

Analisis Sentimen Produk Populer *Moisturizer* Pada *Female Daily* Menggunakan Metode Naive Bayes

Dewi Amalia ^{1,*}, Moch Hafid Totohendarto ², Syariful Alam ³

^{1,2,3} Teknik Informatika; Sekolah Tinggi Teknologi Wastukencana; Jl.Cikopak No.53 Sadang Purwakarta JawaBarat 41141, e-mail: dewiamalia32@wastukencana.ac.id, mhafid@wastukencana.ac.id, syarifulalam@wastukencana.ac.id

* Korespondensi: e-mail: dewiamalia32@wastukanacana.ac.id

Diterima: 29 Juli 2023 ; Review: 15 November 2023; Disetujui: 1 Desember 2023

Cara sitasi: Amalia D, Totohendarto MH, Alam S. 2023. Analisis Sentimen Produk Populer *Moisturizer* Pada *Female Daily* Menggunakan Metode Naive Bayes. *Informatics for Educators and Professionals : Journal of Informatics*. Vol 8 (2): 108 - 121.

Abstrak: *Moisturizer* telah menjadi topik pembicaraan yang populer di kalangan banyak orang melalui media sosial saat ini dalam konteks produk perawatan kulit. Semakin banyak produk populer *moisturizer* membuat konsumen semakin meningkatkan selektivitasnya dalam memilih. Ulasan produk bisa memberikan manfaat bagi konsumen yang akan mencoba produk populer *moisturizer* tersebut. Tetapi, karena jumlah ulasan yang besar, hal ini dapat menjadi tantangan dan menghabiskan banyak waktu. Oleh karena itu, pendekatan analisis sentimen digunakan sebagai solusi untuk mengatasi permasalahan tersebut dengan tujuan mengkategorikan ulasan menjadi positif atau negatif, sehingga dapat memberikan informasi yang relevan mengenai kesesuaian *moisturizer* dengan kebutuhan pengguna. Dalam penelitian ini, metode klasifikasi naive bayes dipilih karena memiliki probabilitas atau peluang tertinggi untuk melakukan pengklasifikasian data. Dari penelitian ini terdapat hasil analisis sentimen mengenai produk populer *moisturizer* dengan tiga *brand* yang diteliti yaitu skintific, loreal dan whitelab. Brand loreal menjadi pemegang nilai akurasi terbesar 89.4% dengan *precision(positif)* 91.9% dan *recall(positif)* 96.9%, dibandingkan dengan brand whitelab hanya mendapatkan nilai akurasi 88.66% dengan nilai *precision(positif)* 91.10% dan *recall(positif)* 96.84% dan terakhir skintific dengan nilai akurasi 80.55% dan *precision(positif)* 86.92% dan *recall(positif)* 91.12%. berdasarkan nilai-nilai tersebut membuktikan bahwa ulasan pengguna *female daily* terhadap produk populer *moisturizer* tergolong memberikan ulasan positif dan dengan menerapkan metode naive bayes, hasil yang diperoleh menunjukkan tingkat akurasi yang memuaskan.

Kata kunci: *Moisturizer*, Analisis sentimen, Naive bayes

Abstract: *Moisturizers* have become a popular topic of conversation among many people via social media today in the context of skin care products. The increasing popularity of moisturizer products has made consumers more selective in their choices. Product reviews can be beneficial for consumers who want to try popular moisturizer products. However, due to the large number of reviews, this can pose a challenge and consume a significant amount of time to read them in their entirety. To address this issue, a sentiment analysis approach is used to categorize reviews as positive or negative, providing relevant information about the suitability of moisturizers for users. In this study, the naive Bayes classification method was chosen as it has the highest probability of accurately classifying data. The research conducted sentiment analysis on popular moisturizer products from three brands: skintific, loreal, and whitelab. The Loreal brand holds the highest accuracy value at 89.4%, with a positive precision of 91.9% and positive recall of 96.9%. In comparison, Whitelab achieved an accuracy of 88.66%, with positive precision and recall values of 91.10% and 96.84%, respectively. Lastly, Skintific had an accuracy of 80.55%, positive precision of 86.92%, and positive recall of 91.12%. Based on these values, it proves that female daily user reviews of popular moisturizer products are classified as giving positive reviews and by applying the Naive Bayes method, the results obtained show a satisfactory level of accuracy.

Keywords: *Moisturizer, Sentiment Analysis, Naïve Bayes*

1. Pendahuluan

Belakangan ini pelembab menjadi salah satu produk perawatan kulit yang sedang viral dan banyak dibicarakan orang di media sosial. Sesuai dengan namanya, *moisturizer* berguna untuk membuat kulit tetap lembab dan memperkuat skin barrier. *Moisturizer* termasuk dalam produk basic skincare, *moisturizer* wajib digunakan setiap hari untuk menjaga kelembaban kulit dan memperkuat skin barrier. Pelembab sering kali digunakan untuk mengurangi kerutan halus serta melembutkan dan menghidrasi kulit. Hal ini dapat meningkatkan kepercayaan diri, kepuasan psikologis, dan kualitas hidup seseorang. Penggunaan pelembab secara efektif merawat kulit kering dan menjaganya tetap halus[1]. Ada banyak merek dan jenis *moisturizer* dipasarkan Indonesia. Berdasarkan data yang didapat di internet dari dashboard Kompas.co.id yang ditulis oleh Raga Putra Wiwaha ada beberapa merek produk pelembab wajah terlaris, tiga diantaranya yaitu Skintific, L'Oreal dan Whitelab.

Sekarang ini semua informasi dengan mudah untuk ditemukan, termasuk informasi tentang produk kecantikan seperti pada media sosial, blog pribadi, maupun web khusus mengulas produk kecantikan. Salah satu web khusus mengulas produk kecantikan yaitu female daily. Meskipun situs tersebut sudah menyediakan ulasan dengan skor bintang, pengguna kadang-kadang memberi ulasan dengan penilaian bintang yang tidak sesuai dengan komentar yang mereka sertakan. Sehingga, dari banyaknya komentar, informasi tidak selalu dapat diperoleh secara langsung. Perlu diketahui bahwa produk yang populer di *Female Daily* sering kali mendapatkan jumlah ulasan yang paling banyak, namun hal tersebut tidak selalu berarti produk tersebut memiliki banyak sentimen positif. Semakin banyak produk populer *moisturizer* membuat konsumen semakin selektif dalam memilih produk yang sesuai. Ulasan produk pun bisa memberikan manfaat bagi konsumen yang akan mencobanya, karena dengan membaca ulasan produk akan memperoleh informasi tentang produk populer *moisturizer* menurut pengalaman konsumen lain.

Krim pelembab (*moisturizer*) diperkirakan akan tumbuh sekitar 5% dalam jangka waktu 2021 hingga 2028 dan diharapkan mencapai nilai sekitar 17,607.57 juta dolar pada tahun 2028 menurut laporan riset dari Data Bridge Market Research. Pertumbuhan industri kecantikan di seluruh dunia sedang mendorong pertumbuhan krim pelembab (*moisturizer*). Menurut Econsultancy pada website belarius.com, ulasan memiliki peran yang sangat penting bagi pembeli dalam proses pengambilan keputusan pembelian. Menariknya, pembeli lebih mempercayai ulasan dari pelanggan lain yang tidak mereka kenal, bahkan 12 kali lebih banyak daripada keterangan produsen tentang produk tersebut. Ulasan positif memiliki pengaruh besar dalam mempengaruhi keputusan pembelian, dan di Indonesia sekitar 87% konsumen mempercayai ulasan positif. Tetapi, jumlah ulasan yang banyak akan cukup menyulitkan dan memerlukan banyak waktu yang signifikan untuk membacanya secara keseluruhan. Analisis sentimen diperlukan untuk memahami tanggapan pengguna kepada produk populer *moisturizer* melewati ulasan. Nantinya digunakan untuk memilih produk yang sesuai dengan kebutuhannya dan juga dapat digunakan oleh produsen untuk mengetahui umpan balik dari pengguna produk tersebut. Fokus penelitian ini adalah mengenai analisis sentimen terhadap ulasan produk *moisturizer* yang populer pada *platform female daily*. Ulasan tersebut akan diklasifikasikan ke dalam dua kategori, yaitu sentimen positif dan sentimen negatif.

Berdasarkan jurnal penelitian terdahulu yang berjudul "Analisa sentimen terhadap review produk kecantikan menggunakan metode naïve bayes classifier" Hasil penilaian dengan menggunakan metode naïve bayes classifier menunjukkan tingkat akurasi sebesar 80.45%. hasil penelitian tersebut tersebut bahwa metode ini efektif untuk digunakan sebagai proses klasifikasi pada website[3]. Menurut penelitian lain yang berjudul "Klasifikasi Text Mining Review Produk Kosmetik Untuk Teks Bahasa Indonesia Menggunakan Algoritma Naive Bayes" diperoleh nilai akurasi tinggi sebesar 90.50%. penelitian ini menyimpulkan bahwa naïve bayes dianggap sebagai salah satu model algoritma pengujian terbaik dan paling akurat dalam mengatasi permasalahan klasifikasi sentimen ulasan produk kosmetik, dan paling sederhana[4].

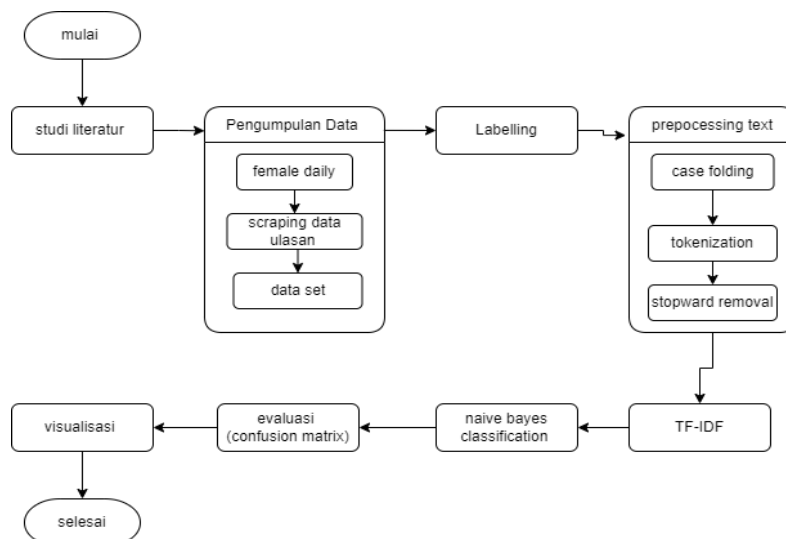
Dalam penelitian ini, dilakukan analisis sentimen terhadap produk *moisturizer* yang populer dengan menerapkan metode naïve Bayes. Analisis sentimen secara otomatis mengolah data untuk menentukan sentimen terhadap suatu kalimat, tentang apakah opini atau kecenderungan masyarakat lebih positif atau negatif[5]. Analisis sentimen juga dapat digunakan

sebagai referensi untuk meningkatkan pelayanan dan kualitas produk. Penelitian ini memiliki tujuan untuk mengatasi masalah dengan melakukan klasifikasi otomatis terhadap ulasan pengguna. Tujuannya adalah untuk menganalisis sentimen produk populer *moisturizer* pada *female daily* dengan menggunakan metode *naïve bayes*.

2. Metode Penelitian

Kerangka penelitian

Pada penelitian ini, digunakan beberapa tahapan dalam metodanya, yang dijelaskan dalam kerangka penelitian. Adapun kerangka penelitian dalam analisis sentimen produk populer *moisturizer* pada *female daily* menggunakan metode *naïve bayes*, pada gambar berikut.



Sumber: Hasil Penelitian(2023)

Gambar 1. Kerangka Penelitian

Pada penelitian ini tahap pertama dilakukan dengan Studi literatur, pada tahap ini melakukan review pada penelitian terdahulu seputar analisis sentimen ulasan yang mengaplikasikan metode *naïve bayes* yang nantinya bisa dijadikan acuan yang dipakai untuk menyelesaikan penelitian. Tahap kedua yaitu pengumpulan data dilakukan dengan *scraping* data menggunakan *web scraper* dengan mengambil data produk populer *moisturizer* pada *female daily*. Tahap ketiga yaitu labelling atau pelabelan dengan memberikan label pada *text* dokumen dengan kelas sentimen positif dan negatif. Tahap keempat *preprocessing text*, pada tahap ini dokumen akan melakukan tahapan *tokenization*, *case folding* dan *stopword removal* untuk menghindari data dokumen yang belum siap diolah menjadi data dokumen yang siap diproses tahap selanjutnya. Tahap kelima TF-IDF dilakukan untuk menghitung bobot atau jumlah kata dalam sebuah dokumen. Tahap enam yaitu klasifikasi menggunakan *naïve bayes*, *naïve bayes* untuk melakukan klasifikasi data sesuai kelas sentimen, mengukur probabilitas hingga menghasilkan nilai akurasi yang didapat dari data testing. Tahap ketujuh evaluasi menggunakan *confusion matrix* digunakan untuk membantu membandingkan nilai yang sebenarnya dengan hasil prediksi. Tahap terakhir yaitu visualisasi yang bertujuan untuk menunjukkan hasil perhitungan klasifikasi dengan pembuatan grafik dan wordcloud

Data yang digunakan pada yaitu data ulasan tiga produk populer *moisturizer* pada *female daily*, Pengumpulan data dilakukan dengan *scraping* menggunakan *google extension* yaitu *web scraper* pada website *female daily* dengan menggunakan fitur '*sort by: popular*'. Data yang diambil yaitu ulasan tiga produk populer *moisturizer* yaitu *skintific*, *loreal* dan *whitelab*. Dari hasil tersebut mendapatkan data sebanyak *skintific* 1500, *loreal* 1630, dan *whitelab* 1270. Data tersebut sudah diberi kelas sentimen positif dan negatif namun belum siap diolah jadi harus melakukan tahapan *preprocessing text* terlebih dahulu supaya data siap dipakai untuk proses selanjutnya. Penelitian ini pada proses *labelling* sampai evaluasi menggunakan bahasa pemrograman *python* pada *google colab* dan *microsoft excel*.

Web scraping

Web scraping adalah teknik untuk mengambil informasi dari situs web secara otomatis tanpa memerlukan proses penyalinan manual[6]. Scraping data adalah proses mengambil atau mengumpulkan data dari internet. Data yang diambil berupa teks, kemudian menyimpannya ke dalam sebuah file excel yang isinya berupa data user ataupun data ulasan produk.

Lexicon based

Lexicon based adalah proses pemilihan kata-kata penting dalam suatu dokumen berdasarkan kamus/leksikon yang ada. Dalam aplikasi ini, kami memiliki dua kamus yang digunakan sebagai daftar kata. Kamus frasa emosi positif dan kamus Frasa emosi negatif[7]. Vander sentiment, yaitu metode analisis *lexicon based* berbasis *lure-based sentiment analysis*[8]. Ulasan positif jika nilai polaritasnya >1, negatif jika polaritasnya <0, dan ulasan netral jika nilai polaritasnya bernilai =0[9].

TF-IDF

Pembobotan TF-IDF adalah proses konversi data teks menjadi data numerik untuk setiap kata atau fitur yang diberi bobot[10]

$$IDF(tk) = \log \left(\frac{D}{df(t)} \right) \dots\dots\dots(1)$$

$$TF\ IDF = TF * IDF(tk) \dots\dots\dots(2)$$

Keterangan:

- IDF(tk) = Nilai Inverse Document Frequency dari kata “tk”
- D = jumlah total dokumen dalam kumpulan dokumen yang akan di analisis
- Df(t) = jumlah dokumen yang mengandung kata “t”
- Tf = jumlah nilai *term* yang muncul dalam sebuah dokumen

Naïve Bayes

Naïve Bayes adalah suatu teknik prediksi yang sederhana berdasarkan probabilitas, yang mengaplikasikan teorema Bayes dengan asumsi independensi yang signifikan[11]. Pendekatan klasifikasi menggunakan metode *naïve bayes* bertujuan untuk membuat keputusan dengan memprediksi hasil suatu kasus berdasarkan klasifikasi yang telah dilakukan sebelumnya[5]. *Naïve bayes* digunakan untuk mengklasifikasikan data sesuai kelas, mengukur probabilitas dan nantinya menghasilkan nilai akurasi yang dari data *testing*.

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \dots\dots\dots (3)$$

P(A|B) yaitu peluang A terjadi jika B sudah terjadi, P(B|A) yaitu peluang B terjadi jika A sudah terjadi, P(A) yaitu peluang A, dan P(A) yaitu peluang A

Confusion Matrix

Confusion matrix yaitu suatu metode yang umumnya digunakan untuk menghitung tingkat akurasi dalam *data mining*[12]. Proses ini hasil evaluasi nantinya akan menghasilkan nilai nilai akurasi, presisi, dan recall. Adapun rumus perhitungan dari *confusion matrix* yaitu:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \dots\dots\dots (4)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots(5)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \dots\dots\dots(6)$$


Keterangan rumus *confusion matrix*:

- TP = True Positif (nilai diprediksi positif dan memang positif sesuai aktual)
- TN = True Negatif (nilai diprediksi negatif dan memang negatif sesuai aktual)
- FN = False Negatif (nilai diprediksi negatif tetapi sebenarnya positif sesuai aktual)
- FP = False Positif (nilai diprediksi positif tetapi sebenarnya negatif aktual negatif)

3. Hasil dan Pembahasan

Pengumpulan data

Dalam penelitian ini, data yang digunakan diperoleh melalui proses pengambilan data ulasan produk populer *moisturizer* pada website <https://femaledaily.com/category/skincare> menggunakan bantuan *Google Extension* yaitu *web scrapper*.



Sumber: Hasil Penelitian(2023)

Gambar 2. Create Sitemap Web Scrapper

Berdasarkan gambar 2. menjelaskan *Create sitemap* untuk mengambil data dengan memasukan link alamat domain produk yang akan *scraping* datanya dan diberi nama yang sesuai dengan produknya. Lalu memilih elemen apa saja yang diperlukan datanya seperti nama, ulasan maupun tanggal. Setelah itu memulai proses *scraping*. Setelah *scraping* data selesai, data dapat disimpan dalam format, seperti csv, xlsx atau json. Selanjutnya hasil dari proses *scraping* data tiap produk populer *moisturizer* menghasilkan data berikut.

1	Text
2	Brand ini tuh brandingnya dimana-mana awalnya skeptiss tp ternyata bagus polli gila mantep sih, kulit beneran makin bagus kalau pakai ini rutin, tipe kulit ku kan kering ya, pakai ini cocok banget bangeet, walaupun harga lumayan tapi sukaak
3	cocok banget di aku dia ngebantu kulit ku yang waktu itu breakout gara gara gentle cleanser, aku mau jual punya ku yang ukuran besar karna nyetok waktu itu ukuran 80 g 270k aja.
4	love hate tapi ujungnya ga recommend sih. why? dari segi volume ini sedikit bangettt huhu. dia cocok di mukaku yang combination & acne prone, tapi gak yang gimana banget juga kayak review orang-orang. apakah aku puas? tentu tidak, makanya repurchase. tapi ternyata tetep sama aja. bagus? engga, jelek? engga juga. tapi cukup 2x aja aku pake ini produk as moisturizer
1	Text
2	Hampa banget kalau ini diskip, gak yang lengket sama sekali. Dibarengi sama sunscreennya cakep poooill nyatuu bgtt, aku biasa jadiin dasar makeup kalau kemana kemana gak bawa primer. Pakai cushion apapun dia nyatu. Gak bikin muka minyak
3	iseng iseng nyoba punya mama sekalian sama yg nightnya. ternyata bagus bgt sih day creamya kasih efek bluring gitu di aku muka berasa mulus bgt. wanginya ga bikin ganggu ditimpa sunscreen gak dempul justru bagus jdnya. ukurannya ada 2, yg mini & full jd kalo mau coba bisa beli yg mini dulu yaa.
1	Text
2	aku rekomended bngt sii buat acne spot nya ini, cuma buat beberapa produk diaku Awal2 emng bagus tpi setelah repurchash malah makin down yaa di aku :(what wrong whitelabb??? tpi sekali lagi untuk obat jerawat nya bagus 4-5 harian ngempes wangi nya juga masih aman gak nyengat
3	di aku ga terlalu bagus huwehh. sorry. ga terlalu mempan juga di jerawatku. kurang suka juga sama teksturnya yang cream dan berwarna. jadi kelihatan kalau lagi pake acne cream. aku gak tau kalau di orang lain bagus apa enggak. aku ga repurchase lagi

Sumber: Hasil Penelitian(2023)

Gambar 3. Hasil Scarping Data Ulasan Produk Populer *Moisturizer*

Berdasarkan gambar 3. menunjukkan hasil *scraping* data ulasan produk populer *moisturizer* yang telah di dapatkan dari proses *scraping*, total data dapat dilihat di tabel 1.

Tabel 1. Total Data Hasil Scraping

Moisturizer Total data	
Skintific	1500
Loreal	1630
Whitelab	1270
Data total	4400

Sumber: Hasil Penelitian(2023)

Labelling

Labelling atau pelabelan data dilakukan untuk menentukan sentimen terhadap setiap ulasan produk populer *moisturizer*. Dalam penelitian ini, dua kelas sentimen yang digunakan, adalah sentimen positif dan sentimen negatif.

```
!pip install vaderSentiment

analyser = SentimentIntensityAnalyzer()

scores = [analyser.polarity_scores(x) for x in data['ulasan']]
print(scores)
data['Compound_Score'] = [x['compound'] for x in scores]

data.loc[data['Compound_Score'] < 0, 'Sentiments'] = 'Negatif'
data.loc[data['Compound_Score'] == 0, 'Sentiments'] = 'Netral'
data.loc[data['Compound_Score'] > 0, 'Sentiments'] = 'Positif'
data.head(10)
```

Sumber: Hasil Penelitian(2023)

Gambar 4. Proses Labelling Data Ulasan Produk Populer *Moisturizer*

Pada gambar 4 menampilkan proses labelling pada *google colaboratory* dan mendapatkan jumlah hasil sentimen data ulasan dapat dilihat pada tabel 2.

Tabel 2. Jumlah Hasil Sentimen Data Ulasan

Moisturizer	Jumlah data		
	Positif	Negatif	Total
Skintific	1227	212	1439
Loreal	843	56	899
Whitelab	1108	127	1235
Data total	3178	395	3573

Sumber: Hasil Penelitian (2023)

Preprocessing text

Tahapan *preprocessing text* dilakukan untuk mengubah data yang awalnya tidak terstruktur menjadi terstruktur. Selain itu, tahapan ini juga bertujuan untuk membersihkan data dari noise atau gangguan yang tidak diinginkan, sehingga mempermudah analisis dan pengolahan selanjutnya. Lalu dan mempersiapkan data yang akan diklasifikasikan dengan melakukan, *tokenization*, *case folding*, dan *stopword removal*. Semua tahapan *preprocessing text* menggunakan python dengan tools *google colaboratory*.

Case folding

Tahapan *case folding* berfungsi untuk mengubah huruf kapital menjadi huruf kecil dalam data ulasan, serta menghapus angka, tanda baca dan spasi untuk menyederhanakan teks dalam analisis.

```
def preprocess_text(kalimat):
    #mengubah kalimat menjadi huruf kecil
    lower_case = str(kalimat).lower()

    #menghapus angka dari kalimat
    hasil = re.sub(r"\d+", "", lower_case)

    #menghapus tanda baca dari kalimat
    hasil = hasil.translate(str.maketrans("", "", string.punctuation))

    #menghapus spasi pada awal dan akhir kalimat
    hasil = hasil.strip()

    return hasil
```

Sumber: Hasil Penelitian (2023)

Gambar 5. Proses Case Folding

Tokenization

Tahapan *tokenization* berfungsi untuk memisahkan setiap kalimat dalam ulasan menjadi kata-kata tunggal, sehingga kata-kata tersebut dapat diberi bobot atau pembobotan.

```
1 def tokenize_text(kalimat):
2     tokens = nltk.tokenize.word_tokenize(kalimat)
3     return tokens
```

Sumber: Hasil Penelitian (2023)

Gambar 6. Proses Tokenization

Stopword removal

Tahapan *stopword removal* adalah proses penghapusan kata-kata umum yang sering kali timbul dan yang tidak memberikan makna atau tidak memberi pengaruh isi dari data ulasan.

```
def stopword_text(tokens):
    cleaned_tokens = []
    for token in tokens:
        if token not in stopwords:
            cleaned_tokens.append(token)
    return cleaned_tokens
```

Sumber: Hasil Penelitian (2023)

Gambar 7. Proses Stopword Removal

Setelah melakukan tahapan semua *preprocessing text* tersebut, akan diperoleh hasil seperti yang terlihat pada gambar dibawah ini.

ulasan	Sentiments	case	token	stop
worth to try sih tpi ga yg wow bgt kyk yg di r...	Positif	worth to try sih tpi ga yg wow bgt kyk yg di r...	[worth, to, try, sih, tpi, ga, yg, wow, bgt, k...	[worth, to, try, sih, tpi, ga, yg, wow, bgt, k...
best moisturizer banget..., bikin lembab iya c...	Positif	best moisturizer banget bikin lembab iya cerah...	[best, moisturizer, banget, bikin, lembab, iya...	[best, moisturizer, banget, bikin, lembab, iya...
Ini produk bagus bangettt. Digunain dimalem ha...	Negatif	ini produk bagus bangettt digunain dimalem har...	[ini, produk, bagus, bangettt, digunain, dimal...	[produk, bagus, bangettt, digunain, dimalem, h...
pake ini sebenarnya udah mikir panjang karena l...	Negatif	pake ini sebenarnya udah mikir panjang karena l...	[pake, ini, sebenarnya, udah, mikir, panjang, k...	[pake, sebenarnya, udah, mikir, panjang, liat, ...
Okay, ini produk bagus kalau aku lagi di daer...	Negatif	okayy ini produk bagus kalau aku lagi di daera...	[okayy, ini, produk, bagus, kalau, aku, lagi, ...	[okayy, produk, bagus, kalau, aku, daerah, din...

Sumber: Hasil Penelitian (2023)

Gambar 8. Hasil Data Ulasan Setelah Preprocessing Text

TF-IDF (*Term Frequency-Inverse Document Frequency*)

Pada tahap TF-IDF, langkah pertama yaitu menghitung term frequency (TF) yang merupakan frekuensi kemunculan suatu kata dalam suatu dokumen.

```
# Menghitung Term Frequency (TF) untuk setiap kata dalam setiap dokumen
tf = {}
for i, doc in enumerate(data['clean']):
    tf[i] = {}
    words = doc.split()
    for word in words:
        tf[i][word] = tf[i].get(word, 0) + 1
```

Sumber: Hasil Penelitian (2023)

Gambar 9. Proses Term Frequency (TF)

Selanjutnya, proses inverse document frequency (IDF) menghitung document frequency (DF), yaitu berapa frekuensi dokumen yang mengandung kata tertentu. DF mengukur seberapa sering kata tersebut muncul dalam seluruh dataset.

```
1 # Menghitung Document Frequency (DF) untuk setiap kata
2 df = {}
3 for doc in data['clean']:
4     words = set(doc.split())
5     for word in words:
6         df[word] = df.get(word, 0) + 1

# Menghitung Inverse Document Frequency (IDF) untuk setiap kata
ids = {}
total_documents = len(data)
for word, freq in df.items():
    idf = math.log10(total_documents / freq)
    ids[word] = idf
```

Sumber: Hasil Penelitian (2023)

Gambar 10. Proses Document Frequency (DF) dan Invers Document Frequency (IDF)

Setelah mendapatkan nilai IDF (inverse document frequency), langkah berikutnya adalah mencari nilai TF-IDF (*Term Frequency-inverse document frequency*). Nilai TF-IDF didapatkan dengan mengalikan nilai TF (*term frequency*) dengan nilai IDF (*inverse document frequency*) untuk setiap kata dalam setiap dokumen.

```
# Menampilkan hasil
for doc_id, term_freqs in tf.items():
    print("Dokumen ID:", doc_id)
    for word, freq in term_freqs.items():
        tfidf = freq * ids[word]
        print("Kata:", word, "TF-IDF:", tfidf)
```

Sumber: Hasil Penelitian (2023)

Gambar 11. Proses (TF-IDF) Term Frequency-Inverse Document Frequency

Perhitungan pembobotan kata dapat dilakukan dengan dua cara, baik secara manual di excel maupun menggunakan python. Jika dilakukan dengan cara manual bisa dilihat perhitungannya pada rumus TF-IDF yang telah dijelaskan sebelumnya.

Klasifikasi Naïve bayes

Dokumen ulasan produk *moisturizer* yang telah melakukan proses tahapan preprocessing dan TF-IDF (pembobotan kata) selanjutnya dapat diklasifikasikan. Microsoft Excel digunakan guna perhitungan *term frequency* (TF) dan *inverse document frequency* (IDF) secara manual. Sedangkan, Python digunakan untuk memodelkan klasifikasi sentimen menggunakan metode Naïve Bayes Classifier dan menghitung nilai TF-IDF dengan lebih efisien dan akurat.

Menghitung klasifikasi naïve bayes

Berikut ini yaitu kumpulan data sampel yang akan digunakan untuk menghitung klasifikasi terdapat 4 data ulasan, data sampel tersebut ditandai sebagai 2 sentimen positif, dan 2 sentimen negatif. Adapun data sampel yang nantinya digunakan sebagai data latih, dan bisa dilihat pada tabel berikut.

Tabel 3. Data Sampel Ulasan

Dokumen ulasan	Sentiment
skintific bagus banget sih beli product skin barrier membaik tekstur nya cepet nyerap kulit ngademin ga mengeluarkan aroma aneh	positif
aku abis pake skintific bagus banget pas dicoba keren melembabkan	positif
aku ga cocok langsung timbul bruntusan jidat lumayan banyak aku stop trus coba lagi eh bruntusan nya muncul akhirnya stop pake deh	negatif
baru pertama kali coba skintific langsung jerawat	negatif

Sumber: Hasil Penelitian (2023)

Dari tabel 3. yang berisi data sampel tersebut dilakukan an perhitungan dengan menggunakan microsoft excel, pertama menentukan nilai term frequency pada dokumen yang berisi data ulasan.

Tabel 4. Term Frequency (TF) Data sampel

TERM	TF			
	d1	d2	d3	d4
skintific	1	1	0	1
bagus	1	1	0	0
banget	1	1	0	0
sih	1	0	0	0
beli	1	0	0	0
product	1	0	0	0
skin	1	0	0	0
barier	1	0	0	0
membaik	1	0	0	0
tekstur	1	0	0	0
nya	1	0	1	0
cepat	1	0	0	0
nyerap	1	0	0	0
kulit	1	0	0	0
ngademin	1	0	0	0
ga	1	0	1	0
mengeluarkan	1	0	0	0
aroma	1	0	0	0
aneh	1	0	0	0
aku	0	1	2	0
abis	0	1	0	0
pake	0	1	1	0
pas	0	1	0	0
dicoba	0	1	0	0
keren	0	1	0	0
melembabkan	0	1	0	0
cocok	0	0	1	0
langsung	0	0	1	1

Sumber: Hasil Penelitian (2023)

Setelah menentukan nilai term frequency, langkah selanjutnya adalah melakukan perhitungan untuk menghitung jumlah kemunculannya kata unik dan total kata dalam setiap kategori. Berikut adalah alur prosesnya.

Tabel 5. Kemunculan Kata Unik Pada Sampel

Kategori	Jumlah dokumen di setiap kategori	Jumlah Dokumen Seluruhnya	P(Kategori)	Jumlah Kata Setiap Kategori
positif	2	4	0,50	29
negatif	2	4	0,50	27
Jumlah Kata Unik		45		

Sumber: Hasil Penelitian (2023)

Dari tabel 5. diatas didapatkan hasil perhitungan menunjukkan bahwa jumlah kata dalam kategori positif adalah 29 kata, sedangkan dalam kategori negatif terdapat 27 kata. Selain itu, terdapat 45 kata unik yang muncul dalam keseluruhan data. Lalu setelah mendapatkan nilai jumlah kata unik dan nilai jumlah kata pada setiap kategori, langkah selanjutnya adalah menghitung nilai probabilitas untuk setiap kategori.

$$P(\text{Kata}) = \frac{\text{jumlah dari satu kata di satu kategori} + 1}{\text{jumlah kata tiap kategori} + \text{jumlah keseluruhan kata unik}} \dots\dots\dots (7)$$

Cara menghitung probabilitas penulis akan mencontohkan untuk kata "skintific" dimana 2 ditambah 1 lalu hasilnya dibagi dengan jumlah total kata unik, yaitu 29 (jumlah kata pada kategori positif) ditambah 45 (jumlah kata unik secara keseluruhan).

$$(skintific | positif) \frac{2 + 1}{29 + 45} = \frac{3}{74} = 0,0405$$

$$(skintific | negatif) \frac{1 + 1}{27 + 45} = \frac{2}{72} = 0,02777$$

Model klasifikasi naïve bayes

Pada tahapan pemodelan proses klasifikasi naïve bayes menggunakan *python* dengan tools google *colaboratory*. Langkah pertama yaitu menginstall library yang diperlukan, pastikan semua library yang dibutuhkan sudah terinstall dengan baik. Setelah itu, lanjutkan dengan mendeklarasikan semua library yang diperlukan sebelum menggunakannya dalam program.

```
#Import Library
import string
from sklearn.model_selection import train_test_split
from sklearn.feature_extraction.text import TfidfVectorizer

#Naive Bayes
from sklearn.naive_bayes import GaussianNB
```

Sumber: Hasil Penelitian (2023)

Gambar 12. Proses Import Library

Setelah semua library dideklarasikan, langkah selanjutnya adalah melakukan pembagian dataset, pembagian dataset ini dilakukan dengan menggunakan modul atau fungsi dari library python yang telah dimasukan sebelumnya yaitu modul *train_test_split* dari *scikit-learn*. Pembagian dataset dengan memisahkan data training dan data testing dibagi dengan perbandingan 80:20, dimana 80% dari data digunakan untuk training dan 20% untuk testing.

```
#Memisahkan data training dan data testing dengan perbandingan 80:20
X_train, X_test, y_train, y_test = train_test_split(v_data, data['Sentiments'], test_size=0.2, random_state=0)
model_g.fit(X_train,y_train)
```

Sumber: Hasil Penelitian (2023)

Gambar 13. Proses Pembagian Dataset

Setelah pembagian dataset dilakukan, maka data siap diterapkan pada model. Model Naïve Bayes dibuat dengan menggunakan modul naïve bayes dari *Scikit-Learn*. Model klasifikasi yang digunakan adalah gaussian naïve bayes.

```
vectorizer = TfidfVectorizer (max_features=2500)
model_g = GaussianNB()
v_data = vectorizer.fit_transform(data['ulasan']).toarray()
print (v_data)

#algoritme fitting
text_algorithm = GaussianNB ()
model = text_algorithm.fit(X_train, y_train)

# save
dump(model, filename="model_sentiment_naive.joblib")

#Prediksi
predicted = model.predict(X_test)

#Hasil ini akan kita bandingkan dengan nilai y_test (labeling dari manusia)
predicted
```

Sumber: Hasil Penelitian (2023)

Gambar 14. Model Klasifikasi Naive Bayes

Evaluasi (*confusion matrix*)

Pada tahap proses evaluasi ini menggunakan *confusion matrix*. Keempat istilah *confusion matrix* digunakan untuk menghitung akurasi, presisi, recall, guna mengevaluasi kinerja model.

Tabel 6. *Confusion Matrix*

Prediksi	aktual	
	Positif	Negatif
Positif	(TP) True Positif	(FP) False Positif
Negatif	(FN) False Negatif	(TN) True Negatif

Sumber: Hasil Penelitian (2023)

Hasil evaluasi klasifikasi

Pada proses hasil evaluasi naïve bayes dengan *confusion matrix* dilakukan dengan perhitungan menggunakan python dan perhitungan manual.

```
CM = confusion_matrix(y_test,predicted)

TN = CM[0][0]
FN = CM[1][0]
TP = CM[1][1]
FP = CM[0][1]

precision = TP/(TP+FP)
recall = TP/(TP+FN)

print ("TRUE NEGATIVE (TN):",TN)
print ("FALSE NEGATIVE (FN):",FN)
print ("TRUE POSITIVE (TP):",TP)
print ("FALSE POSITIVE (FP):",FP)
print ("PRECISION:",precision*100,"%")
print ("RECALL:",recall*100,"%")
print(confusion_matrix(y_test,predicted))
print(classification_report(y_test,predicted))
```

Sumber: Hasil Penelitian (2023)

Gambar 15. Proses Confusion Matrix

Setelah melakukan proses dengan python pada google colaboratory makan akan didapatkan hasil nilai *accuracy, precision dan recall*

Skintific

```
Akurasi Algoritme: 80.55555555555556 %
TRUE NEGATIVE (TN): 6
FALSE NEGATIVE (FN): 22
TRUE POSITIVE (TP): 226
FALSE POSITIVE (FP): 34
PRECISION: 86.92307692307692 %
RECALL: 91.12903225806451 %
```

Sumber: Hasil Penelitian (2023)

Gambar 16. Hasil Confusion Matrix

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% = \frac{226+6}{226+6+34+22} = \frac{232}{288} = 0,8055 = 80,55 \%$$

$$\text{Precision (positif)} = \frac{TP}{TP+FP} \times 100\% = \frac{226}{226+34} = \frac{226}{260} = 0,8692 = 86,92\%$$

$$\text{Recall(positif)} = \frac{TP}{TP+FN} = \frac{226}{226+22} = \frac{226}{248} = 0,9112 = 91,12\%$$

Loreal

Akurasi Algoritme: 89.44444444444444 %
 TRUE NEGATIVE (TN): 1
 FALSE NEGATIVE (FN): 5
 TRUE POSITIVE (TP): 160
 FALSE POSITIVE (FP): 14
 PRECISION: 91.95402298850574 %
 RECALL: 96.96969696969697 %

Sumber: Hasil Penelitian (2023)

Gambar 17. Hasil Confusion Matrix Loreal

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% = \frac{160+1}{160+14+1+5} = \frac{161}{180} = 0,894 = 89,4\%$$

$$\text{Precision(positif)} = \frac{TP}{TP+FP} \times 100\% = \frac{160}{160+14} = \frac{160}{174} = 0,919 = 91,9\%$$

$$\text{Recall(positif)} = \frac{TP}{TP+FN} \times 100\% = \frac{160}{160+5} = \frac{160}{165} = 0,969 = 96,9\%$$

Whitelab

Akurasi Algoritme: 88.66396761133603 %
 TRUE NEGATIVE (TN): 4
 FALSE NEGATIVE (FN): 7
 TRUE POSITIVE (TP): 215
 FALSE POSITIVE (FP): 21
 PRECISION: 91.10169491525424 %
 RECALL: 96.84684684684684 %

Sumber: Hasil Penelitian (2023)

Gambar 18. Hasil Confusion Matrix Whitelab

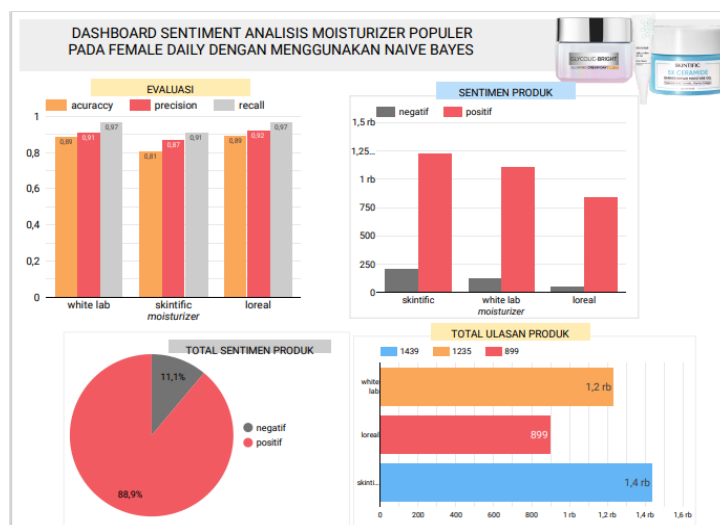
$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% = \frac{215+4}{215+21+4+7} = \frac{219}{247} = 0,8866 = 88,66\%$$

$$\text{Precision(positif)} = \frac{TP}{TP+FP} \times 100\% = \frac{215}{215+21} = \frac{215}{236} = 0,9110 = 91,10\%$$

$$\text{Recall(positif)} = \frac{TP}{TP+FN} \times 100\% = \frac{215}{215+7} = \frac{215}{222} = 0,9684 = 96,84\%$$

Visualisasi

Tahap visualisasi disini di tuangkan dalam bentuk grafik untuk menampilkan sebuah informasi dan untuk mempermudah pembacaan hasil klasifikasi penelitian. Visualisasi ini menggunakan *tools lookers studio*.



Sumber: Hasil Penelitian (2023)

Gambar 19. Visualisasi Hasil

Visualisasi dengan *column chart* dengan judul evaluasi untuk mengetahui perbandingan perhitungan akurasi menggunakan *confusion matrix* yang didalamnya menunjukkan tingkat *accuracy*, *precision*, dan *recall* dari setiap produk populer *moisturizer*. Dan *column chart* untuk mengetahui perbandingan jumlah sentimen tiga produk yaitu jumlah sentimen produk positif (dilambangkan dengan kolom merah) dan sentimen produk negatif (dilambangkan dengan kolom abu) dari setiap produk populer *moisturizer*. Juga ada total sentimen produk, berisikan seluruh total sentimen yang negatif dan positif di visualisasikan dengan *pie chart* digunakan untuk mengetahui jumlah data positif dan negatif dari produk populer *moisturizer*. Dan terakhir ada *bar chart* untuk total ulasan produk yang menunjukkan jumlah ulasan dari setiap produk populer *moisturizer*. Ada juga *wordcloud* dari data ulasan setiap produk populer *moisturizer* dengan menghasilkan kata yang sering muncul dalam ulasan teks negatif dan positif yang sudah dianalisis.



Sumber: Hasil Penelitian (2023)

Gambar 20. Wordcloud Skintific Negatif

Berdasarkan gambar 20. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data negatif skintific adalah "bruntusan", "kering", "skintific", "jerawatan", dan lain – lain.



Sumber: Hasil Penelitian (2023)

Gambar 21. Wordcloud Skintific Positif

Berdasarkan gambar 21. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data positif skintific adalah "moisturizer", "skin barrier", "skintific", "cocok", dan lain – lain.



Sumber: Hasil Penelitian (2023)

Gambar 22. Wordcloud Loreal Negatif

Berdasarkan gambar 22. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data negatif loreal adalah "loreal", "noda hitam", "berminyak", "thick", dan lain – lain.



Sumber: Hasil Penelitian (2023)

Gambar 23. *Wordcloud* Loreal Positif

Berdasarkan gambar 23. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data positif loreal adalah “glycolic bright”, “glowing”, “cream spf”, “loreal paris”, dan lain – lain



Sumber: Hasil Penelitian (2023)

Gambar 24. *Wordcloud* Whitelab Negatif

Berdasarkan gambar 24. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data negatif whitelab adalah “jerawat”, “kering”, “acne cream”, “bekas”, dan lain – lain.



Sumber: Hasil Penelitian (2023)

Gambar 25. *Wordcloud* Whitelab Positif

Berdasarkan gambar 25. *Wordcloud* tersebut berisi kata yang sering kali muncul dalam ulasan data positif whitelab adalah “whitelab”, “bagus banget”, “kempes”, “bekas jerawat”, dan lain – lain.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa analisis sentimen produk populer *moisturizer* pada platform *Female daily* menggunakan metode Naïve Bayes telah mencapai hasil yang baik. Data dari tiga brand *moisturizer* diambil menggunakan web scraping dengan bantuan *Google Extension* bernama *Webscraper*. Data kemudian melalui tahap preprocessing text dan klasifikasi menggunakan metode Naïve Bayes, serta dievaluasi dengan confusion matrix menggunakan bahasa pemrograman Python di Google Colaboratory.

Hasil evaluasi menunjukkan bahwa model klasifikasi memiliki akurasi sebesar 80.55% untuk ulasan skintific, 89.4% untuk ulasan Loreal, dan 88.66% untuk ulasan Whitelab. Selain itu, nilai precision (kemampuan sistem mencari ketepatan informasi) dan recall (tingkat keberhasilan sistem menemukan kembali informasi) juga mencapai nilai tinggi pada kelas positif untuk ketiga produk *moisturizer* tersebut. Hal ini mengindikasikan bahwa ulasan pengguna pada platform *Female daily* cenderung memberikan sentimen positif terhadap produk *moisturizer* yang populer.

Berdasarkan nilai-nilai tersebut, analisis sentimen produk populer *moisturizer* pada *female daily* menggunakan naïve bayes disimpulkan dapat mengidentifikasi sentimen data dengan baik.

Referensi

- [1] M. E. T. Butar butar and A. Y. Chaerunisaa, "Peran Pelembab dalam Mengatasi Kondisi Kulit Kering," *Majalah Farmasetika*, vol. 6, no. 1, Oct. 2020, doi: 10.24198/mfarmasetika.v6i1.28740.
- [2] E. Y. Hidayat and D. Handayani, "Penerapan 1D-CNN untuk Analisis Sentimen Ulasan Produk Kosmetik Berdasar *Female daily* Review," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, pp. 153–163, Jan. 2023, doi: 10.25077/teknosi.v8i3.2022.153-163.
- [3] R. Sari, "Analisis Sentimen Review Restoran menggunakan Algoritma Naive Bayes berbasis Particle Swarm Optimization," *JURNAL INFORMATIKA*, vol. 6, no. 1, pp. 23–28, 2019, [Online]. Available: <http://ejournal.bsi.ac.id/ejournal/index.php/ji/article/view/4695>
- [4] E. Indrayuni, "Klasifikasi Text Mining Review Produk Kosmetik Untuk Teks Bahasa Indonesia Menggunakan Algoritma Naive Bayes," *JURNAL KHATULISTIWA INFORMATIKA*, vol. VII, no. 1, 2019.
- [5] N. M. A. J. Astari, Dewa Gede Hendra Divayana, and Gede Indrawan, "Analisis Sentimen Dokumen Twitter Mengenai Dampak Virus Corona Menggunakan Metode Naive Bayes Classifier," *Jurnal Sistem dan Informatika (JSI)*, vol. 15, no. 1, pp. 27–29, Nov. 2020, doi: 10.30864/jsi.v15i1.332.
- [6] D. D. Ayani, H. S. Pratiwi, and H. Muhardi, "Implementasi Web Scraping untuk Pengambilan Data pada Situs Marketplace," *Jurnal Sistem dan Teknologi Informasi*, vol. 7, no. 4, 2019.
- [7] N. S. Fathullah, Y. A. Sari, and P. P. Adikara, "Analisis Sentimen Terhadap Rating dan Ulasan Film dengan menggunakan Metode Klasifikasi Naïve Bayes dengan Fitur Lexicon-Based," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 4, no. 2, pp. 590–593, 2020, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [8] P. A. Sumitro, D. I. Mulyana, and W. Saputro, "Analisis Sentimen Terhadap Vaksin Covid-19 di Indonesia pada Twitter Menggunakan Metode Lexicon Based," *Jurnal J-COM (Jurnal Informatika dan Teknologi Komputer)*, vol. 02, no. 02, pp. 50–56, 2021, [Online]. Available: <https://developer.twitter.com>
- [9] M. Hamka, N. Alfatari, and D. Ratna Sari, "Analisis Sentimen Produk Kecantikan Jenis Serum Menggunakan Algoritma Naïve Bayes Classifier," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 4, no. 1, p. 64, Sep. 2022, doi: 10.30865/json.v4i1.4740.
- [10] J. A. Septian, T. M. Fahrudin, and A. Nugroho, "Analisis Sentimen Pengguna Twitter Terhadap Polemik Persepakbolaan Indonesia Menggunakan Pembobotan TF-IDF dan K-Nearest Neighbor," *JOURNAL OF INTELLIGENT SYSTEMS AND COMPUTATION*, 2019, [Online]. Available: <https://t.co/9WloaWpfd5>
- [11] C. Fadlan, S. Ningsih, and A. P. Windarto, "PENERAPAN METODE NAÏVE BAYES DALAM KLASIFIKASI KELAYAKAN KELUARGA PENERIMA BERAS RASTRA," *JUTIM*, vol. 3, no. 1, 2018.
- [12] B. Gunawan, H. S. Pratiwi, and E. E. Pratama, "Sistem Analisis Sentimen pada Ulasan Produk Menggunakan Metode Naive Bayes," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 4, no. 2, pp. 17–29, 2018, [Online]. Available: www.femaledaily.com