
Otomatisasi Penerusan Laporan Pengaduan Menggunakan Neural Network

Lukman Khoiruddin¹, Acihmah Sidauruk^{*2}, Yoga Pristyanto³, Muhammad Resa Arif Yudiyanto⁴, Hendra Kurniawan⁵

^{1,2,3,5}Sistem Informasi, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

⁴Fakultas Teknik, Universitas Muhammadiyah Magelang

Email: ¹lukman.kh@students.amikom.ac.id, ^{*2}acihmah@amikom.ac.id,
³yoga.pristyanto@amikom.ac.id, ⁴resamuhammad96@unimma.ac.id,
⁵hendrakurniawan@amikom.ac.id

(Naskah masuk: 4 April 2024, diterima untuk diterbitkan: 17 April 2024)

Abstrak: Saat ini terdapat sistem laporan pengaduan masyarakat yang sudah terintegrasi ke berbagai instansi. Sistem ini dikembangkan oleh Pemerintah Republik Indonesia bernama Sistem Layanan Aspirasi dan Pengaduan Online Rakyat (LAPOR!). Berdasarkan sistem LAPOR jumlah aduan yang masuk terus meningkat. Dengan adanya sistem ini berbagai aduan yang disampaikan oleh warga masyarakat dapat terintegrasi ke instansi yang berwenang menangani aduan tersebut. Dengan terintegrasinya sistem maka jumlah pengaduan yang masuk sangat banyak sehingga terdapat kendala pada saat proses verifikasi pengaduan yang nantinya akan diteruskan ke pihak yang berwenang. Tujuan penelitian ini adalah melakukan klasifikasi terhadap setiap laporan pengaduan dan mengetahui pengaruh terhadap Replace Slang Word. Dalam proses klasifikasi di penelitian ini menggunakan algoritma Artificial Neural Network. Jumlah data pengaduan yang digunakan adalah sebanyak 750 data pengaduan. Data tersebut terbagi menjadi 3 kategori yaitu bidang pendidikan, kesehatan dan infrastruktur. Untuk pembagian jumlah data dilakukan sama di setiap kategori. Pada tahapan Preprocessing menggunakan replace slang word sebagai pengganti kata slang terhadap kata aslinya. Hasil dari penelitian ini adalah menunjukkan nilai tinggi terhadap nilai Accuracy yaitu sebesar 99,33% untuk F1 score, Precision, dan Recall memiliki nilai yang sama yaitu 99,09%. Dengan hasil yang tinggi maka metode yang diusulkan dapat digunakan untuk melakukan pengklasifikasian terhadap laporan pengaduan.

Kata Kunci – Klasifikasi;Pengaduan;Neural Network, Replace Slang Word, Accuracy

Automation Of Forwarding Complaint Reports Using Neural Network

Abstract: Pengelolaan Pengaduan Pelayanan Publik (SP4N LAPOR!) is a service for conveying all aspirations and complaints of the Indonesian people through several complaint channels. With this system, complaints made by the community can be integrated and channeled to the appropriate agency/party. With the integration, the number of complaints that enter the system is very large so that there are obstacles in the complaint verification process to be forwarded to the competent authorities. The report classification process is needed to speed up the verification process and follow-up on complaints. The purpose of this study is to classify each complaint report and determine the effect of the Replace Slang Word stages. In this study, an Artificial Neural Network is used in the classification process for each complaint data by using a total of 750 complaint data and 3 categories namely education, health, and infrastructure in the distribution of the same amount of data in each category. In the Preprocessing stage use the Replace Slang Word stage to replace the slang words to the original words. With the results of using the Replace slang word stage it has a high value in accuracy namely 99.33%, for F1 score. Precision and recall the value is the same namely 99.09%. With high results from the model the proposed can be used in the classification of complaints reports.

Keywords – Classification, Complaint, Artificial Neural Network, Replace Slang Word, Accuracy

1. PENDAHULUAN

Pada saat ini pemanfaatan internet di Indonesia berkembang secara baik. Pemanfaatan internet dalam pelayanan publik telah dilakukan oleh berbagai pihak, baik swasta maupun pemerintah. Salah satu bentuknya adalah pengaduan masyarakat yang dapat dilakukan menggunakan berbagai jenis media sosial, SMS, dan website. Saat ini terdapat sistem laporan pengaduan masyarakat yang sudah terintegrasi ke berbagai pihak dan instansi. Sistem ini dikembangkan oleh Pemerintah Republik Indonesia bernama Sistem Pengelolaan Pengaduan Pelayanan Publik Nasional (SP4N) – Layanan Aspirasi dan Pengaduan Online Rakyat (LAPOR!). Sistem tersebut dapat diakses melalui website www.lapor.go.id. Berdasarkan sistem SP4N-LAPOR! rata-rata jumlah laporan yang masuk adalah 570 laporan per hari dan total pengguna yang terdaftar per Januari 2019 adalah 801.257 pengguna. Jumlah laporan yang masuk sejak 2012 berjumlah 1.389.891 laporan. Hingga tahun 2022 ini tingkat kepuasan masyarakat terhadap sistem pengaduan tersebut baru diangka 54% [1].

Sistem SP4N-LAPOR! telah terhubung dengan 34 Kementerian, 96 Lembaga, dan 493 pemerintah daerah. Sistem ini memudahkan dalam pengelolaan laporan pengaduan karena terpusat dan terintegrasi ke berbagai kementerian, lembaga, dan pemerintah daerah. Alur proses laporan di sistem tersebut dimulai dengan memasukkan laporan dan akan diverifikasi minimal 3 hari. Selanjutnya, laporan diteruskan ke pihak terkait dan akan diproses minimal 5 hari. Proses verifikasi berjalan lama, dikarenakan perlu pengecekan laporan oleh admin untuk mengetahui isi laporan dan pihak yang dituju. Dalam era digital yang terus berkembang, penanganan laporan pengaduan menjadi aspek penting bagi organisasi publik maupun swasta dalam mempertahankan kepercayaan dan kepuasan pelanggan. Tantangan muncul ketika volume pengaduan meningkat secara signifikan, melebihi kapasitas penanganan manual yang tersedia. Dalam mengatasi tantangan ini, teknologi otomatisasi menjadi solusi dengan pendekatan klasifikasi berbasis *machine learning* agar proses tersebut dapat dilakukan secara lebih efektif dan efisien [2].

Berbagai algoritma *machine learning* sudah banyak diterapkan dalam berbagai pendekatan klasifikasi. Salah satu algoritma tersebut yaitu *Naïve Bayes Classifier* (NBC) yang digunakan dalam melakukan analisis sentiment terhadap perilaku korupsi pejabat pemerintah berdasarkan data Twitter. Analisis sentiment yang dilakukan terhadap respon masyarakat dengan berbagai kategori diantaranya yaitu sentimen positif, negatif, marah, kecewa serta tingkat kepercayaan yang rendah. Hasil analisis menggunakan metode NBC tersebut mampu memperoleh tingkat akurasi sebesar 89,73% dengan dominasi sentiment negatif sebesar 224 dan 95 sentimen positif [3]. Penelitian lain dalam kasus analisis sentimen dapat juga dilakukan menggunakan algoritma *Support Vector Machine* (SVM) terhadap ulasan pengguna. Dalam penelitian tersebut, dilakukan perbandingan algoritma NBC dan SVM dengan kombinasi ekstraksi fitur dengan TF-IDF dan Word2Vec. Hasil perbandingan dari keempat skenario tersebut menunjukkan kinerja algoritma SVM dengan TF-IDF lebih stabil dan lebih baik dibanding algoritma NBC dengan tingkat akurasi sebesar 86,90% [4].

Selain analisis sentimen, algoritma *machine learning* juga dapat digunakan dalam melakukan otomatisasi pemrosesan laporan pengaduan. Penelitian [5] tersebut menggunakan kombinasi metode *Latent Dirichlet Allocation* (LDA) dan SVM dalam mengekstrak setiap laporan aduan yang masuk untuk diteruskan kepada instansi terkait sesuai dengan pola dan kecocokan kategori dari konten/dokumen pengaduan. Total dataset yang digunakan sebanyak 1436 data dengan jumlah 44 instansi yang diperoleh dari proses scrapping. Melalui pra proses, terdapat validasi manual dan ditemukan 512 laporan yang tidak sesuai proses disposisinya. Sehingga data akhir yang digunakan sebanyak 924 data tersebar ke dalam 4 instansi secara tidak seimbang. Pembagian data rasio data latih dan data uji sebanyak 70:30 mampu menghasilkan tingkat akurasi yang kurang baik yaitu 79,85%.

Penelitian lain membandingkan antara pendekatan *Deep Learning Neural Network* (DLNN) dengan berbagai algoritma *machine learning* diantaranya SVM, *C4.5 Decision Tree*, dan *Random Forest* dalam pembuatan alat alternatif dalam penilaian kerentanan tanah longsor. Berbagai variable independent yang digunakan dalam analisis tersebut diantaranya yaitu ketinggian, kemiringan,

aspek, penggunaan lahan, NDVI, jenis tanah, jarak ke sesar, jarak ke batas geologi dan litologi. Hasil penelitian tersebut menunjukkan hasil bahwa model DLNN mendapatkan kinerja tertinggi dalam mengklasifikasikan tanah longsor dengan tingkat akurasi sebesar 95,02%, disusul model MLP-NN 82,00%, model SVM 81,01%, model C4.5 80,51% dan model RF sebesar 75,12% [6]. Dari hasil penelitian tersebut menunjukkan bahwa kinerja algoritma *deep learning* menggunakan *Neural Network* lebih unggul dibandingkan algoritma *machine learning* konvensional.

Selain algoritma yang mempengaruhi kinerja model klasifikasi, terdapat faktor lain yang memiliki dampak signifikan terhadap tingkat keakuratan model. Pembagian rasio dataset untuk data latih dan data uji sangat berpengaruh terhadap kinerja model [7]. Penelitian lain tentang klasifikasi wayang punakawan dengan algoritma *Convolutional Neural Network* (CNN) membandingkan berbagai skenario percobaan. Dalam skenario tersebut salah satunya yaitu membandingkan berbagai rasio dataset *training* dan *testing*. Dari hasil percobaan yang dilakukan menunjukkan bahwa rasio 80:20 yaitu 80% untuk data *training* dan 20% untuk data *testing* memperoleh hasil yang lebih stabil dan paling unggul dibandingkan rasio yang lain [8].

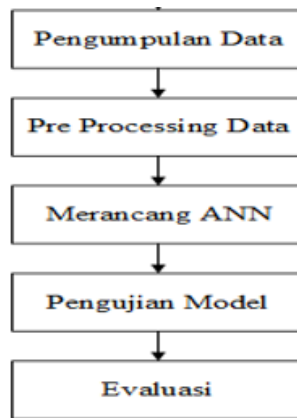
Berbagai tantangan analisis teks dalam *machine learning* diantaranya adalah banyaknya data yang tidak normal. Saat ini tidak hanya dikarenakan ketidaklengkapan data, kehilangan data (*missing value*), akan tetapi semakin banyak kata-kata dan kalimat yang ada di media sosial saat ini menggunakan bahasa gaul dan terkesan tidak mengikuti aturan dan ejaan yang sesuai. Hal tersebut (*slang word*) menjadi faktor penting yang berdampak terhadap kinerja model klasifikasi, oleh sebab itu perlunya penambahan pra proses terhadap penormalan kata-kata dan kalimat tidak baku [9], agar dataset menjadi lebih normal sebelum dilakukan proses pembelajaran. Dataset yang sudah dinormalisasi dari kata-kata tidak baku dapat meningkatkan kinerja model seperti penelitian [10] yang mampu menaikkan 3,5% nilai akurasi setelah melakukan tahap pra proses dengan menghilangkan kata-kata tidak baku (*slang word*).

Tingkat keberhasilan sebuah model dalam mengklasifikasikan sebuah teks tidak terlepas dari metode ekstraksi fitur yang digunakan. Berbagai penelitian telah membandingkan metode ekstraksi fitur teks seperti Word2Vec dan TF-IDF telah dibandingkan terhadap pengenalan emosi manusia berdasarkan dari teks. Penelitian tersebut menggunakan 4 skenario terhadap algoritma NBC dan SVM dan memperoleh hasil bahwa TF-IDF lebih unggul dibandingkan dengan skenario Word2Vec berdasarkan dari parameter akurasi [11] [12]. Selain kinerja TF-IDF yang bagus, metode ini lebih mampu mengenali kemiripan data dibandingkan metode Word2Vec yang memerlukan dataset dalam jumlah yang besar. Sehingga proses komputasi dengan metode TF-IDF akan lebih ringan dan biaya komputasi yang lebih murah dibandingkan dengan metode Word2Vec [13].

Berdasarkan penelitian diatas akan dilakukan text classification untuk mengklasifikasikan setiap laporan ke kategori yang sesuai. Dalam penelitian ini menggunakan pra proses tambahan yaitu menormalkan kata tidak baku (*slang word*) karena laporan pengaduan dapat berasal dari mana saja dan semua kalangan yang memungkinkan terdapat bahasa slang/gaul dalam isi pengaduan. Algoritma yang digunakan yaitu *Artificial Neural Networks* yang memiliki keunggulan dibandingkan algoritma-algoritma *machine learning* secara konvensional yang dikombinasikan dengan metode TF-IDF yang memiliki peran dalam ekstraksi fitur.

2. METODE PENELITIAN

Tahapan penelitian menggambarkan dan menjelaskan tentang urutan penelitian. Tahapan penelitian ditunjukkan pada gambar 1 berikut



Gambar 1. Alur Penelitian

2.1. Pengumpulan Data

Dataset penelitian berupa data pengaduan yang berasal dari www.lapor.go.id yang dibagi dalam tiga kategori, yaitu kesehatan, pendidikan, dan infrastruktur. Data tersebut disimpan dalam format csv yang memiliki kolom teks dan label. Kolom teks berisi isi aduan dan kolom label berisi pelabelan kategori aduan.

2.2. Pre Processing Data

Proses ini digunakan untuk membersihkan data dari *noise* supaya siap untuk digunakan pada proses selanjutnya. Data yang dilakukan dalam preprocessing adalah data aduan dan memiliki beberapa tahapan-tahapan, yaitu Data Cleaning, Case Folding, Replace Slang Words, Stopword Removal, Stemming, dan Tokenizing.

2.2.1. Data Cleaning

Data cleaning merupakan tahapan membersihkan data teks dari kata yang tidak diperlukan untuk mengurangi *noise*. Kata yang dihilangkan dalam dokumen teks antara lain karakter HTML, emoticons, hastag (#) dan URL.

2.2.2. Case Folding

Case Folding merupakan tahapan untuk mengubah semua karakter teks menjadi non kapital (*lower case*) serta menghilangkan tanda baca. Dalam penelitian ini untuk merubah teks menjadi *lower case* menggunakan modul yang disediakan *python*. Untuk menghilangkan tanda baca menggunakan modul *Regular Expression (regex)*.

2.2.3. Replace Slang Words

Replace Slang Word merupakan tahapan untuk mengubah kata slang / bahasa gaul ke kata aslinya. Sehingga mengurangi kata yang dihilangkan karena tidak memiliki makna. Dalam penelitian ini menggunakan dua sumber data kamus slang yang digunakan untuk menjadi rujukan. Data pertama dari <https://raw.githubusercontent.com/fendiirfan/Kamus-Alay/main/Kamus-Alay.csv> dan data kedua dari <https://raw.githubusercontent.com/nasalsabila/kamus-alay/master/colloquial-indonesian-lexicon.csv>.

2.2.4. Stopword Removal

Stopword Removal merupakan tahapan proses untuk menghapus kata-kata yang tidak memiliki arti yang relevan. Kata yang tidak memiliki arti yang sesuai akan dihilangkan untuk mendapatkan ciri dari dokumen. Contoh kata yang perlu dihilangkan yakni seperti " ini, itu, dan,

atau" dan banyak lagi kata-kata sejenis. Dalam penelitian ini menggunakan library Sastrawi untuk melakukan stopword removal.

2.2.5. Stemming

Stemming merupakan tahapan proses menghilangkan imbuhan (infeksi) kata ke bentuk dasarnya, namun bentuk dasar tersebut tidak berarti sama dengan akar kata (*root word*). Misalnya, kata "mendengarkan", "dengarkan", "didengarkan" akan ditransformasi menjadi kata "dengar". Untuk melakukan proses stemming menggunakan library Sastrawi yang menerapkan Algoritma Nazief dan Adriani dalam melakukan *stemming* bahasa Indonesia.

2.2.6. Tokenizing

Tokenizing merupakan tahapan proses untuk memecah keseluruhan data teks dari kalimat menjadi kata per kata. Kata yang dipecah tersebut dinamai token.

2.3. Merancang ANN

Setelah tahapan preprocessing data dilakukan tahapan selanjutnya adalah pemberian bobot pada setiap kata dengan menggunakan metode TF-IDF, tahap selanjutnya melakukan split validation, kemudian merancang model ANN dan melatih model dengan data training.

2.3.1. Pembobotan TF-IDF

Term Frequency Inverse Document Frequency (TF-IDF) merupakan metode pembobotan yang dilakukan untuk ekstraksi data teks. Tujuan dari TF-IDF adalah menemukan jumlah kata yang diketahui (tf) setelah dikalikan dengan frekuensi aduan, dimana suatu kata tersebut muncul (idf). Metode TF-IDF dilakukan dengan menghitung bobot dengan cara integrasi antara term frequency (tf) dan inverse document frequency (idf). Metode TF-IDF digunakan untuk mengetahui berapa sering suatu kata muncul di dalam dokumen. Langkah pertama adalah menghitung nilai term frequency tiap kata. Langkah kedua adalah menghitung nilai document frequency tiap kata. Langkah ketiga adalah menghitung inverse document frequency dan langkah terakhir yaitu menghitung bobot atau weight dari hasil perkalian term frequency dikalikan dengan inverse document frequency [ref].

2.3.2. Split Validation

Split Validation merupakan teknik validasi yang membagi data menjadi dua bagian secara acak, yaitu data training dan data testing. Pada penelitian ini menggunakan split validation *test error* yaitu membagi data set menjadi data training dan data testing secara terpisah. Jumlah pembagiannya 80% untuk data training dan 20% untuk data testing.

2.3.3. Klasifikasi

Merupakan proses klasifikasi dengan algoritma ANN. Sebelum melakukan klasifikasi maka tahapan yang dilakukan adalah *Learning Model* dengan cara melatih model menggunakan data latih yang berjumlah 80% dari dataset. Setelah model selesai dilatih, selanjutnya dilakukan *testing model* menggunakan data testing yang berjumlah 20% dari dataset.

3. HASIL DAN PEMBAHASAN

3.1. Data Cleaning

Dalam penelitian ini menggunakan modul *Regular Expression (regex)* dalam melakukan data cleaning. Berikut tabel data yang telah dilakukan data cleaning.

Tabel 1. Data Cleaning

Sebelum Data Cleaning	Sesudah Data Cleaning
Lampu penerangan jalan di JL SUKAMEKAR RT/RW 06/05 KELURAHAN SUKAWARNA KECAMATAN SUKAJADI KOTA BANDUNG ada 1penerangan jalan yang masih mati (sepertinya terlewat dari penerangan sebelumnya) lokasi nya ada di paling ujung jalan sukamekar 1 (rumah tusuk sate) mohon bantuan agar bisa dihidupkan. Karena di lokasi tersebut sangat gelap tidak ada penerangan sama sekali. Terima kasih. #LAPOR	Lampu penerangan jalan di JL SUKAMEKAR RT/RW 06/05 KELURAHAN SUKAWARNA KECAMATAN SUKAJADI KOTA BANDUNG ada 1penerangan jalan yang masih mati (sepertinya terlewat dari penerangan sebelumnya) lokasi nya ada di paling ujung jalan sukamekar 1 (rumah tusuk sate) mohon bantuan agar bisa dihidupkan. Karena di lokasi tersebut sangat gelap tidak ada penerangan sama sekali. Terima kasih.LAPOR
pak jalan sabili di lingkungan x kel. binjai estate kec. binjai selatan kapan ya akan diperbaiki? berikut saya lampirkan foto dan lokasi google map https://goo.gl/maps/997pvzqqevlq3gnb9 mohon responnya pak untuk kondisi binjai yang lebih baik. terima kasih	pak jalan sabili di lingkungan x kel. binjai estate kec. binjai selatan kapan ya akan diperbaiki? berikut saya lampirkan foto dan lokasi google map mohon responnya pak untuk kondisi binjai yang lebih baik. terima kasih

Pada Tabel 1 di atas menggambarkan data laporan yang belum dilakukan data cleaning dan sesudah dilakukan data cleaning. Data aduan yang belum dilakukan data cleaning terdapat URL. Kemudian, URL tersebut dihilangkan setelah dilakukan data cleaning. Pada data ke 1 terdapat karakter hastag (#) dan pada data ke 2 terdapat URL, sehingga dalam proses *data cleaning* akan dibersihkan.

3.2. Case Folding

Hasil proses case folding pada penelitian ini ditunjukkan pada tabel 2 berikut.

Tabel 2. Case Bolding

Sebelum Case Folding	Sesudah Case Folding
Lampu penerangan jalan di JL SUKAMEKAR RT/RW 06/05 KELURAHAN SUKAWARNA KECAMATAN SUKAJADI KOTA BANDUNG ada 1penerangan jalan yang masih mati (sepertinya terlewat dari penerangan sebelumnya) lokasi nya ada di paling ujung jalan sukamekar 1 (rumah tusuk sate) mohon bantuan agar bisa dihidupkan. Karena di lokasi tersebut sangat gelap tidak ada penerangan sama sekali. Terima kasih.LAPOR	lampu penerangan jalan di jl sukamekar rtw kelurahan sukawarna kecamatan sukajadi kota bandung ada penerangan jalan yang masih mati seperti terlewat dari penerangan sebelumnya lokasi nya ada di paling ujung jalan sukamekar rumah tusuk sate mohon bantuan agar bisa dihidupkan karena di lokasi tersebut sangat gelap tidak ada penerangan sama sekali terima kasih lapor
pak jalan sabili di lingkungan x kel. binjai estate kec. binjai selatan kapan ya akan diperbaiki? berikut saya lampirkan foto dan lokasi google map mohon responnya pak untuk kondisi binjai yang lebih baik. terima kasih	pak jalan sabili di lingkungan x kel binjai estate kec binjai selatan kapan ya akan diperbaiki berikut saya lampirkan foto dan lokasi google map mohon responnya pak untuk kondisi binjai yang lebih baik terima kasih

3.3. Replace Slang Words

Apabila data aduan ditemukan kata slang atau singkatan yang sama dengan di kamus kata slang, maka akan dilakukan pergantian (*replace*) kata dengan kata aslinya. Proses replace slang words menggunakan cara perulangan untuk mengecek kata slang/gaul dan singkatan di setiap data aduan. Apabila ditemukan kata slang/gaul atau kata singkatan, maka akan dilakukan pergantian (*replace*) kata sesuai rujukan dari kamus slang yang digunakan.

Tabel 3. Kamus Slang

Kata Slang/Gaul	Kata Asli
se7	setuju
t4	tempat
uplot	unggah
jl	jalan
maaciw	Terima kasih

spp	Sumbangan pendidikan	pembinaan
-----	----------------------	-----------

3.4. Stopword Removal

Proses *stopword removal* menggunakan library *sastrawi* untuk kata *stopword* menggunakan bawaan dari *sastrawi* dan kata *stopword* yang ditambahkan oleh peneliti. Proses *stopword removal* ditunjukkan pada tabel 4.

Tabel 4. Stopword Removal

Stopword Removal dari Sastrawi	Stopword Removal Tambahan Peneliti
'ada'	'oleh'
'adalah'	'dengan'
'adanya'	'bahwa'
'adapun'	'kepada'
'agak'	'kpd'
'agaknya'	'yth'

Kata dalam *stopword* yang digunakan berasal dari bawaan *sastrawi* dan kata yang ditambahkan oleh peneliti. Dalam isi data aduan terdapat berbagai kata yang tidak memiliki arti relevan dengan klasifikasi karena hal ini peneliti menambahkan kata *stopword* yang telah disesuaikan. Berikut tabel 5 hasil proses *stopword removal*.

Tabel 5. Proses Stopword Removal

Sebelum Stopword Removal	Sesudah Stopword Removal
lampu penerangan jalan di jalan sukamekar rtrw kelurahan sukawarna kecamatan sukajadi kota bandung ada penerangan jalan yang masih mati sepertinya terlewat dari penerangan sebelumnya lokasi nya ada di paling akhirnya jalan sukamekar rumah tusuk sate mohon bantuan agar bisa dihidupkan karena di lokasi tersebut sangat gelap tidak ada penerangan sama sekali terima kasih lapor	lampu penerangan jalan jalan sukamekar sukawarna sukajadi bandung penerangan jalan masih mati terlewat penerangan lokasi jalan sukamekar rumah tusuk sate bantuan dihidupkan lokasi gelap penerangan lapor
pak jalan sabili di lingkungan kali kelurahan binjai estate kecamatan binjai selatan kapan iya akan diperbaiki berikut saya lampirkan foto dan lokasi google map mohon responnya pak untuk kondisi binjai yang lebih baik terima kasih	jalan sabili lingkungan kali binjai estate binjai selatan diperbaiki lampirkan foto lokasi google map responnya kondisi binjai

Pada tabel 5 menggambarkan hasil dari proses *stopword removal* yang sebelum dilakukan *stopword* dan sesudah *stopword*. *Stopword removal* berfungsi untuk mengurangi kata yang tidak relevan dengan klasifikasi dengan proses ini isi data aduan yang akan diklasifikasi hanya berisi data yang sesuai dengan penelitian. Proses *stopword* dalam penelitian menggunakan library *sastrawi* dengan modul *stopword*, jika terdapat kata yang sesuai dengan kamus *stopword* maka akan dihapus.

3.5. Stemming

Stemming merupakan tahapan proses menghilangkan imbuhan (infeksi) kata ke bentuk dasarnya, agar mempermudah dalam tahap pembobotan. Proses stemming pada penelitian menggunakan algoritma *Nazief* dan *Adriani* pada *Library Sastrawi*. Berikut tabel 6 proses *Stemming*.

Tabel 6. Proses Stemming

Sebelum Stemming	Sesudah Stemming
lampu penerangan jalan jalan sukamekar sukawarna sukajadi bandung penerangan jalan masih mati terlewat penerangan lokasi jalan	lampu terang jalan jalan sukamekar sukawarna sukajadi bandung terang jalan masih mati

sukamekar rumah tusuk sate bantuan dihidupkan lokasi gelap penerangan lapor	terang lokasi jalan sukamekar rumah tusuk sate bantu hidup lokasi gelap terang lapor
jalan sabili lingkungan kali binjai estate binjai selatan diperbaiki lampirkan foto lokasi google map responnya kondisi binjai	jalan sabili lingkungan kali binjai estate binjai selatan baik lampir foto lokasi respon kondisi binjai

Pada tabel 6 menjelaskan hasil proses *stemming* dari data aduan. Sebelum proses *stemming* maka disetiap dari data aduan terdapat kata imbuhan (*infeksi*) dengan melakukan *stemming* maka menghilangkan kata imbuhan (*infeksi*) menjadi kata dasar.

3.6. Tokenizing

Tokenizing merupakan proses untuk memisahkan keseluruhan data teks yang sebelumnya berupa kalimat menjadi kata per kata atau token. Dalam tahap ini mempermudah dalam proses klasifikasi karena data dipecah dalam per kata atau token. Berikut tabel 7 hasil proses *Tokenizing*.

Tabel 7. Hasil Tokenizing

Sebelum Tokenizing	Sesudah Tokenizing
lampu terang jalan jalan sukamekar sukawarna sukajadi bandung terang jalan masih mati terang lokasi jalan sukamekar rumah tusuk sate bantu hidup lokasi gelap terang lapor	'lampu', 'terang', 'jalan', 'jalan', 'sukamekar', 'sukawarna', 'sukajadi', 'bandung', 'terang', 'jalan', 'masih', 'mati', 'terang', 'lokasi', 'jalan', 'sukamekar', 'rumah', 'tusuk', 'sate', 'bantu', 'hidup', 'lokasi', 'gelap', 'lapor'
jalan sabili lingkungan kali binjai estate binjai selatan diperbaiki lampirkan foto lokasi google map responnya kondisi binjai	'jalan', 'sabili', 'lingkungan', 'kali', 'binjai', 'estate', 'selatan', 'baik', 'lampir', 'foto', 'lokasi', 'responnya', 'kondisi',

3.7. Pembobotan TF-IDF

Term Frequency Inverse Document Frequency (TFIDF) merupakan metode pembobotan yang dilakukan untuk setiap *term* data teks. Data teks yang dilakukan pembobotan yaitu data isi aduan yang sudah melewati proses *preprocessing*. Proses ini bertujuan untuk memberikan nilai kepada setiap *term* yang digunakan sebagai input pada proses klasifikasi. Berikut tabel 8 hasil perhitungan TF dan IDF.

Tabel 8. Perhitungan TF Dan IDF

Term	TF		IDF	
	Teks 1	Teks 2	df	Log (n/df)
lampu	1	0	1	0.30102999566398
terang	4	0	1	0.30102999566398
jalan	4	1	2	0
sukamekar	2	0	1	0.30102999566398
sukawarna	1	0	1	0.30102999566398
sukajadi	1	0	1	0.30102999566398
bandung	1	0	1	0.30102999566398
masih	1	0	1	0.30102999566398
mati	1	0	1	0.30102999566398
lokasi	2	1	2	0
rumah	1	0	1	0.30102999566398
tusuk	1	0	1	0.30102999566398
sate	1	0	1	0.30102999566398
bantu	1	0	1	0.30102999566398
hidup	1	0	1	0.30102999566398
gelap	1	0	1	0.30102999566398
lingkungan	0	1	1	0.30102999566398
kali	0	1	1	0.30102999566398
binjai	0	3	1	0.30102999566398

estate	0	1	1	0.30102999566398
selatan	0	1	1	0.30102999566398
baik	0	1	1	0.30102999566398
lampir	0	1	1	0.30102999566398
foto	0	1	1	0.30102999566398
respon	0	1	1	0.30102999566398
kondisi	0	1	1	0.30102999566398

Dari tabel 8 dapat diketahui nilai TF dan IDF pada setiap kata (*term*). Proses selanjutnya dengan menghitung pembobotan TF-IDF dengan persamaan (1). Berikut tabel 9 hasil pembobotan TF-IDF.

Tabel 9. Hasil Pembobotan TF-IDF

Term	TF * IDF	
	Teks 1	Teks 2
lampu	0.30102999566398	0
terang	0.30102999566398	0
jalan	0	0
sukamekar	0.30102999566398	0
sukawarna	0.30102999566398	0
sukajadi	0.30102999566398	0
bandung	0.30102999566398	0
masih	0.30102999566398	0
mati	0.30102999566398	0
lokasi	0	0
rumah	0.30102999566398	0
tusuk	0.30102999566398	0
sate	0.30102999566398	0
bantu	0.30102999566398	0
hidup	0.30102999566398	0
gelap	0.30102999566398	0
linkungan	0	0.30102999566398
kali	0	0.30102999566398
binjai	0	0.30102999566398
estate	0	0.30102999566398
selatan	0	0.30102999566398
baik	0	0.30102999566398
lampir	0	0.30102999566398
foto	0	0.30102999566398
respon	0	0.30102999566398
kondisi	0	0.30102999566398

Pada tabel 9 dapat diketahui nilai pembobotan pada setiap kata (*term*). Nilai pembobotan ini akan digunakan dalam proses klasifikasi

3.8. Split Validation

Split Validation merupakan teknik validasi yang membagi data menjadi dua bagian secara acak, sebagian sebagai data training dan sebagian sebagai data testing. Pada penelitian ini menggunakan split validation *test error* yaitu membagi data set menjadi data training dan data testing secara terpisah. Data set dibagi dengan jumlah yang berbeda masing-masing 80% untuk data training dan 20% untuk data testing. Berikut gambar 2 Split Validation.

```
X_train, X_test, y_train, y_test = train_test_split(
    data_bersih,
    label,
    test_size=0.2,
    random_state=123)
```

Gambar 2. Split Validation

Pada gambar 2 menjelaskan penggunaan *split validation* dengan membagi data training dan data testing. $test_size=0.2$ digunakan untuk membagi data test sebesar 20% maka data training sebesar 80% maka jumlah data test sebanyak 150 data dan untuk data training sebanyak 600 data.

3.9. Pengujian Model

Pengujian model dilakukan dengan tujuan mengetahui kinerja ANN dalam proses klasifikasi. Pengujian dengan memasukan data testing yang sebesar 20% dalam beberapa skenario pengujian. Berikut tabel 10 Skenario Pengujian Model.

Tabel 10 Skenario Pengujian

Skenario Pengujian	80% Data Training dan 20% Data Testing	
	Dengan Replace Slang Words	Tanpa Replace Slang Words
Skenario 1	Epoch 20	Epoch 20
Skenario 2	Epoch 50	Epoch 50
Skenario 3	Epoch 100	Epoch 100

Pada tabel 10 menjelaskan skenario yang dilakukan dalam pengujian model. Dataset dibagi dua yaitu data training sebanyak 600 data dan data testing sebanyak 150 data. Pengujian model dengan tujuan untuk mengetahui kinerja ANN dalam proses klasifikasi dan juga membandingkan dalam menggunakan tahap preprocessing yaitu replace slang words dan dan tanpa replace slang words, selain itu juga menguji dalam penggunaan epoch dengan jumlah yang berbeda.

3.10. Evaluasi

Evaluasi kinerja *Artificial Neural Network* dalam klasifikasi pengaduan menggunakan *Confusion Matrix* berdasarkan model yang telah dibuat. *Confusion Matrix multiclass* yang digunakan dalam evaluasi dikarenakan terdiri 3 kelas dalam kasus ini. Penilaian ketepatan klasifikasi untuk *multiclass classification* didefinisikan perkelas. Kualitas keseluruhan klasifikasi dapat dinilai dengan dua cara yakni melalui rata-rata dari tiap kriteria yang dihitung untuk setiap kelasnya (*macro-averaging*) atau jumlah penghitungan untuk mendapatkan kumulatif TP; FN, TN, dan FP (*micro-averaging*). Berikut tabel 11 *Confusion Matrix Multiclass*.

Tabel 11 *Confusion Matrix Multiclass*

Kelas Aktual	Replace Slang Word			Tanpa Replace Slang Word		
	Kelas Prediksi			Kelas Prediksi		
	Label 0	Label 1	Label 2	Label 0	Label 1	Label 2
Label 0	54	0	0	54	0	0
Label 1	0	46	1	0	46	1
Label 2	0	0	49	0	1	48

Pada tabel 11 menggambarkan hasil confusion matrix multiclass dari evaluasi model. Dari tabel diatas digunakan untuk mencari nilai TP, FN, FP, dan TN yang akan digunakan dalam perhitungan kriteria evaluasi yaitu *Accuracy*, *F1 Score*, *Precision*, dan *Recall*. Berikut tabel 12 Nilai Setiap Kelas Label.

Tabel 12 Nilai Setiap Class Label

Kelas Label	Replace Slang Words				Tanpa Replace Slang Words			
	TP	FN	FP	TN	TP	FN	FP	TN
Label 0	54	0	0	96	54	0	0	96
Label 1	46	1	0	103	46	1	1	102
Label 2	49	0	1	100	48	1	1	100

Pada tabel 12 dapat diketahui nilai TP, FN, FP, dan TN pada setiap kelas label. Dengan nilai yang didapat maka dilanjutkan perhitungan dengan rumus untuk mencari setiap kriteria evaluasi. Berikut tabel 13 hasil perhitungan kriteria perfoma

Tabel 13 Hasil Perhitungan Kriteria Performa

Evaluasi		Dengan Replace Slang Words	Tanpa Replace Slang Words
Skenario 1	Loss	4.93 %	4.71 %
	Accuracy	99.33%	98.67 %
	F1 Score	99.09%	98.47 %
	Precision	99.09%	98.47 %
	Recall	99.09%	98.47 %
Skenario 2	Loss	4.10 %	3.97 %
	Accuracy	99.33%	98.67 %
	F1 Score	99.09%	98.47 %
	Precision	99.09%	98.47 %
	Recall	99.09%	98.47 %
Skenario 3	Loss	4.12 %	3.97 %
	Accuracy	99.33%	98.67 %
	F1 Score	99.09%	98.47 %
	Precision	99.09%	98.47 %
	Recall	99.09%	98.47 %

Pada tabel 13 berisi hasil perhitungan setiap kriteria perfoma pada setiap skenario pengujian. Dari tabel diatas dapat diketahui jika nilai kriteria Accuracy berbeda untuk pengujian dengan menggunakan *replace slang words* dan tidak menggunakan *replace slang words*, untuk kriteria F1 Score, Precision, dan Recall bernilai sama dalam pengujian dengan menggunakan *replace slang words* dan tidak menggunakan *replace slang words*. Selain itu skenario dengan merubah nilai epoch tidak berpengaruh dalam kriteria perfoma, bisa dilihat dari tabel diatas untuk nilai kriteria pada setiap skenario sama. Nilai Loss adalah nilai *training loss* yaitu nilai dari penghitungan loss function dari training dataset dan prediksi dari modelnya. Nilai loss dapat berubah-ubah dalam setiap pengujian model namun perbedaanya tidak signifikan.

4. KESIMPULAN

Berdasarkan peneltian dan hasil pengujian metode Neural Network untuk klasifikasi laporan pengaduan di sistem LAPOR! , maka diperoleh kesimpulan yaitu: Hasil pengujian model neural network dengan menggunakan data testing sebesar 20% dan replace slang words pada preprocessing data dengan hasil Accuracy 99.33%, F1 Score 99.09%, Precision 99.09%, Recall 99.09%. Algoritma Neural Network memiliki perfoma yang sangat baik dalam klasifikasi laporan pengaduan. Hal ini dapat dilihat dari hasil pengujian dengan menggunakan replace slang words mempunyai nilai kriteria Accuracy 99.33%, F1 Score 99.09%, Precision 99.09%, Recall 99.09%. Tidak menggunakan replace slang words memiliki nilai kriteria Accuray 98.67%, F1 Score 98.47 %, Precision 98.47 %, Recall 98.47%. Pada pengujian ke-2 mendapatkan penurunan nilai Accuracy.F1 Score, Precision, dan Reacll, akan tetapi tidak berpengaruh signifikan dikarenakan masih adanya perbedaan antara nilai kriteria perfoma dengan menggunakan replace slang words dan tanpa replace slang words.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada fakultas ilmu komputer serta lembaga penelitian dan pengabdian masyarakat Universitas Amikom Yogyakarta yang telah memberikan dukungan terlaksananya penelitian ini.

DAFTAR PUSTAKA

- [1] Mujiono, “Kualitas Layanan Sebagai Upaya Kepuasan Masyarakat Pemanfaat Media Sosial Dan Sms Center Sebagai Sarana Pengaduan”. , Jurnal Ilmu Manajemen, vol. 9, no. , Jun.2020.
- [2] S. Wulandari, “PENINGKATAN KUALITAS PELAYANAN PUBLIK MELALUI APLIKASI PENGADUAN SP4N-LAPOR! PADA KEMENTERIAN PENDAYAGUNAAN APARATUR NEGARA DAN REFORMASI BIROKRASI,” *Jurnal Ilmiah Wahana Bhakti Praja*, vol. 13, no. 2, pp. 152–166, Oct. 2023, doi: 10.33701/jiwbp.v13i2.3627.
- [3] A. Syakir and F. N. Hasan, “JURNAL MEDIA INFORMATIKA BUDIDARMA Analisis Sentimen Masyarakat Terhadap Perilaku Korupsi Pejabat Pemerintah Berdasarkan Tweet Menggunakan Naive Bayes Classifier,” vol. 7, pp. 1796–1805, 2023, doi: 10.30865/mib.v7i4.6648.
- [4] M. Daffa Dhiyaulhaq and P. Harry Gunawan, “JURNAL MEDIA INFORMATIKA BUDIDARMA Sentiment Analysis of the Jakarta-Bandung Fast Train Project Using the SVM Method,” vol. 7, pp. 2128–2136, 2023, doi: 10.30865/mib.v7i4.6855.
- [5] “A. Muhammad, A.R. Baskara, M. Irham, “KLASIFIKASI LAPORAN KELUHAN PELAYANAN PUBLIK BERDASARKAN INSTANSI MENGGUNAKAN METODE LDA-SVM”, *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 8, no. 6, Des. 2021.
- [6] D. T. Bui, P. Tsangaratos, V. T. Nguyen, N. Van Liem, and P. T. Trinh, “Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment,” *Catena (Amst)*, vol. 188, May 2020, doi: 10.1016/j.catena.2019.104426.
- [7] A. Rácz, D. Bajusz, and K. Héberger, “Effect of dataset size and train/test split ratios in qsar/qspr multiclass classification,” *Molecules*, vol. 26, no. 4, Feb. 2021, doi: 10.3390/molecules26041111.
- [8] M. Resa Arif Yudianto and H. Al Fatta, “ANALISIS PENGARUH TINGKAT AKURASI KLASIFIKASI CITRA WAYANG DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK.”
- [9] M. A. Palomino and F. Aider, “Evaluating the Effectiveness of Text Pre-Processing in Sentiment Analysis,” *Applied Sciences (Switzerland)*, vol. 12, no. 17, Sep. 2022, doi: 10.3390/app12178765.
- [10] S. K. Dirjen, P. Riset, D. Pengembangan, R. Dikti, S. Khomsah, and A. S. Aribowo, “Terakreditasi SINTA Peringkat 2 Model Text-Preprocessing Komentar Youtube Dalam Bahasa Indonesia,” *masa berlaku mulai*, vol. 1, no. 3, pp. 648–654, 2017.
- [11] D. E. Cahyani and I. Patasik, “Performance comparison of tf-idf and word2vec models for emotion text classification,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 5, pp. 2780–2788, Oct. 2021, doi: 10.11591/eei.v10i5.3157.
- [12] H. D. Abubakar and M. Umar, “Sentiment Classification: Review of Text Vectorization Methods: Bag of Words, Tf-Idf, Word2vec and Doc2vec,” *SLU Journal of Science and Technology*, vol. 4, no. 1 & 2, pp. 27–33, Aug. 2022, doi: 10.56471/slujst.v4i.266.
- [13] H. Kusniyati and A. A. Nugraha, “Analysis of Matric Product Matching Between Cosine Similarity with Term Frequency-Inverse Document Frequency (TF-IDF) and Word2Vec in PT. Pricebook Digital Indonesia,” *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, pp. 105–112, Jan. 2020, doi: 10.32628/cseit195672.