



PAPER – OPEN ACCESS

Analisis Perbandingan Antara Algoritma Fuzzy Association Rule Mining dan Random Forest untuk Evaluasi Kemasan Kopi Gayo

Author : Anneke Hazima Putri Amir, et al
DOI : 10.32734/ee.v9i2.2779
Electronic ISSN : 2654-704X
Print ISSN : 2654-7031

Volume 9 Issue 2 – 2026 TALENTA Conference Series: Energy & Engineering (EE)



This work is licensed under a [Creative Commons Attribution-NoDerivatives 4.0 International License](https://creativecommons.org/licenses/by-nd/4.0/).

Published under licence by TALENTA Publisher, Universitas Sumatera Utara



Analisis Perbandingan Antara Algoritma *Fuzzy Association Rule Mining* dan *Random Forest* untuk Evaluasi Kemasan Kopi Gayo

Anneke Hazima Putri Amir^a, Novi Purnama Sari^{a*}

^aJakarta State of Polytechnic, Jl. Prov. DR. G.A. Siwabessy, Depok 16425, Indonesia
anneke.hazima.putri.amir.tgp22@mhs.wpnj.ac.id, novi.purnamasari@grafika.pnj.ac.id

Abstrak

Evaluasi desain kemasan kopi Gayo pada tahap awal masih mengandung tingkat subjektivitas yang tinggi dalam penentuan elemen visual dan strukturalnya. Subjektivitas ini berpotensi memicu bias yang signifikan saat desainer menerjemahkan persepsi emosional konsumen ke dalam wujud atribut fisik kemasan. Penelitian ini bertujuan untuk membandingkan dan mengintegrasikan dua pendekatan algoritma komputasi guna mengevaluasi elemen morfologi kemasan yang paling optimal secara objektif. Metodologi yang digunakan melibatkan proses *Kansei Engineering* yang dianalisis lebih lanjut menggunakan algoritma *Random Forest* (RF) untuk prediksi kuantitatif dan *Fuzzy Association Rule Mining* (FARM) untuk ekstraksi pola kualitatif. Hasil pemodelan menunjukkan bahwa algoritma RF mengidentifikasi nilai metrik evaluasi RMSE sebesar 0,2814, MAE sebesar 0,2303, dan skor R^2 sebesar -0,5658. Oleh karena itu, penelitian selanjutnya disarankan menggunakan dataset yang lebih luas dan pengembangan algoritma machine learning agar hasil evaluasi desain kemasan menjadi lebih akurat dan objektif.

Kata Kunci: Kemasan; Kopi Gayo; *Kansei Engineering*; *Fuzzy Association Rule Mining*; *Random Forest*

Abstract

Evaluation of Gayo coffee packaging design in the early stages still involves a high degree of subjectivity in determining its visual and structural elements. This subjectivity has the potential to trigger significant bias when designers translate consumers' emotional perceptions into the physical attributes of the packaging. This study aims to compare and integrate two computational algorithm approaches to objectively evaluate the most optimal packaging morphological elements. The methodology employed involves the *Kansei Engineering* process, which is further analyzed using the *Random Forest* (RF) algorithm for quantitative prediction and *Fuzzy Association Rule Mining* (FARM) for qualitative pattern extraction. The modeling results show that the RF algorithm identified evaluation metrics of an RMSE of 0.2814, an MAE of 0.2303, and an R^2 score of -0.5658. Therefore, further research is recommended using a broader dataset and the development of machine learning algorithms to make the evaluation results of packaging design more accurate and objective.

Keywords: *Fuzzy Association Rule Mining*; Gayo Coffee; *Kansei Engineering*; Packaging; *Random Forest*

1. Pendahuluan

Evaluasi menjadi tahap penting dalam proses desain kemasan karena berperan dalam meminimalkan ketidakpastian dan ambiguitas persepsi konsumen melalui pengukuran kesesuaian desain terhadap preferensi emosional pengguna [1]. Proses ini melibatkan analisis respons subjektif konsumen terhadap elemen desain guna memastikan kualitas dan efektivitas produk yang optimal [2], sekaligus menekan tingkat subjektivitas melalui pendekatan yang lebih terstruktur dan berbasis data [3],[4]. Secara umum, evaluasi kemasan dapat dilakukan melalui metode konvensional seperti kuesioner maupun pendekatan berbasis algoritma *machine learning*. Metode konvensional memungkinkan pengumpulan opini langsung terkait desain, fungsi dan daya tarik kemasan, namun cenderung dipengaruhi oleh bias dan subjektivitas sehingga akurasi terbatas [5]. Sebaliknya, pendekatan *machine learning* menjadi alternatif yang lebih objektif dan efisien dengan memanfaatkan pengolahan data dalam skala besar serta analisis pola perilaku konsumen tanpa intervensi langsung, sehingga mampu mengurangi bias manusia [6],[7]. Oleh karena itu,

penggunaan *machine learning* dalam evaluasi kemasan mampu meningkatkan akurasi dan relevansi hasil yang lebih tinggi dibandingkan metode konvensional.

Artificial Intelligence (AI) dan statistik multivariat memiliki peran signifikan dalam evaluasi desain produk karena mampu meningkatkan kualitas pengambilan keputusan. Berdasarkan penelitian [8], beberapa metode *machine learning* yang digunakan meliputi *Artificial Neural Network* (ANN), *Support Vector Regression* (SVR), *Gaussian Process* (GP), *Genetic Algorithm* (GA) dan pendekatan *Active Learning* (AL) dan *Bayesian Optimization* (BO). Penelitian tersebut menjelaskan bahwa ANN banyak digunakan untuk proses prediksi karena mampu memodelkan hubungan *nonlinear* yang kompleks. GP diterapkan karena memiliki kemampuan interpretasi dan estimasi ketidakpastian yang lebih baik dibandingkan beberapa algoritma lainnya. Namun, penggunaan metode-metode tersebut masih memiliki beberapa kekurangan, seperti sensitivitas terhadap kualitas data, kecenderungan *overfitting*, kompleksitas komputasi yang tinggi dan rendahnya interpretabilitas model yang bersifat *black box*.

Metode evaluasi menggunakan *machine learning* telah banyak digunakan untuk meningkatkan objektivitas dalam pengambilan keputusan desain produk. Penelitian Shuyao [5], metode *Rough Set Theory* (RST) dan *Fuzzy Association Rule Mining* (FARM) dikombinasikan untuk mengevaluasi produk *exercise bike* dengan optimalisasi menggunakan *Kansei Engineering* (KE). Hasil penelitian tersebut menunjukkan bahwa pendekatan ini dapat membantu produsen dalam mengidentifikasi kebutuhan emosional pengguna secara lebih akurat dan merancang produk yang selaras dengan aspek psikologis konsumen [5]. Penelitian Dogan, et.al [9], mengintegrasikan *Association Rule Mining* (ARM) dengan optimasi *Fuzzy Logic* (FARM) untuk mengidentifikasi produk *e-commerce* berdasarkan jumlah penjualan. Algoritma FARM dimanfaatkan untuk merekomendasikan produk serupa sesuai kebutuhan pelanggan melalui aturan asosiasi *fuzzy*. Hasilnya menunjukkan bahwa FARM mampu menghasilkan informasi penjualan yang lebih relevan dan menemukan aturan baru yang tidak diperoleh dari pendekatan ARM konvensional [9]. FARM menjadi metode yang mampu mengeksplorasi pola persepsi konsumen berbasis logika *fuzzy* [10], sehingga dapat menangkap ketidakpastian dan ambiguitas dalam penelitian.


Penelitian Sakornsathien, et.al [11], membandingkan tiga metode yaitu *Random Forest* (RF), *Decision Tree* dan *Deep Learning* dalam menentukan *Product Co-design System*. Hasilnya menunjukkan bahwa RF memiliki nilai *recall* tertinggi dengan akurasi mencapai 100% dibandingkan metode lainnya. RF mampu mengidentifikasi faktor visual utama yang memengaruhi preferensi konsumen dan menghasilkan prediksi yang valid [12], sekaligus mendukung pengambilan keputusan desain berdasarkan variabel dengan tingkat kepentingan tinggi [13]. Evaluasi tersebut membuktikan tingkat akurasi dan validitas ilmiah yang tinggi dan telah banyak diterapkan dalam bidang desain produk [14]. RF memiliki keunggulan dalam kemampuan prediksi dan saat menangani data berdimensi tinggi, sekaligus mampu memberikan informasi terkait tingkat pengaruh setiap variabel terhadap preferensi konsumen [15]. Namun, penggunaan metode FARM dan RF dalam evaluasi kemasan masih belum dilakukan sehingga penelitian ini menjadi kebaruan dalam evaluasi kemasan.

Kemasan memiliki peran strategis dalam industri makanan dan minuman karena menjadi elemen pertama yang diamati konsumen dan memengaruhi keputusan pembelian [16],[17]. Peningkatan kepuasan konsumen dapat diwujudkan melalui optimalisasi aspek kemasan pada produk kopi Gayo yang selaras dengan ekspektasi pasar. Akan tetapi, kopi Gayo belum memiliki kemasan yang ditujukan bagi *end user* [18]. Kondisi tersebut mengakibatkan daya saing di pasar global belum optimal dan cenderung tertinggal dibandingkan produk dari negara nonprodusen [18]. Meskipun demikian, kopi Gayo telah menembus pasar ekspor utama dalam perdagangan internasional, seperti Amerika Serikat, Jepang, dan negara-negara Eropa dengan nilai transaksi mencapai USD 215,96 juta pada tahun 2023 atau setara dengan 23,24% dari total ekspor kopi Indonesia [19]. Kualitas produk dipengaruhi oleh kemasan yang berperan penting dalam melindungi dan menjaga kondisi produk selama proses penyimpanan [20].

Tujuan penelitian ini untuk mengevaluasi elemen desain kemasan berdasarkan konsep kopi Gayo dengan pendekatan *Fuzzy Association Rule Mining* (FARM) dan *Random Forest* (RF). Metode FARM dan RF telah banyak diterapkan secara terpisah di berbagai bidang, namun penelitian yang secara khusus membandingkan keduanya dalam konteks evaluasi desain kemasan produk khususnya kopi Gayo masih sangat terbatas. FARM memiliki keunggulan dalam mengidentifikasi pola asosiasi berdasarkan persepsi subjektif konsumen melalui logika *fuzzy* [21], sedangkan RF menunjukkan kemampuan klasifikasi yang tinggi dengan memanfaatkan data historis dan variabel terukur [22].

2. Metode Penelitian

Penelitian ini dirancang secara sistematis dengan tujuan utama untuk mengevaluasi desain kemasan pada kopi Gayo menggunakan dua metode *machine learning*, yaitu *Fuzzy Association Rule Mining* (FARM) dan *Random Forest* (RF). Penelitian ini berfokus pada penentuan metode evaluasi yang paling efektif berdasarkan hasil analisis data yang diperoleh dari proses *Kansei Engineering*. Tahapan prosedur meliputi identifikasi masalah, penerapan *Kansei Engineering* (KE), pelaksanaan evaluasi desain secara terpisah menggunakan metode FARM dan RF, serta analisis kinerja kedua metode untuk menentukan pendekatan evaluasi yang paling optimal. Berikut diagram alur penelitian ditunjukkan pada Gambar 1 yang menggambarkan proses evaluasi berbasis *machine learning*.



Gambar 1. Diagram Alur Penelitian

2.1. Identifikasi Masalah

Identifikasi masalah dilakukan untuk merumuskan kebutuhan evaluasi terhadap desain kemasan kopi Gayo yang memiliki karakter emosional dan bersifat subjektif. Permasalahan utama terletak pada pemilihan metode evaluasi yang tidak hanya mampu mengukur preferensi konsumen terhadap elemen desain kemasan, tetapi juga dapat dibandingkan secara kuantitatif dari aspek efisiensi dan akurasi prediksi. Oleh karena itu, pendekatan algoritma berbasis *machine learning* dipilih sebagai solusi untuk memenuhi kebutuhan evaluasi secara objektif dan terukur.

2.2. Kansei Engineering Process

Proses *Kansei Engineering* digunakan sebagai tahap awal untuk menghasilkan data input berupa konsep desain dan elemen visual yang berasal dari penelitian sebelumnya, sehingga membentuk data terstruktur yang dapat diolah secara algoritmik. Proses ini menghasilkan dua jenis data utama, yaitu data *semantic differential* dan data morfologi sampel kemasan yang berfungsi sebagai representasi afektif serta representasi visual struktural dari desain kemasan kopi Gayo.

- **Data *Semantic Differential***

Data *semantic differential* menggambarkan dimensi emosional dan persepsi afektif konsumen terhadap konsep desain kemasan yang telah diidentifikasi pada penelitian terdahulu. Setiap konsep desain diterjemahkan ke dalam pasangan kata Kansei yang mencerminkan karakter emosional produk [23]. Selanjutnya, setiap pasangan kata Kansei diberikan nilai numerik untuk menunjukkan tingkat kecenderungan persepsi terhadap suatu konsep desain, sehingga membentuk matriks data kuantitatif [24]. Penilaian kata Kansei menggunakan skala lima poin (1,2,3,4,5) yang dinilai mampu memberikan hasil yang lebih rinci [25].

- **Morfologi Sampel Kemasan**

Konsep desain yang dihasilkan melalui proses KE kemudian dikembangkan ke dalam bentuk mockup kemasan tiga dimensi (3D) untuk merepresentasikan visualisasi nyata dari desain yang diusulkan [26]. Tahap berikutnya dilakukan analisis morfologi, yaitu proses sistematis untuk menguraikan dan mengelompokkan setiap atribut visual pada desain kemasan ke dalam elemen-elemen terstruktur. Analisis ini bertujuan untuk mengidentifikasi elemen visual yang berpengaruh terhadap persepsi konsumen [27]. Setiap elemen desain tidak hanya diamati secara visual, tetapi juga diklasifikasikan ke dalam kategori yang mencerminkan variasi jenis dan tingkat karakteristik desain. Proses tersebut bertujuan untuk mengubah informasi visual menjadi variabel terstruktur yang dapat dianalisis menggunakan pendekatan algoritmik.

2.3. Evaluasi Menggunakan Machine Learning

Tahapan analisis algoritma *machine learning* dilakukan untuk mengevaluasi hubungan antara karakteristik desain kemasan dan persepsi emosional konsumen berdasarkan data input yang telah dibentuk pada penelitian sebelumnya. Data input terdiri atas dua komponen utama, yaitu data morfologi kemasan sebagai variabel independen dan data *semantic differential* sebagai variabel dependen. Kedua data tersebut digunakan sebagai dasar dalam proses pemodelan dan evaluasi menggunakan metode *Fuzzy Association Rule Mining* (FARM) dan *Random Forest* (RF) secara terpisah.

- ***Fuzzy Association Rule Mining***

Pada metode FARM, data input berupa morfologi kemasan berperan sebagai variabel *antecedent*, sedangkan data *semantic differential* sebagai variabel *consequent* yang telah melalui transformasi numerik. Seluruh data kemudian diproses melalui tahap fuzzifikasi untuk mengubah nilai crisp menjadi derajat keanggotaan *fuzzy* yang merepresentasikan tingkat persepsi dan ketidakpastian konsumen [21].

$$\mu_A(x) = \text{fungsi keanggotaan fuzzy dari item } A \quad (1)$$

Tahap fuzzifikasi bertujuan memetakan atribut desain dan skor *semantic differential* ke dalam himpunan linguistik melalui fungsi keanggotaan yang telah ditentukan, sehingga menghasilkan representasi data yang lebih fleksibel dibandingkan pendekatan biner. Selanjutnya, pembentukan aturan asosiasi dilakukan dengan menghitung nilai *fuzzy support* sesuai rumus (2) untuk mengukur frekuensi kemunculan kombinasi atribut desain dan persepsi dalam dataset.

$$\text{support}(A \Rightarrow B) = \frac{1}{N} \sum_{i=1}^N \min(\mu_A(t_i), \mu_B(t_i)) \quad (2)$$

Tahap berikutnya adalah perhitungan *fuzzy confidence* berdasarkan rumus (3) untuk menilai tingkat keandalan hubungan antara *antecedent* dan *consequent*. Nilai ini menunjukkan probabilitas munculnya persepsi emosional tertentu akibat kombinasi elemen desain tertentu. Selain itu, dilakukan perhitungan *fuzzy lift* sesuai rumus (4) untuk mengevaluasi kekuatan asosiasi secara objektif, apakah hubungan antarvariabel bersifat independen, saling memperkuat, atau lemah. Hanya aturan dengan nilai *fuzzy support*, *confidence*, dan *lift* yang memenuhi ambang batas yang dipertahankan sebagai pengetahuan yang valid [21].

$$\text{confidence}(A \Rightarrow B) = \frac{\sum_{i=1}^N \min(\mu_A(t_i), \mu_B(t_i))}{\sum_{i=1}^N \mu_A(t_i)} \quad (3)$$

$$\text{lift}(A \Rightarrow B) = \frac{\text{confidence}(A \Rightarrow B)}{\text{support}(B)} \quad (4)$$

- *Random Forest*

Pada metode RF, data *input* terdiri atas data morfologi kemasan dan *semantic differential* yang telah melalui tahap pra-proses dan transformasi numerik. Dataset ini digunakan untuk membangun model prediksi guna mengevaluasi hubungan antara karakteristik desain dan persepsi emosional konsumen [28].

RF dalam penelitian ini menerapkan dua pendekatan, yaitu klasifikasi dan regresi. Pada pendekatan klasifikasi, model menghasilkan prediksi kelas berdasarkan mekanisme *majority voting* dari seluruh pohon keputusan sebagaimana dirumuskan pada persamaan (5). Data *input* digunakan untuk memetakan kombinasi atribut desain ke dalam kategori persepsi tertentu.

$$\hat{y} = \text{mode}(h_1(x), h_2(x), \dots, h_T(x)) \quad (5)$$

Sementara itu, pada pendekatan regresi, model menghasilkan nilai prediksi kontinu berdasarkan rata-rata *output* seluruh pohon keputusan sesuai persamaan (6). Pendekatan ini memungkinkan estimasi tingkat intensitas persepsi konsumen terhadap suatu desain kemasan secara kuantitatif.

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x) \quad (6)$$

2.4. Analisis Hasil Algoritma Machine Learning

Analisis hasil algoritma *machine learning* dilakukan untuk mengevaluasi performa metode FARM dan RF dalam mengidentifikasi hubungan antara elemen morfologi kemasan dan persepsi emosional konsumen. Tahap analisis diawali dengan pengamatan distribusi data target menggunakan histogram, *Kernel Density Estimation* (KDE) dan *boxplot* untuk mengetahui pada nilai SD Score [29]. Selanjutnya, analisis korelasi dilakukan menggunakan *heatmap* berbasis *Pearson Correlation* setelah proses *One-Hot Encoding* untuk mengidentifikasi hubungan antar fitur morfologi dan potensi multikolinearitas pada dataset. Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 agar model memperoleh data pelatihan yang cukup besar

sekaligus tetap memiliki data uji untuk mengevaluasi kemampuan prediksi secara objektif [30]. Evaluasi model dilakukan menggunakan parameter RMSE, MAE dan R^2 , sedangkan analisis *feature importance* digunakan untuk mengidentifikasi elemen desain kemasan yang paling berpengaruh terhadap preferensi konsumen.

3. Hasil dan Pembahasan

3.1. Identifikasi Masalah

Identifikasi masalah terdapat pada hasil elemen desain kemasan kopi Gayo masih terdapat subjektivitas dan ambiguitas, karena penilaian dari konsumen masih mengandung bias individu. Kondisi ini menyebabkan hasil evaluasi desain kemasan belum mampu memberikan ukuran yang konsisten dan terukur dalam menentukan preferensi konsumen. Evaluasi kemasan perlu dilakukan untuk mengurangi ketidakpastian tersebut, khususnya pada hasil elemen desain yang diperoleh melalui pendekatan *Kansei Engineering* yang bersifat subjektif [5]. Selain itu, kebutuhan akan metode evaluasi yang mampu mengkuantifikasi persepsi emosional menjadi penting agar hasil analisis dapat dibandingkan secara objektif. Oleh karena itu, penggunaan metode machine learning seperti *Fuzzy Association Rule Mining* (FARM) dan *Random Forest* (RF) dipilih karena FARM mampu menangkap pola asosiasi berbasis persepsi *fuzzy*, sedangkan RF unggul dalam akurasi prediksi dan pengolahan data multidimensi.

3.2. Proses Kansei Engineering

Pada penelitian Maharani [18], konsep kemasan terpilih kopi Gayo adalah *minimalist – modern* serta aspek *sustainability* melalui proses pendekatan *Kansei Engineering* (KE). KE menjadi salah satu pendekatan berbasis data yang digunakan untuk mengoptimalkan proses perancangan desain produk [31],[32]. Proses *Kansei Engineering* digunakan untuk menghasilkan data terstruktur berupa persepsi emosional dan elemen visual desain kemasan berdasarkan penelitian sebelumnya. Data yang dihasilkan meliputi *semantic differential* yang merepresentasikan respons afektif konsumen dalam bentuk skala numerik serta data morfologi yang menguraikan atribut desain seperti material, bentuk, warna, dan teknik cetak. Selanjutnya, konsep desain divisualisasikan dalam bentuk mockup tiga dimensi (3D) untuk mendukung evaluasi secara lebih representatif. Hasil dari proses ini menjadi dasar data *input* untuk analisis lanjutan menggunakan metode *machine learning*. Berikut hasil dari *mock up* 3D dari kemasan Kopi Gayo.



Gambar 2. Mockup Desain 3D Kopi Gayo

- *Semantic Differential*

Hasil pengolahan data menunjukkan bahwa sebagian besar atribut Kansei berada pada kecenderungan nilai positif, yang mengindikasikan bahwa desain kemasan yang dikembangkan telah mampu memenuhi preferensi emosional konsumen [33], khususnya pada aspek estetika, modernitas, dan daya tarik visual. Nilai penilaian tersebut kemudian diolah menjadi *SD Score* (M–M) yang ditunjukkan pada Tabel 2, yaitu nilai rata-rata (*mean*) dari seluruh responden, sehingga merepresentasikan kecenderungan umum persepsi terhadap setiap elemen desain. Temuan ini menunjukkan adanya perbedaan tingkat dominasi antar atribut Kansei, yang mengindikasikan bahwa beberapa elemen desain memiliki pengaruh yang lebih signifikan dalam membentuk persepsi konsumen. Oleh karena itu, hasil *semantic differential* dalam penelitian ini berperan sebagai dasar dalam menentukan prioritas elemen desain kemasan yang selanjutnya digunakan sebagai *input* pada tahap evaluasi menggunakan metode *machine learning* [34].

- Morfologi Sampel Kemasan

Morfologi sampel kemasan dianalisis dengan menguraikan setiap atribut visual menjadi elemen terstruktur, seperti material, bentuk tutup, bentuk badan, fitur, gaya desain, warna, impresi, dan teknik cetak. Setiap sampel kemasan memiliki kombinasi elemen yang berbeda sehingga menghasilkan variasi karakteristik desain yang dapat diklasifikasikan secara sistematis

Tabel 1. Morfologi Sampel Kemasan

Type (X)	X1	X2	X3	X4	X5	X6	X7	X8
	Material	Cup	Shape	Features	Design Style	Color	Impression	Print Technical
1	Multilayer (Plastic Only)	Sealed	Standing Pouch	Tear Notch	Minimalist	Bright	Culture	Direct
						Color		
2	Flexible Foil	Sealed + Tuck End	Flat Bottom Bag	Tear Notch + Valve	Simple	Color full	Culture + Tasteful	Indirect
								
	Paper Foil	Tuck End	Flat Bottom + Folding Box Horizontal	Valve				
3					Modern	Vibrant Color	Tasteful	
	Kraft Foil	Slip Lid + Tuck End	Flat Bottom + Folding Box Vertical	Valve + Tin Tie				
4					Luxury	Dark Color	Unique	
	Aluminum Foil	Slip Lid	Folding Box Vertical	Valve + Ziplock				
5					Illustrative	Neutral	Luxury	
	Aluminum Foil + Ivory	Screw Cap	Tube + Folding Box Horizontal	Ziplock				
6					Traditional		Non-Impression	
	Ivory	Snap-On Cap	Tube	Single Serve Filter Coffee				
7								
	Ivory + Can	Hinged Lid		Spoon				
8								
	Composite Can		Rounded Rectangle					
			Customized					
9				Non-Fitur				
	Can							
10								
	Glass Packaging							
11								

Tabel 2. Breakdown Morfologi Kemasan

Sample Code	Material	Lid Shape	Body Shape	Features	Design Style	Color	Impression	Print Technical	SD Score (M – M)
A	3	1	2	5	3	3	1	1	4.1
B	2	1	2	3	6	2	1	1	4
C	2	1	2	5	4	3	1	1	3.4
D	3	1	2	2	6	4	2	1	4
E	2	1	2	6	5	3	2	1	4.4
...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...
AAD	11	6	7	9	3	1	3	2	4
AAE	11	7	7	9	5	2	3	2	4

3.3. Evaluasi Menggunakan Machine Learning

- **Data Splitting**

Tahap data *splitting* dilakukan untuk membagi dataset kemasan kopi specialty Gayo menjadi data pelatihan (*training set*) dan data pengujian (*testing set*) menggunakan rasio 80:20. Sebelum pembagian data, seluruh fitur kategorikal dikonversi ke bentuk numerik menggunakan *One-Hot Encoding* melalui fungsi `pd.get_dummies()`. Variabel *x* digunakan sebagai data fitur morfologi kemasan sedangkan variabel *y* merupakan target berupa nilai SD 2 Score. Hasil pembagian menunjukkan bahwa sebanyak 45 data digunakan sebagai *training test* dan 12 data digunakan sebagai *testing set* ditunjukkan pada Gambar 3.

```

X_k = pd.get_dummies(df_kopi[k_cols])
y_k = df_kopi['SD 2 Score']
X_train_k, X_test_k, y_train_k, y_test_k = train_test_split(
    X_k, y_k, test_size=0.2, random_state=42
)
print(f'Training Set : {X_train_k.shape}')
print(f'Testing Set : {X_test_k.shape}')

Training Set : (45, 8)
Testing Set : (12, 8)

```

Gambar 3. Data Splitting

- **Baseline Model**

Pada Gambar 4, menunjukkan proses pembentukan *baseline model* menggunakan algoritma *Random Forest Regression* pada dataset kemasan kopi specialty Gayo dengan parameter $n_estimators = 100$ yang berarti model menggunakan 100 *decision tree* untuk melakukan prediksi terhadap nilai SD 2 Score. Model dilatih menggunakan *training set* dan diuji menggunakan *testing set* untuk mengevaluasi kemampuan prediksi berdasarkan data morfologi kemasan. Hasil evaluasi menunjukkan nilai RMSE sebesar 0,3131 dan MAE sebesar 0,2463 yang mengindikasikan bahwa rata-rata kesalahan prediksi model masih berada pada tingkat yang relatif kecil. Namun, nilai R^2 sebesar -0,9388 menunjukkan bahwa *model baseline* belum mampu menjelaskan hubungan antara variabel morfologi kemasan dan target prediksi secara optimal, sehingga hasil tersebut digunakan sebagai acuan awal sebelum dilakukan pengembangan dan optimasi model untuk meningkatkan performa evaluasi kemasan.

```

rf_base_k = RandomForestRegressor(n_estimators=100, random_state=42)
rf_base_k.fit(X_train_k, y_train_k)
pred_base_k = rf_base_k.predict(X_test_k)

print('=' * 50)
print(f' BASELINE MODEL: Kopi Gayo')
print('=' * 50)
print(f'RMSE : (np.sqrt(mean_squared_error(y_test_k, pred_base_k)):.4f)')
print(f'MAE : (mean_absolute_error(y_test_k, pred_base_k):.4f)')
print(f'R2 : (r2_score(y_test_k, pred_base_k):.4f)')

=====
BASELINE MODEL: Kopi Gayo
=====
RMSE : 0.3131
MAE : 0.2463
R2 : -0.9388

```

Gambar 4. Baseline Model

- *Hyperparameter Tuning*

Proses optimasi dilakukan dengan pendekatan *cross-validation* sehingga model dapat diuji pada beberapa pembagian data guna meningkatkan kestabilan dan kemampuan generalisasi prediksi. Parameter yang dioptimasi meliputi $n_estimators$ sebagai jumlah decision tree, max_depth sebagai kedalaman maksimum pohon, $min_samples_split$ sebagai jumlah minimum sampel untuk melakukan pemisahan node dan $min_samples_leaf$ sebagai jumlah minimum sampel pada setiap *leaf node*. Pada Gambar 5 menunjukkan hasil tuning kombinasi parameter terbaik diperoleh pada $n_estimators = 300$, $max_depth = 15$, $min_samples_split = 30$ dan $min_samples_leaf = 1$. Nilai best CV R^2 sebesar -0,1734 menunjukkan bahwa performa model setelah *tuning* mengalami peningkatan dibandingkan baseline model sebelumnya, meskipun kemampuan model dalam menjelaskan variabilitas data masih belum optimal. Oleh karena itu, proses *hyperparameter tuning* digunakan untuk meningkatkan stabilitas dan akurasi model RF dalam mengevaluasi hubungan antara elemen morfologi kemasan dan persepsi emosional konsumen terhadap desain.

```
param_dist = {
    'n_estimators': [100, 200, 300, 500],
    'max_depth': [None, 5, 10, 15, 20],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4]
}

rf_tuned_k = RandomizedSearchCV(
    RandomForestRegressor(random_state=42),
    param_distributions=param_dist,
    n_iter=10, cv=3, random_state=42, scoring='r2', n_jobs=-1
)
rf_tuned_k.fit(X_train_k, y_train_k)

best_rf_k = rf_tuned_k.best_estimator_
print(f'Best Params (Kopi Gayo): {rf_tuned_k.best_params_}')
print(f'Best CV  $R^2$  : {rf_tuned_k.best_score_:.4f}')
```

Gambar 5. *hyperparameter tuning*

- *Evaluasi Model Optimal*

Hasil evaluasi model optimal pada kemasan kopi *specialty* Gayo menunjukkan nilai RMSE sebesar 0,2814 dan MAE sebesar 0,2303 yang mengindikasikan bahwa tingkat kesalahan prediksi model relatif rendah dan cukup stabil dalam memprediksi nilai SD 2 *Score* ditunjukkan pada Gambar 6. Selain, nilai R^2 sebesar -0,5658 menunjukkan bahwa kemampuan model dalam menjelaskan hubungan antara elemen morfologi kemasan dan persepsi emosional konsumen masih belum optimal.

```
pred_k = best_rf_k.predict(X_test_k)
pred_train_k = best_rf_k.predict(X_train_k)

rmse_k = np.sqrt(mean_squared_error(y_test_k, pred_k))
mae_k = mean_absolute_error(y_test_k, pred_k)
r2_k = r2_score(y_test_k, pred_k)

print('=' * 50)
print(f'  MODEL OPTIMAL: Kopi Gayo')
print('=' * 50)
print(f'RMSE : {rmse_k:.4f}')
print(f'MAE : {mae_k:.4f}')
print(f' $R^2$  : {r2_k:.4f}')
```


```
=====
MODEL OPTIMAL: Kopi Gayo
=====
RMSE : 0.2814
MAE : 0.2303
R2 : -0.5658
```

Gambar 6. Evaluasi Model Optimal

3.4. Analisis Hasil Algoritma Machine Learning

- *Distribusi Target: Histogram & KDE*


Pada Gambar 7, histogram dan kurva *Kernel Density Estimation* (KDE) menunjukkan distribusi skor SD 2 pada objek kopi *specialty* Gayo yang digunakan sebagai data target dalam metode FARM dan RF. Sebagian besar data berada pada rentang 3,6 – 4,2 dengan pusat distribusi di sekitar nilai 3,9 – 4,0, sehingga menunjukkan persepsi konsumen cenderung positif terhadap desain kemasan. Distribusi data yang relatif stabil mendukung proses evaluasi dan pembentukan model machine learning secara lebih konsisten.



Gambar 7. Histogram & KDE: Skor SD 2

- *Boxplot Target*


Boxplot menunjukkan sebaran data target SD 2 pada objek kopi specialty Gayo dengan median berada di sekitar nilai 3,9. Rentang data yang relatif merata dan tidak adanya *outlier* signifikan menunjukkan bahwa data memiliki konsistensi yang baik untuk proses evaluasi menggunakan metode FARM dan RF. Kondisi tersebut mendukung pembentukan pola asosiasi *fuzzy* dan meningkatkan kestabilan prediksi model *machine learning* yang tunjukkan pada Gambar 8.



Gambar 8. Boxplot Target

- Analisis Korekasi Morfologi

Berdasarkan heatmap korelasi morfologi kopi specialty Gayo yang ditunjukkan pada Gambar 9, sebagian besar fitur menunjukkan korelasi rendah hingga sedang sehingga mengindikasikan bahwa setiap elemen desain kemasan memiliki karakteristik yang relatif independen. Beberapa fitur seperti material, *lid shape* dan *body shape* menunjukkan hubungan positif yang cukup tinggi karena memiliki keterkaitan visual dalam membentuk persepsi struktur kemasan. Sementara itu, fitur *design style* menunjukkan korelasi negatif terhadap beberapa atribut lain yang menandakan adanya perbedaan karakter visual pada konsep desain kemasan. Hasil korelasi menunjukkan bahwa data morfologi tidak mengalami multikolinearitas tinggi, sehingga dataset dinilai cukup stabil untuk digunakan pada metode FARM dalam pembentukan pola asosiasi *fuzzy* maupun RF dalam proses prediksi preferensi konsumen terhadap desain kemasan kopi specialty Gayo.




Gambar 9. Heatmap Korelasi Morfologi

- *Feature Importance*

Pada Gambar 10 menghasilkan analisis yang menunjukkan bahwa elemen *body shape* memiliki nilai kepentingan tertinggi dibandingkan variabel lainnya, sehingga menjadi faktor utama yang memengaruhi persepsi emosional konsumen terhadap desain kemasan. Variabel *impression* dan *features* juga memberikan kontribusi yang cukup besar dalam proses prediksi model,


sedangkan *print technical* dan *lid shape* memiliki pengaruh yang relatif rendah. Hasil ini menunjukkan bahwa bentuk utama kemasan dan kesan visual produk menjadi elemen dominan dalam menentukan preferensi konsumen terhadap kemasan.



Gambar 10. Feature Importance

- Diagnostik: *Actual vs Predicted*

Pada Gambar 11 menunjukkan perbandingan antara nilai aktual dan nilai prediksi model pada evaluasi desain kemasan kopi specialty Gayo. Garis merah diagonal merepresentasikan kondisi prediksi sempurna, sedangkan titik-titik data menunjukkan hasil prediksi model terhadap nilai aktual *SD 2 Score*. Sebagian besar titik berada di sekitar rentang nilai aktual 3,5 – 4,2 dan nilai prediksi 3,7 – 4,0 yang menunjukkan bahwa model mampu menghasilkan prediksi yang cukup mendekati data aktual.



Gambar 11. Actual vs Predicted

- Komparasi Akurasi Prediksi

Pada bagian ini dilakukan analisis terhadap kinerja algoritma *machine learning* berdasarkan parameter evaluasi yang meliputi RMSE, MAE dan R^2 score. Pada Tabel 3. Menunjukkan bahwa hasil evaluasi menggunakan *machine learning* kopi Gayo.

Tabel 3. Komparasi Akurasi Prediksi

Metode	RSME	MAE	R^2 Score
RF	0.2814	0.2303	-0.5658
FARM	0.2736	0.2233	-0.4805

Berdasarkan hasil evaluasi pada objek kopi Gayo, metode *Random Forest* dipilih sebagai pendekatan yang digunakan dalam penelitian ini meskipun metode FARM menunjukkan nilai *error* yang sedikit lebih rendah. *Random Forest* menghasilkan nilai RMSE sebesar 0,2814 dan MAE sebesar 0,2303 dengan nilai R^2 sebesar -0,5658, yang menunjukkan bahwa model masih memiliki keterbatasan dalam menjelaskan variabilitas data persepsi konsumen. Namun demikian, *Random Forest* memiliki keunggulan dalam kestabilan model dan kemampuannya dalam menangani hubungan nonlinier antarvariabel desain kemasan secara lebih *robust*. Selain itu, metode ini mampu mengidentifikasi tingkat kepentingan masing-masing elemen desain, sehingga memberikan informasi yang lebih komprehensif dalam mendukung pengambilan keputusan berbasis data. Dengan

mempertimbangkan aspek tersebut, *Random Forest* dinilai lebih relevan untuk digunakan sebagai metode evaluasi desain kemasan kopi Gayo dalam penelitian ini.

4. Kesimpulan

Penelitian ini membandingkan 2 metode algoritma *machine learning* diantaranya *Fuzzy Association Rule Mining* (FARM) dan *Random Forest* (RF) dengan menggunakan data sekunder pendekatan *Kansei Engineering* (KE). Hasilnya menunjukkan bahwa metode RF lebih unggul dengan nilai RMSE 0.2814, MSE 0.2303, dan R^2 -0.5658 yang lebih besar dibandingkan metode FARM. Hal ini menunjukkan performa dan prediksi hasil algoritma *machine learning* terbukti efektif dalam evaluasi kemasan kopi Gayo. Hasil algoritma *machine learning* terbukti efektif dalam evaluasi kemasan kopi specialty Gayo, sehingga penelitian selanjutnya disarankan menggunakan *dataset* yang lebih besar, variabel yang lebih beragam dan pengembangan metode algoritma untuk meningkatkan akurasi dan objektivitas hasil evaluasi.

Referensi

- [1] P. Gao, Y. Zhang, and Z. Long, "Kansei Drives Sustainable Material Innovation—An Approach to Enhance the Added Value of Biomass Materials," *Sustain.*, vol. 16, no. 13, 2024, doi: 10.3390/su16135546.
- [2] Y. Zuo and Z. Wang, "Subjective product evaluation system based on kansei engineering and analytic hierarchy process," *Symmetry (Basel)*, vol. 12, no. 8, pp. 1–25, 2020, doi: 10.3390/sym12081340.
- [3] T. Zhu, C. Wu, Z. Zhang, Y. Li, and T. Wu, "Research on Evaluation Methods of Complex Product Design Based on Hybrid Kansei Engineering Modeling," *Symmetry (Basel)*, vol. 17, no. 2, pp. 1–24, 2025, doi: 10.3390/sym17020306.
- [4] Z. Wang, W. Liu, and M. Yang, "Data-driven multi-objective affective product design integrating three-dimensional form and color," *Neural Comput. Appl.*, vol. 34, no. 18, pp. 15835–15861, 2022, doi: 10.1007/s00521-022-07232-2.
- [5] L. I. Shuyao, "Integrating rough set theory and fuzzy association rule mining for product kansei knowledge analysis," *J. Adv. Mech. Des. Syst. Manuf.*, vol. 18, no. 6, pp. 1–13, 2024, doi: 10.1299/jamdsm.2024jamdsm0081.
- [6] S. Bhaskaran and R. Marappan, "Design and analysis of an efficient machine learning based hybrid recommendation system with enhanced density-based spatial clustering for digital e-learning applications," *Complex Intell. Syst.*, vol. 9, no. 4, pp. 3517–3533, 2023, doi: 10.1007/s40747-021-00509-4.
- [7] T. Hagendorff, *Linking Human And Machine Behavior: A New Approach to Evaluate Training Data Quality for Beneficial Machine Learning*, vol. 31, no. 4. Springer Netherlands, 2021. doi: 10.1007/s11023-021-09573-8.
- [8] R. Arboretti, R. Ceccato, L. Pegoraro, and L. Salmaso, "Design of Experiments and machine learning for product innovation : A systematic literature review," no. March 2021, pp. 1131–1156, 2022, doi: 10.1002/qre.3025.
- [9] O. Dogan, F. C. Kem, and B. Oztaysi, "Fuzzy association rule mining approach to identify e-commerce product association considering sales amount," *Complex Intell. Syst.*, vol. 8, no. 2, pp. 1551–1560, 2022, doi: 10.1007/s40747-021-00607-3.
- [10] H. Zheng, J. He, G. Huang, Y. Zhang, and H. Wang, "Dynamic optimisation based fuzzy association rule mining method," *Int. J. Mach. Learn. Cybern.*, vol. 10, no. 8, pp. 2187–2198, 2019, doi: 10.1007/s13042-018-0806-9.
- [11] K. Sakornsathien, S. Sinthupinyo, and P. Anuntavoranich, "Application of Kansei engineering and data mining in developing an ingenious product co-design system," *Int. J. Mach. Learn. Comput.*, vol. 9, no. 1, pp. 67–74, 2019, doi: 10.18178/ijmlc.2019.9.1.767.
- [12] R. Joshi, R. Gupte, and P. Saravanan, "A Random Forest Approach for Predicting Online Buying Behavior of Indian Customers," *Theor. Econ. Lett.*, vol. 08, no. 03, pp. 448–475, 2018, doi: 10.4236/tel.2018.83032.
- [13] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," *Babylonian J. Mach. Learn.*, vol. 2024, pp. 69–79, 2024, doi: 10.58496/bjml/2024/007.
- [14] M. Wang, X. Cheng, and Z. He, "Research on Multiple Affective Responses Design of Product Based on Kansei Engineering and TOPSIS-AISM," *Math. Probl. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/6945986.
- [15] N. Nair, M. Patel, S. Gupta, and P. Singh, "Leveraging Neural Networks and Random Forest Algorithms for Enhanced Predictive Customer Behavior Analytics Authors :," pp. 1–23.
- [16] J. García-Madariaga, M.-F. Blasco López, I. M. Burgos, and N. R. Virto, "Do isolated packaging variables influence consumers' attention and preferences?," *Physiol. Behav.*, vol. 200, pp. 96–103, 2019, doi: https://doi.org/10.1016/j.physbeh.2018.04.030.
- [17] M. A. Yasin, A. Hakim, and M. F. Perdana, "Penerapan Kansei Engineering Dalam Desain Ulang Kemasan Kue Tambang di UMKM Sumber Jaya," *G-Tech J. Teknol. Terap.*, vol. 8, no. 3, pp. 1705–1719, 2024, doi: 10.33379/gtech.v8i3.4550.
- [18] D. Maharani, "Pengembangan Kemasan Kopi Specialty Gayo Menggunakan Kansei Engineering Berbasis Clustering dan CNN-LSTM [Skripsi]," Politeknik Negeri Jakarta, 2025.
- [19] A. Nabilah and Daspar, "Analisa Peluang dan Ancaman Perdagangan Produk Perkebunan (Kopi): Studi Kasus Pada Perdagangan Indonesia dengan Amerika Serikat," vol. 22, no. 1, 2025.
- [20] M. Divanshi, A. Das, and R. Hv, *Quality Control and Risk Assessment of Food Storage and Packaging*, 1st ed. CRC Press, 2024.
- [21] H. R. Ibraheem, M. M. Hamad, H. R. Ibraheem, and M. M. Hamad, "Integrating Fuzzy Set Theory with Association Rule Mining for Advanced E-Commerce Recommendations Integrating Fuzzy Set Theory with Association Rule Mining for Advanced E-Commerce Recommendations," vol. 6, no.

- 1, 2025.
- [22] J. L. Speiser, M. E. Miller, J. Tooze, and E. Ip, "A comparison of random forest variable selection methods for classification prediction modeling," *Expert Syst. Appl.*, vol. 134, pp. 93–101, 2019, doi: <https://doi.org/10.1016/j.eswa.2019.05.028>.
- [23] N. P. Sari, W. Prastiwinarti, A. H. P. Amir, N. P. Suharto, T. Salsabila, and A. Isna, "Analisis Preferensi Konsumen Terhadap Konsep Kemasan Parfum dengan Pendekatan Kansei Engineering," vol. 4, no. 1, pp. 501–509.
- [24] A. Isna, N. P. Sari, D. Maharani, and F. Fadhillah, "Implementasi Kansei Engineering dalam Menentukan Konsep Pengembangan Kemasan Rujak Buah Potong," *J. INTECH Tek. Ind. Univ. Serang Raya*, vol. 10, no. 1, pp. 9–18, 2024, doi: [10.30656/intech.v10i1.7832](https://doi.org/10.30656/intech.v10i1.7832).
- [25] N. P. Sari, *Perencanaan Dan Pengembangan Kemasan Kansei Engineering*. Depok: PNJ Press, 2019.
- [26] A. Hakim, B. Suhardi, P. W. Laksono, and M. Ushada, "Systematic Review of Kansei Engineering Method Developments in the Design Field," *J. Optimasi Sist. Ind.*, vol. 23, no. 1, pp. 92–108, 2024, doi: [10.25077/josi.v23.n1.p92-108.2024](https://doi.org/10.25077/josi.v23.n1.p92-108.2024).
- [27] V. Čok, V. Daria, and J. and Povh, "Methodology for mapping form design elements with user preferences using Kansei engineering and VDI," *J. Eng. Des.*, vol. 33, no. 2, pp. 144–170, Feb. 2022, doi: [10.1080/09544828.2021.2012133](https://doi.org/10.1080/09544828.2021.2012133).
- [28] H. Valecha, A. Varma, I. Khare, A. Sachdeva, and M. Goyal, "Prediction of Consumer Behaviour using Random Forest Algorithm," in *2018 5th IEEE Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, 2018, pp. 1–6. doi: [10.1109/UPCON.2018.8597070](https://doi.org/10.1109/UPCON.2018.8597070).
- [29] G. A. López-Ramírez, A. Aragón-Zavala, and C. Vargas-Rosales, "Exploratory Data Analysis for Path Loss Measurements: Unveiling Patterns and Insights Before Machine Learning," *IEEE Access*, vol. 12, pp. 62279–62295, 2024, doi: [10.1109/ACCESS.2024.3394904](https://doi.org/10.1109/ACCESS.2024.3394904).
- [30] S. Raschka, "Model Evaluation , Model Selection and Algorithm Selection in Machine Learning," 2018.
- [31] X. Li, S. Jianning, Z. Zhipeng, and R. and Bai, "Product innovation concept generation based on deep learning and Kansei engineering," *J. Eng. Des.*, vol. 32, no. 10, pp. 559–589, Oct. 2021, doi: [10.1080/09544828.2021.1928023](https://doi.org/10.1080/09544828.2021.1928023).
- [32] M.-C. Chiu and K.-Z. Lin, "Utilizing text mining and Kansei Engineering to support data-driven design automation at conceptual design stage," *Adv. Eng. Informatics*, vol. 38, pp. 826–839, 2018, doi: <https://doi.org/10.1016/j.aei.2018.11.002>.
- [33] N. P. Sari *et al.*, "Developing the Concept of Emotion for Rendang Packaging Design Using Kansei Engineering BT - Kansei Engineering and Emotion Research," T. Tsai, K. Chen, T. Yamanaka, S. Koyama, S. Schütte, and A. Mohd Lokman, Eds., Singapore: Springer Nature Singapore, 2024, pp. 15–27.
- [34] H. Wu, "Fuzzy Logic and Deep Learning for Brand Attention: A Consumer-Centric Approach to Product Packaging Design," *IEEE Access*, vol. 13, pp. 139696–139703, 2025, doi: [10.1109/ACCESS.2025.3596858](https://doi.org/10.1109/ACCESS.2025.3596858).