

Klasifikasi Sinyal EEG Untuk Mengenali Jenis Emosi Menggunakan Recurrent Neural Network

Aspirani Utari¹, Dian Palupi Rini^{2,*}, Winda Kurnia Sari³, Tommy Saputra⁴

¹Magister Ilmu Komputer, Faculty of Computer Science, Universitas Sriwijaya, Palembang, Indonesia

²Artificial Intelligence Laboratory, Faculty of Computer Science, Universitas Sriwijaya, Palembang, Indonesia

³Information System, Faculty of Computer Science, Universitas Sriwijaya, Palembang, Indonesia

⁴USS Artificial Intelligence Research Group, Faculty of Computer Science, Universitas Sumatera Selatan, Palembang, Indonesia

Email: ¹09012682226006@student.unsri.ac.id, ^{2,*}dprini@unsri.ac.id, ³windakurniasari@unsri.ac.id, ⁴tommysaputra@uns.ac.id

Email Penulis Korespondensi: dprini@unsri.ac.id

Submitted: 15/12/2023; Accepted: 25/12/2023; Published: 26/12/2023

Abstrak—Penelitian ini berfokus pada eksplorasi mendalam dan analisis tentang penerapan dua jenis Recurrent Neural Network (RNN), yakni Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Dua model tersebut dilatih dengan parameter yang sama, terdiri dari tiga lapisan, menggunakan fungsi aktivasi relu, dan menerapkan 1 tingkat dropout. Dalam rangka membandingkan kinerja keduanya, dilakukan percobaan dengan menggunakan tiga kelompok dataset untuk keperluan pelatihan dan evaluasi performa. Evaluasi tersebut mencakup metrik-metrik seperti akurasi, recall, F1-score, dan area di bawah kurva (AUC). Dataset yang digunakan adalah eeg emotion yang terdiri dari 2458 variabel unik. Dalam hal kinerja, LSTM berhasil mengungguli performa GRU dalam tugas klasifikasi data emosi berdasarkan sinyal eeg. Di sisi lain, GRU menunjukkan kelebihan dalam percepatan proses pelatihan dibandingkan LSTM. Meskipun akurasi kedua metode hampir serupa dalam semua pembagian data, namun dalam evaluasi kurva ROC, model LSTM mendemonstrasikan keunggulan dengan kurva yang lebih optimal dibandingkan GRU.

Kata Kunci: Long Short-Term Memory; Gated Recurrent Unit; Klasifikasi Emosi; Sinyal EEG

Abstract—This research focuses on in-depth exploration and analysis of the application of two types of Recurrent Neural Network (RNN), namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU). The two models are drilled with the same parameters, consist of three layer, use the relu activation function, and apply 1 dropout level. In order to compare the performance of the two, experiments were carried out using five groups of datasets for training and performance evaluation purposes. The evaluation includes metrics such as accuracy, recall, F1-score, and area under the curve (AUC). The dataset used is Eeg Emotion which contains 2458 unique variables. In terms of performance, LSTM succeeded in outperforming GRU in the task of classifying emotional data based on EEG signals. On the other hand, GRU shows advantages in accelerating the training process compared to LSTM. Although the accuracy of both methods is almost similar in all data divisions, in the evaluation of the ROC curve, the LSTM model demonstrates superiority with a more optimal curve compared to GRU.

Keywords: Long Short-Term Memory; Gated Recurrent Unit; Emotion Classification; EEG Signals

1. PENDAHULUAN

Kemampuan untuk mendeteksi kondisi mental secara otonom berguna untuk berbagai tujuan di berbagai bidang seperti robotika, perawatan kesehatan, pendidikan, ilmu saraf dan lain-lain. Pentingnya mekanisme interaksi manusia-mesin yang efisien meningkat seiring dengan banyaknya skenario kehidupan nyata di mana perangkat pintar, termasuk robot otonom dapat diterapkan. Salah satu dari sekian banyak alternatif yang dapat digunakan untuk berinteraksi dengan mesin adalah melalui sinyal aktivitas otak. Sinyal - sinyal ini, yang disebut electroencephalogram atau disingkat EEG, menyampaikan informasi mengenai voltase yang diukur oleh elektroda (kering atau basah) yang ditempatkan di sekitar kulit kepala seseorang [1]. Fisiologis dan psikologis studi telah menunjukkan bahwa perubahan sinyal fisiologis cenderung lebih dekat dengan emosi nyata seseorang daripada ekspresi wajah, postur atau suara [2]. Emosi merupakan reaksi terhadap seseorang atau suatu kejadian, dimana emosi dibagi menjadi dua keluaran yaitu positif dan negatif. Dari dua keluaran tersebut ada beberapa kategori di dalamnya seperti marah, senang, sedih, takut dan sebagainya [3]. Rangsangan untuk membangkitkan emosi untuk studi berbasis EEG sering ditemukan paling baik dengan musik [4] dan film [5]. Pola aktivasi karena rangsangan visual emosional pada sinyal EEG berbeda satu sama lain, tingkat aktivasi yang terkecil (terendah) jika netral membangkitkan emosi seperti sungai, isyarat burung, keindahan alam, taman bunga dan lain -lain. Sedangkan positif dan negatif berdampak pada aktivasi saraf dalam bentuk yang berbeda membangkitkan emosi dikarenakan video emosional [6]. Output dari sinyal EEG adalah data time-series. Oleh karena itu, membandingkan data keluaran dengan sinyal EEG standar dapat diketahui emosi, penyakit atau masalah yang terjadi [7].

Nilai rata - rata yang dinormalisasi dari jendela waktu yang diekstraksi dari elektroda AF7 saat diamati menunjukkan bahwa nilai minimum dan maksimum paling sering dipetakan ke emosi negatif, sedangkan positif dan netral sangat erat kaitannya, memiliki aturan yang tumpang tindih satu sama lain seperti harapan dan kesedihan yang masing - masing dianggap positif dan negatif tetapi sering dialami serentak [8]. Beberapa metode kemampuan klasifikasi diterapkan seperti RandomForest, Support Vector Machine (SVM) linier dan Diskriminan Fisher yang sudah mencapai akurasi tinggi, namun performa tinggi dari perceptron multilayer sederhana menunjukkan model

jaringan saraf bisa efektif, terutama yang lebih kompleks yang telah bekerja dengan baik dalam berbagai eksperimen klasifikasi [9].

Metode deep learning telah menghasilkan kinerja yang baik dan menunjukkan klasifikasi yang lebih unggul dibandingkan dengan metode konvensional machine learning [10]. Deep Learning memiliki keuntungan dalam membangun arsitektur yang mendalam untuk mempelajari informasi yang lebih abstrak. Sifat terpenting dari metode pembelajaran mendalam adalah bahwa metode ini dapat secara otomatis mempelajari representasi fitur sehingga menghindari banyak rekayasa yang memakan waktu [11].

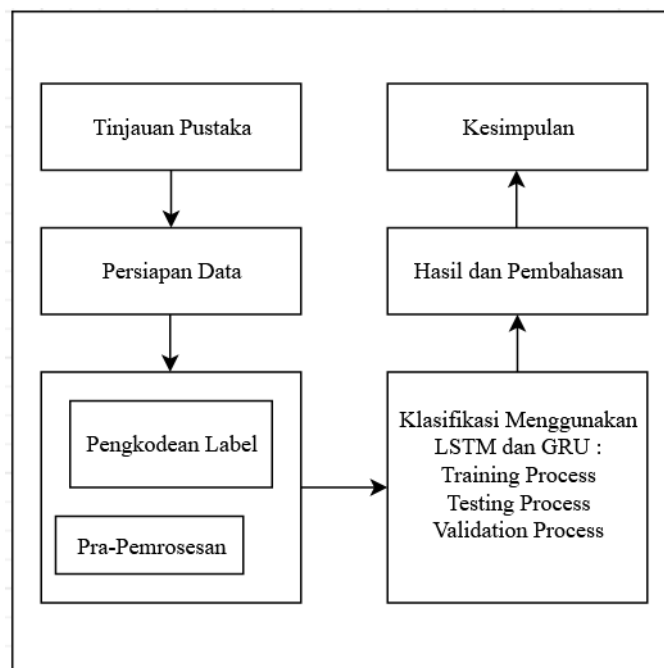
Metode dalam pengklasifikasian sinyal EEG pada beberapa penelitian bervariasi, seperti OneR dan Jaringan Bayes [8], mencapai akurasi keseluruhan sekitar 97,89%, mengungguli keadaan terkini dengan 2,99 poin persentase, EEG signal classification using LSTM and improved neural network algorithms [12], LSTM dan NN yang ditingkatkan diusulkan untuk kinerja yang lebih baik dengan akurasi masing-masing 71,3% dan 78,9%, dalam klasifikasi EEG.

Beberapa contoh teknik deep learning yang digunakan untuk pemrosesan sinyal EEG antara lain convolutional neural network [13], Generative Adversarial Networks [14], autoencoder [15], Long Short-Term Memory [16], Transfer Learning [17]. Salah satu metode deep learning yang diusulkan pada penelitian ini adalah Recurrent Neural Network. Hal ini dikarenakan algoritma RNN bekerja untuk memproses data yang bersifat sekuensial. Hal ini selaras dengan data sinyal EEG yang sekuensial dimana mengasumsikan bahwa input dan output tergantung satu sama lain.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Umumnya, langkah-langkah yang diterapkan dalam metodologi penelitian ini melibatkan penggunaan kerangka kerja yang terstruktur untuk memandu setiap tahapan. Kerangka penelitian yang digunakan seperti yang terlihat pada Gambar 1, terdiri dari tahap tinjauan pustaka yang mencakup evaluasi studi dalam rentang 1 sampai 5 tahun terakhir. Dilanjutkan dengan fase persiapan data, dataset EEG Emosi dengan lebih dari 2.100 sampel data digunakan. Setelah itu, tahap pra-pemrosesan dilakukan dengan merubah kategori atau label data menjadi representasi numerik. Pengklasifikasian menggunakan arsitektur jaringan saraf rekuren (RNN), khususnya LSTM dan GRU. Proses pengklasifikasian ini meliputi tiga tahapan: pelatihan, validasi, dan pengujian. Langkah akhir melibatkan analisis hasil serta penarikan kesimpulan berdasarkan temuan yang diperoleh.



Gambar 1. Kerangka Penelitian

2.2 Persiapan Data

Dalam rangka eksperimen, digunakan dataset EEG yang difokuskan pada penangkapan pola gelombang otak yang terkait dengan berbagai emosi dan perasaan. Dataset ini terdiri dari 2549 variabel dan 2132 baris data. Di antara variabel tersebut, 2548 berisi data dalam format desimal, sedangkan 1 variabel lainnya berisi data dalam bentuk string yang berfungsi sebagai label.

Data direkam dari dua partisipan yang terdiri dari satu laki-laki dan satu perempuan untuk menentukan kondisi netral, positif, dan negatif. Pengumpulan data ini dilakukan melalui penggunaan headband Muse EEG yang dilengkapi dengan elektroda kering, yang memungkinkan untuk merekam aktivitas EEG pada titik lokasi TP9, AF7, AF8, dan TP10 [18],[19]. Dataset ini dijelaskan lebih lanjut dalam Tabel 1, dengan spesifikasi sebagai berikut:

Tabel 1. Data Label

Label	Jumlah Label
Positive	708
Negative	708
Neutral	716
Total	2132

Langkah berikutnya dalam persiapan data adalah melakukan pengecekan missing value, yang mencakup identifikasi apakah terdapat nilai yang hilang dalam dataset dan sejauh mana nilai-nilai tersebut memengaruhi kualitas data. Ini terilustrasikan pada Gambar 2.

```
# Checking for missing values
for col in df.columns:
    if(df[col].isnull().sum()>0):
        print(col)
```

Gambar 2. Pengecekan missing values

2.3. Pra-pemrosesan

Dalam penelitian ini, label encoding digunakan untuk mengkonversi variabel kelas yang awalnya dalam bentuk data string menjadi nilai numerik. Proses transformasi label atau kelas dari dataset terlihat pada Gambar 3. Dalam gambar tersebut, terdapat tiga kelas yang semula dalam bentuk string, yaitu "Neutral" diubah menjadi kelas 0, "Positive" diubah menjadi kelas 1, dan "Negative" diubah menjadi kelas 2.

```
# Mapping for labels
label_mapping = {'NEUTRAL': 0, 'POSITIVE': 1, 'NEGATIVE': 2}

# Added a new label column with numeric values based on the mapping
dataframe['numeric_label'] = dataframe['label'].map(label_mapping)

# Import LabelEncoder from sklearn.preprocessing
from sklearn.preprocessing import LabelEncoder

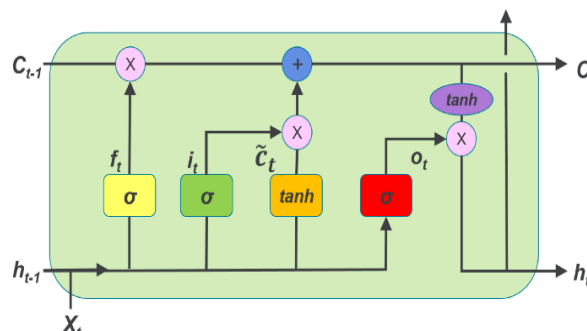
# Initialize LabelEncoder
model_label_encoding = LabelEncoder()

# Do a label transformation to a numeric value
dataframe['label'] = model_label_encoding.fit_transform(dataframe['label'])
```

Gambar 3. Transformasi label

2.4 Long Short-Term Memory

Mekanisme gerbang LSTM mengimplementasikan tiga lapisan: (1) input gate, (2) forget gate, dan (3) output gate [20]. Setiap unit arsitektur LSTM yang ditampilkan dalam Gambar 4 memiliki sel memori, dan keadaan pada waktu t direpresentasikan sebagai c_t . Proses membaca dan memodifikasi dikendalikan oleh gerbang sigmoid dan mempengaruhi gerbang masukan i_t , gerbang forget f_t dan gerbang keluaran o_t .



Gambar 4. Arsitektur LSTM

Di bawah ini merupakan rumus persamaan dari semua gerbang LSTM:

Gerbang Masukan:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{1}$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{2}$$

Gerbang Masukan:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{3}$$


Gerbang Masukan:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{4}$$

Proses pembuatan model pada penelitian ini dimulai dengan membangun layer input sesuai dengan bentuk data latihan. Kemudian, layer LSTM diimplementasikan dengan ukuran neuron 128, dirancang untuk menghasilkan keluaran sekuensial. Setelah itu, digunakan layer Dense dengan 64 neuron dan aktivasi ReLU untuk melanjutkan ekstraksi fitur dari keluaran LSTM. Terakhir, digunakan layer output dengan 3 neuron dan aktivasi softmax untuk menghasilkan prediksi klasifikasi dalam konteks multi-kelas. Model lengkap dirangkai dengan menggabungkan layer input dan output menggunakan kelas Model dari Keras. Langkah-langkah ini dirancang untuk menciptakan model LSTM yang efektif dalam mengolah data sekuensial dan melakukan tugas klasifikasi dengan akurasi yang tinggi.

2.5 Gated Recurrent Units

GRU merupakan mekanisme gating dalam RNN, mirip dengan LSTM yang memiliki gerbang lupakan, namun dengan jumlah parameter yang lebih sedikit karena tidak menyertakan gerbang keluaran. Meskipun LSTM lebih kuat daripada GRU karena kemampuannya untuk melakukan perhitungan yang lebih kompleks, GRU tetap memiliki kegunaan yang signifikan [21]. Gambaran arsitektur GRU dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur GRU

Untuk melakukan perbandingan dan mendapatkan model terbaik, model yang sama dengan yang dibangun menggunakan LSTM juga dikonstruksi menggunakan GRU. Proses ini dimulai dengan mendefinisikan layer input sesuai dengan bentuk data latihan. Layer GRU diimplementasikan dengan ukuran neuron 128, dirancang untuk menghasilkan keluaran sekuensial. Data yang diperoleh dari lapisan GRU kemudian diproses lebih lanjut dengan menggunakan layer Flatten untuk mengubahnya menjadi format 1D. Layer Dense dengan 64 neuron dan aktivasi ReLU digunakan untuk melanjutkan ekstraksi fitur. Terakhir, layer output dengan 3 neuron dan aktivasi softmax digunakan untuk menghasilkan prediksi klasifikasi dalam konteks multi-kelas. Dengan melakukan langkah-langkah yang serupa dengan model LSTM, model GRU ini dapat dibandingkan untuk mendapatkan hasil terbaik.

2.6 Confusion Matrix

Dalam penelitian ini, digunakan matriks kebingungan multikelas dengan 3 kelas, di mana untuk menghitung nilai akurasi, presisi, recall, dan F1-score seperti yang ditunjukkan dalam persamaan 5-8. Langkah-langkah evaluasi dasar dari confusion matrix menghasilkan persamaan-persamaan berikut:

$$\text{Accuracy} = \frac{\sum_{i=1}^I \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}}{I} * 100\% \tag{5}$$

$$\text{Precision} = \frac{\sum_{i=1}^I TP_i}{\sum_{i=1}^I (FP_i + TP_i)} * 100\% \tag{6}$$

$$\text{Recall} = \frac{\sum_{i=1}^I TP_i}{\sum_{i=1}^I (TP_i + FN_i)} * 100\% \tag{7}$$

$$\text{F1 score} = \frac{2 * \text{Presisi} * \text{Recall}}{\text{Presisi} + \text{Recall}} \tag{8}$$

2.7 Pengujian Data dan Pemisahan Pelatihan Data

Pada penelitian ini, pembagian data latih dan uji dilakukan dalam tiga skenario seperti disajikan pada Tabel 2.

Tabel 2. Pembagian data

Validasi	Data
Validasi pertama	Data latih 90% dan data uji 10%
Validasi kedua	Data latih 80% dan data uji 20%
Validasi ketiga	Data latih 70% dan data uji 30%

3. HASIL DAN PEMBAHASAN


Dalam penelitian ini, dilakukan perbandingan antara model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam pengenalan emosi berdasarkan data EEG. Hasil perbandingan menunjukkan bahwa meskipun kedua model menggunakan jumlah layer yang sama, model LSTM memiliki tingkat akurasi yang sedikit lebih tinggi daripada model GRU dalam berbagai skenario pembagian data latih dan uji. Hasil ini menunjukkan bahwa meskipun arsitektur model serupa, ada perbedaan performa yang dapat dihubungkan dengan karakteristik masing-masing mekanisme gating dalam LSTM dan GRU.

Faktor yang mungkin memengaruhi hasil kurang optimal dari model GRU adalah interaksi antara komponen gerbang yang ada dalam arsitektur GRU. Meskipun GRU memiliki lebih sedikit parameter daripada LSTM, interaksi antara gerbang masukan, gerbang reset, dan unit aktual dalam GRU mungkin memiliki dampak yang berbeda pada kemampuan model untuk mengingat informasi sekuensial dengan baik. Selain itu, pengaruh dari jumlah layer yang sama pada kedua model dapat memberikan wawasan tentang bagaimana arsitektur GRU dan LSTM merespon kompleksitas data EEG.


Meskipun hasil GRU tidak lebih baik dalam penelitian ini, menunjukkan bahwa pilihan antara LSTM dan GRU harus didasarkan pada tujuan dan karakteristik spesifik dari tugas pengenalan emosi berdasarkan data EEG. Kemungkinan adanya faktor-faktor lain yang mempengaruhi hasil juga dapat dijelajahi lebih lanjut dalam studi berikutnya. Diskusi lebih lanjut mengenai interpretasi hasil dan implikasi praktis dari perbandingan ini akan memberikan pandangan yang lebih mendalam tentang kelebihan dan keterbatasan masing-masing model dalam konteks pengenalan emosi.

3.1 Hasil validasi pertama


Pada validasi pertama, dilakukan pembagian data latih sebesar 90% dan data uji sebesar 10%, dengan parameter dan jumlah layer yang identik pada model LSTM dan GRU. Hasil dari validasi ini direpresentasikan melalui grafik ROC akurasi yang dapat ditemukan pada Gambar 6 dan Gambar 7. Selain itu, perkembangan kurva loss ROC juga dapat diamati melalui visualisasi pada Gambar 8 dan Gambar 9.




Gambar 6. Kurva akurasi LSTM



Gambar 7. Kurva akurasi GRU



Gambar 8. Kurva loss LSTM



Gambar 9. Kurva loss GRU

Hasil dari validasi pertama juga direpresentasikan melalui confusion matrix yang dapat ditemukan pada Gambar 10 untuk model LSTM dan Gambar 11 untuk model GRU. Perolehan akurasi dari kedua model ini mengindikasikan bahwa model LSTM berhasil mencapai akurasi maksimal 99%, sementara model GRU memiliki akurasi sebesar 97%.

```

7/7 [=====] - 1s 55ms/step
      precision    recall  f1-score   support

     0       1.00      0.97      0.98         63
     1       1.00      0.99      0.99         82
     2       0.96      1.00      0.98         69

 accuracy                   0.99         214
 macro avg                   0.99         214
 weighted avg                 0.99         214
    
```

Gambar 10. Hasil Kinerja Evaluasi LSTM

```

7/7 [=====] - 1s 54ms/step
      precision    recall  f1-score   support


     0       0.98      0.98      0.98         63
     1       0.95      0.99      0.97         82
     2       0.97      0.93      0.95         69

 accuracy                   0.97         214
 macro avg                   0.97         214
 weighted avg                 0.97         214
    
```


Gambar 11. Hasil Kinerja Evaluasi GRU

3.2 Hasil validasi kedua


Pada tahap validasi kedua, data latih dibagi menjadi 80% dan data uji sebesar 20%, dengan parameter dan jumlah lapisan yang sama pada model LSTM dan GRU. Meskipun hasil validasi ini belum sepenuhnya memuaskan, grafik ROC akurasi dapat dilihat pada Gambar 12 dan Gambar 13, di mana kurva yang dihasilkan oleh model LSTM lebih baik dibandingkan dengan model GRU. Selain itu, perubahan dalam kurva loss ROC juga dapat diamati melalui visualisasi pada Gambar 14 dan Gambar 15.




Gambar 12. Kurva akurasi LSTM



Gambar 13. Kurva akurasi GRU



Gambar 14. Kurva loss LSTM



Gambar 15. Kurva loss GRU

Selain itu, hasil dari validasi kedua juga dipaparkan melalui confusion matrix yang dapat ditemukan pada Gambar 16 untuk model LSTM dan Gambar 17 untuk model GRU. Hasil akurasi dari kedua model ini menunjukkan bahwa baik model LSTM maupun GRU memiliki akurasi sebesar 97%.

```

14/14 [=====] - 1s 53ms/step
precision    recall  f1-score   support

   0         0.98    0.97    0.98     115
   1         1.00    0.95    0.97     164
   2         0.93    0.99    0.96     148

 accuracy          0.97     427
 macro avg         0.97    0.97    0.97     427
 weighted avg      0.97    0.97    0.97     427
    
```

Gambar 16. Hasil Kinerja Evaluasi LSTM

```

14/14 [=====] - 1s 52ms/step
precision    recall  f1-score   support


   0         0.97    0.97    0.97     115
   1         0.99    0.98    0.98     164
   2         0.95    0.97    0.96     148

 accuracy          0.97     427
 macro avg         0.97    0.97    0.97     427
 weighted avg      0.97    0.97    0.97     427
    
```


Gambar 17. Hasil Kinerja Evaluasi GRU

3.3 Hasil validasi ketiga


Pada tahap validasi ketiga, data latih dibagi menjadi 70% dan data uji sebesar 30%, dengan parameter dan jumlah lapisan yang sama pada model LSTM dan GRU. Meskipun hasil validasi ini masih belum optimal, grafik ROC akurasi dapat dilihat pada Gambar 18 dan Gambar 19. Selain itu, perubahan dalam kurva loss ROC juga dapat diamati melalui visualisasi pada Gambar 20 dan Gambar 21.




Gambar 18. Kurva akurasi LSTM



Gambar 19. Kurva akurasi GRU



Gambar 20. Kurva loss LSTM



Gambar 21. Kurva loss GRU

Hasil evaluasi model ketiga dari kedua model ini menunjukkan bahwa baik LSTM maupun GRU memiliki akurasi sebesar 96%. Meskipun demikian, pada pertengahan pelatihan, data berhasil mencapai akurasi training sebesar 99%. Selanjutnya, analisis lebih lanjut diperlukan untuk memahami faktor-faktor yang mempengaruhi perbedaan hasil akurasi antara kedua model.

```

20/20 [=====] - 1s 55ms/step
           precision    recall  f1-score   support

      0       0.95        0.98        0.96         190
      1       1.00        0.96        0.98         231
      2       0.94        0.95        0.95         219

 accuracy          0.96          0.96          0.96         640
 macro avg         0.96          0.96          0.96         640
 weighted avg      0.96          0.96          0.96         640
    
```

Gambar 22. Hasil Kinerja Evaluasi LSTM

```

20/20 [=====] - 1s 54ms/step
           precision    recall  f1-score   support

      0       0.94        0.98        0.96         190
      1       1.00        0.96        0.98         231
      2       0.95        0.95        0.95         219

 accuracy          0.96          0.96          0.96         640
 macro avg         0.96          0.96          0.96         640
 weighted avg      0.96          0.96          0.96         640
    
```

Gambar 23. Hasil Kinerja Evaluasi GRU

4. KESIMPULAN

Berdasarkan hasil dan percobaan yang dilakukan dalam penelitian ini, dapat disimpulkan bahwa kedua model, yaitu LSTM dan GRU, telah berhasil diimplementasikan untuk tujuan pengenalan emosi berdasarkan data EEG. Meskipun kedua model tersebut memiliki performa yang relatif baik dalam melakukan klasifikasi emosi, terdapat variasi dalam hasil kinerja keduanya. Dalam validasi yang melibatkan berbagai pembagian data latih dan uji, terlihat bahwa model LSTM secara konsisten mencapai akurasi yang lebih tinggi dibandingkan dengan model GRU. Hal ini menunjukkan bahwa dalam konteks dataset ini, LSTM lebih baik dalam memahami dan memodelkan pola-pola yang terkait dengan emosi manusia berdasarkan data EEG. Pada beberapa skenario validasi, akurasi

GRU juga mencapai tingkat yang baik, namun masih sedikit di bawah performa LSTM.

REFERENCES

- [1] J. J. Bird, “Sebuah Studi tentang Klasifikasi Kondisi Mental menggunakan Antarmuka Otak- Mesin berbasis EEG,” pp. 795–803, 2018.
- [2] M. Egger, M. Ley, and S. Hanke, “Emotion Recognition from Physiological Signal Analysis: A Review,” *Electron. Notes Theor. Comput. Sci.*, vol. 343, pp. 35–55, 2019, doi: 10.1016/j.entcs.2019.04.009.
- [3] A. N. Rohman, E. Utami, and S. Raharjo, “Deteksi Kondisi Emosi pada Media Sosial Menggunakan Pendekatan Leksikon dan Natural Language Processing,” *Eksplora Inform.*, vol. 9, no. 1, pp. 70–76, 2019, doi: 10.30864/eksplora.v9i1.277.
- [4] D. O. Bos, “EEG-based Emotion The Influence of Visual and Auditory Stimuli Recognition,” *IEEE Trans. Biomed. Eng.*, vol. 57, no. 7, pp. 1798–1806, 2010.
- [5] Y. P. Lin et al., “EEG-based emotion recognition in music listening,” *IEEE Trans. Biomed. Eng.*, vol. 57, no. 7, pp. 1798–1806, 2010, doi: 10.1109/TBME.2010.2048568.
- [6] M. Asadur Rahman, M. Foissal Hossain, M. Hossain, and R. Ahmmed, “Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal,” *Egypt. Informatics J.*, vol. 21, no. 1, pp. 23–35, 2020, doi: 10.1016/j.eij.2019.10.002.
- [7] W. L. Mao, H. I. K. Fathurrahman, Y. Lee, and T. W. Chang, “EEG dataset classification using CNN method,” *J. Phys. Conf. Ser.*, vol. 1456, no. 1, 2020, doi: 10.1088/1742-6596/1456/1/012017.
- [8] J. J. Bird, C. D. Buckingham, and D. R. Faria, “Machine Translated by Google Klasifikasi Sentimen Emosional Mental dengan Antarmuka Mesin Otak berbasis EEG” 2022.
- [9] H. H. Jasper, “ETRI Journal - 2022 - Agarwal - Electroencephalography-based imagined speech recognition using deep long short-term memory.Ing.pdf.” 2022.
- [10] et al Guo, “Generating Sequences With Recurrent Neural Networks,” pp. 1–43, 2016, [Online]. Available: <http://arxiv.org/abs/1308.0850>
- [11] M. Coskun, O. YILDIRIM, A. UÇAR, and Y. DEMIR, “an Overview of Popular Deep Learning Methods,” *Eur. J. Tech.*, vol. 7, no. 2, pp. 165–176, 2017, doi: 10.23884/ejt.2017.7.2.11.
- [12] P. N. S. Thomas, G. S. Radha, and S. T. George, “Klasifikasi sinyal EEG menggunakan LSTM dan algoritma jaringan saraf yang,” vol. 0, 2019.
- [13] C. García-Vicente, G. C. Gutiérrez-Tobal, J. Jiménez-García, A. Martín-Montero, D. Gozal, and R. Hornero, “ECG-based convolutional neural network in pediatric obstructive sleep apnea diagnosis,” *Comput. Biol. Med.*, vol. 167, no. September, 2023, doi: 10.1016/j.compbimed.2023.107628.
- [14] Y. Jiao, Y. Deng, Y. Luo, and B. L. Lu, “Driver sleepiness detection from EEG and EOG signals using GAN and LSTM networks,” *Neurocomputing*, vol. 408, pp. 100–111, 2020, doi: 10.1016/j.neucom.2019.05.108.
- [15] H. Lerogeron, R. Picot-Clémente, L. Heutte, and A. Rakotomamonjy, “Learning an autoencoder to compress EEG signals via a neural network based approximation of DTW,” *Procedia Comput. Sci.*, vol. 222, pp. 448–457, 2023, doi: 10.1016/j.procs.2023.08.183.
- [16] R. Zeghlache, M. A. Labiod, and A. Mellouk, “Driver vigilance estimation with Bayesian LSTM Auto-encoder and XGBoost using EEG/EOG data,” *IFAC-PapersOnLine*, vol. 55, no. 8, pp. 89–94, 2022, doi: 10.1016/j.ifacol.2022.08.015.
- [17] M. N. van Stigt, E. A. Groenendijk, H. A. Marquering, J. M. Coutinho, and W. V. Potters, “High performance clean versus artifact dry electrode EEG data classification using Convolutional Neural Network transfer learning,” *Clin. Neurophysiol. Pract.*, vol. 8, pp. 88–91, 2023, doi: 10.1016/j.cnp.2023.04.002.
- [18] J. J. Bird, A. Ekart, C. D. Buckingham, and D. R. Faria, “Mental emotional sentiment classification with an eeg-based brain-machine interface.” *The International Conference on Digital Image and Signal Processing (DISP’19)*, Springer, 2019.
- [19] J. J. Bird, L. J. Manso, E. P. Ribiero, A. Ekart, and D. R. Faria, “A study on mental state classification using eeg-based brain-machine interface.” *9th International Conference on Intelligent Systems*, IEEE, 2018.
- [20] A. Kumar and R. R. (nee Khemchandani), *Attentional Recurrent Neural Networks for Sentence Classification*, vol. 757. Springer Singapore, 2019. doi: 10.1007/978-981-13-1966-2.
- [21] G. Weiss, Y. Goldberg, and E. Yahav, “On the Practical Computational Power of Finite Precision RNNs for Language Recognition.” *arXiv preprint arXiv:1805.04908*, 2018.