



Penerapan Seleksi Fitur *Particle Swarm Optimization* pada Klasifikasi Teks (Studi Kasus: Komentar *Cyberbullying* Instagram)

Nadya Lestari^{#1}, Tursina^{#2}, Enda Esyudha Pratama^{#3}

[#]Program Studi Informatika, Fakultas Teknik, Universitas Tanjungpura
Jl. Prof. H. Dr. Hadari Nawawi, Kota Pontianak, 78115

¹lestarinadya49@student.untan.ac.id

²tursina@informatika.untan.ac.id

³enda@informatika.untan.ac.id

Abstrak— Dunia saat ini sedang berada di era *Big Data*, dimana sejumlah besar data berdimensi tinggi tersebar di berbagai domain, seperti media sosial, layanan kesehatan, bio-informatika, dan pendidikan *online*. *Big Data* adalah salah satu teknik pembelajaran mesin dan menjadi alat penting yang populer dalam bisnis, sehingga pengelolaan *Big Data* yang efektif menjadi hal yang sangat penting. Salah satu topik yang menarik untuk diteliti dalam kajian *Big Data* khususnya *text mining* ialah *cyberbullying* Instagram. Beberapa teknik yang dapat digunakan untuk memecahkan masalah *text mining* yaitu, *clustering*, klasifikasi, *outlier*, asosiasi, dan masih banyak lagi. Klasifikasi merupakan bentuk dasar dari analisis data yang banyak diterapkan diberbagai bidang. Penelitian ini membangun model klasifikasi menggunakan algoritma *Logistic Regression* dengan penambahan proses seleksi fitur menggunakan algoritma *Particle Swarm Optimization* sebagai tahapan yang berada sebelum proses pelatihan model regresi untuk mengklasifikasi komentar *cyberbullying* Instagram. Seleksi fitur dilakukan untuk mempertahankan kinerja model klasifikasi dengan menggunakan jumlah fitur pelatihan yang lebih sedikit. Hasil penelitian menunjukkan bahwa penambahan seleksi fitur dapat mereduksi fitur kata sebanyak 40% yang diikuti penurunan akurasi, presisi, dan AUC masing-masing sebesar 1,25%, 4,25%, 1,09% serta peningkatan nilai *recall* dan *f1-score* secara berurut sebesar 5,36% dan 0,57%. Penambahan *Particle Swarm Optimization* sebagai seleksi fitur pada kasus disimpulkan efektif mempertahankan kinerja pembelajaran model dilihat dari nilai AUC yang tetap berada pada kategori *Good Classification* saat dilatih dengan fitur kata yang lebih sedikit.

Kata kunci— seleksi fitur, *Particle Swarm Optimization*, klasifikasi teks, *Logistic Regression*, *cyberbullying*.

I. PENDAHULUAN

Big data adalah salah satu teknik pembelajaran mesin dan menjadi alat penting yang populer dalam bisnis, sehingga pengelolaan *big data* yang efektif menjadi hal yang sangat penting [1]. Salah satu topik yang menarik untuk diteliti dalam kajian *big data* khususnya *text mining*

ialah *cyberbullying* Instagram. Menurut [2], *cyberbullying* merupakan topik penelitian yang menarik dilihat dari banyaknya jumlah penelitian dalam kajian *text mining* yang telah dilakukan dengan mengangkat topik tersebut. Beberapa teknik yang dapat digunakan untuk memecahkan masalah *text mining* yaitu, *clustering*, klasifikasi, *outlier*, asosiasi, dan masih banyak lagi.

Klasifikasi merupakan bentuk dasar dari analisis data yang banyak diterapkan diberbagai bidang. Ada banyak algoritma yang dapat dikembangkan untuk klasifikasi misalnya *Naive Bayes*, *Decision Tree*, *Support Vector Machine*, *Logistic Regression*, *Neural Network*, *Deep Belief Network*, dan algoritma klasifikasi lainnya.

Penelitian terkait klasifikasi oleh [3], penelitian membandingkan kinerja algoritma *Logistic Regression* dan *Naive Bayes* pada klasifikasi biner spam sms, hasil penelitian menunjukkan bahwa *Logistic Regression* lebih baik dalam menangani kasus tersebut dibanding *Naive Bayes*. Ada juga penelitian [4] yang menyatakan bahwa *Logistic Regression* berkerja lebih efektif daripada *SGD Classifier* (*SGD*) dan *LGBM Classifier* (*LGM*). Keunggulan *Logistic Regression* dibandingkan algoritma lain ialah kemampuannya dalam membangun sebuah model prediksi dengan pilihan biner [5].

Penelitian tentang deteksi *cyberbullying* sebelumnya pernah dilakukan oleh [6], penelitian ini membangun aplikasi pendeteksi komentar *cyberbullying* Instagram menggunakan metode *Naive Bayes* dengan nilai akurasi sebesar 98,5%. Penelitian lain mengenai *cyberbullying* Instagram dilakukan oleh [7] menggunakan algoritma *Logistic Regression* dan menghasilkan akurasi paling optimal sebesar 75%.

Penelitian lain terkait deteksi *cyberbullying* dilakukan oleh [8] menggunakan *Support Vector Machine*, pada penelitian ini dilakukan penambahan seleksi fitur *Particle Swarm Optimization* untuk mereduksi jumlah fitur pelatihan, hasilnya dari penelitian ini menunjukkan bahwa kombinasi algoritma klasifikasi dan seleksi fitur dapat

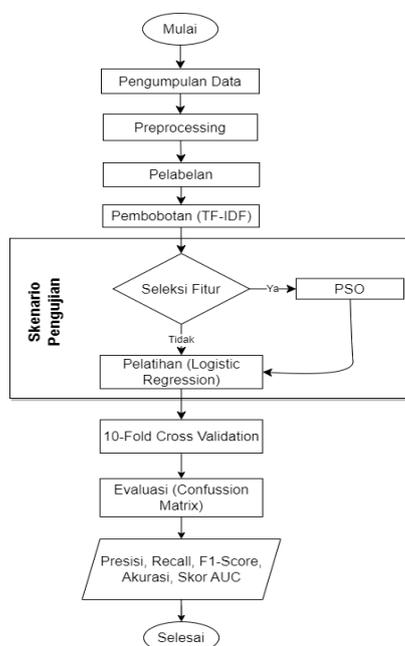
mempertahankan kinerja mesin pembelajaran menggunakan fitur pelatihan yang lebih sedikit. Klasifikasi dengan seleksi fitur melakukan pelatihan model menggunakan subset terpilih berdasarkan hasil seleksi. Menurut [9], penambahan seleksi fitur bisa memberikan hasil mendekati atau bahkan meningkatkan kinerja pembelajaran. Beberapa algoritma seleksi fitur yang telah dikembangkan diantaranya *Information Gain*, *Chi Square*, *Genetic Algorithm*, *Particle Swarm Optimization*, dan *N-Gram*.

Penelitian lain terkait seleksi fitur pernah dilakukan oleh [10], hasil penelitian menyatakan bahwa metode seleksi fitur *Particle Swarm Optimization* (PSO) memberikan hasil yang paling optimal saat dikombinasikan dengan algoritma klasifikasi dibandingkan seleksi fitur *N-Gram*, *Chi Square*, dan *Information Gain*. *Particle Swarm Optimization* adalah algoritma optimasi yang diadaptasi dari cari kawan burung terbang serta kawan ikan yang bergerombol dan diperkenalkan pertama kali oleh [11]. Keunggulan dari *Particle Swarm Optimization* (PSO) adalah penerapan yang sangat sederhana dengan sedikit parameter [12].

Berdasarkan latar belakang yang telah diuraikan maka dalam penelitian ini akan dilakukan klasifikasi komentar *cyberbullying* Instagram menggunakan algoritma *Logistic Regression* dengan penambahan *Particle Swarm Optimization* sebagai seleksi fitur.

II. METODOLOGI PENELITIAN

Tahapan-tahapan penelitian yang dilakukan serta ringkasan penjelasannya dapat dilihat pada Gambar 1 dan Tabel I.



Gambar 1 . Alur Penelitian

TABEL I
HASIL VALIDASI DAN PENGUJIAN SKENARIO I

| Tahapan Penelitian | Kegiatan |
|--------------------------------------|--|
| Pengumpulan data | Dilakukan dengan teknik scrapping terhadap komentar Instagram menggunakan <i>phantombooster.com</i> |
| <i>Preprocessing</i> | Melakukan penghilangan terhadap karakter yang kurang relevan dengan proses klasifikasi teks |
| Pelabelan | Pelabelan dilakukan secara manual dengan sistem <i>voting</i> dengan bantuan tiga orang responden |
| Pembobotan TF-IDF | Pembobotan dilakukan menggunakan metode TF-IDF |
| Pelatihan <i>Logistic Regression</i> | Membangun pemodelan klasifikasi <i>Logistic Regression</i> dengan dan tanpa seleksi fitur <i>Particle Swarm Optimization</i> |
| <i>10-Fold Cross Validation</i> | Melakukan Cross Validation K=10 untuk melihat persebaran data |
| Evaluasi | Evaluasi menggunakan <i>confussion matrix</i> |

A. Pengumpulan Data

Pengumpulan data dilakukan secara scrapping pada lima akun public figur yaitu @amandamanopo, @najwashihab, @smindrawati, @zinidinzidan_real, dan @cimoynuraini_wjy menggunakan tools *phantombooster.com*.

B. Preprocessing

Preprocessing mengubah data mentah (*raw*) menjadi data yang lebih bersih melalui dua tahapan yaitu *case folding* dan *filtering*. *Case folding* akan merubah setiap huruf pada *raw* menjadi kecil. Pada tahap *filtering* dilakukan tahap penghapusan *term* berupa alamat *url*, *mention*, *link*, *hashtag*, karakter *byte*, angka, tanda baca, karakter bukan huruf dan kelebihan jarak spasi.

C. Pelabelan

Pelabelan dilakukan berdasarkan suara terbanyak (*voting*) dengan tiga orang responden yang merupakan pengguna aktif Instagram. Kalimat *cyberbullying* merujuk yaitu kalimat yang berisi komentar kasar, ancaman, hinaan, fitnah dan pelecehan [2]. Kalimat yang tidak termasuk *cyberbullying* didefinisikan sebagai non-*cyberbullying*. Kalimat *cyberbullying* akan dilabel dengan "1" dan kalimat non-*cyberbullying* dilabel dengan "0".

D. Pembobotan TF-IDF

Pembobotan mengubah data yang semula berupa teks menjadi bentuk fitur numerik agar dapat diolah pada tahap selanjutnya. Pembobotan pada penelitian ini menggunakan TF-IDF murni. *Term Frequency* (TF) ialah jumlah kemunculan setiap kata (*term*) dalam sebuah dokumen. *Inverse Document Frequency* (IDF) adalah jumlah

kemunculan term di dalam semua kumpulan dokumen. Nilai IDF dan *Term Weighting*. TF-IDF dapat dihitung menggunakan bentuk Persamaan 1 dan 2.

$$IDF_j = \log\left(\frac{D}{df_j}\right) \tag{1}$$

$$W_{ij} = tf_{ij} \times IDF_j \tag{2}$$

E. Skenario Pengujian

Pengujian dilakukan berdasarkan skenario pengujian. Pada setiap skenario pengujian akan dilakukan evaluasi menggunakan *confussion matrix*. Ada dua skenario yang digunakan pada penelitian yaitu

- Skenario pengujian pertama melakukan klasifikasi *Logistic Regression* tanpa seleksi fitur, pada skenario ini juga dilakukan pengujian menggunakan split menggunakan perbandingan 90:10, 80:20, 70:30, 60:40, dan 50:50 seperti yang dilakukan oleh [13]. Metode evaluasi dengan nilai akurasi terbaik akan digunakan pada skenario pengujian kedua.
- Skenario pengujian kedua melakukan klasifikasi menggunakan *Logistic Regression* dengan penambahan seleksi fitur PSO. Komposisi split menggunakan komposisi dengan hasil terbaik pada skenario pengujian pertama. Pada skenario pengujian kedua dilakukan iterasi PSO menggunakan jumlah partikel 5, 10, 15, 25, 50, dan 100 dengan masing-masing sebanyak lima kali pengulangan [14].

1) *Logistic Regression*: Cara kerja *Logistic Regression* biner secara sederhana dapat diterapkan dengan langkah sebagai berikut:

a) Mendefinisikan X dan y, X merupakan nilai kalimat (x) yang telah melewati tahap TF-IDF dan berlaku sebagai variabel predictor (independen), y merupakan variabel respons (dependen) merupakan label dari X yang harus bernilai 0 atau 1.

b) Hitung nilai logit (Y) menggunakan persamaan 3.

$$Y = b_0 + b_1 * X_1 + b_2 * X_2 + \dots + b_n * X_n \tag{3}$$

c) Menghitung probabilitas prediksi (P(X)) peristiwa positif (y=1) menggunakan fungsi logistik atau sigmoid (lihat persamaan 4)

$$P(X) = \frac{\exp(\text{logit})}{1 + \exp(\text{logit})} \tag{4}$$

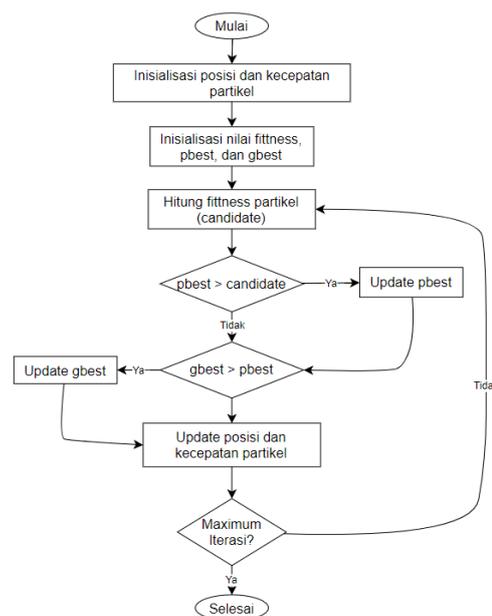
d) Menentukan koefisien dalam model dengan menggunakan metode Maximum Likelihood Estimation (MLE). Rumus untuk log-likelihood dalam konteks Logistik Regression biner adalah sebagai berikut:

$$LL = \sum [y_i * \log(P(X_i)) + (1 - Y_i) * \log(1 - P(X_i))] \tag{5}$$

Keterangan:

- $b_0, b_1, b_2, \dots, b_n$ adalah koefisien yang akan diestimasi dalam model.
- LL adalah log-likelihood.
- Σ menunjukkan operasi penjumlahan yang dilakukan untuk semua observasi dalam sampel data.
- y_i adalah variabel respons atau variabel target untuk observasi ke-i.
- $P(X_i)$ adalah probabilitas prediksi bahwa observasi ke-i akan termasuk dalam kategori $y = 1$ (*cyberbullying*).
- $\log()$ adalah fungsi logaritma natural (logaritma basis e), e adalah bilangan Euler yang setara dengan 2.71828183.

2) *Logistic Regression + PSO*: Penerapan PSO menggunakan *library* dari *pyswarm* yaitu *discrete.BinaryPSO*. Nilai parameter yang digunakan merupakan nilai *default* dari *library*, $C1 = 0.5, C2 = 0.5, w = 2, \text{iter} = 10, k = 3, \text{ dan } p = 2$. Adapun tahapan PSO secara dapat diterapkan sebagai berikut (lihat Gambar 2). Input pada PSO ialah *matrix* fitur yang didapatkan dari tahap pembobotan TF-IDF.



Gambar. 2 Flowchart PSO

a) Inisialisasi posisi dan kecepatan partikel. Masing-masing merupakan matrix berukuran $m * n$. m adalah jumlah partikel (ditetapkan di awal), n adalah jumlah fitur yang dihasilkan dari proses pembobotan. Posisi diinisialisasi secara acak menggunakan bilangan biner yaitu 0 atau 1, fitur-fitur dengan nilai posisi 1 merupakan fitur yang digunakan pada perhitungan *fitness* tiap partikel (*candidate*). Kecepatan partikel diinisialisasi secara acak menggunakan bilangan desimal pada rentang diantara 0 dan 1.

- b) Menghitung *fitness* menggunakan persamaan 6 (Vieira et al., 2013).

$$Fitness = \alpha(1-P) + (1-\alpha) (1-Nf/Nt) \quad (6)$$

- c) Menentukan nilai *pbest* dan *gbest*, *Pbest* adalah nilai *fitness* terbaik dari suatu partikel pada semua iterasi yang telah dilakukan. *Gbest* adalah nilai *fitness* terbaik dari semua partikel pada semua iterasi yang telah dilakukan. Pada iterasi pertama, nilai *fitness* dari setiap partikel akan dijadikan sebagai *pbest* setiap partikel, kemudian nilai *pbest* tertinggi dari semua partikel akan dijadikan sebagai *gbest*.

- d) Menentukan *pbest* baru. Jika *fitness candidate* kurang dari *pbest*, selanjutnya *fitness candidate* menjadi *pbest* baru

- e) Menentukan *pbest* dan *gbest* baru. Jika nilai *pbest* kurang dari *gbest* maka *pbest* menjadi nilai *gbest*.

- f) Memperbarui nilai kecepatan (lihat persamaan 7) dan posisi partikel (lihat persamaan 8 dan persamaan 9) untuk iterasi selanjutnya

$$V_{(is)} = w * V_{(is)} + c_1 * rand() * (pbest_{(i)} - x_{(is)}) + c_2 * rand() * (gbest - x_{(is)}) \quad (7)$$

$$S_{(s)} = 1 / (1 + e^{-vis}) \quad (8)$$

$$\text{If } (rand() < S(V_{is})) \text{ then } X_{is} = 1 \\ \text{else } X_{is} = 0 \quad (9)$$

Keterangan:

- $v_{(i)}$ = kecepatan partikel
- $x_{(i)}$ = posisi partikel saat ini
- w = berat inertia
- c_1, c_2 = koefisien akselerasi
- $rand()$ = bilangan acak dengan rentang 0 hingga 1
- $Pbest$ = posisi *personal best* saat ini
- $Gbest$ = posisi *global best* saat ini
- e = bilangan Euler setara dengan 2.71828183.

- g) Kembali ke langkah 2 menggunakan nilai posisi dan kecepatan yang baru hingga iterasi mencapai maksimum.

Keluaran dari seleksi fitur PSO ini adalah fitur-fitur dari partikel dengan nilai *fitness* terbaik. Fitur-fitur ini kemudian digunakan untuk melakukan klasifikasi *Logistic Regression*.

F. Evaluasi

Evaluasi dilakukan menggunakan *confusion matrix* serta *classification report* untuk menampilkan hasil perhitungannya. Tolak ukur yang digunakan pada tahap evaluasi adalah akurasi, presisi, *recall*, *f1-score*, dan skor AUC.

$$Akurasi = \frac{TP+TN}{P+N} \quad (10)$$

$$Recall = TP_{rate} = \frac{TP}{TP+FN} \quad (11)$$

$$Presisi = \frac{TP}{TP+FP} \quad (12)$$

$$F1-Score = (2(Presisi * Recall) / (Presisi + Recall)) \quad (13)$$

$$False\ Positive\ Rate = FP_{rate} = \frac{FP}{TN+FP} \times 100\% \quad (14)$$

$$AUC = \frac{1+TP_{rate}-FP_{rate}}{2} \quad (15)$$

III. HASIL DAN PEMBAHASAN

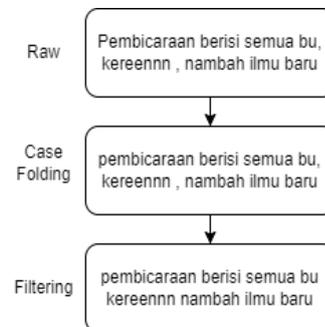
Berikut merupakan uraian hasil dan pembahasan dari tiap tahap penelitian yang telah dilakukan.

A. Hasil Pengumpulan Data

Pengumpulan data secara *scrapping* menggunakan *phantombooster.com* menghasilkan 34.476 baris raw data (lihat Gambar 3), hasil *scrapping* kemudian disimpan ke dalam file excel.

| | |
|----|--|
| 1 | Pembicaraan berisi semua bu, kereennn , nambah ilmu saya ni bu 🤍👍 |
| 2 | Sehat selalu bu |
| 3 | Pertanyaan n jawaban yg cerdas. Semoga semua sehat. Om Dad sekali! |
| 4 | Respect bu @smindrawati 👍 |
| 5 | Semoga sehat selalu ya bu.. @smindrawati Ibu adalah menteri kebangga Bu, pajak bunga 15% untuk khusus sektor pertanian kalau diturunkan atau |
| 6 | menarik lebih banyak investor ke sektor pertanian 🇮🇩👍 |
| 7 | kita tunggu episode selanjutnya bu , sehat selalu bu sri... |
| 8 | Keren. |
| 9 | Mantul Bu 🤍👍 |
| 10 | Sehat selalu lbuk 🤍 |
| 11 | Sehat selalu bu sri, terima kasih atas pengabdian utk bangsa dan negara, i |
| 12 | Menteri fav @smindrawati |
| 13 | Ibuuu🤍 |
| 14 | Ibu menteri kebanggaan 🤍👍👍👍👍👍👍 |
| 15 | Sehat selalu Ibu Presiden Republik Indonesia kebanggaan negeri |
| 16 | Beh wanita hebattt 🤍👍👍👍 |
| 17 | wah kiye mesti sampeyan arep sosialisasi PPS |
| 18 | Seru bukkk podcastnya, sy nonton sampai hbs |

Gambar. 3 Sampel Kalimat Hasil Scrapping



Gambar. 4 Perubahan Kalimat pada Tahap Preprocessing

B. Hasil Preprocessing

34.476 baris data hasil *scrapping* sebelumnya dijadikan sebagai masukan pada tahap *preprocessing*. Setelah

dilakukan *preprocessing* jumlah baris pada dataset menjadi 19.443 karena adanya kalimat yang hanya berupa tag akun dan *emoticon* sehingga komentar-komentar tersebut hilang pada saat *preprocessing*. Perubahan kalimat pada tahap *preprocessing* dapat dilihat pada Gambar 4.

C. Pelabelan Manual

Pelabelan dilakukan menggunakan teknik *voting* terhadap tiap kalimat dalam dataset dan melibatkan tiga orang relawan, pelabelan menghasilkan 2110 data berlabel *bully* dan 16.456 data berlabel bukan *bully*. Untuk mencapai keseimbangan data maka selanjutnya penelitian menggunakan masing-masing 2000 baris data untuk setiap labelnya (lihat Tabel II).

TABEL II
PERSEBARAN LABEL

| Label | Jumlah Kalimat |
|-----------------------|----------------|
| Cyberbullying (1) | 2000. |
| Non-cyberbullying (0) | 2000 |

D. Pembobotan TF-IDF

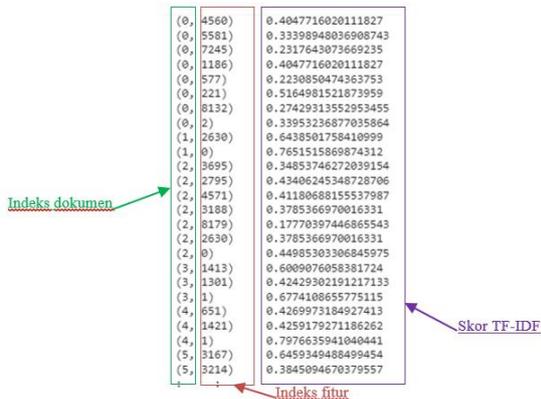
Proses TF-IDF pada seluruh data menggunakan *Tfidfvectorizer* menghasilkan fitur sebanyak 8226 fitur.

```

Jumlah Feature 8226

feature_names
Index(['aa', 'aaa', 'aaaa', 'aaaaa', 'aaaaaa', 'aaaaaaaaaaaaaaaaiiiiinn',
      'aaaaaaaaawww', 'aaaaaah', 'aaaaaas', 'aaaah',
      ...
      'zidane', 'zidanjing', 'zidann', 'zidannn', 'zidat', 'zidinzidan',
      'zonk', 'zuc', 'zuma', 'zzzzz'],
      dtype='object', length=8226)
    
```

Gambar. 5 Fitur Kata



Gambar. 6 Hasil Pembobotan TF-IDF

1) *Indeks Dokumen*: Indeks dokumen merupakan representasi indeks kalimat pada corpus (*dataset*), contoh angka 0 adalah representasi kalimat pertama dari corpus, angka 1 adalah representasi kalimat kedua dari corpus dan seterusnya.

2) *Indeks Fitur*: Indeks kata merupakan representasi indeks dari fitur (*feature names*) yang dihasilkan dari *bag of words*. Contohnya Indeks dokumen 1 memiliki indeks

fitur 2630 dan 0 mengartikan kalimat pada indeks ke-1 mengandung fitur dengan indeks 2630 dan 0.

3) *Skor TF-IDF*: Skor TF-IDF merupakan representasi dari bobot setiap IDF, yang merupakan hasil kalkulasi dari *tfidfvectorizer*.

E. Hasil Pengujian Skenario Pertama

Tabel III adalah hasil pengujian metode evaluasi skenario pertama.

TABEL III
HASIL SKENARIO PENGUJIAN PERTAMA

| Split Data | Akurasi |
|-----------------|---------|
| 90:10 | 85,50 % |
| 80:20 | 84,25 % |
| 70:30 | 82,92 % |
| 60:40 | 81,56 % |
| 50:50 | 83,28 % |
| Akurasi Terbaik | 85,50% |

Berdasarkan hasil pengujian menggunakan split data, split 90:10 menghasilkan model dengan akurasi terbaik yaitu 85,50 % sehingga split 90:10 akan digunakan pada skenario pengujian kedua.

F. Hasil Pengujian Skenario Kedua

Tabel IV merupakan hasil pengujian pada skenario kedua.

TABEL IV
HASIL SKENARIO PENGUJIAN KEDUA

| Jumlah Partikel | Perulangan ke-i | Jumlah Fitur | Skor AUC |
|---------------------------|-----------------|--------------|----------|
| 10 | 1 | 4950 | 82,13 % |
| 10 | 2 | 4984 | 80,98 % |
| 10 | 3 | 4962 | 80,02 % |
| 10 | 4 | 5022 | 75,57 % |
| 10 | 5 | 5080 | 78,06 % |
| Rata-Rata AUC Partikel 10 | | | 79,35% |
| 15 | 1 | 5005 | 79,22 % |
| 15 | 2 | 5066 | 83,26 % |
| 15 | 3 | 5025 | 80,60 % |
| 15 | 4 | 4970 | 81,42 % |
| 15 | 5 | 5143 | 84,29 % |
| Rata-Rata AUC Partikel 15 | | | 81,76% |
| 25 | 1 | 4962 | 80,72 % |
| 25 | 2 | 5013 | 79,51 % |
| 25 | 3 | 5019 | 77,08 % |
| 25 | 4 | 5002 | 80,93 % |
| 25 | 5 | 4979 | 82,77 % |
| Rata-Rata AUC Partikel 25 | | | 80,20% |
| 50 | 1 | 5050 | 80,03 % |
| 50 | 2 | 5048 | 76,96 % |
| 50 | 3 | 5025 | 78,96 % |
| 50 | 4 | 4957 | 78,51 % |
| 50 | 5 | 5042 | 80,22 % |
| Rata-Rata AUC Partikel 50 | | | 78,94% |
| 100 | 1 | 5027 | 82,17 % |
| 100 | 2 | 5021 | 77,83 % |

| Jumlah Partikel | Perulangan ke-i | Jumlah Fitur | Skor AUC |
|----------------------------|-----------------|--------------|----------|
| 100 | 3 | 5074 | 79,34 % |
| 100 | 4 | 5008 | 80,56 % |
| 100 | 5 | 5000 | 80,86 % |
| Rata-Rata AUC partikel 100 | | | 80,15% |
| Rata-Rata AUC Terbaik | | | 81,76 % |
| Skor AUC Terbaik | | | 84,29 % |

Tabel IV menunjukkan perubahan skor AUC dan jumlah fitur yang dihasilkan pada skenario pengujian kedua. Nilai rata-rata AUC pada pengujian dengan 10 partikel sebesar 79,35%, jumlah partikel 15 sebesar 81,76 %, jumlah partikel 25 sebesar 80,20%, jumlah partikel 50 sebesar 78,94%, dan jumlah partikel 100 sebesar 80,15%.

Model LR+PSO menghasilkan rata-rata AUC terbaik sebesar 81,76 %, saat iterasi menggunakan 15 partikel. Subset terbaik kemudian diambil berdasarkan skor AUC terbaik dari iterasi menggunakan 15 partikel karena menghasilkan rata-rata AUC paling baik.

G. Hasil Pengujian Skenario Kedua

Jumlah fitur yang mampu direduksi PSO pada 25 percobaan yang telah dilakukan berada di rentang 4950 hingga 5143 fitur dari total keseluruhan yaitu 8226 fitur. Model terbaik pada skenario pengujian kedua menghasilkan Skor AUC sebesar 84,29 % dengan jumlah fitur sebanyak 5143 pada percobaan dengan jumlah partikel 15.

TABEL V
RATA-RATA PERULANGAN AUC TIAP PARTIKEL

| Jumlah Partikel | Rata-rata AUC |
|-------------------|---------------|
| 10 | 79,35% |
| 15 | 81,76% |
| 25 | 80,20% |
| 50 | 78,94% |
| 100 | 80,15% |
| Rata-rata terbaik | 81,76% |

H. Hasil Validasi

Tabel VI memberikan hasil 10-Cross Validation pada model terpilih dari tiap-tiap skenario pengujian. Berdasarkan tabel tersebut model Logistic Regression tanpa seleksi fitur menghasilkan skor validasi sebesar 80,25 % dengan standar deviasi sebesar 4,25 %, sementara model Logistic Regression+PSO memberikan skor validasi sebesar 77,91 % dengan standar deviasi sebesar 2,47%.

TABEL VI
HASIL 10-CROSS VALIDATION

| C_val ke | Akurasi C_val | |
|----------|---------------------|-------------------------|
| | Logistic Regression | Logistic Regression+PSO |
| 1 | 78,25 % | 80,83 % |
| 2 | 80,75 % | 75,00 % |
| 3 | 78,25 % | 74,72 % |
| 4 | 82,75 % | 80,83 % |
| 5 | 79,50 % | 81,11 % |

| C_val ke | Akurasi C_val | |
|-------------------|---------------------|-------------------------|
| | Logistic Regression | Logistic Regression+PSO |
| 6 | 88,25 % | 79,17 % |
| 7 | 80,50 % | 77,50 % |
| 8 | 82,50 % | 74,44 % |
| 9 | 70,50 % | 76,94 % |
| 10 | 81,25 % | 78,55 % |
| Akurasi Rata-Rata | 80,25 % | 77,91 % |
| Standar Deviasi | 4,25 % | 2,47 % |

I. Hasil Evaluasi

Evaluasi dilakukan terhadap model terbaik dari masing-masing skenario pengujian.

TABEL VII
CONFUSION MATRIX MODEL LOGISTIC REGRESSION

| Aktual | Prediksi | |
|-------------------|-------------------|---------------|
| | Non-Cyberbullying | Cyberbullying |
| Non-Cyberbullying | 184 | 22 |
| Cyberbullying | 36 | 158 |

Tabel VII adalah confusion matrix dari model terbaik pada skenario pengujian pertama. Model berhasil melakukan klasifikasi dengan jumlah prediksi benar sebanyak 343 dari 400 data uji. Model skenario pengujian pertama memberikan hasil yang lebih baik untuk memprediksi data yang bukan cyberbullying yaitu sebanyak 184 prediksi benar dan 22 prediksi salah dan untuk data cyberbullying yaitu sebanyak 158 prediksi benar dan 36 prediksi salah.

```

precision    recall  f1-score   support

   0         0.84    0.89    0.86     206
   1         0.88    0.81    0.84     194

 accuracy          0.85     400
 macro avg         0.86    0.85    0.85     400
weighted avg         0.86    0.85    0.85     400

0.8538184365929337
    
```

Gambar. 7 Classification Report Logistic Regression

Hasil classification report dari skenario pengujian pertama (lihat Gambar 7) menunjukkan bahwa kelas cyberbullying (label 1) memiliki nilai presisi lebih tinggi dari kelas non-cyberbullying (label 0) namun memiliki nilai yang lebih rendah pada recall dan f1-score.

TABEL VIII
CONFUSION MATRIX MODEL LOGISTIC REGRESSION+PSO

| Aktual | Prediksi | |
|---------------------|---------------------|---------------|
| | Bukan Cyberbullying | Cyberbullying |
| Bukan Cyberbullying | 166 | 37 |
| Cyberbullying | 26 | 171 |

Tabel VIII adalah confusion matrix dari model terbaik pada skenario pengujian kedua dengan 337 prediksi benar dan 63 prediksi salah. Berbeda dari model pada skenario pengujian pertama, pada skenario kedua model melakukan

klasifikasi dengan lebih baik pada data *cyberbullying* daripada yang *non-cyberbullying*. Model memprediksi data yang *non-cyberbullying* yaitu sebanyak 166 prediksi benar dan 37 prediksi salah dan untuk data *cyberbullying* sebanyak 171 prediksi benar dan 26 prediksi salah.

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0 | 0.86 | 0.82 | 0.84 | 203 |
| 1 | 0.82 | 0.87 | 0.84 | 197 |
| accuracy | | | 0.84 | 400 |
| macro avg | 0.84 | 0.84 | 0.84 | 400 |
| weighted avg | 0.84 | 0.84 | 0.84 | 400 |

0.8428771473581556

Gambar. 8 Classification Report Logistic Regression+PSO

Classification report model Logistic Regression dengan seleksi fitur PSO menunjukkan bahwa kelas *cyberbullying* (1) memiliki nilai presisi yang lebih rendah dari kelas bukan *cyberbullying* (0) namun memiliki nilai yang lebih tinggi pada *recall*.

J. Analisis

Berbeda dari penelitian sebelumnya [15] yang menunjukkan peningkatan nilai evaluasi setiap penambahan jumlah partikel sebanyak lima, grafik pada Tabel IV menunjukkan bahwa penambahan jumlah partikel PSO tidak berbanding lurus dengan peningkatan kinerja model.

TABEL IX
PERBANDINGAN JUMLAH TUPLE

| Tuple | Logistic Regression | Logistic Regression+PSO |
|--------------------|---------------------|-------------------------|
| True Positif (TP) | 158 | 171 |
| True Negatif (TN) | 184 | 166 |
| False Positif (FP) | 22 | 37 |
| False Negatif (FN) | 36 | 26 |

Tabel IX menggambarkan perubahan jumlah *tuple confusion matrix* yaitu *True Positif* yaitu komentar yang positif mengandung *cyberbullying* dan diklasifikasikan dengan benar sebagai *cyberbullying*, *True Negatif* yaitu komentar *non cyberbullying* yang benar diklasifikasikan sebagai *non cyberbullying*, *False Positif* yaitu komentar *non cyberbullying* yang salah diklasifikasikan sebagai *cyberbullying*, *False Negatif* yaitu komentar *non cyberbullying* yang salah diklasifikasikan sebagai *cyberbullying*. Berdasarkan tabel tersebut dapat diketahui bahwa seleksi fitur meningkatkan kemampuan model untuk mengklasifikasi *teks cyberbullying* namun menurunkan kemampuan model mengklasifikasi *teks non cyberbullying* dilihat dari nilai *True Positif* dan *False Positif* yang meningkat namun *True Negatif* dan *False Negatif* menurun.

Tabel X merupakan hasil perbandingan validasi dan evaluasi *confusion matrix* dari model *Logistic Regression* tanpa dan dengan seleksi fitur PSO.

TABEL X
PERBANDINGAN HASIL VALIDASI DAN EVALUASI

| Tolak Ukur | Model | | Selisih (a -b) |
|---|---------|------------|----------------|
| | LR (a) | LR+PSO (b) | |
| Jumlah Fitur | 8226 | 5143 | - 3083 |
| Skor <i>Cross Validation</i> | 80,25 % | 77,91 % | -2,34 % |
| Standar Deviasi (<i>Cross Validation</i>) | 4,25 % | 2,47 % | -1,7 8% |
| Akurasi | 85,50 % | 84,25 % | - 1,25 % |
| Presisi | 86,46 % | 82,21 % | - 4,25 % |
| Recall | 81,44 % | 86,80 % | + 5,36 % |
| F1-Score | 83,87 % | 84,44 % | + 0,57 % |
| Skor AUC | 85,38 % | 84,29 % | - 1,09 % |

Berdasarkan Tabel IV penambahan seleksi fitur dapat mereduksi fitur sekitar 40% dari total keseluruhan. Menurut Tabel VI kedua model yang dibandingkan memiliki kinerja yang cukup baik dilihat dari skor *Cross Validation* yang tidak terlalu jauh dari akurasi hasil uji lain menggunakan Split 90:10. Model klasifikasi tanpa seleksi fitur memiliki skor *Cross Validation* dan standar deviasi yang lebih tinggi dibandingkan model dengan seleksi fitur PSO yang memiliki skor *Cross Validation* dan standar deviasi yang lebih rendah (Tabel VI dan Tabel X). Skor *Cross Validation* tinggi dan standar deviasi tinggi mengindikasikan bahwa model tanpa seleksi fitur bekerja lebih baik pada saat menangani data tertentu namun sensitif terhadap variasi data, sebaliknya standar deviasi yang lebih kecil pada model dengan seleksi fitur mengindikasikan bahwa bahwa model klasifikasi tersebut menjadi lebih konsisten atau lebih stabil walaupun skor *Cross Validation*-nya lebih kecil, sehingga mampu menciptakan model yang lebih general [16]. Penurunan standar deviasi juga dapat diartikan bahwa seleksi fitur mengubah variasi data menjadi lebih kecil dan cenderung menjadi lebih seragam atau homogen.

Tabel X menunjukkan bahwa model klasifikasi setelah dilakukan seleksi fitur menggunakan PSO mengalami penurunan akurasi, presisi, dan AUC masing-masing sebesar 1,25 %, 4,25 %, dan 1,09 % namun mengalami peningkatan pada nilai *recall* dan *f1-score* masing-masing sebesar 5,36 % dan 0,57 % setelah dilakukan seleksi fitur PSO. Penurunan akurasi, presisi, dan skor AUC merupakan pengaruh yang disebabkan oleh turunya jumlah *True Negatif* dan *False Negatif* akibat pemilihan fitur.

Peningkatan nilai *recall* disebabkan oleh peningkatan informasi relevan [17] sebagai akibat dari hilangnya fitur-fitur yang tidak relevan serta *noise* di dalam data yang diungkapkan oleh sehingga model dapat lebih fokus pada fitur terpilih dan mengklasifikasi secara lebih akurat [8]. Menurut [8], [18] model dengan *recall* (sensitivitas) yang lebih besar dapat mengklasifikasi komentar *cyberbullying* dengan lebih baik daripada model dengan nilai *recall* yang lebih kecil. Selain *recall f1-score* juga menunjukkan peningkatan saat dilatih menggunakan fitur yang lebih sedikit, hal ini terjadi karena nilai *recall* yang meningkat cukup banyak sehingga ikut meningkatkan nilai *f1-score*.

Pada saat kasus *False Positif* dan *False Negatif* model tidak seimbang *f1-score* harus lebih dipertimbangkan daripada akurasi, dan setelah *f1-score*, *recall* harus lebih dipertimbangkan daripada presisi karena model yang dibuat sebisa mungkin ingin menghindari *False Negatif* [19] dimana model gagal mengenali sebuah komentar *cyberbullying* dan mengelompokkannya sebagai *non cyberbullying*. Berdasarkan hasil analisis model terbaik dari penelitian ini adalah model klasifikasi dengan seleksi fitur PSO pada iterasi dengan jumlah partikel 15 karena menghasilkan *f1-score* dan *recall* paling baik dan memiliki akurasi, presisi, dan AUC cukup baik walaupun lebih rendah sedikit daripada yang dilatih dengan seluruh fitur.

IV. KESIMPULAN

Hasil penelitian menunjukkan bahwa penambahan seleksi fitur dapat mereduksi fitur kata sebanyak 40%. Penerapan seleksi fitur PSO meningkatkan *True Positif* dan *False Positif* sehingga meningkatkan nilai *recall* dan *f1-score* sebesar 5,36% dan 0,57%, namun menurunkan *True Negatif* dan *False Negatif* yang berpengaruh pada penurunan akurasi, presisi, dan AUC masing-masing sebesar 1,25%, 4,25%, 1,09%. Penambahan seleksi fitur PSO juga bisa membangun model menjadi lebih general dan stabil dilihat dari adanya penurunan standar deviasi. Penerapan *Particle Swarm Optimization* sebagai seleksi fitur pada kasus komentar *cyberbullying* Instagram disimpulkan efektif meningkatkan kinerja model klasifikasi berdasarkan kenaikan *f1-score* dan *recall* serta nilai AUC yang tetap berada pada kategori *Good Classification* serta akurasi dan presisi yang cukup baik. Dalam penelitian ini parameter PSO yang digunakan merupakan *default* dari *library* sehingga mungkin PSO belum mencapai kinerja terbaiknya, penelitian ini juga tidak melakukan *stemming* dan normalisasi, serta menghilangkan *emoticon* pada dataset tanpa melakukan konversi makna, penelitian selanjutnya diharapkan dapat melakukan tuning *hyperparameter* serta hal-hal yang belum dilakukan pada penelitian ini guna menggali pengetahuan baru yang belum ditemukan.

UCAPAN TERIMA KASIH / ACKNOWLEDGMENT

Penulis mengucapkan terima kasih kepada seluruh pihak yang terlibat dalam penulisan dan penerbitan artikel ini, semoga apa yang disampaikan dalam tulisan ini bisa bermanfaat bagi pengembangan ilmu dikemudian hari.

REFERENSI

- [1] D. Fadma Ristianti, "Komparasi Algoritma Klasifikasi pada Data Mining," *Proc. 1 st STEEEM*, vol. 1, no. 1, pp. 148–156, 2019.
- [2] A. Sarwani, R. Sianturi, A. Ayu Kustianti, A. Putri Siswadi, D. Nurmalita, and E. Puspitasari, "Teknologi Informasi Efektif Mendeteksi Cyberbullying," *J. Heal. Educ. Sci. Technol.*, vol. 5, no. 2, pp. 151–164, Aug. 2022, doi: 10.25139/htc.v5i2.4673.
- [3] F. Reviantika, Y. Azhar, G. I. Marthasari, Wicaksono, and Triyono, "Analisis Klasifikasi SMS Spam Menggunakan Logistic Regression," *J. Sist. Cerdas*, vol. 4, no. 2, pp. 37–43, 2021, [Online]. Available: <https://www.cnbcindonesia.com>
- [4] A. Muneer and S. M. Fati, "A comparative analysis of machine learning techniques for cyberbullying detection on twitter," *Futur. Internet*, vol. 12, no. 11, pp. 1–21, 2020, doi: 10.3390/fi12110187.
- [5] M. R. Nurhusen, J. Indra, and ..., "Analisis Sentimen Pengguna Twitter Terhadap Kenaikan Harga Bahan Bakar Minyak (BBM) Menggunakan Metode Logistic Regression," *J. Media ...*, vol. 7, pp. 276–282, 2023, doi: 10.30865/mib.v7i1.5491.
- [6] A. S. Hutagalung, A. B. P. Negara, and E. E. Pratama, "Aplikasi Pendeteksi Cyberbullying Terhadap Komentar Postingan Media Sosial Instagram dengan Metode Naïve Bayes Classifier Berbasis Website," *J. Sist. dan Teknol. Inf.*, vol. 9, no. 3, p. 364, 2021, doi: 10.26418/justin.v9i3.44843.
- [7] S. Aisyah, "Implementasi Sentiment Analysis Cyberbullying pada Instagram dengan Algoritma Logistic Regression," 2020.
- [8] D. Fortuna, I. D. Sulvianti, and G. A. Dito, "Penerapan Binary Particle Swarm Optimization Support Vector Machine untuk Klasifikasi Komentar Cyberbullying di Instagram," *Xplore J. Stat.*, vol. 11, no. 1, pp. 59–69, Jan. 2022, doi: 10.29244/xplore.v11i1.859.
- [9] G. G. S. Putra, W. Swastika, and P. L. T. Irawan, "Perbandingan Particle Swarm Optimization dengan Genetic Algorithm dalam Feature Selection untuk Analisis Sentimen pada Permendikbudristek PPKS-LPT," *JEPIN (Jurnal Edukasi dan Penelit. Inform.)*, vol. 8, no. 3, pp. 412–421, 2022.
- [10] F. Septianingrum, A. Susilo, and Y. Irawan, "Metode Seleksi Fitur Untuk Klasifikasi Sentimen Menggunakan Algoritma Naive Bayes : Sebuah Literature Review," vol. 5, pp. 799–805, 2021, doi: 10.30865/mib.v5i3.2983.
- [11] J. Kennedy and R. Eberhart, "Particle Swarm Optimization PAPER - IGNORE FROM REFS," *ICNN'95-international Conf. neural networks*, pp. 1942–1948, 1995.
- [12] A. S. H. Basari, B. Hussin, I. G. P. Ananta, and J. Zeniarja, "Opinion mining of movie review using hybrid method of Support Vector Machine and Particle Swarm Optimization," in *Procedia Engineering*, 2013, vol. 53, pp. 453–462. doi: 10.1016/j.proeng.2013.02.059.
- [13] L. Efrizoni, S. Defit, M. Tajuddin, and A. Anggrawan, "Komparasi Ekstraksi Fitur dalam Klasifikasi Teks Multilabel Menggunakan Algoritma Machine Learning," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 21, no. 3, pp. 653–666, 2022, doi: 10.30812/matrik.v21i3.1851.
- [14] K. A. Hanafiah, *Rancangan percobaan : teori dan aplikasi / Kemas Ali Hanafiah*. Jakarta: Rajawali Press, 2010.
- [15] A. Taufik, "Optimasi Particle Swarm Optimization Sebagai Seleksi Fitur Pada Analisis Sentimen Review Hotel Berbahasa Indonesia Menggunakan Algoritma Naïve Bayes," *J. Tek. Komput.*, vol. III, no. 2, 2017, [Online]. Available: <http://www.tripadvisor.com>
- [16] M. Dash ' and H. Liu, "Feature Selection for Classification," 1997. [Online]. Available: www.elsevier.com/locate/ida
- [17] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *JMLR* 3, pp. 1157–1182, 2003.
- [18] Guruprasad, "Catatan tentang Sensitivitas, Spesifisitas, Presisi, Recall dan skor F1," *Analitis Vidhya*, 2019. <https://medium.com/analytics-vidhya/notes-on-sensitivity-specificity-precision-recall-and-f1-score-e34204d0bb9b>
- [19] R. Susetyoko, Wiratmoko Yuwono, and Elly Purwantini, "Model Klasifikasi Pada Seleksi Mahasiswa Baru Penerima KIP Kuliah Menggunakan Regresi Logistik Biner," *J. Inform. Polinema*, vol. 8, no. 4, pp. 31–40, 2022, doi: 10.33795/jip.v8i4.914.