

Klasifikasi Saran dan Kritik pada SIMAK UNISMUH dengan menggunakan Algoritma Recurrent Neural Network (RNN)

Ahmad Faisal^{*1}, Titin Wahyuni², Fahriz Irhamna Rachman³

^{1,2,3}Informatika, Universitas Muhammadiyah Makassar, Makassar, 90221, Indonesia

e-mail: 105841112420@student.unismuh.ac.id

Abstract

Sistem Informasi Manajemen Akademik (SIMAK) Unismuh Makassar is an important platform used by students to submit suggestions and criticisms related to various academic aspects. In this study, researchers implemented the Recurrent Neural Network (RNN) algorithm to classify suggestions and criticisms received through SIMAK Unismuh. The purpose of this study was to determine the implementation of the RNN Algorithm in classifying suggestions and criticisms on the SIMAK Unismuh page and how successful the RNN Algorithm was in classifying suggestions and criticisms on the SIMAK Unismuh page. RNN was chosen because of its ability to process sequential text data, such as input in the form of sentences, which allows the model to capture the context of the input more effectively. The dataset used in this study consists of a number of suggestion and criticism data that have been categorized manually. The RNN model that was built was then trained and tested using the data to assess its accuracy and performance. The results showed that the model achieved the highest accuracy of 91% and the lowest accuracy of 90%. Although there were variations in model performance, these results indicate that RNN has good potential in classifying suggestion and criticism texts.

Keyword: Text Classification; Recurrent Neural Network (RNN); SIMAK Unismuh; Suggestions and Criticisms; Academic Information System.

Abstrak

Sistem Informasi Manajemen Akademik (SIMAK) Unismuh Makassar merupakan platform penting yang digunakan oleh mahasiswa untuk menyampaikan saran dan kritik terkait berbagai aspek akademik. Dalam penelitian ini, peneliti mengimplementasikan algoritma Recurrent Neural Network (RNN) untuk mengklasifikasikan saran dan kritik yang diterima melalui SIMAK Unismuh. Tujuan dari penelitian ini adalah untuk mengetahui implementasi Algoritma RNN dalam mengklasifikasi saran dan kritik di laman SIMAK Unismuh dan bagaimana keberhasilan Algoritma RNN dalam mengklasifikasi saran dan kritik di laman SIMAK Unismuh. RNN dipilih karena kemampuannya dalam mengolah data teks yang berurutan, seperti masukan dalam bentuk kalimat, yang memungkinkan model untuk menangkap konteks dari masukan tersebut secara lebih efektif. Dataset yang digunakan dalam penelitian ini terdiri dari sejumlah data saran dan kritik yang telah dikategorikan secara manual. Model RNN yang dibangun kemudian dilatih dan diuji menggunakan data tersebut untuk menilai akurasi dan performanya. Hasil penelitian menunjukkan bahwa model mencapai akurasi tertinggi sebesar 91% dan akurasi terendah sebesar 90%. Meskipun terdapat variasi dalam performa model, hasil ini menunjukkan bahwa RNN memiliki potensi yang baik dalam mengklasifikasikan teks saran dan kritik.

Kata kunci: Klasifikasi Teks; Recurrent Neural Network (RNN); SIMAK Unismuh; Saran dan Kritik; Sistem Informasi Akademik

1. Pendahuluan

Perkembangan teknologi informasi yang semakin pesat di era globalisasi saat ini tidak bisa dihindari lagi pengaruhnya terhadap dunia pendidikan. Dalam konteks pembelajaran dan pengembangan institusi pendidikan seperti universitas semakin mengedepankan teknologi guna meningkatkan pengalaman akademik hingga sistem administrative yang dapat ditawarkan kepada mahasiswa[1].

Untuk mengatasi permasalahan tersebut, diperlukan pendekatan yang lebih cermat dalam mengklasifikasikan konteks saran dan kritik yang disampaikan oleh mahasiswa, salah satu pendekatan yang dapat digunakan adalah dengan mengimplementasikan Algoritma RNN pada konteks saran dan kritik di SIMAK Unismuh Makassar.

Pada tiap langkah waktu, proses dari RNN tidak hanya berupa data masukan asal, tapi juga nilai dari lapis tersembunyi yang terdapat pada langkah waktu sebelumnya sebuah metode untuk melakukan klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut[2].

Berdasarkan penelitian sebelumnya dengan judul “Klasifikasi Kalimat Ilmiah Menggunakan “RNN” Penelitian ini telah berhasil membuat model komputasi klasifikasi kalimat menggunakan RNN, dengan fitur yang telah diekstraksi menggunakan fungsi Word2Vec untuk menghasilkan satu set vektor[3].

Berdasarkan latar belakang tersebut, maka peneliti menggunakan metode RNN yang ditujukan untuk mengklasifikasikan atau mengolah kesesuaian konteks saran dan kritik pada hak angket simak Unismuh, sehingga akan diketahui klasifikasi dari kritik dan saran tersebut (positif, negatif, atau netral). Dengan menggunakan metode ini, diharapkan mendapat tingkat akurasi yang cukup tinggi dalam mengklasifikasikan kesesuaian konteks saran dan kritik pada hak angket simak Unismuh.

2. Metode Penelitian

Penelitian ini terdiri dari beberapa tahapan yaitu pengambilan data, pelabelan data, *preprocessing* dan pembentukan model RNN.

2. 1. Pengambilan Data

Tahap pengumpulan data yang digunakan dalam penelitian ini diperoleh dari Universitas SIMAK Muhammadiyah Makassar. SIMAK merupakan sumber data resmi yang mencatat informasi akademik mahasiswa, antara lain riwayat akademik, kualifikasi mata kuliah, dan status akademik lainnya.

Sistem manajemen akademik atau yang dikenal dengan SIMAK adalah aplikasi perangkat lunak yang berfungsi untuk menyajikan informasi dan mengelolah administrasi terkait kegiatan akademik. Penggunaan perangkat lunak semacam ini diharapkan dapat meningkatkan efisiensi pengolahan akademik dan memudahkan akses terhadap informasi yang dibutuhkan dengan cepat dan mudah[4].

Sistem Informasi Manajemen Akademik adalah segala macam hasil interaksi antara elemen di lingkungan akademik untuk menghasilkan informasi yang kemudian dijadikan landasan pengambilan sebuah keputusan melaksanakan tindakan, baik oleh pelaku proses itu sendiri maupun dari pihak luar kampus[5]. Merujuk PP Nomor 60 Tahun 1999 pasal 9 ayat 1 administrasi akademik pendidikan tinggi diselenggarakan dengan menerapkan sistem kredit semester, ayat 2 pelaksanaan ketentuan sebagaimana dimaksud pada ayat 1 diatur oleh Menteri[6].

Data yang dikumpulkan dari aplikasi SIMAK adalah berupa data sentimen kritik dan saran mahasiswa. Kritik berasal dari kata kritis yang artinya hakekat, esensi atau substansi. Yaitu inti daripada sebuah persoalan. Sesungguhnya semua kritik pasti melihat sisi negatif. Tidak ada kritik melihat sisi positif. Tujuan semua kritik sama, supaya sesuatu yang negatif bisa menjadi positif. Masalahnya adalah, banyak orang tidak memahami hakekat daripada kritik itu sendiri[7]. Saran adalah sebuah solusi yang ditujukan untuk menyelesaikan permasalahan yang dihadapi. Saran harus bersifat membangun, mendidik, dan secara objektif dan sesuai dengan topik yang dibahas[8].

2. 2. Pelabelan Data

Pelabelan sentimen dilakukan secara manual untuk mengidentifikasi pola dan karakteristik dalam teks yang menunjukkan sentimen Saran dan kritik. Ulasan yang diperoleh SIMAK UNISMUH disimpan dalam atribut ulasan, sedangkan nilai klasifikasi saran dan kritik disimpan dalam atribut label.

2. 3. Preprocessing

Preprocessing data adalah tahap di mana data mentah disiapkan dan dibersih sebelum dianalisis. Proses ini melibatkan beberapa langkah untuk memastikan data siap digunakan. Beberapa tahapan dalam *preprocessing* data seperti tahap *cleaning* dan *tokenizing*. Tahapan *cleaning* membersihkan data dari elemen yang tidak diperlukan seperti tanda baca, angka, atau

karakter khusus yang tidak relevan sedangkan tahapan *tokenizing* adalah tahapan yang memecah teks menjadi unit-unit yang lebih kecil, seperti kata atau token.

2. 4. Model RNN

Dalam dunia kecerdasan buatan, *Supervised Learning*, *Natural Language Processing* (NLP), dan RNN memiliki hubungan yang erat dalam mengolah dan memahami bahasa manusia. *Supervised Learning* berperan sebagai metode pelatihan model menggunakan data berlabel, yang banyak diterapkan dalam berbagai tugas NLP seperti klasifikasi teks, analisis sentimen, dan penerjemahan bahasa. Sementara itu, RNN menjadi salah satu jenis arsitektur jaringan saraf yang dirancang khusus untuk menangani data berurutan, sehingga sangat cocok untuk menangkap hubungan kontekstual dalam teks. Dengan menggabungkan ketiga konsep ini, sistem berbasis kecerdasan buatan dapat belajar dari data berlabel, memahami struktur bahasa, serta memproses informasi dalam bentuk urutan kata secara lebih efektif.

Dengan menggunakan algoritma-algoritma *supervised learning*, model dapat digunakan untuk mengklasifikasikan data ke dalam kategori yang tepat atau untuk melakukan prediksi numerik [9].

Dalam algoritma *supervised learning*, sistem akan diberikan data pelatihan yang berisi informasi input dan output yang di inginkan, sehingga memungkinkan sistem untuk mempelajari berdasarkan data yang telah ada. Sistem akan mencari pola dalam dataset tersebut, kemudian pola tersebut akan dijadikan sebagai acuan untuk kumpulan data yang ada [10].

NLP adalah cabang ilmu komputer yang terkait dengan kecerdasan buatan yang mempelajari interaksi antara bahasa manusia dan komputer. Dalam ruang lingkup yang lebih luas, NLP mengcakup segala bentuk manipulasi komputer terhadap bahasa alami [11].

Dalam tugas NLP juga melibatkan proses penguraian kata atau bahasa menjadi komponen yang lebih sederhana. Ini melibatkan pemahaman hubungan antar komponen tersebut dan penelusuran cara komponen – komponen tersebut bekerja secara bersamaan untuk membentuk makna yang utuh [12].

RNN merupakan salah satu jenis algoritma pembelajaran mesin yang berbasis pengolahan informasi dari sebuah data dan merupakan algoritma deep learning. RNN menyimpan pola-pola informasi masa lalu dengan melakukan perulangan di dalam arsitekturnya agar dapat membuat informasi tersebut tetap tersimpan. RNN merupakan pengembangan dari Jaringan Saraf Tiruan (JST) dan arsitekturnya mirip dengan *Multilayer Perceptron* (MLP) [13]. *Hidden layer* sebelumnya menyimpan informasi dari proses ekstraksi fitur di awal sehingga saat *hidden layer* dijadikan input untuk proses selanjutnya itu menyimpan *memory* (ingatan) dari input sebelumnya [14].

Hidden layer sebelumnya menyimpan informasi dari proses ekstraksi fitur di awal sehingga saat *hidden layer* dijadikan input untuk proses selanjutnya itu menyimpan *memory* (ingatan) dari input sebelumnya [15]. Berikut *pseudocode* untuk model RNN.

```
import pandas as pd
import numpy as np
from tqdm import tqdm
from keras.preprocessing.text import Tokenizer
tqdm.pandas(desc="progress-bar")
from gensim.models import Doc2Vec
from sklearn import utils
from sklearn.model_selection import train_test_split
from keras.preprocessing.sequence import pad_sequences
import gensim
from sklearn.linear_model import LogisticRegression
from gensim.models.doc2vec import TaggedDocument
import re
import seaborn as sns
import matplotlib.pyplot as plt

df = pd.read_excel('/content/drive/MyDrive/Skripsi/2020/Ahmad
Faisal RNN/saran.xlsx',sheet_name="Sheet1")
# Replace 'path_to_your_excel_file.xlsx' with your actual file
pathdf = df[['ULASAN', 'LABEL']]
# Selecting relevant columns
```

```

df = df[pd.notnull(df['ULASAN'])]
# Dropping rows with null 'ULASAN' values
df.rename(columns={'ULASAN': 'ULASAN'}, inplace=True)
# Rename 'ULASAN' to 'ULASAN' for consistency
# Mengatur ulang indeks baris
df.index = range(len(df))
\# Menghitung total jumlah kata dalam kolom 'ULASAN'
total_words = df['ULASAN'].apply(lambda x: len(x.split('
'))).sum()
print("Total jumlah kata dalam semua ulasan:", total_words)
# Menghitung jumlah kemunculan setiap nilai dalam kolom
'LABEL'cnt_pro =
df['LABEL'].value_counts()
# Menggambar diagram batang menggunakan Seaborn
plt.figure(figsize=(12, 4))
sns.barplot(x=cnt_pro.index, y=cnt_pro.values, alpha=0.8)
plt.ylabel('Jumlah Kemunculan', fontsize=12)
plt.xlabel('LABEL', fontsize=12)
plt.xticks(rotation=90)
plt.show()

def print_message(index):
example = df.iloc[index][['ULASAN', 'LABEL']].values
if len(example) > 0:
    print('ULASAN:', example[0])
    print('LABEL:', example[1])
# Menggunakan fungsi print_message() dengan indeks tertentu
print_message(12)
import string
def remove_punctuation(text):
    return text.translate(str.maketrans(' ', ' ',
string.punctuation))
# Menghapus tanda baca dari kolom ULASAN
df['ULASAN'] = df['ULASAN'].apply(remove_punctuation)
import nltk
# Download the 'punkt' resource
nltk.download('punkt')
# Tokenisasi teks menggunakan nltk
def tokenize_text(text):
    tokens = []
    for sent in nltk.sent_tokenize(text):
        for word in nltk.word_tokenize(sent):
            if len(word) <= 0:
                continue
            tokens.append(word.lower())
    return tokens
# Memisahkan data menjadi train dan test
train, test = train_test_split(df, test_size=0.01,
random_state=42)
# TaggedDocument untuk train dan test set
train_tagged = train.apply(
    lambda r: TaggedDocument(words=tokenize_text(r['ULASAN']),
tags=[r.LABEL]),
axis=1)
test_tagged = test.apply(
    lambda r: TaggedDocument(words=tokenize_text(r['ULASAN']),
tags=[r.LABEL]),
axis=1)

```

```

# Pengaturan tokenizer
max_features = 500000 # Jumlah maksimum kata yang akan
digunakan
max_sequence_length = 50 # Panjang maksimum setiap teks
tokenizer = Tokenizer(num_words=max_features, split=' ',
filters='!"#$%&() *+, -./:; <=>?@[\]^_{}~', lower=True)
tokenizer.fit_on_texts(df['ULASAN'].values)
# Konversi teks ke dalam urutan angka (sequences)
X_train = tokenizer.texts_to_sequences(train['ULASAN'].values)
X_train = pad_sequences(X_train, maxlen=max_sequence_length)
X_test = tokenizer.texts_to_sequences(test['ULASAN'].values)
X_test = pad_sequences(X_test, maxlen=max_sequence_length)
print('Found %s unique tokens.' % len(tokenizer.word_index))
# Konversi teks ke dalam urutan angka (sequences)
X = tokenizer.texts_to_sequences(df['ULASAN'].values)
X = pad_sequences(X, maxlen=max_sequence_length)
print('Shape dari data tensor:', X.shape)
#train_tagged.values
train_tagged.values
from gensim.models.doc2vec import Doc2Vec, TaggedDocument
# Ubah ukuran vektor (vector_size) sesuai kebutuhan Anda
vector_size = 20
# Inisialisasi model Doc2Vec
d2v_model = Doc2Vec(dm=1, dm_mean=1, vector_size=vector_size,
window=8, min_count=1, workers=1, alpha=0.065, min_alpha=0.065)
# Membangun kosakata dari tagged documents pada data pelatihan
train_tagged =
[TaggedDocument(words=tokenize_text(row['ULASAN']),
tags=[row['LABEL']]) for index, row in train.iterrows()]
d2v_model.build_vocab(train_tagged)
# Bangun vocab dari train_tagged
d2v_model.build_vocab(train_tagged)
# Latih model
for epoch in range(30):
    d2v_model.train(utils.shuffle(train_tagged),
total_examples=len(train_tagged), epochs=1)
    d2v_model.alpha -= 0.002 # Reduksi alpha setiap epoch
    d2v_model.min_alpha = d2v_model.alpha # Tetapkan min_alpha
sesuai alpha saat ini
# Mendapatkan jumlah kata dalam kosakata
num_words = len(d2v_model.wv.key_to_index)
print("Jumlah kata dalam kosakata:", num_words)
# Mengakses kata-kata dalam kosakata
words_in_vocab = list(d2v_model.wv.key_to_index.keys())
print("Kata-kata dalam kosakata:", words_in_vocab)
# Inisialisasi matriks embedding kosong
embedding_matrix = np.zeros((len(d2v_model.dv.vectors),
d2v_model.vector_size))
# Mengisi matriks embedding dengan vektor-vektor dokumen dari
model Doc2Vec
for i in range(len(d2v_model.dv.vectors)):
    embedding_matrix[i] = d2v_model.dv.vectors[i]
# Contoh penggunaan matriks embedding
print("Ukuran matriks embedding:", embedding_matrix.shape)
print("Contoh vektor untuk dokumen pertama:", embedding_matrix[0])

```

Cara kerja RNN dalam penelitian ini adalah dengan memproses teks saran dan kritik secara berurutan, mengingat konteks kata-kata sebelumnya untuk memahami makna kalimat

secara keseluruhan, dan kemudian mengklasifikasikan teks tersebut ke dalam kategori yang sesuai berdasarkan pelatihan yang telah dilakukan. Model ini dapat membantu mengotomatisasi dan meningkatkan efisiensi dalam pengelolaan masukan pengguna di sistem SIMAK UNISMUH.

3. Hasil dan diskusi

3. 1. *Preprocessing Data*

Data yang akan diolah terlebih dahulu dikumpulkan dari data SIMAK Muhammadiyah Makassar. Dataset berupa dataset ulasan mahasiswa dalam bentuk kritik dan saran. Berikut adalah hasil pengumpulan data ulasan yang telah disimpan dalam Excel.

Tabel 1. Dataset Ulasan

ULASAN	LABEL
Kedepanya kami bisa diberikan dosen yang lebih produktif dan mampu bekerja sama dengan mahasiswa menyelesaikan permasalahan dalam pertemuan covid ini. Tapi untuk dosen saat ini sudah luar biasa kok.	Kritik
Saya berharap pelayanan akademik mampu memberikan pelayanan yang baik kepada mahasiswa dan seluruh masyarakat Unismuh. Terutama untuk para bapak/ibu dosen sekiranya mampu memberikan metode yang baik bagi mahasiswa sehingga mahasiswa lebih aktif dan produktif dalam proses pembelajaran.	Kritik
Memperbaiki yang baik menjadi lebih baik lagi.	Saran

Tahapan selanjutnya adalah proses pelabelan data Dimana proses ini dilakukan secara manual untuk mengidentifikasi pola sentiment saran dan kritik. Berikut tabel pelabelan data yang dapat dilihat di bawah ini:

Tabel 2. Tahap Pelabelan Data

ULASAN	LABEL
proses perkuliahan sangat baik dan disiplin.	Kritik
Semoga ruangan perkuliahan bisa memiliki pendingin ruangan (AC)	Saran

Setelah dilakukan pelabelan data, selanjutnya data akan melalui tahap *preprocessing*. *Preprocessing* data adalah tahap di mana data mentah disiapkan dan dibersih sebelum dianalisis. Proses ini melibatkan beberapa langkah untuk memastikan data siap digunakan. Berikut tahapan-tahapan dalam *preprocessing* data:

a. *Cleaning*

Tahap *cleaning* data melibatkan proses menghapus tanda baca seperti koma, titik, tanda tanya, tanda seru, bintang, dan pagar dari teks atau data.

Tabel 3. Tahap Cleaning

Sebelum	Sesudah
Sangat komunikatif dengan mahasiswa	Sangat komunikatif dengan mahasiswa
Sudah baik , terimakasih atas ilmu yang telah diberikan	Sudah baik terimakasih atas ilmu yang telah diberikan
Walaupun yang masuk diklas asdos tetapi cara mengajarnya sangat baik, terimakasih atas ilmu yang telah diberikan	Walaupun yang masuk diklas asdos tetapi cara mengajarnya sangat baik terimakasih atas ilmu yang telah diberikan

b. *Tokenizing*

Tokenizing adalah langkah dalam pemrosesan teks yang melibatkan pemecahan teks menjadi unit-unit lebih kecil yang disebut token. Unit-unit ini dapat berupa kata-kata, frasa, atau entitas lainnya.

Tabel 4. Tahap Tokenizing

Sebelum	Sesudah
maksimalkan pertemuan dalam perkuliahan	['maksimalkan', 'pertemuan', 'dalam', 'perkuliahan']
sangat komunikatif dengan mahasiswa	['sangat', 'komunikatif', 'dengan', 'mahasiswa']
kedepannya bisa lebih ditingkatkan lagi	['kedepannya', 'bisa', 'lebih', 'dingkatkan', 'lagi']

3. 2. Hasil Pengujian Metode RNN

Dengan langkah-langkah ini, hasil prediksi pada data validasi telah ditampilkan dan disimpan ke dalam file Excel untuk dianalisis lebih lanjut atau dipresentasikan kepada pihak terkait. Pada penelitian ini dilakukan pengujian untuk pembagian data (90 : 10) dan (80 : 20).

- a. **Pembagian data 90 : 10.** Hasil Pengujian untuk pembagian data 90 : 10 menunjukkan nilai epoch, metrik, grafik dan hasil prediksi sebagai berikut.

- 1) Epoch

```

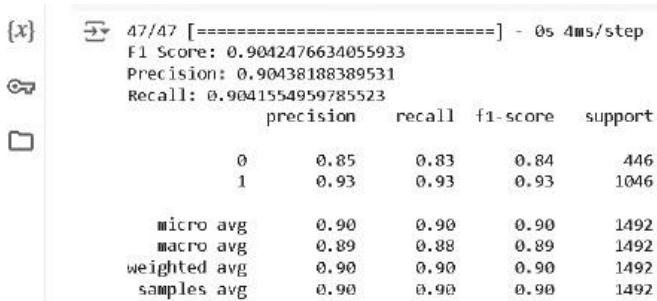
Epoch 1/15 - loss: 0.5924 - acc: 0.7060 - val_loss: 0.4212 - val_acc: 0.8271 - 6s/epoch - 3ms/step
Epoch 2/15 - loss: 0.4204 - acc: 0.8714 - val_loss: 0.2559 - val_acc: 0.9142 - 4s/epoch - 30ms/step
Epoch 3/15 - loss: 0.2451 - acc: 0.9200 - val_loss: 0.2555 - val_acc: 0.9196 - 4s/epoch - 31ms/step
Epoch 4/15 - loss: 0.1971 - acc: 0.9380 - val_loss: 0.2453 - val_acc: 0.9169 - 4s/epoch - 30ms/step
Epoch 5/15 - loss: 0.1585 - acc: 0.9495 - val_loss: 0.2530 - val_acc: 0.9196 - 4s/epoch - 31ms/step
Epoch 6/15 - loss: 0.1095 - acc: 0.9387 - val_loss: 0.2530 - val_acc: 0.9196 - 4s/epoch - 31ms/step
Epoch 7/15 - loss: 0.1547 - acc: 0.9537 - val_loss: 0.2493 - val_acc: 0.9236 - 4s/epoch - 30ms/step
Epoch 8/15 - loss: 0.1322 - acc: 0.9590 - val_loss: 0.2496 - val_acc: 0.9196 - 4s/epoch - 30ms/step
Epoch 9/15 - loss: 0.1161 - acc: 0.9620 - val_loss: 0.2599 - val_acc: 0.9129 - 4s/epoch - 30ms/step
Epoch 10/15 - loss: 0.1153 - acc: 0.9642 - val_loss: 0.2723 - val_acc: 0.9008 - 4s/epoch - 30ms/step
Epoch 11/15 - loss: 0.1125 - acc: 0.9621 - val_loss: 0.2680 - val_acc: 0.9209 - 4s/epoch - 30ms/step
Epoch 12/15 - loss: 0.0837 - acc: 0.9753 - val_loss: 0.2871 - val_acc: 0.9196 - 4s/epoch - 30ms/step
Epoch 13/15 - loss: 0.0779 - acc: 0.9733 - val_loss: 0.3007 - val_acc: 0.9209 - 4s/epoch - 30ms/step
Epoch 14/15 - loss: 0.0745 - acc: 0.9770 - val_loss: 0.3570 - val_acc: 0.9102 - 4s/epoch - 30ms/step
Epoch 15/15 - loss: 0.0598 - acc: 0.9830 - val_loss: 0.3188 - val_acc: 0.9182 - 4s/epoch - 30ms/step
Epoch 16/15 - loss: 0.0591 - acc: 0.9812 - val_loss: 0.3531 - val_acc: 0.9102 - 4s/epoch - 30ms/step
dict_keys(['loss', 'acc', 'val_loss', 'val_acc'])
validation loss: [0.421220064163208, 0.25503015181884477, 0.25545173803438111, 0.2452619969844818, 0.2525]

```

Gambar 1. Epoch 1 – 15

Dari gambar 1 dapat dilihat bahwa pada pembagian data 90:10 dengan batch size 16, Epoch pertama (1), untuk *Training Accuracy* mencapai 70% dan *Validasi Accuracy* 82%.

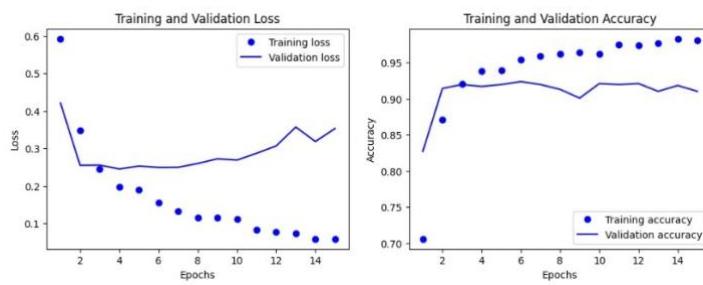
- 2) Metrik



Gambar 2. Metrik 0.1

Gambar 2 menunjukkan hasil evaluasi model klasifikasi dalam bentuk metrik kinerja. Tabel memperlihatkan nilai *precision*, *recall*, dan *f1-score* untuk dua kelas: 0 dan 1. Kelas 0 memiliki *precision* 0.85, *recall* 0.83, dan *f1-score* 0.84 dengan *support* 446, sedangkan kelas 1 memiliki *precision* 0.93, *recall* 0.93, dan *f1-score* 0.93 dengan *support* 1046.

3) Grafik



Gambar 3. Grafik 0.1

Gambar 3 menunjukkan grafik yang menggambarkan perubahan nilai *loss* dan akurasi selama proses pelatihan dan validasi model *machine learning*.

4) Hasil Prediksi

Tabel 5 berikut ini memperlihatkan hasil prediksi 0.1 yang membandingkan antara label sebenarnya dan hasil prediksi.

Tabel 5. Hasil Prediksi 0.1

Ulasan	Label Sebenarnya	Prediksi
sebaiknya materi yang akan di pelajari terlebih dahulu dijelaskan agar mahasiswa dapat lebih mudah memahaminya	Saran	Saran
Mahasiswa sering tidak tahu bagaimana cara mengajukan keluhan tentang penilaian	Kritik	Kritik
Agar lebih tepat waktu lagi	Kritik	Kritik

b. **Pembagian data 80 : 20.** Hasil Pengujian untuk pembagian data 80 : 20 menunjukkan nilai epoch, metrik, grafik dan hasil prediksi sebagai berikut.

1) Epoch

```

Epoch 1/15
373/373 - 6s - loss: 0.6218 - acc: 0.6950 - val_loss: 0.5278 - val_acc: 0.7218 - 6s/epoch - 15ms/step
Epoch 2/15
373/373 - 4s - loss: 0.3904 - acc: 0.8397 - val_loss: 0.3043 - val_acc: 0.8975 - 4s/epoch - 10ms/step
Epoch 3/15
373/373 - 4s - loss: 0.2627 - acc: 0.9130 - val_loss: 0.2641 - val_acc: 0.9048 - 4s/epoch - 11ms/step
Epoch 4/15
373/373 - 4s - loss: 0.2191 - acc: 0.9274 - val_loss: 0.2472 - val_acc: 0.9202 - 4s/epoch - 10ms/step
Epoch 5/15
373/373 - 4s - loss: 0.1803 - acc: 0.9418 - val_loss: 0.2515 - val_acc: 0.9202 - 4s/epoch - 10ms/step
Epoch 6/15
373/373 - 4s - loss: 0.1542 - acc: 0.9524 - val_loss: 0.2585 - val_acc: 0.9155 - 4s/epoch - 11ms/step
Epoch 7/15
373/373 - 4s - loss: 0.1274 - acc: 0.9584 - val_loss: 0.2790 - val_acc: 0.9102 - 4s/epoch - 11ms/step
Epoch 8/15
373/373 - 4s - loss: 0.1172 - acc: 0.9656 - val_loss: 0.2805 - val_acc: 0.9209 - 4s/epoch - 11ms/step
Epoch 9/15
373/373 - 4s - loss: 0.0973 - acc: 0.9703 - val_loss: 0.3050 - val_acc: 0.9169 - 4s/epoch - 11ms/step
Epoch 10/15
373/373 - 4s - loss: 0.0788 - acc: 0.9750 - val_loss: 0.3285 - val_acc: 0.8968 - 4s/epoch - 11ms/step
Epoch 11/15
373/373 - 4s - loss: 0.0880 - acc: 0.9728 - val_loss: 0.3038 - val_acc: 0.9068 - 4s/epoch - 11ms/step
Epoch 12/15
373/373 - 4s - loss: 0.0580 - acc: 0.9832 - val_loss: 0.3260 - val_acc: 0.9048 - 4s/epoch - 11ms/step
Epoch 13/15
373/373 - 4s - loss: 0.0516 - acc: 0.9844 - val_loss: 0.4559 - val_acc: 0.8861 - 4s/epoch - 11ms/step
Epoch 14/15
373/373 - 4s - loss: 0.0533 - acc: 0.9847 - val_loss: 0.3307 - val_acc: 0.9142 - 4s/epoch - 11ms/step
Epoch 15/15
373/373 - 4s - loss: 0.0461 - acc: 0.9851 - val_loss: 0.3723 - val_acc: 0.9062 - 4s/epoch - 11ms/step
dict_keys(['loss', 'acc', 'val_loss', 'val_acc'])
Validation loss: [0.5278254151344299, 0.304330050945282, 0.26413100957870483, 0.24721147119998932, 0.2514]

```

Gambar 4. Epoch 1 – 15 0.2

Dari gambar 4 dapat dilihat bahwa pada pembagian data 80:20 dengan batch size 16, Epoch pertama (1), untuk *Training Accuracy* mencapai 69% dan *Validasi Accuracy* 72%.

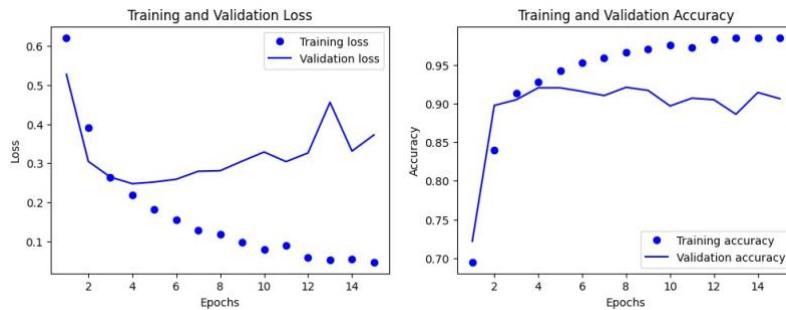
2) Metrik

47/47 [=====] - 0s 4ms/step				
F1 Score: 0.9042476634055933				
Precision: 0.90438188389531				
Recall: 0.9041554959785523				
	precision	recall	f1-score	support
0	0.85	0.83	0.84	446
1	0.93	0.93	0.93	1046
micro avg	0.90	0.90	0.90	1492
macro avg	0.89	0.88	0.89	1492
weighted avg	0.90	0.90	0.90	1492
samples avg	0.90	0.90	0.90	1492

Gambar 5. Metrik 0.2

Gambar 5 menunjukkan hasil evaluasi model klasifikasi dalam bentuk metrik kinerja. Tabel memperlihatkan nilai *precision*, *recall*, dan f1-score untuk dua kelas: 0 dan 1. Kelas 0 memiliki *precision* 0.85, *recall* 0.83, dan f1-score 0.84 dengan *support* 446, sedangkan kelas 1 memiliki *precision* 0.93, *recall* 0.93, dan f1-score 0.93 dengan *support* 1046.

3) Grafik



Gambar 6. Grafik 0.2

Gambar 6 menunjukkan dua grafik yang membandingkan metrik pelatihan dan validasi model pembelajaran mesin selama beberapa *epoch*.

4) Hasil Prediksi

Tabel 6 berikut ini memperlihatkan hasil prediksi 0.2 yang membandingkan antara label sebenarnya dan hasil prediksi.

Tabel 6. Hasil Prediksi 0.2

Ulasan	Label Sebenarnya	Prediksi
Sudah bagus pembawaan materinya tetap di pertahankan saja dan kalau bisa dalam proses pembelajaran suasannya dosennya bisa membuat suasannya tidak terlalu tegang sehingga mahasiswa juga senang dalam menerima materi	Saran	Kritik 0
lebih baik di adakan perkuliahan tatap muka	Saran	Saran 1
Jam kuliah yang singkat sering sekali terasa kurang	Kritik	Kritik 1

Tabel di atas menunjukkan daftar komentar atau umpan balik dari mahasiswa mengenai berbagai aspek kampus mereka, seperti proses pembelajaran, fasilitas, dan pelayanan. Kolom A berisi teks komentar, kolom B dan C berisi label 'kritik' atau 'saran', dan kolom D berisi angka biner (0 atau 1) yang mungkin menunjukkan klasifikasi atau kategori dari komentar tersebut.

4. Kesimpulan

Hasil penelitian ini berhasil mengimplementasikan Metode RNN untuk klasifikasi saran dan kritik pada SIMAK UNISMUH dengan menggunakan 7.457 data. Hasil evaluasi menunjukkan bahwa model mencapai akurasi tertinggi sebesar 91% dan akurasi terendah sebesar 90%. Meskipun terdapat variasi dalam performa model, hasil ini menunjukkan bahwa RNN memiliki potensi yang baik dalam mengklasifikasikan teks saran dan kritik. Model RNN dapat membantu institusi dalam memahami dan merespon masukan dari pengguna dengan lebih efektif, meskipun masih memerlukan optimasi lebih lanjut untuk meningkatkan konsistensi dan akurasi hasil. Untuk meningkatkan performa model, disarankan untuk melakukan pengembangan lebih lanjut dengan mencoba berbagai arsitektur RNN lainnya seperti LSTM atau GRU, serta melakukan optimasi hyperparameter dan penambahan data pelatihan.

Referensi

- [1] Yusny, R., & Yasa, G. I. (2019). MENGEMBANGKAN (PEMBELAJARAN) BLENDED LEARNING DENGAN SISTEM LINGKUNGAN PEMBELAJARAN VIRTUAL (VLE) DI PTKIN. *Jurnal Ilmiah Islam Futura*, 19(1). <https://doi.org/10.22373/jif.v19i1.3707>
- [2] Rozi, I. F., Wijayaningrum, V. N., & Khozin, N. (2020). KLASIFIKASI TEKS LAPORAN MASYARAKAT PADA SITUS LAPOR! MENGGUNAKAN RECURRENT NEURAL NETWORK. *SISTEMASI*, 9(3). <https://doi.org/10.32520/stmsi.v9i3.977>
- [3] Firmansyah, M. R., Ilyas, R., & Kasyidi, F. (2020). Klasifikasi Kalimat Ilmiah Menggunakan Recurrent Neural Network. Prosiding The 11th Industrial Research Workshop and National Seminar, 11(1).
- [4] Ardiansyah, D., Saepudin, A., Aryanti, R., & Fitriani, E. (2020). Perancangan Sistem Informasi Akademik Madrasah Aliyah Negeri (Man) 4 Karawang Berbasis Web. *Jurnal Teknologi Dan Open Source*, 3(2), 187–201. <https://doi.org/10.36378/jtos.v3i2.783>
- [5] Agustiandra, V., & Sabandi, A. (2019). Persepsi Guru Terhadap Penerapan Sistem Informasi Manajemen Di Sekolah Menengah Kejuruan (Smk) Negeri 3 Padang. *Jurnal Bahana Manajemen Pendidikan*, 8(1), 1. <https://doi.org/10.24036/bmp.v8i1.103704>
- [6] Map, J., Ilyasi, A., Susanto, H., & Astuti, S. J. W. (2020). PELAKSANAAN SISTEM ADMINISTRASI AKADEMIK DI UNIVERSITAS ISLAM JEMBER. MAP (Jurnal Manajemen Dan Administrasi Publik), 3(2). <https://doi.org/10.37504/map.v3i2.245>
- [7] Ardiansyah, D., Saepudin, A., Aryanti, R., & Fitriani, E. (2020). Perancangan Sistem Informasi Akademik Madrasah Aliyah Negeri (Man) 4 Karawang Berbasis Web. *Jurnal Teknologi Dan Open Source*, 3(2), 187–201. <https://doi.org/10.36378/jtos.v3i2.783>
- [8] Adanson, Y. N., & Fitriana, G. F. (2022). Rancang Bangun Aplikasi Midesk Berbasis Website Menggunakan Metode User Centered Design. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 4(1). <https://doi.org/10.30865/json.v4i1.4376>
- [9] Mestika, J. C., Selan, M. O., & Qadafi, M. I. (2022). Menjelajahi Teknik-Teknik Supervised Learning untuk Pemodelan Prediktif Menggunakan Python. *BIIKMA : Buletin Ilmiah Ilmu Komputer Dan Multimedia*, 99(99).
- [10] Abijono, H., Santoso, P., & Anggreini, N. L. (2021). Algoritma Supervised Learning Dan Unsupervised Learning Dalam Pengolahan Data. *Jurnal Teknologi Terapan: G-Tech*, 4(2), 315–318. <https://doi.org/10.33379/gtech.v4i2.635>
- [11] Fajar Ramadhan, D., Noertjahjono, S., & Dedy Irawan, J. (2020). PENERAPAN CHATBOT AUTO REPLY PADA WHATSAPP SEBAGAI PUSAT INFORMASI PRAKTIKUM MENGGUNAKAN ARTIFICIAL INTELLIGENCE MARKUP LANGUAGE. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 4(1). <https://doi.org/10.36040/jati.v4i1.2375>
- [12] Husamuddin, H., Prasetyo, D. B., & Rustamadji, H. C. (2020). Otomatisasi Layanan Frequently Ask Questions Berbasis Natural Language Processing Pada Telegram Bot. *Telematika*, 17(2), 145. <https://doi.org/10.31315/telematika.v1i1.3383>
- [13] Nurashila, S. S., Hamami, F., & Kusumasari, T. F. (2023). Perbandingan Kinerja Algoritma Recurrent Neural Network (Rnn) Dan Long Short-Term Memory (Lstm): Studi Kasus Prediksi Kemacetan Lalu Lintas Jaringan Pt Xyz. *JIPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(3), 864–877. <https://doi.org/10.29100/jipi.v8i3.3961>
- [14] Bai, Y., Xie, J., Liu, C., Tao, Y., Zeng, B., & Li, C. (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants. *International Journal of Electrical Power and Energy Systems*, 126. <https://doi.org/10.1016/j.ijepes.2020.106612>

- [15] Bai, Y., Xie, J., Liu, C., Tao, Y., Zeng, B., & Li, C. (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants. International Journal of Electrical Power and Energy Systems, 126. <https://doi.org/10.1016/j.ijepes.2020.106612>