

# Implementasi Metode Learning Vector Quantization (LVQ) Untuk Klasifikasi Keluarga Beresiko Stunting

Abdul Aziz<sup>1</sup>, Fitri Insani<sup>2\*</sup>, Jasril<sup>3</sup>, Fadhilah Syafria<sup>4</sup>

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: <sup>1</sup>11950111664@students.uin-suska.ac.id, <sup>2\*</sup>fitri.insani@uin-suska.ac.id, <sup>3</sup>jasril@uin-suska.ac.id,

<sup>4</sup>fadhilah.syafria@uin-suska.ac.id

Email Penulis Korespondensi: fitri.insani@uin-suska.ac.id

Submitted: 19/05/2023; Accepted: 27/06/2023; Published: 29/06/2023

**Abstrak**—Stunting adalah kondisi tinggi postur tubuh anak terlalu pendek dari rata-rata kelompok anak seusianya. Kondisi ini mempengaruhi kesehatan balita pada jangka pendek dan panjang, yaitu postur tubuh tidak optimal ketika dewasa, berkurangnya kesehatan reproduksi, serta gangguan fungsi kognitif yang mengarah pada kinerja akademik yang buruk. Salah satu faktor penyebab stunting adalah kurangnya pemenuhan gizi, fasilitas kesehatan dasar, serta pola pengasuhan yang buruk dari orang tua. Namun, pendataan dan klasifikasi keluarga beresiko stunting saat ini masih dengan menggunakan microsoft excel, yang tidak efektif dalam mengolah data besar. Oleh sebab itu, model LVQ digunakan untuk mengklasifikasikan data dengan cepat. Berdasarkan pengujian, hasil optimal dicapai dengan menggunakan jumlah neuron input sebanyak 7, jenis jarak menggunakan chebychev distance, learning rate sebesar 0.1, jumlah epoch sebanyak 7, dan 30% data latih. Akurasi sebesar 99.83% dicapai dengan menggunakan pengujian tersebut. Penelitian ini menunjukkan bahwa metode LVQ dapat digunakan untuk mengidentifikasi keluarga yang beresiko mengalami stunting.

**Kata Kunci:** Stunting; LVQ; Klasifikasi; Keluarga Beresiko Stunting; Gizi

**Abstract**—Stunting is a condition where a child's height is too short compared to children of the same age. This condition affects the health of toddlers in the short and long term, such as suboptimal body posture in adulthood, decreased reproductive health, and decreased learning capacity, resulting in suboptimal performance in school. One of the causes of stunting is a lack of nutrition, basic health facilities, and poor parenting practices. However, the current data collection and classification of families at risk of stunting still use Microsoft Excel, which is ineffective in processing large data. Therefore, the LVQ method, which is an improvement of the Vector Quantization method, is used to accelerate the classification process. In this study, 5 parameters were tested, and the optimal result was achieved by using 7 input neurons, Chebychev distance as the distance measure, a learning rate of 0.1, 7 epochs, and 30% of training data. With these parameters, an accuracy of 99.83% was obtained. Based on these results, the LVQ method can help improve accuracy in classifying families at risk of stunting.

**Keywords:** Stunting; LVQ; Classification; Families at Risk of Stunting; Nutrition.

## 1. PENDAHULUAN

*Stunting* merupakan masalah umum pada balita di Indonesia yang diakibatkan oleh gizi buruk[1]. *Stunting* diartikan sebagai suatu kondisi tinggi postur tubuh anak terlalu pendek dari rata-rata kelompok anak seusianya [2][3]. Prevalensi *stunting* pada balita di Indonesia sekitar 24,4%, menurut data SSGI (Studi Status Gizi Indonesia) tahun 2021 masih di atas batas yang ditetapkan WHO yaitu 20% [4]. Hal ini membuat Indonesia berada pada peringkat ketiga di Asia Tenggara pada prevalensi balita *stunting*.

*Stunting* tidak hanya berdampak langsung, tetapi juga berdampak jangka panjang, seperti postur tubuh saat orang dewasa yang buruk, kesehatan reproduksi yang buruk, dan prestasi akademik di bawah standar karena kurangnya perkembangan intelektual[5]. Orang tua memainkan peranan yang penting dalam mencegah *stunting* pada balita. Pola pemenuhan gizi, fasilitas kesehatan dasar, dan pola asuh yang buruk dari orang tua merupakan faktor keluarga mengalami *stunting*[6]. Akibatnya, penting untuk berupaya menurunkan jumlah keluarga yang berisiko *stunting*.

Salah satu cara penanganan keluarga berisiko *stunting* adalah dengan memberikan pendampingan dan bantuan oleh pemerintah. Namun, banyak program pemerintah yang belum tepat sasaran dan belum sesuai kriteria yang diharapkan [7]. Kampung KB Tunas Harapan merupakan salah satu contoh kampung KB (Kampung Berkualitas) yang gencar dalam pengentasan *stunting* di Kecamatan Tuah Madani Kota Pekanbaru [8][9]. Dalam prosesnya, Kampung KB Tunas Harapan memerlukan pendataan dan klasifikasi keluarga berisiko *stunting* yang menjadi sasaran utama dalam program pengentasan *stunting*. Namun, proses pendataan dan klasifikasi keluarga berisiko *stunting* masih menggunakan cara yang bersifat manual yaitu menggunakan *microsoft excel*. Seiring berjalannya waktu, proses klasifikasi keluarga berisiko *stunting* menjadi rumit karena peningkatan jumlah penduduk. Oleh karena itu, diperlukan cara yang lebih baik untuk mengkategorikan keluarga yang berisiko mengalami *stunting*.

Klasifikasi adalah praktik mengkategorikan sesuatu menurut seperangkat aturan atau kriteria[10] [11]. Model LVQ merupakan perbaikan dari model *Vector Quantization* yang memungkinkan mengelola data yang besar dalam waktu singkat. LVQ telah diaplikasikan untuk berbagai masalah klasifikasi, seperti pengklasifikasian pencemaran air sungai[12], persalinan[13], penyakit infeksi saluran pernapasan akut (ISPA)[14], klasifikasi status gizi balita[15] dan prediksi penerimaan bantuan[16][17][18]. Saat ini, ada beberapa peneliti telah melakukan penelitian dalam membandingkan LVQ dengan metode klasifikasi lainnya. Hasil penelitian [19] menyatakan LVQ

lebih cepat dan akurat daripada SOM pada klasifikasi data akreditasi. Selain itu, [20] menyatakan hasil nilai akurasi LVQ lebih tinggi dari ID3 dan C45 dalam memprediksi pemberian bantuan UKM jasa telematika Indonesia.

Penelitian ini menggunakan algoritma LVQ untuk klasifikasi data. Selain melengkapi penelitian sebelumnya yang menggunakan LVQ dalam klasifikasi secara umum, penelitian ini fokus pada klasifikasi keluarga beresiko stunting dengan mengumpulkan dan menganalisis data berdasarkan kriteria yang telah ditetapkan. Penelitian ini juga memanfaatkan parameter yang tersedia dalam RapidMiner untuk mengoptimalkan proses klasifikasi, termasuk mengatur jumlah neuron input, jenis jarak, *learning rate*, jumlah epoch, dan persentase data latihan. Tujuan dari penelitian ini untuk mengimplementasikan metode LVQ untuk klasifikasi keluarga beresiko *stunting* di Kampung KB Tunas Harapan. Selanjutnya, data akan diolah menggunakan metode LVQ untuk mengklasifikasikan keluarga-keluarga tersebut menjadi kelompok yang memiliki risiko *stunting* dan tidak beresiko *stunting*. Diharapkan hasil penelitian ini dapat menjadi solusi untuk mempercepat dan meningkatkan akurasi proses klasifikasi keluarga beresiko *stunting* di Kampung KB Tunas Harapan, sehingga program pengentasan *stunting* dapat berjalan lancar.

## 2. METODOLOGI PENELITIAN

Bagian ini akan menjelaskan metodologi penulis untuk melakukan penelitian ini. Ketujuh langkah penelitian ini digambarkan pada Gambar 1.



Gambar 1. Langkah-langkah Penelitian

### 2.1 Rumusan Masalah

Tahap awal dalam sebuah penelitian adalah mencari permasalahan yang akan diangkat dan diteliti. Pada penelitian ini, rumusan masalah yang dibahas adalah mengenai implementasi model klasifikasi *Learning Vector Quantization* (LVQ) untuk memprediksi resiko *stunting* pada keluarga. Dalam penelitian ini, metode LVQ digunakan untuk menganalisis data keluarga yang berisiko mengalami *stunting* di Kecamatan Tuah Madani.

### 2.2 Studi Pustaka

Pada fase ini, penulis mendefinisikan masalah, menyelidiki konteks historisnya, dan membaca literatur atau penelitian yang relevan dalam upaya mencari solusinya. Penulis mempelajari teori-teori yang relevan, seperti teori tentang *stunting*, teori keluarga beresiko *stunting*, dan teori tentang metode LVQ.

### 2.3 Pengumpulan Data

Pengumpulan data dilakukan di Balai Penyuluhan KB di Kecamatan Tuah Madani untuk mengumpulkan data yang diperlukan. Data primer yang digunakan adalah data pendataan keluarga tahun 2021 dari Balai Penyuluhan KB Kecamatan Tuah Madani. 7 dari 20 parameter untuk menilai keluarga berisiko *stunting* ditunjukkan pada Tabel 1 berikut.

Tabel 1. Data Keluarga Beresiko *Stunting* Kecamatan Tuah Madani

Data ke-	Kode keluarga	NIK Kepala keluarga	Nama kepala keluarga	Keluarga memiliki anak baduta	Keluarga memiliki anak balita	PUS	PUS Hamil	...	Kategori Keluarga beresiko <i>stunting</i>
1.	147...	321...	A...Muna...	×	×	✓	×	...	×
2.	147...	140...	Aa...Musli...	✓	✓	✓	×	...	✓
3.	147...	140...	A.. Sup...	×	×	✓	×	...	×

4.	147...	149...	Ab...	x	✓	✓	x	...	✓
5.	147...	1471...	Aba... Pel...	x	x	✓	x	...	✓
6.	147...	140...	Ab... Sak...	✓	x	✓	x	...	✓
7.	147...	120...	Ab... Az...	x	x	✓	x	...	✓
8.	147...	147...	Ab.. Ri...	x	✓	✓	x	...	✓
9.	147...	471...	Abd... Has...	x	x	✓	x	...	✓
...	...	...	...	...	...	...	...	...	...
23619	147...	147...	Zu..r Di..	x	✓	✓	x	...	✓

**2.4 Data Preprocessing**

Pada tahapan ini menyiapkan data untuk digunakan dalam analisis LVQ . *Cleaning* data, transformasi data, dan imputasi data dilakukan pada fase preprocessing. Performa dan keakuratan model LVQ dapat ditingkatkan dengan melakukan preprocessing data yang benar.

a. *Cleaning* Data

Pada tahap ini, memfilter parameter yang tidak diperlukan dalam proses klasifikasi. Parameter yang dihapus yaitu kode keluarga, nomor induk kependudukan, dan nama keluarga karena tidak mempengaruhi hasil klasifikasi. Hasil *cleaning* data pada Tabel 2 berikut.

**Tabel 2.** Hasil *Cleaning* Data

Data ke-	Keluarga memiliki anak baduta	Keluarga memiliki anak balita	PUS	PUS Hamil	Anak putus sekolah	Tidak ada sumber penghasilan	Lantai rumah tanah	...	Keluarga beresiko <i>stunting</i>
1.	x	x	✓	x	-	x	x	...	x
2.	✓	✓	✓	x	-	x	x	...	✓
3.	x	x	✓	x	-	x	x	...	x
4.	x	✓	✓	x	-	x	x	...	✓
5.	x	x	✓	x	-	x	x	...	✓
6.	✓	x	✓	x	-	x	x	...	✓
7.	x	x	✓	x	-	x	x	...	✓
8.	x	✓	✓	x	-	x	x	...	✓
9.	x	x	✓	x	-	x	x	...	✓
...	...	...	...	...	...	...	x	...	...
23619	x	✓	✓	x	-	x	x	...	✓

b. Transformasi Data

Menurut algoritma LVQ, vektor input ditugaskan ke kelas dengan jarak terkecil ke vektor bobotnya. Oleh karena itu, nilai kelas dan parameter yang berupa symbol diubah menjadi bentuk numerik sehingga jaringan LVQ dapat mengidentifikasi data dengan benar. Fitur *replace* dan *change* pada Rapidminer digunakan untuk transformasi dalam penelitian ini. Transformasi data dapat dilihat pada Tabel 3 berikut.

**Tabel 3.** Hasil Transformasi Data

Keluarga memiliki anak baduta	Keluarga memiliki anak balita	PUS	PUS Hamil	Anak putus sekolah	Tidak ada sumber penghasilan	Lantai Rumah Tanah	Makan Makanan Beragam	...	Keluarga Beresiko <i>Stunting</i>
0	0	1	0	-	0	0	0	...	2
1	1	1	0	-	0	0	0	...	1
0	0	1	0	-	0	0	0	...	2
0	1	1	0	-	0	0	0	...	1
0	0	1	0	-	0	0	0	...	1
1	0	1	0	-	0	0	0	...	1
0	0	1	0	-	0	0	0	...	1
0	1	1	0	-	0	0	0	...	1
0	0	1	0	-	0	0	0	...	1
...	...	...	...	...	...	...	...	...	...
0	1	1	0	-	0	0	0	0	1

c. Imputasi Data

Agar data dapat digunakan untuk pengujian dan analisis, imputasi data digunakan untuk mengganti nilai lain dengan nilai yang kosong atau hilang. Aplikasi Rapidminer digunakan untuk melakukan imputasi data. Hasil

imputasi data ditampilkan pada Tabel 4..

Tabel 4. Hasil Imputasi Data

Keluarga memiliki anak baduta	Keluarga memiliki anak balita	PUS	PUS Hamil	Anak putus sekolah	Tidak ada sumber penghasilan	Lantai Rumah Tanah	Makan Makanan Beragam	...	Keluarga Beresiko Stunting
0	0	1	0	1	0	0	0	...	2
1	1	1	0	1	0	0	0	...	1
0	0	1	0	1	0	0	0	...	2
0	1	1	0	1	0	0	0	...	1
0	0	1	0	1	0	0	0	...	1
1	0	1	0	1	0	0	0	...	1
0	0	1	0	1	0	0	0	...	1
0	1	1	0	1	0	0	0	...	1
0	0	1	0	1	0	0	0	...	1
...	...	...	...	...	...	...	...	...	...
0	1	1	0	1	0	0	0	0	1

### 2.5 Pemodelan menggunakan LVQ

Algoritma LVQ akan diterapkan pada data yang diproses setelah proses pengolahan data selesai. Tahapan metode pelatihan LVQ sebagai berikut [21].

- Pada proses awal, tentukan nilai parameternya, yaitu nilai learning rate ( $\alpha$ ), jumlah iterasi (epoch), penerunan learning rate (Dec  $\alpha$ ), minimum learning rate (Min  $\alpha$ ) yang akan digunakan dan tentukan bobot awal kelas.
- Inputkan data dan kelas
- Lakukan jika ( $epoch \leq$  maksimum epoch dan  $\alpha \geq$  min  $\alpha$ ):

- Epoch = epoch + 1;
- Hitung jarak minimum, dapat menggunakan perhitungan jarak berikut:  
Jarak *Euclidean* antara vektor input X dengan vektor bobot W ke-i:

$$d(X, W_i) = \sqrt{\sum_{j=1} (X_j - W_{ij})^2} \tag{1}$$

Jarak *Manhattan* antara vektor input X dengan vektor bobot W ke-i:

$$d(X, W_i) = \sum_{j=1} |X_j - W_{ij}|^2 \tag{2}$$

Jarak *Chebychev* antara vektor input X dengan vektor bobot W ke-i:

$$d(X, W_i) = \max (|X_j - W_{ij}|)^2 \tag{3}$$

Keterangan :

d (X, W<sub>i</sub>) :jarak minimum vektor

X :vektor input yang akan diklasifikasikan

W<sub>i</sub> : vektor bobot ke-i pada layer output, yang merepresentasikan suatu kelas.

j : indeks pada atribut atau fitur.

- Lakukan pembaharuan bobot untuk memperbaharui bobot :

Apabila  $T = C_j$  maka :

$$W_j(\text{baru}) = W_j(\text{lama}) + \alpha[X_i - W_j(\text{lama})] \tag{4}$$

Apabila  $T \neq C_j$ , maka :

$$W_j(\text{baru}) = W_j(\text{lama}) - \alpha[X_i - W_j(\text{lama})] \tag{5}$$

Keterangan :

X : vektor pelatihan

T : Kelas yang benar pada Vektor pelatihan.

W<sub>j</sub> : vektor bobot pada output ke-j

C<sub>j</sub> : Kelas yang menampilkan output ke-j

- Hentikan proses jika tercapai maksimumEpoch.

- Setelah pelatihan selesai, akan diperoleh bobot akhir (w) setelah proses tersebut.


### 2.6 Pengujian dan Analisis

Pada langkah ini, pengujian data dengan berbagai masukan untuk melihat pengaruhnya terhadap akurasi. Dalam pengujian ini, 5 skenario berbeda diuji dengan bantuan *tools* Rapidminer dengan pengaturan parameter yang dapat disesuaikan. Pengujian tersebut yaitu pengujian jumlah neuron, jenis jarak, alpha, epoch, jumlah pembagian data latih.

### 2.7 Kesimpulan dan Saran

Tahapan ini, mencakup kesimpulan akhir penelitian. Selain itu, saran untuk penelitian lebih lanjut dimasukkan pada tahap ini.

## 3. HASIL DAN PEMBAHASAN



**Gambar 2.** Arsitektur LVQ Klasifikasi Keluarga Beresiko *Stunting*

Berdasarkan Gambar 2 tersebut, parameter X1 samapai X17 merepresentasikan neuron input yang digunakan, sedangkan kelas adalah neuron output yang dihasilkan dari perhitungan bobot. Pada neuron input X1 sampai X17, angka 1 diartikan sebagai “iya” dan angka 0 diartikan sebagai kata “tidak”. Pada data kelas, angka 1 merepresentasikan bahwa data tersebut masuk dalam keluarga beresiko *stunting* dan angka 2 masuk pada kelas keluarga tidak beresiko *stunting*. Daftar Kelas dan Bobot Parameter tercantum dalam Tabel 5 dan Tabel 6 berikut.

**Tabel 5.** Daftar Kelas

Neuron output	Nilai	Daftar Kelas
y1	1	Beresiko <i>Stunting</i>
y2	2	Tidak beresiko <i>Stunting</i>

**Tabel 6.** Bobot Parameter

Neuron Input	Keterangan	Kategori Keluarga Beresiko <i>Stunting</i>	
			Nilai
X1	Keluarga memiliki anak baduta (umur anak < 2 tahun)	“Tidak”	0
		“Iya”	1
X2	Keluarga memiliki anak balita (umur anak 2 – 5 tahun)	“Tidak”	0
		“Iya”	1
X3	Keluarga termasuk pasangan usia subur (umur istri 15 – 49 tahun)	“Tidak”	0
		“Iya”	1
X4	Keluarga termasuk pasangan usia subur (istri berusia 15-49 tahun dan sedang hamil)	“Tidak”	0
		“Iya”	1
X5	Terdapat anak yang putus sekolah dalam keluarga (usia 7 – 15 tahun)	“Tidak”	0
		“Iya”	1
X6	Keluarga tidak memiliki sumber penghasilan untuk makan	“Tidak”	0
		“Iya”	1
X7	Lantai rumah beralaskan tanah	“Tidak”	0
		“Iya”	1
X8	Makan makanan beragam (minimal 2 kali sehari)	“Tidak”	0
		“Iya”	1
X9	Keluarga kurang mampu	“Tidak”	0

		Iya	1
X10	Sumber air minum keluarga tidak layak	“Tidak”	0
		“Iya”	1
X11	Kondisi jamban keluarga tidak layak	“Tidak”	0
		“Iya”	1
X12	Keluarga tidak memiliki rumah layak huni	“Tidak”	0
		“Iya”	1
X13	Pendidikan terakhir ibu rendah (dibawah SLTP/Sederajat)	“Tidak”	0
		“Iya”	1
X14	Umur istri terlalu muda (< 20 tahun)	“Tidak”	0
		“Iya”	1
X15	Umur istri sangat tua (> 35 tahun)	“Tidak”	0
		“Iya”	1
X16	Jarak anak sangat dekat (< 2 tahun)	“Tidak”	0
		“Iya”	1
X17	Jumlah anak sangat banyak (> 2 anak)	“Tidak”	0
		“Iya”	1


Ada 23.607 data dan 17 parameter yang akan dianalisis. Kelas 1 mencakup 17.500 data dari keluarga berisiko *stunting*, sedangkan kelas 2 mencakup 6.107 data dari keluarga tidak berisiko *stunting*.

### 3.1 Pengujian dan Analisis

Setelah itu, pengujian data dilakukan dengan 5 parameter yang terdapat di dalam *tools Rapid Miner* diantaranya yaitu pengujian jumlah neuron, jenis jarak yang digunakan, *learning rate* atau alpha, epoch (iterasi), dan pembagian jumlah data latih .

#### 3.1.1 Pelatihan jumlah neuron

Pada pelatihan pertama, dilakukan pelatihan jumlah neuron , pelatihan dilakukan dengan menggunakan jumlah neuron yang berbeda (mulai dari 1 hingga 10), untuk parameter jarak yang digunakan jenis *eulidean distance* dan jumlah iterasi yang digunakan sebanyak 2.



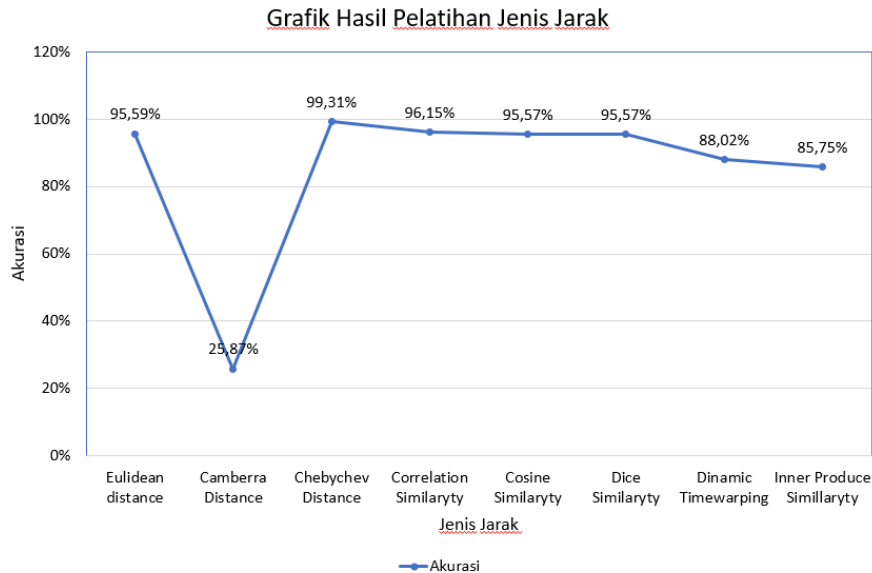
**Gambar 3.** Grafik Hasil Pelatihan Jumlah Neuron

Berdasarkan Gambar 3, setelah melakukan pelatihan jumlah neuron dari 1 sampai dengan 10. Pelatihan menghasilkan rata-rata maksimum pada jumlah neuron 7. Oleh karena itu, untuk pelatihan selanjutnya akan menggunakan jumlah neuron 7.

#### 3.1.2 Pelatihan Jenis Jarak

Berikutnya adalah pelatihan jarak pada LVQ. Untuk pengujian ini digunakan beberapa jenis jarak yang tersedia pada *tools rapid miner*. Selain itu, dalam pelatihan ini menggunakan jumlah neuron optimal yang ditentukan pada pengujian sebelumnya sebesar 7, alpha dengan nilai 0.1 , dan epoch sebanyak 2. Pengujian ini dilakukan untuk menentukan jenis jarak yang paling optimal dalam memisahkan data pada proses klasifikasi. Hal ini penting dilakukan untuk memastikan model yang dibangun memiliki performa yang optimal dalam klasifikasi. Gambar 4

berikut menampilkan hasil pengujian jenis jarak.




**Gambar 4.** Grafik hasil Pelatihan Jenis Jarak

Jadi, Berdasarkan grafik diatas, setelah dilakukan pengujian dari jenis jarak didapatkan hasil terbaik dengan menggunakan jenis jarak *Chebyshev* dengan nilai 99,31%. Maka untuk pengujian selanjutnya akan digunakan jumlah neuron 7 dan jenis jarak yang baik digunakan yaitu *Chebyshev distance*.

### 3.1.3 Pelatihan learning rate (Alpha)

Pelatihan kali ini dilakukan untuk mempelajari perubahan learning rate (alpha) terhadap kinerja model. Pelatihan menggunakan rentang alpha 0.1 hingga 1, jumlah neuron 7, jenis jarak chebyshev distance, dan banyak iterasi 2. Nilai alpha berpengaruh untuk mengontrol seberapa besar langkah yang diambil oleh algoritma pada setiap iterasi dalam mencari nilai bobot dan bias yang optimal. Butuh waktu yang lama untuk mencapai nilai optimum jika nilai alpha terlalu kecil. Sebaliknya jika nilai alpha terlalu besar, laju perhitungan kesulitan untuk mencapai konvergensi dan dapat melewati nilai optimum. Gambar 5 berikut ini menampilkan hasil pelatihan nilai alpha.




**Gambar 5.** Grafik Hasil Pelatihan Nilai Alpha

Berdasarkan pelatihan nilai alpha 0.1 hingga 1 pada Gambar 5, memperoleh hasil terbaik pada nilai alpha 0.1 dengan akurasi 99,31%. Jadi untuk skenario pelatihan berikutnya menggunakan nilai alpha 0.1.

### 3.1.4 Pelatihan Epoch (iteration)

Tujuan dari pelatihan ini adalah untuk mengetahui efek iterasi (epoch) yang optimal dalam proses pelatihan model. Dengan melakukan pelatihan jumlah iterasi diharapkan dapat mempercepat pelatihan dan meningkatkan akurasi klasifikasi. Jumlah iterasi (epoch) digunakan dari 1 sampai 10, jumlah neuron 7, jarak Chebyshev distance, dan nilai alpha 0.1. Gambar 6 berikut menggambarkan pengujian iterasi optimum.

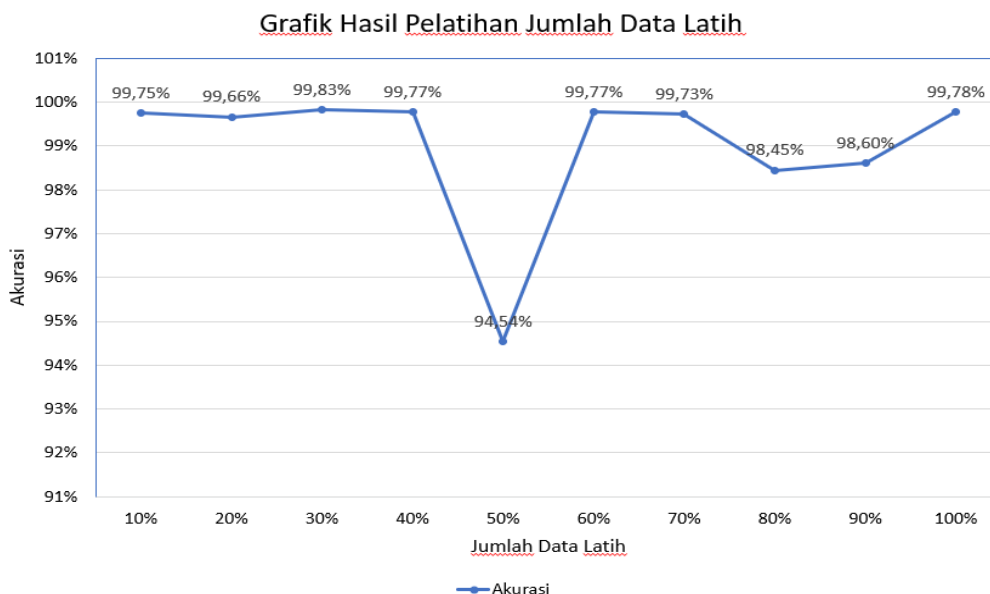


**Gambar 6.** Grafik Hasil Pelatihan Epoch (Iteration)

Dari hasil grafik tersebut, setelah melatih iterasi 1 sampai 10 diperoleh hasil yang optimal pada iterasi ke 7 dengan nilai 99.78 % , jadi untuk skenario berikutnya menggunakan iterasi 7.

### 3.1.5 Pelatihan Data latih

Untuk pelatihan terakhir, yaitu pelatihan banyak data latih. Pelatihan dilakukan untuk melihat pengaruh jumlah data latih terhadap nilai akurasi. Parameter yang digunakan dalam pelatihan yaitu, jumlah neuron 7, jarak *chebyshev distance*, nilai alpha 0.1, dan iterasi (epoch) 7. Pelatihan data latih sebanyak 10 % sampai 100 % dari seluruh dataset. Gambar 7.berikut menggambarkan hasil pelatihan pengaruh jumlah data latih.



**Gambar 7.** Grafik Hasil Pelatihan Jumlah Data Latih

Gambar 7 menunjukkan bahwa untuk mencapai akurasi 99.83%, jumlah data yang digunakan untuk pelatihan sebesar 30 % . Oleh karena itu, pada percobaan kelima ini, jumlah data pelatihan 30% dipilih. Setelah menyelesaikan semua skenario pelatihan, nilai optimal dipilih untuk setiap pelatihan, yaitu jumlah neuron 7, jarak chebychev, alfa 0.1, epoch (iterasi) sebanyak 7, dan 30 persen jumlah data latih. Nilai-nilai ini dapat dilihat pada

Tabel 7 berikut.

**Tabel 7.** Hasil Pelatihan 5 Skenario

No. Skenario	Jenis Pelatihan	Nilai Terbaik
1	Jumlah neuron	7
2	Jenis jarak	Chebychev distance
3	Learning Rate ( $\alpha$ )	0.1
4	Epoch (iterasi)	7
5	Jumlah data latih	30%
Akurasi yang didapatkan		99.83%

Berdasarkan hasil pelatihan pada Tabel 7, ditentukan rekomendasi parameter terbaik adalah jumlah neuron sebesar 7, jenis jarak *Chebychev*, *learning rate* 0.1, jumlah epoch yang ditetapkan sebesar 7, dan persentase data latih sebesar 30%. Semua penentuan tersebut didasarkan pada hasil pengujian dan evaluasi sebelumnya untuk mencapai hasil yang optimal dalam klasifikasi keluarga beresiko *stunting*. Semua penentuan tersebut didasarkan pada hasil pengujian dan evaluasi sebelumnya untuk mencapai hasil yang optimal dalam klasifikasi keluarga beresiko *stunting*. Berdasarkan hasil dari 5 proses skenario pengujian diperoleh akurasi 99.83%.

#### 4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan metode LVQ dalam klasifikasi keluarga beresiko *stunting* di Kampung KB Tunas Harapan. Penggunaan metode LVQ dengan jumlah neuron input sebanyak 7, *Chebychev distance* sebagai jenis jarak, *learning rate* 0.1, jumlah epoch 7, dan 30% data latih memberikan hasil yang optimal dengan tingkat akurasi mencapai 99.83%. Hal ini menunjukkan bahwa metode LVQ mampu meningkatkan akurasi proses klasifikasi keluarga beresiko *stunting*. Hasil ini dapat menjadi solusi yang efektif dalam upaya pengentasan *stunting* di Kampung KB Tunas Harapan dan memberikan kontribusi positif dalam peningkatan program kesehatan masyarakat. Dengan demikian, penelitian ini membuka peluang untuk pengembangan lebih lanjut dan penerapan metode LVQ dalam konteks klasifikasi keluarga beresiko *stunting* serta masalah sejenis lainnya. Adapun saran penelitian selanjutnya, dapat dilakukan perbandingan dengan menggunakan metode klasifikasi lainnya yang mungkin dapat menghasilkan nilai akurasi yang lebih baik.

#### REFERENCES

- [1] K. Rahmadhita, "Permasalahan *Stunting* dan Pencegahannya," *J. Ilm. Kesehat. Sandi Husada*, vol. 11, no. 1, pp. 225–229, 2020, doi: 10.35816/jiskh.v11i1.253.
- [2] D. Millati, Nisrina Anis, *Cegah Stunting Sebelum Genting : Peran Remaja Dalam Pencegahan Stunting*. Jakarta: KPG (Kepustakaan Populer Gramedia ), 2021.
- [3] I. A. D. Wira, "Faktor-Faktor yang Mempengaruhi *Stunting* pada Balita," *PRAMANA J. Has. Penelit.*, vol. 2, no. 2, pp. 213–219, 2022, [Online]. Available: <http://stahnmpukuturan.ac.id/jurnal/index.php/pramana/article/view/2723>.
- [4] Kementerian Kesehatan Republik Indonesia, *Buku Saku Hasil Studi Status Gizi Indonesia ( SSGI) Tingkat Nasional, Provinsi, dan Kabupaten/Kota Tahun 2021*. 2021.
- [5] S. Mustika and C. Khairunnisa, "Prevalensi *Stunting* pada Siswa SMP Negeri 7 Lhokseumawe Abstrak Pendahuluan malnutrisi zat gizi kronis atau penyakit infeksi kronis maupun berulang yang ditunjukkan Republik Indonesia ( Kemenkes RI ) hanya terbatas pada kelompok usia Balita . Penelitian," *Galen. J. Kedokt. dan Kesehat. Mhs. Malikussaleh*, vol. 1, no. 4, 2022.
- [6] T. A. Rofiah, N. M. Syaroh, M. Safitri, F. V. Satriaji4, and T. M. Fahrudin, "Monitoring pada Keluarga dengan Anak Berisiko *Stunting* di Desa Candiharjo Kecamatan Ngoro," *KARYA UNGGUL J. Pengabd. Kpd. Masy.*, vol. 1, pp. 43–52, 2022.
- [7] Badan Kependudukan Dan Keluarga Berencana Nasional, "Peraturan Badan Kependudukan Dan Keluarga Berencana Nasional RI No. 12 Tahun 2021 Tentang Percepatan Penurunan Angka *Stunting* Indonesia Tahun 2021-2024," vol. 2, no. 1, pp. 1–5, 2021.
- [8] "BKKBN Riau giatkan 'celengan' masyarakat cegah *stunting* - ANTARA News." <https://www.antaraneews.com/berita/3204525/bkkbn-riau-giatkan-celengan-masyarakat-cegah-stunting> (accessed Dec. 04, 2022).
- [9] "Geliat Kampung KB Tuah Madani Melalui Inovasi "Cemara *Stunting* ." " <https://rri.co.id/pekanbaru/kesehatan/70434/geliat-kampung-kb-tuah-madani-melalui-inovasi-%22cemara-stunting%22> (accessed Dec. 04, 2022).
- [10] M. S. A. I Gusti Ayu Agung Diatri Indradewi, "Jaringan Syaraf Tiruan LVQ Berbasis Parameter HSV dalam Penentuan Uang Jaringan Syaraf Tiruan LVQ Berbasis Parameter HSV dalam Penentuan Uang Rupiah Palsu," vol. 13, no. January 2019, pp. 47–52, 2020.
- [11] Eko Prasetyo, *Data mining konsep dan aplikasi menggunakan MATLAB*, 1st ed. CV Andi Offset, 2012.
- [12] M. R. Rahimi and H. Hartatik, "Penerapan Algoritma Learning Vector Quantization dalam Pengklasifikasian Tingkat



- Pencemaran Air Sungai,” *Semnasteknomedia Online*, vol. 4, no. 1, pp. 4-9-1, Feb. 2016, Accessed: Dec. 13, 2022. [Online]. Available: <https://ojs.amikom.ac.id/index.php/semnasteknomedia/article/view/1180>.
- [13] R. Tantiati, M. T. Furqon, and C. Dewi, “Implementasi Metode Learning Vector Quantization (LVQ) untuk Klasifikasi Persalinan,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 10, pp. 9701–9707, 2019.
- [14] E. Setyowati and S. Mariani, “Penerapan Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) untuk Klasifikasi Penyakit Infeksi Saluran Pernapasan Akut (ISPA),” *Prism. Pros. Semin. Nas. Mat.*, vol. 4, pp. 514–523, 2021.
- [15] N. .H. . M. Iin Sulistya, “Prediksi Status Gizi Balita Menggunakan Algoritma Learning Vector Quantization (Lvq) (Studi Kasus: Posyandu Di Pengungsian Kelurahan Petobo),” Universitas Taduloko, Palu, 2020.
- [16] R. Arifando, N. Hidayat, and A. A. Soebroto, “Klasifikasi Calon Penerima Bantuan Keluarga Miskin Menggunakan Metode Learning Vector Quantization (LVQ) (Studi Kasus: Daerah Kecamatan Mlandingan, Situbondo),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 6, pp. 2173–2181, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>.
- [17] V. C. Pamungkas, L. Muflikhah, and R. C. Wihandika, “Klasifikasi Penerimaan Program Keluarga Harapan (PKH) Menggunakan Metode Learning Vector Quantization (Studi Kasus Desa Kedungjati),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2659–2666, 2019.
- [18] R. Syahputra and W. Riansah, “Prediksi Penerima Bantuan Pangan Non-Tunai Dengan Metode Learning Vector Quantization Pada Desa Tanjung Selamat,” *J. Educ. ...*, vol. 9, no. 4, pp. 96–100, 2021, [Online]. Available: <http://journal.ipts.ac.id/index.php/ED/article/view/3042%0Ahttp://journal.ipts.ac.id/index.php/ED/article/download/3042/1991>.
- [19] Mayang Hermeiliza Eka Putri, “Perbandingan Metode Learning Vector Quantization Dan Self Organizing Map Pada Klasifikasi Data Akreditasi,” Universitas Sriwijaya, Palembang, 2020.
- [20] E. Tita Tosida, F. Delli Wihartiko, and I. Lumesa, “Learning Vector Quantization Implementation to Predict the Provision of Assistance for Indonesian Telematics Services SMES,” *Int. J. Eng. Technol.*, vol. 7, no. 3.20, p. 381, 2018, doi: 10.14419/ijet.v7i3.20.20576.
- [21] H. Harliana and S. Kirono, “Penerapan Learning Vector Quantization Dalam Memprediksi Jumlah Rumah Tangga Miskin,” *J. Sains dan Inform.*, vol. 5, no. 2, pp. 118–127, 2019, doi: 10.34128/jsi.v5i2.192.