

HYBRID MATRIK CO-OCCURENCE DAN LEARNING VECTOR QUANTIZATION PADA KLASIFIKASI CITRA GELOMBANG SUARA PERUT

Ibnu Rivansyah Subagyo, Mutaqin Akbar

Informatika, Universitas Mercu Buana Yogyakarta

Jl. Jembatan Merah No.84C, Condongcatur, Sleman, Daerah Istimewa Yogyakarta, Indonesia

211110104@student.mercubuana-yogya.ac.id

ABSTRAK

Penelitian ini bertujuan untuk mengklasifikasi perbedaan citra gelombang suara perut antara kondisi kenyang dan lapar menggunakan metode Hybrid Gray Level Co-Occurrence Matrix (GLCM) dan Learning Vector Quantization (LVQ). Penelitian ini di latar belakang oleh tantangan dalam mendeteksi kondisi lapar atau kenyang secara objektif, khususnya pada individu dengan pola makan tidak teratur atau gangguan pencernaan. Ketidakmampuan membedakan sinyal tubuh dapat berdampak pada penanganan kesehatan yang kurang tepat. Dalam penelitian ini, Suara organ pencernaan manusia direkam dan dianalisis dengan ekstraksi fitur GLCM untuk menggambarkan informasi tekstural citra gelombang suara 2D perut. Sedangkan algoritma LVQ digunakan untuk mengklasifikasikan citra gelombang 2D suara menjadi perut kenyang dan perut lapar. Penelitian ini menggabungkan teknik pengolahan citra dan kecerdasan buatan untuk pengenalan suara perut yang lebih akurat. Eksperimen menunjukkan bahwa metode yang diusulkan dapat membedakan perut kenyang dan lapar dengan parameter nilai alfa (α) = 0,001 dan nilai decalfa (deca) = 0,7, Epoch 4 yang menghasilkan akurasi klasifikasi perut lapar dan perut kenyang yang tertinggi dengan akurasi yaitu 99%. Hasilnya membuka peluang penerapan teknologi ini dalam pengembangan sistem pendukung keputusan di bidang kesehatan dan nutrisi.

Kata kunci : Analisis citra, Deteksi lapar, GLCM, LVQ, Suara perut.

1. PENDAHULUAN

Rasa lapar merupakan sinyal alami tubuh yang menunjukkan bahwa energi dari makanan yang dikonsumsi sebelumnya telah digunakan, sehingga tubuh memerlukan asupan baru. Ketika perut mulai kosong, sering kali muncul suara keroncongan yang berasal dari kontraksi otot lambung dan usus yang bergerak dalam kondisi tanpa makanan. Fenomena ini menjadi tanda bahwa tubuh siap untuk menerima asupan makanan, yang sering kali disertai dengan perasaan tidak nyaman seperti perih atau rasa nyeri ringan di perut. Namun, pada beberapa individu, terutama mereka yang memiliki pola makan tidak teratur, sinyal ini dapat disalahartikan dengan gejala gangguan pencernaan, seperti sakit maag. Maag, atau gastritis, terjadi akibat produksi asam lambung yang berlebih yang mengakibatkan iritasi pada lapisan mukosa lambung. Pada kondisi yang parah, rasa nyeri di ulu hati bisa berkembang menjadi peradangan serius yang mempengaruhi sistem pencernaan secara keseluruhan [1], [2].

Mahasiswa, sebagai salah satu kelompok yang rentan mengalami perubahan pola makan karena aktivitas yang padat, sering kali menghadapi masalah pada sistem pencernaan. Stres akademik dan tekanan waktu menyebabkan mereka kerap mengabaikan waktu makan yang ideal dan pemenuhan gizi [3], sehingga meningkatkan risiko gangguan pencernaan seperti maag atau kembung. Ketidakmampuan untuk mengenali perbedaan antara rasa lapar alami dan gejala maag dapat mengakibatkan penanganan yang kurang tepat terhadap kesehatan pencernaan mereka[4].

Rasa lapar dan kenyang tidak hanya dipengaruhi oleh jumlah makanan yang dikonsumsi tetapi juga oleh berbagai faktor internal dan eksternal. Faktor internal meliputi kadar gula darah, hormon, serta zat kimia otak yang mengatur nafsu makan dan rasa kenyang. Faktor eksternal meliputi pola makan, jenis makanan, serta kondisi psikologis individu. Sensasi lapar yang tidak diimbangi dengan makan dapat menyebabkan lapisan mukosa lambung terganggu oleh asam lambung, sedangkan perut kenyang tidak selalu menandakan bahwa kebutuhan gizi telah terpenuhi secara seimbang [2], [3].

Penelitian ini bertujuan untuk mengklasifikasi perbedaan suara perut yang disebabkan oleh kondisi lapar dan kondisi kenyang. Klasifikasi ini dilakukan dengan metode pengolahan citra suara menggunakan Learning Vector Quantization (LVQ) dan Gray Level Co-Occurrence Matrix (GLCM). Metode LVQ dipilih karena keandalannya dalam mengklasifikasikan pola dari data kompleks seperti citra 2D suara [5]. GLCM digunakan sebagai metode ekstraksi fitur karena kemampuannya untuk mengklasifikasi informasi tekstur pada citra yang dihasilkan dari gelombang suara [6], [7].

Metode klasifikasi citra suara yang digunakan di penelitian ini melibatkan ekstraksi fitur tekstur dari gelombang suara menggunakan GLCM, yang kemudian dilanjutkan dengan klasifikasi menggunakan algoritma LVQ. GLCM memungkinkan pengolahan tekstur suara untuk membedakan suara perut lapar dari perut kenyang, sedangkan LVQ bertugas untuk mempelajari pola-pola tersebut dan melakukan klasifikasi berdasarkan vektor-vektor pembelajaran[8].

2. TINJAUAN PUSTAKA

2.1. Perut Lapar

Perut lapar adalah kondisi yang menunjukkan bahwa tubuh memerlukan energi dari makanan. Kondisi ini ditandai dengan rasa ingin makan, suara keroncongan di perut, dan perasaan gelisah. Perut lapar merupakan sinyal alami yang mengajak kita untuk makan sesuai dengan kebutuhan tubuh. Namun, hal ini juga bisa dipengaruhi oleh berbagai faktor lain, baik yang berasal dari dalam maupun dari luar tubuh.

Faktor-faktor internal yang mempengaruhi perut lapar antara lain adalah: kadar gula darah, hormon-hormon tertentu, zat kimia otak, dan protein-peptida yang terlibat dalam pengaturan nafsu makan dan rasa kenyang. Faktor-faktor eksternal yang mempengaruhi perut lapar antara lain adalah: waktu dan pola makan, jenis dan jumlah makanan, lingkungan sekitar, dan kondisi psikologis.

Pada saat perut lapar tetapi tidak makan, asam lambung akan mencerna lapisan mukosa lambung. Hal ini disebabkan oleh peningkatan gerakan peristaltik lambung saat lambung kosong, yang akan merangsang peningkatan produksi asam lambung. Akibatnya, dapat timbul rasa nyeri di ulu hati [2].

2.2. Perut Kenyang

Perut kenyang merupakan sensasi yang menandakan bahwa tubuh telah mendapatkan asupan makanan yang cukup. Sensasi ini biasanya disertai dengan rasa puas dan hilangnya nafsu makan. Namun, perut kenyang tidak hanya ditentukan oleh jumlah makanan yang dikonsumsi, tetapi juga oleh jenis dan kualitas makanan, serta faktor-faktor fisiologis lainnya, seperti hormon-hormon yang mengatur rasa lapar dan kenyang. Oleh karena itu, perut kenyang tidak selalu berarti bahwa tubuh telah memenuhi kebutuhan gizi yang seimbang. Banyak remaja yang salah mengira bahwa makan sampai perut kenyang adalah cara untuk memenuhi kebutuhan gizi [3] padahal makanan yang mereka konsumsi mungkin tidak mengandung nutrisi yang cukup atau bahkan berlebihan. Hal ini dapat berdampak negatif bagi kesehatan dan kesejahteraan mereka.

2.3. Gelombang Suara

Gelombang suara adalah fenomena mekanis yang mendasari pengalaman pendengaran manusia dan memiliki aplikasi luas dalam berbagai bidang. Gelombang suara telah menjadi fokus kajian seiring pemahaman mendalam terhadap sifat-sifatnya [9]. Karakteristik gelombang suara, seperti kecepatan rambat dan frekuensi, memiliki peran penting dalam menjelaskan bagaimana suara terbentuk, merambat, dan diinterpretasikan oleh pendengar. Penelitian terkini melibatkan penerapan gelombang suara dalam teknologi audio [10] Melalui pengembangan alat seperti speaker, gelombang suara dapat direkam, dianalisis, serta dimanipulasi untuk memenuhi kebutuhan praktis dan ilmiah.

Pengenalan suara adalah salah satu bidang penting dalam analisis forensik digital, yang digunakan untuk mengklasifikasi individu melalui karakteristik suara mereka. Metode yang digunakan dalam pengenalan suara sangat bervariasi, dan salah satu pendekatan yang menjanjikan adalah menggunakan Learning Vector Quantization (LVQ). LVQ adalah teknik pembelajaran terawasi yang mengklasifikasikan data berdasarkan pola dan fitur yang diekstraksi dari suara. Penelitian oleh Mardothillah [11] menunjukkan bagaimana LVQ dapat diimplementasikan untuk mengenali suara dalam konteks forensik digital, dengan akurasi yang signifikan dalam klasifikasi pembicara.

2.4. Gray Level Co-Occurance Matrix (GLCM)

Gray Level Co-Occurance Matrix (GLCM) merupakan metode pengolahan citra dengan menggunakan statistik seperti matriks yang berdasar pada pixel. GLCM diambil untuk melakukan ekstraksi ciri dengan tekstur yang merupakan pembeda dalam melakukan klasifikasi [12] Matriks GLCM salah satu sumber ciri yang paling populer dan efektif dalam analisis tekstur [6]. Beberapa fitur umum yang sering dihitung menggunakan GLCM adalah kontras, homogenitas, entropi, dan korelasi. Penelitian ini menggunakan metode GLCM dengan fitur kontras dan homogenitas untuk mengklasifikasi perut lapar dan perut kenyang.

Kontras mengukur perbedaan lokal dalam intensitas nilai piksel. Nilai kontras yang tinggi menunjukkan adanya perbedaan tajam antara intensitas piksel tetangga. Nilai kontras didapat dari rumus berikut:

$$\text{Kontras} = \sum_{i=1}^N \sum_{j=1}^N P(i, j) \times (i - j)^2 \quad (1)$$

di mana $P(i, j)$ merupakan elemen dalam matriks GLCM, i, j merupakan indeks baris dan kolom pada GLCM, dan N : jumlah level intensitas dalam citra.

Homogenitas mengukur seberapa seragam nilai piksel dalam gambar. Nilai homogenitas yang tinggi menunjukkan bahwa piksel-piksel dalam gambar memiliki intensitas yang serupa. Nilai homogenitas diambil dari rumus berikut:

$$\text{Homogenitas} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + |i - j|} \quad (2)$$

di mana $P(i, j)$ merupakan elemen dalam matriks GLCM, i, j merupakan indeks baris dan kolom pada GLCM, dan N : jumlah level intensitas dalam citra.

2.5. Learning Vector Quantization (LVQ)

Learning Vector Quantization (LVQ) merupakan metode klasifikasi yang telah menjadi fokus penelitian di bidang pembelajaran mesin. LVQ dikaji karena kemampuannya dalam mengelompokkan data ke

dalam kategori tertentu berdasarkan vektor pembelajaran yang diinisialisasi [5].

Model ini menggabungkan prinsip kuantisasi vektor dengan pembelajaran berbasis prototipe, di mana vektor pembelajaran diadaptasi untuk mencocokkan distribusi data yang diberikan. Banyak penelitian menyoroti keefektifan LVQ dalam menangani tugas klasifikasi pada data yang kompleks dan multi dimensional. Pengembangan dan variasi model LVQ juga terus dieksplorasi untuk meningkatkan kinerja dan adaptabilitasnya terhadap berbagai jenis masalah klasifikasi [8].

LVQ juga merupakan metode pembelajaran terawasi yang menggunakan vektor bobot untuk melakukan klasifikasi. Dalam konteks pengenalan bahasa isyarat seperti yang penelitian yang dilakukan oleh [7], LVQ digunakan untuk membandingkan fitur gerakan tangan yang terekam dengan vektor bobot yang mewakili kata kerja tertentu. Penelitian sebelumnya telah menunjukkan bahwa LVQ dapat menghasilkan akurasi yang tinggi dalam klasifikasi pola gerakan tangan. Dengan kontribusinya yang signifikan dalam pengenalan pola dan klasifikasi data, LVQ menjadi alat yang penting dalam pemrosesan informasi dan pengambilan keputusan di berbagai bidang, termasuk klasifikasi perut kenyang dan perut lapar.


Penelitian sebelumnya juga telah mengeksplorasi penggunaan LVQ untuk klasifikasi personal berdasarkan geometri tangan, seperti yang ditunjukkan oleh [13] di mana geometri tangan digunakan untuk mengklasifikasikan individu berdasarkan citra punggung tangan mereka. Pendekatan ini menunjukkan kekuatan LVQ dalam menangani data biometrika, dengan tingkat keberhasilan klasifikasi mencapai 85,71%.

Kemudian terdapat penelitian mengenai klasifikasi buah menggunakan LVQ. LVQ digunakan untuk klasifikasi buah pisang berformalin dan tidak, dimana tingkat akurasi yang didapatkan adalah 90,9% [14]. Kemudian ada juga klasifikasi jenis buah berry, dimana nilai akurasi yang didapatkan adalah 98% [15].

Menurut [16], LVQ dapat digunakan untuk menganalisis rekaman suara dan mengklasifikasi pola yang terkait dengan gejala ini. Proses ini melibatkan ekstraksi fitur dari sinyal audio yang mencakup berbagai atribut suara, seperti frekuensi, amplitudo, dan durasi. Dengan menggunakan LVQ, fitur-fitur ini dapat digunakan untuk membangun model klasifikasi. Selain itu, LVQ memungkinkan pengurangan kompleksitas data melalui teknik kompresi seperti Discrete Cosine Transform (DCT), yang meminimalkan jumlah instansi sambil tetap mempertahankan informasi penting yang diperlukan untuk analisis.

Algoritma LVQ terdiri dari beberapa langkah: inisialisasi vektor referensi dan laju pembelajaran awal, pencarian indeks yang meminimalkan jarak antara input pelatihan dan vektor referensi, pembaruan vektor referensi berdasarkan kecocokan kelas,

penurunan laju pembelajaran secara bertahap, dan evaluasi syarat penghentian, seperti jumlah iterasi atau nilai laju pembelajaran yang mencapai batas tertentu [17].




Gambar 1. Arsitektur LVQ [17]

Demikian juga, kombinasi GLCM dan LVQ dalam aplikasi medis telah efektif dalam meningkatkan akurasi untuk tugas-tugas kompleks, seperti membedakan antara kondisi perut lapar dan kenyang menggunakan citra gelombang suara 2D.

3. METODE PENELITIAN


Penelitian ini dilakukan dengan menggunakan metode eksperimen seperti yang terdapat pada blok diagram Gambar 2. Data-data yang diperoleh berupa audio perut yang direkam dan nantinya dianalisis untuk mengklasifikasi antara perut lapar dan perut kenyang.




Gambar 2. Blok Diagram Penelitian

Suara lambung yang dihasilkan lalu di akuisisi dan menghasilkan data audio berupa audio splitting. Audio tersebut nantinya divisualisasikan dalam bentuk gambar dengan mengekstrak audio menjadi image. Dari image diubah dengan menggunakan citra aras keabuan (Grayscale) untuk menghemat komputasi menjadi satu ruang warna. Hasil Grayscale kemudian lanjutkan proses menggunakan co-occurrence matrik untuk menghasilkan ciri kontras dan homogeniti. Proses akhir yaitu ciri kontras dan homogeniti diklasifikasikan menggunakan neural network LVQ untuk di klasifikasi menjadi perut lapar atau perut kenyang.

Proses penelitian ini diawali dengan akuisisi data, di mana suara lambung direkam menggunakan mikrofon pada ponsel dengan format MP3. Setelah direkam, data audio diubah ke format WAV dan dipindahkan dari ponsel ke komputer. Selanjutnya, dilakukan proses audio splitting untuk memotong data audio dalam format WAV tersebut menjadi segmen-segmen kecil dari data kontinu. Data audio yang telah diproses kemudian divisualisasikan dalam bentuk citra gelombang suara dua dimensi (2D) untuk mempermudah interpretasi dan pengambilan keputusan, seperti yang ditunjukkan pada Gambar 3.



Gambar 3. Citra 2D Visualisasi Audio




Gambar 4. Citra 2D Visualisasi Audio Aras Keabuan

Langkah berikutnya adalah konversi visualisasi data menjadi gambar grayscale. Representasi grayscale ini menampilkan intensitas cahaya pada setiap piksel dalam gambar dengan rentang nilai 0 (hitam) hingga 255 (putih), di mana nilai yang lebih tinggi menunjukkan intensitas cahaya yang lebih tinggi. Gambar hasil konversi grayscale ditunjukkan pada Gambar 4. Setelah itu, dilakukan ekstraksi ciri


menggunakan metode Gray Level Co-occurrence Matrix (GLCM). GLCM adalah metode statistik untuk analisis tekstur citra yang menghitung frekuensi kemunculan pasangan nilai keabuan pada jarak dan arah tertentu[18].

Dalam penelitian ini, dua ciri tekstur yang digunakan adalah homogeneity dan contrast. Ciri yang telah diekstraksi dari citra visualisasi data kemudian digunakan dalam pelatihan model Learning Vector Quantization (LVQ) sebagai bagian dari implementasi machine learning. LVQ adalah metode pembelajaran berbasis prototipe yang efektif untuk klasifikasi data berbasis pola. Arsitektur LVQ yang digunakan dalam penelitian ini ditunjukkan pada Gambar 4.



Gambar 5. Arsitektur Learning Vector Quantization (LVQ)

Gambar 5 menunjukkan arsitektur dari metode Learning Vector Quantization (LVQ) yang digunakan dalam penelitian, sebuah algoritma pembelajaran berbasis prototipe yang digunakan untuk klasifikasi data. Diagram ini terdiri dari lapisan input, lapisan proses, dan lapisan output. Pada lapisan input, data yang masuk berupa fitur-fitur yang telah diekstraksi, seperti contrast dan homogeneity dari citra gelombang suara. Data tersebut dihitung jaraknya terhadap bobot (w) menggunakan fungsi berbasis jarak, seperti jarak Euclidean. Proses perhitungan ini bertujuan untuk menentukan kedekatan data masukan dengan masing-masing prototipe kelas. Nilai hasil perhitungan diteruskan ke fungsi aktivasi untuk memutuskan klasifikasi akhir. Lapisan output memberikan hasil klasifikasi berupa kelas yang sesuai, misalnya, apakah data tersebut termasuk kondisi perut lapar atau perut kenyang. Arsitektur ini menunjukkan bahwa LVQ bekerja dengan prinsip kompetisi antar-prototipe, di mana setiap input diklasifikasikan ke dalam kelas prototipe yang paling dekat. Proses ini dilengkapi dengan pembaruan bobot secara bertahap menggunakan parameter seperti learning rate untuk meningkatkan akurasi klasifikasi.



Gambar 6. Flowchart metode LVQ

Flowchart ini merepresentasikan proses Learning Vector Quantization (LVQ), sebuah metode supervised learning untuk klasifikasi data. Proses diawali dengan inialisasi parameter, yaitu α (laju pembelajaran), decaAlfa (penurunan laju pembelajaran), MinAlfa (nilai minimum α), MaxEpoch (maksimum epoch), bobot awal (w), serta data pelatihan (P). Selanjutnya, dilakukan iterasi dengan menambahkan epoch, dan jarak Euclidean antara bobot dan sampel data dihitung untuk memilih bobot dengan jarak minimum terhadap data masukan.

Setelah itu, dilakukan evaluasi terhadap prediksi kelas apakah sesuai dengan target. Jika prediksi tidak sesuai, bobot diperbarui agar menjauh dari sampel. Sebaliknya, jika prediksi sesuai, bobot diperbarui agar mendekati sampel. Nilai α kemudian dikurangi dengan faktor decayAlfa , sebagai bentuk penurunan laju pembelajaran seiring bertambahnya iterasi. Proses ini terus berulang hingga jumlah epoch mencapai MaxEpoch atau nilai α menjadi lebih kecil dari MinAlfa .

Ketika kondisi berhenti terpenuhi, bobot akhir (w) ditampilkan. Selanjutnya, bobot hasil pelatihan digunakan untuk pengujian data, dan hasil prediksi dibandingkan dengan target untuk mengevaluasi

kinerjanya. Hasil akhir berupa perbandingan antara prediksi dan target ditampilkan sebagai evaluasi performa model. Flowchart ini menunjukkan pendekatan Learning Vector Quantization yang mengoptimalkan bobot melalui pembaruan adaptif berdasarkan jarak Euclidean, serta menyertakan mekanisme laju pembelajaran yang berkurang secara bertahap untuk mencapai konvergensi yang stabil.

Parameter-parameter LVQ yang digunakan dalam penelitian ini meliputi α , $\text{decalpa}(\text{deca})$, dan epoch, seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Parameter LVQ

Parameter	Nilai
Data Latih	50
Data Uji	20
Target	2((1)Perut Kenyang, (2)Perut Lapar)
alfa	0.1;0.01;0.001
decAlfa	0.1;0.5;0.9
minAlfa	0.00001
maxEpoch	100

Tabel 1 berisi parameter-parameter yang digunakan dalam pelatihan model Learning Vector Quantization (LVQ), yang terdiri dari α , decalpha , epoch, dan akurasi yang dicapai oleh model. Parameter pertama, α , merupakan learning rate atau kecepatan pembelajaran model, dengan nilai 0.001. Learning rate ini mengatur seberapa besar perubahan yang terjadi pada bobot model setiap kali model melakukan pembelajaran terhadap data. Nilai α yang kecil dipilih untuk menghindari perubahan drastis yang dapat menyebabkan overfitting. Parameter kedua, decalpha (deca), digunakan untuk mengurangi nilai α secara bertahap di setiap iterasi atau epoch, dan dalam penelitian ini, nilainya adalah 0.7, yang berarti setiap iterasi, nilai α akan dikurangi sebesar 70% dari nilai sebelumnya.

Selanjutnya, epoch merupakan jumlah iterasi penuh yang dilakukan pada seluruh dataset. Pada penelitian ini, model LVQ dilatih selama 4 epoch, di mana setiap epoch model memperbarui bobotnya berdasarkan hasil pembelajaran sebelumnya. Hasilnya menunjukkan bahwa dengan kombinasi nilai α 0.001, decalpha 0.7, dan 4 epoch, akurasi model dalam mengklasifikasikan citra suara perut lapar dan kenyang mencapai 99%. Akurasi yang sangat tinggi ini menegaskan bahwa parameter-parameter tersebut optimal dalam mengklasifikasi kondisi perut berdasarkan citra gelombang suara.

4. HASIL DAN PEMBAHASAN

Hasil ekstraksi fitur kontras dan homogenitas untuk data latih dan data uji ditampilkan. Dari total 120 data latih yang tersedia, dipilih 20 data untuk direpresentasikan dalam Tabel 2, sedangkan keseluruhan fitur data uji juga disajikan pada Tabel 2.

Tabel 2. Hasil Ekstraksi Ciri Data Latih

NO	Data Latih	Kontras	Homogenitas
1	P1	35949193766	519272274
2	P2	35949193766	542459178
3	P3	35949193766	565646082
4	P4	58147727432	519272274
5	P5	58147727432	542459178
6	P6	58147727432	565646082
7	P7	35949193766	588832986
8	P8	35949193766	612019890
9	P9	35949193766	635206794
10	P10	58147727432	588832986
11	P11	58147727432	612019890
12	P12	58147727432	635206794
13	P13	35949193766	658393698
14	P14	35949193766	681570602
15	P15	35949193766	704747506
16	P16	58147727432	658393698
17	P17	58147727432	681570602
18	P18	58147727432	704747506
19	P19	35949193766	727924410
20	P20	35949193766	751091314

Tabel 2 menyajikan hasil ekstraksi ciri dari data latih yang dianalisis menggunakan metode Gray Level Co-Occurrence Matrix (GLCM). Pada tabel ini, beberapa fitur tekstur seperti kontras dan homogenitas yang dihasilkan dari citra gelombang suara perut lapar dan kenyang dibandingkan. GLCM digunakan untuk mengukur seberapa sering pasangan piksel dengan nilai keabuan tertentu muncul bersama dalam citra pada jarak dan arah tertentu. Nilai kontras menunjukkan perbedaan intensitas antara piksel yang berdekatan, di mana nilai yang lebih tinggi menandakan variasi intensitas yang lebih besar. Sebaliknya, homogenitas mengukur keteraturan tekstur, di mana nilai yang lebih tinggi menunjukkan tekstur yang lebih seragam atau konsisten.

Tabel 3. Hasil Ekstraksi Ciri Data Uji

No	Data Uji	Kontras	Homogenitas
1	U1	36078459898	318836790
2	U2	36078459898	332213832
3	U3	36078459898	345590874
4	U4	58147727432	542459178
5	U5	58147727432	555826220
6	U6	58147727432	569203262
7	U7	36078459898	358967916
8	U8	36078459898	372344958
9	U9	36078459898	385721990
10	U10	58147727432	582580304
11	U11	58147727432	595957346
12	U12	58147727432	609334388
13	U13	36078459898	399099022
14	U14	36078459898	412476064
15	U15	36078459898	425853106
16	U16	58147727432	622711430
17	U17	58147727432	636088472
18	U18	58147727432	649465514
19	U19	36078459898	385721990
20	U20	58147727432	582580304

Tabel 3 menyajikan data uji yang digunakan untuk mengevaluasi model yang telah dilatih menggunakan metode GLCM dan LVQ. Data uji ini terdiri dari citra gelombang suara yang berbeda dari data latih, dan digunakan untuk mengukur performa model dalam mengklasifikasikan kondisi perut lapar dan kenyang. Tabel ini memberikan gambaran tentang jumlah dan distribusi data uji yang mencakup variasi antara perut lapar dan kenyang, sehingga model dapat diuji dengan kondisi yang berbeda dari data pelatihan.

Tabel 4. Hasil Penelitian

deca	α	epoch	% Kumulatif
0.1	0.1	88	99%
	0.01	66	99%
	0.001	44	99%
0.3	0.1	26	90%
	0.01	20	90%
	0.001	13	90%
0.5	0.1	14	88%
	0.01	10	88%
	0.001	7	88%
0.7	0.1	8	99%
	0.01	6	99%
	0.001	4	99%
0.9	0.1	4	78%
	0.01	3	78%
	0.001	2	78%

Tabel 4 menunjukkan hasil akurasi data pelatihan pada tiap alfa dan dec alfa, serta menunjukkan hasil akurasi dari citra uji dengan parameter pada Tabel 1. Hasil penelitian menunjukkan bahwa parameter dengan nilai alfa (α) = 0,001 dan nilai decalfa (deca) = 0,7 pada iterasi ke-4 menghasilkan akurasi klasifikasi perut lapar dan perut kenyang yang tertinggi, yaitu 99%.

Hasil penelitian ini menunjukkan bahwa metode Hybrid GLCM dan LVQ terbukti sangat efektif dalam mengklasifikasikan kondisi perut lapar dan kenyang. Berdasarkan analisis data, parameter terbaik untuk algoritma LVQ ditemukan pada nilai *learning rate* (α) sebesar 0,001, tingkat penurunan *learning rate* (deca) sebesar 0,7, dan jumlah iterasi pelatihan (*epoch*) sebanyak 4. Kombinasi parameter tersebut menghasilkan tingkat akurasi klasifikasi tertinggi, yaitu sebesar 99%.

Proses pengumpulan data pada tabel hasil penelitian dilakukan melalui implementasi kode pemrograman di MATLAB. Kode ini dirancang untuk mengekstrak fitur suara perut menggunakan metode GLCM, yang menghasilkan nilai kontras dan homogenitas sebagai representasi tekstur dari citra gelombang suara. Hasil ekstraksi fitur ini kemudian dimasukkan ke dalam algoritma LVQ untuk pelatihan dan pengujian model klasifikasi.

Parameter seperti α , deca, dan epoch diuji secara sistematis untuk menemukan kombinasi yang memberikan performa optimal. Pada setiap kombinasi parameter, model dievaluasi menggunakan data uji, dan akurasi yang dihasilkan dicatat hingga diperoleh

konfigurasi optimal. Hasilnya, kombinasi $\alpha = 0,001$, $\text{deca} = 0,7$, dan 4 epoch terbukti menghasilkan akurasi terbaik, yaitu 99%.

Berdasarkan tabel hasil ekstraksi fitur menggunakan GLCM, nilai kontras dan homogenitas terbukti konsisten dalam membedakan kondisi perut lapar dan kenyang. Nilai kontras yang tinggi menunjukkan adanya variasi intensitas piksel yang signifikan, sedangkan homogenitas yang tinggi mencerminkan tekstur yang lebih seragam. Kedua parameter ini relevan untuk memodelkan perbedaan pola gelombang suara perut pada kedua kondisi tersebut.

Dibandingkan dengan penelitian sebelumnya, metode ini menunjukkan peningkatan akurasi yang signifikan. Penelitian lain yang menggunakan LVQ untuk klasifikasi data kompleks umumnya mencatat akurasi di kisaran 85% hingga 98%, tergantung pada domain aplikasinya. Namun, integrasi GLCM sebagai metode ekstraksi fitur tekstur dalam penelitian ini terbukti mampu meningkatkan kinerja model secara signifikan. Hal ini menunjukkan bahwa representasi tekstur dari sinyal suara memiliki peran penting dalam meningkatkan akurasi model klasifikasi.

Keunggulan lain dari metode ini adalah efisiensi proses pelatihan. Model hanya membutuhkan empat iterasi untuk mencapai konvergensi optimal, menunjukkan bahwa parameter yang dipilih memberikan kestabilan pembelajaran tanpa menyebabkan overfitting.

Metode ini memiliki potensi aplikasi yang luas, khususnya di bidang kesehatan, seperti pengembangan alat diagnostik untuk gangguan pencernaan atau sistem pemantauan nutrisi pasien. Selain itu, pendekatan ini juga dapat diadaptasi untuk aplikasi komersial, misalnya dalam bentuk aplikasi seluler yang membantu pengguna menentukan waktu makan ideal berdasarkan sinyal tubuh mereka.

Namun demikian, penelitian ini memiliki beberapa keterbatasan. Ukuran sampel yang relatif kecil menjadi salah satu kendala utama, sehingga hasil yang diperoleh mungkin belum sepenuhnya mencerminkan performa model pada populasi yang lebih besar. Studi lanjutan dengan ukuran sampel yang lebih besar dan beragam sangat diperlukan untuk memastikan bahwa metode ini dapat digeneralisasi dengan baik. Selain itu, pengujian di berbagai kondisi lingkungan juga dapat memberikan wawasan tambahan mengenai robusta metode ini dalam situasi yang lebih kompleks.

5. KESIMPULAN DAN SARAN

Penelitian yang dilakukan menunjukkan bahwa metode Hybrid Gray Level Co-Occurrence Matrix (GLCM) dan Learning Vector Quantization (LVQ) mampu mengklasifikasi kondisi perut lapar dan kenyang dengan tingkat akurasi sangat tinggi, mencapai 99% pada iterasi ke-4 dengan parameter $\text{decalfa} = 0,7$ dan $\alpha = 0,001$. Keberhasilan ini menegaskan bahwa kombinasi GLCM dan LVQ

efektif untuk memproses dan mengklasifikasikan citra gelombang suara dari organ pencernaan, memberikan kontribusi signifikan dalam pengembangan teknologi kesehatan, termasuk potensi untuk mendiagnosis gangguan pencernaan atau memantau kondisi nutrisi pasien. Selain itu, metode ini membuka peluang pengembangan aplikasi komersial untuk menentukan waktu makan optimal berdasarkan sinyal tubuh. Namun, penelitian ini memiliki keterbatasan, terutama ukuran sampel yang kecil dan fokus pada data individu tertentu, sehingga diperlukan studi lanjutan dengan data lebih bervariasi untuk meningkatkan generalisasi serta eksplorasi parameter tambahan guna meningkatkan efisiensi dan performa metode pada populasi yang lebih luas.

DAFTAR PUSTAKA

- [1] V. D. Fitriana, E. Dardjito, and W. A. K. Putri, "HUBUNGAN TINGKAT STRES DENGAN ASUPAN ZAT GIZI MAKRO DAN POLA KONSUMSI MAKANAN PADA MAHASISWI TINGKAT AKHIR," *J. Nutr. Coll.*, vol. 11, no. 3, pp. 204–210, Jul. 2022, doi: 10.14710/jnc.v11i3.32235.
- [2] I. Iswatun, E. S. Wijayanti, and A. N. Fatimatuz Z., "Asuhan Keperawatan Keluarga Nyeri Akut Pada Klien Dengan Gastritis : Studi Kasus," *SURYA J. Media Komun. Ilmu Kesehat.*, vol. 13, no. 2, pp. 212–217, Sep. 2021, doi: 10.38040/js.v13i2.255.
- [3] R. Femylati and R. Kurniasari, "PEMANFAATAN MEDIA KREATIF UNTUK EDUKASI GIZI PADA REMAJA (Literature Review)," *HEARTY*, vol. 10, no. 1, p. 16, Dec. 2021, doi: 10.32832/hearty.v10i1.4732.
- [4] K. T. Silangen, B. J. Waleleng, and F. E. N. Wantania, "Gejala Gastrointestinal pada Pasien COVID-19," *E-Clin.*, vol. 9, no. 2, p. 279, Mar. 2021, doi: 10.35790/ecl.v9i2.32851.
- [5] W. Usman, I. S. Damanik, and J. T. Hardinata, "Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) dalam Menentukan Klasifikasi Jenis Tilang Berdasarkan Kendaraan," *Pros. Semin. Nas. Ris. Inf. Sci. SENARIS*, vol. 1, pp. 780–780, Sep. 2020, doi: 10.30645/senaris.v1i0.84.
- [6] R. Yulia, A. C. Siregar, and B. C. Octariadi, "Identifikasi Ular Menggunakan Metode Gray Level Co-Occurrence Matrix Dan Histogram," *Jutisi J. Ilm. Tek. Inform. Dan Sist. Inf. Vol 13 No 2 Agustus 2024*, Aug. 2024, [Online]. Available: <http://ojs.stmik-banjarbaru.ac.id/index.php/jutisi/article/view/1964>
- [7] M. F. Arif and A. P. Arnaz, "IMPLEMENTASI METODE LEARNING VECTOR QUANTIZATION (LVQ) PADA PENGENALAN BAHASA ISYARAT YANG MENGANDUNG KATA KERJA," *JAMI J. Ahli*

- Muda Indones.*, vol. 3, no. 1, pp. 1–8, Jun. 2022, doi: 10.46510/jami.v3i1.40.
- [8] C. A. Wicaksana and D. E. T. Lufianawati, “Pengenalan Pola Vektor Tanda Tangan Citra Digital Menggunakan Metode Pembagian Wilayah dan Learning Vector Quantization (LVQ),” *Setrum Sist. Kendali-Tenaga-Elektron.-Telekomun.-Komput.*, vol. 10, no. 2, Nov. 2021, doi: 10.36055/setrum.v10i2.13054.
- [9] Z. Mushtaq, S.-F. Su, and Q.-V. Tran, “Spectral images based environmental sound classification using CNN with meaningful data augmentation,” *Appl. Acoust.*, vol. 172, p. 107581, Jan. 2021, doi: 10.1016/j.apacoust.2020.107581.
- [10] T. Nayerifard, H. Amintoosi, A. G. Bafghi, and A. Dehghantanha, “Machine Learning in Digital Forensics: A Systematic Literature Review,” 2023, *arXiv*. doi: 10.48550/ARXIV.2306.04965.
- [11] R. Mardhotillah, B. Dirgantoro, and C. Setianingsih, “Speaker Recognition for Digital Forensic Audio Analysis using Support Vector Machine,” in *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, Yogyakarta, Indonesia: IEEE, Dec. 2020, pp. 514–519. doi: 10.1109/ISRITI51436.2020.9315351.
- [12] A. Pariyandani, D. A. Larasati, E. P. Wanti, and b Muhathir, “Klasifikasi Citra Ikan Berformalin Menggunakan Metode k-NN dan GLCM,” in *Seminar Nasional Teknologi Informatika (Semantika)*, Politeknik Ganesha Medan, 2020. [Online]. Available: <https://semantika.polgan.ac.id/index.php/Semantika/article/view/49/48>
- [13] Y. Mardiana and T. U. Kalsum, “Implementation of Artificial Neural Networks with Learning Vector Quantization (LVQ) Algorithm for Detecting Fingerprint Characteristics,” *J. Komput. Inf. Dan Teknol.*, vol. 1, no. 2, Dec. 2021, doi: 10.53697/jkomitek.v1i2.432.
- [14] R. Musa and M. Akbar, “Identification of Formaldehyde Bananas using Learning Vector Quantization,” *Indones. J. Inf. Syst.*, vol. 3, no. 2, Art. no. 2, Feb. 2021, doi: 10.24002/ijis.v3i2.4110.
- [15] A. Faaizah and M. Akbar, “Sistem Klasifikasi Buah Berry Menggunakan Image Berry Dengan Metode Learning Vector Quantization,” *IKRA-ITH Inform. J. Komput. Dan Inform.*, vol. 7, no. 3, Art. no. 3, Nov. 2023, doi: 10.37817/ikraith-informatika.v7i3.3066.
- [16] Y. Sun, “Timbre-Based Portable Musical Instrument Recognition Using LVQ Learning Algorithm,” *Mob. Netw. Appl.*, vol. 28, no. 6, pp. 2171–2181, Dec. 2023, doi: 10.1007/s11036-023-02174-y.
- [17] A. Badrujaman, “Development of Android-Based Speech Recognition Application Using Learning Vector Quantization Method in Optimizing Deaf Communication,” *IJEEIT Int. J. Electr. Eng. Inf. Technol.*, vol. 5, no. 2, pp. 41–49, Sep. 2022, doi: 10.29138/ijeeit.v5i2.1889.
- [18] L. Ningsih, Agus Buono, Mushthofa, and Toto Haryanto, “Fuzzy Learning Vector Quantization for Classification of Mixed Meat Image Based on Character of Color and Texture,” *J. RESTI Rekayasa Sist. Dan Teknol. Inf.*, vol. 6, no. 3, pp. 421–429, Jun. 2022, doi: 10.29207/resti.v6i3.4067.