

IMPLEMENTASI ALGORITMA *LONG SHORT-TERM MEMORY* PADA SISTEM KLASIFIKASI MAHASISWA BERPOTENSI *DROP OUT*

Niken Mutiara Wulandari^{*1}, Laode Saidi², Budi Wijaya Rauf³

^{1,2,3}Program Studi Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Halu Oleo

Email: ¹nknmutiara@gmail.com, ²laode.saidi@uho.ac.id, ³budiwijaya@uho.ac.id

* Penulis Korespondensi

Abstrak

Penelitian ini bertujuan untuk menghasilkan sebuah sistem klasifikasi mahasiswa yang berpotensi *drop out*. Sistem klasifikasi ini diharapkan dapat membantu mengidentifikasi mahasiswa yang berpotensi *drop out* sejak dini dalam upaya pencegahan. Penelitian ini menggunakan data akademik berupa nilai Indeks Prestasi Semester (IPS) 1-7, Indeks Prestasi Kumulatif Semester 7 (IPKS7), dan SKS7, serta data non akademik yang meliputi Program Studi dan Jalur Masuk sebagai parameter klasifikasi. Metode yang digunakan adalah algoritma *Long Short-Term Memory* (LSTM) dengan pengembangan sistem menggunakan pendekatan CRISP-DM. Pengujian sistem dilakukan menggunakan metode *black box testing* dan evaluasi performa menggunakan *confusion matrix*. Hasil penelitian menunjukkan bahwa sistem klasifikasi yang dikembangkan mencapai tingkat akurasi 93% berdasarkan evaluasi *confusion matrix*, dan seluruh fungsionalitas sistem berjalan sesuai yang diharapkan berdasarkan hasil *black box testing*.

Kata kunci: *long short-term memory*, klasifikasi, mahasiswa berpotensi *drop out*, *confusion matrix*, *black box testing*

Abstract

This research aims to produce a classification system for students who have the potential to drop out. This classification system is expected to help identify students who have the potential to drop out early on in prevention efforts. This research uses academic data in the form of Semester Grade Point Average (IPS) 1-7, Cumulative Grade Point Average Semester 7 (IPKS7), and Cumulative SKS 7, as well as non-academic data including Study Program and Entry Path as classification parameters. The method used is the Long Short-Term Memory (LSTM) algorithm with system development using the CRISP-DM approach. System testing is done using black box testing method and performance evaluation using confusion matrix. The results showed that the classification system developed achieved an accuracy rate of 93% based on confusion matrix evaluation, and all system functionality runs as expected based on the results of black box testing.

Keywords: *long short-term memory*, classification, students potentially dropping out, *confusion matrix*, *black box*

1. PENDAHULUAN

Long Short-Term Memory (LSTM) merupakan algoritma machine learning yang unggul dalam menganalisis data sekuensial dan *time series* [1]. LSTM adalah variasi dari *Recurrent Neural Network* (RNN) yang mampu menyimpan informasi jangka panjang dan mengatasi masalah *vanishing gradient*, sehingga sangat relevan untuk menganalisis performa akademik mahasiswa yang bersifat berkelanjutan dan memiliki pola temporal [2].

Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Halu Oleo menghadapi tantangan signifikan dalam ketepatan waktu kelulusan mahasiswa. Data periode 2016-2021 menunjukkan FMIPA memiliki rata-rata 336 lulusan per tahun, sementara sekitar 2.133 mahasiswa belum

menyelesaikan studi tepat waktu. Kesenjangan ini mengakibatkan akumulasi mahasiswa dan meningkatkan risiko *drop out*, terutama bagi mahasiswa dengan IPK di bawah 2,00 [3].

Drop out mahasiswa dapat disebabkan oleh berbagai faktor, termasuk kesalahan memilih jurusan, kurangnya pemahaman materi, dan faktor eksternal lainnya [4]. Mengingat kompleksitas faktor-faktor tersebut, diperlukan mekanisme identifikasi dini mahasiswa berisiko *drop out* melalui sistem klasifikasi prediktif.

Penelitian sebelumnya telah menggunakan algoritma tradisional seperti KNN dan C4.5 dengan akurasi 81,50% [5] dan C4.5 dengan akurasi 92% [3]. Namun, penggunaan algoritma LSTM yang memiliki kemampuan lebih canggih dalam menganalisis data

sekuensial diharapkan dapat memberikan hasil prediksi yang lebih akurat untuk mengidentifikasi mahasiswa berpotensi *drop out*, sehingga dapat mendukung upaya pencegahan yang lebih efektif.

2. LANDASAN TEORI

2.1 Drop Out

Drop out (DO) atau penghentian status mahasiswa terjadi ketika perguruan tinggi memutuskan status kemahasiswaan seseorang berdasarkan alasan tertentu yang telah ditetapkan. Untuk meminimalkan risiko *drop out*, perguruan tinggi dapat menerapkan kebijakan atau aturan yang menetapkan standar maksimal dalam proses pembelajaran [6]. Berikut kebijakan universitas Halu Oleo terkait evaluasi keberhasilan studi mahasiswa Program Sarjana pada akhir semester VII (evaluasi tengah program) [7]: (1) Telah mengumpulkan sekurang-kurangnya 75 sks, (2) Mahasiswa mencapai Indeks Prestasi Kumulatif Sementara (IPKS) sekurang-kurangnya 2,25 (kecuali untuk Prodi Kedokteran dengan IPKS minimal 2,00), (3) Mahasiswa yang tidak memenuhi ketentuan sebagaimana dimaksud pada huruf 1 dan 2 dinyatakan tidak dapat melanjutkan studi atau *Drop Out* (DO) kecuali yang pernah dan tengah menjalankan cuti akademik.

2.2 Long Short-Term Memory (LSTM)

Long short-term memory Recurrent Neural Network (LSTM RNN) adalah bentuk lanjutan dari jaringan saraf yang dirancang untuk memahami ketergantungan jangka panjang. Metode ini pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, kemudian dikembangkan lebih lanjut hingga menjadi sangat populer. LSTM RNN terbukti sangat efektif dalam menangani berbagai jenis masalah. Unit LSTM memiliki beberapa variasi, tetapi secara umum strukturnya meliputi *forget gate*, *input gate*, dan *output gate* [8].

Beberapa keunggulan LSTM-RNN dalam penerapannya yaitu: (1) Mengatasi masalah *vanishing gradient* yang terdapat pada RNN, (2) Memori jangka Panjang dan pendek, (3) lebih efisien dalam pemodelan urutan data, (4) Kemampuan generalisasi yang lebih baik[8].

2.3 Confussion Matrix

Confusion matrix merupakan alat analisis prediktif yang menampilkan dan membandingkan nilai sebenarnya dengan nilai prediksi model, yang dapat digunakan untuk menghasilkan metrik evaluasi seperti *Precision*, *Accuracy*, *Recall*, dan *F1-score* [9]. Contoh confusion matrix dapat dilihat pada Tabel 1.

Tabel 1. *Confussion Matrix*

Classification	Predicted Class	
	Class = Yes	Class = No
Class = Yes	a (True Positive – TP)	b (False Negative – FN)
Class = No	c (False Positive – FP)	d (True Negative – TN)

Perhitungan *performance* dan *F-Measure* dalam *confussion matrix* menggunakan persamaan sebagai berikut [10] [11]:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{FP+TP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{FN+TP} \times 100\% \quad (3)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (4)$$

2.4 Randomized Search Cross Validation

Randomized Search Cross Validation adalah metode optimasi *hyperparameter* yang melakukan pencarian secara acak untuk menemukan kombinasi parameter terbaik dalam suatu algoritma. Berbeda dengan *Grid Search CV* yang menguji semua kombinasi parameter secara sistematis, *Randomized Search CV* melakukan sampling acak pada ruang parameter, sehingga dapat mencari parameter optimal lebih efisien dan cepat, terutama ketika menghadapi banyak *parameter* dan *dataset* besar [12].

2.5 Cross-Industry Standard Process Model for Data Mining

Dalam praktik data *mining*, CRISP-DM (*Cross-Industry Standard Process for Data Mining*) dikenal sebagai salah satu metodologi yang paling banyak diterapkan. Pendekatan ini menguraikan alur kerja data *mining* melalui enam fase berurutan: (1) Pemahaman Bisnis, (2) Pemahaman Data, (3) Persiapan Data, (4) Pemodelan, (5) Evaluasi, dan (6) Implementasi. Setiap tahapan dirancang untuk memandu proses analisis data secara sistematis dari identifikasi kebutuhan bisnis hingga penerapan model akhir [13].

3. METODE PENELITIAN

Metode yang digunakan dalam penelitian ini adalah metode *Cross Industry Standard Process for Data Mining* (CRISP-DM). Metode CRISP-DM terdiri dari enam tahap [14] yaitu:

3.1 Business Understanding

Penelitian ini dimotivasi oleh adanya kompleksitas faktor-faktor yang dapat memicu terjadinya *drop out*. penelitian ini bertujuan untuk merancang dan menghasilkan sistem klasifikasi mahasiswa berpotensi *drop out* berdasarkan pola akademiknya.

3.2 Data Understanding

Tahapan ini bertujuan untuk menganalisis data yang telah dikumpulkan. Dataset yang terkumpul berjumlah 2.110 data mahasiswa program S1 dari angkatan 2016 hingga 2021. Data awal masih berupa data mentah sebelum dilakukan proses *preprocessing* dan terdiri dari 15 atribut, meliputi nama, NIM, angkatan, IPS semester 1 hingga 7 (IPS1-7), SKS Kumulatif hingga semester 7, IPK semester 7 (IPKS7), program studi, jalur masuk, tanggal lulus, periode serta status mahasiswa. Setelah proses studi pustaka, variabel atau atribut yang digunakan dalam penelitian ini mencakup tahun masuk, IPS semester 1 hingga 7, SKS Kumulatif hingga semester 7, IPK semester 7 (IPKS7), program studi, jalur masuk dan status mahasiswa.

3.3 Data Preparation

Tahapan ini bertujuan untuk memastikan kualitas data yang baik agar menghasilkan model dengan performa optimal. Tahapan ini mencakup:

1. Data Selection

Data selection merupakan tahapan untuk menentukan atribut yang diperlukan untuk klasifikasi. Atribut tersebut digunakan untuk memprediksi apakah seorang mahasiswa berpotensi *drop out* atau tidak berdasarkan status mahasiswanya. Informasi mengenai atribut data yang digunakan dalam penelitian dapat dilihat dalam Tabel 2.

Table 2. Data Selection

No	Atribut
1	IPS (Indeks Prestasi 1-7)
2	SKS7
3	IPKS7
4	Program Studi
5	Jalur Masuk
6	Status Mahasiswa

2. Data Cleaning

Proses pembersihan data dalam penelitian ini melibatkan pengisian data yang memiliki nilai hilang (*missing value*) menggunakan interpolasi dan nilai *default* (*unknown*) serta mengganti nilai tidak valid (#N/A) dengan nilai yang valid (0.0). *Missing value* merujuk pada

data yang kosong (*null*) dan tidak dapat digunakan dalam analisis penelitian. Pemeriksaan nilai hilang dan penanganannya dilakukan menggunakan sintaks *Python*. Jumlah data yang *missing value* dapat dilihat pada Gambar 1 dan setelah pembersihan nilai *missing* dapat dilihat pada Gambar 2.

Jalur Masuk	IPS1	IPS2	IPS3	IPS4	IPS5	IPS6	IPS7
185	63	62	2	2	2	2	3

Gambar 1. Jumlah data *missing value*

```
Series([], dtype: int64)
```

Gambar 2. Jumlah data *missing value* setelah *cleaning*

3. Data Transformation

Pada proses data transformation ini terdiri dari beberapa tahap, diantaranya pelabelan data kategorikal, membagi dataset menjadi data fitur (X) dan data target (y), pembagian dataset menjadi data *training*, data *testing*, data *validation*, normalisasi data, penanganan *imbalance* data dan *reshape* data untuk model LSTM.

a. Pelabelan data kategorikal

Tahap ini merupakan tahapan yang digunakan untuk merubah data kategorikal menjadi bentuk numerik untuk mempermudah proses pelatihan. Atribut yang akan diubah kedalam bentuk numerik adalah atribut status mahasiswa, program studi, dan jalur masuk. Atribut status mahasiswa memiliki dua kategori yaitu "Tidak Berpotensi DO" = 0, dan "Berpotensi DO" = 1. Sementara itu, atribut program studi dan jalur masuk dikonversi menggunakan teknik *one-hot encoding* yang menghasilkan nilai biner (*true/false* atau 1/0) untuk setiap kategori yang ada.

b. Membagi dataset menjadi fitur (X) dan target (y)

Tahap ini merupakan proses pemisahan antara variabel independen (yang digunakan untuk membuat prediksi) dan variabel dependen (yang ingin diprediksi). Variabel independen sering kali direpresentasikan sebagai fitur (X), yang dalam penelitian ini meliputi kolom IPS1-7, SKS7, IPKS7, program studi, jalur masuk. Sementara itu, variabel dependen atau target (y) yang akan diprediksi adalah status mahasiswa.

c. Membagi data menjadi data *training*, *testing* dan *validation*

Metode *splitting* yang akan digunakan dalam penelitian ini adalah *random sampling* yaitu mengambil data secara acak berdasarkan parameter tertentu. Rasio pembagian data dapat dilihat pada Gambar 3.

Train Samples	Val Samples	Test Samples	Train Ratio (%)	Val Ratio (%)	Test Ratio (%)	Val Accuracy	Test Accuracy	Val Loss	Test Loss
927	104	258	72%	8%	20%	0.8846	0.8410	0.326	0.343
876	155	258	68%	12%	20%	0.9354	0.9186	0.354	0.362
824	207	258	64%	16%	20%	0.9323	0.9147	0.215	0.263
773	258	258	60%	20%	20%	0.9186	0.9108	0.262	0.278
721	310	258	56%	24%	20%	0.9193	0.9186	0.256	0.264
670	361	258	52%	28%	20%	0.9252	0.9069	0.263	0.297
618	413	258	48%	32%	20%	0.9225	0.8992	0.298	0.336

Gambar 3. Rasio pembagian data

d. Normalisasi data

Tahap selanjutnya adalah normalisasi pada fitur numerik (IPS1-7, SKS7 dan IPKS7) dengan menskalakan nilai-nilai ke dalam rentang tertentu, yaitu antara 0 - 1 menggunakan metode *MinMaxScaler*.

e. Penanganan *imbalance* data

Ketidakseimbangan kelas (*imbalance* data) antara kelas berpotensi DO dan tidak berpotensi DO pada data *training* diatasi dengan menggunakan metode *Synthetic Minority Oversampling Technique* (SMOTE) untuk menambah data sintesis pada kelas minoritas guna menyeimbangkan distribusi kelas. Pendistribusi kelas pada data latih sebelum dan sesudah dilakukan SMOTE dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4. Grafik jumlah data sebelum SMOTE



Gambar 5. Grafik jumlah data setelah SMOTE

f. *Reshape* data untuk model LSTM

LSTM memerlukan data input dalam format 3D (tiga dimensi), yang terdiri dari *samples*, *timesteps* dan *features*. Dalam konteks ini, *samples* adalah jumlah data, *timesteps* adalah jumlah langkah waktu dalam urutan (seperti semester), dan *features* adalah jumlah variabel pada setiap timestep. Data setelah *reshape* dapat dilihat pada Tabel 3, Tabel 4 dan Tabel 5.

Tabel 3. Data Fitur Setelah di *Reshape* (*Training*)

Samples	Timesteps	Features
1.318	1	25

Tabel 4. Data Fitur Setelah di *Reshape* (*Validation*)

Samples	Timesteps	Features
207	1	25

Tabel 5. Data Fitur Setelah di *Reshape* (*Testing*)

Samples	Timesteps	Features
258	1	25

4. Modeling

Pada tahap *Modeling* ini setiap parameter akan diuji, menggunakan metode *random search cross validation* dan hasil dari parameter yang optimal akan diterapkan ke dalam model klasifikasi. Jumlah parameter-parameter yang akan diuji sebelum kemudian digunakan dalam pembuatan model LSTM dapat dilihat pada Tabel 6.

Tabel 6. Parameter Pengujian Model LSTM

Parameter	Keterangan
Learning rate	0.0001, 0.001, 0.01
Units	32, 64, 128
Dropout rate	0.2 – 0.5
Batch size	32, 64, 128
Epoch	50, 100, 150

a. *Randomized search cross validation*

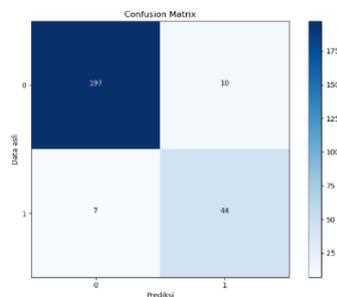
Setelah melakukan *reshape* data, langkah berikutnya adalah membangun model dan melakukan *hyperparameter tuning* menggunakan metode *Randomized Search CV* untuk menentukan kombinasi *hyperparameter* terbaik bagi model LSTM. Model diuji dengan lima kombinasi *hyperparameter* untuk menemukan pengaturan yang menghasilkan performa terbaik. Rincian *hyperparameter* yang diuji serta hasil tuning terbaik disajikan pada Tabel 7.

Tabel 7. Hasil *Random Search Cross Validation*

Parameter	Nilai Uji	Nilai Terbaik
<i>Learning rate</i>	0.0001, 0.001, 0.01	0.0001
<i>Units</i>	32, 64, 128	32
<i>Dropout rate</i>	0.2 – 0.5	0.2
<i>Batch size</i>	32, 64, 128	64
<i>Epoch</i>	50, 100, 150	150

5. Evaluation

Setelah hasil prediksi mahasiswa berpotensi DO diperoleh, *confusion matrix* digunakan untuk menghitung akurasi performa model. *Confusion matrix* dapat dilihat pada Gambar 6 dan hasil akurasi model LSTM untuk klasifikasi mahasiswa berpotensi DO dapat dilihat pada Gambar 7.



Gambar 6. *Confusion matrix*

Classification Report:				
	precision	recall	f1-score	support
0	0.97	0.95	0.96	207
1	0.81	0.86	0.84	51
accuracy			0.93	258
macro avg	0.89	0.91	0.90	258
weighted avg	0.94	0.93	0.93	258

Gambar 7. Hasil akurasi

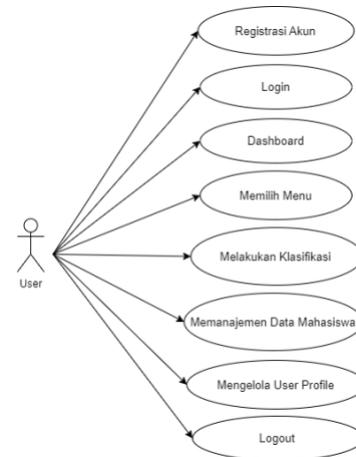
Dari gambar yang disajikan, evaluasi klasifikasi menggunakan *confusion matrix* menghasilkan *True Positive* sebanyak 44 data, *False Negative* sebanyak 10 data dan *False Positive* sebanyak 7 data, serta *True Negative* sebanyak 197 data. Adapun nilai akurasi yang diperoleh sebesar 93%. Nilai *precision* untuk kelas berpotensi DO 81% dan tidak berpotensi DO 97%, sementara nilai *recall* untuk kelas berpotensi DO 86% dan tidak berpotensi DO 95%, terakhir *F1-Score* kelas berpotensi DO 84% dan tidak berpotensi DO 96%.

6. Deployment

Tahap implementasi atau *deployment* ialah tahap pengaplikasian model algoritma yang telah di evaluasi ke dalam sistem klasifikasi berbasis *web*.

Dari hasil evaluasi model yang telah diperoleh, kemudian diterapkan pada perancangan sistem UML

(*Undefined Modelling Language*). *Use Case Diagram* pada sistem ini memiliki 1 aktor yaitu *user*. *Use case diagram* dari sistem klasifikasi mahasiswa berpotensi *drop out* dapat dilihat pada Gambar 8.



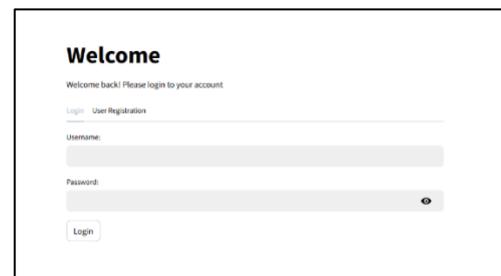
Gambar 8. *Use Case Diagram*

4. HASIL DAN PEMBAHASAN

Hasil pemodelan yang telah didapatkan selanjutnya diimplementasikan ke dalam sistem klasifikasi dan kemudian akan dilakukan pengujian terhadap dataset 2018. Berikut merupakan tampilan dari sistem klasifikasi mahasiswa berpotensi DO menggunakan algoritma *long short-term memory*.

4.1 Halaman login

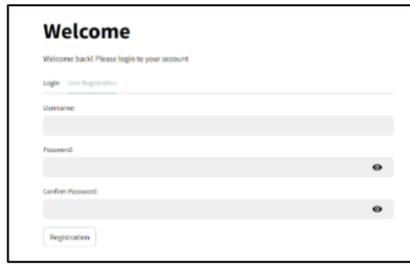
Halaman *login* berfungsi sebagai halaman awal yang akan dilewati *user* untuk bisa mengakses halaman selanjutnya. Halaman ini hanya bias diakses oleh *user* yang telah memiliki akun. Adapun rancangan *user interfacenya* dapat dilihat pada Gambar 9.



Gambar 8. Halaman *login*

4.2 Halaman registrasi

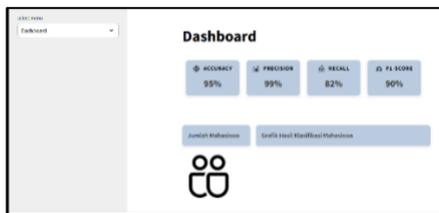
Halaman registrasi adalah halaman yang digunakan *user* yang belum mempunyai akun untuk mendaftarkan akunnya. Pada halaman ini, *user* akan diminta untuk mengisi *username* dan *password*, serta mengkonfirmasi ulang *password* yang telah dimasukkan sebelumnya. Adapun *user interfacenya* dapat dilihat pada Gambar 10.



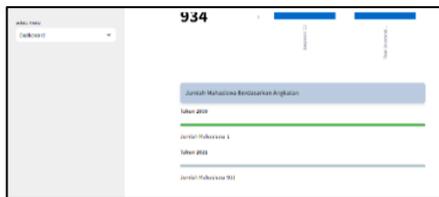
Gambar 10. Halaman Registrasi

4.3 Halaman dashboard

Halaman dashboard merupakan halaman utama yang akan dilihat oleh *user* ketika berhasil login. Adapapun rancangan *user interfacenya* dapat dilihat pada Gambar 11 dan Gambar 12.



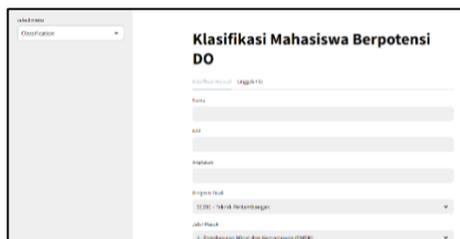
Gambar 11. Halaman dashboard 1



Gambar 12. Halaman dashboard 2

4.4 Halaman klasifikasi

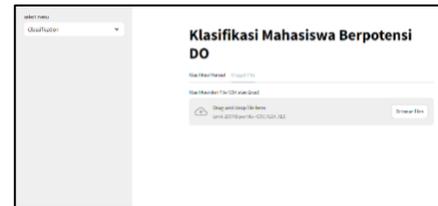
Halaman klasifikasi merupakan halaman yang digunakan untuk mengklasifikasikan mahasiswa. pada halaman ini *user* dapat memilih dua cara pengklasifikasian yaitu klasifikasi manual atau klasifikasi *file* unggahan. Adapun rancangan *user interfacenya* dapat dilihat pada Gambar 13 dan Gambar 14 dan Gambar 15.



Gambar 13. Halaman klasifikasi 1



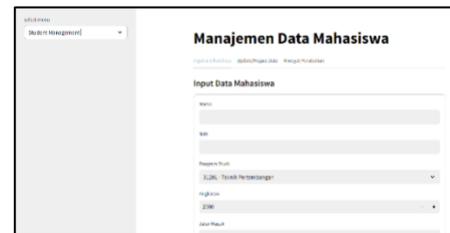
Gambar 14. Halaman klasifikasi 2



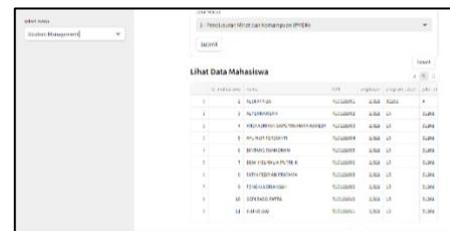
Gambar 15. Halaman klasifikasi 3

4.5 Halaman manajemen mahasiswa

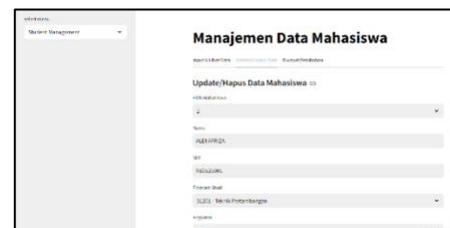
Halaman Manajemen Mahasiswa merupakan halaman yang dapat *user* gunakan untuk mengelola data mahasiswa, baik itu untuk menginput data mahasiswa baru yang akan diklasifikasi maupun *update* atau menghapus data mahasiswa yang telah ada, dan di halaman ini juga *user* dapat melihat riwayat perubahan yang telah dilakukan. Adapun rancangan *user interfacenya* dapat dilihat pada Gambar 16, Gambar 17, Gambar 18 dan Gambar 19.



Gambar 16. Halaman manajemen mahasiswa 1



Gambar 17. Halaman manajemen mahasiswa 2



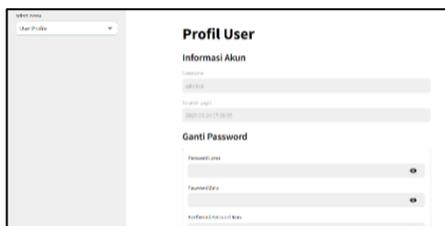
Gambar 18. Halaman manajemen mahasiswa 3



Gambar 19. Halaman manajemen mahasiswa 4

4.6 Halaman profil user

Halaman profil *user* adalah halaman yang dapat user gunakan untuk mengganti *password* dan melihat informasi akun. Adapapun rancangan *user interfacenya* dapat dilihat pada Gambar 20.



Gambar 20. Halaman profil user

4.7 Hasil pengujian dataset 2018

Setelah model dilatih dan dievaluasi pada dataset awal, pengujian pada dataset baru dengan karakteristik serupa yang tidak digunakan selama pelatihan sangat penting untuk menilai kemampuan generalisasi model. Sebagai sampel representatif, Tabel 8 menunjukkan beberapa mahasiswa Program Studi Ilmu Komputer angkatan 2018 beserta hasil prediksi status akademik mereka.

Tabel 8. Perbandingan Data Aktual dan Prediksi

Status	Data Aktual (2018)	Data Prediksi	Selisih	Presentase Error (%)
Lulus	43	42	1	2.33%
Belum Lulus/Calon DO	17	18	1	5.88%
Total Mahasiswa	60			

5. KESIMPULAN

Implementasi algoritma LSTM pada sistem klasifikasi mahasiswa berpotensi DO mencapai akurasi 93% berdasarkan *confusion matrix*, dengan hanya tujuh kesalahan klasifikasi dari 258 sampel. *Classification report* menunjukkan performa model yang cukup bagus dengan *precision* 97% (tidak DO) dan 81% (DO), *recall* 95% (tidak DO) dan 86% (DO). *F1-score* masing-masing 96% dan 84% menandakan keseimbangan *precision* dan *recall* yang baik. *Black Box Testing* juga membuktikan sistem berjalan sesuai harapan. Pengembangan lebih lanjut dapat mencakup

variabel tambahan dan pengujian pada *dataset* lebih besar untuk meningkatkan generalisasi model.

6. DAFTAR PUSTAKA

- [1] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1570–1580, 2021, doi: 10.35957/jatisi.v8i3.1159.
- [2] A. R. Isnain, H. Sulistiani, B. M. Hurohman, A. Nurkholis, and S. Styawati, "Analisis Perbandingan Algoritma LSTM dan Naive Bayes untuk Analisis Sentimen," *J. Edukasi dan Penelit. Inform.*, vol. 8, no. 2, p. 299, 2022, doi: 10.26418/jp.v8i2.54704.
- [3] K. Faozi, "Optimasi Algoritma C4. 5 dengan Fuzzy Inference System Mamdani dalam Memprediksi Mahasiswa Berpotensi Dropout," *Sci. Sacra J. Sains, Teknol. dan ...*, vol. 2, no. 3, pp. 272–280, 2022, [Online]. Available: <http://pijarpemikiran.com/index.php/Scientia/article/view/238%0Ahttp://pijarpemikiran.com/index.php/Scientia/article/download/238/217>
- [4] A. Ulfa, D. Winarso MKom, and E. Arribe MMSi, "Sistem Rrekomendasi Jurusan Kuliah Bagi Calon Mahasiswa Baru Menggunakan Algoritma C4.5 (Studi Kasus : Universitas Muhammadiyah Riau)," *Fasilkom*, vol. 10, no. 1, pp. 61–65, 2020.
- [5] N. L. Ratniasih, "Penerapan Algoritma Klasifikasi Untuk Penentuan Mahasiswa Berpotensi Drop Out," *J. Teknol. Inf. dan Komput.*, vol. 6, no. 3, pp. 417–422, 2021, doi: 10.36002/jutik.v6i3.1347.
- [6] A. Ramadhani, R. F. Noor, D. Vernanda, and T. Herdiawan, "Klasifikasi Mahasiswa Berpotensi Drop Out Menggunakan Algoritma C4.5 di Politeknik Negeri Subang," *J. Tekno Kompak*, vol. 18, no. 1, p. 101, 2024, doi: 10.33365/jtk.v18i1.3439.
- [7] "Peraturan Rektorat No 1 tahun 2019," pp. 1–23, 2016.
- [8] A. A. Anandari, G. Harsono, and A. F. Wajdi, *Long Short-Term Memory Recurrent Neural Network (LSTM-RNN) Aplikasi Penginderaan Jauh untuk Kelautan & Perikanan Laut Tangkap*. CV Jejak (Jejak Publisher), 2024. [Online]. Available: https://books.google.co.id/books?id=9j0eEQAAQBAJ&dq=buku+LSTM&lr=&hl=id&source=gbs_navlinks_s
- [9] M. O. Sanjaya, S. Bukhori, and M. `Ariful Furqon, "Virtual Assistant for Thesis Technical Guide Using Artificial Neural Network," *Indones. J. Artif. Intell. Data Min.*,

- vol. 6, no. 2, p. 188, 2023, doi: 10.24014/ijaidm.v6i2.23473.
- [10] H. Salmawati, Yuyun, “Klasifikasi Mahasiswa Berpotensi Drop Out Menggunakan Algoritma Decision Tree C4 . 5 Dan Naive Bayes Di Universitas Jambi,” *J. Ilm. Ilmu Komput.*, vol. 8, no. 2, p. 115032, 2021, [Online]. Available: <https://repository.unja.ac.id/25341/>
- [11] T. Fadiyah Basar, D. E. Ratnawati, and I. Arwani, “Analisis Sentimen Pengguna Twitter terhadap Pembayaran Cashless menggunakan ShopeePAY dengan Algoritma Random Forest,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 3, pp. 1426–1433, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [12] A. R. Hidayati, A. S. Fitriani, M. A. Rosid, F. Sains, and D. Teknologi, “Analisa Sentimen Pemilu 2019 Pada Judul Berita Online Menggunakan Metode Logistic Regression,” *Kesatria J. Penerapan Sist. Inf. (Komputer dan Manajemen)*, vol. 4, no. 2, pp. 298–305, 2023, [Online]. Available: <http://www.pkm.tunasbangsa.ac.id/index.php/kesatria/article/view/164>
- [13] Y. Suhandha, I. Kurniati, and S. Norma, “Penerapan Metode Crisp-DM Dengan Algoritma K-Means Clustering Untuk Segmentasi Mahasiswa Berdasarkan Kualitas Akademik,” *J. Teknol. Inform. dan Komput.*, vol. 6, no. 2, pp. 12–20, 2020, doi: 10.37012/jtik.v6i2.299.
- [14] Y. Yudiana, A. Yulia Agustina, and dan Nur Khofifah, “Prediksi Customer Churn Menggunakan Metode CRISP-DM Pada Industri Telekomunikasi Sebagai Implementasi Mempertahankan Pelanggan,” *Indones. J. Islam. Econ. Bus.*, vol. 8, no. 1, pp. 01–20, 2023, [Online]. Available: http://e-journal.lp2m.uinjambi.ac.id/ojp/index.php/ij_oieb