

## Klasifikasi Berat Badan Lahir Rendah (BBLR) Pada Bayi Dengan Metode *Learning Vector Quantization* (LVQ)

Suryani Agustin<sup>1</sup>, Budi Darma Setiawan<sup>2</sup>, Mochammad Ali Fauzi<sup>3</sup>

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya  
Email: <sup>1</sup>suryaniagustin88@gmail.com, <sup>2</sup>s.budidarma@ub.ac.id, <sup>3</sup>moch.ali.fauzi@ub.ac.id

### Abstrak

Berat Badan Lahir Rendah (BBLR) merupakan kondisi dari bayi yang lahir memiliki berat kurang dari 2500 gram atau 2.5 kg. BBLR adalah salah satu faktor dari kematian bayi di Indonesia. Pencegahan dan penanganan pada ibu hamil saat mengetahui akan melahirkan bayi dengan kondisi BBLR sangat diperlukan, demi meminimalisir kematian saat proses kelahiran. Maka dari itu diharapkan dengan adanya sistem klasifikasi berat badan lahir rendah pada bayi ini dapat membantu untuk mengidentifikasi kondisi bayi pada ibu hamil sebelum bayi dilahirkan. Pada penelitian digunakan metode *Learning Vector Quantization* (LVQ) dengan 96 data dan 6 fitur yaitu usia, pendidikan, paritas, interval kelahiran, hemoglobin dan status gizi. Yang akan mengklasifikasikan ke dalam dua kelas yaitu kelas kasus yang berarti bayi lahir dengan BBLR dan kelas kontrol yang berarti bayi lahir tidak mengalami BBLR. Berdasarkan hasil pengujian yang dilakukan, sistem menghasilkan rata-rata akurasi sebesar 60.5% dengan menggunakan parameter optimal untuk *learning rate* 0.1, pengurang *learning rate* 0.1 dan maksimum epoch 5. Untuk pengujian *k-fold cross validation* nilai akurasi tertinggi sebesar 58.3% dan nilai akurasi rata-ratanya adalah 46.85%.

**Kata kunci:** klasifikasi, berat badan lahir rendah, bayi, *learning vector quantization*

### Abstract

*Low Birth Weight (LBW) is the condition as a birth weight of a baby less than 2500 grams or 2.5 kg.. LBW is a factor of infant mortality in Indonesia. The prevention and treatment of pregnant women when they know they will give birth to babies with LBW are very necessary, in order to minimize the death during the birth process. Therefore, it is expected that the existence of a low birth weight classification system in infant can help to identify the condition of the baby in pregnant women before the baby is born. This research use the Learning Vector Quantization (LVQ) method with 96 data and 6 features, there are age, education, parity, birth interval, hemoglobin and nutritional status. Those who will classify into two classes first is case class, which means the baby is born with LBW and the control class means that the baby is born without LBW. Based on the results of testing, the system produces an average accuracy is 60.5% using optimal parameters for learning rate 0.1, learning rate decrement 0.1 and maximum epoch is 5. In the k-fold cross validation testing the best accuracy value is 58.3% and the average accuracy is 46.85%.*

**Keywords:** classification, low birth weight, infant, *learning vector quantization*

## 1. PENDAHULUAN

Angka Kematian Bayi (AKB) menjadi faktor keberhasilan dari pembangunan dalam bidang kesehatan. Presentase nilai AKB yang masih tinggi telah mendapat perhatian lebih dan menjadi fenomena diberbagai negara berkembang, termasuk Indonesia. Pada tahun 2015, Indonesia memiliki angka AKB yang jauh dari tujuan yang ingin diraih sesuai dengan hasil

perencanaan pembangunan (Depkes RI, 2005). Berdasarkan survei pada tahun 2012 yang dilakukan oleh lembaga Survei Demografi dan Kesehatan Indonesia (SDKI), angka kematian bayi yang ada di Indonesia yakni sebanyak 32 kematian setiap 1000 kelahiran. Penyebab tertinggi dari kematian bayi yang baru lahir di Indonesia adalah asfiksia 27%, Berat Badan Lahir Rendah (BBLR) 29%, dan lain-lain 44% (JNPK-KR, 2008). Dari angka tersebut

menunjukkan bahwa penyebab terbesar dari kematian bayi di Indonesia adalah BBLR. BBLR adalah kondisi dari seorang bayi yang lahir dengan berat kurang dari 2500 gram atau 2.5 kg. BBLR dapat terjadi pada kondisi bayi prematur yang lahir kurang bulan maupun bayi yang lahir cukup bulan dan memiliki masalah pada proses pertumbuhannya selama masa kehamilan (Sutarjo, 2014).

Data WHO juga mencatat bahwa presentase kelahiran BBLR di Indonesia mencapai 15.5% dan berada dalam peringkat ke sembilan dunia. Maka bisa diambil kesimpulan bahwa dalam setahun ada satu dari sepuluh bayi yang lahir di Indonesia mengalami BBLR. Pada tahun 2013 berdasarkan hasil pengamatan dari Riset Kesehatan Dasar (Riskesdas) menunjukkan bahwa presentase balita dengan usia 0-59 bulan lahir mengalami BBLR 10.25%. Presentase yang paling tinggi terjadi di daerah Sulawesi Tengah yakni sebesar 16.8% dan yang paling rendah di ada provinsi Sumatra Utara yakni sebesar 7.2% (Kemenkes RI, 2014). Menurut data yang ada pada dinas kesehatan Kota Malang tahun 2011, angka bayi lahir dengan BBLR terjadi sebanyak 363 proses kelahiran. Sementara di RSUD Dr. Syaiful Anwar Malang tercatat ada 107 kelahiran yang mengalami BBLR periode tahun 2011 (Dinas Kesehatan Malang, 2011).

Cukup tingginya angka kelahiran bayi yang mengalami BBLR di Indonesia disebabkan banyaknya faktor diantaranya yaitu usia ibu hamil, kelahiran dengan usia kandungan yang sangat muda ataupun sangat tua, jarak antar kehamilan, jumlah kehamilan sebelumnya, kandungan gizi dan kadar hemoglobin dari ibu hamil juga turut berperan menjadi penyebab BBLR. Faktor pendukung lainnya yang menjadi penyebab kelahiran BBLR adalah beban pekerjaan yang terlalu berat saat ibu sedang mengandung juga jenjang pendidikan yang ditempuh calon ibu (Mitayani, 2009).

Penelitian yang mengangkat permasalahan BBLR pernah dilakukan (Yasin & Aspriyanti, 2017) dengan metode *Weighted Probabilistic Neural Network* (WPNN). WPNN merupakan salah satu bentuk modifikasi dari algoritme Probabilistic Neural Network (APNN) dengan ditambahkan faktor pemberi bobot diantara lapisan penjumlahan dan lapisan pola. WPNN merupakan salah satu anggota dari algoritme klasifikasi jaringan syaraf yang menggunakan fungsi probabilistik. Hasil dari penelitian ini menunjukkan bahwa klasifikasi pada BBLR dengan metode WPNN memiliki tingkat

keakuratan sebesar 94.44%. Namun metode ini mempunyai kelemahan yaitu untuk menentukan parameter *smoothing* nya harus dilakukan dengan cara *trial and error*. Sehingga memerlukan banyak waktu percobaan untuk mendapatkan parameter yang optimal untuk menghasilkan nilai akurasi yang diinginkan.

Selain algoritme WPNN, terdapat algoritme *Learning Vector Quantization* (LVQ) yang juga bagian dari jaringan syaraf tiruan. Algoritme LVQ adalah algoritme klasifikasi terhadap pola yang pada masing-masing *outputnya* dapat mewakili dan menghasilkan kelas tertentu. Terdiri dari *input layer* dan *output layer*. Walaupun LVQ juga memiliki parameter masukan, namun parameter pada LVQ nilai optimalnya lebih bisa diprediksi dengan menjadikan referensi pada penelitian sebelumnya menjadi acuan. Menurut penelitian yang sudah dilakukan sebelumnya menunjukkan bahwa metode LVQ menghasilkan akurasi yang tinggi.

Seperti halnya penelitian yang sudah dilakukan oleh (Agustinus, 2018) yaitu mengklasifikasikan risiko hipertensi menggunakan metode *Learning Vector Quantization* (LVQ). Dari hasil penelitian tersebut diperoleh hasil akurasi sistem sebesar 93.841%. Data atau masukan yang diperlukan untuk bisa mendeteksi penyakit melalui sebuah sistem adalah dengan menggunakan rekaman medis pasien dari hasil pemeriksaan pasien.

Dengan adanya beberapa penjelasan diatas, penulis akan mengangkat judul penelitian ***Klasifikasi Berat Badan Lahir Rendah (BBLR) Pada Bayi Dengan Metode Learning Vector Quantization (LVQ)***. Penelitian ini memiliki tujuan untuk mengetahui nilai parameter yang optimal untuk pengklasifikasian BBLR dengan metode LVQ dan juga akurasi yang dihasilkan oleh sistem.

## 2. DASAR TEORI

### 2.1 Berat Badan Lahir Rendah (BBLR)

Bayi yang mengalami Berat Badan Lahir

Rendah (BBLR) adalah jika berat bayi tersebut kurang dari angka 2500 gram atau 2.5 kg tanpa melihat periode waktu bayi berada dalam rahim (gestasi). BBLR dapat terjadi dikarenakan usia kehamilan yang kurang dari usia normal yaitu 37 minggu dan berat bayi pun lebih rendah dari bayi pada umumnya. (Manuaba, 2007). Pada tahun 1961, WHO telah menetapkan bahwa bayi yang

baru lahir dan mempunyai berat kurang dari berat bayi normal yaitu 2500 gram disebut *Low Birth Weight Infants (LBWI)*.

Faktor yang menyebabkan seorang bayi terlahir BBLR adalah sebagai berikut (Setaningrum, 2005):

1. Usia Ibu Hamil
 

Faktor usia memiliki peranan yang sangat penting terhadap masalah kesehatan pada ibu hamil dan bayinya, maka dianjurkan untuk merencanakan kehamilan saat usia sudah memasuki 20-30 tahun (Setaningrum, 2005)
2. Jarak Kehamilan
 

Jarak kehamilan yang sangat dekat akan mempengaruhi proses hilangnya kalsium pada tulang, terutama ibu hamil yang asupan hariannya kurang terpenuhi (Purwoastuti, 2009).
3. Paritas
 

Proses kehamilan yang berulang menjadikan dampak kerusakan pada dinding pembuluh darah di dalam rahim, kondisi ini dapat mengakibatkan terganggunya kandungan nutrisi pada janin untuk kehamilan berikutnya yang dapat mempengaruhi proses pertumbuhan pada janin sehingga akan terlahir bayi dengan kondisi BBLR (Wiknjosastro, 2002).
4. Kadar Hemoglobin (HB)
 

Ibu hamil yang terkena anemia akan menaikkan risiko BBLR pada bayinya, risiko terjadinya pendarahan sebelum persalinan dan saat proses persalinan berlangsung dapat menjadi sebab dari kematian pada ibu dan bayi yang ada di dalam kandungan jika ibu tersebut mengalami anemia yang cukup parah (Depkes RI, 2008).
5. Status Gizi Ibu Hamil
 

Menurut (Risesdas, 2007) kandungan gizi pada ibu hamil dapat mempengaruhi berat bayi yang akan dilahirkan, maka dari itu memperhatikan asupan makanan pada ibu hamil sangatlah penting dilakukan. Pengukuran antropometri adalah sebuah cara untuk menghitung status gizi dari ibu hamil. Ukuran antropometri ibu hamil yang biasa dilakukan adalah dengan mengukur berat badan dan mengukur Lingkar Lengan Atas (LILA) pada saat proses kehamilan.

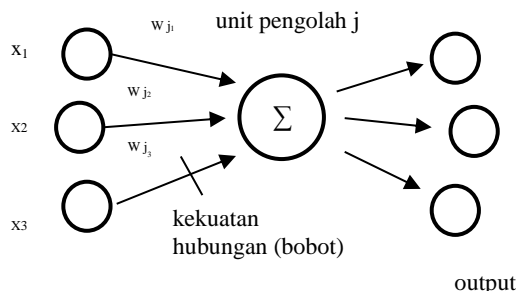
6. Pendidikan

Tingkat pendidikan berpengaruh pada perubahan dalam bersikap dan berperilaku hidup sehat. Tingkat pendidikan yang lebih tinggi kebanyakan akan lebih mempermudah penyerapan informasi dan dapat diterapkan dalam kehidupan sehari-hari (Kemenkes RI, 2014).

2.2 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan

sebuah prinsip dari proses komputasi yang cara berpikirnya meniru jaringan syaraf biologis yang ada pada otak manusia. JST digunakan untuk meringankan kerja berbagai bidang diantaranya pengolahan sinyal, pengenalan pola, kecerdasan buatan dan lainnya (Sudarto, 2002). Kelebihan yang dimiliki JST yaitu kemampuannya untuk melakukan proses generalisasi dari data training menjadi kumpulan data baru. Kemampuan ini diibaratkan seperti proses seorang manusia saat mengenali sesuatu yang baru (May, Sunardi, & Hidayatno, 2002). Struktur jaringan syaraf tiruan ditunjukkan pada Gambar 1.



Gambar 1 Arsktekur Jaringan Syaraf Tiruan

Sumber : (Wuryandari & Afrianto, 2012)

2.3 Learning Vector Quantization (LVQ)

Learning Vector Quantization (LVQ) adalah

salah satu algoritme klasifikasi terhadap sebuah pola yang pada setiap *outputnya* dapat merepresentasikan, mewakili dan menghasilkan sebuah kelas tertentu. Proses yang berlangsung dalam tiap neuron bertujuan untuk mencari jarak yang paling dekat antara bobot dan vektor *input* yang saling berhubungan (Kusumadewi & Sri Hartati, 2006). Kelas atau kategori yang didapatkan dari hasil perhitungan pada lapisan kompetitif bergantung pada jarak antar vektor bobot dan vektor *input* dari suatu kelas. Ketika suatu vektor masukan mendekati nilai vektor bobot dari suatu kelas maka lapisan pada

jaringan kompetitif akan melakukan pengelompokan vektor *input* ke kelas yang sesuai (Dillak, Pangestuty, & Bintiri, 2012).


Secara umum langkah-langkah dari algoritme LVQ adalah (Fausett, 1994):

1. Inisialisasi variabel masukan yaitu vektor (X), bobot awal (Wj), *learning rate* ( $\alpha$ ).
2. Jika kondisi berhenti belum terpenuhi, kerjakan langkah no. 3-6
3. Setiap vektor masukan data latih (X) akan mengerjakan langkah 4-5
4. Hitung jarak terkecil  $|X_i - W_j|$  (1)
5. Ubah nilai Wj dengan ketentuan:  
 Jika  $T = C_j$  maka  
 $W_j = W_j + \alpha (X - W_j)$  (2)  
 Jika  $T \neq C_j$  maka  
 $W_j = W_j - \alpha (X - W_j)$  (3)
6. Kurangi nilai *learning rate*  
 $\alpha = \alpha * dec \alpha$  (4)
7. Berhenti ketika mencapai iterasi tertentu dan *learning rate* mencapai nilai terkecil.

Keterangan:

- X = Vektor masukan pada data
- T = Kelas asli
- Wj = Bobot dari vektor
- Cj = Kelas dari sistem
- $|X_i - W_j|$  = Jarak euclidean *input* dan bobot

LVQ memiliki arsitektur jaringan yang terdiri dari masukan, bobot dan keluaran. Penelitian ini menggunakan arsitektur jaringan LVQ yang terlihat pada Gambar 2.



Gambar 2 Arsitektur Learning Vector Quantization (LVQ)

### 3. DATA DAN METODE

#### 3.1. Data Penelitian

Pada penelitian ini, data yang digunakan adalah berupa data sekunder, yaitu data rekam medis pasien yang melakukan proses persalinan di puskesmas Jumpandang Baru, Makassar periode 1 Januari 2014-31 Desember 2014. Datanya berjumlah 96 dengan 48 kategori kasus dengan nilai 1 yang berarti bayi mengalami BBLR dan 48 kategori kontrol dengan nilai 2 yang berarti bayi tidak mengalami BBLR. Terdapat 6 fitur diantaranya yaitu usia ibu hamil, pendidikan terakhir ibu hamil, jarak atau interval kehamilan, paritas, hemoglobin dan juga status gizi yang ditentukan menggunakan pengukuran Lingkar Lengan Atas (LILA). Data yang digunakan ditunjukkan pada Tabel 1.

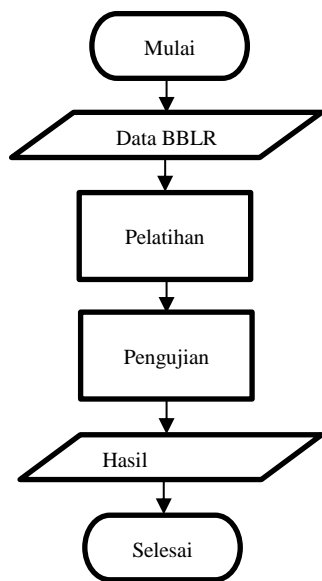
Tabel 1 Data Penelitian

Usia	Didik	Paritas	Interval	HB	LILA	BBLR
21	3	2	2	11.6	22	1
22	2	2	4	12	23	1
27	4	2	2	11.8	23	1

35	4	3	3	11	24	2
27	3	4	3	9	24.5	2
23	2	2	3	12.2	20	2

### 3.2. Metode Usulan

Penelitian ini menggunakan metode *Learning Vector Quantization (LVQ)*. Terdapat beberapa tahapan dalam menerapkan algoritme LVQ dalam sistem. Secara umum proses dari sistem ditunjukkan pada Gambar.3



Gambar 3 Diagram Alir Kerja Sistem Secara Umum

#### 3.2.1 Pelatihan Data

Proses pelatihan merupakan proses awal dari algoritme LVQ. Proses pelatihan dimulai dari memasukkan beberapa parameter seperti  $\alpha$ ,  $\text{dec } \alpha$  dan maksimum epoch. Kemudian akan dilakukan proses perhitungan jarak dengan *euclidean* dan dicari jarak minimumnya. Setelah kelas dari vektor input didapatkan langkah selanjutnya adalah memperbarui nilai bobot yang hasilnya akan mendekati atau menjauhi kelas tertentu. Setelah berjalan satu epoch maka akan dilakukan pengurangan pada nilai  $\alpha$ . Proses ini dilakukan berulang kali hingga kondisi berhenti tercapai. Setelah proses pelatihan berjalan dan kondisi berhenti tercapai, maka akan dihasilkan nilai bobot akhir yang digunakan untuk dasar dalam proses pengujian.

#### 3.2.2 Pengujian Data

Setelah proses pelatihan dijalankan maka tahap berikutnya adalah melakukan proses pengujian. Pada tahap pengujian akan diketahui hasil dari akurasi perhitungan dengan menggunakan algoritme LVQ. Proses pengujian dimulai dari memasukkan bobot akhir dari hasil

pelatihan dan juga data uji. Kemudian dari kedua vektor tersebut dihitung jarak euclidean. Kelas yang mempunyai jarak terdekat akan menjadi kelas dari data uji tersebut.

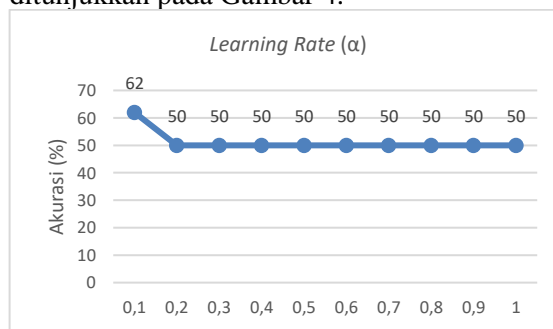
## 4. HASIL DAN PEMBAHASAN

Pada proses penelitian ini terdapat proses pengujian akurasi dengan beberapa parameter diantaranya *learning rate*, pengurang *learning rate* dan maksimum epoch. terdapat pengujian data *k-fold cross validation* untuk melihat apakah ada ditemukan pengaruh dari pertukaran data yang digunakan sebagai data latih maupun data uji.

Setiap pengujian akan dilakukan 10 kali percobaan dengan nilai bobot awal yang berbeda. Dengan parameter *learning rate* 0.1, pengurang *learning rate* 0.1 dan maksimum epoch 20. Perbandingan data latih dan data uji yang digunakan yaitu 80:20. Sebanyak 76 data latih dan data uji sebanyak 20. Hasil dari proses pengujian digambarkan dalam bentuk grafik dengan angka untuk memudahkan proses analisis hasil.

### 4.1 Pengujian Learning Rate ( $\alpha$ )

Tujuan dari pengujian ini adalah untuk mengetahui pengaruh dari parameter *learning rate* kepada hasil akurasi dari proses pengujian, karena *learning rate* merupakan parameter yang mempunyai pengaruh perubahan bobot data, makin tinggi nilainya maka makin jauh jarak antara bobot awal dengan bobot baru yang dihasilkan. Pada pengujian ini nilai *learning rate* yang digunakan adalah 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, dan 1. Pengujian *learning rate* ditunjukkan pada Gambar 4.



Gambar 4. Pengujian Learning Rate ( $\alpha$ )

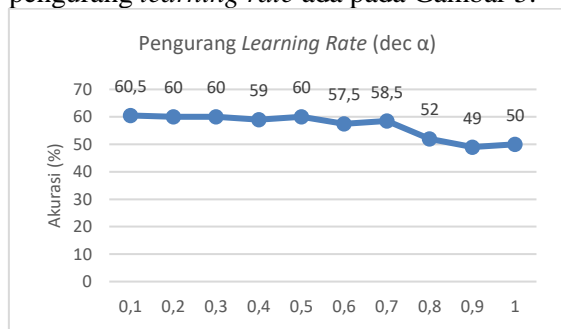
Pada pengujian ini dihasilkan akurasi tertinggi sebesar 62% pada *learning rate* 0.1 dan akurasi terendah sebesar 50% dengan nilai 0.2 sampai 1. Grafik menunjukkan tren menurun kemudian konstan hingga akhir.. Hal ini disebabkan karena pada proses pengujian



pertama selama 10 kali percobaan dengan nilai 0.1 sudah mencapai konvergen. Dengan demikian 0.1 dijadikan sebagai nilai parameter *learning rate* untuk proses pengujian berikutnya.

**4.2 Pengujian Pengurang *Learning Rate* (dec  $\alpha$ )**

Tujuan dari pengujian ini yaitu untuk mengetahui pengaruh dari parameter pengurang *learning rate* kepada hasil akurasi dari proses pengujian, karena nilai pengurang *learning rate* mempunyai pengaruh untuk memperkecil nilai *learning rate* agar dapat mencapai bobot yang ideal. Pada pengujian ini nilai pengurang *learning rate* yang digunakan adalah 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, dan 1. Pengujian pengurang *learning rate* ada pada Gambar 5.

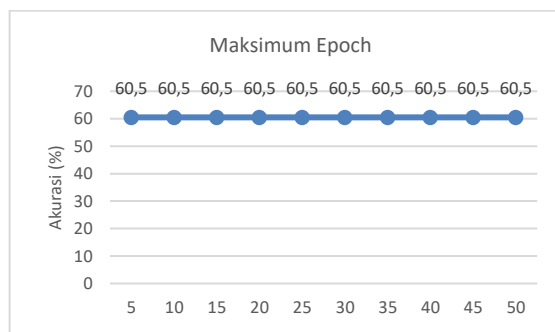


Gambar 5 Pengujian Pengurang *Learning Rate* (dec  $\alpha$ )

Pada pengujian ini dihasilkan akurasi tertinggi sebesar 60.5% pada *learning rate* 0.1 dan akurasi terendah sebesar 49% dengan nilai 0.9. Grafik menunjukkan tren cenderung menurun hingga nilai parameter terakhir. Maka dapat dikatakan makin besar nilai pengurang *learning rate*, akan menghasilkan akurasi yang rendah. Hal ini bisa terjadi karena jika nilai pengurang *learning rate* makin besar, maka nilai dari *learning rate* pun makin besar dan mengakibatkan sulitnya mencapai konvergensi pada perubahan bobot. Dengan demikian 0.1 dijadikan sebagai nilai parameter pengurang *learning rate* untuk proses pengujian berikutnya.

**4.3 Pengujian Maksimum Epoch**

Pengujian ini memiliki tujuan untuk mengetahui dan melihat pengaruh dari nilai maksimum epoch kepada nilai hasil akurasi dari pengujian, karena maksimum epoch adalah syarat berhenti dari proses pelatihan, maka makin tinggi nilai epochnya, makin banyak juga perulangan yang dilakukan. Pengujian ini menggunakan nilai maksimum epoch 5, 10, 15, 20, 25, 30, 35, 40, 45 dan 50. Pengujian maksimum epoch ditunjukkan pada Gambar 6.



Gambar 6 Pengujian Maksimum Epoch

Pada pengujian ini dihasilkan akurasi tertinggi sebesar 60.5% pada maksimum epoch 5 dan berlangsung konstan hingga parameter epoch terakhir yaitu 50. Grafik menunjukkan tren yang tetap. Hal ini menunjukkan bahwa pada nilai epoch 5, sudah mencapai rata-rata nilai akurasi maksimum dan semua batas maksimal epoch menghasilkan akurasi yang stabil. Dengan demikian nilai 5 dijadikan sebagai nilai parameter maksimum epoch untuk proses pengujian berikutnya.

**4.4 Pengujian *K-Fold Cross Validation***

Pengujian ini bertujuan untuk melihat pengaruh dari pertukaran data latih dan data uji menggunakan pengujian *k-fold cross validation* dengan nilai  $k=4$ . Parameter yang akan digunakan yaitu parameter dengan nilai terbaik pada hasil pengujian sebelumnya. Dengan menggunakan parameter *learning rate* 0.1, pengurang *learning rate* 0.001 dan maksimum epoch 5. Pengujian *k-fold cross validation* ditunjukkan pada Tabel 2.

Tabel 2 K-Fold Cross Validation

Fold	Data	Kelompok	Akurasi (%)
1	Data Latih	D2, D3, D4	58.3
	Data Uji	D1	
2	Data Latih	D1, D3, D4	50
	Data Uji	D2	
3	Data Latih	D1, D2, D4	41.6
	Data Uji	D3	
4	Data Latih	D1, D2, D3	37.5
	Data Uji	D4	
Rata-rata			46.85

Dari Tabel 2 menunjukkan bahwa akurasi terbaik berada pada fold 1 dengan nilai sebesar 58.3% dengan data latih yaitu gabungan kelompok D2, D3 dan D4 dan data uji nya yaitu

kelompok D1. Sedangkan untuk rata-rata akurasi hasil pengujian *k-fold cross validation* adalah sebesar 46.85%. Terjadinya perbedaan akurasi pada tiap fold menandakan bahwa persebaran nilai pada data tidak merata. Dan dapat disimpulkan bahwa pertukaran kombinasi antara data latih dan data uji bisa mempengaruhi nilai akurasi yang dihasilkan

## 5. PENUTUP

Berdasarkan semua tahap penelitian yang telah dilakukan berawal dari proses perancangan, implementasi dan pengujian sistem. Maka kesimpulan yang bisa diperoleh dari penelitian ini adalah:

1. Dari semua proses pengujian yang dilakukan dengan menggunakan parameter yang telah ditentukan, sistem menghasilkan rata-rata akurasi tertinggi pada parameter *learning rate* 0.1, pengurang *learning rate* 0.1, dan maksimum epoch sebanyak 5.
2. Berdasarkan nilai optimal parameter yang telah didapatkan, sistem menghasilkan rata-rata akurasi terbaik sebesar 60.5%. Sedangkan untuk rata-rata akurasi yang didapatkan setelah pengujian *k-fold cross validation* adalah sebesar 46.85%. Akurasi menunjukkan nilai cukup rendah dikarenakan fitur dari data yang digunakan memiliki nilai information gain yang kecil

Adapun saran untuk pengembangan atau penelitan selanjutnya yaitu dengan menambahkan seleksi fitur untuk menghasilkan fitur yang baik, menggabungkan dengan algoritme lainnya selain LVQ. Sistem juga dapat ditambahkan (*Graphical User Interface*) GUI agar dapat memudahkan pengguna dalam mengoperasikannya.

## 6. DAFTAR PUSTAKA

- Agustinus, I. (2018). Klasifikasi Risiko Hipertensi Menggunakan Metode Learning Vector Quantization (LVQ).
- Depkes RI. (2005). *Angka Kematian Ibu dan Angka Kematian Bayi*. Jakarta: Depkes RI.
- Depkes RI. (2008). *Tetanus Neonatorum dan Bayi Berat Lahir Rendah*. Jakarta: Depkes RI.
- Dillak, Pangestyuty, & Bintiri. (2012). Klasifikasi Jenis Musik Berdasarkan File Audio Menggunakan Jaringan Syaraf Tiruan Learning Vector Quantization. *Seminar Nasional Informatika 2012*.
- Dinas Kesehatan Malang. (2011). *Profil Kesehatan Kota Malang*. Malang: Dinas Kesehatan Malang.
- Fausett, L. (1994). *Fundamentals of Neural Network : Architectures, Algorithms, and Applications*. New Jersey: Prentice-Hall, Inc.
- JNPK-KR. (2008). *Pelatihan Klinik Asuhan Persalinan Normal*. Jakarta: Jaringan Nasional Pelatihan Klinik-Kesehatan Reproduksi.
- Kemendes RI. (2014). *Profil Kesehatan Republik Indonesia tahun 2013*. Jakarta: Kementerian Kesehatan RI.
- Kusumadewi, S., & Sri Hartati. (2006). *Neuro Fuzzy : Integrasi Sistem Fuzzy dan Jaringan Syaraf, Edisi pertama*. Yogyakarta: Graha Ilmu.
- Manuaba. (2007). *Pengantar Kuliah Obstetri*. Jakarta.
- May, I. L., Sunardi, & Hidayatno, A. (2002). Pengenalan Vokal Bahasa Indonesia dengan Jaringan Syaraf Tiruan Melalui Transformasi Wavelet Diskret.
- Mitayani. (2009). *Asuhan Keperawatan Maternitas*. Jakarta: Salemba Medika.
- Purwoastuti, E. (2009). *Waspada Osteoporosis*. Yogyakarta: Kanisius.
- Riskesdas. (2007). *Gizi pada Ibu Hamil*. Jakarta: Riskesdas RI.
- Setaningrum, S. (2005). Hubungan Antara Kenaikan Berat Badan, Lingkar lengan atas, Kadar Hemoglobin Ibu Hamil Trimester III dengan Berat Bayi Lahir di Puskesmas Ampel I Boyolali 2005. *Jurnal Semarang*.
- Sudarto, S. (2002). Jaringan Syaraf Tiruan (Sebuah Teori).
- Sutarjo, U. S. (2014). *Profil Kesehatan Indonesia Tahun 2014*. Jakarta: Kementerian Kesehatan Republik Indonesia.
- Wiknjosastro, H. (2002). *Ilmu Kebidanan*. Jakarta: Yayasan Bina Pustaka Sarwono Prawirohardjo.
- Wuryandari, M. D., & Afrianto, I. (2012).

Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation dan Learning Vector Quantization pada Pengenalan Wajah. *Jurnal Komputer dan Informatika*.

Yasin, H., & Aspriyanti, D. (2017). Klasifikasi Data Berat Bayi Lahir Menggunakan Weighted Probabilistic Neural Network (WPNN). *Media Statitiska*.