

Pelaporan Jalan Rusak dengan Deteksi Citra dan Uji Viralitas dari Data Twitter

Krisna Bayu Dharma Putra¹, Venus Angela Kurniawan², Anisa Bintang Maharani³, Dzikri Rahadian Fudholi⁴

¹Fakultas Matematika dan Ilmu Pengetahuan Alam, Sleman, 55281, email: krisnabayu01@mail.ugm.ac.id

²Fakultas Matematika dan Ilmu Pengetahuan Alam, Sleman, 55281, email: venus.angela.kurniawan@mail.ugm.ac.id

³Fakultas Teknik Universitas Gadjah Mada, Sleman, 55284, email: anisa.bintang2803@mail.ugm.ac.id

⁴Fakultas Matematika dan Ilmu Pengetahuan Alam, Sleman, 55281, email: dzikri.r.f@ugm.ac.id

Corresponding Author: Dzikri Rahadian Fudholi

INTISARI — Kasus jalan rusak di Indonesia mendapat penanganan yang lambat dari pemerintah. Pada penelitian ini diajukan sebuah sistem untuk memprediksi tingkat urgensi penanganan jalan rusak berdasarkan kritik dan keluhan masyarakat pengguna Twitter. Sistem ini menggabungkan algoritma klasifikasi citra jalan rusak dan algoritma analisis sentimen untuk memperoleh tingkat kerusakan jalan yang dikeluhkan serta mengukur tingkat negativitas sentimen masyarakat tentang kondisi jalan. Penelitian ini bertujuan untuk memberikan informasi yang lebih komprehensif dan akurat kepada pemerintah. Penggabungan model klasifikasi citra menggunakan algoritma YOLOv8 yang berhasil mencapai nilai F-1 sebesar 86.1% dan model analisis sentimen menggunakan IndoBERTweet yang mencapai nilai F-1 sebesar 83% diharapkan dapat membantu meningkatkan kepuasan masyarakat terkait infrastruktur jalan dan mempercepat proses identifikasi serta penanganan jalan rusak. Namun, kolaborasi dengan pihak pemerintah juga diperlukan untuk memastikan implementasi sistem pelaporan jalan rusak ini menjadi efektif dan dapat terealisasi untuk menangani kerusakan jalan di Indonesia. Melalui pengembangan lebih lanjut, sistem ini dapat berpotensi menjadi alat yang berharga dalam memperbaiki kondisi jalan di Indonesia dan meningkatkan kesejahteraan masyarakat secara keseluruhan.

KATA KUNCI — *Algoritma IndoBERT; YOLOv8; Analisis Sentimen; Kerusakan Jalan; Klasifikasi Citra*

I. PENDAHULUAN

A. LATAR BELAKANG

Transportasi merupakan aspek penting dalam kehidupan masyarakat masa kini. Peningkatan jumlah kendaraan bermotor di Indonesia pada tahun 2021 adalah sebesar 0.043% dari tahun sebelumnya. Hal ini menciptakan tantangan untuk mengimbangnya dengan kondisi jalan yang baik. Menurut UU RI no. 38 Tahun 2004 pasal 1 ayat (4), jalan adalah prasarana transportasi darat yang meliputi segala bagian jalan, termasuk bangunan pelengkap dan perlengkapannya yang diperuntukkan bagi lalu lintas yang berada pada permukaan tanah dan atau air, serta di atas permukaan air, kecuali jalan kereta api, jalan lori, dan jalan kabel. Faktor penentu kualitas jalan yang ideal diantaranya karakteristik jalur, keberadaan lubang, keberadaan marka, medan jalan, dan penerangan. Berbagai macam kegiatan manusia yang dilakukan di jalan, diantaranya perjalanan menuju tempat kerja, sekolah, dan aktivitas jual beli. Jalan juga digunakan sebagai sarana aktivitas sosial, yaitu sebagai tempat kita melakukan interaksi dengan manusia lain seperti bertegur sapa.

Di Indonesia, masih banyak kita temukan jalan dengan permukaan yang tidak rata, terdapat lubang dan retakan, tidak adanya marka, jalur yang cenderung sempit, serta medan jalan yang cukup ekstrim. Menurut laporan Statistik Transportasi Darat yang dirilis oleh Badan Pusat Statistik [1] terdapat 16.01% jalan rusak dan 15.9% jalan rusak berat di Indonesia pada tahun 2021. Kondisi jalan yang buruk dapat kita temukan terutama di daerah perbatasan dan jauh dari kota.

Jalan yang tidak ideal sebagai tempat publik dapat menghambat mobilitas masyarakat dan tidak dapat menciptakan kondisi santai serta rasa aman ketika berjalan atau berkendara [2]. Jalan sebagai akses transportasi yang buruk juga berpengaruh dalam aktivitas bisnis seperti pertimbangan investasi hingga pengembangan suatu wilayah karena terkendala dalam eksplorasi. Oleh karena itu, aspek kelayakan jalan memegang peran penting dalam kesejahteraan hidup masyarakat.

Kondisi jalan yang rusak ringan maupun berat telah banyak menuai kritikan masyarakat. Ketidakmerataan infrastruktur di seluruh wilayah Indonesia juga seringkali menimbulkan rasa iri dan rasa tidak adil bagi masyarakat. Namun, kritik yang disampaikan terhadap pemerintah juga mendapatkan respon serta penanganan yang lambat dari pihak berwajib apabila tidak viral di media sosial. Hal ini terbukti pada kasus Bima dan Gubernur Lampung yang ramai dibicarakan di Twitter pada bulan April 2023 [3]. Kasus tersebut menyoroti jalanan Lampung yang rusak parah dan mengganggu kenyamanan masyarakatnya dalam menjalani aktivitas, tetapi pengkritik justru diancam hukuman karena tuduhan pencemaran nama baik [4]. Kasus ini kemudian mencuat di berbagai media sosial dan mendapatkan perhatian publik. Melalui kasus tersebut, kondisi jalan di Provinsi Lampung akhirnya disorot oleh publik dan Pemerintah Provinsi mendapatkan kritik dalam pembangunan infrastruktur wilayahnya. Presiden Jokowi pun sampai turun tangan untuk memeriksa keadaan kondisi jalan di sana pemerintah. Memanfaatkan hal tersebut, penelitian bertujuan untuk menganalisis sentimen masyarakat di Twitter mengenai kondisi jalan dan menggabungkannya dengan *Road Detector* yang dapat mendeteksi kerusakan jalan.

B. TUJUAN DAN MANFAAT

Penelitian ini memiliki tujuan dan manfaat sebagai berikut :

- Mendapatkan model untuk memprediksi sentimen masyarakat dari dataset yang ada.
- Mendapatkan model untuk melakukan prediksi apakah suatu jalan rusak atau tidak.
- Memberikan insight tentang sentimen masyarakat terhadap kerusakan jalan.
- Memprediksi urgensi kerusakan jalan berdasarkan sentimen masyarakat.

C. BATASAN PENELITIAN

Data yang digunakan memiliki dua buah tipe data, yaitu data berupa teks untuk klasifikasi sentimen masyarakat dan data berupa citra untuk klasifikasi jalan rusak. Data set teks dibatasi teks berbahasa Indonesia, sedangkan data set citra terbatas pada

citra jalan. Dataset teks memiliki tiga buah label, yaitu positif, netral, atau negatif. Sementara data citra memiliki dua buah label, yaitu rusak atau normal.

D. CELAH PENELITIAN

Berdasarkan kajian literatur yang kami acu, belum ada penelitian yang mencoba mengkombinasikan metode *Natural Language Processing* dengan *Computer Vision* untuk merancang suatu sistem dalam pelaporan jalan rusak. Hal inilah yang menginspirasi peneliti untuk menggunakan kedua metode dalam suatu rancangan sistem yang berguna untuk pelaporan jalan rusak berdasarkan citra dan *sentimen* masyarakat pada suatu *tweet* di twitter.

II. KAJIAN TEORI

Hasil penelitian oleh Koto dkk. [5] membandingkan model INDOBERT dengan beberapa model lain seperti MALAYBERT, Naïve Bayes, MBERT, dan BiLSTM. IndoBert menunjukkan kinerja yang lebih baik dalam analisis sentimen dengan skor F1 tertinggi sebesar 84.13%, lebih tinggi dari Naïve Bayes sebesar 13.2% dan MBERT sebesar 7.5%. Penelitian lain [6] menggunakan IndoBert untuk analisis sentimen terhadap bahasa *slang* dalam pasar saham Indonesia. Dalam penelitian ini, dilakukan tahap *preprocessing* termasuk penghapusan tanda baca, penghapusan *stopwords*, tokenisasi, dan penyesuaian dimensi data. Setelah dilatih dengan IndoBert, didapatkan skor F1 untuk kelas negatif sebesar 0.65, kelas netral sebesar 0.44, kelas positif sebesar 0.65, dan tingkat akurasi sebesar 60.35%.

Penelitian lainnya [7] membandingkan INDOBERTweet dengan beberapa metode BERT lainnya seperti MALAYBERT, MBERT, dan INDOBERT. Hasilnya menunjukkan bahwa IndoBertweet memiliki performa rata-rata 86.1%, yang lebih tinggi dari IndoBert, MALAYBERT, dan MBERT. Selain itu, beberapa peneliti juga menggunakan model selain IndoBert untuk analisis sentimen, seperti pendekatan CNN-LSTM yang digunakan oleh Pane dkk. (2022) [8]. Penelitian ini berhasil mencapai skor ROC-AUC sebesar 0.966.

Alqethami dkk. [9] membandingkan empat model *deep learning* untuk deteksi dan klasifikasi jalan rusak. Data yang digunakan yaitu jalan di Saudi Arabia dan jenis kerusakan dibagi menjadi empat jenis. Model yang digunakan merupakan *pre-trained* model (AlexNet, VGG-16, dan ResNet-34) dan model yang diajukan peneliti (RoadNet). Hasil yang didapatkan adalah RoadNet mendapatkan nilai F-1 terbesar yaitu sebesar 0.99, diikuti AlexNet sebesar 0.98. Model VGG-16 sendiri mendapat nilai F-1 sebesar 0.95 dan model ResNet-34 dengan F-1 sebesar 0.76.

Hegde dkk. [10] melakukan deteksi jalan rusak menggunakan *bounding box*. Metode yang diajukan berupa gabungan dari *ensemble prediction* dengan *ensemble model* menggunakan Ultralytics YOLO. Hasil yang didapatkan berupa nilai F-1 yang mencapai 0.67.

III. METODOLOGI

A. NATURAL LANGUAGE PROCESSING

1. DATASET

Pada *dataset* NLP, *dataset* terdiri dari *dataset* [11] yang memiliki dua label, yaitu positif dan negatif yang kemudian digabungkan dengan *dataset* [5] yang memiliki tiga buah label, yaitu negatif, netral, dan positif. Kedua *dataset* ini kemudian akan disatukan menjadi *dataset final*. *Dataset final* ini yang akan

dilakukan analisis dan *modelling* menggunakan algoritma INDOBERT dan CNN-LSTM, ditunjukkan pada Tabel I.

Tabel I. Penjelasan Dataset *Final*

Kolom	Penjelasan	Tipe data
Sentence	Berisi teks <i>tweet</i>	String
Label	Berisi label <i>tweet</i> positif, netral, atau negatif	String

2. PREPROCESSING

Tahap *preprocessing* yang dilakukan dalam penelitian ini sebagai berikut;

- 1) *Lowercasing*. Pada proses ini, teks akan diubah menjadi huruf kecil untuk menjaga konsistensi analisis.
- 2) *Remove Link* (Menghapus Tautan). Semua *link* yang ada pada *tweet* dihapus agar tidak mempengaruhi analisis.
- 3) *Remove Username*. Menghapus semua *mention username* yang diawali dengan "@" dan *retweet* yang diawali dengan "RT" serta diikuti oleh "@" dan *username*.
- 4) *Remove hashtags* dan spasi berlebih. Menghapus *hashtags* yang diawali dengan "#" dan menghapus spasi berlebih pada *tweet*.
- 5) Tokenisasi. Memecah *tweet* menjadi unit yang lebih kecil, yaitu kata dan frasa.
- 6) Pengubahan kata *slang* menjadi formal. Proses ini dilakukan untuk menjaga keseragaman dan konsistensi analisis.
- 7) *Remove Stopwords*. Menghapus kata-kata yang tidak memiliki makna penting atau tidak penting dalam analisis.
- 8) *Stemming*. Mengubah token-token yang didapatkan menjadi kata dasar (*stem words*) untuk mengatasi variasi dari kata bermakna sama.

3. MODELLING

a. INDOBERT

INDOBERT adalah model yang dikembangkan oleh Bryan dkk [12] pada tahun 2020. INDOBERT adalah versi Indonesia dari *model* BERT [6] yang dilatih pada sekitar 220 miliar kata-kata berbahasa Indonesia. INDOBERT dilatih menggunakan 2.4 miliar *steps* yang terbagi menjadi 180 *epochs*. INDOBERT memiliki keunggulan pada tugas-tugas seperti *POS* dan *NER*, *dependency parsing*, *sentiment analyst*, dan *discourse coherence* [5]. Hal tersebut membuat INDOBERT dipilih sebagai model pada penelitian ini. Untuk *baseline*, digunakan model *pre-trained* "indobert-large-p2" yang dilatih pada dataset dengan menggunakan 10 *epochs* dan, *batchsize* 32, *optimizer* menggunakan *adam optimizer* sebesar 0.000001.

b. INDOBERTWEET

INDOBERTweet adalah sebuah model variasi dari INDOBERT yang dikembangkan oleh [7] pada tahun 2021. INDOBERTweet dilatih mengikuti prosedur dari model indobert-base-uncased (INDOBERT). Model ini menggunakan encoder *transformer* berupa 12 *hidden layer* dengan dimensi 768 diikuti oleh 12 *attention heads* dan 3 *feed-forward layer* dengan dimensi 3072 [7].

INDOBERTTweet dilatih dengan menggunakan data Twitter sebanyak 26 juta *tweet* dalam rentang waktu Desember 2019 sampai Desember 2020. INDOBERTweet juga melalui *fine tuning* untuk kasus *sentiment analysis*, *emotion analysis*, dan *hate speech classification* dengan menambahkan *MLP layer* dengan menggunakan *input* berupa *output* dari INDOBERTweet [7].

c. CNN-LSTM

Model ini diawali dengan *layer convolutional CNN* dengan *input* berupa *word embedding* tiap token. *Output* dari *layer CNN* ini akan menjadi *input* untuk *layer LSTM* setelah dilakukan *dimensional reduction*. *Layer LSTM* ini kemudian akan mengekstrak fitur lokal [13].

B. COMPUTER VISION

1. DATASET


Dataset yang digunakan untuk mendeteksi jalan rusak berasal dari Road Damage Detection Challenge 2022 [14] dan Kaggle [15]. Terdapat 50.741 citra yang berasal dari tujuh negara. Data citra yang ada disesuaikan dengan kebutuhan dan dibagi menjadi dua kelas yaitu jalan rusak dan normal. Data dengan anotasi dianggap sebagai jalan rusak dan data tanpa anotasi dianggap sebagai jalan normal. Setelah dilakukan proses *cleaning* dan pembagian data, citra yang dapat digunakan dalam penelitian ini sebanyak 41.705 data dengan pembagian 29.981 data jalan rusak dan 11.724 data jalan normal.

2. MODELLING

Untuk pemodelan pada data citra, digunakan model *pre-trained YOLOv8*. Model YOLO yang digunakan adalah model untuk klasifikasi, yaitu model *yolov8n-cls*. Model dioptimasi menggunakan menggunakan *Stochastic Gradient Descent* dengan *learning rate* 0.01. *Momentum* 0.9 digunakan untuk memperbaharui *weight*. *Epoch* yang digunakan adalah 15 *epochs*.

IV. HASIL DAN PEMBAHASAN

A. NATURAL LANGUAGE PROCESSING



Gambar 1. Distribusi dataset NLP

Dataset yang digunakan merupakan dataset gabungan yang didapatkan dari [5] dan [11]. Kedua dataset ini kemudian digabungkan menjadi satu buah dataset. Dataset gabungan ini mempunyai total *tweet* sebanyak 16.398 yang terbagi menjadi 8.430 sentimen positif, 6.601 sentimen negatif, dan 1.367 sentimen netral dengan proporsi seperti Gambar 1. Dataset ini kemudian dibagi menjadi *dataset train*, *validation*, dan *test* dengan proporsi seperti pada Tabel II. Tabel II menunjukkan proporsi penggunaan dataset untuk *train*, *validation*, dan *test*. Peneliti menggunakan *dataset training* berjumlah 14.638 *tweet*, *dataset validation* sebanyak 1.260 *tweet*, dan *dataset test* sebanyak 500 *tweet*. *Dataset* ini terbagi menjadi tiga buah label, yaitu positif, netral, dan negatif.


Tabel II. Pembagian Label Dataset Teks

Dataset	Jumlah <i>tweet</i> positif	Jumlah <i>tweet</i> netral	Jumlah <i>tweet</i> negatif	Total
Train	7487	1148	6003	14638
Validation	735	131	394	1260
Test	208	88	204	500

Proses evaluasi dilakukan dengan menggunakan matrik berupa skor F1 dan *accuracy*. Skor *accuracy* didapatkan dari menghitung jumlah jumlah label terprediksi benar lalu membaginya dengan seluruh total data lalu mengalikannya dengan 100, sedangkan skor F1 didapatkan dengan rumus :


$$F1 = \frac{2 \times precision \times recall}{(precision + recall)}$$

Recall adalah pembagian antara jumlah *true positive* dengan penjumlahan *true positive* dan *false negative*. *Precision* didapat dengan membagi jumlah *true positive* dengan jumlah *true positive* ditambah *false positive*. Selanjutnya, hasil evaluasi F1 dari ketiga model akan dibandingkan untuk menentukan model dengan nilai F1 terbesar. Model dengan nilai F1 terbesar akan ditetapkan sebagai model dengan performa terbaik.



Gambar 2. Train dan validation loss model NLP

Gambar 2 Menunjukkan bahwa terjadi penurunan loss pada train dataset setelah *epochs* kedua sampai *epochs* ke-10, tetapi setelah *epochs* ke-8 tidak terjadi penurunan nilai loss yang signifikan. Gambar 2 juga menunjukkan bahwa INDOBERT memiliki skor *loss* yang paling minimal. Namun, *loss* justru terlihat fluktuatif pada dataset validasi, terutama untuk model INDOBERTweet (Gambar 2). Selain itu, setelah melewati *epochs* ketiga, model INDOBERT justru mengalami kenaikan *loss*. Model ketiga, yaitu CNN-LSTM, menunjukkan performa yang kurang baik sebab terdapat peningkatan *loss* sepanjang berjalannya nilai *epochs*. Hal ini menandakan bahwa model CNN-LSTM mengalami *overfitting*.



Gambar 3. Train dan validation F1 model NLP

Model INDOBERT memiliki kenaikan kurva F1 terbaik (Gambar 3) ditunjukkan dengan kenaikan kurva yang paling besar. Namun, Gambar 5 menunjukkan bahwa performa model INDOBERT menurun ditandai dengan nilai F1 pada validasi lebih rendah daripada train. Hal ini menandakan bahwa ada kemungkinan bahwa model INDOBERT *overfit*. Sebaliknya,

INDOBERTtweet justru menunjukkan performa stabil baik untuk train set maupun validation set, namun mengalami penurunan cukup besar untuk test set.

Tabel III. Tabel Hasil Model

Model	Accuracy			F1		
	Train	Validation	Test	Train	Validation	Test
INDOBERT	99,30%	92,70%	90%	99,10%	89,30%	82%
INDOBERTtweet	95%	91,20%	88%	95%	91%	83%
CNN-LSTM	96%	87,60%	84%	96,90%	87,60%	80%

Hasil keseluruhan evaluasi ketiga model dapat dilihat pada Tabel III. Hasil yang tertera terdiri dari nilai F1 dan akurasi untuk proses *train*, *validation*, dan *testing*. Akurasi pada model INDOBERT memiliki penurunan sebesar 3% antara proses *training* dan *testing*. Penurunan nilai F1 model INDOBERT lebih signifikan yaitu sebesar 17,1%. Nilai F1 yang rendah pada model INDOBERT menandakan bahwa model ini memiliki rasio *precision* dan *recall* yang kurang baik.

Penurunan nilai akurasi dan F1 tidak hanya terjadi pada model INDOBERT, namun juga pada model INDOBERTtweet dan CNN-LSTM. Penurunan akurasi dan F1 pada model INDOBERTtweet berturut-turut adalah 7% dan 12%. Sedangkan pada model CNN-LSTM, penurunan akurasi dan F1 berturut-turut adalah 12% dan 16,9%. Nilai F1 pada kedua model juga tergolong rendah sehingga rasio antara *precision* dan *recall* pada kedua model kurang baik.


Penurunan nilai akurasi dan nilai F1 antara *training* dan *testing* yang cukup jauh menandakan kemungkinan terjadinya *overfit* pada seluruh model. Dari ketiga model, disimpulkan bahwa model INDOBERTtweet adalah model yang paling baik karena memiliki nilai F1 pada data *test* yang paling besar diantara model lainnya. Penurunan antara F1 *train* dan *test* pada model INDOBERTtweet juga yang paling kecil.

B. COMPUTER VISION

Data secara keseluruhan dibagi menjadi data train, validasi, dan test dengan persentase 80%, 10%, dan 10%. Tabel IV menunjukkan pembagian data.


Tabel IV. Pembagian Label Dataset Citra

Dataset	Jumlah citra jalan normal	Jumlah citra jalan rusak	Total
Train	9379	23984	33363
Validation	1172	2998	4170
Test	1173	2999	4172



Gambar 4. Train dan validation loss YOLOv8

Pada data *train*, penurunan *loss* terjadi dari *epoch* pertama hingga *epoch* terakhir seperti pada Gambar 4. Penurunan paling pesat terjadi di antara *epoch* pertama dan kedua. Kemudian, penurunan *epoch* cukup landai dari *epoch* kedua hingga epoch ke-9. Dari epoch ke-9 hingga terakhir, penurunan *loss* lebih besar sehingga garis menjadi lebih curam. Sedangkan untuk data validasi, secara keseluruhan *loss* mengalami penurunan, seperti pada Gambar 5. Namun, penurunan yang dialami lebih fluktuatif dan cenderung naik pada epoch-epoch akhir.



Gambar 5. Akurasi YOLOv8


Evaluasi pada saat proses training dilakukan dengan metrik akurasi. Secara keseluruhan, akurasi pada model YOLO mengalami kenaikan, terutama pada epoch ke-4 hingga epoch ke-7. Namun, setelah itu, nilai akurasi menjadi fluktuatif. Nilai akurasi tertinggi yang didapatkan pada saat proses training adalah 84,26%. Kemudian, pada proses testing untuk model, didapatkan hasil seperti pada Tabel V.

Tabel V. Hasil Model YOLOv8

Model	Akurasi	F-1	Precision	Recall
YOLOv8-cls	79.20%	86.10%	82.60%	89.90%

Pada tabel 5., terlihat bahwa nilai akurasi pada data test lebih rendah daripada nilai akurasi pada proses training. Penurunan nilai akurasi dapat menandakan terjadinya *overfitting* pada model YOLO. Tetapi, nilai akurasi hanya turun sekitar 5%, yaitu dari 84% menjadi 79%. Penurunan nilai akurasi sebesar 5% masih dapat dianggap wajar sehingga model YOLO dianggap tidak *overfit*.

C. IMPLEMENTASI



Gambar 6. Alur kerja sistem

Implementasi dilakukan menggunakan data *test* yang diperoleh dengan cara melakukan *scraping* secara manual pada platform *twitter*. *Scraping* ini dilakukan dengan mencari sebuah *tweet* dengan kata kunci “#jalanrusak, #jalanberlubang, #jalanhancur” pada platform *twitter*. Gambar 6 menunjukkan alur kerja sistem.

Tabel VI. Tabel Penjelasan data input

Kolom	Penjelasan	Tipe Data
ID	Berisi ID untuk masing-masing data	Int
image	Berisipi citra yang akan dideteksi.	image
impression_dict	Berisi array dari kumpulan string tweet, reply, ataupun quote retweet. Setiap impresi dipisahkan dengan tanda koma.	Array
link	tautan menuju postingan tweet	string


Tweet yang didapat pun di-filter dengan beberapa kriteria sebagai berikut :



1. Tweet harus berisi gambar jalan
2. Tweet setidaknya memiliki impression berupa reply atau quote retweet
3. Tweet berbahasa Indonesia

Setelah didapatkan tweet yang sesuai kriteria, gambar akan diunduh dan disimpan dalam direktori khusus yang kemudian akan diakses melalui variabel Image_path. Selanjutnya impression pada tweet berupa teks yang didapat dari tweet itu sendiri, reply pada tweet tersebut, atau quote retweet pada tweet tersebut akan dimasukkan secara manual ke dalam satu buah array khusus yang berisi string kumpulan dari impresi yang ada pada suatu tweet. Kemudian, tweet yang didapat akan diberikan ID, mulai dari 1 hingga n tweet. Selanjutnya, semua data yang didapatkan akan disusun seperti Tabel VI.

Selanjutnya, pemrosesan dilakukan pada dataset yang tertera pada Tabel VI. Pertama, dilakukan klasifikasi citra jalan rusak atau normal. Jika citra yang didapat merupakan jalan normal, maka tweet dengan ID ini akan dilompati dan dilanjutkan pada ID berikutnya. Jika citra pada tweet merupakan jalan rusak, prediksi sentimen akan dilakukan pada impresi tweet yang tersimpan dalam variabel impression_dict. Sentimen yang didapatkan akan dihitung sesuai dengan kategorinya yaitu negative, positive, dan neutral. Jumlah sentimen akan disimpan ke dalam dataframe bersama dengan ID tweet. Kemudian, berdasarkan jumlah sentimen tiap kategori, skoring akan dilakukan. Skoring dilakukan dengan aturan sentimen negatif mendapat nilai +3, sentimen netral mendapat nilai 1, sentimen positif mendapat nilai -1. Skor yang didapat berdasarkan aturan akan dijumlahkan sehingga mendapatkan skor akhir. Tweet akan diurutkan berdasarkan skor yang paling tinggi ke skor yang paling rendah. Tweet dengan skor tertinggi akan dinyatakan sebagai tweet yang memiliki potensi untuk viral dan memiliki tingkat kerusakan jalan yang meresahkan masyarakat sehingga perlu segera ditangani. Tabel VII menunjukan contoh data input.

Tabel VII. Contoh data input

ID	image	impression_dict	link
1		["Jalannya banyak kolam nya [emot][emot][emot][emot]","Bak anekdot.; Di tempat lain lubang yang berjalan, ini jalan yang berlubang, cem mana pulak ini mas Chenu", "Gimana kalau pak PJ Gub Heru yg telp tanya tentang kondisi jalan yg	https://t.co/mH11M5MmXG / Twitter

		memprihatinkan???", "Setelah lampung timbul lah jawa tengah..jln rusak"]	er
2		["Ya begitulah kualitas infrastruktur buatan jokowi", "Perlu diaudit tuh yg dapat tender ngerjain proyek jalan tsb...[emot][emot]","Yang penting mah udah di kerjain, terus ada foto pengerjaan nya, kalo rusak lagi mah urusan belakangan[emot]"]	https://t.co/RpCRdCaJNA https://t.co/d35yniLcli / Twitter er
3		["Pemda Bogor bagai mana ini pak @ridwankamil semoga dengan followers bapak yang banyak bisa viralkan jalan raya Parung-Bogor yg banyak lubang dan banyak makan korban, apa harus nunggu viral dan berjatuhan korban ? @bogorkab @LesmanaRadio bantu viralkan #jalanberlubang", "kalau nggak salah jalan raya parung itu jalan nasional atau jalan ptovinsi", "Ustadz @AchFath mungkin bisa bantu advokasi..."]	https://t.co/AMfHycLkTP / Twitter er

Tabel VII. Hasil Implementasi

ID	Negative	Neutral	Positive	Skor
1	4	0	0	12
2	3	0	0	9
3	2	0	1	5

Tabel VII Menunjukkan bahwa ID 1 memiliki skor tertinggi. Hal ini menunjukkan bahwa tweet dengan ID 1 memiliki kecenderungan yang lebih tinggi untuk viral. Skor ini juga dapat menggambarkan bahwa masyarakat cukup merasa resah terhadap kondisi jalan pada tweet ini sehingga penanganan lebih lanjut diperlukan.

V. KESIMPULAN DAN SARAN

Secara keseluruhan, kedua model ini dapat digunakan untuk menjadi acuan dalam melakukan prediksi viralitas jalan rusak pada data twitter dengan pembobotan skor. Hal itu dibuktikan dengan nilai F1 sebesar 83% untuk model INDOBERT dan 86.1% untuk model YOLOv8. Namun, masih perlu dilakukan peningkatan efisiensi sistem.

Pada implementasi, model ini sudah mampu memberikan skor untuk masing-masing tweet yang digunakan untuk melakukan test. Namun, proses implementasi yang masih dilakukan secara manual masih memiliki banyak sekali kekurangan sehingga penelitian serta peningkatan efisiensi sistem perlu ditingkatkan.

Secara keseluruhan, kedua model ini dapat digunakan untuk menjadi acuan dalam melakukan prediksi viralitas jalan rusak pada data twitter dengan pembobotan skor.

REFERENSI

- [1] Badan Pusat Statistik, *Statistik Transportasi Darat 2021*. 2022.
- [2] M. J. Koohsari *dkk.*, "Public open space, physical activity, urban design and public health: Concepts, methods and research agenda," *Health Place*, vol. 33, hlm. 75–82, Mei 2015, doi: 10.1016/j.healthplace.2015.02.009.
- [3] Anonim, "Setelah Dikritik Bima 'Dajjal', Jalan Rusak di Lampung Mulai Diperbaiki Baca artikel detiksumut, "Setelah Dikritik Bima 'Dajjal', Jalan Rusak di Lampung Mulai Diperbaiki," *detik.com*, 20 April 2023.
- [4] Anonim, "Kriminalisasi Bima dan Ruang Aparat Usut Jalan Rusak di Lampung," *CNN Indonesia*, 18 April 2023.
- [5] F. Koto, A. Rahimi, J. H. Lau, dan T. Baldwin, "IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP," Online. [Daring]. Tersedia pada: <https://huggingface.co/>
- [6] J. Devlin, M.-W. Chang, K. Lee, K. T. Google, dan A. I. Language, "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding." [Daring]. Tersedia pada: <https://github.com/google/tensorflow/tensor2tensor>
- [7] F. Koto, J. H. Lau, dan T. Baldwin, "IndoBERTweet: A Pretrained Language Model for Indonesian Twitter with Effective Domain-Specific Vocabulary Initialization," Sep 2021, [Daring]. Tersedia pada: <http://arxiv.org/abs/2109.04607>
- [8] S. F. Pane, J. Ramdan, A. G. Putrada, M. N. Fauzan, R. M. Awangga, dan N. Alamsyah, "A Hybrid CNN-LSTM Model With Word-Emoji Embedding For Improving The Twitter Sentiment Analysis on Indonesia's PPKM Policy," dalam *2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, IEEE, Des 2022, hlm. 51–56. doi: 10.1109/ICITISEE57756.2022.10057720.
- [9] S. Alqethami, S. Alghamdi, T. Alsubait, dan H. Alhakami, "RoadNet: Efficient Model to Detect and Classify Road Damages," *Applied Sciences*, vol. 12, no. 22, hlm. 11529, Nov 2022, doi: 10.3390/app122211529.
- [10] V. Hegde, D. Trivedi, A. Alfarrarjeh, A. Deepak, S. Ho Kim, dan C. Shahabi, "Yet Another Deep Learning Approach for Road Damage Detection using Ensemble Learning," dalam *2020 IEEE International Conference on Big Data (Big Data)*, IEEE, Des 2020, hlm. 5553–5558. doi: 10.1109/BigData50022.2020.9377833.
- [11] "dwisaji/twitter-minggu-sentiment-dataset · Datasets at Hugging Face." <https://huggingface.co/datasets/dwisaji/twitter-minggu-sentiment-dataset> (diakses 16 Juni 2023).
- [12] B. Wilie *dkk.*, "IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding." [Daring]. Tersedia pada: <https://github.com/annisanurulazhar/absa-playground>
- [13] S. F. Pane, J. Ramdan, A. G. Putrada, M. N. Fauzan, R. M. Awangga, dan N. Alamsyah, "A Hybrid CNN-LSTM Model With Word-Emoji Embedding For Improving The Twitter Sentiment Analysis on Indonesia's PPKM Policy," dalam *2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, IEEE, Des 2022, hlm. 51–56. doi: 10.1109/ICITISEE57756.2022.10057720.
- [14] D. Arya, H. Maeda, S. K. Chosh, D. Toshniwal, dan Sekimoto. Yoshihide, "RDD2022: A multi-national image dataset for automatic Road Damage Detection," Sep 2022.
- [15] A. Basily, "Road Damage," *Kaggle*, 2020.