

PREDIKSI KETERLAMBATAN SEBUAH MASKAPAI MENGGUNAKAN METODE K-NEAREST NEIGHBOR

Ardiansyah Jaya Winata ¹⁾

¹⁾ Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara
Letjen S. Parman St No.1, RT.6/RW.16, Tomang, Grogol petamburan, West Jakarta City, Jakarta 11440
email : ardiansyah.535210014@stu.untar.ac.id

ABSTRACT

Penelitian ini bertujuan untuk membandingkan model prediksi keterlambatan penerbangan maskapai menggunakan tiga algoritma machine learning: K-Nearest Neighbor (KNN), Naïve Bayes, dan Random Forest. Data yang digunakan diperoleh dari platform Kaggle, terdiri dari 539.382 observasi dengan 6 atribut utama. Fitur target dalam prediksi adalah "Class", dengan fitur lain seperti 'Flight', 'Time', 'Length', 'Airline', dan 'DayOfWeek'. Dataset dibagi menjadi data latih (60%) dan data uji (40%). Hasil eksperimen menunjukkan bahwa metode K-Nearest Neighbor menghasilkan akurasi tertinggi sebesar 64%, diikuti oleh Random Forest dengan 62%, dan Naïve Bayes dengan 60%. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Penelitian ini menunjukkan bahwa metode K-Nearest Neighbor lebih unggul dibandingkan dua metode lainnya dalam memprediksi keterlambatan maskapai. Implikasi dari hasil ini mencakup potensi peningkatan efisiensi maskapai dalam memitigasi risiko keterlambatan, yang berdampak pada kepuasan pelanggan dan pengelolaan operasional.

Key words

Keterlambatan maskapai, K-Nearest Neighbor, Naïve Bayes, Random Forest

1. Pendahuluan

Perkembangan transportasi udara telah mengalami peningkatan signifikan sejak tahun 2003, dengan semakin banyak masyarakat yang memilih perjalanan menggunakan jasa penerbangan komersial [1]. Moda transportasi ini menunjukkan tanda-tanda pertumbuhan berkelanjutan di sektor penerbangan [2]. Terdapat banyak faktor yang menyebabkan transportasi udara semakin populer dan diminati masyarakat. Salah satu faktor utama adalah waktu, karena waktu sangat diperhitungkan dalam dunia transportasi. Ketika menggunakan transportasi udara dengan maskapai penerbangan, waktu yang diperlukan untuk menempuh jarak tertentu menjadi lebih singkat [1].

Meskipun perkembangan transportasi penerbangan membawa banyak keuntungan, dampak negatif juga tidak

dapat diabaikan, seperti terjadinya keterlambatan penerbangan. Keterlambatan penerbangan (*flight delay*) merupakan permasalahan serius dalam penerbangan komersial. Keterlambatan penerbangan (*flight delay*) didefinisikan sebagai perbedaan waktu antara jadwal keberangkatan atau kedatangan dengan waktu aktual keberangkatan atau kedatangan [3]. Keterlambatan bisa terjadi dikarenakan kondisi cuaca, kepadatan lalu lintas udara, masalah teknis pada pesawat, dan lain-lain [4][5]. Hal ini membuat permintaan transportasi udara semakin meningkat. Namun demikian, permintaan transportasi di sebagian besar bandara sibuk sering kali melebihi kapasitas bandara karena lambatnya peningkatan kapasitas bandara [6].

Di bandara-bandara besar, kemacetan merupakan hal yang lumrah, dan oleh karena itu, keterlambatan juga sering terjadi. Terbatasnya kapasitas mengakibatkan pesawat harus mengantri di darat untuk lepas landas (*take-off*) dan berputar-putar di udara sebelum mendarat (*landing*) [7]. Oleh karena itu, peneliti berupaya membuat klasifikasi untuk membandingkan tingkat keterlambatan dalam penerbangan dengan menggunakan metode algoritma *machine learning* seperti KNN (*K-Nearest Neighbor*), *Naïve Bayes*, dan *Random forest*. Penerapan algoritma *machine learning* dapat berguna karena data penerbangan yang dihasilkan cukup besar serta mencakup berbagai fitur dan kombinasi yang berpotensi memengaruhi keterlambatan [8]. Data keterlambatan maskapai dalam penelitian ini diperoleh dari platform Kaggle. Data tersebut berisi informasi terperinci mengenai waktu penerbangan, di mana ketepatan waktu sangat penting dalam berbagai aspek industri penerbangan secara keseluruhan [9].

2. Metode Penelitian

2.1 Data

Dalam penelitian ini, data yang digunakan diperoleh dari platform [Kaggle](https://www.kaggle.com). Dataset ini mencakup 539.382 observasi dan terdiri dari tujuh atribut utama. Atribut yang dijadikan target prediksi adalah "Class," yang memiliki dua nilai, yaitu "delay" (1) dan "no_delay" (0). Fitur-fitur lain yang digunakan dalam dataset meliputi 'Flight', 'Time',

'Length', 'Airline', 'AirportFrom', 'AirportTo', dan 'DayOfWeek'.

Beberapa tahap pra-pemrosesan data dilakukan untuk mempersiapkan dataset agar dapat digunakan dalam model prediksi. Fitur "AirportFrom" dan "AirportTo" dihapus karena hanya berisi kode kota yang tidak relevan dalam klasifikasi dan tidak memberikan kontribusi signifikan dalam memprediksi keterlambatan. Selain itu, fitur "Airline" diubah menjadi representasi numerik agar dapat diproses oleh algoritma machine learning yang digunakan.

2.2 Pra-pemrosesan

Dataset awal dibagi menjadi dua bagian, yaitu data latih (60%) dan data uji (40%). Pembagian ini bertujuan untuk menguji performa setiap metode dalam mengklasifikasikan penerbangan yang mengalami keterlambatan dan yang tidak. Hasil eksperimen dievaluasi dan dibandingkan berdasarkan nilai akurasi yang dihasilkan oleh setiap metode.

2.3 K-Nearest Neighbor

Algoritma KNN adalah sebuah algoritma untuk mengklasifikasikan objek berdasarkan data latih yang mempunyai jarak paling dekat dengan objek tersebut. K-Nearest Neighbor merupakan sebuah model machine learning untuk klasifikasi [10][11]. Cara kerja dari K-Nearest Neighbor (KNN) adalah melakukan klasifikasi dengan melihat kemiripan objek dengan kategori tertentu berdasarkan kelas terdekat [12].

$$D = \sqrt{(x_2 - y_1)^2 + (x_1 - y_2)^2} \quad (1)$$

D adalah Jarak tetangga terdekat, X digunakan sebagai Sampel data dan Y adalah Data uji

2.4 Naïve Bayes

Metode Naïve Bayes merupakan algoritma yang mampu menerima input dalam bentuk apa pun dan memiliki kecepatan tinggi dalam memproses data[13][14]. Naïve Bayes dalam penelitian ini digunakan untuk melakukan pengkategorian, seperti klasifikasi data menjadi kategori "delay" dan "no_delay". Konsep dasar yang digunakan pada Naïve Bayes adalah Teorema Bayes yang dinyatakan pertamakali oleh Thomas Bayes [15]. Pengklasifikasi Bayesian paling baik diterapkan pada masalah di mana informasi dari banyak atribut harus dipertimbangkan secara bersamaan untuk memperkirakan probabilitas keseluruhan dari suatu kejadian [16][17].

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2)$$

$P(A|B)P(A|B)P(A|B)$ menunjukkan probabilitas posteriori bahwa kejadian A terjadi setelah memperhitungkan informasi B, $P(B|A)P(B|A)P(B|A)$ menunjukkan probabilitas bahwa bukti B terjadi jika kejadian A benar-benar terjadi, $P(A)P(A)P(A)$ adalah probabilitas prior bahwa kejadian A terjadi tanpa memperhatikan bukti B, dan $P(B)P(B)P(B)$ adalah probabilitas bahwa bukti atau informasi B terjadi secara keseluruhan.

2.5 Random Forest

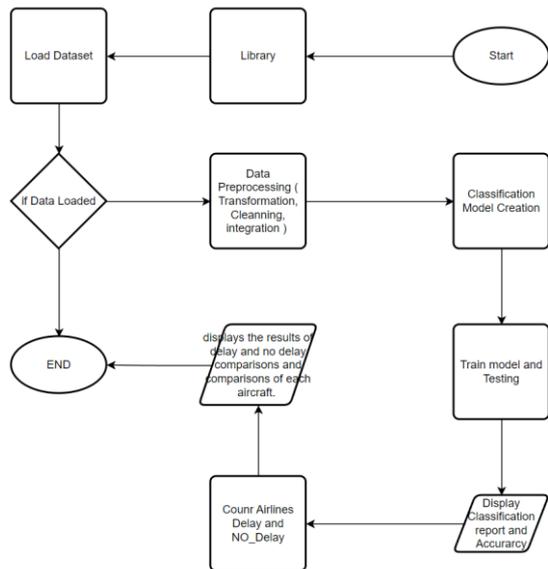
Random Forest merupakan salah satu algoritma machine learning untuk klasifikasi data dalam jumlah yang besar[18]. Metode ini merupakan sebuah ensemble (kumpulan) metode pembelajaran menggunakan pohon keputusan sebagai *base classifier* yang dibangun dan dikombinasikan. Decision tree atau pohon pengambil keputusan adalah sebuah diagram alir yang berbentuk seperti pohon, yang memiliki sebuah *root node* yang digunakan untuk mengumpulkan data[19]. Random Forest biasanya digunakan untuk analisa klasifikasi dan regresi [20].

$$\text{Gini} = 1 - \sum_{i=1}^c (P_i)^2 \quad (3)$$

Saat melakukan Random Forests berdasarkan data klasifikasi, indeks Gini digunakan sebagai faktor penentu dalam membuat keputusan tentang percabangan node pada pohon keputusan. Indeks Gini memungkinkan perhitungan ketidakmurnian atau ketidakjelasan di setiap cabang node, dan ini membantu dalam pemilihan cabang yang memiliki kemungkinan lebih tinggi untuk menghasilkan prediksi yang akurat. Dalam rumus ini, "pi" mengacu pada frekuensi relatif kelas yang diamati dalam data, dan "c" adalah jumlah kelas yang ada dalam masalah klasifikasi.

2.6 Skema Eksperimen

Skema eksperimen dalam penelitian yang akan dilakukan digambarkan pada gambar 1. Eksperimen akan dimulai dengan membuat library disusul dengan memanggil dataset dalam format csv. Yang setelah di panggil maka dilakukan Pra-processing sebuah data dengan mentransformasikan kelas Airline dan menghapus kelas AirportFrom dan AirportTo setelah hal itu maka proses akan dilanjutkan dengan membuat model K-Nearest Neighbor, Naïve Bayes dan Random Forest serta menjalankan Train model dan menampilkan output-output yang akan digunakan untuk di evaluasi lebih lanjut pada hasil dan pembahasan



Gambar 1 Skema Eksperimen dan Metode Evaluasi

2.7 Metode Evaluasi

Metode evaluasi akan dilakukan dengan ketiga metode yang sudah ditentukan, untuk metode K-Nearest Neighbor akan menggunakan kelas terdekat sebanyak 5 kelas. Setelah model ketiga metode tersebut sudah terbuat maka akan dilakukan report classification untuk melihat nilai akurasi yang di dapat dan melihat perbandingan jumlah *delay* dan *no_delay* secara keseluruhan dan secara permasing-masing maskapai penerbangan

3. Hasil Percobaan

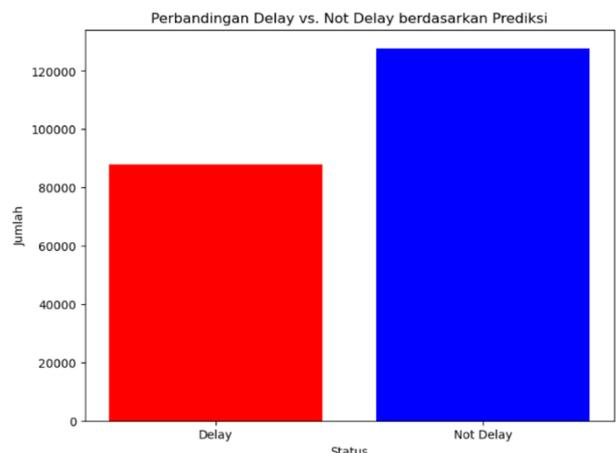
Hasil dari klasifikasi menggunakan 3 metode algoritma ini mendapatkan laporan klasifikasi yang memberikan informasi lebih tentang performa model.

Tabel 3 Laporan klasifikasi menggunakan K-Nearest Neighbor

	K-Nearest Neighbor		Naïve Bayes		Random Forest	
	0	1	0	1	0	1
Precision	66	60	61	56	65	57
Recall	71	55	73	43	67	55
F1-score	68	57	67	49	66	56
Accuracy	0.64		0.60		0.62	

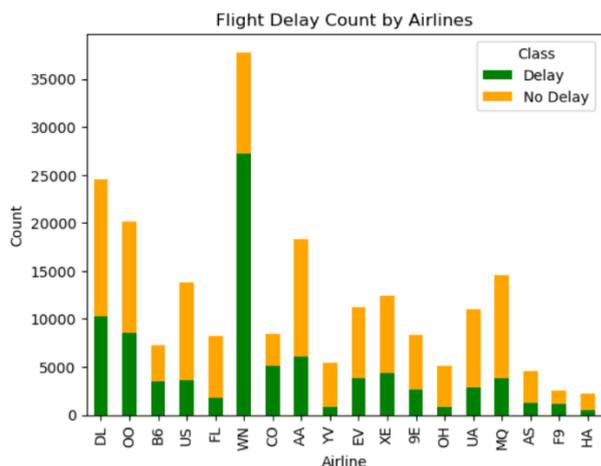
Hasil laporan klasifikasi menunjukkan bahwa akurasi yang di dapat dari metode K-Nearest Neighbor adalah 64% dengan nilai sepsifiknya yaitu 0.636704935736699% , pada metode Naïve Bayes adalah 60% dengan nilai spesifiknya yaitu 0.5955050451210412% , dan pada metode Random Forest, hasil akurasi yang di dapatkan adalah 62% dengan nilai spesifiknya yaitu 0.6168952459525476%. adapun hasil precision, recall,

dan F1-score. Precision merupakan sebuah ukuran yang mengukur tingkat proporsi jumlah dokumen yang dapat ditemukan kembali oleh sebuah proses pencarian dan dianggap relevan untuk kebutuhan pencarian informasi atau rasio jumlah dokumen relevan yang ditemukan dengan total jumlah dokumen yang ditemukan, dalam hasil laporan klasifikasi tersebut metode K-Nearest Neighbor menunjukkan bahwa dari semua prediksi yang dilakukan oleh model sebagai class 0 mendapatkan sekitar 66% sedangkan class 1 mendapatkan sekitar 60% , pada metode Naïve Bayes menunjukkan bahwa class 0 mendapatkan sekitar 61% sedangkan class 1 mendapatkan sekitar 56% dan pada metode Random Forest menunjukkan bahwa class 0 mendapatkan 65% sedangkan pada class 1 mendapatkan sekitar 57%. , pada hasil laporan klasifikasi K-Nearest Neighbor menunjukkan bahwa recall pada class 0 yaitu sekitar 71% dan class 1 55%, pada klasifikasi dengan Naïve Bayes menunjukkan bahwa recall pada class 0 yaitu sekitar 73% dan class 1 43%, dan pada klasifikasi Random Forest menunjukkan bahwa recall pada class 0 yaitu sekitar 67% dan class 1 55%. F1-score adalah perbandingan presisi dan perolehan rata-rata tertimbang, pada hasil laporan K-Nearest Neighbor menunjukkan bahwa F1-score di class 0 mendapatkan sekitar 68% dan class 1 mendapatkan sekitar 55%, pada hasil laporan Naïve Bayes menunjukkan bahwa F1-score di class 0 mendapatkan sekitar 67% dan class 1 mendapatkan sekitar 49%, dan pada hasil Random Forest menunjukkan bahwa F1-score di class 0 mendapatkan sekitar 66% dan class 1 mendapatkan sekitar 56%



Gambar 2 diagram perbandingan *delay* dan *no delay* dengan metode K-Nearest Neighbor

Dalam perbandingan disini, menunjukkan bahwa *not delay* lebih besar dari *delay* dengan nilai detailnya yaitu 88007 untuk *delay* dan 127746 untuk *no delay* . Adapun perbandingan seberapa banyak sebuah maskapai penerbangan terjadi *delay* dan *no delay*



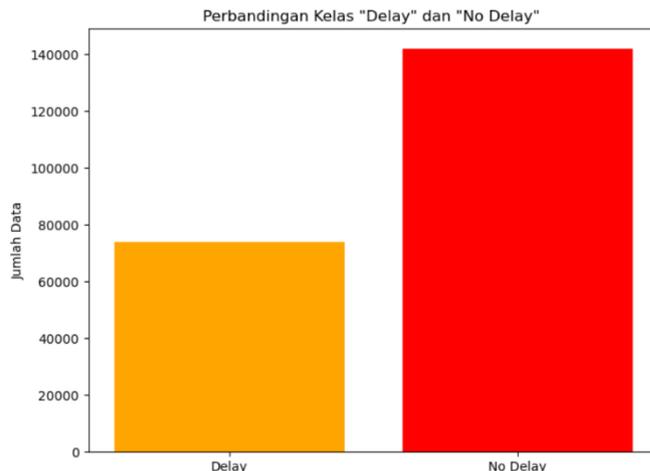
Gambar 3 diagram perbandingan seberapa sering pesawat mengalami *delay* dan *no delay* Pada metode *K-Nearest Neighbor*

Pada gambar diatas menunjukkan perbandingan beberapa maskapai penerbangan dalam seberapa sering mengalami keterlambatan, dalam diagram ini menunjukkan bahwa maskapai penerbangan dengan kode WM sering mengalami keterlambatan lebih banyak dari beberapa maskapai lainnya.

Tabel 4 nilai spesifik dari perbandingan setiap pesawat

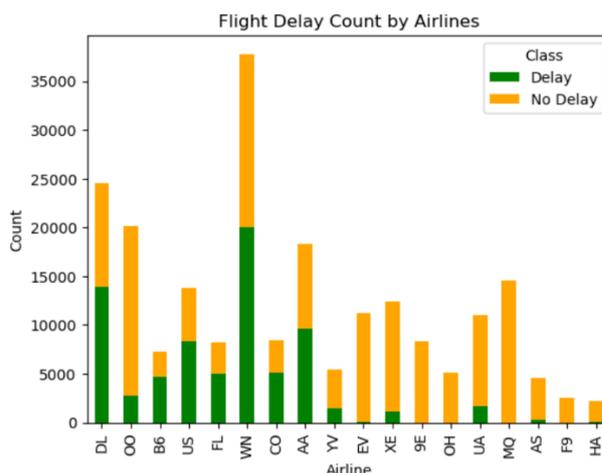
Airline	Delay	No Delay
DL	10255	14290
OO	8492	11660
B6	3483	3757
US	3600	10165
FL	1735	6526
WN	27187	10594
CO	5087	3357
AA	6079	12217
YV	841	4576
EV	3786	7406
XE	4406	7979
9E	2675	5664
OH	856	4213
UA	2898	8081
MQ	3810	10726
AS	1222	3396
F9	1089	1474
HA	506	1665

Berbeda dengan hasil *delay* dan *no_delay* dari *K-Nearest Neighbor*, pada klasifikasi *Naïve Bayes* memiliki perbandingan 73918 untuk *delay* dan 141835 *no_delay*.



Gambar 4 diagram perbandingan *delay* dan *no delay* dengan metode *Naïve Bayes*

Pada perbandingan setiap maskapai penerbangannya, *Naïve Bayes* mendapatkan hampir serupa dengan metode *K-Nearest Neighbor*.



Gambar 5 diagram perbandingan seberapa sering maskapai penerbangan mengalami *delay* dan *no delay* pada metode *Naïve Bayes*

Dalam diagram tersebut menunjukkan bahwa penerbangan dengan 'WM' memiliki *delay* dan *no_delay* paling banyak dari pesawat lainnya, Adapun nilai spesifik dari perbandingan pada gambar 5.

Tabel 5 nilai spesifik dari perbandingan setiap pesawat metode *Naïve Bayes*

Airline	Delay	No Delay
DL	13928	10617
OO	2719	17433
B6	4650	2590
US	8328	5437
FL	4961	3300
WN	20013	17768
CO	5137	3307
AA	9663	8633

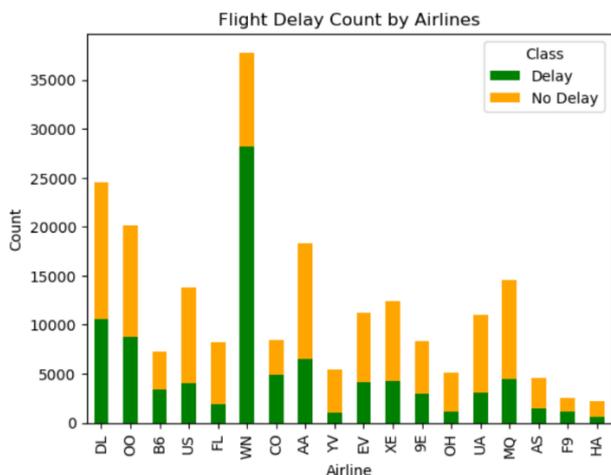
YV	1441	3976
EV	26	11166
XE	1144	11241
9E	3	8336
OH	0	5069
UA	1642	9337
MQ	0	14536
AS	246	4372
F9	0	2563
HA	17	2154

Pada klasifikasi Random Forest, hasil perbandingan *delay* dan *no_delay*nya adalah 92351 untuk *delay* dan 123402 *no_delay*. Dengan bentuk perbandingan diagram sebagai berikut :



Gambar 6 diagram perbandingan *delay* dan *no delay* dengan metode *Random Forest*

Adapun perbandingan *delay* dan *no_delay* setiap maskapai penerbangan, pada metode *Random Forest* perbandingan pesawat kode 'WM' memiliki kemiripan dengan *K-Nearest Neighbor* dan *Naïve Bayes*.



Gambar 7 diagram perbandingan seberapa sering maskapai penerbangan mengalami *delay* dan *no delay* pada metode *Random Forest* [3]

Pada perbandingan tersebut terlihat jelas bahwa maskapai penerbangan dengan kode 'WM' memiliki perbandingan *delay* dan *no_delay* paling tinggi dari beberapa maskapai penerbangan lainnya, dengan nilai spesifik sebagai berikut :

Tabel 6 nilai spesifik dari perbandingan setiap pesawat pada metode *Random Forest*

Airline	Delay	No Delay
DL	10628	13917
OO	8720	11432
B6	3377	3863
US	3999	9766
FL	1898	6363
WN	28204	9577
CO	4941	3503
AA	6539	11757
YV	1034	4383
EV	4150	7042
XE	4454	8131
9E	2947	5392
OH	1088	3981
UA	3033	7946
MQ	4463	10073
AS	1411	3207
F9	1116	1447
HA	549	1622

4. Kesimpulan

Dari ketiga metode ini, metode yang paling tinggi mendapatkan akurasi adalah metode *K-Nearest Neighbor* dengan akurasi mencapai 64% sedangkan metode yang mendekati akurasi *K-Nearest Neighbor* ialah metode *Random Forest* dengan akurasi mencapai 62% dan yang terkecil adalah *Naïve Bayes* dengan akurasi mencapai 60%. Hal ini menunjukkan bahwa *Naïve Bayes* kurang efektif dalam melakukan klasifikasi pada Data ini, Hal yang dapat dipertimbangkan dari ketiga metode ini dalam klasifikasi kedepannya yaitu menggunakan metode bantuan seperti *SMOTE* untuk menyeimbangkan setiap kelas dalam fitur agar mengurangi kemungkinan terjadinya ketidak seimbangan suatu kelas.

REFERENSI

S. Lolitha, S. Lukas, and F. Panduwina, "Prediksi Keterlambatan Penerbangan Menggunakan Metode Decision Tree Untuk Penentuan Premi Asuransi Perjalanan," *Prosiding Seminar Nasional Teknoka*, vol. 5, 2020, doi: 10.22236/teknoka.v5i.326.

W. Cheevachaiamol, B. Teinwan, and P. Chutima, "Flight delay prediction using a hybrid deep learning method," *Engineering Journal*, vol. 25, no. 8, 2021, doi: 10.4186/ej.2021.25.8.99.

V. Y. P. Ardhana et al., "Prediksi Flight Delay Berbasis Algoritma Neural Network," *Journal of Informatics*,

- Electrical and Electronics Engineering*, vol. 2, no. [11,5] 2022, doi: 10.47065/jieec.v2i1.429.
- [4] R. Kothari *et al.*, "Selection of Best Machine Learning Model to Predict Delay in Passenger Airlines," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3298979.
- [5] N. M. T. Dewi, "Perlindungan Hukum Bagi Penumpang Pesawat Udara Jika Terjadi Keterlambatan Jadwal Penerbangan Menurut Undang - Undang Nomor 1 Tahun 2009 Tentang Penerbangan," *KERTHA WICAKSANA*, vol. 15, no. 2, 2021, doi: 10.22225/kw.15.2.2021.124-129.
- [6] Z. Wang, C. Liao, X. Hang, L. Li, D. Delahaye, and M. Hansen, "Distribution Prediction of Strategic Flight Delays via Machine Learning Methods," *Sustainability (Switzerland)*, vol. 14, no. 22, 2022, doi: 10.3390/su142215180.
- [7] A. Geryana and D. Rachmawati, "Dampak Ketidaksesuaian Konfigurasi Parkir Pesawat di Parking Stand Bandar Udara Iskandar Pangkalan Bun Kalimantan Tengah," *El-Mal: Jurnal Kajian Ekonomi & Bisnis Islam*, vol. 5, no. 2, 2023, doi: 10.47467/elmal.v5i2.3534.
- [8] D. Schösser and J. Schönberger, "ON THE PERFORMANCE OF MACHINE LEARNING BASED FLIGHT DELAY PREDICTION – INVESTIGATION ON THE IMPACT OF SHORT-TERM FEATURES," *Promet - Traffic and Transportation*, vol. 34, no. 6, 2022, doi: 10.7307/ptt.v34i6.4132.
- [9] I. Hatipoğlu, Ö. Tosun, and N. Tosun, "FLIGHT DELAY PREDICTION BASED WITH MACHINE LEARNING," *Logforum*, vol. 18, no. 1, 2022, doi: 10.17270/J.LOG.2022.655.
- [10] A. N. Kasanah, M. Muladi, and U. Pujiyanto, "Penerapan Teknik SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Objektivitas Berita Online Menggunakan Algoritma KNN," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 3, no. 2, 2019, doi: 10.29207/resti.v3i2.945.
- [11] N. Azizah, M. Riyad Firdaus, R. Suyaningsih, and F. Indrayatna, "Penerapan Algoritma Klasifikasi K-Nearest Neighbor pada Penyakit Diabetes," *Prosiding Seminar Nasional Statistika Aktuaria*, vol. 2, no. 1, 2023.
- [12] S. Margareta, I. Arwani, and D. E. Ratnawati, "Implementasi Algoritma K-Nearest Neighbor Pada Database Menggunakan Bahasa SQL," *Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 7, 2020.
- [13] M. H. Setiono, "A KOMPARASI ALGORITMA DECISION TREE, RANDOM FOREST, SVM DAN K-NN DALAM KLASIFIKASI KEPUASAN PENUMPANG MASKAPAI PENERBANGAN," *INTI Nusa Mandiri*, vol. 17, no. 1, 2022, doi: 10.33480/inti.v17i1.3420.
- [14] M. B. Rissan and R. F. Hassan, "Naïve-Bayes family for sentiment analysis during COVID-19 pandemic and classification tweets," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 28, no. 1, 2022, doi: 10.11591/ijeecs.v28.i1.pp375-383.
- A. Z. Amrullah, A. Sofyan Anas, and M. A. J. Hidayat, "Analisis Sentimen Movie Review Menggunakan Naive Bayes Classifier Dengan Seleksi Fitur Chi Square," *Jurnal*, vol. 2, no. 1, 2020, doi: 10.30812/bite.v2i1.804.
- N. Husin, "Komparasi Algoritma Random Forest, Naïve Bayes, dan Bert Untuk Multi-Class Classification Pada Artikel Cable News Network (CNN)," *Jurnal Esensi Infokom : Jurnal Esensi Sistem Informasi dan Sistem Komputer*, vol. 7, no. 1, 2023, doi: 10.55886/infokom.v7i1.608.
- G. Gustientiedina, M. Siddik, and Y. Deselinta, "Penerapan Naïve Bayes untuk Memprediksi Tingkat Kepuasan Mahasiswa Terhadap Pelayanan Akademis," *Jurnal Infomedia*, vol. 4, no. 2, 2020, doi: 10.30811/jim.v4i2.1892.
- Y. Wanli Sitorus, P. Sukarno, S. Mandala, F. Informatika, and U. Telkom, "Analisis Deteksi Malware Android menggunakan metode Support Vector Machine & Random Forest," in *e-Proceeding of Engineering*, 2021.
- N. I. S. Baldanullah, N. Mulyarizki, I. Permatasari, I. P. Naufal, and D. C. Pratama, "Parallel Processing Pada Pemodelan Machine Learning Menggunakan Random Forest," *Journal of Informatics and Advanced Computing (JIAC)*, vol. 4, no. 1, 2023.
- M. L. Suliztia, "Penerapan Analisis Random Forest Pada Prototype Sistem Prediksi Harga Kamera Bekas Menggunakan Flask," *Fakultas Matematika Dan Ilmu Pengetahuan Alam*, 2020.