



Artikel Penelitian

Implementasi *Random Forest* Menggunakan SMOTE untuk Analisis Sentimen Ulasan Aplikasi *Sister for Students* UNEJ

Anisa Fitri Anjani^a, Dian Anggraeni^{b,*}, I Made Tirta^c

^{abc} *Jurusan Matematika Fakultas MIPA, Universitas Jember, Jl. Kalimantan Tegalboto No.37, Krajan Timur, Sumsbersari, Kec. Sumsbersari, 68121, Kabupaten Jember, Jawa Timur, Indonesia*

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 30 Maret 2023

Revisi Akhir: 22 Agustus 2023

Diterbitkan *Online*: 03 September 2023

KATA KUNCI

Random Forest,
SMOTE,
Analisis Sentimen,
Sister for Students

KORESPONDENSI

E-mail: dian_a.fmipa@unej.ac.id*

ABSTRACT

Pendidikan di era digital sangat memanfaatkan teknologi dan informasi sebagai prasarana pembelajaran melalui aplikasi milik perguruan tinggi tertentu. *Sister for Students* (SFS) merupakan aplikasi yang dikembangkan oleh UPT-TIK Universitas Jember yang memiliki peran sangat penting untuk menunjang kegiatan pembelajaran di Universitas Jember, sehingga perlu dilakukan analisis kualitas layanan aplikasi tersebut berdasarkan komentar oleh pengguna menggunakan analisis sentimen. Analisis sentimen merupakan klasifikasi teks yang dilakukan dengan tujuan memperoleh informasi dari pengguna mengenai kualitas layanan SFS. Masalah yang sering terjadi pada proses klasifikasi yaitu adanya data *imbalance*, salah satunya pada klasifikasi teks. SMOTE dilakukan untuk menangani data *imbalance* dengan cara membangkitkan data sintesis pada kelas minoritas, hal ini diharapkan agar kinerja klasifikasi lebih baik. Penelitian ini menggunakan metode klasifikasi *Random Forest* dan SMOTE dengan perbandingan proporsi *splitting* data 60:40, 70:30, 80:20 dan 90:10 untuk analisis sentimen pada ulasan aplikasi SFS. Data yang digunakan sebanyak 913 data dimana kelas positif sejumlah 363 dan negatif sejumlah 550. Hasil model terbaik yaitu model *Random Forest* menggunakan SMOTE dengan proporsi 90:10 dengan akurasi *testing* 98,9%, *recall* 100%, *precision* 96,7%, *f1-score* 98,3% dan nilai AUC sebesar 99,2%. Informasi yang diperoleh dari analisis sentimen SFS UNEJ diperoleh kata yang mengarah positif yaitu “bagus”, “mantap”, “keren”, “bantu”, “lumayan”, “lebihbaik”, “mudah”, “unej” dan “suka”. Kata yang mengarah pada sentimen negatif yaitu “eror”, “tidakbisa”, “presensi”, “jelek”, “update”, “ribet”, “sulit”, “forceclose” dan “qrcode”.

1. PENDAHULUAN

Proses pembelajaran saat ini tidak lagi hanya dilakukan secara luring namun dapat dilakukan secara daring melalui aplikasi-aplikasi yang dibuat oleh instansi perguruan tinggi tertentu. Salah satu aplikasi milik Universitas Jember yang digunakan untuk proses pembelajaran adalah *Sister for Students* (SFS). SFS merupakan aplikasi berbasis *mobile* yang dikembangkan oleh pihak Unit Pelaksana Teknis Teknologi Informasi dan Komunikasi (UPT-TIK) Universitas Jember. Peran SFS sangat penting untuk menunjang kegiatan pembelajaran di Universitas Jember sehingga perlu dilakukan analisis kualitas layanan aplikasi tersebut berdasarkan *review* oleh pengguna. Kualitas layanan suatu aplikasi dapat dianalisa menggunakan analisis sentimen.

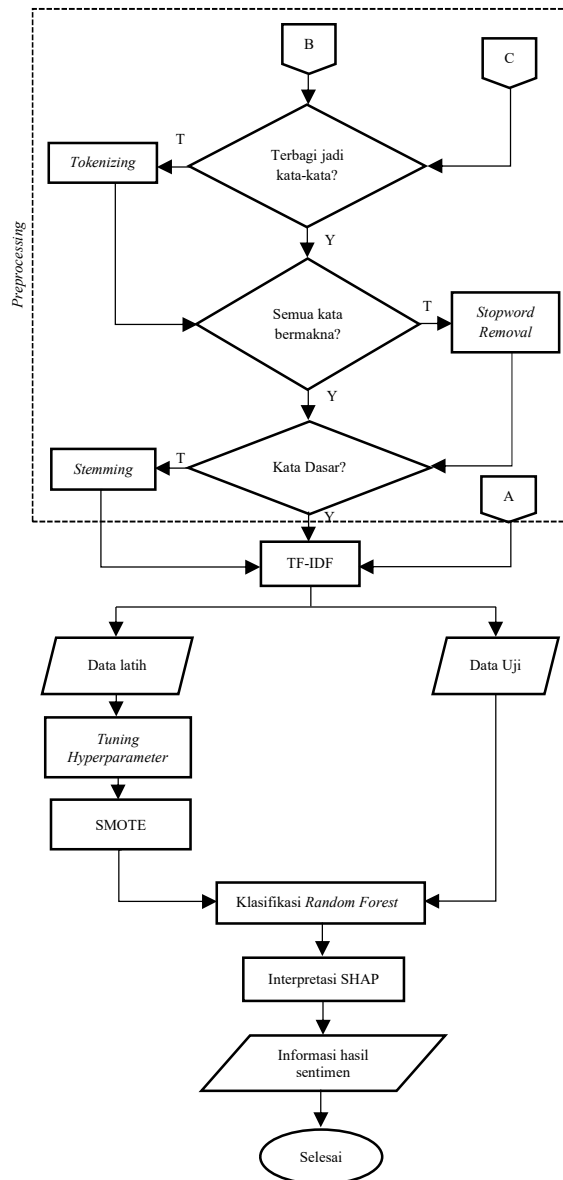
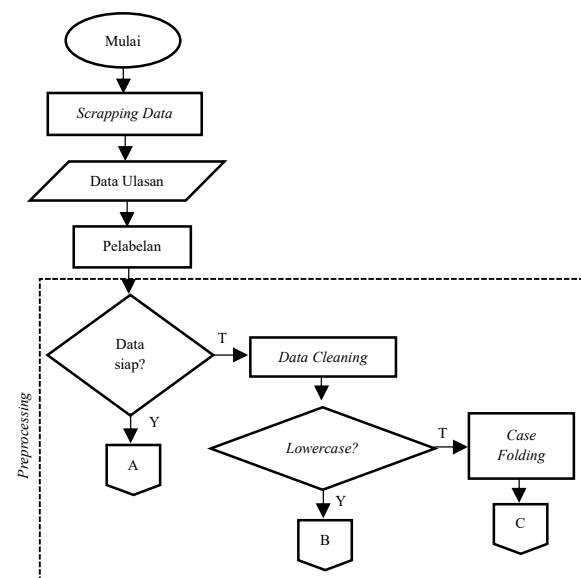
Analisis sentimen merupakan salah satu bentuk aplikasi *text mining* yang melakukan proses klasifikasi pada dokumen teks dengan tujuan memperoleh informasi pengguna mengenai kualitas suatu layanan. Sentimen pengguna dapat berupa permasalahan yang dapat mengarah ke hal positif, negatif ataupun netral dan dapat digunakan sebagai tolak ukur dalam meningkatkan pelayanan kualitas suatu aplikasi [1]. Menurut [2] masalah yang sering terjadi pada proses klasifikasi yaitu adanya data tidak seimbang (*imbalance*) salah satunya pada masalah klasifikasi teks. Ketidakseimbangan data terjadi ketika jumlah kelas data berbeda antar kelas lainnya. Metode SMOTE (*Synthetic Minority Oversampling Technique*) dapat menangani *imbalance* pada data. Metode ini dilakukan dengan menambah data sintesis (data yang baru dibangkitkan) pada kelas minoritas.

Penelitian analisis sentimen sebelumnya [3] dengan membahas sentimen pada aplikasi Duolingo menggunakan metode *Naive Bayes* dan *Synthetic Minority Over Sampling Technique*. Hasil penelitian ini diperoleh akurasi lebih tinggi dengan menggunakan *Naive Bayes* dan SMOTE yaitu 91,95% dibandingkan tanpa SMOTE menghasilkan akurasi 77,14%. Penelitian oleh [4] mengenai komparasi algoritma *Naive Bayes*, *Random Forest* dan *Support Vector Machine* untuk analisis sentimen aplikasi Ruangguru. Hasil akurasi yang diperoleh dari ketiga metode tersebut algoritma *Random Forest* menghasilkan nilai akurasi paling tinggi yaitu 97,16% dibanding kedua algoritma lainnya. Penelitian oleh [5] membahas sentimen *twitter* tentang protesnya petani India dengan komparasi beberapa metode klasifikasi. Penelitian ini diperoleh klasifikasi *Random Forest* menghasilkan akurasi model paling baik yakni 95,51% daripada metode klasifikasi *Naive Bayes*, *Decision Tree* dan *SVM*.

Dalam penelitian ini akan dilakukan analisis sentimen terhadap aplikasi pembelajaran Universitas Jember yaitu *Sister for Student* dengan menggunakan algoritma *Random Forest* dan SMOTE. SMOTE digunakan untuk mengatasi ketidakseimbangan kelas pada data ulasan aplikasi *Sister for Students*. Penelitian ini dilakukan untuk mengetahui ulasan pengguna terhadap aplikasi, dimana ulasan tersebut dapat menjadi masukan bagi pihak UPT-TIK untuk mempertahankan dan meningkatkan kualitas dan pelayanan akademik.

2. METODE

Populasi data dalam penelitian ini adalah data ulasan aplikasi pengguna *Sister for Student* yang berasal dari *Google Play*. Pengambilan data menggunakan *Python* yang diperoleh dari *scraping* data website *google play store* aplikasi *Sister for Students*. Selanjutnya yaitu dilakukan pelabelan manual, *preprocessing* (*cleaning*, *case folding*, *tokenizing*, *stop word removal* dan *stemming*), TF-IDF, klasifikasi *Random Forest* menggunakan SMOTE dan interpretasi SHAP seperti pada Gambar 1.



Gambar 1. Flowchart penelitian

2.1. Scrapping Data

Data ulasan aplikasi pengguna *Sister for Student* berasal dari *Google Play*. *Sister for Student* (SFS) merupakan aplikasi berbasis *mobile* yang dikembangkan oleh Unit Pelaksana Teknis Teknologi Informasi dan Komunikasi (UPT-TIK) Universitas Jember. Aplikasi ini memiliki banyak fitur yang dapat digunakan mahasiswa untuk *record* presensi perkuliahan, program rencana studi, melihat grafik indeks prestasi, transkrip nilai, tagihan, riwayat pembayaran UKT dan lain sebagainya [6]. Aplikasi SFS dirilis pada 24 Mei 2018 dan dapat diunduh secara gratis di *Play Store*. Berdasarkan informasi aplikasi yang tertera pada *play store*, SFS telah diunduh lebih dari 50.000 pengguna dan terdapat 3.818 ulasan yang terdiri dari 1.135 komentar dan 2.683 *rating* pengguna.

2.2. Text Preprocessing

Menurut [7] *text preprocessing* merupakan proses yang dilakukan untuk membersihkan data teks sebelum dilakukan analisis lebih lanjut. *Text preprocessing* membersihkan data hingga menjadi bentuk dasar dari setiap kata agar mudah untuk dilakukan analisis lebih lanjut. Tahap *text preprocessing* antara lain sebagai berikut.

- Cleaning* digunakan untuk membersihkan data, dengan cara menghapus karakter-karakter seperti tanda baca, url (link), hastag, username dan karakter selain alfabet dari A-Z.
- Case folding* digunakan untuk mengkonversi semua karakter huruf yang ada dalam dokumen menjadi *lowercase* (huruf kecil). Contoh *case folding* seperti "PT Astra" diubah menjadi "pt astra".
- Tokenizing* digunakan untuk membagi kalimat pada suatu dokumen menjadi kata-kata. Cara yang dilakukan pada proses tokenisasi ini memecah kalimat menjadi satuan kata.
- Stopword Removal* digunakan untuk menghapus kata-kata yang tidak penting dari text. *Stopword* sendiri adalah kata-kata yang sering muncul namun tidak terlalu penting digunakan dalam text mining. Contoh *Stopword* adalah "di", "ke", "akhirnya", "yang", "bagaimanapun", "dengan", "akan" dan lain-lain.
- Stemming* digunakan untuk mengubah kata yang berimbuhan menjadi kata dasar. Contoh *stemming* yaitu mengubah kata "makanan" menjadi "makan".

2.3. TF-IDF (Term Frequency-Inverse Document Frequency)

TF-IDF merupakan gabungan antara *Term Frequency* (TF) dengan *Inverse Document Frequency* (IDF), dimana hasil gabungan ini diperoleh dari perkalian antara kedua teknik tersebut [8]. *Term Frequency* (TF) yaitu metode pembobotan kata dimana frekuensi munculnya kata menunjukkan tingkat kepentingan kata dalam sebuah dokumen. *Inverse Document Frequency* (IDF) yaitu frekuensi semua dokumen yang mengandung suatu kata menunjukkan seberapa umum kata tersebut [9]. *Term Frequency-Inverse Document Frequency* (TF-IDF) dapat didefinisikan sebagai metode pembobotan kata dengan menghitung nilai frekuensi munculnya kata di suatu dokumen dan membandingkan kemunculan kata tersebut pada beberapa dokumen. Pembobotan TF-IDF dapat diformulasikan pada persamaan (1) [10].

$$TF - IDF = \left(\frac{f_{ij}}{l_i}\right) \times \left(\log\left(\frac{n}{n_j}\right) + 1\right) \quad (1)$$

2.4. SMOTE (Synthetic Minority Oversampling Technique)

SMOTE (*Synthetic Minority Oversampling Technique*) merupakan metode teknik *oversampling* yang digunakan untuk menangani masalah ketidakseimbangan data dengan pengolahan yang berbeda dari metode *oversampling* sebelumnya. Menurut [11] SMOTE dapat mengatasi masalah *overfitting*, tidak menyebabkan informasi hilang, dapat meningkatkan akurasi dan prediksi kelas. Proses SMOTE dilakukan dengan cara menentukan kelas minoritas pada data,

kemudian menentukan jarak k tetangga terdekat yang diperoleh dengan menghitung jarak *Euclidean* antar data minoritas. Selanjutnya membangkitkan data sintetis pada garis yang menghubungkan antar k tetangga terdekat dan menghasilkan titik acak pada garis. Rumus yang digunakan untuk membangkitkan data sintetis pada data tidak seimbang dengan metode SMOTE dapat dilihat pada persamaan (2). Perhitungan jarak tetangga terdekat pada data berskala numerik numerik dapat dihitung menggunakan jarak *Euclidean* pada Prsamaaan (3) [12].

$$X_{new} = X_i + (\bar{X}_k - X_i) \times \delta \quad (2)$$

$$d(i, j) = \sqrt{\sum_{i=k}^n (x_{ik} - x_{jk})^2} \quad (3)$$

2.5. Random Forest Classifier

Random Forest Classifier adalah metode klasifikasi yang terdiri dari beberapa kumpulan pohon keputusan (*decision tree*) yang menerapkan *majority vote* (suara terbanyak) untuk menentukan suatu keputusan. Pohon keputusan ini terdiri dari tiga bagian yaitu *root node*, *internal node* dan *leaf node*. Penentuan simpul atau akar dari pohon keputusan dapat menggunakan nilai *entropy* persamaan (4) dan nilai *information gain* persamaan (5) ataupun *gini index* persamaan (6) dan *gini split* persamaan (7). Cara kerja *Random Forest* secara keseluruhan diawali dengan menentukan pohon yang akan dibuat sebanyak n . Melakukan *bagging* dengan mengambil sampel dari fitur dan sampel baris untuk dilakukan pemodelan dengan *decision tree* sehingga terbentuk banyak pohon yang ditentukan. Setelah itu menggunakan *entropy* dan *information gain* atau *gini split index* untuk membuat pohon dan melihat hasil prediksi mayoritas [13].

$$Entropy(S) = \sum_{i=1}^n -P_i \log_2 P_i \quad (4)$$

$$Gain(S, J) = Entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} \times Entropy(S_i) \quad (5)$$

$$Gini(S) = 1 - \sum_{i=1}^n (P_i)^2 \quad (6)$$

$$Gini_{split} = \sum_{i=1}^n \frac{|S_i|}{|S|} \times Gini(S_i) \quad (7)$$

2.6. Confusion Matrix

Evaluasi yang dapat digunakan untuk mengukur kinerja klasifikasi dapat menggunakan *confusion matrix*. *Confusion matrix* mengandung informasi berupa perbandingan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi sebenarnya. *Confusion matrix* dilakukan untuk mengetahui sejauh mana model bekerja sesuai dengan apa yang kita inginkan. *Confusion matrix* dapat dinyatakan pada Tabel 1. Ukuran performa yang dapat digunakan untuk melihat hasil evaluasi model dapat menggunakan *accuracy* persamaan (8), *recall* persamaan (9), *precision* persamaan (10) dan *F-1 score* persamaan (11) [14].

Tabel 1. *Confusion matrix*

| Aktual | Prediksi | |
|-------------|-------------|-------------|
| | Negatif (0) | Positif (1) |
| Negatif (0) | TN | FP |
| Positif (1) | FN | TP |

(Sumber: Purnama, 2019)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\% \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \cdot 100\% \quad (9)$$

$$Precision = \frac{TP}{TP + FP} \cdot 100\% \quad (10)$$

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} \quad (11)$$

2.7. SHAP (Shapley Addictive Explanations)

Shapley Addictive Explanations (SHAP) dapat digunakan untuk melakukan interpretasi model *machine learning* dengan tujuan mengetahui kontribusi setiap fitur sehingga dapat menjelaskan prediksi masing-masing individu. Konsep SHAP adalah untuk mencari nilai terbaik antar fitur sesuai dengan seberapa penting kontribusi fitur tersebut dalam suatu model [15]. [16] mengatakan bahwa SHAP adalah metode yang populer untuk menginterpretasikan model *machine learning*. SHAP mampu memberikan penjelasan secara lokal maupun global yang didasarkan oleh nilai Shapley. Nilai Shapley dapat memberikan informasi secara adil diantara fitur.

Fitur dan nilai Shapley dapat divisualisasikan menggunakan *force plot*, dimana setiap nilai fitur adalah kekuatan untuk meningkatkan dan menurunkan suatu prediksi tertentu. Prediksi dilakukan dari *base value* atau rata-rata dari model, setiap nilai Shapley mendorong untuk meningkatkan (nilai positif) atau menurunkan (nilai negatif) prediksi. Prediksi untuk melihat kepentingan fitur secara global yang informatif dapat divisualisasikan menggunakan *summary plot*. Konsep *summary plot* yaitu menggabungkan *feature importance* dengan efek fitur. Titik-titik yang ada pada *summary plot* merupakan nilai Shapley dengan posisi sumbu *y* adalah fitur dan sumbu *x* nilai Shapley [17].

3. HASIL

3.1. Scraping Data

Scraping data sentimen aplikasi *Sister for Students* menggunakan bahasa pemrograman *python*. Ulasan diambil keseluruhan menggunakan *syntax reviews_all* dengan mencantumkan link *com.unej.sisterforstudent* yang diperoleh melalui *Google Play*. Data yang berhasil diambil sebanyak 1.135 yang dapat dilihat pada Tabel 2.

Tabel 2. *Scraping data*

| No. | Ulasan |
|-----|--|
| 0 | Beberapa (mayoritas) fitur sekadar pajangan saja dan kadang waktu presensi qrcode bermasalah padahal download dari siacad langsung |
| 1 | Aplikasi sering eror masa hasil studi sekarang tidakbisa dilihat |
| 2 | Dengan adanya sfs ini sangat membantu mahasiswa sangat bermanfaat dan mempermudah mahasiswa untuk presensi melihat jadwal kuliah Semoga kedepannya SFS ini bisa terus berkembang dan menjadi lebihbaik lagi |
| 3 | Aplikasinya lebih bagus dari sebelumnya, jaringan di aplikasi ini sudah bagus sekali dan sudah banyak fitur nya yang berguna untuk pembelajaran, saran saja agar menambahkan fitur kehadiran di login supaya jika terjadi masalah seperti elearning eror kita masih bisa masuk dari aplikasi ini dan untuk mencegah alpha. |

3.2. Pelabelan

Pelabelan dilakukan secara manual dengan menggunakan acuan daftar opini (positif/negatif). Pelabelan dibaca dengan saksama kemudian diberi label sesuai dengan konteks sentimen dan kata acuan yang mengandung sentimen setiap kalimat. Selain melakukan pelabelan juga dilakukan penghapusan kalimat yang tidak relevan dan tidak mengandung sentimen, sehingga data yang siap digunakan sebanyak 913 komentar. Hasil pelabelan ulasan *Sister for Students* dapat dilihat pada Tabel 3.

Tabel 3. Hasil pelabelan manual

| No. | Ulasan | Sentimen |
|-----|--|----------|
| 0 | Beberapa (mayoritas) fitur sekadar pajangan saja dan kadang waktu presensi qrcode bermasalah padahal download dari siacad langsung | Negatif |
| 1 | Aplikasi sering eror Masa hasil studi sekarang tidakbisa dilihat | Negatif |
| 2 | Dengan adanya sfs ini sangat membantu mahasiswa sangat bermanfaat dan mempermudah mahasiswa untuk presensi melihat jadwal kuliah Semoga kedepannya SFS ini bisa terus berkembang dan menjadi lebihbaik lagi | Positif |
| 3 | Aplikasinya lebih bagus dari sebelumnya, jaringan di aplikasi ini sudah bagus sekali dan sudah banyak fitur nya yang berguna untuk pembelajaran, saran saja agar menambahkan fitur kehadiran di login supaya jika terjadi masalah seperti elearning eror kita masih bisa masuk dari aplikasi ini dan untuk mencegah alpha. | Positif |


3.3. Preprocessing

Tahap *Preprocessing* akan menghilangkan tanda baca, karakter selain huruf, kata-kata tidak bermanfaat dan mengubah kata menjadi bentuk dasar yang akan digunakan untuk analisis. Tahapan *preprocessing* yang penulis gunakan antara lain *cleaning*, *case folding*, *tokenizing*, *stopword removal* dan


stemming. Hasil data setelah preprocessing dapat dilihat pada Tabel 4. Data setelah preprocessing dari sentimen positif divisualisasikan menggunakan word cloud seperti pada Gambar 1 dan sentimen negatif pada Gambar 2. Kata yang memiliki frekuensi kemunculan paling banyak ditunjukkan oleh kata yang memiliki ukuran besar, yaitu kata “bagus”, “mantap” dan “keren” untuk dokumen yang mengandung sentimen positif. Kata “presensi”, “eror” dan “tidakbisa” merupakan kata yang mendominasi dari dokumen sentimen negatif.

Tabel 4. Hasil preprocessing

| No. | Ulasan | Sentimen |
|-----|---|----------|
| 0 | fitur presensi qrcode masalah download siakad | Negatif |
| 1 | aplikasi eror hasil tidakbisa | Negatif |
| 2 | sfs bantu mahasiswa manfaat mudah mahasiswa presensi jadwal kuliah sfs kembang lebihbaik | Positif |
| 3 | aplikasi bagus jaring aplikasi bagus fitur fitur guna ajar tambah fitur hadir login elearning eror masuk aplikasi alpha | Positif |



Gambar 1. Word cloud sentimen positif



Gambar 2. Word cloud sentimen negatif

3.4. TF-IDF (Term Frequency-Inverse Document Frequency)

TF-IDF dilakukan untuk memperoleh pembobotan tiap kata yang ada tiap dokumen. Hasil pembobotan yang diperoleh terdapat pada Tabel 5, dimana hasil yang diperoleh dapat dikatakan bahwa kata yang banyak muncul tiap dokumen akan memiliki bobot nilai kecil, sedangkan kata yang jarang muncul akan memiliki nilai bobot besar.

Tabel 5. Hasil TF-IDF

| No. | Kata | TF-IDF | Label |
|-----|----------|-------------------|---------|
| 0 | fitur | 0,323769472813996 | Negatif |
| | presensi | 0,236084608648383 | |
| | qrcode | 0,300755363830046 | |
| | masalah | 0,499527391179826 | |
| | download | 0,388139340645653 | |
| | siakad | 0,590596169023113 | |
| : | : | : | : |

<https://doi.org/10.25077/TEKNOSI.v9i2.2023.163-172>

| No. | Kata | TF-IDF | Label |
|-----|-----------|-------------------|---------|
| 3 | aplikasi | 0,357657030630871 | Positif |
| | bagus | 0,286401255760606 | |
| | jaring | 0,240594931363861 | |
| | fitur | 0,536686895240611 | |
| | guna | 0,262832388267219 | |
| | ajar | 0,268948455799421 | |
| | tambah | 0,389463378318976 | |
| | hadir | 0,244261085037314 | |
| | login | 0,177988622514974 | |
| | elearning | 0,248246420974272 | |
| | eror | 0,117508852700484 | |
| | masuk | 0,207118478577506 | |
| | alpha | 0,20229270677714 | |

3.5. Random Forest Menggunakan SMOTE

Random Forest memerlukan splitting data untuk membagi data training data testing. Splitting data dilakukan menggunakan package sklearn.model_selection dengan mengimpor train_test_split. Penelitian ini menggunakan empat perbandingan splitting data dengan proporsi data training dan data testing yaitu 60:40, 70:30, 80:20 dan 90:10 untuk mengetahui hasil proporsi pada tiap model. Hasil splitting data untuk data training dapat dilihat pada Tabel 6.

Tabel 6. Data training

| Proporsi | Data Training | | Jumlah |
|----------|---------------|---------|--------|
| | Positif | Negatif | |
| 90:10 | 333 | 488 | 821 |
| 80:20 | 290 | 440 | 730 |
| 70:30 | 251 | 388 | 639 |
| 60:40 | 219 | 328 | 547 |

Data yang telah di splitting dilakukan proses tuning hyperparameter menggunakan Grid Search. Cara kerja grid search sendiri yaitu dengan mengacak nilai yang dimasukkan pada hyperparameter dan diperoleh parameter terbaik dari hasil kombinasi nilai tersebut. Hyperparameter terbaik yang diperoleh tiap proporsi terdapat pada Tabel 7.

Tabel 7. Hyperparameter tiap proporsi

| Proporsi | Parameter | | | | | |
|----------|--------------|-----------|------------------|-------------------|-------------|-----------|
| | random state | max depth | min samples leaf | min samples split | n estimator | criterion |
| 90:10 | 100 | 30 | 1 | 10 | 100 | gini |
| 80:20 | 42 | 15 | 1 | 2 | 200 | gini |
| 70:30 | 100 | 25 | 1 | 15 | 50 | gini |
| 60:40 | 1 | 15 | 2 | 15 | 200 | entropy |

Data training yang dihasilkan dari tiap proporsi pada Tabel 6 menunjukkan bahwa data tidak seimbang, karena jumlah kelas positif lebih sedikit daripada kelas negatif sehingga dilakukan penyeimbangan data menggunakan SMOTE. Package yang digunakan pada SMOTE yaitu imblearn.over_sampling dengan mengimpor SMOTE. Tahapan pada SMOTE ini dengan menentukan kelas minoritas kemudian membangkitkan data

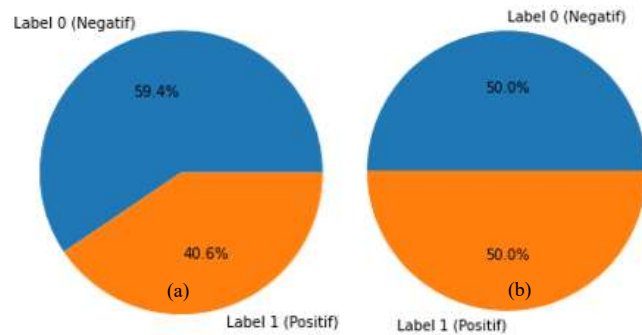
berdasarkan jarak k tetangga terdekat. Jumlah k tetangga terdekat yang digunakan pada penelitian ini adalah $k = 50$, kemudian data dibangkitkan secara acak sehingga menghasilkan data sintetis (Tabel 8).

Tabel 8 Hasil data sintetis

| No. | Komentar | TF-IDF | Label |
|-----|--------------------|---|---------|
| 823 | luarbiasa keren | 0,125467490400267 0,874532509599733 | Positif |
| : | : | : | : |
| 977 | kembang krs | 0,0386019847074139 0,462663353413632 | Positif |

| No. | Komentar | TF-IDF | Label |
|-----|----------|--------------------|-------|
| | lancar | 0,530319583489469 | |
| | pintar | 0,0526387274276565 | |
| | positif | 0,0526387274276565 | |
| | tingkat | 0,577695767574312 | |
| | unej | 0,0312515284964482 | |

Data *training* sebelum dan setelah SMOTE pada proporsi 90:10 divisualisasikan menggunakan *pie chart* seperti pada Gambar 3. Selisih kelas positif dan negatif pada proporsi 90:10 yaitu 155 data atau disebut tidak seimbang sebesar 40,6% data minoritas dari keseluruhan data seperti pada Gambar 3(a). Setelah dilakukan SMOTE jumlah kelas positif dan negatif sama besar yaitu 488 atau data disebut seimbang seperti pada Gambar 3(b).



(a) Sebelum SMOTE; (b) Setelah SMOTE

Gambar 3. Visualisasi sebelum dan setelah SMOTE proporsi 90:10

Data *training* tiap proporsi yang telah di SMOTE dilakukan untuk melatih model dan data *testing* dilakukan untuk menguji model pada klasifikasi *Random Forest*. Klasifikasi *Random Forest* menggunakan *package* `sklearn.ensemble` dengan mengimpor `RandomForestClassifier`. Data *training* dan data *testing* tiap proporsi dilakukan pemodelan menggunakan masing-masing parameter terbaiknya. Secara umum kerja *Random Forest* sendiri diawali dengan menentukan jumlah pohon, dilanjut dengan mengambil sampel untuk pemodelan. Setelah itu membangun pohon dengan *gini split indeks* atau *information gain* dan diperoleh hasil prediksi klasifikasi. Evaluasi pengujian model menggunakan *package* `sklearn.metrics` dengan mengimpor `confusion_matrix` dan `roc_auc_score`. Hasil *confusion matrix* dan performa model menggunakan *Random Forest* setelah SMOTE berturut-turut dapat dilihat pada Tabel 9 dan Tabel 10.

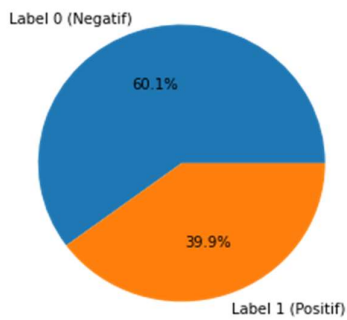
Tabel 9. *Confusion matrix random forest SMOTE*

| Proporsi | Aktual | <i>Random Forest+SMOTE</i> | |
|----------|---------|----------------------------|---------|
| | | Prediksi | |
| | | Negatif | Positif |
| 90:10 | Negatif | 61 | 1 |
| | Positif | 0 | 30 |
| 80:20 | Negatif | 107 | 3 |
| | Positif | 0 | 73 |
| 70:30 | Negatif | 158 | 4 |
| | Positif | 4 | 108 |
| 60:40 | Negatif | 216 | 6 |
| | Positif | 7 | 137 |

Sebagai contoh pada hasil *confusion matrix* proporsi 90:10 diperoleh secara keseluruhan 30 komentar positif, dimana 30 komentar diprediksi dengan benar dan 0 komentar diprediksi salah. Jumlah komentar negatif sejumlah 62 komentar, dimana 61 komentar diprediksi dengan benar dan 1 komentar diprediksi salah. Performa evaluasi akurasi *training* pada proporsi 90:10 *Random Forest* menggunakan SMOTE diperoleh 0,985 atau sebesar 98,5% data *training* dapat membentuk model, pada akurasi *testing* diperoleh sebesar 0,989 atau 98,9% data dapat diprediksi dengan benar oleh model. Hasil pada *recall* menunjukkan sebesar 100% kelas positif dalam dataset diprediksi dengan benar dan pada *precision* sebesar 96,7% kelas yang diprediksi positif sebenarnya adalah kelas positif dalam dataset. Hasil prediksi klasifikasi model dapat dilihat pada Gambar 4, diperoleh komentar positif SFS yaitu 39,9% atau sejumlah 364 komentar dan komentar negatif yaitu 60,1% atau sejumlah 549 komentar.

Tabel 10. Performa evaluasi *random forest SMOTE*

| Proporsi | Akurasi | | Recall | F-1 Score | Precision | AUC |
|----------|---------|-------|--------|-----------|-----------|-------|
| | Train | Test | | | | |
| 90:10 | 0,985 | 0,989 | 1,000 | 0,983 | 0,967 | 0,992 |
| 80:20 | 0,980 | 0,983 | 1,000 | 0,979 | 0,960 | 0,986 |
| 70:30 | 0,989 | 0,970 | 0,964 | 0,964 | 0,964 | 0,969 |
| 60:40 | 0,987 | 0,964 | 0,951 | 0,954 | 0,958 | 0,962 |



Gambar 4. Prediksi klasifikasi model proporsi 90:10

3.6. SHAP (Shapley Addictive Explanations)

Informasi analisis sentimen SFS pada penelitian ini diperoleh melalui interpretasi *Shapley Addictive Explanations* (SHAP) dengan menggunakan *shap.TreeExplainer* dan mengimpor *library shap*. SHAP yang digunakan untuk menggambarkan interpretasi lokal pada penelitian ini yaitu *force plot*, plot ini digunakan untuk melihat bagaimana kata-kata berkontribusi pada prediksi model. Sampel yang digunakan dengan komentar “sfs bantu mahasiswa manfaat mudah mahasiswa presensi jadwal kuliah sfs kembang lebihbaik” menghasilkan *force plot* seperti pada Gambar 5.




Gambar 5. Force plot sampel positif

Dapat dilihat titik-titik nilai shapley yang terdorong ke arah kiri (kelas 0) yaitu kata “eror”, “tidakbisa”, “presensi”, “jelek”, “update”, “ribet”, “sulit”, “forceclose” dan “qrcode”. Artinya, kata-kata tersebut merupakan kata yang paling berkontribusi untuk memprediksi sentimen negatif. Kata-kata tersebut mengindikasikan bahwa aplikasi SFS eror saat melakukan KRS, hasil studi yang tidak bisa dilihat, tidak bisa melakukan presensi, sulit scan QR code dan sering terjadinya *force close*.

Force plot menghasilkan nilai prediksi dari komentar senilai 0,94 dan prediksi rata-rata model (*base value*) senilai 0,4995. Dapat dilihat nilai dari *base value* terdorong ke arah kanan menuju nilai prediksi 0,94 yang menunjukkan bahwa komentar mengarah ke kelas 1, artinya komentar tersebut mengarah ke kelas positif. Kata-kata yang paling berkontribusi dalam meningkatkan

prediksi (ke arah positif) yaitu kata “bantu”, “mudah”, “lebihbaik” dan “kembang”, sedangkan kata “presensi” berkontribusi dalam mengurangi prediksi (ke arah negatif).


Sampel yang digunakan dengan komentar “aplikasi eror hasil tidakbisa” menghasilkan *force plot* seperti pada Gambar 6. Plot tersebut menghasilkan nilai prediksi komentar senilai 0,01 dan prediksi rata-rata model (*base value*) senilai 0,4995. Dari nilai *base value* terdorong ke arah kiri menuju nilai prediksi 0,01 yang menunjukkan komentar mengarah ke kelas 0, artinya komentar tersebut mengarah ke kelas negatif. Kata-kata yang paling berkontribusi dalam mengurangi prediksi (ke arah negatif) yaitu kata “eror”, “tidakbisa” dan tidak terdapat kata yang berkontribusi untuk meningkatkan prediksi (ke arah positif).




Gambar 5. Force plot sampel negatif

Interpretasi model secara global dilakukan menggunakan *summary plot* dapat dilihat pada Gambar 7. Kata-kata yang dihasilkan pada sumbu vertikal sebelah kiri merupakan urutan kata-kata berdasarkan tingkat kontribusinya pada prediksi model. Warna yang ada pada sumbu vertikal sebelah kanan menunjukkan tinggi atau rendahnya nilai suatu fitur, jika berwarna merah maka fitur tersebut tinggi, jika warna biru maka suatu fitur rendah.

Kata “bagus”, “mantap”, “keren”, “bantu”, “lumayan”, “lebihbaik”, “mudah”, “unej” dan “suka” menghasilkan titik-titik nilai shapley yang terdorong ke arah kanan (kelas 1), yang berarti kata-kata tersebut merupakan kata yang paling berkontribusi untuk memprediksi sentimen positif. Dari kata tersebut sebagian pengguna puas dengan layanan aplikasi karena fitur-fitur yang semakin bagus, tampilan yang menyenangkan, lebih baik dari versi sebelumnya, sangat membantu dan mempermudah kegiatan pembelajaran. Visualisasi secara global juga dapat dilihat menggunakan *feature importance* SHAP (Gambar 8) untuk melihat pengaruh fitur secara keseluruhan tanpa melihat kontribusi kata pada masing-masing kelas. Plot ini diperoleh bahwa fitur “eror”, “bagus”, “tidakbisa”, “mantap” dan “presensi” tetap menjadi fitur yang memiliki kontribusi paling besar dalam memprediksi kelas sentimen.



Gambar 6. Summary plot random forest SMOTE



Gambar 7. Summary bar plot random forest SMOTE

4. PEMBAHASAN

Berdasarkan hasil penelitian pada evaluasi (Tabel 9) dan performa model (Tabel 10) masing-masing proporsi menunjukkan hasil performa yang sangat baik. Secara keseluruhan SMOTE tidak memberikan pengaruh besar pada keempat proporsi model. Hal ini disebabkan *Random Forest* sudah sangat baik dalam memprediksi sejumlah 913 data dengan rata-rata ketidakseimbangan data sebesar 40,6%, namun SMOTE

dapat menaikkan performa akurasi *testing* pada proporsi 80:20 sebesar 0,005. SMOTE juga mampu menaikkan performa *recall*, *f-1-score* dan *precision* pada tiap proporsi. Selain itu jika dilihat dari nilai AUC, SMOTE dapat menaikkan nilai pada keempat proporsi dan mampu mengurangi kesalahan prediksi pada kelas positif di proporsi 80:20, 70:30 dan 60:40.

Peneliti menentukan diantara keempat proporsi model tersebut model terbaik yaitu proporsi *splitting* data 90:10 dengan model *Random Forest* menggunakan SMOTE. Hal tersebut jika dilihat

dari performa yang dihasilkan model dapat memprediksi data dengan benar yaitu dengan rata-rata 0,985 dimana lebih besar dari proporsi lainnya. Proporsi 90:10 juga menghasilkan nilai AUC paling besar diantara keempat proporsi yaitu senilai 0,992 yang artinya model mampu memprediksi data dengan benar sebesar 0,992 atau 99%. Hasil prediksi klasifikasi model diperoleh komentar positif sejumlah 364 dan komentar negatif sejumlah 549, hasil prediksi tersebut hanya selisih 1 dengan data aktual sehingga dapat diartikan model dengan proporsi 90:10 bekerja sangat baik.

Informasi yang diperoleh dari hasil visualisasi *Shapley Addictive Explanation* (SHAP) pada Gambar 7, diperoleh bahwa klasifikasi SFS yang mengarah pada sentimen positif yaitu “bagus”, “mantap”, “keren”, “bantu”, “lumayan”, “lebihbaik”, “mudah”, “unej” dan “suka”, dari kata tersebut sebagian pengguna puas dengan layanan aplikasi karena fitur-fitur yang semakin bagus, tampilan yang menyenangkan, lebih baik dari versi sebelumnya, sangat membantu dan mempermudah kegiatan pembelajaran. Informasi tersebut diperoleh untuk mempertahankan aplikasi dari segi fitur-fitur yang disediakan dan tampilan pada SFS. Kata yang mengarah pada sentimen negatif yaitu “eror”, “tidakbisa”, “presensi”, “jelek”, “update”, “ribet”, “sulit”, “forceclose” dan “qrcode”, dimana kata tersebut mengindikasikan aplikasi SFS masih belum memberikan layanan secara optimal kepada pengguna. Kurangnya pelayanan ini disebabkan karena eror saat melakukan KRS, hasil studi yang tidak bisa dilihat, tidak bisa melakukan presensi, sulit scan QR code dan sering terjadinya *force close*. Informasi tersebut diperoleh untuk menjadi masukan kepada pihak UPT-TIK Universitas Jember agar meningkatkan kualitas dalam mengakses seluruh fitur antara lain KRS, presensi, hasil studi, scan QR code serta memperbaiki *force close* pada aplikasi.

5. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dipaparkan, diperoleh kesimpulan bahwa hasil klasifikasi model terbaik sentimen SFS UNEJ yaitu proporsi *splitting* data 90:10 dengan model *Random Forest* menggunakan SMOTE. Proporsi tersebut menghasilkan performa klasifikasi akurasi *training* sebesar 98,5%, akurasi *testing* 98,9%, *recall* 100%, *precision* 96,7%, *f1-score* 98,3% dan nilai AUC sebesar 99,2%. SMOTE yang digunakan pada model dapat meningkatkan performa klasifikasi dan mengurangi kesalahan prediksi, namun secara keseluruhan tidak memberikan pengaruh yang besar. Hal ini disebabkan karena *Random Forest* telah mampu mengklasifikasikan 913 data dengan rata-rata ketidakseimbangan data *training* sebesar 39,87%. Berdasarkan hasil performa dan prediksi klasifikasi, model mampu mengklasifikasikan komentar aplikasi SFS UNEJ dengan sangat baik.

Informasi yang diperoleh dari analisis sentimen SFS UNEJ diperoleh kata yang mengarah positif yaitu “bagus”, “mantap”, “keren”, “bantu”, “lumayan”, “lebihbaik”, “mudah”, “unej” dan “suka”, dari kata tersebut sebagian pengguna puas dengan layanan aplikasi karena fitur-fitur yang semakin bagus, tampilan yang menyenangkan, lebih baik dari versi sebelumnya, sangat membantu dan mempermudah kegiatan pembelajaran. Kata yang mengarah pada sentimen negatif yaitu “eror”, “tidakbisa”,

<https://doi.org/10.25077/TEKNOSI.v9i2.2023.163-172>

“presensi”, “jelek”, “update”, “ribet”, “sulit”, “forceclose” dan “qrcode”. Kata tersebut mengindikasikan SFS masih belum memberikan layanan secara optimal yang disebabkan karena eror saat melakukan KRS, hasil studi yang tidak bisa dilihat, tidak bisa melakukan presensi, sulit scan QR code dan sering terjadinya *force close*.

DAFTAR PUSTAKA

- [1] W. E. Nurjanah, R. Setya Perdana, and M. A. Fauzi, “Analisis sentimen terhadap tayangan televisi berdasarkan opini masyarakat pada media sosial twitter menggunakan metode k-kearest neighbor dan pembobotan jumlah retweet,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 12, pp. 1750–1757, 2017, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [2] R. Siringoringo, “Klasifikasi data tidak Seimbang menggunakan algoritma SMOTE dan k-nearest neighbor,” *Jurnal ISD*, vol. 3, no. 1, pp. 44–49, 2018.
- [3] S. Chohan, A. Nugroho, A. Maezar Bayu Aji, W. Gata, and S. Nusa Mandiri, “Analisis sentimen aplikasi duolingo menggunakan metode naïve bayes dan synthetic minority over sampling technique,” *Paradigma –Jurnal Informatika dan Komputer*, vol. 22, no. 2, pp. 139–144, 2020, doi: [10.31294/p.v2i1i2](https://doi.org/10.31294/p.v2i1i2).
- [4] E. Fitri, Y. Yuliani, S. Rosyida, and W. Gata, “Analisis sentimen terhadap aplikasi ruangguru menggunakan algoritma naive bayes, random forest dan support vector machine,” *Transformatika*, vol. 18, no. 1, pp. 71–80, 2020, [Online]. Available: www.nusamandiri.ac.id,
- [5] A. S. Neogi, K. A. Garg, R. K. Mishra, and Y. K. Dwivedi, “Sentiment analysis and classification of Indian farmers’ protest using twitter data,” *International Journal of Information Management Data Insights*, vol. 1, no. 2, Nov. 2021, doi: [10.1016/j.ijime.2021.100019](https://doi.org/10.1016/j.ijime.2021.100019).
- [6] A. Yolanda, “Perancangan Ulang User Interface (Ui) Dan User Experience (Ux) Menggunakan Metode Lean UX Pada Aplikasi Sister for Students (Sfs) Universitas Jember,” Universitas Jember, Jember, 2020.
- [7] F. A. Nugraha, N. H. Harani, and R. Habibi, *Analisis Sentimen Terhadap Pembatasan Sosial Menggunakan Deep Learning*, Pertama. Bandung: Kreatif Industri Nusantara, 2020.
- [8] O. W. Purbo, *Text Mining Analisis MedSos, Kekuatan Brand & Intelijen di Internet*. Yogyakarta: ANDI, 2019.
- [9] J. D. C. Aruan, B. Rahayudi, and A. Ridok, “Analisis sentimen opini Masyarakat terhadap pelayanan rumah sakit umum daerah menggunakan metode support vector machine dan term frequency-inverse document frequency,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 5, pp. 2072–2078, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [10] S. Jabri, A. Dahbi, and T. Gadi, “Ranking of text documents using TF-IDF weighting and association rules mining,” in *International Conference on Optimization (ICOA)*, 2018, pp. 26–27.
- [11] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic Minority Over-

sampling Technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002.

- [12] N. P. Y. T. Wijayanti, E. N. Kencana, and I. W. Sumarjaya, “SMOTE: potensi dan kekurangannya pada survei,” *E-Jurnal Matematika*, vol. 10, no. 4, p. 235, Nov. 2021, doi: [10.24843/mtk.2021.v10.i04.p348](https://doi.org/10.24843/mtk.2021.v10.i04.p348).
- [13] I. Saputra and D. A. Kristiyanti, *Machine Learning Untuk Pemula*. Informatika Bandung, 2022.
- [14] B. Purnama, *Pengantar Machine Learning. Bandung*. Informatika Bandung, 2019.
- [15] R. Mayapada, R. W. Yanti, and S. Syarifuddin, “Analisis tingkat kepentingan terhadap faktor-faktor yang mempengaruhi indeks pembangunan manusia di indonesia,” *JOMTA Journal of Mathematics: Theory and Applications*, vol. 4, no. 2, pp. 45–49, 2022, [Online]. Available: www.bps.go.id.
- [16] A. F. Hadi, A. F. Zulva, M. L. Hakim, M. D. Saputra, and H. Sadiyah, “Implementasi Explainable Machine Learning: Visualisasi Global Explainability and Local Interpretability pada Analisis Sentimen dengan SHAP dan LIME,” *E-Jurnal BIAStatistics Departemen Statistika FMIPA Universitas Padjadjaran*, vol. 17, no. 1, pp. 1–18, 2023.
- [17] C. Molnar, *Interpretable Machine Learning a Guide for Making Black Box Models Explainable*. Germany: Lean Publishing, 2019.

NOMENKLATUR

| | |
|-------------|---|
| f_{ij} | frekuensi munculnya kata j dalam dokumen i |
| l_i | jumlah kata pada dokumen i |
| n | banyaknya dokumen |
| n_j | banyaknya dokumen yang mengandung kata j |
| X_{new} | data sintetis baru |
| X_i | data kelas minoritas |
| \hat{X}_k | data k tetangga terdekat |
| δ | bilangan acak antara 0 dan 1 |
| $d(i, j)$ | jarak <i>euclidean</i> antar objek i dengan j |
| x_{ik} | nilai objek i pada variabel ke- k |
| x_{jk} | nilai objek j pada variabel ke- k |
| S | himpunan kasus |
| P_i | proporsi S_i terhadap S |
| J | atribut |
| n | jumlah partisi atribut J |
| $ S_i $ | jumlah kasus partisi ke- i dalam S |
| $ S $ | jumlah kasus dalam S |
| TP | kelas positif yang berhasil diprediksi dengan benar |
| FP | kelas positif yang gagal diprediksi dengan benar |
| TN | kelas negatif yang berhasil diprediksi dengan benar |
| FN | kelas negatif yang gagal diprediksi dengan benar |

BIODATA PENULIS



Anisa Fitri Anjani
Lahir di Denpasar, 16 April 2000. Mahasiswa tingkat akhir yang sedang menyelesaikan program Sarjana Matematika di Fakultas MIPA Universitas Jember.



Dian Anggraeni, S.Si., M.Si.
Lahir di Situbondo, 16 Februari 1982. Menyelesaikan gelar Sarjana (S1) Statistika Fmipa Universitas Brawijaya tahun 2005. Menyelesaikan gelar Magister (S2) Statistika tahun 2013 di Institut Teknologi Sepuluh Nopember (ITS) Surabaya. Mulai tahun 2007 sampai saat ini menjadi dosen di Jurusan Matematika FMIPA Universitas Jember.



Prof. Drs. I Made Tirta, M.Sc., Ph.D.
Lahir di Singaraja, 20 Desember 1959. Menyelesaikan gelar Sarjana (S1) Pendidikan Matematika FKIP Universitas Udayana tahun 1984. Menyelesaikan gelar Magister (S2) tahun 1994 dan Doktor (S3) tahun 2001 pada The University of New England, Armidale Australia dalam bidang Statistika, khususnya Hierarchical Generalized Linier Model (HLGM). Mulai tahun 1999 sampai saat ini menjadi dosen di Jurusan Matematika FMIPA Universitas Jember.