



Analisis Data CATA Hasil Uji Sensori Produk Coklat Menggunakan Algoritma Naïve Bayes dan *Tools* XLSTAT

Lafnidita Farosanti

Program Studi Ilmu Komputer, Fakultas Teknologi dan Sains, Universitas PGRI Wiranegara, Pasuruan, Indonesia
Email: lafnidita.f@gmail.com

Abstrak

Penelitian ini mengeksplorasi penggunaan kombinasi metode CATA, XLSTAT, dan Naïve Bayes untuk mengklasifikasikan produk coklat berdasarkan atribut sensori dominan serta memahami preferensi konsumen. *Check-All-That-Apply* (CATA) merupakan metode evaluasi sensori deskriptif sederhana dan cepat untuk mengidentifikasi karakteristik produk berdasarkan persepsi konsumen walaupun bukan berasal dari panelis terlatih. Analisis klasifikasi menggunakan Naïve Bayes pada data CATA menghasilkan nilai rata-rata akurasi sebesar 93%. Begitu juga dengan precision, recall, dan F1-score menunjukkan nilai rata-rata diatas 90%. Prediksi terhadap 114 data uji menunjukkan 98 data sebagai 'Produk A', 16 data sebagai 'Produk B', dan tidak ada yang diprediksi sebagai 'Produk C'. Hasil analisis XLSTAT mendukung temuan ini, menunjukkan bahwa produk ideal lebih terkait dengan Produk A, sebagaimana terlihat dalam grafik biplot yang menempatkan keduanya dalam kuadran F1 kanan, mengindikasikan kesamaan karakteristik yang dominan antara atribut produk ideal dengan Produk A.

Kata Kunci: CATA; Naïve Bayes; Uji Sensori; Produk Ideal

ABSTRACT

This research explores the use of a combination of CATA, XLSTAT, and Naïve Bayes methods to classify chocolate products based on dominant sensory attributes and understand consumer preferences. Check-All-That-Apply (CATA) is a simple and fast descriptive sensory evaluation method to identify product characteristics based on consumer perceptions even though they do not come from trained panelists. Classification analysis using Naïve Bayes on CATA data produces an average accuracy value of 93%. Likewise, precision, recall, and F1-score show average values above 90%. Predictions of 114 test data showed 98 data as 'Product A', 16 data as 'Product B', and none were predicted as 'Product C'. The results of the XLSTAT analysis support this finding, showing that the ideal product is more related to Product A, as seen in the biplot graph which places both in the right F1 quadrant, indicating the dominant characteristic similarities between the attributes of the ideal product and Product A.

Keywords: CATA; Naïve Bayes; Sensory Profiling; Ideal Product

1. PENDAHULUAN

Produk coklat merupakan salah satu makanan yang banyak dikonsumsi oleh berbagai kalangan karena cita rasa dan karakteristik sensoriknya yang khas. Evaluasi sensori menjadi

aspek penting dalam pengembangan produk coklat guna memahami preferensi konsumen dan meningkatkan kualitas produk. Salah satu metode yang umum digunakan dalam evaluasi sensori adalah *Check-All-That-Apply* (CATA), yang memungkinkan panelis untuk memilih atribut yang sesuai dengan persepsi mereka terhadap suatu produk (Jaeger, S. R., 2018). Metode ini sangat efektif dalam memperoleh data deskriptif tanpa memerlukan panelis yang terlatih secara khusus (Jaeger, S. R., 2019).

Beberapa penelitian terkait uji sensori produk yaitu pada penelitian (Oktafa et al., 2017) yang membandingkan kinerja Algoritma RBFN (*Radial Basis Function*) dan Naïve Bayes menggunakan *tools* WEKA dimana RBFN memiliki nilai akurasi yang lebih tinggi dibanding dengan naïve bayes yaitu terpaut 3,2% , namun memiliki waktu eksekusi yang lebih lambat yakni 0,003 detik. Penelitian (Ridho, 2024) melakukan perbandingan antara algoritma C4.5 dan Naïve Bayes menggunakan *tools* Rapidminer. algoritma C4.5 digunakan untuk pemilihan atribut yang signifikan dan membangun pohon keputusan yang memberikan pemahaman lebih baik tentang preferensi konsumen. Selain itu, metode Naive Bayes bisa digunakan untuk mengklasifikasikan preferensi konsumen berdasarkan kombinasi atribut yang diberikan. Pengujian yang dihasilkan terlihat bahwa Algoritma Naive Bayes memiliki tingkat akurasi yang lebih tinggi daripada Algoritma C45 dalam memprediksi preferensi konsumen terkait rasa cabai rawit. Analisis uji sensori juga dapat dilakukan dengan bantuan *tools* XLSTAT yang lebih spesifik dalam merepresentasikan atribut dominan yang terdapat dalam produk ideal yaitu melalui teknik *Correspondence Analysis (CA)* dan *Mean Impact Analysis* (Dwijatmoko, 2023).

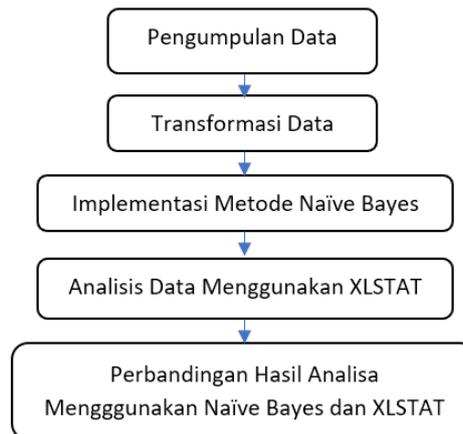
Oleh karena itu dalam penelitian ini, data CATA hasil uji sensori produk coklat dianalisis menggunakan *tools* XLSTAT dan algoritma Naïve Bayes. XLSTAT merupakan perangkat lunak berbasis Microsoft Excel yang menyediakan berbagai fitur analisis statistik, termasuk analisis sensori dan klasifikasi data. Sementara itu, Naïve Bayes adalah algoritma klasifikasi berbasis probabilitas yang dapat digunakan untuk memprediksi preferensi konsumen berdasarkan karakteristik sensori yang dipilih dalam uji CATA.

Tujuan utama dari penelitian ini adalah untuk mengeksplorasi bagaimana kombinasi metode CATA, XLSTAT, dan Naïve Bayes dapat digunakan untuk mengklasifikasikan produk coklat berdasarkan atribut sensori yang dominan serta memahami pola preferensi konsumen. Hasil dari analisis ini diharapkan dapat memberikan wawasan yang lebih mendalam bagi produsen dalam mengembangkan produk coklat yang lebih sesuai dengan selera pasar. Dengan pendekatan ini, penelitian ini tidak hanya memberikan kontribusi dalam

ranah akademik, tetapi juga memiliki implikasi praktis dalam industri makanan, khususnya dalam inovasi produk berbasis evaluasi sensori yang lebih efisien dan berbasis data.

2. METODE

Diagram alir penelitian dirancang untuk mempermudah melaksanakan kegiatan penelitian. Gambar 1 menunjukkan rancangan diagram alir penelitian.



Gambar 1. Diagram Alir Penelitian

2.1 Pengumpulan Data

Uji sensori produk diawali dengan merekrut panelis dengan mengupload link google form untuk melakukan pengujian sensori. Panelis terdiri dari mahasiswa dan dosen di lingkungan kampus dengan rentang usia 17-60 tahun. Panelis yang dipilih dipastikan menyukai dan tidak alergi terhadap produk cokelat tertentu. Pembuatan minuman cokelat membutuhkan beberapa peralatan diantaranya timbangan, pemanas air, gelas ukur 2L, pengaduk, teko saji serta cup kecil. Takaran yang digunakan dalam pembuatan minuman cokelat mengikuti anjuran penyajian yang tertera pada kemasan produk. Penyajian sampel dilakukan pada saat minuman sudah di suhu ruang $\pm 25^{\circ}\text{C}$ pada cup dengan volume sekitar 50 mL. Atribut mutu cokelat akan ditentukan oleh *panel leader* melalui FGD yang disajikan pada Tabel 1. Atribut yang dievaluasi berupa aroma, rasa, *after taste* dan tingkat kesukaan.

Tabel 1. Atribut Pengujian Sensori Minuman Cokelat

Atribut	Sub Atribut	Keterangan
Aroma	Cokelat ID	Aroma khas produk cokelat
	Kopi	Aroma khas kopi
	Burnt	Aroma gosong setelah dipanggang
	Biskuit	Aroma khas kue
	Nutty	Aroma khas kacang
	Sweet	Aroma dengan sensasi gula karamel atau vanila

Atribut	Sub Atribut	Keterangan
Rasa	Bitter	Aroma dengan sensasi pahit yang jelas
	Fruity	Aroma khas buah-buahan
	Creamy	Aroma lembut seperti susu atau krim yang gurih
	Milky	Aroma khas susu
	Vanila	
	Manis	
	Asin	
	Asam	
	Pahit	
	Umami	
Aftertaste	Dry	Sensasi rasa kering setelah mencicipi
	Grainy	Sensasi rasa berpasir seperti tepung
	Asam	Sensasi rasa asam setelah produk ditelan
	Lengket	

Panelis menjawab pertanyaan tentang atribut yang terdapat pada masing-masing produk coklat melalui link google form yang dibagikan oleh panitia. Pada pengujian CATA, konsumen diminta melakukan *checklist* atribut berdasarkan list atribut yang ada untuk menggambarkan suatu produk (Jaeger, S. R., 2020). Data yang diperoleh dari hasil dari pengujian CATA berupa data dikotomis yaitu “1” yang menunjukkan kehadiran suatu atribut pada produk dan “0” yang menunjukkan ketidak hadiran atribut pada produk (Hunaefi & Farhan, 2021). Meskipun sederhana, rata-rata frekuensi atribut sensori CATA mencerminkan peringkat intensitas rata-rata produk makanan. Berdasarkan deskripsi sensori produk, pendekatan umum dengan mempertimbangkan antara tabel kontingensi dan atribut CATA, yaitu matriks produk dan atribut yang menggambarkan jumlah konsumen yang memilih atribut CATA tertentu untuk mengkarakterisasi produk (Jaeger, S. R., 2019).

2.2 Transformasi Data

Jawaban responden dapat didownload dalam format excel. Implementasi algoritma naïve bayes memerlukan *tools* Google Colab yang bisa diakses secara online. Agar dapat mengolah data menggunakan *tools* Google Colab dan XLSTAT, data excel diubah ke dalam format CSV (*Comma Separated Value*).

Panelis hanya memilih jawaban ‘Ya’ dan ‘Tidak’ yang menyatakan atribut pada masing-masing produk coklat. Jawaban tersebut berupa kategorikal sehingga diperlukan perubahan data menggunakan metode *one hot encoding* menjadi data biner seperti pada Tabel 2. Keterangan dalam Tabel 2, produk 1 dipilih sebagai "Manis" dan "Pahit", produk 2 dipilih sebagai "Manis" dan "Asam", produk 3 dipilih sebagai "Asam" dan "Pahit". Dataset dalam penelitian ini kolom produk merupakan informasi nama dari masing-masing merk coklat.

Tabel 2. Contoh tabulasi data CATA sensori

Produk	Manis	Asam	Pahit
1	1	0	1
2	1	1	0
3	0	1	1

2.3 Implementasi Metode Naïve Bayes

Algoritma Naïve Bayes diterapkan untuk mengklasifikasikan preferensi konsumen terhadap produk coklat berdasarkan data atribut sensori yang telah dikumpulkan. Algoritma Naïve Bayes dapat bekerja dengan baik pada dataset kecil dan tetap robust terhadap noise karena berbasis pada probabilitas yang transparan. Untuk data biner, probabilitas dihitung berdasarkan frekuensi kejadian, sementara untuk data kategorikal, model Bernoulli atau Multinomial dapat mengelola kategori tanpa transformasi data yang kompleks (Romli et al., 2021).

2.4 Analisis Data Menggunakan *Tools* XLSTAT

Data yang telah diklasifikasikan dianalisis lebih lanjut menggunakan XLSTAT untuk mendapatkan wawasan tambahan mengenai pola preferensi panelis. XLSTAT digunakan untuk visualisasi hasil, analisis statistik deskriptif, serta eksplorasi hubungan antara atribut sensori dan tingkat kesukaan panelis.

2.5 Perbandingan Hasil Analisa Menggunakan Naïve Bayes dan XLSTAT

Hasil klasifikasi menggunakan Naïve Bayes dibandingkan dengan hasil analisis di XLSTAT untuk mengevaluasi kesesuaian prediksi dengan pola preferensi panelis. Perbandingan ini bertujuan untuk menilai efektivitas kedua pendekatan dalam memahami preferensi konsumen serta memberikan rekomendasi untuk pengembangan produk coklat yang ideal.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Hasil survei responden ditransformasi ke dalam bentuk biner menghasilkan sejumlah 340 dataset yang terdiri dari 109 Produk A, 118 Produk B, dan 113 Produk C dengan jumlah 23 atribut atau kolom seperti yang disebutkan di Tabel 1. Semua atribut bernilai biner 0 dan 1, kecuali *Gender* yaitu ‘Perempuan’ dan ‘Laki-laki’, dan *Sampel* yang menyatakan ketiga produk coklat yaitu ‘Produk A’, ‘Produk B’, dan ‘Produk C’. Responden terdiri dari 219 laki-laki dan 121 perempuan di lingkungan dosen dan mahasiswa di Universitas PGRI Wiranegara.

3.2 Implementasi Algoritma Naïve Bayes

Pada tahap ini menggunakan *tools* Google Colab untuk membuat model klasifikasi Naïve Bayes sehingga diharapkan mampu melakukan prediksi data yang menyatakan atribut ideal terhadap salah satu produk coklat. Pre-processing data dilakukan dengan mengubah nilai kolom *Gender* menggunakan teknik *one hot encoding* menjadi 'P' untuk perempuan, dan 'L' untuk laki-laki. Selanjutnya membagi dataset (*data splitting*) menjadi *data training* dan *data validation* dengan prosentase 80% : 20%. *Data training* berfungsi mempelajari pola data masing-masing produk menggunakan rumus probabilitas, sedangkan *data validation* untuk menguji validitas model klasifikasi menggunakan algoritma Naïve Bayes. Gambar 2 menampilkan *screenshot* kode program bagian *pre-processing*.

```

from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import GaussianNB
from sklearn.metrics import accuracy_score, classification_report

X = df.drop('Sampel', axis=1) # Features
y = df['Sampel']             # Target variable
X = pd.get_dummies(X, columns=['Gender'], drop_first=True) # Example assuming Gender is categorical
# Split data into training and testing sets
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

```

Gambar 2. Coding Pre-processing Data

Proses selanjutnya yakni import library sklearn Gaussian Naive Bayes untuk membuat model klasifikasi serta uji coba model dengan melakukan prediksi terhadap data testing sejumlah 114 data yang dianggap sebagai atribut ideal oleh panelis. Gambar 3 menampilkan listing kode program untuk membuat dan memprediksi model.

```

# Initialize and train the Gaussian Naive Bayes model
model = GaussianNB()
model.fit(X_train, y_train)

# Make predictions on the test set
y_pred = model.predict(X_test)

```

Gambar 3. Coding Implementasi Naïve Bayes

Selanjutnya visualisasi *confusion matrix* dengan melakukan import *library seaborn* dan *matplotlib*. *Confusion Matrix* adalah sebuah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi, khususnya dalam *machine learning* dan statistik. *Confusion matrix* membandingkan prediksi model dengan nilai aktual dari dataset uji, sehingga dapat memberikan gambaran seberapa baik model melakukan klasifikasi. Gambar 4 menampilkan

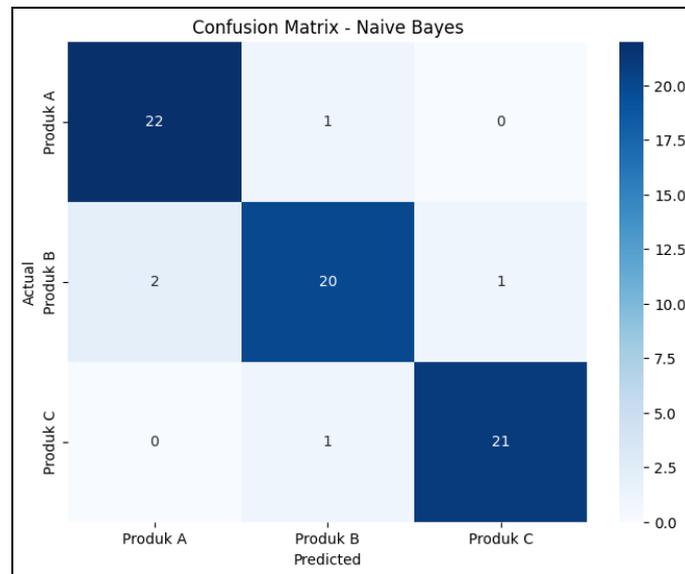
program visualisasi *confusion matrix*. Gambar 5 menampilkan visual *confusion matrix* yang dihasilkan.

```
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt

cm = confusion_matrix(y_test, y_pred)

plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt="d", cmap="Blues",
            xticklabels=np.unique(y_test), yticklabels=np.unique(y_test))
plt.xlabel("Predicted")
plt.ylabel("Actual")
plt.title("Confusion Matrix - Naive Bayes")
plt.show()
```

Gambar 4. Coding Visualisasi Confusion Matrix



Gambar 5. Visualisasi Confusion Matrix

Warna dalam diagram *confusion matrix* menginformasikan bahwasanya semakin gelap warna yang dihasilkan maka semakin tinggi nilai atau *value* yang ada di dalamnya. Semakin tinggi nilai dalam selnya maka semakin banyak model dalam memprediksi data secara benar.

Berdasarkan Gambar 5 tersebut, dapat disimpulkan bahwa :

1. Jumlah Produk A diprediksi benar sebagai 'Produk A' sama dengan 22.
2. Jumlah Produk B diprediksi benar sebagai 'Produk B' sama dengan 20.
3. Jumlah Produk C diprediksi benar sebagai 'Produk C' sama dengan 21.
4. Jumlah Produk A diprediksi salah sebagai 'Produk B' sama dengan 1.
5. Jumlah Produk B diprediksi salah sebagai 'Produk A' sama dengan 2.

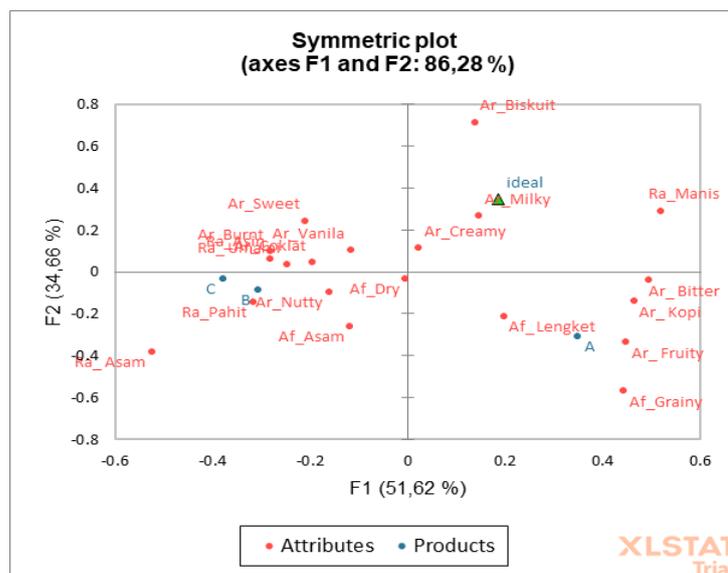
6. Jumlah Produk B diprediksi salah sebagai ‘Produk C’ sama dengan 1.
7. Jumlah Produk C diprediksi salah sebagai ‘Produk B’ sama dengan 1.

Selanjutnya data tersebut digunakan untuk mengevaluasi metode menggunakan perhitungan nilai akurasi, *precision*, *recall*, dan *F1-score*. Nilai *precision*, *recall*, dan *f1-score* Produk A : 0.92, 0.96, dan 0.94. Nilai *precision*, *recall*, dan *f1-score* Produk B : 0.91, 0.87, dan 0.89. Nilai *precision*, *recall*, dan *f1-score* Produk C : 0.95, 0.95, dan 0.95.

Model mempunyai nilai rata-rata akurasi 0,926 atau sebesar 93%. Pengujian terhadap dataset uji sebanyak , 98 data diprediksi sebagai ‘Produk A’, 16 data diprediksi sebagai ‘Produk B’, namun tidak ada yang diprediksi sebagai ‘Produk C’. Hal itu dapat diasumsikan bahwa sebagian besar data yang merepresentasikan atribut ideal diprediksi sebagai Produk A.

3.3 Analisis Menggunakan XLSTAT

Tahap ini peneliti menganalisis diagram yang merepresentasikan hasil *Correspondence Analysis* (CA) dan *Mean Impact Analysis*. *Correspondence Analysis* adalah teknik statistik eksploratif yang digunakan untuk menganalisis hubungan antara dua variabel kategorikal, dalam hal ini antara atribut sensorik dan produk yang diuji. *Eigenvalues* dalam *Correspondence Analysis* (CA) menunjukkan seberapa besar setiap dimensi dalam analisis dapat menjelaskan variasi atau struktur hubungan dalam data (Utami et al., 2023). Nilai eigen yang lebih besar berarti dimensi tersebut lebih berkontribusi dalam menjelaskan hubungan antara produk dan atribut sensorik. Diagram biplot merupakan perbandingan antara *score plot* (mengenai sampel) dan *loading plot* (mengenai atribut sensori) (Dwijatmoko, 2023). Gambar 6 adalah grafik biplot yang dihasilkan melalui analisis data menggunakan XLSTAT.

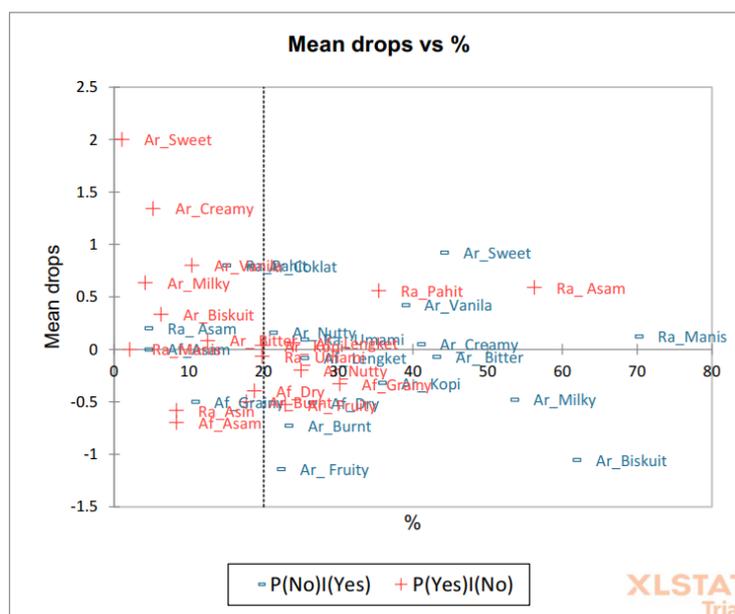


Gambar 6. Grafik Biplot XLSTAT

Berdasarkan Gambar 6, Nilai F1 (51.62%) menunjukkan dimensi ini menjelaskan lebih dari setengah variasi dalam hubungan antara atribut sensorik dan produk. Ini berarti bahwa dimensi pertama adalah yang paling penting dalam memahami perbedaan antar produk berdasarkan atribut sensorik. Nilai F2 (34.66%) dimensi kedua masih cukup penting dan menambah informasi dalam visualisasi hubungan antara produk dan atribut. Dalam hal ini untuk mengidentifikasi Produk yang paling mendekati ideal adalah dengan lebih memperhatikan posisi kedua titik tersebut dalam kuadran F1.

Melalui grafik biplot yang dihasilkan, produk ideal lebih mirip atau dekat dengan Produk A karena sama-sama terletak di kuadran F1 kanan. Produk ideal memiliki karakteristik Ar_Creamy (aroma creamy) , Ar_Biskuit (aroma biskuit), Ar_Milky (aroma susu), dan Ra_Manis (rasa manis). Sedangkan Produk B dan C memiliki kemiripan dimana keduanya terletak pada kuadran yang sama yaitu F1 kiri. Atribut dominan pada Produk B adalah aroma manis, aroma coklat, dan rasa manis. Sedangkan atribut dominan pada Produk C adalah aroma coklat, aroma gosong, aroma kacang-kacangan, dan rasa pahit.

Mean Impact Analysis adalah metode untuk memahami bagaimana keberadaan atau ketiadaan suatu atribut sensorik mempengaruhi tingkat kesukaan (likings) terhadap suatu produk. Dalam analisis CATA, diagram ini membantu mengidentifikasi atribut yang berkontribusi positif, negatif, atau tidak berpengaruh terhadap preferensi konsumen. Gambar 7 adalah diagram yang menyatakan kondisi atribut yang termasuk dalam kategori *Mean Impact Analysis*.



Gambar 7. Mean Impact Analysis

3.3.1 Identifikasi Atribut "*Must Have*" (Harus Ada)

Atribut yang berkontribusi positif secara signifikan terhadap kesukaan ditandai dengan mean liking yang lebih tinggi ketika atribut tersebut ada. Jika suatu atribut berada di kanan atas diagram, itu menunjukkan bahwa atribut ini meningkatkan preferensi produk. Contoh : Ar_Sweet termasuk dalam kategori ini, menunjukkan bahwa kehadiran rasa manis meningkatkan kepuasan panelis. Sebagai saran, atribut ini harus diprioritaskan dalam pengembangan produk.

3.3.2 Identifikasi Atribut "*Must Not Have*" (Sebisa Mungkin Dihindari)

Atribut yang berkontribusi negatif terhadap kesukaan ditandai dengan mean liking yang lebih rendah ketika atribut tersebut ada. Jika suatu atribut berada di kiri bawah diagram, maka atribut ini cenderung menurunkan kesukaan produk. Contoh : Ra_Asin dan Af_Asam kemungkinan masuk ke kategori ini, karena penambahan atribut ini bisa mengurangi preferensi panelis. Sebagai saran, jika atribut ini ada dalam produk, perlu dikurangi atau dihilangkan.

3.3.3 Identifikasi Atribut "*Nice to Have*" (Menambah Nilai, tetapi Tidak Wajib)

Atribut yang berkontribusi positif, tetapi tidak signifikan, biasanya terletak di kanan tengah diagram. Kehadiran atribut ini meningkatkan preferensi, tetapi tidak terlalu berpengaruh jika atribut ini tidak ada. Contoh : Ra_Asam tampaknya masuk dalam kategori ini. Sebagai saran, atribut ini bisa dipertahankan atau ditingkatkan, tetapi bukan faktor utama yang menentukan kesukaan.

3.3.4 Identifikasi Atribut yang "Tidak Mempengaruhi" Kesukaan

Atribut yang berada di tengah diagram memiliki sedikit atau tidak ada pengaruh terhadap kesukaan. Atribut ini tidak meningkatkan atau menurunkan nilai liking secara signifikan. Contoh : Ar_Creamy dan Ar_Vanila mungkin berada di zona ini. Atribut ini tidak menjadi prioritas dalam reformulasi produk.

3.3.5 Analisis Mean Drop (Dampak Negatif Terhadap Kesukaan)

Mean drop menunjukkan seberapa besar penurunan skor liking ketika suatu atribut hadir dalam produk. Semakin besar *mean drop*, semakin buruk pengaruh atribut terhadap preferensi konsumen. Contoh : Af_Grainy mungkin memiliki *mean drop* tinggi, artinya tekstur grainy (berbutir) tidak disukai oleh panelis. Jika atribut dengan *mean drop* tinggi ada dalam produk, sebaiknya dikurangi atau dihilangkan.

4. PENUTUP

Analisis klasifikasi menggunakan algoritma Naïve Bayes terhadap data CATA hasil uji sensori produk coklat menunjukkan nilai akurasi yang cukup tinggi. Rata-rata nilai akurasi dari ketiga produk coklat mencapai 93%. Sedangkan nilai *precision*, *recall*, dan *f1-score* masing-masing produk adalah Produk A : 0.92, 0.96, dan 0.94 ; Produk B : 0.91, 0.87, dan 0.89 ; dan Produk C : 0.95, 0.95, dan 0.95. Hal tersebut menunjukkan bahwa model atau analisis yang dilakukan memiliki tingkat keberhasilan tinggi dalam mengklasifikasikan atau memprediksi data dengan benar. Prediksi terhadap dataset uji sebanyak 114 data menunjukkan 98 data diprediksi sebagai ‘Produk A’, 16 data diprediksi sebagai ‘Produk B’, namun tidak ada yang diprediksi sebagai ‘Produk C’. Hal itu dapat diasumsikan bahwa sebagian besar data yang merepresentasikan atribut ideal diprediksi sebagai Produk A. Analisis berikutnya menggunakan *tools* XLSTAT menunjukkan bahwa produk ideal lebih kuat keterkaitannya dengan Produk A yang dapat dibuktikan dengan melihat grafik biplot dimana keduanya terletak dalam kuadran yang sama yaitu F1 kanan. Hasil analisis keduanya menunjukkan hasil yang selaras dimana atribut produk ideal mempunyai karakteristik atau kemiripan lebih dominan terhadap Produk A. Penelitian selanjutnya dapat menambahkan informasi lain terkait panelis seperti jenis kelamin dan usia agar menambah komponen deskriptif yang mempengaruhi keterkaitan terhadap pemilihan produk ideal serta penambahan kualifikasi pemilihan panelis yang tidak hanya dari unsur satu organisasi saja tapi juga menyasar masyarakat lebih luas.

DAFTAR PUSTAKA

- Dwijatmoko, M. I. 2023. Analisa Atribut Sensori Cokelat Susu Kacang Mete Komersial Dengan Metode Free Choice Profiling Dan Principle Component Analysis. 8(3).
- Hunaefi, D., & Farhan, Z. M. 2021. Karakterisasi Sensori Cheese Tea dengan Metode Check All That Apply (CATA), Emotional Sensory Mapping (ESM), dan Ideal Profile Method (IPM). *Jurnal Mutu Pangan : Indonesian Journal of Food Quality*, 8(1), 1–9. <https://doi.org/10.29244/jmpi.2021.8.1.1>
- Jaeger, S. R. 2018. An assessment of the CATA-variant of the EsSense Profile®. *Food Quality and Preference.*, 68(360-370).
- Jaeger, S. R. 2019. The item-by-use (IBU) method for measuring perceived situational appropriateness: A methodological characterization using CATA questions. *Food Quality and Preference*, 78, 103724. <https://doi.org/10.1016/j.foodqual.2019.103724>
- Jaeger, S. R. 2020. apply (CATA) questions: Sensory term citation frequency reflects rated term intensity and applicability. *Food Quality and Preference.*, 86, 103986.

- Oktafa, H., Permadi, M. R., & Agustianto, K. 2017. Studi Komparasi Data Uji Sensoris Makanan dengan Preference Test (Hedonik dan Mutu Hedonik), antara Algoritma Naïve Bayes Classifier dan Radial Basis Function Network.
- Ridho, S. 2024. Analisis Preferensi Konsumen dalam Memilih Produk Hortikultura Menggunakan Metode Algoritma C45 dan Naive Bayes. *Emitor: Jurnal Teknik Elektro*, 66–77. <https://doi.org/10.23917/emitor.v24i1.2401>
- Romli, I., Pardamean, T., Butsianto, S., Wiyatno, T. N., & Mohamad, E. B. 2021. Naive Bayes Algorithm Implementation Based on Particle Swarm Optimization in Analyzing the Defect Product. *Journal of Physics: Conference Series*, 1845(1), 012020. <https://doi.org/10.1088/1742-6596/1845/1/012020>
- Utami, F., Adawiyah, D. R., & Indrasti, D. 2023. Sensory Profiling Evaluation and Panel Performance Test of Chocolate Ice Cream Premix Products. *agriTECH*, 43(4), 344. <https://doi.org/10.22146/agritech.70125>