

Klasifikasi Sinyal EEG Subband Beta untuk Identifikasi Persepsi Rasa Manis dan Asam Menggunakan Algoritma Machine Learning

Classification of EEG Beta Subband Signals for Identifying Sweet and Sour Taste Perception Using Machine Learning Algorithms

Marianus Yakobus Lili Lejap^{*1}, Silvester Tena², Bima Gerry Pratama³

^{1,2}Teknik Elektro, Universitas Nusa Cendana, ³Teknik Elektro, Politeknik Negeri Bandung

E-mail : marianus.lejap@staf.undana.ac.id^{*1}, siltena@staf.undana.ac.id²

bima.pratama@polban.ac.id³

Received 31 October 2025; Revised 22 November 2025; Accepted 25 November 2025

Abstrak— Aktivitas gelombang otak (EEG) dapat digunakan untuk mengenali respons manusia terhadap stimulus sensorik, termasuk persepsi rasa. Penelitian ini bertujuan untuk mengklasifikasikan aktivitas otak terhadap dua jenis stimulus rasa, yaitu rasa manis (Susu) dan rasa asam (Lemon), menggunakan sinyal EEG pada subband Beta (12–25 Hz) dengan pendekatan machine learning. Penelitian ini merupakan pengembangan dari studi sebelumnya yang hanya menampilkan visualisasi topografi otak (brain heatmap), dengan menambahkan analisis klasifikasi otomatis berbasis kecerdasan buatan. Data EEG direkam dari empat kanal utama, yaitu T3, T4, CP1, dan CP2, kemudian diekstraksi menggunakan dua fitur utama: Mean Absolute Value (MAV) dan Variance (VAR). Total data yang digunakan sebanyak 10.644 potong data (3.550 Susu dan 7.094 Lemon). Tiga algoritma machine learning digunakan untuk membandingkan performa klasifikasi, yaitu Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Decision Tree (DT). Hasil pengujian menunjukkan bahwa Decision Tree menghasilkan performa terbaik dengan akurasi 84,0%, F1-score 0,727, dan ROC AUC 0,789, diikuti oleh KNN dengan akurasi 76,6%. Model SVM linear menunjukkan performa terendah akibat ketidakseimbangan data dan distribusi non-linear. Hasil ini membuktikan bahwa fitur EEG pada subband Beta dapat digunakan untuk membedakan stimulus rasa manis dan asam secara objektif. Penelitian ini memberikan kontribusi terhadap pengembangan sistem EEG-based Taste Recognition dan membuka peluang penerapan dalam bidang neurogastronomi serta Brain–Computer Interface (BCI).

Kata kunci: EEG, subband Beta, klasifikasi rasa, machine learning, Decision Tree.

Abstract - Brain wave activity (EEG) can be used to recognize human responses to sensory stimuli, including taste perception. This study aims to classify brain activity corresponding to two taste stimuli, sweet (milk) and sour (lemon), using EEG signals in the Beta subband (12–25 Hz) through a machine learning approach. This work extends a previous study that visualized EEG topography (brain heatmap) by introducing automated classification based on artificial intelligence. EEG data were recorded from four main channels (T3, T4, CP1, and CP2) and extracted using two primary features: Mean Absolute Value (MAV) and Variance (VAR). The dataset contained 10,644 chunks (3,550 sweet and 7,094 sour). Three machine learning algorithms were compared, namely Support Vector Machine (SVM), K-Nearest Neighbor (KNN), and Decision Tree (DT). Experimental results indicate that the Decision Tree achieved the best performance with an accuracy of 84.0%, F1-score 0.727, and ROC AUC 0.789, followed by KNN with an accuracy of 76.6%. The linear SVM model performed poorly due to class imbalance and non-linear data distribution. These findings demonstrate that EEG Beta subband features can objectively distinguish between sweet and sour stimuli. This study contributes to the development

of EEG-based Taste Recognition systems and provides potential applications in neurogastronomy and brain-computer interface (BCI) technologies.

Keywords: EEG, Beta subband, taste classification, machine learning, Decision Tree.

1. PENDAHULUAN

Peran sistem pengecap sangat penting dalam mendeteksi nutrisi, mendorong perilaku adaptif untuk memastikan asupan nutrisi yang seimbang dan memadai, serta menghindari potensi racun. Oleh karena itu, sistem pengecap berperan penting dalam menjaga kesehatan manusia. Sistem pengecap telah berevolusi untuk mengenali dan mencerna berbagai zat dengan rasa yang berbeda, seperti sukrosa manis, sekaligus menghindari senyawa dengan rasa yang tidak enak, seperti kina pahit[1]. Dalam menjalankan tugasnya, sistem rasa harus mengambil keputusan dengan cepat untuk menentukan apakah suatu zat aman atau berbahaya untuk dikonsumsi. Keputusan ini dipengaruhi oleh berbagai faktor, termasuk tingkat keakraban dengan zat tersebut dan kesesuaiannya dengan budaya makan. [2][3].

Ketika kita makan, rasa dan aroma makanan dideteksi oleh reseptor bau atau organ sensorik yang merespon rangsangan setelah senyawa aroma diangkat ke epitel penciuman[4]. Daya tarik rasa merupakan salah satu faktor krusial yang memengaruhi preferensi konsumen terhadap produk makanan/minuman. Hal ini dapat memengaruhi suasana hati yang dirasakan konsumen selama dan setelah makan. Lebih dari itu, faktor ini juga sangat memengaruhi kemampuan konsumen untuk mengingat makanan yang mereka konsumsi. Perubahan kinerja memori dan kondisi kognitif dapat tercermin dalam perubahan spektrum gelombang elektroensefalogram (EEG)[5][6][7].

Penelitian sebelumnya yang menggunakan EEG dan MEG menyimpulkan bahwa terkait rasa, terdapat aktivasi yang lebih besar di insula tengah (MI) dan insula belakang (PI). Penelitian ini dilakukan oleh Nakamura dkk. pada tahun 2013 dengan tujuan menentukan lokasi regio gustatori utama di insula melalui paradigma berbasis atensi dalam eksperimen fMRI. Temuan mereka menunjukkan bahwa korteks rasa primer pada manusia terletak di MI (Insula Tengah). Sementara itu, AI (Insula Anterior) terkait dengan atensi yang diberikan pada kualitas rasa [8].

EEG, juga dikenal sebagai Elektroensefalografi, adalah alat yang berfungsi merekam aktivitas listrik di otak. Alat ini dipasang di kulit kepala untuk merekam aktivitas tersebut. [9]. Elektroda dipasang di kulit kepala menggunakan sistem penempatan elektroda yang telah disetujui oleh American Electroencephalographic Society, yaitu Sistem Internasional 10-20. EEG merupakan teknologi yang paling cocok digunakan dalam penelitian tentang bagaimana otak bereaksi terhadap rasa makanan atau minuman karena memiliki resolusi temporal yang baik dan lebih terjangkau sehingga dapat digunakan secara luas[10]. Rasa mencakup lima rasa dasar: asam, manis, pahit, asin, dan umami. Rasa umami dan manis menandakan keberadaan nutrisi esensial, sehingga umumnya disukai manusia. Sementara itu, rasa asin menunjukkan kandungan natrium dalam makanan yang memicu nafsu makan dan keinginan untuk makan atau minum. Umumnya, rasa asam dan pahit dianggap tidak menyenangkan atau tidak disukai manusia. Rasa asam dan pahit berfungsi sebagai sinyal toksisitas atau peringatan tentang zat beracun dan berbahaya dalam makanan. Rasa asam dan pahit dapat menyebabkan penolakan makanan[11][12].

Dengan cara ini, sistem pengecap yang bertanggung jawab untuk merasakan rasa makanan harus dengan cepat menentukan apakah suatu zat menimbulkan risiko atau bahaya saat tertelan.[2]. Dalam penelitian ini, kami menyelidiki perbedaan aktivitas otak manusia terhadap stimulus rasa manis (Susu) dan rasa asam (Lemon) menggunakan analisis sinyal EEG (Electroencephalogram) pada pita frekuensi Beta (12–25 Hz). Tujuan utama penelitian ini adalah untuk menguji hipotesis bahwa pola respons sinyal EEG manusia berbeda secara signifikan antara kedua stimulus rasa tersebut, serta mengembangkan sistem yang mampu mengenali jenis rasa secara otomatis menggunakan pendekatan *machine learning*.

2. METODE PENELITIAN

Metodologi yang digunakan dalam penelitian ini dijelaskan di bawah ini:

A. Seleksi Partisipan

Dalam studi ini, kami menggunakan data sekunder dari penelitian sebelumnya yang merekam sampel sinyal EEG dari 32 responden dalam kondisi sehat (15 pria dan 17 wanita) dengan rerata usia ($25,5 \pm 5,5$) tahun. Berdasarkan kriteria tersebut, partisipan tidak memiliki riwayat gangguan kejiwaan dan gangguan pengecapan. Responden tidak makan/minum 1-2 jam sebelum pengumpulan data dilakukan. Dalam studi ini, proses perekaman berlangsung selama enam detik setiap kali responden meminum larutan tersebut. Terdapat dua stimulus, yaitu Manis (susu cokelat) dan Asam (jus lemon), dengan air sebagai baseline.Signal Recording

1) Alat EEG

Kami akan merekam sinyal EEG menggunakan headset Ultracortex Mark IV [13] yang dapat menangkap sampel EEG dari 16-35 berbagai saluran di kulit kepala pemakainya [14]. Papan Cyton OpenBCI akan memfasilitasi komunikasi nirkabel yang menghubungkan perangkat keras dan perangkat lunak komputer. Papan ini berfungsi untuk menangkap dan mengintegrasikan sinyal EEG dengan aplikasi berbasis GUI yang disediakan oleh OpenBCI. Rekaman EEG diperoleh pada laju pengambilan sampel 256 Hz.

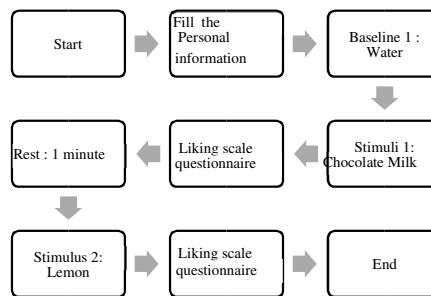
Keempat elektroda diposisikan pada T3, T4, CP1, dan CP2 dalam sistem internasional 10-20. Posisi ground elektroda ditempelkan pada daun telinga partisipan. Keempat kanal ini terletak di dekat area otak yang terlibat dalam pemrosesan respons rasa.[15].

Contoh gambar Ultracortex dan OpenBCI dapat dilihat pada gambar berikut.



Gambar 1. Headset Ultracortex [13]

1) Stimulus dan prosedur



Gambar 2. Langkah-Langkah Akuisisi Data EEG [16]

Dua jenis minuman manis dan asam diberikan kepada setiap partisipan. Dalam penelitian ini, tujuannya adalah untuk mengeksplorasi perbedaan respons sinyal EEG terhadap rasa manis dan asam dalam minuman olahan. Berbeda dengan pendekatan sebelumnya,[17][18] yang

menggunakan bahan-bahan alami untuk merangsang rasa, kami memilih susu cokelat sebagai representasi rasa manis dan jus lemon sebagai representasi rasa asam. Rasa manis dianggap sebagai sensasi alami yang disukai manusia, sementara susu cokelat dipilih karena kandungan kalorinya yang tinggi dan popularitasnya di semua kelompok umur.[17]. Sementara itu, rasa asam dipilih sebagai representasi rasa yang kurang disukai dan cenderung menimbulkan respon penghindaran. [11][12].



Gambar 3. Proses perekaman sinyal EEG saat memasukkan stimulus rasa asam

Selama perekaman, responden diminta untuk menutup mata. Selama 6 detik, subjek mengonsumsi larutan stimulus. Perekaman dilakukan selama enam detik sambil responden meminum larutan tersebut. Dua jenis stimulus yang digunakan adalah jus lemon dan susu cokelat dengan air sebagai bahan dasar. Setelah setiap stimulus diberikan, responden mengisi kuesioner yang merinci persepsi mereka terhadap rasa, serta menilai kesukaan mereka terhadap larutan tersebut pada skala 0 (tidak suka sama sekali) hingga 10 (sangat suka).[18]. Rangkaian stimulus disusun berdasarkan urutan air, susu rasa cokelat, dan jus rasa lemon. Setelah mengonsumsi larutan manis, responden berkumur dengan air sesuai petunjuk. Dokumentasi sinyal EEG bertujuan untuk menangkap reaksi otak terhadap stimulus rasa manis dan asam dalam minuman yang diberikan.

B. Pengolahan Sinyal EEG

a) Praproses

Perangkat lunak MATLAB digunakan untuk memproses sinyal EEG yang diperoleh. Total ($fs \times t$) = $(256 \times 6) = 1536$ data mentah dikumpulkan dari 4 kanal termasuk (CP1, CP2, T3, T4). Sinyal dipilih melalui bandpass (0,5-45 Hz), dilakukan Automatic Artifact Removal (AAR), dan Independent Component Analysis (ICA). Setelah itu, sinyal dipisahkan menjadi 5 Sub Band: Alpha (8-12Hz), Beta (12-25Hz), Gamma (25-50Hz), Delta (0,5-4Hz), Theta (4-8Hz). Setelah tahap preprocessing, data yang tersisa adalah 1.200 titik data. Kemudian dibagi menjadi 100 bagian. Proses ini menghasilkan data berukuran 100 baris x 20 kolom fitur (4 kanal x 5 subband). Dalam penelitian ini kami menggunakan subband Beta.

b) Ekstraksi Fitur

Kami menggunakan fitur Nilai Absolut Rata-rata (MAV) dan Varians (VAR). Ekstraksi fitur dilakukan dengan MATLAB.

1. Mean Absolute value (MAV)

MAV sering digunakan dalam ekstraksi fitur. MAV adalah rata-rata dari jumlah absolut sinyal yang berurutan. [19].

$$MAV = \frac{\sum_{i=1}^n |x_i|}{n} \quad (1)$$

Dimana:

x = nilai data

n = banyak data

i = perulangan (dilakukan dari data ke-1 sampai data ke-n)

$$\begin{array}{lcl} |...| & = & \text{nilai absolut} \\ \sum & = & \text{sigma (simbol operator penjumlahan)} \end{array}$$

2. Variance

Varians adalah ukuran keragaman (variasi) data statistik. Semakin tinggi nilai varians, semakin rendah nilai yang diharapkan.[20]

$$Var = \frac{\sum_{i=1}^n (x - \bar{x})^2}{n - 1} \quad (2)$$

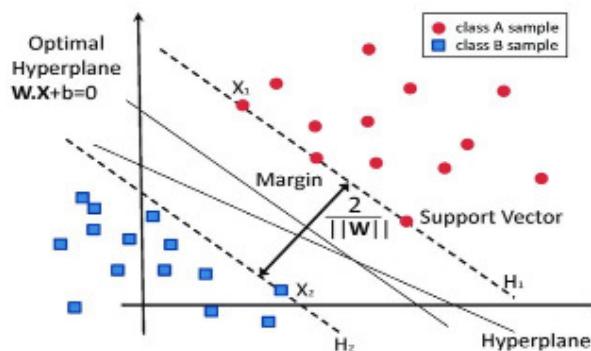
$$\begin{array}{lcl} x & = & \text{nilai data} \\ x & = & \text{nilai data} \\ \bar{x} & = & \text{Mean} \\ n & = & \text{banyak data} \\ i & = & \text{perulangan (dilakukan dari data ke-1 sampai data ke-n)} \\ \sum & = & \text{sigma (simbol operator penjumlahan)} \\ (...)^2 & = & \text{simbol kuadrat/pangkat 2} \end{array}$$

C. Proses Klasifikasi

Tiga algoritma machine learning digunakan untuk membandingkan performa klasifikasi. Sebelum pelatihan, data dibagi menjadi dua subset: Training set: 80% data dan Testing set: 20% data. Tiga algoritma machine learning :

- 1) Support Vector Machine atau SVM adalah algoritma machine learning yang cukup populer untuk kasus supervised learning. SVM dapat digunakan untuk kasus klasifikasi maupun regresi, namun kebanyakan digunakan untuk klasifikasi. Cara kerja dari algoritma ini adalah dengan membuat best line atau decision boundary yang disebut dengan hyperplane yang membagi ruang n-dimensi ke dalam kelas/kategori sehingga nantinya akan dengan mudah menentukan kelas/kategori data baru.[21]

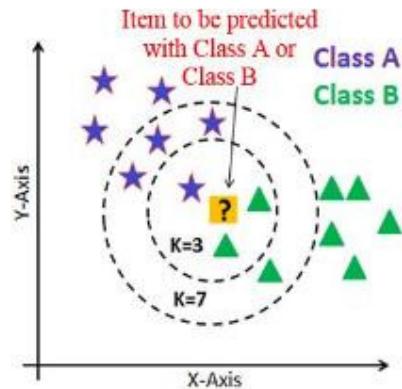
Pada **Error! Reference source not found.**4, ada dua kelas/kategori yakni lingkaran yang berwarna merah dan segiempat yang berwarna biru. Algoritma SVM akan membuat *hyperplane* untuk membagi data tersebut. Terdapat sebuah garis yang *optimal hyperplane* karena memiliki margin yang jauh dari data terdekat.



Gambar 4. Klasifikasi dengan algoritma SVM

2) K-Nearest Neighbor (KNN)

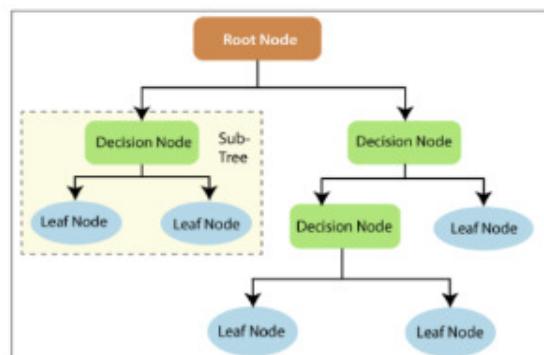
K-Nearest Neighbors atau yang biasa disingkat dengan KNN adalah salah satu algoritma supervised learning yang paling sederhana. Algoritma ini bekerja mengklasifikasikan data baru berdasarkan kemiripan dengan sejumlah K tetangga terdekatnya. Dengan kata lain, data baru akan diklasifikasikan ke dalam kategori berdasarkan mayoritas kategori tetangganya.[19]



Gambar 5. Klasifikasi dengan Algoritma KNN

3) Decision Tree (DT)

Pohon keputusan adalah salah satu metode ampuh yang umum digunakan di berbagai bidang, seperti pembelajaran mesin, pemrosesan gambar, dan identifikasi pola. DT adalah model berurutan yang menyatukan serangkaian pengujian dasar secara efisien dan kohesif di mana fitur numerik dibandingkan dengan nilai ambang batas dalam setiap pengujian. Aturan konseptual jauh lebih mudah dibangun daripada bobot numerik dalam jaringan saraf koneksi antara node. Selain itu, DT adalah model klasifikasi yang biasanya digunakan dalam Penambangan Data. Node dan cabang terdiri dari setiap pohon. Setiap node mewakili fitur dalam kategori yang akan diklasifikasikan dan setiap subset mendefinisikan nilai yang dapat diambil oleh node. Karena analisisnya yang sederhana dan presisinya pada berbagai bentuk data, pohon keputusan telah menemukan banyak bidang implementasi. [22]



Gambar 6. Algoritma Decision Tree

D. Evaluasi Model

Evaluasi dilakukan menggunakan pendekatan *Stratified 5-Fold Cross Validation* untuk mengurangi risiko *overfitting* dan memastikan distribusi kelas tetap seimbang di setiap fold. Kinerja model dievaluasi berdasarkan metrik:

- Akurasi (Accuracy): proporsi klasifikasi benar terhadap seluruh data.
- Precision: tingkat ketepatan model dalam memprediksi kelas positif (*Susu*).
- Recall (Sensitivitas): kemampuan model dalam mengenali kelas positif secara benar.
- F1-Score: harmonisasi antara precision dan recall.
- ROC AUC (Receiver Operating Characteristic – Area Under Curve): mengukur kemampuan model dalam membedakan dua kelas.

3. HASIL DAN DISKUSI

A. Hasil Kuesioner

Setelah peserta merasakan stimulus yang mencakup minuman yang masing-masing mewakili rasa manis dan asam, mereka diminta untuk memberikan deskripsi pengalaman rasa tersebut. Secara konsisten, semua peserta menggolongkan susu cokelat sebagai pemicu persepsi rasa manis, sementara jus lemon secara seragam digambarkan sebagai asam. Setelah tugas deskripsi rasa, peserta kemudian diinstruksikan untuk menilai kesukaan mereka terhadap setiap rasa pada skala tertentu. Skor kesukaan ini memberikan wawasan berharga tentang evaluasi subjektif rasa manis dan asam di antara 15 peserta pria dan 17 peserta wanita. Rata-rata peringkat kesukaan untuk rasa manis dan asam dirangkum dalam Tabel 1, yang mencerminkan preferensi keseluruhan untuk modalitas rasa ini dalam populasi sampel.

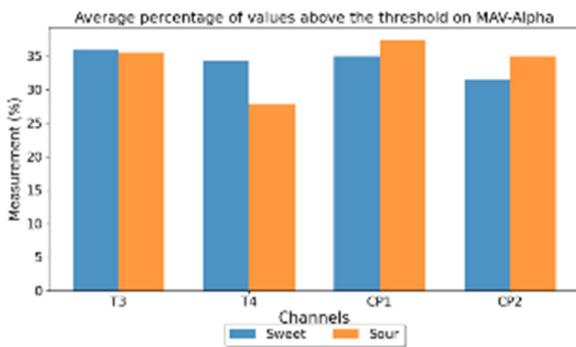
TABEL I HASIL KUESIONER

Respondents	Liking scale (0 – 10)	
	Sweetness (Chocolate milk)	Sourness (Lemon Juice)
Man	9	4.8
Woman	9.35	4.94

B. Ekstraksi Fitur

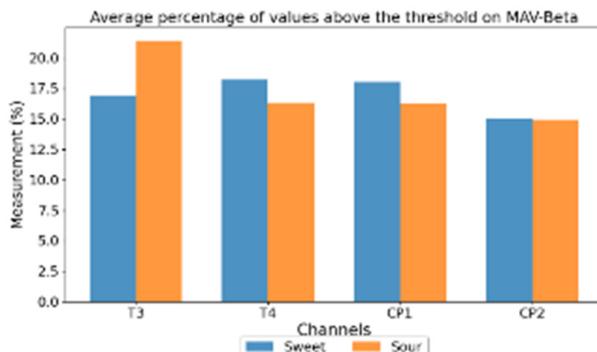
Sinyal EEG diperoleh dengan mengelompokkannya berdasarkan frekuensi dan saluran gelombang otak, menggunakan fitur MAV dan Varians. Selanjutnya, persentase kategori data yang melebihi ambang batas yang telah ditentukan dihitung, dengan mengkategorikan data yang lebih tinggi sebagai "ON" dan data yang lebih rendah sebagai "OFF". Hasil persentase "ON" untuk setiap kanal untuk kedua fitur ini digambarkan pada Gambar 4-7.

Berdasarkan Gambar 7, pola aktivitas otak pada fitur MAV Subband Alpha hanya menunjukkan sedikit perbedaan antara stimulus asam dan manis. Nilai T3, CP1, dan CP2 cenderung sama untuk kedua rasa. Hanya ada sedikit perbedaan pada kanal T4. Pada kanal stimulus asam, CP1 mendapatkan nilai tertinggi sebesar 37,4, diikuti oleh T3 dengan nilai 35,5, CP2 dengan nilai 35, dan T4 dengan nilai 27,8. Sementara itu, untuk stimulus manis, nilai tertinggi terdapat pada kanal T3 sebesar 35,9, diikuti oleh CP1 dengan nilai 35,0, T4 dengan nilai 34,4, dan CP2 dengan nilai 31,4.



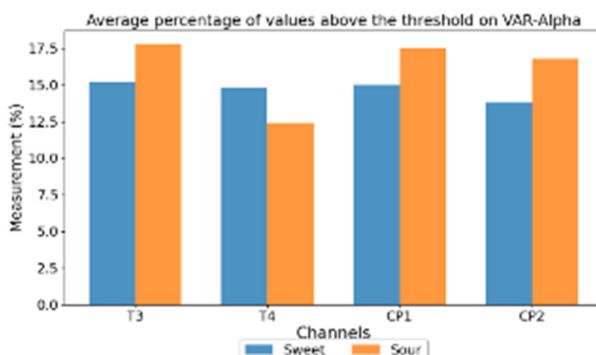
Gambar 7. Pola asam dan manis pada subband MAV alpha

Berdasarkan Gambar 8, menunjukkan pola yang berbeda dibandingkan dengan Gambar 7. Pada fitur MAV Subband Beta, stimulasi rasa asam lebih dominan pada kanal T3 dengan nilai tertinggi 21,4 diikuti oleh T4 dengan 16,3, CP1 dengan 16,2 dan CP2 dengan 14,9. Sementara untuk stimulus manis, kanal T4 menunjukkan nilai tertinggi 18,2, diikuti oleh CP1 dengan 18,0, T3 dengan 16,9 dan terendah pada CP2 dengan 15. Secara umum pada kanal T4, CP1, dan CP2 menunjukkan nilai yang relatif dekat untuk kedua rasa, yang menunjukkan bahwa aktivitas otak di wilayah ini tidak berbeda secara signifikan antara stimulus asam dan manis.



Gambar 8. Pola asam dan manis pada subband MAV Beta

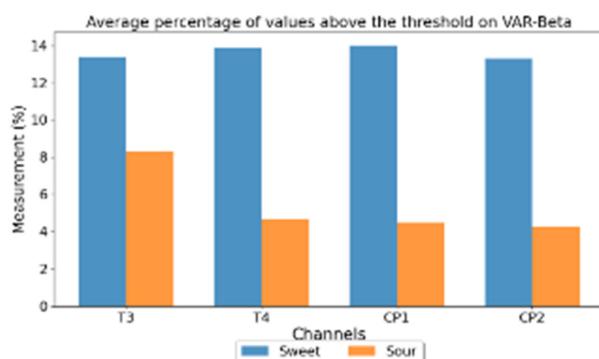
Berdasarkan Gambar 9, pola aktivitas otak pada fitur Variance Subband Alpha menunjukkan nilai asam tertinggi pada kanal T3, CP1 dan CP2 dibandingkan dengan nilai manis. Sementara nilai terendah pada fitur dan subband ini adalah asam pada kanal T4. Kanal T3 mendapat nilai tertinggi Nilai asam sebesar 17,8, diikuti oleh CP1 sebesar 17,5 dan CP2 sebesar 16,8. Nilai terendah adalah T4 dengan 12,4, sementara itu, untuk stimulus manis nilai tertinggi adalah T3 sebesar 15,2, diikuti oleh CP1 sebesar 15, T4 sebesar 14,8 dan terendah pada CP2 sebesar 13,8.



Gambar 9. Pola asam dan manis pada subband VAR Alpha

Perbedaan yang tidak terlalu signifikan antara stimulus asam dan manis pada keempat kanal teramat. Hal ini menunjukkan bahwa variabilitas aktivitas otak pada subband fitur Varians Alpha tidak dipengaruhi secara signifikan oleh jenis rasa.

Berbeda dengan gambar 9, gambar 10 menunjukkan perbedaan yang sangat signifikan dalam aktivitas otak ketika diberikan stimulus manis dan asam. Data pada Gambar 10 menunjukkan bahwa aktivitas otak pada subband fitur Varians Beta lebih tinggi ketika diberikan stimulus rasa manis dibandingkan dengan rasa asam.



Gambar 10. Pola asam dan manis pada subband VAR Beta

Hal ini menunjukkan bahwa rasa manis memicu respons otak yang lebih kuat pada regio yang dianalisis dibandingkan dengan rasa asam. Pada stimulus manis kanal CP1 menunjukkan nilai tertinggi sebesar 14,0 diikuti oleh T4 dengan nilai 13,9, T3 13,4, dan CP2 13,3. Sementara itu, untuk stimulus asam, nilai tertinggi untuk saluran T3 adalah 8,3, diikuti oleh T4 4,7, CP1 4,5, dan CP2 4,3.

C. Klasifikasi Model

Penelitian ini menggunakan delapan fitur utama yang diambil dari sinyal EEG subband Beta, yaitu Mean Absolute Value (MAV) dan Variance (VAR) pada empat kanal utama: T3, T4, CP1, CP2. Data EEG terdiri dari dua jenis stimulus, yaitu rasa manis (Susu) dan rasa asam (Lemon), dengan total 10.644 potong data (3.550 data Susu dan 7.094 data Lemon). Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian, dengan normalisasi *z-score* agar skala tiap fitur setara. Proses klasifikasi dilakukan menggunakan tiga algoritma *machine learning*, yaitu Support Vector Machine (SVM) dengan kernel linear, K-Nearest Neighbor (KNN) dengan $k=5$, dan Decision Tree (DT). Hasil pengujian performa ditunjukkan pada Tabel 2 berikut.

Tabel 2. Hasil Evaluasi Model Klasifikasi EEG Subband Beta

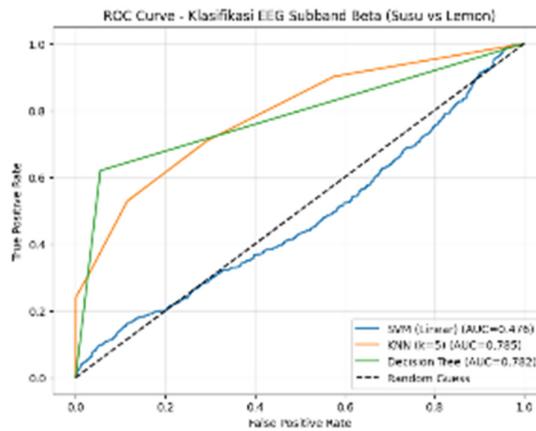
Model	CV Mean	CV Std	Akurasi	Precision	Recall	F1-Score	ROC AUC
SVM (linear)	0.666	0.000	0.667	0.000	0.000	0.000	0.476
KNN (k=5)	0.756	0.005	0.766	0.697	0.528	0.601	0.785
Decision Tree	0.827	0.007	0.840	0.846	0.637	0.727	0.789

D. Analisis Performa Model

Berdasarkan hasil pengujian, Decision Tree memberikan hasil terbaik dengan nilai akurasi 84,0%, F1-score 0,727, dan ROC AUC 0,789. Model ini menunjukkan kemampuan yang baik dalam mengenali pola non-linear antara fitur EEG terhadap jenis stimulus rasa. Model KNN (k=5) menempati posisi kedua dengan akurasi 76,6% dan ROC AUC 0,785, menandakan bahwa pendekatan berbasis jarak masih cukup efektif dalam membedakan pola sinyal EEG antar stimulus. Sedangkan SVM linear menunjukkan performa rendah (akurasi 66,7%) karena gagal memisahkan kelas akibat distribusi data yang tidak seimbang antara *Lemon* dan *Susu*.

E. Analisis ROC Curve

Kurva ROC yang ditampilkan pada Gambar 11 menunjukkan kemampuan tiap model dalam membedakan kedua stimulus. Kurva Decision Tree dan KNN berada jauh di atas garis diagonal acak ($AUC \approx 0,79$), menunjukkan bahwa kedua model memiliki kemampuan klasifikasi yang baik. Kurva SVM linear mendekati diagonal, menunjukkan kemampuan diskriminasi yang lemah ($AUC \approx 0,47$). Dari grafik tersebut terlihat bahwa Decision Tree sedikit lebih unggul dibanding KNN pada hampir seluruh rentang *False Positive Rate (FPR)*, yang berarti model ini lebih konsisten dalam mengenali stimulus *Susu* (kelas minoritas).



Gambar 11. ROC Curve

F. Diskusi

Hasil eksperimen menunjukkan bahwa fitur MAV dan VAR pada pita Beta (12–25 Hz) mengandung informasi yang cukup untuk membedakan dua jenis stimulus rasa. Hal ini sesuai dengan penelitian terdahulu yang menyebutkan bahwa aktivitas otak pada pita Beta meningkat selama proses persepsi rasa dan pemrosesan emosi positif, terutama pada area temporal dan parietal [3][10]. Model Decision Tree mampu mengenali hubungan non-linear antara nilai MAV dan VAR dengan kelas stimulus. Kanal CP1 dan T3 diketahui memiliki kontribusi terbesar terhadap hasil klasifikasi, sejalan dengan lokasi anatomi insula dan gustatory cortex yang berperan dalam persepsi rasa. Sebaliknya, performa rendah pada SVM linear mengindikasikan bahwa pola aktivitas EEG terhadap stimulus rasa tidak bersifat linear, sehingga memerlukan pendekatan yang lebih fleksibel. Dari sudut pandang fisiologis, respons otak terhadap rasa manis (*Susu*) cenderung menunjukkan aktivitas Beta yang lebih tinggi, mencerminkan peningkatan

perhatian dan kenikmatan sensorik. Sebaliknya, stimulus asam (Lemon) menghasilkan aktivitas Beta yang lebih rendah dan lebih terlokalisasi, menggambarkan reaksi penolakan atau aversive response ringan. Perbedaan pola ini dapat dimanfaatkan oleh sistem machine learning untuk membedakan kedua kondisi secara otomatis.

4. KESIMPULAN

A. Kesimpulan

Penelitian ini telah berhasil mengembangkan analisis sinyal EEG subband Beta dari pendekatan deskriptif berbasis brain heatmap menjadi pendekatan prediktif berbasis klasifikasi machine learning. Dengan menggunakan delapan fitur utama yang diperoleh dari Mean Absolute Value (MAV) dan Variance (VAR) pada kanal T3, T4, CP1, dan CP2, sistem mampu mengenali perbedaan aktivitas otak terhadap dua jenis stimulus rasa, yaitu rasa manis (Susu) dan rasa asam (Lemon). Tiga algoritma machine learning telah diuji, yaitu Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Decision Tree (DT). Dari hasil eksperimen diperoleh kesimpulan Model Decision Tree memberikan performa terbaik dengan akurasi sebesar 84,0%, F1-score 0,727, dan ROC AUC 0,789, menunjukkan kemampuan tinggi dalam mengenali pola non-linear pada data EEG. Model KNN (k=5) memberikan performa cukup baik dengan akurasi 76,6% dan AUC 0,785, menandakan bahwa pendekatan berbasis kedekatan data efektif untuk membedakan stimulus rasa. Model SVM linear memiliki performa rendah (akurasi 66,7%), karena tidak mampu memisahkan kelas secara optimal pada data EEG yang bersifat non-linear dan tidak seimbang. Fitur Variance pada kanal CP1 dan T3 menunjukkan kontribusi paling dominan dalam membedakan stimulus manis dan asam, sesuai dengan lokasi area insula dan parietal yang berperan dalam persepsi rasa. Hasil ini menegaskan bahwa sinyal EEG pada pita Beta mengandung informasi yang cukup kuat untuk mengidentifikasi persepsi rasa manusia. Pendekatan klasifikasi berbasis machine learning tidak hanya memberikan validasi objektif terhadap perbedaan pola aktivitas otak, tetapi juga membuka potensi pengembangan sistem EEG-based Taste Recognition untuk aplikasi di bidang neurogastronomi dan Brain–Computer Interface (BCI).

B. Saran

Berdasarkan hasil penelitian dan keterbatasan yang dihadapi, beberapa saran yang dapat diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Penanganan ketidakseimbangan data (class imbalance): Proporsi data antara stimulus Lemon dan Susu yang tidak seimbang menyebabkan bias pada model linear seperti SVM. Kedepan dapat dieksplorasi untuk menggunakan teknik lain agar model lebih stabil.
2. Model ensemble learning seperti Random Forest, Gradient Boosting, atau XGBoost dapat dieksplorasi untuk meningkatkan akurasi dan generalisasi klasifikasi EEG.

DAFTAR PUSTAKA

- [1] P. A. S. Breslin, “An evolutionary perspective on food and human taste,” *Curr. Biol.*, vol. 23, no. 9, pp. R409–R418, 2013, doi: 10.1016/j.cub.2013.04.010.
- [2] D. Carlos, R. Origin, C. L. Generation, and W. F. Programmed, “The neural mechanisms of gustation : a distributed processing code,” vol. 7, no. November, pp. 1279–1287, 2006.
- [3] M. Y. L. Lejap, A. D. Wibawa, and P. H. Mukti, “EEG Brain Heatmap Visualization for Sweet and Sour Tasting,” *Proc. - Int. Semin. Intell. Technol. its Appl. ISITIA*, no. 2024, pp. 367–372, 2024, doi: 10.1109/ISITIA63062.2024.10668352.
- [4] R. S. T. Linforth, “Developments in instrumental techniques for food flavour evaluation: Future prospects,” *J. Sci. Food Agric.*, vol. 80, no. 14, pp. 2044–2048, 2000, doi: 10.1002/1097-0010(200011)80:14<2044::AID-JSFA753>3.0.CO;2-Z.
- [5] N. Z. Ndaro and S. Y. Wang, “Effects of Fatigue Based on Electroencephalography Signal

- during Laparoscopic Surgical Simulation," *Minim. Invasive Surg.*, vol. 2018, 2018, doi: 10.1155/2018/2389158.
- [6] A. D. Wibawa, N. Fatih, Y. Pamungkas, M. Pratiwi, P. A. Ramadhani, and Suwadi, "Time and Frequency Domain Feature Selection Using Mutual Information for EEG-based Emotion Recognition," *Int. Conf. Electr. Eng. Comput. Sci. Informatics*, vol. 2022-Octob, no. October, pp. 19–24, 2022, doi: 10.23919/EECSI56542.2022.9946522.
- [7] Y. Pamungkas and U. W. Astuti, "Comparison of Human Emotion Classification on Single-Channel and Multi-Channel EEG using Gate Recurrent Unit Algorithm," *ICCoSITE 2023 - Int. Conf. Comput. Sci. Inf. Technol. Eng. Digit. Transform. Strateg. Facing VUCA TUNA Era*, pp. 375–380, 2023, doi: 10.1109/ICCoSITE57641.2023.10127686.
- [8] Y. Nakamura *et al.*, "Localization of the primary taste cortex by contrasting passive and attentive conditions," *Exp. Brain Res.*, vol. 227, no. 2, pp. 185–197, 2013, doi: 10.1007/s00221-013-3499-z.
- [9] Z. Khakim and S. Kusrohmaniah, "Dasar - Dasar Electroencephalography (EEG) bagi Riset Psikologi," *Bul. Psikol.*, vol. 29, no. 1, p. 92, 2021, doi: 10.22146/buletinpsikologi.52328.
- [10] C. Solnais, J. Andreu-perez, J. Sánchez-fernández, and J. Andréu-abela, "Journal of Economic Psychology The contribution of neuroscience to consumer research: A conceptual framework and empirical review," *J. Econ. Psychol.*, vol. 36, pp. 68–81, 2013, doi: 10.1016/j.jeop.2013.02.011.
- [11] M. Behrens and W. Meyerhof, "Bitter taste receptors and human bitter taste perception," vol. 63, pp. 1501–1509, 2006, doi: 10.1007/s00018-006-6113-8.
- [12] N. Pomirleanu, B. M. Gustafson, and S. Bi, "Ooh , that ' s sour : An investigation of the role of sour taste and color saturation in consumer temptation avoidance," pp. 1–14, 2020, doi: 10.1002/mar.21363.
- [13] "Ultracortex 'Mark IV' EEG Headset.pdf." [Online]. Available: <https://shop.openbci.com/products/ultracortex-mark-iv>
- [14] "Dokumen open BCI.pdf." [Online]. Available: <https://docs.openbci.com/>
- [15] E. Iannilli, N. Noennig, T. Hummel, and A. M. Schoenfeld, "Spatio-temporal correlates of taste processing in the human primary gustatory cortex," *Neuroscience*, vol. 273, pp. 92–99, 2014, doi: 10.1016/j.neuroscience.2014.05.017.
- [16] U. W. Astuti, A. D. Wibawa, and Y. Pamungkas, "Classification of Sweet and Sour Taste Using Electroencephalography (EEG)," *Int. Conf. Math. Stat. their Appl. ICMSA*, 2023.
- [17] C. Park, D. Looney, and D. P. Mandic, "Estimating human response to taste using EEG," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 6331–6332, 2011, doi: 10.1109/IEMBS.2011.6091563.
- [18] F. D. Mihafu, J. Y. Issa, and M. W. Kamiyango, "Current Research in Nutrition and Food Science Implication of Sensory Evaluation and Quality Assessment in Food Product Development : a Review," vol. 08, no. 3, 2020, doi: 10.12944/CRNFSJ.8.3.03.
- [19] J. H. Kim, C. M. Kim, and M. S. Yim, "An investigation of insider threat mitigation based on eeg signal classification," *Sensors (Switzerland)*, vol. 20, no. 21, pp. 1–17, 2020, doi: 10.3390/s20216365.
- [20] I. Stancin, M. Cifrek, and A. Jovic, "A review of eeg signal features and their application in driver drowsiness detection systems," *Sensors*, vol. 21, no. 11, 2021, doi: 10.3390/s21113786.
- [21] M. P. Hosseini, A. Hosseini, and K. Ahi, "A Review on Machine Learning for EEG Signal Processing in Bioengineering," *IEEE Rev. Biomed. Eng.*, vol. 14, no. c, pp. 204–218, 2021, doi: 10.1109/RBME.2020.2969915.
- [22] "View of Classification Based on Decision Tree Algorithm for Machine Learning _ Journal of Applied Science and Technology Trends.pdf."