

INSTAGRAM-BASED SENTIMENT ANALYSIS ON THE OIL REFINERY PROJECT IN BATAM USING SVM AND XGBOOST

ANALISIS SENTIMEN PENGGUNA INSTAGRAM TERHADAP RENCANA PEMBANGUNAN KILANG MINYAK DI BATAM MENGGUNAKAN SVM DAN XGBOOST

Doni Immanuel Rumapea¹, Ozzi Suria²

^{1,2}Universitas Mercu Buana Yogyakarta, Sleman, Yogyakarta
doniimmanuelr11@gmail.com¹, ozzisuria@mercubuana-yogya.ac.id²

Abstract - This sentiment analysis of Instagram comments regarding the planned construction of an oil refinery in Batam classifies public opinion into three categories: positive, neutral, and negative. The initial dataset of 1,576 comments was reduced to 1,441 after text preprocessing (tokenization, stop-word removal, and stemming), and then split into 1,152 training instances and 289 testing instances. Two machine learning algorithms, Support Vector Machine (SVM) with `class_weight='balanced'` and Extreme Gradient Boosting (XGBoost) with oversampling, were applied to address class imbalance. In addition to accuracy (SVM: 81.25%; XGBoost: 96%), precision, recall, and F1-score metrics were evaluated to assess the balance between true-positive and true-negative classifications. The results indicate that XGBoost not only outperformed SVM in terms of accuracy but also achieved the highest F1-score on the minority class, demonstrating its ability to detect negative opinions that have often been overlooked. This study offers a novel contribution to Instagram-based sentiment analysis a platform that is visually distinct from Twitter by focusing on public opinions surrounding the strategic issue of energy infrastructure development. The findings can be utilized for real-time sentiment mapping, supporting policy formulation, urban planning, and monitoring industry responses to critical projects in the digital era.

Keywords - Sentiment Analysis, SVM, XGBoost, Oversampling

Abstrak - Analisis sentimen komentar Instagram terhadap rencana pembangunan kilang minyak di Batam ini mengklasifikasikan opini publik ke dalam tiga kategori: positif, netral, dan negatif. Dataset awal sebanyak 1.576 komentar direduksi menjadi 1.441 setelah pra-pemrosesan teks (tokenisasi, penghapusan stopword, dan stemming), lalu dibagi menjadi 1.152 data pelatihan dan 289 data pengujian. Dua algoritma pembelajaran mesin Support Vector Machine (SVM) dengan `class_weight='balanced'` dan Extreme Gradient Boosting (XGBoost) dengan oversampling diterapkan untuk mengatasi ketidakseimbangan kelas. Selain akurasi (SVM: 81,25%; XGBoost: 96%), dievaluasi pula metrik precision, recall, dan F1-score untuk mengukur keseimbangan antara klasifikasi benar positif dan benar negatif. Hasilnya, XGBoost tidak hanya unggul dalam akurasi, tetapi juga mencapai F1-score tertinggi pada kelas minoritas, menunjukkan kemampuannya dalam mendeteksi opini negatif yang selama ini sering terlewat. Penelitian ini menawarkan kontribusi baru dalam analisis sentimen berbasis Instagram platform yang secara visual berbeda dengan Twitter dengan fokus pada opini masyarakat seputar isu strategis pembangunan infrastruktur energi. Temuan dapat dimanfaatkan untuk pemetaan sentimen publik secara real-time, mendukung perumusan kebijakan, perencanaan kota, dan pemantauan respons industri terhadap proyek-proyek kritical di era digital.

Kata Kunci - Analisis Sentimen, SVM, XGBoost, Oversampling

I. PENDAHULUAN

Instagram, sebagai media sosial berbasis visual, telah berkembang menjadi ruang publik untuk mengekspresikan opini terhadap berbagai isu sosial. Tidak hanya digunakan untuk berbagi foto dan video, platform ini juga menjadi wadah diskusi mengenai kebijakan publik. Dalam konteks ini, komentar pengguna pada unggahan terkait pembangunan kilang minyak di Batam mencerminkan keragaman opini masyarakat yang penting untuk dianalisis secara sistematis. Penelitian ini bertujuan untuk menerapkan dan membandingkan performa dua algoritma machine learning SVM dan XGBoost dalam klasifikasi sentimen. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan f1-score untuk mengukur efektivitas model terhadap data tidak seimbang yang diambil dari media sosial. Salah satu isu strategis yang menjadi perbincangan publik adalah rencana pembangunan kilang minyak di Batam. Proyek ini menimbulkan berbagai persepsi, baik dari sisi dukungan atas penguatan infrastruktur energi nasional maupun kekhawatiran terhadap dampak lingkungan dan sosial. Komentar-komentar pengguna Instagram terhadap isu ini mencerminkan beragamnya sudut pandang yang muncul di tengah masyarakat[1]. Oleh karena itu, penting untuk memahami kecenderungan sentimen publik secara sistematis dan terukur[2].

Analisis sentimen merupakan pendekatan yang digunakan untuk mengevaluasi opini pengguna berdasarkan data teks[3]. Dalam konteks media sosial, analisis ini memerlukan teknik pengolahan bahasa alami (natural language processing/NLP) serta algoritma pembelajaran mesin yang andal. Metode ini tidak hanya membantu mengklasifikasikan opini menjadi kategori seperti positif, netral, atau negatif, tetapi juga memberikan wawasan mengenai pola pikir publik. Sejumlah penelitian sebelumnya telah mengadopsi pendekatan machine learning untuk keperluan analisis sentimen[4]. Penggunaan Support Vector Machine (SVM) untuk klasifikasi sentimen Twitter dan memperoleh akurasi yang memadai[5]. Pengkajian keunggulan XGBoost dalam klasifikasi dokumen teks dan menunjukkan hasil yang kompetitif[6]. Pengelompokan XGBoost dikenal unggul dalam hal akurasi dan efisiensi komputasi karena kemampuannya melakukan regularisasi dan pemangkasan pohon yang optimal. Meskipun demikian, masih terdapat kesenjangan penelitian yang secara spesifik menyoroti sentimen publik di platform Instagram terhadap isu pembangunan nasional. Kebanyakan studi terdahulu berfokus pada Twitter atau media sosial berbasis teks lainnya. Hal ini membuka ruang penelitian baru yang menggabungkan konteks lokal dengan pendekatan teknis untuk memahami opini masyarakat dalam ranah visual-digital seperti Instagram.

Penelitian ini bertujuan untuk mengimplementasikan dan membandingkan performa dua algoritma machine learning, yakni SVM dan XGBoost, dalam mengklasifikasikan sentimen komentar pengguna Instagram terhadap pembangunan kilang minyak di Batam. Melalui pendekatan ini, diharapkan dapat diperoleh model klasifikasi sentimen yang tidak hanya akurat, tetapi juga aplikatif untuk keperluan pemetaan opini publik secara real-time. Untuk menerapkan dan membandingkan performa dua algoritma populer, SVM dan XGBoost, dalam melakukan analisis sentimen komentar pengguna Instagram terkait pembangunan kilang minyak di Batam.

II. SIGNIFIKASI STUDI

A. Studi Literatur

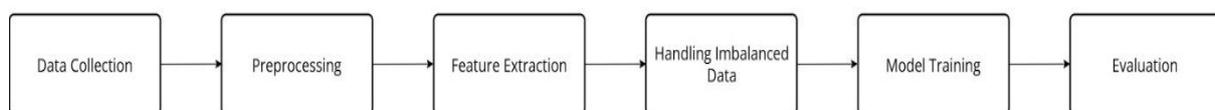
Bagian ini mengkaji dua aspek utama: studi literatur dan kontribusi penelitian. Dalam studi literatur, berbagai pendekatan sebelumnya yang menggunakan algoritma pembelajaran mesin untuk klasifikasi sentimen di media sosial telah dibahas, dengan fokus pada keunggulan SVM dalam mengolah data kecil berdimensi tinggi dan kekuatan XGBoost dalam menangani data kompleks serta efisiensi komputasi. Kontribusi penelitian ini terletak pada pemanfaatan data Instagram yang masih kurang dieksplorasi dalam literatur, serta pendekatan kontekstual pada isu pembangunan di

wilayah Batam. Penelitian ini juga mengusulkan penggunaan teknik penyeimbangan data berbeda pada masing-masing algoritma dan menilai kinerjanya secara kuantitatif.

Penelitian ini memberikan manfaat praktis bagi pemerintah daerah, perencanaan kota, dan pemangku kebijakan lainnya dalam memahami opini publik secara real-time. Selain itu, keterbatasan seperti bias data dan potensi overfitting pada teknik oversampling diakui sebagai ruang untuk pengembangan lebih lanjut. Analisis sentimen telah berkembang sebagai metode penting dalam penelitian berbasis teks, terutama seiring dengan pertumbuhan data dari media sosial. Berbagai studi menunjukkan efektivitas SVM dan XGBoost dalam klasifikasi sentimen. SVM unggul dalam mengolah data berukuran kecil dengan fitur yang tinggi, kekuatan XGBoost dalam menghadapi kompleksitas data dengan akurasi tinggi dan efisiensi komputasi [7]. Proses pra-pemrosesan teks yang mencakup stemming, stopword removal, dan tokenisasi memiliki dampak langsung terhadap hasil klasifikasi [8]. Meskipun penelitian ini dilakukan secara daring, lokasi pengumpulan data difokuskan pada akun Instagram yang secara spesifik membahas isu pembangunan di wilayah Batam. Pendekatan ini bertujuan untuk mendapatkan data yang kontekstual dan mencerminkan opini masyarakat terhadap kondisi lokal. Dengan demikian, hasil penelitian memiliki relevansi geografis yang kuat dan dapat dibandingkan dengan studi sejenis di lokasi atau konteks lain.

Metode Penelitian dan Evaluasi Penelitian ini menggunakan pendekatan kuantitatif dengan dukungan teknik text mining dan machine learning. Proses dimulai dengan pra-pemrosesan teks, termasuk normalisasi, penghapusan tanda baca, tokenisasi, stemming dengan Sastrawi, serta penghilangan stopword. Data yang telah dibersihkan kemudian diubah menjadi representasi numerik menggunakan TF-IDF Vectorizer. Untuk mengatasi masalah ketidakseimbangan data antar kelas, diterapkan teknik Random Oversampling [9].

Model klasifikasi dibangun menggunakan dua algoritma, yaitu SVM dan XGBoost. Pembagian data dilakukan menjadi set pelatihan dan pengujian. Evaluasi performa model mencakup metrik akurasi, precision, recall, dan f1-score untuk mengukur sejauh mana model mampu mengklasifikasikan sentimen secara tepat [10]. Proses ini dirancang untuk memastikan bahwa temuan yang dihasilkan dapat diandalkan dan replikatif, sekaligus menjawab hipotesis utama bahwa XGBoost memiliki performa lebih tinggi dibandingkan SVM dalam konteks klasifikasi komentar pengguna Instagram.



Gambar 1. Alur Jalan Penelitian

B. Metodologi Penelitian

Gambar 1 menampilkan alur tahapan penelitian ini yang diawali dengan proses pengumpulan data berupa komentar pengguna dari platform Instagram yang berkaitan dengan rencana pembangunan kilang minyak di Batam.

1. Data Collection

Tahapan awal dalam penelitian ini adalah pengumpulan data berupa komentar dari pengguna Instagram yang menanggapi unggahan terkait rencana pembangunan kilang minyak di wilayah Batam. Untuk menunjang efisiensi dan kuantitas data, proses scraping dilakukan secara otomatis menggunakan ekstensi browser Instant Data Scraper pada Google Chrome. Alat ini memungkinkan peneliti mengambil data komentar dari unggahan publik secara masif tanpa harus melakukan penyalinan secara manual. Setelah proses scraping selesai, seluruh komentar yang terkumpul

dievaluasi kembali secara manual untuk memastikan relevansi topik, keaslian komentar, serta menghilangkan data duplikat atau tidak valid. Hasilnya sebanyak 1576 berhasil dikumpulkan dan siap untuk dilakukan pra-pemrosesan teks.

2. Preprocessing

Data yang telah dikumpulkan kemudian melalui serangkaian proses pembersihan dan standarisasi teks agar siap digunakan dalam pelatihan model. Langkah-langkah pra-pemrosesan yang dilakukan meliputi:

- Pembersihan karakter khusus, seperti emotikon, tanda baca, angka, dan URL.
- Tokenisasi, yaitu proses memecah kalimat menjadi satuan kata yang lebih kecil.
- Normalisasi huruf, dengan mengubah semua teks menjadi huruf kecil untuk konsistensi.
- Penghapusan stopword, yaitu menghilangkan kata-kata umum dalam Bahasa Indonesia yang tidak berkontribusi besar terhadap makna kalimat, menggunakan daftar stopwords Bahasa Indonesia.
- Stemming, yaitu mengembalikan kata ke bentuk dasarnya menggunakan algoritma Sastrawi, sehingga kata dengan akar makna yang sama dapat dikenali sebagai satu entitas oleh model.

Pra-pemrosesan ini sangat krusial dalam meningkatkan kualitas input dan efektivitas representasi fitur. Hasil akhir dari proses ini menghasilkan sebanyak 1441 komentar layak pakai yang kemudian digunakan sebagai basis data untuk tahapan analisis selanjutnya.

3. Feature Extraction

Setelah teks dibersihkan dan dinormalisasi, tahap selanjutnya adalah mentransformasikan data teks menjadi representasi numerik agar dapat diproses oleh algoritma pembelajaran mesin. Dalam penelitian ini digunakan metode TF-IDF (Term Frequency–Inverse Document Frequency), yang memberikan bobot berdasarkan frekuensi kata dalam dokumen relatif terhadap seluruh korpus [11]. Teknik ini membantu mengidentifikasi kata-kata yang memiliki makna penting dalam konteks kalimat, dan secara otomatis mengurangi bobot kata-kata yang sering muncul namun kurang informatif. Hasil dari tahap ini adalah sebuah matriks vektor yang mewakili setiap komentar dalam bentuk angka-angka berbobot, yang akan digunakan dalam tahap pelatihan model.

4. Handling Imbalanced Data

Distribusi data yang diperoleh menunjukkan adanya ketimpangan kelas yang signifikan, dengan dominasi komentar bernuansa negatif (sekitar 80%), sementara kelas positif dan netral jauh lebih sedikit. Ketidakseimbangan ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas. Untuk mengatasi hal ini, digunakan dua pendekatan penyeimbangan data yang berbeda pada masing-masing algoritma: Pada SVM, diterapkan pengaturan parameter `class_weight='balanced'`, yang secara otomatis memberikan bobot lebih besar pada kelas minoritas selama proses pelatihan. Pada XGBoost, digunakan metode Random Oversampling, yaitu teknik memperbanyak data pada kelas positif dan netral secara acak agar distribusi kelas menjadi lebih proporsional. Langkah ini penting untuk meningkatkan sensitivitas model terhadap seluruh kategori sentimen secara merata.

5. Model Training

Setelah data dinyatakan bersih dan seimbang, dilakukan pembagian dataset menjadi dua bagian: set pelatihan sebanyak 1.152 data (80%) dan set pengujian sebanyak 289 data (20%). Dua algoritma pembelajaran mesin dipilih sebagai metode klasifikasi utama yaitu: SVM, yang dikenal efektif untuk data berdimensi tinggi dengan margin klasifikasi yang kuat[12] dan XGBoost, algoritma boosting yang sangat efisien dalam menangani dataset besar dan kompleks[13] serta mampu mengatasi overfitting dengan baik[14]. Kedua model dilatih menggunakan parameter yang dioptimalkan agar mampu mengenali pola sentimen dalam komentar secara akurat.

6. Evaluation

Model yang telah dilatih dievaluasi untuk mengukur sejauh mana performa klasifikasi yang dicapai. Evaluasi dilakukan menggunakan empat metrik utama, yaitu Accuracy, Precision, Recall, dan F1-score, yang dihitung berdasarkan komponen confusion matrix (True Positive, True Negative, False Positive, False Negative) untuk memberikan gambaran menyeluruh mengenai ketepatan dan keseimbangan kemampuan model dalam mengklasifikasikan setiap kelas.

III. HASIL DAN PEMBAHASAN

Hasil evaluasi menunjukkan bahwa model SVM memperoleh akurasi sebesar 81,25% pada data uji, sementara XGBoost mencatatkan akurasi tertinggi sebesar 96% setelah penerapan oversampling. Temuan ini mengindikasikan bahwa XGBoost lebih andal dalam menangani distribusi data yang kompleks dan tidak seimbang. Tahapan evaluasi ini dirancang untuk memastikan bahwa model yang dihasilkan tidak hanya akurat, tetapi juga konsisten dan dapat direplikasi pada kasus serupa di masa depan. Studi oleh Permana & Maani (2024) yang menggunakan data Twitter menunjukkan tingkat akurasi SVM sebesar 84% dan XGBoost sebesar 92%. Meskipun platform berbeda, pola akurasi serupa menunjukkan bahwa XGBoost secara konsisten lebih unggul dalam menangani data sosial yang tidak seimbang dan informal [15].

```
SVM - Akurasi Data Latih: 0.9041811846689896
SVM - Akurasi Data Uji: 0.8125

=== Classification Report (Data Uji) ===
      precision    recall  f1-score   support

   Negatif      0.92     0.87     0.89       238
    Netral     0.34     0.48     0.40        23
    Positif     0.52     0.59     0.55         27

 accuracy          0.81       288
 macro avg         0.59     0.65     0.62       288
weighted avg         0.84     0.81     0.82       288

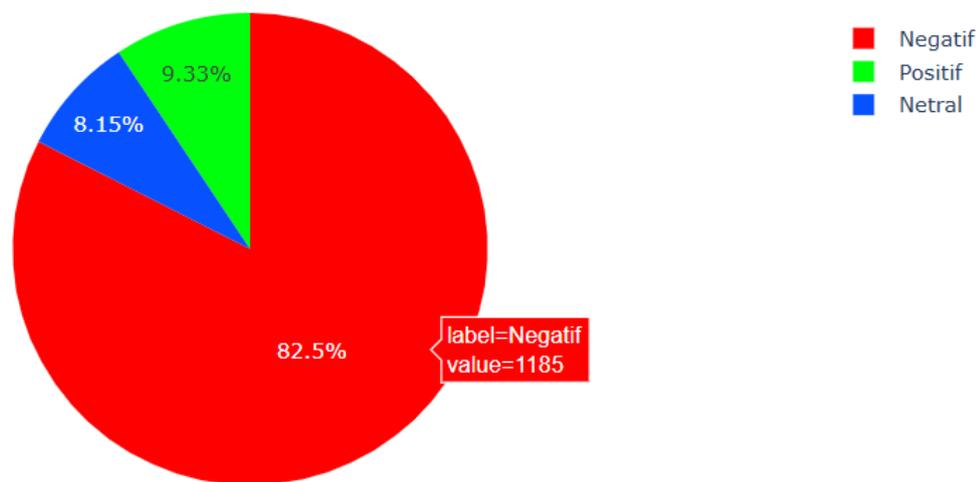
=== Confusion Matrix (Data Uji) ===
[[207  19  12]
 [  9  11   3]
 [  9   2  16]]
```

Gambar 2. Hasil dari SVM

Hasil klasifikasi menggunakan algoritma SVM menunjukkan akurasi pada data latih sebesar 90,41% dan pada data uji sebesar 81,25%. Evaluasi performa model melalui classification report menghasilkan f1-score tertinggi pada kelas negatif sebesar 0.89, sedangkan kelas netral hanya mencapai 0.40 dan kelas positif 0.55. Hal ini menunjukkan bahwa model cenderung bias terhadap kelas mayoritas, yaitu sentimen negatif. Confusion matrix pada data uji memperlihatkan bahwa dari

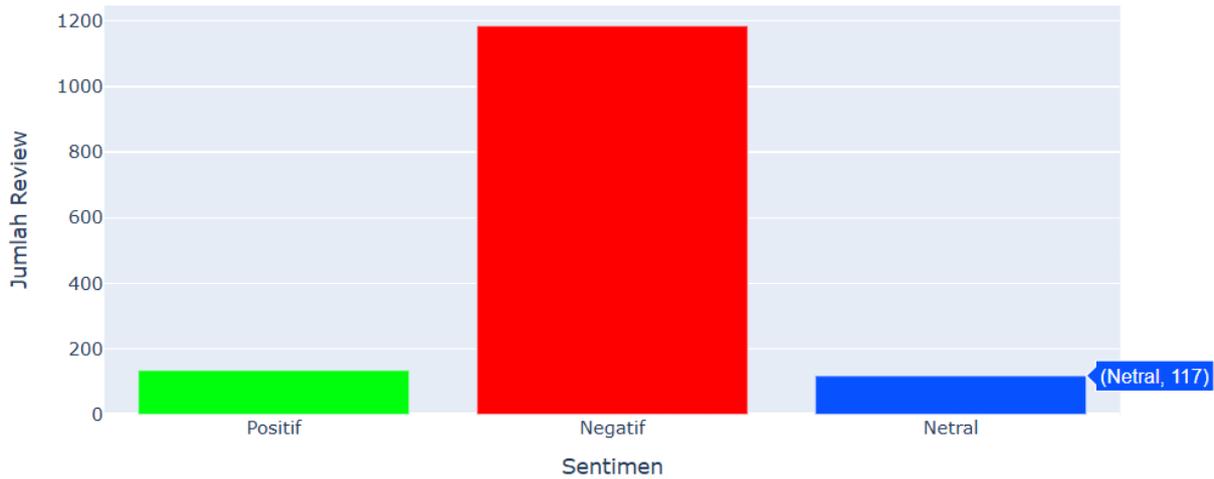
238 komentar negatif, 207 diklasifikasikan dengan benar, sedangkan sebagian komentar netral dan positif cenderung keliru diklasifikasikan. Ketidakseimbangan distribusi data menjadi faktor utama yang memengaruhi performa klasifikasi, terutama pada kelas netral dan positif yang jumlahnya relatif sedikit. Untuk mengurangi dampak bias tersebut dan potensi overfitting pada kelas mayoritas, parameter `class_weight='balanced'` telah diterapkan dalam model SVM. Parameter ini secara otomatis menyesuaikan bobot tiap kelas berdasarkan frekuensi data [16], sehingga kelas minoritas diberi bobot lebih besar.

Meskipun SVM menunjukkan akurasi yang cukup baik pada kelas dominan (negatif), model ini memiliki keterbatasan dalam membedakan sentimen netral dan positif. Berdasarkan confusion matrix, banyak komentar positif yang diklasifikasikan sebagai negatif. Hal ini disebabkan oleh ketidakmampuan SVM menangkap nuansa semantik yang lebih kompleks, seperti penggunaan ironi atau kontras dalam bahasa informal. Misalnya, komentar seperti *“bagus sih, tapi korupsinya pasti banyak”* sering terklasifikasi sebagai negatif sepenuhnya karena dominasi kata “korupsi”.



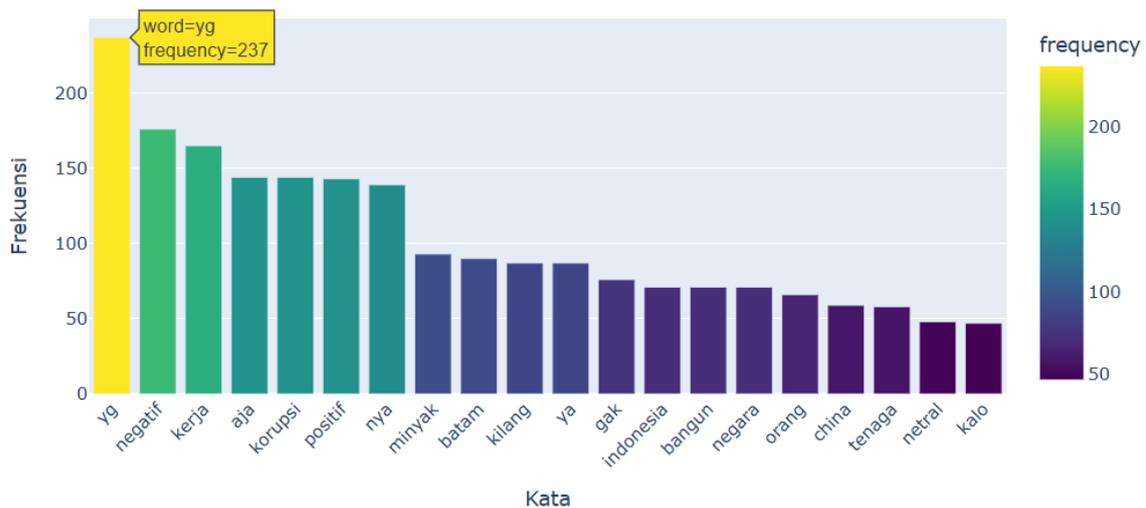
Gambar 3. Visualisasi SVM dalam bentuk Pie Chart menggunakan Flask

Visualisasi pie chart di atas menunjukkan distribusi sentimen yang diklasifikasikan menggunakan algoritma Support Vector Machine (SVM) terhadap data pengguna Instagram terkait rencana pembangunan kilang minyak di Batam. Dari diagram tersebut, terlihat bahwa mayoritas sentimen bersifat **negatif**, yaitu sebesar **82,5%** (sebanyak 1.185 data), yang ditandai dengan warna merah mencolok. Sementara itu, sentimen **positif** hanya mencakup **9,33%** dari total data dan ditunjukkan dengan warna hijau, sedangkan **sentimen netral** berada di angka **8,15%** dan ditandai dengan warna biru. Hasil ini mencerminkan kecenderungan kuat penolakan atau kekhawatiran masyarakat terhadap proyek pembangunan tersebut, yang perlu diperhatikan oleh pemangku kebijakan dalam merespons opini publik.



Gambar 4. Visualisasi SVM dalam bentuk Bar Chart menggunakan Flask

Gambar 4 merupakan visualisasi diagram batang (bar chart) yang menunjukkan hasil klasifikasi sentimen menggunakan algoritma SVM terhadap data komentar pengguna Instagram mengenai rencana pembangunan kilang minyak di Batam. Grafik ini menggambarkan distribusi jumlah review berdasarkan tiga kategori sentimen, yaitu **positif**, **negatif**, dan **netral**. Terlihat bahwa sentimen **negatif** mendominasi secara signifikan dengan jumlah hampir mencapai **1.200 review**, dibandingkan dengan **positif** yang hanya sekitar **130 review**, dan **netral** sebanyak **117 review**. Visualisasi ini mempertegas bahwa sebagian besar masyarakat cenderung memberikan respons negatif terhadap proyek tersebut, yang bisa menjadi indikator adanya ketidaksetujuan atau kekhawatiran publik.



Gambar 5. Visualisasi Frekuensi 20 Kata yang Paling Sering Muncul menggunakan Flask

Visualisasi pada Gambar 5 menampilkan 20 kata yang paling banyak muncul dalam kumpulan data komentar Instagram terkait pembangunan kilang minyak di Batam. Grafik ini menggunakan diagram batang berwarna gradasi untuk menggambarkan frekuensi kemunculan setiap kata, dengan warna kuning menunjukkan frekuensi tertinggi dan ungu menunjukkan frekuensi terendah. Kata **"yg"** muncul paling sering dengan frekuensi **237 kali**, diikuti oleh kata-kata bermuatan negatif seperti **"negatif"**, **"korupsi"**, dan **"gak"**, yang mencerminkan dominasi opini kritis di antara pengguna. Selain itu, muncul pula kata-kata seperti **"kerja"**, **"minyak"**, **"batam"**, dan **"kilang"** yang merepresentasikan topik utama diskusi. Hasil ini dapat membantu dalam memahami fokus perhatian dan persepsi publik terhadap isu yang sedang dianalisis.

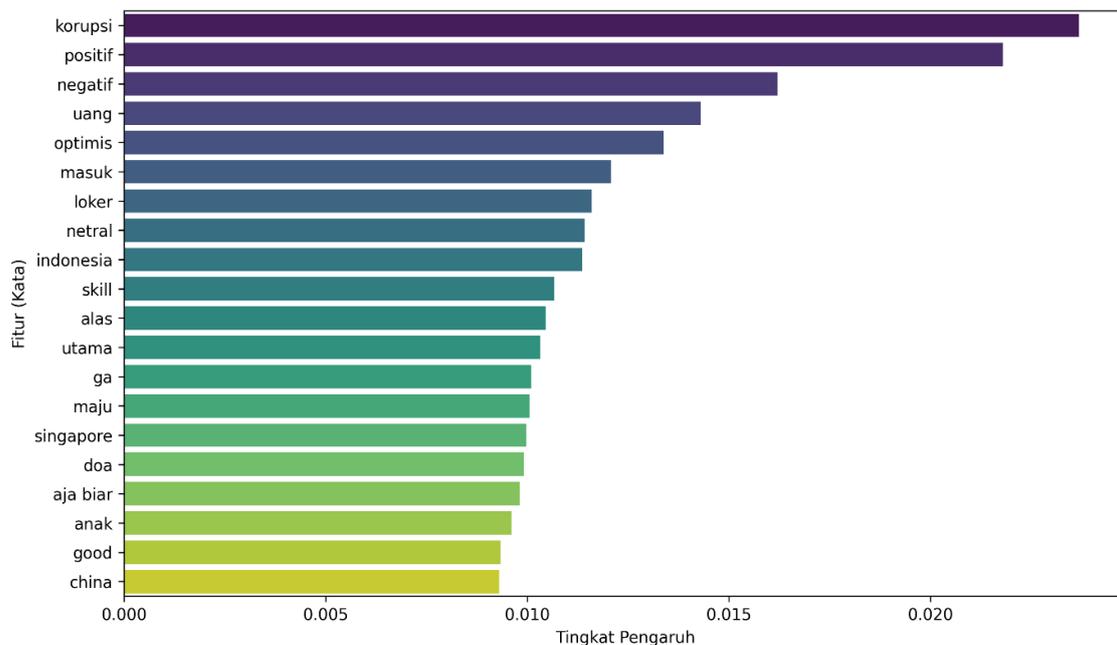
Visualisasi yang ditampilkan pada aplikasi Flask menggambarkan distribusi sentimen pengguna Instagram yang telah diklasifikasikan menggunakan algoritma SVM. Diagram pie menunjukkan bahwa sentimen negatif mendominasi dengan persentase sebesar 82,5%, setara dengan 1.185 komentar[17]. Sentimen positif dan netral masing-masing hanya mencakup 9,33% (134 komentar) dan 8,15% (117 komentar). Distribusi ini juga diperkuat oleh grafik batang yang menampilkan jumlah komentar per kategori sentimen, di mana kolom berwarna merah (negatif) jauh lebih tinggi dibandingkan dua kategori lainnya.

	precision	recall	f1-score	support
Negatif	0.98	0.93	0.95	261
Netral	0.95	0.99	0.97	230
Positif	0.96	0.98	0.97	220
accuracy			0.96	711
macro avg	0.96	0.97	0.96	711
weighted avg	0.96	0.96	0.96	711

Gambar 6. Hasil dari XGBoost

Untuk mengatasi masalah yang sama seperti yang terjadi pada SVM, digunakan teknik Random Oversampling sebelum pelatihan model XGBoost. Teknik ini bekerja dengan memperbanyak sampel pada kelas minoritas (netral dan positif) dengan cara menduplikasi data secara acak[18]. Tujuannya adalah untuk menyeimbangkan distribusi kelas agar model tidak berat sebelah. Setelah diterapkan oversampling, jumlah data dari ketiga kelas menjadi relatif seimbang, sehingga model XGBoost dapat belajar secara lebih adil terhadap masing-masing kelas.

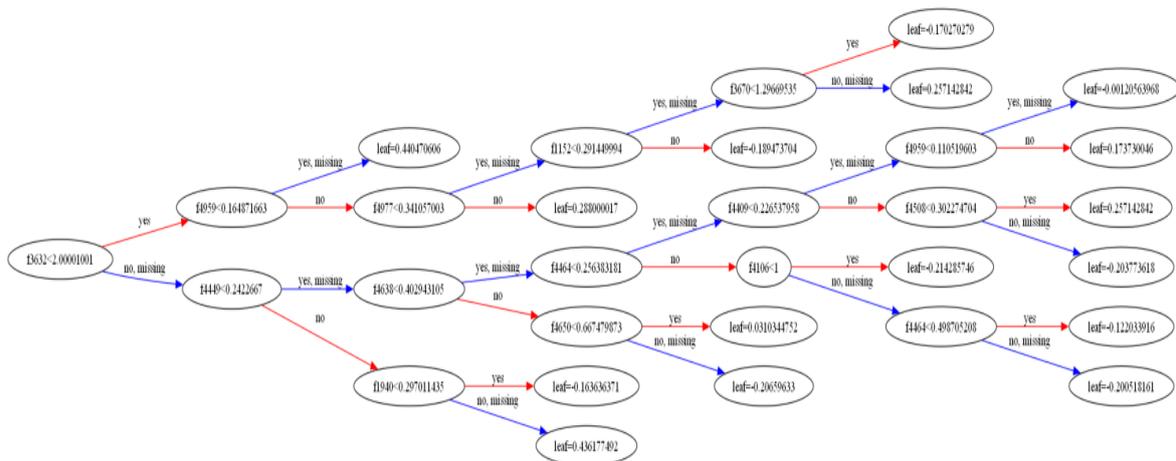
Hasil dari pelatihan model XGBoost bisa dilihat pada Gambar 6 menunjukkan peningkatan signifikan. F1-score pada ketiga kelas (negatif, netral, positif) berada pada kisaran 0.95 hingga 0.97, dan akurasi keseluruhan mencapai 96%[19].



Gambar 7. Top 20 Kata Paling Berpengaruh Dalam Analisis Sentimen

Selain mengevaluasi kinerja model secara kuantitatif, penelitian ini juga menyajikan visualisasi interpretatif untuk memahami bagaimana model XGBoost mengambil keputusan dalam klasifikasi sentimen. Visualisasi pertama menampilkan dua puluh kata atau fitur yang memiliki kontribusi

terbesar terhadap hasil prediksi. Untuk menghasilkan grafik pada Gambar 7 ini, peneliti menggunakan fungsi `plot_importance()` dari pustaka XGBoost, yang menampilkan tingkat kepentingan masing-masing fitur berdasarkan metrik tertentu, seperti gain, weight, atau cover. Visualisasi disesuaikan menggunakan pustaka `matplotlib`, yang memungkinkan pengaturan aspek visual seperti warna, label sumbu, dan judul grafik. Grafik ini membantu menunjukkan bahwa kata “korupsi”, “positif”, dan “negatif” memiliki pengaruh paling besar dalam menentukan sentimen, sekaligus mengungkap bahwa model cukup sensitif terhadap kata-kata yang memiliki muatan emosional atau relevansi sosial tinggi. Kemunculan kata asing seperti “china” atau “singapore” juga menunjukkan bahwa model memperhatikan pola kata dari konteks global yang muncul dalam komentar pengguna. Model XGBoost mampu mengenali pola-pola sentimen dengan lebih akurat berkat kemampuannya menangani fitur interaktif. Visualisasi kata penting (Gambar 7) menunjukkan bahwa XGBoost tidak hanya mempertimbangkan kata-kata eksplisit seperti “korupsi” dan “positif”, tetapi juga kata-kata konteks global seperti “china” dan “singapore”. Ini menandakan sensitivitas XGBoost terhadap wacana geopolitik yang muncul dalam komentar publik, sebuah hal yang tidak terdeteksi oleh SVM.



Gambar 8. Struktur Pohon Keputusan XGBoost

Visualisasi kedua yang ditampilkan pada Gambar 8 merupakan representasi dari salah satu struktur pohon keputusan (*decision tree*) yang dibentuk oleh algoritma XGBoost selama proses pelatihan model. Visualisasi ini dihasilkan menggunakan fungsi `plot_tree()` yang disediakan oleh pustaka XGBoost[20], dengan pengaturan tambahan seperti `num_trees=0` untuk menampilkan pohon pertama, dan `rankdir='LR'` agar struktur terbaca dari arah kiri ke kanan guna mempermudah interpretasi. Pohon keputusan tersebut menggambarkan proses klasifikasi yang dilakukan oleh model melalui serangkaian aturan berbasis fitur yang diperoleh dari representasi numerik teks menggunakan metode Term Frequency Inverse Document Frequency (TF-IDF).

Setiap simpul (*node*) dalam pohon menggambarkan kondisi pemisahan berdasarkan nilai TF-IDF dari kata tertentu dalam komentar pengguna. Misalnya, suatu simpul dapat merepresentasikan kondisi seperti: "Apakah nilai TF-IDF dari kata 'korupsi' lebih kecil dari 0,018?". Jika kondisi tersebut bernilai benar, maka alur klasifikasi akan bergerak ke cabang kiri, dan sebaliknya jika tidak terpenuhi, maka akan diarahkan ke cabang kanan. Proses ini berlanjut secara rekursif hingga mencapai simpul akhir atau *leaf node*, yaitu titik di mana model memberikan prediksi akhir terhadap sentimen komentar, baik negatif, netral, maupun positif. Setiap *leaf node* mengandung skor prediksi yang menentukan keanggotaan suatu komentar terhadap kelas sentimen tertentu berdasarkan jalur logika yang dilalui.

Struktur visual ini memperlihatkan bahwa proses klasifikasi pada XGBoost tidak bergantung pada satu fitur Ftunggal, melainkan pada kombinasi dari berbagai fitur yang membentuk pola keputusan berlapis[21]. Warna cabang pada diagram umumnya biru dan merah menunjukkan arah percabangan serta tingkat kontribusi dari setiap simpul terhadap keseluruhan prediksi. Keberadaan simpul dan percabangan yang kompleks mencerminkan kemampuan model dalam menangkap hubungan non-linier dan kontekstual di antara kata-kata dalam komentar yang bersifat informal serta tidak terstruktur. Pentingnya visualisasi ini terletak pada kemampuannya untuk memberikan transparansi terhadap proses pengambilan keputusan oleh model, yang dalam banyak kasus bersifat *black-box*. Dengan menampilkan struktur pohon keputusan secara eksplisit, peneliti dan pembaca dapat menelusuri bagaimana model membentuk klasifikasi berdasarkan urutan kondisi yang logis dan terukur[22].

IV. KESIMPULAN

Penelitian ini menegaskan potensi pendekatan *machine learning* dalam mengidentifikasi dan memahami sentimen publik di media sosial, khususnya terkait isu sensitif seperti rencana pembangunan kilang minyak di Batam. Melalui perbandingan dua algoritma, SVM dan XGBoost, ditemukan bahwa keberhasilan klasifikasi sangat dipengaruhi oleh kualitas, keseimbangan, dan karakteristik linguistik data yang digunakan. Model SVM, meskipun mampu mencapai akurasi tinggi pada data latih (90,41%), menunjukkan penurunan performa yang signifikan pada data uji (81,25%) dan kesulitan dalam mengenali kelas minoritas (positif dan netral). Hal ini menyoroti keterbatasan model dalam menghadapi distribusi data yang tidak seimbang, bahkan setelah penerapan strategi *class_weight='balanced'*. Di sisi lain, penerapan teknik *Random Oversampling* pada model XGBoost menghasilkan peningkatan kinerja yang konsisten, dengan akurasi hingga 96% dan *f1-score* tinggi di semua kelas (antara 0.95–0.97). Namun, perlu dicatat bahwa teknik oversampling juga berpotensi menyebabkan *overfitting*, terutama jika tidak disertai dengan validasi silang atau regularisasi yang tepat. Terbatasnya jumlah dataset dan sifat komentar yang informal serta kontekstual juga menjadi tantangan tersendiri dalam proses pelabelan dan pelatihan model. Oleh karena itu, ke depan diperlukan pengumpulan data yang lebih representatif, serta eksplorasi teknik *augmentation* dan *embedding* berbasis konteks (seperti BERT) untuk meningkatkan pemahaman semantik. Dari sisi kebijakan, temuan ini dapat dimanfaatkan oleh pemerintah kota Batam dan pemangku kepentingan terkait sebagai indikator awal untuk memetakan reaksi publik secara real time. Sistem klasifikasi sentimen otomatis ini dapat membantu merancang strategi komunikasi yang lebih responsif dan transparan terhadap kekhawatiran masyarakat, terutama dalam konteks pembangunan infrastruktur yang menimbulkan dampak sosial dan lingkungan. Implementasi teknologi ini juga dapat diperluas ke isu-isu publik lainnya guna mendukung pengambilan keputusan berbasis data (*data-driven policy*).

REFERENSI

- [1] I. Permana and K. D. Maani, "Publication Trend of Public Sentiment Towards Indonesia Government Policies," *Sinkron*, vol. 8, no. 3, pp. 2061–2069, 2024, doi: 10.33395/sinkron.v8i3.13843.
- [2] N. Alvionika, S. Faisal, R. Rahmat, and A. F. N. Masruriyah, "Analisis Sentimen Pada Komentar Instagram Provider By.U Menggunakan Metode K-Nearest Neighbors (KNN)," *J. Algoritma*, vol. 21, no. 2, pp. 50–63, 2024, doi: 10.33364/algoritma/v.21-2.1672.
- [3] M. T. Uliniansyah *et al.*, "Twitter dataset on public sentiments towards biodiversity policy in Indonesia," *Data Br.*, vol. 52, p. 109890, 2024, doi: 10.1016/j.dib.2023.109890.
- [4] A. Daza, N. D. González Rueda, M. S. Aguilar Sánchez, W. F. Robles Espiritu, and M. E. Chauca Quiñones, "Sentiment Analysis on E-Commerce Product Reviews Using Machine Learning and Deep

- Learning Algorithms: A Bibliometric Analysis and Systematic Literature Review, Challenges and Future Works,” *Int. J. Inf. Manag. Data Insights*, vol. 4, no. 2, 2024, doi: 10.1016/j.jjimei.2024.100267.
- [5] D. Nasrullah, “Klasifikasi Bidang Fokus Publikasi Jurnal,” 2023, [Online]. Available: <https://repository.unissula.ac.id/29646/>
- [6] E. Setiawan, W. W. Pamungkas, I. Komputer, and U. Borobudur, “Pengujian Algoritma Deep Learning Pada Analisis Terhadap Layanan Gojek Menggunakan Data Media,” vol. 10, no. 2, pp. 1–15, 2024.
- [7] A. Samih, A. Ghadi, and A. Fennan, “Enhanced sentiment analysis based on improved word embeddings and XGBoost,” *Int. J. Electr. Comput. Eng.*, vol. 13, no. 2, pp. 1827–1836, 2023, doi: 10.11591/ijece.v13i2.pp1827-1836.
- [8] S. Setyabudi and E. Aryanny, “Sentiment Analysis of Lazada Marketplace User Ratings with Naïve Bayes and Support Vector Machine Methods,” *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 1, pp. 422–433, 2025, doi: 10.35314/sww8cg21.
- [9] M. Iqrom, M. Afdal, Rice Novita, Medyantiwi Rahmawita, and Tengku Khairil Ahsyar, “Sentiment Analysis of Gojek, Grab, Maxim Applications Using Support Vector Machine Algorithm,” *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 1, pp. 237–248, 2025, doi: 10.35314/52fycr56.
- [10] Suwarno and R. Kusnadi, “Comparative Analysis of SVM, XGBoost and Neural Network on Hate Speech Classification,” *J. RESTI*, vol. 5, no. 5, pp. 896–903, 2021, doi: 10.29207/resti.v5i5.3506.
- [11] B. Prasetyo, Ahmad Yusuf Al-Majid, and Suharjito, “A Comparative Analysis of MultinomialNB, SVM, and BERT on Garuda Indonesia Twitter Sentiment,” *PIKSEL Penelit. Ilmu Komput. Sist. Embed. Log.*, vol. 12, no. 2, pp. 445–454, 2024, doi: 10.33558/piksel.v12i2.9966.
- [12] A. Lowell, A. Lowell, K. Candra, E. Indra, and S. Informasi, “Perbandingan Metode Support Vector Machine (SVM) Dan Naive Bayes Pada Analisis Sentimen Ulasan Aplikasi OVO,” *J. Media Inform. [Jumin]*, vol. 7, no. 1, pp. 125–133, 2025.
- [13] B. Hakim and P. R. Kinasih, “Sentiment Analysis of Indonesian Citizen Tweets Using Support Vector Machine on the Rebranding of Twitter to X,” *J. Tekno Kompak*, vol. 18, no. 2, p. 468, 2024, doi: 10.33365/jtk.v18i2.4293.
- [14] R. Randy Suryono, “Sentiment Analysis of the Influence of the Korean Wave in Indonesia Using the Naive Bayes Method and Support Vector Machine Analisis Sentimen Pengaruh Korean Wave Di Indonesia Dengan Metode Naive Bayes Dan Support Vector Machine,” *J. Inovtek Polbeng - Seri Inform.*, vol. 10, no. 1, pp. 308–319, 2025.
- [15] I. Permana and K. D. Maani, “Publication Trend of Public Sentiment Towards Indonesia Government Policies,” *Sinkron*, vol. 8, no. 3, pp. 2061–2069, 2024, doi: 10.33395/sinkron.v8i3.13843.
- [16] I. P. A. P. Widiarta, R. Dwiyanaputra, and A. Aranta, “Analisis Sentimen Masyarakat Terhadap Kebijakan Penerapan Ppkm Di Media Sosial Twitter Dengan Menggunakan Metode XGBoost,” *J. Teknol. Informasi, Komputer, dan Apl. (JTika)*, vol. 5, no. 2, pp. 154–163, 2023, doi: 10.29303/jtika.v5i2.342.
- [17] Y. Yulistiani and S. Styawati, “Analisis Sentimen Terhadap Calon Presiden Indonesia 2024 dengan Metode Extreme Gradient Boosting (XGBOOST),” *J. Inform. J. Pengemb. IT*, vol. 9, no. 3, pp. 322–328, 2024, doi: 10.30591/jpit.v9i3.6127.
- [18] E. Z. Astuti, C. A. Sari, E. H. Rachmawanto, and R. R. Ali, “Comparative Study of Machine Learning Algorithms for Performing Ham or Spam Classification in SMS,” *Sci. J. Informatics*, vol. 11, no. 1, pp. 177–186, 2024, doi: 10.15294/sji.v11i1.47364.
- [19] R. A. M. Pratama, K. I. Rachmadiansyah, and S. Sidharta, “Technique of Mental Health Issues Classification based on Machine Learning: Systematic Literature Review,” *Procedia Comput. Sci.*, vol. 227, pp. 137–146, 2023, doi: 10.1016/j.procs.2023.10.511.
- [20] P. Hafidzah, S. Maryani, B. Y. Ihsani, E. Erwin, and A. K. Niswariyana, “Penerapan Deep Learning dalam Menganalisis Sentimen di Media Sosial,” *Semin. Nas. Paedagogia*, vol. 4, pp. 328–339, 2024.
- [21] R. Kusumaningrum, I. Z. Nisa, R. Jayanto, R. P. Nawangsari, and A. Wibowo, “Deep learning-based application for multilevel sentiment analysis of Indonesian hotel reviews,” *Heliyon*, vol. 9, no. 6, p. e17147, 2023, doi: 10.1016/j.heliyon.2023.e17147.
- [22] V. Ong, A. D. S. Rahmanto, W. Williemi, N. H. Jeremy, D. Suhartono, and E. W. Andangsari, “Personality Modelling of Indonesian Twitter Users with XGBoost Based on the Five Factor Model,” *Int. J. Intell. Eng. Syst.*, vol. 14, no. 2, pp. 248–261, 2021, doi: 10.22266/ijies2021.0430.22.