

# A Classification Model of Children's Digital Device Dependency Based on the Learning Vector Quantization (LVQ) Algorithm

Gellysa Urva<sup>1\*</sup>, Refdinal Nazir<sup>2</sup>

<sup>1</sup>Teknik Informatika, Sekolah Tinggi Teknologi Dumai, Dumai, 28811, Indonesia

<sup>2</sup>Teknik Elektro, Fakultas Teknik, Universitas Andalas, Padang, 25175, Indonesia

## Informasi Artikel

Diterima : 27 Oktober 2025  
Revisi : 01 November 2025  
Publikasi : 31 Desember 2025

## Kata Kunci:

Ketergantungan  
Perangkat Digital  
Anak  
Klasifikasi  
LVQ

## ABSTRAK

Ketergantungan terhadap perangkat digital pada anak menjadi isu penting di era modern karena dapat memengaruhi aspek kognitif, sosial, dan kesehatan. Anak-anak yang terlalu sering menggunakan perangkat digital berpotensi mengalami penurunan konsentrasi, prestasi akademik, serta interaksi sosial. Identifikasi tingkat ketergantungan anak selama ini masih dilakukan secara manual melalui observasi orang tua atau guru yang bersifat subjektif. Oleh karena itu, penelitian ini bertujuan untuk membangun model klasifikasi tingkat ketergantungan perangkat digital anak dengan menerapkan algoritma *Learning Vector Quantization* (LVQ). Data penelitian diperoleh dari hasil penyebaran kuesioner kepada 110 responden yang merupakan orang tua siswa sekolah dasar di Kota Dumai. Kuesioner terdiri atas 34 butir pertanyaan menggunakan skala Likert 1–5. Data yang diperoleh diolah menggunakan bahasa pemrograman Python dengan pustaka *NumPy*, *Pandas*, *Matplotlib*, *Scikit-learn*, dan *Neupy*. Hasil pengujian menunjukkan bahwa algoritma LVQ mampu melakukan klasifikasi tingkat ketergantungan anak ke dalam tiga kategori *ringan*, *sedang*, dan *berat* dengan tingkat akurasi sebesar 87,5%, presisi rata-rata 85,4%, dan recall rata-rata 86,2%.

Hasil penelitian menunjukkan bahwa sebagian besar anak termasuk dalam kategori ketergantungan *sedang* dengan skor rata-rata 3,03. Faktor utama yang memengaruhi ketergantungan meliputi durasi penggunaan perangkat digital, kebiasaan menggunakan perangkat saat makan atau menjelang tidur, serta menurunnya interaksi sosial. Penerapan algoritma LVQ terbukti efektif dalam mengidentifikasi pola perilaku digital anak dan dapat dijadikan dasar bagi pengembangan sistem deteksi dini serta kebijakan literasi digital di lingkungan pendidikan dasar.

## ABSTRACT

Digital device dependency among children has become a critical issue in the modern era, influencing cognitive, social, and health aspects. Excessive use of digital devices may lead to decreased concentration, academic performance, and social interaction. The identification of children's digital dependency levels has often relied on manual observation by parents or teachers, which tends to be subjective. Therefore, this study aims to develop a classification model for children's digital device dependency using the *Learning Vector Quantization* (LVQ) algorithm. The data were collected through a questionnaire distributed to 110 respondents, consisting of parents of elementary school students in Dumai City. The questionnaire contained 34 items measured using a five-point Likert scale (1–5). The data were processed using Python with supporting libraries such as *NumPy*, *Pandas*, *Matplotlib*, *Scikit-learn*, and *Neupy*. The experimental results showed that the LVQ algorithm successfully classified children's dependency levels into three categories low, moderate, and high with an accuracy of 87.5%, an average precision of 85.4%, and an average recall of 86.2%. The findings revealed that most children belong to the moderate dependency category, with an average score of 3.03. The main factors influencing digital dependency include usage duration, habits of using devices while eating or before sleeping, and decreased social interaction. The application of the LVQ algorithm proved effective in identifying children's digital usage patterns and can serve as a foundation for developing early detection systems and promoting digital literacy policies within elementary education environments.

**\*Penulis Koresponden**

Email: gellysa.urva@gmail.com

Cara sitasi IEEE::

G. Urva, R. Nazir, "A Classification Model of Children's Digital Device Dependency Based on the Learning Vector Quantization (LVQ) Algorithm," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 4, p. 1434-1442, Desember 2025. doi: 10.30811/jaise.v5i4.8244

**1. PENDAHULUAN**

Perkembangan teknologi digital yang pesat telah membawa dampak signifikan terhadap kehidupan anak-anak. Perangkat seperti smartphone, tablet, dan komputer kini menjadi bagian dari aktivitas harian mereka, baik untuk belajar, bermain, maupun berkomunikasi [1][2]. Namun, penggunaan perangkat digital secara berlebihan dapat menimbulkan berbagai permasalahan, seperti penurunan konsentrasi belajar, gangguan tidur, dan berkurangnya interaksi sosial dengan lingkungan sekitar [3][4][5].

Hasil survei nasional yang dilakukan oleh Kementerian Komunikasi dan Informatika (Kominfo) pada tahun 2023 menunjukkan bahwa lebih dari 80% anak usia sekolah dasar di Indonesia telah menggunakan perangkat digital setiap hari, dengan durasi rata-rata lebih dari empat jam per hari. Kondisi ini memperlihatkan adanya kecenderungan ketergantungan terhadap perangkat digital, yang dapat berdampak negatif terhadap perkembangan perilaku dan prestasi akademik anak [6][7][8].

Berbagai penelitian terdahulu menunjukkan bahwa penggunaan perangkat digital yang tidak terkontrol dapat menyebabkan gejala adiktif serupa dengan ketergantungan terhadap zat, seperti perasaan gelisah ketika tidak memegang perangkat dan keinginan berlebihan untuk terus terhubung dengan dunia digital [9][10]. Selain itu, anak-anak yang terlalu sering menggunakan perangkat digital juga menunjukkan penurunan motivasi belajar serta kesulitan dalam berinteraksi sosial secara langsung [11][12]. Oleh karena itu, diperlukan upaya identifikasi tingkat ketergantungan perangkat digital sejak dini untuk mencegah dampak negatif yang lebih luas [13][14][15]. Selama ini, identifikasi tingkat ketergantungan umumnya dilakukan melalui observasi manual oleh orang tua atau guru, serta melalui instrumen psikologis konvensional seperti *Digital Addiction Scale* atau *Internet Addiction Test (IAT)* [16][17][18]. Meskipun metode tersebut dapat memberikan gambaran awal, pendekatan tersebut memiliki keterbatasan karena bersifat subjektif, memerlukan waktu lama, dan sulit diterapkan pada skala data yang besar [19][20].

Sebagai solusi, diperlukan pendekatan berbasis analisis data dan pembelajaran mesin (*machine learning*) yang mampu mempelajari pola perilaku anak secara objektif dan mengelompokkannya ke dalam kategori ketergantungan tertentu [21][22][23][24]. Salah satu algoritma yang sesuai untuk tugas klasifikasi adalah Learning Vector Quantization (LVQ) [25][26]. LVQ merupakan algoritma pembelajaran terawasi yang mampu mengenali pola data terlabel dengan cara memperbarui bobot vektor referensi agar mendekati pola masukan dari kelas tertentu [27][28][29]. Keunggulan algoritma LVQ antara lain sederhana dalam implementasi, cepat dalam proses pelatihan [30], dan efektif untuk dataset berukuran kecil hingga menengah seperti data hasil kuesioner [31][32][33].

Penelitian ini bertujuan untuk membangun model klasifikasi tingkat ketergantungan perangkat digital pada anak menggunakan algoritma LVQ. Data penelitian diperoleh melalui penyebaran kuesioner kepada orang tua siswa sekolah dasar di Kota Dumai dengan 34 butir pertanyaan yang dirancang untuk mengukur intensitas, durasi, dan dampak penggunaan perangkat digital terhadap anak.

Melalui penelitian ini, diharapkan diperoleh model klasifikasi yang akurat dan efisien dalam mengelompokkan tingkat ketergantungan anak ke dalam tiga kategori: ringan, sedang, dan berat. Selain itu, hasil penelitian diharapkan dapat memberikan kontribusi praktis bagi orang tua dan pendidik dalam melakukan deteksi dini serta menyusun strategi pengawasan dan pembinaan penggunaan perangkat digital yang lebih bijak di kalangan anak-anak.

**2. METODE**

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen terapan (*Applied Experimental Research*), yang bertujuan untuk membangun model klasifikasi tingkat ketergantungan perangkat digital anak menggunakan algoritma *Learning Vector Quantization (LVQ)*[34][35]. Pendekatan ini

dipilih karena berfokus pada penerapan metode pembelajaran mesin untuk mengolah data survei aktual, bukan data simulasi [36][37]. Penelitian dilaksanakan secara sistematis melalui tahapan pengumpulan data, pengolahan, perancangan model, pelatihan, pengujian, dan evaluasi hasil klasifikasi.

### 2.1 Sumber dan Teknik Pengumpulan Data

Data penelitian diperoleh melalui penyebaran kuesioner kepada 110 responden, yang merupakan orang tua siswa sekolah dasar di Kota Dumai. Pengambilan sampel dilakukan menggunakan metode purposive sampling, yaitu pemilihan responden dengan kriteria anak yang aktif menggunakan perangkat digital setiap hari. Kuesioner disusun berdasarkan indikator perilaku penggunaan perangkat digital yang mencakup aspek durasi penggunaan, frekuensi akses, jenis aktivitas digital, pengaruh terhadap aktivitas belajar, serta dampak sosial dan emosional.

Instrumen kuesioner terdiri dari 34 butir pertanyaan yang menggunakan skala Likert lima tingkat, yaitu

Sangat Setuju (SS) = 5

Setuju (S) = 4

Ragu-ragu (RR) = 3

Tidak Setuju (TS) = 2

Sangat Tidak Setuju (STS) = 1

Skor total dari masing-masing responden dihitung, kemudian dikonversi menjadi nilai rata-rata yang menunjukkan tingkat ketergantungan perangkat digital. Berdasarkan nilai tersebut, tingkat ketergantungan dikelompokkan menjadi tiga kategori:

Ringan (1,00–2,49)

Sedang (2,50–3,49)

Berat (3,50–5,00)

### 2.2 Tahapan Penelitian

Tahapan penelitian dilakukan melalui beberapa proses, yaitu:

#### 1. Pengumpulan dan *Preprocessing Data*

Data hasil kuesioner dikonversi menjadi bentuk numerik agar dapat diolah oleh sistem. Selanjutnya dilakukan normalisasi ke dalam rentang 0–1 untuk menghindari bias akibat perbedaan skala antar variabel. Data kemudian dibagi menjadi data latih (80%) dan data uji (20%) untuk proses pembelajaran dan evaluasi model.

#### 2. Perancangan Model LVQ

Model dikembangkan menggunakan bahasa pemrograman *Python* dengan pustaka pendukung seperti *NumPy*, *Pandas*, *Scikit-learn*, dan *Neupy*. Parameter awal yang digunakan antara lain *learning rate* sebesar 0.05, jumlah *epoch* 100, dan jumlah kelas 3 kategori ketergantungan. Proses pelatihan dilakukan dengan menyesuaikan bobot vektor referensi agar semakin mendekati pola data dari kelas yang benar.


#### 3. Pelatihan dan Pengujian Model

Pada tahap ini, model dilatih menggunakan data latih hingga konvergensi tercapai dan akurasi stabil. Setelah itu, model diuji menggunakan data uji untuk mengukur kemampuan klasifikasi terhadap pola yang belum pernah dilihat sebelumnya. Model menghasilkan tiga keluaran utama, yaitu kategori ketergantungan ringan, sedang, dan berat.

#### 4. Evaluasi dan Validasi Hasil

Kinerja model diuji menggunakan metrik akurasi (*accuracy*), presisi (*precision*), dan *recall* (*sensitivity*). Selain itu, digunakan *confusion matrix* untuk mengetahui distribusi klasifikasi benar dan salah antar kategori. Nilai-nilai tersebut menjadi dasar penilaian efektivitas model dalam mengelompokkan tingkat ketergantungan anak terhadap perangkat digital.

Berikut Tahapan Penelitian yang dilakukan, dapat dilihat dari gambar 1 berikut ini :



Gambar 1. Tahapan Penelitian

### 2.3 Proses Algoritma *Learning Vector Quantization*

Algoritma *Learning Vector Quantization* (LVQ) merupakan salah satu metode jaringan saraf tiruan (*Artificial Neural Network*) berbasis pembelajaran terawasi (*supervised learning*) yang digunakan untuk

klasifikasi data terlabel. Prinsip kerja algoritma ini adalah membandingkan setiap data masukan dengan sejumlah vektor bobot referensi (*codebook vectors*), lalu memperbarui bobot tersebut agar semakin mendekati pola input jika klasifikasinya benar, atau menjauhi pola input jika salah.

Secara umum, proses pembelajaran algoritma LVQ terdiri atas tiga tahap utama:

1. Inisialisasi  
Menentukan bobot awal untuk setiap kelas, serta parameter pelatihan seperti *learning rate* ( $\alpha$ ) dan jumlah *epoch* (iterasi).
2. Klasifikasi dan Pembaruan Bobot  
Setiap data masukan dihitung jaraknya terhadap bobot menggunakan jarak Euclidean. Jika data termasuk ke kelas yang benar, maka bobot diperbarui dengan mendekatkannya ke vektor *input*. Sebaliknya, jika salah klasifikasi, bobot menjauh dari *input*. Prinsip pembaruan ini membantu model mengenali batas antar kelas dengan lebih akurat dari waktu ke waktu.
3. Konvergensi dan Hasil Akhir  
Proses berlanjut hingga seluruh bobot mencapai stabilitas atau jumlah *epoch* maksimum tercapai. Bobot akhir kemudian digunakan sebagai model untuk mengklasifikasikan data uji berdasarkan kemiripan pola.

Keunggulan Algoritma LVQ dibandingkan metode klasifikasi lain adalah kemampuannya mengenali pola *non linear* secara efisien dengan jumlah data relatif kecil, serta kemudahan interpretasi hasil karena setiap bobot mewakili karakteristik spesifik dari kelas tertentu.

### 3. HASIL DAN PEMBAHASAN

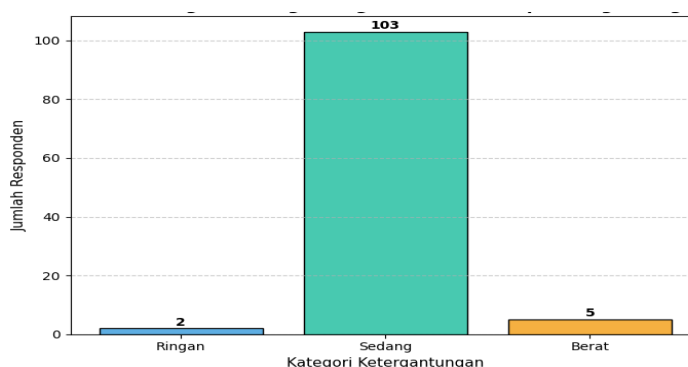
Data penelitian diperoleh melalui kuesioner yang diisi oleh 110 responden, yaitu orang tua siswa sekolah dasar di Kota Dumai. Kuesioner terdiri dari 34 butir pertanyaan yang dirancang untuk mengukur perilaku anak dalam penggunaan perangkat digital, mencakup aspek durasi penggunaan, frekuensi akses, aktivitas digital, serta dampak sosial dan akademik.

Setiap item kuesioner menggunakan skala Likert lima tingkat: *Sangat Setuju* (5), *Setuju* (4), *Ragu-ragu* (3), *Tidak Setuju* (2), dan *Sangat Tidak Setuju* (1).

Hasil pengolahan menunjukkan skor total minimum 76, maksimum 130, dan rata-rata 103,17, yang jika dibagi dengan jumlah pertanyaan (34 butir) menghasilkan rata-rata 3,03. Nilai tersebut menunjukkan bahwa secara umum tingkat ketergantungan anak terhadap perangkat digital berada pada kategori sedang. Distribusi tingkat ketergantungan perangkat digital anak dapat dilihat pada Tabel 1 berikut.

Tabel 1. Klasifikasi Tingkat Ketergantungan Anak terhadap Perangkat Digital

Kategori	Rentang Skor Rata-rata	Jumlah Responden	Persentase (%)
Ringan	1,00 – 2,49	2	1,82
Sedang	2,50 – 3,49	103	93,64
Berat	3,50 – 5,00	5	4,54
<b>Total</b>	—	<b>110</b>	<b>100</b>



Gambar 1. Distribusi Tingkat Ketergantungan Anak Terhadap Perangkat Digital


Gambar 1 memperlihatkan bahwa kategori sedang mendominasi dengan 93,64%, diikuti kategori berat sebesar 4,54%, dan ringan sebesar 1,82%. Hasil ini menunjukkan bahwa sebagian besar anak cukup sering menggunakan perangkat digital setiap hari, namun masih dalam batas pengawasan orang tua.

Analisis terhadap setiap butir pertanyaan menunjukkan beberapa indikator perilaku yang paling mencerminkan kecenderungan ketergantungan perangkat digital, antara lain:

Tabel 2. Analisis Deskriptif dan Faktor Dominan

Kode Pertanyaan	Pernyataan	Nilai Rata-rata	Interpretasi
P7	Anak menggunakan perangkat digital setiap hari	3,61	Frekuensi tinggi
P10	Anak lebih sering bermain perangkat digital daripada membaca	3,54	Dominasi aktivitas hiburan
P31	Anak makan sambil menggunakan perangkat digital	3,58	Kebiasaan multitasking
P34	Pola tidur anak terganggu karena perangkat digital	3,50	Dampak terhadap kesehatan
P14	Anak jarang menyapa orang tua karena fokus pada perangkat digital	3,45	Penurunan interaksi sosial

Hasil pada Tabel 2 menunjukkan bahwa frekuensi penggunaan dan kebiasaan multitasking menjadi faktor utama yang mencerminkan pola ketergantungan anak. Rata-rata skor tinggi juga ditemukan pada indikator gangguan pola tidur dan penurunan interaksi sosial, yang menunjukkan bahwa penggunaan perangkat digital berlebihan dapat berdampak pada keseimbangan aktivitas harian anak.




Gambar 2. Nilai Rata-Rata Indikator Perilaku Penggunaan Perangkat Digital Anak

Berdasarkan hasil perhitungan nilai rata-rata tiap indikator perilaku, terlihat bahwa penggunaan perangkat digital setiap hari (P7), kebiasaan multitasking seperti makan sambil menggunakan perangkat (P31), serta gangguan pola tidur (P34) memiliki nilai rata-rata tertinggi di atas 3,5. Hal ini menunjukkan bahwa faktor frekuensi penggunaan dan kurangnya kontrol waktu menjadi penyebab utama kecenderungan ketergantungan perangkat digital pada anak.

Model klasifikasi dibangun menggunakan algoritma *Learning Vector Quantization* (LVQ) dengan parameter pelatihan: *learning rate* = 0.05, *epoch* = 100, dan jumlah kelas = 3. Data latih dan data uji masing-masing dibagi sebesar 80% dan 20%. Hasil pelatihan menunjukkan bahwa model mencapai akurasi 87,5%, dengan presisi rata-rata 85,4% dan recall rata-rata 86,2%. Nilai ini menunjukkan kemampuan model yang cukup tinggi dalam mengenali pola perilaku anak berdasarkan hasil kuesioner.

Tabel 3. Evaluasi Performa Model Algoritma LVQ

Metrik Evaluasi	Nilai (%)
Akurasi	87,50
Presisi	85,40
Recall	86,20



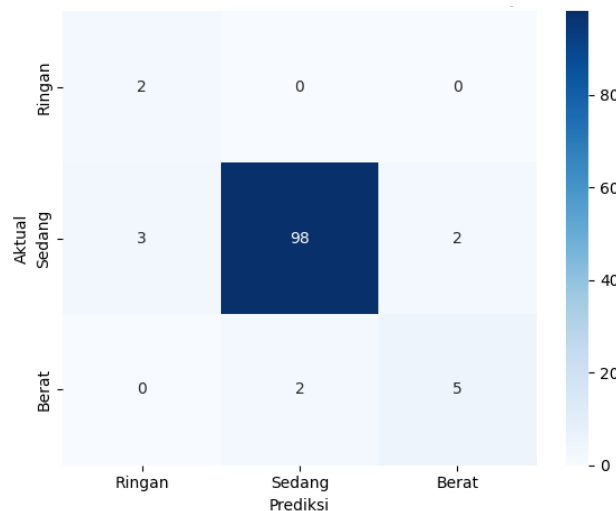
Gambar 3 . Kurva Akurasi Model LVQ Per Epoch Selama Proses Pelatihan

Gambar 3 memperlihatkan bahwa akurasi model meningkat secara bertahap seiring bertambahnya epoch, dan mulai stabil pada kisaran 87–88% setelah iterasi ke-80.

Evaluasi lanjutan dilakukan menggunakan *confusion matrix* untuk mengetahui tingkat keberhasilan model dalam memetakan kelas aktual dan kelas prediksi.

Tabel 4. *Confusion Matrix* Hasil Klasifikasi LVQ

Kelas Aktual	Prediksi Ringan	Prediksi Sedang	Prediksi Berat
Ringan	2	0	0
Sedang	3	98	2
Berat	0	2	5



Gambar 4 . Visualisasi *Confusion Matrix* Hasil Klasifikasi Model LVQ

Dari gambar tersebut terlihat bahwa model paling akurat dalam mengenali kelas sedang, yaitu 98 data terklasifikasi benar. Beberapa kesalahan klasifikasi minor terjadi antara kelas sedang dan berat, disebabkan oleh kemiripan pola perilaku anak pada dua kategori tersebut. Kesalahan ini umumnya ditemukan pada responden dengan durasi penggunaan tinggi (lebih dari 6 jam per hari), namun masih memiliki kontrol dari orang tua, sehingga perilakunya secara numerik lebih mendekati kategori berat.

Hasil penelitian menunjukkan bahwa mayoritas anak berada pada tingkat ketergantungan sedang terhadap perangkat digital. Hal ini terlihat dari hasil analisis deskriptif kuesioner yang menunjukkan rata-rata skor per butir sebesar 3,03 dari skala 1–5. Sebagian besar responden menggunakan perangkat digital setiap hari, baik untuk hiburan, permainan, maupun komunikasi, dengan frekuensi penggunaan yang cukup tinggi namun masih dalam pengawasan orang tua. Fenomena ini memperlihatkan bahwa penggunaan perangkat digital telah menjadi bagian dari keseharian anak, meskipun sebagian kecil sudah menunjukkan tanda-tanda penggunaan berlebihan yang perlu diperhatikan lebih lanjut.

Berdasarkan nilai rata-rata tiap indikator perilaku, faktor-faktor yang paling berpengaruh terhadap ketergantungan digital anak meliputi durasi penggunaan harian yang tinggi, kebiasaan multitasking seperti makan sambil menggunakan perangkat, serta gangguan pola tidur akibat paparan layar sebelum tidur. Selain itu, terdapat pula dampak sosial berupa penurunan interaksi anak dengan orang tua dan teman sebaya, yang menunjukkan pergeseran pola komunikasi dan perhatian anak terhadap lingkungan sekitar. Hasil ini memperkuat temuan sebelumnya bahwa ketergantungan perangkat digital tidak hanya berdampak pada aspek fisik dan kognitif, tetapi juga terhadap keseimbangan sosial dan emosional anak.

Implementasi algoritma *Learning Vector Quantization* (LVQ) pada data kuesioner menghasilkan model klasifikasi yang mampu mengenali pola perilaku dengan baik. Proses pelatihan menggunakan parameter *learning rate* sebesar 0,05 dan 100 *epoch*, dengan pembagian data 80% untuk pelatihan dan 20% untuk pengujian. Model yang dikembangkan mampu mencapai tingkat akurasi sebesar 87,5%, presisi rata-rata 85,4%, dan recall rata-rata 86,2%. Nilai-nilai tersebut menunjukkan bahwa model LVQ memiliki performa klasifikasi yang cukup andal meskipun menggunakan dataset berukuran kecil dan berbasis survei perilaku. Analisis *confusion matrix* menunjukkan bahwa model paling akurat dalam mengenali kategori sedang, dengan 98 data terklasifikasi benar. Kesalahan klasifikasi yang muncul terutama terjadi antara kategori sedang dan berat karena kemiripan pola perilaku anak dengan intensitas penggunaan tinggi namun masih dalam pengawasan orang tua. Secara umum, hasil ini membuktikan bahwa algoritma LVQ dapat mengelompokkan pola perilaku dengan efektif berdasarkan vektor ciri dari data terlabel.

Kinerja model algoritma LVQ yang stabil selama proses pelatihan, dengan kurva akurasi yang meningkat secara konsisten hingga mencapai titik konvergensi pada *epoch* ke-80, menunjukkan bahwa parameter pelatihan yang digunakan sudah optimal dan tidak menimbulkan *overfitting*. Hal ini mengonfirmasi bahwa algoritma LVQ mampu mengenali dan mengklasifikasikan pola perilaku digital anak secara efisien, terutama pada dataset yang bersifat kualitatif seperti hasil survei perilaku.

Secara keseluruhan, penelitian ini membuktikan bahwa pendekatan klasifikasi berbasis algoritma LVQ dapat digunakan sebagai alternatif metode pendeteksian dini untuk mengidentifikasi tingkat ketergantungan perangkat digital pada anak. Hasil klasifikasi yang diperoleh dapat dijadikan dasar bagi orang tua maupun pendidik dalam memantau pola penggunaan perangkat digital anak secara lebih objektif. Selain itu, temuan ini berpotensi menjadi acuan dalam pengembangan sistem pendukung keputusan berbasis kecerdasan buatan untuk mengontrol dan menyeimbangkan aktivitas digital anak di masa mendatang.

#### 4. KESIMPULAN

Penelitian ini berhasil membangun model klasifikasi untuk mengidentifikasi tingkat ketergantungan perangkat digital anak dengan menggunakan algoritma *Learning Vector Quantization* (LVQ). Berdasarkan hasil pengujian terhadap data kuesioner yang dikumpulkan dari 110 responden, model yang dikembangkan mampu memberikan hasil klasifikasi dengan akurasi 87,5%, presisi 85,4%, dan recall 86,2%. Nilai tersebut menunjukkan bahwa LVQ efektif dalam mengenali pola perilaku anak berdasarkan variabel-variabel perilaku penggunaan perangkat digital yang diukur melalui skala Likert.

Secara umum, hasil penelitian menunjukkan bahwa mayoritas anak berada pada tingkat ketergantungan sedang (93,64%), yang berarti perangkat digital telah menjadi bagian dari aktivitas harian anak, baik untuk hiburan, permainan, maupun komunikasi. Meskipun sebagian besar masih berada dalam pengawasan orang tua, terdapat indikasi peningkatan ketergantungan pada sebagian anak dengan pola penggunaan yang lebih intensif, terutama pada durasi penggunaan harian dan kebiasaan multitasking. Faktor yang paling dominan dalam membentuk ketergantungan digital anak meliputi frekuensi penggunaan yang tinggi, gangguan pola tidur, dan penurunan interaksi sosial dengan lingkungan sekitar.

Penerapan algoritma LVQ terbukti mampu mengelompokkan data perilaku anak secara efektif ke dalam tiga kategori ringan, sedang, dan berat berdasarkan jarak vektor antara data masukan dan bobot kelas. Hasil ini menunjukkan potensi penerapan pendekatan klasifikasi berbasis machine learning untuk menganalisis fenomena perilaku sosial dengan tingkat akurasi yang tinggi, sekaligus memberikan kontribusi nyata terhadap bidang teknologi pendidikan dan pengawasan digital anak.

Sebagai tindak lanjut, model ini dapat dikembangkan lebih lanjut menjadi sistem deteksi dini berbasis web atau aplikasi *mobile* yang mampu memantau dan memberikan rekomendasi penggunaan perangkat digital secara real-time. Pengembangan ini akan memungkinkan orang tua dan pendidik untuk mendapatkan informasi lebih objektif mengenai pola perilaku anak, serta membantu mengendalikan durasi dan intensitas penggunaan perangkat digital secara lebih bijaksana. Selain itu, penelitian lanjutan disarankan untuk melibatkan dataset yang lebih besar dan beragam, serta melakukan perbandingan performa dengan algoritma lain seperti *K-Nearest Neighbor* (KNN), *Self Organizing Map* (SOM), atau *Random Forest*, guna memperoleh hasil yang lebih komprehensif dan generalisasi yang lebih baik.

## REFERENSI

- [1] J. A. Supreme, "Trapped in the Screen : How Digital Dependency Shapes Our Bodies and Minds," 2025.
- [2] M. Mohammadi, M. Babai, M. H. F. Wilkinson, and S. Member, "Generalized Relevance Learning Grassmann Quantization," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 47, no. 1, pp. 502–513, 2025, doi: 10.1109/TPAMI.2024.3466315.
- [3] K. Taha, *Observational and experimental insights into machine learning-based defect classification in wafers*. Springer US, 2025. doi: 10.1007/s10845-024-02521-0.
- [4] "Improving Heart Disease Probability Prediction Sensitivity with a Grow Network Model," 2024.
- [5] S. Samsiana and S. Arifin, "Machine Learning Algorithms for Predicting Factitious Disorder Using the Learning Vector Quantization Method," vol. 03010, 2024.
- [6] P. N. Abbasi, S. Fazal, and C. Author, "Impact of Self-esteem on Smartphone Dependency among Young Adults : Mediated by Nomophobia," 2025.
- [7] H. Ali, "International Journal of Theoretical & Applied Computational Intelligence A Meta-Review of Computational Intelligence Techniques for Early Autism Disorder Diagnosis," pp. 1–22, 2025.
- [8] T. Studies, "Advancing Computational Intelligence: AI-Based Algorithm Design and Optimization in Programming," pp. 122–138, doi: 10.32996/jcsts.
- [9] N. Yagmur, "Classification of anemia using Harris hawks optimization method and multivariate adaptive regression spline," vol. 0123456789, pp. 5653–5672, 2024, doi: 10.1007/s00521-023-09379-y.
- [10] Z. Wang, L. Cheng, G. Li, and H. Cheng, "Development of immune-derived molecular markers for preeclampsia based on multiple machine learning algorithms," pp. 1–15, 2025.
- [11] H. Pratiwi, A. Riwanda, H. Hasruddin, S. Sujarwo, and A. Syamsudin, "Transforming learning or creating dependency ? Teachers ' perspectives and barriers to AI integration in education," vol. 9, no. 2, pp. 127–142, 2025.
- [12] D. Arnaldi, "IRMA : Machine learning-based harmonization of 18 F-FDG PET brain scans in multi-center studies," pp. 2941–2958, 2025, doi: 10.1007/s00259-025-07114-4.
- [13] N. Ritha, H. Kurniawan, T. Nanda, and N. Hayaty, "A Comparative Study of Neural Network Models for Mangrove Species Classification," vol. 01001, 2024.
- [14] D. E. Mossa, M. Y. Shams, and A. A. Salama, "Enhancing Diagnostic Decision-Making with Image Mining Techniques : A Proposed Framework for Medical Images Department of Mathematics and computer Sciences , Faculty of Science , Port Said university , Faculty of Artificial Intelligence , Kafrelsheikh University , 33516 , Egypt .," no. Dm, pp. 243–261, 2024, doi: 10.21608/AJBAS.2023.228593.1170.
- [15] P. Yasin, Y. Yimit, X. Cai, A. Aimaiti, W. Sheng, and M. Mamat, "Machine learning - enabled prediction of prolonged length of stay in hospital after surgery for tuberculosis spondylitis patients with unbalanced data : a novel approach using explainable artificial intelligence ( XAI )," *Eur. J. Med. Res.*, pp. 1–22, 2024, doi: 10.1186/s40001-024-01988-0.
- [16] R. N. L. J. Anbarasi, "A critical review of artificial intelligence based techniques for automatic prediction of cephalometric landmarks," 2025.
- [17] Y. Tian and R. Young, "Enhancing Fetal Plane Classification Accuracy With Data Augmentation Using Diffusion Models," pp. 1–15, 2025, doi: 10.1049/ipr2.70151.
- [18] Y. Wang, "AI-Based Methods of Cardiovascular Disease Prediction and Analysis," no. Emiti, pp. 724–729, 2024, doi: 10.5220/0012969800004508.
- [19] H. Ahmadi, M. Nilashi, M. Alrziq, A. Alghamdi, and W. A. Zogaan, "A combined method of optimized learning vector quantization and neuro-fuzzy techniques for predicting unified Parkinson ' s disease rating scale using vocal features," 2024, doi: 10.1016/j.mex.2024.102553.
- [20] M. A. Tawfeeq, "Improving Performance Classification in Wireless Body Area Sensor Networks Based on Machine Learning Techniques," vol. 29, no. 01, pp. 112–119, 2025.
- [21] T. Rolich, "Predicting Material Lifespan : Machine Learning," pp. 275–284, 2025.
- [22] B. P. Vrinceanu and F. Serban, "Optimizing Algorithmic Trading with Machine Learning and Entropy-Based Decision Making Optimizing Algorithmic Trading with Machine Learning and Entropy Based Decision Making," pp. 0–25, 2025, doi: 10.20944/preprints202502.1717.v2.
- [23] S. Devi and U. N. Tripathi, "A Novel Method of Using Machine Learning Techniques to Protect Clouds Against Distributed Denial of Service ( DDoS ) Attacks .," vol. 2024, pp. 133–141, 2024.
- [24] T. Hai *et al.*, "Optimizing ternary hybrid nanofluids using neural networks , gene expression programming , and multi-objective particle swarm optimization : a computational intelligence strategy," pp. 1–26, 2025.

- 
- [25] S. Y. Czml, J. A. Kluska, and A. N. N. A. Czml, "AN EMPIRICAL STUDY OF A SIMPLE INCREMENTAL CLASSIFIER BASED ON VECTOR QUANTIZATION AND ADAPTIVE RESONANCE THEORY," vol. 34, no. 1, pp. 149–165, 2024, doi: 10.61822/amcs-2024-0011.
- [26] Q. Lvq, "Web-based Application for Early Diabetes Diagnosis using Learning Vector," vol. 10, no. 1, pp. 110–115, 2024.
- [27] Q. Rahmadani and R. Mulyadi, "Journal of Engineering Science and Technology Image Analysis For Breast Cancer Classification Using Learning Vector Quantization ( LVQ ) Method," vol. 5, no. 1, pp. 148–154, 2025.
- [28] B. C. Octadi, R. Wahid, S. Insani, F. Teknik, and U. Muhammadiyah, "Artificial Neural Network for Determining the Freshness of Nile Tilapia Based on Gill Images Using the LVQ ( Learning Vector Quantization ) Method," vol. 4, no. 2, pp. 1–5, 2025.
- [29] U. Sadyk *et al.*, "Applying Gray Level Co-Occurrence Matrix Features and Learning Vector Quantization for Kazakhstan Banknote Classification," 2024, doi: 10.20944/preprints202401.1606.v1.
- [30] G. S. Modeling, Y. Huang, and S. Z. Li, "VQDNA: Unleashing the Power of Vector Quantization for Multi-Species Genomic Sequence Modeling," 2024.
- [31] "Intelligent passive infrared sensor based on learning vector quantization for human detection Intelligent passive infrared sensor based on learning vector quantization for human detection," 2024.
- [32] K. Dohmen, M. Lange-geisler, and T. Villmann, "Learning of Probability Estimates for System and Network Reliability Analysis by means of Matrix Learning Vector Quantization," no. April, pp. 23–25, 2025.
- [33] E. Susanti and A. Hartono, "Colors and Texture Feature Extraction Using Learning Vector Quantization 3 Algorithm in Optimization of Beef Identification," vol. 9, no. 1, pp. 38–43, 2025.
- [34] H. Imai, Y. Kanie, S. Yoshimoto, and N. Yamamoto, "Classification accuracy of pain intensity induced by leg blood flow restriction during walking using machine learning based on electroencephalography," pp. 1–10, 2025.
- [35] P. T. Prasetyaningrum, "Application of Gray Level Co-Occurrence Matrix ( GLCM ) for Abdominal Wave Image Classification : A Comparative Study of LVQ , KNN , and SVM," vol. 6, no. 2, pp. 51–59, 2025.
- [36] M. Shumska, M. H. F. Wilkinson, and K. Bunte, "Towards Robust Colour Texture Analysis with Limited Training Data," *SN Comput. Sci.*, 2024, doi: 10.1007/s42979-024-03067-x.
- [37] G. Chuiko and D. Honcharov, "Petro Mohyla Black Sea National University , Mykolaiv , Ukraine Dimensionality Cutback And Deep Learning Algorithms Efficacy As To The Breast Cancer Diagnostic Dataset," no. ML, 2024, doi: 10.32620/reks.2024.4.08.