



## Analisis Sentimen Berbasis Aspek Pada Ulasan Aplikasi Indrive Menggunakan Bidirectional Encoder Representations From Transformers (Bert)

Asri Kinanti Febriany<sup>1</sup>, Eka Dyar Wahyuni<sup>2</sup>, Reisa Permatasari<sup>3</sup>

Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas  
Pembangunan Nasional “Veteran” Jawa Timur<sup>123</sup>

Received: 01 Oktober 2024  
Revised: 07 Oktober 2024  
Accepted: 14 Oktober 2024

### Abstract

*Ekonomi digital di Indonesia turut disumbangkan oleh bisnis transportasi online. Salah satu pendatang baru pada bisnis transportasi online ini adalah inDrive. Rating ulasan dari google play store tidak cukup untuk menggambarkan kualitas sebuah aplikasi, oleh karena itu diperlukannya Analisis Sentimen Berbasis Aspek (ABSA) yang pada dasarnya dapat mengidentifikasi aspek dan mengidentifikasi sentimen dari aspek tersebut. Dengan pendekatan LDA (Latent Dirichlet Allocation) didapatkan 3 aspek utama yang ada pada dataaset periode Januari hingga Juli yaitu fitur lelang, sistem aplikasi, tarif & layanan transportasi. Kelebihan fitur lelang mencakup kemudahan pengguna dalam. Implementasi model ABSA menggunakan IndoBERT, dan hasil uji validasi dengan 100 data ulasan baru menunjukkan keberhasilan dengan akurasi 92% untuk pengujian aspek dan 84% untuk pengujian sentimen.*

**Keywords:** Analisis Sentimen Berbasis Aspek, IndoBERT, inDrive

(\*) Corresponding Author: [askntfebrany@gmail.com](mailto:askntfebrany@gmail.com)

**How to Cite:** Febriany, A. K., Wahyuni, E. D., & Permatasari, R. (2024). Analisis Sentimen Berbasis Aspek Pada Ulasan Aplikasi Indrive Menggunakan Bidirectional Encoder Representations From Transformers (Bert). <https://doi.org/10.5281/zenodo.14263982>.

## PENDAHULUAN

Indonesia menjadi negara pemain utama dalam ekonomi digital Asia Tenggara (Google dan Temasek, 2022). Selain *e-commerce*, ekonomi digital Indonesia juga disumbang oleh bisnis transportasi online. Transportasi online adalah transportasi umum berbasis aplikasi sebagai media untuk melakukan pemesanan sebelum menggunakannya (Dwianto dan Sadikin, 2021). Fenomena transportasi online ini menjadi cepat populer dan diminati oleh masyarakat karena menawarkan inovasi terbaru mengenai transportasi yang digabungkan dengan teknologi komunikasi secara online, dan menyediakan berbagai layanan, sehingga memberikan kemudahan bagi masyarakat dalam efisiensi waktu untuk memesan layanan transportasi online dimana saja dan kapan saja dengan hanya menggunakan smartphone. Selain itu, transportasi online menjadi salah satu pilihan utama masyarakat karena harga dan kenyamanannya (Astutik dkk. 2022).

Jasa dan layanan transportasi online kini semakin marak di Indonesia. Peminatnya tidak terbatas dan mampu mencakup segala usia. Memang, ada dua nama besar, seperti Grab dan Gojek yang menduduki pasar di peringkat atas. Namun, inDrive menjadi nama baru yang siap bersaing di bidang potensial ini. inDriver merubah namanya menjadi inDrive pada tahun 2022. Ciri khas aplikasi yang satu ini ternyata memudahkan sekaligus mewujudkan benefit tersendiri bagi setiap pihak pengguna. Pengemudi diberikan kesempatan untuk memasang rate tripnya sendiri. Penumpang cukup memilih driver yang diinginkan berdasarkan

indikator penawaran harga tersebut. Tentu, driver dan penumpang mendapatkan feedback sepadan serta sama-sama menguntungkan.(Onlinejek.com, 2022).

Sampai saat ini, aplikasi inDrive telah diunduh oleh lebih dari 100 juta orang dan dengan beragam ulasan-ulasan yang berisi kritik, saran dan pertanyaan dari para pengguna. Ulasan-ulasan tersebut dapat berpengaruh buruk terhadap citra inDrive apabila terdapat banyak kritikan karena ketidakpuasan pengguna terhadap layanannya dan akhirnya membuat masyarakat enggan memilih aplikasi tersebut di antara banyaknya aplikasi ojek online yang dianggap lebih baik. Oleh karena itu perlu dilakukan analisis sentimen terhadap ulasan-ulasan tersebut agar dapat dijadikan tolak ukur baik tidaknya layanan transportasi online inDrive menurut pengguna.

Sentimen positif, netral atau negatif masyarakat bisa merujuk ke beberapa aspek pada aplikasi. Misalnya, masyarakat senang dengan aplikasi ojek online karena mempunyai tampilan yang millennial walaupun terdapat banyak iklan yang mengganggu. Maka dengan adanya permasalahan tersebut dapat dibangun sebuah sistem yang dapat dilakukan yaitu analisis sentimen. Analisis sentimen merupakan sebuah cara riset komputasional dari opini, sentimen dan emosi yang diekspresikan secara tekstual (Liu, 2010).

Salah satu upaya untuk mengetahui kelebihan dan kekurangan biasa disebut dengan *Aspect-Based Sentiment Analysis* (ABSA). Pada penelitian ini akan dilakukan dua tahapan klasifikasi. Pertama, melakukan clustering topik/aspek menggunakan metode LDA. Kedua, melakukan klasifikasi sentimen berdasarkan aspek menggunakan metode *Bidirectional Encoder Representations from Transformers* (BERT).

## **Tinjauan Penelitian**


### **1. inDrive**

InDrive adalah layanan transportasi yang menawarkan platform pemesanan perjalanan daring. Didirikan pada tahun 2013, kini InDrive tersedia di lebih dari 655 kota di 48 negara di lima benua. Pada tahun 2022, ini adalah aplikasi transportasi online terbanyak kedua yang diunduh di seluruh dunia berdasarkan data Google Play dan App Store. InDrive telah menciptakan solusi mobilitas yang memberikan pilihan, dengan tetap mempertahankan elemen manusia di dalamnya. Platform ini memberikan pengemudi dan penumpang kebebasan untuk menentukan harga, rute, dan rincian perjalanan lainnya secara langsung. Model peer-to-peer kami memungkinkan terciptanya transparansi dan pilihan lebih, untuk melawan ketidakadilan yang banyak terdapat di penyedia layanan mobilitas, termasuk algoritma dan kondisi tidak adil bagi pengemudi, serta manipulasi harga. ("Tentang Kami," InDrive, 2023).

### **2. BERT**

Representasi Encoder Bidirectional Transformers atau disingkat BERT, adalah model representasi bahasa terlatih yang dibuat pada tahun 2018 oleh peneliti Google AI Language. BERT dibuat menggunakan pembelajaran semi-diawasi, ELMo, ULMFiT, OpenAI Transformers, dan Transformers serta teknik deep learning (Devlin dkk. 2019). BERT adalah deep learning model yang telah memberikan hasil canggih pada berbagai tugas Natural Language Processing (NLP). BERT memiliki 6 lapisan Transformer yang ditumpangkan di atas encoder dan decoder masing masing, yang menyumbang file proses pelatihan yang sangat

kompleks, konfigurasi tinggi, waktu pelatihan yang banyak dan biaya yang sangat mahal. Namun, Google membuka sumber dari pretrained model dari BERT, yang mana dapat digunakan tanpa harus membuat model terlebih dahulu.



Gambar 2. Ilustrasi 12 Layer Dalam Model BERT

BERT processing dimulai dari sebuah kata dengan representasi embedding dari lapisan embedding. Setiap lapisan melakukan beberapa penghitungan multi-headed attention pada representasi kata dari lapisan sebelumnya untuk membuat representasi perantara baru. Semua representasi perantara ini memiliki ukuran yang sama. Dalam model BERT 12 layer, sebuah token akan memiliki 12 representasi menengah (Devlin dkk. 2019).

### 3. IndoBERT

IndoBERT adalah model yang telah dilatih sebelumnya berdasarkan model BERT yang dilatih dengan 4 miliar kata dari teks bahasa Indonesia yang berasal dari berita online, media sosial, Wikipedia, artikel online, subjudul dari rekaman video, dan dataset paralel yang kemudian disebut Indo4B (Isa dkk. 2022). Pada tahap *pre training*, IndoBERT dilatih menggunakan dataset Indo4B. Kemudian pada tahap *fine tuning*, model yang telah dilatih pada tahap *pre training* disesuaikan dan dilatih dengan dataset khusus yang memiliki label. (Jayadianti dkk. 2022)

### METODE PENELITIAN

Peneilitan ini menggunakan studi literatur yaitu menggunakan jurnal, artikel ilmiah, penelitian serta sumber dari internet terpercaya seperti dokumentasi BERT dan sumber-sumber yang berkaitan dengan penelitian lainnya. Pada tahap analisis kebutuhan mencakup analisis kebutuhan data serta kebutuhan *software* dan *hardware* agar tujuan dari penelitian dapat tercapai. Data yang dibutuhkan dalam penelitian ini yaitu data berupa ulasan pengguna aplikasi InDrive yang terdapat di *google play store*. Dalam melakukan penelitian ini digunakan *software* dan *hardware* untuk merancang dan menjalankan sistem yang telah dibuat. *Hardware* yang digunakan yaitu laptop Asus GL503GE dengan spesifikasi RAM 8GB + 8GB serta penyimpanan internal SSHD sebesar 1TB. *Software* yang digunakan yaitu *web browser Microsoft Edge*. *Spreadsheet* untuk melihat data dan *Google Colab* untuk menjalankan bahasa pemrograman *Phyton*. *Data collecting / scraping* dengan menggunakan bantuan *google play scraper*. Proses *scraping* akan dilakukan berulang kali sebanyak data yang dibutuhkan. Setelah proses *scraping* selesai dilakukan, maka dataframe akan disimpan dalam bentuk *Comma Separated Value (CSV)* agar tidak perlu melakukan proses *scraping* lagi untuk selanjutnya. Dalam data *preprocessing*, ada beberapa tahapan di dalamnya. Tahapan-tahapan data *preprocessing* (Kurniawan dkk. 2022) yang dilakukan adalah *case folding*, *data*

*cleaning*, normalisasi, *stopwords removal*, dan *stemming*. Dalam konteks penelitian ini akan menerapkan metode *Latent Dirichlet Allocation* (LDA) untuk mengidentifikasi topik-topik yang ada dalam kumpulan ulasan aplikasi. Setelah itu kemudian dilakukan tahap labeling, klasifikasi, dan evaluasi.

## **HASIL DAN PEMBAHASAN**

### **1. Analisis Kebutuhan**

Data yang diperlukan dalam penelitian ini adalah data pada komentar aplikasi InDrive di *Google Play Store*. Data yang diambil yaitu data berbahasa Indonesia yang diambil dalam kurun waktu 1 Januari 2023 sampai dengan 11 Juli 2023.

### **2. Data Collecting**

pengumpulan data menggunakan library *google-play-scraper*. Dalam pengumpulan data ulasan ini yang dibutuhkan adalah id dari aplikasi InDrive yang. Data yang didapatkan dari proses *scraping* terdistribusi ke dalam 11 kolom, yaitu kolom *reviewId* mengandung ID unik untuk setiap ulasan atau komentar.

Selanjutnya data yang didapatkan dari proses *scraping*, dilakukan penyaringan data secara manual untuk menghapus data yang memiliki jumlah kata kurang dari 4. Setelah proses penyaringan, total data yang didapatkan sebanyak 10463 data.

### **3. Data Preprocessing**

#### **a. Case Folding**

Tahapan "case-folding" adalah proses mengubah semua karakter teks menjadi huruf kecil (*lowercase*). Ini dilakukan untuk memastikan konsistensi dalam analisis teks, karena karakter huruf besar dan kecil dianggap berbeda oleh komputer.

#### **b. Data Cleansing**

Pada tahap ini, dilakukan proses *cleaning* dengan menghapus karakter yang tidak relevan. Data berasal dari beragam karakter pengguna, yang berarti tidak semua karakter kata yang digunakan oleh pengguna memiliki nilai penting. Langkah pembersihan bertujuan untuk menghilangkan tanda baca, angka, URL, nama pengguna atau mention, tagar atau hashtag, serta huruf tunggal yang tidak berarti.

#### **c. Normalisasi**

Kata-kata non-standar dataset diubah menjadi kata-kata standar atau dieja selama tahap normalisasi. Contohnya seperti penulisan 'utk' diubah menjadi kata standarnya yaitu 'untuk'.

#### **d. Stopwords Removal**

Tahapan ini digunakan untuk menghilangkan kata-kata yang tidak berarti apa-apa. Contohnya seperti penghilangan kata 'di', 'ke', 'dari', 'dan', 'yang'.

#### **e. Stemming**

Tahap *stemming* adalah penghilangan afiks seperti prefiks, sufiks, dan konfiks untuk mengubah kata-kata berimbuhan menjadi bentuk akarnya. Contohnya seperti kata 'penegakan' menjadi 'tegak'.

### **4. Topic Modeling**

Pada tahap ini menerapkan metode *Latent Dirichlet Allocation* (LDA) untuk mengidentifikasi topik-topik yang ada dalam kumpulan ulasan aplikasi. Pada

metode LDA dibutuhkan yang namanya *corpus* berisikan kata unik atau *token* dari dataset. Tabel 4.7 merupakan contoh dari isi corpus

Tabel 7. Contoh Isi Corpus

['bbm', 'customer', 'driver', 'edit', 'harga', 'tumpang', 'murah', 'tarif', 'jarak', 'sesuai', 'ongkos', 'saldo', 'daftar', 'chat', 'autobid', 'mod', 'fitur', 'bot', 'akun', 'order', ]

Proses selanjutnya menghitung TF-IDF berdasarkan kamus *corpus* yang dibuat berdasarkan dataset menggunakan *library* Gensim. Tabel 7 merupakan contoh hasil TF-IDF.


Tabel 8. Contoh TF-IDF

[[0,1), (1,1)], [(0, 1)], [(0, 1)], [(0, 1)], [(2, 1)]

Setiap kata pada dataset diubah menjadi angka dan tidak akan berulang atau yang biasa disebut dengan token. Pada Tabel 8 angka sebelum tanda koma merupakan kata dan angka setelah tanda koma merupakan jumlah munculnya kata tersebut dalam sebuah ulasan.

a. Penentuan Jumlah Topik

Hasil dari TF-IDF selanjutnya digunakan dalam proses uji *clustering* aspek, pada sumbu X merupakan *number of topics* lalu untuk sumbu Y merupakan *coherence score*. *Number of topics* yang memiliki *coherence score* paling tinggi merupakan *num topics* terbaik untuk dipilih.



Gambar 3. Grafik Hasil Nilai Koherensi

Gambar 3 menunjukkan bahwa *coherence score* tertinggi didapat oleh *number of topics* 3 dengan *coherence score* 0,52, maka *number of topics* atau jumlah topik terbaik adalah 3.

b. Penentuan Nama Aspek

Berdasarkan hasil penghitungan nilai koherensi didapatkan *number topics* 3 sebagai yang terbaik untuk dijadikan aspek, dan nama label aspek akan diinterpretasikan berdasarkan kata-kata yang terbentuk dari pembagian topik oleh LDA yaitu: “Tarif dan Layanan Transportasi”, “Sistem Aplikasi”, “Fitur Lelang”.

**5. Labeling**

a. Labeling Data Aspek

Dengan hasil yang telah didapatkan dari *topic modeling*, per baris dokumen telah memiliki *dominant topic* nya masing-masing. Sehingga hanya perlu sedikit menyesuaikan dengan hasil yang ada.

Tabel 9. Contoh Pelabelan Apek Berdasarkan Hasil *Dominant Topic*

No	Kalimat Preprocessed	Aspek
1	tarif bawa standart contoh kemarin order indrive tarif rupiah cek aplikasi belah gojek harga rupiah yuk kawan cocol full kanan bodoh cocol full kanan bawah harga standart tumpang sok elit harga bikin driver cekik	Tarif dan Layanan Transportasi
2	akun tidak akses uang deposit hilang kacau	Sistem Aplikasi
3	kalah pakai mod deh standby kalah cepat aplikasi tuyul original kalah	Fitur Lelang

b. Labeling Data Sentimen

Data yang berhasil dilabeli aspeknya selanjutnya dilakukan pelabelan sentimen menggunakan label dominan dari Vader, TextBlob dan pelabelan manual.

**6. Klasifikasi**

a. Pembagian Data

Dataset untuk klasifikasi dibagi dengan metode hold-out yaitu data train sebanyak 80% dan data testing sebanyak 20% dari total data yang akan dilatih.

b. Klasifikasi Sentimen Menggunakan BERT

Proses fine-tuned IndoBERT ini menggunakan beberapa *hyperparameter* seperti *learning rate*, *dropout rate* dan *epochs* berdasarkan skenario percobaan yang ada pada tabel di bawah ini.

Tabel 12. Skenario Pengujian Sentimen

Data	Learning rate	Dropout rate	Epochs
Tanpa penyeimbangan kelas dan menggunakan penyeimbangan kelas (undersampling)	2e-5	0.1, 0.3	2, 4, 6, 8, 10

c. Klasifikasi Aspek Menggunakan BERT

Tabel 13. Skenario Pengujian Aspek

Data	Learning rate	Dropout rate	Epochs
Tanpa penyeimbangan kelas dan menggunakan penyeimbangan kelas (undersampling).	2e-5	0.1, 0.3	2, 4, 6, 8, 10

Pada proses klasifikasi aspek, terdapat beberapa kali pengujian dengan pemilihan *learning rate*, *dropout rate* dan *epochs* yang ada pada tabel 13 Learning rate 2e-5 dipilih karena dapat membuat BERT mengatasi masalah *catastrophic forgetting* (Sun dkk. 2019) dropout rate 0.1 dan 0.3 berdasarkan penelitian yang dilakukan oleh Liang dkk (2021) dan epoch 2,4,6,8,10 berdasarkan penelitian yang dilakukan oleh Said dan Manik (2022).

**7. Evaluasi**

Evaluasi model dilakukan menggunakan dataset *testing* untuk mengevaluasi apakah model klasifikasi menghasilkan *precision*, *recall*, *F1*, *accuracy* yang baik


atau tidak. Cara melakukan evaluasi ini yaitu dengan menggunakan *classification report* dari tiap skenario dan *confusion matrix* pada *classification report* terbaik.

1. Klasifikasi Sentimen Menggunakan BERT

Pada klasifikasi sentimen, terdapat beberapa skenario dari penggunaan *learning rate* 2e-5 dan perpaduan data, *dropout rate* dan *epoch*. Berikut adalah *classification report* dari tiap skenario.

Tabel 14. *Classification Report* Klasifikasi Sentimen


No.	Data	Dropout rate	Epoch	Accuracy	Precision	Recall	F1
1.	Imbalance	0.1	2	0.8668	0.8677	0.8668	0.8668
2.	Imbalance	0.1	4	0.8372	.8421	0.8372	0.8365
3.	Imbalance	0.1	6	0.8388	0.8409	0.8388	0.8384
4.	Imbalance	0.1	8	0.8459	0.8467	0.8459	0.8458
5.	Imbalance	0.1	10	0.8464	0.8472	0.8464	0.8465
6.	Imbalance	0.3	2	0.8434	0.8434	0.8434	0.8433
7.	Imbalance	0.3	4	0.8413	0.8414	0.8413	0.8412
8.	Imbalance	0.3	6	0.8464	0.8474	0.8464	0.8461
9.	Imbalance	0.3	8	0.8444	0.8448	0.8444	0.8442
10.	Imbalance	0.3	10	0.8444	0.8462	0.8444	0.8444
11.	Balance	0.1	2	0.8824	0.8826	0.8824	0.8824
12.	Balance	0.1	4	0.8903	0.8909	0.8903	0.8903
13.	Balance	0.1	6	0.8964	0.8965	0.8964	0.8964
14.	Balance	0.1	8	0.8894	0.8904	0.8894	0.8894
15.	Balance	0.1	10	0.8929	0.8934	0.8929	0.8929
16.	Balance	0.3	2	0.8613	0.8763	0.8613	0.8606
17.	Balance	0.3	4	0.8911	0.8912	0.8911	0.8911
18.	Balance	0.3	6	0.8911	0.8923	0.8911	0.8912
19.	Balance	0.3	8	0.9017	0.9030	0.9017	0.9016
<b>20.</b>	<b>Balance</b>	<b>0.3</b>	<b>10</b>	<b>0.9052</b>	<b>0.9081</b>	<b>0.9052</b>	<b>0.9050</b>



Gambar 4. Training Validation Accuracy dan Loss

Pada Gambar 4 menunjukkan performa model yang mana training accuracy cenderung meningkat seiring dengan peningkatan jumlah epoch dan training loss juga berkurang seiring dengan penambahan epoch. Namun pada validation accuracy dan loss terdapat ketidakstabilan pada validation accuracy dan loss, kemungkinan menandakan adanya overfitting. Overfitting dapat terjadi ketika model terlalu banyak menghafal data training dan kesulitan dalam menggeneralisir informasi pada data baru dengan baik.

## 2. Klasifikasi Aspek Menggunakan BERT



Gambar 5. Training Validation Accuracy dan Loss

Pada Gambar 5 menunjukkan performa model yang mana training accuracy cenderung meningkat seiring dengan peningkatan jumlah epoch dan training loss juga berkurang seiring dengan penambahan epoch. Namun pada validation accuracy dan loss terdapat ketidakstabilan pada validation accuracy dan loss, kemungkinan menandakan adanya overfitting. Overfitting dapat terjadi ketika model terlalu banyak menghafal data training dan kesulitan dalam menggeneralisir informasi pada data baru dengan baik.

Pada klasifikasi aspek, terdapat beberapa skenario dari penggunaan learning rate  $2e-5$  dan perpaduan data, dropout rate dan epoch. Berikut adalah classification report dari tiap skenario.

Tabel 15. *Classification Report* Klasifikasi Aspek

No.	Data	Dropout rate	Epoch	Accuracy	Precision	Recall	F1
1.	Imbalance	0.1	2	0.8327	0.8338	0.8327	0.8329
2.	Imbalance	0.1	4	0.8281	0.8307	0.8281	0.8233
3.	Imbalance	0.1	6	0.8332	0.8325	0.8332	0.8301
4.	Imbalance	0.1	8	0.8321	0.8358	0.8321	0.8325
5.	Imbalance	0.1	10	0.8444	0.8433	0.8444	0.8423
6.	Imbalance	0.3	2	0.8357	0.8354	0.8357	0.8344
7.	Imbalance	0.3	4	0.8429	0.8432	0.8429	0.8429
8.	Imbalance	0.3	6	0.8500	0.8490	0.8500	0.8482
9.	Imbalance	0.3	8	0.8464	0.8453	0.8464	0.8450
10.	Imbalance	0.3	10	0.8495	0.8481	0.8495	0.8483
11.	Balance	0.1	2	0.8780	0.8792	0.8780	0.8776
12.	Balance	0.1	4	0.8718	0.8761	0.8718	0.8702
13.	Balance	0.1	6	0.8859	0.8876	0.8859	0.8862
14.	Balance	0.1	8	0.8797	0.8831	0.8797	0.8802
15.	Balance	0.1	10	0.8683	0.8808	0.8683	0.8673
16.	Balance	0.3	2	0.8911	0.8922	0.8911	0.8912
17.	Balance	0.3	4	0.8859	0.8875	0.8859	0.8861
18.	Balance	0.3	6	0.8832	0.8833	0.8832	0.8832
19.	Balance	0.3	8	0.8920	0.8927	0.8920	0.8920
<b>20.</b>	<b>Balance</b>	<b>0.3</b>	<b>10</b>	<b>0.8929</b>	<b>0.8936</b>	<b>0.8929</b>	<b>0.8929</b>

### 8. Validasi

Dalam penelitian ini telah disiapkan 100 data ulasan baru untuk menjadi data validasi yang menghasilkan prediksi sentimen negatif sebanyak 43 dari 58 data yang benar dan untuk sentimen positif sebanyak 41 dari 42 data benar, sehingga bisa disimpulkan untuk prediksi sentimen mendapatkan *accuracy* sebesar 84%. Lalu untuk prediksi aspek menghasilkan prediksi aspek fitur lelang sebanyak 41 dari 37 data benar, sistem aplikasi sebanyak 30 dari 34 data benar dan tarif &

layanan sebanyak 29 dari 29 data benar dan bisa disimpulkan untuk prediksi aspek mendapatkan *accuracy* sebesar 92%.

## KESIMPULAN

Berikut adalah kesimpulan dalam membangun model analisis sentimen berbasis aspek ulasan aplikasi InDrive di google play store.

1. Pada penelitian ini ditemukan 3 aspek dominan yang didapatkan dari hasil topic modelling menggunakan LDA (Latent Dirichlet Allocation) dengan dataset periode 1 Januari 2023 – 11 Juli 2023 yaitu fitur lelang, sistem aplikasi dan tarif & layanan transportasi.
2. Model klasifikasi sentiment dengan akurasi terbaik (90%) yang didapatkan dalam penelitian ini yaitu dengan kombinasi hyperparameter dropout rate 0.3, epoch 10 dengan komposisi data yang seimbang.
3. Model klasifikasi aspek dengan akurasi terbaik (89%) yang didapatkan dalam penelitian ini yaitu dengan kombinasi hyperparameter dropout rate 0.3, epoch 10 dengan komposisi data yang seimbang.
4. Hasil uji validasi dengan 100 data ulasan baru menunjukkan keberhasilan dengan akurasi 92% untuk pengujian aspek dan 84% untuk pengujian sentimen.

## DAFTAR PUSTAKA

- Astutik, D. K. A., Indrasetianingsih, A., & Fitriani, F. (n.d.). Penerapan Text Mining pada Analisis Sentimen Pengguna Twitter Layanan Transportasi Online Menggunakan Metode Density Based Spatial Clustering of Applications with Noise (DBSCAN) dan K-Means. *J Statistika*, 5(1), 184 - 194. <https://doi.org/10.36456/jstat.vol15.no1.a5983>
- Classification? Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 11856 LNAI(2), 194–206. [https://doi.org/10.1007/978-3-030-32381-3\\_16](https://doi.org/10.1007/978-3-030-32381-3_16)
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 1*, 4171-4186. 10.18653/v1/N19-1423
- Dwianto, E., & Sadikin, M. (2021). Analisis Sentimen Transportasi Online pada Twitter Menggunakan Metode Klasifikasi Naïve Bayes dan Support Vector Machine. *Jurnal Format*, 10(1).
- Google & Temasek. (2022). e-Conomy SEA 2022: Unlocking the \$1 trillion digital opportunity in Southeast Asia. <https://www.temasek.com.sg/content/dam/temasek-corporate/news-and-views/resources/reports/e-Conomy SEA 2022 report.pdf>
- InDriver: Layanan Transportasi Online Baru Saingan Grab dan Gojek di Indonesia. (2022, January 15). Onlinejek. Retrieved May 26, 2023, from <https://onlinejek.com/indriver-layanan-transportasi-online/>
- Liang, X., Wu, L., Li, J., Wang, Y., Meng, Q., Qin, T., Chen, W., Zhang, M., & Liu, T.-Y. (2021). R-Drop: Regularized Dropout for Neural Networks. *NeurIPS*, 1–21. <http://arxiv.org/abs/2106.14448>

- Said, F., & Manik, L. P. (2022, 9). Aspect-Based Sentiment Analysis on Indonesian Presidential Election Using Deep Learning. *PARADIGMA Journal of Computer Science and Informatics*, 24(2), 160-167. <https://doi.org/10.31294/paradigma.v24i2.1415>
- Sun, C., Qiu, X., Xu, Y., & Huang, X. (2019). How to Fine-Tune BERT for Text