

Klasifikasi Cyberbullying Pada Media Sosial Dengan Menggunakan Metode Recurrent Neural Network Dan Long Short Term Memory

Khusnul Chuluq¹, Salamun Rohman Nudin²

^{1,2} Jurusan Teknik Informatika Fakultas Teknik Universitas Negeri Surabaya

UNESA Kampus Ketintang Surabaya

1khusnul.20117@mhs.unesa.ac.id

2salamunrohman@unesa.ac.id

Abstrak — Pesatnya Kemajuan media sosial dan teknologi komunikasi berbasis online sangat memberikan dampak yang signifikan pada pola interaksi dan komunikasi antar individu satu dengan individu yang lain. Cyberbullying sangat sukar untuk dilacak dan telah menjadi bahasan studi yang sering diteliti akhir-akhir ini. Beberapa studi yang memiliki kaitan dengan Twitter untuk melacak user media sosial yang mendapat ancaman Cyberbullying. Salah satu studi Cyberbullying via media sosial Twitter mengikhtisarkan bahwa terdapat hubungan antara user Twitter terhadap apa yang mereka ketik di media sosial mengilustrasikan Cyberbullying. Tujuan dari penelitian ini yaitu untuk pengembangan dan pengoptimalan dari penelitian sebelumnya dengan mengadaptasi metode yang berbeda yakni Recurrent Neural Network dan Long Short Term Memory, dan Pengklasifikasian Cyberbullying pada data tweet berbahasa Indonesia. Dataset yang digunakan berjumlah 13.169 baris tweet, dataset tersebut telah dilakukan pelebaran data, proses preprocessing dilakukan pada dataset sebelum dataset tersebut diolah pada proses training. Hasil dari penelitian dengan menggunakan metode Recurrent Neural Network dan Long Short Term Memory mendapatkan nilai F1-score sebesar 94%, nilai presisi sebesar 93%, recall sebesar 94% dan akurasi sebesar 94%. Klasifikasi Cyberbullying diharapkan mampu memberikan bantuan bagi peneliti lain untuk tujuan Analisa banyaknya depresi di masyarakat pengguna media sosial.

Kata Kunci - Pengguna Twitter, Media Sosial, Cyberbullying, Klasifikasi, Recurrent Neural Network dan Long Short Term Memory.

I. PENDAHULUAN

Pesatnya Kemajuan media sosial dan teknologi komunikasi berbasis online sangat memberikan dampak yang signifikan pada pola interaksi dan komunikasi antar individu satu dengan individu yang lain. Hal ini juga mengakibatkan terjadinya lonjakan cyberbullying yang memberikan ancaman pada kesehatan mental dan kesehatan fisik masing-masing setiap orang. [1].

Cyberbullying merupakan tindakan intimidasi, penghinaan, atau pelecehan yang dilakukan secara daring (online) menggunakan teknologi seperti media sosial, pesan instan, email, atau platform permainan online. Fenomena ini telah menjadi masalah yang semakin serius di seluruh dunia, termasuk di Indonesia. Perilaku Cyberbullying merupakan modifikasi dari perundungan di dunia nyata ke dunia maya atau media sosial. Hal ini timbul dikarenakan dukungan pesatnya teknologi media sosial dapat beroperasi melalui jarak yang jauh dan mudah digunakan. Perilaku cyberbullying

melalui jaringan daring sehingga jejak digital yang ditinggalkan masih tersimpan berupa video, gambar, maupun cuitan atau tulisan yang memiliki dampak besar pada mental korban di kehidupan sosialnya [4].

Di Indonesia, peningkatan pemakaian media sosial yang sangat drastis pada akhir-akhir ini bahkan dalam beberapa tahun terakhir terdapat banyak kasus cyberbullying yang dilaporkan di Indonesia. Menurut survei yang dilakukan oleh lembaga riset We Are Social dan Hootsuite pada tahun 2020, sekitar 93% populasi Indonesia menggunakan media sosial dan platform digital lainnya secara aktif. Cyberbullying dapat terjadi pada siapa saja, termasuk anak-anak, remaja, dan dewasa. Namun, anak-anak dan remaja cenderung menjadi sasaran yang lebih rentan karena kurangnya pengalaman dan kemampuan mereka untuk menghadapi tindakan tersebut. Menurut hasil riset digital civility index pada Mei 2020 oleh Microsoft, menjadikan posisi atas bagi negara paling tidak sopan se-Asia pasifik adalah Indonesia seperti gambar berikut.



Gambar 1. Hasil Riset Digital Civility Index Mei 2020 terhadap perilaku tidak sopan di Indonesia

Sumber : Microsoft (2023)

Berdasarkan penelitian dari Yayasan Kita dan Dunia pada tahun 2019, sekitar 33,3% pelajar di Indonesia mengalami cyberbullying. Tindakan cyberbullying yang sering dilakukan meliputi mengancam, mengolok-olok, dan menyebarkan kabar bohong atau rahasia pribadi. Untuk meminimalisir permasalahan ini, Pemerintah Indonesia telah menetapkan beberapa kebijakan dan undang-undang terkait dengan cyberbullying. Salah satu contohnya adalah Undang-Undang No. 19 Tahun 2016 tentang Perubahan atas Undang-Undang No. 11 Tahun 2008 tentang Informasi dan Transaksi Elektronik (ITE), yang memberikan sanksi pidana bagi pelaku

cyberbullying dan menyediakan mekanisme untuk melaporkan kasus-kasus tersebut. Namun, Usaha untuk meminimalisir cyberbullying bukan hanya dapat dilaksanakan dari pemerintah saja, namun juga dapat dilaksanakan oleh masyarakat luas. Kesadaran dan pendidikan tentang bahaya cyberbullying, serta pentingnya menghormati dan menghargai orang lain di dunia maya, dapat membantu mengurangi insiden-insiden cyberbullying di Indonesia [6].

Pada penelitian sebelumnya yang berjudul [5] "A Hybrid Deep Learning Approach for Cyberbullying Detection in Twitter Social Media Platform". Penelitian ini menggunakan metode RNN dan Dholpin Echolocation Algorithm (DEA) dalam pengklasifikasian dengan dataset komentar dari beberapa situs media sosial Twitter. Penelitian ini bertujuan untuk mengklasifikasikan komentar yang memberikan hasil performa berdasarkan akurasi, daya ingat, presisi, F-measure dan spesifikasi yang terbagi dengan 3 skenario masukan dataset yaitu skenario 1 dengan 60:40%, skenario 2 dengan 70:30% dan scenario 3 dengan 90:10%.

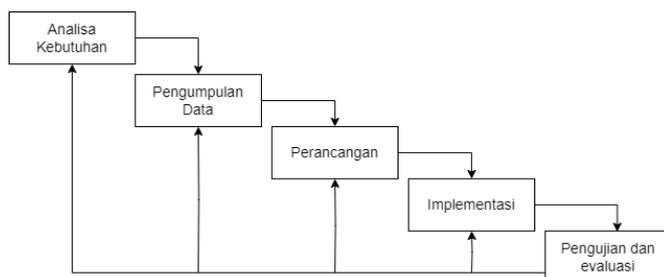
Terdapat juga penelitian dengan judul [2] Automatic Cyberbullying Detection : A Mexican Case in High School and Higher Education Students. Penelitian ini bertujuan untuk mengklasifikasikan performa pada cyberbullying yang dilakukan oleh siswa sekolah menengah dan universitas di meksiko dengan menggunakan metode naïve bayes sebagai model untuk mengidentifikasi akurasi, presisi, sensitivitas dan nilai-F pada dataset yang diambil dari dataset sentiment Twitter.

Selain itu ada juga Early Detection of Cyberbullying on Social Media Network [3]. Penelitian ini memanfaatkan metode Support Vector Machine (SVM) dalam melacak cyberbullying dengan mempertimbangkan tingkat akurasi, presisi, daya ingat dan Nilai-F serta penggunaan dataset dari sosial media Vine.

Maka berdasarkan pada masalah yang diuraikan diatas dan dibuatlah suatu judul untuk penulisan skripsi ini adalah "Klasifikasi Cyberbullying pada Media Sosial Menggunakan Metode Recurrent Neural Network dan Long Short Term Memory".

II. METODOLOGI PENELITIAN

Dalam merancang sebuah penelitian harus ada susunan dari alur penelitian yang jelas tahapan-tahapannya. Penyusunan alur penelitian ini menjadikan langkah awal dilakukannya proses penyelesaian masalah atau penyusunan dari gagasan-gagasan yang dirangkum secara struktural, padat, teratur, logis dan sistematis dan model metode yang digunakan dalam penelitian ini adalah Recurrent Neural Network dan Long Short Term Memory. Berikut ini tahapan flowchart alur penelitian yang digunakan:



Gambar 2. Hasil Diagram alur penelitian

Berdasarkan Gambar 2 Diagram alur penelitian, dapat diketahui tahapan-tahapan yang akan diterapkan pada penelitian, yaitu :

A. Studi Literatur

Tahapan awal untuk Tahapan awal untuk melakukan penelitian adalah studi literatur. Dimana peneliti akan mengumpulkan data dengan melakukan penghimpunan paper, buku, artikel, literatur, jurnal, sumber dari internet yang berkesinambungan dengan pembahasan penulisan yang memiliki kecocokan topik terkait klasifikasi menggunakan metode Recurrent Neural Network dan Long Short Term Memory.

B. Analisa Kebutuhan

Tahapan ini yaitu menganalisa kebutuhan untuk menentukankomponen-komponen yang dibutuhkan dalam Kalsifikasi menggunakan metode Recurrent Neural Network dan Long Short Term Memory. Pada penelitian klasifikasi ini dibutuhkan sebuah sistem yang dapat mendukung agar pelaksanaan penelitian klasifikasi ini berjalan dengan lancar. Adapun kebutuhan yang digunakan dalam sistem dalah sebagai berikut :

1. Spesifikasi Perangkat Keras (Hardware)

Penelitian membutuhkan laptop sebagai perangkat keras yang digunakan dengan memiliki uraian sebagai berikut :

- a) Type Laptop : Ideapad Slim 3
- b) Processor : Intel Core i3-1215U
4,4Ghz 6 Core 8 Threads
- c) RAM : 16 GigaByte.
- d) System Type : OS 64bit.

2. Spesifikasi Perangkat Lunak (Software)

Perangkat Lunak (Software) yang digunakan untuk penelitian ini adalah sebagai berikut :

- a) Ubuntu 22.04 LTS
Merupakan system operasi yang digunakan pada Laptop Lenovo Ideapad Slim 3.
- b) Google Chrome
Mesin yang digunakan sebagai peramban web sumber terbuka.
- c) Google Colab
Layanan berbasis awan yang tidak perlu instalasi atau pengunduhan khusus di komputer untuk *scrapping* data berupa tweet yang memiliki *keyword* yang telah ditentukan sebelumnya.
- d) Microsoft Exel
Digunakan untuk menyaring dan mengkalsifikasikan data tweet yang telah diolah dari Google Colab.
- e) Python
Adalah bahasa pemrograman yang digunakan dalam pembuatan dan merancang program.
- f) Laravel
Adalah Kerangka Kerja yang digunakan dalam membuat sistem.

C. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah Ujaran Kasar dan Kebencian Bahasa Indonesia dari Kaggle dengan jumlah 13.169 tweet. Datanya adalah dibagi menjadi dua kelas yaitu cyberbullying dan tidak cyberbullying. Teknik oversampling digunakan untuk mengatasi beberapa masalah-masalah data informasi yang tidak selaras. Hal ini dilakukan karena jumlah data yang diberi label sebelum oversampling berbeda-beda hampir 50%. Hal ini memerlukan teknik pengambilan Oversampling untuk meningkatkan data berlabel yang cyberbullying. Selain itu, diharapkan dapat meningkatkan kinerja sistem

D. Perancangan Sistem

1. Alur Proses Sistem

Tahapan Tahapan analisis dengan metode Klasifikasi Recurrent Neural Network dan Long Short Term Memory diawali dengan memasukkan informasi data yang di konversi menjadi data train dan data test yang selanjutnya dilanjutkan dengan proses pre-processing sampai klasifikasi.

Gambar 3. Alur Proses Sistem

Gambar diatas menunjukkan penelitian ini dilakukan dalam beberapa tahapan proses. Berikut merupakan penggambaran dari masing-masing tahapan yang dilakukan :

- a) Pengolahan Dataset
 Pengolahan dataset berdasarkan data yang berisi tweet Ujaran Kasar dan Kebencian Bahasa Indonesia dari Kaggle dengan jumlah 13.169 tweet yang telah memiliki penanda (labelling) masing-masing kalimat pada data yang telah di olah di dalam excel.
- b) Pre-processing
 Data latih dan data uji yang telah di inputkan dari pengolahan dataset sebelumnya kemudian diproses oleh sistem untuk dilakukannya proses Case Folding. Tahapan selanjutnya setelah Case Folding adalah Tokenizing untuk menghapus angka dan tanda baca yang tidak perlu, dan whitespace. Setelah tahap tokenizing, maka dilakukan tahap Stopwords yaitu dengan membersihkan kata-kata yang bersifat general. Kemudian dilakukan Stemming untuk mengembalikan ke dalam kata dasar.
- c) Pelabelan Kata
 Selanjutnya pada tahap ini ada pelabelan kata, pelabelan kata dilakukan untuk memberikan label pada teks ke dalam kategori atau kelas tertentu berdasarkan model klasifikasi yang telah dilatih.

- d) Penerapan Klasifikasi Metode Recurrent Neural Network dan Long Short Term Memory
 Langkah selanjutnya adalah masuk ke tahap klasifikasi metode Recurrent Neural Network dan Long Short Term Memory yang akan memberikan nilai bobot pada proses data dalam memastikan keakuratan data train yang sudah dimasukkan.
- e) Proses Penginputan Pengujian Data Uji

2. Proses Dataset

Dataset berupa tweet berbahasa Indonesia yang diambil dari Kaggle. Dataset dari Kaggle ini akan dibagi menjadi dua bagian yaitu data latih dan data uji. Data latih dan data uji diklasifikasikan menggunakan Recurrent Neural Network dan Long Short Term Memory dengan label 0 dan 1 menyesuaikan klasifikasi tiap tweet. Sebaliknya data test yang dilakukan proses pemilahan secara manual dilabeli angka 0 dan 1 menyesuaikan klasifikasi. Data test selanjutnya akan dilakukan proses evaluasi untuk memastikan akurasi pada data di dalam system. Scraping dat train dan data test dilakukan pada scraping dengan Waktu yang tidak bersamaan. Berikut sampel data tweet yang diambil dari Kaggle :

Tabel 1. Sampel Dataset yang diambil dari Kaggle

No.	DATA TWEET
1	BAJINGAN HOMO!!!\nHATI2 TERHADAP ANAK2 KITA TERUTAMA DI KAMAR MANDI LAKI2, JGN BIARKAN SENDIRI!
2	USER X LO NGOMONG AJA KAGA BENER BANGKE'
3	MEMANG ANAK ANJING KAMPANG'

Data tweet pada tabel 4 telah dilakukan labelling untuk menentukan Kategori Klasifikasi yang akan menjadi dasar kategori data tweet yang berpotensi mengandung unsur cyberbullying. Dalam hal ini adalah untuk memperoleh informasi kategori klasifikasi terhadap banyaknya tweet yang mengandung unsur cyberbullying melalui sosial media Twitter. Labelling diisi angka 1 dan 0 sebagai berikut :

Tabel 2. Labelling Kategori Klasifikasi Cyberbullying

Bully	Sikap	Agama	Ras	Psikologis	Hewan	Seksual	Kecacatan	Umum
1	1	0	0	0	0	0	0	0
1	1	0	0	0	0	0	0	0
1	1	0	0	0	1	0	0	0

3. Implementasi

- a) Pre-Processing
 Tahap Pre-processing ini adalah tahap untuk menghapus noise dan perkataan yang buruk,

menyelaraskan bentuk kata, meminimalisir banyak kata untuk mendapatkan akurasi yang terbaik pada tahapan berikutnya. Sehingga data yang akan digunakan tersebut siap untuk di proses. Pemrosesan data meliputi beberapa tahapan, yaitu :

- a) Pada proses Case Folding adalah untuk mengubah huruf yang awalnya tercampuk tidak beraturan menjadi bentuk huruf kecil. misalnya, kata "ANJING" dan mengetik "ANJING", "AnjInG", atau "anjing", tetap menghasilkan hasil yang sama yaitu "anjing".
 - b) Pada proses Cleaning data adalah untuk membersihkan simbol dari kumpulan data yang tidak di diperlukan seperti, seperti angka, tanda baca, hastag, emoji, link suatu situs dan mention sehingga data yang digunakan lebih akurat.
 - c) Pada proses Tokenization dilakukan perubahan kalimat menjadi kata tunggal yang di konversikan menjadi potongan-potongan token.
 - d) Pada proses Stopword Removal yaitu untuk membersihkan kata general yang tidak memiliki arti yang berarti dan kemunculan jumlah kata yang melimpah dalam suatu teks.
 - e) Pada proses Stemming adalah proses yang memiliki tujuan untuk membersihkan imbuhan dari kata yang nantinya akan dikembalikan ke kata dasar dari kata tersebut.
- b) Klasifikasi Recurrent Neural Network dan Long Short Term Memory dan Optimasi ADAM

Pada proses pemodelan menggunakan Recurrent Neural Network dan Long Short Term Memory ini, terdapat proses traing dan testing. Proses training merupakan proses pelatihan data, dimana program mesin diberikan suatu algoritma dengan menggunakan dataset yang sudah memiliki label. Selanjutnya proses testing, profram mesin akan dilakukan pengujian dengan menggunakan data yang baru untuk memberikan tingkat keakurasian dan klasifikasi yang di tetapkan.. Adapun yang dibutuhkan dalam proses pemodelan Recurrent Neural Network dan Long Short Term Memory ini adalah :

- a) Menentukan fungsi kernel yang akan digunakan pada Recurrent Neural Network dan Long Short Term Memory Multi kelas. Fungsi yang digunakan adalah kernel Relu dan Sigmoid.
- b) Optimasi menggunakan ADAM (Adaptive Moment Estimation) berfungsi untuk memberikan nilai optimasi pada saat proses pelatihan berlangsung. ADAM mampu meminimalkan nilai loss pada perputaran proses pelatihan.
- c) Menentukan hasil klasifikasi yang di inputkan menggunakan model RNN dan LSTM agar dapat memberikan hasil pengujian dengan nilai akurasi yang terbaik pada klasifikasi.

Proses Pemodelan dilakukan menggunakan framework Tensorflow dan library SimpleRNN. Library yang digunakan pada proses build up model memberikan penyesuaian dan mampu untuk menghasilkan inputan berupa parameter dari banyaknya kumpulan yang membantu pembangunan model sehingga model yang didapatkan memiliki kualitas yang optimal dalam mempelajari data train dan data test sebagai data inputan. Aktivasi pada layer model menggunakan kernel relu dan sigmoid sebagai fungsi. Klasifikasi biner memberikan hasil keluaran angka berupa 1 dan 0. Interpretasi dari output tersebut memberikan kelas positif dalam probabilitasnya sehingga dalam metode Recurrent Neural Network semua inputan dimasukan dan berjalan melalui hidden layer yang nantinya menghasilkan output, namun pada metode Recurrent Neural Network memiliki proses perulangan (loop). Inputan yang dimasukkan dan memberikan hasil output akan dimasukkan Kembali sebagai inputan yang berulang secara sekuensial dalam proses di hidden layer untuk menyesuaikan dengan target.

Kelemahan model yang dimiliki Ketika memanfaatkan arsitektur library simpleRNN mampu dicegah dengan menutup keterbatasan model dengan menggabungkan lebih dari satu model dengan arsitektur yang berbeda. Kelebihan model pada setiap sisi menjadikan kelemahan simpleRNN pada saat memperhitungkan dari pasangan arsitektur yang sesuai dalam pembangunan hybrid model. Pada penelitian ini menggunakan penggabungan arsitektur simpleRNN dan LSTM untuk memilah-milah data dari Twitter. LSTM sendiri mempunyai kemampuan yang luar biasa dalam hal memperkirakan (predict) jumlah data dengan ketergantungan jangka Panjang (Long Term). sehingga hasil yang didapatkan menunjukkan bahwa Hybrid Model dapat mencegah kelemahan dari arsitektur simpleRNN. Model tersebut dapat mencegah ketergantungan jangka Panjang dan menaikkan performa pada saat hasil uji sebagai bentuk..

Long Short Term Memory membutuhkan beberapa layer. Layer-layer tersebut difungsikan untuk membuat arsitektur jaringan LSTM sebagai berikut : Embedding layer, LSTM layer, Dense layer, Dropout layer dan Fully connected layer. Pada proses Embedding layer dilakukan konversi vector teks dengan perubahan kata menjadi angka atau vektor.

Pengklasifikasian Recurrent Neural Network dan Long Short Term Memory menggunakan fungsi untuk memecah pola. Recurrent Neural Network dan Long Short Term Memory memberikan hasil hyperlane yang optimal dari pola yang telah dipecah menjadi dua. Recurrent Neural Network dan Long Short Term Memory hanya perlu memiliki inputan kernel (menyesuaikan kernel yang digunakan) dalam suatu parameter pada data yang dilakukan pemilihan secara tidak beraturan. Pembobotan nilai pada metode Recurrent Neural Network dan Long Short Term Memory dilakukan menggunakan formulasi matematika sehingga dalam sekali proses akan memberikan keputusan yang selalu sama untuk banyaknya pilihan kernel dan inputan parameter yang sama.

Tujuan utama dari Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) adalah menangkap informasi dan pola dalam data sequential. Baik RNN maupun LSTM memiliki kemampuan untuk bekerja dengan urutan

data, seperti teks, waktu deret, atau sinyal waktu nyata. Berikut tujuan utama metode keduanya sebagai berikut :

Kelebihan Recurrent Neural Network (RNN)

- Memahami konteks temporal, RNN dirancang untuk memahami dan memodelkan konteks temporal dalam data sequential. Ini memungkinkan jaringan untuk memahami hubungan dan dependensi antara elemen-elemen yang berurutan.
- Pengolahan urutan variabel Panjang, RNN mampu mengelola urutan data dengan panjang yang bervariasi. Hal ini membuatnya berguna dalam tugas-tugas di mana panjang urutan dapat berubah, seperti dalam pemrosesan teks atau analisis deret waktu.
- Pemahaman ketergantungan jangka pendek, Tujuan utama RNN adalah menangkap ketergantungan jangka pendek dalam data. Jaringan ini dapat "mengingat" informasi baru-baru ini dan menggunakan informasi tersebut dalam prediksi atau klasifikasi.

Kelebihan Long Short-Term Memory (LSTM)

- Mengatasi Masalah Vanishing Gradient merupakan salah satu tujuan utama LSTM dalam RNN. Dengan demikian, LSTM dapat mempertahankan dan menggunakan informasi jangka panjang, yang terkadang hilang dalam RNN.
- Memahami Ketergantungan Jangka Panjang, LSTM memiliki mekanisme memori jangka panjang yang memungkinkan penyimpanan informasi untuk jangka waktu yang lama. Ini membantu dalam tugas-tugas yang memerlukan pemahaman konteks jangka panjang, seperti pemrosesan bahasa alami atau tugas sequence-to-sequence learning.
- Pemilihan Informasi yang Relevan, Salah satu tujuan khusus LSTM adalah memberikan kontrol yang lebih besar atas informasi yang relevan dan perlu dipertahankan dalam memori jangka panjang. Ini dapat membantu dalam fokus pada aspek-aspek penting dari data.

Tujuan Utama Recurrent Neural Network (RNN) Dan Long Short-Term Memory (LSTM)

- Pengenalan Pola dan Representasi Abstrak, Baik RNN maupun LSTM bertujuan untuk mengenali pola yang kompleks dan membangun representasi abstrak dari data sequential. Hal ini dapat meningkatkan kemampuan jaringan untuk melakukan prediksi atau klasifikasi.
- Fleksibilitas dalam Implementasi, Keduanya dirancang untuk fleksibel dan dapat diaplikasikan dalam berbagai tugas, termasuk namun tidak terbatas pada pemrosesan bahasa alami, pengenalan ucapan, analisis deret waktu, dan lainnya.
- Menghadapi Tantangan Kontekstual, Baik RNN maupun LSTM diimplementasikan untuk mengatasi tantangan-tantangan yang muncul dalam tugas-tugas dengan konteks temporal yang kompleks, di mana informasi dari waktu sebelumnya penting untuk pengambilan keputusan di masa depan.

Sehingga disimpulkan bahwa RNN memberikan fondasi untuk bekerja dengan data sequential, LSTM, dengan mekanisme memori jangka panjangnya, menjadi solusi yang lebih unggul dalam beberapa konteks, terutama ketika mempertahankan informasi jangka panjang dan mengatasi masalah vanishing gradient menjadi kritis.

E. Evaluasi dan Pengujian Model

Pada tahap ini akan menghitung dari hasil klasifikasi algoritma Recurrent Neural Network dan Long Short Term Memory. Pada evaluasi ini akan dilakukan perhitungan terkait presisi, akurasi, recall dan F1-score untuk memperoleh nilai yang maksimal dari perhitungan tersebut perlu untuk membuat confusion matrix sebagai bentuk hasil komparasi evaluasi klasifikasi dataset menggunakan algoritma Recurrent Neural Network dan Long Short Term Memory. Berikut merupakan tabel evaluasi yang ditunjukkan pada tabel dibawah ini

Nilai Aktual	Nilai Prediksi	
	Positif	Negatif
Positif	TP	FP
Negatif	FN	TN

Gambar 4. Confusion Matrix

III. HASIL DAN PEMBAHASAN

A. Hasil Pengumpulan Data

Data yang telah diolah menggunakan Google collab berupa data tweet yang memiliki arti atau mengandung cyberbullying yang di adopsi dari Kaggle dengan jumlah 13.169 data tweet.

Gambar 5. Hasil data tweet dari Kaggle

B. Hasil Pelabelan Data

Kemudian data yang telah diambil dari kaggle tersebut selanjutnya dilakukan labelling untuk membedakan klasifikasi yang masuk kedalam kategori cyberbullying dan non-cyberbullying. Kemudian dilakukan labelling lagi untuk menentukan klasifikasi pada cyberbullying masuk ke klasifikasi sikap, Agama, Ras, Psikologis, Hewan, Pelecehan Seksual, Kecacatan atau Umum. Dalam mempermudah proses klasifikasi pada sistem maka yang termasuk dalam klasifikasi yang disebutkan ditandai dengan label 1 dan yang tidak termasuk dalam klasifikasi yang disebutkan ditandai dengan label 0. Kemudian setelah diberi label dapat diperoleh hasil label yang masuk klasifikasi cyberbullying sebanyak 10.086 data, dan hasil label yang tidak masuk klasifikasi cyberbullying sebanyak 8.126 data tweet. Jika dipresentasikan, data yang masuk

klasifikasi cyberbullying sebesar 55% dan data yang tidak masuk klasifikasi cyberbullying sebesar 45%.

yang berarti dan frekuensi kemunculan yang sering pada banyak teks. Proses Stemming merupakan proses yang difungsikan untuk membersihkan kata imbuhan dari semua kata yang tidak dibutuhkan yang nantinya akan dikembalikan ke kata dasarnya.

Gambar 6. Presentase pembagian data

Gambar 8. Source Code Case Folding

C. Hasil Pre-Processing Data

Pada tahapan ini, data asli dilakukan pengolahan untuk memperoleh data berupa teks sebelum data tersebut diolah lebih lanjut. Pre-processing ini dimaksudkan dengan tujuan membersihkan noise, mengkonversi data, memperkuat fitur agar dapat menyesuaikan dengan kebutuhan yang diperlukan serta digunakan untuk memperkecil dan memperbesar data. Dalam pre-processing sendiri terdapat beberapa tahapan, diantaranya :

Gambar 9. Source Code Case Tokenizing

1. Cleaning

Tahapan Cleaning dimana pada tahapan ini berguna untuk membersihkan kata-kata yang memiliki karakter yang tidak diperlukan seperti tanda baca, angka, link, mention dan hastag. Kemudian juga dilakukan penghapusan karakter spasi pada setiap kata..

2. Case Folding

Tahapan ini untuk difungsikan sebagai perubah huruf dimana proses dari bentuk huruf yang bercampur (lowercase dan uppercase) menjadi semua huruf kecil.

Gambar 10. Source Code Case Stop Removal

Hasil Pre-Processing dari Case Folding, Cleaning, Stopwords Removal, Stemming, Tokenizing dapat ditampilkan pada tabel berikut :

Tabel 3. Hasil pre-processing

3. Stopwords Removal, Stemming, Tokenizing

Pada tahapan proses Tokenizing, kalimat-kalimat yang dikonversikan menjadi token. Token atau potongan kata tunggal selanjutnya akan dilakukan proses Stopwords Removal untuk membersihkan kata general yang tidak memiliki arti

Tweet Asli	
Lg bayangin misal ni orang nikah ama kiwil ntar anak nya berbentuk seperti apa ya? apakah kalo cewek kyk kekeyi kalo cowok kyk temon.	
Tahap Pre-Processing	Hasil
<i>Cleaning</i>	Lg bayangin misal ni orang nikah ama kiwil ntar anak nya berbentuk seperti apa ya apakah kalo cewek kyk kekeyi kalo cowok kyk temon
<i>Case Folding</i>	lg bayangin misal ni orang nikah ama kiwil ntar anak nya berbentuk seperti apa ya

Gambar 7. Source Code Case Folding

	apakah kalo cewek kyk kekeyi kalo cowok kyk temon
<i>Tokenizing</i>	[lg, bayangin, misal, ni, orang, nikah, sama, kiwil, ntar, anaknya, berbentuk, seperti, apa, ya, apakah, kalo, cewek, kyk, kekeyi, kalo, cowok, kyk, temon]
<i>Stopwords Removal</i>	[lg, bayangin, misal, orang, nikah, kiwil, anaknya, berbentuk, cewek, kekeyi, cowok, temon]
<i>Stemming</i>	[lagi, bayang, misal, orang, nikah, kiwil, anak, bentuk, cewek, kekeyi, cowok, temon]
Hasil Akhir	
Lagi bayang misal orang nikah kiwil anak bentuk cewek kekeyi cowok temon	

D. Word Cloud

Output dari proses pre-processing, dapat di gambarkan melalui wordcloud. Pada wordcloud akan memberikan visualisasi dari kata-kata yang mengambil dasar dari banyaknya kemunculan kata tersebut, frekuensi kemunculan yang sering akan memebrikan visual kata yang lebih besar pad kata tersebut.

Berikut merupakan tampilan wordcloud dari hasil scraping data tweet tentang cyberbullying.

Gambar 11. Word Cloud

E. Hasil Pengujian

Data yang telah dilakukan preprocessing kemudian diubah menjadi nomor unik per kata. Dengan memanfaatkan library dari Python Tokenizer, data diubah dengan rentang nomor 0 sampai 3000 dan maksimal kalimat sepanjang 30 kata. Dari pengubahan data tersebut membuat 1 kalimat dataset menjadi 70 kata secara otomatis, jika melebihi akan dipotong dan jika kurang akan ditambah dengan kata lain (00_v) yang dimana kata tersebut tidak terdeteksi oleh sistem sebagai data latih. Dalam model yang dibuat mengharuskan data memiliki panjang kata 70. Data yang telah dilakukan tokenizer kemudian dibagi untuk menjadi data latih dan data uji masih dengan penggunaan library yang sama yaitu Tokenizer. Sehingga menghasilkan jumlah data latih sebanyak 80% dan data uji sebanyak 20%.

Kemudian dilakukan klasifikasi dengan menggunakan metode Recurrent Neural Network dan Long Short Term Memory. Dalam penelitian ini, dataset akan diuji dengan

memisahkan data dimana pembagian dataset dilakukan menjadi 2 segmen yaitu data latih dan data uji. Data latih difungsikan pada pembuatan model, sedangkan data latih di fungsikan untuk pengujian performa model, sedangkan data test untuk menguji performa model. Pegujian akan dilakukan menggunakan 2 kernel yang berkesinambungan sebagai berikut :

1. Kernel Relu dan Sigmoid

Pada Kernel Linear dilakukan sebanyak 4 kali menggunakan skala 10 untuk mencari hasil akurasi akurasi terbaik. Berikut ini tabel hasil klasifikasi Recurrent Neural Network dan Long Short Term Memory menggunakan kernel linear.

Tabel 4. Hasil pengujian kernel linear dan Sigmoid Recurrent Neural Network dan Long Short Term Memory

No	Rasio	Accuracy	Precision	F1-Score	Recall
1.	6:4	89	83	89	88
2.	7:3	88	85	88	87
3.	8:2	94	93	94	94
4.	9:1	90	88	90	89

Berdasarkan hasil pengujian pada Tabel 4 dapat diambil keputusan bahwa nilai keakuratan yang maksimal untuk penggunaan kernel linear dan sigmoid yaitu menggunakan perbandingan 8:2 menghasilkan akurasi sebesar 94%, Precision sebesar 93%, F1-Score sebesar 94%, dan Recall sebesar 94%. Tabel berikut menunjukkan evaluasi hasil kernel linear dan sigmoid.

Tabel 5. Evaluasi hasil kernel linear dan sigmoid

Metrik Evaluasi	Nilai (%)
Akurasi	94
Precision	93
F1-Score	94
Recall	94

F. Confusion Matrix

Setelah semua tahap telah dilakukan, proses yang terakhir adalah pengukuran keefektifan model yang telah dibuat dan diuji. Nilai akurasi yang didapatkan sebelumnya akan diukur menggunakan matrix confusion. Hasil pengukuran keefektifan metode yang telah dibangun adalah sebagai berikut :

Gambar 12. Confusion matrix model Recurrent Neural Network dan Long Short Term Memory

Pada Gambar 12 diatas prediksi matrix confusion untuk model algoritma Recurrent Neural Network dan Long Short Term Memory menyatakan bahwa sebelah kiri merupakan Aktual dan bagian bawah adalah hasil Prediction sehingga dapat dinyatakan bahwa dimana yang masuk dalam klasifikasi cyberbullying (Positif) dan yang tidak masuk dalam klasifikasi cyberbullying (Negatif) adalah 5929 True Negative (TN), 1419 False Negative (FN), 571 False Positive (FP), 5082 True Positive (TP).

Pada tahapan ini, hasil dari evaluasi yang dilakukan menggunakan confusion matrix. Pengukuran pada performa sistem dalam proses klasifikasi untuk menghitung keakuratan, nilai presisi, nilai recall yang maksimal. berikut hasil confusion matrix.

Tabel 6. Data confusion matrix kernel linear dan sigmoid

Nilai Aktual	Nilai Prediksi	
	Positif	Negatif
Positif	(TP) 5082	(FN) 1419
Negatif	(FP) 571	(TN) 5929

Dari data Confusion Matrix diatas, hasil akurasi, presisi, recall kernel linear dapat dihitung sebagai berikut :

$$Akurasi = \frac{TP + TN}{(TP + FP + FN + TN)} = \frac{5082 + 5929}{(5082 + 571 + 1419 + 5929)} = 0.94\%$$

$$Recall = \frac{TP}{TP + FN} = \frac{5082}{5082 + 1419} = 0.94\%$$

$$Presisi = \frac{TP}{TP + FP} = \frac{5082}{5082 + 571} = 0.93\%$$

Berdasarkan perhitungan evaluasi hasil menggunakan Confusion Matrix diatas sama dengan hasil perhitungan yang dilakukan menggunakan program Python, maka dapat disimpulkan bahwa kernel linear dan sigmoid memiliki akurasi sebesar 94% recall sebesar 94%, dan presisi sebesar 93%.

G. Tampilan Web

Berikut adalah tampilan dari implementasi klasifikasi cyberbullying dengan metode Recurrent Neural Network dan Long Short Term Memory dengan model yang telah dihasilkan dari tahap pelatihan. Implementasi sistem ini berbentuk web yang dibangun dengan menggunakan library python Flask.

Gambar 13. Tampilan utama aplikasi web

Kemudian pada Gambar 14 menunjukkan hasil klasifikasi opini dari teks. opini yang dimasukkan oleh pengguna dan Gambar 14 menunjukkan hasil klasifikasi opini dari range data yang diambil oleh pengguna.

Gambar 14. Hasil Klasifikasi Opini dari Data Text Realtime

IV. KESIMPULAN

Berdasarkan hasil yang didapatkan dari penelitian dengan menggunakan metode Recurrent Neural Network dan Long Short Term Memory pada klasifikasi cyberbullying di media sosial Twitter dapat ditarik kesimpulan sebagai berikut :

1. Implementasi pengembangan sistem klasifikasi Cyberbullying pada Media Sosial dengan menggunakan metode Recurrent Neural Network dan Long Short Term Memory dimulai dengan pengumpulan dataset yang di ambil dari website resmi Kaggle, kemudian melakukan pelabelan dataset untuk menjadikan acuan dari kebutuhan klasifikasi yang kemudian di preprocessing untuk mendapatkan kata dasar dari sebuah kalimat. Model Recurrent Neural Network dan Long Short Term Memory pada sistem menggunakan library keras dari tensorflow dengan menggunakan activation Relu dan Sigmoid sebesar 84% accuracy, 84% f1-score, 84% recall dan 83% precision.
2. Implementasi pengembangan optimasi menggunakan ADAM (Adaptive Moment Estimation) guna untuk meminimalisir loss pada setiap train menggunakan library keras dari tensorflow memberikan peningkatan pada metode Recurrent Neural Network dan Long Short Term Memory sebesar 94% accuracy, 94% f1-score, 94% recall dan 93% precision.

V. SARAN

Penelitian mengenai klasifikasi Cyberbullying pada Media Sosial ini ini berpeluang sangat besar untuk pengembangan maupun terobosan lebih lanjut. Pengembangan yang dimaksudkan salah satunya yaitu dengan mencoba

menambahkan interface dalam pengambilan data tweet secara periodik dengan parameter waktu atau tanggal dan bisa juga untuk menggunakan metode yang lain, diharapkan menggunakan dua atau lebih metode untuk meningkatkan keakuratan sistem. Dari pada itu pada masing-masih proses bisa diakukan pengembangan Kembali terutama pada proses pemberian label sehingga penelitian tersebut mampu memberikan keakuratan nilai yang terbaik dan lebih tinggi.

UCAPAN TERIMA KASIH

Peneliti senantiasa mengucap rasa syukur kepada Tuhan yang maha esa atas nikmat, rezeki, kemudahan dan kelancaran dariNYA, sehingga peneliti bisa menuntaskan penelitian ini dengan maksimal. Penulis juga mengucapkan terima kasih kepada Dosen Pembimbing yang telah memberi arahan dan masukan yang sangat bermanfaat buat peneliti. Kedua orang tua peneliti yang tak selalu memberikan doa terbaik dan membantu dalam segala hal. Semua saudara-saudara Jurusan Teknik Informatika yang senantiasa memberikan support dan motivasi sehingga peneliti dapat menuntaskan penelitian ini dengan baik dan lancar.

REFERENSI

- [1] Al-Rahmi, W. M., Yahaya, N., Alamri, M. M., Aljarboa, N. A., Kamin, Y. Bin, & Moafa, F. A. (2019). A model of factors affecting cyber bullying behaviors among university students. *IEEE Access*, 7, 2978–2985. <https://doi.org/10.1109/ACCESS.2018.2881292>
- [2] Arce-Ruelas, K. I., Alvarez-Xochihua, O., Pellegrin, L., Cardoza-Avendano, L., & Gonzalez-Fraga, J. A. (2022). Automatic Cyberbullying Detection: a Mexican case in High School and Higher Education students. *IEEE Latin America Transactions*, 20(5), 770–779. <https://doi.org/10.1109/TLA.2022.9693561>
- [3] López-Vizcaíno, M. F., Nóvoa, F. J., Carneiro, V., & CACHED, F. (2021). Early detection of cyberbullying on social media networks. *Future Generation Computer Systems*, 118, 219–229. <https://doi.org/10.1016/j.future.2021.01.006>
- [4] Sheldon, P., Rauschnabel, P. A., & Honeycutt, J. M. (2019). Cyberstalking and Bullying. In J. M. H. Pavica Sheldon, Philipp A. Rauschnabel (Ed.), *The Dark Side of Social Media* (pp. 43–58). Academic Press. <https://doi.org/10.1016/b978-0-12-815917-0.00003-4>
- [5] Murshed, B. A. H., Abawajy, J., Mallappa, S., Saif, M. A. N., & Al-Ariki, H. D. E. (2022). DEA-RNN: A Hybrid Deep Learning Approach for Cyberbullying Detection in Twitter Social Media Platform. *IEEE Access*, 10(February), 25857–25871. <https://doi.org/10.1109/ACCESS.2022.3153675>
- [6] Singgih, E., Iskandar, J., Goestjahjanti, F. S., Fahlevi, M., Nadeak, M., Fahmi, K., Anwar, R., Asbari, M., & Purwanto, A. (2020). The Role of Job Satisfaction in the Relationship between Transformational Leadership, Knowledge Management, Work Environment and Performance. *Solid State Technology*, 63(2s), 293–314. <http://www.solidstatetechnology.us/index.php/JSST/article/view/1556>