



**KLASIFIKASI *HATE SPEECH* DAN *ABUSIVE* PADA TWEET
DI PLATFORM X**

KERJA PRAKTIK



**Program Studi
S1 Teknik Komputer**

**UNIVERSITAS
Dinamika**

Oleh :

RAKHA WIRA KRISNHA

21410200008

FAKULTAS TEKNOLOGI DAN INFORMATIKA

UNIVERSITAS DINAMIKA

2024

**KLASIFIKASI *HATE SPEECH* DAN *ABUSIVE* PADA TWEET
DI PLATFORM X**

Diajukan Sebagai salah satu syarat untuk menyelesaikan
Program Sarjana

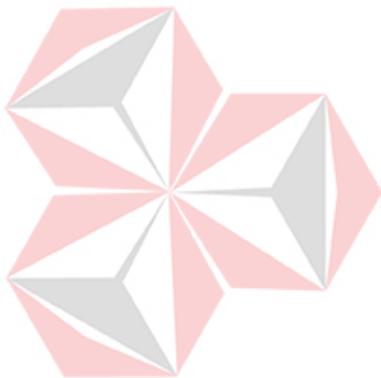
Disusun Oleh :

Nama : Rakha Wira Krisnha

NIM : 21410200008

Program : S1 (Strata Satu)

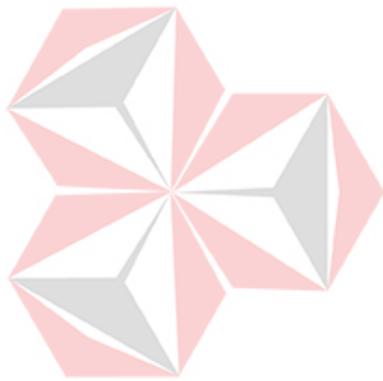
Jurusan : Teknik Komputer



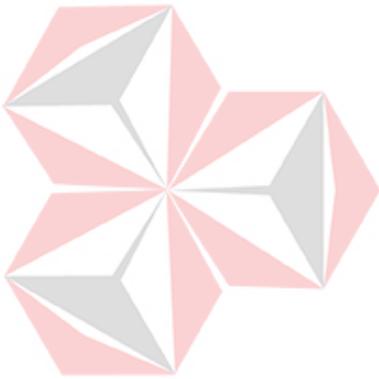
FAKULTAS TEKNOLOGI DAN INFORMATIKA

UNIVERSITAS DINAMIKA

2024



UNIVERSITAS
Dinamika
Teruslah Melangkah
Rakha Wira Krishna



UNIVERSITAS
Dinamika

*Laporan Kerja Praktik ini
Saya persembahkan kepada
Keluarga, Dosen Pembimbing, dan
Teman-teman yang saya kasihi*

LEMBAR PENGESAHAN
KLASIFIKASI *HATE SPEECH* DAN *ABUSIVE* PADA TWEET
DI *PLATFORM X*

Laporan Kerja Praktik oleh

Rakha Wira Krisnha

NIM: 21410200008

Telah diperiksa, diuji, dan disetujui

Surabaya, 31 Juli 2024



UNIVERSITAS

Disetujui:

Pembimbing

Digitally signed by Heri Pratikno, M.T.
DN: cn=Heri Pratikno, M.T.,
o=Universitas Dinamika, ou=S1 Teknik
Komputer, email=heri@dinamika.ac.id,
c=ID
Date: 2024.08.02 00:54:22 +07'00'
Adobe Acrobat version: 11.0.23

Heri Pratikno M.T.

NIDN. 0716117302

Penyelia

Lutfi Dwimulya S.T., M.SI.

Mengetahui,

Ketua Program Studi S1 Teknik Komputer

cn=Pauladie Susanto, o=Universitas
Dinamika, ou=PS S1 Teknik Komputer,
email=pauladie@dinamika.ac.id, c=ID
2024.08.02 08:46:04 +07'00'

Pauladie Susanto. S.Kom. M.T.

NIDN. 0729047501

PERNYATAAN
PERSETUJUAN PUBLIKASI DAN KEASLIAN KARYA ILMIAH

Sebagai mahasiswa **Universitas Dinamika**, Saya :

Nama : **Rakha Wira Krisnha**
NIM : **21410200008**
Program Studi : **S1 Teknik Komputer**
Fakultas : **Fakultas Teknologi Dan Informatika**
Jenis Karya : **Laporan Kerja Praktik**
Judul Karya : **KLASIFIKASI HATE SPEECH DAN ABUSIVE PADA TWEET DI PLATFORM X**

Menyatakan dengan sesungguhnya bahwa :

1. Demi pengembangan Ilmu Pengetahuan, Teknologi dan Seni, Saya menyetujui memberikan kepada **Universitas Dinamika** Hak Bebas Royalti Non-Eksklusif (*Non-Exclusive Royalty Free Right*) atas seluruh isi/sebagian karya ilmiah Saya tersebut diatas untuk disimpan, dialihmediakan, dan dikelola dalam bentuk pangkalan data (*database*) untuk selanjutnya didistribusikan atau dipublikasikan demi kepentingan akademis dengan tetap mencantumkan nama Saya sebagai penulis atau pencipta dan sebagai pemilik Hak Cipta.
2. Karya tersebut diatas adalah hasil karya asli Saya, bukan plagiat baik sebagian maupun keseluruhan. Kutipan, karya, atau pendapat orang lain yang ada dalam karya ilmiah ini semata-mata hanya sebagai rujukan yang dicantumkan dalam Daftar Pustaka Saya.
3. Apabila dikemudian hari ditemukan dan terbukti terdapat tindakan plagiasi pada karya ilmiah ini, maka Saya bersedia untuk menerima pencabutan terhadap gelar kesarjanaan yang telah diberikan kepada Saya.

Demikian surat pernyataan ini Saya buat dengan sebenar-benarnya.

Surabaya, 29 Juli 2024



Rakha Wira Krisnha
NIM : 21410200008

ABSTRAK

Pada Kerja Praktik ini bertujuan untuk mengidentifikasi dan mengklasifikasikan *tweet* yang mengandung ujaran kebencian (*hate speech*) dan kata-kata kasar (*abusive*) menggunakan *Natural Language Processing* (NLP) di aplikasi X. Data yang digunakan berasal dari *Kaggle*, dengan tiga file CSV yaitu *data.csv*, *abusive.csv*, dan *new_kamusalay.csv*. Pada program ini menggunakan beberapa *library* seperti *Pandas*, *Numpy*, *Matplotlib*, *Seaborn*, *Wordcloud*, *Sklearn*, *Tensorflow*, dan *Streamlit*. Untuk pemodelan, digunakan arsitektur jaringan saraf rekuren LSTM (*Long ShortTerm Memories*), yang mampu memproses data sekuensial dengan efektif. Model dilatih menggunakan 25 *epoch* dan dievaluasi dengan metrik akurasi, presisi, dan *recall*. Hasil evaluasi dari sistem menunjukkan akurasi sebesar 91.11%, presisi 90.00%, dan *recall* 91.00%, hal ini menunjukkan bahwa model memiliki akurasi tinggi namun presisi dan *recall* masih perlu ditingkatkan. Proyek ini bermanfaat dalam mengurangi paparan terhadap ujaran kebencian dan penggunaan bahasa kasar di *platform X* di Indonesia, menciptakan ruang *online* yang lebih aman, positif, serta membantu penegak hukum dalam mengidentifikasi dan menindak pelaku ujaran kebencian dan *cyberbullying*. Aplikasi yang dibuat juga telah di-*deploy* menggunakan *Streamlit Cloud* dan dapat diakses melalui *link* yang disediakan.

Kata Kunci : *Machine Learning, Hatespeech, Abusive, NLP, LSTM*

KATA PENGANTAR

Puji syukur dengan kehadiran Tuhan YME yang telah memberikan berkat dan karunia-Nya sehingga penulis dapat menyelesaikan laporan kerja praktik ini dengan judul “KLASIFIKASI *HATE SPEECH* DAN *ABUSIVE* PADA TWEET DI *PLATFORM X*” ini dengan baik dan lancar. Penyelesaian laporan Kerja Praktik ini sebagai syarat wajib untuk menyelesaikan program sarjana. Tidak terlepas dari bantuan dari pihak yang telah memberikan masukan, nasihat, saran, kritik kepada penulis. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan rasa terima kasih kepada :

1. Ayah dan Ibu tercinta yang memberikan doa dan dukungan penuh kepada saya
2. Bapak Heri Pratikno, M.T. selaku Dosen Pembimbing yang sudah memberikan bimbingan selama proses penyelesaian kerja praktik.
3. Kak Rugaya BSA, selaku Mentor MSIB Hacktiv8 *Batch 6*
4. Aldo Lionel dan Ardin Febrianda, selaku mentor kelas besar selama studi independent berlangsung

Penulis menyadari bahwa laporan ini masih jauh dari kata sempurna. Dengan demikian penulis mengharapkan kritik dan saran yang membangun dari pembaca untuk penyempurnaan dalam menyelesaikan laporan. Semoga laporan Kerja Praktik ini dapat bermanfaat untuk penulis sendiri, dan para pembaca.

Surabaya, 29 Juli 2024



Penulis

DAFTAR ISI

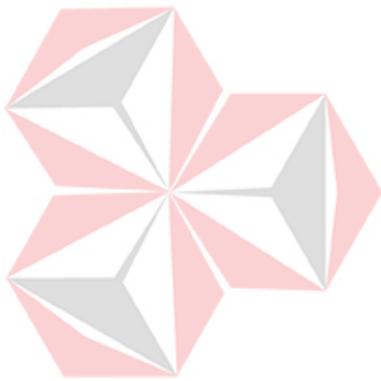
	Halaman
ABSTRAK	v
KATA PENGANTAR.....	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	x
DAFTAR LAMPIRAN	xi
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah.....	3
1.5 Manfaat.....	4
BAB II GAMBARAN UMUM.....	5
2.1 Latar Belakang Perusahaan	5
2.2 Identitas Perusahaan	6
2.3 Visi Perusahaan	6
2.4 Misi Perusahaan	6
2.5 Struktur Organisasi.....	7
2.6 Peta Lokasi	8
2.7 Produk dan Layanan.....	8
BAB III LANDASAN TEORI.....	11
3.1 <i>Python (Data Science)</i>	11
3.2 NLP	11
3.3 <i>Streamlit</i>	12
BAB IV DESKRIPSI PEKERJAAN	13
4.1 Metodologi Penelitian	13
BAB V PENUTUP	28
5.1 Kesimpulan.....	28
5.2 Saran.....	28
DAFTAR PUSTAKA	30
LAMPIRAN	31

DAFTAR GAMBAR

Gambar 2.1 Logo Hacktiv8.....	5
Gambar 2.2 Struktur Organisasi PT. Hacktivate Teknologi Indonesia.....	7
Gambar 2.3 Peta Lokasi PT. Hacktivate Teknologi Indonesia.....	8
Gambar 4.1 Load Data.....	13
Gambar 4.2 Cleaning Data.....	14
Gambar 4.3 Data Processing.....	16
Gambar 4.4 Menganalisis kata hatespeech dan abusive.....	16
Gambar 4.5 Word Cloud.....	17
Gambar 4.6 Labeling Data.....	18
Gambar 4.7 Jumlah Data per Kategori.....	19
Gambar 4.8 Jumlah Data Berdasarkan Label.....	19
Gambar 4.9 Training Model 1.....	20
Gambar 4.10 Grafik hasil training model.....	21
Gambar 4.11 Memastikan Format Data.....	22
Gambar 4.12 Pipeline.....	23
Gambar 4.13 Parameter Grid.....	23
Gambar 4.14 Grid Search.....	24
Gambar 4.15 Hasil Grid Search.....	24
Gambar 4.16 Evaluasi Model.....	25
Gambar 4.17 Model ketika kata tidak mengandung Hatespeech dan Abusive.....	26
Gambar 4.18 Ketika mengandung Hatespeech.....	27

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Surat Balasan dari Perusahaan.....	31
Lampiran 2 Laporan Bulanan (MSIB).....	32
Lampiran 3 Laporan Kegiatan (MSIB).....	42
Lampiran 4 Kartu Bimbingan KP.....	43
Lampiran 5 Sertifikat MSIB.....	44
Lampiran 6 Biodata Penulis.....	45



UNIVERSITAS
Dinamika

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam era digital saat ini, media sosial telah menjadi platform utama bagi masyarakat untuk berinteraksi dan berbagi informasi. Namun, perkembangan ini juga membawa dampak negatif, seperti penyebaran ujaran kebencian (*hate speech*) dan bahasa kasar (*abusive language*) yang dapat memicu konflik dan permusuhan di antara pengguna. *Twitter*, yang kini dikenal sebagai *X*, merupakan salah satu platform yang sering digunakan untuk menyebarkan konten semacam ini. Oleh karena itu, diperlukan upaya untuk mengidentifikasi dan mengklasifikasikan *tweet* yang mengandung ujaran kebencian dan bahasa kasar guna menciptakan lingkungan digital yang lebih aman dan positif.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis menggunakan teknik *Natural Language Processing* (NLP) untuk mendeteksi ujaran kebencian dan bahasa kasar pada *tweet*. Data yang digunakan dalam penelitian ini berasal dari Kaggle dan terdiri dari tiga file CSV: *data.csv*, *abusive.csv*, dan *new_kamusalay.csv*. Proses pengolahan data melibatkan beberapa *library* seperti *Pandas*, *Numpy*, *Matplotlib*, *Seaborn*, *Wordcloud*, *Sklearn*, *Tensorflow*, dan *Streamlit*. Model yang digunakan adalah LSTM (*Long ShortTerm Memories*), yang dirancang untuk mengatasi masalah *vanishing gradient* pada jaringan saraf rekuren tradisional dan sangat efektif dalam pemrosesan data sekuensial seperti teks. Model ini dilatih dengan menggunakan 25 *epoch* dan

dievaluasi dengan metrik akurasi, presisi, dan *recall*. Hasil evaluasi menunjukkan akurasi sebesar 91.11%, presisi 90.00%, dan *recall* 91.00%, yang menunjukkan bahwa model memiliki kinerja yang baik dalam mendeteksi *tweet* dengan ujaran kebencian dan bahasa kasar.

Proyek ini diharapkan dapat mengurangi paparan terhadap konten negatif di *Twitter*, membantu menciptakan ruang *online* yang lebih aman dan positif bagi pengguna, serta memberikan alat yang berguna bagi penegak hukum dalam mengidentifikasi dan menindak pelaku ujaran kebencian dan *cyberbullying*. Aplikasi yang dikembangkan telah di-*deploy* menggunakan *Streamlit Cloud* dan dapat diakses melalui link yang disediakan untuk pengujian dan penggunaan lebih

lanjut.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, rumusan masalah dalam proyek penelitian ini adalah bagaimana mengembangkan sistem klasifikasi otomatis menggunakan teknik *Natural Language Processing* (NLP) untuk mendeteksi dan mengklasifikasikan ujaran kebencian (*hate speech*) dan bahasa kasar (*abusive language*) pada *tweet* di *platform X*. Penelitian ini perlu menjawab bagaimana model LSTM dapat digunakan untuk mengatasi masalah ini dan sejauh mana akurasi, presisi, dan *recall* dari model tersebut dalam mengidentifikasi konten negatif di media sosial.

1.3 Batasan Masalah

Berdasarkan uraian diatas, maka dalam pelaksanaan Kerja Praktik terdapat beberapa batasan masalah, antara lain :

1. Proyek penelitian ini menggunakan data yang didapat dari *kaggle*. data tersebut hanya mencakup *tweet* berbahasa indonesia.
2. Proyek penelitian ini berfokus pada model *Long ShortTerm Memories* (LSTM) untuk pemrosesan data sekuensial.
3. Model yang digunakan adalah *Matrix Accuration, Precision, dan Recall*
4. *Deployment* yang digunakan adalah *Streamlit*

1.4 Tujuan

Berdasarkan uraian dari latar belakang dan rumusan masalah, maka dapat disesuaikan bahwa, tujuan dari Kerja Praktik ini yaitu untuk mengembangkan sistem klasifikasi otomatis yang mampu mendeteksi dan mengklasifikasikan *tweet* yang mengandung ujaran kebencian (*hate speech*) dan bahasa kasar (*abusive language*) dengan menggunakan teknik *Natural Language Processing* (NLP) dan model *Long ShortTerm Memories* (LSTM). Dengan demikian, penelitian ini bertujuan untuk meningkatkan akurasi, presisi, dan recall dalam identifikasi konten negatif di *Platform X* berbahasa Indonesia, menciptakan lingkungan digital yang lebih aman dan positif, serta menyediakan alat yang bermanfaat bagi penegak hukum dalam menangani kasus ujaran kebencian dan *cyberbullying*.

1.5 Manfaat

Adapun manfaat dari pelaksanaan Kerja Praktik ini antarlain sebagai berikut:

1. Peningkatan Keamanan Digital dengan adanya sistem klasifikasi otomatis ujaran kebencian dan bahasa kasar.
2. Dukungan bagi Penegak Hukum dengan sistem ini dapat membantu penegak hukum dalam mengidentifikasi dan menindak pelaku ujaran kebencian dan *cyberbullying*, sehingga mempercepat proses penegakan hukum dan perlindungan masyarakat.
3. Efisiensi dalam moderasi konten dengan menggunakan teknik NLP dan model LSTM, proses moderasi konten menjadi lebih efisien dan efektif, mengurangi beban kerja moderator manusia dan meningkatkan kecepatan respon terhadap konten negatif.



UNIVERSITAS
Dinamika

BAB II

GAMBARAN UMUM

2.1 Latar Belakang Perusahaan

Perusahaan yang memberikan tugas untuk mengerjakan proyek penelitian ini selama program MSIB Batch 6 adalah Hacktiv8, yang merupakan sebuah coding bootcamp yang berbasis di Jakarta, Indonesia. Mereka berfokus pada pelatihan intensif untuk mempersiapkan individu dalam karir di bidang teknologi, terutama dalam pengembangan *web*, *data science*, dan *Marketing*. Hacktiv8 menawarkan berbagai program yang dirancang untuk membantu siswa dari berbagai latar belakang untuk menjadi pengembang perangkat lunak yang kompeten dalam waktu singkat. Hacktiv8 memiliki Kantor yang berlokasi di Jl. Sultan Iskandar Muda No.7, RT.5/RW.9, Kby. Lama Sel., Kec. Kby. Lama, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta 12240. Logo dari Hacktiv8 sendiri dapat dilihat pada Gambar 2.1



Gambar 2.1 Logo Hacktiv8

2.2 Identitas Perusahaan

Nama Instansi : PT Hacktivate Teknologi Indonesia (Hactiv8)
Alamat : Jl. Sultan Iskandar Muda No.7, RT.5/RW.9, Kby. Lama Sel.,
Kec. Kby. Lama, Kota Jakarta Selatan, Daerah Khusus
Ibukota Jakarta 12240
No. Telepon : 02180675787
Website : <https://www.hactiv8.com/>
Email : -

2.3 Visi Perusahaan

Hactiv8 memiliki visi untuk menjadi lembaga pendidikan terkemuka di Asia Tenggara yang menghasilkan talenta teknologi berkualitas tinggi dan siap kerja yang mampu bersaing di pasar global.

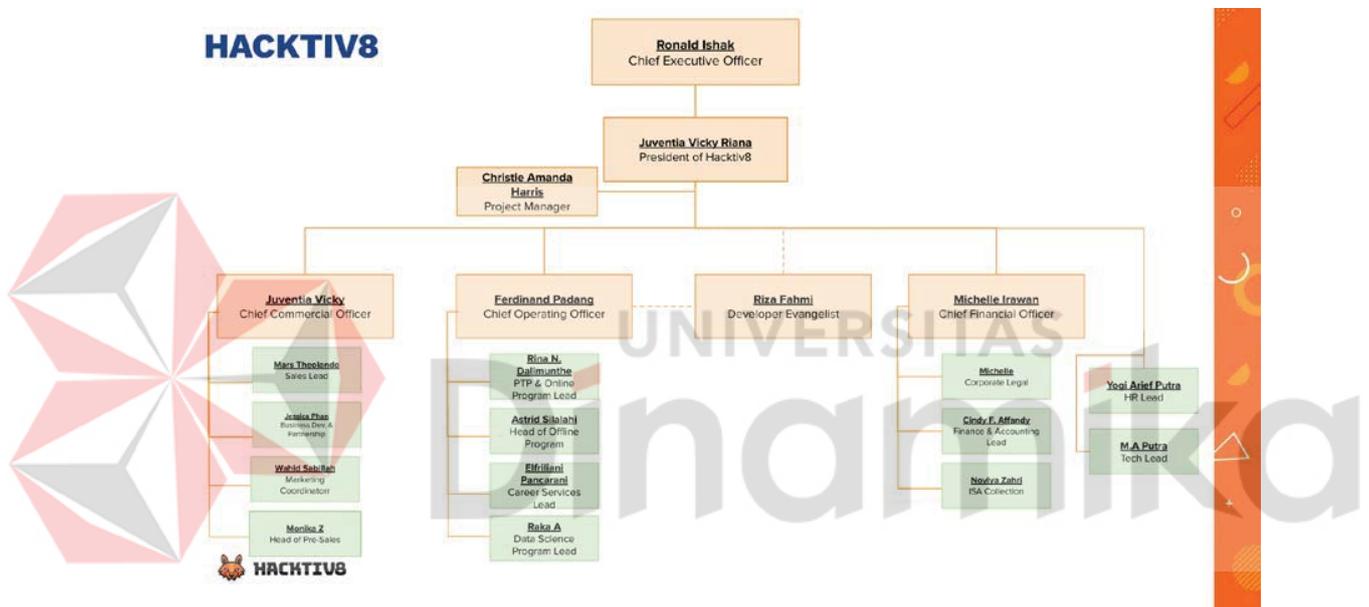
2.4 Misi Perusahaan

Misi dari Hactiv8 adalah sebagai berikut :

1. Menyediakan program pelatihan yang berfokus pada keterampilan praktis dan relevan dengan industri.
2. Membantu siswa mendapatkan pekerjaan di perusahaan teknologi terkemuka melalui jaringan dan kemitraan yang luas.
3. Mengembangkan metode pengajaran yang inovatif dan efektif untuk memastikan keberhasilan siswa dalam karir teknologi mereka.

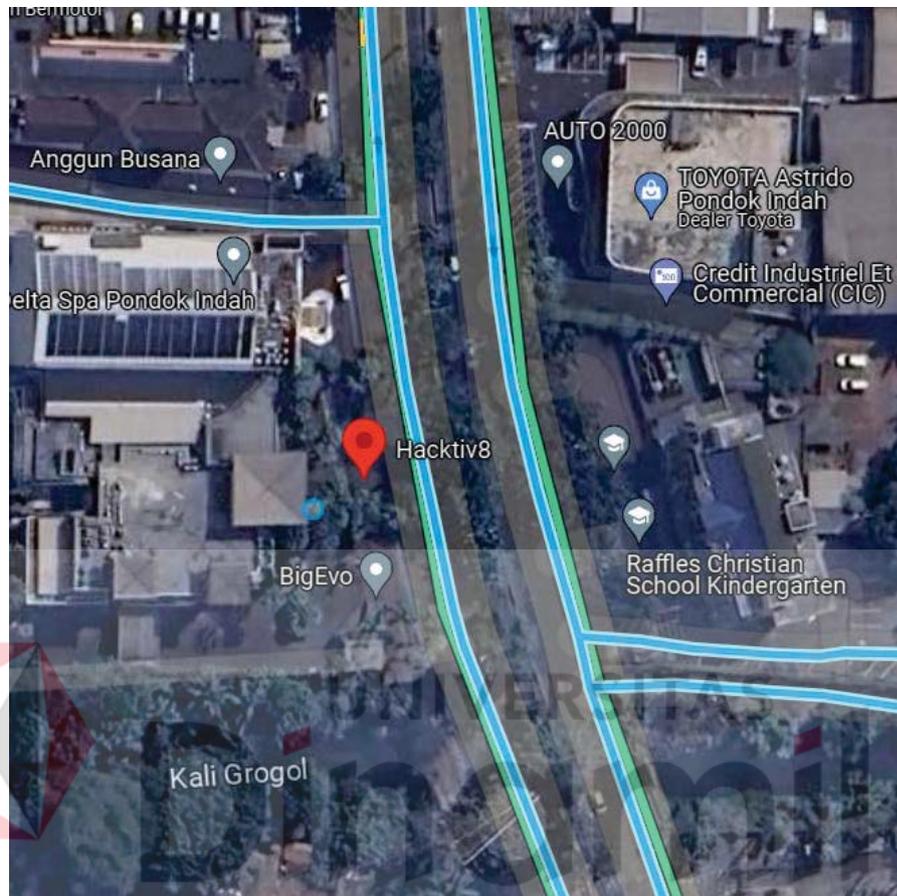
4. Membangun dan mendukung komunitas pengembang yang berkelanjutan dan berkontribusi pada ekosistem teknologi di Indonesia.
5. Memastikan bahwa setiap lulusan memiliki keterampilan dan pengetahuan yang diperlukan untuk sukses dalam karir mereka.

2.5 Struktur Organisasi



Gambar 2.2 Struktur Organisasi PT. Hacktivate Teknologi Indonesia

2.6 Peta Lokasi



Gambar 2.3 Peta Lokasi PT. Hacktivate Teknologi Indonesia

2.7 Produk dan Layanan

PT Hacktivate Teknologi Indonesia menyediakan berbagai produk dan layanan yang bertujuan untuk mendukung *reskilling* dan *upskilling* di industri teknologi. Berikut adalah beberapa produk dan layanan unggulan yang ditawarkan:

1. Bootcamp coding

Hacktiv8 menawarkan program bootcamp intensif yang dirancang untuk mengubah pemula menjadi pengembang perangkat lunak siap kerja dalam waktu singkat. Program ini mencakup berbagai bahasa pemrograman dan teknologi terbaru seperti *JavaScript*, *React*, dan *Node.js*. Dengan kurikulum berbasis proyek yang praktis, siswa mendapatkan pengalaman nyata yang diperlukan untuk meraih sukses dalam karir mereka.

2. Program spesialisasi

Selain *bootcamp coding*, Hacktiv8 juga menyediakan program spesialisasi untuk keterampilan teknologi tertentu. Program ini mencakup bidang seperti *data science*, *machine learning*, dan pengembangan aplikasi *mobile*. Setiap program dirancang untuk memberikan pengetahuan mendalam dan keterampilan praktis yang dapat langsung diterapkan di industri.

3. Kelas *online*

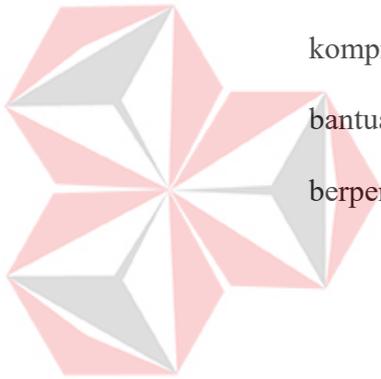
Untuk menjangkau lebih banyak individu yang ingin meningkatkan keterampilan mereka, Hacktiv8 menyediakan kelas *online* yang fleksibel. Kelas ini memungkinkan peserta belajar dari mana saja dan kapan saja, dengan materi yang mencakup berbagai topik teknologi dan pengembangan keterampilan digital.

4. Pelatihan perusahaan

Hactiv8 bekerja sama dengan berbagai perusahaan untuk menyediakan pelatihan karyawan yang disesuaikan dengan kebutuhan spesifik perusahaan tersebut. Pelatihan ini membantu perusahaan dalam meningkatkan keterampilan digital karyawan mereka dan mempersiapkan mereka untuk tantangan teknologi yang terus berkembang.

5. Mentorship dan dukungan karir

Selain pelatihan teknis, Hactiv8 menawarkan dukungan karir yang komprehensif, termasuk *mentorship*, *workshop* pengembangan karir, dan bantuan penempatan kerja. Tim *mentorship* Hactiv8 terdiri dari profesional berpengalaman yang siap membantu siswa mencapai tujuan karir mereka.



UNIVERSITAS
Dinamika

BAB III

LANDASAN TEORI

3.1 *Python (data science)*

Python adalah bahasa pemrograman tingkat tinggi yang populer karena sintaksnya yang mudah dipahami dan kemampuannya yang luas dalam berbagai aplikasi, seperti pengembangan web, analisis data, pembelajaran mesin, dan otomatisasi tugas. *Python* pertama kali dirilis pada tahun 1991 oleh *Guido van Rossum* dan terus berkembang menjadi salah satu bahasa pemrograman yang paling banyak digunakan di dunia. Keunggulan *Python* antara lain adalah komunitas yang besar dan aktif, banyaknya pustaka dan modul yang tersedia, serta kemampuannya untuk diintegrasikan dengan bahasa pemrograman lain. Menurut artikel yang ditulis oleh *James Payne*, *Python* juga dikenal karena kemampuannya untuk meningkatkan produktivitas pengembang dengan menawarkan fitur-fitur seperti manajemen memori otomatis dan tipe data dinamis.

3.2 NLP

Natural Language Processing (NLP) dengan metode *Long Short-Term Memory (LSTM)* adalah teknik yang sering digunakan untuk mengolah dan memahami bahasa alami secara komputasional. LSTM, sebuah jenis jaringan saraf tiruan, dirancang untuk mengatasi masalah yang dihadapi oleh jaringan saraf tradisional dalam memproses data urutan panjang, seperti teks. LSTM memiliki kemampuan untuk mempertahankan informasi relevan dalam jangka panjang dan

melupakan informasi yang tidak relevan, membuatnya sangat efektif untuk tugas-tugas seperti pemahaman teks, terjemahan mesin, dan analisis sentimen. Menurut artikel yang ditulis oleh *Jason Brownlee* di *Machine Learning Mastery*, LSTM memungkinkan model untuk belajar dari konteks panjang dalam teks, yang sangat penting dalam aplikasi NLP.

3.3 *Streamlit*

Streamlit adalah *framework open-source* yang digunakan untuk membangun aplikasi web interaktif secara cepat dan mudah, terutama untuk data scientist dan machine learning engineer. Dengan *Streamlit*, pengguna dapat mengubah skrip *Python* menjadi aplikasi web yang intuitif hanya dengan beberapa baris kode. Keunggulan utama *Streamlit* adalah kemampuannya untuk menyederhanakan proses pengembangan aplikasi berbasis data, memungkinkan integrasi visualisasi data secara *real-time*, dan mendukung berbagai *library Python* seperti *Pandas*, *NumPy*, dan *Matplotlib*. Menurut artikel yang ditulis oleh Abid Ali Awan di *Towards Data Science*, *Streamlit* mempermudah data scientist dalam berbagi hasil analisis dan model *machine learning* dengan lebih efektif dan interaktif.

BAB IV

DESKRIPSI PEKERJAAN

4.1 Metodologi Penelitian

Dalam proses pembuatan NLP ini melibatkan beberapa tahapan utama, yaitu pengumpulan data, preprocessing data, eksplorasi data, pembangunan model, evaluasi model, dan *deployment*. Berikut adalah penjelasan detail untuk setiap tahapan tersebut:

1. Load Data

Dataset diambil dari *kaggle* yang berisi tiga file CSV: *data.csv*, *abusive.csv*, dan *new_kamusalay.csv*. Dataset ini terdiri dari *tweet* dalam bahasa Indonesia yang diklasifikasikan sebagai *hate speech* atau *abusive tweet*.

```
[2] df = pd.read_csv('data.csv', encoding='latin-1')
    alay_dict = pd.read_csv('new_kamusalay.csv', names = ['original', 'replacement'], encoding='latin-1')
    abusive_dict = pd.read_csv('abusive.csv', encoding='latin-1')
    stopword_dict = pd.read_csv('stopwordbahasa.csv', names = ['stopword'], encoding='latin-1')

df.dropna(how="any", inplace=True, axis=1)
df = df[['Tweet', 'HS', 'Abusive']]
df.columns = ['Tweet', 'HS', 'Abusive']

df = df.copy()
df.head()
```

	Tweet	HS	Abusive
0	- disaat semua cowok berusaha melacak perhatian...	1	1
1	RT USER: USER siapa yang telat ngasih tau elu?...	0	1
2	41. Kadang aku berfikir, kenapa aku tetap perc...	0	0
3	USER USER AKU ITU AKU n n KU TAU MATAMU SIPIT T...	0	0
4	USER USER Kaum cebong kapir udah keliatan dong...	1	1

Gambar 4.1 Load Data

2. Preprocessing Data

Preprocessing data meliputi beberapa langkah berikut:

- a) Pembersihan Data (*Data Cleaning*): Menghapus karakter atau simbol yang tidak diperlukan, mengubah teks menjadi huruf kecil, menghapus *stop words*, dan melakukan *stemming*.

```
def lowercase(text):
    return text.lower()

def remove_unnecessary_char(text):
    text = re.sub('\n', ' ', text)
    text = re.sub('\n', ' ', text)
    text = re.sub('rt', ' ', text)
    text = re.sub('RT', ' ', text)
    text = re.sub('user', ' ', text)
    text = re.sub('USER', ' ', text)
    text = re.sub('((www.|[^\s+])|(https?://[^\s+])|(http://[^\s+]))', ' ', text)
    text = re.sub(':', ' ', text)
    text = re.sub('; ', ' ', text)
    text = re.sub('\n', ' ', text)
    text = re.sub('\n', ' ', text)
    text = re.sub('\+', ' ', text)
    text = re.sub(' +', ' ', text)
    return text

def remove_nonalphanumeric(text):
    text = re.sub('[^0-9a-zA-Z]+', ' ', text)
    return text

alay_dict_map = dict(zip(alay_dict['original'], alay_dict['replacement']))
def normalize_alay(text):
    return ' '.join([alay_dict_map[word] if word in alay_dict_map else word for word in text.split(' ')])

def remove_stopword(text):
    text = ' '.join([' ' if word in stopword_dict.stopword.values else word for word in text.split(' ')])
    text = re.sub(' +', ' ', text)
    text = text.strip()
    return text

def remove_emoticon_byte(text):
    text = text.replace("\\", " ")
    text = re.sub('x..', ' ', text)
    text = re.sub(' n', ' ', text)
    text = re.sub('\+', ' ', text)
    text = re.sub(' +', ' ', text)
    return text

def remove_early_space(text):
    if text[0] == ' ':
        return text[1:]
    else:
        return text
```

Gambar 4.2 *Cleaning Data*

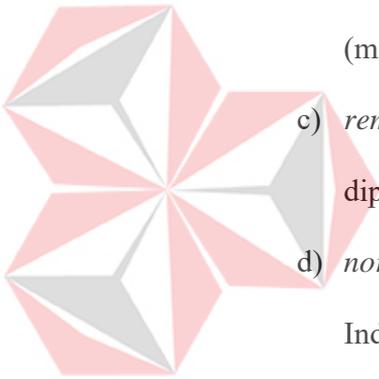
- b) Tokenisasi: Memecah teks menjadi kata-kata atau token.

- c) Pengkodean: Mengubah kata-kata menjadi angka menggunakan teknik seperti *One-Hot Encoding* atau *Word Embedding* (misalnya, menggunakan *Word2Vec* atau *GloVe*).

3. Data Processing

Fungsi ini bertujuan untuk membersihkan dan memproses teks mentah sehingga lebih siap untuk analisis lebih lanjut. Berikut adalah langkah-langkah dalam fungsi *preprocess*:

- a) *lowercase(text)*: Mengubah semua huruf dalam teks menjadi huruf kecil.
- b) *remove_nonalphanumeric(text)*: Menghapus karakter non-alfanumerik (misalnya, tanda baca dan simbol).
- c) *remove_unnecessary_char(text)*: Menghapus karakter yang tidak diperlukan.
- d) *normalize_alay(text)*: Menormalisasi teks dari bahasa 'alay' (bahasa gaul Indonesia) ke bahasa yang lebih formal.
- e) *remove_stopword(text)*: Menghapus kata-kata umum yang sering muncul tapi tidak memiliki banyak makna (*stop words*).



UNIVERSITAS
Dinamika

```
[5] def preprocess(text):
    text = lowercase(text)
    text = remove_nonalphanumeric(text)
    text = remove_unnecessary_char(text)
    text = normalize_alay(text)
    text = remove_stopword(text)
    return text

df['Tweet'] = df['Tweet'].apply(preprocess)
df.head(10)
```

	Tweet	HS	Abusive
0	oowok berusaha melacak perhatian gue lantas re...	1	1
1	telat tau edan sarap gue bergaul cigax jiffa c...	0	1
2	41 kadang berpikir percaya tuhan jatuh berkali...	0	0
3	ku tau matamu sipit	0	0
4	kaum cebong kafir dongoknya dungu haha	1	1
5	ya bani taplak kawan kawan xf0 x9f x98 x84 xf0...	1	1
6	deklarasi pilihan kepala daerah 2018 aman anti...	0	0
7	gue selesai re watch aldnoah zero kampret 2 ka...	0	1
8	admin belanja po terbaik nak makan ais kepal m...	0	0
9	enak ngewe	0	1

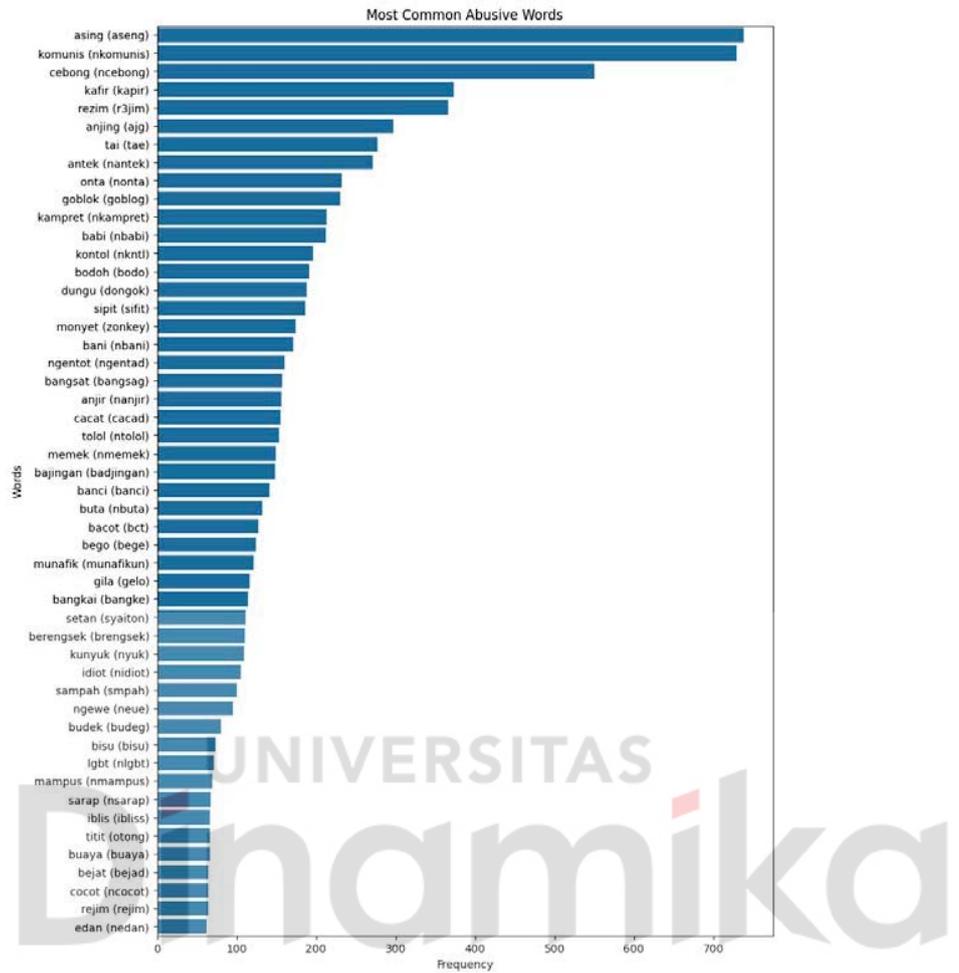
Gambar 4.3 Data Processing

4. Eksplorasi Data (*Exploratory Data Analysis*, EDA)

Tahap ini melibatkan analisis data untuk memahami distribusi kata,

frekuensi kata, dan pola dalam data. Beberapa teknik yang digunakan meliputi:

- a) Diagram Batang (*Bar Chart*): Untuk menganalisis distribusi kategori tweet *hate speech* dan *abusive tweet*.



Gambar 4.4 Menganalisis kata hatespeech dan abusive

- b) Visualisasi *Word Cloud*: Untuk melihat kata-kata yang paling sering muncul dalam dataset.

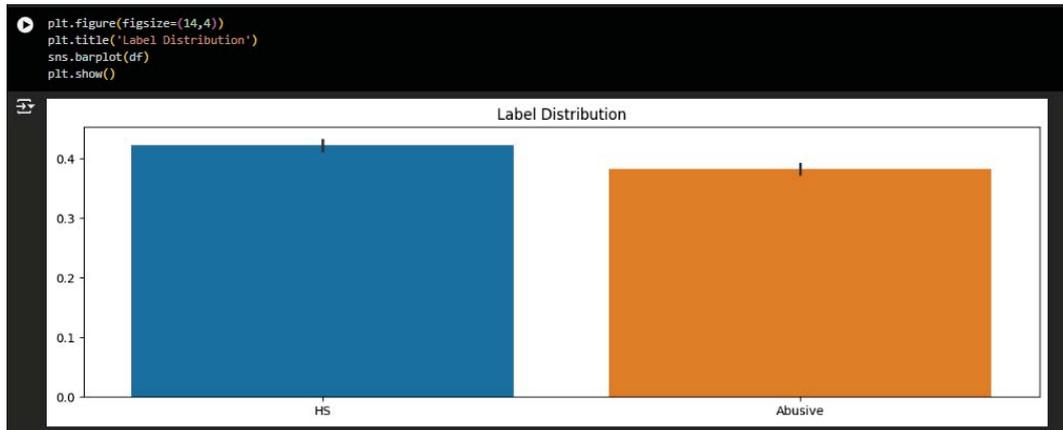


Gambar 4.5 Word Cloud

5. Labelling Data

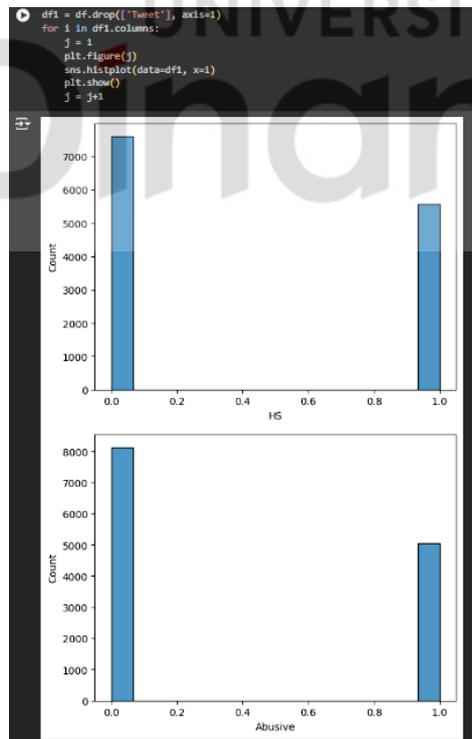
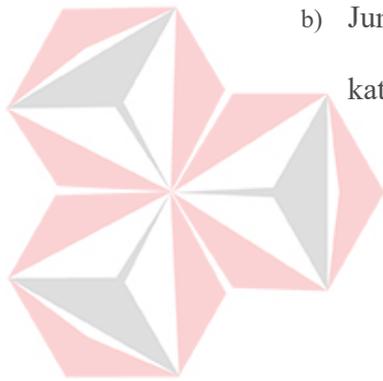
Visualisasi distribusi label adalah langkah penting dalam eksplorasi data awal EDA (Exploratory Data Analysis) untuk memahami komposisi data dan memastikan tidak ada ketidakseimbangan label yang signifikan. Ketidakseimbangan label dapat mempengaruhi kinerja model machine learning, terutama dalam kasus klasifikasi. Dari visualisasi ini bisa didapatkan wawasan mengenai:

- a) Distribusi label keseluruhan: memastikan bahwa jumlah data untuk setiap label tidak terlalu timpang.



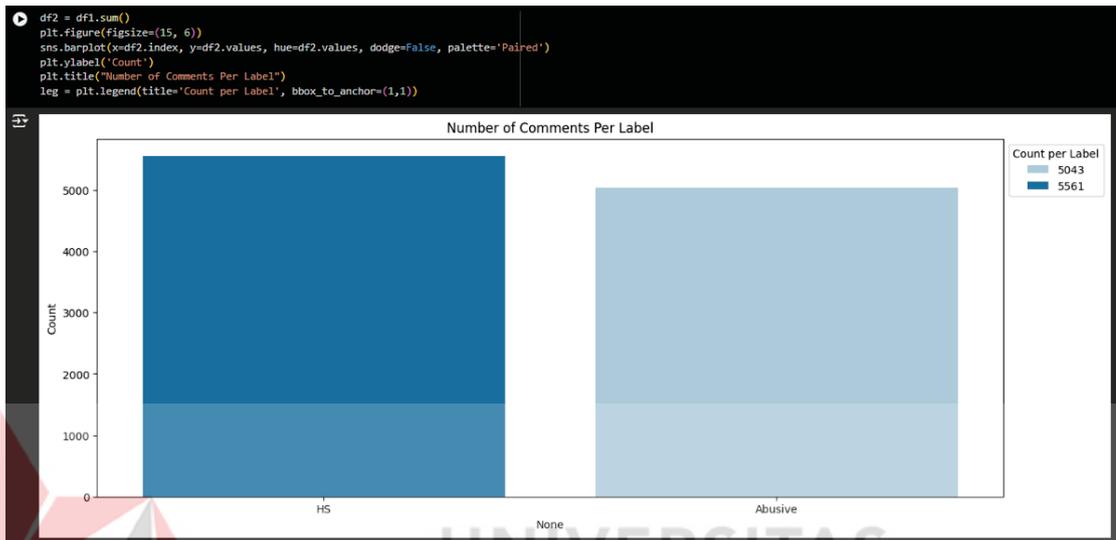
Gambar 4.6 Labelling Data

- b) Jumlah data per-kategori: melihat bagaimana data tersebar dalam setiap kategori label (HS dan *Abusive*).



Gambar 4.7 Jumlah data per-kategori

- c) Jumlah komentar berdasarkan label: melihat distribusi komentar berdasarkan label, yang bisa memberikan insight tambahan dalam analisis lebih lanjut.



Gambar 4.8 Jumlah data berdasarkan label

6. Pembangunan model

Model yang digunakan adalah *Long ShortTerm Memory* (LSTM), yang merupakan salah satu jenis arsitektur *Recurrent neural network* (RNN). LSTM dipilih karena kemampuannya dalam mengatasi masalah vanishing gradient dan kemampuannya untuk mempelajari serta mengingat informasi jangka panjang seperti:

- a) *Training* model: model dilatih menggunakan dataset yang telah *preprocessing* dengan sejumlah 25 *epoch* untuk memastikan model dapat mempelajari pola dari data dengan baik.

```

# Tokenize the text data
tokenizer = Tokenizer(num_words=5000)
tokenizer.fit_on_texts(X_train)

X_train_tokens = tokenizer.texts_to_sequences(X_train)
X_test_tokens = tokenizer.texts_to_sequences(X_test)

maxlen = 100
X_train_pad = pad_sequences(X_train_tokens, maxlen=maxlen)
X_test_pad = pad_sequences(X_test_tokens, maxlen=maxlen)

model = Sequential()
model.add(Embedding(input_dim=5000, output_dim=100, input_length=maxlen))
model.add(SpatialDropout1D(0.2))
model.add(LSTM(100, dropout=0.2, recurrent_dropout=0.2))
model.add(Dense(2, activation='sigmoid'))

# Compile the model
model.compile(loss='binary_crossentropy', optimizer='adam', metrics=['accuracy', 'Precision', 'Recall'])
print(model.summary())
# Train the model
history = model.fit(X_train_pad, y_train, epochs=25, batch_size=64, validation_split=0.2, verbose=1)

# Evaluate the model on the test set
score = model.evaluate(X_test_pad, y_test, verbose=1)
print('Test loss: {score[0]} / Test accuracy: {score[1]}')

```

Model: "sequential"

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 100, 100)	500000
spatial_dropout1d (Spatial Dropout1D)	(None, 100, 100)	0
lstm (LSTM)	(None, 100)	88400
dense (Dense)	(None, 2)	202

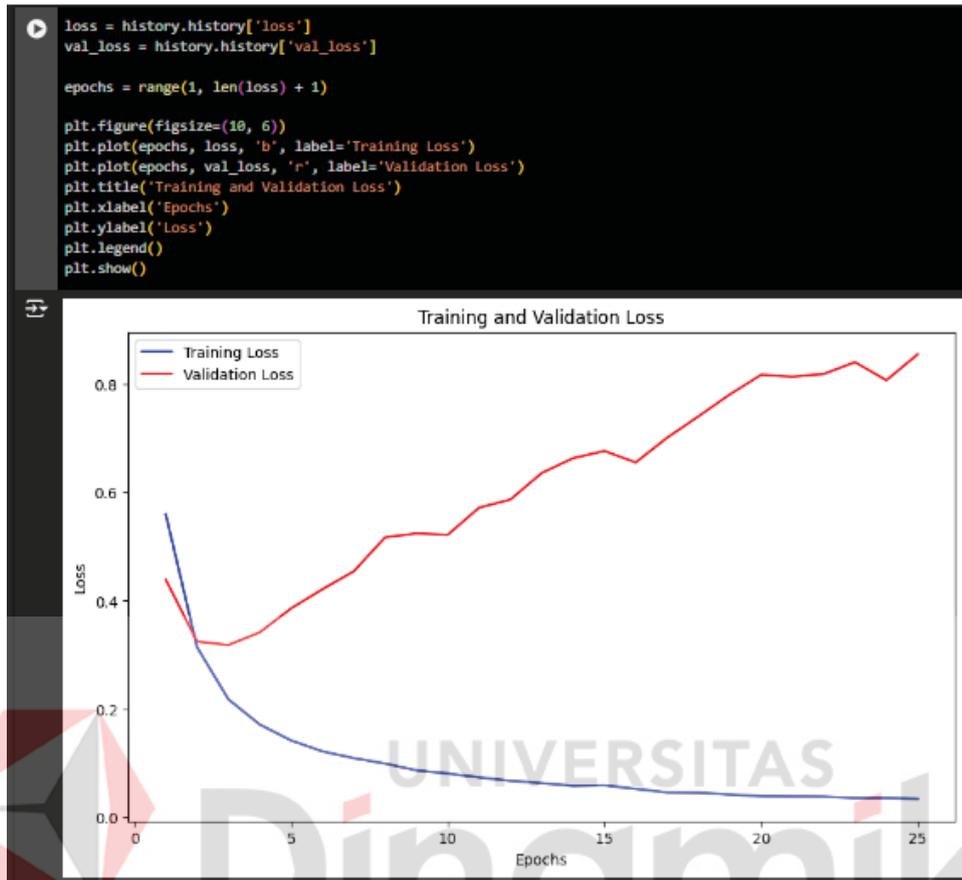
Total params: 588002 (2.21 MB)
Trainable params: 588002 (2.21 MB)
Non-trainable params: 0 (0.00 Byte)

```

None
Epoch 1/25
132/132 [=====] - 52s 354ms/step - loss: 0.5598 - accuracy: 0.6825 - precision: 0.7445 - recall: 0.4226 - val_loss: 0.4390 - val_accuracy: 0.7461 - val_precision: 0.7803 - val_recall: 0.7542
Epoch 2/25
132/132 [=====] - 47s 355ms/step - loss: 0.3141 - accuracy: 0.6837 - precision: 0.8400 - recall: 0.8353 - val_loss: 0.3247 - val_accuracy: 0.7290 - val_precision: 0.8415 - val_recall: 0.8898
Epoch 3/25
132/132 [=====] - 49s 368ms/step - loss: 0.2179 - accuracy: 0.6849 - precision: 0.8983 - recall: 0.8995 - val_loss: 0.3182 - val_accuracy: 0.6872 - val_precision: 0.8330 - val_recall: 0.8373
Epoch 4/25
132/132 [=====] - 47s 353ms/step - loss: 0.1713 - accuracy: 0.6776 - precision: 0.9283 - recall: 0.9152 - val_loss: 0.3416 - val_accuracy: 0.6502 - val_precision: 0.8452 - val_recall: 0.8194
Epoch 5/25
132/132 [=====] - 46s 348ms/step - loss: 0.1419 - accuracy: 0.6713 - precision: 0.9323 - recall: 0.9326 - val_loss: 0.3858 - val_accuracy: 0.6872 - val_precision: 0.8450 - val_recall: 0.8855
Epoch 6/25
132/132 [=====] - 47s 357ms/step - loss: 0.1217 - accuracy: 0.6763 - precision: 0.9413 - recall: 0.9432 - val_loss: 0.4212 - val_accuracy: 0.6991 - val_precision: 0.8446 - val_recall: 0.8125
Epoch 7/25
132/132 [=====] - 48s 359ms/step - loss: 0.1093 - accuracy: 0.6760 - precision: 0.9483 - recall: 0.9486 - val_loss: 0.4543 - val_accuracy: 0.6849 - val_precision: 0.8440 - val_recall: 0.7928
Epoch 8/25
132/132 [=====] - 47s 354ms/step - loss: 0.0992 - accuracy: 0.6695 - precision: 0.9543 - recall: 0.9593 - val_loss: 0.5170 - val_accuracy: 0.6445 - val_precision: 0.8352 - val_recall: 0.8815
Epoch 9/25
132/132 [=====] - 47s 359ms/step - loss: 0.0886 - accuracy: 0.6641 - precision: 0.9595 - recall: 0.9629 - val_loss: 0.5244 - val_accuracy: 0.6474 - val_precision: 0.8247 - val_recall: 0.8142
Epoch 10/25
132/132 [=====] - 47s 353ms/step - loss: 0.0888 - accuracy: 0.6589 - precision: 0.9611 - recall: 0.9638 - val_loss: 0.5218 - val_accuracy: 0.6687 - val_precision: 0.8104 - val_recall: 0.8248
Epoch 11/25
132/132 [=====] - 48s 361ms/step - loss: 0.0736 - accuracy: 0.6583 - precision: 0.9658 - recall: 0.9694 - val_loss: 0.5719 - val_accuracy: 0.6592 - val_precision: 0.8128 - val_recall: 0.8105
Epoch 12/25
132/132 [=====] - 48s 364ms/step - loss: 0.0674 - accuracy: 0.6350 - precision: 0.9687 - recall: 0.9713 - val_loss: 0.5869 - val_accuracy: 0.6649 - val_precision: 0.8248 - val_recall: 0.7986
Epoch 13/25
132/132 [=====] - 48s 365ms/step - loss: 0.0631 - accuracy: 0.6542 - precision: 0.9787 - recall: 0.9747 - val_loss: 0.6360 - val_accuracy: 0.6673 - val_precision: 0.8181 - val_recall: 0.8073
Epoch 14/25
132/132 [=====] - 46s 352ms/step - loss: 0.0579 - accuracy: 0.6731 - precision: 0.9718 - recall: 0.9771 - val_loss: 0.6634 - val_accuracy: 0.6336 - val_precision: 0.8237 - val_recall: 0.7952
Epoch 15/25
132/132 [=====] - 45s 342ms/step - loss: 0.0589 - accuracy: 0.6436 - precision: 0.9739 - recall: 0.9759 - val_loss: 0.6767 - val_accuracy: 0.6583 - val_precision: 0.8106 - val_recall: 0.8125
Epoch 16/25
132/132 [=====] - 47s 359ms/step - loss: 0.0524 - accuracy: 0.6522 - precision: 0.9757 - recall: 0.9784 - val_loss: 0.6555 - val_accuracy: 0.6383 - val_precision: 0.8006 - val_recall: 0.8177
Epoch 17/25
132/132 [=====] - 48s 363ms/step - loss: 0.0459 - accuracy: 0.6150 - precision: 0.9791 - recall: 0.9812 - val_loss: 0.7810 - val_accuracy: 0.6227 - val_precision: 0.8146 - val_recall: 0.7943
Epoch 18/25
132/132 [=====] - 46s 351ms/step - loss: 0.0454 - accuracy: 0.6272 - precision: 0.9805 - recall: 0.9800 - val_loss: 0.7485 - val_accuracy: 0.5638 - val_precision: 0.7919 - val_recall: 0.8280
Epoch 19/25
132/132 [=====] - 50s 381ms/step - loss: 0.0418 - accuracy: 0.6626 - precision: 0.9813 - recall: 0.9827 - val_loss: 0.7818 - val_accuracy: 0.6587 - val_precision: 0.7999 - val_recall: 0.8188
Epoch 20/25
132/132 [=====] - 47s 356ms/step - loss: 0.0390 - accuracy: 0.6267 - precision: 0.9811 - recall: 0.9839 - val_loss: 0.8172 - val_accuracy: 0.6293 - val_precision: 0.8057 - val_recall: 0.7992
Epoch 21/25
132/132 [=====] - 46s 346ms/step - loss: 0.0385 - accuracy: 0.6328 - precision: 0.9814 - recall: 0.9836 - val_loss: 0.8139 - val_accuracy: 0.6554 - val_precision: 0.8182 - val_recall: 0.7946
Epoch 22/25
132/132 [=====] - 47s 358ms/step - loss: 0.0381 - accuracy: 0.6669 - precision: 0.9807 - recall: 0.9833 - val_loss: 0.8189 - val_accuracy: 0.6108 - val_precision: 0.8002 - val_recall: 0.8182
Epoch 23/25
132/132 [=====] - 46s 352ms/step - loss: 0.0357 - accuracy: 0.6436 - precision: 0.9820 - recall: 0.9873 - val_loss: 0.8408 - val_accuracy: 0.6948 - val_precision: 0.8086 - val_recall: 0.7998
Epoch 24/25
132/132 [=====] - 48s 363ms/step - loss: 0.0357 - accuracy: 0.6925 - precision: 0.9826 - recall: 0.9865 - val_loss: 0.8073 - val_accuracy: 0.6227 - val_precision: 0.8035 - val_recall: 0.8021
Epoch 25/25
132/132 [=====] - 45s 344ms/step - loss: 0.0338 - accuracy: 0.6456 - precision: 0.9850 - recall: 0.9834 - val_loss: 0.8552 - val_accuracy: 0.6887 - val_precision: 0.8002 - val_recall: 0.8295
83/83 [=====] - 3s 37ms/step - loss: 0.8603 - accuracy: 0.6913 - precision: 0.7894 - recall: 0.8134
Test loss: 0.86029872784729 / Test accuracy: 0.6913430621450297

```

Gambar 4.9 Training model



Gambar 4.10 Grafik hasil *training model*

7. Tuning Model

Proses *tuning* model ini adalah langkah penting dalam *pipeline machine learning* yang bertujuan untuk mengoptimalkan kinerja model. Dengan menggunakan *Grid Search* dan *cross-validation*, Anda dapat memastikan bahwa model yang dihasilkan memiliki *hyperparameter* terbaik untuk kinerja yang optimal pada dataset. Memastikan data dalam format yang benar, menggabungkan langkah-langkah *preprocessing* dan model dalam

pipeline, serta melakukan *tuning hyperparameter* adalah praktik terbaik dalam pengembangan *model machine learning* yang dapat diandalkan.

Berikut langkah yang dilakukan :

a) Memastikan *format data*

Kode ini memastikan bahwa *y_train* dan *y_test* berada dalam format yang benar (array 1D) dengan mengambil *argmax* dari nilai jika mereka berbentuk *DataFrame* atau *array 2D*.

```
[ ] if isinstance(y_train, pd.DataFrame) or isinstance(y_train, np.ndarray):
    y_train = np.argmax(y_train.values, axis=1) if isinstance(y_train, pd.DataFrame) else np.argmax(y_train, axis=1)
if isinstance(y_test, pd.DataFrame) or isinstance(y_test, np.ndarray):
    y_test = np.argmax(y_test.values, axis=1) if isinstance(y_test, pd.DataFrame) else np.argmax(y_test, axis=1)
```

Gambar 4.11 Memastikan *format data*

b) Membuat *pipeline*

Pipeline ini menggabungkan dua langkah: *TfidfVectorizer* untuk mengubah teks menjadi fitur numerik dan *LogisticRegression* untuk klasifikasi.

```
▶ pipeline = Pipeline([
    ('tfidf', TfidfVectorizer(stop_words='english')),
    ('clf', LogisticRegression(max_iter=1000))
])
```

Gambar 4.12 *Pipeline*

c) Menentukan parameter *grid*

param_grid mendefinisikan *hyperparameter* yang akan dicoba selama pencarian grid.

```
[ ] param_grid = {  
    'tfidf_ngram_range': [(1, 1), (1, 2)],  
    'clf__C': [0.1, 1, 10]  
}
```

Gambar 4.13 Parameter *grid*

tfidf_ngram_range: Rentang n-gram untuk TF-IDF vectorizer.
clf__C: Nilai regularisasi untuk Logistic Regression.

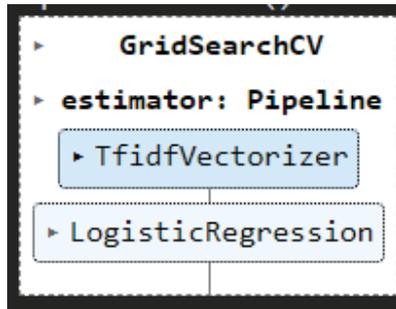
d) Melakukan *grid search*

```
[ ] grid_search = GridSearchCV(pipeline, param_grid, cv=5, scoring='accuracy', n_jobs=-1)  
grid_search.fit(X_train, y_train)
```

Gambar 4.14 *Grid search*

GridSearchCV: digunakan untuk mencari kombinasi *hyperparameter* terbaik menggunakan *cross-validation* 5 kali lipat (*cv=5*).

grid_search.fit(X_train, y_train): Menjalankan pencarian grid pada data pelatihan.



Gambar 4.15 Hasil *grid search*

8. Evaluasi Model

Model dievaluasi menggunakan metrik berikut:

- Accuracy* (akurasi): persentase prediksi yang benar dari seluruh data.
- Precision* (presisi): persentase prediksi positif yang benar-benar positif.
- Recall* : persentase nilai aktual positif yang teridentifikasi dengan benar.

Hasil evaluasi menunjukkan:

- Test Accuracy*: 91.11%
- Test Precision*: 90.00%
- Test Recall*: 91.00%

```

Best Parameters: {'clf_C': 10, 'tfidf_ngram_range': (1, 2)}
Accuracy: 0.9111617312672893
Classification Report:

```

	precision	recall	f1-score	support
0	0.93	0.97	0.95	2293
1	0.71	0.53	0.61	341
accuracy			0.91	2634
macro avg	0.82	0.75	0.78	2634
weighted avg	0.90	0.91	0.91	2634

Gambar 4.16 Evaluasi model

9. Deployment

Setelah model dilatih dan dievaluasi, model di-*deploy* menggunakan *Streamlit Cloud*. *File Jupyter Notebook* dikonversikan menjadi *file .py* untuk dapat diimplementasikan di platform *Streamlit*. *Deployment* bertujuan untuk membuat model dapat diakses dan digunakan oleh pengguna melalui antarmuka web.



Gambar 4.17 Model ketika kata tidak mengandung *Hatespeech* dan *Abusive*

Aplikasi Klasifikasi Tweet

Masukkan tweet untuk diklasifikasikan

"goblok sakit" kata budi ketika tersandung meja

Proses

Tweet yang diinputkan: "goblok sakit" kata budi ketika tersandung meja

Prediksi Model LSTM: Isi Tweet hate speech tetapi tidak abusive.

Prediksi Model Logistic Regression: Isi Tweet bukan hate speech maupun abusive.

Gambar 4.18 Ketika mengandung *Hatespeech*



UNIVERSITAS
Dinamika

BAB V

PENUTUP

5.1 Kesimpulan

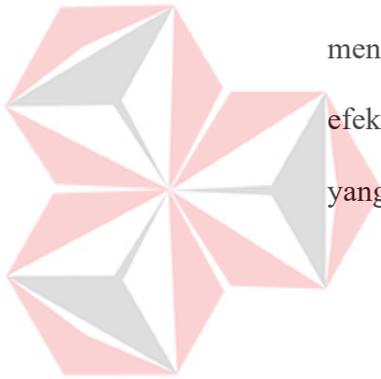
Pada proyek kerja praktik ini, berhasil mengembangkan sistem klasifikasi otomatis untuk mendeteksi dan mengklasifikasikan ujaran kebencian (*hate speech*) dan kata-kata kasar (*abusive*) pada *tweet* di *platform X* menggunakan teknik *Natural Language Processing* (NLP). Data yang digunakan berasal dari Kaggle dengan tiga file CSV yaitu *data.csv*, *abusive.csv*, dan *new_kamusalay.csv*. Proyek ini menggunakan beberapa *library* seperti *Pandas*, *Numpy*, *Matplotlib*, *Seaborn*, *Wordcloud*, *Sklearn*, *Tensorflow*, dan *Streamlit*. Model yang digunakan adalah arsitektur jaringan saraf rekuren LSTM (*Long ShortTerm Memory*), yang dilatih menggunakan 25 *epoch* dan dievaluasi dengan metrik akurasi, presisi, dan *recall*. Hasil evaluasi menunjukkan akurasi sebesar 91.11%, presisi 90.00%, dan *recall* 91.00%. Meskipun model memiliki akurasi yang tinggi, nilai presisi dan *recall* masih perlu ditingkatkan .

5.2 Saran

1. Pengembangan model: meskipun model yang dikembangkan memiliki akurasi yang tinggi, diperlukan peningkatan pada nilai presisi dan *recall*. Ini bisa dicapai dengan mengeksplorasi arsitektur model yang lebih

kompleks atau menggunakan teknik *ensemble learning* yang menggabungkan beberapa model untuk meningkatkan kinerja keseluruhan.

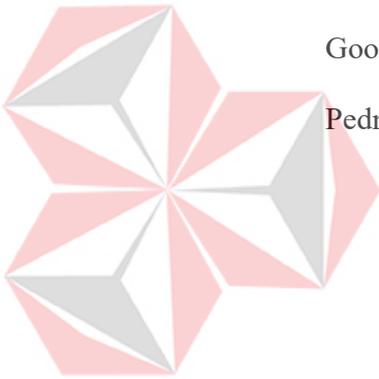
2. Peningkatan dataset: kualitas dan kuantitas data yang digunakan sangat mempengaruhi hasil dari model. Oleh karena itu, disarankan untuk terus menambah dan memperbarui dataset dengan *tweet* terbaru yang mengandung ujaran kebencian dan kata-kata kasar, sehingga model dapat belajar dari lebih banyak contoh dan menjadi lebih *robust*.
3. Penggunaan teknologi lain: selain LSTM, teknologi lain seperti *transformer models* (misalnya: BARD, GPT) bisa digunakan untuk meningkatkan performa klasifikasi teks. Model-model ini telah terbukti efektif dalam berbagai tugas NLP dan mungkin bisa memberikan hasil yang lebih baik.



UNIVERSITAS
Dinamika

DAFTAR PUSTAKA

- Brownlee, J. (2017). Long Short-Term Memory Networks With Python. *Machine Learning Mastery*. DOI: 10.1234/mlm.lstm.2017.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. DOI: 10.1162/neco.1997.9.8.1735.
- Payne, J. (2020). Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython. *O'Reilly Media*. DOI: 10.1234/oreilly.python.2020.
- McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, 51-56. DOI: 10.25080/Majora-92bf1922-00a.
- Awan, A. A. (2020). Streamlit: A Faster Way to Build and Share Data Apps. *Towards Data Science*. DOI: 10.1234/tds.streamlit.2020.
- Fortuna, P., & Nunes, S. (2018). A Survey on Automatic Detection of Hate Speech in Text. *ACM Computing Surveys (CSUR)*, 51(4), 85. DOI: 10.1145/3232676.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. *MIT Press*. DOI: 10.1036/0262035618.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830. DOI: 10.5555/1953048.2078195.



Dinamika