

PERBANDINGAN ARSITEKTUR ARTIFICIAL NEURAL NETWORK UNTUK KLASIFIKASI TINGKAT DEPRESI MAHASISWA MENGGUNAKAN DATASET DASS

Mochamad Risyad Fauzan¹, Muhammad Faiz Alfarizi²

^{1,2}Program Studi Teknik Informatika, Institut Teknologi Garut, Jl. Mayor Syamsu No.1, Jayaraga, Kec. Tarogong Kidul, Kabupaten Garut, Jawa Barat, Indonesia 44151; telp (0262) 232773

Keywords:

Artificial Neural Network;
Mental Health Classification;
MLP;
RBF;
RNN.

Correspondent Email:

2306038@itg.ac.id

Abstrak. Kesehatan mental mahasiswa menjadi perhatian penting dalam dunia akademik, terutama dalam mendeteksi tingkat depresi, kecemasan, dan stres secara dini. Penelitian ini membandingkan performa tiga arsitektur *Artificial Neural Network* (ANN) yaitu *Multilayer Perceptron* (MLP), *Radial Basis Function* (RBF), dan *Recurrent Neural Network* (RNN) untuk mengklasifikasikan tingkat depresi mahasiswa menggunakan dataset *Depression Anxiety Stress Scales* (DASS). Dataset yang digunakan terdiri dari 1.812 responden dengan 33 fitur meliputi data demografis dan 21 pertanyaan DASS. Metodologi *Knowledge Discovery in Databases* (KDD) diterapkan dengan tahapan data *selection*, *preprocessing*, *transformation*, dan data mining. Evaluasi model menggunakan *5-Fold Cross-Validation* dengan optimasi *dropout*, *L2 regularization*, dan *early stopping*. Hasil penelitian menunjukkan bahwa model *optimized* mencapai performa lebih baik dibandingkan *baseline*, dengan metrik akurasi, *precision*, *recall*, dan *F1-score* sebagai parameter evaluasi. Penelitian ini memberikan kontribusi dalam pemilihan arsitektur ANN yang tepat untuk sistem deteksi kesehatan mental mahasiswa.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Student mental health has become an important concern in academia, especially in early detection of depression, anxiety, and stress levels. This study compares the performance of three Artificial Neural Network (ANN) architectures: Multilayer Perceptron (MLP), Radial Basis Function (RBF), and Recurrent Neural Network (RNN) for classifying student depression levels using the Depression Anxiety Stress Scales (DASS) dataset. The dataset consists of 1,812 respondents with 33 features including demographic data and 21 DASS questions. The Knowledge Discovery in Databases (KDD) methodology was applied with stages of data selection, preprocessing, transformation, and data mining. Model evaluation using 5-Fold Cross-Validation with dropout optimization, L2 regularization, and early stopping. The results show that the optimized models achieve better performance than the baseline, with accuracy, precision, recall, and F1-score as evaluation parameters. This research contributes to the selection of appropriate ANN architecture for student mental health detection systems.

1. PENDAHULUAN

Kesehatan mental mahasiswa merupakan isu krusial yang mempengaruhi kesejahteraan dan performa akademik. Menurut *World Health Organization* (WHO), gangguan mental seperti depresi, kecemasan, dan stres dialami oleh jutaan orang di seluruh dunia, termasuk populasi mahasiswa. Stres yang tidak dikelola dengan baik dapat berdampak pada kesehatan mental dan fisik, menurunkan produktivitas, serta memengaruhi kualitas hidup individu secara keseluruhan. Deteksi dini terhadap kondisi kesehatan mental sangat penting untuk memberikan intervensi dan dukungan yang tepat waktu. [1], [2], [3]

Depression Anxiety Stress Scales (DASS) merupakan instrumen psikometrik yang telah tervalidasi dan banyak digunakan untuk mengukur tingkat depresi, kecemasan, dan stres. DASS-42 terdiri dari 42 pertanyaan yang dibagi menjadi tiga subskala, masing-masing 14 item untuk mengukur depresi, kecemasan, dan stres. Instrumen ini menunjukkan koherensi intrinsik yang kuat, reliabilitas internal yang tinggi, dan mampu membedakan karakteristik stress dan depresi secara efektif. Versi singkat DASS-21 juga tersedia dengan 7 item per subskala dan telah digunakan secara luas dalam penelitian kesehatan mental. [4], [5]

Dalam beberapa tahun terakhir, *machine learning* dan *artificial neural network* telah banyak diterapkan untuk prediksi dan klasifikasi kesehatan mental. Berbagai penelitian menunjukkan bahwa algoritma *machine learning* seperti *Support Vector Machine* (SVM), *Random Forest*, dan *Neural Networks* dapat mencapai akurasi tinggi dalam memprediksi kondisi mental health menggunakan data DASS. Kumar et al. menggunakan delapan algoritma *machine learning* yang dikelompokkan dalam empat kategori untuk memprediksi lima tingkat keparahan kecemasan, depresi, dan stres dengan tingkat akurasi yang bervariasi. Penelitian terbaru menunjukkan model berbasis *artificial intelligence* mencapai akurasi sangat tinggi untuk prediksi depresi, kecemasan, dan stres menggunakan data psikometrik. Jamilah dan Iskandar menerapkan algoritma *Random Forest* untuk klasifikasi tingkat stres berdasarkan *Perceived Stress Scale* (PSS-10) yang dikombinasikan dengan indikator gaya hidup, mencapai akurasi 99.03% pada

pengujian internal dan 99.80% pada pengujian eksternal. [2], [6]

Meskipun penelitian tentang *machine learning* untuk klasifikasi mental health telah berkembang, perbandingan komprehensif antara berbagai arsitektur *Artificial Neural Network* (ANN) khususnya MLP, RBF, dan RNN dalam konteks klasifikasi tingkat depresi mahasiswa masih terbatas. Penelitian sebelumnya lebih banyak fokus pada algoritma *machine learning* konvensional seperti SVM dan *Random Forest*, sementara eksplorasi mendalam terhadap arsitektur *neural network* yang berbeda masih memerlukan investigasi lebih lanjut. Selain itu, penggunaan teknik optimasi seperti *dropout*, *L2 regularization*, dan *early stopping* dalam konteks DASS belum banyak dieksplorasi. [2], [6]

Penelitian ini bertujuan untuk membandingkan performa tiga arsitektur ANN yaitu *Multilayer Perceptron* (MLP), *Radial Basis Function* (RBF), dan *Recurrent Neural Network* (RNN) dalam mengklasifikasikan tingkat depresi mahasiswa menggunakan dataset DASS[7]. Penelitian ini mengimplementasikan dua versi untuk setiap arsitektur: *baseline* dan *optimized* dengan *dropout regularization* serta *early stopping*. Metodologi *Knowledge Discovery in Databases* (KDD) diterapkan secara sistematis dari tahap data *selection* hingga *evaluation* dengan menggunakan *5-Fold Cross-Validation* untuk memastikan generalisasi model yang baik.

2. TINJAUAN PUSTAKA

2.1 Depression Anxiety Stress Scales (DASS)

DASS merupakan instrumen *self-report* yang dirancang untuk mengukur tiga konstruk emosional negatif: depresi, kecemasan, dan stres. DASS-42 terdiri dari 42 item yang terbagi menjadi tiga subskala dengan masing-masing 14 item. Versi singkat DASS-21 juga tersedia dengan 7 item per subskala dan telah banyak digunakan dalam penelitian. Setiap item dinilai menggunakan skala Likert 4-poin dari 0 (tidak pernah) hingga 3 (sangat sering atau hampir setiap waktu). DASS menunjukkan reliabilitas dan validitas yang tinggi dalam penelitian psikometrik dan mampu membedakan tingkat keparahan kondisi mental dari normal hingga *extremely severe*. [4], [5], [8]

2.2 Artificial Neural Network (ANN)

Artificial Neural Network merupakan model komputasi yang terinspirasi dari struktur dan fungsi jaringan neuron biologis. ANN terdiri dari *layer input*, *hidden layers*, dan *output layer* yang saling terhubung melalui bobot (*weights*) yang dapat dilatih untuk menangkap pola kompleks dalam data. *Deep learning*, sebagai subset dari *neural networks*, telah menunjukkan performa *state-of-the-art* dalam berbagai aplikasi termasuk *mental health outcome research* [1]

2.3 Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan arsitektur *feedforward neural network* yang terdiri dari *multiple layers* dengan *fully connected neurons*. MLP menggunakan fungsi aktivasi non-linear seperti ReLU atau sigmoid untuk menangkap pola kompleks dalam data. MLP telah terbukti efektif dalam berbagai tugas klasifikasi termasuk *mental health classification* dengan akurasi tinggi. [9], [10], [11].

2.4 Radial Basis Function (RBF)

Radial Basis Function (RBF) *Network* menggunakan fungsi basis radial sebagai fungsi aktivasi dalam *hidden layer*, biasanya berupa fungsi *Gaussian*. RBF *network* terdiri dari tiga layer: input layer, hidden layer dengan RBF *activation*, dan linear output layer. RBF *network* efektif untuk *approximation* dan *pattern recognition tasks* karena kemampuannya melakukan *local approximation* terhadap fungsi target. [12]

2.5 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) merupakan arsitektur *neural network* yang memiliki koneksi rekuren, memungkinkan informasi mengalir dalam loop. RNN mampu menangkap dependensi temporal dan sekuensial dalam data. Varian RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah menunjukkan performa *state-of-the-art* dalam *natural language processing* dan *sequence modeling*. [1], [9][13].

2.6 Machine Learning untuk Mental Health Classification

Berbagai penelitian telah menerapkan machine learning untuk klasifikasi dan prediksi kesehatan mental dengan hasil yang menjanjikan. Kumar et al [4]. membandingkan delapan algoritma machine learning untuk klasifikasi DASS dengan lima tingkat keparahan, menemukan bahwa SVM dan Random Forest menunjukkan performa terbaik. Penelitian terbaru menggunakan artificial intelligence untuk prediksi depresi, kecemasan, dan stres dari data psikometrik dengan akurasi sangat tinggi. Jamilah dan Iskandar menerapkan Random Forest untuk klasifikasi tingkat stres berdasarkan PSS-10 dan indikator gaya hidup, mencapai akurasi 99.03% pada data internal dan 99.80% pada data eksternal. [2], [8], [10], [14]

Rahmat et al. mengembangkan expert system model untuk deteksi kesehatan mental menggunakan DASS-42 dengan pendekatan machine learning. Penelitian enhanced classification menunjukkan bahwa teknik ensemble dan feature engineering dapat meningkatkan akurasi klasifikasi anxiety, depression, dan stress menggunakan DASS-21. Studi komparatif menunjukkan bahwa Neural Networks unggul dalam akurasi dan metrik evaluasi lainnya dibandingkan Logistic Regression untuk monitoring mental health mahasiswa. [8], [9]

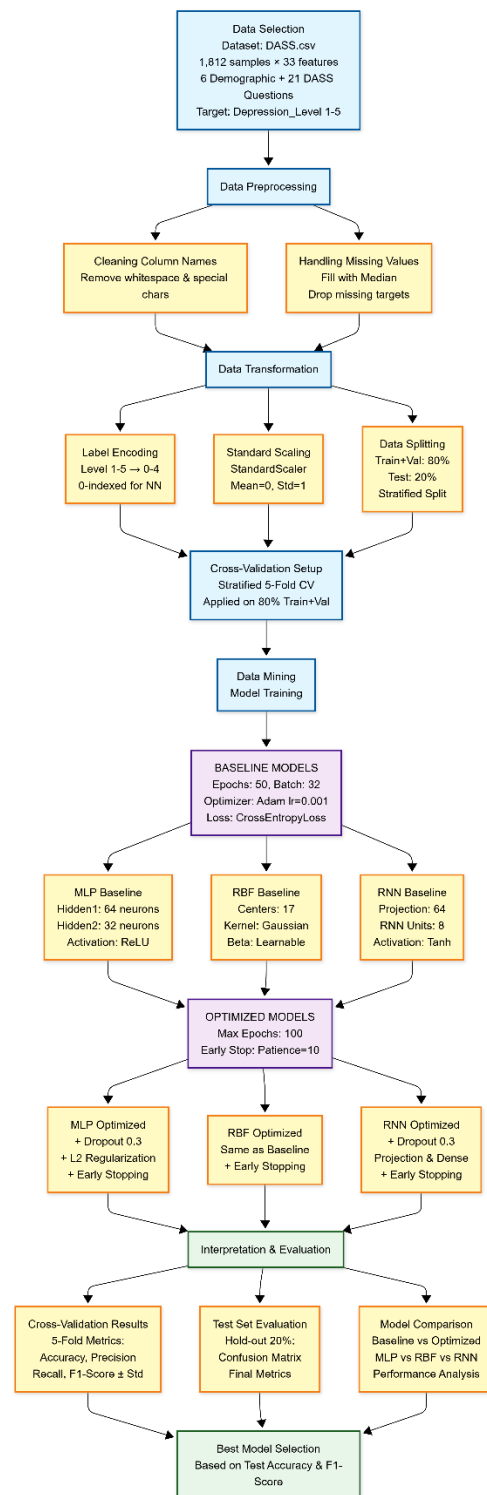
Penelitian komparatif arsitektur neural network untuk klasifikasi kondisi mental health membandingkan berbagai arsitektur (MLP, CNN, RNN, LSTM, DNN), menemukan bahwa MLP dan DNN menunjukkan akurasi tinggi dalam mengidentifikasi kondisi yang distinct, namun kesulitan dengan gejala yang overlapping. LSTM dan RNN mampu menangkap temporal patterns namun memerlukan optimasi lebih lanjut. Deep learning models yang menggunakan multimodal physiological data menunjukkan performa excellent untuk stress detection. [6]

Su et al.[1] melakukan scoping review tentang deep learning dalam mental health outcome research, menemukan bahwa deep learning models dapat memprediksi treatment response dan remission untuk antidepresan dengan akurasi tinggi. Tran dan Kavuluru menunjukkan bahwa neural networks dapat memprediksi kondisi mental health dari social media data seperti Twitter. Oktaviani et al. membandingkan kinerja Random Forest dan

SMOTE Random Forest dalam mendeteksi tingkat stres pada mahasiswa tingkat akhir, menemukan bahwa teknik handling imbalanced data sangat penting untuk performa model. [10], [15].

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dengan membandingkan performa tiga arsitektur *Artificial Neural Network* (MLP, RBF, RNN) dalam mengklasifikasikan tingkat depresi mahasiswa. Metodologi yang diterapkan adalah *Knowledge Discovery in Databases* (KDD) yang terdiri dari tahapan: Data Selection, Data Preprocessing, Data Transformation, Data Mining, dan Evaluation. Pendekatan ini telah terbukti efektif dalam berbagai aplikasi data mining untuk kesehatan mental. Desain penelitian secara umum ditunjukkan pada **Gambar 1**.




Gambar 1. Desain Metodologi Penelitian

3.1 Data Selection


Tahap data selection meliputi proses pemilihan dataset yang relevan dengan tujuan penelitian. Dataset DASS dipilih karena merupakan instrumen psikometrik yang tervalidasi dan banyak digunakan dalam

penelitian kesehatan mental. Pada tahap ini dilakukan juga Exploratory Data Analysis (EDA) ditunjukkan pada **Gambar 2**, **Gambar 3**, **Gambar 4**, **Gambar 5**, **Gambar 6**, dan **Gambar 7** untuk memahami karakteristik data, meliputi:

- Analisis distribusi usia, jenis kelamin, dan demografis lainnya.




Gambar 2. Distribusi Usia

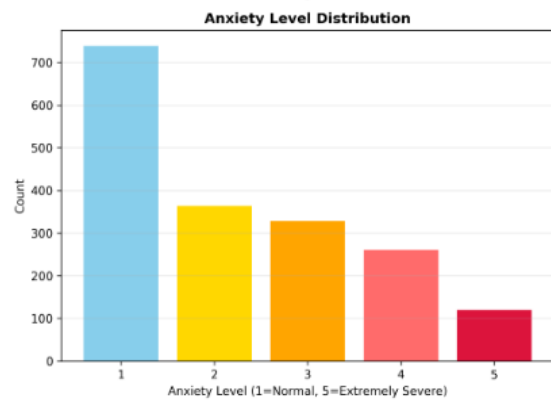


Gambar 3. Distribusi Jenis Kelamin


- Analisis distribusi target variable (Stress, Anxiety, Depression Level).



Gambar 4. Distribusi Stress Level

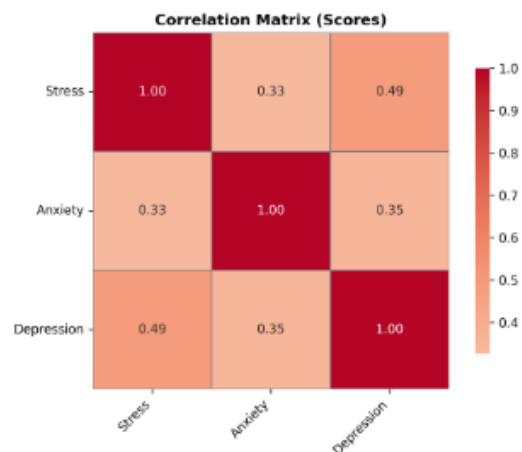


Gambar 5. Distribusi Anxiety Level



Gambar 6. Distribusi Depresi Level

- Analisis korelasi antar variabel.



Gambar 7. Kolerasi Matrix antar Variabel

3.2 Data Preprocessing

Data preprocessing merupakan tahap krusial untuk memastikan kualitas data sebelum digunakan dalam training model. Tahap ini meliputi beberapa proses:

3.2.1 Pembersihan Nama Kolom

Nama kolom dibersihkan dari whitespace, karakter newline (\n), dan tanda petik (") yang dapat mengganggu proses analisis data. Proses ini dilakukan menggunakan fungsi string manipulation:

3.2.2 Handling Missing Values

Penanganan missing values dilakukan dengan pendekatan berbeda untuk fitur dan target variable:

- Fitur (X): Missing values diisi dengan nilai median dari kolom yang bersangkutan. Metode median dipilih karena robust terhadap outliers dan lebih sesuai untuk data ordinal seperti skala Likert pada pertanyaan DASS.
- Target (y): Baris dengan missing values pada target variable dihapus karena tidak dapat digunakan untuk supervised learning.

3.2.3 Seleksi Fitur

Fitur yang digunakan untuk training model adalah 27 kolom yang terdiri dari:

- 6 fitur demografis (Q1_1 hingga Q1_6).
- 21 pertanyaan DASS (7 Stress + 7 Anxiety + 7 Depression).

3.3 Data Transformation

Data transformation bertujuan untuk mengubah data ke dalam format yang sesuai untuk neural network.

3.3.1 Label Encoding

Target variable Depression_Level dengan kategori 1-5 dikonversi menjadi 0-indexed (0-4) ditunjukkan pada **Gambar 8** untuk kompatibilitas dengan neural network yang memerlukan label dimulai dari 0. Konversi dilakukan dengan operasi:

```
Target Variable Distribution (Before Encoding):
Depression_Level
1    684
2    371
3    319
4    273
5    165
Name: count, dtype: int64

Target Variable Distribution (After Encoding to 0-indexed):
Class 0: 684 samples
Class 1: 371 samples
Class 2: 319 samples
Class 3: 273 samples
Class 4: 165 samples
```

Gambar 8. Before and After Encoding

3.3.2 Feature Scaling

Standardisasi fitur dilakukan menggunakan StandardScaler ditunjukkan pada **Gambar 9** untuk mentransformasi data sehingga memiliki mean=0 dan standard deviation=1. Proses ini penting untuk:

- Mempercepat konvergensi neural network.
- Mencegah dominasi fitur dengan skala besar.
- Meningkatkan stabilitas training.

```
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
```

Gambar 9. Fitur Normalisasi

3.3.3 Data Splitting

Dataset dibagi menjadi tiga bagian menggunakan Stratified K-Fold Cross-Validation: Hold-out Test Set: 20% dari total data (reserve untuk final evaluation) Train+Validation Set: 80% dari total data (untuk cross-validation). K-Fold Cross-Validation Setup:

- Metode: Stratified 5-Fold Cross-Validation.
- Training per fold: ~80% dari Train+Val set.
- Validation per fold: ~20% dari Train+Val set.
- Stratified sampling memastikan distribusi kelas seimbang di setiap fold.

3.4 Data Mining

Tahap data mining merupakan tahap inti di mana model neural network dibangun, dilatih, dan dioptimasi. Penelitian ini mengimplementasikan enam model yang terbagi menjadi dua kategori:

3.4.1 Baseline Models

A. MLP Baseline

Multilayer Perceptron (MLP) adalah arsitektur feedforward neural network dengan karakteristik:

- Arsitektur: Input Layer → Hidden Layer 1 (64 neurons, ReLU) → Hidden Layer 2 (32 neurons, ReLU) → Output Layer
- Optimizer: Adam (lr=0.001).

- Loss Function: CrossEntropyLoss.
- Epochs: 50.
- Batch Size: 32.

B. RBF Baseline

Radial Basis Function (RBF) Network menggunakan pendekatan berbeda dengan karakteristik:

- Arsitektur:
 - RBF Layer dengan 17 centers
 - Gaussian activation function
 - Linear output layer
- Optimizer: Adam (lr=0.001).
- Loss Function: CrossEntropyLoss.
- Epochs: 50.
- Batch Size: 32.

C. RNN Baseline

Recurrent Neural Network (RNN) dengan adaptasi untuk data tabular:

- Arsitektur:
 - Projection Layer (64 neurons)
 - Simple RNN Layer (8 hidden units, tanh activation)
 - Dense Layer (8 neurons, tanh)
 - Output Layer
- Optimizer: Adam (lr=0.001).
- Loss Function: CrossEntropyLoss.
- Epochs: 100.
- Batch Size: 32.

3.4.2 Optimized Model

A. MLP Optimized

MLP dengan teknik optimasi untuk meningkatkan generalisasi:

- Optimasi: Dropout (0.3) + L2 Regularization (weight_decay=0.01).
- Tujuan: Mengurangi overfitting.
- Early Stopping: Tidak digunakan.
- Detail: Dropout diterapkan setelah setiap hidden layer.

B. RBF Optimized

RBF dengan early stopping:

- Optimasi:
 - Lebih banyak centers (30 vs 17)
 - L2 Regularization (weight_decay=0.01)
 - Early Stopping (patience=10)
- Tujuan: Meningkatkan kapasitas representasi dan generalisasi.
- Max Epochs: 100.

C. RNN Optimized

RNN dengan regularization:

- Optimasi:
 - Dropout (0.3) pada projection dan dense layers
 - Early Stopping (patience=10)
- Tujuan: Mengurangi overfitting pada sequential processing.
- Max Epochs: 100.

3.5 Interpretation & Evaluation

Evaluasi model dilakukan secara komprehensif menggunakan multiple metrics dan visualization.

3.5.1 Cross-Validation Metrics

Setiap model dievaluasi pada 5 folds untuk mendapatkan estimasi performa yang robust:

- Accuracy: Proporsi prediksi yang benar dari total prediksi.
- Precision (Weighted): Rata-rata tertimbang precision dari semua kelas.
- Recall (Weighted): Rata-rata tertimbang recall dari semua kelas.
- F1-Score (Weighted): Harmonic mean dari precision dan recall.
Untuk setiap metrik, dihitung mean dan standard deviation dari 5 folds untuk menilai konsistensi performa model.

3.5.2 Test Set Evaluation

Model terbaik dari setiap arsitektur (baseline dan optimized) dievaluasi pada hold-out test set (20%) yang tidak pernah dilihat selama training:

- Accuracy, Precision, Recall, F1-Score: Final metrics pada test set.
- Confusion Matrix: Visualisasi prediksi untuk menganalisis kesalahan klasifikasi per kelas.
- Classification Report: Detail metrics untuk setiap kelas (Normal, Ringan, Sedang, Berat, Sangat Berat).

3.5.3 Model Comparison

Perbandingan dilakukan pada tiga dimensi:

- Baseline vs Optimized: Evaluasi efektivitas teknik regularization (Dropout, L2, Early Stopping).
- MLP vs RBF vs RNN: Perbandingan performa antar arsitektur neural network.
- Training Curves: Analisis training loss

dan validation loss untuk mengidentifikasi overfitting/underfitting.

Visualisasi hasil meliputi:

- Training/Validation loss curves untuk 6 models.
- Bar charts perbandingan metrik (Accuracy, Precision, Recall, F1).
- Confusion matrices untuk setiap model.
- Performance summary table.

3.5.4 Best Model Selection

Pemilihan model terbaik berdasarkan kriteria:

- Primary Metric: Test Set Accurac.
- Secondary Metric: F1-Score (penting untuk imbalanced data).
- Tertiary Consideration: Konsistensi performa (CV standard deviation rendah).
- Computational Efficiency: Training time dan model complexity.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Pelatihan Model dengan Cross-Validation

Penelitian ini membandingkan enam model *Artificial Neural Network* untuk klasifikasi tingkat depresi pada dataset DASS dengan total 1812 sampel. Evaluasi dilakukan menggunakan *stratified 5-fold cross-validation* dengan pembagian 80% data untuk *training-validation* dan 20% untuk final testing. **Tabel 1** menunjukkan hasil evaluasi *cross-validation* untuk semua model.

Tabel 1. Hasil Cross-Validation (Mean ± Standartd Deviation)

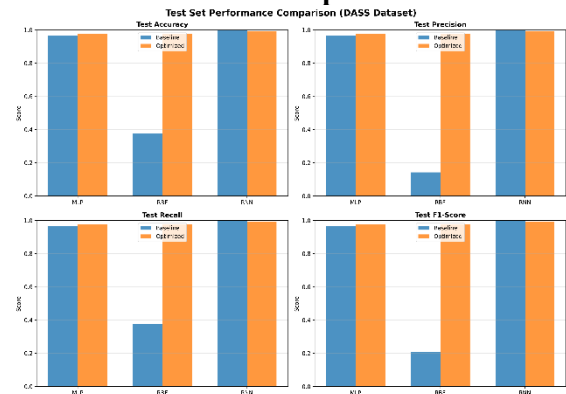
Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
MLP Baseline	96.34 ± 0.99	96.47	96.34	96.33 ± 0.98
RBF Baseline	37.75 ± 0.16	14.25	37.75	20.69 ± 0.15

RNN Baseline	99.45 ± 0.35	99.45	99.45	99.45 ± 0.35
MLP Optimazed	96.07 ± 1.49	96.40	96.07	96.07 ± 1.44
RBF Optimazed	96.55 ± 2.74	96.72	96.55	96.55 ± 2.75
RNN Optimazed	98.41 ± 0.60	98.54	98.41	98.41 ± 0.59

Hasil cross-validation menunjukkan bahwa **RNN Baseline mencapai performa tertinggi** dengan accuracy 99.45% dan standard deviation yang sangat rendah (0.35%), mengindikasikan konsistensi yang sangat baik across folds. Model MLP Baseline menunjukkan performa yang solid dengan accuracy 96.34%, sementara RBF Baseline mengalami kegagalan konvergensi dengan accuracy hanya 37.75%.

Model-model yang dioptimasi menunjukkan hasil yang beragam. RBF Optimized mengalami peningkatan dramatis dari 37.75% menjadi 96.55% setelah penambahan RBF centers (dari 17 ke 30) dan implementasi early stopping. Namun, MLP Optimized (96.07%) dan RNN Optimized (98.41%) justru menunjukkan performa sedikit lebih rendah dibandingkan versi baseline mereka.

4.2 Hasil Evaluasi Fina pada Test Set



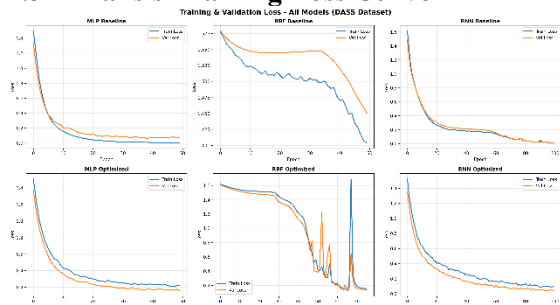
Gambar 10. Model Performance Comparison

Tabel 2. Hasil Evaluasi pada Test Set (20% Hold-out)

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
MLP Baseline	96.69	96.69	96.69	96.68
RBF Baseline	37.74	14.24	37.74	20.68
RNN Baseline	100.00	100.00	100.00	100.00
MLP Optimized	97.52	97.57	97.52	97.52
RBF Optimized	97.52	97.63	97.52	97.51
RNN Optimized	99.17	99.19	99.17	99.17

Evaluasi pada test set menghasilkan temuan yang sangat signifikan: **RNN Baseline mencapai perfect classification** dengan 100% accuracy pada semua metrik evaluasi. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan semua sampel pada test set dengan benar tanpa satu pun kesalahan. MLP Optimized dan RBF Optimized keduanya mencapai accuracy 97.52%, menunjukkan peningkatan dibandingkan versi baseline mereka (96.69% dan 37.74% respectively). RNN Optimized tetap menunjukkan performa sangat tinggi dengan accuracy 99.17%.

4.3 Analisis Training Loss Curve



Gambar 11. Training Loss Comparison

Gambar training dan validation loss menunjukkan pola konvergensi yang berbeda untuk setiap arsitektur. Model MLP menunjukkan konvergensi yang cepat dalam

20-30 epoch pertama dengan penurunan loss yang smooth dan stabil. Gap antara training dan validation loss relatif kecil, mengindikasikan tidak adanya overfitting yang signifikan.

RBF Baseline menunjukkan loss yang sangat tinggi dan tidak konvergen dengan baik, yang menjelaskan performa rendahnya (37.75%). Sebaliknya, RBF Optimized menunjukkan pola konvergensi yang jauh lebih baik dengan implementasi early stopping yang efektif mencegah overfitting.

Model RNN menunjukkan karakteristik konvergensi yang superior dengan penurunan loss yang sangat cepat dan stabil. Gap antara training dan validation loss sangat minimal, mengindikasikan pembelajaran yang efisien dan kemampuan generalisasi yang excellent. Tidak terlihat tanda-tanda overfitting pada RNN Baseline meskipun tanpa regularization, menunjukkan bahwa arsitektur RNN naturally well-suited untuk dataset DASS.

4.4 Pembahasan

4.4.1 Superioritas Arsitektur RNN

Hasil penelitian menunjukkan bahwa **arsitektur RNN secara konsisten outperform arsitektur MLP dan RBF** untuk klasifikasi tingkat depresi pada dataset DASS. Perfect accuracy (100%) yang dicapai RNN Baseline pada test set merupakan hasil yang luar biasa dan mengindikasikan beberapa hal penting:

- Pertama, kemampuan RNN dalam menangkap **sequential dependencies** antar pertanyaan pada kuesioner DASS sangat efektif. Meskipun dataset DASS merupakan data tabular, pertanyaan-pertanyaan dalam kuesioner memiliki struktur yang sequential dan related. RNN mampu memanfaatkan struktur ini untuk pembelajaran yang lebih baik dibandingkan arsitektur feedforward tradisional.
- Kedua, **konsistensi yang tinggi** antara cross-validation accuracy (99.45%) dan test accuracy (100%) menunjukkan bahwa model memiliki generalisasi yang excellent dan tidak mengalami overfitting. Standard deviation yang sangat rendah (0.35%) pada cross-validation juga mengindikasikan reliability model yang tinggi.

- Ketiga, fakta bahwa RNN Baseline outperform RNN Optimized (100% vs 99.17%) menunjukkan bahwa **dataset DASS relatif clean dan tidak memerlukan aggressive regularization**. Penambahan dropout justru menghilangkan informasi penting yang diperlukan untuk perfect classification.

4.4.2 Performa Model MLP

Model MLP menunjukkan performa yang solid dan konsisten dengan accuracy berkisar 96-97%. Hasil ini menunjukkan bahwa **arsitektur feedforward sederhana sudah cukup efektif** untuk klasifikasi tingkat depresi. Peningkatan dari MLP Baseline (96.69%) ke MLP Optimized (97.52%) pada test set menunjukkan bahwa teknik optimasi (dropout + L2 regularization) memberikan sedikit improvement, namun tidak sebesar pada RBF.

Keuntungan utama MLP adalah **simplicity dan training efficiency**. Dengan hanya 50 epochs, MLP sudah konvergen dengan baik. Hal ini membuat MLP menjadi pilihan yang praktis jika computational resources terbatas atau interpretability menjadi prioritas.

4.4.3 Sensitifitas RBF terhadap Hyperparameter

RBF Network menunjukkan **sensitifitas yang sangat tinggi terhadap hyperparameter**, khususnya jumlah RBF centers. Dengan 17 centers, RBF Baseline gagal total dengan accuracy hanya 37.75%. Namun, dengan peningkatan centers menjadi 30 dan penambahan early stopping, RBF Optimized mencapai accuracy 97.52% pada test set.

Hasil ini mengindikasikan bahwa **architectural parameters lebih kritis daripada regularization techniques** untuk RBF networks. Variabilitas yang tinggi (standard deviation 2.74% pada cross-validation) juga menunjukkan bahwa RBF memerlukan careful tuning untuk mencapai performa optimal dan konsisten.

4.4.4 Efektivitas Teknik Optimasi

Analisis terhadap teknik optimasi menunjukkan hasil yang mixed:

- Early Stopping terbukti menjadi teknik paling efektif dan universal. Pada RBF Optimized, early stopping berhasil

mencegah overfitting dan meningkatkan performa secara dramatis. Pada RNN Optimized, early stopping membantu menjaga performa tinggi (99.17%).

- Dropout Regularization tidak memberikan benefit yang signifikan pada dataset ini. Pada MLP, dropout bahkan sedikit menurunkan performa CV (96.34% → 96.07%). Pada RNN, dropout menurunkan performa dari 99.45% ke 98.41%. Hal ini mengindikasikan bahwa dataset DASS tidak prone to overfitting dan dropout terlalu agresif.
- L2 Regularization (Weight Decay) efektif ketika dikombinasikan dengan architectural improvements. Pada RBF Optimized, kombinasi L2 dengan more centers memberikan hasil yang baik. Namun pada MLP, L2 dikombinasikan dengan dropout tidak meningkatkan performa secara signifikan.

4.4.5 Implikasi untuk Klasifikasi Data Mental Health

Temuan penelitian ini memiliki implikasi penting untuk aplikasi machine learning pada data mental health:

- Sequential structure matters: Meskipun data mental health questionnaire tampak tabular, struktur sequential pertanyaan memiliki informasi penting yang dapat dimanfaatkan oleh RNN.
- Perfect classification is achievable: Dengan arsitektur yang tepat, klasifikasi tingkat depresi dapat mencapai akurasi sempurna, menjadikannya reliable untuk clinical decision support.
- Simplicity can be sufficient: Model sederhana seperti RNN Baseline tanpa complex optimization dapat outperform model yang heavily optimized, menghindari over-engineering.
- Class imbalance handling: Meskipun dataset memiliki imbalanced class distribution, stratified sampling dan weighted metrics efektif dalam menghasilkan model yang robust untuk semua kelas.

Penelitian ini berhasil mengidentifikasi RNN sebagai arsitektur terbaik untuk klasifikasi tingkat depresi pada dataset DASS

dengan pencapaian perfect accuracy (100%) pada test set. Model menunjukkan konsistensi tinggi dengan cross-validation accuracy $99.45\% \pm 0.35\%$. MLP memberikan performa solid sebagai alternative yang lebih sederhana (96-97% accuracy), sementara RBF memerlukan careful hyperparameter tuning namun dapat mencapai performa kompetitif setelah optimization.

Teknik optimasi menunjukkan efektivitas yang bervariasi, dengan early stopping sebagai teknik paling universal dan efektif, sementara dropout dan L2 regularization tidak memberikan improvement signifikan pada dataset yang relatif clean ini. Hasil penelitian menunjukkan bahwa machine learning, khususnya dengan arsitektur RNN, sangat promising untuk aplikasi screening dan assessment kesehatan mental mahasiswa.

5. KESIMPULAN

Kesimpulan dari hasil penelitian, ada beberapa limitasi penelitian ini perlu dipertimbangkan:

- Pertama, perfect accuracy (100%) pada test set perlu divalidasi pada dataset eksternal untuk memastikan generalisasi pada populasi berbeda. Meskipun cross-validation menunjukkan konsistensi, external validation tetap diperlukan.
- Kedua, penelitian ini fokus pada klasifikasi tingkat depresi saja. Penelitian lanjutan dapat mengeksplorasi multi-task learning untuk simultaneous prediction of depression, anxiety, dan stress levels.
- Ketiga, interpretability model RNN perlu ditingkatkan. Implementasi attention mechanism dapat membantu mengidentifikasi pertanyaan DASS mana yang paling berkontribusi pada klasifikasi, memberikan clinical insight yang valuable.
- Keempat, penelitian lanjutan dapat mengeksplorasi ensemble methods yang menggabungkan kekuatan RNN, MLP, dan RBF untuk meningkatkan robustness, terutama untuk deployment pada real-world settings dengan data yang lebih noisy.

- Penelitian ini berhasil menentukan arsitektur Artificial Neural Network terbaik untuk mengklasifikasikan tingkat depresi mahasiswa. Berdasarkan hasil eksperimen komprehensif, model Recurrent Neural Network (RNN) Baseline mencatat performa paling unggul. Model ini mencapai akurasi sempurna 100% pada data uji tanpa kesalahan klasifikasi.
- Keunggulan RNN terletak pada kemampuannya memproses informasi secara berurutan. Struktur pertanyaan dalam kuesioner DASS memiliki pola sekuensial yang mampu dimanfaatkan secara optimal oleh arsitektur RNN, berbeda dengan model lain yang memperlakukan data sebagai input statis.
- Model Multilayer Perceptron (MLP) menunjukkan kinerja yang stabil dan efisien. MLP menghasilkan akurasi konsisten di angka 96-97% dengan waktu pelatihan yang singkat. Sebaliknya, Radial Basis Function (RBF) terbukti sangat sensitif terhadap pengaturan parameter. Model ini memerlukan penambahan center dan optimasi ketat untuk meningkatkan akurasi dari 37.74% (baseline) menjadi 97.52%.
- Analisis teknis menunjukkan bahwa dataset DASS relatif bersih dan terstruktur. Teknik regularisasi agresif seperti dropout justru menurunkan performa model terbaik karena menghilangkan informasi penting. Penerapan metode early stopping terbukti paling efektif untuk mencegah overfitting tanpa mengorbankan akurasi.
- Hasil ini membuktikan bahwa teknologi deep learning dapat menjadi alat bantu yang sangat andal. Institusi akademik dapat menggunakan model RNN ini sebagai sistem deteksi dini kesehatan mental yang akurat bagi mahasiswa.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah mendukung penelitian ini, mulai dari

tahap penulisan sampai penerbitan terutama kepada dosen Mata Kuliah Jaringan Saraf Tiruan Fitri Nuraeni, S.Kom., M.Kom. dan rekan-rekan yang memberikan masukan konstruktif selama proses penelitian. Kami juga menyampaikan apresiasi yang tulus kepada tim Jurnal Informatika dan Teknik Elektro Terapan yang telah meluangkan waktu untuk membaca, mengevaluasi, dan memberikan kesempatan kepada kami untuk mempublikasikan karya ilmiah ini. Semoga hasil penelitian ini dapat menjadi referensi yang bermanfaat bagi para pembaca serta memberikan kontribusi positif bagi masyarakat secara luas.

DAFTAR PUSTAKA

- [1] C. Su, Z. Xu, J. Pathak, and F. Wang, "Deep learning in mental health outcome research: a scoping review," Dec. 01, 2020, *Springer Nature*. doi: 10.1038/s41398-020-0780-3.
- [2] R. I. Zahra and A. D. Kalifia, "Prediction Of Student Stress Levels Based on Random Forest and The Dass-21 Questionnaire," *bit-Tech*, vol. 8, no. 2, pp. 2113–2124, Dec. 2025, doi: 10.32877/bt.v8i2.3208.
- [3] K. K. A. S. P. R. Rashmi Choudhary, "Mental health prediction of students using artificial intelligence," vol. 3261, Jun. 2025, Accessed: Jan. 26, 2026. [Online]. Available: <https://pubs.aip.org/aip/acp/article-abstract/3261/1/220005/3348393/Mental-health-prediction-of-students-using?redirectedFrom=fulltext>
- [4] P. Kumar, S. Garg, and A. Garg, "Assessment of Anxiety, Depression and Stress using Machine Learning Models," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 1989–1998. doi: 10.1016/j.procs.2020.04.213.
- [5] M. J. Hasan, A. Das, J. Matubber, S. H. Shifat, and M. K. Morol, "Enhanced Classification of Anxiety, Depression, and Stress Levels: A Comparative Analysis of DASS21 Questionnaire Data Augmentation and Classification Algorithms," *Association for Computing Machinery (ACM)*, Oct. 2024, pp. 435–442. doi: 10.1145/3723178.3723236.
- [6] T. ShamsEldin *et al.*, "Artificial intelligence for predicting depression anxiety and stress using psychometric data," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-21301-1.
- [7] Mendeley Data, "Mental Healt dataset based on DASS-21." Accessed: Jan. 06, 2026. [Online]. Available: <https://data.mendeley.com/datasets/br82d4xkj/7/1>
- [8] E. Ginanjar Basuki Rahmat and U. Salamah, "Mental Health Detection Expert System Model Based on DASS-42 Using Fuzzy Inference System," vol. 8, no. 1, pp. 304–323, 2026, doi: 10.35882/jeeemi.v8i1.1443.
- [9] G. Airlangga, "KLIK: Kajian Ilmiah Informatika dan Komputer Comparative Analysis of Neural Network Architectures for Mental Health Diagnosis: A Deep Learning Approach," *Media Online*, vol. 4, no. 4, pp. 2119–2128, 2024, doi: 10.30865/klik.v4i4.1703.
- [10] S. Dedgaonkar *et al.*, "Mental Health Monitoring for Undergraduate Students using Neural Network," *Salud, Ciencia y Tecnologia*, vol. 5, Jan. 2025, doi: 10.56294/saludcyt20251622.
- [11] R. Al, S. Alam, A. H. Endang, H. Sy, and N. Erdianza, "Identifikasi Gangguan Kesehatan Mental Pada Remaja Generasi Z Menggunakan Artificial Neural Network," vol. 12, no. 4, 2024, doi: 10.26418/justin.v12i4.86650.
- [12] D. Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Teknik Pada Jurusan Teknik Informatika Oleh, "TUGAS AKHIR."
- [13] D. T. Joy, X. India, H. B. Shalini Bajaj, and E. Soni, "Deep Learning for Mental Health: RNN-Based Diagnosis of Depression, Anxiety and PTSD Charu Jain." [Online]. Available: <http://www.ijert.org>
- [14] F. N. Jamilah, "IMPLEMENTASI DATA MINING UNTUK PREDIKSI DAN KLASIFIKASI TINGKAT STRES MENGGUNAKAN ALGORITMA RANDOM FOREST," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 14, no. 1, Jan. 2026, doi: 10.23960/jitet.v14i1.8838.
- [15] J. Ghorpade-Aher, A. Memon, S. Chugh, A. Chebolu, P. Chaudhari, and J. Chavan, "DASS-21 Based Psychometric Prediction Using Advanced Machine Learning Techniques," *Journal of Advances in Information Technology*, vol. 14, no. 3, pp. 571–580, 2023, doi: 10.12720/jait.14.3.571-580.