalam semua kombinasi parameter..

Kata kunci—Sliding Window, STFT, EMG, AlexNet

Abstract

A spectrogram plays a crucial role in signal analysis, especially when dealing with Electromyography (EMG) signals that vary over time. The accuracy of EMG signal representation in spectrograms heavily depends on the parameter settings within the Short Time Fourier Transform (STFT) method, including window size, overlap, and window type. In the realm of finger motion recognition, selecting the most suitable parameters presents a significant challenge due to the sensitivity of EMG signals to minor changes that can impact recognition accuracy. Consequently, each STFT parameter influences spectrogram quality, necessitating research to identify the optimal configurations.

In this study, a deep learning model, AlexNet, will be employed to conduct recognition on spectrograms derived from processed EMG signals, using various combinations of STFT parameters (window size, overlap, and window type) for five distinct human finger movements. The experimental findings reveal that the parameter combination involving a window size of 300, a 50% overlap, and the Hamming window type performs the best among all 36 parameter combinations. An analysis of each parameter indicates that a window size of 100 consistently outperforms window sizes of 200 and 300. Moreover, a 50% overlap is consistently superior to 25% and 75%. Additionally, Hanning window types consistently outperform Hamming, Blackman, and Tukey in all parameter combinations.

Keywords—Sliding Window, STFT, EMG, AlexNet

1. PENDAHULUAN

Spektrogram adalah alat yang digunakan secara luas dalam pemrosesan sinyal untuk menganalisis sinyal yang bervariasi waktu seperti sinyal Elektromiografi (EMG). Namun, kualitas representasi spektrogram dari sinyal EMG dapat dipengaruhi oleh parameter yang digunakan dalam metode *windowing Short Time Fourier Transform* (STFT) [9]. Hal ini terutama berlaku dalam kasus pengenalan jari, di mana variasi kecil dalam sinyal EMG dapat berdampak signifikan pada akurasi pengenalan [4].

Salah satu tantangan utama dalam menggunakan spektrogram untuk pengenalan jari adalah memilih ukuran jendela STFT yang optimal, parameter tumpang tindih, dan jenis jendela yang digunakan. Ukuran jendela menentukan resolusi temporal spektrogram, dengan jendela yang lebih besar memberikan resolusi frekuensi yang lebih baik tetapi resolusi temporal yang lebih rendah, dan sebaliknya untuk jendela yang lebih kecil. Parameter tumpang tindih menentukan seberapa banyak setiap jendela tumpang tindih dengan jendela yang berdekatan, dan dapat mempengaruhi kehalusan spektrogram yang dihasilkan [4].

Pada penelitian yang dilakukan oleh [6], panjang jendela yang lebih kecil (50, 100, dan 250 ms) mengurangi resolusi frekuensi, sementara panjang jendela yang lebih besar (300 dan 200 ms) mengurangi resolusi waktu. Panjang jendela 50 ms dengan tumpang tindih 0% dari frekuensi puncak menghasilkan kemiringan frekuensi yang lebih tinggi. Sebaliknya, jendela berukuran besar memiliki efek sebaliknya. Panjang jendela 250 ms dengan 50% tumpang tindih untuk frekuensi rata-rata, median, dan puncak mengurangi dispersi data tetapi menurunkan kemiringan frekuensi. Faktor lain yang berpengaruh adalah jenis jendela yang digunakan.

Penelitian oleh [7] menemukan bahwa STFT menggunakan jendela Tukey memberikan akurasi yang lebih baik daripada jendela Hann. Namun, penelitian [6] memiliki kekurangan karena tidak ada percobaan yang dilakukan untuk menggunakan sinyal EMG sebagai input pada pembelajaran mesin, sehingga tidak dapat mengetahui bagaimana hasil pengolahan sinyal dengan berbagai panjang jendela dan tumpang tindih dapat mempengaruhi kinerja pembelajaran mesin. Aplikasi terhadap temuan ini pada pembelajaran mesin memerlukan percobaan lanjutan untuk mengevaluasi pengaruhnya pada tugas yang spesifik. Sedangkan penelitian [7] hanya mempertimbangkan dua jenis jendela saja (jendela Hann dan Tukey) dan dua durasi segmen (100ms dan 200ms), sehingga kesimpulan dari penelitian ini mungkin tidak dapat diterapkan pada durasi segmen yang berbeda.

Berdasarkan kekurangan dari dua penelitian yang telah dilakukan, masih terdapat beberapa aspek yang perlu diperhatikan. Terdapat gap antara variasi parameter metode *windowing* pada penelitian [6] yang belum diterapkan dalam penelitian [7]. Oleh karena itu, diperlukan penelitian lanjutan untuk menganalisis efek dari variasi parameter metode *windowing* pada akurasi pembelajaran mesin dalam menyelesaikan tugas klasifikasi jari manusia.

Penelitian ini mengambil beberapa referensi penelitian lain sebagai tinjauan pustaka untuk memahami konteks penelitian lebih dalam. Dalam penelitian oleh [2] sebuah model jaringan AlexNet berhasil menghasilkan akurasi tinggi dalam mendeteksi aritmia menggunakan sinyal EKG, mencapai 99,94% dan 98,63% pada set pelatihan dan validasi (set A), serta 96,59% pada set pengujian. Sementara itu, penelitian [8] mengklasifikasikan gerakan tangan melalui sinyal EMG dengan jaringan saraf berulang LSTM dan GRU, mencapai kinerja terbaik sebesar 98,57%. [7] menggunakan sinyal sEMG untuk mengklasifikasikan gerakan jari, mencapai akurasi 85,29% dan 97,78%. [3] menyoroti pentingnya pemilihan parameter STFT dalam analisis spektrum EMG. Penelitian [6] memperkenalkan metode *slope recognition* menggunakan CNN untuk mengenali sinyal EMG dengan akurasi 99,94%. [1] membandingkan algoritma pembelajaran mesin dan *deep learning* dalam mengklasifikasikan gerakan tangan melalui sinyal EMG, dengan LSTM mencapai akurasi superior mendekati 99%. Sementara [5] menggabungkan pembelajaran mendalam dan sinyal EMG, mencapai akurasi uji 99,59% dan skor F1 99,57% dalam mengklasifikasikan gerakan tangan. Semua penelitian ini menghadirkan

kontribusi signifikan dalam pengembangan teknologi medis dan pengenalan pola sinyal biomedis.

2. METODE PENELITIAN

2.1 Analisis Sistem

Rancangan sistem untuk penelitian ini ditunjukkan untuk mendeteksi gerakan jari. Sistem ini menggunakan data sinyal EMG. Sistem pada penelitian ini melibatkan beberapa tahapan penting. Tahap pertama adalah persiapan penempelan elektroda pada lengan. Elektroda ditempatkan dengan benar pada kulit untuk mendapatkan sinyal EMG yang akurat dan stabil. Setelah elektroda ditempatkan, tahap selanjutnya adalah sensing EMG dengan Open BCI Ganglion. Open BCI Ganglion adalah alat yang memungkinkan pengguna untuk merekam dan memproses sinyal EMG dengan mudah dan efisien. Sinyal EMG yang terkumpul kemudian diolah melalui tahap preprocessing, di mana sinyal tersebut difilter dan dikondisikan agar sesuai dengan kebutuhan analisis. Tahap ekstraksi fitur kemudian dilakukan untuk mengidentifikasi pola-pola penting dalam sinyal EMG yang terkumpul. Fitur-fitur yang akan digunakan dalam analisis EMG, yaitu fitur waktu-frekuensi yang didapat dari proses Short Time Fourier Transform. Fitur-fitur spectrogram hasil dari sinyal EMG akan digunakan untuk membangun model yang dapat memberikan hasil klasifikasi untuk memprediksi gerakan jari hasil dari representasi sinyal EMG. Arsitektur AlexNet digunakan sebagai model pada penelitian ini, yang merupakan salah satu jenis algoritma neural network efektif dalam memproses data temporal seperti sinyal EMG yang memiliki input data dua dimensi berupa spectrogram. AlexNet dapat digunakan untuk memprediksi dan mengklasifikasikan aktivitas EMG dengan akurasi yang tinggi.

2.2 Peralatan Pendukung

Peralatan yang digunakan yaitu laptop sebagai perangkat pengembangan sistem. Perangkat keras merupakan perangkat utama untuk menjalankan perangkat lunak.

2.2.1 Peralatan Keras


Perangkat keras yang digunakan pada penelitian ini berperan dalam proses pelatihan dan pengujian sistem. Personal Computer (PC) berperan dalam pelatihan sistem memiliki spesifikasi prosesor AMD Ryzen 5 3200U with Radeon Vega Mobile Gfx 2.10 GHz, RAM 20 GB, *system type* 64-bit OS. Sedangkan perangkat pengambilan data yaitu Open BCI Ganglion Board dan Wifi Shield Open BCI.

2.2.1 Peralatan Lunak

Perangkat lunak berperan dalam tahapan pre-processing, pelatihan dan pengujian sistem. Spesifikasi perangkat lunak yang digunakan yaitu Python 3.10.6, Tensorflow 2.9.0, Keras 2.2.4.1, Numpy 1.24.0, Matplotlib 3.6.3, Librosa 0.10.1.

2.3 Implementasi Pengambilan Data


Implementasi pengambilan data diperoleh dari 33 partisipan, dengan rentang usia berkisar antara 20 hingga 29 tahun. Data tersebut dikumpulkan melalui perangkat Open BCI yang digunakan untuk merekam sinyal EMG dengan tingkat pengambilan sampel sebesar 1000 Hz selama periode 120 detik sesuai dengan diagram pewaktuan pengambilan data (gambar 2).



Gambar 1 Pewaktuan Pengambilan Data

2.4 Implementasi Pra-Pemrosesan

Implementasi tahap pemrosesan terdiri dari pelabelan data, filtrasi dengan *filter bandpass*, dan rektifikasi.



Gambar 2 Proses Preprocessing

2.4.1 Implementasi Pelabelan Data

Pelabelan data dilakukan setiap 24.000 baris data. Setiap kali mencapai 24.000 baris data label akan berganti. Label data pertama akan berulang setiap 120.000 baris data, yang berarti bahwa setelah mencapai 120.000 baris data, label akan kembali ke label awal dan melanjutkan proses ini dengan label-label berikutnya dalam urutan yang sama.

2.4.2 Implementasi Filter Bandpass dan Rektifikasi

Data setelah melalui proses pelabelan kemudian diterapkan *band pass filter* antara 15 Hz hingga 49 Hz untuk mengisolasi sinyal dalam rentang ini.

2.5 Implementasi Ekstraksi Ciri

Data dari 33 file yang telah melalui tahapan pra-pemrosesan akan diproses menjadi spektrogram dengan menerapkan metode *Short-Time Fourier Transform* (STFT). Setiap data spektrogram akan berisi 4000 data EMG (dengan panjang 4 detik dan sampel rate 1000Hz) untuk setiap *channel*. Setiap gerakan akan direpresentasikan oleh empat spektrogram karena masing-masing gerakan memiliki empat *channel*. Keempat spektrogram tersebut akan digabungkan secara horizontal menjadi satu dataset spektrogram yang mewakili satu gerakan dan akan digunakan sebagai input untuk model *deep learning* AlexNet. Proses ini akan diulangi untuk setiap data gerakan yang terdapat di 33 file sebelumnya. Setelah proses tersebut selesai, data spektrogram akhir akan dibagi menjadi tiga bagian, yaitu 80% data training, 10% data validasi, dan 10% data testing. Setelah pembagian data, kita akan memiliki 792 data untuk training, 99 data untuk validasi, dan 99 data untuk testing. Sebelum menjalankan proses STFT, tahap awal yang perlu dilakukan adalah menyiapkan parameter-parameter yang dibutuhkan untuk metode STFT, seperti ukuran jendela (*window size*), ukuran langkah (*hop size*), dan jenis jendela (*window type*).

Tabel 1 Parameter STFT

No	Parameter	Variasi Parameter
1	<i>Window Size</i> (ms)	100, 200, 300
2	<i>Hop Size</i> (%)	25, 50, 75
3	<i>Window Type</i>	<i>Hanning, Hamming, Blackman, Tukey</i>

Data akan diolah menggunakan metode STFT dengan berbagai kombinasi tiga *window size*, empat *hop size*, dan empat *window type* sesuai dengan yang tertera dalam Tabel 1. Total dari kombinasi-kombinasi ini adalah sebanyak 36 variasi parameter yang akan digunakan dalam pengolahan data dengan metode STFT.

2.6 Implementasi Pelatihan Model

Data spectrogram hasil penerapan metode STFT menghasilkan 792 data pelatihan, 99 validasi, dan 99 data pengujian. Kemudian akan diolah satu persatu ke model *deep learning* AlexNet.

Tabel 2 Arsitektur AlexNet

Layer	Type Layer	Jumlah Filter	Unit	Ukuran Filter	Stride
0	Input	-	-	-	-
1	Con2D, GeLu Activate	96	-	11x11	4x4
	Max-pooling	-	-	3x3	2x2
2	Con2D, GeLu Activate	256	-	5x5	-
	Max-pooling	-	-	3x3	2x2
3	Con2D, GeLu Activate	384	-	3x3	-
4	Con2D, GeLu Activate	384	-	3x3	-
5	Con2D, GeLu Activate	256	-	3x3	-
	Max-pooling	-	-	3x3	2x2
6	Flatten	-	-	-	-
7	Fully Connected, GeLu Activate	-	4096	-	-
	Dropout (0,5)	-	-	-	-
8	Fully Connected, GeLu Activate	-	4096	-	-
	Dropout (0,5)	-	-	-	-
9	Fully Connected, Softmax	-	5	-	-

2.7 Implementasi Evaluasi Model

Pengujian model dilaksanakan dengan memanfaatkan data uji, yang telah kita alokasikan sebesar 10% dari seluruh dataset yang telah dipersiapkan sebelumnya. Untuk mengukur performa model, kami akan menerapkan metode yang dikenal sebagai confusion matrix. Metode ini memungkinkan kita untuk membandingkan hasil prediksi dari model dengan

label yang sebenarnya pada data uji. Dari perbandingan ini, berbagai metrik evaluasi akan dihitung, termasuk akurasi, presisi rata-rata, recall rata-rata, dan nilai *f1-score*.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Perbandingan Keseluruhan Model

Kombinasi parameter *window size* 300, *hop size* 50%, dan *window type* Hamming memiliki nilai *accuracy*, *recall*, presisi, dan *f1-score* terbaik dari seluruh kombinasi parameter STFT, Sehingga menghasilkan rata-rata keseluruhan matrik evaluasi yang paling tinggi.

Tabel 3 Data Matrik Evaluasi dari Data Testing

No	Window Size	Hop Size	Window Type	Accuracy	Recall	Presisi	F1	Rata-Rata Matrik Evaluasi
1	300	50%	Hamming	96,97%	97,02	96,91%	96,87%	96,94%
2	100	25%	Hanning	96,97%	96,88	96,88%	96,86%	96,90%
3	100	25%	Hamming	91,92%	96,88	96,88%	96,86%	95,64%
4	300	75%	Hamming	94,95%	95,20	94,85%	94,95%	94,99%
5	300	50%	Hanning	93,94%	94,08	93,69%	93,73%	93,86%
6	300	75%	Tukey	93,94%	93,95	93,88%	93,82%	93,90%
7	200	25%	Hanning	93,94%	93,84	93,66%	93,54%	93,75%
8	100	50%	Hanning	93,94%	93,40	93,86%	93,45%	93,66%
9	100	50%	Blackman	92,93%	93,22	93,12%	92,92%	93,05%
10	200	50%	Blackman	92,93%	93,08	92,77%	92,88%	92,92%
11	100	75%	Hanning	91,92%	92,77	93,45%	92,03%	92,54%
12	200	75%	Hanning	92,93%	92,73	92,38%	92,43%	92,62%
13	100	25%	Blackman	91,92%	92,08	91,93%	91,96%	91,97%
14	200	25%	Blackman	91,92%	91,73	92,19%	91,93%	91,94%
15	100	50%	Tukey	91,92%	91,71	92,36%	91,39%	91,85%
16	100	25%	Tukey	90,91%	90,73	90,88%	90,73%	90,81%
17	200	25%	Hamming	89,90%	89,72	90,31%	89,91%	89,96%
18	100	75%	Blackman	88,89%	88,64	89,10%	88,69%	88,83%
19	200	75%	Blackman	87,88%	88,46	88,95%	87,84%	88,28%
20	300	25%	Tukey	87,88%	87,82	87,35%	87,34%	87,60%
21	300	50%	Blackman	85,86%	86,67	86,55%	86,01%	86,27%
22	300	50%	Tukey	86,87%	86,38	89,13%	86,77%	87,29%
23	300	25%	Blackman	84,85%	85,23	85,21%	84,96%	85,06%
24	300	25%	Hanning	83,84%	84,78	85,82%	84,05%	84,62%
25	300	75%	Blackman	82,83%	82,08	82,98%	81,93%	82,46%
26	100	50%	Hamming	81,82%	81,38	81,56%	81,21%	81,49%
27	200	50%	Tukey	80,81%	80,82	81,42%	80,37%	80,86%
28	100	75%	Hamming	76,77%	78,58	80,80%	76,47%	78,16%
29	300	25%	Hamming	79,80%	78,43	86,22%	78,05%	80,63%
30	200	25%	Tukey	78,79%	77,13	79,07%	77,18%	78,04%
31	200	50%	Hanning	75,76%	76,88	79,38%	75,66%	76,92%
32	200	75%	Hamming	75,76%	76,85	78,59%	75,29%	76,62%
33	200	50%	Hamming	72,73%	73,91	80,07%	72,74%	74,86%
34	300	75%	Hanning	71,72%	72,89	78,18%	71,54%	73,58%
35	200	75%	Tukey	70,71%	71,07	71,90%	69,47%	70,79%
36	100	75%	Tukey	61,62%	61,30	61,31%	59,24%	60,87%

3.2 Hasil Perbandingan Model Deep Learning AlexNet Berdasarkan Window Size

Hasil dalam Tabel 3 dapat dianalisis lebih mendalam untuk mengevaluasi dampak dari *window size*. Analisa grafik perbandingan akurasi, *recall*, presisi, dan *f1 score* dari 3 parameter

window size (100ms, 200ms, 300ms) dilakukan terhadap 12 kombinasi parameter (3 parameter *hop size* dan 4 parameter *window type* pada tabel 1). Analisa ini dilakukan agar bisa menilai perbandingan *window size* secara objektif tanpa terpengaruh parameter lain dalam menghasilkan nilai akurasi, *recall*, presisi, dan *f1 score*.

Hasil analisa akurasi, *recall*, presisi, dan *f1 score* (Tabel 4, Tabel 5, Tabel 6, Tabel 7) didapat dengan menjumlahkan berapa kali frekuensi kemenangan dalam analisa grafik *window size*. Semua *window size* dipasangkan dengan 12 kombinasi parameter lain di masing masing matrik evaluasi untuk mengetahui kemenangan dalam analisis grafik *window size*.

Berdasarkan empat tabel tersebut *window size* 100ms memiliki frekuensi kemenangan paling banyak dibanding *window size* 200ms dan 300ms di seluruh matrik evaluasi

Tabel 4 Hasil Analisa Grafik Akurasi *Window Size*

Window Size	Jumlah Poin
100	8
200	3
300	4

Tabel 5 Hasil Analisa Grafik *Recall Window Size*

Window Size	Jumlah Poin
100	9
200	0
300	3

Tabel 6 Analisa Grafik Presisi *Window Size*

Window Size	Jumlah Poin
100	9
200	0
300	3

Tabel 7 Hasil Analisa Grafik *F1 Score Window Size*

Window Size	Jumlah Poin
100	9
200	0
300	3

3.3 Hasil Perbandingan Model Deep Learning AlexNet Berdasarkan Hop Size

Analisa grafik perbandingan akurasi, *recall*, presisi, dan *f1 score* dari 3 parameter *hop size* (25%, 50%, 75%) dilakukan terhadap 12 kombinasi parameter (3 parameter *window size* dan 4 parameter *window type* pada tabel 1). Analisa ini dilakukan agar bisa menilai perbandingan *hop size* secara objektif tanpa terpengaruh parameter lain dalam menghasilkan nilai akurasi, *recall*, presisi, dan *f1 score*.

Hasil analisa akurasi, *recall*, presisi, dan *f1 score* (Tabel 8, Tabel 9, Tabel 10, Tabel 11) didapat dengan menjumlahkan berapa kali frekuensi kemenangan dalam analisa grafik *hop size*. Semua *hop size* dipasangkan dengan 12 kombinasi parameter lain di masing masing matrik evaluasi untuk mengetahui kemenangan dalam analisis grafik *hop size*.

Berdasarkan empat tabel tersebut *hop size* 50% memiliki frekuensi kemenangan paling banyak dibanding *hop size* 25% dan 75% di seluruh matrik evaluasi

Tabel 8 Hasil Analisa Grafik Akurasi Hop Size

Hop Size	Jumlah Poin
25%	4
50%	7
75%	1

Tabel 9 Hasil Analisa Grafik Recall Hop Size

Hop Size	Jumlah Poin
25%	4
50%	7
75%	1

Tabel 10 Hasil Analisa Grafik Presisi Hop Size

Hop Size	Jumlah Poin
25%	4
50%	7
75%	1

Tabel 11 Hasil Analisa Grafik *F1 Score Hop Size*

Hop Size	Jumlah Poin
25%	4
50%	7
75%	1

3.4 Hasil Perbandingan Model Deep Learning AlexNet Berdasarkan Window Type

Analisa grafik perbandingan akurasi, *recall*, presisi, dan *f1 score* dari 4 parameter *window type* (Hanning, Hamming, Blackman, Tukey) dilakukan terhadap 9 kombinasi parameter (3 parameter *window size* dan 3 parameter *hop size* pada tabel 1). Analisa ini dilakukan agar bisa menilai perbandingan *window type* secara objektif tanpa terpengaruh parameter lain dalam menghasilkan nilai akurasi, *recall*, presisi, dan *f1 score*.

Hasil analisa akurasi, *recall*, presisi, dan *f1 score* (Tabel 12, Tabel 13, Tabel 14, Tabel 15) didapat dengan menjumlahkan berapa kali frekuensi kemenangan dalam analisa grafik *window type*. Semua *window type* dipasangkan dengan 12 kombinasi parameter lain di masing masing matrik evaluasi untuk mengetahui kemenangan dalam analisis grafik *window type*.

Berdasarkan empat tabel tersebut *window type* Hanning memiliki frekuensi kemenangan paling banyak dibanding *window type* Hamming, Blackman, dan Tukey di seluruh matrik evaluasi

Tabel 12 Hasil Analisa Grafik Akurasi *Window Type*

Window Type	Jumlah Poin
Hanning	5
Hamming	2
Blackman	1
Tukey	1

Tabel 13 Hasil Analisa Grafik *Recall Window Type*

Window Type	Jumlah Poin
Hanning	5
Hamming	3
Blackman	1
Tukey	1

Tabel 14 Hasil Analisa Grafik Presisi *Window Type*

Window Type	Jumlah Poin
Hanning	5
Hamming	3
Blackman	1
Tukey	1

Tabel 15 Hasil Analisa Grafik *F1 Score Window Type*

Window Type	Jumlah Poin
Hanning	5
Hamming	3
Blackman	1
Tukey	1

4. KESIMPULAN

Berdasarkan pengujian, pengamatan, dan analisis hasil yang diperoleh, dapat disimpulkan bahwa kombinasi parameter dengan *window size* 300, *hop size* 50%, dan *window type* Hamming memiliki performa terbaik dari keseluruhan kombinasi parameter yang berjumlah 36 kombinasi. Analisis setiap parameter menunjukkan bahwa *window size* 100 secara rata-rata lebih baik daripada 200 dan 300, sementara *hop size* 50% secara rata-rata lebih baik daripada 25% dan 75%. Selain itu, *window type* Hanning secara rata-rata tampil lebih baik daripada Hamming, Blackman, dan Tukey dalam semua kombinasi parameter.

5. SARAN

Penelitian ini memiliki potensi yang baik, namun masih memerlukan beberapa perbaikan. Saran-saran yang dapat meningkatkan kualitas penelitian berikutnya termasuk penggunaan dataset yang lebih besar untuk menghindari pemampatan data EMG yang signifikan saat dikonversi menjadi data spektrogram dalam domain frekuensi.

DAFTAR PUSTAKA

- [1] S. Alam, M. S. Kabir, M. N. Hossain, Q. R. Hasnaine, dan M. G. Rabiul Alam, "Classification Accuracy Comparison between Machine Learning Algorithms and a Deep Learning Algorithm in Predicting Hand Gestures," dalam Conference of Open Innovation

- Association, FRUCT, 2022-November, pp. 22–29, 2022. <https://doi.org/10.23919/FRUCT56874.2022.9953843>.
- [2] H. Dang, M. Sun, G. Zhang, X. Qi, X. Zhou, dan Q. Chang, "A Novel Deep Arrhythmia-Diagnosis Network for Atrial Fibrillation Classification Using Electrocardiogram Signals," IEEE Access, vol. 7, pp. 75577–75590, 2019. <https://doi.org/10.1109/ACCESS.2019.2918792>.
- [3] C. De la Fuente, E. Martinez-Valdes, J. I. Priego-Quesada, A. Weinstein, O. Valencia, M. R. Kunzler, J. Alvarez-Ruf, dan F. P. Carpes, "Understanding the effect of window length and overlap for assessing sEMG in dynamic fatiguing contractions: A non-linear dimensionality reduction and clustering," Journal of Biomechanics, vol. 125, 2021. <https://doi.org/10.1016/j.jbiomech.2021.110598>.
- [4] H. Jeon, Y. Jung, S. Lee, dan Y. Jung, "Area-efficient short-time fourier transform processor for time–frequency analysis of non-stationary signals," Applied Sciences (Switzerland), vol. 10, no. 20, pp. 1–10, 2020. <https://doi.org/10.3390/app10207208>.
- [5] M. A. Ozdemir, D. H. Kisa, O. Guren, A. Onan, dan A. Akan, "EMG based Hand Gesture Recognition using Deep Learning," dalam TIPTEKNO 2020 - Tip Teknologjleri Kongresi - 2020 Medical Technologies Congress, TIPTEKNO 2020, 2020. <https://doi.org/10.1109/TIPTEKNO20054.2020.9299264>.
- [6] W. Ren, Y. Liu, Q. Song, dan H. Deng, "Slope recognition based on human body surface EMG signal Using CNN," dalam Proceedings - 2022 3rd International Conference on Electronic Communication and Artificial Intelligence, IWECAI 2022, pp. 58–62, 2022. <https://doi.org/10.1109/IWECAI55315.2022.00019>.
- [7] R. S. Worasawate, P. Laohapiengsak, dan M. Wangkid, "CNN Classification of Finger Movements using Spectrum Analysis of sEMG Signals," dalam ICSEC 2021 - 25th International Computer Science and Engineering Conference, pp. 138–142, 2021. <https://doi.org/10.1109/ICSEC53205.2021.9684641>.
- [8] D. Xiong, D. Zhang, X. Zhao, dan Y. Zhao, "Hand Gesture Recognition Using Instant High-density EMG Graph via Deep Learning Method," dalam Proceedings - 2020 Chinese Automation Congress, CAC 2020, pp. 5143–5148, 2020. <https://doi.org/10.1109/CAC51589.2020.9326536>.
- [9] W. Alexander dan C. M. Williams, "Digital Signal Processing: Principles, Algorithms and System Design," dalam Digital Signal Processing: Principles, Algorithms and System Design.

- [10] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (n.d.). *ImageNet Classification with Deep Convolutional Neural Networks*. <http://code.google.com/p/cuda-convnet/>