

Implementasi Learning Vector Quantization (LVQ) Untuk Klasifikasi Gaya Belajar

Teguh Sujana¹, Rita Novita², Haris Tri Saputra³, Agusviyanda⁴

^{1,3}Sistem Informasi, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Riau

^{2,4}Informatika Kesehatan, Fakultas Kesehatan dan Informatika, Institut Kesehatan Payung Negeri Pekanbaru

¹teguh.sujana@lecturer.unri.ac.id*, ²rita.novita@payungnegeri.ac.id, ³haristrisaputra@lecturer.unri.ac.id,

⁴agusviyanda@payungnegeri.ac.id

Abstract

Learning style is an individual's preference in acquiring, processing, and understanding new information, which is generally grouped into three main categories: visual, auditory, and kinesthetic. This study aims to develop an automatic classification method to identify students' learning styles efficiently. The Learning Vector Quantization (LVQ) algorithm is used to classify learning styles based on 100 data samples, with a network structure consisting of 36 neurons in the input layer and 3 neurons in the output layer. The implementation is carried out using MATLAB software, and the model is evaluated using accuracy metrics and Mean Square Error (MSE). Testing is carried out with various ratios of training data and test data, and the best configuration is obtained when using 90 data as training data and 10 data as test data, with a learning rate of 0.05 and 500 iterations. The results show an accuracy of 80% and a minimum MSE value of 0.12. These findings indicate that increasing the amount of training data has a positive impact on model accuracy. This research contributes to the development of an automated learning style classification system that can be integrated into educational systems to effectively support more personalized and adaptive learning strategies.

Keywords: learning styles, classification, artificial neural network, learning vector quantization, learning rate

Abstrak

Gaya belajar merupakan preferensi individu dalam memperoleh, memproses, dan memahami informasi baru, yang secara umum dikelompokkan menjadi tiga kategori utama: visual, auditori, dan kinestetik. Penelitian ini bertujuan untuk mengembangkan metode klasifikasi otomatis guna mengidentifikasi gaya belajar siswa secara efisien. Algoritma *Learning Vector Quantization* (LVQ) digunakan untuk mengklasifikasikan gaya belajar berdasarkan 100 sampel data, dengan struktur jaringan yang terdiri dari 36 neuron pada lapisan input dan 3 neuron pada lapisan output. Implementasi dilakukan menggunakan perangkat lunak MATLAB, dan model dievaluasi menggunakan metrik akurasi serta *Mean Square Error* (MSE). Pengujian dilakukan dengan berbagai rasio data latih dan data uji, dan konfigurasi terbaik diperoleh saat menggunakan 90 data sebagai data latih dan 10 data sebagai data uji, dengan *learning rate* sebesar 0.05 dan iterasi sebanyak 500. Hasil menunjukkan akurasi mencapai 80% dan nilai MSE minimum sebesar 0.12. Temuan ini menunjukkan bahwa penambahan jumlah data latih berdampak positif terhadap akurasi model. Penelitian ini memberikan kontribusi dalam pengembangan sistem klasifikasi gaya belajar otomatis yang dapat diintegrasikan ke dalam sistem pendidikan untuk mendukung strategi pembelajaran yang lebih personal dan adaptif secara efektif.

Kata kunci: gaya belajar, klasifikasi, artificial neural network, learning vector quantization, learning rate

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Gaya belajar merupakan salah satu aspek penting dalam dunia pendidikan yang menggambarkan bagaimana seorang individu memproses, memahami, dan menyimpan informasi. Gaya belajar merujuk pada pendekatan atau kebiasaan individu dalam merespons situasi belajar untuk menyerap serta mengolah informasi baru [1]. Dalam hal ini, gaya belajar tidak hanya terbatas pada preferensi sensorik, tetapi juga mencakup cara berpikir, strategi pengambilan keputusan, serta interaksi individu terhadap lingkungan belajar. Seorang siswa yang memahami gaya belajarnya akan memiliki keunggulan dalam menentukan strategi belajar yang paling efektif untuk dirinya.

Gaya ini mencerminkan bagaimana seseorang mengamati, mengingat, berpikir, dan menyelesaikan

persoalan selama proses pembelajaran [2]. Pemahaman tentang gaya belajar menjadi sangat penting, terutama bagi pendidik, karena berkaitan erat dengan efektivitas proses belajar-mengajar. Pendidik yang mampu mengenali variasi gaya belajar di dalam kelas dapat menyusun pendekatan pembelajaran yang lebih inklusif dan personal, seperti menyajikan materi dalam bentuk visual untuk siswa visual, audio untuk siswa auditori, serta memberikan praktik langsung untuk siswa kinestetik. Umumnya, gaya belajar diklasifikasikan menjadi tiga kategori utama, yaitu visual (mengandalkan penglihatan), auditori (melalui pendengaran), dan kinestetik (berbasis gerakan dan sentuhan) [3]. Klasifikasi ini sangat membantu dalam mengidentifikasi preferensi belajar siswa secara sistematis [4].

Namun, dalam praktik pendidikan, mengklasifikasikan gaya belajar banyak siswa secara manual memerlukan waktu yang panjang dan rentan terhadap kesalahan subjektif. Proses manual ini juga dapat menyebabkan ketidakakuratan dalam menentukan pendekatan pembelajaran yang optimal bagi setiap siswa. Hal ini menjadi semakin krusial ketika diterapkan dalam skala besar, seperti di sekolah dengan jumlah siswa yang tinggi atau dalam sistem pendidikan daring berbasis masif. Kebutuhan akan personalisasi pembelajaran yang efektif dan efisien menuntut adanya sistem klasifikasi yang dapat bekerja secara otomatis, cepat, dan akurat. Untuk mengatasi kendala tersebut, pendekatan berbasis teknologi, khususnya dalam ranah *soft computing*, menjadi solusi alternatif yang lebih efisien dan presisi dalam mendukung perancangan strategi pembelajaran yang adaptif berbasis data.

Salah satu metode *soft computing* yang banyak digunakan adalah Jaringan Saraf Tiruan atau *Artificial Neural Networks* (ANN) [5,6]. Implementasi ANN dalam klasifikasi gaya belajar menawarkan beberapa keunggulan, seperti kemampuan menangani kompleksitas data tinggi, toleransi terhadap ketidakpastian data, serta fleksibilitas dalam mengadaptasi parameter jaringan selama proses pelatihan. Berkat karakteristik tersebut, ANN menjadi pilihan tepat dalam pengembangan sistem klasifikasi gaya belajar yang membutuhkan akurasi tinggi, kecepatan proses, dan skalabilitas pada jumlah data siswa yang besar [7]. Seiring perkembangan teknologi dan ilmu komputer, ANN telah berkembang ke dalam berbagai arsitektur, salah satunya adalah *Learning Vector Quantization* (LVQ). LVQ merupakan salah satu varian ANN yang efektif untuk tugas klasifikasi, khususnya ketika berhadapan dengan data berskala besar dan kompleks [8]. LVQ bekerja dengan cara membentuk prototipe kelas berdasarkan data pelatihan, sehingga mampu mengenali dan mengelompokkan data baru ke dalam kelas yang sesuai [9].

Keunggulan LVQ terletak pada kemampuannya dalam menangani dataset besar dengan akurasi yang tinggi [10], serta memiliki kecepatan komputasi yang lebih tinggi dibandingkan dengan metode *Backpropagation* karena tidak memerlukan proses propagasi balik [11]. Hal ini menjadikannya metode yang efisien dari sisi waktu dan sumber daya komputasi. Selain itu, model yang dihasilkan oleh LVQ relatif lebih mudah untuk ditafsirkan dibandingkan dengan metode *deep learning* yang kompleks, sehingga sangat mendukung proses evaluasi hasil [12]. LVQ juga menunjukkan performa stabil bahkan ketika digunakan pada data dengan jumlah kelas yang banyak [13], sehingga relevan untuk klasifikasi gaya belajar yang memiliki beberapa kategori dominan seperti visual, auditori, dan kinestetik.

Berbagai studi sebelumnya menunjukkan bahwa LVQ telah digunakan secara luas di banyak bidang karena kemampuannya yang fleksibel dan akurat dalam klasifikasi. Misalnya, di sektor medis, LVQ digunakan

untuk klasifikasi kasus stroke berdasarkan parameter klinis dan kondisi patologis pasien [14], serta dalam diagnosis penyakit pada saluran pernapasan dengan mempertimbangkan fitur fisiologis dan gejala klinis [15]. Dalam bidang biomedis, metode ini diaplikasikan untuk mengklasifikasikan jenis kelamin janin dari gambar ultrasound menggunakan ekstraksi fitur berbasis citra [16]. Di ranah pendidikan, LVQ telah digunakan untuk klasifikasi isi abstrak tesis dalam sistem pengelolaan akademik [17], sedangkan dalam dunia manajemen bisnis, LVQ diterapkan untuk segmentasi pelanggan berdasarkan perilaku konsumsi [18].


Dengan latar belakang tersebut, penelitian ini berfokus pada pemanfaatan metode *Learning Vector Quantization* untuk mengklasifikasikan gaya belajar siswa. Tujuan utamanya adalah untuk mengenali pola pembelajaran individu secara otomatis, efisien, dan akurat, sebagai alternatif dari pendekatan manual yang memakan waktu. Pemanfaatan ANN dalam konteks ini diharapkan dapat mempercepat proses identifikasi gaya belajar terutama dalam skala besar seperti di institusi pendidikan atau lembaga pelatihan yang memiliki jumlah siswa yang banyak.

Selain itu, penelitian ini juga bertujuan untuk mengevaluasi performa LVQ dalam aspek akurasi klasifikasi, efisiensi waktu proses pelatihan dan pengujian, serta sensitivitas model terhadap variasi data latih. Eksperimen akan dilakukan dengan mengeksplorasi konfigurasi parameter seperti jumlah iterasi, *learning rate*, data latih, dan data uji untuk menemukan konfigurasi yang optimal dalam konteks klasifikasi gaya belajar. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan sistem pendukung keputusan berbasis AI di bidang pendidikan, khususnya untuk mendukung proses pembelajaran yang adaptif dan berbasis kebutuhan individu. Dengan demikian, strategi pembelajaran yang disesuaikan dengan gaya belajar siswa akan menjadi lebih tepat sasaran, meningkatkan motivasi belajar, serta memperbaiki hasil akademik secara keseluruhan.

Kontribusi utama (*novelty*) dari penelitian ini terletak pada penerapan algoritma LVQ untuk klasifikasi gaya belajar berbasis kuesioner VAK, yang belum banyak dikaji dalam literatur sebelumnya. Penelitian ini tidak hanya mengevaluasi performa LVQ pada data tersebut, tetapi juga menawarkan pendekatan yang aplikatif untuk diintegrasikan ke dalam sistem pendidikan digital. Implementasi sistem klasifikasi ini dapat digunakan sebagai modul pendukung dalam *platform* pembelajaran daring (*e-learning*) guna merekomendasikan strategi belajar yang sesuai secara otomatis, sehingga menciptakan pengalaman belajar yang lebih personal, adaptif, dan berbasis data. Dengan pendekatan ini, institusi pendidikan dapat melakukan transformasi digital yang lebih terarah dan berbasis kebutuhan nyata siswa dalam konteks pembelajaran modern.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengkaji efektivitas *Learning Vector Quantization* (LVQ) dalam mengklasifikasikan gaya belajar siswa. Secara umum, tahapan dalam penelitian ini terdiri dari delapan fase utama sesuai dengan alur penelitian ilmiah, yaitu: survei awal, studi literatur, pengumpulan data, analisis data, perancangan, implementasi, pengujian, serta hasil dan pembahasan.



Gambar 1. Kerangka Kerja Penelitian

Berdasarkan alur pada Gambar 1, tahapan-tahapan berikut dijelaskan sebagai berikut:

2.1. Survei Awal

Tahap ini dilakukan untuk mengidentifikasi permasalahan dalam proses pembelajaran, khususnya terkait kebutuhan personalisasi strategi pembelajaran berdasarkan gaya belajar siswa. Survei dilakukan melalui observasi langsung ke beberapa sekolah dan wawancara informal dengan guru dan siswa, guna memperoleh gambaran awal mengenai keragaman gaya belajar dan kesulitan dalam mengidentifikasinya secara manual.

Data yang diperoleh menunjukkan bahwa proses manual sangat rentan terhadap subjektivitas, membutuhkan waktu lama, dan kurang efisien dalam skala besar. Hal ini memperkuat kebutuhan akan solusi berbasis komputasi yang mampu mengotomatisasi identifikasi gaya belajar secara akurat. Survei ini juga memberikan masukan awal mengenai jenis data yang relevan untuk dianalisis serta bagaimana sistem klasifikasi dapat membantu guru dalam pengambilan keputusan pembelajaran yang lebih adaptif.

2.2. Studi Literatur.

Peneliti melakukan telaah pustaka dari berbagai jurnal ilmiah, buku, dan laporan penelitian sebelumnya yang berkaitan dengan teori gaya belajar, metode klasifikasi berbasis *Artificial Neural Networks* (ANN), serta penerapan *Learning Vector Quantization* (LVQ) di berbagai domain. Studi literatur ini menjadi landasan untuk merancang sistem klasifikasi yang relevan dan memperkuat dasar teoritis penelitian.

Dalam LVQ, salah satu komponen utama yang digunakan adalah perhitungan jarak *Euclidean*. Konsep dasar ini digunakan untuk mengukur kedekatan antara data input X_i dan bobot neuron W_j , yang berperan dalam menentukan neuron atau prototipe terdekat sebagai representasi dari kelas tertentu. Setelah neuron terdekat teridentifikasi, bobot W_j akan diperbarui tergantung pada hasil klasifikasi. Jika klasifikasi benar, bobot akan disesuaikan agar lebih mendekati input; jika salah, bobot akan dijauhkan dari input. Strategi ini bertujuan meningkatkan kemampuan diskriminatif jaringan.

Lebih lanjut, literatur juga menekankan pentingnya pengaturan nilai learning rate α secara adaptif, yang secara bertahap dikurangi selama proses pelatihan untuk memastikan stabilitas model dan mempercepat konvergensi tanpa fluktuasi signifikan.

Berbagai penelitian sebelumnya menunjukkan bahwa LVQ telah banyak diterapkan dalam klasifikasi di berbagai bidang, seperti medis, biomedis, bisnis, dan pendidikan. Namun, berdasarkan telaah literatur yang dilakukan, ditemukan bahwa penerapan LVQ untuk klasifikasi gaya belajar secara otomatis berbasis kuesioner VAK masih sangat terbatas. Sebagian besar pendekatan masih menggunakan metode manual atau algoritma klasifikasi lain seperti *Decision Tree* atau *K-Nearest Neighbor* tanpa eksplorasi mendalam terhadap struktur jaringan ANN yang lebih efisien seperti LVQ. Selain itu, belum banyak penelitian yang mengevaluasi performa LVQ dengan konfigurasi parameter yang bervariasi secara sistematis dalam konteks pendidikan.

Oleh karena itu, gap utama dalam studi ini adalah belum adanya kajian yang secara spesifik menerapkan dan mengevaluasi metode LVQ untuk klasifikasi gaya belajar berbasis kuesioner VAK dengan pendekatan eksperimen parameter yang menyeluruh serta pengaitan langsung dengan sistem pembelajaran digital adaptif. Gap ini menjadi dasar urgensi dan arah kontribusi penelitian yang dilakukan.

2.3. Pengumpulan Data

Data primer diperoleh melalui penyebaran kuesioner gaya belajar berbasis model VAK (*Visual, Auditory, Kinesthetic*) kepada siswa tingkat sekolah menengah atas dari beberapa institusi pendidikan yang berbeda. Kuesioner ini disusun berdasarkan indikator-indikator spesifik yang merepresentasikan preferensi belajar, seperti kecenderungan terhadap ketertarikan visual, pendengaran, atau aktivitas fisik. Jawaban siswa dari

kuesioner tersebut kemudian dikodekan dalam format numerik agar dapat diolah lebih lanjut dalam sistem komputasi.

Total responden yang dijadikan sampel dalam penelitian ini dipilih secara acak menggunakan pendekatan *purposive sampling*, dengan mempertimbangkan keberagaman gaya belajar yang diharapkan dapat memperkaya variasi data. Data hasil kuesioner ini berisi 36 variabel input yang menggambarkan karakteristik masing-masing siswa, dan satu variabel target yang menunjukkan klasifikasi gaya belajar (*Visual, Auditory, atau Kinesthetic*).

Pada tahap ini, data yang telah dikodekan menjadi masukan utama dalam penerapan metode *Learning Vector Quantization* (LVQ). Untuk keperluan klasifikasi, setiap data input akan dihitung jarak Euclidean-nya terhadap bobot neuron yang ada, guna menentukan representasi kelas yang paling mendekati karakteristik responden.

Setelah jarak *Euclidean* dihitung, bobot terdekat W_j akan ditentukan dan diperbarui berdasarkan hasil klasifikasi. Proses ini diikuti dengan pengurangan nilai *learning rate* α secara bertahap untuk menjaga kestabilan pembelajaran model. Tahapan ini memastikan bahwa model yang dikembangkan dapat belajar dari pola data yang tersedia secara optimal sebelum memasuki proses analisis lebih lanjut.

2.4. Analisis Data

Proses analisis data dilakukan menggunakan algoritma *Learning Vector Quantization* (LVQ). Tahapan analisis disusun secara sistematis sebagai berikut:

a. Konversi Input Numerik

Setiap pernyataan pada kuesioner dikodekan ke dalam bentuk numerik untuk dapat diproses oleh model jaringan saraf. Proses ini melibatkan normalisasi nilai agar berada dalam rentang yang sesuai untuk pembelajaran mesin.

b. Perhitungan Jarak *Euclidean*

Untuk setiap data input X_i , dilakukan perhitungan jarak *Euclidean* terhadap seluruh bobot neuron W_j menggunakan rumus:

$$d_j = \sqrt{\sum_{i=1}^n (X_i - W_{ji})^2} \quad (1)$$

Tujuan langkah ini adalah menentukan neuron representatif yang paling dekat dengan data input.

c. Identifikasi Bobot Terdekat (*Winning Neuron*)

Bobot dengan jarak terkecil terhadap data input dipilih sebagai representasi kelas target. Neuron tersebut dikenal sebagai "*winning neuron*".

d. Pembaruan Bobot (*Weight Update*)

Jika kelas prediksi sesuai dengan kelas target, maka bobot diperbarui agar lebih mendekati data input.

Sebaliknya, jika prediksi salah, bobot dijauhkan dari input. Rumus pembaruan bobot:

$$W_j^{new} = W_j^{old} + \alpha(X_i - W_j^{old}) \quad (2)$$

Atau

$$W_j^{new} = W_j^{old} - \alpha(X_i - W_j^{old}) \quad (3)$$

e. Penyesuaian *Learning Rate* (α)

Nilai *learning rate* diturunkan secara bertahap pada setiap iterasi untuk memastikan model konvergen secara stabil. Proses ini berlanjut hingga α mencapai batas minimum α_{min} .

f. Evaluasi Model

Setelah pembelajaran selesai, bobot akhir digunakan untuk mengklasifikasikan data uji. Kinerja model dievaluasi berdasarkan metrik akurasi dan *Mean Square Error* (MSE).

Tabel 1 berikut merinci variabel input (X_1 – X_{36}) dan deskripsinya. Variabel-variabel ini merefleksikan preferensi gaya belajar yang menjadi dasar klasifikasi oleh sistem.

Tabel 1. Variabel yang mempengaruhi kelompok Gaya Belajar

Variable	Description
X_1	<i>I prefer listening to information rather than reading books.</i>
X_2	<i>When doing something, I prefer reading the instructions first.</i>
X_3	<i>I prefer reading over listening to explanations.</i>
X_4	<i>When I'm alone, I usually play music or sing.</i>
X_5	<i>I prefer exercising rather than reading books.</i>
X_6	<i>I can always point out north or south wherever I am.</i>
X_7	<i>I prefer writing letters, journals, or diaries.</i>
X_8	<i>When others speak, I often say "I hear you, that sounds good."</i>
X_9	<i>My room, desk, car, or house is usually messy/disorganized.</i>
X_{10}	<i>I enjoy designing, building, and creating things with my hands.</i>
X_{11}	<i>I almost know all the songs I hear.</i>
X_{12}	<i>When listening to others, I usually visualize what they are saying in my mind.</i>
X_{13}	<i>I enjoy sports and consider myself good at it.</i>
X_{14}	<i>I find it easy to have long conversations on the phone with friends.</i>
X_{15}	<i>Life would be boring without music.</i>
X_{16}	<i>I love socializing and can easily talk to anyone.</i>
X_{17}	<i>When I see an image, I can easily recognize the same object even if it's rotated/changed.</i>
X_{18}	<i>I usually say, "I think I need to find a solid foundation for this" or "I want to manage this properly."</i>
X_{19}	<i>When I recall an experience, I often see it as an image in my mind.</i>
X_{20}	<i>When remembering an experience, I often hear myself talking about it in my mind.</i>
X_{21}	<i>When recalling an experience, I often remember how I felt about it.</i>
X_{22}	<i>I prefer music over painting.</i>
X_{23}	<i>I often doodle on paper while talking on the phone or in meetings.</i>

X_{24}	<i>I prefer doing demonstrations rather than writing a report about an event.</i>
X_{25}	<i>I prefer reading stories aloud rather than listening to them.</i>
X_{26}	<i>I usually speak slowly.</i>
X_{27}	<i>I prefer speaking over writing.</i>
X_{28}	<i>My handwriting is usually messy.</i>
X_{29}	<i>I usually use my finger to point at the sentences I'm reading.</i>
X_{30}	<i>I can quickly do addition and multiplication in my mind.</i>
X_{31}	<i>I like spelling and I'm good at it.</i>
X_{32}	<i>I get distracted if someone talks while I'm watching TV.</i>
X_{33}	<i>I like taking notes of instructions given to me.</i>
X_{34}	<i>I can easily remember what people say.</i>
X_{35}	<i>I learn best by doing or practicing.</i>
X_{36}	<i>I find it very hard to sit still for long periods.</i>
Y	<i>Learning Style Result (Auditory, Visual, Kinesthetic)</i>

Pada tabel 1, variabel-variabel X merupakan variabel yang ditetapkan sebagai variabel *input*. Sedangkan variabel Y yang merupakan kelompok gaya belajar yang ditetapkan sebagai variabel target. Data tersebut kemudian diolah dengan menggunakan metode LVQ yang terdiri atas [19].

a. Inisialisasi bobot awal (W_{ij}), *learning rate* (α), nilai *minimal* $\alpha_{\min}$, dan *epoch*. Masukkan data *input* dan target.
b. Selama $\alpha \geq \alpha_{\min}$, lakukan: langkah pertama yang dilakukan adalah menghitung jarak Euclidean antara data input X_i dan bobot neuron W_j untuk menentukan tingkat kedekatan masing-masing neuron terhadap data tersebut. Setelah itu, bobot terdekat W_j dipilih sebagai representasi kelas yang paling sesuai dengan input. Kemudian, dilakukan pembaruan bobot berdasarkan hasil klasifikasi, di mana bobot diperbaiki agar lebih mendekati data input jika klasifikasinya benar, atau dijauhkan apabila klasifikasinya salah. Selanjutnya, nilai *learning rate* α dikurangi secara bertahap untuk memperkecil perubahan bobot pada setiap iterasi, sehingga mendukung konvergensi model menuju kestabilan yang optimal.

c. Gunakan bobot akhir W untuk pengujian data baru dan klasifikasi berdasarkan jarak minimum.

2.5. Perancangan

Perancangan sistem dilakukan dengan membangun arsitektur Jaringan Syaraf Tiruan menggunakan algoritma pembelajaran *Learning Vector Quantization* (LVQ). Jaringan ini bersifat kompetitif, di mana setiap neuron output merepresentasikan satu kelas gaya belajar (Visual, Auditori, atau Kinestetik). Input yang masuk akan bersaing untuk dikelompokkan ke dalam salah satu kelas tersebut.

Arsitektur jaringan LVQ yang dirancang meliputi komponen sebagai berikut:


a. *Input layer*: Terdiri dari 36 neuron yang merepresentasikan 36 variabel input dari hasil kuesioner VAK.

b. *Output layer*: Terdiri dari 3 neuron, masing-masing mewakili kelas gaya belajar: Visual, Auditori, dan Kinestetik.

c. Bobot (W): Terdapat tiga vektor bobot utama (W_1 , W_2 , W_3) yang menghubungkan setiap neuron input dengan neuron output.

Fungsi aktivasi: Digunakan fungsi aktivasi linier yang bertujuan meneruskan nilai input ke output tanpa transformasi non-linier. Dalam konteks LVQ, fungsi aktivasi ini memfasilitasi pemilihan neuron output berdasarkan kedekatan (jarak minimum) terhadap vektor bobot, sehingga proses klasifikasi dapat berjalan secara langsung dan efisien.

Gambar 2 menunjukkan struktur arsitektur jaringan LVQ yang digunakan dalam penelitian ini [20]:



Gambar 2. Arsitektur Jaringan LVQ untuk Klasifikasi Gaya Belajar

Langkah selanjutnya adalah pembagian data untuk keperluan pelatihan (*training*) dan pengujian (*testing*). Proporsi data didasarkan pada distribusi kelompok gaya belajar sebagai berikut:

- Data latih (*training*)
 - Visual: 60 data
 - Auditori: 70 data
 - Kinestetik: 90 data
- Data Uji (*Testing*)
 - Visual: 40 data
 - Auditori: 30 data
 - Kinestetik: 10 data

Data latih digunakan untuk membentuk pola klasifikasi dalam model, sedangkan data uji digunakan untuk mengevaluasi akurasi sistem dalam mengidentifikasi gaya belajar berdasarkan input baru. Proses pengujian ini bertujuan untuk memastikan performa model pada kondisi nyata dan variatif.

2.6. Implementasi

Implementasi sistem dilakukan dengan mengaplikasikan algoritma *Learning Vector Quantization* (LVQ) menggunakan perangkat lunak MATLAB versi R2022a. MATLAB dipilih karena fleksibilitasnya dalam pengolahan data numerik, dukungan penuh terhadap fungsi jaringan saraf tiruan, dan kemudahan dalam visualisasi hasil evaluasi, sehingga mempercepat proses pengembangan dan pengujian model.

Tahapan implementasi diawali dengan pemrograman arsitektur jaringan LVQ yang terdiri dari 36 *neuron* pada lapisan input dan 3 *neuron* pada lapisan *output*, sesuai dengan jumlah fitur dan kelas target. Bobot awal diinisialisasi secara acak, dan proses pelatihan dilakukan dengan iterasi sejumlah epoch yang telah ditentukan. Data latih digunakan untuk mengoptimalkan bobot jaringan melalui perhitungan jarak Euclidean dan pembaruan bobot berdasarkan hasil klasifikasi.

Berikut adalah pseudocode pelatihan LVQ yang digunakan dalam proses implementasi:

```
Pseudocode 1. Pelatihan LVQ
Inisialisasi bobot w secara acak
Tentukan  $\alpha$  (learning rate),  $\alpha_{min}$ , dan jumlah epoch
Selama  $\alpha \geq \alpha_{min}$  dan epoch belum selesai:
    Untuk setiap data latih  $x_i$ :
        Hitung jarak Euclidean antara  $x_i$  dan seluruh  $w_j$ 
        Pilih neuron  $w_j$  terdekat
        Jika kelas prediksi = kelas target:
             $w_j = w_j + \alpha * (x_i - w_j)$ 
        Else:
             $w_j = w_j - \alpha * (x_i - w_j)$ 
        kurangi nilai  $\alpha$  secara bertahap
    Simpan bobot akhir
Gunakan bobot akhir untuk mengklasifikasi data uji
```

Setelah proses pelatihan selesai, model diuji menggunakan data uji yang telah disiapkan. Hasil klasifikasi dari model dibandingkan dengan hasil klasifikasi aktual (berbasis kuesioner VAK) untuk mengukur performa model. Evaluasi dilakukan menggunakan beberapa metrik:

- Akurasi: Persentase data uji yang diklasifikasikan dengan benar.
- Mean Square Error (MSE): Mengukur rata-rata kuadrat selisih antara output yang diprediksi dan target.
- Waktu pelatihan: Durasi proses pelatihan sampai konvergen.
- Stabilitas klasifikasi: Konsistensi hasil pada variasi parameter seperti epoch dan learning rate.

Evaluasi model menunjukkan bahwa LVQ tidak hanya mampu memberikan hasil klasifikasi yang akurat, tetapi juga cukup efisien dari segi waktu pelatihan. Selain itu, proses pelatihan menunjukkan konvergensi yang stabil pada pengaturan parameter tertentu, memperkuat kelayakan algoritma ini untuk diintegrasikan ke dalam sistem klasifikasi gaya belajar berbasis teknologi.

3. Hasil dan Pembahasan

Bab ini menyajikan hasil implementasi dan evaluasi dari metode *Learning Vector Quantization* (LVQ) dalam klasifikasi gaya belajar berdasarkan data kuesioner VAK (Visual, Auditori, Kinestetik). Evaluasi dilakukan terhadap berbagai konfigurasi data latih dan data uji serta parameter pelatihan untuk mengukur performa model secara menyeluruh.

3.1. Konfigurasi Pengujian

Dataset dibagi menjadi tiga konfigurasi untuk mengevaluasi pengaruh jumlah data latih terhadap akurasi klasifikasi:

- 60 data untuk pelatihan dan 40 data untuk pengujian,
- 70 data untuk pelatihan dan 30 data untuk pengujian,
- 90 data untuk pelatihan dan 10 data untuk pengujian.

Setiap konfigurasi diuji dengan berbagai kombinasi parameter, termasuk nilai learning rate (α) sebesar 0.01, 0.02, 0.03, 0.04, dan 0.05, serta jumlah iterasi sebanyak 500.

3.2. Hasil Pengujian dan Visualisasi

Berikut ini merupakan hasil pengujian yang dapat dilihat pada tabel 2, tabel 3, tabel 4, dan gambar 3.

Tabel 2. Hasil Pengujian 60 data uji dan 40 data latih

No	Epoch	Learning Rate	Jumlah Benar	Jumlah Salah	Akurasi
1	500	0.05	22	18	55%
2	500	0.04	23	17	57,5%
3	500	0.03	18	22	45%
4	500	0.02	21	19	52,5%
5	500	0.01	22	18	55%

Tabel 2 menyajikan hasil klasifikasi dengan proporsi 60 data latih dan 40 data uji. Akurasi tertinggi tercapai pada learning rate 0.04 yaitu sebesar 57.5%, sementara nilai terendah terdapat pada learning rate 0.03 (45%). Hal ini menunjukkan bahwa model belum mampu mengenali pola secara optimal karena jumlah data latih yang relatif kecil. Fluktuasi akurasi pada konfigurasi ini menandakan bahwa model masih belum stabil terhadap perubahan parameter.

Tabel 3. Hasil Pengujian 70 data uji dan 30 data latih

No	Epoch	Learning Rate	Jumlah Benar	Jumlah Salah	Akurasi
1	500	0.05	23	7	76,7%


2	500	0.04	23	7	76,7%
3	500	0.03	22	8	73,3%
4	500	0.02	22	8	73,3%
5	500	0.01	22	8	73,3%

Tabel 3 menunjukkan peningkatan performa signifikan dibandingkan Tabel 2. Pada proporsi 70 data latih dan 30 data uji, akurasi tertinggi tercapai sebesar 76.7% pada learning rate 0.04 dan 0.05. Performa model lebih stabil, terbukti dari akurasi yang seragam pada nilai learning rate 0.01 hingga 0.03 (73.3%). Ini menunjukkan bahwa dengan lebih banyak data latih, model memiliki kemampuan generalisasi yang lebih baik.

Tabel 4. Hasil Pengujian 90 data uji dan 10 data latih

No	Epoch	Learning Rate	Jumlah Benar	Jumlah Salah	Akurasi
1	500	0.05	8	2	80%
2	500	0.04	8	2	80%
3	500	0.03	8	2	80%
4	500	0.02	8	2	80%
5	500	0.01	8	2	80%

Tabel 4 merepresentasikan konfigurasi terbaik dari seluruh pengujian. Dengan 90 data latih dan hanya 10 data uji, model *consistently* menghasilkan akurasi sebesar 80% pada semua nilai learning rate. Hal ini menandakan bahwa model sangat mampu mengenali pola klasifikasi saat diberi cukup data pelatihan. Nilai MSE yang relatif rendah dan stabil (rata-rata 0.233) juga memperkuat kesimpulan bahwa model telah mencapai performa optimal. Namun, perlu kehati-hatian karena ukuran data uji yang kecil dapat menyebabkan bias akurasi.



Gambar 3. Grafik Akurasi Vs Learning Rate Pada Berbagai Konfigurasi

Gambar 3 menggambarkan hubungan antara learning rate dan akurasi model pada ketiga konfigurasi data. Garis tren menunjukkan bahwa peningkatan jumlah data latih menyebabkan akurasi model meningkat dan menjadi lebih stabil terhadap perubahan learning rate. Pada konfigurasi 60:40, akurasi cenderung fluktuatif dan rendah. Sementara pada konfigurasi 90:10, kurva akurasi datar di level 80%, menandakan kestabilan model.

3.3 Analisis Hasil

Hasil menunjukkan bahwa peningkatan jumlah data latih memberikan dampak positif terhadap akurasi

model. Pada konfigurasi 60:40, akurasi maksimum hanya 57.5%. Pada konfigurasi 70:30, akurasi meningkat hingga 76.7%. Konfigurasi terbaik diperoleh pada 90:10 dengan akurasi konstan 80% untuk seluruh nilai learning rate.

a. Pengaruh Jumlah Data Latih

Hasil menunjukkan bahwa peningkatan jumlah data latih memberikan dampak positif terhadap akurasi model. Pada konfigurasi 60:40, akurasi maksimum hanya 57.5%. Pada konfigurasi 70:30, akurasi meningkat hingga 76.7%. Konfigurasi terbaik diperoleh pada 90:10 dengan akurasi konstan 80% untuk seluruh nilai learning rate.

b. Pengaruh *learning Rate*

Learning rate yang lebih besar (0.04 dan 0.05) cenderung menghasilkan akurasi lebih tinggi. Nilai learning rate yang terlalu kecil (misal 0.01–0.02) memperlambat konvergensi dan berpotensi menghambat pembelajaran optimal.

c. Evaluasi Berdasarkan Gaya Belajar

Analisis hasil klasifikasi per kelas menunjukkan bahwa gaya belajar visual dan auditori lebih sering diprediksi secara akurat dibandingkan kinestetik. Ini kemungkinan disebabkan oleh distribusi data latih yang tidak seimbang.

d. Rata-rata dan Standar Deviasi

- Rata-rata Akurasi (Konfigurasi 90:10): 80.0%
- Standar Deviasi Akurasi: 0.00

Nilai standar deviasi yang nol menunjukkan bahwa akurasi model tidak berubah di seluruh nilai learning rate. Meski tampak ideal, hal ini patut dicurigai sebagai anomali karena jumlah data uji yang terlalu kecil (10 data). Jumlah ini tidak cukup untuk menampilkan variasi hasil yang realistis, sehingga evaluasi perlu dilakukan pada dataset yang lebih besar untuk memperoleh gambaran performa yang valid.

e. Potensi *Overfitting* dan Validitas

Akurasi yang stabil pada konfigurasi 90:10 kemungkinan besar dipengaruhi oleh ukuran data uji yang sangat kecil, sehingga fluktuasi tidak tampak. Tidak menutup kemungkinan terjadi overfitting karena model sangat disesuaikan terhadap data latih.

f. Uji Ulang Konsistensi

Pengujian ulang sebanyak lima kali menunjukkan hasil akurasi bervariasi hanya antara 78% hingga 80%, menandakan bahwa model relatif konsisten meskipun tetap perlu validasi lebih besar di masa depan.

Dari hasil pengujian yang dilakukan dapat dilihat bahwa:

- Model LVQ berhasil mencapai akurasi terbaik 80% pada konfigurasi 90:10 dengan MSE rata-rata 0.233.

- Pembagian data latih yang lebih besar dan learning rate 0.04–0.05 direkomendasikan untuk performa optimal.
- Diperlukan dataset lebih besar untuk menghindari bias hasil uji dan memastikan generalisasi model lebih luas.

4. Kesimpulan

Berdasarkan penjabaran dan hasil pengujian yang telah dijelaskan pada bab-bab sebelumnya, maka dapat disimpulkan bahwa penelitian ini bertujuan untuk mengembangkan sistem klasifikasi gaya belajar berbasis algoritma *Learning Vector Quantization* (LVQ), guna membantu proses identifikasi preferensi belajar siswa secara otomatis, cepat, dan akurat.

Dari hasil pengujian, dapat disimpulkan bahwa:

a. Algoritma LVQ mampu melakukan klasifikasi gaya belajar siswa berdasarkan data kuesioner VAK dengan akurasi tertinggi mencapai 80% pada konfigurasi 90 data latih dan 10 data uji, serta menghasilkan rata-rata nilai *Mean Square Error* (MSE) sebesar 0,233.

b. LVQ menunjukkan performa yang stabil pada konfigurasi data latih yang besar, khususnya dengan nilai learning rate antara 0.04 hingga 0.05. Namun, kestabilan ini belum sepenuhnya dapat diandalkan karena ukuran data uji yang relatif kecil, yang berpotensi menyebabkan bias evaluasi.

c. Penelitian ini menunjukkan efektivitas metode LVQ dalam pengklasifikasian gaya belajar, namun efektivitas tersebut masih terbatas dalam konteks data berskala kecil dan distribusi kelas yang tidak seimbang.

Keterbatasan penelitian ini terletak pada jumlah data yang masih terbatas, tidak dilakukannya perbandingan dengan metode klasifikasi lain, serta belum dilakukan pengujian lanjutan pada data yang lebih beragam dan representatif. Selain itu, stabilitas hasil pada data uji yang sangat kecil (10 data) masih perlu divalidasi dengan skenario pengujian yang lebih luas.

Potensi aplikasi nyata dari sistem ini sangat relevan untuk diterapkan dalam lingkungan pendidikan, seperti sistem manajemen pembelajaran (*Learning Management System/LMS*) atau *platform e-learning*, yang dapat secara otomatis merekomendasikan metode pengajaran sesuai gaya belajar siswa. Hal ini dapat meningkatkan efektivitas pembelajaran personalisasi dan mendukung pendekatan adaptif dalam pengajaran berbasis teknologi.

Sebagai tindak lanjut, saran untuk penelitian selanjutnya meliputi:

a. Melakukan komparasi antara metode LVQ dengan algoritma klasifikasi lain seperti KNN, SVM, atau *Random Forest* untuk mengevaluasi efektivitas secara komprehensif.

b. Menggunakan jumlah data latih dan uji yang lebih besar dan seimbang antar kelas, agar model mampu

melakukan generalisasi yang lebih baik dan dapat digunakan dalam sistem nyata secara andal.

Daftar Rujukan

- [1] M. N. Harahap, "Tinjauan Gaya Belajar dan Model Pembelajaran Dalam Peningkatan Prestasi Belajar Siswa," *MANHAJ: Jurnal Ilmu Pengetahuan, Sosial Budaya dan Kemasyarakatan*, vol. 2, no. 2, pp. 55–67, 2023.
- [2] D. M. Arumsari, "Analisis Gaya Belajar Siswa Terhadap Hasil Belajar Pada Mata Pelajaran IPAS," *LEARNING: Jurnal Inovasi Penelitian Pendidikan dan Pembelajaran*, vol. 3, no. 1, pp. 111–119, 2023, doi: 10.51878/learning.v3i1.2118.
- [3] L. Rahmawati and S. Gumiandari, "Identifikasi Gaya Belajar (Visual, Auditorial dan Kinestetik) Mahasiswa Tadris Bahasa Inggris Kelas 3F lain Syekh Nurjati Cirebon," *Pedagogik Jurnal Pendidikan*, vol. 16, no. 1, pp. 54–61, 2021, doi: 10.33084/pedagogik.v16i1.1876.
- [4] Hidayatunnisa, Kusriani, and Kusnawi, "Perbandingan Kinerja Metode Naive Bayes dan Support Vector Machine dalam Analisis Soal," *Jurnal FASILKOM*, vol. 13, no. 2, pp. 173–180, 2023, doi: 10.37859/jf.v13i02.5087.
- [5] A. I. Sakti *et al.*, "Implementasi Artificial Neural Network (ANN) dalam Memprediksi Nilai Tukar Rupiah terhadap Dolar Amerika," *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 12, no. 2, pp. 124–130, Nov. 2024, doi: 10.37905/euler.v12i2.26654.
- [6] H. D. Bhakti, "Aplikasi Artificial Neural Network (ANN) untuk Memprediksi Masa Studi Mahasiswa Program Studi Teknik Informatika Universitas Muhammadiyah Gresik," *Eksplora Informatika*, vol. 9, no. 1, pp. 88–95, Sep. 2019, doi: 10.30864/eksplora.v9i1.234.
- [7] Hidayatunnisa, Kusriani, and Kusnawi, "Perbandingan Kinerja Metode Naive Bayes dan Support Vector Machine dalam Analisis Soal," *Jurnal FASILKOM*, vol. 13, no. 2, pp. 173–180, 2023, doi: 10.37859/jf.v13i3.6292.
- [8] E. Setyowati and S. Mariani, "Penerapan Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) Untuk Klasifikasi Penyakit Infeksi Saluran Pernapasan Akut (ISPA)," *Matematika*, in *PRISMA, Prosiding Seminar Nasional*, 2021, pp. 514–523. [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [9] F. Alamri, S. Ningsih, I. Djakaria, D. Wungguli, and I. K. Hasan, "Perbandingan Metode LVQ dan Backpropagation Untuk Klasifikasi Status Gizi Anak Di Kecamatan Sangkup," *Jurnal Gaussian*, vol. 12, no. 3, pp. 314–321, Sep. 2023, doi: 10.14710/j.gauss.12.3.314-321.
- [10] E. Budianita and W. Prijodiprodjo, "Penerapan Learning Vector Quantization (LVQ) untuk Klasifikasi Status Gizi Anak," *IJCCS*, vol. 7, no. 2, pp. 155–166, 2013, doi: 10.22146/ijccs.3354.
- [11] J. Gea, "Implementasi Algoritma Learning Vector Quantization Untuk Pengenalan Barcode Barang," *Journal of Informatics, Electrical and Electronics Engineering*, vol. 2, no. 1, pp. 1–4, 2022, doi: 10.47065/jieee.v2i1.385.
- [12] E. Setyowati and S. Mariani, "Penerapan Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) Untuk Klasifikasi Penyakit Infeksi Saluran Pernapasan Akut (ISPA).," in *PRISMA, Prosiding Seminar Nasional Matematika*, 2021, pp. 514–523. [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [13] A. Aziz, F. Insani, J. Jasril, and F. Syafria, "Implementasi Metode Learning Vector Quantization (LVQ) Untuk Klasifikasi Keluarga Beresiko Stunting," *Building of Informatics, Technology and Science (BITS)*, vol. 5, no. 1, pp. 12–20, Jun. 2023, doi: 10.47065/bits.v5i1.3478.
- [14] P. Melani, A. Batubara, I. Afrianty, S. Sanjaya, and F. Syafria, "Klasifikasi Penyakit Stroke Jaringan Syaraf Tiruan Menerapkan Metode Learning Vector Quantization," *Jurnal Informatika Universitas Pamulang*, vol. 8, no. 2, pp. 223–228, 2023, doi: 10.32493/informatika.v7i2.31359.
- [15] A. R. Yanti and S. N. Endah, "Aplikasi Deteksi Dini Gangguan Sistem Pernafasan Menggunakan Metode Learning Vector Quantization (LVQ) Berbasis Web," *Sukmawati N Endah*

-
- Jurnal Masyarakat Informatika*, vol. 7, no. 1, pp. 55–65, 2016, doi: 10.14710/jmasif.7.1.10134.
- [16] E. Sivari, Z. Civelek, and S. Sahin, “Determination and classification of fetal sex on ultrasound images with deep learning,” *Expert Syst Appl*, vol. 240, pp. 1–13, Apr. 2024, doi: 10.1016/j.eswa.2023.122508.
- [17] F. R. Hariri, E. Utami, and A. Amborowati, “Learning Vector Quantization untuk Klasifikasi Abstrak Tesis,” *Citec Journal*, vol. 2, no. 2, pp. 128–143, 2015.
- [18] A. B. Pratama, E. Budianita, N. Yanti, R. Mai Candra, and T. Informatika UIN Sultan Syarif Kasim Riau Jl Subrantas Km, “Implementasi Metode Learning Vector Quantization (LVQ) Untuk Sentimen Analisis Terhadap Aplikasi Go-Jek Pada Playstore,” *Jurnal Nasional Komputasi dan Teknologi Informasi*, vol. 5, no. 3, pp. 364–373, 2022, doi: 10.32672/jnkti.v5i3.4287.
- [19] M. F. Arif and A. A. Pramana, “Implementasi Metode Learning Vector Quantization (LVQ) Pada Pengenalan Bahasa Isyarat yang Mengandung Kata Kerja,” *JAMI: Jurnal Ahli Muda Indonesia*, vol. 3, no. 1, pp. 1–8, Jun. 2022, doi: 10.46510/jami.v3i1.40.
- [20] A. Saleh, M. Harahap, and E. Indra, “Kombinasi Jaringan Learning Vector Quantization Dan Normalized Cross Correlation Pada Pengenalan Wajah,” *Junal Sistem Informasi Ilmu Komputer Prima*, vol. 3, no. 2, pp. 13–0, Feb. 2020, doi: 10.34012/jusikom.v3i2.851.